SIMULATION MODELLING AND DATA ANALYTICS FOR REAL-WORLD NETWORK PROCESSES

MUHAMMAD ALFAS ST

DEPARTMENT OF MECHANICAL ENGINEERING

INDIAN INSTITUTE OF TECHNOLOGY DELHI

MARCH 2026

© Indian Institute of Technology Delhi (IITD), New Delhi, 2026

SIMULATION MODELLING AND DATA ANALYTICS FOR REAL-WORLD NETWORK PROCESSES

by

MUHAMMAD ALFAS ST

Department of Mechanical Engineering

Submitted

in fulfillment of the requirements of the degree of **Doctor of Philosophy**

to the

INDIAN INSTITUTE OF TECHNOLOGY DELHI

March 2026

Dedicated to Uppachi and Umma

Certificate

This is to certify that the thesis entitled **"Simulation Modelling and Data Analytics for Real-World Network Processes"**, submitted by **Muhammad Alfas ST** to the Indian Institute of Technology Delhi, for the award of the degree of **Doctor of Philosophy** is a record of the original, bona fide research work carried out by him under my supervision and guidance. The thesis has reached the standards fulfilling the requirements of the regulations related to the award of the degree.

The results contained in this thesis have not been submitted in part or in full to any other University or Institute for the award of any degree or diploma to the best of our knowledge.

Prof. Shaurya Shriyam
Department of Mechanical Engineering,
Indian Institute of Technology Delhi.

Acknowledgements

First and foremost, I am deeply grateful to Allah for the resilience and perseverance that enabled me to complete the long PhD journey.

I am deeply grateful to my Uppachi and Umma for their unwavering support and trust. My deepest thanks go to my siblings, Aflah and Noorbina, for always standing by my plans and ideas. I'm equally thankful to my father-in-law and mother-in-law for their steadfast belief in me. To Shuaib, Asiya, Misab, and Ihthisham - thank you for the fun and support.

My special gratitude and love to Sumi, who came into my life mid-PhD and stood by me in all highs and lows. Also, love to Izzu, my endless source of joy and excitement.

I thank my supervisor, Prof. Shaurya Shriyam, for his invaluable guidance and brilliant ideas. I will always be grateful for all the knowledge and skills he taught me.

I am deeply grateful to Prof. Varun Ramamohan for his support and insightful feedback throughout my PhD journey. His innovative methodologies not only guided my research but also inspired me to continue in academia. I acknowledge my gratitude to other members of the research committee - Prof. Nomesh Bolia and Prof. Biplab Basak for the feedback and positive reinforcements.

I thank Prof. Sandeep Kumar, Prof. Amit Kumar, Prof. Amber Shrivastava, and Prof. Prashant Palker for all the discussions and guidance.

I am deeply grateful to my friends, juniors, seniors, and labmates: Prashant, Nidhin, Dvarkesh, Rajat, Ajmal, Nishanta, Soham, Najiya, Shoaib, Sarthak, Sri Harsha, Shivam, Adarsh, and Mohit, for their support, countless contributions, and the memorable moments we shared throughout this journey.

Muhammad Alfas ST

Abstract

Society consists of interconnected individuals, groups, and institutions, giving rise to complex phenomena like social norms, epidemics, and crowd flow. Network science offers a powerful framework to model these dynamics by capturing heterogeneity and interactions through nodes and edges. In this work, we explore epidemics and crowd flow through the lens of network science, examining both its strengths and limitations.

The first objective of this work is to explore the network representation for population dynamics and built spaces. From population dynamics, we mainly deal with epidemic models. But network epidemic models are found to be useful in other scenarios like opinion propagation, traffic congestion, and computer virus spreading. The built space model is intended for crowd flow modelling. So the second objective is to develop simulation models for epidemics and crowd flow based on these network models. While simulating a process, one major task is to calibrate the simulation parameters. Thus, we set our third objective to explore the simulation parameters. Sensitivity analyses and parameter estimation methods are studied from the network perspective. While studying epidemics and crowd flow or any network processes, one of the major applications is to control them, often using the allocation of resources. For our fourth objective, we explore resource allocation strategies. For epidemics, we consider testing kit allocation, and for crowd flow, the application is a facility layout planning problem. Studies often point out that network models are less scalable and require more computational resources. So for our final objective, we chose scalability studies for these applications.

We start with modelling epidemics on a network. The population under consideration is modelled as a contact network, and diseases spread through the network from individual to individual. The third chapter introduces two simulation methodologies for modeling epidemics using a contact network. We experiment with different types of network models and conduct exhaustive sensitivity analyses by varying epidemic parameters. To capture the dynamic nature of epidemics, we have computed the effective reproduction number. We then explore graph coarsening methods as a part of our scalability objective.

After the foundational epidemic modelling study, we focus on parameter estimation. Existing epidemic parameter estimation methods mostly follow Bayesian approaches and non-network methodologies. We employ graph neural networks along with network epidemiological models for parameter estimation. To improve the scalability of the approach, we explore graph reduction methods. We approach the parameter estimation method from the perspectives of classification and inference. We do experiments with different types of network models, and the performances are compared against existing approaches.

In the next chapter, we explore two strategies for testing kit allocation using multi-armed bandits. For epidemics, sequential allocation policies can incorporate findings from everyday data and can improve the allocation strategies. Bandit-based allocation does exactly that. The first strategy does prevalence computation using an empirical Bayesian approach, allocation using Thompson sampling and Gittins index, and integrates pooled testing to maximize the kit usage. The second strategy incorporates network models and makes use of graph neural networks to compute prevalence. Both methods are compared against selected benchmarks and proved to be efficient.

For the final chapter, we consider facility layout planning for an airport check-in area. For service systems like airports, crowd flow is a major decision factor. We develop a network representation model for facility layouts and propose a novel network-based simulator for crowd flow dynamics. A simulation-optimization framework is developed with this simulator and a genetic algorithm optimizer. Experiments are conducted using a real airport layout. Results prove the efficacy of the proposed methods.

We have explored the advantages of network approaches in epidemics and crowd flow modelling, and studied applications such as testing kit allocation and facility layout planning. These approaches are found to capture more granular details of the system. However, scalability remains the most critical factor that must be prioritised when planning for real-world scenarios. Overall, the findings highlight the potential of network-based methods to enhance both understanding and decision-making in complex spatial and epidemiological systems, provided that scalability challenges are adequately addressed.

सार

समाज आपस में जुड़े हुए व्यक्तियों, समूहों और संस्थाओं से मिलकर बना होता है, जिससे सामाजिक मानदंडों, महामारी फैलाव और भीड़ प्रवाह जैसे जटिल परिघटनाएं उत्पन्न होती हैं। नेटवर्क विज्ञान इन गतिशीलताओं को मॉडल करने के लिए एक सशक्त ढांचा प्रदान करता है, जो विषमता और अंतःक्रियाओं को नोड्स और एजेस के माध्यम से दर्शाता है। इस कार्य में, हम नेटवर्क विज्ञान के दृष्टिकोण से महामारी और भीड़ प्रवाह का अध्ययन करते हैं, तथा इसके लाभों और सीमाओं का मूल्यांकन करते हैं।

इस शोध का पहला उद्देश्य जनसंख्या गतिशीलता और निर्मित स्थानों के लिए नेटवर्क प्रतिनिधित्व का अन्वेषण करना है। जनसंख्या गतिशीलता के संदर्भ में, हम मुख्यतः महामारी मॉडल से संबंधित हैं। लेकिन नेटवर्क आधारित महामारी मॉडल अन्य परिदृश्यों में भी उपयोगी पाए गए हैं, जैसे कि मत–प्रचार, यातायात जाम, और कंप्यूटर वायरस का फैलाव। निर्मित स्थान मॉडल को भीड़ प्रवाह को मॉडल करने के लिए विकसित किया गया है। अतः हमारा दूसरा उद्देश्य नेटवर्क मॉडल के आधार पर महामारी और भीड़ प्रवाह के लिए सिमुलेशन मॉडल विकसित करना है। सिमुलेशन करते समय, एक प्रमुख कार्य होता है सिमुलेशन मापदंडों को कैलिब्रेट करना। हमारा तीसरा उद्देश्य इन्हीं सिमुलेशन मापदंडों का अध्ययन करना है। नेटवर्क के दृष्टिकोण से संवेदनशीलता विश्लेषण और मापदंड अनुमान विधियों का अध्ययन किया गया है। महामारी और भीड़ प्रवाह जैसी नेटवर्क प्रक्रियाओं का अध्ययन करते समय, इनका नियंत्रण करना एक प्रमुख अनुप्रयोग होता है, जिसमें अक्सर संसाधनों का आवंटन किया जाता है। हमारे चौथे उद्देश्य के अंतर्गत, हम संसाधन आवंटन रणनीतियों का अध्ययन करते हैं। महामारी के लिए हम परीक्षण किट के आवंटन पर ध्यान केंद्रित करते हैं, जबकि भीड़ प्रवाह के लिए इसे एक सुविधा–लेआउट योजना की समस्या के रूप में प्रस्तुत किया गया है। कई अध्ययनों में यह बताया गया है कि नेटवर्क मॉडल कम मापनीय होते हैं और अधिक संगणनात्मक संसाधनों की आवश्यकता होती है। अतः हमारे अंतिम उद्देश्य में, हम इन अनुप्रयोगों के लिए मापनीयता का विश्लेषण करते हैं।

हम नेटवर्क पर आधारित महामारी मॉडलिंग से शुरुआत करते हैं। विचाराधीन जनसंख्या को एक संपर्क नेटवर्क के रूप में मॉडल किया जाता है, और रोग इस नेटवर्क के माध्यम से व्यक्ति से व्यक्ति में फैलता है। पहले अध्याय में, हम संपर्क नेटवर्क पर आधारित महामारी मॉडलिंग के लिए दो सिमुलेशन विधियों का परिचय देते हैं। हम विभिन्न प्रकार के नेटवर्क मॉडलों के साथ प्रयोग करते हैं और महामारी मापदंडों को बदलते हुए व्यापक संवेदनशीलता विश्लेषण करते हैं। महामारी की गतिशील प्रकृति को पकड़ने के लिए, प्रभावी प्रजनन संख्या की गणना की गई है। इसके बाद, हम मापनीयता के उद्देश्य के अंतर्गत ग्राफ कोर्सनिंग विधियों का अन्वेषण करते हैं।

प्रारंभिक महामारी मॉडलिंग अध्ययन के बाद, हम मापदंड अनुमान की दिशा में आगे बढ़ते हैं। मौजूदा महामारी मापदंड अनुमान विधियाँ प्रायः बायेसियन दृष्टिकोण और गैर–नेटवर्क विधियों का अनुसरण करती हैं। हम नेटवर्क महामारी मॉडल के साथ ग्राफ न्यूरल नेटवर्क्स का उपयोग करके मापदंडों का अनुमान

लगाते हैं। इस पद्धति की मापनीयता बढ़ाने के लिए, ग्राफ रिडक्शन विधियों का अध्ययन किया गया है। हम वर्गीकरण और अनुमान दोनों दृष्टिकोणों से समस्या का समाधान करते हैं। विभिन्न नेटवर्क मॉडलों के साथ प्रयोग किए गए हैं, और उनके प्रदर्शन की तुलना मौजूदा विधियों से की गई है।

अगले अध्याय में, हम परीक्षण किट आवंटन के लिए मल्टी–आर्म्ड बैंडिट्स आधारित दो रणनीतियों का अध्ययन करते हैं। महामारी के परिदृश्य में, अनुक्रमिक आवंटन नीतियाँ प्रतिदिन के डेटा से सीख लेकर आवंटन में सुधार कर सकती हैं। बैंडिट–आधारित आवंटन इसी कार्य को कुशलता से करता है। पहली रणनीति एक अनुभवजन्य बायेसियन दृष्टिकोण से प्रिवेलेन्स की गणना करती है, थॉम्पसन सैम्पलिंग और गिटिंस इंडेक्स के माध्यम से आवंटन करती है, और किट उपयोग को अधिकतम करने के लिए पूल परीक्षण को एकीकृत करती है। दूसरी रणनीति नेटवर्क मॉडलों को शामिल करती है और प्रिवेलेन्स की गणना के लिए ग्राफ न्यूरल नेटवर्क्स का उपयोग करती है। दोनों विधियों की तुलना मानक विधियों से की गई है और इनकी दक्षता सिद्ध हुई है।

अंतिम अध्याय में, हम एक हवाईअड्डे के चेक–इन क्षेत्र के लिए सुविधा–लेआउट योजना की समस्या को प्रस्तुत करते हैं। हवाईअड्डों जैसे सेवा तंत्रों में, भीड़ प्रवाह एक प्रमुख निर्णय कारक होता है। हम सुविधा लेआउट के लिए नेटवर्क प्रतिनिधित्व मॉडल विकसित करते हैं और भीड़ प्रवाह की गतिशीलता के लिए एक नया नेटवर्क–आधारित सिमुलेटर प्रस्तावित करते हैं। इस सिमुलेटर और एक जेनेटिक एल्गो–रिदम ऑप्टिमाइज़र के साथ एक सिमुलेशन–ऑप्टिमाइज़ेशन ढांचा तैयार किया गया है। एक वास्तविक हवाईअड्डा लेआउट पर प्रयोग किए गए हैं। परिणामों से यह स्पष्ट होता है कि प्रस्तावित विधि कुशल है।

इस कार्य में, हमने महामारी और भीड़ प्रवाह मॉडलिंग में नेटवर्क आधारित दृष्टिकोणों के लाभों का अन्वेषण किया है, तथा परीक्षण किट आवंटन और सुविधा–लेआउट योजना जैसे अनुप्रयोगों का अध्ययन किया है। इन विधियों को प्रणाली के सूक्ष्म विवरणों को बेहतर तरीके से पकड़ने में सक्षम पाया गया है। हालांकि, मापनीयता अब भी एक प्रमुख चुनौती बनी हुई है, जिसे वास्तविक परिदृश्यों की योजना बनाते समय प्राथमिकता दी जानी चाहिए। कुल मिलाकर, इस शोध के निष्कर्ष यह दर्शाते हैं कि यदि मापनीयता से जुड़ी चुनौतियों का सही समाधान किया जाए, तो नेटवर्क आधारित विधियाँ जटिल स्थानिक और महामारी प्रणालियों में न केवल समझ, बल्कि निर्णय–निर्माण की गुणवत्ता को भी बेहतर बना सकती हैं।

Keywords: network modelling, epidemics, parameter estimation, network scalability, testing kit allocation, multi-armed bandits, pedestrian dynamics, airport simulation

Contents

Certificate **i**

Acknowledgements **iii**

Abstract **v**

Contents **ix**

List of Figures **xiii**

List of Tables **xv**

Abbreviations **xvii**

Symbols **xix**

1 Introduction **1**
1.1 Motivation 1
1.2 Research Themes 4
1.2.1 Network Models 5
1.2.2 Epidemics on Networks 8
1.2.3 Graph Neural Networks 10
1.2.4 Crowd Flow and Pedestrian Dynamics 15
1.3 Research Objectives 16
1.4 Thesis Organisation 17

2 Literature Review **19**
2.1 Network Epidemiology 19
2.2 Epidemic Parameter Estimation 22
2.3 Graph Neural Networks in Epidemiology 24
2.4 Resource Allocation in Epidemics 26
2.4.1 Testing Kit and Vaccine Allocation 26
2.4.2 Pooled Testing 28
2.5 Servicescape and Crowd Flow 29

2.5.1 Facility Layout Planning in Service Systems 29
2.5.2 Airport Systems Simulation 30
2.5.3 Network Pedestrian Simulation Models 32
2.6 Research Gaps 32

3 Epidemics on Networks: Simulation and Sensitivity Analysis 35
3.1 Introduction 35
3.2 Methodology 36
3.2.1 Epidemic Dynamics 38
3.2.2 Network Epidemiological Models 40
3.2.3 Network Generation Models 43
3.3 Simulation Experiments 48
3.4 Results and Discussion 49
3.4.1 Validation Using the Hagelloch Measles Data 67
3.5 Summary 69

4 Epidemic Parameter Estimation 71
4.1 Introduction 71
4.2 Problem Formulation 73
4.3 The GREPE Framework 74
4.3.1 Graph Reduction 76
4.3.1.1 Graph Sampling 76
4.3.1.2 Local Variational Neighbourhood (LVN) 77
4.3.1.3 Featured Graph Coarsening (FGC) 78
4.4 Simulation Experiments 80
4.5 Results and Discussions 82
4.5.1 Parameter Classification 82
4.5.2 Ablation Experiments 86
4.5.2.1 Removal of Features 87
4.5.2.2 Modification of Learning Modules 89
4.5.2.3 Fixing Parmeter Class 90
4.5.3 Explainability Quantification 91
4.5.4 Scalability Experiments 93
4.5.5 Parameter Inference 96
4.5.6 Validation on the Hagelloch Measles Outbreak Data 100
4.6 Summary 103

5 Resource Allocation for Epidemic Control 105
5.1 Introduction 105
5.2 Multi-Armed Bandit Allocation Framework 106
5.2.1 Data Collection 107
5.2.2 Prevalence Estimation 109

5.2.3 Bandit Allocation . . . 110
5.2.4 Pooled Testing . . . 112
5.3 Graph Neural Bandits Allocation Framework . . . 116
5.3.1 SEIAQRS Epidemic Model . . . 118
5.3.2 Graph Neural Thompson Sampling . . . 119
5.4 Simulation Experiments . . . 121
5.5 Results and Discussions . . . 124
5.5.1 MAB Allocation . . . 124
5.5.2 GNB Allocation . . . 128
5.6 Summary . . . 131

6 Layout Planning: Network Models and Pedestrian Dynamics 133
6.1 Introduction . . . 133
6.2 Simulation Optimization Framework . . . 134
6.2.1 Network-based Layout Representation . . . 136
6.2.2 Network-based Pedestrian Dynamics . . . 139
6.2.3 Social Force Model . . . 143
6.2.4 Layout Evaluation . . . 144
6.2.4.1 Passenger Experience Metrics . . . 145
6.2.4.2 Operational Efficiency metrics . . . 147
6.2.5 Genetic Algorithm . . . 148
6.3 Case Study: Bangalore Airport Terminals . . . 151
6.4 Summary . . . 154

7 Conclusions and Future Directions 155
7.1 Conclusions . . . 155
7.2 Research Contributions . . . 160
7.3 Policy Implications . . . 162
7.4 Limitations . . . 164
7.4.1 Role of Synthetic and Real-World Data . . . 167
7.5 Future Research Directions . . . 168

Glossary 171

References 177

List of Publications 211

Biography of Researcher 213

List of Figures

1.1 Visualization of network models 7
1.2 Schematic overview of the GNN architecture with pooling 15

3.1 Overview of epidemic dynamics simulation methodology. 37
3.2 SEIRS time series trajectories showing the population size in each compartment. 51
3.3 Comparison of ITP and NTP approaches for all network models. . . . 53
3.4 Heatmap for comparison of all six network models with respect to mutual information. 54
3.5 Comparison of effective reproduction number (R_t) over time for different network models. 54
3.6 Comparison of timeseries plots obtained from coarsened networks against those from the original network. 56
3.7 Disease spreading dynamics over the network for different network models 57
3.8 Temporal variation of mutual information between coarsened networks and original networks. 59
3.9 Effect of varying the value of β on disease spreading dynamics for all six network models 60
3.10 Effect of varying the recovery period ($\frac{1}{\gamma}$) on disease spreading dynamics for all six network models 61
3.11 Effect of varying the latent period ($\frac{1}{\sigma}$) on disease spreading dynamics for all six network models 63
3.12 Effect of varying the immunity period ($\frac{1}{\omega}$) on disease spreading dynamics for all six network models 64
3.13 Effect of varying the number of initial infections on disease spreading dynamics for all six network models 65
3.14 Comparison of runtime efficiency (in seconds) between ITP network model and NTP network model 66
3.15 Comparison of cumulative number of infections along with variability of three models along with observed data. 68

4.1 Workflow of the GREPE framework 74
4.2 Variation of time taken and accuracy convergence 94

4.3 Time taken for different modules of the GREPE pipeline for (a) different numbers of nodes, (b) different time horizons. 96
4.4 Parameter inference results 99
4.5 Hagelloch validation comparison 101

5.1 Schematic overview of the the MAB allocation process 107
5.2 GNB Allocation Architecture 117
5.3 SEIAQRS state transtions. 119
5.4 Effect of parameters D and q on detection rate 124
5.5 Comparison of undetected cases with detected. 125
5.6 Daily detection rate for ten allocation strategies 126
5.7 Effect of prevalence on detecting positive cases 127
5.8 Detection performance for 65-city dataset 128
5.9 Comparison of GNB Allocation strategies 129
5.10 Comparison of allocation strategies on SNAP networks 129

6.1 Original BLR Terminal layouts 135
6.2 Simulation-optimization framework 136
6.3 Development of LayoutNet 138
6.4 NetPDSim overview 140

List of Tables

3.1 List of parameters and values 48
3.2 Average values of major network summary statistics for the networks generated for analysis in this paper 50
3.3 Mutual information between the time series of the fraction of infected individuals in the original and coarsened network models. 58
3.4 Comparison of runtime efficiency (in seconds) between ITP network model, NTP network model, and ODE-based compartmental model . 66

4.1 Parameter classes for classification problem 81
4.2 Accuracy scores for parameter classification experiments 83
4.3 Comparison of average accuracy of GraphCL model with the supervised GNN models. 87
4.4 Accuracy scores for ablation experiments based on feature removal . . 88
4.5 Accuracy scores for module-centric ablation experiments 89
4.6 Accuracy scores for fixed-parameter experiments 91
4.7 Explainability scores of every feature 92
4.8 Accuracy scores after retaining only one feature 93
4.9 Time taken for graph reduction 95
4.10 R^2 scores for parameter inference 97
4.11 $NRMSE$ scores for Parameter Inference 98
4.12 Quantitative comparison of GrepeFlow variants on the Hagelloch outbreak 102

5.1 Comparison of MAB allocation strategies 125
5.2 GNB allocation results from SBM network 130
5.3 Performance comparison of different strategies in SNAP networks. . . 130

6.1 Comparison of layout metrics between the original layout and the optimized layout of BLR T1 152
6.2 Comparison of layout metrics between the original layout and the optimized layout of BLR T2 153

Abbreviations

ABM	**A**gent **B**ased **M**odelling
BA	**B**arabási–**A**lbert
BA-AT	**B**arabási–**A**lbert with **A**ging and **T**riads
BA-C	**B**arabási–**A**lbert **C**ommunity
BB	**B**eta **B**inomial
BLR T1	**B**angalore **I**nternational **A**irport **T**erminal 1
CA	**C**ellular **A**utomata
cINN	**C**onditional **I**nvertible **N**eural **N**etwork
CL-SF	**C**hung–**L**u **S**cale–**F**ree
CV	**C**omputer **V**ision
DES	**D**iscrete **E**vent **S**imulation
DS	**D**iffusion **S**ampling
ER	**E**rdős–**R**ényi
ERGM	**E**xponential **R**andom **G**raph **M**odel
FGC	**F**eatured **G**raph **C**oarsening
FFS	**F**orest **F**ire **S**ampling
FLP	**F**acility **L**ayout **P**lanning
GA	**G**enetic **A**lgorithm
GAT	**G**raph **A**ttention **N**etworks
GIN	**G**raph **I**somorphism **N**etwork
GI	**G**ittins **I**ndex
GNB	**G**raph **N**eural **B**andit
GNN	**G**raph **N**eural **N**etwork
GNTS	**G**raph **N**eural **T**hompson **S**ampling
GP	**G**amma **P**oisson
GREPE	**G**raph **R**eduction-enabled **E**pidemiological **P**arameter **E**stimation

GR	**G**ilbert **R**andom
GCN	**G**raph **C**onvolutional **N**etworks
IATA	**I**nternational **A**ir **T**ransport **A**ssociation
ITP	**I**ncremental **T**ime **P**rogression
LSTM	**L**ong **S**hort–**T**erm **M**emory
LVN	**L**ocal **V**ariational **N**eighborhood
MAB	**M**ulti **A**rmed **B**andit
MI	**M**utual **I**nformation
ML	**M**achine **L**earning
MSGNN)	**M**ulti-scale **S**patio-temporal **G**raph **N**eural **Network**
NRMSE	**N**ormalized **R**oot **M**ean **S**quared **E**rror
NTP	**N**ext–**E**vent **T**ime **P**rogression
OE	**O**perational **E**fficiency
ODE	**O**rdinary **D**ifferential **E**quation
PE	**P**assenger **E**xperience
RWS	**R**andom **W**alk **S**ampling
SBM	**S**tochastic **B**lock **M**odel
SEIRS	**S**usceptible–**E**xposed–**I**nfected–**R**ecovered–**S**usceptible
SFLP	**S**ervice **F**acility **L**ayout **P**lanning
SFM	**S**ocial **F**orce **M**odel
SIR	**S**usceptible–**I**nfected–**R**ecovered
STAN	**S**patio-**T**emporal **A**ttention **N**etwork
SW-TL	**S**mall–**W**orld with **T**riangular **L**attice
TS	**T**hompson **S**ampling
WS	**W**atts–**S**trogatz

Symbols

β	Transmission rate
γ	Recovery rate
σ	Rate of progression from exposed to infected (inverse of latency period)
ω	Rate of waning immunity (inverse of immunity period)
R_0	Basic reproduction number
R_t	Effective reproduction number at time t
G	Graph representing the network
V	Set of nodes (individuals or spaces) in the graph
E	Set of edges (connections) in the graph
T	Total simulation time
S	Number of susceptible individuals
E	Number of exposed individuals (infected but not yet infectious)
I	Number of infectious individuals
I_0	Number of initially infectious individuals
R	Number of recovered (and immune) individuals
θ	Model parameters
Θ	Graph Laplacian matrix
X	Node features
$\mathcal{L}$	Loss function
C	Mapping matrix
ρ	Prevalence rate
δ	Test positivity rate
$\mathcal{S}$	Score function
$\mathcal{A}$	Set of agents (agent list)
$\vec{F}$	Force vector