

[Centro de Información de COVID \(CIC\): Charlas científicas relámpago](#)

Transcripción de una presentación de Ajitesh Srivastava (Universidad del Sur de California) y Viktor K Prasanna (Universidad del Sur de California), septiembre de 2020



[Perfil de Viktor K. Prasanna en la base de datos del CIC](#)

Título: [Predicciones precisas y asignación de recursos para la respuesta a la pandemia COVID-19](#)

[Subvención de La Fundación Nacional de Ciencias \(NSF, por sus siglas en inglés\): #: 2027524](#)

[Grabación de YouTube con diapositivas](#)

[Seminario web del CIC de Septiembre 2020](#)

Editor de la transcripción: Brian Buckley

Traducción: Isabella Graham Martínez

Transcripción

Katie Naum:

Eso nos lleva a nuestro orador final Ajitesh Srivastava de la Universidad de California. Ajitesh, puedes compartir cuando estés listo.

Ajitesh Srivastava:

Diapositiva 1

Muy bien, gracias. Espero que puedan ver mi pantalla. Bien. Mi nombre es Ajitesh Srivastava. Soy el coinvestigador de esta subvención: Recuperar: Predicciones detalladas precisas y asignación de recursos para la respuesta a la epidemia de COVID-19.

Diapositiva 2

Los objetivos de este proyecto son los siguientes: pronósticos precisos de COVID-19 en varios niveles, incluso para varios países, para el nivel estatal, el nivel nacional y los pronósticos detallados como el nivel del vecindario. Nos gustaría incorporar la identificación basada en datos de una serie de casos no reportados que no se observan realmente, pero que afectan significativamente a los pronósticos a largo plazo, y finalmente, cómo utilizar estos pronósticos de manera efectiva para la gestión de recursos durante la pandemia.

Esto es lo que hemos logrado hasta ahora. Tenemos un pronóstico preciso de COVID-19. En pocos segundos, podemos realizar entrenamiento y predicciones para 3.000 condados en menos

de 30 segundos. Proporcionamos garantías de fiabilidad sobre los factores no observados. Por ejemplo, cuánto subregistro está pasando. En algunos casos, podemos identificar ese número y podemos garantizar matemáticamente que ese número está cerca de la verdad.

Tenemos una interfaz web y un repositorio de Github disponibles al público y también ofrecemos evaluaciones semanales que comparan nuestro enfoque con los modelos que utiliza actualmente el CDC. Estamos proporcionando nuestro caso y pronósticos de muerte al CDC, que incluye el nivel nacional de EE.UU. semanal, el nivel estatal y el nivel del condado. Estos se utilizarán para informar al público y para la selección de los lugares de las pruebas de vacunación.

También estamos proporcionando nuestras previsiones para desarrollar modelos conjuntos a UMass centro de predicción y a KIT, donde estamos proporcionando previsiones nacionales y estatales de Alemania. Aquí están las publicaciones: dos de ellas están preimpresas y una de ellas ha sido aceptada en la conferencia de KDD.

Diapositiva 3

Por lo tanto, la idea central que afirmamos aquí es que un modelo no es suficiente. Simplemente tener un modelo que es complejo no es suficiente. Pronosticar requiere tomar decisiones con respecto a qué estrategia de aprendizaje usas, qué tipo de procesamiento previo de datos usas, qué eliges como parámetros, qué decides tener como hiperparámetros. Todas estas decisiones pueden afectar significativamente sus resultados de pronóstico.

Con eso en mente, nos gustaría tener un modelo que capture varias complejidades y, sin embargo, preferimos enfoques de aprendizaje simples para evitar el sobreajuste para que sepamos que lo que estamos aprendiendo está realmente cerca de la verdad, y que y queremos comprobar matemáticamente la capacidad de aprendizaje - ¿Si lo que estamos afirmando que tenemos - se ajustaba a los datos del pasado? ¿O realmente aprendió algo? Y nos gustaría tener una ejecución rápida para permitir el análisis de escenarios. Usted puede leer este documento para entender cómo empezamos desde un modelo complejo y simplificarlo en un modelo matemáticamente equivalente que es fácil de aprender.

Diapositiva 4

Así que un aspecto central de nuestro trabajo es abordar la capacidad de aprendizaje. A pesar de las simplificaciones, una ecuación en nuestro modelo todavía no es lineal. Así que siempre podemos ajustar sus datos a cualquier modelo, pero ¿refleja la verdad? Porque puede haber múltiples soluciones. Por ejemplo, aquí para el factor de subregistro, se ven cuatro curvas. Todos estos cuatro modelos de una manera, se ajustan a los datos del pasado muy bien, pero conducen a resultados significativamente diferentes. Entonces, ¿cómo sabes cuál de estas cuatro curvas refleja la verdad? Por lo tanto, demostramos que este factor de subregistro se puede aprender confiablemente de los datos sólo bajo ciertas condiciones y los detalles de esto están en el documento.

Diapositiva 5

Tenemos una visualización en línea donde se pueden realizar pronósticos de forma interactiva y también se puede ver varios escenarios de dónde vamos y qué pasaría si ponemos nuestro mejor esfuerzo vs. qué pasaría si ponemos nuestro peor esfuerzo donde podríamos estar en unas pocas semanas a partir de ahora.

Diapositiva 6

En nuestra página, también proporcionamos comparaciones de nuestro enfoque con otros enfoques de los CDC y hemos estado consistentemente en los dos primeros, los tres primeros entre unos 25 modelos que se están utilizando actualmente.

Diapositiva 7

Otro trabajo relevante que estamos considerando es aprender confiablemente los efectos de varias pólizas. También estamos interesados en realizar, resolviendo algunos problemas de asignación de recursos ahora que tenemos pronósticos precisos. Entonces, ¿cómo asignamos los EPP o cómo decidimos dónde deberían realizarse las pruebas a través del mapa y dónde deberíamos tener sitios de vacunación?

Y con eso, terminaré mi charla. Gracias.