



Universitatea POLITEHNICA din București  
Splaiul Independenței nr. 313, București  
+ 40-21-402 91 00

# Evaluarea prin modelare a factorilor de risc în răspândirea COVID-19 în industria de panificație

## Colectiv de cercetare:

- Prof.dr.ing. Ioan-Ștefan Sacală
- Prof.dr.ing. Eden Mamut
- Prof.dr.ing. Ciprian Dobre
- Conf.dr.ing. Radu-Ioan Ciobanu



Universitatea POLITEHNICA din București  
Splaiul Independenței nr. 313, București  
+ 40-21-402 91 00

# Cuprins

<b>1. Introducere</b>	2
<b>2. Sinteza literaturii de specialitate privind modele de transmitere a virusilor în comunități</b>	2
<b>3. Definierea a 3 scenarii de transmitere a virusului prin contactul dintre subiecți și suprafețe sau obiecte</b>	3
3.1. Transmiterea virusului SARS-CoV-2 prin schimbul de obiecte tari infectate (scenariul 1)	3
3.2. Transmiterea virusului SARS-CoV-2 prin contact cu suprafețe tari infectate (scenariul 2)	4
3.3. Transmiterea virusului SARS-CoV-2 prin contact cu pâinea neambalată (scenariul 3)	4
<b>4. Prototiparea unui model de tip Machine Learning – Artificial Intelligence (ML-AI)</b>	5
<b>5. Simularea celor trei scenarii de transmitere a virusului</b>	7
5.1. Scenariul 1	7
5.2. Scenariul 2	8
5.3. Scenariul 3	10
<b>6. Analiza de senzitivitate</b>	11
6.1. Scenariul 1	11
6.2. Scenariul 2	12
6.3. Scenariul 3	13
<b>7. Definierea strategiei de validare a rezultatelor</b>	14
7.1. Scenariul 1	14
7.2. Scenariul 2	21
7.3. Scenariul 3	25
<b>8. Concluzii</b>	30
<b>Bibliografie</b>	31



## 1. Introducere

Pandemia de COVID-19 s-a răspândit și a devastat țări de peste tot din lume, și continuă să reprezinte o amenințare majoră la nivel global, pe măsură ce din ce în ce mai multe cazuri noi sunt identificate zilnic. Descoperită prima oară în orașul Wuhan din China în decembrie 2019, COVID-19 este o afecțiune respiratorie care poate provoca simptome severe și moarte.

La momentul prezent, încă nu se cunosc informații concrete și complete despre modul în care virusul care cauzează COVID-19, SARS-CoV-2, se transmite. O serie de studii s-au făcut în ultima perioadă [13,11], dar încă sunt foarte multe necunoscute.

Scopul acestui raport este de a realiza o analiză a modului în care virusul SARS-CoV-2 se transmite în diverse scenarii (cu aplicabilitate în realitate) prin intermediul obiectelor sau suprafețelor, cu accentul pus pe efectele transmiterii sale prin intermediul pâinii neambalate.

Restul acestui raport este structurat în felul următor. În secțiunea 2, se realizează o scurtă sinteză a literaturii de specialitate privind câteva modele de transmitere a virușilor (și în special SARS-CoV-2) în comunități. Mai departe, în secțiunea 3 se definesc trei scenarii de transmitere a virusului prin contactul dintre subiecți și suprafețe sau obiecte. În secțiunea 4, se prezintă un model pentru simularea interacțiunilor dintre utilizatori și a transmiterii virusului prin intermediul unor obiecte sau suprafețe. În secțiunea 5 se descrie modul în care cele trei scenarii prezentate în secțiunea 3 sunt implementate într-un simulator de interacțiuni. Mai departe, secțiunea 6 propune o analiză de sensibilitate a rezultatelor celor trei scenarii, iar în secțiunea 7 se analizează și validează rezultatele. În final, în secțiunea 8 se extrag concluziile analizei curente.

## 2. Sinteza literaturii de specialitate privind modele de transmitere a virușilor în comunități

Modelarea unor boli virale precum COVID-19 este foarte importantă pentru a determina impactul pe care îl pot avea pe viitor. Un prim mod de a realiza acest lucru este prin intermediul modelării tradiționale (stative), dar astfel de modele au anumite limitări. Pentru a adresa aceste limitări, metode de învățare automată și inteligență artificială (ML-AI) ar putea fi folosite, deoarece sunt capabile să găsească modele predictive de o calitate superioară.

Un exemplu de astfel de model a fost propus în [8], unde s-au analizat diferiți factori implicați în recuperarea în urma infectării cu MERS. S-au folosit elemente precum SVM-uri (support vector machines), arbori condiționali de inferență, metode Bayes naive sau modele J48.

Un alt exemplu de aplicare a algoritmilor de ML-AI în modelarea virusurilor sau a bolilor infecțioase este prezentat în [4], unde se propune o metodă de a compara proteinele din virusul SARS cu cele ale altor virusuri, pentru a prezice câte din aceste proteine sunt similare, folosind



modele SVM în combinație cu metoda BLAST din biotehnologie, pentru a prezice clasa funcțională a unei proteine.

O sinteză a modelelor de predicție utile în lupta împotriva COVID-19 este prezentată în [10], unde se împart metodele existente în patru categorii principale: Big Data, date din rețele sociale, modele matematice, și tehnici de învățare automată. În analiza realizată, sunt abordați o serie de parametri legați de virus, afecțiune și infectare, printre care se regăsesc numărul zilnic de decese, numărul de persoane infectate, perioada de incubație, parametrii ambientali (temperatură, umiditate, viteza vântului, etc.), facilități medicale existente, distanțarea socială, carantinarea, izolarea, rata de transmitere, mobilitatea, poziția geografică, vârsta, sexul, cele mai vulnerabile și puțin vulnerabile categorii, boli precedente, timpul de raportare, etc.

Metodele de interes deosebit analizate în [10] sunt cele de ML-AI, cum ar fi soluții care presupun utilizarea de ecuații logistice, Weibull sau Hill pentru a găsi ratele de infectare. Un alt exemplu analizat utilizează regresie logistică, arbori de gradient, sau chiar metode de învățare profundă. În [2], se propune o metodă de învățare profundă numită Deep Sequential Prediction Model (DSPM), precum și un model de regresie non-parametric (NRM) pentru a prezice infectarea COVID-19.

În [5], autorii propun antrenarea unei rețele neuronale artificiale (ANN) de tip multilayer perceptron (MLP), pe care o folosesc cu succes pentru a obține un model global al numărului maxim de pacienți din toate locațiile geografice, pe unitatea de timp.

În final, autorii din [7] propun un framework integrat cu componente ML-AI pentru a împiedica răspândirea COVID-19 în orașe inteligente. Autorii propun un nou model matematic pentru a reprezenta răspândirea virusului în orașe, apoi detaliază implementarea unei infrastructuri care generează, capturează, stochează și analizează datele folosind algoritmi inteligenți pentru a detecta și preveni răspândirea COVID-19, pentru a previziona următoarea pandemie, pentru a face tracing de contacte, pentru a monitoriza cazurile, etc.

### 3. Definirea a 3 scenarii de transmitere a virusului prin contactul dintre subiecți și suprafețe sau obiecte

Pentru analiza impactului transmiterii virusului SARS-CoV-2 în diferite circumstanțe, s-au definit trei scenarii care au fost analizate în acest raport, prezentate în continuare.

#### 3.1. Transmiterea virusului SARS-CoV-2 prin schimbul de obiecte tari infectate (scenariul 1)

Primul scenariu presupune o situație în care, pe o suprafață de formă rectangulară, există un număr de subiecți prezenți, care se mișcă și interacționează în interiorul acelei suprafețe. În



acest scenariu, ne interesează efectele transmiterii virusului SARS-CoV-2 prin intermediul unor obiecte potențial infectate.

Astfel, este posibil ca, atunci când doi subiecți se află în apropiere unul de celălalt, să schimbe între ei un obiect. Dacă subiectul care dă obiectul este infectat cu virusul SARS-CoV-2 și, înainte de a da obiectul mai departe, lasă particule de virus pe acesta (de exemplu, tușește), există o posibilitate ca subiectul care primește obiectul să ia mai departe virusul prin contactul cu aceste particule de pe obiectul schimbat.

În acest scenariu, este de interes modul în care interacțiunile umane și impactul a diverși parametri legați de transmiterea virusului SARS-CoV-2 (cum ar fi, de exemplu, probabilitatea ca, dacă o persoană este infectată, va lăsa particule de virus pe un obiect) conduc la potențiala infectare a mai multor persoane.

### 3.2. Transmiterea virusului SARS-CoV-2 prin contact cu suprafețe tari infectate (scenariul 2)

Al doilea scenariu se bazează pe analiza evoluției transmiterii de SARS-CoV-2 la contactul cu diferite suprafețe. În acest caz, persoane infectate cu virusul îl pot transmite pe acesta la contactul cu suprafețe de diferite tipuri (lemn, metal, plastic, etc.), iar alte persoane pot intra în contact cu aceste suprafețe și pot lua mai departe virusul punându-și mâna la gură, nas, ochi, etc.

Ca un exemplu real, putem analiza un spațiu geografic de tipul unei instituții precum filiala unei bănci, unde există un flux continuu de persoane în fiecare zi. Aceste persoane pot pune mâna pe suprafețe precum clanțele sau mânerele ușilor, ghișeele din bancă, scaunele din zona de așteptare, automatul de apă, etc. Ne interesează să putem analiza diferite astfel de scenarii, unde să se poată controla dimensiunea spațiului, numărul de persoane prezente în acest spațiu, sau numărul de suprafețe pe care participanții la interacțiune îl pot atinge.

### 3.3. Transmiterea virusului SARS-CoV-2 prin contact cu pâinea neambalată (scenariul 3)

Cel de-al treilea scenariu este și cel mai complex, pentru că presupune o serie mai bogată de interacțiuni care pot duce la infectare, atât pe termen scurt (în interiorul unei suprafețe de analiză), cât și pe termen mai lung (la ieșirea din suprafața de analiză).

Mai precis, în acest caz suntem interesați să analizăm modul în care virusul SARS-CoV-2 se poate transmite prin interacțiunea cu un produs alimentar de largă circulație. Ca produs, s-a ales pâinea neambalată care se desface în regim de autoservire într-un magazin alimentar de largă circulație, deoarece aceasta este **singurul produs care se comercializează neambalat și care nu poate fi spălat sau curățat precum legumele sau fructele**. Scenariul 3 presupune



că avem o zonă de analiză în principal rectangulară (dar nu numai, deoarece se poate extinde ușor scenariul și la alte tipuri de suprafețe de testare) în care există un flux continuu de persoane care pot fi interesate în a achiziționa pâine (de exemplu, un magazin mic „de colțul blocului” sau un hipermarket de dimensiuni mari). Într-un astfel de magazin, o persoană poate veni cu scopul de a cumpăra o pâine. Când face acest lucru, se duce la raionul de pâine, de unde alege pâinea sau pâinile pe care le va achiziționa. În acest proces de alegere, există posibilitatea ca un cumpărător fie să pună mâna pe o pâine și să o pună direct în coșul de cumpărături, fie să pună mâna pe mai multe pâini pentru a le testa prospețimea, consistența, etc. Mai mult, este posibil ca, atunci când cumpărătorul se află în zona pâinii, **acesta să tușească sau să vorbească cu glas ridicat**, lucru care poate duce la transmiterea de particule purtătoare de virus. În momentul contactului mâinii cumpărătorului cu o pâine, acesta poate fie **să transmită virusul de pe mână pe pâine** (în cazul în care cumpărătorul era infectat când a venit în magazin), ori **să fie el însuși infectat prin atingerea suprafeței pe care existau particule de virus** (adică pâinea). Într-o astfel de situație, ne interesează să analizăm impactul pe care existența unor persoane infectate printre cumpărătorii dintr-un magazin îl poate avea asupra cumpărătorilor neinfecțați, în funcție de diverși parametri precum dimensiunea magazinului, fluxul de persoane în magazin, rata de infectare, probabilitatea ca un cumpărător să pună mâna pe mai multe pâini, etc.

Trebuie menționat faptul că, pentru toate cele trei scenarii prezentate în această secțiune, ne-am concentrat exclusiv pe transmiterea virusului SARS-CoV-2 prin intermediul suprafețelor sau al obiectelor (obiecte de scris, mânere de ușă, teighea, pâine, etc.). **Nu s-au luat în considerare interacțiunile dintre oameni care nu păstrează distanțarea socială și care pot duce la transmiterea virusului pe cale aeriană.**

## 4. Prototiparea unui model de tip Machine Learning – Artificial Intelligence (ML-AI)

Pentru a putea analiza în mod cât mai realist scenariile prezentate în secțiunea 3, a fost necesară prototiparea unui model de tip ML-AI capabil să simuleze un astfel de scenariu și să controleze o serie de parametri care țin de comportamentul oamenilor în interiorul unor arii de simulare. **Modelarea matematică pentru scenariile prezentate anterior a fost necesară din cauza faptului că, pentru o astfel de situație, nu se pot folosi oameni adevărați ca subiecți.**

Complexitatea lucrului cu interacțiuni sociale este cauzată de două probleme dificile: formalizarea proprietăților de mobilitate și extragerea de modele de mobilitate. Deocamdată, sunt două tipuri de modele de mobilitate folosite: trace-uri de utilizatori mobili, și modele sintetice. Trace-urile sunt rezultate în urma unor experimente care înregistrează caracteristicile de mobilitate (ca locația, tendințele, etc.) ale utilizatorilor, în timp ce modelele sintetice sunt modele pur matematice care exprimă mișcarea nodurilor. Pentru a testa un scenariu precum



cele din secțiunea 3, este necesar un model care poate simula un trace real sau un model sintetic, și care apoi poate aplica o logică de interacțiune cu o serie de parametri configurabili. În scopul acestei analize, am ales să utilizăm simulatorul MobEmu [1,6] și modelul de mobilitate HCMM [3].

Avantajul principal al modelelor sintetice este că permit modificarea multor parametri, spre deosebire de trace-uri. Totuși, modelele aleatoare nu se potrivesc neapărat cu realitatea, pentru că s-a demonstrat că distribuțiile timpilor de contact din trace-urile reale sunt distribuții grele. Acest lucru se întâmplă pentru că oamenii nu se deplasează aleator, comportamentul lor fiind orientat pe activități. De aceea, considerăm că modelele aleatoare nu ar trebui folosite pentru testarea interacțiunilor umane. În schimb, modele sociale, care se bazează pe comunități umane și pe comportament real, ar trebui utilizate, eventual în combinație cu trace-urile reale. Din acest motiv, simulatorul MobEmu utilizat pentru analiza celor trei scenarii oferă posibilitatea testării folosind modele sintetice sociale.

Ținând cont că modele de interacțiune umană pot fi compuse din sute (sau chiar mii) de participanți, testarea de scenarii precum cele prezentate în secțiunea 3 se poate dovedi complicată. Mai mult, dacă modelele de interacțiune propuse nu funcționează cum trebuie din prima, reîncercarea unei versiuni noi ar putea fi necesară, lucru care s-ar putea dovedi scump, atât din punct de vedere financiar, cât și al timpului și efortului organizațional. Din acest motiv se folosesc simulatoarele, care sunt capabile să ruleze modele sintetice de mobilitate. MobEmu este un astfel de simulator, care poate rula un scenariu controlat de un utilizator pe un model de mobilitate dorit. Este scris în Java, așa că este modular și ușor de înțeles și modificat, motiv pentru care l-am ales în implementarea celor trei scenarii prezentate în capitolul 3.

Funcționalitatea MobEmu este simplă: rulează un model de interacțiune socială și, la fiecare pas (dat de unitatea de timp a modelului) verifică dacă un contact între două noduri (adică între două persoane, sau între o persoană și un obiect static precum o pâine, conform scenariilor descrise în capitolul 3) are loc. Dacă este cazul, atunci logica de interacțiune dorită este aplicată pentru fiecare nod, raportat la nodul întâlnit. Mai mult, diverse statistici sunt colectate. Pe lângă verificarea contactelor, MobEmu mai verifică la fiecare pas și dacă nodurile trebuie să realizeze altfel de acțiuni (să iasă din magazin, să se îndrepte spre raionul de pâine, să schimbe un obiect cu altcineva, etc.). La fiecare pas, MobEmu calculează și comunitatea unui participant folosind algoritmul k-CLIQUE [14].

Așa cum s-a menționat mai sus, modelul de mobilitate utilizat în implementarea și analiza celor trei scenarii în simulatorul MobEmu este Home-Cell Mobility Model (HCMM) [3], bazat pe CMM [9]. HCMM se bazează pe supoziția că modul în care oamenii interacționează nu se bazează doar pe relațiile sociale dintre ei, ci și pe atracția unei locații fizice. Astfel, fiecare comunitate umană are o celulă fizică (un spațiu geografic) de care aparține. HCMM se bazează pe modelul „caveman” [12] și presupune că fiecare persoană este atrasă de celula de care aparține pe baza unei atracții sociale exercitată de acea persoană asupra tuturor celorlalte persoane care fac parte din comunitatea sa. Conform acestui model, atracția unei celule externe (adică diferită



de cea de care aparține persoana) este calculată pe baza relațiilor persoanei respective cu celelalte persoane care aparțin de acea celulă. Când o persoană ajunge într-o celulă de care nu aparține comunitatea sa, va sta acolo cu o probabilitate  $p_e$  și se va întoarce în celula sa cu probabilitatea  $1-p_e$ . În HCMM, o persoană pornește cu o comunitate prestabilită, având legături puternice cu celelalte persoane din acea comunitate (de exemplu, grupul de prieteni, familia, colegii, etc.). Totuși, pe baza unei probabilități de regrupare  $p_r$ , legăturile sociale ale unei persoane pot fi reconectate cu persoane din alte comunități. Mai mult, decizia unei persoane de a părăsi celula în care se află este dată de o probabilitate de rămânere  $p_{rem}$ .

Așadar, folosind simulatorul MobEmu și modelul HCMM, putem simula cele trei scenarii propuse în secțiunea 3 într-un mod apropiat de realitate, care ne poate pune la dispoziție niște rezultate care aproximează bine lumea reală.

## 5. Simularea celor trei scenarii de transmitere a virusului

În această secțiune, vom prezenta modul în care cele trei scenarii de transmitere a virusului descrise în secțiunea 3 au fost implementate folosind modelul prezentat în secțiunea 4.

### 5.1. Scenariul 1

Primul scenariu analizat se referă la o situație în care virusul SARS-CoV-2 se poate transmite printr-un schimb de obiecte între două persoane, dacă una din persoane era infectată și a lăsat particule de SARS-CoV-2 pe obiectul schimbat. În cadrul MobEmu folosind HCMM pentru simularea interacțiunilor dintre noduri, putem să controlăm următorii parametri de intrare în analiza pe care o realizăm:

- durata simulării (în ore)
- lățimea și lungimea spațiului de simulare (în metri)
- numărul de participanți în cadrul scenariului (densitatea de persoane pe suprafață)
- numărul de comunități sociale în care sunt grupați participanții
- rata  $R_e$  cu care participanții din acest scenariu schimbă un obiect între ei; acest parametru reprezintă practic probabilitatea ca, atunci când doi participanți sunt în contact (se află la o distanță suficient de mică unul de celălalt cât să poată interacționa), vor schimba un obiect potențial infectat
- probabilitatea ca un participant să fie infectat  $R_i$ , care reprezintă rata de infectare în zona respectivă, adică procentul de participanți la simulare care pornesc rulare deja infectați





- rata de transmitere a virusului SARS-CoV-2 pe un obiect  $R_t$ , parametru care se referă la probabilitatea ca, atunci când un participant este infectat și urmează să dea un obiect către alt participant, va transmite particule infectate pe acel obiect.

În acest scenariu, participanții vor fi ficși, adică presupunem că aceștia nu pot ieși din spațiul de simulare pe durata colectării datelor. De asemenea, noi participanți nu pot intra în spațiul analizat. La începutul rulării experimentelor, se va stabili numărul de participanți care încep simularea fiind infectați pe baza ratei de infectare  $R_t$ .

La fiecare moment de timp al simulării, dacă o persoană este infectată cu SARS-CoV-2 (adică dacă avea virusul de dinainte de începerea experimentului), se stabilește dacă îl transmite sau nu pe un obiect (pe care apoi îl poate da altei persoane) cu probabilitatea  $R_t$ . Este important de menționat aici faptul că, pe baza informațiilor existente în literatura de specialitate [13], virusul SARS-CoV-2 aflat pe o suprafață va fi infecțios doar pentru o anumită perioadă de timp. Acest lucru înseamnă că, deși la un moment dat de timp virusul a existat pe un obiect, e posibil ca, în momentul în care obiectul este transmis către altă persoană, acesta să nu mai poată infecta acea persoană. Experimentele realizate aici țin cont de această situație, folosind rezultate prealabile pentru stabilirea duratei de viață a virusului pe diverse suprafețe [11].

În cadrul acestui scenariu, următorii pași au loc atunci când doi participanți intră în contact:

1. se schimbă un obiect cu probabilitatea  $R_o$
2. dacă obiectul era infectat (virusul era încă activ pe el) și persoana care primește obiectul nu era infectată, se consideră că această persoană va putea lua virusul prin interacțiunea cu obiectul respectiv.

La finalul unui astfel de experiment, ne interesează să extragem următoarele metrici:

- numărul de obiecte care au fost schimbate
- numărul de obiecte infectate (cu virusul activ pe ele) care au fost schimbate
- numărul de utilizatori care au fost infectați în urma interacțiunilor cu obiectele primite de la alte persoane.

Pe baza acestei descrieri, prezentăm rezultatele obținute în secțiunea 7.1.

## 5.2. Scenariul 2

Al doilea scenariu care a fost analizat se referă la o situație în care virusul SARS-CoV-2 se poate transmite prin intermediul unor suprafețe tari infectate, de exemplu în cadrul unei instituții publice care lucrează cu publicul, ghișee pentru operațiuni administrative, oficii de bănci, etc. În acest caz, infecția se poate produce pe loc, prin faptul că o persoană infectată a pus mâna pe



una sau mai multe astfel de suprafețe și le-a infectat, iar o persoană neinfectată a atins una din acele suprafețe infectate și a luat virusul.

Pentru acest scenariu, putem să controlăm următorii parametri de intrare în MobEmu:

- durata simulării (în ore)
- lățimea și lungimea spațiului de simulare (în metri)
- numărul de participanți în cadrul scenariului (densitatea de persoane pe suprafață)
- rata  $R_a$  cu care participanții din acest scenariu ating suprafețele din zona simulată
- probabilitatea ca un participant să fie infectat  $R_i$ , care reprezintă rata de infectare în zona respectivă, adică procentul de participanți la simulare care pornesc simularea deja infectați
- rata de transmitere a virusului SARS-CoV-2 pe o suprafață  $R_t$ , parametru care se referă la probabilitatea ca, atunci când un participant este infectat și atinge o suprafață, va transmite particule infectate pe aceasta.

În acest scenariu, participanții la simulare au un flux continuu pe durata experimentelor. Mai precis, ei intră în spațiul public (bancă, etc.), petrec timp acolo (calculat în funcție de dimensiunea spațiului), după care ies din zona de simulare. La fiecare nou participant la simulare, se stabilește dacă este infectat în prealabil sau nu pe baza ratei de infectare  $R_i$ .

La fiecare moment de timp al simulării pentru acest scenariu, se fac următorii pași pentru fiecare participant:

1. participantul va putea atinge o suprafață pe baza probabilității  $R_a$
2. când se atinge o suprafață, se pot întâmpla două lucruri:
  - a. dacă participantul este infectat cu virusul SARS-CoV-2, va putea transmite virusul pe suprafața pe care o atinge cu probabilitatea  $R_t$
  - b. dacă participantul nu este infectat, dar atinge o suprafață infectată, se poate infecta (probabilitatea de infectare este dată de momentul când suprafața a fost infectată, știindu-se faptul că virusul rămâne o perioadă pe un obiect tare, dar riscul de infectare este din ce în ce mai mic în timp [13]).

La finalul unui astfel de experiment, ne interesează să aflăm numărul de utilizatori care au fost infectați în urma interacțiunilor cu suprafețele atinse de alte persoane infectate.

Pe baza acestei descrieri, prezentăm rezultatele obținute în secțiunea 7.2.



### 5.3. Scenariul 3

Cel de-al treilea scenariu analizat se referă la o situație în care virusul SARS-CoV-2 se poate transmite prin intermediul unui produs alimentar infectat, și ne-am îndreptat către un produs alimentar foarte popular: o pâine neambalată vândută într-un magazin. Prin extensie către alte produse alimentare pe bază de pâine (sandwich-uri, hamburgeri șamd) impactul în societate este imens. În acest caz, infecția se poate produce pe loc (o persoană infectată a pus mâna pe una sau mai multe pâini și le-a infectat, iar o persoană neinfectată a atins una din acele pâini și a luat virusul) sau pe termen mai lung (o persoană neinfectată a luat o pâine infectată acasă și a mâncat-o împreună cu familia).

În cadrul MobEmu, putem să controlăm următorii parametri de intrare pentru acest scenariu:

- durata simulării (în ore)
- lățimea și lungimea spațiului de simulare (în metri)
- numărul de participanți în cadrul scenariului (densitatea de persoane pe suprafață)
- numărul de suprafețe tari pe care un participant le poate atinge
- rata  $R_b$  cu care participanții din acest scenariu (cumpărătorii de pâine din magazin, conform descrierii din secțiunea 3) se duc la raionul de pâine
- rata  $R_c$  cu care participanții din acest scenariu cumpără pâine, odată ajunși la raion
- probabilitatea ca un participant să fie infectat  $R_i$ , care reprezintă rata de infectare în zona respectivă, adică procentul de participanți la simulare care pornesc simularea deja infectați
- rata de transmitere a virusului SARS-CoV-2 pe o pâine  $R_t$ , parametru care se referă la probabilitatea ca, atunci când un participant este infectat și atinge o pâine, va transmite particule infectate pe aceasta.

În acest scenariu, participanții la simulare au un flux continuu pe durata experimentelor. Mai precis, ei intră în magazin, petrec niște timp acolo (calculat în funcție de dimensiunea magazinului), după care ies din magazin. La fiecare nou cumpărător care intră în magazin, se stabilește dacă este infectat în prealabil sau nu pe baza ratei de infectare  $R_i$ .

La fiecare moment de timp al simulării pentru acest scenariu, se fac următorii pași pentru fiecare participant:

1. participantul decide dacă se va duce la raionul de pâine pe baza probabilității  $R_b$
2. odată ajuns acolo, un participant poate face una din două acțiuni:



- a. va lua o pâine direct, fără să atingă alte pâini, cu probabilitatea  $R_c$
  - b. va atinge 2-4 pâini (cu o distribuție uniformă) înainte să aleagă o pâine pe care o va cumpăra
3. în cazul în care se merge pe varianta 2b, se pot întâmpla două lucruri:
- a. dacă participantul este infectat cu virusul SARS-CoV-2, va putea transmite virusul pe fiecare pâine pe care le atinge cu probabilitatea  $R_t$
  - b. dacă participantul nu este infectat, dar atinge o pâine infectată, se poate infecta (probabilitatea de infectare este dată de momentul când pâinea a fost infectată, știindu-se faptul că virusul rămâne o perioadă pe un obiect moale, dar riscul de infectare este din ce în ce mai mic în timp [13]).

La fiecare moment de timp al simulării, se verifică dacă numărul de pâini expuse a scăzut sub o limită prestabilită, moment în care se reintroduc pâini noi (se aduc din depozit în magazin). Este foarte important de menționat aici faptul că, în implementarea curentă, **nu se ține cont de contaminarea din procesul de aprovizionare**. Un astfel de caz (în care, de exemplu, este posibil ca transportatorii de pâine infectați să transmită virusul pe paleți întregi de pâine) va fi tratat în iterații viitoare ale experimentelor.

La finalul unui astfel de experiment, ne interesează să extragem următoarele metrici:

- numărul de utilizatori care au fost infectați în urma interacțiunilor cu obiectele primite de la alte persoane
- numărul total de pâini infectate scoase din magazin (cu care cumpărătorii au plecat acasă).

Pe baza acestei descrieri, prezentăm rezultatele obținute în secțiunea 7.3.

## 6. Analiza de sensibilitate

### 6.1. Scenariul 1

În analiza rezultatelor obținute în urma acestui scenariu, am utilizat următorii parametri ficși:

- participanți - 20
- comunități sociale - 4
- durata de simulare - 6 ore
- raza de contact - 0.5 m (doi participanți pot schimba un obiect dacă se află la maxim jumătate de metru unul de celălalt)
- viteza de deplasare a unui participant - între 0 și 0.5 m/s



- durata maximă de infecțiozitate a virusului pe un obiect schimbat - 3 ore (conform [13]).

Pe lângă parametrii ficși prezentați mai sus, am creat două scenarii diferite, pentru a putea observa diferite situații posibile. Cele două scenarii diferă din punct de vedere al dimensiunii spațiului de simulare, astfel:

- scenariul 1.1 - spațiu de 200x200 m
- scenariul 1.2 - spațiu de 40x40 m.

Comportamentul pentru fiecare din cele două scenarii este definit de către trei parametri importanți, așa cum s-a prezentat în secțiunea 5.1:

- rata de transmitere a virusului SARS-CoV-2 pe un obiect  $R_t$
- probabilitatea ca un participant să fie infectat  $R_i$
- rata de schimb a unui obiect  $R_o$ .

Pentru fiecare din cele două scenarii, s-a variat câte unul din acești parametri, ținându-i pe ceilalți doi ficși, pentru a vedea impactul fiecărui parametru asupra rezultatelor.

## 6.2. Scenariul 2

În analiza rezultatelor obținute în urma acestui scenariu, am utilizat următorii parametri ficși:

- durata de simulare - 10 ore
- fluxul de cumpărători pe oră - 100
- durata maximă de infecțiozitate a virusului pe o pâine - 3 ore (conform [13]).

Pe lângă parametrii ficși prezentați mai sus, am creat trei scenarii diferite, prin care am încercat simularea a trei categorii de zone. Cele trei scenarii diferă din punct de vedere al dimensiunii spațiului de simulare (tradus prin numărul de oameni care se află în medie simultan în suprafața analizată, numărul de suprafețe, și rata  $R_a$  cu care se ating suprafețele), astfel:

- spațiu mic - 15 oameni, 5 suprafețe,  $R_a=0.03$
- spațiu mediu - 30 de oameni, 10 suprafețe,  $R_a=0.02$
- spațiu mare - 70 oameni, 15 suprafețe,  $R_a=0.0$ .

Comportamentul pentru fiecare din cele trei scenarii este definit de către doi parametri importanți, așa cum s-a prezentat în secțiunea 5.2:

- rata de transmitere a virusului SARS-CoV-2 pe un obiect  $R_t$



- probabilitatea ca un participant sa fie infectat  $R_i$ .

Pentru fiecare din cele trei scenarii, s-a variat câte unul din acești parametri, ținându-l pe celălalt fix, pentru a vedea impactul fiecărui parametru asupra rezultatelor. Atunci când se variază rata de transmitere, probabilitatea de infectare are valoarea 0.003. Când variem probabilitatea de infectare, rata de transmitere este 0.01.

### 6.3. Scenariul 3

În analiza rezultatelor obținute în urma acestui scenariu, am utilizat următorii parametri ficși:

- durata de simulare - 10 ore
- fluxul de participanți pe oră - 100
- durata maximă de infecțiozitate a virusului pe o suprafață tare - 3 ore (conform [13]).

Pe lângă parametrii ficși prezentați mai sus, am creat trei scenarii diferite, prin care am încercat simularea a trei tipuri de magazine care vând pâine. Cele trei scenarii diferă din punct de vedere al dimensiunii spațiului de simulare (tradus prin numărul de cumpărători care se află în medie simultan în magazin, rata  $R_b$  cu care se duc la raionul de pâine, și rata  $R_c$  cu care cumpără pâine odată ajunși la raion), astfel:

- scenariul „magazin de la colț” - 15 cumpărători,  $R_b=0.1$ ,  $R_c=0.75$
- scenariul „supermarket” - 30 de cumpărători,  $R_b=0.075$ ,  $R_c=0.5$
- scenariul „hipermarket” - 70 de cumpărători,  $R_b=0.05$ ,  $R_c=0.25$ .

S-a considerat că numărul de pâini disponibile la raion este egal cu numărul mediu de clienți în magazin pe oră. Comportamentul pentru fiecare din cele trei scenarii este definit de către doi parametri importanți, așa cum s-a prezentat în secțiunea 5.3:

- rata de transmitere a virusului SARS-CoV-2 pe un obiect  $R_t$
- probabilitatea ca un participant sa fie infectat  $R_i$ .

Pentru fiecare din cele trei scenarii, s-a variat câte unul din acești parametri, ținându-l pe celălalt fix, pentru a vedea impactul fiecărui parametru asupra rezultatelor. Atunci când se variază rata de transmitere, probabilitatea de infectare are valoarea 0.003. Când variem probabilitatea de infectare, rata de transmitere este 0.1.

*Sucala*



## 7. Definirea strategiei de validare a rezultatelor

În vederea definirii strategiei de validare, în prima etapă au fost analizate rezultatele simulărilor și relevanța acestora. Astfel, rezultatele obținute sunt sintetizate în cele ce urmează.

### 7.1. Scenariul 1

Figurile de mai jos arată rezultatele obținute pentru scenariul 1.

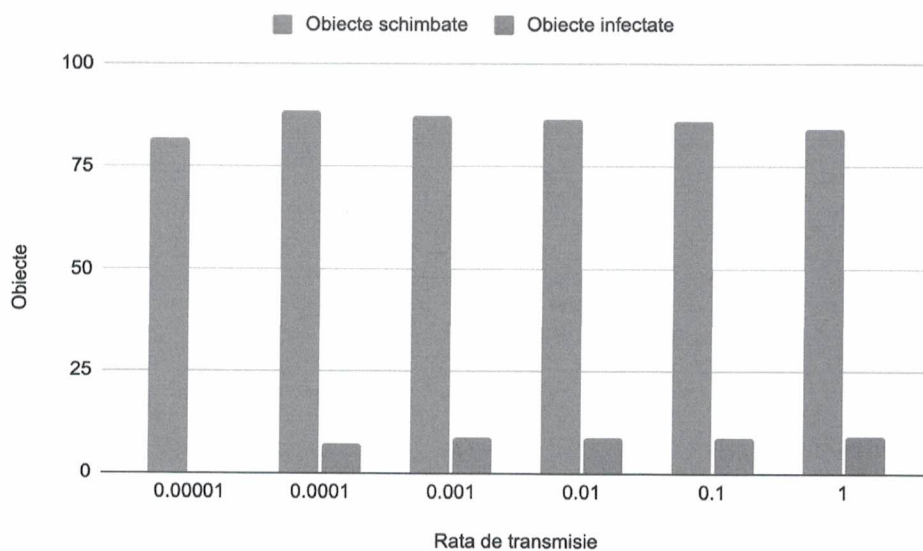


Figura 7.1. Obiecte schimbate și obiecte infectate pentru scenariul 1.1 atunci când se variază rata de transmitere.

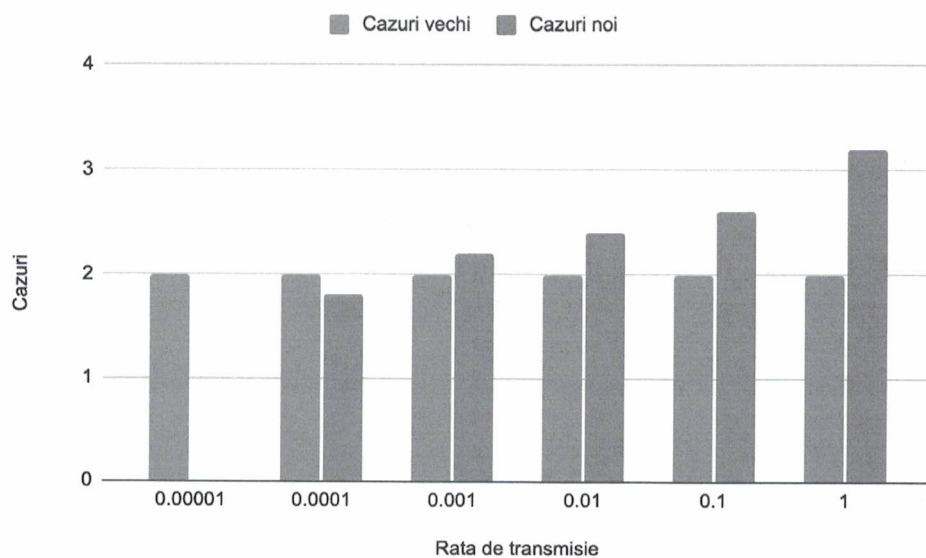


Figura 7.2. Cazuri vechi și cazuri noi pentru scenariul 1.1 atunci când se variază rata de transmitere.

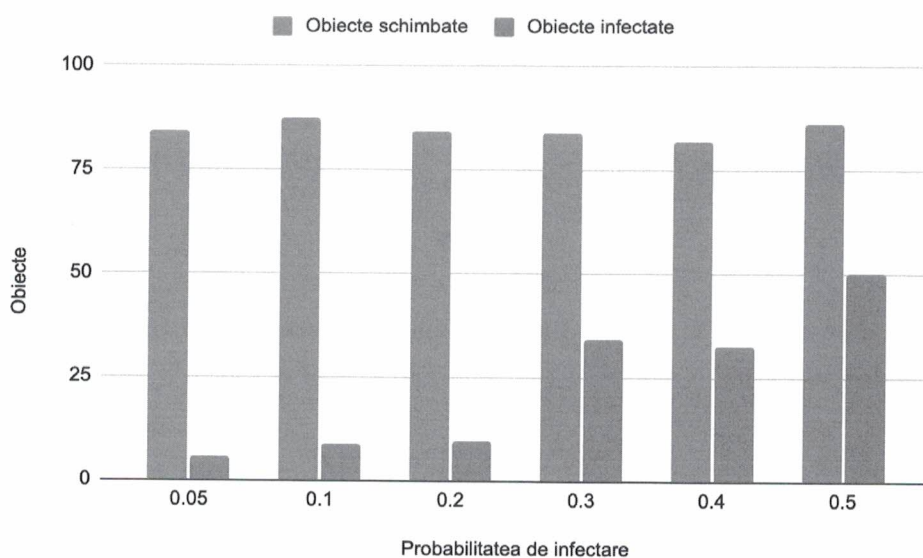


Figura 7.3. Obiecte schimbate și obiecte infectate pentru scenariul 1.1 atunci când se variază probabilitatea de infectare.

Sacala






Figura 7.4. Cazuri vechi și cazuri noi pentru scenariul 1.1 atunci când se variază probabilitatea de infectare.




Figura 7.5. Obiecte schimbate și obiecte infectate pentru scenariul 1.1 atunci când se variază rata de schimb.

Sacala

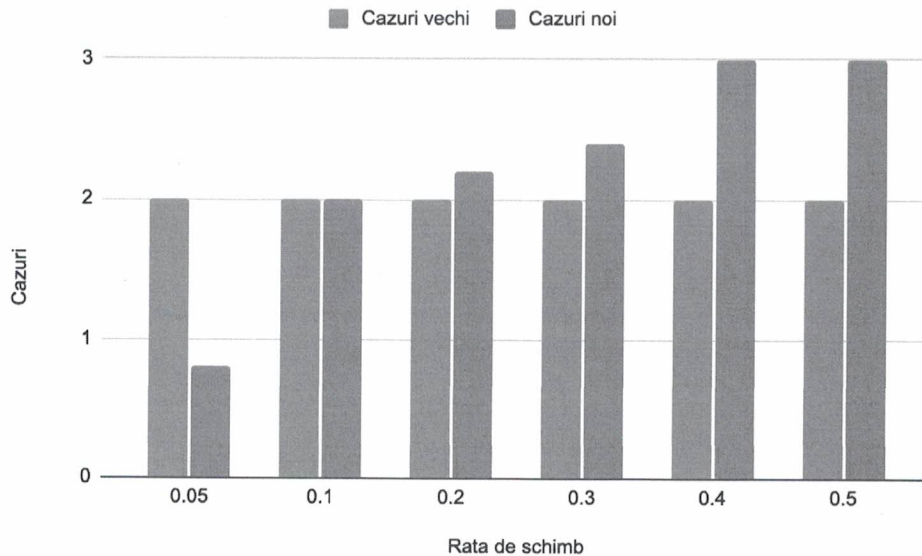


Figura 7.6. Cazuri vechi și cazuri noi pentru scenariul 1.1 atunci când se variază rata de schimb.

Figurile 7.1-7.6 prezintă rezultatele obținute pentru scenariul 1.1. În figurile 7.1 și 7.2, se variază rata de transmitere în timp ce sunt ținute fixe valorile pentru rata de schimb (0.2, adică există o probabilitate de 20% ca, la un contact, doi participanți să schimbe un obiect) și probabilitatea de infectare (0.1, adică 10% din participanți sunt infectați). În această situație, se poate observa că, deși ajungem cu o rată de transmitere de până la 1 (adică un participant infectat va transmite sigur virusul pe obiectul schimbat), se ajunge la maxim 10 obiecte infectate în cele 6 ore de simulare și un număr de aproximativ 3 cazuri noi de COVID-19, în condițiile în care existau 2 cazuri la începutul simulării. Pe cazul mai realist când avem o rată de transmitere de 1% (participantul va lăsa, în medie, particule pe obiect o dată la 100 de secunde), valorile obținute sunt chiar mai mici.

În figurile 7.3 și 7.4, s-au păstrat fixe rata de schimb (0.2) și rata de transmitere (0.001) și s-a variat probabilitatea de infectare, adică numărul inițial de cazuri de COVID-19 dintre participanți. Impactul este cel așteptat, adică, dacă aveam un caz de COVID-19 inițial, mai rezultă aproximativ încă unul, dacă aveam două mai rezultă aproximativ încă două, iar dacă aveam 6, mai rezultă încă 4. Se poate totuși observa că, de la un punct încolo, creșterea numărului de cazuri inițiale nu va mai duce la o creștere a cazurilor noi, dar acest lucru se datorează faptului că există un număr fix de participanți la simulare.

În final, figurile 7.5 și 7.6 prezintă comportamentul scenariului 1.1 atunci când variem rata de schimb și ținem fixe probabilitatea de infectare (0.1) și rata de transmitere (0.001). Se poate observa că ajungem la maxim 3 cazuri noi, atunci când se schimbă obiecte cu o probabilitate de 50% (un caz foarte puțin probabil în realitate).




Figura 7.7. Obiecte schimbate și obiecte infectate pentru scenariul 1.2 atunci când se variază rata de transmitere.




Figura 7.8. Cazuri vechi și cazuri noi pentru scenariul 1.2 atunci când se variază rata de transmitere.

*Sucala*




Figura 7.9. Obiecte schimbate și obiecte infectate pentru scenariul 1.2 atunci când se variază probabilitatea de infectare.

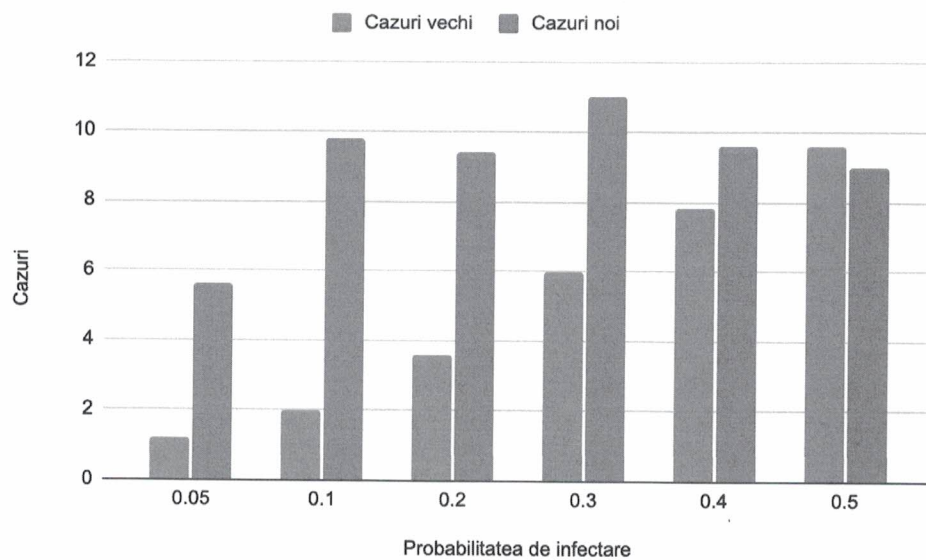


Figura 7.10. Cazuri vechi și cazuri noi pentru scenariul 1.2 atunci când se variază probabilitatea de infectare.

Sucala

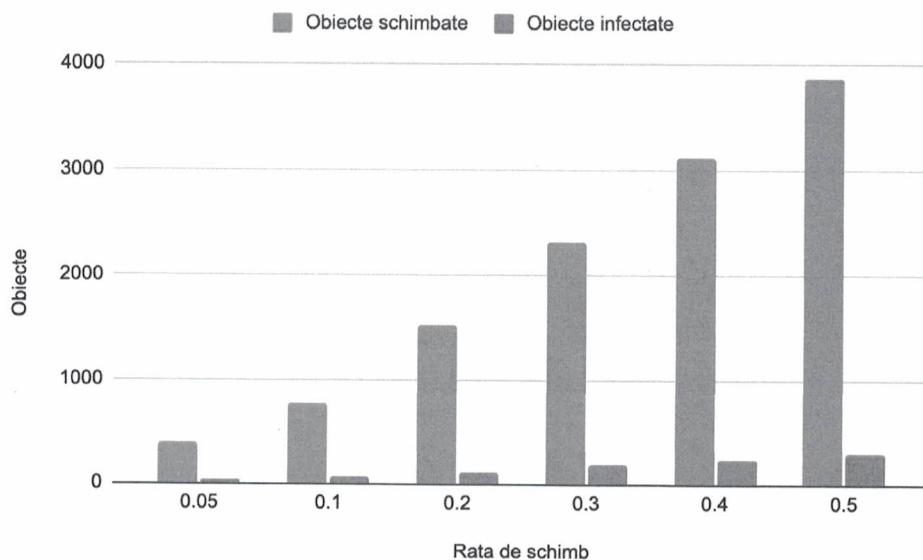


Figura 7.11. Obiecte schimbate și obiecte infectate pentru scenariul 1.2 atunci când se variază rata de schimb.




Figura 7.12. Cazuri vechi și cazuri noi pentru scenariul 1.2 atunci când se variază rata de schimb.

Figurile 7.7-7.12 prezintă rezultatele pentru scenariul 1.2, unde spațiul de simulare este considerabil mai mic pentru același număr de utilizatori. Într-o astfel de situație, vor fi mult mai



multe interacțiuni între participanți, și deci implicit mai multe schimburi de obiecte. Din acest motiv, rezultatele sunt cele așteptate, și anume faptul că numărul de cazuri noi va fi mai mare, ajungând în unele situații până la 10 (maximul pentru scenariul 1.1 fiind 4).

Așadar, concluziile scenariului 1 sunt următoarele:

- cel mai mare impact asupra numărului nou de cazuri îl are probabilitatea de infectare
- restrângerea spațiului de interacțiune duce la un număr mai mare de contacte, care poate crește considerabil numărul de infectări noi.

## 7.2. Scenariul 2

Figurile de mai jos arată rezultatele obținute pentru scenariul 2.




Figura 7.13. Cazuri vechi și cazuri noi pentru scenariul cu spațiul mic atunci când se variază rata de transmitere.




Figura 7.14. Cazuri vechi și cazuri noi pentru scenariul cu spațiul mic atunci când se variază rata de infectare.

Figurile 7.13 și 7.14 prezintă scenariul cu spațiul de dimensiuni reduse, unde pot intra maxim 15 noduri și există 5 suprafețe care pot fi atinse și infectate. În acest caz, se poate observa în figura 7.13 că, la o rată de transmitere realistă (până în 0.01), numărul de cazuri noi apărute prin urmare a atingerilor suprafețelor este de maxim 3. Dacă avem o rată de transmitere de 0.5 (adică o persoană infectată are o șansă de 50% să infecteze o suprafață în fiecare secundă), numărul de cazuri crește exponențial (în mod natural). Figura 7.14 exprimă niște concluzii similare, și anume că, dacă rata de infectare este în valori normale (până la 0.01, adică 10 la mie), numărul de cazuri noi este de maxim 16.

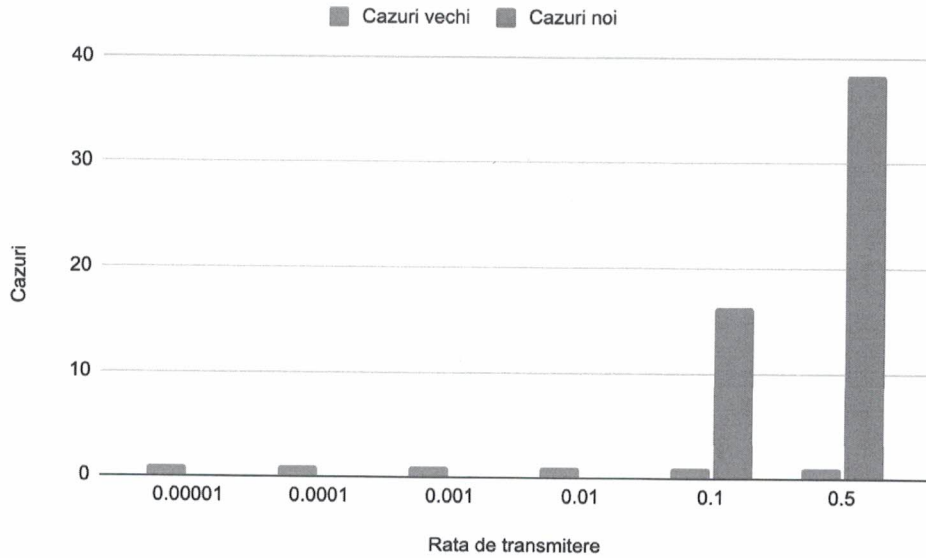


Figura 7.15. Cazuri vechi și cazuri noi pentru scenariul cu spațiul mediu atunci când se variază rata de transmitere.




Figura 7.16. Cazuri vechi și cazuri noi pentru scenariul cu spațiul mediu atunci când se variază rata de infectare.

Figurile 7.15 și 7.16 prezintă cazul cu spațiul de interacțiune de dimensiune medie, unde, pentru o rată de transmitere în limite normale, numărul de cazuri noi de COVID-19 tinde spre 0. Pentru





o rată de infectare până la 0.01 (10 la mie), numărul de cazuri noi este de maxim 9, la un număr total de 1000 de vizitatori ai spațiului public.




Figura 7.17. Cazuri vechi și cazuri noi pentru scenariul cu spațiul mare atunci când se variază rata de transmitere.

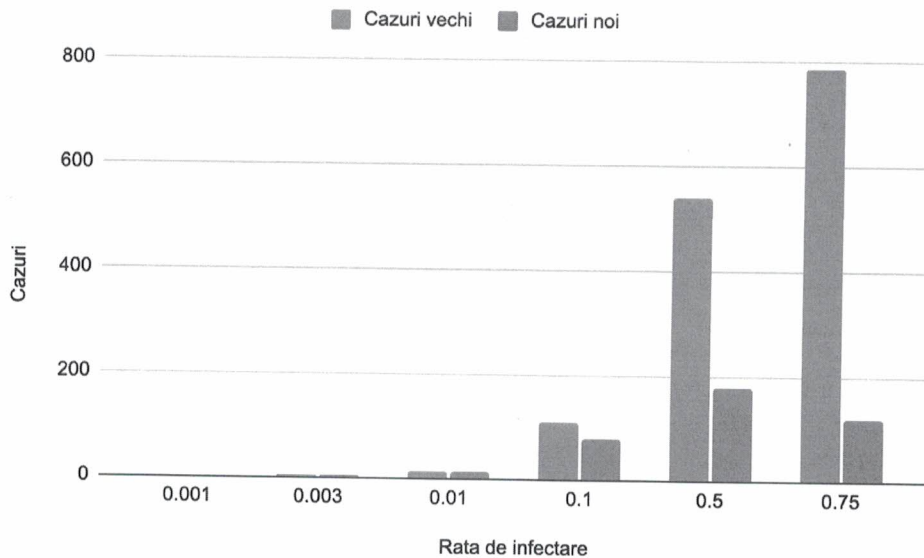


Figura 7.18. Cazuri vechi și cazuri noi pentru scenariul cu spațiul mare atunci când se variază rata de infectare.



În final, pe cazul cu spațiul de dimensiuni mari, apar maxim 6 cazuri noi la 1000 de persoane pentru o rată de transmitere de 0.01, și maxim 15 cazuri noi (tot la 1000 de persoane) pentru o rată de infectare de 10 la mie. Valorile sunt mai mari decât cele de la spațiul mediu și cel mic, pentru că există mai mulți participanți simultan în spațiul analizat, dar și mai multe suprafețe care pot transmite virusul.

### 7.3. Scenariul 3

Figurile de mai jos arată rezultatele obținute pentru scenariul 3.




Figura 7.19. Cazuri vechi și cazuri noi pentru scenariul „magazin de la colț” atunci când se variază rata de transmitere.

Sacala




Figura 7.20. Cazuri vechi și cazuri noi pentru scenariul „magazin de la colț” atunci când se variază probabilitate de infectare.

Figurile 7.19 și 7.20 prezintă rezultatele obținute pentru scenariul „magazinul de la colț”, unde avem un număr redus de cumpărători care se pot afla la un moment dat în magazin, dar valori mai mari pentru rata cu care aceștia se duc la raionul de pâine și pentru rata cu care cumpără. În figura 7.19, se poate observa că, atunci când rata de transmitere are valori scăzute (până la 1%), numărul de cazuri noi după 10 ore de simulare este foarte aproape de 0. Atunci când rata de transmitere crește (deci când se mărește șansa ca un cumpărător infectat să contamineze pâinea), va crește în mod natural și numărul de cazuri. Totuși, se poate observa că, și atunci când avem o rată de transmitere de 50% (care este considerabil mai mare decât ce ar putea fi în realitate), numărul mediu de cazuri noi abia se apropie de valoarea de 1. Ar mai fi util de menționat că, pentru configurația din figura 7.19, **numărul mediu de pâini infectate este mai mic decât 1**. Dacă presupunem că dimensiunea medie a unei familii din România este de 2.7 persoane (conform unui studiu făcut de ONU în 2017 [13]), atunci putem să avem **cel mult două persoane noi infectate ca urmare a mâncatului pâinii infectate**. Pentru acest calcul, ne bazăm pe faptul că 80% din persoanele care cumpără o pâine o mănâncă în cel mult 3 ore, cât timp virusul încă este infecțios. Dacă pâinea este mâncată după o perioadă mai lungă de timp, atunci riscul de infecție va scădea și mai mult.

Figura 7.20 ne arată faptul că, dacă rata de infectare crește semnificativ (deci dacă numărul de cazuri pe mia de locuitori crește), numărul de cazuri noi rezultate din transmiterea prin intermediul pâinii este totuși scăzut. Chiar și atunci când avem aproape 350 de cumpărători infectați în prealabil (din cei aproximativ 1000 care intră în magazin în timpul simulării de 10 ore), vom avea maxim 7 cazuri noi de infectări din cauza contactului cu pâinea în magazin. Un



efect mai pronunțat se observă la numărul de pâini infectate care ies din magazin (22 pentru o probabilitate de infectare de 50% și 31 pentru o probabilitate de infectare de 75%, rezultând în 48 și respectiv 60 de cazuri noi prin împărțirea pâinii cu familia), dar acest lucru se observă doar pentru valori foarte mari (și greu de atins în realitate) ale ratei de infectare. Pentru o rată de infectare similară cu cea prezentă în România în noiembrie 2020, se poate observa că rezultă maxim un caz nou de COVID-19 luat din incinta magazinului, respectiv maxim 2 cazuri rezultate prin mănncarea pâinii infectate.




Figura 7.21. Cazuri vechi și cazuri noi pentru scenariul „supermarket” atunci când se variază rata de transmitere.




Figura 7.22. Cazuri vechi și cazuri noi pentru scenariul „supermarket” atunci când se variază probabilitatea de infectare.

Figurile 7.21 și 7.22 prezintă rezultatele obținute pentru scenariul „supermarket”, unde putem avea 30 de cumpărători simultan în magazin. Conform figurii 7.21, comportamentul pentru un supermarket este similar primului scenariu: doar pentru valori mari ale ratei de transmitere (10% și respectiv 50%) se pot observa mai multe cazuri noi de infectare cu SARS-CoV-2 din magazin. În același timp, din aproximativ 1000 de pâini cumpărate din magazin, numărul maxim de pâini infectate este de 4 (ducând la alte 10 persoane infectate în urma mâncatului pâinii), atunci când rata de transmisie are o valoare extremă de 50%. Acest lucru înseamnă că, în mod normal, numărul de pâini infectate va fi foarte aproape de 0 pentru majoritatea cazurilor.

Figura 7.22 arată un comportament similar cu cel din figura 7.20, observându-se faptul că, pentru valori plauzibile ale ratei de infecție (între 3 și 10 la mie), numărul de cazuri noi rezultate din interacțiunea cu pâinea potențial infectată ajunge la maxim 8. În același timp, numărul maxim de pâini infectate pentru o rată de infecție de 0.01 este de 4, care poate duce la maxim încă 9 infectări rezultate în urma mâncatului acelei pâini.

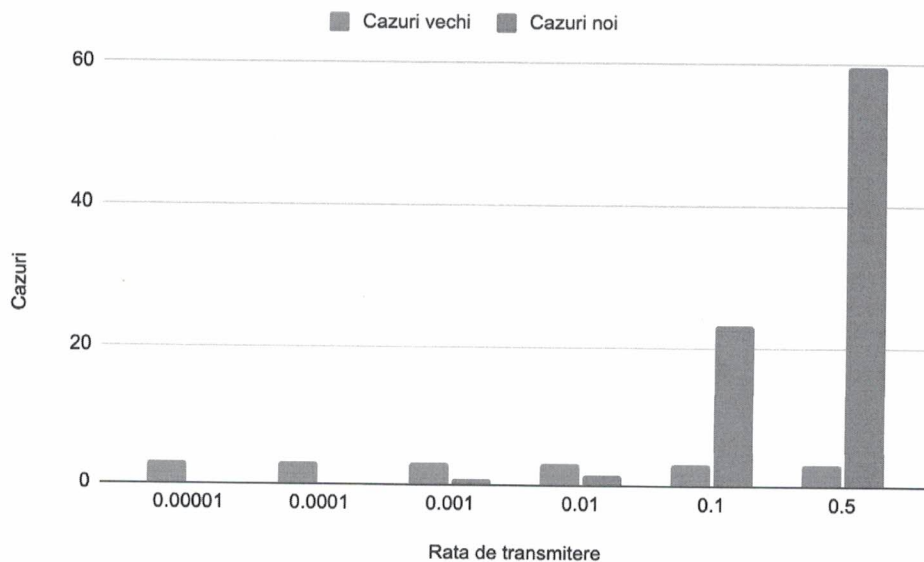


Figura 7.23. Cazuri vechi și cazuri noi pentru scenariul „hipermarket” atunci când se variază rata de transmitere.




Figura 7.24. Cazuri vechi și cazuri noi pentru scenariul „hipermarket” atunci când se variază probabilitatea de infectare.

În final, figurile 7.23 și 7.24 prezintă scenariul „hipermarket”, unde s-a considerat că pot participa maxim 70 de cumpărători simultan. Atunci când se variază rata de transmitere (așa

Sacala



cum se poate observa în figura 7.23), numărul de cazuri noi de infectare este mai mare doar pentru rate mari de transmitere (10% și respectiv 50%), ajungându-se la un maxim de 60 de cazuri noi. Dat fiind numărul mai mare de persoane aflate în spațiul hipermarketului, se susține faptul că vor fi mai multe cazuri decât la un supermarket sau un magazin mic pentru rate mari de infecție, pentru că vor fi mai mulți cumpărători care vor atinge pâinile. Din punct de vedere al numărului de pâini infectate care pleacă din magazin, valoarea maximă (pentru o rată de transmitere de 50%) este 14, ceea ce s-ar traduce prin aproximativ 37 de persoane infectate prin mâncatul acelor pâini. Pentru valori mai plauzibile de rată de transmitere (maxim 10%), se ajunge la maxim 4 pâini infectate ieșite din magazin.

În figura 7.24, se poate observa că numărul de cazuri noi crește repede pentru probabilități de infectare mai mari (ajungând la peste 750 de cazuri pornind de la peste 400 persoane care intră în hipermarket fiind deja infectați cu COVID-19). Este totuși important de menționat aici că valori atât de mari pentru rata de infectare sunt puțin probabile în acest moment. Valorile pentru România se găsesc momentan între 0.003 și 0.01, deci numărul maxim de noi cazuri poate ajunge până la cel mult 58 de cazuri de persoane infectate în magazin. Pentru aceleași valori ale ratei de infectare, numărul maxim de pâini infectate cumpărate ajunge până la maxim 9, care ar putea duce la încă cel mult 24 de persoane infectate după ce pâinile au ieșit din magazin.

Pentru a putea concluziona rezultatele prezentate în această secțiune, pornim de la faptul că, în România, se livrează aproximativ **4 milioane** de pâini neambalate zilnic. Dacă ne orientăm după rezultatele scenariului cu supermarketul (pe care îl putem considera o valoare mediană între cele trei categorii de magazin) și presupunem o rată de transmisie de **10%**, pentru o rată de infectare de **3 la mie** (un pic mai mică decât cea a Bucureștiului în noiembrie 2020) vor putea apărea **5** cazuri noi de infectare în magazin la **1000** de pâini vândute, deci **20000 de cazuri zilnice**. Pentru o rată de infectare de **10 la mie** (mai mult decât orice județ din România în noiembrie 2020), numărul de infectări de la atingerea pâinii din magazin poate ajunge până la **28000 pe zi** (fiind **7** cazuri la **1000** de pâini vândute).

Este totuși important de menționat că valorile prezentate mai sus reprezintă **cazul cel mai rău** (o rată de transmitere de **10%**), în care se presupune că majoritatea clienților din magazine pot ajunge să infecteze foarte ușor o pâine, deci nu poartă măști, mănuși, etc. Dacă am presupune o rată de transmitere mai aproape de realitatea zilnică (**1%**), numărul de cazuri pentru o rată de infectare plauzibilă pentru persoanele care intră într-un magazin (**0.0003**) s-ar diminua la **mai puțin de 500 de cazuri noi zilnic per 4 milioane de pâini**.

## 8. Concluzii

În acest raport, s-a realizat o analiză a răspândirii COVID-19 în trei scenarii bazate pe cazuri reale, cu accent pe modelarea transmiterii virusului prin interacțiunea persoanelor infectate cu pâinea neambalată. Pentru fiecare scenariu, s-au luat în considerare diverși parametri precum



rata de infectare sau probabilitatea de transmitere, pentru a se analiza ce influență au acești factori asupra apariției unor cazuri noi de infectare.

Primul scenariu a simulat o zonă rectangulară în care participanții interacționează schimbând obiecte între ei. Din cauză că unii participanți pot fi infectați cu SARS-CoV-2, este posibil ca ei să transmită virusul prin particule aflate pe obiectele schimbate. În urma analize, s-a observat că, pentru valori realiste ale ratei de transmitere a virusului, numărul de cazuri noi de COVID-19 rezultate în urma a 6 ore de interacțiune este mic.

În al doilea scenariu, s-a simulat o arie în care participanții pot intra sau ieși, și unde aceștia ating diferite suprafețe. În acest scenariu, o persoană infectată poate transmite mai departe virusul pe o suprafață, iar altcineva să se infecteze atingând acea suprafață. Rezultatele obținute în acest scenariu au arătat că numărul de cazuri noi crește aproape exponențial cu rata de transmitere, dar că, pentru valori apropiate de adevăr ale acestei rate, numărul de potențiale infectări este scăzut.

În final, s-a analizat modul în care virusul se poate propaga prin interacțiunea unui grup de subiecți cu un produs alimentar într-un magazin, și s-a ales în mod specific pâinea care se desface neambalată într-un magazin comercial. Simulările efectuate au arătat că, dacă se presupune o rată de transmitere a virusului de 1% (apropiată de valorile reale), numărul de cazuri noi de infecție pentru o populație cu o rată statistică de infectare de 3 la 10000 ar fi de ordinul a 500 de cazuri noi zilnic pentru un volum de desfacere la nivel național de 4 milioane de pâini pe zi.

Este important de subliniat faptul că rezultatele menționate sunt obținute prin realizarea unei aplicații informatice de tip mașină de învățare, la care au fost modificate parametrii modelului în funcție de anumite scenarii și ipoteze. Rezultatele obținute nu au fost validate prin măsurători fizice și statistice.

Echipa de cercetare a dorit să demonstreze utilitatea unor astfel de instrumente în activitățile de management al transmiterii virusului SARS-CoV-2 în comunități și tipurile de informații care pot fi obținute.

## Bibliografie

- [1] <https://github.com/raduciobanu/mobemu> (accesat pe 12.11.2020)
- [2] Devante Ayriss, Kye Horbury, Blake Williams, Mitchell Blackney, Celine Shi Hui See, Syed Afaq Ali Shah. "Deep Learning Models for Early Detection and Prediction of the spread of Novel Coronavirus (COVID-19)." arXiv preprint arXiv:2008.01170 (2020).
- [3] Chiara Boldrini, Andrea Passarella. "HCMM: Modelling spatial and temporal properties of human mobility driven by users' social relationships." Computer Communications 33, no. 9 (2010): 1056-1074.





- [4] C. Z. Cai, L. Y. Han, X. Chen, Z. W. Cao, and Y. Z. Chen. "Prediction of functional class of the SARS coronavirus proteins by a statistical learning method." *Journal of proteome research* 4, no. 5 (2005): 1855-1862.
- [5] Zlatan Car, Sandi Baressi Šegota, Nikola Anđelić, Ivan Lorencin, Vedran Mrzljak. "Modeling the Spread of COVID-19 Infection Using a Multilayer Perceptron." *Computational and Mathematical Methods in Medicine* 2020 (2020).
- [6] Radu-Ioan Ciobanu, Radu-Corneliu Marin, Ciprian Dobre. "Mobemu: a framework to support decentralized ad-hoc networking." In *Modeling and Simulation in HPC and Cloud Systems*, pp. 87-119. Springer, Cham, 2018.
- [7] Ibrahim Abaker Targio Hashem, Absalom E. Ezugwu, Mohammed A. Al-Garadi, Idris N. Abdullahi, Olumuyiwa Otegbeye, Queeneth O. Ahman, Godwin CE Mbah, Amit K. Shukla, Haruna Chiroma. "A Machine Learning Solution Framework for Combatting COVID-19 in Smart Cities from Multiple Dimensions." *medRxiv* (2020).
- [8] Maya John, Hadil Shaiba. "Main factors influencing recovery in MERS Co-V patients using machine learning." *Journal of infection and public health* 12, no. 5 (2019): 700-704.
- [9] Sunho Lim, Chansu Yu, Chita R. Das. "Clustered mobility model for scale-free wireless networks." In *Proceedings. 2006 31st IEEE Conference on Local Computer Networks*, pp. 231-238. IEEE, 2006.
- [10] Gitanjali R. Shinde, Asmita B. Kalamkar, Parikshit N. Mahalle, Nilanjan Dey, Jyotismita Chaki, Aboul Ella Hassanien. "Forecasting Models for Coronavirus Disease (COVID-19): A Survey of the State-of-the-Art." *SN Computer Science* 1, no. 4 (2020): 1-15.
- [11] Universitatea din București, Centru de cercetări "3 NanoSAE", Institutul de virusologie „Ștefan S. Nicolau”, Academia Română, Institutul național de boli infecțioase „Prof. dr. Matei Balș”. "Studiu privind riscurile și căile de transmitere și contaminare cu virusul SARS- CoV-2 prin intermediul unor produse de panificație preambalate și formularea unor propuneri de soluții, măsuri și tehnologii noi și emergente pentru prevenirea transmiterii virusului în comunități", 2020.
- [12] Duncan J. Watts. "Small worlds: the dynamics of networks between order and randomness". Princeton university press, 2004.
- [13] World Health Organization. "Water, sanitation, hygiene and waste management for COVID-19: technical brief," 03 March 2020. No. WHO/2019-NCoV/IPC\_WASH/2020.1. World Health Organization, 2020.
- [14] Eiko Yoneki, Pan Hui, Jon Crowcroft. "Visualizing community detection in opportunistic networks." In *Proceedings of the second ACM workshop on Challenged networks*, pp. 93-96. 2007.

