

Univerzita Hradec Králové
Fakulta informatiky a managementu
Katedra informačních technologií

Modelování dopadů šíření COVID na pivovarnictví

Diplomová práce

Autor: Bc. Lukáš Florner, DiS.
Studijní obor: 1802T001 / Aplikovaná informatika


Vedoucí práce: doc. RNDr. Kamila Štekerová, PhD.

Hradec Králové

červenec 2021

Prohlášení:

Prohlašuji, že jsem bakalářskou/diplomovou práci zpracoval/zpracovala samostatně a s použitím uvedené literatury.

A handwritten signature in blue ink, appearing to be 'L. Florner', written over a horizontal line.

V Hradci Králové dne: 14.11.2021

Lukáš Florner

Poděkování:

Děkuji vedoucí diplomové práce doc. RNDr. Kamile Štekerové Ph.D.
za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Anotace

Diplomová práce řeší simulaci multiagentového systému v jazyce Python a frameworku MESA. Jako konkrétní aplikaci jsem si vybral model dopadů šíření epidemie COVID-19 na pivovarnictví. Při řešení byly použity charakteristiky onemocnění, rozložení populace, návyky v konzumaci piva a systém opatření proti šíření epidemie – vše převzaté z veřejně dostupných lékařských a statistických zdrojů. Výsledkem je funkční model demonstrující propady v odbytu modelového pivovaru v závislosti na rozsahu epidemie, přijatých opatřeních proti jejímu šíření a chování agentů.

Klíčová slova

multiagentový systém, MESA, python, ABMS, covid, epidemie, pivo, simulace

Annotation

Title: Simulation of COVID spread impacts on brewing industry

Diploma thesis is focused on a simulation of multi-agent system in Python language with help of Mesa framework. As a specific application, I created a model of COVID-19 epidemic spread affecting brewing industry. The solution uses disease characteristics, population distribution, beer consumption habits and a system of precautionary measures against the spread of the epidemic - all taken from publicly available medical and statistical sources. The result is a working model demonstrating effects on sales of a model brewery depending on epidemic phase, precautionary measures against its spread and agents' behavior

Keywords

Multi-agent based system, MESA, python, ABMS, covid, epidemic, beer, simulation

Obsah

Úvod.....	1
1 Teoretická část.....	3
1.1 SARS-CoV-2	3
1.1.1 Základní charakteristika.....	3
1.1.2 Způsoby přenosu	4
1.1.3 Inkubační doba a imunita	5
1.1.4 Rozdělení obyvatel podle ohrožených skupin.....	6
1.2 Epidemiologická opatření	7
1.2.1 Omezení mobility.....	7
1.2.2 Trasování a projekt Chytrá karanténa	10
1.2.3 Sociální distancování	14
1.2.4 Ochrana ohrožených skupin	16
1.2.5 Ochrana dýchacích cest	17
1.2.6 Testování	19
1.2.7 Sektorová omezení	19
1.3 Ekonomické následky pandemie	21
1.3.1 Pivovarnictví v době pandemie	24
1.3.2 Pivo v české populaci	25
1.4 Matematické modelování epidemie.....	26
1.5 Multiagentové modelování.....	27
1.5.1 Modelování vztahů	28
1.5.2 Rozhodování agentů	29
1.5.3 Vstupní data modelů	29
1.5.4 Agentový model SIR.....	31
1.5.5 Agentový model SEIR a objektový přístup.....	32
1.5.6 Agentové modely ve frameworku MESA.....	38
1.5.7 Další příklady agentových modelů.....	40
1.6 Framework MESA.....	41
2 Praktická část	44
2.1 Představení vlastního modelu – ODD protokol	44
2.1.1 Účel	45
2.1.2 Entity a stavové proměnné.....	45

2.1.3	Popis procesu a časování akcí.....	75
2.1.4	Návrhové vzory.....	83
2.1.5	Vstupní data a inicializace	97
2.1.6	Submodely protiopatření	98
2.2	Ovládání a volba simulačních scénářů.....	103
2.2.1	Volba Generátor / Simulátor	104
2.2.2	Volba typu simulace	104
2.2.3	Volba počtu kroků simulace	104
2.2.4	Volba hodnoty seedu.....	104
2.2.5	Volba velikosti populace.....	104
2.2.6	Volba scénářů protiopatření.....	105
3	Výsledky modelu.....	110
3.1	Přehled testovaných scénářů.....	110
3.1.1	Samostatná protiopatření	110
3.1.2	Výsledek simulací samostatných protiopatření	114
3.1.3	Kombinovaná protiopatření	125
3.1.4	Výsledek simulací kombinovaných protiopatření	127
3.1.5	Shrnutí výsledků simulací	129
4	Závěr	131
5	Seznam použité literatury	134
6	Přílohy.....	143

Seznam obrázků

Obrázek 1 - Community Mobility Report pro ČR.....	9
Obrázek 2 - Stringency index	20
Obrázek 3 - Rushin index ČNB	22
Obrázek 4 - Změny v ubytovacích službách Airbnb	23
Obrázek 5 - Dopad na sektor pohostinství.....	23
Obrázek 6 - Schéma koloběhu peněz v simulaci	35
Obrázek 7 - Schéma epidemiologického modelu SEIR.....	39
Obrázek 8 - Rozdělení agentů podle věkových kategorií	46
Obrázek 9 - Rozdělení domácností	47
Obrázek 10 - Schéma Generátoru.....	57
Obrázek 11 - Pořadí a výpočet milníků onemocnění.....	76
Obrázek 12 - Schéma procesu infekce a výpočet infectious_rate	78
Obrázek 13 - Schéma činností Simulátoru	79
Obrázek 14 - Rozdělení akcí mezi agenty a model.....	80
Obrázek 15 - Sekvenční diagram běhu Simulátoru	81
Obrázek 16 - Sekvenční diagram metody infect_heal_or_die	82
Obrázek 17 - síťový graf sociálních vazeb.....	89
Obrázek 18 - Schéma protipatření testováním.....	100
Obrázek 19 - Schéma protipatření karanténou	101
Obrázek 20 - Schéma protipatření omezením mobility	102
Obrázek 21 - Schéma protipatření trasovací aplikací.....	103
Obrázek 22 - Porovnání výsledků samostatných protipatření.....	114
Obrázek 23 - Předpokládané průběhy epidemie.....	117
Obrázek 24 - Skutečný průběh epidemie v ČR	117

Obrázek 25 - Průběh epidemie ve scénáři lockdown!1	118
Obrázek 26 - Průběh epidemie ve scénáři lockdown!10	119
Obrázek 27 - Průběh epidemie ve scénáři sector_w!1	121
Obrázek 28 - Průběh epidemie ve scénáři mask_i!1	122
Obrázek 29 - Průběh epidemie ve scénáři mask_r!1	123
Obrázek 30 - Průběh epidemie ve scénáři app_qd!1	124
Obrázek 31 - Porovnání kombinovaných scénářů se základními scénáři	127
Obrázek 32 - Průběh epidemie ve scénáři sector_r!1,mask_r!1,test_dw!0	128

Seznam tabulek

Tabulka 1 - Epidemiologická data ČR k 1.12.2020 dle věkových skupin.....	6
Tabulka 2 - Typy agentů použitých v modelu SEIR.....	33
Tabulka 3 - Simulované scénáře a opatření v modelu SEIR.....	35
Tabulka 4 - Atributy klíče populace v config_gen.json	48
Tabulka 5 - Atributy klíče domacnosti v config_gen.json.....	50
Tabulka 6 - Atributy klíče imunita v config_gen.json.....	51
Tabulka 7 - Atributy klíče pivo v config_gen.json.....	51
Tabulka 8 - Struktura souboru mobilita.csv.....	52
Tabulka 9 - Struktura klíče podniky v config_gen.json	54
Tabulka 10 - Atributy klíče firmy v config_gen.json	54
Tabulka 11 - Atributy třídy BeerAgent.....	58
Tabulka 12 - Atributy třídy BeerModel.....	64
Tabulka 13 - Atributy epidemiologických opatření	69
Tabulka 14 - Parametry souboru s výsledky každého kroku simulace	90
Tabulka 15 - Atributy souboru s postupem infekce v populaci.....	93
Tabulka 16 - Atributy souboru s porovnáním všech simulovaných scénářů	94
Tabulka 17 - Přehled parametrů protiopatření pro aplikaci v modelu	105

Úvod

Česká republika, rok 2019. 10 694 000 obyvatel, z toho 19,9 % starších 65 let a 1,71 milionu ještě nebylo ani 15 let [8]. Každý z obyvatel, včetně kojenců, vypil v roce 2019 v průměru celých 142 litrů piva, přičemž v restauracích kvůli tomu umazal 99 půllitrů a jednu dvoudecku navrch [9]. Restaurace byly otevřeny všem zájemcům dle ochoty, času, nálady provozovatele a přísnosti místních předpisů... Takový byl rok 2019. A pak se zjevil COVID-19. Nejprve ve vzdálené Říši středu, spíše v amatérských videích a v hrůzu nahánějících statusech na sociálních sítích než v oficiálních prohlášeních tamních autorit. Někomu bylo už v té chvíli jasné, že díky celosvětovému pohybu obyvatel, služeb a zboží je jen otázkou času, než se nová a vysoce nakažlivá nemoc přelije přes cimbuří Velké čínské zdi. Někdo se tomu jen smál a došlo mu to až s nárazem do globalizované reality, nejspíš někdy na přelomu února a března 2020. A jsou jistě i lidé, kteří na COVID-19 nevěří dodnes.

Do lidského světa, který se obecně vyznačuje značnou mírou nejistot, přinesl COVID-19 nejistoty ještě větší. Nejen díky dosud ne úplně známým charakteristikám nemoci, její inkubační době, existenci/neexistenci super-přenašečů. . . Ale i kvůli pandemickým plánům nedostatečně připraveným na tak masivní katastrofu, kvůli politické i mediální nestabilitě, a nakonec i kvůli individuálnímu chování obyvatel. Výsledkem je chaos, nebo spíš a mnohem lépe řečeno – komplexní systém. Systém, jehož jednotlivé části se snaží vyřešit svůj problém (ať už jde o omezení šíření onemocnění, o vyhnutí se kolapsu zdravotnictví, nebo o omezení ekonomických ztrát, či třeba jen o prostý boj za osobní svobodu v podobě záměrného nedodržování vyhlášených opatření). Systém, ve kterém nikdo nemá absolutní kontrolu nad událostmi, ani klíč k přesným informacím a nejspíš ani k jediným správným rozhodnutím. Protože žádná z částí systému není izolovaná a vzájemně se ovlivňují, efekty jednotlivých kroků se skládají jako vlnky na hladině rybníka zasaženého hned několika hrstmi kamenů a kamínků vrženými z různých stran, v různých časech, různými lidmi a s různou silou. Popsat takové interference pomocí matematických a statistických metod je nesmírně složitý úkol (ne-li přímo nemožný) a ještě mnohem náročnější je odhadnout další vývoj celého systému. Ať už jde o rybník, nebo o lidskou společnost, díky ohromnému množství proměnných můžeme

chování a vývoj celého systému jen odhadovat. Ruku v ruce s tím ale přichází mnohem palčivější otázka – jak takový systém řídit? Jak ho nastavit, aby poskytoval optimální výsledky? A jde to vůbec?

A právě v tomto bodě přichází ke slovu multiagentové modely a simulace – Agent-based modelling and simulation – Multiagentní modelování a simulace (ABMS). Nechci tím říct, že ABMS je ono toužebně hledané řešení a odpověď na každou otázku (není to kladivo na každý hřebík). I ABMS pracuje s mnoha zjednodušeními a tím pádem nemůže popsat realitu naprosto přesně. Může ale nabídnout jiný pohled, a i při značném zjednodušení problému se lze dobrat výsledkům odpovídajícím skutečnosti a predikcím chování systému za změněných podmínek. Díky ABMS a posunu ve výkonnosti výpočetní techniky od konce 20. století můžeme úspěšně a poměrně snadno modelovat i systémy, jejichž matematické řešení by bylo velmi obtížné [62].

V této práci se budu zabývat právě modelováním komplexního systému. Cílem je sestavení, spuštění a vyhodnocení modelu hypotetické populace s alespoň tisíci obyvateli (agenty) s věkovou strukturou a pivními návyky odpovídajícími obyvatelstvu ČR. Pivo jsem zvolil jako zajímavý a široce využívaný obchodní artikl, národní nápoj a komoditu s velmi dobře dostupnými statistickými údaji (a taky mě téma piva baví o něco víc než kupříkladu téma prodejnosti koksovaného uhlí v čase globálního oteplování). Součástí řešení je také prezentace a vysvětlení výsledků s identifikací nejdůležitějších parametrů a nástinem dalších možností optimalizace řešení.

1 Teoretická část

Teoretická část této práce shrnuje nejdůležitější poznatky, informace a souvislosti platné v době tvorby této práce a potřebné k sestavení a zhodnocení modelu. Kapitola 1.1 obsahuje stručnou charakteristiku viru SARS-CoV-2 a onemocnění Covid-19, mechanismy přenosu, detekce a popis ohrožených skupin. Kapitola 1.2 představuje nejrozšířenější epidemiologická opatření, přičemž největší prostor je věnována omezením mobility a projektu Chytrá karanténa, resp. jeho ekvivalentům v jiných zemích. Úlohou kapitoly 1.3 je shrnutí dopadů pandemie onemocnění Covid-19 na hospodářství. Zvláštní pozornost je pak věnována pivovarnictví. Kapitola 1.4 popisuje problematiku modelování epidemie. Velmi stručně je zmíněna metoda matematického modelování a mnohem širší prostor je věnován několika agentovým modelům, které zpracovávají problematiku modelování epidemie onemocnění Covid-19. V samém závěru kapitoly (a celé teoretické části) je uveden stručný popis frameworku MESA, ve kterém je zpracován model z praktické části studentské práce.

1.1 SARS-CoV-2

Virus SARS-CoV-2 způsobující onemocnění Covid-19 byl v lidských pacientech poprvé objeven v hlavním městě čínské provincie Chu-Pej Wu-Chanu na podzim roku 2019 a oficiálně Čínská lidová republika přiznala šíření nové vysoce nakažlivé nemoci způsobené novým typem koronaviru až v závěru roku. V ČR byl první případ onemocnění zaznamenán 1.3.2020 a World Health Organization – Světová zdravotnická organizace (WHO) vyhlásila v souvislosti s celosvětovým rozšířením nemoci Covid-19 11.3.2020 pandemii [10]. Od té doby se podle oficiálních statistik celosvětově nakazilo přes 243 950 000 lidí a více než 4 950 000 osob podlehlo komplikacím, které onemocnění provází (údaj k 22.10.2021, zdroj: worldometers.info/coronavirus).

1.1.1 Základní charakteristika

Nově objevený koronavirus SARS-CoV-2 je zástupcem širší čeledi Coronaviridae obsahující 39 známých druhů jedno vláknových RNA virů. V lidské

populaci se již dříve rozšířily některé z koronavirů, kterou jsou označovány za původce respiračních onemocnění, a to od těch s lehkým průběhem a nízkou nebezpečností (např. původci rýmy jako je alfa-koronavirus HCoV-229E nebo beta-koronavirus HCoV-OC43), až po respirační onemocnění vyvolávající zápal plic, multiorgánové selhání, septický šok apod. Do této druhé skupiny patří mimo SARS-CoV-2 i koronaviry SARS-CoV a MERS způsobující závažná onemocnění SARS s úmrtností 6.7-10 % [13] a MERS s úmrtností přes 35 % [11].

SARS-CoV-2 se od svého nejbližšího příbuzného SARS-CoV liší v průběhu onemocnění, kdy generuje vyšší počty asymptomatických přenašečů a má delší inkubační dobu. Vrcholu virulence navíc dosahuje před projevením příznaků. Zejména tato vlastnost napomáhá mnohem snazšímu šíření v populaci. K průniku do buňky využívá SARS-CoV-2 receptor ACE-2 (spike protein), který je v lidských buňkách poměrně běžným. To je zřejmě důvodem, proč Covid-19 napadá nejen dýchací soustavu, ale může napadnout prakticky všechny životně důležité orgány [14]. Při porovnání s virem sezónní chřipky (čeleď Orthomyxoviridae) je u SARS-CoV-2 vyšší celková závažnost onemocnění, a to zejména pro starší věkové skupiny nebo osoby s přidruženými onemocněními. 5-10 x vyšší je i celková mortalita (0,5-1 %) [14]. Již z těchto informací je patrné, že vysoká publicita, která se SARS-CoV-2 dostává, má své opodstatnění

1.1.2 Způsoby přenosu

Nejvýznamnějším způsobem přenosu viru SARS-CoV-2 je přenos vzduchem [15]. Prvním typem takového přenosu je přenos pomocí kapének [12] (částice viru obalené vrstvou vydechované tekutiny o průměru větším než 5 μ m, přičemž samotný vir má velikost 70-90 nm [11]). Kapénky jsou do vzduchu uvolňovány nejen při kýchání a kašlání, ale i při dýchání, mluvení, křiku nebo zpěvu, přičemž čím vyšší je intenzita dané aktivity, tím vyšší je i emise kapének. Účinná vzdálenost pro kapénkový přenos nákazy je odhadována na 1.5-2 m [10]. Druhým významným způsobem přenosu vzduchem je přenos pomocí aerosolu (průměr částice menší nebo roven 5 μ m). Ty se také uvolňují ve výše zmíněných činnostech a jde i o vysychající kapénky [12]. Jejich nebezpečnost je v tom, že se mohou dostat dále do dýchacích cest nově nakaženého a způsobit závažnější infekci [16]. Ve vzduchu navíc

vydrží aerosol déle než těžší kapénky – u kapének se jedná o několik minut, zatímco u aerosolů až o několik hodin [16]. Ukazuje se přitom, že aerosol se uvolňuje více při mluvení a zpěvu (80-90 % vydechovaných částic je dokonce menší než 1 μ m) než při kašli nebo kýchání [16]. Výrazně přitěžujícím faktorem vedoucím ke zvýšení rizika nákazy je pak vliv prostředí. Riziko roste zejména v případě uzavřených, špatně větraných nebo naopak klimatizovaných prostor s recirkulací vzduchu [10]. Poměrně masivní přenos byl zaznamenán i v hromadných dopravních prostředcích při použití vzduchové recirkulace [16], ve sportovních zařízeních jako jsou tělocvičny a fitcentra [17], nebo při lékařských zákrocích [18].

Přenos pomocí povrchů je podle významu třetí možností infekce. Na površích může být virus aktivní i několik hodin (např. 4 hodiny na mědi, 2 dny na površích z plastu). K infekci pak dochází při doteku očí, úst nebo nosu. V porovnání s kapénkovou nebo aerosolovou infekcí se však jedná o vzácnější přenos [10].

1.1.3 Inkubační doba a imunita

Inkubační doba onemocnění do projevení příznaků je 5-14 dní s mediánem 7.6 dnů a nejvyšší virulence, resp. virové nálože, Covid-19 dosahuje 1-3 dny před projevením příznaků [10], což činí kontrolu epidemie velmi obtížnou [20]. Uvádí se také, že 1-20 % nakažených je zodpovědných za 80 % všech infekcí [19]. Popsán je příklad, kdy jediný asymptomatický přenašeč nakazil při pěvecké zkoušce více než polovinu ze 61členného pěveckého sboru [10]. Všeobecně známý je v ČR i případ rozšíření nákazy mezi návštěvníky pražského klubu Tachtle Mechtle během jediné noci. U Covid-19 je tedy významný vliv tzv. superpřenašečů – jedinců s asymptomatickým průběhem onemocnění ale masivně uvolňujících viry ze sliznic, nebo jedinců krátce před projevením symptomů, kdy produkce virových partikulí dosahuje maxima.

Problematická je zatím také odpověď na otázku, zda prodělání infekce znamená získání imunity a zejména jak dlouho tato imunitní ochrana trvá. SARS-CoV-2 je zcela novým patogenem a zkušenosti s jeho diagnostikou, léčbou i dlouhodobým působením netrvaly déle než od konce roku 2019. Ve světě zatím proběhlo několik studií imunity k SARS-CoV-2 a existuje zřejmě nemalá skupina lidí

(10-12 %), jejichž tělo po prodělaném onemocnění nevytvoří protilátky vůbec, a další skupině (27 %) zmizí protilátky za méně než půl roku [21], [22]. To by zhruba odpovídalo poznatkům o trvání imunizace proti méně nebezpečným koronavirům, kde byly doloženy reinfekce s frekvencí od 3 do 12 měsíců od prodělánání poslední epizody [23]. V literatuře se lze již setkat i s prokázanými případy reinfekce u SARS-CoV-2 [22], [24].

1.1.4 Rozdělení obyvatel podle ohrožených skupin

Samotná závažnost průběhu nemoci Covid-19 se liší podle věkových skupin, přičemž platí, že ohroženější jsou starší lidé, zatímco např. u dětských pacientů je průběh většinou asymptomatický. Výrazně přitěžujícím faktorem je mimo věku také mužské pohlaví, nemoci srdce a oběhové soustavy a nadváha s BMI \geq 30. Až poté následuje diabetes, chronická onemocnění plic a onkologická onemocnění [26].

Tabulka 1 - Epidemiologická data ČR k 1.12.2020 dle věkových skupin

Věk	Potvrzených případů Covid-19		Pravděpodobnost hospitalizace		Pravděpodobnost úmrtí při hosp.	
	Muži	Ženy	Muži	Ženy	Muži	Ženy
0-4	4 642	4 354	1.6	1.2	0.0	0.0
5-14	17 294	16 600	0.3	0.4	0.0	0.0
15-19	11 429	11 443	0.6	0.6	1.4	0.0
20-49	121 032	129 460	1.8	1.4	3.3	2.2
50-64	53 466	59 104	7.9	4.5	9.4	6.2
64-74	20 612	21 132	28.5	20.7	22.7	13.7
75+	14 988	25 703	51.6	38.3	39.4	29.6

V některých případech pak dochází k rozvoji nebo návratu přidruženého onemocnění až v průběhu probíhající infekce SARS-CoV-2 nebo po jejím skončení. Jako příklad lze uvést reaktivaci herpetické virové infekce (HSV) zejména v plicích postižených koronavirovou pneumonií, kde HSV pokračují v destrukci tkání i po odeznění Covid-19 [18]. Covid-19 má také může mít vliv na progresi onkologických

onemocnění [27], anebo na vznik a rozvoj diabetu [28] [29]. Dle některých poznatků může prodělání onemocnění navíc zvyšovat pravděpodobnost tvorby krevních sraženin, cévních mozkových příhod, onemocnění oběhové soustavy, chronických onemocnění plic, rozvoj duševních onemocnění nebo dlouhodobá smyslová postižení, a to i několik měsíců po prodělání nákazy a bez ohledu na závažnost průběhu [30] (problematika souhrnně označovaná jako long covid).

1.2 Epidemiologická opatření

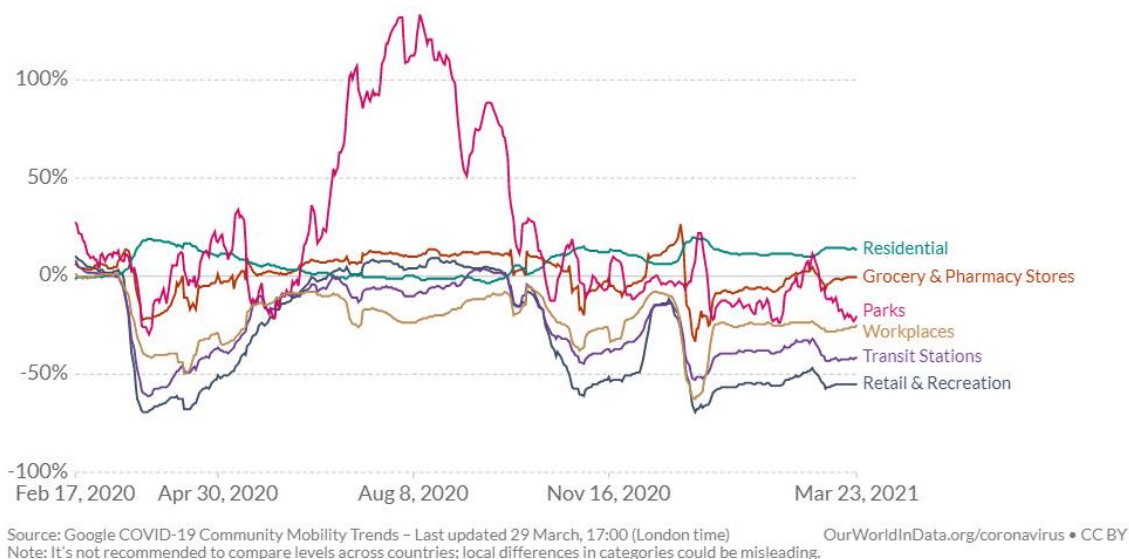
V případě nebezpečného a vysoce nakažlivého onemocnění, na které neexistuje specifická léčba, nebo je z finančních či jiných důvodů v dané lokalitě nedosažitelná, jsou epidemiologická opatření jedinou funkční zbraní proti masivnímu rozšíření infekce. Pomocí různě nastavených opatření lze pak v zásadě volit hned několik přístupů cílů – od úplné eliminace nákazy v daném prostoru, přes kontrolované šíření s co nejplošší křivkou nově nakažených nebo hospitalizovaných pacientů, až po cílené promoření společnosti a tím zajištění tzv. stádní imunity. Volba strategie podléhá místním přírodním, zdravotním, společenským, finančním i politickým podmínkám, vlastnostem patogenu a nebezpečnosti samotné infekce a je zajímavým námětem pro tvorbu epidemiologického modelu, model agentový nevyjímaje.

1.2.1 Omezení mobility

Omezení mobility obyvatel zahrnuje celou škálu opatření – od nařízené karantény pro pozitivně testované a osoby z nakažení podezřelé přes zákaz shromažďování nad určitý počet osob nebo omezení vycházení v nočních hodinách, až po úplný zákaz vycházení, kdy lidé mohou opustit své bydliště jen pro účely nákupu nezbytných prostředků nebo kvůli návštěvě lékaře. Platí, že čím přísnější omezení je, tím rychleji a výrazněji dochází k potlačení infekce. Je to ovšem také cesta s nejvyššími okamžitými ekonomickými náklady [5] (což neznamená, že se v delším horizontu ekonomicky ne-vyplatí – záleží na trvání omezení, na existenci přírodního rezervoáru infekce nebo podmínkách migrace a na dostupnosti léčby). Omezení může být přitom nařízené a případně vynucované represivními složkami daného státu, nebo ponecháno na dobro-volné bázi. Omezení mobility bylo v

průběhu pandemie v nějakém stupni aplikováno v každém vyspělém státě. V případě České republiky to bylo už v první vlně na jaře 2020 například úplné uzavření měst Uničov a Litovel, kdy byl zakázán vstup i odjezd z uzavřených lokalit i pohyb obyvatel po samotném městě, s nezbytnými výjimkami.

Důvodem bylo rozšíření nákazy importované místními turisty vracejícími se z Itálie a efekt uzávírky (tzv. lockdownu) byl pozorovatelný v rychlém zastavení komunitního šíření nákazy a postupné marginalizaci viru. Podobná situace nastala např. v únoru 2021 v Chebu, což dokládá přinejmenším dočasnou efektivitu tvrdých opatření. Vývoj mobility, resp. pohyb obyvatel je možné sledovat např. přes prostředky informačních technologií – k dispozici mohou být data mobilních operátorů, veřejné kamerové systémy, speciální aplikace apod. Lze pak nepřímo vyhodnocovat efekt i dodržování opatření. Příkladem takových aplikací je např. COVID-19 Community Mobility Reports – Google Mobility Report (GMR) vyhodnocující data uživatelů chytrých zařízení s operačním systémem Android a zapnutou lokační historií (LocationHistory). GMR zobrazuje změnu mobility obyvatel v daném dni proti stejnému dni v před-pandemické době (změna proti roku 2019). Protože GMR využívá jen data uživatelů služeb Google, neposkytuje přehled o lidech, kteří tyto technologie nepoužívají. Jedná se především o starší věkové skupiny, ve kterých nejsou tolik rozšířené chytré telefony - např. v roce 2019 využívalo chytrý telefon téměř 70 % osob starších 16 let, z toho v kategorii 65+ je to jen necelých 20 % a data v mobilním telefonu využívá zhruba 75 % z nich [33]. GMR je prezentován v přehledném reportu podle zemí a oblastí mobility (veřejná místa, rezidenční oblast, nákupní zóny atd.) [34]. Existují i výstupy a reprezentace dat založené na GMR, kde lze zobrazit celé sledované období od počátku pandemie. Např. přehled na datové platformě ourworldindata.org (Obrázek 1) představuje zobrazení tohoto rozsahu, navíc přepočítáno na sedmidenní klouzavý průměr. Tato metoda umožňuje snížit vliv mimořádných událostí – extrémů jako jsou např. velké hromadné akce (demonstrace, festivaly apod.), které zkreslují GMR zejména v rámci jednoho srovnávacího dne.



Obrázek 1 - Community Mobility Report pro ČR

Data z období 02/2020-03/2021 ukazují změny v mobilitě obyvatel v průběhu času z hlediska různých kategorií lokalit. Zdroj: převzato z [1]

Kategorie Parks představuje městské parky, chráněné krajinné oblasti, lesy a podobné lokace, Residential představuje bydliště, do kategorie Grocery, Pharmacy a Stores spadají obchody a obchodní centra s nezbytnými komoditami (potravin, léky, zdravotní materiál apod.), Workplaces jsou pracoviště, Transit Station zahrnuje veřejnou dopravní infrastrukturu (dopravní prostředky i např. nádraží) a Retail a Recreation zahrnuje služby, rekreační a zábavní zařízení a mimo jiné také restaurace a pivnice.

V grafu (Obrázek 1) je patrný propad pohybu zejména při první vlně pandemie na přelomu února a března 2020 a naopak nárůst pohybu obyvatel v kategorii Parks (zejména v souvislosti s počasím a ročním obdobím). Také je viditelný trend snížení mobility na pracovištích, částečně zřejmě z důvodu sektorových omezení a částečně kvůli masivnímu přechodu na home office v zaměstnáních, která to umožňují. Kategorie, která utrpěla z hlediska mobility největší ztráty, protože vykazuje největší propady i nejnižší průměrnou mobilitu, je Retail a Recreation. Přehledy a změny mobility silně korelují s průběhem epidemie Covid-19, ale liší se podle zemí a geografických a podnebních podmínek. Nárůst počtu nakažených snižuje mobilitu obyvatel ve zbytných kategoriích, a naopak zvyšuje přítomnost v bydlištích, případně ve volné přírodě (ačkoliv nelze říct, zda se jedná spíše o následek

centrálních nařízení a omezení, nebo o přirozenou snahu obyvatel vyhnout se nákaze). Také lze konstatovat, že omezení mobility koreluje se snížením tempa přenosu infekce [35].

1.2.2 Trasování a projekt Chytrá karanténa

S omezením mobility souvisí i problematika trasování, tedy vyhledávání kontaktů pozitivně testovaných, případně upozornění na možnost setkání se s nakaženým. Motivací k trasování je buď zajištění izolace a otestování všech osob, které se setkaly s potvrzeným nakaženým, nebo poskytnutí informace o možném rizikovém kontaktu s tím, že se pak jedinec rozhodne, zda se nechá otestovat nebo alespoň omezí sociální kontakty. Dopad na mobilitu obyvatel je tedy patrný, přičemž v případě uspokojivé úrovně trasování může omezení mobility i výrazně limitovat. Využití informačních technologií je při trasování nezbytné ať už ve formě databází a dotazníků zdravotních služeb, nebo jako aplikace na koncových zařízeních. První metodou trasování je dotazování, které provádí např. hygienické stanice. V takovém případě zaměstnanec hygienické stanice vyplňuje s pozitivně testovaným jedincem dotazník, jehož součástí je i dotaz na všechny kontakty, se kterými se nakažený setkal v posledních 5 dnech (intervaly se v jednotlivých zemích liší). Nevýhodou tohoto typu trasování je, že vyžaduje úplnou spolupráci dotazovaného, který si musí vzpomenout na všechny kontakty a být ochotný sdílet informace, případně musí povolit využití dat telefonních operátorů jako je tomu v případě vzpomínkových map [36]. Kapacita systému náročného na lidský kapitál je pak rychle vyčerpána v případě masivního komunitního šíření infekce. V České republice je tak i z tohoto důvodu k dispozici také formulář pro tzv. samotrasování, který nakažený vyplní a pracovník hygienické stanice pak při následném telefonickém dotazování jen doplní případné detaily.

Součástí trasování je i aplikace eRouška nebo služba trasování poskytovaná přes aplikaci Mapy.cz, kterou si může každý provozovatel chytrého mobilního telefonu nainstalovat a aktivovat na svém mobilním zařízení. Samotrasování, eRouška a spolupráce s mapovou aplikací mapy.cz společnosti Seznam a.s. tvoří pilíře projektu Chytrá karanténa. Ten se inspiroval v podobných projektech v Korejské lidové republice, Německu nebo v Singapuru, který pomocí státní

agentury GovTech vyvinul trasovací aplikaci TraceTogether a uvolnil ji i pro použití v jiných zemích jako opensource (možnosti použití zdrojového kódu TraceTogether využila např. Austrálie) [37]. Trasování pomocí aplikace eRouška je založeno na výměně identifikátorů mobilních telefonů (v podobě šifrovaných klíčů) z instalací eRoušky v okolí uživatele, a to pomocí technologie Bluetooth a na základě Google/Apple API (tzv. Exposure Notification System). To je rozhraní vyvinuté a dále zlepšované oběma jmenovanými společnostmi mimo jiné pro měření vzdálenosti mobilních zařízení s cílem poskytnout vládám a soukromým organizacím standardizovaný rámec pro vývoj vlastních trasovacích aplikací a současně zajistit maximální míru ochrany osobních údajů uživatelů.

V případě pozitivního PCR testu jedinec obdrží informační SMS s kódem pro zadání do aplikace eRouška a po zadání tohoto kódu dojde k odeslání informací o okolních zařízeních uložených v historii zařízení na server. Informace se zpracují a odesílají na aktivní zařízení, kde dojde k porovnání databází a případně i k upozornění na kontakt s rizikovou osobou. Data jsou přitom anonymní a neumožňují přímou identifikaci nakaženého [38]. Na podobném principu funguje i aplikace TraceTogether, která také využívá modul Bluetooth, narozdíl od eRoušky ale není postavena na Google/Apple API a využívá vlastní rozhraní [39]. Volba Bluetooth jako technologie pro trasování je dána hned několika aspekty - jednak je Bluetooth přítomný ve většině chytrých telefonů, jednak signál Bluetooth funguje jen na omezenou vzdálenost a je tedy v jistém souladu s přenosovou vzdáleností onemocnění Covid-19 a v neposlední řadě nejde o geolokaci ve smyslu sledování GPS souřadnic uživatele (byť při sběru dat od velkého množství uživatelů a při použití pokročilých analytických metod lze zpětně identifikovat a trasovat konkrétní uživatele i podle dat z Bluetooth [37]).

Aplikace od společnosti Seznam a.s. využívá polohová data uživatelů aplikace Mapy.cz. Pokud uživatel souhlasí a má zapnutou geolokaci (GPS modul), je v případě pobytu v blízkosti pozitivně testované osoby upozorněn pomocí notifikace.

Indická trasovací aplikace Aarogya Setu pak využívá vlastně všechny přístupy současně – jednak detekuje mobilní telefony s instalovanou aplikací v okolí pomocí

Bluetooth technologie a jednak využívá a odesílá i geolokační data z modulu GPS. Navíc je v aplikaci přístupný i sebetrasovací formulář a dotazník zdravotního stavu. Důvodem a vlastně i výhodou takového řešení je přítomnost všech důležitých informací a otázek na jednom místě a díky kombinaci Bluetooth a GPS dat je také možné rychle identifikovat clustery – místa s vysokou koncentrací nakažených, případně jejich výskyt předvídat a omezit falešně pozitivní nebo negativní hlášení [36].

Singapur pak uvedl do provozu mimo aplikace samotné i nositelnou elektroniku s funkcionalitou odpovídající funkcionalitě TraceTogether - token s Bluetooth modulem schopným komunikace se serverem. Motivací k tomuto kroku bylo jednak technické omezení u telefonů Apple, které neumožňují (resp. v době psaní této práce neumožňovaly) kontinuální běh Bluetooth a také pokrytí skupin, které nemají z jakýchkoliv důvodů přístup k moderním technologiím (např. starší občané, chudí zahraniční pracovníci, nebo obecně občané, kteří nechtějí instalovat aplikaci na vlastní zařízení) [37].

Aby systém trasovacích aplikací plně fungoval, musí být zastoupení instalovaných aplikací v populaci co nejširší – uvádí se alespoň 60% [37]. Podle MIT Technology Review Covid Tracing Tracker je to cíl, který se k lednu 2021 podařilo splnit jen v Kataru a Singapuru. V Kataru celková penetrace přesáhla 90 %, aplikace je tam však povinná při pohybu mimo domov a porušení povinnosti je velmi tvrdě postihováno [41]. V Singapuru využívalo na počátku roku 2021 aplikaci nebo nositelný token 80% obyvatel, přičemž ještě 3 měsíce po uvedení aplikace to bylo necelých 25 %. Zvýšení počtu uživatelů je dáno částečně distribucí tokenů pro obyvatele, kteří nemohou nebo nechtějí instalovat aplikaci, částečně oznámením vlády, že aplikace nebo token bude v budoucnu povinná a nejspíš i opakovaným ujištěním, že data z aplikací a tokenů budou využita jen pro zdravotní účely. Z evropských zemí je nejvyšší zastoupení aplikace v populaci ve Finsku a to u 45% obyvatel. Např. v Německu je to přes 22.6% obyvatel [42] a v České republice je zastoupení necelých 16 % (údaj z aplikace eRouška k 1.4.2021).

Trasovací aplikace musí být kontinuálně nebo v rozumných intervalech (ideálně denně) připojené k internetu z důvodu výměny dat mezi aplikací

a serverem. Podmínkou použitelnosti tohoto přístupu je také spolupráce pozitivně testovaných – při kontaktování zaměstnancem hygienické služby (resp. jejich ekvivalenty mimo ČR) musí nakažený sdělit, že má aplikaci nainstalovanou a umožnit identifikaci zařízení. V případě eRoušky stačí zadat kód z SMS obdrženy po potvrzení positivity a data odeslat na server. Ve všech zemích s podobným nastavením dobrovolnosti instalace přitom trasovací aplikace naráží na dva podobné a vzájemné protichůdné problémy – nedůvěra uživatelů v instituce a obava ze sledování na straně jedné a nespokojenost mnohdy početných skupin uživatelů s omezenými funkcionalitami aplikací nebo přímo se samotnou dobrovolností instalace na straně druhé. Stížnosti jedné i druhé strany přitom často pramení spíše z nepochopení a neznalosti funkce aplikací. Tento problém se týká i velmi rozvinutých států se stabilním právním i socioekonomickým prostředím jako je např. Německo nebo Nový Zéland. I zde existují požadavky na odstranění dobrovolnosti (minimálně prostřednictvím povinnosti instalace a aktivace aplikace při vstupu do veřejných prostor jako jsou budovy úřadů, prostředky hromadné dopravy apod.) a současně jsou již samotné tyto záměry a diskuze kritizovány kvůli možnému porušování lidských práv, z důvodu obav ze zneužití dat i z důvodu nerovnoměrné distribuce informačních technologií ve všech vrstvách společnosti [43]. Výsledkem působení obou protichůdných proudů je pak zřejmě nižší zastoupení aplikací ve společnostech. Obava ze ztráty soukromí nebo ze zbytečnosti omezené aplikace a z toho plynoucí odmítání instalace (nebo nositelné elektroniky) přitom může paradoxně vést k déletrvající ztrátě občanských i osobních svobod a zejména k hlubším ekonomickým škodám z důvodu déletrvajících a razantnějších protiepidemických opatření, než by tomu bylo v případě dostatečného rozšíření trasování [38].

Na nezanedbatelnou efektivitu trasovacích aplikací ukazuje například 24% poměr pozitivně testovaných osob doporučených k testu prostřednictvím aplikace Aarogya Setu, zatímco v populaci testované na základě jiných doporučení byl poměr zachycených pozitivních testů 5x nižší [36], nebo téměř 79 000 anonymních oznámení od pozitivně testovaných a přes 318 000 upozornění na setkání s

pozitivně testovanou osobou v aplikaci eRouška (údaje z aplikace eRouška k 1.4.2021).

Trasovací aplikace mají také nespornou výhodou ve flexibilní reakci na změny v šíření epidemie nebo charakteristik původce onemocnění (ať již z důvodu nových vědeckých poznatků nebo kvůli novým mutacím). V takovém případě lze provést update prostředí a změnit např. limitní dobu expozice nebo přepočítat třídy vzdáleností (u eRoušky je po poslední aktualizaci nejvyšším stupněm rizika z důvodu rychlého šíření britské varianty SARS-CoV-229 označena vzdálenost ≤ 2 m po dobu ≤ 7 minut), případně uvést nové funkcionality jako je využití čtečky QR kódů pro evidenci přítomnosti ve veřejných budovách nebo implementaci upozornění na pozitivní výsledek antigenního i PCR testu, jako se plánuje v případě Německé aplikace Corona-Warn-App [44] [45]. Uvažovat by se dalo i o notifikacích pro uživatele nad rámec hlášení o kontaktu s pozitivně testovanou osobou (např. upozornění na místo se statisticky vyšším rizikem nákazy, na nedodržení bezpečné vzdálenosti apod.), nebo možnost instalace nebo nastavení různých úrovní anonymity podle preferencí uživatele.

Mimo speciálních aplikací jsou k dispozici i další nástroje pro boj s epidemií, které souvisí s trasováním. V několikrát zmíněném Singapuru jde např. o systém SaveEntry, který sestává z QR kódu umístěného na vstupech a výstupech z míst s vyšší koncentrací lidí (úřady, sportoviště, pracoviště, ale i restaurace a bary). Každý příchozí má povinnost QR kód načíst prostřednictvím chytrého telefonu a zadat a odeslat údaje potřebné pro kontaktování v případě výskytu pozitivně testované osoby v daném prostoru a odpovídajícím čase [46]. Systém je v různých variantách aplikován i v jiných státech, nebo se o jeho aplikaci uvažuje, nicméně stále zůstává problém s lidmi, kteří nejsou vybaveni potřebnou technologií (a musí data vyplnit ručně), se zabezpečením osobních informací a případně i s dostupnou legislativou.

1.2.3 Sociální distancování

Zatímco omezení mobility je cíleno na co nejširší omezení mezilidského kontaktu, sociální distancování představuje zásadu udržování rozestupů mezi

osobami, které spolu nesdílejí stejnou domácnost, a to na vzdálenost 2 metrů, resp. 6 stop [47]. Argumentem pro toto opatření je skutečnost, že SARS-CoV-2 se přenáší jako kapénková infekce a vzdálenost 2 metrů je dostatečná k tomu, aby se kapénky nakaženého nedostaly do dýchacích cest jedinců v okolí [20].

Odhadovaným efektem sociálního distancování je snížení přírůstku nakažených o 1 % denně (0.9-2 %) od 4. dne po zavedení opatření a snížení mortality zejména na přelomu prvního a druhého týdne od realizace opatření (od 10. dne po zavedení opatření již nebyl pozorován statisticky významný rozdíl v mortalitě) [48]. V případě masivního šíření onemocnění se tento v počátku téměř zanedbatelný rozdíl projeví podobně exponenciálním růstem jako epidemie samotná. Např. pokud se 7 dní po zavedení sociálního distancování díky tomuto opatření nenakazí 1 600 osob, vede to ke snížení počtu nakažených o 55 000 osob na konci následujícího týdne a o 600 000 po 21 dnech od zavedení opatření [48].

Sociální distancování (a přeneseně vlastně jakákoliv protiepidemická opatření, která nevedou k úplné eradikaci nebo alespoň podstatnému omezení viru) mohou mít ale i poměrně nepříjemný efekt, který úzce souvisí s délkou a populačním rozložením imunity pro prodělaném onemocnění a kapacitou zdravotního systému. Jak ukazuje studie [20] založená na matematickém modelu epidemie SEIRS, regresní analýze, struktuře společnosti a zdravotnictví v USA a na známých vlastnostech lidských koronavirů HCoV-OC43, HCoV-HKU1 a SARS-CoV-2, dochází v případě krátkodobé imunity (1-2 roky) k periodickým epidemiím, jejichž průběhy a dopad na obyvatelstvo se od první vlny epidemie příliš neliší. Při kratším trvání imunity pak může dojít k vymizení sezónnosti epidemických vln a epidemie probíhají s menšími výkyvy po většinu roku. V případě příliš brzkého uvolnění opatření sociálního distancování pak překvapivě dochází i k rychlému návratu epidemie dokonce s horším průběhem, než pokud nebyla epidemie vůbec omezována (zde je úzká souvislost s volnou kapacitou zdravotního systému a časovou prodlevou mezi nákazou a hospitalizací). Výsledky také již méně překvapivě dokazují, že čím větší je zpoždění v přijímání opatření, tím déle musí opatření trvat a tím větší je počet obětí a zatížení zdravotních systémů. To ovšem zjevně platí pro všechny protiepidemická opatření.

Odhad efektu sociálního distancování je velmi problematický, a to zejména z důvodu aerosolového mechanismu přenosu SARS-CoV-2 v uzavřených prostorech nebo prostorech se vzduchovou recirkulací a obecně v prostorech s vyšší koncentrací nakažených, jako jsou např. nemocniční budovy (viz. kapitola 1.1.2). Jde o situace, kdy se nákaza může šířit na mnohem větší vzdálenosti, případně vůbec nevyžadují osobní kontakt s nakaženým. Otázkou je také vliv povětrnostních podmínek (např. vlhkost a teplota vzduchu, směr a rychlost větru, intenzita slunečního záření apod.).

1.2.4 Ochrana ohrožených skupin

Ohrožená skupina představuje tu část obyvatel, kteří jsou nejvíce vnímaví vůči viru a hrozí jim nejzávažnější následky, včetně úmrtí. Definice WHO však kromě těchto skupin uvádí i osoby žijící v sociálně ohrožené skupině (bezdomovci, uprchlíci apod.), osoby pobývajících v uzavřených prostorech s vysokou sociální interakcí (domovy seniorů, detenční zařízení apod.) a osoby dlouhodobě se zdržující v prostorech s vysokou koncentrací virových partikul (pracovníci ve zdravotnictví a sociálních službách) [49]. Další informace o ohrožených skupinách byly uvedeny v kapitole 6. Ochrana ohrožených osob je realizována pomocí izolace klíčových zařízení (nemocnice, domovy pro seniory apod.), vybavení ohrožených skupin ochrannými pomůckami a omezením jejich mobility.

Z dosavadního průběhu epidemie je zřejmé, že cíle ochrany ohrožených skupin nejspíš není možné naplnit. Důvodem je zejména příliš velká skupina ohrožených osob - např. obezita spadající do rizikových faktorů je přítomna u 40% obyvatel ČR [25], obyvatel starších 65 let je 20 % [8], ne všichni pobývají v izolovatelných zařízeních, a i kdyby ano, zůstává otázka, kdo bude izolované skupiny obsluhovat. Klíčovou otázkou pak je i způsob ochrany zdravotního personálu, a to na všech úrovních a pracovištích, protože virová nálož v neřízeně proměřované populaci bude značná, prosté vybavení běžnými ochrannými prostředky je nejspíš nedostačující a vyčerpání kapacit zdravotních služeb vede ke značným zdravotním i materiálním škodám.

Jedno z doporučení WHO pro ochranu zdravotního personálu je totiž i odložení neakutních ošetření a preventivních prohlídek [49], což je z dlouhodobého hlediska opatření kontraproduktivní pro celou populaci. Z praxe také vyplývá, že v případě zavlečení nákazy, byť jediným infikovaným do chráněného prostředí dochází k rychlému rozvoji infekce mnohdy s devastujícími následky na celou chráněnou skupinu (z toho lze dovozovat, že před nákazou není možné se účinně chránit ani v rámci jedné domácnosti). V neposlední řadě je tu i otázka mutace viru v souvislosti s vyšším rozšířením nemoci v nechráněné části populace. A samozřejmě problém reinfekcí, problematika omezeného trvání imunity a z toho vyplývajících epidemických vln různých četností ale srovnatelných intenzit [20]. Izolace ohrožených skupin by pak mohla trvat neomezeně dlouho, nebo by bylo nutné ji periodicky opakovat vždy při nástupu další epidemické vlny.

O nefunkčnosti opatření ochrany ohrožených skupin nakonec svědčí i výsledky simulačních experimentů pomocí ABMS, kdy ani izolace skupiny seniorů nevedla k nižší mortalitě v dané skupině, narozdíl od jiných celopopulačních omezení [5].

1.2.5 Ochrana dýchacích cest

Ochrana před infekcí má i podobu osobních ochranných pomůcek a návyků. Dle doporučení WHO je pro snížení rizika přenosu nákazy důležité dodržování zásad jako je sociální distancování, ochrana dýchacích cest, časté větrání, vyhýbání se davům, pravidelné mytí nebo desinfekce rukou a etiketa kašlání [50].

Z uvedených doporučení byla již od začátku pandemie asi nejvíce diskutovaná problematika roušek. Bariérová ochrana dýchacích cest, tedy roušky, respirátory nebo obličejové štíty funguje na principu zpomalení proudu vzduchu vystupujícího při dýchání z plic. Společně se vzduchem dochází i ke zpomalení pohybu částic – kapének i aerosolu, které mohou být nosným médiem pro virus SARS-CoV-2 (ale i pro další původce vzduchem přenosných onemocnění). Tento jev a efekt bariérových ochranných pomůcek lze dokonce zobrazit pomocí Schilderové zobrazovací metody [51].

Většina materiálů použitých i pro domácí výrobu masek je schopná přímo zachytávat kapénky a skrz roušku do okolního prostředí uniká jen aerosol, a to při nižší rychlosti, než by tomu bylo bez bariér. Efektivita filtrace vystupujících plynů je přitom poměrně vysoká i u běžných materiálů. Např. obyčejné bavlněné tričko (resp. rouška ze stejného materiálu a ve stejné tloušťce) odfiltruje až 70 % virových partikulí (přenášených v kapénkách nebo aerosolu, zachycených na vláknech materiálu). Mnohem vyšší účinnosti, a to přes 96 %, dosahuje chirurgická rouška a s 94 % účinností si špatně nevede ani rouška vytvořená ze sáčku do vysavače s HEPA filtrem [52].

Studie [52] zkoumala filtrační schopnost bariérové ochrany v souvislosti s virem chřipky, ale vzhledem k totožnému mechanismu šíření je možné výsledky aplikovat i na SARS-CoV-2. Tomu odpovídají i výsledky studií provedených v průběhu pandemie onemocnění Covid-19. Například v Německém městě Jena došlo po zavedení nošení povinné ochrany dýchacích cest na všech místech, kde se mohou setkávat lidé nesdílející společnou domácnost, k razantnímu poklesu nových případů infekce. V celém Německu došlo v průběhu prvních 10 dnů od zavedení opatření o 2.3-13% pokles nových případů (parametry nařízení se mohou v decentralizovaném systému lišit v jednotlivých zemích federace). Denní snížení přenosu nákazy pak bylo odhadnuto na 40%. K nejvýraznějšímu poklesu nových nákaz (o 50 %) přitom došlo u skupiny osob nad 60 let [53]. Efekt opatření byl tedy dvojnásobný – došlo nejen k lepší ochraně ohrožené skupiny, ale navíc i k omezení negativního dopadu na zdravotní systém.

K podobným závěrům došla i studie analyzující data z Wu-Chanu, Číny, Itálie a New Yorku mezi daty 23.1. a 9.5.2020 a sledující vliv epidemiologických opatření [15]. Např. v Itálii vedlo zavedení povinných roušek ke snížení počtu nových infekcí v období mezi 6.4. a 9.5. o více než 75 000 (při optimisticky odhadované 0.5% úmrtnosti jde o 375 ušetřených životů). Ochrana dýchacích cest se tak ukazuje jako nejúčinnější a zároveň velmi levné epidemiologické opatření, které vede k rychlému poklesu nově nakažených. Jde o nejsilnější nástroj pro kontrolu epidemie, bez něhož jsou ostatní opatření účinná jen velmi omezeně [15] (snad vyjma úplného zákazu vycházení).

1.2.6 Testování

Testování je nedílnou součástí zvládnání jakékoliv epidemie, protože bez něj není možné odhalit nakažené (symptomy mohou odpovídat více různým onemocněním). U onemocnění Covid-19 je situace o to složitější, že nemoc mohou šířit asymptomatictí nakažení a symptomatický přístup k řízení epidemie je tak nedostačující. Pomocí testování asymptomatické populace je však možné detekovat asymptomatické přenašeče a včas je izolovat [54].

Tato základní myšlenka pak stojí za veřejným testováním, které je v České republice zabezpečeno pomocí antigenních testů a v případě podezření na nákazu (pozitivní výsledek antigenního testu, rizikový kontakt nebo příznaky onemocnění) pak i PCR testem. Ve veřejném i odborném prostoru probíhá diskuze, zda je taková praxe s ohledem na nižší citlivost antigenních testů efektivní, nebo by bylo lepší více využívat PCR testy i přes jejich vyšší finanční a časovou náročnost. Je však zřejmé, že i testování s nižší citlivostí vede k podstatnému omezení epidemie, pokud je prováděno masivně pravidelně a v kratších intervalech (např. 2x týdně). Nižší citlivost je tak kompenzována vyšší četností pokusů o zachycení přenašeče. Naopak čím delší jsou prodlevy mezi testy, tím menší je efekt testování a zhruba od dvoutýdenních intervalů již není vliv testování statisticky významný [54].

1.2.7 Sektorová omezení


Sektorová omezení představují uzavření nebo omezení provozů, prostor a činností, při kterých existuje zvýšené riziko přenosu infekce. Identifikace takových prostor je založena na známých vlastnostech patogenu, zejména infekčnosti a mechanismu přenosu. Z 1.1.2 a 1.1.3 je možné vcelku snadno odvodit, že se bude jednat o všechny činnosti, kdy dochází k blízkému osobnímu mezilidskému kontaktu a komunikaci. Protože není prakticky realizovatelné dlouhodobě uzavřít všechny dotčené sektory (přímo nebo nepřímo by se zřejmě jednalo o úplné uzavření ekonomiky, služeb poskytovaných státem a neziskovými organizacemi i uzavření volnočasových aktivit, vyjma aktivit individuálních), jsou v první řadě a v závislosti na stavu rozšíření epidemie uzavírány ty sektory, které nejsou nezbytně nutné z hlediska zajištění základních potřeb obyvatel a současně v nich hrozí nejvyšší riziko

infekce podle dostupných poznatků nebo na základě uvážení autorit. Omezení však nemusí souviset jen s nařízeními regulačních úřadů, ale i s odlivem zákazníků z důvodu obav z nakažení, nebo např. z důvodu nečekaných problémů s distribucí nebo dodavatelsko-odběratelskými řetězci, což může sektorovou krizi ještě prohloubit [55].

V České republice se sektorová omezení v průběhu roku 2020 měnila několikrát, a to jak ve smyslu zpřísnění opatření při nárůstu onemocnění, tak i ve smyslu uvolnění a alespoň částečného obnovení provozu v době poklesu epidemie. V kontextu jiných vyspělých zemí jsou opatření v ČR v průběhu roku 2020 hodnocena jako jedna z mírnějších, což ukazuje i tzv. Index přísnosti epidemiologických omezení v různých zemích v čase (Obrázek 2).

Index přísnosti (Stringency Index)

(0 - 100)



Obrázek 2 - Stringency index

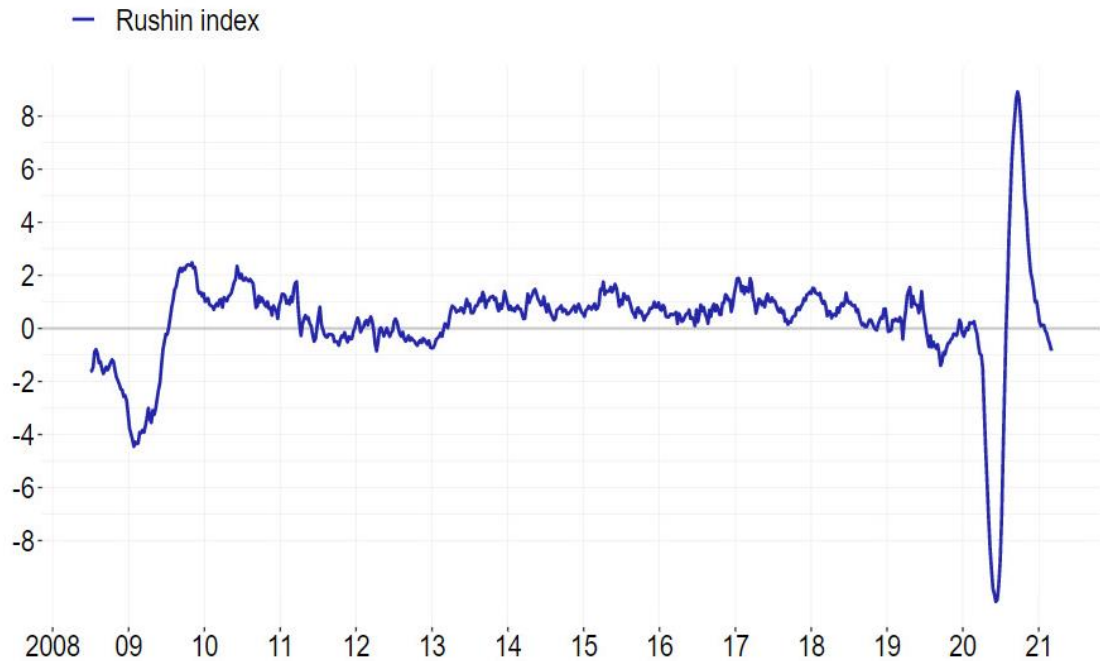
Stringency index slouží pro porovnání přísnosti opatření v různých zemích - čím vyšší je hodnota Stringency index, tím přísnější je celková úroveň opatření. Zdroj: Převzato z [2]

1.3 Ekonomické následky pandemie

Česká národní banka dlouhodobě zpracovává souhrnný index ekonomiky, tzv. Rushin index (Obrázek 3). Ten zachycuje hospodářskou aktivitu v 10 klíčových oblastech (spotřeba elektřiny, průmyslová výroba, tržby ve službách a maloobchodu, předstihové ukazatele atd.). Agregovaná data pak popisují změny hospodářské aktivity v čase.

Podle Rushin indexu byl rok 2020 pro českou ekonomiku náročnější než zásah Velké recese z let 2008-2015 a to zejména ve 2. čtvrtletí. Ve 4. čtvrtletí aktivita po let-ním uvolnění roste jen mírně a s růstem nových případů Covid-19 na přelomu roku pak v 1. čtvrtletí 2021 opět mírně klesá. Pokles ve 2. čtvrtletí 2020 je dán téměř úplným uzavřením ekonomiky, kdy došlo v mnoha případech i k přerušování výroby. V opatřeních přijatých od podzimu 2020 až dosud (květen 2021) již průmysl fungovat nepřestal, což pomohlo hospodářství stabilizovat [2] (česká ekonomika je ovšem malá a silně proexportní, navíc provázaná s ekonomikou Německou a hospodářské výkony jsou tak značně ovlivněny situací ve světě). Stabilizace hospodářství, neuzavření průmyslu a pravděpodobně i státní podpora a kompenzace podnikatelskému sektoru jsou nejspíš hlavním důvodem relativně nízkého růstu nezaměstnanosti. Ta ke konci roku 2020 vystoupala na 3.8 % z 2% hodnoty za rok 2019 [56]. Stále tak jde o nejnižší hodnotu ze všech zemí EU [2]. Meziročně také stouply úspory domácností z důvodu odložené spotřeby a to o 18.9 %. Výsledek je to dobrý i vzhledem k tomu, že HDP ČR se za rok 2020 propadl o 5.6 % ve srovnání s rokem 2019 (z toho ve 2. čtvrtletí 2020 došlo mezičtvrtletně k propadu o 8.7 % a ve srovnání se stejným čtvrtletím roku 2019 dokonce o 10.8 % [2]). Z důvodu různých omezení o 4.3 % poklesla i celková produktivita práce [56]. Pro další vývoj bude důležitý zejména průběh očkování a poptávka po zboží a službách v zahraničí.

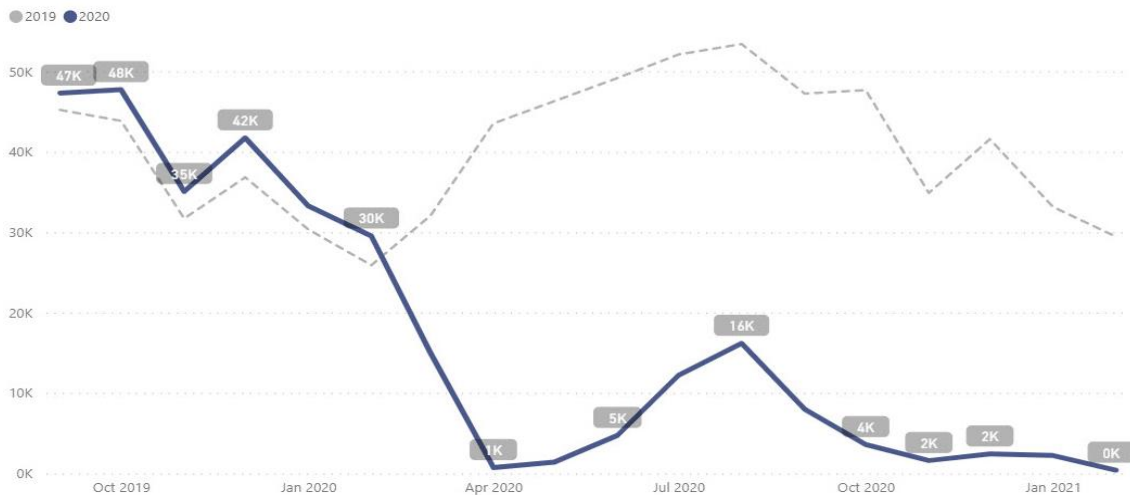
The Rushin Index of the Czech Economy (quarterly changes, %)



Obrázek 3 - Rushin index ČNB

Rushin index ČNB ukazuje pokles hospodářské aktivity ve 2. čtvrtletí 2020 a poklesem začíná i rok 2021. Zdroj: Převzato z [2]

Zatímco dopad na průmysl nevypadá až tak závažně, zcela jiná situace panuje v sektoru služeb, a to zejména v oborech souvisejících s cestovním ruchem, pohostinstvím, lázeňstvím a ubytovacími službami. Celosvětově vytváří turismus 7 % globálního HDP a ztráty z důvodu proti pandemických opatření a praktického zastavení turismu jsou pro rok 2020 odhadovány na 910 - 1 200 miliard dolarů. [57]. V ČR tvořil cestovní ruch v roce 2019 2,9 % HDP, z čehož 43 % připadalo na návštěvy a pobyty tuzemských turistů [58]. Expozice ČR vůči cestovnímu ruchu je tedy naštěstí relativně nízká, což do jisté míry omezuje škody na hospodářství, nicméně pro některé regiony je zásah mnohem citelnější. Zajímavý je např. pohled na statistiku ubytování Airbnb s porovnáním let 2019 a 2020 v Praze, což je zejména pro zahraniční klientelu jedno z turisticky nejatraktivnějších míst v ČR. Celkově pak sektor ubytování propadl v roce 2020 o více než 55 % oproti roku 2019.

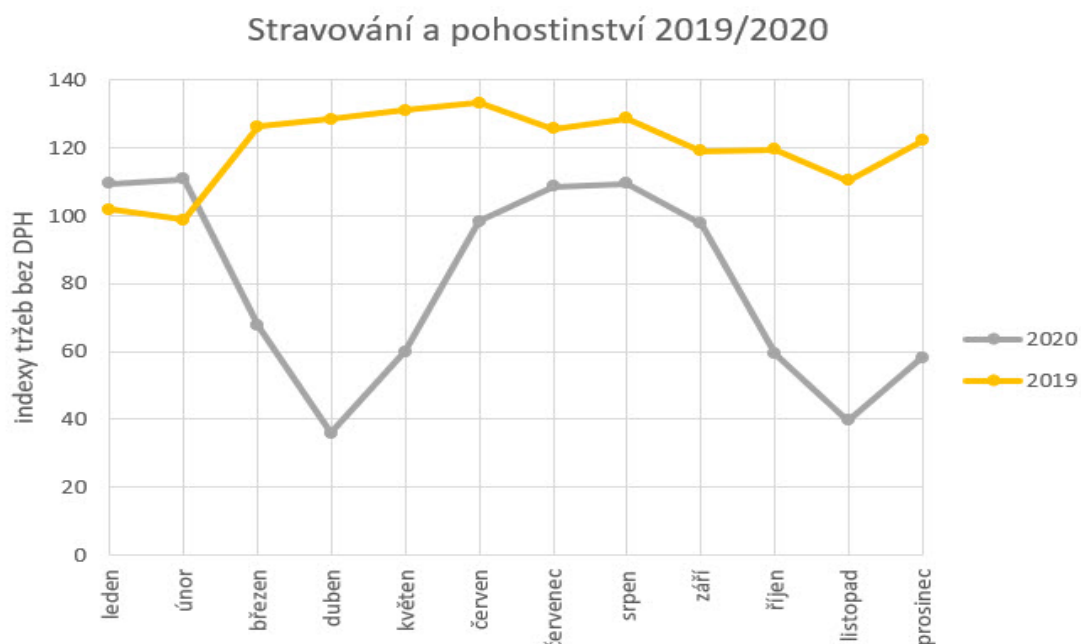


Obrázek 4 - Změny v ubytovacích službách Airbnb

Pokles realizovaných ubytování přes službu Airbnb v Praze v prvním pandemickém roce 2020
Zdroj: Převzato z [3]

V sektoru stravování a pohostinství je stav velmi podobný. Omezení mobility, uzavření restauračních zařízení anebo omezení počtu hostů a požadavky na hygienická opatření vedly v roce 2020 k třetinovému propadu tržeb.

Odhad všech dlouhodobých dopadů je obtížný až nemožný, důsledky se projeví ve zdánlivě nesouvisejících oblastech a mohou souviset i se změnou chování spotřebitelů, které se po odeznění pandemie nevrátí k původním návykům.



Obrázek 5 - Dopad na sektor pohostinství

Propad sektoru pohostinství v indexech tržeb (bez DPH). Zdroj: Převzato z [4]

1.3.1 Pivovarnictví v době pandemie

Z hlediska této publikace a otázek, na které hledá odpovědi, je nejdůležitějším průmyslovým sektorem pivovarnictví. Sektor pivovarnictví je velmi úzce navázán na turistický ruch a pohostinství a byl proto pandemií zasažen velmi tvrdě a prakticky ze dne na den. Problém přitom není jen v uzavření restaurací a omezení turismu, ale i v načasování uzávěry. V březnu se pomalu otevírá pivní sezóna a pivovary jsou již připravené na distribuci piva odběratelům v restauracích a podobných zařízeních. Nemalá část produkce je tak již přečerpána do sudů (KEG) a způsob, jak přečerpát takto připravené pivo do lahví, plechovek nebo menších obalů vhodných pro distribuci konečným spotřebitelům není ani snadný, ani k pivu citlivý. Z důvodu hledání alternativních cest k zákazníkům nastaly velmi rychle potíže i s nedostatkem obalů a jejich strmě rostoucí cenou [55]. Problém se navíc prohlubuje s epidemiologickou metodou brzda-plyn, kdy dochází k uvolňování a zpřísnění opatření v závislosti na momentálním stavu epidemie, a to i ve velmi krátkých časových úsecích, případně jsou změny parametrů epidemiologických opatření k veřejnosti komunikované nejasně, nebo vůbec. Producenti ani distributoři pak nejsou v takové situaci schopní z důvodů technologických i logistických dostatečně rychle reagovat na neustále se měnící podmínky a relevantní volbou je pak činnost přerušit nebo výrazně omezit [59].

Ztráty v českém pivovarnictví se jen za 1. pololetí roku 2020 vyšplhaly na 4.71 miliardy Kč. Největší podíl na ztrátě mají právě zavřené restaurace, tedy z pohledu pivovarů klíčový segment ON TRADE. Tržby v tomto segmentu poklesly o 55 % (4.24 miliardy Kč) a ve ztrátě byly i pivovary samotné (kvůli zvýšeným nákladům na obaly, distribuci, likvidaci piva, závazkům apod.) i dodavatelé (celkem 1.27 miliardy Kč). Jedinou kladnou položkou je prodej v segmentu OFF TRADE (maloobchod a obecně pivo prodávané v obalech), kde se prodeje zvýšily o 14 % (+0.8 miliardy Kč). Je tedy patrné, že část spotřebitelů přešla na balené pivo, nicméně v rozsahu, který pivovarům nedokázal kompenzovat ani pětinu ztrát z ON TRADE.

Celkově došlo k poklesu spotřeby piva o 55 % [60]. Pro 2. pololetí odhaduje Centrum ekonomických a tržních analýz ztráty na dalších 3.2-3.8 miliardy Kč [61].

Pokles pivovarnictví je patrný v celé EU i USA. V zemích sedmadvacítky je odhadovaný pokles odvětví mezi 20 a 25 %, přičemž rozdíly mezi zeměmi jsou značné a souvisejí zejména s místní pivní kulturou a strukturou výroby, resp. importu. Např. v Belgii poklesla produkce piva o 55 %, v Portugalsku o 70 %, ale v Estonsku jen o 7 % [59]. Nejhůře přitom situaci nesou menší pivovary, které se před pandemií soustředily převážně na segment ON TRADE a prodej baleného piva byl jen okrajovou činností, a pivovary s vlastní sítí restauračních zařízení [55].

V roce 2019 pivovarnictví rostlo zejména díky exportu. Zahraniční poptávka zvýšila tržby pivovarů o 4.5 %, zatímco poměr konzumace čepovaného piva v restauracích a podobných zařízeních poklesl na 35 % (-1 % oproti roku 2018). Stále to však představovalo roční tuzemskou spotřebu v průměru 142 l na obyvatele ČR [9]. Při předpokládaném poklesu spotřeby o 55 % v roce 2020 se tedy spotřeba národního moku (Moravané snad prominou) snížila na 64 l na osobu (a bez přechodu části zákazníků k balenému pivu by byla průměrná spotřeba ještě o něco nižší).

1.3.2 Pivo v české populaci

Spotřeba piva není v populaci jednotná, ale liší se mimo jiné v závislosti na pohlaví, věku i dosaženém vzdělání. Podle průzkumu trhu uskutečňovaného společností CVVM mezi lety 2004 a 2018 a zaměřeného právě na konzumaci piva a pivní návyky ve společnosti, byl v roce 2018 podíl mužů a žen konzumujících pivo 86 % a 49 % (při zprůměrování hodnot za roky 2016-2018 z důvodu zmenšení možné statistické chyby je podíl mužů konzumujících pivo 87 % a žen 55 %). Muži, kteří alespoň někdy konzumují pivo, také uvádějí v průměru vyšší týdenní množství vypitého piva a to 7.6 půllitrů oproti 2.7 půllitrům u žen (tříletý průměr pak činí 8 půllitrů u mužů a 2.4 půllitrů u žen). Průzkum konzumace podle věkových skupin byl naposledy zveřejněn za rok 2016, v dalších letech se však dle výzkumníků poměry příliš neměnily. Nejvyšší průměrnou spotřebu uváděli muži ve věku 30-59 let. V této skupině pije pivo 90 % osob s průměrnou spotřebou 8.3 půllitrů týdně. Následuje skupina nad 60 let a nejnižší (a v průběhu času navíc klesající) spotřebu uvádějí muži ve věku 18-30 let [75] [76].

1.4 Matematické modelování epidemie

K modelování epidemií lze použít buď standardní matematický přístup nebo modelování pomocí multiagentových systémů [62]. Výhodou matematického modelu je snadnost implementace i rychlost, s jakou je možné dopracovat se k výsledkům. Např. základní epidemiologický model SIR lze popsat třemi rovnicemi, jejichž výpočtem se v jednotlivých krocích zjišťuje aktuální stav epidemie (daný stavem předchozím) [63]:

$$S_t = S_{t-1} - \beta I_{(t-1)} \frac{S_{(t-1)}}{N}$$

$$I_t = I_{t-1} - \beta I_{(t-1)} \frac{S_{(t-1)}}{N} - \gamma I_{(t-1)}$$

$$R_{(t)} = R_{(t-1)} + I_{(t-1)}$$

kde:

- S představuje potenciálně infikovatelné jedince (Susceptible),
- I jedince infikované a nemoc přenášející (Infected),
- R jedince imunní, vyléčené, případně jinak zajištěné proti (re-)infekci (Recovered),
- β je koeficientem nakažlivosti, tedy kolik jedinců z množiny S v průměru nakazí infikovaný jedinec (v jednom kroku),
- γ je koeficientem ukazujícím na průměrný počet vyléčených a,
- $t-1$ jsou informace o předchozím stavu modelu.

Mimo SIR se velmi často používá i model SEIR, který mimo zdravých (S), infikovaných (I) a vyléčených nebo jinak imunizovaných (R) jedinců počítá jedince vystavené nákaze, ale zatím nepotvrzené E (Exposed), kteří se tak mohou stát skrytými přenašeči v průběhu inkubační doby. To lépe odpovídá charakteru onemocnění SARS-CoV-2 a v takto koncipovaných modelech se obecně dosahuje vyšší přesnosti výpočtů ve srovnání s reálnými podmínkami [5]). Matematické vyjádření využívá diferenciálních rovnic a je již o něco složitější [6]. Pomocí matematického modelování lze s využitím parametrizace a diferenciálních rovnic zachytit různé další jevy a vlastnosti populace ovlivňující průběh epidemie, např.

přírůstky nebo úbytky obyvatel, vliv dočasné imunizace, migraci obyvatel, šíření onemocnění v domácnostech a pracovištích apod. [40]

Nevýhodou matematického přístupu však stále zůstává fakt, že popisuje pouze homogenní skupinu (příp. skupiny) a výsledky pak zahrnují vysokou míru abstrakce celého epidemického systému. Zobrazují vlastně průměrné chování homogenní skupiny [63]. Jen těžko lze pak matematicky popsat i takové vlivy jako jsou prostředky chytré karantény, mutace viru nebo dynamické rozhodování agentů.

1.5 Multiagentové modelování

Jiným přístupem, který umožňuje vnést do modelování epidemie jistou heterogenitu, je modelování multiagentové (ABMS). Díky němu lze modelovat např. interakce mezi agenty i s ohledem na v čase se vyvíjející sociální vazby, definovat odlišné vzorce chování jednotlivých (skupin) agentů, modelovat rozhodování např. v podobě přizpůsobování akcí agentů dynamicky se měnícímu stavu modelu apod. Široké možnosti multiagentových modelů a jejich poměrně snadná implementace dostávají tento přístup k modelování nejen epidemií do popředí zájmu výzkumníků [40].

Základem ABMS je agent, tedy samostatná jednotka s určitými vlastnostmi a možnostmi interakce s okolím, včetně interakce s jinými agenty. Jednotliví agenti přitom mohou mít vlastnosti nastavené různě a stavy se mohou v průběhu modelování měnit podle požadavků a podmínek simulace. Agenti se pohybují, nebo jinak interagují, ve vymezeném prostoru, resp. světě. I ten může mít definovány určité vlastnosti jako jsou různé pravděpodobnosti nákazy v různých typech lokalit, maximální množství agentů v dané lokalitě a jednom čase apod. V jistém smyslu může být i svět agentů považován za specifický typ agenta.

Vzájemné interakce agentů mezi sebou i se světem a jeho pravidly pak generují systémovou dynamiku – jde o přístup modelování zdola [62]. Současné možnosti výpočetní techniky přitom umožňují, aby multiagentové systémy obsahovaly velká množství agentů i vlastností relevantních pro model a bylo tak možné simulovat i chování velkých městských aglomerací nebo celých států [40].

1.5.1 Modelování vztahů

Pro modelování epidemie pomocí ABMS jsou důležité zejména kontakty mezi agenty. Při nich dochází k přenosu onemocnění a šíření patogenu v modelové populaci. Multiagentové systémy mohou takovou dynamiku postihnout buď pomocí náhodných vzájemných interakcí agentů nebo pomocí pevně daných sociálních sítí jako jsou rodiny, pracovní a školení kolektivy, zájmová a sportovní sdružení, kulturní akce apod. Možností je i kombinace obou přístupů. Mimo pevných sociálních vazeb, které lze zachytit pomocí explicitního členství v předem definovaných skupinách, je výzvou ABMS i zachycení neformálních vazeb mezi agenty a změny v pevných strukturách sociálních skupin. Příkladem mohou být neformální setkávání přátel, sousedů nebo přechod do jiné zájmové skupiny, založení rodiny apod. Takové události nelze jednoduše zachytit v předem daném plánu, ale jedná se spíše o náhodné jevy, které mohou vést ke vzniku pevných struktur [40]. Podobný může být i vliv cestování, volba dopravního prostředku pro cestu do zaměstnání apod. - každá z takových interakcí ovlivňuje dynamiku epidemie.

Interakce lze ukládat do persistentního datového zdroje, který pak může sloužit k vyhodnocení, zda se agent nakazil (po uplynutí inkubační doby) nebo pro potřeby trasování v rámci metod Chytré karantény.

Problémem modelování sociálních vazeb v AMBS, nebo obecně modelování agentových systémů s mnoha vzájemnými vazbami, je zejména rostoucí výpočetní náročnost, která i při lineárním růstu populace může narůstat exponenciálně. To pak vyžaduje buď úpravu na straně struktury a četnosti interakcí, nebo využití distribuovaných výpočtů pro snížení časové náročnosti simulace [40] [81]. Model pak obsahuje určitou míru zjednodušení, byť stále nesrovnatelně menší v porovnání s úrovní abstrakce matematického modelu. Rozdělením velkého modelu do menších sub-modelů (clusterů) a definicí pravidel pro komunikaci mezi clustery pak lze modelovat i takové rozsahy a složitosti, které by jinak narážely na technické limity použitých nástrojů (např. v Mesa nebo NetLogo) [81].

1.5.2 Rozhodování agentů

Jednou z možností, kterou nabízejí multiagentové systémy, je rozhodování agentů o jejich dalších akcích. Jedná se o další přiblížení simulace reálnému světu, ve kterém se lidé rozhodují na základě podmínek prostředí a vlastních zkušeností a přizpůsobují své chování situaci. Rozhodování agentů v ABMS může mít podobu jednoduchých podmínek a pevných pravidel (pokud je autobus plný, nenastoupím), nebo složitějších konstruktů založených na předchozích zkušenostech, tj. aplikaci regrese (autobus je v tomto čase obvykle plný, půjdu tedy na dřívější spoj) či výsledcích učících algoritmů (Reinforcement Learning využívající stavového prostoru pozorování, možných akcí a odměn za výsledek zvolené akce nebo řetězce akcí) [82]. Vliv rozhodování je další charakteristikou modelu, kterou by nebylo možné postihnout modelováním matematickým a v ABMS může působit jako zpětnovazební smyčka a součást emergentního chování systému.

Aby se agent mohl rozhodnout, musí mít k dispozici informace o svém okolí [82]. Nezáleží přitom ani tak na kvalitě nebo pravdivosti informace, jen na její dostupnosti. Tímto způsobem je možné modelovat i vliv poplašných zpráv, cílených dezinformačních kampaní nebo vlivových skupin, což opět zvyšuje atraktivitu multiagentového přístupu. Šíření informace v populaci může být dáno globálně, např. televizním vysíláním s předpokladem, že všichni agenti obdrží stejnou informaci ve stejném čase, nebo může být fragmentováno podle vybraných skupin agentů, případně si mohou agenti předávat informace při vzájemné interakci. Informační toky se pak stávají dalším samostatným prvkem simulace a jejich struktura a kvalita se ve spojení s rozhodovacími schopnostmi agentů může stát dominantní silou směřování simulace.

1.5.3 Vstupní data modelů

Základní součástí simulací, které modelují reálný systém, jsou vstupní data a výchozí podmínky pro změny vnitřních stavů simulace. Jednoduché simulace, jako je např. Sugarscape nebo Wolf Sheep Predation z knihovny modelů NetLogo [83] vystačí se základními parametry populací (počet agentů, náhodný pohyb ve světě, energie vlků a ovcí, rychlost dorůstání trávy apod.). To je dáno zejména jejich

účelem, kterým je demonstrace možností multiagentového modelování. Oba modely by ale mohly být mnohem složitější (a výsledkově zajímavější), pokud by byly nastaveny podle reálných podmínek. V modelu Wolf Sheep Predation by šlo například o počet vlků a ovcí odpovídajícímu jejich proporčnímu zastoupení v reálném světě, různá míra konzumace trávy v souvislosti s velikostí a stářím ovce a mnoho dalších charakteristik založených na empirických datech. Výsledky běhu takových modelů by lépe odpovídaly skutečnosti, tedy blížily by se svými výsledky reálným situacím více než modely nastavené náhodně.

Snaha přiblížit se reálnému světu je patrná v mnoha multiagentových systémech. Např. model [5] (Petrônio C. L. Silva), který bude detailněji popsán v kapitole 1.5.5, implementuje informace o populaci Brazílie včetně ekonomické a sociologické struktury obyvatelstva. Podobně model [40] (Mingxin Zhang) využívá statistická data, evidenci místních autorit a sčítání lidu k sestavení populace obsahující agenty věkem, pohlavím a sociální statusem co nejvíce odpovídajícím reálné více než 19 milionové populaci Pekingu. Součástí charakteristik populace modelu [40] jsou i denní aktivity jednotlivých agentů. K sestavení populace je pak využito speciálního algoritmu.

V případě modelování epidemie je také žádoucí mimo populace samotné definovat i co nejreálnější charakteristiku onemocnění, vzít v úvahu rizikové skupiny obyvatel, příp. mobilitu obyvatel v závislosti na věku a strukturu sociálních skupin jako jsou školní nebo pracovní kolektivy [40]. Pro modelování ekonomických dopadů je do vstupních charakteristik modelu zjevně nutné zahrnout i relevantní data modelovaném produktu, jeho spotřebě za běžných okolností, změnách v návycích spotřebitelů při nestandardních podmínkách během epidemie apod.

Přestože model kvůli mnoha zjednodušením nikdy nebude zcela odpovídat skutečnosti, výsledky modelu založeném na relevantních datech budou pravděpodobně mnohem bližší výsledkům skutečnosti než data náhodně zvolená.

V následujících kapitolách 1.5.4, 1.5.5 a 1.5.6 jsou detailněji popsány příklady multiagentových modelů epidemie, které byly vybrány jako ukázka možností

přístupu ABMS a které slouží jako inspirace pro sestavení vlastního modelu CovidBeerSimulator. Modely se vzájemně liší mírou abstrakce, složitostí a použitými nástroji pro jejich sestavení.

1.5.4 Agentový model SIR

Sestavení jednoduchého epidemického modelu SIR lze i v případě ABMS realizovat poměrně rychle a jednoduše, např. pomocí modulů Pandas a Numpy programovacího jazyka Python, což demonstruje např. model [63] (Christian Graf). Pro SIR model stačí sestavit dataframe s informacemi o modelovaném systému – počet agentů, jejich stav (S|I|R) a mechanismus, kterým dochází k infikování agenta.

V [63] je použita metoda náhodného výběru pomocí generátoru pseudonáhodných čísel v rovnoměrném statistickém rozdělení, což znamená, že se agenti setkávají zcela náhodně, v rámci homogenní skupiny mají všichni stejnou pravděpodobnost nakažení a nakažení agenti mají všichni stejnou pravděpodobnost vyléčení. Běh modelu probíhá v jednotlivých krocích a končí tehdy, když se počty agentů se stavy S, I a R stabilizují. Pokud běží takový model v dostatečném počtu opakování, pak jsou zprůměrované výsledky i průběhy křivek velmi podobné výsledkům matematickému modelu. Takový výsledek může sloužit jako validace správnosti nastavení a běhu modelu.

Oproti matematickému modelu však umožňuje ABMS model sledovat samotný průběh jevu na úrovni jednotlivých agentů anebo, a to je možná ještě důležitější, upravit parametry modelu tak, aby více odpovídaly reálným situacím. Konkrétně v modelu [63] je přidána funkcionalita jednoduché sociální interakce, kdy již nedochází k infikování libovolného náhodného agenta, ale agenta, který se vyskytuje v definovaném okolí. Mimo stavu S | I | R je tak každému agentu dána vlastní pozice ve virtuální ploše čtvercové sítě a na počátku je opět náhodně několik z nich infikováno. Infikovaný agent však může se stejnou pravděpodobností infikovat pouze agenty nacházející se v bezprostředním okolí, a to po dobu, než se sám vyléčí. Jedná se tak de facto o simulaci perkolace. Efektem takové změny je podstatné snížení rychlosti šíření epidemie (zploštění křivek, záleží však na volbě parametrů). Naopak po přidání prvku náhodnosti, kdy každý infikovaný agent může mimo své

okolí infikovat ještě další náhodně vybrané agenty (1..n) kdekoliv na ploše, dochází k razantnímu zrychlení průběhu epidemie a sníží se i počet agentů, kteří po celou dobu zůstanou v množině R.

Simulaci by bylo možno dále rozvíjet a zpřesňovat přidáním dalších parametrů a funkcí - např. agenti mají různou pravděpodobnost nakažení danou geneticky, nakažení a délka infekce může být ovlivněna komorbiditami, mezi agenty mohou být modelovány různé vazby (sociální role, rodinná příslušnost apod.). I v tomto základním tvaru ale poskytuje model [63] elegantní, výpočetně rychlý a reálnému průběhu bližší epidemický model, než je základní model matematický.

1.5.5 Agentový model SEIR a objektový přístup

Vyjma základního modelování průběhu epidemie, ať již s nebo bez přidání parametrů prostředí a vlastností agentů, lze modelovat i různá opatření ovlivňující šíření onemocnění. Tím může být efekt sociálního distancování, různých typů ochrany dýchacích cest, omezení mobility obyvatelstva, represivních opatření apod.

Příkladem takového modelu je model [5] (Petrônio C. L. Silva) pracující s různými stupni sociálního distancování a využitím ochrany dýchacích cest. Na těchto základech pak sleduje ekonomické efekty různě nastavených opatření. Oproti modelu [63] se liší hned v několika aspektech. Předně svým rozsahem a cílem, neboť nemodeluje jen samotný průběh epidemie, ale snaží se zachytit i související dopady opatření, konkrétně jejich ekonomický efekt základě epidemiologického modelu SEIR. Systém se také liší technickým provedením – opět je zpracován v jazyce Python, nicméně je použit objektový přístup a veškeré komponenty modelu (agenti, prostředí i samotné kroky simulace) zpracovává jako třídní instance, zatímco v modelu [63] jsou agenti i jejich interakce součástí jediné instance Dataframe (tabulky). Výhodou objektového přístupu je jeho snadná rozšiřitelnost a přenositelnost na modelované prostředí (zcela v duchu objektového paradigma). Cenou za takový přístup je však rychlost a obecně vyšší nároky na výpočetní výkon, protože se pracuje s celými objekty namísto řádků v optimalizovaném Numpy poli. Zatímco model [63] tak v základu pracuje s 10 000 agenty v simulaci, model [5] pracuje s populací 300 agentů.

Posledním rozdílem je obecně informační základna, ze které model vychází. Při sestavování [5] se autoři inspirovali jinými epidemickými modely a jejich výsledky (např. australským modelem vyhodnocujícím jako optimální opatření 13 týdnů trvajícím lockdown s omezením mobility 90% obyvatel a limitovaným přeshraničním stykem, aby nedocházelo k zavlečení infekce migrací [5], nebo modely simulující uvolňování restrikcí, efekty vakcinace apod.), navíc jsou socioekonomické parametry modelu nastaveny podle reálných dat z Brazílie, včetně takových detailů, jako je kapacita zdravotního systému.

Model [5] obsahuje 5 typů agentů, přičemž každý z nich zastupuje jiný typ objektu, jak se shrnuto v tabulce níže (Tabulka 2).

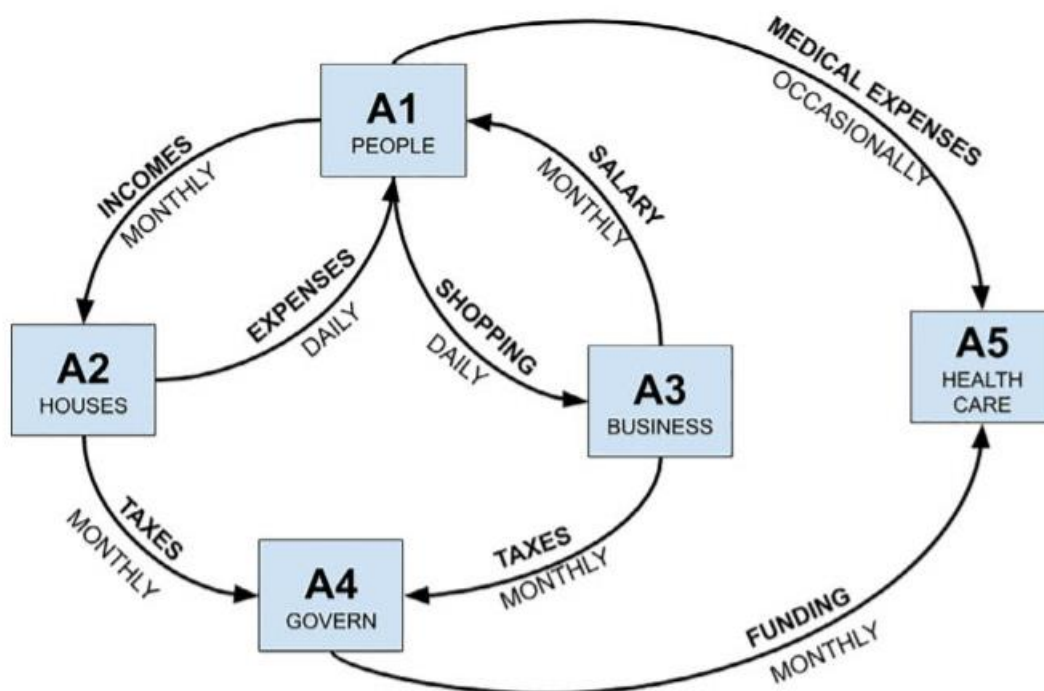
Tabulka 2 - Typy agentů použitých v modelu SEIR

A1: Osoba (Person)	
Popis	Dynamicky pozicovaný agent, může mít asociace k prostředí (k Domácnosti, Zaměstnání...)
Atributy	Pozice, věk, domácnost, epidemiologický status, stav infekce, zdravotní stav, majetek, příjem, sociální vrstva
Akce	Pohyb (náhodná procházka, přesun na definovanou pozici – domů, do zaměstnání, do nemocnice), kontakt s jinou osobou
A2: Domácnost (Houses)	
Popis	Reprezentace rodiny (k agentu Domácnosti se vztahují jednotlivé Osoby), slouží také pro sdílení společných prostor
Atributy	Pozice, sociální vrstva, evidence Osob (rodina), majetek, příjmy a výdaje
Akce	Evidence Osob, účetní bilance
A3: Obchod/Zaměstnání (Business)	
Popis	Reprezentace zaměstnání (zde Osoby dostávají plat), nebo obchodního prostoru (zde Osoby nakupují produkty)
Atributy	Pozice, sociální vrstva, evidence Osob (zaměstnanci, zákazníci), majetek, příjmy a výdaje
Akce	Účetní bilance
A4: Státní správa (Government)	

Popis	Agent (jedinečný) transferující platby od Domácností a Obchodů do Zdravotního systému a nezaměstnaných Osob
Atributy	Pozice, majetek
Akce	Účetní bilance
A5: Zdravotní systém (Healthcare System)	
Popis	Agent (jedinečný) poskytující zdravotní služby Osobám
Atributy	Pozice, majetek
Akce	Účetní bilance

Zajímavě je řešen přenos infekce, kde model počítá se vzdáleností agentů A1 a pokud je vzdálenost nižší než limitní vzdálenost (δ), pak se může dosud zdravý agent nakazit s pravděpodobností β . Zvolená metoda umožňuje jednoduchou implementaci různých scénářů změnou jediného (nebo několika málo) parametrů - např. snížením δ lze simulovat aplikaci rozestupů. Pravděpodobnost infekce β se také liší pro jednotlivé věkové skupiny, stejně jako se liší závažnost následků (asymptomatický průběh, hospitalizace, kritický stav nebo pravděpodobnost úmrtí).

Ekonomická stránka modelu (viz.Obrázek 6) je tvořena různou počáteční distribucí bohatství, při-čemž statistické údaje jsou převzaty z makroekonomických ukazatelů Brazílie a pře-neseny na cílovou (simulovanou) populaci. Počet agentů A1 je v modelu roven 300. Součástí simulace je pak koloběh peněz (za nákupy zboží, transfery zdravotnímu systému, výběr daní apod.), které pocházejí z počátečního bohatství a příjmu zaměstnaných osob a dávek v nezaměstnanosti.



Obrázek 6 - Schéma koloběhu peněz v simulaci

Zdroj: Převzato z [5]

Mimo základního scénáře (S0) byl také model hned na počátku validován z epidemiologického hlediska podle externí aplikace umožňující matematické modelování SEIR a parametry objektů simulace byly přizpůsobeny empirickým poznatkům z výsledků tohoto matematického modelu. Přehled scénářů je uveden v tabulce Tabulka 3.

Tabulka 3 - Simulované scénáře a opatření v modelu SEIR

(S0) Normální stav bez epidemie (Baseline)	
Popis	Základní scénář bez epidemie. Z hlediska ekonomiky je základní model nastaven na stagnaci (nulový přírůstek HDP), což odpovídá makroekonomické situaci a predikcím bez vypuknutí epidemie SARS-CoV-2
Výsledek	Vygenerovaná data slouží pro porovnání s následujícími epidemiologickými modely
(S1) Nedělat nic (Do nothing)	
Popis	Neomezované promořování (politická reprezentace se rozhodla nepřijímat žádné kroky ke zmírnění epidemie)
Výsledek	Výkon ekonomiky je mírně negativně ovlivněn, dochází ale k zahlcení zdravotního systému a model má nejvyšší počet obětí.

	Díky tomu je tento scénář označen za nejkatastrofičtější ze všech simulací
(S2) Úplné omezení mobility (Lockdown)	
Popis	Znemožnění pohybu agentů A1, včetně uzavření pracovišť i nákupních lokací, po jasně definovanou dobu a bez výjimek. Agenti A1 se mohou setkávat pouze v rámci rodiny (A2). Autoři připouštějí je takto koncipovaný lockdown není ve většině případů realistický, protože vyžaduje obyvatelstvo schopné/ochotné podřídit se vyhlášeným opatřením (dobrovolně nebo na základě represí)
Výsledek	Zdravotní systém zůstává plně funkční, úmrtnost je velmi nízká (dle doby vyhlášení opatření), simulované HDP poklesne nejméně o 20% - tento scénář má nejhorší ekonomické následky, ztráty by musela kompenzovat Státní správa (A4)
(S3) Podmínečné omezení mobility (Conditional lockdown)	
Popis	Implementace úplného lockdownu ze scénáře S2 v případě dosažení určité podmínky – pokud podíl infikovaných agentů A1 v populaci přesáhne 5%. Uvolnění lockdownu přichází ve chvíli, kdy podíl infikovaných opět klesne pod zvolenou 5% mez
Výsledek	Zdravotní systém zůstává plně funkční, ačkoliv počet obětí je vyšší než ve scénáři S2. Ekonomika se propadá do hluboké recese ve chvíli lockdownu, ale poměrně rychle se vzpamatuje po uvolnění. Autoři přidávají poznámku o implementaci scénáře S3 na Novém Zélandu, kde se zavedením tvrdých opatření po omezenou dobu (a při dostatečné kapacitě veřejného testování) podařilo epidemii poměrně rychle dostat pod kontrolu
(S4) Izolace rizikových skupin (Vertical isolation)	
Popis	Agentům A1 spadajícím do ohrožených skupin (dle rizika hospitalizace a fatálního průběhu onemocnění) je znemožněn pohyb (mohou se setkávat pouze s agenty obývajícími stejnou domácnost). Za rizikové a izolované jsou označeny osoby nad 65 let, pod 18 let a osoby se symptomatickým průběhem nemoci – poměrově jde zhruba o 20 % populace. Ostatní se mohou dále pohybovat a účastnit se ekonomických aktivit
Výsledek	Průběh epidemie je podobný průběhu simulace podle scénáře S1. Ve shodě se zdroji zmiňovanými autory simulace nedojde k efektivní ochraně ohrožených skupin, postupně je vyčerpána

	kapacita zdravotního systému a počty obětí jsou podobné katastrofickému scénáři S1. Propad simulované ekonomiky je podobný S1
(S5) Částečná izolace (Partial isolation)	
Popis	Zhruba 50 % agentů A1 je znemožněn pohyb (náhodný výběr s normálním rozdělením, $p \leq 0.5$). Ostatní se mohou pohybovat a účastnit ekonomické aktivity
Výsledek	Křivka nárůstu infikovaných agentů A1 je plošší než S1 nebo S4, v delším horizontu ale dochází k podobným výsledkům v podobě vyčerpané kapacity zdravotního systému i v počtu obětí. Podobná je i ekonomická křivka
(S6) Ochrana dýchacích cest (Use of face masks)	
Popis	Změnou parametrů modelu (zvýšení minimální přípustné vzdálenosti agentů A1 a snížení pravděpodobnosti přenosu infekce) bylo docíleno efektu nošení roušek a rozestupů. Pohyb agentů A1 není nijak omezován
Výsledek	Simulace ukazuje podstatné zploštění křivky nakažených oproti scénáři S5, zdravotní systém zůstává plně funkční, ekonomika není negativně ovlivněna a dosahuje podobných výsledků jako S1. Počet obětí je nicméně vyšší než u S2 nebo S3
(S7) Ochrana dýchacích cest s část. izolací (Use of face masks and 50 % of social isolation)	
Popis	Kombinace částečné izolace S5 a nošení ochrany dýchacích cest S6
Výsledek	Výsledek vykazuje lepší parametry z hlediska počtu obětí a volných kapacit zdravotního systému, je tedy lepší než samostatné scénáře S5 a S6. Ekonomický propad je o něco vyšší než u S5, ale rozdíly jsou minimální. Autoři simulace tento scénář označují jako nejvyváženější z hlediska výsledků i navržených opatření (snížení mobility na dobrovolné bázi a ekonomicky i společensky levné opatření v podobě roušek)

Jednotlivé simulace jsou spouštěny ve 35 kolech, přičemž každé z kol obsahuje 1440 kroků (1 krok odpovídá 1 hodině ⇒ 60 dní). Výsledky všech 35 kol jsou pak zprůměrovány pro závěrečnou interpretaci.

Model [5] je mnohem propracovanější než jednoduchý model SIR z kapitoly 1.5.4 a mimo reálných populačních dat a vlivu věku agentů na pravděpodobnost hospitalizace nebo úmrtí obsahuje dokonce i koloběh peněz v modelové ekonomice a změny v HDP vlivem pandemie a opatření k jejímu potlačení. Nicméně nemodeluje dopady pandemie na konkrétní produkt nebo odvětví, a to ani z okamžitého hlediska, ani v delším časovém horizontu. Model také neobsahuje žádnou formu rozhodování agentů, resp. rozhodování agentů je stochastické.

1.5.6 Agentové modely ve frameworku MESA

Mimo objektového přístupu, nebo přístupu pomocí datově analytické knihovny Pandas lze nalézt i agentové modely zpracované v různých frameworkích, včetně frameworku MESA. Jedním z jednoduchých příkladů je model Damiena Farrella z University College Dublin, který kombinuje základní funkcionalitu MESA s vizualizační knihovnou Bokeh [64] (Damien Farrell). Model pracuje s epidemiologickým modelem SIR a obsahuje v základní verzi 10 agentů (výsledky jsou pak zpracovány pro skupinu 400 agentů).

Vstupními hodnotami modelu je mimo velikosti populace a mřížky i pravděpodobnost přenosu nákazy a úmrtí. Agenti se pohybují v mřížce s náhodnou výchozí pozicí a k nákaze dochází s určitou pravděpodobností při kontaktu nakaženého agenta s nenakaženou populací na stejné pozici. Agenti mají náhodně přiřazený věk (ten se ale v modelu nevyužívá a je pouze informativní), liší se délkou infekce i rekonvalescence a s určitou pravděpodobností mohou zemřít. Vizualizace výstupů (mřížka s agenty i grafy) nejsou zpracovány pomocí frameworku MESA, ale pomocí vizualizační knihovny Bokeh. Výhodou modelu je jeho jednoduchost a otevřený zdrojový kód. S jednoduchostí se také pojí rychlost běhu modelu, který tak může obsahovat několik stovek i nižší tisíce agentů, aniž by to mělo výrazný vliv na výkon. Z toho mimo jiné vyplývá, že framework MESA zřejmě není vhodný pro simulace velkého rozsahu s řádově desítkami nebo stovkami tisíc agentů (za předpokladu nevyužití distribuovaných systémů). Složitě sociální vazby nebo možnost rozhodování agentů budou dále snižovat rychlost simulace. I s menším množstvím agentů je však možné dosáhnout zajímavých a hodnotných výsledků.


Jiným modelem zpracovaným ve frameworku MESA je agentový model SEIR, resp. Age-Stratified and Quarantine-modified SEIR with Non-Linear Incidence Rates (ASQ-SEIR-NLIR), využitý pro demonstraci vakcinačních strategií na Filipínách [6] (Jose M. A. Minoza).

Model pracuje s demografickými daty obyvatelstva Quezon City s využitím informací o věku (Age-Stratified) a sociálním zařazení, zdravotním stavu a komorbiditách. Součástí je flexibilní karanténa definovaná v několika úrovních podle stavu epidemie (Quarantine-modified) a charakteristické vlastnosti onemocnění včetně různé pravděpodobnosti nákazy a vlivů epidemiologických opatření (Non-Linear Incidence Rates, informace jsou čerpány z datových sad čínské provincie Hubei). Celkem je v modelu 160 agentů.

Model zpracovává pět scénářů vakcinačních strategií – žádná vakcinace, prioritizace ohrožených skupin a pracovníků v klíčových sektorech, prioritizace ostatních zaměstnanců (zemědělství, stavebnictví, doprava a logistika, prodej a služby vč. ubytování), prioritizace starších obyvatel a kombinace přednostního očkování posledně jmenované dvojice. Tyto scénáře jsou součástí tří fází, resp. cílů experimentů:

- I. fáze I řeší optimalizační strategii pro zabránění předčasným úmrtím způsobeným onemocněním Covid-19
- II. fáze II optimalizuje běh modelu a výsledky z hlediska limitování vážných ekonomických a sociálních dopadů
- III. fáze III řeší zadání co nejširší redukce komunitního přenosu.

Výsledkem je pak nalezení optimální strategie, která v případě tohoto modelu spočívá v přednostním očkování starších spoluobčanů.



Obrázek 7 - Schéma epidemiologického modelu SEIR

Zdroj: převzato z [6]

Model má také několik zajímavých rysů z hlediska práce s agenty, kteří nespádají do věkové kategorie 15-65 let (a nejsou autory bráni jako pro model důležití), nebo jsou v jistém smyslu chráněni před nákazou. Např. agenti v určitém věku jsou ponecháni doma a neinteragují s jinými agenty (lze říct, že jsou v trvalém lockdownu). Agenti, kteří nosí roušky a dodržují sociální distancování, jsou automaticky chráněni před nakažením. Vakcinace probíhá v jednom kroku z důvodu zjednodušení modelu při absenci vlivů nerovnoměrné distribuce vakcín, byť vakcinačních lokací může být více (sleduje se i vliv rozmístění vakcinačních lokací).

1.5.7 Další příklady agentových modelů

Mimo modelů popsaných výše existuje celá řada dalších, z nichž některé se zaměřují na nalezení optimálního řešení v podobě co nejmenších ekonomických ztrát a současně co nejmenšího počtu obětí - např. [65] (Patrick Mellacher) má právě tento cíl, a navíc je velmi podrobný z hlediska diverzifikace agentů – součástí simulace je kupříkladu i omezení pracovní schopnosti obyvatel z důvodu uzavřených škol, agenti mají různé sociálně-ekonomické role, takže je možné části z nich nařídít práci z domova, sledovat dopad nákazy v ošetrovatelském personálu apod.

Model [66] (Martin Bicher) obsahuje mimo jiné i celý životní cyklus agentů – kalkuluje s pravděpodobností narození nových agentů a v čase determinovaném střední dobou dožití také s pravděpodobností jejich úmrtí (je tak možné porovnávat i zkrácení střední doby dožití při vypuknutí pandemie Covid-19 a vliv různých opatření).

Modely se také mohou lišit z hlediska výkonu a modularity nebo z pohledu použité technologie. Simulace [5], [6], [63] a [64] jsou postaveny na jazyce Python a poslední ze jmenovaných navíc na ABMS frameworku MESA. Model [65] je postaven nad modelovacím nástrojem NetLogo, stejně jako ABMS model projektu ASSOCC [67] (Amineh Ghorbani).

Problémem modelů postavených nad ABMS frameworky jako je např. MESA, NetLogo, AnyLogic aj. však může být jejich výkonnost, která znemožňuje opravdu rozsáhlé simulace obsahující několik milionů agentů [66] (byť to nemusí platit vždy,

neboť např. [67] využívá NetLogo zejména pro výpočty simulace a k samotné graficky náročné vizualizaci slouží framework Unity postavený nad jazykem C). Model [66] toto řeší pomocí vlastní implementace ABMS v jazyce JAVA, přičemž jejich model simuluje celou populaci Rakouska (přes 9 milionů aktivních agentů) a podobným způsobem se s problematikou výpočtové náročnosti vypořádal i epidemiologický model Pekingů [40].

Jak je patrné, je k dispozici velké množství modelů využitelných k různým účelům a postavených nad různými technologiemi. Jednu věc však mají všechny jmenované (a mnohé další modely) společné. K jejich sestavení nestačí jen využít znalosti programování (Python, Java, C, JavaScript, ...) nebo speciálních nástrojů (NetLogo, RepastSymphony, AnyLogic, ...), ale je nutné postihnout i oblasti zdánlivě nesouvisející, jako je medicína, ekonomie, sociologie, psychologie, biologie a v neposlední řadě i matematika a statistika. Z nich vydestilované relevantní znalosti je pak nutné sestavit do funkčního celku. Díky tomu je agentové modelování a simulace vpravdě multidisciplinární oblastí náročnou na vstupní kapitál (kompetenční i informační), ale schopnou poskytnout pomocnou ruku v téměř jakékoliv oblasti lidské činnosti [62].

1.6 Framework MESA

MESA je framework pro tvorbu agentových modelů. Pro tvorbu modelů se používá programovací jazyk Python ve verzi 3+. Cílem MESA je stát se konkurentem jiných ABMS frameworků jako je např. NetLogo nebo RePast [68].

Mimo využití Pythonu 3 je výhodou frameworku MESA vysoká modularita a snadná a rychlá vizualizace modelu přímo v prohlížeči pomocí Javascriptového interface a vlastního vestavěného webového serveru (ale lze využít i Google Colab nebo Jupyter). Uživatel si může dokonce pomocí Pythonu a Javascriptu napsat vlastní modul pro vizualizaci a implementovat ho do Frameworku. Vizualizační modul je postaven nad Javascriptovým frameworkem Graph.js a předpokladem pro úpravy a nové vizualizace je tak dobrá znalost Javascriptu.

Základní moduly frameworku MESA jsou třídy Agent, Model a Scheduler, které se starají o agenty (s definovanými vlastnostmi a metodami), samotný model

(s globálním nastavením simulace a metodami pro běhové operace) a časování kroků simulace.

Agenti se pohybují v prostoru definovaném modelem (třída Space), přičemž je možné využít jak diskrétní prostor čtvercové nebo hexagonální sítě (se sdílenými nebo vyhrazenými koordináty), nebo spojitý prostor, kde mohou pozice agentů nabývat libovolných (float) hodnot.

Pod modul Scheduler (a Time) pak spadá metodika aktivace agentů – aktivace v náhodném pořadí, souběžné provádění akcí (to však může být náročnější na výpočetní prostředky) anebo tzv. StagedActivation, jejímž prostřednictvím mají agenti možnost zpracovávat v rámci jednoho kroku více různých fází.

MESA také nabízí možnost automatického běhu simulace v různých kombinacích vstupních parametrů (podobně jako BehaviorSpace v NetLogo). Tuto funkcionalitu zajišťuje třída Batchrunner. Pomocí tohoto nástroje je pak možné snáze hledat optimální řešení, neboť MESA umožňuje ukládat výsledky různých simulací v cyklu Batchrunneru, aniž by pro to musel programátor psát vlastní metody. S tím také úzce souvisí modul DataCollector, který slouží pro definici výstupních hodnot (včetně volání funkcí pro jejich přepočet) za běhu modelu. DataCollector sbírá tvůrcem modelu definované informace v každém kroku simulace, a to jak na úrovni celého modelu, tak na úrovni agentů.

Poslední součástí MESA je vizualizační modul, který umožňuje zobrazovat průběh simulace např. pomocí mřížky s agenty nebo grafovými a textovými výstupy. Samotná vizualizace probíhá ve webovém prohlížeči a vizuální elementy jsou do jisté míry modifikovatelné. Vizualizační modul také umožňuje umístit ovládací prvky modelu (lišty se škálou hodnot, vstupní pole apod.). Výsledné okno pak obsahuje i ovládací tlačítka pro zahájení, přerušení a reset simulace.

Výhodou MESA je také existence dokumentace, která poskytuje základní vhled do práce s frameworkem a obsahuje i ukázkový příklad ABMS pro distribuci bohatství (MoneyModel). K frameworku také existuje celá řada rozšíření. Jako příklad lze uvést modul Mesa-GEO pro geografické úlohy, která umožňuje definovat různě tvarované objekty s určitými vlastnostmi (stále se ale jedná o agenty) jako

jsou jezera, budovy, různé povrchy apod. [69]. Rozšíření Mesa-SIR obsahuje volby a nastavení pro jednoduchou simulaci SIR modelů [70] a posledním jmenovaným rozšířením je Multi-Level Mesa pro modelování sítí – vztahů mezi agenty [71].

2 Praktická část

V rámci této práce byl sestaven agentový model s názvem CovidBeerSimulator (CBS) modelující dopad šíření onemocnění Covid-19 v populaci na konzumaci piva. Účelem modelu je také demonstrovat dopady různých opatření na množství zkonsumovaného piva a odhadnout tak ideální kombinaci opatření, které vede k minimalizaci ztrát v sektoru pivovarnictví. Jako zdroj inspirace pro model byly využity modely uvedené v kapitolách 1.5.4 - 1.5.7. Jako datové podklady pro nastavení entit a pravidel byly využity informace prezentované v Teoretické části studentské práce.

Model je napsán v jazyce Python. K tvorbě modelu byl využit framework MESA, jeho vestavěná podpora paralelizace úloh (pro běh více simulačních scénářů souběžně), datově analytický nástroj Pandas a vizualizační nástroj Plotly. Verze jednotlivých nástrojů jsou uvedeny v souboru requirements.txt v repozitáři na GitHub, kde je volně k dispozici i kompletní zdrojový kód modelu, konfigurační soubory a datové zdroje. Adresa repozitáře je <https://github.com/lukyfox/CovidBeerSimulator>.

2.1 Představení vlastního modelu – ODD protokol

Model CBS je popsán pomocí ODD protokolu, což je formát popisu multiagentových modelů, který strukturovanou formou postihuje všechny důležité aspekty modelu. ODD protokol je široce využívanou metodou popisu ABMS ve vědeckých článcích [72]. Ačkoliv jsou některé jeho části kritizovány zejména pro svou náročnost a rozsah u komplexnějších modelů [72], je ODD protokol užitečný jak pro čtenáře dokumentace a uživatele modelu, tak pro samotné vývojáře, kterým může v průběhu tvorby výstupního textu protokolu umožnit hlubší vhled do vlastního modelu a poskytnout náměty k zamyšlení, úpravám i rozšířením. K tvorbě ODD protokolu modelu CBS byla využita šablona dostupná na stránkách Iowa State University, Iowa [73].

2.1.1 Účel

Úlohou modelu CBS je simulace šíření epidemie onemocnění Covid-19 a modelování jejích dopadů na spotřebu piva v souvislosti s různými epidemiologickými opatřeními. Cílem simulace je poskytnout rámec pro návrh opatření, příp. jejich kombinace, které mají nejmenší negativní vliv na spotřebu piva v modelové populaci a současně vedou k nejlepšímu možnému průběhu epidemie. Jde tedy o nástroj pro nalezení rovnováhy mezi spotřebou piva a počtem nakažených, resp. zemřelých.

CBS se skládá ze 2 částí – Generátoru populace a její základní mobility a Simulátoru, ve kterém jsou modelovány jednotlivé kroky, dochází k infikacím, konzumaci piva, aktivaci protiepidemických opatření atd. Simulátor nemůže běžet bez výstupů Generátoru, zatímco Generátor je na nastavení a charakteristikách Simulátoru zcela nezávislý – poskytuje bázi dat s definicí stavů. Motivací k rozdělení modelu na 2 části je snížení doby běhu simulace a možnost uložení různých konfigurací populace, onemocnění a dalších entit pro experimenty.

V dalším textu budou obě části popisovány společně (pokud to bude přínosné z hlediska funkcí nebo užitečné pro pochopení modelu) a označeny názvy Generátor a Simulátor.

2.1.2 Entity a stavové proměnné

Entity modelu CBS lze rozdělit do 4 hlavních skupin – *Populace*, *Prostor*, *Epidemie* a *Čas*. Jakákoliv aktivita v modelu pak pracuje s charakteristikami těchto skupin (v případě *Epidemie* je výjimkou základní běh modelu – bez epidemie, sloužící pro získání srovnávací báze, resp. referenční hodnoty).

Čas

Entita *Čas* zastupuje časování modelu při běhu Simulátoru a je nejjednodušší ze všech entit. Plynutí času v Simulátoru je koncipováno pomocí kroků, přičemž 1 krok představuje 1 hodinu simulačního času. Celá simulace pak běží 100 dní, tj. 2400 kroků, což je dostatečná doba pro mapování průběhu epidemické vlny i jejích dopadů na spotřebu piva (nastavení délky běhu Simulátoru závisí na rozhodnutí uživatele). Kroky jsou číslovány od 0, avšak 0. krok je využit k prvotnímu nastavení

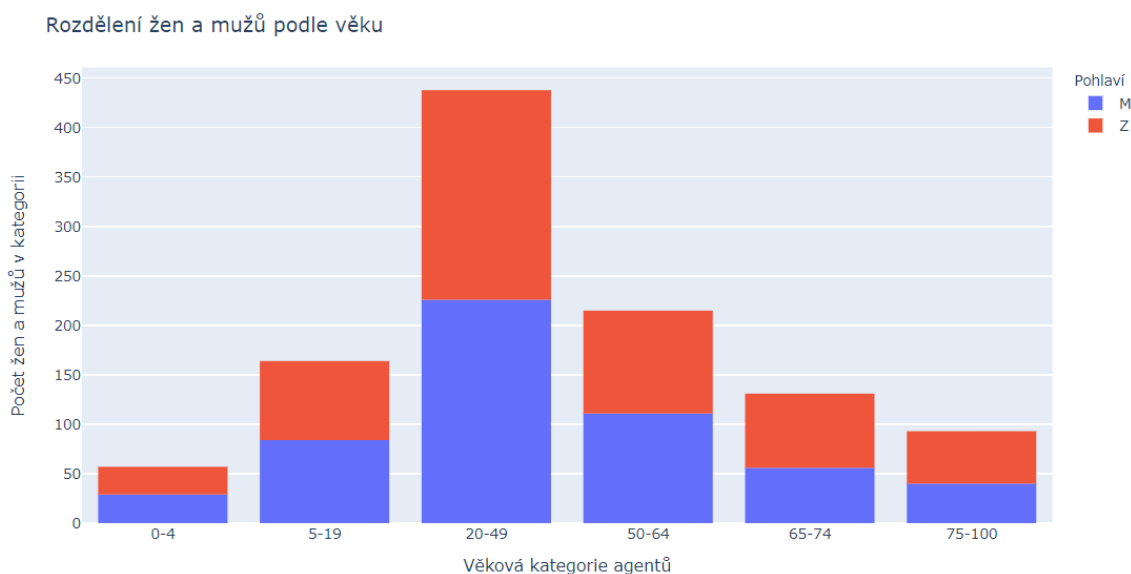
modelu v Simulátoru. Entita *Čas* je využívána Generátorem při tvorbě všech entit obsahujících jakékoliv časové plány – řetězce mobility agentů i průběh onemocnění v případě nakažení.

Stavovou proměnnou entity je počet kroků od počátku běhu Simulátoru a maximální počet kroků, po které Simulátor běží.

Populace

Populace se skládá z jednotlivých agentů a jejich vazeb a vlastností. Vytvoření entity *Populace* je pak úlohou Generátoru. Generátor pracuje se vstupními daty definovanými v konfiguračním souboru formátu JSON – v CBS se jedná o soubor `config_gen.json` umístěný ve složce `data/source` v projektové složce CBS. Konfigurační soubor je rozdělen do větví – pro entitu *Populace* se jedná o konfigurační větev označené klíči `populace`, `domacnosti`, `imunita` a `pivo`. Mimo souboru `config_gen.json` je pro konstrukci populace a její mobility důležitý soubor `mobilita.csv`.

Klíč populace popisuje složení populace, resp. podíl mužů a žen v jednotlivých věkových kategoriích společně s důležitými epidemiologickými charakteristikami jako je podíl asymptomatických průběhů onemocnění covid-19 v dané věkové kategorii apod. (zdroj: [7]). Velikost populace vytvořené Generátorem pro popisovanou konfiguraci CBS je 1098 agentů.

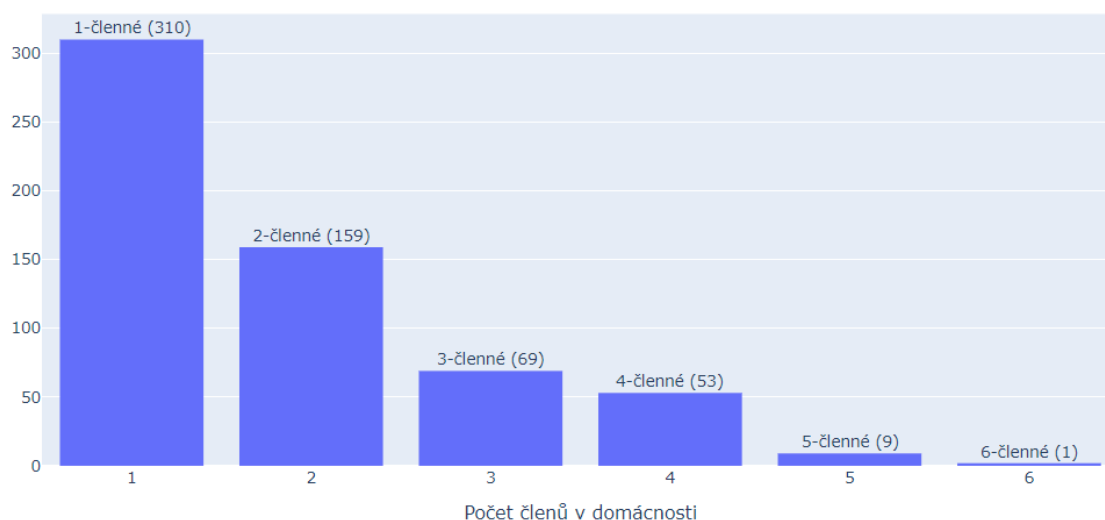


Obrázek 8 - Rozdělení agentů podle věkových kategorií

Výstup Generátoru odpovídá nastaveným parametrům konfiguračních souborů. Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Plotly)

Klíč domácnosti obsahuje strukturu domácností z hlediska počtu členů (zdroj: [74]). Výsledná struktura domácností odpovídá poměrům v konfiguračním souboru, viz. Obrázek 9.

Histogram domácností



Obrázek 9 - Rozdělení domácností

Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Plotly)

Každý agent má přiřazenu právě jednu lokaci označenou jako domácnost (lokace typu D). Agenti, kteří mají přiřazenu stejnou lokaci typu D, tj. stejnou hodnotu `house_id` tvoří společnou domácnost, jejíž velikost se v CBS pohybuje od 1 do 6 členů. V modelu nemůže nastat situace, kdy Generátor vygeneruje společnou domácnost tvořenou výhradně agenty mladšími 19 let a domácnosti s více členy tak zpravidla obsahují děti a jejich rodiče. Toho je docíleno tak, že Generátor neprve stanoví počet a strukturu domácností podle konfiguračních souborů a velikosti cílové populace. Každá domácnost (buňka gridu) obdrží unikátní identifikátor, domácnosti jsou seřazeny od nejpočetnější k jednočlenným a přidělování agentů k domácnostem pak probíhá v cyklu nejprve pro skupiny nezletilých (přičemž každá domácnost může obsahovat 0..N-1 nezletilých, kde N je celková velikost domácnosti), poté jsou přidělováni agenti věkově odpovídající rodičům nezletilých a nakonec jsou umístěni agenti nejstarší. Alokace agentů do domácností je tak sice náhodná, nicméně tato pravidla zajišťující, aby domácnosti nebyly vyjma nezletilých tvořeny např. jen kombinací agentů mladších 19 a starších 70 let). Z hlediska pořadí

konstrukce domácností a prioritizace podle věkových skupin jsou nejmenší, jednočlenné domácnosti tvořeny ve vyšší míře staršími agenty s vyšší pravděpodobností vážného průběhu onemocnění.

Klíč *imunita* specifikuje trvání imunity po prodělaném onemocnění, tj. dobu, po kterou jsou agenti imunní vůči reinfekci (zdroj: [10], [21], [23])

Klíč *pivo* specifikuje spotřebu piva v populaci a její rozdělení podle věkových kategorií a pohlaví (zdroj: [75], [76]). Součástí je odhad podílu zdravých nebo bezpříznakových agentů, kteří při nemožnosti navštívit restauraci (lokaci typu R) konzumují lahvové pivo. V CBS tvoří pro každou věkovou kategorii obsahující konzumenty piva pravděpodobnost substituce 15 % (odhad dle výsledků dotazníkového šetření). Tabulka 4 poskytuje přehled nastavení jednotlivých klíčů a jejich význam.

Tabulka 4 - Atributy klíče populace v config_gen.json

Klíč: POPULACE	
Atribut: kategorie	
Popis	Věková kategorie – rozsah (text) "od-do". Jedná se o strukturovaný text, např. „0-4“ odkazuje na skupinu agentů ve věku od 0 do 4 let (otevřený interval)
Atribut: podil_mužu	
Popis	Podíl mužů v dané věkové kategorii – desetinné číslo. Např. 0.0267 v kategorii "0-4" znamená, že v populaci je 2.67 % mužů ve věku do 4 let včetně
Atribut: podil_žen	
Popis	Podíl žen v dané věkové kategorii – desetinné číslo
Atribut: asypm_podil_muži	
Popis	Podíl mužů v dané věkové kategorii s asymptomatickým průběhem onemocnění – desetinné číslo. Např. 0.6375 v kategorii 0-4 = 63.75 % nemocných ve věku 0-4 let včetně má asymptomatický průběh onemocnění
Atribut: tezky_prubeh_hospitalizace_muži	
Popis	podíl mužů v dané věkové kategorii s těžkým nebo závažným průběhem onemocnění vyžadujícím hospitalizaci – desetinné číslo.

Klíč: POPULACE	
	Např. 0.016 v kategorii 0-4 = 1.6\% nemocných ve věku 0-4 let včetně vyžaduje hospitalizaci
Atribut: umrti_pri_hospitalizaci_muži	
Popis	podíl mužů v dané věkové kategorii s těžkým nebo závažným průběhem onemocnění (vyžadujícím hospitalizaci), kteří v důsledku onemocnění zemřou – desetinné číslo. Např. 0.006 v kategorii 15-19 znamená, že 0.6 % nemocných s těžkým nebo závažným průběhem ve věku 15-19 let onemocnění podlehe
Atribut: asympt_podil_zeny	
Popis	Podíl žen v dané věkové kategorii s asymptomatickým průběhem onemocnění – desetinné číslo
Atribut: tezky_prubeh_hospitalizace_zeny	
Popis	Podíl žen v dané věkové kategorii s těžkým nebo závažným průběhem onemocnění vyžadujícím hospitalizaci – desetinné číslo
Atribut: umrti_pri_hospitalizaci_zeny	
Popis	Podíl žen v dané věkové kategorii s těžkým nebo závažným průběhem onemocnění vyžadujícím hospitalizaci, které v důsledku onemocnění zemřou – desetinné číslo
Atribut: inkubacni_doba	
Popis	Délka inkubační doby ve dnech – po tuto dobu ještě nejsou patrné příznaky onemocnění (příznaky, s výjimkou asymptomatického průběhu, propukají až po uplynutí inkubační doby) - rozsah (text) "od-do". Např. „2-14“ v kategorii "0-4" znamená inkubační doba u 2-14 dnů pro danou věkovou kategorii (v aktuálním nastavení <i>config_gen.json</i> se inkubační doba, ani následující parametry v jednotlivých kategoriích neliší)
Atribut: symptomaticka_doba_stredni_prubeh	
Popis	Délka symptomatické fáze onemocnění (po projevení příznaků) u lehkých a středních průběhů nevyžadujících hospitalizaci nebo u průběhu asymptomatického – rozsah (text) "od-do". Strukturovaný text (rozsah), např. „5-9“ = délka asymptomatické nebo symptomatické epizody lehkého a středního průběhu v rozsahu 5-9 dnů pro danou věkovou kategorii
Atribut: symptomaticka_doba_tezky_prubeh	

Klíč: POPULACE	
Popis	Délka symptomatické fáze onemocnění u závažných a těžkých průběhů vyžadujících hospitalizaci – rozsah (text) "od-do". Např. „9-21“ znamená délku symptomatické epizody závažného nebo těžkého průběhu v rozsahu 9-21 dnů pro danou věkovou kategorii
Atribut: infekcni_doba_pred_priznaky	
Popis	Fáze asymptomatického super-přenašeče těsně před koncem inkubační doby – v této době a v prvním dnu po projevení příznaků dosahuje agent maximální hodnoty infekčnosti (tj. vylučuje nejvyšší množství životaschopných virových partikulí), virulence agenta od této chvíle postupně klesá – rozsah (text) "od-do". Např. „1-3“ znamená délku asymptomatické fáze s maximální virulencí v rozsahu 1-3 dny před projevením příznaků v dané věkové kategorii (v aktuálním nastavení <i>config_gen.json</i>) se inkubační doba, ani následující parametry v jednotlivých kategoriích neliší)

Tabulka 5 - Atributy klíče domácnosti v *config_gen.json*

Klíč: DOMACNOSTI	
Atribut: pocet_clenu_domacnosti	
Popis	Počet členů ve společné domácnosti (kategorie) a poměr počtu domácností dané velikosti na všech domácnostech – slovníkový formát {velikost domácnosti: podíl}. Např. 1 před dvojtečkou označuje jednočlennou domácnost, a číslo 0.285 značí, že jednočlenné domácnosti tvoří 28.5 % všech domácností

Tabulka 6 - Atributy klíče imunita v config_gen.json

Klíč: IMUNITA	
Atribut: kategorie_imunity	
Popis	Označení typu imunity – strukturovaný text (výčet). Např. „bez imunity“ znamená, že může být agent znovu infikován ihned po uzdravení
Atribut: delka_imunity_dny	
Popis	Trvání imunity ve dnech – rozsah (text) "od-do". Např. „30-179“ znamená, že agent s danou kategorií imunity je imunní alespoň 30, ale nejvýše 179 dnů po uzdravení
Atribut: podíl	
Popis	Podíl kategorie imunity na celkovém počtu agentů – desetinné číslo. Např. 0.27 u kategorie_imunity „kratkodoba“ udává, že 27 % agentů po prodělání nemoci zůstává imunní ještě 30-179 dnů

Tabulka 7 - Atributy klíče pivo v config_gen.json

Klíč: PIVO	
Atribut: kategorie	
Popis	věková kategorie konzumentů – rozsah (text) "od-do"
Atribut: konzumace_05_muži	
Popis	průměrná týdenní konzumace piva v půllitrech v dané věkové kategorii u mužů – desetinné číslo. Např. 6.3 u kategorie „18-29“ udává průměrnou spotřebu 3.15 l piva na agenta ve věku 18-29 let týdně
Atribut: konzumace_05_zeny	
Popis	průměrná týdenní konzumace piva v půllitrech v dané věkové kategorii u žen – desetinné číslo
Atribut: podíl_muži	
Popis	podíl konzumentů piva v dané věkové kategorii u mužů – desetinné číslo. Např. 0.84 u kategorie „18-29“ udává, že mezi agenty ve věku 18-29 let včetně jich pivo konzumuje 84 %
Atribut: podil_zeny	
Popis	podíl konzumentů piva v dané věkové kategorii u žen – desetinné číslo

Klíč: PIVO	
Atribut: podil_cepovane	
Popis	podíl čepovaného piva na celkové spotřebě (zbývající část je v modelu přiřazena pivu lahvovému) – desetinné číslo
Atribut: prechod_na_lahvove_podil	
Popis	podíl konzumentů piva, kteří jsou ochotni případné omezení konzumace čepovaného piva dorovnat konzumací piva lahvového – desetinné číslo. Např. hodnota 0.15 udává, že agent s 15 % pravděpodobností nahradí konzumaci čepovaného piva ve stejném množství pivem lahvovým při nemožnosti navštívit restaurační zařízení a za předpokladu dobrého zdravotního stavu.

Součástí entity *Populace* je i mobilita agentů, tedy plán jejich pohybu v Simulátoru. Soubor *mobilita.csv* definuje základ pro výpočet mobility agentů. Podle uvedených pravděpodobností, lokací a věkových kategorií pak Generátor vypočítává týdenní řetězec mobility pro každého z agentů – každý agent má tak na počátku svůj vlastní náhodně zvolený „cestovní plán“ pokrývající týden simulačního času (168 kroků).

Tabulka 8 - Struktura souboru *mobilita.csv*

Soubor: MOBILITA.csv	
Atribut: oblast	
Popis	označení cílové oblasti pohybu – D=domov, P=park, W=firma/škola (podle věku agenta), R=restaurace, N=nákupní zóna – strukturovaný text (výčet)
Atribut: kategorie	
Popis	věková kategorie agenta pro danou cílovou oblast – rozsah (text) "od-do". Např. „5-14“ znamená, že cílové oblasti na daných řádcích se týkají agentů věku mezi 5 a 14 let
Atribut: číselné sloupce 0...167	
Popis	čísla v názvu sloupců zastupují čísla kroků, resp. hodiny (ve výchozím stavu souboru je tedy definováno 24 hodin), čísla v řádcích jsou pak v rozsahu 0-1 a udávají pravděpodobnost, s jakou si pro danou hodinu agent vybere odpovídající řádkovou

Soubor: **MOBILITA.csv**

lokaci. Např. hodnota 0.2 u oblasti „N“ a kategorie „65-74“ ve sloupci 8 udává, že agent ve věku 65-74 let včetně se bude v 8 hodin ráno s 20 % pravděpodobností nacházet v lokaci některé z nákupních zón

Z hlediska entity *Populace* je výsledkem práce Generátoru výstupní soubor *df_agents.csv* obsahující specifikace agentů jako je např. průběh onemocnění při nakažení a jeho výsledek, označení domovské buňky, zaměstnání apod. a soubor *df_agent_moves.csv* s týdenním plánem mobility pro každého z agentů.

Prostor

Prostor je svět, ve kterém se agenti pohybují a v němž dochází ke vzájemným interakcím. Jedná se o čtvercovou síť (grid), přičemž každá buňka gridu má vlastní unikátní souřadnice a přiřazen alespoň jeden název lokace. Počet buněk je určen velikostí populace a z ní plynoucí strukturou lokací. Stejně jako u agentů je definice vlastností prostoru specifikována klíči v *config_gen.json*.

Klíč *podniky* obsahuje specifikace poměru organizaci na počet obyvatel a obchodu k jiným druhům soukromých společností. (zdroj: [78], [79], [80]).

Tabulka 9 - Struktura klíče podniky v config_gen.json

Klíč: PODNIKY	
Atribut: pocet_restauraci_na_obyvatele	
Popis	počet obyvatel na 1 restaurační zařízení – celé číslo. Např. 265 udává, že na 1 restauraci připadá 265 obyvatel
Atribut: pocet_zaku_na_skole	
Popis	průměrný počet žáků a studentů v 1 školním zařízení – celé číslo. Např. 224 udává, že 1 školní zařízení navštěvuje v průměru 224 žáků
Atribut: pomer_obchodu_k_firmam	
Popis	poměr obchodů (maloobchodní provozovny) na celkovém množství firem – desetinné číslo. Např. 0.242 uvádí, že 24.2 % všech firem v modelu tvoří obchodní provozovny

Klíč *firmy* specifikuje velikost malých a středních firem z pohledu počtu zaměstnanců a podílu různě velikých firem v prostředí ČR (zdroj: [77]).

Tabulka 10 - Atributy klíče firmy v config_gen.json

Klíč: FIRMY	
Atribut: min_velikost	
Popis	minimální počet zaměstnanců firmy (od) – celé číslo. Např. 1 udává, že daná firma má alespoň 1 zaměstnance
Atribut: max_velikost	
Popis	maximální počet zaměstnanců firmy (do) – celé číslo. Např. 9 udává, že daná firma má nejvíce 9 zaměstnanců.
Atribut: podíl	
Popis	podíl firem dané velikosti na celkovém počtu firem – desetinné číslo. Např. 0.267 udává, že firem s daným rozsahem zaměstnanců je na trhu 26.7 %

Typy lokací modelu CBS

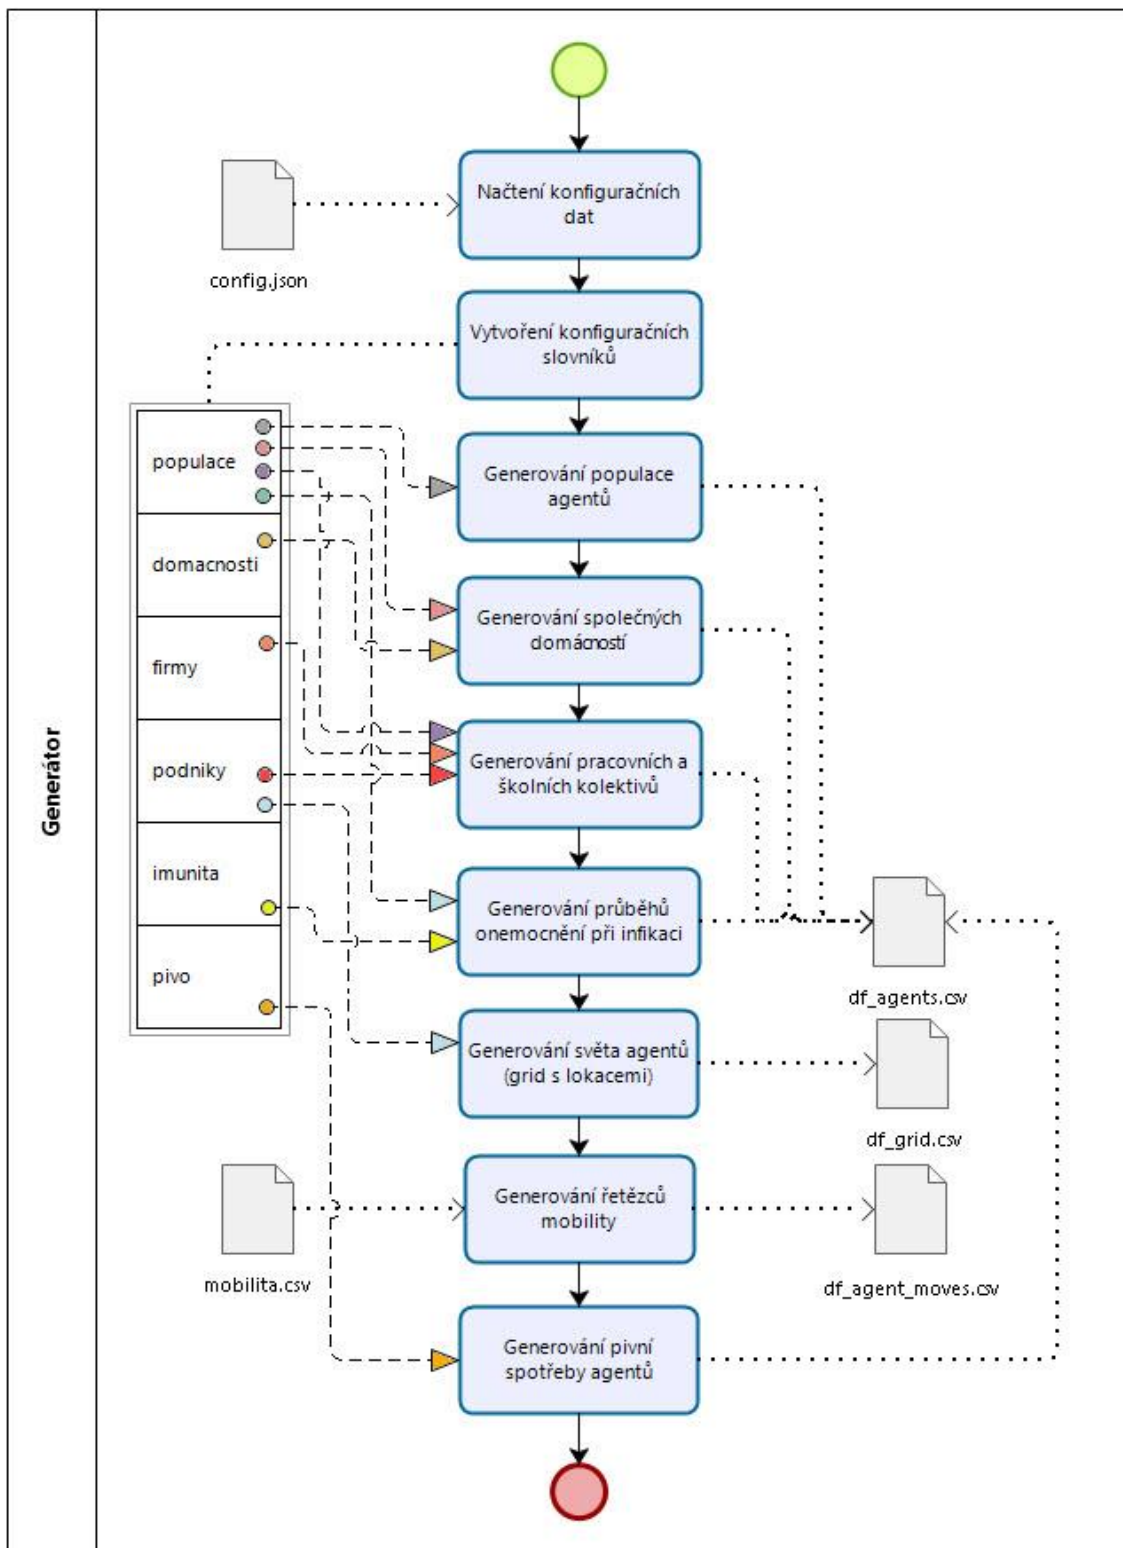
- Lokace D, domácnost (household) – domácnost je domovská buňka agenta. Každý agent má přiřazenu právě jednu lokaci typu D a agenti se stejnou lokací typu D pak tvoří společnou domácnost. Generátor vyvábí společné domácnosti o velikosti 1-6 agentů, v závislosti na velikosti populace a nastavení klíče *domacnosti*. V lokacích typu D agenti konzumují lahvové pivo.
- Lokace W, firma (Workplace) – jde o lokaci zaměstnání agenta. Agenti navštěvují svá zaměstnání, pokud spadají do odpovídajících věkových kategorií. Agenti se stejnou lokací typu W pak tvoří společný pracovní kolektiv. Generátor vytváří firmy až do velikosti 250 agentů, v závislosti na velikosti populace a nastavení klíče *firmy*.
- Lokace S, škola (School) – školu navštěvují v modelu CBS agenti do věku 18 let včetně. Významově jde o stejnou lokaci, jako je W, a rozdíl je dán jen věkem agentů. Pro vyšší přehlednost ve vygenerovaném gridu je ale škola označena vlastním typem. Agenti se stejnou lokací S pak tvoří společný školní kolektiv. Generátor vytváří školy v závislosti na velikosti populace a nastavení klíče *podniky*.
- Lokace N, nákupní zóna (shoppinG) – nákupní zóna je lokace, ve které agenti nakupují základní potřeby. Pokud model obsahuje více lokací typu N, navštěvují je agenti na základě náhodného výběru. Generátor vytváří nákupní zóny v závislosti na velikosti populace a nastavení klíče *podniky*, přičemž lokace typu N tvoří určitý podíl lokací typu W a jsou z lokací typu W vybírány. Z toho také vyplývá, že určité pracovní kolektivy agentů jsou v modelu také zaměstnanci nákupních zón.
- Lokace R, restaurace (Restaurant) – restaurace jsou lokace, ve kterých dochází ke konzumaci čepovaného piva. Pokud model obsahuje více lokací typu R, navštěvují je agenti na základě náhodného výběru. Stejně jako v případě lokací typu N vytváří Generátor restaurace v závislosti na velikosti populace a nastavení klíče *podniky*, přičemž lokace typu R tvoří určitý podíl lokací typu W

a jsou z lokací typu *W* vybírány. Z toho vyplývá, že určité pracovní kolektivy agentů jsou v modelu také zaměstnanci restaurací.

- Lokace *P*, park, příroda (Park) – přírodní lokace jsou otevřenou krajinou nebo městským parkem. Pokud model obsahuje více lokací typu *P*, navštěvují je agenti na základě náhodného výběru. Generátor vytváří parky jako desetinu počtu všech ostatních buněk gridu. Parky jsou lokací, ve které sice dochází k interakci mezi agenty, ale přenos případné infekce je díky otevřenému prostoru méně pravděpodobný.
- Lokace *H*, nemocnice (Hospital) – speciální typ lokace, kam jsou převáženi všichni agenti se závažným průběhem onemocnění vyžadující hospitalizaci. Lokace typu *H* je v gridu vždy jen jedna a není součástí modelování epidemie – žádní agenti modelu CBS nejsou zaměstnanci nemocnice a není modelován ani dopad epidemie na zdravotní systém.

Z pohledu entity *Prostor* je výsledkem práce Generátoru soubor `df_grid.csv` obsahující název lokace pro každou buňku společně s jejími souřadnicemi ve 2D prostoru jako dictionary. Např. `{'W':(2, 22)}` udává, že lokace se souřadnicemi $x=2$ a $y=22$ je typu *W*.

Entity *Prostor*, *Populace* a *Čas* pak Generátor využívá k tvorbě dalšího souboru – `df_agent_moves.csv`. Ten obsahuje řetězce plánu mobility agentů, přičemž je s populací v souboru `df_agents.csv` propojen pomocí identifikátoru agenta (`unique_id`). Soubor `df_agent_moves.csv` obsahuje 169 sloupců (první pro `unique_id` a další jsou jednotlivé hodiny týdne) a počet řádků odpovídá velikosti populace. V řádcích je pak uvedena lokace, na které se agent v danou hodinu týdne nachází (vypočteno pseudonáhodným výběrem z dat souboru `mobilita.csv` pro každého jednotlivého agenta).



Obrázek 10 - Schéma Generátoru

Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Bizagi Modeler)

Do uvedených konfiguračních souborů `df_agents.csv`, `df_agent_moves.csv` a `df_grid.csv` Generátor uloží vypočítaná data, která jsou vstupními daty pro Simulátor. Ten si je

po svém startu načte a využije pro tvorbu objektů a instancí modelu a agentů a pro samotný běh simulace. Jedná se o 2 třídy – třídu agentů `BeerAgent` (potomek třídy `mesa.model.Agent`) a třídu modelu `BeerModel` řídicího běh simulace (potomek třídy `mesa.agent.Model`).

Třída `BeerAgent`

Třída představuje reprezentaci agenta populace v Simulátoru, data agentů vychází z Generátoru.

Tabulka 11 - Atributy třídy `BeerAgent`

Třída: <code>BeerAgent</code>	
Atribut: age	
Popis	věk agenta
Výchozí hodnota / zdroj	<code>df_agents.csv</code> (age)
Atribut: sex	
Popis	pohlaví agenta
Výchozí hodnota / zdroj	<code>df_agents.csv</code> (sex)
Atribut: sicktype	
Popis	typ onemocnění po projevení příznaků
Výchozí hodnota / zdroj	<code>df_agents.csv</code> (sicktype)
Atribut: house_id	
Popis	jedinečné identifikační číslo domácnosti
Výchozí hodnota / zdroj	<code>df_agents.csv</code> (house_id)
Atribut: work_id	
Popis	jedinečné identifikační číslo pracoviště; pokud má agent nastavenou stejnou hodnotu pro <code>house_id</code> a <code>work_id</code> , je v domácnosti (péče o děti, důchod)
Výchozí hodnota / zdroj	<code>df_agents.csv</code> (work_id)
Atribut: age_categ	
Popis	věková kategorie
Výchozí hodnota / zdroj	<code>df_agents.csv</code> (age_categ)

Třída: BeerAgent	
Atribut: immunity_duration (imd)	
Popis	počet kroků, po které je agent imunní vůči reinfekci
Výchozí hodnota / zdroj	df_agents.csv (immunity_duration * 24)
Atribut: incubation_period (ip)	
Popis	počet kroků od nákazy k projevení příznaků, tj. délka inkubační doby
Výchozí hodnota / zdroj	df_agents (incubation_period * 24)
Atribut: spreader_period_from (spf)	
Popis	číslo kroku v rámci incubation_period, kdy nakažený agent začne být infekční. Po dosažení tohoto čísla kroku virulence dosahuje maxima
Výchozí hodnota / zdroj	df_agents (agent.spreader_period_from * 24)
Atribut: sickness_period (sp)	
Popis	počet kroků příznakové fáze onemocnění (od konce inkubační doby do vyléčení), tj. délka symptomatické fáze onemocnění
Výchozí hodnota / zdroj	df_agents (sickness_period * 24)
Atribut: infected_in_step (iis)	
Popis	číslo kroku, ve kterém došlo k infikaci (neinfikovaný nebo vyléčený agent má hodnotu iis rovnu 0)
Výchozí hodnota / zdroj	0 (v okamžiku infikace iis = číslo aktuálního kroku, pacient 0 má iis rovno 1)
Atribut: non_infectious_till (nit)	
Popis	číslo kroku, do kterého je nakažený agent neinfekční – vypočítaná hodnota ve chvíli nakažení
Výchozí hodnota / zdroj	vypočítaná hodnota (nit = iis + ip – spf)
Atribut: infected_by	
Popis	zdroj infekce – seznam unique_id agentů, od kterých byl agent infikován (v případě reinfekcí obsahuje

Třída: BeerAgent	
	seznam více hodnot). Inicializační infekce na počátku běhu modelu (pacient 0) je označena hodnotou -1
Výchozí hodnota / zdroj	prázdná hodnota
Atribut: infected_at_place	
Popis	název lokace, kde došlo k infekci agenta (seznam z důvodu reinfekcí)
Výchozí hodnota / zdroj	prázdná hodnota
Atribut: super_spreader_till (sst)	
Popis	číslo kroku v rámci běhu simulace, do kterého je agent super-přenašečem, resp. do přechodu fáze inkubační doby do fáze symptomatického onemocnění
Výchozí hodnota / zdroj	vypočítaná hodnota ($sst = iis + ip$)
Atribut: regular_illness_till (rit)	
Popis	číslo kroku v rámci běhu simulace, do kterého je nakažený agent v symptomatické fázi onemocnění, tj. jde o poslední krok onemocnění. Virulence agenta se v průběhu onemocnění lineárně snižuje od 100 % v kroku odpovídajícímu sst do 0 % v kroku odpovídajícímu rit. V této fázi onemocnění tedy agent již nemůže nikoho nakazit.
Výchozí hodnota / zdroj	Vypočítaná hodnota ($rit = iis + ip + sp$)
Atribut: immune_till (imt)	
Popis	číslo kroku v rámci simulace, do kterého je vyléčený agent imunní vůči reinfekci
Výchozí hodnota / zdroj	Vypočítaná hodnota ($imt = iis + ip + sp + imd$)
Atribut: quarantine_till	
Popis	číslo kroku v rámci simulace, do kterého má agent nařizenu karanténu, vypočítaná hodnota v okamžiku nákazy agenta

Třída: BeerAgent	
Výchozí hodnota / zdroj	Vypočítaná hodnota v okamžiku infekce, trvání karantény se bere z nastavení protipatření <i>quarantine</i>
Atribut: infectious_rate (ir)	
Popis	virulence (infekčnost) agenta – vypočítaná hodnota závisící na fázi onemocnění a případných protiepidemických opatřeních
Výchozí hodnota / zdroj	Vypočítaná hodnota (v době od <i>nit+1</i> do <i>sst+1</i> je <i>ir</i> = 1, v době od <i>sst+2</i> do <i>rit</i> lineárně klesá od 1 k 0, v každém jiném kroku je <i>ir</i> = 0)
Atribut: sickness_count	
Popis	Počet prodělaných onemocnění (epizod) v rámci simulace
Výchozí hodnota / zdroj	0
Atribut: sickness_result	
Popis	Výsledek onemocnění v kroku <i>rit+1</i> (u agentů, u kterých Generátor stanovil úmrtí v důsledku onemocnění, je uveden text „exitus“, ostatní agenti mají uvedenu prázdnou hodnotu)
Výchozí hodnota / zdroj	df_agents.csv (sickness_result)
Atribut: work_type	
Popis	typ pracovního poměru agenta – firma (W), škola (S) nebo domov (D)
Výchozí hodnota / zdroj	df_agents.csv (work_type)
Atribut: coord_house_xgrid, coord_house_ygrid	
Popis	x-ová a y-ová souřadnice domovské buňky agenta
Výchozí hodnota / zdroj	df_agents.csv (coord_house_xgrid, coord_house_ygrid)
Atribut: coord_work_xgrid, coord_work_ygrid	
Popis	x-ová a y-ová souřadnice zaměstnání agenta
Výchozí hodnota / zdroj	df_agents.csv (coord_work_xgrid, coord_work_ygrid)
Atribut: route_plan	

Třída: BeerAgent	
Popis	Týdenní (168 kroků) pohybový řetězec agenta – čísla kroků v rámci týdenního plánu tvoří indexy pole a označení cílové lokace je hodnota D, W, N, P nebo R na dané pozici
Výchozí hodnota / zdroj	df_agent_moves.csv (řádek s odpovídajícím číslem <i>unique_id</i> agenta)
Atribut: current_place	
Popis	Označení aktuální lokace agenta (D, W, N, P nebo R), vypočítaná hodnota podle čísla kroku v rámci simulace a odpovídajícího čísla kroku v <i>route_plan</i>
Výchozí hodnota / zdroj	Na počátku simulace jsou všichni agenti v lokaci typu D
Atribut: tydenni_spotreba_cepovane	
Popis	týdenní spotřeba čepovaného piva agenta
Výchozí hodnota / zdroj	df_agents.csv (tydenni_spotreba_cepovane)
Atribut: tydenni_spotreba_lahvove	
Popis	týdenní spotřeba lahvového piva agenta
Výchozí hodnota / zdroj	df_agents.csv (tydenni_spotreba_lahvove)
Atribut: beers_per_hour	
Popis	průměrná hodinová spotřeba piva – slovník s klíči „lahvove“ a „cepovane“. Vypočítaná hodnota závisící na počtu lokací R v řetězci mobility u agenta pro čepované pivo a počet lokací D v řetězci mobility pro pivo lahvové. Hodnoty se vypočítávají na začátku simulace a jsou platné pro celý běh (teoretická spotřeba piva je v průběhu simulace konstantní, skutečná spotřeba může být ovlivněna konkrétním stavem agenta a simulace)

Třída: BeerAgent	
	Agenti s prázdnou hodnotou <i>beers_per_hour</i> (prázdný slovník nenaplněný výpočtem) nejsou konzumenty piva
Výchozí hodnota / zdroj	Vypočítaná hodnota ($\text{beers_per_hour.lahvove} = \text{tydenni_spotreba_lahvove} / \text{počet lokací D v route_plan}$, $\text{beers_per_hour.cepovane} = \text{tydenni_spotreba_cepovane} / \text{počet lokací R v route_plan}$)
Atribut: tested_at_step	
Popis	číslo kroku v rámci simulace, kdy byl agent naposledy testován, hodnota je použita pro testování s danou frekvencí (např. 1x za 3 dny)
Výchozí hodnota / zdroj	Vypočítaná hodnota (na počátku simulace 0)
Atribut: positive_test_at_step	
Popis	číslo kroku v rámci simulace, kdy byl agent testován pozitivně
Výchozí hodnota / zdroj	Vypočítaná hodnota (na počátku simulace 0)
Atribut: smart_app_active	
Popis	příznak, zda je agent vybaven trasovací aplikací nebo tokenem (aplikace eRouška)
Výchozí hodnota / zdroj	False u agenta bez aplikace, True u agenta s aplikací – výpočet agentů s aplikací je dán nastavením v protiopatření <i>smart_app</i> (nastavení slovníku <i>penetration</i>)
Atribut: has_mask_till	
Popis	Číslo kroku v rámci simulace, do kdy agent nosí ochranu dýchacích cest – aplikuje se v případě cílených (individuálních) opatření na základě trasovací aplikace
Výchozí hodnota / zdroj	Vypočítaná hodnota (na počátku simulace 0, poté dle nastavení opatření <i>smart_app</i> a stavu epidemie)

Třída BeerModel

Třída představuje reprezentaci modelu, resp. simulace – zpracovává infekci agentů, aplikaci protiepidemických opatření i výstupní data populace.

Tabulka 12 - Atributy třídy BeerModel

Třída: BeerModel	
Atribut: data_path	
Popis	Cesta ke složce se zdrojovými (konfiguračními) a výstupními datovými soubory
Výchozí hodnota / zdroj	Pokud není zadána jiná složka, používá simulace složku „data“ v pracovním adresáři projektu Simulátoru
Atribut: max_steps	
Popis	Počet kroků simulace
Výchozí hodnota / zdroj	720 kroků (90 dnů), pokud uživatel nezadá jinou hodnotu
Atribut: beer_age_limit	
Popis	Limitní věk, od kterého mohou agenti v modelu konzumovat pivo
Výchozí hodnota / zdroj	df_agents.csv (house_id)
Atribut: df_agents	
Popis	Seznam agentů a jejich parametrů z Generátoru pro vytváření instancí třídy BeerAgent, uloženo v tabulkovém formátu (Pandas dataframe) jako archivace výchozího stavu (využito pro náhodný výběr parametrů onemocnění ze stejné věkové kategorie při reinfekci)
Výchozí hodnota / zdroj	df_agents.csv
Atribut: agent_age_categs	
Popis	Věkové kategorie agentů v simulaci
Výchozí hodnota / zdroj	Vypočítaná hodnota podle agentů v simulaci
Atribut: grid	
Popis	Čtvercová síť světa agentů definovaná jako MultiGrid – jednu buňku může obývat více než 1 agent

Výchozí hodnota / zdroj	Vypočítaná hodnota podle df_grid.csv
Atribut: places	
Popis	slovník lokací v modelu – klíčem je název lokace, hodnotou seznam buněk
Výchozí hodnota / zdroj	df_agents.csv (immunity_duration * 24)
Atribut: agents	
Popis	seznam instancí agentů v simulaci
Výchozí hodnota / zdroj	df_agents.csv (parametry agentů), df_agent_moves.csv (parametry řetězce mobility – route_plan)
Atribut: df_deaths	
Popis	Seznam instancí agentů, kteří v průběhu simulace podlehnou onemocnění
Výchozí hodnota / zdroj	prázdná hodnota
Atribut: beer	
Popis	Slovník pro uložení konzumace piva v simulaci, klíčem je druh piva (lahvove, cepovane), hodnotou dosavadní součet vypitého piva za všechny agenty
Výchozí hodnota / zdroj	0
Atribut: simtype	
Popis	typ simulace – hodnota určuje, zda bude simulace obsahovat i šíření epidemie
Výchozí hodnota / zdroj	výchozí hodnotou je „covid“ určující, že se v simulaci počítá se šířením epidemie, hodnota „no_covid“ pak označuje simulaci bez epidemie a slouží pro zjištění konzumace piva za běžných okolností (referenční hodnota)
Atribut: precautions	
Popis	seznam opatření pro aplikaci v simulaci, zadána uživatelem jako parametr při spuštění simulace pomocí main.py –precautions
Výchozí hodnota / zdroj	prázdná hodnota
Atribut: base_P	

Popis	základní pravděpodobnost nákazy v modelu, hodnota je konstantní v celém běhu simulace. Atribut <code>base_P</code> se používá k výpočtu <code>infectious_rate</code> agenta
Výchozí hodnota / zdroj	0.02
Atribut: tested_agents	
Popis	počet pozitivně a negativně testovaných agentů jako slovník s klíči „positive“ a „negative“
Výchozí hodnota / zdroj	0 na počátku simulace; pokud je součástí simulace protipatření test, po pozitivním nebo negativním výsledku testu se inkrementuje příslušná hodnota
Atribut: df_results	
Popis	výsledky každého kroku simulace v tabulkovém formátu, podkladová data pro vizualizaci a vyhodnocení opatření
Výchozí hodnota / zdroj	prázdná hodnota; tabulka se plní daty na konci každého kroku modelu
Atribut: df_infected_agents	
Popis	výsledky infikace v tabulkovém formátu – uložení informací o zdroji a cíli infekce, lokace apod. Slouží pro analýzu nejčastějších míst přenosu nákazy, sledování vlivu super-přenašečů apod.
Výchozí hodnota / zdroj	prázdná hodnota; tabulka se plní daty při každé úspěšné infikaci
Atribut: df_smart_contacts	
Popis	informace pro trasování kontaktů pomocí trasovací aplikace, data v tabulkovém formátu
Výchozí hodnota / zdroj	prázdná hodnota; tabulka se plní daty při kontaktech agentů vybavených trasovací aplikací a při aktivním protipatření <code>smart_app</code>
Atribut: df_agent_snapshot	

Popis	aktuálním stav agentů v tabulkovém formátu, nahrazuje vestavěný DataCollector frameworku MESA z důvodu optimalizace běhu simulace
Výchozí hodnota / zdroj	tabulka je naplněna v 0 kroku simulace po inicializaci agentů; přepočítání relevantních dat je spuštěno při každé aktualizaci agenta a jeho stavu
Atribut: <code>schedule</code>	
Popis	vlastní časovač (scheduler) modelu, agenti jsou pro provedení vlastního kroku aktivováni v náhodném pořadí (RandomActivation)
Výchozí hodnota / zdroj	-
Atribut: <code>precaution_mask</code>	
Popis	konfigurace protiepidemického opatření ochranou dýchacích cest jako slovník
Výchozí hodnota / zdroj	výchozí hodnoty všech protiopatření vychází z konfiguračního souboru <code>config_sim.json</code> (v případě <code>precaution_mask</code> jde o klíč <code>mask</code>)
Atribut: <code>precaution_lockdown</code>	
Popis	konfigurace protiepidemického opatření sektorovým, nebo úplným uzavřením lokací v simulaci – pokud jsou vyjmenovány všechny lokace mimo lokace typu D, pak jde o lockdown, v jiném případě o sektorová omezení
Výchozí hodnota / zdroj	<code>config_sim.json</code> (<code>sector</code>)
Atribut: <code>precaution_smart_app</code>	
Popis	konfigurace protiepidemického opatření trasovací aplikací (eRouška)
Výchozí hodnota / zdroj	<code>config_sim.json</code> (<code>smart_app</code>)
Atribut: <code>precaution_quarantine</code>	
Popis	konfigurace protiepidemického opatření karanténou – karanténa může být uvalena na agenty ve společné domácnosti nebo na pracovišti nakaženého agenta.

	<p>Sami nakažení agenti (mimo asymptomatický průběh nezachycený případným testem) zůstávají v karanténě automaticky a bez ohledu na aplikaci protiopatření.</p> <p>Pokud je karanténa uvalena na pracovní kolektiv zaměstnanců restaurace (lokace R), nebo je v karanténě kvůli zdravotnímu stavu nebo pozitivním testům více než 75 % zaměstnanců konkrétní lokace R, pak je dané zařízení uzavřeno do návratu minimálního počtu zaměstnanců do práce.</p>
Výchozí hodnota / zdroj	config_sim.json (karantena)
Atribut: precaution_test	
Popis	konfigurace protiepidemického opatření testováním
Výchozí hodnota / zdroj	config_sim.json (test)
Atribut: applied_precautions	
Popis	seznam protiepidemických opatření aplikovaných v daném běhu simulace
Výchozí hodnota / zdroj	seznam konfigurovaných protiopatření naplněný v závislosti na zadání parametrů od uživatele – obsahuje vždy jen protiopatření platná pro daný scénář simulace
Atribut: a_not_infected	
Popis	počet neúspěšných pokusů o infekci v průběhu simulace
Výchozí hodnota / zdroj	0 na počátku simulace; v případě neúspěšného pokusu o infekci je hodnota inkrementována
Atribut: a_newly_infected	
Popis	počet úspěšných pokusů o infekci v průběhu simulace
Výchozí hodnota / zdroj	0 na počátku simulace; v případě úspěšného pokusu o infekci je hodnota inkrementována
Atribut: a_postponed_r_visit	

Popis	počet odložených návštěv lokací typu R z důvodu rozhodnutí agentů
Výchozí hodnota / zdroj	0 na počátku simulace; v případě, kdy se agent rozhodne nepodstoupit riziko nákazy (s přihlédnutím ke stavu epidemie a vlastní věkové kategorii) a neuskuteční plánovanou návštěvu lokace typu R, je hodnota inkrementována
Atribut: a_realized_r_visit	
Popis	počet realizovaných návštěv lokací typu R podle <i>route_plan</i> agenta
Výchozí hodnota / zdroj	0 na počátku simulace; v případě realizace plánované návštěvy lokace typu R je hodnota inkrementována
Atribut: duration	
Popis	celková doba běhu simulace v sekundách
Výchozí hodnota / zdroj	0

Protiopatření

Jak již bylo zmíněno v předchozích částech, součástí modelu je také 5 protiepidemických opatření s různými možnostmi nastavení. Jedná se o ochranu dýchacích cest (*precaution_mask*), testování (*precaution_test*), trasovací aplikaci (*precaution_smart_app*), karanténu (*precaution_quarantine*) a sektorová omezení, příp. lockdown (*precaution_lockdown*).

Protiopatření jsou koncipována jako slovníky, přičemž každé protiopatření má mimo několika atributů, resp. dvojic klíč-hodnota stejných pro všechna nastavení, i své vlastní atributy odpovídající podmínkám a koncepci daného protiopatření (Tabulka 13). Data protiopatření čerpají ze souboru *config_sim.json* a jsou součástí třídy *BeerModel*.

Tabulka 13 - Atributy epidemiologických opatření

Klíč: **name**

Popis	Název protiopatření, nese informaci o konkrétní konfiguraci protiopatření zadané uživatelem
Platné pro	Všechna protiopatření
Klíč: trigger_threshold	
Popis	prahová hodnota pro aktivaci/deaktivaci protiopatření – pokud je dosažena při neaktivním stavu protiopatření, je protiopatření aktivováno a naopak, pokud je hodnota dosažena při aktivním protiopatření (např. při poklesu počtu nemocných pod prahovou hodnotu), je protiopatření deaktivováno (u deaktivace však záleží i na hodnotě <i>min_duration_in_steps</i>). Prahová hodnota odpovídá buď počtu symptomaticky nemocných s průběhem <i>mild</i> a <i>severe</i> , nebo počtu pozitivně testovaných (vybírá se nižší hodnota) v součtu za posledních 7 dnů.
Platné pro	Všechna protiopatření
Klíč: min_duration_in_steps	
Popis	Minimální délka trvání protiopatření v počtech kroků (např. hodnota 240 tak odpovídá 10 simulačním dnům). Pokud je dosaženo podmínek pro deaktivaci protiopatření, pak je protiopatření deaktivováno až ve chvíli, kdy uběhne právě tato minimální doba.
Platné pro	Všechna protiopatření
Klíč: stop_precaution_at	
Popis	Vypočtená hodnota při aktivaci protiopatření – číslo kroku v simulaci, do kterého je protiopatření aktivní za jakýchkoliv podmínek.
Platné pro	Všechna protiopatření
Klíč: applicable_age_categ	
Popis	Věkové rozmezí, pro které je protiopatření aplikovatelné – pokud např. nošení roušek není aplikovatelné pro osoby mladší 5 let a starší 99 let, pak hodnota <i>applicable_age_categ</i> = „5-99“. Pokud by měla být aplikace realizovatelná pro všechny věkové kategorie (jako je tomu např. u sektorových omezení), pak

	hodnota <i>applicable_age_categ</i> = „max“, nebo „0-100“, což je rozsah věku agentů v modelu
Platné pro	Všechna protiopatření vyjma <i>precaution_smart_app</i> , kde je využit jiný mechanismus cílových skupin
Klíč: chapters	
Popis	Počet aktivací daného protiopatření v průběhu simulace
Platné pro	Všechna protiopatření
Klíč: is_active	
Popis	Příznak, zda je dané protiopatření aktivováno (True), nebo deaktivováno (False). Aktivace a deaktivace probíhá při dosažení hodnoty <i>trigger_threshold</i> (a případně splnění dalších podmínek)
Platné pro	Všechna protiopatření
Klíč: protection	
Popis	Účinnost roušky v různých typech lokací (vnitřní prostory). Např. v lokacích typu D je možné předpokládat, že nakažený nebo potenciální nakažený, nebude schopen dodržovat protiopatření 24 h denně a/nebo zcela dokonale a hodnota 0.1 pro lokaci typu D tak znamená, že celková účinnost roušky v této lokaci je snížena o 90 %.
Platné pro	<i>precaution_mask</i> (přeneseně i <i>precaution_smart_app</i> , pokud <i>smart_action</i> obsahuje nasazení roušek)
Klíč: base_protective_value	
Popis	Hodnota ochrany obličejové masky, např. 0.95 znamená, že aplikace roušek sníží virulenci přenašeče o 95 %.
Platné pro	<i>precaution_mask</i> (přeneseně i <i>precaution_smart_app</i> , pokud <i>smart_action</i> obsahuje nasazení roušek)
Klíč: closed_locations	
Popis	Seznam uzavřených lokací – pokud se agent dle svého plánu mobility má přesunout na uzavřenou lokaci, vybere si náhodně náhradní neuzavřenou lokaci k přesunu. Pokud jsou uvedeny lokace typu R, W, N i P, pak se jedná o tzv. tvrdý lockdown se zákazem vycházení. Pokud je uvedena jen některá z lokací, pak

	jde o sektorové omezení (např. uvedení pouze lokace R znamená uzavřená restaurací).
Platné pro	precaution_lockdown
Klíč: penetration	
Popis	Představuje rozdělení trasovacích aplikací nebo tokenů ve věkových skupinách, čímž vlastně nahrazuje applicable_age_categ. Agenty vybavené chytrou aplikací je pak možné trasovat.
Platné pro	precaution_smart_app
Klíč: smart_action	
Popis	Označení akce, která je vyvolána při trasování kontaktů – „Q“ = karanténa na vytrasovaného agenta, „QD“ = karanténa na všechny členy společné domácnosti vytrasovaného agenta, „T“ = testování vytrasovaného agenta, „M“ = nasazení roušky u vytrasovaného agenta, „MD“ = nasazení roušek pro celou společnou domácnost agenta
Platné pro	precaution_smart_app
Klíč: smart_action_prob	
Popis	Podíl agentů (uživatelů trasovací aplikace), kteří se podřídí smart_action, nebo lze parametr využít i jako úspěšnost trasování
Platné pro	precaution_smart_app
Klíč: smart_action_duration	
Popis	Trvání opatření smart_action v počtech kroků (např. hodnota 240 znamená 10 simulačních dnů)
Platné pro	precaution_smart_app
Klíč: delete_db_after	
Popis	Doba retence záznamů v databázi trasovací aplikace ve dnech – po uplynutí této doby je záznam kontaktu smazán
Platné pro	precaution_smart_app
Klíč: quarantine_type	
Popis	Typ karantény – hodnota „D“ = karanténa na celou společnou domácnost, hodnota „W“ = karanténa na celý pracovní nebo školní kolektiv. Karanténa je aplikována na danou skupinu při

	pozitivním testu člena nebo po vypuknutí symptomatické fáze onemocnění typu <i>mild</i> nebo <i>severe</i> ve skupině
Platné pro	precaution_quarantine (přeneseně i precaution_smart_app, pokud smart_action obsahuje karanténu)
Klíč: test_type	
Popis	Označení typu testu – antigenní, nebo PCR. Oba typy testů se liší přesností a zpožděním obdržení výsledků a nelze aplikovat oba testy v rámci jedné simulace souběžně.
Platné pro	precaution_test (přeneseně i precaution_smart_app, pokud smart_action obsahuje testování)
Klíč: wait_till_result	
Popis	Zpoždění výsledků testu – pro antigenní test je zpoždění nulové, pro PCR je výchozí zpoždění 12 h.
Platné pro	precaution_test (přeneseně i precaution_smart_app, pokud smart_action obsahuje testování)
Klíč: frequency_once_per_days	
Popis	Povolená četnost testování ve dnech udává, jak často se může (musí) agent nechat otestovat. Např. hodnota 3 znamená, že mezi jednotlivými testy agenta musí uběhnout alespoň 3 dny, tj. 72 kroků. Hodnoty se mohou lišit pro antigenní a PCR test.
Platné pro	precaution_test (u precaution_smart_app s testováním je hodnota frequency_once_per_days ignorována – agent je otestován, i kdyby na test neměl nárok)
Klíč: accuracy	
Popis	Přesnost testu – s jakou pravděpodobností test odhalí virulentního agenta. Např. hodnota 0.7 udává, že pozitivní agent má 30% šanci na falešně negativní výsledek. Hodnoty <i>accuracy</i> jsou pro antigenní a PCR test různé.
Platné pro	precaution_test (přeneseně i precaution_smart_app, pokud smart_action obsahuje testování)
Klíč: test_places	
Popis	Označení typu lokace, na které může být agent otestován – může nabývat hodnoty W nebo D, přičemž W znamená, že je agent

	otestován při vstupu na pracoviště nebo do školy a D znamená domácí test (příp. testování v odběrových místech). Pokud jsou uvedeny obě hodnoty, je agent otestován, jakmile po uplynutí <i>frequency_once_per_days</i> od posledního testu dorazí na libovolnou z lokací.
Platné pro	precaution_test (u precaution_smart_app s testováním je agent otestován bez ohledu na aktuální lokaci)

Epidemie

Epidemie je tvořena přenosem infekce mezi agenty. Přenos je dán základní pravděpodobností a je řešen pomocí pseudonáhodného čísla při běhu Simulátoru. Úlohou Generátoru je na základě parametrů onemocnění a populace vypočítat průběh případného onemocnění u jednotlivých agentů. Simulátor pak s těmito informacemi pracuje v případě nakažení agenta. Infekci lze šířit mezi agenty na stejné buňce gridu, přičemž v daném kroku má každý infikovaný agent jeden pokus o infekci každého neimunního agenta na stejné pozici. Pravděpodobnost přenosu infekce se v CBS může měnit na základě protiopatření.

Pivo

Konzumace piva se liší lokací, ve které k ní dochází. Lahvové pivo je konzumováno v lokacích typu D, a to v každém kroku agenta průměrné hodinové množství konkrétního agenta nacházejícího se v příslušné lokaci. Agent lahvové pivo nekonzumuje v symptomatické fázi onemocnění, pokud je průběh onemocnění *mild*, nebo *severe*.

Čepované pivo je konzumováno v lokacích typu R, a to v každém kroku agenta průměrné hodinové množství konkrétního agenta nacházejícího se v příslušné lokaci. Agent čepované pivo nekonzumuje v symptomatické fázi onemocnění, pokud je průběh onemocnění *mild*, nebo *severe* a nekonzumuje je ani v případě uzavření lokací R, nebo při vlastní karanténě.

Sociální skupiny agentů

Agenti vytvářejí různé sociální skupiny: pracovní kolektivy, školní kolektivy, společné domácnosti, příp. skupiny zákazníků jedné nákupní lokace nebo skupiny návštěvníků restaurace. V těchto skupinách pak dochází k infikacím a šíření epidemie.

Skupiny jsou definovány v Generátoru na základě vlastností agentů (určující je věk) a podle konfigurace domácností, firem apod. Sociální skupiny společných domácností a pracovních a školních kolektivů jsou pevně dány – domovské ani pracovní buňky agentů se v průběhu simulace nemění. Skupiny zákazníků nákupních zón a restaurací (a případně i návštěvníků parků) jsou pak definovány na základě vypočtených plánů mobility a konfigurace nákupních zón a restaurací. Tyto skupiny se mění v závislosti na výběru konkrétní cílové lokace agenty.

2.1.3 Popis procesu a časování akcí

Pohyb

Pohyb agentů se řídí plánem mobility (`BeerAgent.route_plan`). Ty jsou generovány Generátorem a obsahují 168 kroků s označením lokace, na které se agent v daném kroku bude nacházet. 168 kroků tak odpovídá týdennímu cestovnímu plánu agenta. Výpočet lokace se řídí pravděpodobností výskytu agenta dané věkové skupiny na určité lokaci – viz. popis souboru `mobilita.csv` (Tabulka 8).

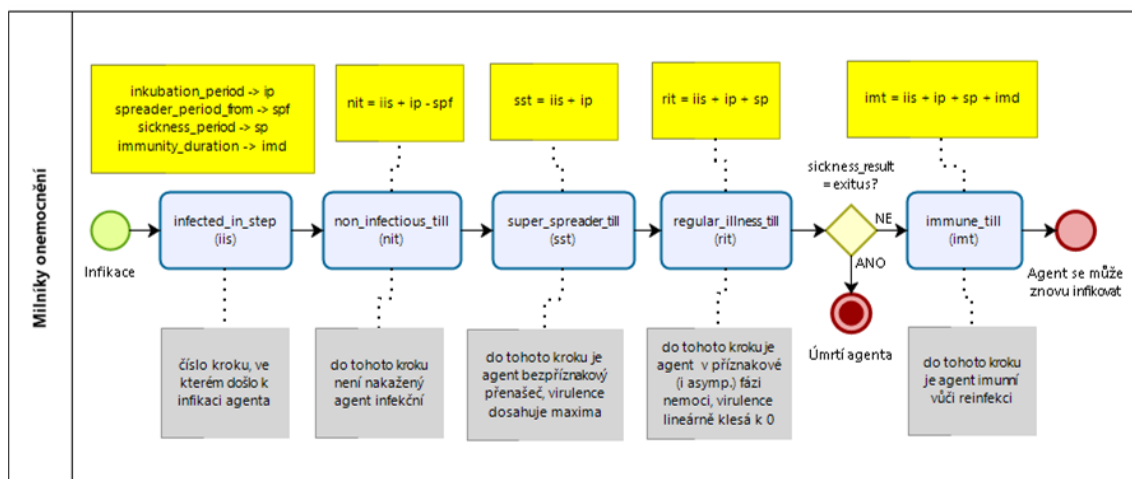
Lokaci agent mění každou simulační hodinu, tj. v každém kroku, kdy v rámci metody `move` ze svého řetězce `route_plan` vyčte plánovanou cílovou lokaci. Pokud je cílová lokace typu D a W, je pozice dána napevno pomocí x a y souřadnic agentova domova (`coord_house_xgrid`, `coord_house_ygrid`) a zaměstnání nebo školy v gridu (`coord_work_xgrid`, `coord_work_ygrid`).

Pokud je lokace typu N, P nebo R, pak si agent volí náhodně za běhu simulace z dostupných lokací daného typu a přesune se na zvolené souřadnice. Do lokace typu H se agent přesunuje jen v případě propuknutí symptomatické fáze onemocnění s vážným průběhem (`sicktype` je typu `severe`), tj. vyžadujícího

hospitalizaci, jinak jsou symptomaticky nemocní agenti v domácí karanténě pocelou dobu symptomatické fáze onemocnění. V průběhu některých scénářů mohou být určité typy lokací nedostupné, např. při sektorovém omezení restaurací není možné navštívit lokace typu R. V takovém případě agent zvolí náhradní lokaci dostupných otevřených lokací.

Zdravotní stav

Zdravotní stav agentů, resp. průběh a výsledek onemocnění je vypočítán Generátorem a vychází z klíčů populace a imunita se souboru config_gen.json. Data z Generátoru jsou pak transformována do instancí agentů při jejich vytvoření. Zdravotní data v instancích třídy BeerAgent jsou uvedena v parametrech sickness_result, immunity_duration, incubation_period, spreader_period_from a sickness_period. Popis významů je uveden v popisu třídy BeerAgent v kapitole 45 (Tabulka 11). V okamžiku nákazy pak Simulátor uloží číslo aktuálního kroku do atributu infected_in_step a z něj pak vypočítá čísla kroků pro následující zdravotní milníky non_infectious_till, super_spreader_till, regular_illness_till a immune_till. Při běhu modelu je pak agent zkontrolován a pokud číslo aktuálního kroku odpovídá některému z milníků, jsou provedeny úpravy parametrů agenta, cílové lokace, konzumace apod. – vždy dle momentální situace a stavu agenta.



Obrázek 11 - Pořadí a výpočet milníků onemocnění

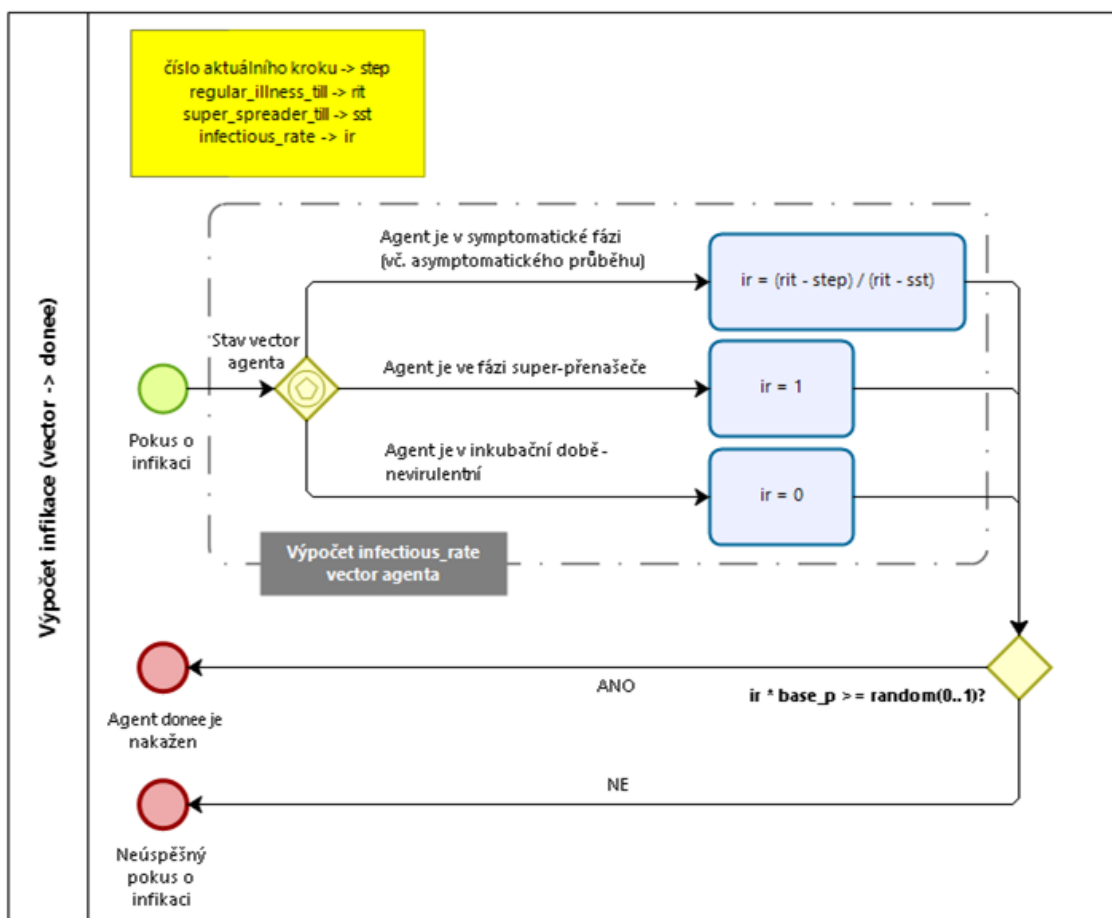
Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Bizagi Modeler)

Prvotní infikace a přenos onemocnění

Na počátku běhu simulace je náhodně vybrán agent pro infikaci (tzv. pacient 0). Náhodná ovšem není skupina, ze které je agent vybírán – jde o agenta žijícího ve společné domácnosti s alespoň 2 dalšími agenty, věkového rozmezí 20-40 let, pracujícího ve firmě odpovídající restauračnímu zařízení nebo obchodu. Důvodem pro takový výběr je rychlejší start epidemie, resp. zajištění, že v dané populaci nějaká epidemie vypukne. Při výběru např. samostatně žijícího seniora by k epidemii vůbec nemuselo dojít, protože sociální kontakty takového agenta budou mnohem méně četné. Asymptomatický průběh pak umožňuje delší dobu výskytu a šíření nákazy v populaci, aniž by byla zachycena zdravotním systémem.

Po přechodu do fáze super-přenašeče, která nastává v inkubační době před projevením příznaků onemocnění, se stává virulentním a může infekci dále šířit na neimunní agenty ve stejné buňce gridu. Přepočet infekce probíhá pro každou dvojici agentů 1x za krok modelu, což také znamená, že čím vyšší je množství infekčních agentů v buňce, tím vyšší je i pravděpodobnost infikace neimunního agenta na stejné pozici. Pravděpodobnost nákazy je dána součinem základní pravděpodobností nákazy v modelu ($\text{BeerModel.base_P} = 0.02$) a vypočtenou hodnotou virulence agenta (infectious_rate). K nákaze dojde, pokud je součin větší nebo roven náhodnému číslu z intervalu 0...1.

Agent, u kterého proběhl test s pozitivním výsledkem (v případě aktivace příslušného protiopatření) a/nebo agent, který je symptomaticky nemocný, zůstává v lokaci D, nebo H minimálně po dobu nastavenou u protiopatření karantény ($\text{precaution_quarantine.min_duration_in_steps}$) nebo do konce onemocnění (tj. minimálně 10 dnů, maximálně do kroku $\text{regular_illness_till}$).



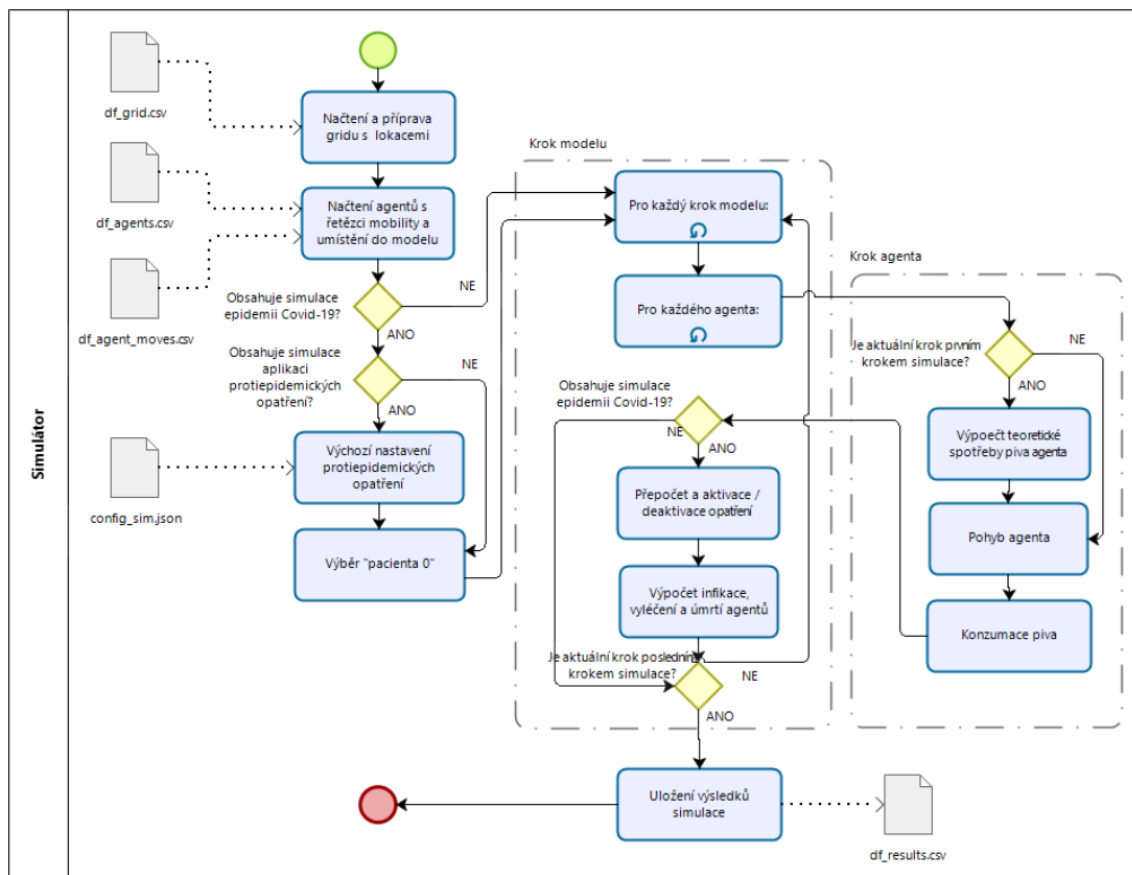
Obrázek 12 - Schéma procesu infekce a výpočet infectious_rate

Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Bizagi Modeler)

Pivní návyky agentů

Pivo je agenty konzumováno v podobě lahvového a čepovaného, přičemž lahvové pivo agenty konzumují v lokaci typu D a čepované v lokaci typu R. Zda agent pivo konzumuje, nebo nikoliv vychází z Generátoru (data pro výpočet podílu pijáků piva v dané věkové skupině a pro dané pohlaví agenta jsou uvedena v klíči pivo souboru `config_gen.json`). Pivo agenty konzumují kdykoliv se nachází ve vhodné lokaci – pijí zde svůj hodinový průměr vypočtený z týdenní konzumace piva a počtem návštěv lokací typu D a R v daném období. Pití piva může být také omezeno stavem agenta (agent v symptomatické fázi onemocnění s průběhem *mild*, nebo *severe* pivo nepije), nebo po uzavření lokací typu R při sektorovém omezení, nebo po uzavření restaurací z důvodu nedostatku personálu – lokace R je zavřena, pokud je dostupných méně než 25 % zaměstnanců.

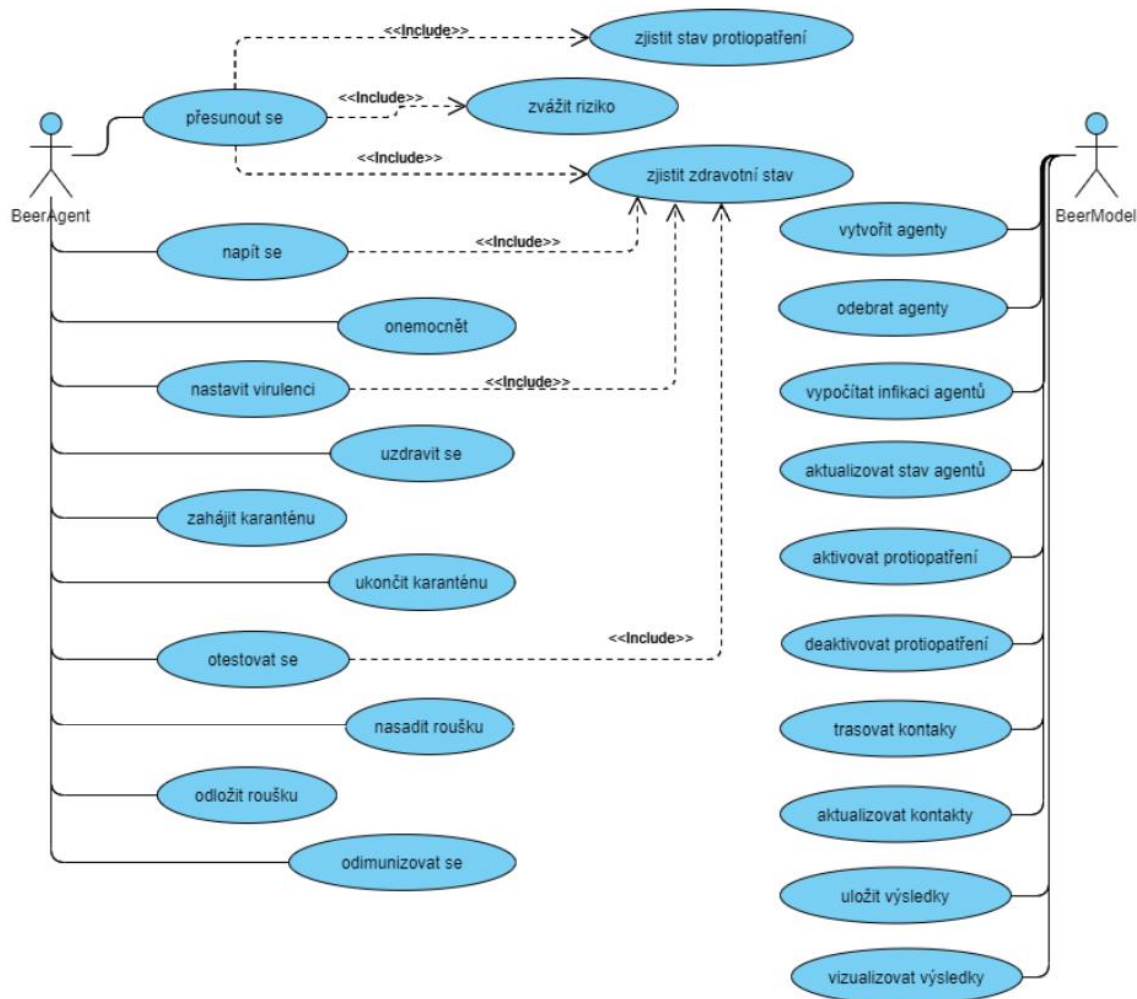
Níže je zobrazen zjednodušený postup akcí v rámci jednotlivých kroků modelu. Akce jsou rozděleny mezi model a agenty (agenti své kroky provádějí v rámci kroku modelu a pro svou činnost jsou aktivováni v náhodném pořadí) a je zde zakresleno i čerpání dat z csv souborů vytvořených Generátorem. Načtení dat, výchozí nastavení a výběr pacienta 0 probíhá v konstruktoru a tedy jednorázově. Ostatní akce se cyklicky opakují až do dosažení maximálního zadaného počtu kroků.



Obrázek 13 - Schéma činností Simulátoru

Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Bizagi Modeler)

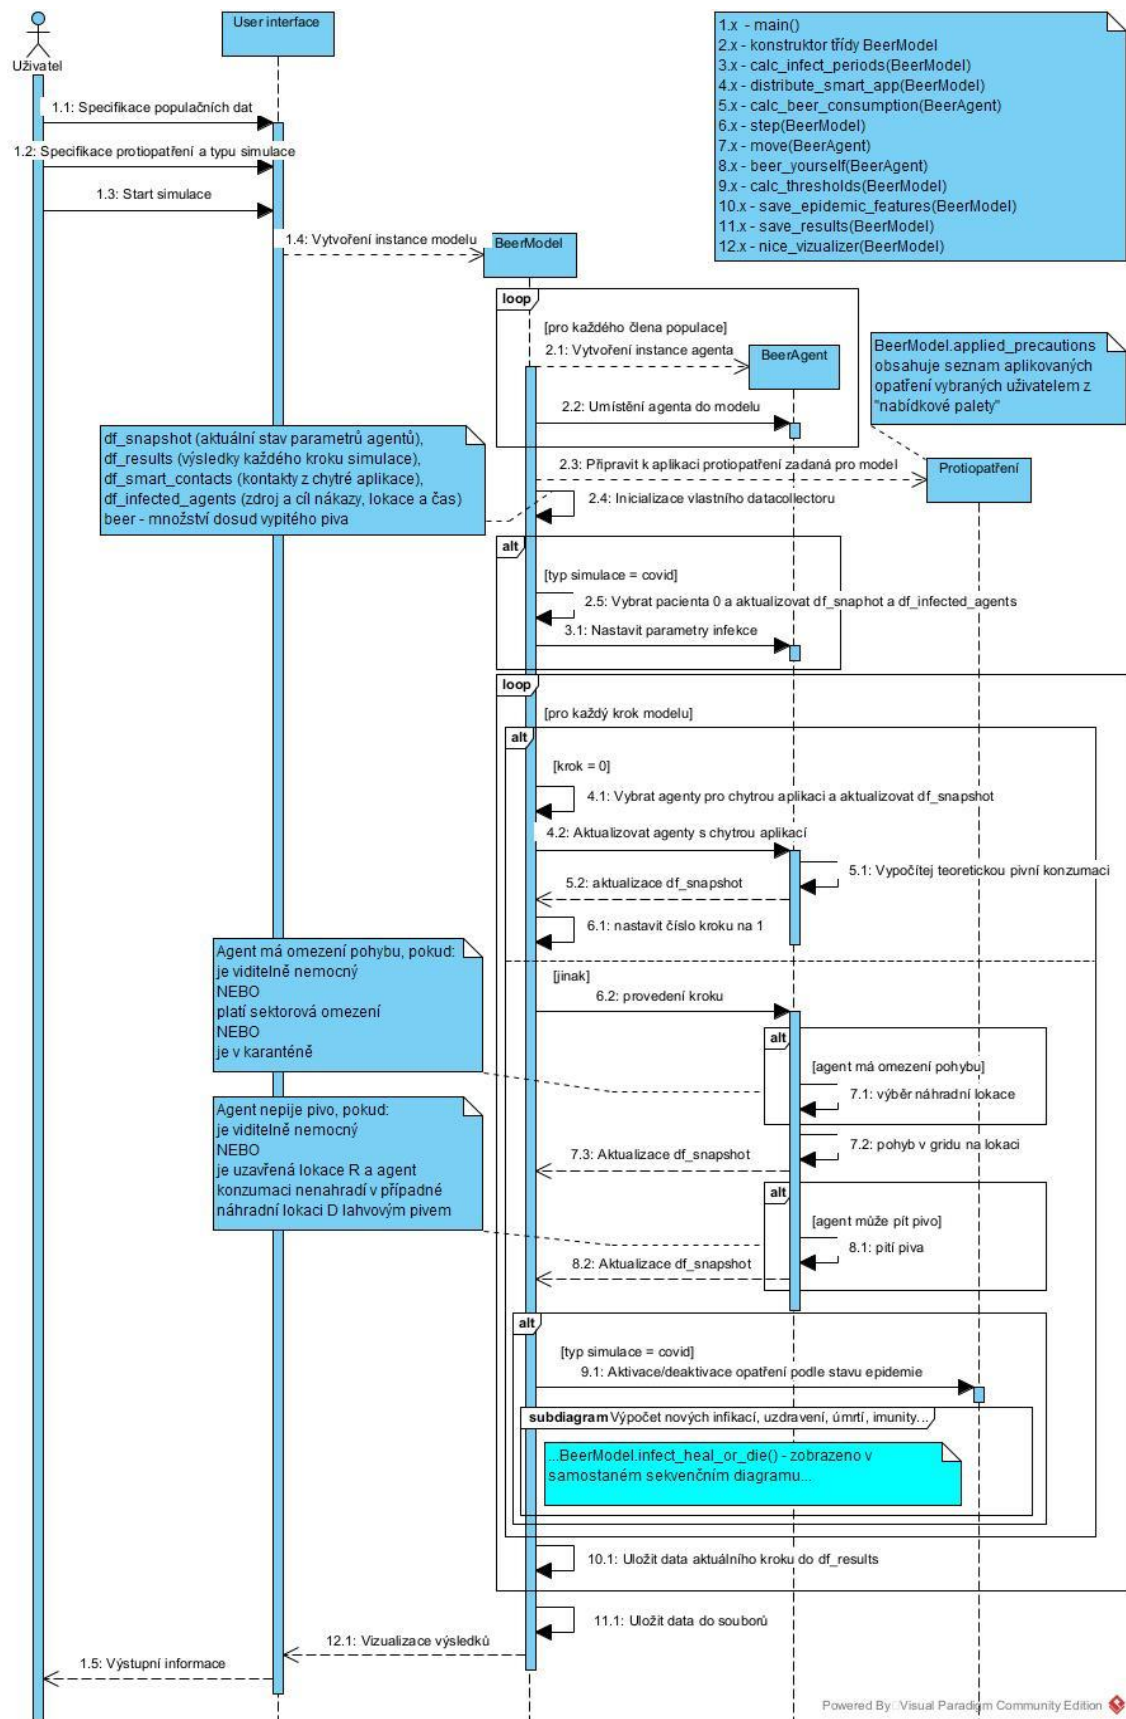
Pomocí UseCase modelu jsou pak níže (Obrázek 14) rozkresleny jednotlivé akce agenta a modelu – diagram informuje o všech aktivitách, které probíhají při běhu Simulátoru ze strany aktérů (agentů i modelu).



Obrázek 14 - Rozdělení akcí mezi agenty a model

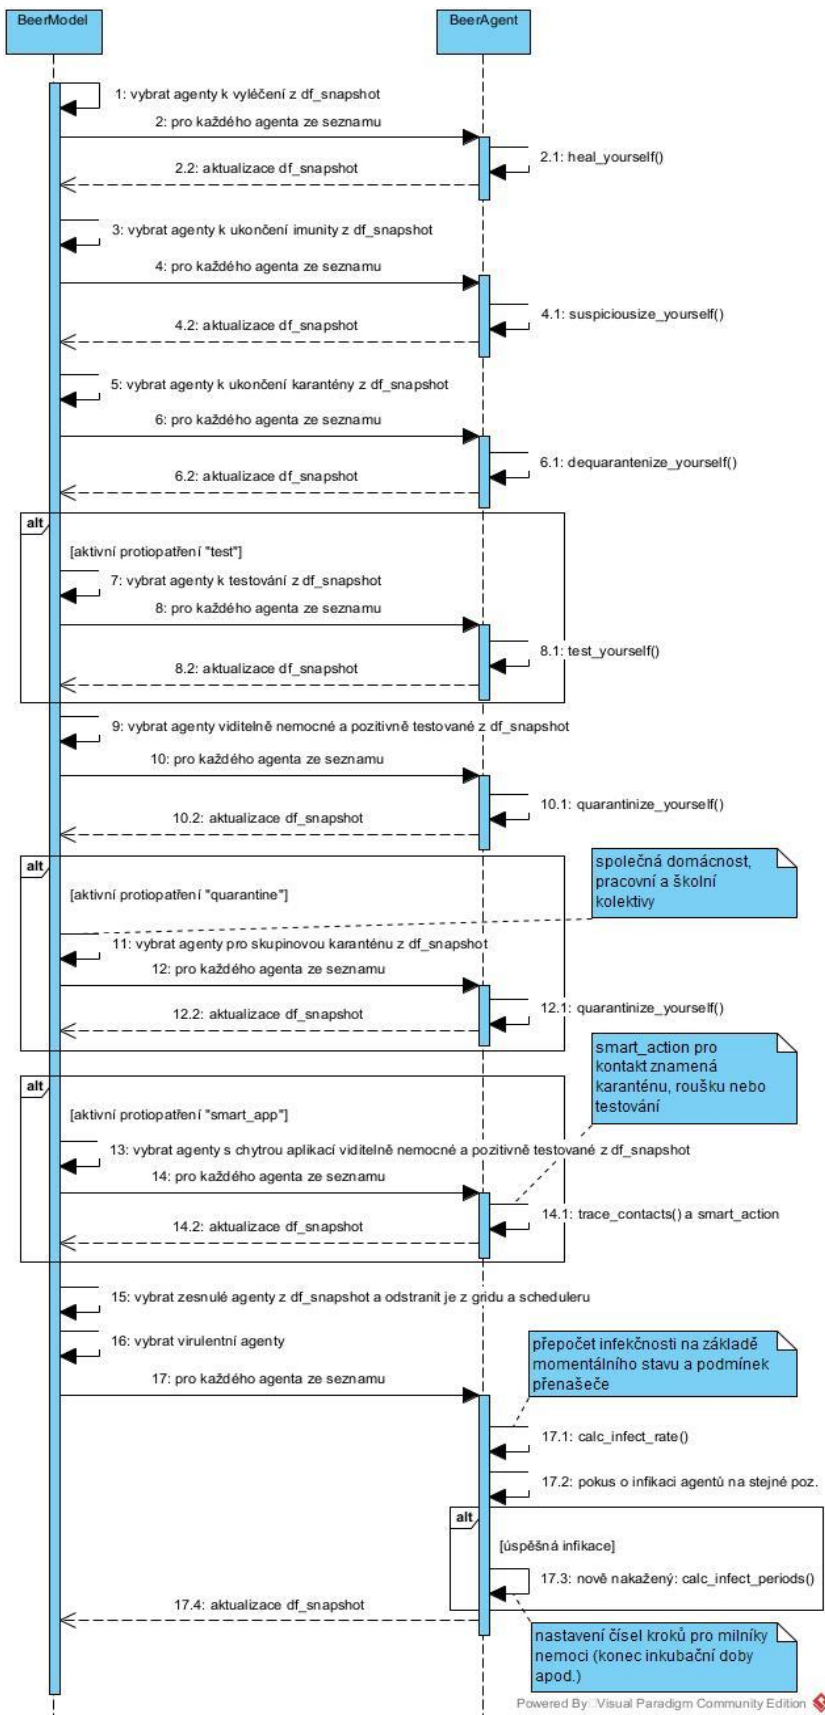
Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Visual Paradigm CE)

Časování jednotlivých akcí agentů a modelu je pak shrnuto v následujícím sekvenčním diagramu. V prvním případě (Obrázek 15) se jedná o náhled na celý systém simulace s chronologickým pořadím jednotlivých aktivit od nultého kroku sloužícího k inicializaci simulace, až po krok poslední s uložením výsledků. Jednou ze zajímavých částí běhu modelu BeerModel je metoda `infect_heal_or_die`, ve které dochází k výpočtům změn zdravotních stavů agentů (infikace, vyléčení, vyvanutí imunity apod.), inicializaci trasování, karantény nebo naopak její ukončení u relevantních agentů. Tato metoda je pak zobrazena v samostatném sekvenčním diagramu na další stránce (Obrázek 16).



Obrázek 15 - Sekvenční diagram běhu Simulátoru

Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Visual Paradigm CE)



Obrázek 16 - Sekvenční diagram metody infect_heal_or_die
 Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Visual Paradigm CE)

2.1.4 Návrhové vzory

Základní principy

Simulace implementuje epidemiologický model SEIRS, ve kterém jsou na počátku všichni agenti vnímaví k infekci (*Susceptible*). Po vystavení patogenu a úspěšném pokusu o infikaci přechází do inkubační doby, v jejíž první fázi nejsou virulentní (*Exposed*) a ve druhé fázi následuje šíření onemocnění od infikovaných agentů super-přenašečů a posléze i agentů v symptomatické fázi onemocnění (*Infected*). Po vyléčení z onemocnění a za předpokladu, že agent na jeho konci nezemře, jsou agenti po určitý čas imunní vůči reinfekci (*Recovered*). Imunita ovšem není časově neomezená a v případě, kdy vyvane před koncem simulace se agent vrací zpátky do skupiny vnímavých agentů (*Susceptible*). Doby trvání jednotlivých fází vychází ze vstupních dat Generátoru a odpovídají poznatkům o onemocnění covid-19 známým v době psaní tohoto textu.

Na pozadí modelu SEIRS pak probíhá konzumace piva a aktivace nebo deaktivace vybraných opatření proti šíření onemocnění. Tato opatření pak snižují konzumaci piva oproti referenčním hodnotám, tj. oproti modelu bez šíření epidemie (resp. takový je předpokládaný výsledek modelu).

Cílem je jednak navrhnout systém pro provedení simulačního experimentu a jednak se pokusit zmapovat vliv různých protiopatření (samostatně nebo ve vybraných kombinacích a konfiguracích) a načasování jejich aktivace na konzumaci piva a průběh epidemie.

Aby bylo možné z provedených experimentů vybrat nejvýhodnější scénář, je pro hodnocení zaveden bodový systém – od celkového množství vypitého piva je odečteno 10 bodů za každou úspěšnou infikaci a 1000 bodů za každého zemřelého agenta. Nejvýhodnější scénář tedy musí splnit dvě podmínky: musí účinně zamezit šíření epidemie a úmrtím agentů, a přitom co nejméně omezovat konzumaci piva.

Atraktory a emergence

CBS se bez epidemie se chová stabilně – agenti se pohybují dle svých týdenních náhodně vygenerovaných plánů (při jejichž znalosti lze dopočítat přibližný stav systému v libovolném bodě), dochází ke stabilnímu růstu konzumace, systém se chová předvídatelně.

V případě vypuknutí epidemie stabilita mizí – nakažení symptomatictí agenti jsou uzavřeni doma nebo v nemocnici, někteří v důsledku onemocnění zemřou. Při růstu parametrů epidemie se agenti mohou rozhodnout, že vynechají návštěvu restaurace pro minimalizaci rizika nákazy, ale stále existuje jistá možnost, že i v takovém případě si dají své oblíbené pivo doma, jen bude lahvové (množstvím však odpovídá původně plánované konzumaci v restauraci). Plány mobility se mění v závislosti na závažnosti epidemie a mění se i konzumace piva. Chování simulace je těžké předvídat. V případě jediné epidemické vlny je atraktorem takového systému pevný bod, ke kterému se systém dostane, jakmile epidemie skončí. V té chvíli se agenti vrací ke svým plánům a stabilnímu růstu spotřeby piva. Pokud by vypukla nová vlna epidemie, příp. byly simulovány mutace viru (oboje by vyžadovalo úpravu CBS), nová vlna nákazy opět systém vychýlí z rovnováhy.

Posledním případem simulace CBS je epidemie s aplikací protiopatření, resp. kombinací protiopatření, které dále znesnadňují předpověď chování a stavu systému v čase, nebo překvapivě dokonce jeho výsledků, protože ne všechny protiopatření nutně vedou ke zlepšení epidemiologické situace. Atraktor je stejný jako u předchozího příkladu. Emergentní chování systému je pak možné hledat právě v situaci, kdy jsou agenti a jejich svět ovlivňováni příliš mnoha výchozími parametry i působením zpětnovazebních smyček vlastních rozhodnutí. Výstupy simulace pak nemusí odpovídat očekávání, protože průběh se řídí pravidly vzniklými až za běhu systému v důsledku vývoje jeho vnitřních stavů. Vynořuje se tak emergence, jejímž výsledkem pak může být (a je) simulace, kde je i přes aplikované protiopatření počet zemřelých stejný nebo dokonce vyšší než u neřízeného promoření, navíc s citelným propadem sledované veličiny pивní konzumace, stejně tak jako simulace, kde je i přes zuřící epidemii spotřeba piva vyšší než v základním scénáři modelu bez epidemie.

Adaptace

Při konfiguraci modelu `simtype = covid` se agenti rozhodují, zda navštíví lokaci R v závislosti na stavu epidemie. Pravděpodobnost, že zůstanou v lokaci D místo plánované lokace R nebo N roste s počtem symptomatických onemocnění typu *mild* a *severe* ve scénářích bez testování, nebo s počtem pozitivních testů ve scénářích obsahujících testování, a to podle vzorce:

$$P = \frac{AC \cdot AI}{2 \cdot N}$$

kde

- P je pravděpodobnost změny plánované lokace z lokace typu R na lokaci D,
- AC je součet aktivních případů onemocnění za posledních 7 dnů, nebo součet pozitivních testů a aktivních případů onemocnění za posledních 7 dnů,
- AI je index věkové kategorie v seznamu věkových kategorií modelu (od 0 pro kategorii "0-4" po 6 u kategorie "75-100"),
- N je velikost populace (1098 agentů).

AI simuluje vliv obav agentů z nákazy, která má vyšší pravděpodobnost vážného průběhu u starších agentů, a tudíž bude právě u starších agentů patrná silnější motivace k vyhnutí se riziku.

Aby se agent rozhodl navštívit plánovanou lokaci R nebo N, musí být $P >$ náhodné číslo z intervalu 0...1.

Cíle

Primárním cílem agentů pijících pivo je napít se. V případě modelování epidemie je pak jejich sekundárním cílem agentů také vyhnout se nákaze, resp. v jistém smyslu zhodnotit přínos návštěvy lokace typu R nebo N versus riziko nákazy. Cílem modelu, resp. jeho uživatele, je maximalizovat konzumaci piva. Z tohoto hlediska je vhodné pokusit se ovlivnit epidemii tak, aby došlo k co nejnížšímu rozšíření onemocnění nebo byla křivka infekcí co nejplošší (a sedmidenní přírůstky

se tak držely na nízkých hodnotách) a agenti se mohli nerušeně věnovat svým primárním cílům.

Učení se

Adaptační chování agentů, tedy snahu vyhnout se nákaze v lokacích, jejichž návštěva není nezbytná (nákup lze realizovat s nižší frekvencí, nechat si zboží přivést, restaurace není nutné navštěvovat vůbec) lze považovat za typ učení, byť s předem danými informacemi – agenti ví, že riziko vážného průběhu onemocnění a úmrtí roste s věkem a podle toho se také rozhodují.

Procesem učení ale prochází i uživatel simulace, který hledá optimální kombinaci opatření a jejich konfiguraci k realizaci svého cíle – maximalizaci konzumace piva při co nejrychlejší eradikaci patogenu a co nejnižších ztrátách na životech.

Predikce

Rozhodování agentů neobsahuje prediktivní uvažování (tj. nepředjímají budoucí vývoj systému). Agenti se rozhodují stochasticky dle svých charakteristik, aktuálního stavu simulace a daných pravidel. Stejně tak se na základě aktuálního stavu rozhoduje model, zda bude aktivovat protipatření.

Citlivost

Vývoj systému ve scénářích s epidemií vykazuje citlivost vůči počátečním podmínkám. V první řadě jde o výběr pacienta 0, který je v aktuální konfiguraci vybírán jako náhodný pracující agent (viz. sekce Prvotní infekce a přenos onemocnění v kapitole 2.1.3) s asymptomatickým průběhem onemocnění. To umožňuje patogenu šířit se prostřednictvím pacienta 0 v populaci od počátku zcela nepozorovaně a epidemie je rozpoznána až ve chvíli, kdy sekundární nakažení přejdou z fáze superpřenašečů do symptomatické fáze (sicktype nakažených agentů je *mild* nebo *severe*). V množině agentů vhodných k výběru pacienta 0 pak navíc záleží i na délce fáze superpřenašeče, délce regulérního onemocnění, počtu a složení rodinných příslušníků a velikosti a typu zaměstnání pacienta 0. To vše ovlivňuje

rychlost počátečního šíření epidemie (v případě výběru symptomatického pacienta 0 by byla epidemie zachycena mnohem dříve a zkrátil by se i čas, kdy je agent skrytým přenašečem).

Systém je také citlivý na nastavení protiopatření, a to jak z hlediska jejich kombinací a uživatelských konfigurací, tak z hlediska uživatelem zvolené hodnoty `trigger_threshold` pro aktivaci a deaktivaci protiopatření.

Interakce

Nejviditelnější interakcí mezi agenty je šíření onemocnění. K tomu dochází v rámci společné buňky gridu, na které se nachází alespoň jeden virulentní a jeden neimunní agent (infikace může být úspěšná, nebo neúspěšná, ale v každém případě jde o interakci). Jako přímou interakci pak lze chápat i trasování pomocí chytré aplikace a její databáze kontaktů – dopad na vytrasovaného agenta pak může být stejný jako by byl nakažen, např. uvalení karantény. Nebo karanténa pro relevantní skupinu agentů.

K nepřímé interakci pak dochází v rámci celé populace, resp. z hlediska cílů modelu zejména té části, která je konzumentem piva. Při šíření epidemie a při současné existenci protiopatření v simulaci pravděpodobně dojde k aktivaci protiopatření a tím i k možnému omezení širší skupiny agentů v pivní konzumaci. Jde zejména o sektorová omezení, karanténu a trasování, které mají vliv na mobilitu agentů. V menší míře se to však týká i testování, jehož výsledkem může být karanténa pozitivně testovaných agentů (bez testování by k omezení např. u asymptomaticky nemocných agentů nemuselo dojít vůbec).

Náhodnost


Náhodnost je široce využívanou vlastností ve všech částech modelu, byť je omezena určitými mezemi, jako jsou zdravotní podmínky, pravděpodobnost výskytu na lokacích, zda agent pije, či nepije pivo apod. - vše rozděleno v rámci věkových skupin. Je však třeba také poznamenat, že stochastické parametry jsou rozděleny mezi Generátor a Simulátor. Zatímco Generátor počítá s náhodnými vlivy v průběhu budování populace, Simulátor již tato data jen využívá ke svém běhu jako

daná pravidla, zdánlivě nenáhodná (např. plány mobility nebo průběh a výsledek onemocnění jsou při pohledu omezeném pouze na Simulátor nenáhodné veličiny). Ve výsledku jsou ale tyto parametry stále náhodné, jen uložené v rámci jiného procesu z důvodu rozdělení činností a zvýšení efektivity simulace.

V rámci Simulátoru je také počítáno s konstantní řadou náhodných čísel pro rozhodování (cíle pohybu, úspěšnost infekce aj.). Důvodem je reprodukovatelnost a testovatelnost modelu. Toho je docíleno zadáním hodnoty *seed* pro generátor pseudonáhodných čísel – pro výsledky je použita hodnota *seed* = 42.

Kolektivy

Agenti dodržují pravidla, která jsou jim vnucena nastavením systému (populací a mobilitou danou Generátorem). Mezi tato pravidla patří tvorba skupin – společné domácnosti, pracovní a školní kolektivy, díky kterým dochází k vytváření pevných sítí a sociálních vazeb. Agenti nemění přiřazenou domácnost, ani pracovní nebo školní kolektiv a vztahy mezi agenty v těchto skupinách jsou tak trvalé a přerušované jen vlivem protipatření nebo nemoci. Stejně tak šíření onemocnění je, s přihlédnutím k pravděpodobnosti přenosu, do určité míry předvídatelné. Kupříkladu níže (Obrázek 17) je uvedeno zobrazení síťového grafu členství ve skupinách u vybraného vzorku 12 domácností. Modré uzly představují agenty, zelené uzly jsou domácnosti, oranžové firmy a červený uzel představuje školu. Orientované hrany definují členství vybraných agentů v jednotlivých sociálních skupinách, resp. přiřazení agentů ke konkrétním lokacím různých typů. Podle stupňů uzlů je možné detekovat lokace, jejich prostřednictvím se bude infekce šířit nejrychleji.



Obrázek 17 - síťový graf sociálních vazeb

Zdroj: vlastní archiv autora (vytvořeno pomocí knihovny networkx)

V tomto konkrétním případě půjde zejména o lokaci školy s `work_id = 596` a firmy s `work_id = 600`. Úspěšná infekce v těchto lokacích představuje start masivního šíření onemocnění po hranách grafu ke členům domácností a od nich dále na členy dalších sociálních skupin. Se znalostí pevných vztahů by pak bylo možné nejen předcházet masivnímu šíření infekce pomocí uzavření uzlů s vysokými stupni (což je vlastně motivace pro sektorová omezení), ale i zpětně trasovat cestu infekce populace a ze zjištěných skutečností predikovat další vývoj.

Mimo pevných sociálních vazeb obsahuje simulace i vazby dynamické, resp. náhodné. Jedná se o návštěvníky lokací vybíraných náhodně z dané množiny dostupných pozic – především restaurace, nákupní zóny a parky. Sociální skupina je v takovém případě předem neodhadnutelná a zpětně nesledovatelná, vytvářená ad-hoc, nicméně dopad na šíření epidemie je stejný, jako u uzlů lokací v pevných vztahových sítích – čím vyšší je stupeň uzlu, ve kterém se nachází virulentní agent, tím masivnější pravděpodobně bude šíření epidemie modelovou populací. Problémem dynamických vazeb, který epidemiologickou situaci ještě více zhoršuje, je i schopnost náhodně propojovat různé statické skupiny, které by se jinak vzájemně vůbec nemohly ovlivnit.

Částečnou odpovědí na ad-hoc sociální skupiny je trasování pomocí chytré aplikace. Zaznamenávání kontaktů agentů vytváří historii takových skupin a umožňuje pak dohledávat kontakty nakažených a případně rozšířit restriktce na jejich pevné sociální sítě (např. karanténa na členy společné domácnosti kontaktu). Kontakty v rámci trasovací aplikace jsou tak vlastně další sociální skupinou, která se formuje za běhu simulace.

Pozorování

Výstupy z běhů simulací jsou ukládány až v posledním kroku. Jedná se o soubor se stavem simulace na konci každého kroku, tj. dataframe `df_results` uložený do csv formátu (název souboru je tvořen typem simulace, seznamem protiopatření a počtem kroků, např. „`covid_sector_r!1-test_dw!0_720.csv`“ bude obsahovat data 720 kroků simulace šíření epidemie covid s aplikovaným opatřením testování od počátku běhu a sektorovým uzavřením lokací R, jakmile je detekován první pozitivní test)

Tabulka 14 - Parametry souboru s výsledky každého kroku simulace

Soubor s výsledky kroků simulace – uložený <code>df_results</code> (csv)	
Atribut: <code>new_infections</code>	
Popis	počet úspěšných pokusů o infikaci v daném kroku
Atribut: <code>plain_infection_attempts</code>	
Popis	počet neúspěšných pokusů o infikaci v daném kroku
Atribut: <code>postponed_r_visits</code>	
Popis	suma odložených návštěv lokace typu R proti plánu od počátku běhu simulace v závislosti na stavu epidemie a rozhodnutí agentů
Atribut: <code>realized_r_visits</code>	
Popis	suma realizovaných návštěv lokace typu R podle plánu mobility agentů
Atribut: <code>beer_consumption_sum_cepovane</code>	
Popis	suma zkonsumovaného čepovaného piva od počátku simulace
Atribut: <code>beer_consumption_sum_cepovane</code>	
Popis	suma zkonsumovaného čepovaného piva od počátku simulace

Soubor s výsledky kroků simulace – uložený <i>df_results</i> (csv)	
Atribut: beer_consumption_sum_lahvove	
Popis	suma zkonsumovaného lahvového piva od počátku simulace
Atribut: death_agents	
Popis	suma agentů, kteří zemřeli v důsledku onemocnění od počátku simulace
Atribut: death_agents_avg_age	
Popis	průměrný věk zemřelých agentů
Atribut: infected_or_sick_agents	
Popis	počet infikovaných agentů v libovolné fázi onemocnění v daném kroku simulace
Atribut: prec_lockdown_is_active	
Popis	označení aktivního (1) nebo neaktivního (0) protipatření lockdown/sektoř v daném kroku
Atribut: prec_lockdown_closed_locations	
Popis	seznam uzavřených lokací při aktivním protipatření v daném kroku
Atribut: prec_lockdown_is_chapter	
Popis	počet aktivací protipatření od počátku simulace
Atribut: prec_mask_is_active	
Popis	označení aktivního (tj. 1) nebo neaktivního (tj. 0) protipatření ochrany dýchacích cest (pro celou relevantní populaci) v daném kroku
Atribut: prec_quarantine_is_active	
Popis	označení aktivního (tj. 1) nebo neaktivního (tj. 0) protipatření ochrany karantény v daném kroku
Atribut: prec_quarantine_active_cases	
Popis	počet agentů nacházejících se v karanténě v daném kroku
Atribut: prec_quarantine_chapter	
Popis	počet aktivací protipatření od počátku simulace
Atribut: prec_quarantine_type	

Soubor s výsledky kroků simulace – uložený <i>df_results</i> (csv)	
Popis	typ karantény
Atribut: prec_smart_app_is_active	
Popis	označení aktivního (tj. 1) nebo neaktivního (tj. 0) protipatření chytrou aplikací v daném kroku
Atribut: prec_smart_app_chapter	
Popis	počet aktivací protipatření od počátku simulace
Atribut: prec_test_is_active	
Popis	označení aktivního (tj. 1) nebo neaktivního (tj. 0) protipatření testováním v daném kroku
Atribut: prec_test_chapter	
Popis	počet aktivací protipatření od počátku simulace
Atribut: prec_test_tested_per_step_negatively	
Popis	počet negativních testů provedených v daném kroku
Atribut: prec_test_tested_per_step_positively	
Popis	počet pozitivních testů provedených v daném kroku
Atribut: sick_asymptomatic	
Popis	počet asymptomaticky nemocných agentů ve fázi po projevení příznaků v daném kroku
Atribut: sick_mild	
Popis	počet mírně a středně vážně nemocných agentů ve fázi po projevení příznaků v daném kroku
Atribut: sick_severe	
Popis	počet vážně nemocných agentů ve fázi po projevení příznaků v daném kroku (počet hospitalizací)
Atribut: super_spreader	
Popis	počet super-přenašečů agentů ve fázi před projevení příznaků v daném kroku
Atribut: step	
Popis	číslo kroku modelu
Atribut: step_duration	

Soubor s výsledky kroků simulace – uložený <i>df_results</i> (csv)	
Popis	výpočetní čas zpracování aktuálního kroku [s]

Soubor s informacemi o infikacích s označením přenašeče, infikovaného agenta a místa nákazy. Název souboru je podobný jako v předchozím případě, jen s textem „_illness_story“ na konci.

Tabulka 15 - Atributy souboru s postupem infekce v populaci

Soubor s vývojem epidemie – uložený <i>df_infected_agents</i> (csv)	
Atribut: infected_in_step	
Popis	číslo kroku, ve kterém došlo k úspěšné infekci
Atribut: place	
Popis	označená typu lokace, na které k události došlo
Atribut: pos	
Popis	souřadnice (x;y) konkrétní buňky gridu
Atribut: vector_age	
Popis	věk přenašeče
Atribut: vector_base_entry_ir	
Popis	virulence přenašeče před započtením vlivu místa a protiopatření (interval 0...1 – čím blíže k 1, tím vyšší virulence)
Atribut: vector_final_output_ir	
Popis	virulence přenašeče po započtení vlivu místa a protiopatření a po násobení hodnotou <i>base_P</i> modelu
Atribut: vector_ir_random_threshold	
Popis	pseudonáhodné číslo prahu infekce – přenos onemocnění je úspěšný, pokud $vector_final_output_ir > vector_ir_random_threshold$
Atribut: vector_id	
Popis	<i>unique_id</i> přenašeče
Atribut: victim_age	
Popis	věk nakaženého agenta

Soubor s vývojem epidemie – uložený <i>df_infected_agents</i> (csv)	
Atribut: victim_id	
Popis	<i>unique_id</i> nakaženého agenta

Oba soubory výše (Tabulka 14 a Tabulka 15) jsou pak použity ke generování grafického výstupu se zobrazením průběhu epidemie, nejčastějšími místy nákazy a informací o zkonsumovaném pivu. Název souboru odpovídá souboru pro uložení *df_results* s koncovkou *html*.

Tabulka 16 - Atributy souboru s porovnáním všech simulovaných scénářů

Soubor s porovnáním všech scénářů (csv)	
Atribut: precautions	
Popis	sekvence protipatření aplikovaných pro danou simulaci, např. „ <i>app_im!0,mask_r!10</i> “ pro uvedení výsledků simulace s protipatřením trasovací aplikací s ideálním 100 % pokrytím populace a ochranou dýchacích cest
Atribut: simtype	
Popis	typ simulace – „no covid“ pro simulaci bez epidemie, „covid“ pro simulaci s epidemií
Atribut: max_steps	
Popis	maximální počet kroků simulace (hodnota bude stejná pro všechny scénáře)
Atribut: beer_cepovane	
Popis	celková konzumace čepovaného piva v dané simulaci
Atribut: beer_lahvove	
Popis	celková konzumace lahvového piva v dané simulaci
Atribut: epi_infected	
Popis	celkový počet agentů, kteří prodělali onemocnění (bez ohledu na počet reinfekcí) v dané simulaci
Atribut: epi_plain_attempts	
Popis	celkový počet neúspěšných pokusů o infekci v dané simulaci
Atribut: epi_successful_attempts	

Soubor s porovnáním všech scénářů (csv)	
Popis	celkový počet úspěšných infikací v dané simulaci
Atribut: epi_death_agents	
Popis	celkový počet zemřelých agentů v dané simulaci
Atribut: scenario_rating	
Popis	Výsledné hodnocení určující celkovou úspěšnost scénáře využívá bodové ohodnocení klíčových výstupních charakteristik simulace ($scenario_rating = beer_cepovane + beer_lahvove - epi_infected * 10 - epi_death_agents * 1000$)

Poznámky k technické realizaci simulace

Tato závěrečná sekce Návrhových vzorů obsahuje několik poznámek k technické realizaci simulace, kde se CBS liší od běžně využívaných možností Mesa. Uvedeno je i zdůvodnění výběru technické realizace.

Implementace vlastního DataCollectoru

V případě zdravotního stavu agentů a jeho změn i v případě aplikace protiepidemických opatření se ukazuje výhoda implementace vlastního DataCollectoru v podobě `df_agent_snapshot`. Ten představuje tabulku (Pandas Dataframe) všech agentů se všemi potřebnými atributy. Díky optimalizované knihovně Pandas a možnostem vyhledávání a hromadným operacím nad daty je nalezení agentů v určité zdravotní fázi nebo stavu velmi rychlé a nevyžaduje implementaci cyklů (v některých případech dokonce cyklů vnořených) přes všechny instance agentů v modelu. V případě úprav informací agentů pak sice systém vyžaduje průchod v cyklu, nicméně se týká jen agentů modifikovaných, přičemž se využívá faktu, že index agenta v poli instancí `BeerModel.agents` odpovídá indexu agenta v dataframe `df_agent_snapshot` a iterace tak nemusí obsahovat celou kolekci instancí, nýbrž jen instance požadované pro změnu. Dataframe `df_agent_snapshot` je vytvořen na počátku běhu simulace a modifikován pokaždé, když je modifikována některá z instancí agentů.

Stejného efektu by bylo možné docílit i pomocí vestavěného DataCollectoru frameworku Mesa. Ten po každém průchodu také umožňuje sesbírat atributy agentů i modelu a provést nad daty jakékoliv výpočty. Navíc i vestavěný DataCollector umožňuje uložit data do formátu Pandas. Jeho nevýhodou je ovšem mnohem vyšší režie než implementované řešení `df_agent_snapshot`. Pravděpodobnou příčinou je sběr a uložení dat pro každý krok simulace namísto průběžných změn tabulky s neměnnou dimenzí. V zásadě to znamená, že např. u simulace s 1000 agenty o 30 attributech se databáze vestavěného DataCollectoru v každém kroku zvětší o matici s rozměrem 1000 x 30. Ukládání není paměťově optimalizované (pomocí kategorizace) a provádění simulačních kroků se tak postupně zpomaluje, tj. každý následující krok je výpočetně a paměťově náročnější. Přitom nezáleží na stavu epidemie, protože výpočet se postupně zpomaluje i když došlo k eradikaci onemocnění a od určitého momentu tedy není třeba přepočítávat infekce. Při testu základního scénáře šíření epidemie bez protiepidemických opatření a 720 krocích byla simulace s konceptem vlastního DataCollectoru hotova v řádu 30 sekund, zatímco simulace využívající vestavěný DataCollector trvala 4x déle. Simulace 1 roku by pak v základním scénáři zabrala více než 24 hodin (odhadnuto na základě přepočtu běhu simulace o 720 krocích za pomoci uložených časů jednotlivých kroků v `df_results`). U řešení s `df_agent_snapshot` jde přitom o méně než 6 minut a nízké jsou i paměťové nároky simulace. Většina scénářů je však náročnější než základní scénář bez šíření epidemie.

Multiprocessing

Protože je CBS schopen modelovat nad jednou populací hned několik různých scénářů daných různými spouštěcími sekvencemi, a protože jedna simulace může běžet od několika minut po několik hodin, jsou výpočty nastaveny na režim multiprocessingu. Technicky je to řešeno pomocí implementace třídy `BatchRunnerMP` (potomek třídy `BatchRunner`) a výpočet může využít až $N-1$ procesorových jader (kde N je celkový počet procesorových jader daného systému). Před uložení souhrnných výsledků s porovnáním všech testovaných scénářů je třeba dokončit všechny simulace, proto systém čeká na dokončení poslední simulace ze sekvence scénářů.

Grafická reprezentace výsledků

Výsledky jednotlivých simulací (s různými parametry) a celkové výsledky běhu celého systému jsou uloženy do html souborů pomocí knihovny Plotly. CBS tedy nevyužívá vestavěné vizualizační možnosti frameworku Mesa, a to ze dvou důvodů. Prvním je nutné zpomalování běhu simulace vykreslováním každého kroku a druhým je složitá implementace vestavěné vizualizace při běhu pomocí BatchRunnerMP. Průběžná vizualizace je zajímavá zejména v případě, kdy model umožňuje aplikaci protiopatření nebo změnu parametrů uživatelem kdykoliv v průběhu simulace. Tuto funkcionalitu však CBS v současné implementaci neobsahuje - např. změna konfiguračních souborů po startu simulace již nemá žádný vliv, a proto není průběžná vizualizace nutná.

2.1.5 Vstupní data a inicializace

Generátor využívá k inicializaci vstupní soubor `config_gen.json`. Jeho parametry již byly popsány v kapitole 45. Pomocí těchto konfiguračních nastavení pak Generátor vytvoří vstupní data pro běh Simulátoru (a ukončí činnost). Vstupními daty pro inicializaci Simulátoru jsou pak soubory `df_agents.csv`, `df_agent_moves.csv` a `grid.csv` vytvořené Generátorem a soubor konfiguračních nastavení `config_sim.json`. Simulátor pak inicializační a konfigurační data čerpá s těchto zdrojů. Jejich přehled a popis je také uveden v kapitole 45.

Uživatel si při nastavení simulace může zvolit, jaká protiopatření nebo jejich kombinace bude v Simulaci používat, jakou budou mít základní konfiguraci, jaká bude prahová hodnota pro jejich aktivaci, kolik kroků simulace poběží a zda bude součástí modelu i epidemie. Tyto volby ovlivňují inicializaci Simulátoru. Detailní popis parametrů protiopatření z hlediska jejich konfigurovatelnosti uživatelem při startu Simulátoru je uveden v kapitole 103. Popis mechanismu fungování protiopatření je uveden v následující kapitole 98.

2.1.6 Submodely protiopatření

Kapitola detailněji popisuje mechanismus funkce protiopatření, která jsou použita v Simulátoru.

Ochrana dýchacích cest

Protiopatření funguje na principu snížení virulence infikovaného agenta, jde tedy o bariérovou ochranu mezi infikovaným agentem a jeho okolím. V modelu je to řešeno přepočtem pravděpodobnosti nakažení neimunního agenta nacházejícího se na stejné lokaci s infekčním agentem. Směr nákazy jde od přenašeče k vnímavému agentovi (tzn. v duchu bariérové ochrany proti šíření nákazy, nikoliv jako ochrana před nakažením). Přepočet je součástí metody `BeerAgent.calc_infect_rate`.

Prvním krokem je zjištění virulence agenta – hodnoty IR , která se liší podle fáze onemocnění infikovaného agenta:

- $IR = 1$ ve fázi super-přenašeče a ve chvíli přechodu do fáze regulárního onemocnění
- $IR = (RIT - N) / (RIT - SST)$, kde RIT je číslo kroku, do kterého je agent nemocný (`BeerAgent.regular_illness_till`), N je číslo aktuálního kroku modelu a SST je číslo kroku, do kterého je agent superpřenašečem (`BeerAgent.super_spreader_till`)
- V každém jiném okamžiku je $IR = 0$

Pokud je aktivní ochrana dýchacích cest (buď prostřednictvím protiopatření `precaution_mask`, nebo `precaution_smart_app` se `smart_action` nařizující agentu individuální ochranu dýchacích cest), pak se výsledné nenulové IR dále přepočítá koeficientem účinnosti bariérové ochrany a koeficientem vlivu prostředí (může jít o nižší pravděpodobnost dokonalého nošení roušky v určitých typech lokací). Výše vypočítané nenulové IR tedy modifikuje vzorec:

- $IR = IR * (1 - MP * PI)$, kde MP je protektivní účinek bariérové ochrany (v modelu je účinnost roušek nastavena na 95 %, hodnota je uložena v proměnné

BeerModel.precaution_mask.base_protective_value) a PI je vliv prostředí (uložené ve slovníku BeerModel.precaution_mask.protection, kde klíče odpovídají identifikátorům lokací a slovníkové hodnoty jsou koeficienty vlivu prostředí PI)

Výsledná pravděpodobnost úspěšného přenosu nákazy P je pak vypočítána dle vzorce:

$P = IR * base_P$, kde $base_P$ je základní pravděpodobnost nákazy modelu (BeerModel.base_P)

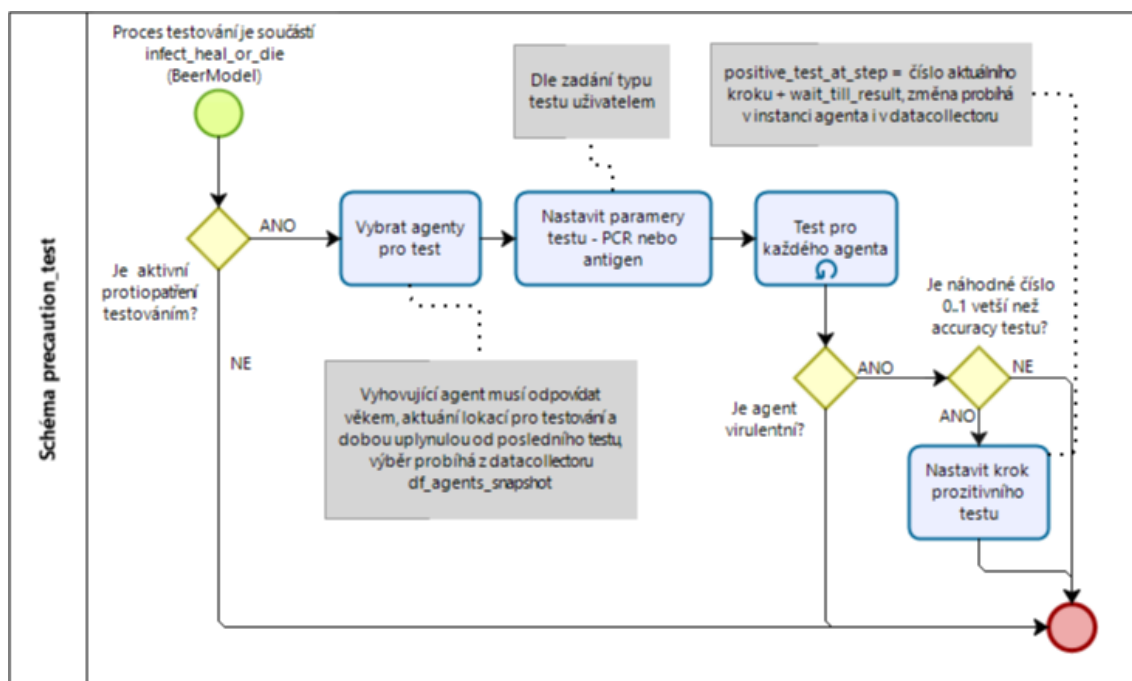
Hodnota P je pak porovnána s hodnotou z generátoru pseudonáhodných čísel ($random =$ desetinné číslo z intervalu(0; 1)) a pokud je $P > random$, dochází k infekci neimunního agenta. Proces probíhá pro každého infekčního agenta na dané pozici až do chvíle, kdy na pozici není žádný neimunní agent. To mimo jiné znamená, že s počtem infekčních agentů roste i riziko přenosu infekce na dosud nenakažené agenty.

Testování

Pokud je zapnuto testování agentů (prostřednictvím precaution_test), jsou agenti testováni v předem povolené lokaci (pracoviště, škola nebo domov - samotesty) a s definovaným časovým odstupem (v modelu 1x za 3 dny u antigenních a 1x za 7 dnů u PCR-RT testů). Seznam agentů, kteří splňují požadavky na testování, se vybírá v každém kroku modelu (v metodě BeerModel.infect_heal_or_die). Test pak probíhá pro každého agenta individuálně.

Infekční agent je označen testem jako pozitivní v případě, že přesnost testu (0.7 u antigenního a 0.99 u PCR-RT testu) je nižší nebo rovna hodnotě z generátoru pseudonáhodných čísel (desetinné číslo z intervalu(0; 1)). Pozitivnímu agentu je nastavena hodnota BeerAgent.positive_test_at_step na aktuální číslo kroku a v následujícím

kroku modelu je odeslán do karantény.



Obrázek 18 - Schéma protiopatření testováním

Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Bizagi Modeler)

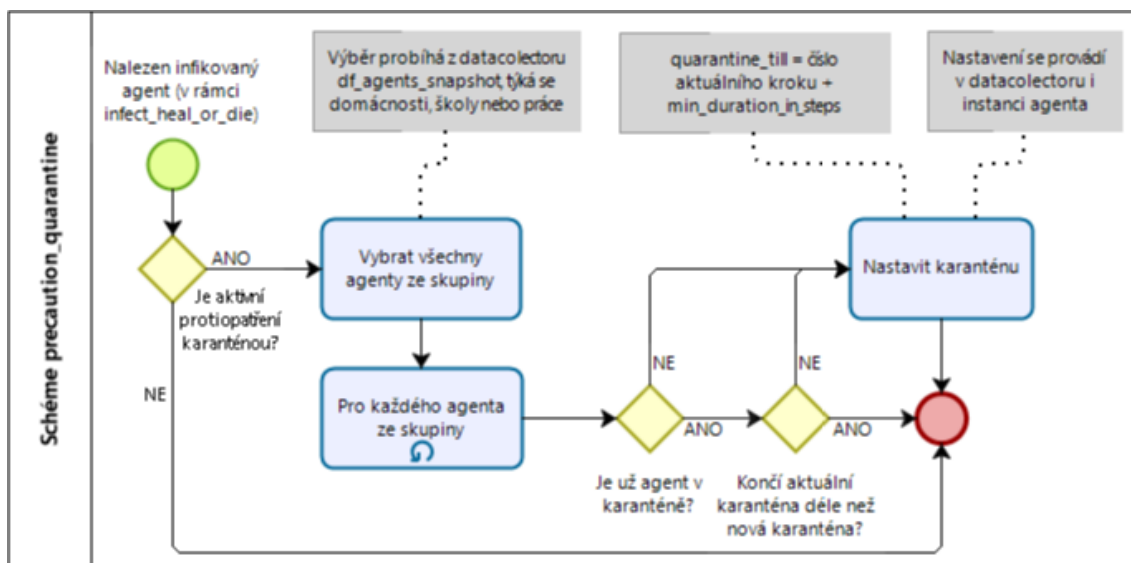
Karanténa

Karanténa je vždy uvalena na agenta, který má pozitivní výsledek testu, nebo přešel do symptomatické fáze onemocnění. Takový agent zůstává v lokaci D, nebo H, nejméně po dobu karantény (dáno parametrem `minimalni_trvani_dnu` souboru `config_sim.json`), nebo do okamžiku vyléčení. Uvalení karantény je součástí metody `infect_heal_or_die`.

Protiepidemické opatření karanténou tuto metodiku rozšiřuje na agenty z kolektivů nakaženého agenta. Pokud je tedy odhalen nakažený agent a je aktivní protiopatření, pak mimo samotného nakaženého agenta je uvalena karanténa na všechny členy domácnosti (stejně `house_id`), pracovního a školního kolektivu (stejně `work_id`), nebo na kombinace těchto skupin (v závislosti na nastavení zadaném uživatelem při startu simulace). Takoví agenti zůstávají v karanténě po dobu jejího nastaveného trvání. Pokud se v průběhu karantény projeví onemocnění, nebo je agent identifikován jako pozitivní (samotestem), je mu karanténa přepočítána jako v případě nakaženého agenta. Pokud agent z kolektivu ve chvíli uvalení karantény již v karanténě je a není symptomaticky

nemocný nebo pozitivně testovaný, je mu doba trvání prodloužena podle karantény nově uvalené.

Protiopatření karanténou je vůči populaci jednoúrovňové. To znamená, že pokud je např. v pracovním kolektivu identifikován nakažený agent, je karanténa uvalena na všechny členy pracovního kolektivu (stejná hodnota `work_id` agentů), ale nikoliv na jejich rodinné příslušníky.



Obrázek 19 - Schéma protiopatření karanténou

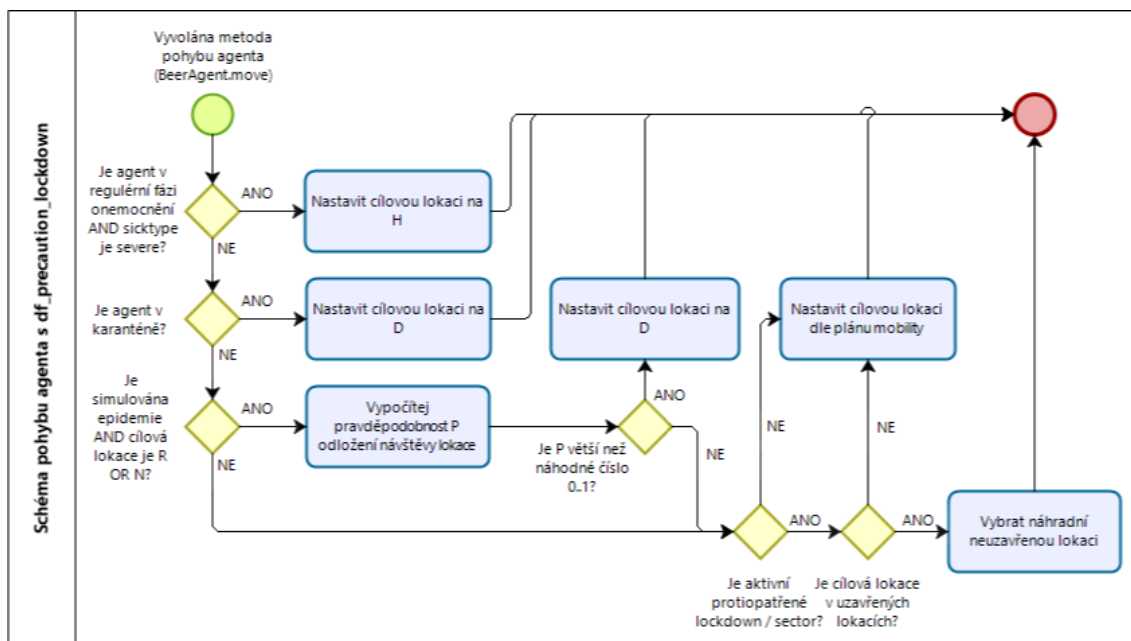
Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Bizagi Modeler)

Sektorová omezení a lockdown

Sektorová omezení spočívají v uzavření určitého typu lokací. Pokud se agent podle svého plánu mobility má přesunout na uzavřenou lokaci, vybírá si buď z náhradních lokací, nebo zůstává (přesune se) na svou lokaci D. Sektorová omezení v CBS umožňují uzavření lokací W a R. Uzavření lokací W zahrnuje jak školní zařízení, tak pracoviště vyjma restaurací a nákupních zón, které jsou z uzavření lokací W vyjmuty. Uzavření lokací R pak znamená zneprístupnění restaurací. Agenti si při sektorových omezeních volí náhradní lokaci – N, P, R nebo D, záleží na tom, jakých lokací se sektorová omezení týkají. Lockdown je pak speciálním typem sektorových omezení s úplným uzavřením ekonomiky, kdy jsou uzavřeny veškeré lokace, vyjma lokací D. To znamená, že při aktivaci protiopatření se agenti v přesunou do lokací D a v nich setrvávají do deaktivace lockdownu. Lze tedy říct, že jde o nejtvrďší protiopatření z hlediska omezení mobility

agentů, které odpovídá úrovni zákazu vycházení, jak byl aplikován např. v čínské provincii Chu-Pej, nebo i v ČR např. při úplné uzavírcce obce Litovel.

Na diagramu níže je zachycena celá pohybová akce agenta, a to jak s případnou aplikací sektorových omezení, tak i místo, kdy se agent rozhoduje, zda bude pokračovat v pohybu podle plánu mobility, nebo se raději vyhne riziku a zůstane v lokaci D.



Obrázek 20 - Schéma protiopatření omezením mobility

Schéma zachycuje i rozhodnutí agentů vyhnout se riziku.

Zdroj: vlastní archiv autora (vytvoreno pomocí nástroje Bizagi Modeller)

Trasovací aplikace

Protiopatření trasováním se skládá ze dvou částí – tvorby databáze kontaktů a jejich trasování v případě odhalení nakaženého agenta.

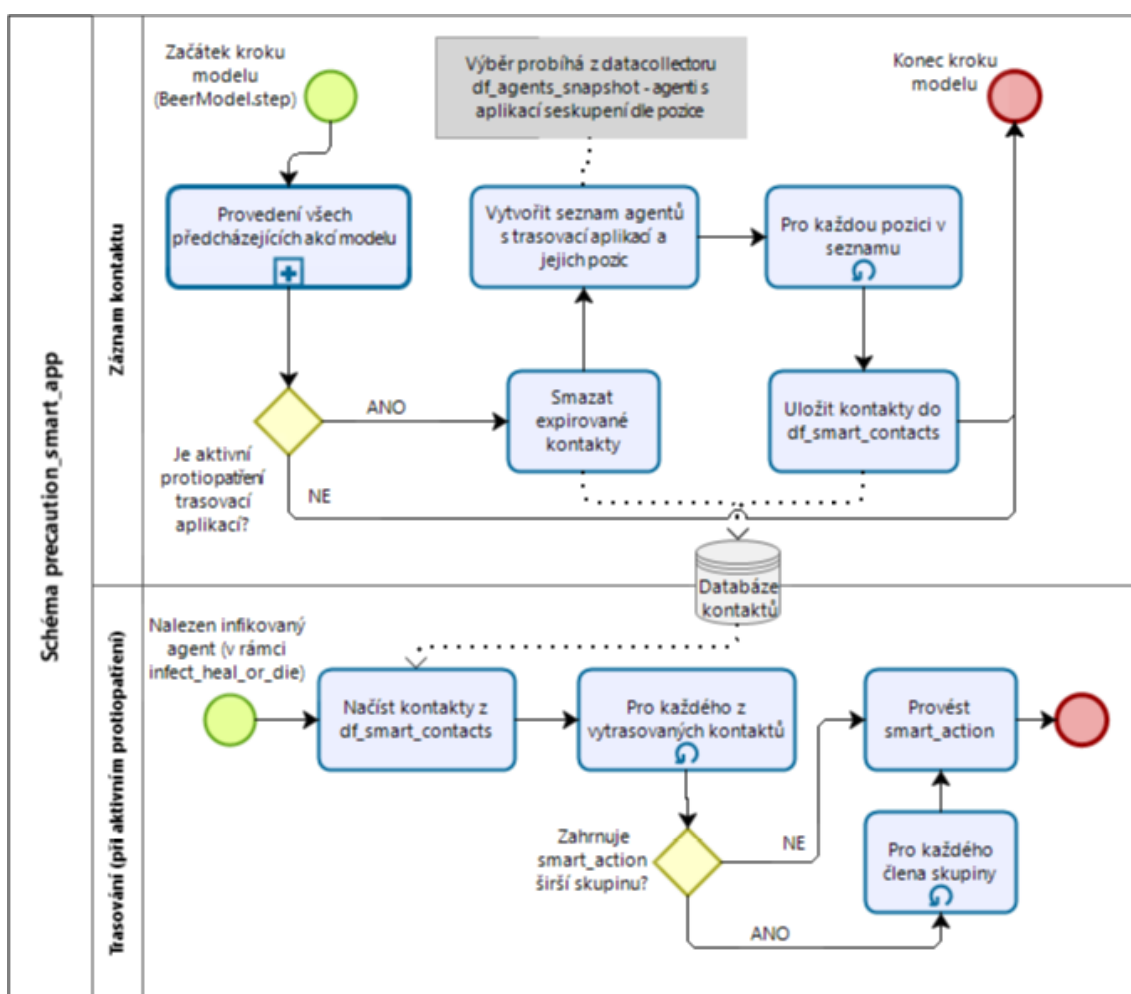
Tvorba databáze (BeerModel.df_smart_contacts) probíhá v každém kroku modelu, kdy se pro každou lokaci gridu zjistí seznam agentů vybavených trasovací aplikací a ten se uloží společně s číslem aktuálního kroku. Databáze je udržována pouze po omezenou dobu (5 dnů, tj. 120 kroků) a záznamy kontaktů, které danou dobu překročí, jsou před uložením aktuálních kontaktů smazány.

Spouštěčem trasování agentů je odhalení nakaženého agenta, a to buď prostřednictvím testování, nebo přechodem do symptomatické fáze onemocnění.

Z databáze kontaktů jsou pak vybrány všechny uložené kontakty a nalezení agenti jsou podrobni akci nastavené v protiopatření (smart_action). Akcí může být:

- karanténa na kontakt, nebo celou domácnost kontaktu,
- aplikace ochrany dýchacích cest na kontakt, nebo celou domácnost kontaktu,
- testování kontaktu.

Ukládání kontaktů a trasování je ze všech aplikovaných protiopatření výpočetně nejnáročnější, a proto simulace obsahující trasování běží nejdéle.



Obrázek 21 - Schéma protiopatření trasovací aplikací

Zdroj: vlastní archiv autora (vytvořeno pomocí nástroje Bizagi Modeler)

2.2 Ovládání a volba simulačních scénářů

Volbu simulačních scénářů provádí uživatel při spuštění simulace. Simulace se spouští z příkazového řádku se zadáním parametrů, zda jde o simulaci nad

uloženými populačními daty, nebo start generování nových populačních dat, v kolika krocích simulace poběží, zda bude nebo nebude simulována epidemie a jaká protopatření budou v simulaci aplikována a kdy případně dojde k jejich aktivaci.

2.2.1 Volba Generátor / Simulátor

Pokud je v parametrech pro spuštění uvedeno *-g* nebo *--generator* (např. *python main.py -g*), je spuštěno generování nových populačních dat. Jakékoliv další parametry příkazové řádky, vyjma *-e*, resp. *--seed* nebo *-ps*, resp. *--popsize*, jsou ignorovány.

2.2.2 Volba typu simulace

Pokud je v parametrech pro spuštění uvedeno *-s* nebo *--simtype* s argumentem *covid* (např. *python main.py -s covid*), je spuštěna simulace se šířením epidemie. Pokud je uveden argument *no_covid* (např. *python main.py -s no_covid*), jedná se o simulaci bez epidemie. Pokud není parametr *-s* nebo *--simtype* uveden vůbec, jedná se vždy o simulaci se šířením epidemie.

2.2.3 Volba počtu kroků simulace

Pokud je v parametrech pro spuštění uvedeno *-n* nebo *--steps* a celočíselnou hodnotou (např. *python main.py -n 2400*), bude simulace probíhat určený počet kroků (např. u *-n 2400* jde o 2400 kroků, tj. 100 simulačních dnů). Pokud parametr není uveden, je výchozí hodnotou 720.

2.2.4 Volba hodnoty seedu

Pokud je v parametrech pro spuštění uvedeno *-e* nebo *--seed* s celočíselnou hodnotou (např. *python main.py -e 125*), je číslo použito jako seed pro generátory pseudonáhodných čísel v simulaci i generátoru. Pokud parametr uveden, je výchozí hodnotou pro seed číslo 42.

2.2.5 Volba velikosti populace

Pokud je v parametrech pro spuštění Generátoru (*-g*) uvedeno *-ps* nebo *--popsize* s celočíselnou hodnotou (např. *python main.py -g -ps 25000*), je číslo použito jako parametr celkové velikosti populace generované Generátorem (v příkladu výše

by šlo o populaci 25000 agentů). Pokud parametr uveden není, je výchozí hodnotou velikosti populace číslo 1100. Velikost generované populace se může vlivem zaokrouhlení a nastavení v konfiguračních souborech mírně lišit (např. výchozí hodnota 1100 generuje populaci 1098 agentů, která odpovídá dané konfiguraci věkových skupin a pohlaví v souboru `config_gen.json`).

2.2.6 Volba scénářů protiopatření

Pokud je v parametrech pro spuštění uveden parametr `-p` nebo `--precautions`, jedná se vždy o simulaci epidemie a případný parametr `-s` nebo `--simtype` s argumentem `no_covid` je ignorován. Argumentem parametru `-p` nebo `--precautions` je alespoň jedno protiopatření s volitelným nastavením. Pro simulaci kombinace opatření jsou tato vzájemně oddělena čárkou. Pro simulaci více protiopatření a jejich kombinace jsou jednotlivé sekvence protiopatření oddělena středníkem - např. `python main.py -p protiopatreni_1,protiopatreni_2;protiopatreni_1` spustí paralelní simulaci dvou scénářů se šířením epidemie a aplikací kombinace protiopatření `protiopatreni_1` a `protiopatreni_2` v prvním případě a samostatnou aplikaci `protiopatreni_1` ve druhém případě.

Protiopatření mohou obsahovat konfigurační znaky. Ty jsou uvedeny za podtržítkem a zpřesňují nastavení. Pokud nejsou uvedeny, je použito výchozí nastavení z konfiguračního souboru `config_sim.json`. Možnosti volby protiopatření a jejich konfigurační znaky v příkazovém řádku jsou uvedeny v tabulce níže.

Tabulka 17 - Přehled parametrů protiopatření pro aplikaci v modelu

Argumenty parametru <code>--precautions</code>	
Protiopatření: Ochrana dýchacích cest	
Argument	<code>mask</code> (<code>python main.py -p mask</code>)
Popis	uvolnění <code>precaution_mask</code> pro použití a možnou aktivaci v simulaci – včetně uvážení vlivu prostředí
Argument	<code>mask_i</code> (<code>python main.py -p mask_i</code>)

Argumenty parametru --precautions	
Popis	uvolnění <i>precaution_mask</i> pro použití a možnou aktivaci v simulaci - bez uvážení vlivu prostředí (protektivní účinek roušek je v každé lokaci stejný)
Protiopatření: Testování	
Argument	<i>test_w</i> (<i>python main.py -p test_w</i>)
Popis	uvolnění <i>precaution_test</i> pro použití a možnou aktivaci v simulaci – agenti se testují v testovací lokaci W
Argument	<i>test_d</i> (<i>python main.py -p test_d</i>)
Popis	uvolnění <i>precaution_test</i> pro použití a možnou aktivaci v simulaci – agenti se testují v testovací lokaci D (synonymum pro testování v odběrových místech nebo samotesty)
Argument	<i>test_p</i> (<i>python main.py -p test_p</i>)
Popis	uvolnění <i>precaution_test</i> pro použití a možnou aktivaci v simulaci – testuje se metodou PCR-RT (bez uvedení znaku <i>p</i> v argumentu jde o testy antigenní)
Poznámka	Konfigurační znaky za podtržítkem lze kombinovat - např. pro testování v lokaci D i W a použití metody PCR-RT se zadá argument ve tvaru <i>test_pwd</i> . Na pořadí konfiguračních znaků nezáleží.
Protiopatření: Karanténa	
Argument	<i>quarantine_d</i> (<i>python main.py -p quarantine_d</i>)
Popis	uvolnění <i>precaution_quarantine</i> pro použití a možnou aktivaci v simulaci – karanténa je uvalena na všechny členy společné domácnosti odhaleného infikovaného agenta
Argument	<i>quarantine_w</i> (<i>python main.py -p quarantine_w</i>)

Argumenty parametru --precautions	
Popis	uvolnění <i>precaution_quarantine</i> pro použití a možnou aktivaci v simulaci – karanténa je uvalena na všechny členy pracovního nebo školního kolektivu odhaleného infikovaného agenta
Poznámka	Konfigurační znaky za podtržítkem lze kombinovat.
Protiopatření: Sektorová omezení	
Argument	<i>sector_r</i> (<i>python main.py -p sector_r</i>)
Popis	uvolnění <i>precaution_lockdown</i> pro použití a možnou aktivaci v simulaci s omezením uzavřených lokací na R (ostatní lokace zůstávají otevřené)
Argument	<i>sector_w</i> (<i>python main.py -p sector_w</i>)
Popis	uvolnění <i>precaution_lockdown</i> pro použití a možnou aktivaci v simulaci s omezením uzavřených lokací na W
Poznámka	Konfigurační znaky za podtržítkem lze kombinovat
Protiopatření: Lockdown	
Argument	<i>lockdown</i> (<i>python main.py -p lockdown</i>)
Popis	uvolnění <i>precaution_lockdown</i> pro použití a možnou aktivaci v simulaci s uzavřením všech lokací – agenti se po aktivaci protiopatření vrátí do lokace D a zůstávají v ní po dobu trvání protiopatření, všechny ostatní lokace jsou uzavřeny. Uvedením argumentu <i>lockdown</i> je ignorován vliv případného argumentu <i>sector</i> .
Protiopatření: Trasovací aplikace	
Argument	<i>app_m</i> (<i>python main.py -p app_m</i>)
Popis	uvolnění <i>precaution_smart_app</i> pro použití a možnou aktivaci v simulaci, kde vytrasovaní agenti používají po dobu danou <i>par</i> .

Argumenty parametru --precautions	
	minimalni_trvani_chytre_akce_dnu (config_sim.json) ochranu dýchacích cest. Konfigurace ochrany je převzata z nastavení v config_sim.json.
Argument	app_md (<i>python main.py -p app_md</i>)
Popis	uvolnění <i>precaution_smart_app</i> pro použití a možnou aktivaci v simulaci, kde vytrasovaní agenti a s nimi navíc i všichni členové jejich společné domácnosti používají ochranu dýchacích cest.
Argument	app_q (<i>python main.py -p app_q</i>)
Popis	uvolnění <i>precaution_smart_app</i> pro použití a možnou aktivaci v simulaci, kde je na vytrasované agenty po dobu odpovídající par. minimalni_trvani_chytre_akce_dnu uvalena karanténa
Argument	app_qd (<i>python main.py -p app_qd</i>)
Popis	uvolnění <i>precaution_smart_app</i> pro použití a možnou aktivaci v simulaci, kde je na vytrasované agenty a s nimi navíc i na všechny členy jejich domácnosti po dobu odpovídající par. minimalni_trvani_chytre_akce_dnu uvalena karanténa
Argument	app_t (<i>python main.py -p app_t</i>)
Popis	uvolnění <i>precaution_smart_app</i> pro použití a možnou aktivaci v simulaci, kde je vytrasovaným agentům nařízeno testování
Argument	app_i (<i>python main.py -p app_i</i>)
Popis	u <i>precaution_smart_app</i> je nastaveno 100% pokrytí populace trasovací aplikací nebo tokenem, tzn. vytrasovatelní jsou všichni agenti
Poznámka	Konfigurační znaky za podtržítkem lze kombinovat jen s konfiguračním znakem <i>i</i> (např. lze použít <i>app_iqm</i> , ale nikoliv <i>app_iqmt</i>)

Vyjma konfiguračních znaků lze využít i nastavení `trigger_threshold`, tedy okamžiku, kdy dojde k aktivaci aplikovaného opatření. Hodnota `trigger_threshold` se uvádí za znakem `!` na konci argumentu protiopatření a jedná se o celé číslo. Např. `python main.py -p sector_r!1` znamená, že protiopatření uzavřením lokací R bude aktivováno při odhalení prvního infikovaného agenta. Pokud hodnota `trigger_threshold` není uvedena, použije se hodnota zadaná v parametru `mez_aktivace_deaktivace` souboru `config_sim.json`.

3 Výsledky modelu

CBS byl spuštěn s 24 simulačními scénáři: 2 základní scénáře pro získání referenčních hodnot (scénář bez epidemie a scénář s epidemií bez protiopatření) a 22 scénářů obsahujících šíření epidemie s různými protiopatřeními.

3.1 Přehled testovaných scénářů

3.1.1 Samostatná protiopatření

Samostatná protiopatření jsou scénáře, ve kterých se vyskytuje jen jedno z možných protiopatření s různě nastavenou konfigurací. Níže je uveden přehled samostatných protiopatření aplikovaných v jednotlivých modelech. Opatření jsou uvedena s plným zněním příkazové řádky (za předpokladu spuštění z pracovního adresáře CBS a mapování interpreteru jazyka Python).

python main.py -n 2400 -s no_covid

Simulace pro získání referenční hodnoty pивní konzumace a hodnocení základního modelu.

python main.py -n 2400 -s covid

Simulace šíření onemocnění Covid-19 populací bez protiopatření pro získání referenčních hodnot pивní konzumace a chování epidemie při nelimitovaném šíření onemocnění.

python main.py -n 2400 -p mask_i!1

Simulace šíření onemocnění Covid-19 v populaci používající ideální ochranu dýchacích cest, aktivace opatření, a tedy nasazení roušek nastává od 1. agenta, který přešel do symptomatické fáze onemocnění (*sicktype* je *mild* nebo *severe*)

python main.py -n 2400 -p mask_r!1

Simulace šíření onemocnění Covid-19 v populaci, kde kvalita ochrany dýchacích cest souvisí s typem lokace, na kterém se agenti nachází (úroveň ochrany se snižuje v domácnostech a restauracích) - porovnání s ideálním stavem.

python main.py -n 2400 -p mask_r!10

Simulace šíření onemocnění Covid-19 v populaci, kde kvalita ochrany dýchacích cest souvisí s typem lokace a aktivace opatření má zpoždění (protiopatření je aktivní až po zachycení 10 agentů v symptomatické fázi onemocnění během 7 dnů) - porovnání s brzkým startem protiopatření (*mask_r!1*).

python main.py -n 2400 -p app_iq!1

Simulace šíření onemocnění Covid-19 v populaci, jejíž členové využívají trasovací aplikace a tokeny ve 100 % případů – populace je tedy zcela pokryta protiopatřením. Na vytrasované agenty je uvalena karanténa. Aktivace opatření a start tvorby databáze kontaktů nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p app_q!1

Simulace šíření onemocnění Covid-19 v populaci, jejíž členové využívají trasovací aplikaci v různě omezené míře (podle parametru *podil_aplikaci_v_kategorii* v *config_sim.json*). Na vytrasované agenty je uvalena karanténa. Aktivace opatření a start tvorby databáze kontaktů nastává od 1. agenta, který přešel do symptomatické fáze onemocnění. Cílem scénáře je zjistit vliv nedokonalého pokrytí populace protiopatřením na jeho efektivitu (v porovnání s *app_iq!1*)

python main.py -n 2400 -p app_qd!1

Simulace šíření onemocnění Covid-19 v populaci, jejíž členové využívají trasovací aplikace v omezené míře. Na vytrasované agenty a všechny členy jejich domácnosti je uvalena karanténa. Aktivace opatření a start tvorby databáze kontaktů nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p app_m!1

Simulace šíření onemocnění Covid-19 v populaci, jejíž členové využívají trasovací aplikace v omezené míře. Vytrasovaní agenti nasadí roušky k ochraně okolí. Aktivace opatření a start tvorby databáze kontaktů nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p app_md!1

Simulace šíření onemocnění Covid-19 v populaci, jejíž členové využívají trasovací aplikace v omezené míře. Vytrasovaní agenti a všichni členové jejich společné domácnosti nasadí roušky k ochraně okolí. Aktivace opatření a start tvorby databáze kontaktů nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p app_t!1

Simulace šíření onemocnění Covid-19 v populaci, jejíž členové využívají trasovací aplikace v omezené míře. Vytrasovaní agenti podstoupí testování. Aktivace opatření a start tvorby databáze kontaktů nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p lockdown!1

Simulace šíření onemocnění Covid-19 v populaci, na kterou je při výskytu 1. agenta v symptomatické fázi onemocnění uvalen úplný lockdown (uzavření všech lokací, agenti zůstávají v lokacích D).

python main.py -n 2400 -p lockdown!10

Simulace šíření onemocnění Covid-19 v populaci s aplikací protiopatření lockdown, kdy je protiopatření aktivní až po zachycení 10 agentů v symptomatické fázi onemocnění (během 7 dnů). Simulace slouží k porovnání s brzkým startem protiopatření *lockdown!1*.

python main.py -n 2400 -p sector_r!1

Simulace šíření onemocnění Covid-19 v populaci s aplikací protiopatření sektorovou uzávěrou restaurací (lokací R). Aktivace opatření nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p sector_w!1

Simulace šíření onemocnění Covid-19 v populaci s aplikací protiopatření sektorovou uzávěrou pracovišť a škol (lokací W, lokace R i N zůstávají otevřené, přestože jde o pracoviště v nich zaměstnaných agentů). Aktivace opatření nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p sector_rw!1

Simulace šíření onemocnění Covid-19 v populaci s aplikací protiopatření sektorovou uzávěrou pracovišť, škol i restaurací (lokací W a R, lokace N zůstávají otevřené, přestože jde o pracoviště v nich zaměstnaných agentů). Aktivace opatření nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p test_w!1

Simulace šíření onemocnění Covid-19 v populaci s aplikací protiopatření testováním na pracovištích a ve školách (v lokacích W a pokud odpovídá work_id agenta lokaci R nebo N, pak pro tyto agenty i na lokaci R a N). Aktivace opatření nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.

python main.py -n 2400 -p test_wd!1

Simulace šíření onemocnění Covid-19 v populaci s aplikací protiopatření testováním na pracovištích i doma (pro zachycení agentů, kteří nechodí do školy nebo do práce a mohu tak přenášet nákazu skrytě v rámci domácnosti). Aktivace opatření nastává od 1. agenta, který přešel do symptomatické fáze onemocnění.


python main.py -n 2400 -p test_wd!0

Simulace šíření onemocnění Covid-19 v populaci s aplikací protiopatření testováním na pracovištích i doma (pro zachycení agentů, kteří nechodí do školy nebo do práce a mohu tak přenášet nákazu skrytě v rámci domácnosti). Aktivace opatření nastává od počátku simulace, tedy ještě před projevením první nákazy – scénář je zařazen pro zjištění vlivu brzkého startu protiopatření i bez zjevné nákazy v populaci.

python main.py -n 2400 -p test_pwd!1

Simulace šíření onemocnění Covid-19 v populaci s aplikací protiopatření testováním na pracovištích i doma (pro zachycení agentů, kteří nechodí do školy nebo do práce a mohu tak přenášet nákazu skrytě v rámci domácnosti). Aktivace opatření nastává od 1. agenta, který přešel do symptomatické fáze onemocnění a typem testu je PCR-RT metoda lišící se přesností, ale i povolenou frekvencí.

3.1.2 Výsledek simulací samostatných protiopatření

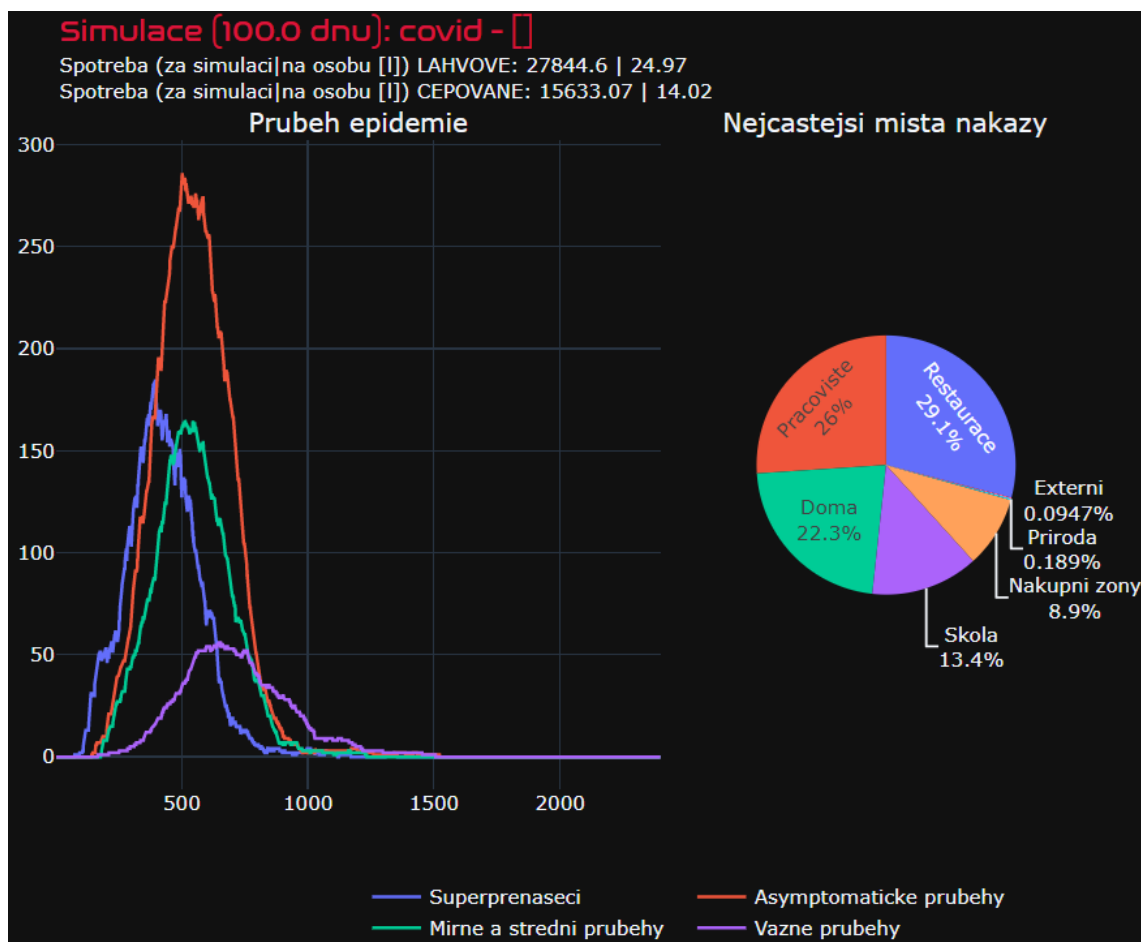


Obrázek 22 - Porovnání výsledků samostatných protiopatření

Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

Výsledky v grafu (Obrázek 22) jsou srovnány podle Hodnocení scénáře, které vychází z bodového přepočtu úspěšnosti (kombinace výsledků pивní spotřeby, počtu nemocných a zemřelých). Čísla v závorkách u názvu protiopatření pod osou x znamenají *procentuální výkonnost hodnocení | pивní spotřeba oproti scénáři no_covid*. Vítězem v úspěšnosti (na grafu pozice nejbližší k pravému sloupci) je scénář *lockdown!1* následovaný ochranou dýchacích cest s ideálním pokrytím *mask_i!1* a na třetím místě je opět úplné uzavření lokací, tentokrát s odloženou aktivací *lockdown!10*.

Z jednotlivých výsledků samostatných protiopatření nebo scénáře *covid* je také možné zjistit, že k nejmasivnějšímu přenosu onemocnění dochází v lokacích typu R, W a D. Důvodem je skutečnost, že jde o místa s vyšším pohybem agentů a kolektivy návštěvníků lokace R jsou navíc dynamické. To je rozdíl oproti lokacím W nebo D, které mají kolektivy statické – skupiny jsou utvořeny na počátku a zůstávají beze změn po celou dobu simulace, což u lokací R platí jen pro kolektivy zaměstnanců.




Obrázek 24 - Detailní zobrazení neřízeného průběhu epidemie ve scénáři covid

Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

Při vysoké dynamice kontaktů je infekční agent schopen nakazit nejen větší množství agentů, ale hlavně u lokací R také agentů z různých kolektivů. To samé sice platí i pro lokace N, kterých je ovšem více než lokací R (16 ku 5) a agenti se tak na lokacích N koncentrují v mnohem menších množstvích s nižším rizikem masivní nákazy.

Vysoké přírůstky nemocných znamenají i vyšší pravděpodobnost odložené spotřeby, tj. stavů, kdy se agent rozhodne nejít do restaurace nebo nákupní zóny a tím snížit riziko nákazy, a samozřejmě snížení spotřeby z důvodu horšího zdravotního stavu větší části populace. S rostoucím počtem nemocných a odložených příležitostí k pití piva v restauracích se pak prohlubuje rozdíl mezi referenční a aktuální spotřebou, a to i přes substituční pití lahvového piva v domácnostech – nad rámec běžné spotřeby.

Při porovnání s typickým průběhem epidemie je patrné, že výstup Simulátoru odpovídá předpokládané epidemické křivce (Obrázek 23). Podobné je to i s reálným průběhem epidemie v ČR (Obrázek 24), kde jsou patrné i vlivy přijatých protipatření a jejich uvolňování. Protože průběhy epidemií v modelu CBS, v předpokládaném průběhu epidemie i reálném světě vzájemně odpovídají, lze konstatovat, že je model validován i z hlediska epidemiologického.



Obrázek 23 - Předpokládané průběhy epidemie
Zdroj: převzato z [84]

Daily new confirmed COVID-19 cases

Shown is the rolling 7-day average. The number of confirmed cases is lower than the number of actual cases; the main reason for that is limited testing.

Our World in Data

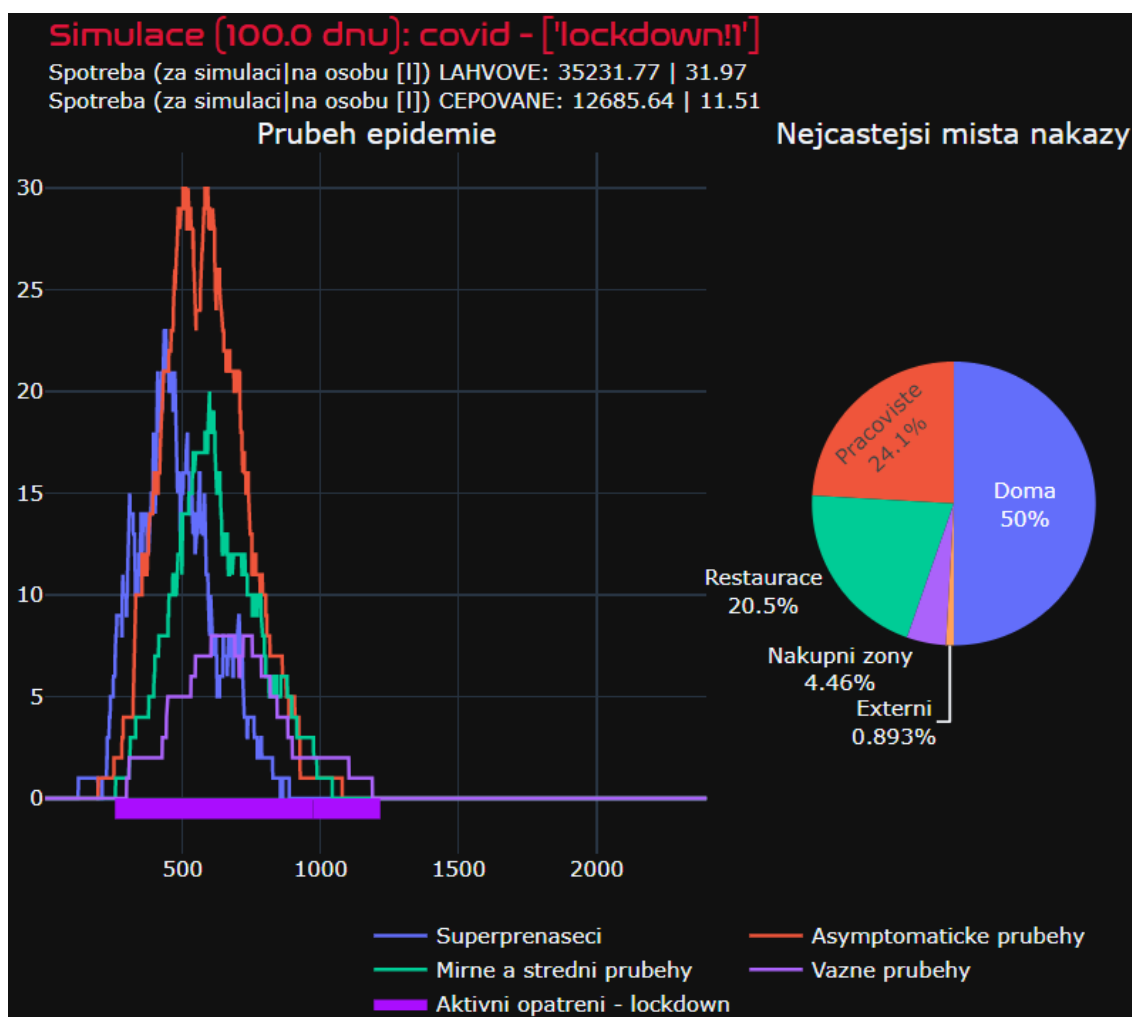
[LINEAR](#) [LOG](#) [+ Add country](#)



Obrázek 24 - Skutečný průběh epidemie v ČR
Zdroj: převzato z [85]

Sektorová omezení

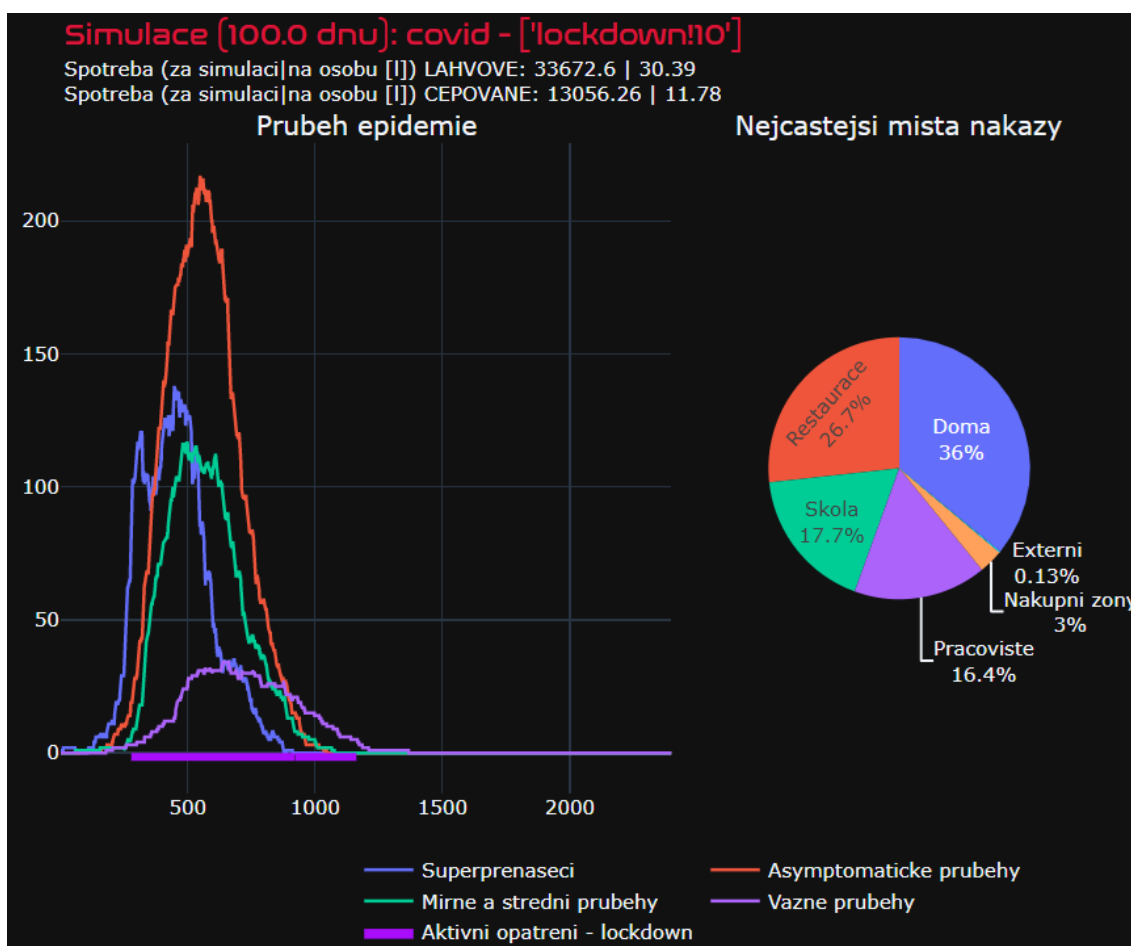
Scénář *lockdown!1* předpokládá uzavření všech lokací, agenti tedy zůstávají pouze v lokacích D a z hlediska spotřeby piva konzumují obvyklé množství lahvového piva a případné návštěvy lokací R s určitou pravděpodobností nahradí opět pitím lahvového piva. Překvapivé na tomto scénáři je, že i přes výrazné omezení mobility a aktivit agentů nedochází k výraznému propadu spotřeby, a to v kombinaci s velmi malým rozšířením epidemie. Scénář je deaktivován v případě, kdy za posledních 7 dní není detekován ani jeden nový symptomaticky nemocný, ale v případě změny situace by nová reaktivace byla velmi rychlá a opět značně účinná.



Obrázek 25 - Průběh epidemie ve scénáři lockdown!1

Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

Ve výsledcích protiopatření *lockdown!10* (Obrázek 26) je naopak patrný negativní vliv zpoždění při zavedení protiopatření – lockdown aktivovaný až při detekci 10 symptomaticky nemocných v průběhu 7 dnů dosahuje mnohem nižší efektivity než brzký start protiopatření. Za povšimnutí stojí především vysoký nárůst superpřenašečů i asymptomatických průběhů ještě před aktivací protiopatření. Ve chvíli aktivace je tak epidemie již rozšířena ve značné části populace. Cenou za případné váhání s aktivací protiopatření, a naopak urychlení jeho deaktivace je 3 % propad ve spotřebě piva a 40 % propad v celkovém hodnocení oproti základnímu scénáři *no_covid* a 2 % propad spotřeby a 29 % v celkovém hodnocení oproti scénáři *lockdown!1*.



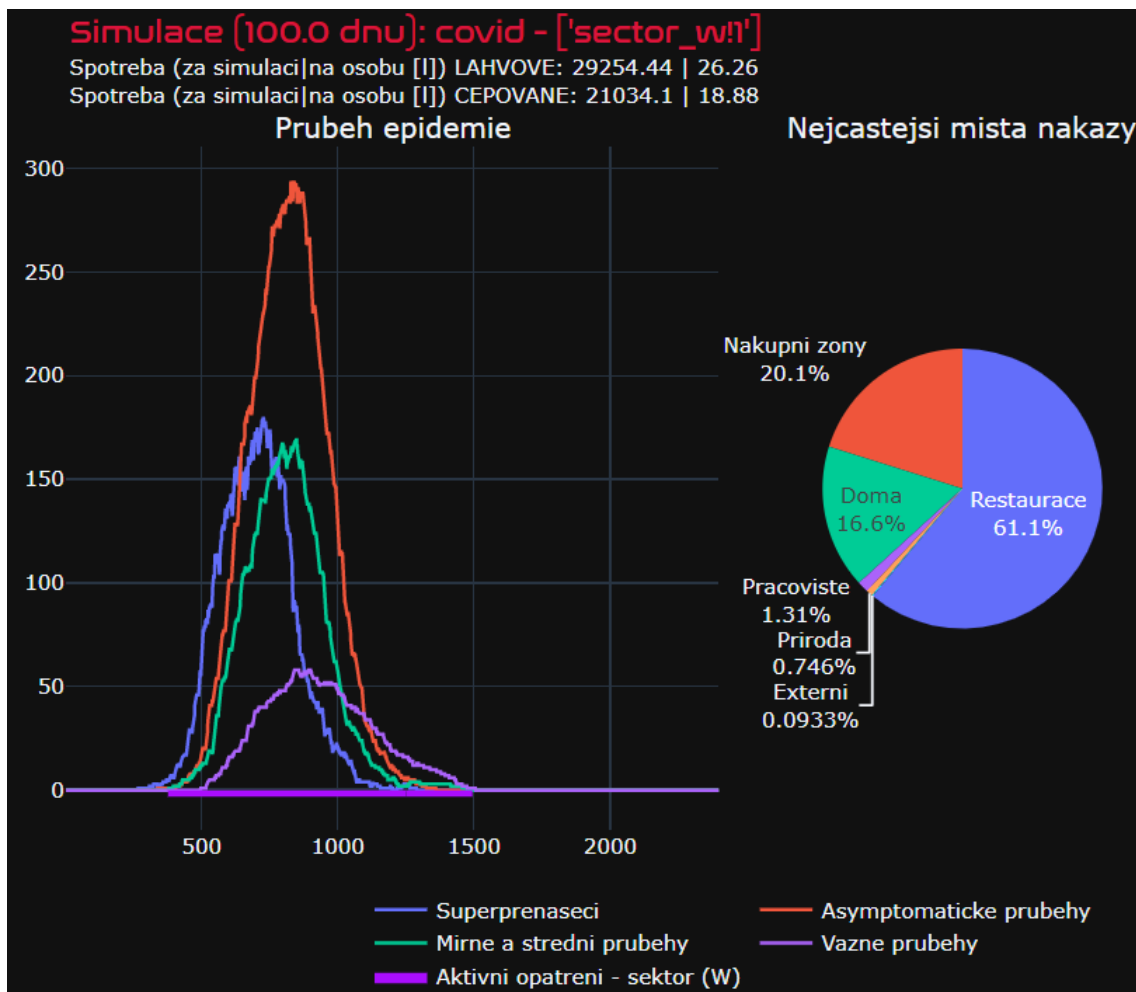
Obrázek 26 - Průběh epidemie ve scénáři lockdown!10

Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

Lockdown je zajímavý i v porovnání s jinými sektorovými omezeními, která si rozhodně nevedou tak dobře. Scénář uzavření restaurací *sector_r!1* (viz. Obrázek 22

s porovnáním všech samostatných protiopatření) je dokonce ze všech nejméně výhodný – spotřeba propadla o 27 %, ale vyšší nemocnost a počet úmrtí snížil celkové hodnocení scénáře o 77 % oproti scénář referenčnímu (epidemie se šířila v jiných lokacích než R prakticky nerušeně).

Výjimkou a překvapením je scénář *sector_w!1* (Obrázek 27), ve kterém dochází ke zvýšení spotřeby, a to dokonce nad referenční hodnoty. Důvodem je, že ve scénáři nejsou uzavřeny restaurace a lokace R jsou tak i mezi náhradními lokacemi pro rozhodování agentů (někteří ze zdravých agentů, superpřenašečů a asymptomaticky nemocných agentů jednoduše zamíří namísto uzavřených pracovišť do restaurace). Protiopatření se navíc v aktivním módu drželo více než 50 dnů, což je dostatečná doba na zvýšení spotřeby čepovaného piva v restauracích i lehce vyšší substituční spotřebu piva lahvového. Nevýhodou scénáře je ovšem vysoký počet nemocných i obětí – epidemie spíše neřízeně prochází populací, než aby byla omezena protiopatřením.



Obrázek 27 - Průběh epidemie ve scénáři sector_w!1

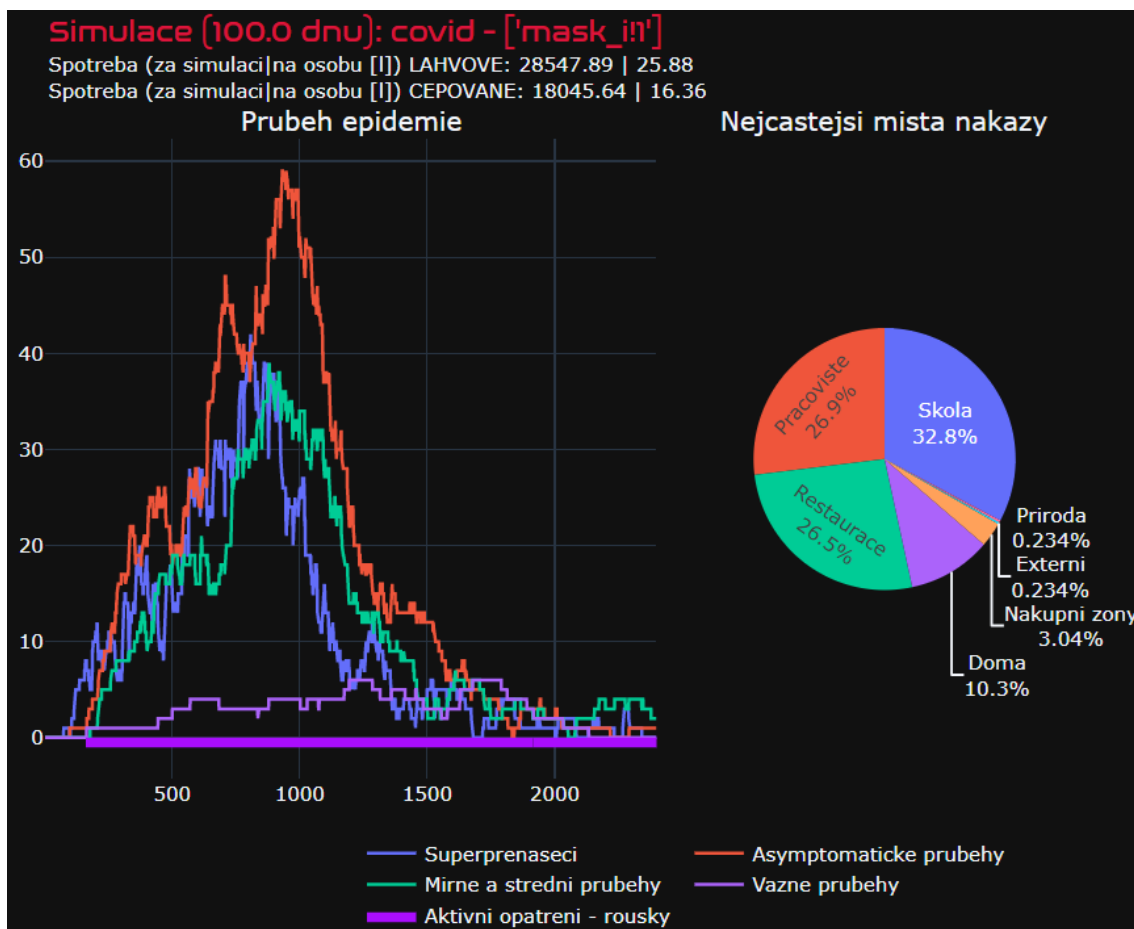
Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

Při porovnání s vítězným scénářem *lockdown!1* (Obrázek 25) je patrný rozdíl nejen v celkovém počtu nemocných, ale i v celkovém trvání protiopatření. Z etického hlediska je celkový lockdown stále lepší volbou než prosté uzavření pracovišť (zejména s přihlédnutím ke skutečnosti že v *lockdown!1* se spotřeba piva oproti referenční hodnotě poklesla jen minimálně).

Ochrana dýchacích cest

Zajímavé je také srovnání protiopatření ochranou dýchacích cest, kdy je rozdíl v účinnosti v různých prostorech. Pokud je ochrana úplná a dokonalá v každém místě (Obrázek 28), je epidemie držena pod kontrolou (tj. počty nakažených jsou nízké). Při nedokonalém nošení roušek v restauracích a doma (Obrázek 29) je

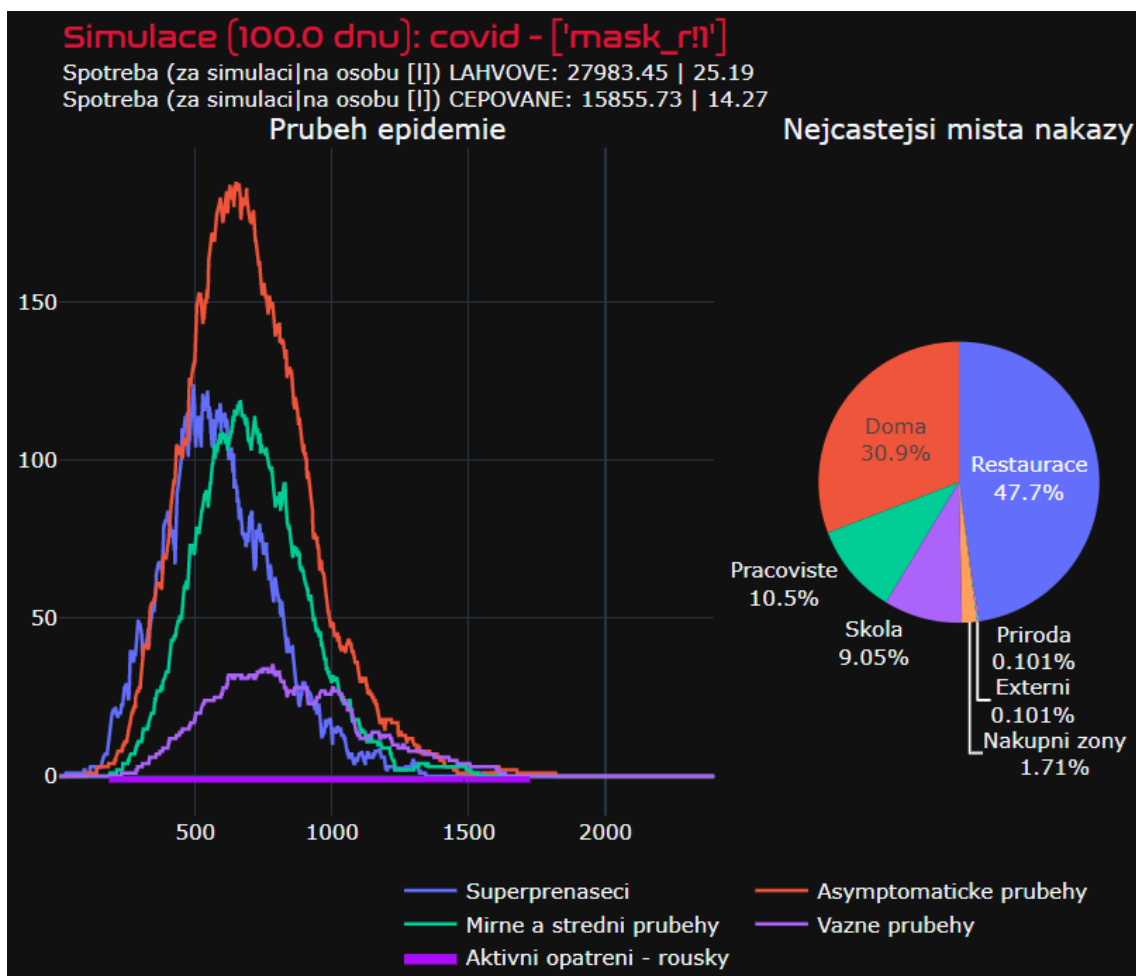
průběh epidemie daleko silnější. V obou případech je ale protiopatření aktivní po velmi dlouhou dobu – epidemie je (alespoň částečně) bržděna a tím roztažena do delšího časového úseku.



Obrázek 28 - Průběh epidemie ve scénáři mask_i!1

Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

Výsledek nedokonalého používání roušek dosahuje spíše podprůměrných výsledků (i když na spotřebu piva nemá až tolik negativní dopad), z čehož plyne, že úspěšnost tohoto ekonomicky levného a snadno aplikovatelného opatření silně závisí na šíři jeho akceptace a disciplíně obyvatel.



Obrázek 29 - Průběh epidemie ve scénáři mask_r!1

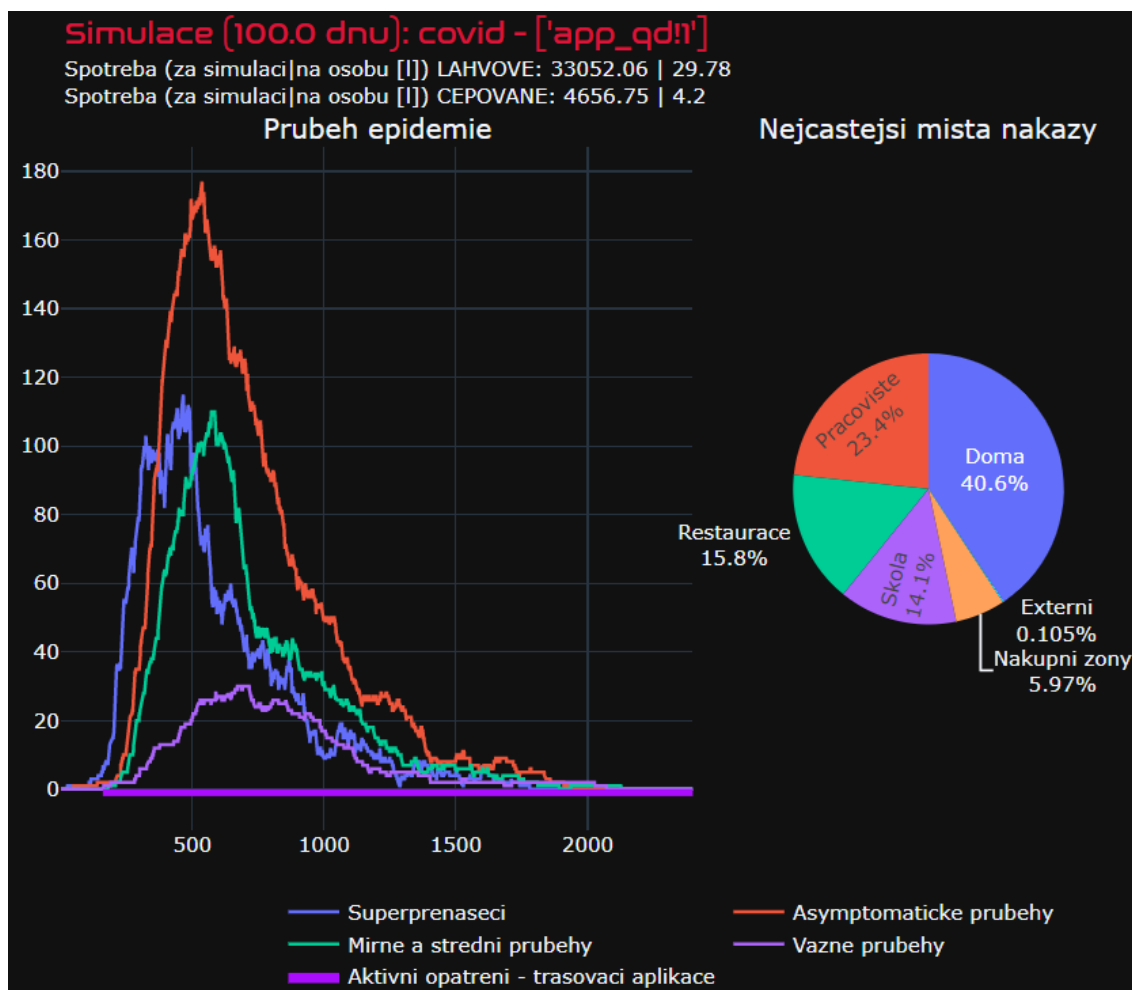
Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

I v případě ochrany dýchacích cest je patrný negativní dopad pozdního spuštění protiopatření (viz. scénář *mask_r!10*, Obrázek 22).

Trasovací aplikace a karanténa

Ochrana dýchacích cest je i jednou z voleb protiopatření trasovací aplikací, kdy si vytrasovaní agenti, a případně i jejich společná domácnost, nasadí roušky. Tento typ opatření je v rámci trasovací aplikace nejvýhodnější. Problémem ovšem je, že všechny scénáře s trasovací aplikací dosahují horších výsledků než neřízený průchod epidemie populací ve scénáři *covid* (Obrázek 22). Důvodem je zjevně roztažení epidemie do delšího období – brždění průchodu může mít tedy i negativní důsledky (i když v případě CBS není počítáno se zatížením zdravotního systému,

který z brždění epidemie profituje a zpětně by ovlivňoval i výsledky ekonomické či sociální).



Obrázek 30 - Průběh epidemie ve scénáři app_qd!1

Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

Charakteristika onemocnění covid-19 hraje ústřední roli v podprůměrných výsledcích cílených protiopatření po vytrasování a ostatně i v případě protiopatření karanténou – ve chvíli, kdy je zachycen symptomatický přenašeč a spuštěna karanténa, ochrana dýchacích cest nebo testování kontaktů, je epidemie rozšířena v širší populaci a omezená skupina vytrasovaných kontaktů nebo statických kolektivů již na její další průběh nemá podstatně omezující vliv.

Testování

Posledním protiopatřením je testování. U testování se ukazuje, že nejdůležitější je nejen brzký start protiopatření, ale také vyšší frekvence testování na co nejširší skupině obyvatel. Vysoká frekvence testů je dokonce důležitější než jejich přesnost, díky čemuž je scénář s antigenním testem se 70 % přesností 1x za 3 dny výhodnější než testování PCR-RT metodou s přesností 99.9 % 1x týdně, i když rozdíl není nijak výrazný (Obrázek 22).

3.1.3 Kombinovaná protiopatření

Kombinace protiopatření na základě výsledků předchozích simulací (s vynecháním scénářů s úplným pokrytím cílové populace trasovací aplikací a s dokonalým využitím protektivní ochrany roušek) pro zjištění, zda skládání protiopatření vede k lepším výsledkům než aplikace protiopatření samostatných.

python main.py -n 2400 -p sector_r!1,app_qd!1,test_dw!0

Scénář kombinuje trasovací aplikaci s nastavením karantény pro celou domácnost kontaktu identifikovaného přenašeče s protiopatřením sektorovým omezením v podobě uzavření lokací R. V kombinaci je uvedeno i antigenní testování ve frekvenci 1x za 3 dny pro všechny agenty z cílové věkové skupiny (podle nastavení v `config_sim.json`, ve výchozím stavu jde o agenty starší 12 let včetně). Protože je aplikováno protiopatření testováním, jsou ostatní aplikovaná protiopatření aktivována ve chvíli, kdy součet pozitivně testovaných agentů a agentů přecházejících do symptomatické fáze onemocnění dosáhne 1 (aktivace proběhne s prvním pozitivním testem nebo prvním symptomaticky nemocným – záleží, jaká událost přijde první). Kombinace také dokresluje situaci, kdy je protiopatření testováním aplikováno ještě před prokazatelným výskytem onemocnění v populaci.

python main.py -n 2400 -p sector_r!1,app_md!1,test_dw!0

Scénář kombinuje trasovací aplikaci s nastavením ochrany dýchacích úst pro celou domácnost kontaktu identifikovaného přenašeče s protiopatřením

sektorovým omezením v podobě uzavření lokací R. V kombinaci je uvedeno i antigenní testování ve frekvenci 1x za 3 dny pro všechny agenty z cílové věkové skupiny. Protože je už od počátku simulace aplikováno protipatření testováním, jsou ostatní aplikovaná protipatření aktivována ve chvíli, kdy součet pozitivně testovaných agentů a agentů přecházejících do symptomatické fáze onemocnění dosáhne 1.

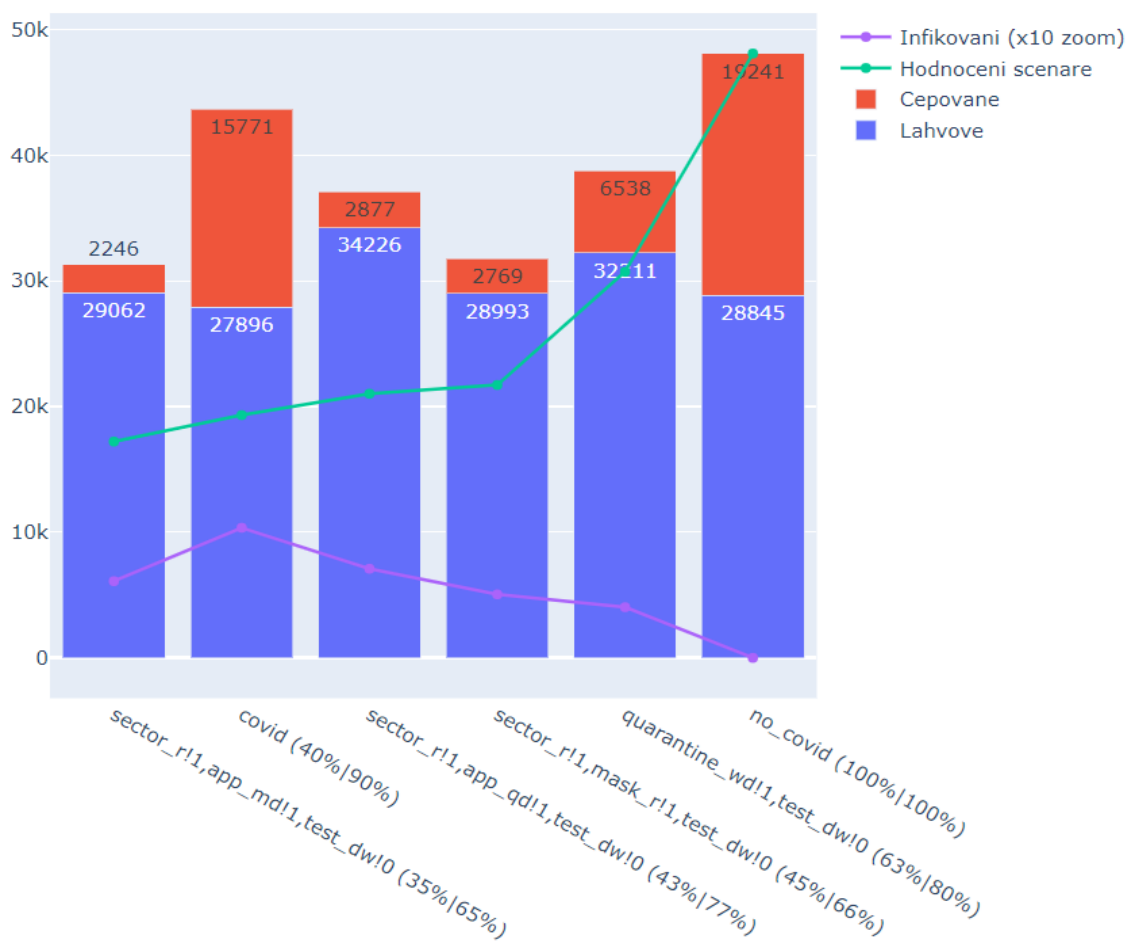
python main.py -n 2400 -p sector_r!1,mask_r!1,test_dw!0

Scénář kombinuje ochranu dýchacích cest pro celou populaci (vyjma agentů mladších 5 let, dle nastavení v config_sim.json) s protipatřením sektorovým omezením v podobě uzavření lokací R. V kombinaci je uvedeno i antigenní testování ve frekvenci 1x za 3 dny pro všechny agenty z cílové věkové skupiny, a to od počátku simulace.

python main.py -n 2400 -p quarantine_wd!1,test_dw!0

Scénář kombinuje karanténu pro domácnost a pracovní kolektiv identifikovaného nemocného a testováním antigenními testy pro všechny agenty z cílové skupiny. Testování je aplikováno od počátku běhu scénáře.

3.1.4 Výsledek simulací kombinovaných protiopatření

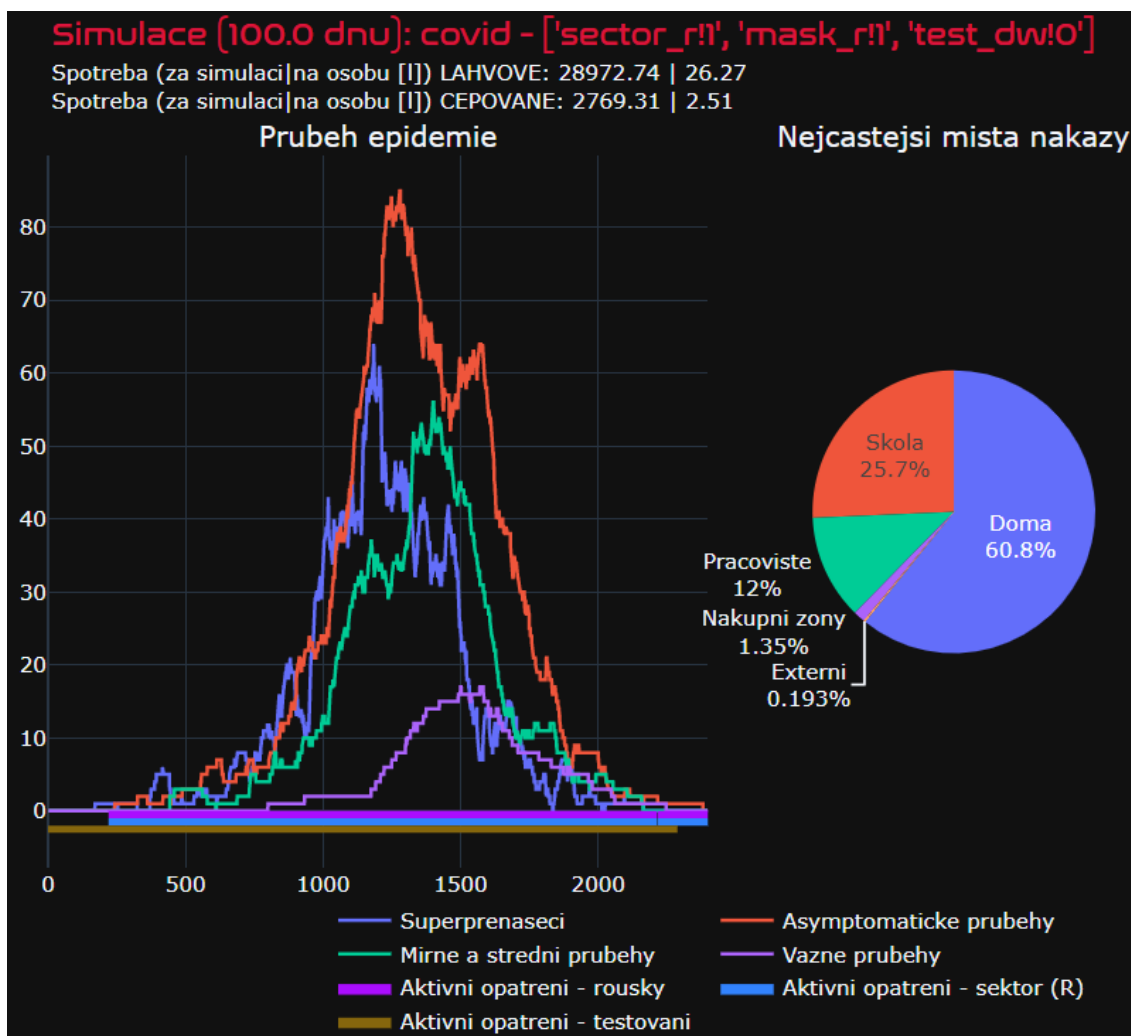


Obrázek 31 - Porovnání kombinovaných scénářů se základními scénáři

Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

U kombinovaných protiopatření ani jeden z testovaných scénářů nevykázal horší celkové hodnocení, než je základní scénář *covid* (Obrázek 31). Vítězným protiopatřením je kombinace *quarantine_wd!1, test_dw!0*, jehož pивní spotřeba i celkové hodnocení vykázalo oproti základnímu scénáři *no_covid* propad 20 % pивní spotřeby a 37 % v celkovém hodnocení.

Propad celkového hodnocení je u kombinovaných protiopatření také nižší, než je průměr samostatných protiopatření, i když z hlediska samostatné spotřeby piva výsledky již tak dobré nejsou a dochází zejména k poklesu v segmentu čepovaného piva (restaurací). U scénáře *sector_r!1, mask_r!1, test_dw!0* (Obrázek 32) se projevil vliv nedokonalého nošení roušek v domácnostech, které se staly hlavním místem přenosu onemocnění.



Obrázek 32 - Průběh epidemie ve scénáři sector_r!1,mask_r!1,test_dw!0

Zdroj: vlastní archiv autora (výsledek simulace zobrazený pomocí nástroje Plotly)

Výhodou protiopatření (Obrázek 32) je poměrně efektivní zpomalení průběhu epidemie, i když je vlivem nedokonalostí v protiopatřeních stále patrná i pozitivní vazba mezi počtem infekčních agentů a přírůstkem nově infikovaných – čím více je infekčních agentů, tím vyšší je pravděpodobnost nakažení neimunního agenta a tím vyšší je počet infekčních agentů (viditelným znakem je exponenciální růst zhruba od kroku 500 do kroku 1200). Propad ve spotřebě je pak dán dlouhodobým uzavřením lokací R plynoucím z dlouho trvající aktivní fáze sektorového omezení.

3.1.5 Shrnutí výsledků simulací

Z porovnání testovaných scénářů vyplývá, že:

- 1 i ve scénáři bez jakýchkoliv protiopatření dochází v průběhu epidemie k citelnému propadu spotřeby piva danému onemocněními agentů a obavami z nákazy zejména u ohrožených skupin (-10 % ve spotřebě),
- 2 samostatná protiopatření mají zpravidla menší účinek, než jejich kombinace (v případě protiopatření tedy může docházet k synergickému působení) a to z hlediska celkového hodnocení vlivu neomezeného jen na spotřebu piva, s výjimkou scénáře *lockdown!1* a *mask_i!1*,
- 3 vliv protiopatření se projevuje vždy se zpožděním, jehož délka souvisí s délkou bezpříznakové fáze onemocnění a množstvím asymptomatických přenašečů,
- 4 při pozdním startu ztrácí všechna protiopatření efektivitu a musí trvat delší dobu – ekonomické i společenské ztráty s pozdní aktivací protiopatření rostou,
- 5 s rostoucí akceptací protiopatření typu ochrana dýchacích cest nebo trasovací aplikace (varianty s konfiguračním znakem „i“ versus varianty bez něj) roste i úspěšnost protiopatření .

Ze spuštěných scénářů je nejvýhodnějším scénářem *lockdown!1*, tedy co nejdřívější a nejtvrdší protiopatření úplným uzavřením ekonomiky, které ovšem paradoxně vede k nejnižším ztrátám. V případě lockdownu se epidemie dostává velmi rychle pod kontrolu a protiopatření nemusí trvat příliš dlouho. Je také otázkou, zda by situaci ještě nevylepšílo delší minimální trvání protiopatření než 10 dnů nastavených v *config_sim.json*, nebo kombinace s cíleným testováním např. agentů s častými sociálními kontakty (uzlů s vysokými stupni).

CBS také neobsahuje mechanismus zavlečení nákazy z vnějšího prostoru v průběhu simulace (tj. zdroj nezávislý na modelové populaci, např. turistický ruch ze zasažených oblastí) nebo vliv mutací patogenu. Pokud by tomu tak bylo, pak je

možné, že samostatný lockdown by musel být aktivován mnohem častěji a bylo by nutné jej doplnit dalšími protiopatřeními pro dosažení co nejlepších výsledků.

4 Závěr

V rámci této diplomové bylo představeno množství informací o viru SARS-CoV-2 a onemocnění Covid-19, které způsobuje. Informace byly podány včetně epidemiologických charakteristik platných v době tvorby diplomové práce, zejména z hlediska inkubační doby, mechanismu a době přenosu infekce a závažnosti onemocnění s ohledem na různé věkové skupiny obyvatel. Dále byly předloženy poznatky o rizikových aktivitách a prostorech, v nichž se pravděpodobnost přenosu zvyšuje a epidemiologických opatřeních, která by měla šíření onemocnění v populaci naopak bránit. Součástí práce jsou také poznatky o ekonomických dopadech šíření onemocnění a epidemiologických opatření, a to zejména v oblasti cestovního ruchu, pohostinství a pivovarnictví. Tyto informace byly využity k vyhledání modelů popisujících šíření epidemie a jejich stručný popis, a to včetně modelu sestavenému ve frameworku MESA programovacího jazyka Python. Ačkoliv šlo o zajímavé modely, žádný z nich se nezaměřoval na pivovarnictví, resp. nemodeloval dopad na spotřebu piva v průběhu epidemie. V samém závěru teoretické části diplomové práce byl stručně představen i framework MESA pro tvorbu multiagentových simulací.

Teoretické znalosti se poté staly východiskem pro tvorbu vlastního modelu ve frameworku MESA s využitím modulu Pandas vhodném pro datovou analýzu. Tvorba modelu a vyhodnocení výsledků je také primárním cílem této práce.

Výsledný model umožňuje jak běh samotné simulace průchodu epidemie populací, tak i generování vlastní populace agentů se všemi důležitými parametry, jako je věková struktura, zdravotní stav v případě nákazy, spotřeba piva, počet restauračních zařízení apod. Generátor pro tvorbu populace umožňuje změnu nastavení pomocí konfiguračního souboru a parametrů příkazového řádku a jeho výstupy jsou opakovaně použitelné - vygenerovanou populaci (v rámci testování byla generovány populace v rozpětí od 100 do 50000 agentů) lze použít nejen pro opakovaný běh simulace, ale i pro jiné experimenty.

Samotná simulace, tedy druhá část modelu, obsahuje mimo vlastní spotřeby piva i možnost aplikace několika protiepidemických opatření, konkrétně jde o

ochranu dýchacích cest, testování, sektorová omezení, lockdown a trasování pomocí chytré aplikace. Protiopatření lze různě kombinovat a široce konfigurovat před zahájením simulace. Výhodou modelu je také paralelizace běhu simulací, čímž je možné simulovat mnoho scénářů souběžně. Simulace lze spouštět pro populace libovolného rozsahu, nicméně paměťová a časová náročnost činí smysluplné scénáře do 10000 agentů. To ovšem odpovídá poznatkům z kapitoly 1.5.6, kde veškeré simulace ve frameworku MESA nepřesahovaly nižší stovky agentů, i vlastním experimentům s těmito modely. Složitost a rozsah populace v rámci CBS si vynutila tvorbu vlastního data collectoru, díky němuž se výrazně zvýšila výkonnost Simulátoru oproti vestavěným nástrojům frameworku MESA.

Pro popis sestaveného modelu byl využit ODD protokol jako základní rámec pro popis a rozbor multiagentových modelů.

Výsledkem je možnost porovnání různých protiopatření vzájemně, i se scénářem zcela volného průchodu onemocnění populací, a to z hlediska spotřeby piva i počtu onemocnění nebo obětí.

V rámci zhodnocení simulace bylo sestaveno a vyhodnoceno 24 různých scénářů (z toho 2 jako základní scénáře pro získání referenčních hodnot pro spotřebu piva za běžných okolností a spotřebu piva, počet nemocných a mrtvých za stavu neřízené epidemie). Po jejich běhu byla zvolena metoda pro přepočítání výstupních dat pro získání celkového hodnocení scénáře kombinujícího jak epidemiologické výsledky, tak výsledky spotřeby – cílem bylo získání pohledu na výhodnost jednotlivých scénářů. Vítězným scénářem byl *lockdown!1*, tedy úplné uzavření ekonomiky přijaté v co nejkratším čase po projevení onemocnění v populaci. Dále bylo konstatováno, že ve všech protiopatřeních záleží na rychlosti přijetí protiopatření a akceptaci jeho dodržování populací. Otestováno bylo také několik kombinovaných scénářů obsahujících více než jedno protiopatření se závěrem, že kombinovaná protiopatření jsou výhodnější než protiopatření samostatná – zejména v případě, kdy kombinace obsahuje testování s co nejvyšší frekvencí a co nejširším záběrem.

Testované scénáře však nejsou jediné možné a vzhledem k možnostem nastavení CovidBeerSimulator (jak v rámci konfiguračních souborů, tak i parametrů pro spuštění simulace), existuje velké množství dalších simulačních scénářů. Současně s tím je systém naprogramován tak, aby bylo možné co nejnázé implementovat dodatečná protipatření nebo funkcionality podle volby a potřeb výzkumníka nebo vývojáře. Jako vhodné rozšíření systému se jeví i umožnění reinfekce z externích zdrojů v průběhu simulace. Množství současných i budoucích možností nastavení také znamená, že možných výstupů může simulace generovat opravdu velké množství. Velké množství výsledků a široké možnosti vstupů, které je generují, jsou vstupními podmínkami pro aplikaci metod statistické analýzy nebo umělé inteligence pro hledání optimální strategie řešení simulace při různých konfiguracích vstupní populace.

5 Seznam použité literatury

- [1] Google. Google Mobility Trends: How has the pandemic changed the movement of people around the world? [online], cit. 5.4.2021. URL: <https://ourworldindata.org/covid-mobility-trends>.
- [2] ADAM, Tomáš and MICHL, Aleš. První odhad dopadů pandemie COVID-19 na ekonomiku ČR - Česká národní banka. [online], 03/2021, cit. 12.4.2021. URL: https://www.cnb.cz/cs/o_cnb/cnblog/Prvni-odhad-dopadu-pandemie-COVID-19-na-ekonomiku-CR/.
- [3] Operátor ICT, a.s. Katalog datové platformy Golemio. [online], cit. 12.4.2021. URL: <https://golemio.cz/cs/data/covid19-v-praze#covid-efekt>.
- [4] ČSÚ [Český statistický úřad]. Statistiky: Obchod, pohostinství, ubytování. [online], cit. 12.4.2021. URL: <https://vdb.czso.cz/vdbvo2/faces/cs/index.jsf?page=statistiky&katalog=31029>.
- [5] SILVA Petrônio C. L. et al. COVID-ABS: An Agent-Based Model of COVID-19 Epidemic to Simulate Health and Economic Effects of Social Distancing Interventions. Chaos, Solitons & Fractals, 139, cit. 12. 4. 2021. URL: <https://arxiv.org/abs/2006.10532v2>. arXiv:2006.10532v2 [cs.AI]
- [6] MINOZA, Jose Marie Antonio, BONGOLAV, Vena Pearl, and RAYO, Joshua Frankie. COVID-19 Agent-Based Model with Multi-objective Optimization for Vaccine Distribution. [online], 01/2021, cit. 14. 4. 2021. URL: <http://arxiv.org/abs/2101.11400v1>. arXiv: 2101.11400v1 [q-bio.PE]
- [7] MZČR [Ministerstvo zdravotnictví České republiky]. COVID-19 v ČR: Otevřené datové sady a sady ke stažení | Onemocnění Aktuálně MZČR. [online], 12/2020, cit.12.4.2021. URL:<https://onemocneni-aktualne.mzcr.cz/api/v2/covid-19>.
- [8] Český statistický úřad. Česká republika od roku 1989 v číslech. [online], 12/2020, cit. 9.4. 2021. URL: <https://www.czso.cz/csu/czso/ceska-republika-od-roku-1989-v-cislech-aktualizovano-11122020>.
- [9] Český svaz pivovarů a sladoven. České pivovarnictví vloni rostlo, letos očekává výrazný propad domácí spotřeby i exportu. [online], cit. 12. 4.2021. URL: <http://ceske-pivo.cz/tz2020/ceske-pivovarnictvi-vloni-rostlo-letos-ocekava-vyrazny-propad-domaci-spotreby-i-exportu>.
- [10] GÖPFERTOVÁ Dana and FABIÁNOVÁ, Kateřina. Epidemiologická charakteristika onemocnění covid-19: Úvaha nad současnými poznatky o onemocnění. Farmakoterapeutická Revue, str.30–36, 05/2020, cit. 5. 4. 2021. ISSN:2533-6878.
- [11] HUBÁČEK, Petr. Nově popsáný koronavirus SARS-CoV-2 a jeho biologické souvislosti. Farmakoterapeutická Revue, str.15–22, 05/2020, cit. 5. 4. 2021. ISSN:2533-6878.

- [12] ŠEDIVÁ, Anna. Imunita u covid-19. Farmakoterapeutická Revue, str. 23–28, 05/2020, cit. 5. 4. 2021. ISSN:2533-6878.
- [13] TESINI Brenda L. Coronaviruses and Acute Respiratory Syndromes (COVID-19, MERS and SARS) - Infections.MSD Manual Consumer Version. [online], 03/2021 , cit. 12.4.2021. URL: <https://www.msdmanuals.com/home/infections/respiratory-viruses/coronaviruses-and-acute-respiratory-syndromes-covid-19-mers-and-sars>.
- [14] STEJSKAL, František. Covid-19 – devět měsíců zkušeností. Jsou přístupy ke kontrole této infekce racionální? Farmakoterapeutická Revue, (Suppl 1):8–14, 05/2020, cit. 5. 4. 2021. ISSN:2533-6878.
- [15] ZHANG, Renyi and LI, Yixin and ZHANG, Annie L. et al. Identifying airborne transmission as the dominant route for the spread of COVID-19. Proceedings of the National Academy of Sciences, 117(26):14857–14863. [online], 06/2020, cit. 12.4.2021. URL: <https://www.pnas.org/content/117/26/14857>. doi:10.1073/pnas.2009637117
- [16] SONG Tang et al. Aerosol transmission of SARS-CoV-2? Evidence, prevention and control. Environment International, 144:106039, [online], 11/2020, cit.10.4.2021. URL: <https://www.sciencedirect.com/science/article/pii/S0160412020319942>. doi:10.1016/j.envint.2020.106039
- [17] JANG, Sukbin and HAN, Si Hyun and RHEE, Ji-Young. Cluster of Coronavirus Disease Associated with Fitness Dance Classes, South Korea - Volume 26, Number 8—August 2020 - Emerging Infectious Diseases journal-CDC. [online], 08/2020, cit. 5.4.2021. URL: https://wwwnc.cdc.gov/eid/article/26/8/20-0633_article. doi:10.3201/eid2608.200633
- [18] CHMELAR, Josef and KOSINA, Pavel and CHLÍBEK Roman. Onemocnění covid-19 na standardním lůžkovém oddělení. Farmakoterapeutická Revue, str. 70–73., 05/2020, cit. 5. 4. 2021. ISSN:2533-6878.64
- [19] VAN DAMME, Wim et al. COVID-19: Does the infectious inoculum dose-response relationship contribute to understanding heterogeneity in disease severity and transmission dynamics? Medical Hypotheses, 146:110431. [online], 01/2021, cit. 12.4. 2021. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7686757/>. doi:10.1016/j.mehy.2020.110431
- [20] KISSLER, Stephen M. and TEDIJANTO, Christine and GOLGDSTEIN, Edward et al. Projecting the transmission dynamics of SARS-CoV-2 through the postpandemic period. Science, 368(6493):860–868. [online], 05/2020, cit.4.5.2021. URL: <https://science.sciencemag.org/content/368/6493/860>. doi:10.1126/science.abb5793
- [21] CHIA, Wan Ni et al. Dynamics of SARS-CoV-2 neutralising anti-body responses and duration of immunity: A longitudinal study. The Lancet Microbe. [online], 03/2021, cit. 12.4.2021. URL:

[https://www.thelancet.com/journals/lanmic/article/PIIS2666-5247\(21\)00025-2/abstract](https://www.thelancet.com/journals/lanmic/article/PIIS2666-5247(21)00025-2/abstract). doi:10.1016/S2666-5247(21)00025-2.

[22] IWASAKI Akiko. What reinfections mean for COVID-19. *The Lancet Infectious Diseases*, 21(1):3–5. [online], 10/2020, cit. 12.4.2021. URL: [https://www.thelancet.com/journals/laninf/article/PIIS1473-3099\(20\)30783-0/abstract](https://www.thelancet.com/journals/laninf/article/PIIS1473-3099(20)30783-0/abstract). doi:10.1016/S1473-3099(20)30783-0

[23] EDRIGE, Arthur W. D. et al. Seasonal coronavirus protective immunity is short-lasting. *Nature Medicine*, 26(11):1691–1693. [online], 09/2020, cit. 12.4.2021. URL: <https://www.nature.com/articles/s41591-020-1083-1>. doi:10.1038/s41591-020-1083-1

[24] SZÚ [Státní zdravotní ústav České republiky]. Počet případů reinfekcí covid-19 v ČR vzrostl, SZÚ. [online], cit. 12.4.2021. URL: <http://www.szu.cz/tema/prevence/pocet-pripadu-reinfekci-covid-19-v-cr-vzrostl>.

[25] ČSÚ [Český statistický úřad]. Jak jsou na tom Češi s chudobou, obezitou či sportováním? | Století statistiky. [online], cit. 5.4.2021. URL: <https://www.czso.cz/csu/stoletistatistiky/jak-jsou-na-tom-cesi-s-chudobou-obezitou-ci-sportovanim>

[26] MeDitorial.cz. Obezita jako významný rizikový faktor horšího průběhu COVID-19 i u mladších pacientů. [online], 05/2020, cit. 5.4.2021. URL: <https://www.prosestru.cz/novinky/obezita-jako-vyznamny-rizikovy-faktor-horsiho-prubehu-covid-19-i-u-mladsich-pacientu-122144.65>. ISSN:1803-6597

[27] SAHA Aritra and ANIRVAN Prajna. Cancer progression in COVID-19. [online], 09/2020, cit. 12.4.2021. URL: <http://ecancer.org/en/journal/article/1099-cancer-progression-in-covid-19-integrating-the-roles-of-renin-angiotensin-aldosterone-system-angiopoietin-2-heat-shock-protein-27-and-epithelial-mesenchymal-transition>. doi:10.3332/ecancer.2020.1099

[28] MALLAPATY Smriti. Mounting clues suggest the coronavirus might trigger diabetes. *Nature*, 583(7814):16–17, 07/2020, cit. 12.4.2021. URL: <https://www.nature.com/articles/d41586-020-01891-8>. doi:10.1038/d41586-020-01891-8.

[29] YANG Liuliu et al. A Human Pluripotent Stem Cell-based Platform to Study SARS-CoV-2 Tropism and Model Virus Infection in Human Cells and Organoids. *Cell Stem Cell*, 27(1):125–136.e7. [online] cit. 12.4.2021. <https://www.sciencedirect.com/science/article/pii/S1934590920302824>. doi:10.1016/j.stem.2020.06.015

[30] MeDitorial.cz. Zdravotní následky dlouhého průběhu covid-19 (long co-vid) a prediktivní faktory jeho rizika. [online], 11/2020, cit. 12.4.2021. URL: <https://www.prolekare.cz/covid-19/zdravotni-nasledky-dlouheho-prubehu-covid-19-long-covid-a-prediktivni-faktory-jeho-rizika-125076>. ISSN:1803-6597.

- [31] SAEED, Umar and UPPAL, Sara Rizwan and PIRACHA, Zahra Zahid et al. Evaluation of SARS-CoV-2 antigen-based rapid diagnostic kits in Pakistan: formulation of COVID-19 national testing strategy. *Virology Journal*, 18(1):34. [online], 02/2021, cit.5.4.2021. <https://virologyj.biomedcentral.com/articles/10.1186/s12985-021-01505-3>. doi:10.1186/s12985-021-01505-3
- [32] FN Motol [Fakultní nemocnice v Motole]. Antigenní testy nejsou spolehlivé, ukazuje provedená studie. [online], 10/2020, cit. 5.4.2021. URL: <https://www.fnmotol.cz/odbor-komunikace/tiskovy-servis/tiskove-zpravy/archiv-2020/27102020-antigenni-testy-nejsou-spolehlive-ukazuje/>.
- [33] ČSÚ [Český statistický úřad]. Informační společnost v číslech - 2020. [online], 03/2020, cit. 5.4.2021. URL:<https://www.czso.cz/csu/czso/informacni-spolecnost-v-cislech-2020>.
- [34] Google.Overview - Community Mobility Reports. [online], cit.5.4.2021. URL: https://support.google.com/covid19-mobility/answer/9824897?hl=en&ref_topic=9822927
- [35] SULYOK, Mihály and WALKER, Mark. Community movement and COVID-19: a global study using Google's Community Mobility Reports. *Epidemiology & Infection*, 148. [online], 11/2020, cit. 5.4.2021. <https://www.cambridge.org/core/journals/epidemiology-and-infection/article/community-movement-and-covid19-a-global-study-using-googles-community-mobility-reports/C1EF917377F6013D5E1ECC44E03A3E6E>. doi:10.1017/S0950268820002757
- [36] BASU, Saurav. Effective Contact Tracing for COVID-19 Using Mobile Phones: An Ethical Analysis of the Mandatory Use of the Aarogya Setu Application in India. *Cambridge Quarterly of Healthcare Ethics*, 30(2):262–271. [online], 11/2020, cit. 5.4.2021. <https://www.cambridge.org/core/journals/cambridge-quarterly-of-healthcare-ethics/article/effective-contact-tracing-for-covid19-using-mobile-phones-an-ethical-analysis-of-the-mandatory-use-of-the-aarogya-setu-application-in-india/8A902BBEF6722241E28458BB70FC1195>. doi:10.1017/S0963180120000821
- [37] LEE, Terence and LEE, Howard. Tracing surveillance and auto-regulation in Singapore: 'smart' responses to COVID-19. *Media International Australia*. [online], 11/2020, cit. 5.4.2021. URL: <https://journals.sagepub.com/doi/pdf/10.1177/1329878X20949545>. doi:10.1177/1329878X20949545.
- [38] NAKIT [Národní agentura pro komunikační a informační technologie, s. p.]. eRouška. [online], cit. 12.4.2021. URL: <https://erouska.cz/caste-dotazy>.
- [39] BAHARUDIN, Bariz. Apple-Google contact tracing system not effective for Singapore: Vivian Balakrishnan. [online], 06/2020, cit. 12.4.2021. URL: <https://www.straitstimes.com/singapore/apple-google-contact-tracing-system-not-effective-for-singapore-vivian-balakrishnan>.

- [40] ZHANG, Mingxin, VERBAECK, Alexander, MENG, Rongqing, et.al. 'Modeling Spatial Contacts for Epidemic Prediction in a Large-Scale Artificial City' *Journal of Artificial Societies and Social Simulation* 19 (4) 3. [online], 2016, cit. 24.10.2021, URL: <http://jasss.soc.surrey.ac.uk/19/4/3.html>. doi: 10.18564/jasss.3148
- [41] SADEK, George. Qatar: Installing COVID-19 Tracing App on MobilePhones and Wearing Face Masks among Recent Mandatory Anti-pandemic Measures Instituted by Authorities | *Global Legal Monitor*. LAW.gov, 06/2020, cit. 12.4.2021. URL: <https://www.loc.gov/item/global-legal-monitor/2020-06-11/qatar-installing-covid-19-tracing-app-on-mobile-phones-and-wearing-face-masks-among-recent-mandatory-anti-pandemic-measures-instituted-by-authorities/>
- [42] JOHNSON, Bobbie. The Covid Tracing Tracker: What's happening in coronavirus apps around the world. *MIT Technology Review*, 12/2020, cit. 12.4.2021. URL: <https://www.technologyreview.com/2020/12/16/1014878/covid-tracing-tracker/>.
- [43] DREAVAR, Charlie. Mandatory Covid-19 app scanning put on back burner. [online], 03/2021, cit. 12.4.2021. URL: <https://www.rnz.co.nz/news/political/438196/mandatory-covid-19-app-scanning-put-on-back-burner>.
- [44] WEIDEMAN, Tobias. Corona-Warn-App 2.0: Check-in per QR-Code startet nach Ostern. *t3n Magazin*, 03/2021, cit. 12.4.2021. URL: <https://t3n.de/news/corona-warn-app-20-check-in-qr-code-1367664/>.
- [45] HEINE, Hanna. Federal government integrates rapid covid-19 tests into corona-warn-app. [online], 03/2021, cit. 12.4.2021. URL: <https://www.coronawarn.app/en/blog/2021-03-31-corona-warn-app-test-integration/>.
- [46] Government of Singapore. SafeEntry - National digital check-in system. [online], cit. 12.4.2021. URL: <https://safeentry.gov.sg/>.
- [47] CDC [National Center for Immunization and Respiratory Diseases]. COVID-19 and Your Health. [online], 02/2020, cit. 12.4.2021. URL: <https://www.cdc.gov/coronavirus/2019-ncov/prevent-getting-sick/social-distancing.html>.
- [48] SIEDNER, Mark J. and HARLING, Guy and REYNOLDS, Zahra et al. Social distancing to slow the US COVID-19 epidemic: Longitudinal pretest–posttest comparison group study. *PLOS Medicine*, 17(8):e1003244, 08/2020, cit.12.4.2021. URL: <https://journals.plos.org/plosmedicine/article?id=10.1371/journal.pmed.1003244>. doi:10.1371/journal.pmed.1003244
- [49] WHO [World health organization]. Overview of public health and social measures in the context of COVID-19. [online], 04/2021, cit. 12.4.2021. URL: <https://apps.who.int/iris/handle/10665/332115>.

[50] WHO [World health organization]. Advice for the public on COVID-19 – World Health Organization. [online], 2020, cit. 12.4.2021. URL: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/advice-for-public>.

[51] XU, Chunwen and NIELSEN, Peter V. and LIU, Li et al. Human exhalation characterization with the aid of Schlieren imaging technique. Building and Environment, 112:190–199, 02/2017, cit. 12.4.2021. <https://www.sciencedirect.com/science/article/pii/S0360132316304632>. doi:10.1016/j.buildenv.2016.11.032

[52] DAVIES, Anna and THOMPSON, Katy-Anne and GIRI Karthika. Testing the Efficacy of Homemade Masks: Would They Protect in an Influenza Pandemic. ResearchGate. [online], 08/2013, cit. 12.4.2021. URL:https://www.researchgate.net/publication/258525804_Testing_the_Efficacy_of_Homemade_Masks_Would_They_Protect_in_an_Influenza_Pandemic. doi:10.1017/dmp.2013.43

[53] MITZE, Timo and KOSFELD Reinhold and RODE Johannes et al. Face Masks Considerably Reduce COVID-19 Cases in Germany: A Synthetic Control Method Approach. [online], 06/2020, cit. 12.4.2021. Institute of Labour Economics, URL: <https://www.iza.org/publications/dp/13319/face-masks-considerably-reduce-covid-19-cases-in-germany-a-synthetic-control-method-approach>. IZA DP No. 13319

[54] LARREMORE, Daniel B. and WILDER, Bryan and LESTER, Evan et. al. Test sensitivity is secondary to frequency and turnaroundtime for COVID-19 screening. Science Advances, 01/2021, cit. 5.4.2021. URL: <https://advances.sciencemag.org/lookup/doi/10.1126/sciadv.abd5393>. doi:10.1126/sciadv.abd5393

[55] PITTS, Eric R. and WITRICK, Katherine. Brewery Packaging in a Post-COVID Economy within the United States. Beverages, 03/2021, cit. 19.4.2021. URL: <https://www.mdpi.com/2306-5710/7/1/14>. doi:10.3390/beverages7010014. doi:10.3390/beverages7010014

[56] ČSÚ [Český statistický úřad]. Hlavní makroekonomické ukazatele. [online], 04/2021, cit. 12.4.2021. URL:https://www.czso.cz/csu/czso/hmu_cr.

[57] UNWTO [World tourism organization]. Tourism and COVID-19 – unprecedented economic impacts | UNWTO. [online], cit. 12.4.2021. URL: <https://www.unwto.org/tourism-and-covid-19-unprecedented-economic-impacts>.

[58] ČSÚ [Český statistický úřad]. Satelitní účet cestovního ruchu. [on-line], 02/2021, cit. 12.4.2021. URL: https://www.czso.cz/csu/czso/satelitni_ucet_cestovniho_ruchu.

[59] MICHALOPOULOS, Sarantis. EU beer market sales fell 20% so far this year due to COVID-19. [online], 11/2020, cit. 12.4.2021. URL: <https://www.euractiv.com/section/beer/news/eu-beer-market-sales-fall-20-so-far-this-year-due-to-covid-19/>.

- [60] Český svaz pivovarů a sladoven. Ztráty českého pivovarnictví způsobené covid-19 dosahují téměř 5 miliard korun, největší dopad měly zavřené hospody. [online], cit. 12. 4. 2021. URL: <http://ceske-pivo.cz/tz2020/ztraty-ceskeho-pivovarnictvi-zpusobene-covid-19-dosahuji-temer-5-miliard-korun-nejvetsi-dopad-mely-zavrene-hospody>.
- [61] CETA - Centrum ekonomických a tržních analýz, z.ú. Odhad ztrát českých pivovarů ve 2. pololetí 2020 (tisková zpráva). [online], 11/2020, cit. 12. 4. 2021. URL: <http://ceske-pivo.cz/download/tiskove-zpravy/2021/apcovidii-final.pdf>.
- [62] PELÁNEK Radek. Modelování a simulace komplexních systémů: jak lépe porozumět světu. Masarykova univerzita, Brno, 2011. 236 s., ISBN 978-80-210-5318-2.
- [63] GRAF Christian. Modelling a Pandemic. [online], 09/2020, cit. 12. 4. 2021. URL: <https://towardsdatascience.com/modelling-a-pandemic-eb94025f248f>.
- [64] FARRELL, Damien. Bioinformatics and other bits - A simple agent based infection model with Mesa and Bokeh. [online], 04/2021, cit. 22.4.2021. URL: <https://dmnfarrell.github.io/bioinformatics/abm-mesa-python>.
- [65] MELLACHER, Patrick. COVID-Town: An Integrated Economic-Epidemiological Agent-Based Model. [online] 04/2020, cit. 12. 4. 2021. URL: <https://mpra.ub.uni-muenchen.de/104109/>. MPRA Paper No. 104109.
- [66] BICHER, Martin et al. Evaluation of contact-tracing policies against the spread of SARS-CoV-2 in Austria - an agent-based simulation. medRxiv, cit. 12. 4. 2021. URL: <https://www.medrxiv.org/content/early/2021/01/23/2020.05.12.20098970>. doi: 10.1101/2020.05.12.20098970
- [67] GHORBANI, Amineh et al. The ASSOCC Simulation Model: A Response to the Community Call for the COVID-19 Pandemic. [online], cit. 12. 4. 2021. URL: <https://rofasss.org/2020/04/25/the-assocc-simulation-model/>
- [68] PROJECT MESA TEAM. Mesa: Agent-based modeling in Python 3+ - Mesa documentation. [online], cit. 12. 4. 2021. URL: <https://mesa.readthedocs.io/en/stable/>.
- [69] CORVINCE. Corvince/Mesa-geo. [online], 04/2021, cit. 23.4.2021. URL: <https://github.com/Corvince/mesa-geo>.
- [70] BAILEY, Mark M. Mesa-SIR: A Mesa extension for SIR models. [online], 04/2020, cit. 23.4.2021. URL: <https://github.com/metalcorebear/COVID-Agent-Based-Model>.
- [71] PIKE, Tom and ENGLISH, Brad. Multilevel-mesa: Provides extension module to Mesa to allow for Hierarchies and Modules of Agents. [online], 03/2021, cit. 23.4.2021. URL: https://github.com/tpike3/ml_mesa.
- [72] GRIMM, Volker and RAILSBACK, Steven F. and VINCENOT et. al. The ODD Protocol for Describing Agent-Based and Other Simulation Models: A Second Update to Improve Clarity, Replication, and Structural Realism. Journal of Artificial Societies and Social Simulation, 23(2):7, 03/2020. cit. 25.7.2021. URL: <http://jasss.soc.surrey.ac.uk/23/2/7.html>. doi:10.18564/jasss.4259

- [73] GRIMM, Volker and BERGER, Uta and DEANGELIS Donald L. et al. Supplement to: Grimm V, Berger U, DeAngelis DL, Polhill JG, Giske J, Railsback SF. 1010. The ODD protocol: a review and first update. cit. 5.8.2021. URL: <http://www2.econ.iastate.edu/tesfatsi/ODD-update-template.doc>
- [74] ČSÚ [Český statistický úřad]. Vývoj počtu a struktury domácností. [online], 12/2014, cit. 25.7.2021. URL: https://www.czso.cz/csu/czso/13-2135-03--3_1_vyvoj_poctu_a_struktury_domacnosti.
- [75] CVVM [Centrum pro výzkum veřejného mínění]. Pivo v české společnosti v roce 2016 (tisková zpráva). [online], 11/2016, c. 25.7.2021. URL: https://cvvm.soc.cas.cz/media/com_form2content/documents/c2/a2121/f9/OR161123a.pdf.
- [76] CVVM [Centrum pro výzkum veřejného mínění]. Pivo v české společnosti v roce 2018 (tisková zpráva). [online], 11/2018, cit. 25.7.2021. URL: https://cvvm.soc.cas.cz/media/com_form2content/documents/c2/a4749/f9/OR181113a.pdf
- [77] ČSÚ [Český statistický úřad]. Malé a střední firmy v ekonomice ČR. [online], 11/2011, cit. 25.7.2021. URL: <https://www.czso.cz/csu/czso/cri/male-a-stredni-firmy-v-ekonomice-cr-v-letech-2003-az-2010-n-u3ag8rcnab>
- [78] AMSP ČR [Asociace malých a středních podniků a živnostníků ČR]. Malé restaurace a hospody bez personálu (tisková zpráva). [online], 06/2018, cit. 25.7.2021. URL: <https://amsp.cz/male-restaurace-a-hospody-bez-personalu/>
- [79] ČSÚ [Český statistický úřad]. České školy v číslech | Století statistiky. [online], 08/2019, cit. 25.7.2021. URL: <https://www.czso.cz/csu/stoletistatistiky/ceske-skoly-v-cislech>
- [80] MPO [Ministerstvo průmyslu a obchodu]. Zpráva o vývoji malého a středního podnikání a jeho podpoře v roce 2017. [online], 2017, cit. 25.7.2021. URL: https://www.mpo.cz/assets/cz/podnikani/male-a-stredni-podnikani/studie-a-strategicke-dokumenty/2018/10/Zprava_MSP_2017.pdf
- [81] TASHAKOR, Ghazal. Scalable Agent-based model simulation using distributed computing on system biology. [online], 09/2020, cit. 24.10.2021. URL: <https://www.tesisenred.net/bitstream/handle/10803/671332/ghta1de1.pdf>
- [82] OSOBA, Osonde and VARDAVAS, Raffaele and GRANA, Justin et. al. Policy-focused Agent-based Modeling using RL Behavioral Models. [online] 06/2020, cit. 24.10.2021. URL: https://www.researchgate.net/publication/342094496_Policy-focused_Agent-based_Modeling_using_RL_Behavioral_Models

[83] WILENSKY, Uri. NetLogo. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. [online], 1999, cit. 24.10.2021. URL: <http://ccl.northwestern.edu/netlogo/>.

[84] ANDERSON, Roy M. and HEESTERBEEK, Hans and KLINKENBERG, Don and HOLLINGSWORTH, Déirdre. How will country-based mitigation measures influence the course of the COVID-19 epidemic? *The Lancet*. [online], 03/2020, cit. 10.9.2021. URL: [https://www.thelancet.com/journals/lancet/article/PIIS0140-6736\(20\)30567-5](https://www.thelancet.com/journals/lancet/article/PIIS0140-6736(20)30567-5). doi: [https://doi.org/10.1016/S0140-6736\(20\)30567-5](https://doi.org/10.1016/S0140-6736(20)30567-5).

[85] Our World in Data. Statistics and Research: Coronavirus (COVID-19) Cases. [online], cit. 10.9.2021. URL: <https://ourworldindata.org/covid-cases>

6 Přílohy

Oskenované zadání práce

UNIVERZITA HRADEC KRÁLOVÉ
Fakulta informatiky a managementu

Strana: 1/3

Údaje o diplomové práci

Osobní číslo:	I1900537	Datum zadání:	21. října 2019
Jméno a příjmení:	Bc. Lukáš Florner, DiS.	Plánované datum odevzdání:	30. června 2020
Obor/kombinace:	Aplikovaná informatika (ai2-k)	Datum odevzdání:	
Zadané téma:	Modelování dopadů šíření COVID na pivovarnictví		
Stav práce:	Rozpracovaná práce		

Údaje o kvalifikační práci

1. Hlavní téma
Modelování dopadů šíření COVID na pivovarnictví
2. Hlavní téma v angličtině
Simulation of COVID spread impacts on brewing industry
3. Název dle studenta
4. Název dle studenta v angličtině
5. Souběžný název
6. Podnázev
7. Anotace (krátký popis práce)
8. Klíčová slova (oddělujte čárkou)
9. Anotace v angličtině (krátký popis práce)
10. Anglická klíčová slova (oddělujte čárkou)
11. Přílohy volně vložené
12. Přílohy vázané v práci
13. Rozsah práce
14. Jazyk práce
CZ
15. Záznam průběhu obhajoby
16. Zásady pro vypracování
Cíl práce
Popsat možnosti tvorby agentových simulací v jazyce Python (framework MESA) a realizovat ukázkový model.
Osnova
1.Úvod
2.Teoretická část
2.1. Komplexní systémy
2.2. Modely a simulace
2.3. Framework MESA
2.4. Agentové modely v epidemiologii

Údaje o diplomové práci

Osobní číslo:	I1900537	Datum zadání:	21. října 2019
Jméno a příjmení:	Bc. Lukáš Florner, DiS.	Plánované datum odevzdání:	30. června 2020
Obor/kombinace:	Aplikovaná informatika (ai2-k)	Datum odevzdání:	
Zadané téma:	Modelování dopadů šíření COVID na pivovarnictví		
Stav práce:	Rozpracovaná práce		

- 3. Praktická část
- 3.1. Popis modelované oblasti (pivovarnictví v ČR, specifikace COVID)
- 3.2. Návrh modelu
- 3.3. Implementace
- 3.4. Uživatelské rozhraní
- 4. Výsledky
- 5. Závěr

17. Seznam doporučené literatury

- PELÁNEK, Radek. Modelování a simulace komplexních systémů: jak lépe porozumět světu. Brno: Masarykova univerzita, 2011. ISBN 978-80-210-5318-2.
- Mesa: Agent-based modeling in Python 3+ –Mesa .1 documentation. [online]. Project Mesa Team [cit. 18.09.2020]. Dostupné z: <https://mesa.readthedocs.io/en/master/index.html>
- COVID-ABS: An agent-based model of COVID-19 epidemic to simulate health and economic effects of social distancing interventions. National Center for Biotechnology Information [online]. Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7340090/>
- CETA | Centrum ekonomických a tržních analýz [online]. Dostupné z: http://eceta.cz/wp-content/uploads/2020/07/Pivovary_COVID_FINAL.pdf
- COVID-19 – ÚZIS ČR. Úvod -
- ÚZIS ČR [online]. Dostupné z: <https://www.uzis.cz/index.php?page=covid-19>

18. Osoby VŠKP

- Vedoucí diplomové práce: **doc. RNDr. Kamila Štekerová, Ph.D.**
Katedra informačních technologií

Elektronická forma kvalifikační práce

Zatím není přiložen žádný soubor s elektronickou formou práce...

Posudky kvalifikační práce

Posudek(y) oponenta:

Hodnocení vedoucího:

Soubor s průběhem obhajoby:

Údaje o diplomové práci

Osobní číslo:	I1900537	Datum zadání:	21. října 2019
Jméno a příjmení:	Bc. Lukáš Florner, DiS.	Plánované datum odevzdání:	30. června 2020
Obor/kombinace:	Aplikovaná informatika (ai2-k)	Datum odevzdání:	
Zadané téma:	Modelování dopadů šíření COVID na pivovarnictví		
Stav práce:	Rozpracovaná práce		

Potvrzuji správnost vložených údajů a potvrzuji plnou shodu elektronické verze s odevzdávanou listinnou verzí VŠKP.

Datum:

Podpis: