

동적 움직임 변화를 반영한 에이전트 기반 코로나-19 시물레이션: 접촉자 발견 수준에 따른 감염 변화

이종성[†]

Agent-Based COVID-19 Simulation Considering Dynamic Movement: Changes of Infections According to Detect Levels

Jongsung Lee[†]

ABSTRACT

Since COVID-19 (Severe acute respiratory syndrome coronavirus type 2, SARS-Cov-2) was first discovered at the end of 2019, it has spread rapidly around the world. This study introduces an agent-based simulation model representing COVID-19 spread in South Korea to investigate the effect of detect level (contact tracing) on the virus spread. To develop the model, related data are aggregated and probability distributions are inferred based on the data. The entire process of infection, quarantine, recovery, and death is schematically described and the interaction of people is modeled based on the traffic data. A composite logistic functions are utilized to represent the compliance of people to the government move control such as social distancing. To demonstrate to effect of detect level on the virus spread, detect level is changed from 0% to 100%. The results indicate active contact tracing inhibits the virus spread and the inhibitory effect increases geometrically as the detect level increases.

Key words : COVID-19, Corona virus, Simulation, Contact tracing, Detect level

요약

2019년 말 코로나19(중증급성 호흡기 증후군 코로나 바이러스 타입 2)가 발견된 이후로 전세계적으로 퍼져나가고 있다. 본 연구에서는 접촉자 발견 수준이 바이러스 전파에 미치는 영향을 파악하기 위해서 현재 대한민국의 코로나19 전파 상황을 반영한 에이전트 기반 시물레이션 모델을 소개한다. 본 연구에서는 실제적인 시물레이션 모델 개발을 위해 대한민국 내 관련 데이터를 수집하고 그 확률분포를 추정하였다. 감염, 격리, 회복, 사망의 전체 감염 프로세스를 도식화하였으며 사람들의 상호 작용을 교통량 데이터를 기반으로 하여 모델링 하였다. 사회적 거리 두기 같은 정부 정책에 대한 사람들의 순응도를 반영하기 위해 합성 로지스틱 함수를 활용하였다. 접촉자 발견 수준에 따른 감염 양상 변화를 파악하기 위해 발견 수준을 0%에서 100%까지 변화 시켰다. 그 결과 적극적인 접촉자 추적이 바이러스 확산을 효과적으로 제한하고 제한의 효과가 접촉자 발견 수준이 증가함에 따라 기하급수적으로 증가하는 것을 확인하였다.

주요어 : 코로나19, 코로나 바이러스, 시물레이션, 접촉자 추적, 접촉 발견 수준

* 이 성과는 2020년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2019R1G1A1011098)

Received: 13 December 2020, **Revised:** 11 January 2021,
Accepted: 12 January 2021

† Corresponding Author: Jongsung Lee
E-mail: js.lee@ut.ac.kr
Department of Industrial and Management Engineering at
Korea National University of Transportation

1. 서론

코로나 바이러스 감염증-19(코로나19)는 신종 코로나 바이러스에 의한 호흡기 감염질환으로 2019년 12월 중국 우한에서 처음 발생한 이후 전 세계로 빠른 속도로 퍼져 나갔다. 이에 세계보건기구(World Health Organization, WHO)는 현지시각 3월 11일 감염병 최고 등급인 팬데믹(pandemic)을 선언했다. WHO에 따르면 전 세계적으로

43,540,739명의 코로나19 확진자가 발생하였고, 1,160,650명이 사망했다(10월 28일 기준). 대한민국의 경우 2020년 1월 우한에서 유입된 입국자가 코로나19 확진되며 첫 코로나19 확진 사례가 되었다. 첫 확진자 발생 이후 10월 28일까지 총 26,146명의 확진자와 461명의 사망자가 발생하였다(WHO, 2020).

코로나19 확산 양상과 정책적인 효과를 파악하기 위해 시뮬레이션 연구들이 수행되었는데 수행된 초기의 연구들은 주로 수리적 모델링 방식인 Susceptible-Exposed-Infectious-Recovered(SEIR)을 이용한 시뮬레이션에 초점을 맞췄다(Annas 등, 2020; Choi & Ki, 2020; He & Sun, 2020; Pandey 등, 2020; Wei 등, 2020). SEIR 방식의 모델은 수리적인 가정하에 전체적인 양상을 보여주는 것에는 장점이 있으나 지역적인 확산 양상, 감염자/비감염자 사이 접촉 통제 등 미시적인 상황을 보여주고 통제하는 부분에는 약점이 존재한다. 반면에 에이전트 기반 시뮬레이션 모델(Agent-Based simulation Model, ABM)은 정책 및 사람들의 움직임을 미시적으로 통제할 수 있어 보다 정밀한 시뮬레이션을 할 수 있는 장점이 있으나 계산 시간이 상대적으로 오래 걸리고 하드웨어 자원 소모가 많은 단점이 존재한다.

본 연구에서는 대한민국을 대상으로 실제 코로나19 확산 데이터를 반영하여 코로나19 확산 양상을 보여주고 접촉자 발견 수준에 따라 확산 양상이 변화하는 모습을 예측하는 ABM을 개발한다. 모델 개발을 위해 대상이 되는 1) 대한민국의 코로나19 감염 사례들을 실증적으로 조사하여 필요한 데이터의 확률 분포를 추정하고 조사한 데이터를 바탕으로 2) 비 확진자가 바이러스에 노출되어 감염된 후 확진 판정을 받고 완치되는 과정을 도시화한다. 또한, 3) 교통 데이터를 이용해 지역별로 확산되는 양상을 실증으로 보여주는 시뮬레이션을 개발, 검증한다. 4) 심리적인 요소가 사람들의 움직임으로 반영되는 것을 합성 로지스틱함수 활용하여 표현하고 이를 시간에 따른 사람들의 움직임 변화로 시뮬레이션 모델에 반영한다. 5) 마지막으로 확진자와 접촉한 사람들 발견 수준(디텍트 레벨, Detect Level, DL) 변화에 따른 확산 양상의 변화를 확인한다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구를 탐구하고 3장에서는 시뮬레이션 개발을 위해 수집한 데이터와 개발한 시뮬레이션 모델을 소개하며 4장에서 개발한 시뮬레이션 모델을 바탕으로 디텍트 레벨 수준에 따른 전체 코로나19 확산 및 병원 병상 수 변화 등에 대해 분석을 진행한다. 그 후 5장에서 결론을 맺는다.

2. 관련연구

SEIR 방식을 이용한 코로나19 감염 양상 변화에 대한 연구도 다수 존재하나 본 장에서는 본 연구에 보다 밀접하게 관련 있는 시뮬레이션 모델 형태인 ABM을 이용한 코로나19 관련 연구를 탐구하도록 한다.

Silva 등(2020)은 사회적 거리 조정이 코로나19 역학 및 사회경제에 미치는 영향을 보여주기 위해 브라질을 대상으로 SEIR 모델을 포함하는 ABM을 개발하였다. 코로나19 확산을 막기 위해 고려될 수 있는 사회정책을 1) 아무 것도 하지 않음 2) lockdown 3)조건부 lockdown 4) 수직 격리 5)부분 격리 6)마스크 착용 7)마스크 착용 및 부분 격리 50% 등의 7가지 시나리오로 만들어 연구를 진행했고, 시뮬레이션을 통해 코로나19 발생 시 확진자들의 움직임과 이를 사회 정책으로 제한하였을 때 그에 따른 사회경제의 변화를 보여주었다. 코로나19에 대한 사회적 정책을 취하지 않으므로써 경제를 살리려는 것은 바이러스 확산으로 발생하는 사회적 비용으로 인해 경제에 부정적인 영향을 미치게 된다는 결과를 도출했고 마스크 사용과 부분 격리가 결합된 시나리오는 가장 좋은 시나리오인 lockdown을 시행할 수 없는 경우를 고려할 때, 생명 보존에 있어서 좋은 접근법이 될 것이라고 제안했다.

Tatapudi 등(2020)은 미국을 사례로 코로나19의 확산을 완화하기 위한 사회적 정책을 검토하고 접촉 추적에 대한 영향을 보기 위해 취약계층과 감염자의 일상적인 사회적 행동(집, 학교, 직장, 커뮤니티 장소를 다니는 행동)을 반영한 ABM을 개발하였다. 사회적 정책에 따른 코로나19가 잠잠해지는 시간과 총 감염자 수, 총 보고된 건수, 총 입원 수, 총 사망자 수를 보여주었고, 마스크를 사용하는 것이 감염자, 입원자, 사망자의 평균 총량을 줄인다는 결론을 도출했다. 무증상과 전증상 50%를 식별한다는 목표를 가진 접촉 추적도 전체 감염자의 평균 66%가 감소할 것으로 예측했다.

Hoertel 등(2020b)은 프랑스 인구의 36.4%에 해당하는 실제 데이터를 바탕으로 코로나19 전염병의 확률적인 ABM을 개발했다. 코로나19 감염 위험에 처한 인구의 사회적 거리두기, 마스크 착용 및 보호를 포함하여 8주에서 16주까지의 폐쇄 연장과 폐쇄 후 조치를 평가하였다. 마스크 쓰기, 사회적 거리두기 등의 방법이 질병 확산 및 사망률을 낮추고 코로나19의 재 확산 시 시행하게 될 두 번째 lockdown의 필요성을 낮출 수 있음을 보여주었다.

Hoertel 등(2020a)은 뉴욕시의 코로나19 전파에 대한 확률론적 ABM을 사용하여 격리 기간(4주~16주), 격리

해제 유형(모든 개인에 대한 1단계 격리 해제, 연령에 대한 2단계 격리 해제)따른 잠재적 영향을 연구했다. 그 결과 연령에 대한 2단계 해제(70세 미만의 모든 개인의 3주 격리와 70세 이상 사람들의 추가 8주 격리)는 모든 개인에 대해 16주 격리 후 치료를 실시한 것에 비해 누적 발생률은 23%, 누적 사망률은 68% 감소하는 것을 시뮬레이션으로 보였다. 또한 8주 격리 기준인 70세를 60세로 강화하면 사망률이 3% 더 감소하고, 필요한 ICU의 병상 수가 상당히 감소한다는 결론을 도출하였다.

Wolfram(2020)은 에이전트 간의 접촉 수에 따른 감염 양상을 살펴보고 Watts-Strogatz, Barabasi-Albert, Grid, Grid3D, 무작위 등 서로 다른 네트워크 종류에 따라 감염자 수의 양상변화를 알아보는 연구를 진행하였다. 1000명의 에이전트를 설정하여 평균 접촉 수, 네트워크 종류, 상호작용 비율, 회복 시간의 변화에 따른 코로나19 감염 양상을 시뮬레이션 했다. 그 결과 네트워크 상에서 에이전트의 수와 에이전트 간의 연결 등을 동일한 조건으로 설정하여도 네트워크의 종류에 따라 일별 최고 확진자와 전체 확진자의 증가속도에 차이가 발생한다는 것을 알 수 있었고, 밀도에 차이를 두었을 때 Grid3D 네트워크에서 가장 전파력이 낮은 것을 알 수 있었다. 또한, 상호작용의 수가 감소함에 따라 총 감염률의 감소에 유의미한 영향을 미친다는 것을 보였다.

Giacopelli(2020)는 롬바르디의 인구 10.06만 명의 코로나 역학을 재현할 수 있는 에이전트 모델을 도입하였다. 해당 모델에서는 롬바르디 지역 거주자들 히트맵을 분석하여 거주자 위치 등 환경적인 요소를 시뮬레이션 모델에 반영하였고 에이전트의 충돌감지, Susceptible - Infected-Recovered-Dead(SIRD) 모델 등을 도입하여 실질적인 시뮬레이션을 할 수 있도록 하였다. 이를 바탕으로 사회적 거리두기, lockdown, 백신 등이 코로나19 전파에 미치는 영향을 연구했다. 이 연구에서는 입자 모델을 활용하여 충돌감지 알고리즘을 적용하였지만 입자들이 시뮬레이션에서 나는 셀의 경계를 가로지르지 못해 지역의 경계에서 발생하는 감염에 대한 부분은 실제적으로 반영하지 못하였다. 또한, 시나리오에 대한 평가를 진행할 때 실제 데이터를 바탕으로 하지 않고 임의의 숫자를 설정하여 감염이 감소되는 것을 모델링하였다.

Abdollahi 등(2020)은 다양한 기간의 School Closure(SC)가 코로나19의 전체 발생률, 발병의 규모 및 피크 시간, 인구의 중환자실(ICU) 입원 요건에 미치는 영향을 파악하고자 ABM 모델을 개발하였다. 온타리오 주의 인

구 통계와 Contact Network(공립학교 및 지역사회 내에서 접촉)를 기반으로 연구를 진행하였다. 시뮬레이션 결과, SC가 코로나19 대유행 동안 다른 사회적 거리 조치와 결합했을 때 질병의 전염은 완화시키겠지만, Self Isolation(SI)에 비해 감염률과 입원율을 줄이는 데 있어 현저하게 낮은 효과를 보인다는 결과를 도출했다.

Wallentin 등(2020)은 코로나19가 장기적으로 이어졌을 때 정부 의사결정자들이 적절한 통제와 개입 조치를 취할 수 있도록 도와주기 위해 ABM을 제시했다. 이들은 단계적 폐쇄 완화로 발생할 수 있는 2차 발병은 스마트폰 애플리케이션으로 보완하도록 제시했는데, 앱을 사용한 접촉추적은 수준이 낮음(13%)일 때를 제외하고 중간(26%), 높음(39%) 수준을 유지하면 연구지역에서 바이러스를 근절하는 데 도움을 줄 수 있는 잠재력을 가진다는 결과를 도출하며 코로나19 확산에 있어서 앱을 사용한 접촉추적방식의 가치를 보여주었다. 이 연구는 접촉자 추적의 효과에 대해서 연구하였으나 실제 데이터를 활용하지 않았고 사람들의 움직임이 시간에 따라 변화하는 양상을 반영하지 않아 실증적인 면에서 제한적이다.

Table 1은 관련 연구의 핵심 내용과 본 연구의 차이를 정리한 것이다. 연구에서 실제 데이터를 적용했는지의 여부와 정부 시책으로 사람들의 움직임을 통제하였는지, 디텍트 레벨 수준을 변화시켰는지, 사람들의 움직임을 시간별로 반영했는지를 나타낸다.

Table 1에 나타난 바와 같이 기존 코로나19 관련 ABM 연구는 다수 존재하나 대부분이 정부 통제(사회적 거리 두기 등) 즉, 사람들의 움직임을 통제 했을 때 코로나19 전파 양상의 변화를 확인하려 하거나 그로 인한 경제적인 여파를 확인하고자 하였다. 감염자와 접촉한 사람들을 추적하려는 연구는 제한적이었고 대부분 정부 통제에 부수적인 요소로 확인하려는 연구였다. 하지만 본 연구에서는 디텍트 레벨을 주요 인자로 하여 확진자를 찾는 과정이 코로나19 감염 양상에 어떠한 변화를 주는지 확인하려 한다. 이는 연구자들이 아는 한 접촉자 발견 수준이 코로나19 감염에 미치는 영향을 탐구하는 연구 중 대한민국의 실증 데이터를 이용한 최초의 연구이다. 또한 본 연구는 기존의 연구와 비교 했을 때 실증 데이터를 활용하였고 정부의 통제 수준을 반영하며 디텍트 수준을 변경할 뿐 아니라 시간이 경과됨에 따라 사람들의 순응도가 변경하는 것을 반영하는 등 감염 전파에 영향을 주는 요인들을 보다 포괄적으로 반영한 현실적인 시뮬레이션 연구라고 할 수 있다.

Table 1. Previous studies of COVID-19 simulation with ABM

Researcher	Region	Use real- world data	Governmental Control	Detect level Control	Dynamic movement changes
Silva et al.	Brazil	X	O	X	O
Tatapudi et al.	USA	X	O	X	X
Hoertel et al.	France	O	X	X	O
Hoertel et al.	USA	O	O	X	X
Wolfram	Virtual	X	O	X	X
Giacopelli	Italia	X	O	X	X
Abdollahi et al.	Canada	X	O	X	O
Wallentin et al.	Germany	X	O	O	X
This Study	South Korea	O	O	O	O

3. 코로나19 전파 시뮬레이션

본 장에서는 개발한 코로나19 전파 시뮬레이션에 대해서 묘사한다. 본 연구에서는 전체 대한민국 인구를 20,000명으로 가정하고 이를 수도권, 강원도, 충청도, 전라도, 경상도, 제주도의 6개 권역으로 나누어 각 도의 인구에 비례하여 배분 하였다.

3.1 시뮬레이션 모델

3.1.1 시뮬레이션 가정

본 시뮬레이션은 시뮬레이션의 현실성 및 시뮬레이션 구현의 용이성, 가용 데이터를 고려하여 다음과 같은 가정 하에 구현되었다.

- 1) 감염자와 비감염자가 만났을 때 일정한 확률로 비 감염자가 감염될 수 있으며 이 확률은 변하지 않는다.
- 2) 사람들은 1:1로 만난다. 즉, 시뮬레이션 내에 다수의 사람이 모이는 장소는 상정하지 않는다.
- 3) 사람들의 움직임은 각 지역 내 혹은 지역 간 교통량과 비례한다.
- 4) 사람들의 움직임은 정부시책(사회적 거리두기)에 영향을 받으며 정부시책은 인구전체에 일괄적으로 일정한 영향을 준다.
- 5) 사람들의 움직임은 심리적 긴장감(순응도)에 영향을 받으며 초기에는 질병에 대한 정보가 적어 낮은 순응도(높은 움직임)를 보이다가 질병이 확산됨에

따라 높은 순응도(낮은 움직임)를 보이고 통제에 대한 피로도가 증가함에 따라 낮은 순응도로 전환 된다.

- 6) 한번 감염된 사람은 재감염 되지 않는다.
- 7) 유증상자는 증상 발현 즉시 검사를 받으며 감염자가 검사를 받을 시 100% 확진 판정을 받는다.
- 8) 무증상자가 사망하는 경우는 없다.
- 9) 병원과 생활치료센터(Community Treatment Center, CTC)의 병상 제한은 고려하지 않는다.

3.1.2 에이전트 상태 다이어그램

개발된 시뮬레이션에서 하나의 에이전트는 한 사람에게 대응된다. Fig. 1은 시뮬레이션에서 코로나19에 대해 사람이 가지는 상태를 도식화하여 나타낸 것이다.

에이전트의 상태는 기본적으로 감염되지 않음(Not infected), 감염(Infected), 회복(Recovered), 사망(Dead)의 상태를 가지며 검사를 받게 되면 검사(Inspection), 검사 후 결과에 따라서 자가격리(Quarantine), 병원(Hospital), CTC의 상태를 가진다.

감염되지 않은 에이전트는 감염된 에이전트와 접촉 시 일정한 확률로 감염되며 상태가 Not Infected에서 Infected로 변경된다. 이 때 코로나로 인한 임상적인 증상(발열, 기침 등)이 발현될지 발현되지 않을지가 확률 분포(P_s)로 결정된다. 확률 분포에 따라서 유증상자(Symptomatic)로 된 경우 일정 기간 경과 후 증상이 발현되며 증상 발현 시까지 소요되는 시간 역시 확률 분포(P_i)로 결정된다. Infected 상태의 에이전트는 접촉 빈도(Contact Number, CN)에 따라서 다른 에이전트에게 코로나19를 전파한다.

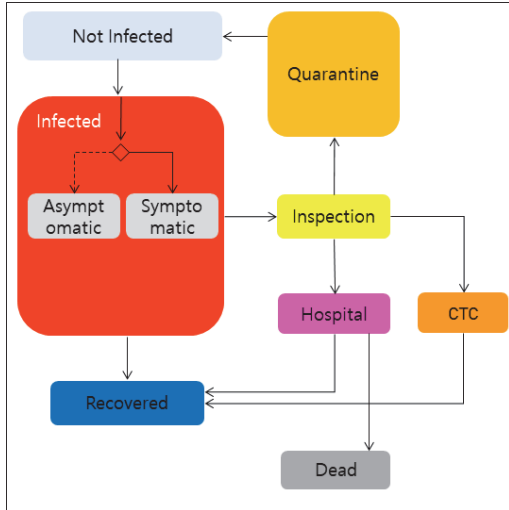


Fig. 1. Agent state diagram

Symptomatic 상태의 에이전트는 증상이 발현 되기까지 다른 에이전트들을 감염시키다가 증상이 발현되면 Inspection 상태가 된다. 무증상자(Asymptomatic)의 경우 Recovered 상태가 되기 전까지 지속적으로 다른 에이전트들을 감염시킨다. Asymptomatic 상태의 경우 실제 증상을 알아차리지 못할 만큼 가벼운 경우이기 때문에 Dead 상태로 변하지 않는다.

Inspection은 검사 단계이며 에이전트는 검사 시간 경과 후에 Quarantine 혹은 Hospital이나 CTC 상태로 변경된다. 증상 발현과 마찬가지로 검사 시간 역시 확률 분포 (P_p)로 결정된다. 에이전트가 Inspection 상태로 변경되는 경우는 Symptomatic 상태에서 증상 발현 후 변경되는 것 외에 감염 에이전트가 Inspection 상태에서 확진되었을 때 이 감염 에이전트와 접촉한 에이전트들을 추적해서 Inspection 상태로 변경하는 것이 있다. 감염자와 접촉한 에이전트 중에는 감염되지 않은 에이전트들도 포함되어 있으며 감염되지 않은 에이전트의 경우 Quarantine으로 상태가 변경되고 감염된 에이전트의 경우 Hospital이나 CTC로 상태 중 하나로 변경된다. 이 때 에이전트가 Hospital과 CTC 중 변경될 상태를 선택하는 것 또한 확률분포(P_H)를 가진다.

Hospital 상태로 전환된 에이전트는 Recovered 상태나 Dead 상태로 전환되는데 Dead의 경우 연령대 별 사망률과 인구당 연령 비율을 합성한 확률분포(P_D)를 사용한다. Hospital 상태에서 머무는 시간 역시 확률분포(P_h)로 결정된다. 개발한 시뮬레이션 모델에서는 Hospital 상

태가 장래에 상태가 악화되어 병원으로 이송되는 환자를 포함하기 때문에 CTC와 병원 간 이동은 고려하지 않는다. 따라서 CTC 상태의 경우 Recovered 상태로만 전환되며 CTC 상태에 머무는 시간 역시 확률분포(P_c)로 결정된다. Quarantine 상태의 경우 14일 경과 후 다시 Not Infected 상태로 변경된다.

3.1.3 감염에이전트 접촉 추적

감염된 에이전트들은 감염 후 자신과 접촉한 에이전트들의 리스트(Contact Agents List, CAL)를 가지고 있다. 감염 에이전트의 확진 판정 후 접촉자 발견 수준(디텍트 레벨, Detect Level, DL)에 따라 CAL 내의 임의의 에이전트들을 선정하여 Inspection 상태로 변경한다. 예를 들어 Inspection 상태에서 특정 에이전트가 확진되었고 그 에이전트의 CAL에 저장된 에이전트들의 수가 10, DL은 50%라고 하면 CAL에 있는 에이전트들 중 임의로 5개를 선택하여 상태를 Inspection으로 변경한다. Fig. 2는 개발한 시뮬레이션 모델에서 디텍트레벨에 따른 접촉자 발견 수준을 묘사한 것이다.

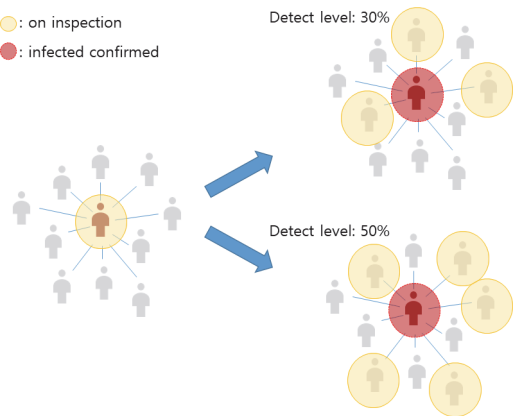


Fig. 2. Contact tracing based on detect level

3.1.4 감염 전파

개발된 시뮬레이션에서 설정한 6개 권역내에 에이전트들은 6개권역 인구에 비례하여 각 권역에 위치하며 권역은 지정되나 권역 내에서 생성되는 위치는 무작위로 생성된다. 본 연구에서는 에이전트 간 1:1 접촉을 기준으로 하며 각 에이전트들의 접촉은 권역 간 교통량 데이터를 기준으로 기준 접촉 횟수(Standard Contact Number, SCN_{ij})를 정의하고 이를 바탕으로 사회적 거리 두기 단계별 정부 시책(Government Policy, $G_{s(t)}$)과 사람들의

정책 순응도를 반영하여 실제 접촉 빈도(Real Contact Number, $RCN_{ij}(t)$)를 설정하였다. 식 (1)은 t 시점에 i 지역에 있는 에이전트가 j 지역에 위치한 에이전트들에 접촉하는 실제 접촉 빈도를 나타낸다.

실제 접촉 횟수는 기준 접촉 횟수와 비례하고 이에 정부 정책 단계에 따른 계수로 보정을 한다. 정책 단계는 0부터 3단계까지 존재하며 (2020년 10월 기준) 단계가 증가 됨에 따라 에이전트들의 실제 접촉 빈도가 줄어든다. $CL(t)$ 는 시간에 따른 사람들의 순응도로 3.1.1의 가정과 같이 처음에는 질병에 대한 정보가 없어 낮은 순응도를 보이다가 질병의 심각성을 인식한 후부터는 높은 순응도를 보이고 이후 질병에 대한 심리적인 피로도가 증가하여 낮은 순응도를 보이는 것으로 가정한다. 순응도가 높으면 상대적으로 낮은 빈도의 접촉이 발생하고 낮아지면 높은 빈도의 접촉이 발생한다. 즉, 접촉 빈도와 순응도는 반비례 관계를 가진다.

$$RCN_{ij}(t) = \frac{SCN_{ij} \times G_s(t)}{CL(t)} \quad (1)$$

- $RCN_{ij}(t)$: t 시점에서 i 권역 에이전트가 j 권역 에이전트를 접촉하는 평균 접촉 빈도,
- SCN_{ij} : i 와 j 권역 간 기준 접촉 빈도,
- $G_s(t)$: 사회적 거리두기 $s(t)$ 단계에서 접촉 계수
- $s(t)$: t 시점 사회적 거리두기 단계 $s(t)=0,1,2,3$
- $CL(t)$: t 시점 사람들의 순응도

본 연구에서는 초기에 순응도가 낮고 중기에는 순응도가 높고 후기로 갈수록 피로도로 인해 순응도가 낮아지는 것을 가정하고 있기 때문에 두 개의 로지스틱 함수를 합성하여 시뮬레이션 내 사람들의 접촉 빈도에 영향을 주도록 순응도를 모델링 하였다. 식 (2)는 이러한 관계를 나타낸 것이다. 사람들의 경각심이 높을수록 이동이 감소된다고 가정하였으나 사람들의 움직임이 0일 수 없으므로 기본적인 접촉 수준은 항상 존재한다고 가정하고 이를 β 로 반영하였다. 식 (2)에서 t 는 시뮬레이션이 진행된 날짜를 의미한다. b_1 은 순응도가 증가하여 접촉빈도가 감소하는 시점을 나타내고, b_2 는 순응도가 감소하여 접촉빈도가 상승하는 시점을 나타낸다. ω_1 은 얼마나 급하게 하강하는지, ω_2 는 얼마나 급하게 상승하는지를 나타낸다.

$$\frac{1}{CL(t)} = (1-\beta) \left\{ \alpha \frac{1}{1+e^{\omega_1(t-b_1)}} + (1-\alpha) \frac{1}{1+e^{-\omega_2(t-b_2)}} \right\} + \beta \quad (2)$$

3.2 데이터 수집 및 분포 추정

Table 2는 본 시뮬레이션에서 필요한 확률 분포를 나열한 것이다. 분포를 추정하기 위한 데이터는 각 지자체 확진자 세부현황 및 질병 관리청 데이터를 활용하였으나 증상 발현까지 걸리는 시간(P_i) 분포는 Lauer 등(2020)의 연구에서 발견한 분포를 활용하였다.

분포 추정은 Table 2의 확률 분포를 추정하기 위한 각 데이터에 대해 정규분포(Normal, N), 로그 정규 분포(Log-normal, LN), 지수분포(Exponential, E), Weibull 분포(W), 최소극단값 분포(Minimum extreme value, MNEV), 최대 극단값 분포(Maximum extreme value, MXEV), 감마 분포(Gamma), 로지스틱 분포(Logistic, L), 로그 로지스틱 분포(Log-logistic, LL) 중 가장 적합한 분포를 선정하였다. 분포 적합성을 판단하는 위해 Anderson-Darling(AD) 통계량을 활용하였다. Table 3은 AD를 활용하여 분포를 추정한 결과 나타낸다. 각 분포에서 첫 번째 인자는 위치 모수(Location parameter), 두 번째 인자는 척도모수(Scale parameter)를 나타낸다.

Table 2. Probability distributions for the simulation

Probability Distribution	Description
P_S	to be symptomatic after infection
P_i	Incubation period distribution
P_p	Time to complete an inspection
P_H	Probability to be hospitalized after inspection
P_h	Time to be released from hospital
P_c	Time to be released from CTC
P_D	To be dead in a hospital

분포 적합결과 P_S 는 최소 극단값 분포를 따르고 P_p , P_h 는 로그 정규 분포, P_H 는 로지스틱 분포를 따르는 것으로 나타났다. P_i 의 경우 충분한 데이터를 확보하지 못하여 Lauer 등 (2020)의 연구 자료를 활용하였다. P_c 와 P_D 의 경우 적합성 검증에 활용한 9가지 분포 중 해당 데이터를 잘 설명하는 분포를 찾기 어려워 데이터 자체를 기반으로 Custom distribution을 생성하여 시뮬레이션에 활용하였다. Custom distribution은 n개의 데이터가 존재할 때 각 데이터 값들은 오름차순으로 정렬하고 각 데이터 포인트들의 확률을 $1/n$ 을 하여 누적 확률 분포를 추정

한다. 이 때 각 데이터 포인트 사이의 값들은 선형 보간법(Linear Interpolation)을 사용하여 추정한다. 코로나 환자가 병원에서 죽을 확률인 P_D 의 경우 대한민국 인구 분포에 대해 Custom distribution을 생성하고 코로나 확진 시 연령대별 사망률을 합성하였다. 식 (3)은 인구분포와 연령별 코로나 사망률을 합성하여 P_D 를 추정한 것이다.

$$P_D = P(Dead|a)Pop(a) \tag{3}$$

$P(Dead|a)$: 코로나 확진자의 나이가 a일 때 사망할 확률
 $Pop(a)$: 연령에 대한 확률 분포

Table 3. Inferred probability distributions based on Anderson-Darling statistics

Probability Distribution	Inferred distribution
P_S	MNEV(0.719, 0.148)
P_i	LN(1.621, 0.418)*
P_p	LN(-0.707, 0.487)
P_H	L(0.592, 0.098)
P_h	LN(3.204, 0.511)
P_c	Custom distribution
P_D	Custom distribution

* Lauer et al (2020)

3.3 시뮬레이션 모델 교정(Calibration)

개발한 시뮬레이션 모델에 실제 코로나19 전파 상황을 반영하기 위해서 필요한 인자 (Parameter)들의 교정을 수행하였다. 교정 대상 인자들은 감염 전파에 직접적인 영향을 주지만 겉으로 드러나지 않아 실제 데이터 파악이 어려운 인자들이다. 이들은 최초 감염자 수(시뮬레이션 시작 시점의 감염자 수), 현재 디택트 레벨, 접촉 시 감염 확률, 사회적 거리두기 단계별 접촉계수($G_{s(t)}$), 사회적 거리두기 단계 기준, 순응도($CL(t)$) 산정에 필요한 인자들이다.

인자들의 교정은 대한민국 내 코로나 일일 확진자 데이터를 기준으로 실제 데이터와 가장 적은 차이를 보여주는 인자들을 최종 산정하는 방식으로 이루어졌다. 사용한 데이터는 총 261일 간의 일일 확진자 데이터이다. 대한민국 전체 인구에 대해서 대규모 시뮬레이션을 진행할 수는 없었기 때문에 규모를 줄여 실제 확진자 데이터에서 1/10한 값을 올린 데이터를 사용하였다. 이후로는

규모를 줄인 일일 확진자 데이터를 실제 일일 확진자 데이터로 지칭하도록 하겠다. 총 500회의 인자 탐색을 진행하였으며 산정된 각 인자들에 대해서 10회씩 시뮬레이션을 반복하여 그 중 실제 일일 확진자 데이터와 가장 비슷한 값을 주는 인자를 최선의 인자로 정하였다. 인자 값 탐색에는 시뮬레이션 모델을 개발하는데 사용한 Anylogic 프로그램과 연동하여 동작하는 상용 프로그램인 OptQuest를 활용하였다.

교정 결과 선정된 인자들의 값은 Table 4에 정리하였다. 사회적 거리두기 단계를 나누는 기준은 정부에서 명목적으로 정한 기준이 있으나 실제 데이터상으로 나타나는 기준을 파악하기 위해 교정 인자로 선정하였다. Table 4에 정리된 값들은 시뮬레이션으로 교정된 인자들이며 이 인자들은 일정한 값 혹은 비율을 의미한다. 즉, Table 4의 인자들 중 시뮬레이션에 사용하는 확률분포를 결정하는데 활용되는 인자들은 없다. 시뮬레이션 모델에서 확률 분포와 관련된 사항들은 Table 2와 Table 3에 정리하였다. 정리된 확률분포들은 모두 실제 데이터를 바탕으로 추정된 것들이다.

Table 4. The parameters obtained after calibration

Parameter	Value	
Initially infected	97	
Detect Level	51.4 %	
Infection probability	28.4 %	
$G_{s(t)}$	$s(t) = 0$	0.725
	$s(t) = 1$	0.382
	$s(t) = 2$	0.282
	$s(t) = 3$	0.176
Thresholds of social distancing stage	$s(t) = 1$	0
	$s(t) = 2$	19
	$s(t) = 3$	30
Compliance Level	b_1	58.842
	ω_1	0.901
	b_2	179.252
	ω_2	0.015
	α	0.004
	β	0.465

Fig. 3와 Fig. 4는 실제 누적 확진자와 일일 확진자 및 교정 결과 얻어진 인자를 가지고 시뮬레이션을 통해 얻어진 누적 확진자와 일일 확진자를 그래프로 표현한 것

이다. Best feasible은 교정 후 산정된 인자를 가지고 10 회 시뮬레이션을 한 후 얻어진 누적 확진자와 일일 확진자를 평균하여 나타낸 것이고 Historic은 실제 일일 확진자 데이터를 나타낸 것이다. 실제 일일 확진자 데이터를 보면 일일 확진자가 급증하는 현상이 두 번에 걸쳐서 나타나는 데 개발한 시뮬레이션 모델이 이를 잘 반영하여 움직이는 것을 그래프 상으로 확인할 수 있다.

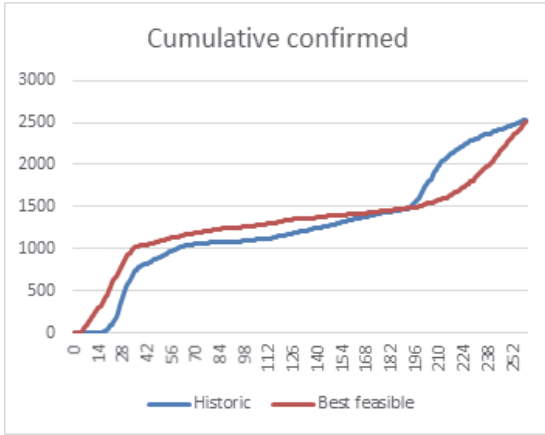


Fig. 3. Cumulative confirmed

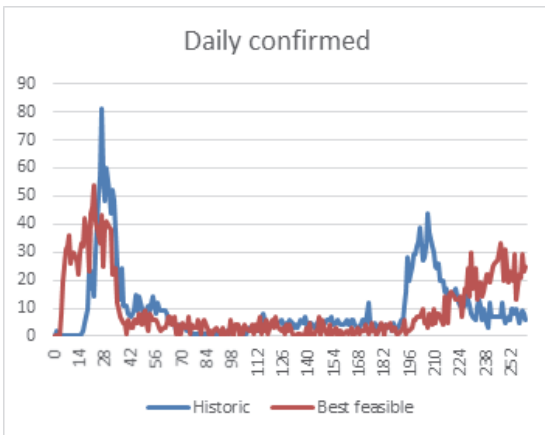


Fig. 4. Daily confirmed

교정된 시뮬레이션 모델의 유효성을 통계적으로 검증하기 위해서 실제 일일 확진자 데이터와 시뮬레이션 모델이 생성한 데이터 사이에 T-검정을 실시하였다. 검증 대상이 되는 데이터들이 시계열 데이터이기 때문에 실제 확진자와 시뮬레이션 모델 생성 확진자 간 차이 데이터에 대해서 그 평균값이 0 인지 아닌지 검증하였다. Table 5는 T-검정결과를 보여준다.

Table 5. T-test result for the difference between Historic and Best feasible

N	Mean	S.D.	T-value	P-value
261	0.077	12.916	0.10	0.924

T-검정에서 귀무가설은 실제 일일 확진자 데이터와 시뮬레이션 생성 확진자 데이터 간 차이가 없다는 것이고 대립 가설은 차이가 존재한다는 것이다. 검정결과 T-value는 0.10, P-value는 0.924로 0.05 유의 수준에서 귀무가설을 기각하지 못하는 것으로 나타났다. 따라서 실제 일일 확진자 데이터와 시뮬레이션 생성 확진자 데이터 사이에는 통계적인 차이가 존재하지 않는다고 볼 수 있다. 즉, 시뮬레이션 모델이 실제 대한민국 내 코로나 확진 상황을 잘 반영하고 있다고 할 수 있다.

3.4 시뮬레이션 모델 구현 및 실행

시뮬레이션 모델은 Anylogic 8.6.0 버전으로 개발되었다. 시뮬레이션 모델의 구조는 3.1.2 절에서 묘사한 에이전트 상태 다이어그램을 Anylogic 프로그램을 활용하여 에이전트로 구현하였다. Fig. 5는 Anylogic으로 구현된 statechart를 나타낸다.

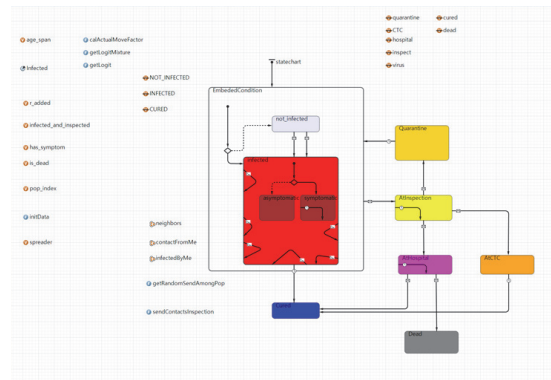


Fig. 5. Implemented statechart of agent

감염의 전파는 에이전트 간 메시지 전달을 통해서 이루어진다. Fig. 6는 감염 메시지의 전달을 개념적으로 보여준다. 시뮬레이션 시간 120일 시점에서 5번 권역에 있는 코로나19 감염자의 경우 자신이 속한 권역을 포함한 모든 권역의 에이전트에 매일 $RCN_{5,j}(120)$ 만큼의 바이러스 전파 메시지를 전달한다. 이 때 $j=\{1,2,3,4,5,6\}$ 이다. 감염 전파는 별도의 구조를 가지지 않으며 Anylogic 에이전트 statechart에 동시에 구현된다.




Fig. 6. Virus spread by an infected agent

실험은 AMD Ryzen 7 3700X 3.59GHz CPU, RAM 16GB 환경에서 이루어졌다. Fig. 7은 개발한 시뮬레이션을 실행한 모습이다. 대한민국을 각 도단위로 6개 권역으로 나누고 각 권역의 인구에 비례해서 에이전트를 생성하였다. 각 권역 옆의 그래프는 권역 별 코로나19 비감염자, 감염자, 회복자를 나타낸 것이고 화면 오른쪽의 그래프들은 각각 일일 확진자, 일일 병원/CTC/자가격리 신규 분류자, 현재 병원/CTC/자가격리 중인 사람 총 수, 누적 사망자 수를 나타낸다.

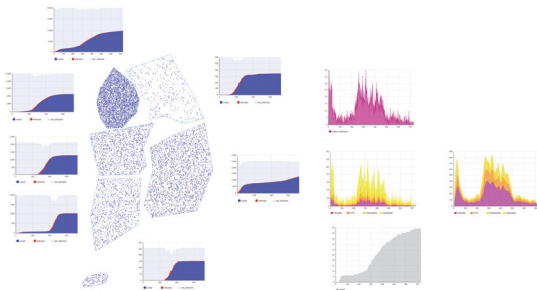


Fig. 7. Simulation execution example

4. 디텍트 레벨에 따른 코로나 전파양상 변화

본 장에서 디텍트 레벨을 변화 시켰을 때 코로나 전파 양상의 변화를 살펴본다. 디텍트 레벨은 0%, 20%, 40%, 60%, 80%, 100%의 총 5단계로 설정한다. 디텍트 레벨에 따른 코로나19 전파 양상을 확인하기 위해 다음의 5

가지 사항을 관찰한다.

- 1) 일일 확진자 수
- 2) 일일 병원 내 환자 수
- 3) 누적 사망자 수
- 4) 누적 완치자 수
- 5) 최대 사용 병상 수

시뮬레이션은 1회 수행 시 2년의 기간 동안 진행되도록 설정하였으며 10회 반복 수행하여 결과를 관측하였다.

4.1 일일 확진자 수 및 병원 내 환자 수 변화

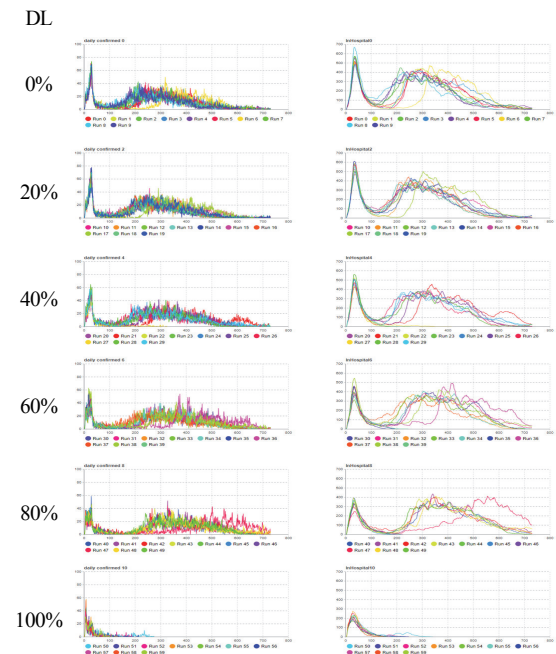


Fig. 8. a) Daily Confirmed b) Daily total number of patients in hospitals

일일 확진자 수와 일일 병원 내 환자 수는 시뮬레이션 기간 동안 매일의 확진자 수와 병원 내 치료 받고 있는 전체 환자 수를 의미하며 시뮬레이션 1회 당 730개씩 총 7300개의 데이터를 수집한다. Fig. 8은 시뮬레이션에서 생성한 일일 확진자 수와 병원 내 환자 수 변화를 모두 그래프에 표현한 것이다.

디텍트 레벨은 확진자와 접촉한 사람을 발견해서 격리하는 비율을 나타낸 것이기 때문에 디텍트 레벨이 높다는 것은 감염의 위험성이 있는 사람들을 사전에 차단하

는 효과가 크다는 것을 의미한다. 높은 디텍트 레벨을 확보함으로써 1) 전체적인 감염자 숫자를 감소시킬 수 있고 이에 따라 빨리 코로나19 상황을 종식시킬 수 있다. 같은 맥락으로 높은 디텍트 레벨은 2) 재유행 시작 시점에 감염 전파자 수를 줄일 수 있으므로 디텍트 레벨이 낮을 때보다 재유행으로 감염자가 폭발적으로 증가하는 시점을 미룰 수 있게 한다. Fig. 8의 그래프들은 위의 가설을 지지하는 결과를 보여준다.

Fig. 8 a)는 일일 확진자 수 변화를 나타낸 그래프이다. 디텍트 레벨이 100%일 때를 제외하고 모두 2차에 걸쳐 크게 코로나 전파가 일어나는 것을 확인할 수 있다. 1차 유행 시 최대 일일 확진자 수는 디텍트 레벨이 증가됨에 따라서 점점 감소하나 1차 유행의 종료 시점은 크게 달라지지 않는 것을 그래프 상 확인할 수 있다. 2차 유행도 마찬가지로 디텍트 레벨이 증가됨에 따라 최대 일일 확진자 수는 감소하며 2차 유행이 진행되는 시기가 점차 뒤로 미루어지는 것을 확인할 수 있다.

Fig. 8 b)의 병원 내 입원 환자 수도 일일 확진자 그래프와 비슷한 형태를 가지나 환자들을 병원에서 치료하는 동안 일일 확진자 수의 일부가 누적되어 입원 환자 수로 나타나기 때문에 절대적인 수가 일일 확진자에 비해 많아지는 형태로 나타난다.

일일 확진자 및 병원 내 환자 수가 디텍트 레벨에 따라 어떠한 변화를 가지는지 통계적으로 분석하기 위해서 디텍트 레벨 0%를 기준으로 각 디텍트 레벨별 차이를 알아 보았다. Table 6는 디텍트 레벨에 따른 평균 값 차이와 95% 신뢰구간을 표현한 것이다.

Table 6의 결과를 보면 일일 확진자의 경우 디텍트 레벨이 20%일 때는 0%일 때와 평균 차이를 보이지 않으나 40%에서 100% 구간으로 늘어남에 따라 일일 확진자 수가 줄어드는 폭이 더 커지는 것을 확인할 수 있다. 병원

Table 6. Mean differences of daily confirmed and daily total number of patients in hospitals from detect level 0%

Detect Level	Daily confirmed		Daily total number of patients in hospitals	
	Mean	C.I.	Mean	C.I.
20%	0.033	(-0.17, 0.24)	-0.18	(-2.9, 2.6)
40%	-1.369	(-1.57, -1.17)	-23.62	(-26.4, -20.8)
60%	-2.636	(-2.84, -2.43)	-45.18	(-47.9, -42.4)
80%	-4.505	(-4.71, -4.30)	-77.24	(-80.0, -74.5)
100%	-8.527	(-8.73, -8.32)	-143.84	(-146.6, -141)

*C.I.: Confidence Interval (95%)

내 환자 수 역시 일일 확진자 수와 비슷한 결과를 나타내지만 일일 확진자의 누적 효과가 있기 때문에 상대적으로 수치가 크게 나타난다. 감소 폭의 변화를 세밀하게 들여다 보면 디텍트 레벨 증가에 따라 일일 확진자, 병원 내 환자 수가 기하급수적으로 감소하는 것을 확인할 수 있는데 이는 코로나19의 감염이 연쇄적으로 일어나는 것에서 기인한다고 예상할 수 있다. 주목할 점은 디텍트 레벨이 0%일 때와 20%일 때 통계적으로 평균 차이가 존재하지 않는다는 것인데 이는 감염자와 접촉한 사람을 잘 발견하지 못할 경우에는 안 찾는 것과 다름이 없다는 것을 의미한다. 다행히 본 연구의 시뮬레이션 모델 상 현재 우리나라는 51.4% 정도의 디텍트 레벨을 가지는 것으로 보여 접촉자 발견하는 활동이 확진자 발생을 억제하는 효과를 내고 있다고 여겨진다.

4.2 누적 사망자 수, 누적 완치자 수 및 최대 사용 병상 수 변화

누적 사망자 수는 시뮬레이션 종료 시까지 사망한 사람들의 수를 집계한 것이며 완치자 수는 코로나19에 걸

Table 7. Mean values changes of the cumulative dead, the cumulative recovered, and bed occupied

Detect Level	Cumulative death		Cumulative recovered		Maximum beds occupied	
	Mean	C.I.	Mean	C.I.	Mean	C.I.
0%	65.30	(53.03, 77.57)	11222	(9476, 12969)	554.8	(579.3, 580.3)
20%	65.80	(53.53, 78.07)	11030	(9284, 12777)	540.7	(515.2, 566.2)
40%	55.60	(43.33, 67.87)	9032	(7286, 10779)	496.4	(470.9, 521.9)
60%	50.50	(38.12, 62.77)	7244	(5498, 8991)	447.0	(421.5, 472.5)
80%	37.00	(24.73, 49.27)	5119	(3371, 6866)	377.3	(351.8, 402.8)
100%	9.30	(-2.97, 21.57)	1155	(-591, 2901)	234.80	(209.34, 260.26)

*C.I.: Confidence Interval (95%)

렸다가 치료된 사람을 의미한다. 누적 사망자 수와 완치자 수를 합산하면 감염되었던 사람의 수가 된다. 최대 사용 병상 수는 시뮬레이션 기간 내 병원 내 환자 수의 최대값으로 코로나19 상황에 대비하여 확보해야 하는 병상 수와 관련이 있다. 각 데이터들은 1회 시뮬레이션이 종료된 후에 수집 되므로 각각 총 10개 씩의 데이터를 수집하였다. Table 7은 누적 사망자 수, 누적 완치자 수 및 최대 필요 병상 수의 평균과 신뢰구간을 디택트 레벨에 따라 정리한 것이다.

누적 사망자 수와 완치자 수 및 최대 필요 병상 수도 일일 확진자 수와 병원 내 환자 수와 같은 양상을 보인다. 평균적으로 누적 사망자 수는 디택트 레벨이 0%일 때 65.30인데 비해 80%일 때는 37.00으로 거의 절반 수준으로 떨어지는 것을 확인할 수 있고 누적 완치자도 마찬가지로 디택트 레벨 0%일 때 11222이던 것이 80%일 때는 5119로 절반 이하로 떨어지는 것을 확인할 수 있다. 최대 사용 병상 수의 경우 평균값의 감소 비율이 누적 사망자수와 누적 완치자 수에 비해 낮기는 하지만 동일하게 감소하는 모습을 보이고 있다. 일일 확진자 수와 병원 내 환자 수와 동일하게 디택트 레벨 0%와 20%는 차이를 보이지 않고 있으며 디택트 레벨이 0%와 20% 일 때 누적 완치자 수를 볼 때 적극적으로 접촉자를 찾아내는 노력이 없을 경우 전체 인구의 50%가 넘는 비율이 코로나19에 감염되는 상황이 발생할 수 있다.

본 연구의 시뮬레이션은 하드웨어 제약으로 인해 전체 대한민국 인구 수를 2만으로 제한하였다. 이에 따라 감염의 전파가 실제에 비해서 상대적으로 빠르게 제한될 수 있다.

5. 결론

본 연구에서는 대한민국을 대상으로 접촉자 발견 수준(디택트 레벨)이 코로나19 감염 양상에 어떠한 영향을 주는 지 확인하기 위하여 에이전트 기반 시뮬레이션 모델을 개발하였다. 시뮬레이션 개발을 위해 일일 확진자 등 대한민국의 실증적인 데이터를 수집하였으며 이를 바탕으로 대한민국 상황을 반영한 시뮬레이션 모델을 개발하였다. 보다 실제 상황과 유사한 시뮬레이션 개발을 위해 대한민국을 6개 권역으로 나누고 권역간 교통량 데이터를 활용하여 감염 전파가 이루어지게 하였으며 여기에 정부의 통제 정책과 사람들의 순응도를 반영하였다. 개발된 시뮬레이션 모델은 일일 확진자 데이터를 통하여 유효성을 검증하였다. 개발된 시뮬레이션 모델을 가지고 디택트

레벨을 변화 시키면서 일일 확진자 수, 병원 내 환자 수, 누적 사망자 수, 누적 완치자 수, 최대 사용 병상 수의 변화를 살펴 보았고 디택트 레벨이 증가할수록 5가지 지표가 모두 기하급수적으로 감소하는 것을 확인하였다. 하지만 낮은 수준의 디택트 레벨(20%)은 접촉자를 찾지 않는 것과 차이없는 감염 양상을 보이는 것을 확인하였다. 따라서 코로나19 전파를 신속히 종료 시키고 그 피해를 최소화하기 위해서는 접촉자를 적극적으로 발견하고 감염이 확산되기 전에 격리시키는 일이 매우 중요할 것으로 보인다.

본 연구는 대한민국 인구를 2만명으로 상정하여 진행되었기 때문에 실제 코로나 전파 양상과 다소 차이가 존재할 수도 있다. 또한 집단 감염등의 상황을 고려하지 않았기 때문에 갑작스러운 확진자 발생을 표현하는데 제한적이다. 실제 코로나19 감염 전파 상황에서는 방역 활동에 적극적으로 반대하는 집단들이 존재했고 이들이 원인이 되어 감염자가 폭증하는 현상이 발생하였는데 이를 반영한다면 실제 감염 전파를 보다 세밀하게 반영한 시뮬레이션 모델을 개발할 수 있을 것으로 보인다. 분석면에 있어서도 본 연구는 디택트 레벨이 코로나19 전파에 어떠한 영향을 주는지에 대해서 다루고 있으나 거리두기 단계와 순응도가 확진자, 사망자 등의 지표에 어떠한 변화를 일으키는 지 연구하는 것도 본 연구의 좋은 확장이 될 수 있을 것으로 생각한다.

현재 우리나라는 크게 확진자와 접촉한 사람을 찾아내는 것, 바이러스 확산 수준에 맞춘 거리두기 단계 조정, 마스크 의무화로 코로나19의 확산을 통제한다. 본 연구에서 발견한 디택트 레벨에 따른 확진자 변화 양상이 코로나19를 통제하는 정책을 정하는데 도움이 될 것으로 판단한다.

References

- Abdollahi, E., M. Haworth-Brockman, Y. Keynan, J. M. Langley, and S. M. Moghadas, "Simulating the effect of school closure during COVID-19 outbreaks in Ontario, Canada", *BMC Medicine*, Vol.18 No. 1, 230, 2020.
- Annas, S., M. Isbar Pratama, M. Rifandi, W.Sanus, and S. Side, "Stability analysis and numerical simulation of SEIR model for pandemic COVID-19 spread in Indonesia", *Chaos, Solitons and Fractals*, Vol. 139, 110072, 2020.

- Choi, S. and M. Ki, “Analyzing the Effect of Social Distancing for Novel Coronavirus Disease 2019 (COVID-19) in South Korea”, *Epidemiology and Health*, Vol. 42, e2020064, 2020.
- Giacopelli, G. “A full-scale agent-based model of Lombardy COVID-19 dynamics to explore social networks connectivity and vaccine impact on epidemic” *MedRxiv*, 2020.
<https://doi.org/10.1101/2020.09.13.20193599>
- He, S., Y. Peng, and K. Sun, “SEIR modeling of the COVID-19 and its dynamics” *Nonlinear Dynamics*, Vol. 101, No. 3, pp 1667-1680, 2020.
- Hoertel, N., M. Blachier, C. Blanco, M. Olfson, M. Massetti, F. Limosin and H. Leleu, “Facing the COVID-19 epidemic in NYC: a stochastic agent-based model of various intervention strategies”, *MedRxiv*, 2020a <https://10.1101/2020.04.23.20076885>
- Hoertel, N., M. Blachier, C. Blanco, M. Olfson, M. Massetti, M. S. Rico, ... H. Leleu, “A stochastic agent-based model of the SARS-CoV-2 epidemic in France”, *Nature Medicine*, Vol. 26, No. 9, pp 1417-1421, 2020b.
- Lauer, S. A., K. H. Grantz, Q. Bi, F. K. Jones, Q. Zheng, H. R. Meredith, ... and J. Lessler, “The incubation period of coronavirus disease 2019 (CoVID-19) from publicly reported confirmed cases: Estimation and application”, *Annals of Internal Medicine*, Vol. 172, No. 9, pp 577-582, 2020.
- Pandey, G., P. Chaudhary, R. Gupta, and S. Pal, “SEIR and Regression Model based COVID-19 outbreak predictions in India”, ArXiv, 2020.
- Silva, P. C. L., P. V. C. Batista, H. S. Lima, M. A. Alves, F. G. Guimarães, and R. C. P. Silva, “COVID-ABS: An agent-based model of COVID-19 epidemic to simulate health and economic effects of social distancing interventions”, *Chaos, Solitons and Fractals*, Vol. 139, 110088, 2020.
- Tatapudi, H., R. Das, and T. K. Das, “Impact assessment of full and partial stay-at-home orders, face mask usage, and contact tracing: An agent-based simulation study of COVID-19 for an urban region”, *Global Epidemiology*, Vol. 2, 100036, 2020.
- Wallentin, G., D. Kaziyeva, and E Reibersdorfer-Adelsberger, “Covid-19 intervention scenarios for a long-term disease management”, *International Journal of Health Policy and Management*, Vol. 9, No. 12, pp 508-516, 2020.
- Wei, Y. Y., Z. Z. Lu, Z. C. Du, Z. J. Zhang, Y. Zhao, S. P. Shen, ... F. Chen, “Fitting and forecasting the trend of COVID-19 by SEIR(+CAQ) dynamic model”, *Zhonghua Liu Xing Bing Xue Za Zhi*, Vol. 41, No. 4, pp 470-475, 2020.
- WHO, retrieved from <https://covid19.who.int/> (visited at 28th Oct)
- Wolfram, C., “An Agent-Based Model of COVID-19”, *Complex Systems*, Vol. 29, pp 87-105, 2020.



이종성 (ORCID : <https://orcid.org/0000-0001-6013-4535> / js.lee@ut.ac.kr)

2005 POSTECH 산업경영공학과 공학사
 2015 POSTECH 산업경영공학과 공학박사 (석박사 통합)
 2015~ 2018 삼성전자 반도체 물류자동화 그룹 책임연구원
 2018~ 현재 한국교통대학교 산업경영공학과 조교수

관심분야 : 조합최적화, 시뮬레이션, 경로탐색