COVID Information Commons (CIC) Research Lightning Talk

Transcript of a Presentation by Leila Hedayatifar (New England Complex Systems Institute)
October 10, 2023

Title: Effects of preventive protocols in COVID spread, an agent-based framework

Leila Hedayatifar CIC Database Profile

NSF Award #: 2032536

YouTube Recording with Slides

Fall 2023 CIC Webinar Information

Transcript Editor: Shikhar Johri

Transcript

स्लाइड *1*

ठीक है, सभी को नमस्कार, यह मेरी खुशी है कि मैं इस वेबिनार में यहां हूं। हां, पिछला वेबिनार एक साल से अधिक समय पहले था और यह उन परिणामों पर था जो हमें पहली परियोजना के लिए मिले थे जो हमने एनएसएफ-प्रदत्त परियोजना के लिए किया था। यह एक नई दिशा है जिससे हम गुजर रहे हैं। यहां, मैं उस अध्ययन और जांच को प्रस्तुत करने जा रहा हूं जो हमने एजेंट-आधारित ढांचे का उपयोग करके COVID में निवारक प्रोटोकॉल के प्रभावों की जांच करने के लिए किया था।

स्लाइड 2

सबसे पहले, मैं इस बारे में बात करना चाहता हूं कि हम महामारी मॉडल का अध्ययन क्यों करते हैं। महामारी मॉडल हमें यह समझने में मदद करते हैं कि संक्रामक रोग एक समाज के माध्यम से कैसे फैलता है। ये मॉडल हमें विभिन्न कारकों के बारे में अंतर्दृष्टि प्रदान करते हैं जो प्रभावी सार्वजनिक स्वास्थ्य हस्तक्षेप विकसित करने के लिए महत्वपूर्ण हैं। वे हमें एक महामारी के संभावित प्रभाव के बारे में भविष्यवाणियां करने और टीकाकरण, सोशल डिस्टेंसिंग, यात्रा प्रतिबंध और अन्य रोकथाम जैसे हस्तक्षेपों की प्रभावशीलता का आकलन करने में मदद करने की भी अनुमति देते हैं। इसके अलावा, नीति निर्माता साक्ष्य-आधारित नीतियों और दिशानिर्देशों को तैयार करने के लिए महामारी मॉडल पर भरोसा करते हैं। सबसे महत्वपूर्ण चीजों में से एक यह है कि सरलीकृत महामारी मॉडल को जनता के साथ साझा करने से रोग संचरण की गतिशीलता की समझ बढ़ सकती है। जनता के लिए, कुछ बहुत ही सरल, समझ में आता है।

स्लाइड 3

हमारे दिमाग में जो विचार थे, उनके आधार पर हमने Net Logo में एक मॉडल डेवलप किया। नेट लोगो एक बहु-एजेंट मॉडलिंग वातावरण और प्रोग्रामिंग भाषा है जिसे जटिल प्रणालियों और मॉडलिंग एजेंट

आधारित ढांचे का अनुकरण करने के लिए डिज़ाइन किया गया है। यह आपको पूरे मॉडल के लिए एक आंकड़ा रखने की अनुमति देता है जिसे आप विकसित कर रहे हैं और पैरामीटर सेट कर रहे हैं। आप उनके लिए अलग-अलग स्थितियों पर विचार कर सकते हैं, जैसे स्लाइडर या स्विच ऑन और ऑफ आइकन।

स्लाइड 4

यह आपको ऐसे प्लॉट और आंकड़े रखने की भी अनुमति देता है जो आपको दिखाते हैं कि समय के साथ मॉडल कैसे विकसित हो रहा है, जिसमें समय के साथ मॉडल के विभिन्न डिब्बे कैसे बदल रहे हैं। मैं इन आंकड़ों के बारे में बाद में बात करूंगा।

स्लाइड 5

अब, मैं उस मॉडल के विभिन्न हिस्सों से गुजरने जा रहा हूं जिसे हमने विकसित किया है - एक एजेंट आधारित मॉडल। यह गतिशीलता को निर्दिष्ट करता है जिसके द्वारा एजेंटों की आबादी बातचीत में संलग्न होती है और पूरे समय विकास से गुजरती है। इसलिए हमारे पास एजेंटों का एक नेटवर्क है जो एक दूसरे से जुड़े हुए हैं और हम अपने नेटवर्क में इन एजेंटों या व्यक्तियों के लिए विभिन्न मापदंडों और विशेषताओं पर विचार करते हैं। पहला कनेक्शन है। ये कनेक्शन एक नेटवर्क का प्रतिनिधित्व करते हैं। हमारे पास संख्याओं, नोड्स या एजेंटों का एक सेट है और फिर हमारे पास औसत नोड डिग्री है जो प्रत्येक नोड के कनेक्शन का प्रतिनिधित्व करती है। हमने उस औसत संख्या के आधार पर विभिन्न नोड्स को एक दूसरे से जोड़ा। फिर, हम नोड्स को स्थानांतरित करते हैं और उन नोड्स को डालते हैं जो वे एक दूसरे के करीब से जुड़े होते हैं। यह प्रत्येक व्यक्ति के लिए स्थानीय कनेक्शन का अनुकरण करता है। फिर, उस पर, हम लंबी दूरी के कनेक्शन बनाते हैं जो अनुकरण करते हैं यदि लोग किसी अन्य स्थान की यात्रा करते हैं या यदि वे किसी भिन्न स्थान पर जाते हैं और उन लोगों के साथ संबंध बनाते हैं जो आमतौर पर उनके करीब नहीं होते हैं। फिर, हम आयु और लिंग जैसे जनसांख्यिकीय मापदंडों पर विचार करते हैं। उम्र और लिंग के लिए, हमारे पास विकल्प है कि यदि आप मॉडल में उन प्रभावों पर विचार करना चाहते हैं, यदि आप आयु वितरण पर विचार करना चाहते हैं, या चाहते हैं कि यह एक यादृच्छिक वितरण हो, या आप अमेरिकी आयु जनसंख्या वितरण का उपयोग करना चाहते हैं, जो जनगणना से खींचा गया है। हम जनसंख्या की आयु सीमा या पुरुष से महिला प्रतिशत की जांच करने में सक्षम हैं। यह हमें विभिन्न वातावरणों का अनुकरण करने की अनुमति देता है, जो उन दिलचस्प चीजों में से एक था जिनका हम अध्ययन करना चाहते थे। दूसरा स्वास्थ्य जोखिम स्तर है। हमने चार अलग-अलग स्वास्थ्य जोखिमों पर विचार किया: जो लोग 65 वर्ष से अधिक उम्र के हैं, गर्भवती महिलाएं और कुछ स्वास्थ्य स्थितियों या गंभीर स्वास्थ्य स्थितियों वाले लोग। मॉडल के लिए यह परिभाषित करना संभव है कि हम अपने सिमुलेशन में कितने मामले रखना चाहते हैं और हम देखते हैं कि मॉडल में क्या होता है।

स्लाइड 6

फिर, हम एसआईआर मॉडल लागू करते हैं। यह एक मौलिक महामारी विज्ञान मॉडल है जो संक्रामक रोग के प्रसार को समझने और विश्लेषण करने के लिए उपयोग किए जाने वाले कुछ अंतर समीकरणों पर आधारित है। इसके तीन अलग-अलग डिब्बे हैं: ऐसे व्यक्ति जो बीमारी के लिए अतिसंवेदनशील हैं, लेकिन अभी तक संक्रमित नहीं हुए हैं, ऐसे व्यक्ति जो वर्तमान में बीमारी से संक्रमित हैं और बीमारी को अन्य लोगों में फैलाने में सक्षम हैं, और ऐसे व्यक्ति जो बीमारी से संक्रमित थे और बरामद हुए थे और अब हैं समय की अवधि के लिए आगे संक्रमण के लिए प्रतिरक्षित। हमारे पास उनके लिए मापदंड हैं। सबसे पहले, प्रारंभिक संक्रमित मामले जो बीमारी के प्रसार की शुरुआत की गारंटी देते थे। फिर, हमारे पास COVID होने की संभावना है, जो COVID के संचरण की संभावना है। इसे कोविड के अलग-अलग वेरिएंट के आधार पर बदला जा सकता है। हमारे पास समय की संक्रमण अवधि और समय की प्रतिरक्षा अवधि है। हमारे पास रोगसूचक मामलों और स्पर्शोन्मुख मामलों के लिए पैरामीटर हैं, जिसमें सक्रिय अवधि भी शामिल है

कि वे बीमारी को प्रसारित कर सकते हैं। हमारे पास रोगसूचक मामलों के लिए वितरण भी है। दूसरा पैरामीटर जो हमारे लिए महत्वपूर्ण था, वह था लॉन्ग COVID। हम इसका अध्ययन करने में सक्षम होना चाहते थे या नहीं। यह सिर्फ एक सीमा के आधार पर माना जाता है, उस सीमा के बाद यदि उनके पास अभी भी लक्षण हैं, तो उन्हें लॉन्ग COVID माना जाएगा। और मामलों का एक छोटा सा हिस्सा सुपर इम्यून था - यह बहुत छोटा है, लेकिन जैसा कि मॉडल और डेटा में बताया गया था, हमने इसे मॉडल में माना।

स्लाइड 7

निवारक प्रोटोकॉल एहतियाती तरीके हैं जो लोग किसी बीमारी के प्रसार को रोकने में मदद करते हैं। COVID के लिए हमारे पास जो थे, उनमें मास्क पहनना, सोशल डिस्टेंसिंग या बीमार लोगों को क्वारंटाइन करना और टीकाकरण भी शामिल था। इन निवारक मॉडलों के लिए, हमने मापदंडों के दो अलग-अलग सेटों पर विचार किया: एहतियाती प्रतिशत, जो इस बात से संबंधित है कि लोग कैसे व्यवहार करते हैं, और टीकाकरण प्रतिशत। टीकाकरण के लिए, हमने विचार किया कि क्या हम मॉडल में टीकाकरण करना चाहते हैं या नहीं। क्या यह टीकाकरण करने वाले लोगों का प्रतिशत होना चाहिए, टीकाकरण की दक्षता, टीकाकरण की दक्षता में क्षय, और टीकाकरण प्राथमिकता भी (इसने हमें उन लोगों का टीकाकरण शुरू करने की अनुमति दी जो उच्च जोखिम वाले स्तर पर हैं)।

स्लाइड 8

कम्पार्टमेंट मॉडल, हमारे मॉडलिंग में, इस प्रकार के मॉडल हमें एक विशिष्ट स्थिति में एजेंट रखने की अनुमति देते हैं और हम समय के साथ प्रत्येक डिब्बे में एजेंटों की संख्या को ट्रैक कर सकते हैं। यदि हम सेटअप पर क्लिक करते हैं, तो हमारे पास परिभाषित औसत कनेक्शन, लंबी दूरी के कनेक्शन और अन्य विशेषताओं के साथ नोड्स का एक सेट होगा जो मैंने पिछली स्लाइड्स में समझाया था। फिर, प्रत्येक समय बिंदु पर, मॉडल एजेंटों की स्थिति की जांच करता है और अपने पड़ोसियों की पिछली स्थिति के आधार पर उस स्थिति को अपडेट करता है। फिर, मॉडल को चलाकर, हम देख सकते हैं कि मॉडल के विभिन्न डिब्बे सिस्टम में, मॉडल में, समय के साथ कैसे बदल रहे हैं। इसके अलावा, कुछ अन्य माप हैं जो हम कर सकते हैं। उदाहरण के लिए, हम मॉडल में फिर से संक्रमित एजेंटों की संख्या में रुचि रखते थे। कितनी बार, कितने नोड्स, या कितने प्रतिशत नोड्स फिर से संक्रमित होते हैं? हम उत्पादकता भी जानना चाहते थे। उत्पादकता की गणना स्पर्शोन्मुख मामलों के आधार पर की जाती है - वे उस समय के दौरान उत्पादक नहीं होते हैं जब वे रोगसूचक होते हैं। हम उन लोगों के प्रतिशत की गणना कर रहे हैं जिनके लक्षण हैं।

स्लाइड 9

इन सभी चीजों को मैंने अब तक समझाया है और नेट लोगो में मॉडल हमें मॉडल के माध्यम से जाने, मापदंडों के साथ खेलने और यह देखने की अनुमति देता है कि विभिन्न पैरामीटर या निवारक नीतियां सिस्टम के व्यवहार को कैसे बदल सकती हैं। स्थिति कैसे बदलती है और सिस्टम के विभिन्न डिब्बे कैसे बदलते हैं। लेकिन अगर आप सिस्टम के औसत व्यवहार को देखना चाहते हैं, तो हमें कई अहसास करने की जरूरत है। इसके लिए, हमें मापदंडों के एक ही सेट के साथ कई अहसासों का एक पहनावा बनाने की आवश्यकता है। उसके आधार पर, हम सिस्टम के औसत व्यवहार का विश्लेषण कर सकते हैं और मॉडल के विभिन्न संभावित परिणामों का पता लगा सकते हैं। यहां, मैं आपको मॉडल चलाते समय उपयोग किए जाने वाले पैरामीटर्स का एक सेटअप दिखाने जा रहा हूं। हम अलग-अलग स्थितियों को देखने जा रहे हैं क्योंकि हमारे पास अलग-अलग यादृच्छिकता है। हमारे पास मॉडल में कुछ यादृच्छिकता है और समय के साथ यादृच्छिकता सिस्टम के व्यवहार को बदल सकती है।

स्लाइड 10

हमने कुछ अहसास किए। मापदंडों के किसी भी सेट के लिए - यहां मैं आपको कुछ परिणाम दिखाने जा रहा हूं जो हमें अपने मॉडल के आधार पर मिले हैं। इनमें से प्रत्येक आंकड़े के लिए और प्रत्येक बिंदु के लिए हम मॉडल को 100 बार चलाते हैं। हमने उन रनों में से प्रत्येक के लिए औसत गणना की। मेरे पास यहां चार आंकड़े हैं और मैं थोड़े समय में इन चार आंकड़ों को समझाने की कोशिश करूंगा। x-अक्ष संचरण की संभावना का प्रतिनिधित्व करता है, जो COVID होने की संभावना है। एक्स-अक्ष पर, हमारे पास प्रति नोड संक्रमण की औसत संख्या है। इससे पता चलता है कि वे कितनी बार संक्रमित हुए। कलर बार महामारी की औसत अवधि का प्रतिनिधित्व करता है और हम कितनी बार कोड चलाते हैं। कौड का स्टॉप टाइम वह समय है जब हमारे पास मॉडल में कोई संक्रमित मामले या प्रतिरक्षा मामले नहीं हैं। यह ग्राफ औसत नोड डिग्री का प्रतिनिधित्व करता है - महामारी की शुरुआत में, यदि आपको याद है, तो नीति निर्माताओं ने लोगों को अपने कनेक्शन को कम करने, अन्य लोगों के साथ अपने कनेक्शन को कम करने के लिए मनाने की कोशिश की। यहां, हम दिखाते हैं कि कनेक्शन के उच्च डिग्री से कनेक्शन के निम्न डिग्री तक जाकर, आप देख सकते हैं कि संचरण की कम संभावनाओं के साथ कनेक्शन की उच्च डिग्री में भी, बीमारी सिस्टम में बहुत तेजी से फैलने वाली है। संक्रमण की औसत संख्या लगभग एक है, जिसका अर्थ है कि अधिकांश मामलों में संक्रमण बहुत तेजी से दिखाई देता है, बहुत कम समय में। लेकिन जैसे-जैसे कनेक्शन कम होते हैं, हम देखते हैं कि उच्च संभावनाओं में बदलाव आया है कि बीमारी नहीं फैलेगी - बीमारी के लिए समय लगता है और हमारे पास कई पुन: संक्रमण होते हैं, ऐसे मामले जहां लोग फिर से संक्रमित हो जाते हैं। बहुत कम डिग्री में, यहां तक कि प्रसारण की बहुत अधिक संभावना के लिए, मॉडल के लिए रन टाइम कुछ मामलों के साथ भी अधिक होता है जहां फिर से संक्रमण होते हैं। इसलिए जब हम कनेक्शन कम करते हैं तो अधिक समय लगता है। बीमारी को समाज में फैलने और फिर पुन: प्रसारित करने में अधिक समय लगता है।

स्लाइड 11

लंबी दूरी के कनेक्शन के लिए, फिर से, हम देखते हैं कि जब हम 0% लंबी दूरी के कनेक्शन से 20% लंबी दूरी के कनेक्शन तक जाते हैं, तो व्यवहार बदल जाता है। आप देख सकते हैं कि, फिर से, हमारे पास प्रसारण की संभावना में बदलाव है। जब हमारे पास बहुत लंबी दूरी के कनेक्शन होते हैं, तो कम समय के लिए भी यात्रा करते हैं, बीमारी तेजी से फैलने वाली है। लेकिन जब हम लंबी दूरी के कनेक्शन को खत्म कर देते हैं, तो बीमारी को फैलने में अधिक समय लगता है और फिर से संक्रमण के मामले कम होते हैं।

स्लाइड 12

यहाँ, मैं y-अक्ष में औसत अवधि दिखा रहा हूँ। सावधानियों के लिए, हम 0% से 100% तक चले गए। आप देखते हैं कि जब एहतियात शून्य होता है, यहां तक कि संचरण की कम संभावना के साथ, हमारे पास महामारी की अवधि में एक चरम है। समाज में इसे प्रसारित करने में लंबा समय लगता है और संक्रमण की उच्च दर होती है। हालाँकि, जैसा कि हम उच्च एहतियाती स्तरों पर जाते हैं, जैसे कि हम यहाँ देखते हैं जहाँ एहतियात 100% है, सभी मामले संक्रमित नहीं होते हैं और बीमारी का प्रसार जल्दी रुक जाता है।

स्लाइड 13

यह आंकड़ा टीकाकरण प्रतिशत के परिणामों का प्रतिनिधित्व करता है। आप देख सकते हैं कि एक छोटे टीकाकरण प्रतिशत के साथ भी, हम मामलों की संख्या और महामारी की अवधि में एक बड़ा बदलाव देखते हैं। उच्च संभावनाओं के लिए, भी, समय बदल रहा है, जो बहुत महत्वपूर्ण है क्योंकि शुरुआत में - याद रखें कि ये टीकाकरण तीन महीने बाद शुरू हुए थे - इसलिए हमें यह देखने में दिलचस्पी थी कि यह अन्य

स्थितियों को कैसे प्रभावित करने वाला है। मैंने इसे यहां नहीं दिखाया, लेकिन आप देख सकते हैं कि छोटे बदलाव भी बहुत अंतर कर सकते हैं।

स्लाइड 14

इसलिए, निष्कर्ष में, मैं कह सकता हूं कि हमारा मॉडल एक आबादी के भीतर एक वायरस के प्रसार को दर्शाता है, कई प्रारंभिक संक्रमित मामलों पर विचार करता है और क्या यह पूरी आबादी में फैल सकता है या कुछ व्यक्तियों को संक्रमित करने से पहले निहित हो सकता है। और उन आंकड़ों के आधार पर, मैं कह सकता हूं कि स्थानीय और लंबी दूरी के कनेक्शन दोनों को कम करना, औसतन, बीमारी के तेजी से प्रसार के लिए एक निवारक के रूप में कार्य करता है। एहतियाती और टीकाकरण नीतियों के कार्यान्वयन से न केवल बीमारी के प्रसार में कमी आती है, बल्कि पुन: संक्रमण की संभावना भी कम होती है। ये इस कार्य के कुछ परिणाम हैं, जो अभी भी प्रगति पर हैं। हमें भविष्य में कई और परिणाम मिलने वाले हैं।

स्लाइड 15-16

मैं इस काम में अपने सहयोगियों को स्वीकार करना चाहता हूं। सुनने के लिए धन्यवाद।