
Investigación Operativa

Operations Research Helps Public Health Services Managers Planning Resources in the COVID-19 Crisis

Daniel García-Vicuña, Marta Cildoz, Martín Gastón-Romeo,
Cristina Azcarate, Fermín Mallor

Instituto de Smart Cities
Universidad Pública de Navarra

✉ daniel.garciadevicuna@unavarra.es, ✉ marta.cildoz@unavarra.es,
✉ martin.gaston@unavarra.es, ✉ cazcarate@unavarra.es, ✉ mallor@unavarra.es

Laida Esparza

Departamento de Medicina Intensiva
Complejo Hospitalario de Navarra

✉ lesparza@navarra.es

Abstract

This article presents the usefulness of operational research models to support the decision-making in management problems on the COVID-19 pandemic. The work describes a discrete event simulation model combined with population growth models, which has been used to provide daily predictions of the needs of ward and intensive care unit beds during the COVID-19 outbreak in the Autonomous Community of Navarre, in Spain. This work also discusses the use of the simulation model in non-acute phases of the pandemic to support decision-making during the return to the normal operation of health services or as a resource management learning tool for health logistic planners.

Keywords: Bed occupancy, Gompertz growth model, Hospital resources planning, Simulation in healthcare.

AMS Subject classifications: 90B90, 37M05.

1. Introducción

La pandemia causada por el virus SARS-CoV-2 se ha convertido en la más letal para la población mundial de los últimos 100 años. Según la página web de la Universidad Johns Hopkins University (<https://coronavirus.jhu.edu/map.html>) a fecha 13 de julio, el número de personas infectadas a nivel mundial rondaba los trece millones y el de fallecidos por COVID-19 excedía el medio millón. Desde su inicio en China y su posterior transmisión a Europa, se ha realizado un enorme esfuerzo de modelado matemático y epidemiológico para representar la transmisión y difusión de la enfermedad en la población. Entre los modelos epidemiológicos destacan los denominados tipo SEIR [5], que clasifican a la población en susceptibles, expuestos, infectados y recuperados y que fueron aplicados en España desde el inicio de la pandemia, por ejemplo, por el Grupo de investigación MUNQU (Modelling Uncertainty Quantification, <http://covid19.webs.upv.es>) de la Universitat Politècnica de València. Una extensión de este modelo [2], mediante la consideración de más compartimentos y la clasificación de la población en tres tramos de edad, permitió a los autores recomendar el 21 de marzo, mediante carta dirigida al Gobierno de España, el confinamiento total de la población y el endurecimiento de medidas restrictivas de movilidad para evitar el colapso de la sanidad pública.

Estos modelos epidemiológicos, mediante la generación de distintos escenarios, han demostrado su utilidad para la evaluación de la eficacia de distintas medidas de distanciamiento social, restricciones de movilidad, aplicación de test y rastreo de contactos en la expansión del virus. Sin embargo, su aplicación para la predicción de la evolución de la pandemia en una determinada región a corto plazo presenta la dificultad de necesitar el conocimiento de un conjunto numeroso de parámetros que modelen la transición entre compartimentos y de la distribución de la población entre los distintos compartimentos en el instante inicial del estudio. Por otro lado, los servicios de salud necesitan conocer, además de la prevalencia e incidencia de la pandemia en la población, la cantidad de recursos críticos necesarios para proporcionar atención médica a los pacientes en el futuro más inmediato. La disposición de tales previsiones facilita la planificación de dichos recursos, como pueden ser las camas hospitalarias, las camas de Unidades de Cuidados Intensivos (UCI), personal médico y equipamiento médico especializado. Es en esta labor de previsión de los recursos necesarios donde la investigación operativa puede prestar una gran ayuda a los responsables de la planificación y de la logística hospitalaria. En este artículo relatamos el apoyo prestado por un grupo de investigadores de la Universidad Pública de Navarra (grupo q-UPHS, www.unavarra.es/quphs) a las autoridades sanitarias navarras proporcionando predicciones diarias sobre las camas hospitalarias y de UCI utilizando modelos de simulación en combinación con modelos de crecimiento de poblaciones, para efectuar la simulación de nuevas hospitalizaciones diarias

futuras.

En el siguiente apartado revisamos brevemente la literatura sobre modelos de simulación utilizados en salud y señalamos las características propias que debe incorporar un modelo utilizado para la predicción. El modelo de simulación de nuevas hospitalizaciones a partir de curvas de crecimiento de poblaciones y su integración en un modelo de simulación de eventos discretos se presenta en la Sección 3. La Sección 4 incluye predicciones del modelo proporcionadas a las autoridades sanitarias y esboza la utilidad de estos modelos de simulación en fases no agudas de la pandemia para ayudar a la toma de decisiones durante la fase de retorno a la operación habitual de los servicios de salud o como herramienta de aprendizaje de gestión. En la Sección 5 se presenta la contribución de los modelos de la Investigación Operativa al análisis de distintos problemas asociados a la gestión de una pandemia. En la Sección 6 se discute de modo más general el papel de la Investigación Operativa en la mejora y sostenibilidad de los Servicios de Salud (importante reto de la sociedad para los próximos años).

2. Simulación en salud

La simulación es una herramienta matemática ampliamente utilizada para abordar complejos problemas de gestión de recursos sanitarios, caracterizados por recursos humanos y materiales limitados y su funcionamiento en contextos de variabilidad e incertidumbre.

Fetter y Thompson publicaron en 1965 el primer artículo relacionado con el uso de la simulación en un ámbito hospitalario [8]. Desde entonces, numerosos trabajos han utilizado la simulación para abordar diferentes problemas relacionados con el flujo de pacientes, la gestión de listas de espera, el dimensionado del número de camas y de otros recursos, el diseño de centros de salud, la localización de recursos sanitarios, la planificación de personal sanitario, el impacto de intervenciones médicas, etc. Estos trabajos se aplican en diferentes escalas, considerando desde departamentos únicos como son los servicios de urgencias, quirófanos, UCIs, etc., hasta el análisis de servicios nacionales o regionales de salud, pasando por centros hospitalarios o ambulatorios. La literatura ofrece numerosos artículos de revisión sobre la aplicación de la simulación en contexto sanitario [4, 12, 14, 16, 18, 22]. Estos trabajos revisan y clasifican las publicaciones considerando diferentes aspectos como los objetivos del estudio, el tipo de aplicación, las especificaciones del modelado y de los datos de entrada, el tipo de simulación empleado, el software utilizado para su implementación, el tipo de medidas de funcionamiento que evalúa el modelo de simulación, etc. Otro aspecto que discuten algunos artículos de revisión es el impacto real de estos trabajos, observándose el bajo porcentaje de aplicación práctica real de los resultados obtenidos con estos modelos de simulación [4], cuestión ésta que debe llamar a la reflexión de los investigadores del área.

Una característica general de los modelos de simulación reportados en la literatura es que su foco se encuentra en el estudio a largo plazo del funcionamiento del sistema de salud (estado estacionario), como soporte para la toma de decisiones de tipo estratégico en relación con el dimensionamiento de recursos y para la evaluación de diferentes políticas de gestión. Así, en estos estudios la simulación comienza representando el sistema en un estado inicial (generalmente vacío) y el modelo evoluciona en el tiempo desechando los resultados observados en el periodo inicial (llamado periodo de calentamiento) por estar influenciado por la situación de partida. Los resultados de la simulación resumen los datos registrados del comportamiento del sistema en el largo plazo y permiten comparar el impacto de diferentes escenarios y de distintas estrategias de gestión. Un ejemplo de esta situación sería el análisis mediante simulación del número de camas necesarias en una UCI hospitalaria. La simulación también se utiliza en el estudio de sistemas en periodos cortos de tiempo, por ejemplo, para analizar la programación de quirófanos durante una semana. En este caso la situación inicial del sistema es conocida (todos los quirófanos disponibles al inicio de la simulación) y, por tanto, no influye en los resultados del análisis. Sin embargo, la utilización de un modelo de simulación, en tiempos de pandemia, para la predicción del número de camas UCI en el futuro próximo, debe partir de una representación fidedigna del estado de ocupación del sistema hospitalario en el momento presente y de la reproducción precisa de su dinámica hasta su abandono del sistema, ya que el estado de ocupación en el futuro depende tanto de la evolución de los pacientes actualmente ingresados como de los hospitalizados en el futuro cercano. Por otro lado, la simulación de las hospitalizaciones futuras se basa en modelos estocásticos que se ajustan a los datos recientemente observados de expansión de la pandemia y de hospitalizaciones y se reajustan cada vez que se observa un nuevo dato.

La utilidad de distintos modelos de simulación (sistemas dinámicos, eventos discretos, agentes) para la toma de decisiones en problemas derivados de la pandemia COVID-19 ha sido expuesta por Currie et al. en [6]. Sin embargo, las publicaciones que aplican modelos de simulación para abordar problemas de gestión de recursos sanitarios en el contexto de esta pandemia son muy escasas, y a diferencia de este trabajo, ninguna de ellas utiliza la simulación como herramienta de predicción. Así, por ejemplo, en [7] se utiliza un modelo de simulación para analizar el impacto en el funcionamiento de un centro ambulatorio para endoscopias de la incorporación de nuevos protocolos de actuación debidos a la COVID-19 (test y otras pruebas de control para los pacientes, previas a la realización de la endoscopia y medidas de distanciamiento en la sala de espera). En [9] se estudia un servicio de transporte médico aéreo y por carretera en Australia. Los autores proponen un modelo de simulación de eventos discretos para analizar diferentes escenarios de demanda originada por el tipo de pacientes que

habitualmente atiende este servicio y por los potenciales pacientes debidos a la COVID-19, estudiando el tiempo de respuesta del servicio para distintos niveles de recursos. En [13], el autor propone un modelo de simulación para estudiar el impacto de la epidemia en el funcionamiento de las cadenas de suministro globales. El trabajo define y analiza diferentes escenarios del efecto de la epidemia en los mercados internacionales concluyendo que los resultados del estudio permitirán desarrollar planes de gestión de la cadena de suministros para futuras pandemias.

En el contexto de UCIs, los trabajos publicados construyen modelos de simulación de eventos discretos para la evaluación del funcionamiento de estas unidades bajo diferentes escenarios, como herramienta de aprendizaje para la gestión de camas y para la evaluación del impacto de diferentes tipos de intervenciones, como soporte de ayuda a la toma de decisiones estratégicas en respuesta a esta y otras futuras pandemias. En [1] suponen la suspensión de llegadas de pacientes de cirugías programadas y consideran dos tipos de pacientes (los pacientes urgentes y los pacientes COVID-19). La simulación permite estimar el porcentaje de pacientes de cada tipo derivados a otros centros por falta de camas y la tasa de ocupación UCI para varios escenarios definidos a partir de diferentes tasas de llegadas de pacientes COVID-19, tiempos de estancia y tamaños de UCIs. Implementan el modelo en una librería de R con acceso libre (<https://andres-alban.shinyapps.io/icu-covid-sim/>). En [20] se consideran siete escenarios construidos a partir de la combinación de diferentes estrategias de intervención social (aislamiento, cuarentena y distancia social), distintos números de camas en UCI (45, 76 y 100) y diferentes tiempos medios de estancia en UCI (6 y 8 días). La simulación permite comparar estos escenarios estimando diferentes medidas de funcionamiento, como el número de días con ocupación total de la UCI y el número de defunciones derivadas de la capacidad de la UCI. Analizan también el número de camas que se necesitarían para satisfacer toda la demanda. El modelo, programado en R, está hospedado en <https://github.com/nhs-bnssg-analytics>.

3. Modelo de simulación para la predicción de recursos

3.1. Modelo de simulación de eventos discretos

El modelo de simulación reproduce el flujo de pacientes representado en la Figura 1. Cuando un paciente de COVID-19 requiere hospitalización, ésta se puede producir en la planta del hospital o directamente en la UCI. Los pacientes ingresados en planta pueden experimentar un empeoramiento de la salud y necesitar su ingreso en UCI al cabo de cierto tiempo. Los pacientes ingresados en la UCI pueden recuperarse y volver a planta o empeorar y fallecer. También, los pacientes ingresados en planta pueden abandonar el hospital bien por

fallecimiento o por mejoría de su salud. Los parámetros y distribuciones de probabilidad necesarias para el modelado del flujo de pacientes son los siguientes:

- h_i : llegada de pacientes COVID-19 el día i .
- p_{U_0} : probabilidad de que un paciente ingrese directamente en la UCI.
- p_{U_1} : probabilidad de que un paciente ingresado en planta sea transferido a la UCI.
- W : distribución de probabilidad del tiempo de transición de planta a UCI.
- p_H : probabilidad de que un paciente en UCI sea transferido a planta.
- Y_H : distribución de probabilidad del tiempo de transición de UCI a planta.
- Y_M : distribución de probabilidad del tiempo hasta el fallecimiento en UCI.
- p_{1_R} : probabilidad de que un paciente en planta sea dado de alta por mejoría.
- X_{1_R} : distribución de probabilidad del tiempo hasta el alta por mejoría desde planta (sin paso por UCI).
- X_{1_M} : distribución de probabilidad del tiempo hasta el fallecimiento en planta (sin paso por UCI).
- p_{2_R} : probabilidad de que un paciente en planta, tras pasar por UCI, sea dado de alta por mejoría.
- X_{2_R} : distribución de probabilidad del tiempo hasta el alta por mejoría desde planta, tras el paso por UCI.
- X_{2_M} : distribución de probabilidad del tiempo hasta el fallecimiento en planta, tras el paso por UCI.

3.2. Estimación de parámetros y distribuciones

Proceso de llegada de pacientes

La simulación de la llegada diaria de pacientes se realizó a partir de una curva de crecimiento de poblaciones tipo Gompertz [24] debido a su sencillez desde un punto de vista paramétrico y de su utilización en situaciones similares.

El modelo Gompertz admite distintas parametrizaciones, entre ellas la siguiente:

$$H(t) = H_T \exp(-\ln(H_T/H_0) \exp(-c(t-t_0))) \quad (3.1)$$

donde,




Figura 1: Flujo de los pacientes COVID-19 por el sistema hospitalario.

- $H(t)$ es el número acumulado de hospitalizaciones hasta el tiempo t .
- H_T es un parámetro que representa el número total de pacientes hospitalizados a la finalización del episodio de pandemia.
- c es otro parámetro que representa la tasa inicial de crecimiento de la población.
- H_0 representa el número de pacientes hospitalizados en el tiempo t_0 .

Esta curva posee un crecimiento inicial de tipo exponencial que gradualmente se va atenuando, para obtenerse finalmente una forma de tipo logístico para la curva. La Figura 2 muestra el ajuste Gompertz a los datos de pacientes hospitalizados en Navarra, mientras que en la Figura 3 podemos observar el ajuste a las personas diagnosticadas con COVID-19 en España, Italia, Alemania y Francia.




Figura 2: Curva de los pacientes hospitalizados acumulados en Navarra desde el 29 de febrero hasta el 12 de mayo. Se comparan los datos reales con el ajuste obtenido con el modelo Gompertz.

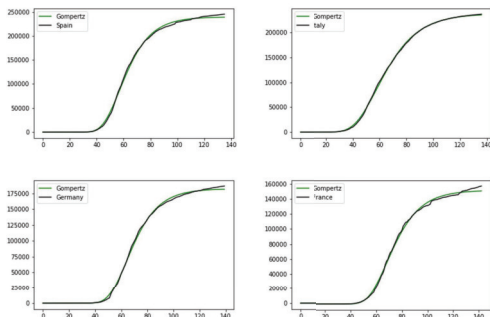


Figura 3: Curvas de los casos positivos acumulados de COVID-19 en España, Italia, Alemania y Francia desde que empezó la pandemia en cada país hasta el 15 de junio. Se compara la curva real de casos con el ajuste que proporciona el modelo Gompertz.

La estimación de los parámetros puede realizarse por mínimos cuadrados, siempre que se disponga de suficientes datos. Para ello, pueden utilizarse el paquete *growthrates* de R, o la función *curve_fit()* del módulo de optimización SciPy de Python.

La simulación de nuevas hospitalizaciones en el día i -ésimo, h_i , se realiza muestreando una distribución de Poisson con media igual a $H(t_i) - H(t_{i-1})$, donde t_i representa el tiempo 24h. del día i -ésimo.

Al inicio de la pandemia, los métodos de optimización proporcionan resultados muy inestables, o no alcanzan un óptimo. En estos casos, la estimación de la curva se realizó fijando el parámetro H_T , a partir de la estimación de la prevalencia final de la enfermedad en la población y aplicando un factor de hospitalización para los casos graves. Por ejemplo, en Navarra que cuenta con una población de 650.000 habitantes, al inicio de la pandemia se barajaban porcentajes de población infectada en torno al 1%-2% y un factor de hospitalización alrededor del 35 %, lo que arrojaba valores para H_T en el rango de 2.275-4.550. A fecha 12 de mayo, se han contabilizado un total de 1.704 pacientes hospitalizados por COVID-19.

Una vez fijado H_T el resto de parámetros se puede estimar por mínimos cuadrados, incluso al inicio de la pandemia con escasez de datos. La Figura 4 muestra la estimación realizada el 26 de marzo fijando el valor de H_T en 2.000. Se compara el ajuste con los datos registrados hasta ese instante y los valores posteriormente observados. El punto de color rojo denominado SSP (Simulation

Starting Point), indica el momento a partir del cual se realizaron las predicciones.




Figura 4: Curva de los pacientes hospitalizados acumulados en Navarra desde el 29 de febrero hasta el 12 de mayo. Se comparan los datos reales con el ajuste realizado el 26 de marzo, en el que se fijó el parámetro H_T en 2.000 para el ajuste de la curva.

Distribuciones de probabilidad de los tiempos de estancia

Las distribuciones de probabilidad de las distintas variables de estancia en el hospital representadas en la Figura 1 se obtuvieron mediante distintos procedimientos, dependiendo de la fase de la pandemia y la disponibilidad de datos. Durante el periodo inicial de la pandemia (hasta el 20 de marzo aproximadamente) el modelo de simulación utilizaba distribuciones de probabilidad triangulares, en las que los tres parámetros de la distribución fueron fijados a partir de la opinión de médicos expertos que habían revisado valores publicados en la literatura describiendo la situación en Italia y China [10, 11, 21, 23]. Cuando hubo suficientes datos recogidos en los registros administrativos hospitalarios, las distribuciones triangulares se sustituyeron por distribuciones de probabilidad con sus parámetros estimados por máxima verosimilitud. Un factor importante en la estimación de los parámetros es la fuerte censura de los datos a lo largo de toda la pandemia, ya que la mayoría de los pacientes COVID-19 todavía seguían ingresados en el momento de realizar los análisis. Esta censura era más extrema en el caso de pacientes ingresados en la UCI. En general, las familias Weibull y lognormal mostraron los mejores ajustes a los datos. En la Figura 5 se muestra un ejemplo del ajuste a la distribución Weibull de los datos del tiempo de estancia en el hospital antes de ir a la UCI a fecha 28 de marzo, utilizando la herramienta Minitab.

Las probabilidades que determinan el recorrido del paciente por el hospital,




Figura 5: Análisis del conjunto de datos de tiempo de estancia en hospital hasta ingresar en UCI a fecha 28 de marzo. Muestran un buen ajuste a una distribución Weibull, con parámetros de forma y escala de 1,80187 y 3,97003 respectivamente.

como el porcentaje de pacientes que precisa de UCI, fueron estimadas también, inicialmente, a partir de valores obtenidos de la literatura, para posteriormente ser estimados a partir de los datos.

Como se ha señalado en la introducción, una de las principales características que distingue un modelo de simulación utilizado con fines de predicción de otros desarrollados con fines de análisis de tipo estratégico es la necesidad de partir de una representación precisa del estado del sistema en el presente y evolucionar con realismo el resto de su transición por el sistema hospitalario. Para estimar el tiempo restante de un paciente en su fase de hospitalización actual (por ejemplo, tiempo hasta el alta desde planta) se utiliza la distribución de probabilidad condicional de la correspondiente variable T condicionada por un valor de estancia mayor a x , el tiempo que ya ha pasado el paciente en dicha fase. Una vez que un valor t es muestreado de esa distribución condicional, el tiempo restante hasta finalizar la fase de hospitalización actual es $t - x$ (que es el evento en el que dicho paciente cambiará su estado en el sistema hospitalario). La determinación de la probabilidad de ingreso en UCI desde planta, al igual que el resto de probabilidades necesarias del modelo, hace también uso del teorema de Bayes para su cálculo: si un paciente lleva t unidades de tiempo ingresado en planta, entonces la probabilidad de ser transferido a UCI es

$$p_{UCI|t} = P(B|X > t) = \frac{P(X > t|B) P(B)}{P(X > t)} \quad (3.2)$$

donde B es el evento de que el paciente ingresado en planta necesite UCI.

4. Utilización durante la pandemia

4.1. Integración del simulador en el proceso de toma de decisiones

El modelo de simulación y su implementación computacional ha constituido una aplicación de éxito de la investigación operativa, dado que las predicciones proporcionadas fueron utilizadas en la toma de decisiones sobre la preparación de recursos necesarios para atender a los pacientes COVID-19, fundamentalmente camas de hospital y de UCI. Los responsables de la logística hospitalaria deseaban conocer las necesidades en un horizonte temporal de una semana, tiempo suficiente para la preparación y despliegue de hospitales de campaña y adecuación de otras instalaciones para recibir pacientes. Por ello, aunque los errores de las predicciones se incrementan considerablemente al extender el horizonte temporal, estos eran razonables en horizontes temporales de hasta una semana. Así, el simulador proporciona unos valores objetivos sobre los que argumentar la toma de decisiones evitando de este modo la arbitrariedad en la planificación de recursos. En la Figura 6 se muestra la predicción realizada el día 16 de marzo para la ocupación de camas UCI. En la parte derecha de la imagen se observa cómo la ocupación real de camas permanece entre el percentil 5 (P5) y el 95 (P95) durante prácticamente los 20 días siguientes al SSP. En las gráficas se ha incluido también la línea que marca el percentil 50 (P50).




Figura 6: Predicción de la ocupación de camas de UCI necesarias para pacientes con COVID-19 realizada el 16 de marzo. La parte derecha muestra un zoom de los primeros 20 días de la predicción.

La utilización del simulador para la predicción a corto plazo requiere, como se ha indicado en la Sección 2, conocer exactamente cómo se encuentra el sistema hospitalario en el momento de arrancar la simulación. Con esta información, además de definir el estado inicial del modelo de simulación, se reajustan las

estimaciones de los parámetros de las distribuciones de probabilidad y de las probabilidades de ramificación que determinan el flujo de pacientes. El Gobierno de Navarra preparó a inicios de marzo una estructura de recogida de la información capaz de proporcionar cada mañana a las 9:00 la información completa que describe el estado del sistema hospitalario de toda la Comunidad Autónoma una hora antes, 8:00. En este sistema de información intervienen el Departamento de Sistemas y Tecnologías para la Salud del Gobierno de Navarra, encargado de almacenar, organizar y replicar la información de salud (representado como sistemas operacionales en la Figura 7) y la Unidad de Gestión del Dato del Complejo Hospitalario de Navarra, encargada de tratar la información recibida desde Gobierno de Navarra y de preparar diariamente el fichero de datos de hospitalización. Dicha unidad, además de preparar los ficheros de datos, también elabora informes, que integran nuestras predicciones, que son enviados a la gerencia del hospital, a la Consejería de Salud y a los responsables políticos de la Comunidad.




Figura 7: Flujo diario de datos, información e informes.

Esta colaboración tuvo su inicio el 12 de marzo de 2020, cuando la dirección del Complejo Hospitalario de Navarra contactó con el grupo de investigación q-UPHS preguntando acerca de la posibilidad de realizar previsiones de recursos necesarios. El día 16 de marzo presentamos el primer prototipo del simulador ante los responsables de la gestión hospitalaria y de la Consejería de Salud, que dieron por buena la herramienta y se comprometieron a facilitar los datos necesarios para su ejecución. Ese mismo día 16 se efectuaron las primeras previsiones utilizando las distribuciones triangulares y estimaciones de los parámetros a partir de valores publicados en la literatura. Se ejecutaron numerosos escenarios para ver en cuáles de ellos las capacidades existentes eran suficientes y en qué situaciones se debían preparar recursos adicionales y en qué cantidad. En los informes diarios, se evaluaban estos escenarios, en los que se indicaba expresamente el número máximo de camas que se iban a ocupar, así como el día en el que se producía. Las Tablas 1 y 2 muestran los resultados obtenidos el día 27 de marzo en los análisis del hospital y la UCI respectivamente. Finalmente,

tanto en el hospital como en la UCI, la ocupación máxima de camas se produjo el 1 de abril con 669 y 81 camas respectivamente (en la UCI el pico se extendió hasta el 5 de abril, día que había 80 camas ocupadas).

Tabla 1: Resultados sobre la ocupación máxima en el hospital, obtenidos el 27 de marzo. Se evaluaron diferentes escenarios, ajustando la curva de casos positivos (escenarios 1-6) y de hospitalización (escenarios 7-9).

Escenario	Nº total de positivos	Porcentaje de hospitalización	Ocupación máxima de camas	Día del pico
1	4.875	35 %	636-713	05-04
2	4.875	40 %	689-767	06-04
3	6.500	35 %	732-822	09-04
4	6.500	40 %	807-897	10-04
5	8.125	35 %	819-922	12-04
6	8.125	40 %	926-1.032	14-04
Escenario	Nº total de hospitalizados	Porcentaje de hospitalización	Ocupación máxima de camas	Día del pico
7	1.600	100 %	669-737	03-04
8	1.800	100 %	710-789	04-04
9	2.000	100 %	743-836	05-04

Tabla 2: Resultados sobre la ocupación máxima en la UCI, obtenidos el 27 de marzo. El porcentaje 7,5 % se ha introducido a posteriori, debido al cambio brusco que presentó este valor a finales de marzo (ver Sección 4.2).

Escenario	Nº total de hospitalizados	Porcentaje de hospitalización	Ocupación máxima de camas	Día del pico
1	1.600	15 %	109-143	08-04
2	1.800	15 %	118-156	07-04
3	2.000	15 %	128-166	09-04
4	1.600	7,5 %	68-92	05-04
5	1.800	7,5 %	71-100	07-04
6	2.000	7,5 %	75-103	07-04

Una vez superado el primer pico de la pandemia el grupo de investigación proporcionó soporte mediante un sistema de vigilancia para la detección temprana de rebrotes, que se describe brevemente en la siguiente sección, y ha estado mejorando el modelo de simulación por si es necesaria su utilización en una futura epidemia. Aun así, con el simulador presentado se obtienen muy buenas

predicciones, incluso a largo plazo, una vez superado el pico de ocupación, tal y como se muestra en la Figura 8.




Figura 8: Predicción de la ocupación de camas necesarias tanto de hospital como de UCI para pacientes con COVID-19 realizada el 4 de abril.

4.2. Aspectos prácticos en la aplicación del modelo de simulación

La situación de emergencia sanitaria a principios de marzo impuso la necesidad de concebir un método para previsión de los recursos que estuviera operativo en pocos días y que pudiera aplicarse de un modo razonable con la información disponible en aquellos momentos. Por ello, inicialmente, se diseñó e implementó computacionalmente una versión simplificada del modelo de simulación expuesto en las secciones anteriores, que requería menos información para su ejecución. El modelo estimaba las camas de hospitalización y de UCI de forma separada a través de dos submodelos, de acuerdo al flujo de pacientes representado en la Figura 9. El modelo de hospital únicamente precisa determinar el flujo de hospitalizaciones diarias y determinar una distribución de probabilidad para la estancia en el hospital. No se diferenciaba el tiempo de estancia según tipo de desenlace (recuperación o muerte), ni trayectoria por el hospital (necesidad de UCI o no). El modelo para camas de UCI era un poco más complejo, ya que consideraba el ingreso directo de pacientes o bien posterior a su paso por planta hospitalaria. Sin embargo, tampoco se distinguía el tiempo de estancia de acuerdo al desenlace, ni se efectuaba seguimiento al paciente una vez dado de alta si éste era ingresado en el hospital.

En ambos casos, al igual que en el modelo completo, la entrada de pacientes se simula utilizando el modelo de crecimiento poblacional Gompertz. Sin embargo, el modelo de simulación ofrecía distintas formas de utilizar el modelo Gompertz para finalmente simular el flujo diario de hospitalizaciones. En los

primeros días de la pandemia, el número de hospitalizaciones era pequeño y presentaba gran variabilidad, sobre todo en ámbitos geográficos pequeños como el navarro tal y como se recoge en la Tabla 3. Por ello, se propusieron dos métodos indirectos de estimación de las hospitalizaciones. En el primero, una curva de crecimiento Gompertz se ajusta a la serie de nuevos contagios (que cuenta con más datos y es más estable), la cual se utiliza para la previsión y simulación de nuevos contagios, que son transformados en hospitalizaciones aplicando un *factor de hospitalización*. Al inicio de la pandemia dicho *factor de hospitalización* se fijó en torno al 35%-40% para hospitalización en planta y de un 3% para hospitalización en UCI. El segundo método propone el ajuste de nuevos casos de contagios en un ámbito geográfico superior, por ejemplo, en España, y a partir de las previsiones de nuevos casos, aplicar dos factores de re-escalamiento para obtener los ingresos hospitalarios, un *factor geográfico*, que pondera el peso de Navarra en el conjunto de España (un 1,3%) y el anterior *factor de hospitalización*.

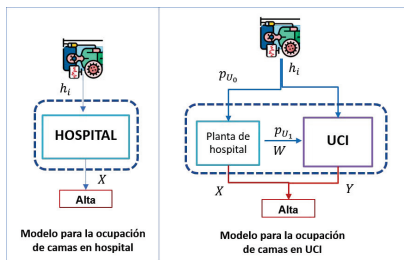


Figura 9: Diagrama de flujo de pacientes simplificado.

Una dificultad añadida a la escasez de datos para estimar los modelos estocásticos que determinan el flujo de pacientes a través del hospital es el cambio de protocolos clínicos y terapéuticos para la atención de los pacientes, fruto de las investigaciones sobre la COVID-19 publicadas en la literatura médica como de la propia experiencia adquirida por los profesionales sanitarios del tratamiento de sus pacientes. Este conocimiento adicional ha repercutido positivamente en los pronósticos de los pacientes, reflejándose en estancias más cortas de los pacientes y en una decreciente tasa de ingreso en UCI debido a la aplicación de mejores procedimientos para la estabilización de pacientes. Esta dificultad se mitiga mediante la actualización diaria de la estimación de distribuciones de probabilidad, incluyendo todos los datos disponibles hasta el día anterior. En situaciones de cambio moderado y continuo, esta actualización diaria puede ser suficiente para adaptar el modelo a la realidad. Sin embargo, a finales de

Tabla 3: Serie histórica de las hospitalizaciones diarias y acumuladas en Navarra hasta el 19 de marzo.

Fecha	Ingresos diarios	Ingresos acumulados	Fecha	Ingresos diarios	Ingresos acumulados
29/02/2020	0	0	10/03/2020	8	17
01/03/2020	2	2	11/03/2020	6	23
02/03/2020	1	3	12/03/2020	12	35
03/03/2020	0	3	13/03/2020	10	45
04/03/2020	0	3	14/03/2020	8	53
05/03/2020	2	5	15/03/2020	25	78
06/03/2020	0	5	16/03/2020	18	96
07/03/2020	1	6	17/03/2020	33	129
08/03/2020	0	6	18/03/2020	43	172
09/03/2020	3	9	19/03/2020	40	212

marzo se produjo un cambio brusco en el porcentaje de pacientes ingresados en UCI, pasando en unos días de niveles del 10 % a niveles del 5 %. Esta reducción en un 50 % de la hospitalización en UCI, ocurrida además en el momento de mayor intensidad de la pandemia, ocasionó la provisión de resultados sesgados al alza que se corrigieron al cabo de unos días, cuando se dispusieron de datos suficientes para corregir a la baja el porcentaje de pacientes ingresados en UCI.

4.3. Utilidades adicionales del modelo de simulación

Programación de la actividad del servicio de salud. La pandemia de la COVID-19 ha requerido la utilización de todos los recursos disponibles de los servicios hospitalarios, ocasionando la cancelación de la actividad habitual de muchos departamentos y servicios. Así, la actividad en quirófanos, excepto la muy urgente, fue suspendida para liberar camas en las UCIs. La incorporación de las fuentes habituales de pacientes a una UCI al modelo de simulación permite su utilización para programar la actividad de las fuentes gestionables, pudiendo prever su impacto en la ocupación futura. En tiempos de pandemia, los pacientes que requieren cuidados intensivos pueden clasificarse en pacientes COVID-19, pacientes procedentes de operaciones programadas en quirófanos y pacientes no programados (emergencias) (ver Figura 10). Habitualmente, las emergencias siguen un patrón aleatorio estable, bien descrito por un proceso de Poisson, que en el periodo de pandemia ha disminuido su tasa de afluencia debido al confinamiento y la disminución de la actividad. En periodos de remisión de la pandemia, la afluencia de pacientes COVID-19 disminuye progresivamente, liberando recursos para la reactivación de la actividad quirúrgica. La determinación de programaciones óptimas de los quirófanos en estos períodos de transición pue-

de realizarse utilizando el modelo de simulación en combinación con técnicas heurísticas de optimización, para resolver problemas que busquen la maximización del recurso cama de UCI, sujeto a probabilidades de rechazo/desvío de pacientes por debajo de cierto umbral de riesgo y que atiendan a las prioridades de los pacientes esperando en las listas de espera de las distintas especialidades. De modo similar, este modelo de simulación se puede utilizar para la suspensión gradual de actividad en quirófanos durante siguientes rebrotes de la pandemia.




Figura 10: Fuentes de llegada a la UCI en tiempos de pandemia. A las dos fuentes habituales (emergencias y quirófanos) se le añaden los pacientes infectados, en este caso, por COVID-19.

En general, la situación descrita plantea el problema de la distribución y asignación de recursos sanitarios (escasos) entre una amplia tipología de pacientes. La pandemia puede ocasionar cambio en protocolos de admisión y alta de otro tipo pacientes que pueden verse afectados indirectamente por la nueva enfermedad. La confrontación del personal médico con la asignación de recursos escasos no es nueva de esta pandemia [3] aunque sí que ha sobredimensionado el problema. Los modelos de simulación pueden servir para evaluar los efectos que poseen cambios en la atención médica a otros pacientes, tanto de forma individual como colectiva en términos de incremento en las listas de espera [19].

Por otro lado, el modelo de simulación también permite su utilización en modo offline, esto es fuera del periodo de pandemia, como herramienta de aprendizaje para la gestión de recursos por parte de los responsables de la logística sanitaria. El modelo de simulación es capaz de recrear diferentes escenarios de pandemia proporcionando en cada uno de ellos los recursos necesarios y confrontándolos con los disponibles o programados. Así mismo, permite testar la influencia de diferentes formas de gestionar la hospitalización de los pacientes (hospital, domiciliaria, residencias...).

5. Apoyo de la Investigación Operativa a la toma de decisiones en tiempos de pandemia

El principal objetivo de este artículo es mostrar cómo el modelado matemático y la simulación han resultado útiles para la planificación de los recursos necesarios para atender a los pacientes COVID-19 durante las semanas de mayor incidencia de la pandemia. Sin embargo, ni la logística hospitalaria es el único ámbito de decisión donde los modelos cuantitativos pueden prestar ayuda ni la simulación la única herramienta posible de análisis. A continuación, se señalan distintos problemas asociados a la gestión de una pandemia y las herramientas de Investigación Operativa que pueden contribuir a su análisis.

Decisiones que afectan al control de la transmisión de la enfermedad. Durante los estadios iniciales de la pandemia, un tema importante de discusión, en foros científicos, políticos, periodísticos, económicos y públicos en general, fue las medidas que deberían adoptarse para ralentizar la transmisión de la enfermedad (“doblar la curva”, se decía). Como se ha mencionado en la introducción, los modelos epidemiológicos tipo SEIR resultan útiles para crear escenarios que valoren el efecto de las distintas medidas adoptadas. Estos modelos, que utilizan ecuaciones diferenciales para el modelado de la evolución de la población en distintos compartimentos, están relacionados con los modelos de simulación de sistemas dinámicos. Este mismo objetivo, puede abordarse de un modo más detallado mediante la *simulación basada en agentes*, permitiendo de tal modo representar la variabilidad individual de la respuesta a las distintas medidas y la transmisión de la enfermedad de modo individual y no a través de medidas globales poblacionales como lo hace la dinámica de sistemas.

Planificación del personal médico y de enfermería para atender el incremento de demanda derivada de la pandemia. La programación de turnos de trabajo, en general, como en salud en particular, es una de las áreas de interés de la investigación operativa por requerir la resolución de problemas de optimización de tipo combinatorio. Durante la pandemia se experimenta un incremento general de la demanda, debido a la avalancha de nuevos pacientes, mientras que ciertas áreas de salud reducen su actividad. Cómo dimensionar la plantilla, y determinar los turnos teniendo en cuenta la cualificación del personal disponible, su vulnerabilidad, su actividad habitual, etc. y la contratación de nuevos profesionales, para hacer frente a toda la actividad sanitaria (nueva y vieja), conlleva el reto de formular modelos matemáticos de optimización adecuados y de proponer algoritmos para su resolución. Una mala planificación del trabajo puede llevar a un incremento en el cansancio y el estrés de los trabajadores. Además, las soluciones deben ser robustas para que puedan modificarse y adaptarse sin gran perjuicio para el sistema en caso de bajas debidas a contagios de los profesionales. En Madrid, la profesora Begoña Vitoriano, ofreció este servicio de organización de los turnos del personal del hospital de campaña de

IFEMA y de otras instalaciones hospitalarias.

Logística de distribución y transporte. La escasez inicial de material de protección propició la colaboración de numerosas organizaciones, empresas y particulares en la elaboración de dichos materiales utilizando impresoras 3D y otros medios reconvertidos para tal fin. Esta atomización, tanto en la producción como en las localizaciones donde eran necesarias (centros de salud, residencias, pequeño comercio, etc.) supone un reto logístico de recogida y reparto eficiente del material. Este problema fue abordado con éxito en Burgos por el profesor Joaquín Pacheco, en colaboración con miembros de Protección Civil. Similar reto fue abordado en Barcelona por el equipo de investigación del profesor Angel Juan, que prestó apoyo a la comunidad *maker* (con 13.000 socios, fabricaron a partir del 23 de marzo, gratuitamente equipos de protección con impresoras 3D domésticas), desarrollando algoritmos para la recogida y distribución de los equipamientos (<http://informatica.blogs.uoc.edu/2020/04/28/grupo-icso-comunidad-maker/>).

Vigilancia de rebrotes. Una vez superado el primer pico de la pandemia, las autoridades sanitarias están alerta ante la aparición de rebrotes, para poder reaccionar a tiempo y reactivar recursos sanitarios en caso de ser necesario. Diversos indicadores se han propuesto para la detección temprana de rebrotes, como el análisis de aguas fecales (el primer estudio sobre detección de SARS-CoV-2 en aguas residuales se hizo en los Países Bajos [15]) o el número de visitas a los servicios de Atención Primaria con síntomas compatibles con la COVID-19 (indicador propuesto por el Complejo Hospitalario de Navarra). La monitorización y control de los valores resultantes de estos indicadores, u otros, como las personas que dan positivo en un test PCR puede realizarse mediante la utilización de gráficos de control. La Figura 11 muestra el control del número de casos positivos en Navarra desde inicio de marzo hasta el 10 de julio. Se observa la fase de crecimiento y de decrecimiento de casos y cómo a partir del 9 de mayo se estabilizan. Los gráficos de control se han construido adaptando los gráficos EWMA (exponentially weighted moving average) a la estacionalidad (festivos, posfestivos y laborables) que presentan los datos. Los gráficos de control representan los datos registrados en dos de las áreas principales de salud en las que se divide Navarra (cada una con un hospital público de referencia): en Estella no se aprecia ninguna anomalía, mientras que en Tudela se muestra rebrote reciente. El tercer gráfico de control representa los datos registrados en Ermitagaña, una de las 57 zonas básicas de salud que compone Navarra. En él se aprecia un pequeño rebrote, que se repite días después. La línea verde representa el número de positivos en Navarra por 10.000 habitantes y la línea roja el de la zona/área de salud concreta representada.

Decisión sobre quién y cuándo vacunar. Este es un problema de decisión importante que tendrán que afrontar las autoridades sanitarias, sobre todo

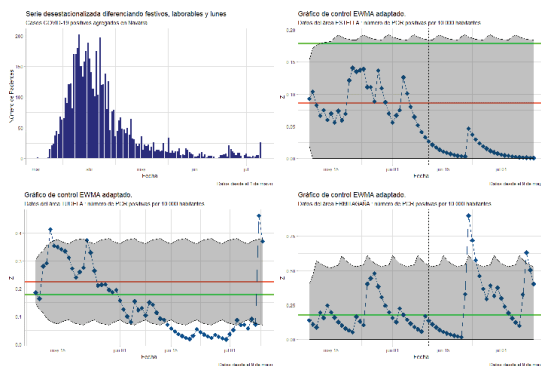


Figura 11: Número de casos positivos en Navarra desde inicio de marzo hasta el 10 de julio (serie desestacionalizada). Gráficos de control de Estella, Tudela (áreas de salud de Navarra) y Ermitagaña (zona básica de salud de Navarra).

si los sistemas de producción de las vacunas tardan un tiempo en proveer las necesidades de toda la población. La estrategia para la vacunación de la población, tratado en otras ocasiones [17], debe decidir qué sectores de la población deben recibir antes la vacuna (además de solventar problemas de índole logístico operacional) atendiendo a criterios de protección de sectores críticos y de vulnerabilidad de la población. Este problema puede complicarse en el caso de disponerse de diversas vacunas, con distintas características de eficiencia para distintos perfiles de la población y distintos precios.

El listado anterior de problemas no es único y se puede completar con otras situaciones en las que los métodos cuantitativos de la Investigación Operativa pueden facilitar la toma de decisiones de los responsables sanitarios. Por ejemplo, en el diseño de aprovisionamiento y redes de distribución, dado que la pandemia ha puesto en evidencia la falta de ciertos recursos sanitarios críticos y la necesidad de disponer de un acopio de ellos para estar disponibles ante un nuevo rebrote o nueva pandemia. En estos temas, nuestra comunidad de investigadores cuenta con numerosos especialistas en modelos de inventarios, localización de instalaciones, logística de almacenamiento y distribución, etc.

6. Conclusiones y observaciones finales

En este artículo hemos relatado cómo los investigadores del grupo q-UPHS de la Universidad Pública de Navarra han prestado soporte a los responsables de

la planificación de recursos del sistema hospitalario navarro durante el período de pandemia COVID-19. Cada día, entre el 16 de marzo y el 30 de abril, los investigadores han entregado un informe con sus previsiones de ocupación de camas para los siguientes días obtenidos a través de un modelo de simulación de eventos discretos que integraba un modelo de curvas de crecimiento poblacional para la predicción de nuevos casos.

Este modelo sirvió de base para su adaptación y utilización por otros investigadores en otras comunidades autónomas españolas, como País Vasco (Inmaculada Aróstegui), Andalucía (David Gómez-Ullate), Madrid (Begoña Vitoriano) y Galicia (Ricardo Cao). El grupo de investigación tuvo una capacidad de respuesta rápida (el modelo de simulación inicial estuvo operativo en tres días) debido a que su investigación se centra en la mejora de los servicios de salud mediante la aplicación de modelos matemáticos de la Investigación Operativa y contaba ya con un modelo de simulación de una UCI, para otros propósitos, que pudo ser convenientemente adaptado. Esta actuación es un ejemplo del retorno que produce a la sociedad la investigación financiada mediante fondos públicos y muestra la necesidad de continuar con políticas de apoyo a la investigación orientada a afrontar los nuevos retos sociales, económicos y medioambientales. Sin embargo, el impacto práctico depende de la colaboración por parte de los gestores del sistema público de salud, que deben facilitar toda la información relativa a los problemas analizados, incluyendo bases de datos, deben participar en la validación de los modelos matemáticos y, por último, deben aceptar sus resultados para ser utilizados en la toma de decisiones. Este entendimiento, colaboración o integración se facilita conformando grupos de investigación multidisciplinares, capaces de hablar tanto el lenguaje del profesional de la medicina, y del gestor, como del investigador en métodos cuantitativos. Por ello, las políticas públicas de investigación deben favorecer la investigación multidisciplinar motivada por problemas concretos y reales de la sociedad, adaptando por ello una estructura, tal vez demasiado compartimentalizada y constreñida por las distintas áreas de conocimiento.

La pandemia ha puesto de manifiesto numerosas áreas de investigación en la que los modelos de la Investigación Operativa pueden aportar sus soluciones. También ha servido para acelerar procesos de cambio en la atención de pacientes ya en marcha, como la telemedicina y la asistencia domiciliaria. Estos cambios, junto al envejecimiento de la población y la amenaza de la reaparición de este virus o de otros similares, van a definir la sanidad pública del siglo XXI y suponen un toque a rebato para que los investigadores preparemos nuestros modelos para apoyar el desarrollo de servicios de salud sostenibles y eficientes y estar mejor preparados en la siguiente emergencia sanitaria.

La mejora de los servicios de salud y las políticas públicas de salud son dos ámbitos clásicos de aplicación de la Investigación Operativa. Congresos (EURO,

INFORMS, WSC) y revistas generalistas de Investigación Operativa (EJOR, JORS, JOM...) le dedican sesiones especiales a salud. Existe un grupo de trabajo europeo ORAHS (Operations Research Applied to Health Services) muy activo, en cuyo congreso anual se presentan más de 100 trabajos de investigación. A pesar de esta relevancia, la investigación española no contribuye de acuerdo al tamaño y calidad de su comunidad de investigadores operativos, que sí que destaca en otros ámbitos de aplicación. La IO española debe ver la transición de sanidad pública al nuevo paradigma descrito en el párrafo anterior como una oportunidad de desarrollar su investigación, con el añadido de impactar con ella en el bienestar de la sociedad, contribuyendo a la sostenibilidad y a la calidad de sus servicios públicos de salud.

Por último, esta labor investigadora, así como la de nuestros colegas estadísticos, debe ser facilitada por la disposición pública de bases de datos de calidad. Iniciativas de gran utilidad para facilitar a las autoridades información sobre la expansión de la enfermedad, como la construcción de un meta-predicador a partir de las predicciones provenientes de diferentes modelos/algoritmos, aportadas por más de 40 grupos de investigación españoles, promovida por la Acción Matemática contra el Coronavirus (Comité Español de Matemáticas, <http://matematicas.uclm.es/cemat/covid19/>), se vieron dificultadas por deficiencias en los datos, con cambios de criterios en su recogida y falta de homogeneidad entre las distintas comunidades. También, la baja calidad de datos hizo desistir al mencionado grupo MUNQU de su emisión de predicciones. Por tanto, desde aquí, al igual que hizo en reiteradas ocasiones el presidente del CEMAT, Alfonso Gordaliza, reiteramos la importancia de disponer de bases de datos de calidad, públicas y actualizadas e instamos a las autoridades a que se apliquen en el diseño de protocolos para la monitorización de las variables de interés, su almacenamiento y su puesta a disposición pública.

Agradecimientos

Esta investigación ha sido financiada por el proyecto MTM2016-77015-R (AEI, FEDER). Los autores desean reconocer la participación del Complejo Hospitalario de Navarra y del Departamento de Sistemas y Tecnologías para la Salud del Gobierno de Navarra en la implementación práctica de este proyecto.

Referencias

- [1] Alban, A., Chick, S., Dongelmans, D.A., et al. (2020). ICU capacity management during the COVID-19 pandemic using a stochastic process simulation. *SSRN Electronic Journal*, Doi: 10.2139/ssrn.3570406.
- [2] Arenas, A., Cota, W., Gomez-Gardenes, J., et al. (2020). A mathematical model for the spatiotemporal epidemic spreading of COVID19. *medRxiv*, Doi: 10.1101/2020.03.21.20040022.

-
- [3] Azcarate, C., Esparza, L., and Mallor, F. (2019). The problem of the last bed: contextualization and a new simulation framework for analyzing physician decisions. *Omega*, **96**, 102120. Doi: 10.1016/j.omega.2019.102120.
- [4] Brailsford, S.C., Harper, P.R., Patel, B., et al. (2009). An analysis of the academic literature on simulation and modelling in health care. *Journal of Simulation*, **3**(3), 130-140.
- [5] Brauer, F., and Castillo-Chavez, C. (2012). *Mathematical Models in Population Biology and Epidemiology*, 2nd Ed. Springer, New York.
- [6] Currie, C.S.M., Fowler, J.W., Kotiadis, K., et al. (2020). How simulation modelling can help reduce the impact of COVID-19. *Journal of Simulation*, **14**(2), 83-97.
- [7] Das, A. (2020). Impact of the COVID-19 pandemic on the workflow of an ambulatory endoscopy center: an assessment by discrete event simulation. *Gastrointestinal Endoscopy*, Doi: 10.1016/j.gie.2020.06.008.
- [8] Fetter, R.B., and Thompson, J.D. (1965). The simulation of hospital systems. *Operations Research*, **13**(5), 689-711.
- [9] Gardiner, F., Johns, H., Bishop, L., et al. (2020). Royal flying doctor service coronavirus disease 2019 activity and surge modeling in Australia. *Air Medical Journal*, Doi: 10.1016/j.amj.2020.05.011.
- [10] Grasselli, G., Pesenti, A., and Cecconi, M. (2020). Critical care utilization for the COVID-19 outbreak in Lombardy, Italy: early experience and forecast during an emergency response. *JAMA*, **323**(16), 1545-1546.
- [11] Guan, W., Ni, Z., Hu, Yu, et al. (2020). Clinical characteristics of coronavirus disease 2019 in China. *New England Journal of Medicine*, **382**, 1708-1720.
- [12] Günal, M.M., and Pidd, M. (2010). Discrete event simulation for the performance modelling in health care: a review of the literature. *Journal of Simulation*, **4**(1), 42-51.
- [13] Ivanov, D. (2020). Predicting the impacts of epidemic outbreaks on global supply chains: a simulation-based analysis on the coronavirus outbreak (COVID-19/SARS-CoV-2) case. *Transportation Research Part E: Logistics and Transportation Review*, **136**, 101922. Doi: 10.1016/j.tre.2020.101922.
- [14] Katsaliaki, K., and Mustafee, N. (2011). Applications of simulation within the healthcare context. *Journal of the Operational Research Society*, **62**(8), 1431-1451.

- [15] Medema, G., Heijnen, L., Elsinga, G., et al. (2020). Presence of SARS-Coronavirus-2 in sewage. *medRxiv*, Doi: 10.1101/2020.03.29.20045880.
- [16] Mielczarek, B. (2016). Review of modelling approaches for healthcare simulation. *Operations Research and Decisions*, **26**(1), 55-72.
- [17] Özaltın, O. Y., Dalgıç, Ö. O., and Erenay, F. S. (2014). Optimal distribution of the influenza vaccine. In *Proceedings of the 2014 Winter Simulation Conference*, 1411-1420.
- [18] Salleh, S., Thokala P., Brennan A., et al. (2017). Simulation modelling in healthcare: an umbrella review of systematic literature reviews. *Pharmacoeconomics*, **35**(9), 937-949.
- [19] Wood, R.M. (2020). Modelling the impact of COVID-19 on elective waiting times. *Journal of Simulation*, Doi: 10.1080/17477778.2020.1764876.
- [20] Wood, R.M., McWilliams, C.J., Thomas, M.J., et al. (2020). COVID-19 scenario modelling for the mitigation of capacity-dependent deaths in intensive care: computer simulation study. *medRxiv*, Doi: 10.1101/2020.04.02.20050898.
- [21] Young, B.E., Ong, S.W.X., Kalimuddin, S., et al. (2020). Epidemiologic features and clinical course of patients infected with SARS-CoV-2 in Singapore. *JAMA*, **323**(15), 1488–1494.
- [22] Zhang, C., Grandits, T., Härenstam, K.P., et al. (2018). A systematic literature review of simulation models for non-technical skill training in healthcare logistics. *Advances in Simulation*, **3**, 15.
- [23] Zhou, F., Yu, T., Du, R., et al. (2020). Clinical course and risk factors for mortality of adult inpatients with COVID-19 in Wuhan, China: a retrospective cohort study. *The Lancet*, **395**(10229), 1054–1062.
- [24] Zwietering, M. H., Jongenburger, I., Rombouts, F. M., et al. (1990). Modeling of the bacterial growth curve. *Applied and Environmental Microbiology*, **56**(6), 1875-1881.

Acerca de los autores

Daniel García Vicuña es estudiante de doctorado en el Departamento de Estadística, Informática y Matemáticas de la Universidad Pública de Navarra y miembro del grupo de investigación q-UPHS (quantitative methods for Uplifting the Performance of Health Services). Sus líneas de investigación se centran en el campo del modelado de simulación de problemas reales complejos.

Marta Cildoz es doctora en Ingeniería industrial. Actualmente es investigadora posdoctoral en el Departamento de Estadística, Informática y Matemáticas de la Universidad Pública de Navarra y miembro del grupo de investigación q-UPHS (quantitative methods for Uplifting the Performance of Health Services). Sus intereses de investigación incluyen la simulación y optimización de problemas reales complejos.

Martin Gastón Romeo es Profesor Contratado Doctor en el Departamento de Estadística, Informática y Matemáticas de la Universidad Pública de Navarra. Su investigación a nivel teórico se centra en el campo del análisis de datos funcionales, las máquinas de aprendizaje estadístico y los modelos de clasificación y predicción con múltiples resultados aplicados en campos como la sanidad, la logística y las energías renovables.

Cristina Azcarate es Profesora del Departamento de Estadística, Informática y Matemáticas de la Universidad Pública de Navarra. Pertenece al grupo de investigación q-UPHS (quantitative methods for Uplifting the Performance of Health Services). Sus líneas de investigación se centran en las aplicaciones de la simulación y optimización en salud, energía, logística y producción.

Fermín Mallor es Catedrático de Universidad en el Departamento de Estadística, Informática y Matemáticas de la Universidad Pública de Navarra. Ha sido investigador visitante en la Universidad de Ciencia y Tecnología de Missouri, entre otros. Sus intereses de investigación incluyen aplicaciones de simulación-optimización (métodos clásicos y metaheurísticos) en salud, energía, logística y producción. Es el director del grupo de investigación q-UPHS (quantitative methods for Uplifting the Performance of Health Services).

Laida Esparza es médica en el Departamento de Medicina Intensiva del Complejo Hospitalario de Navarra y estudiante de doctorado del Departamento de Estadística, Informática y Matemáticas de la Universidad Pública de Navarra. Sus intereses de investigación se centran en el campo del modelado de simulación y en el estudio de los procesos de toma de decisiones clínicas y la gestión de camas en las unidades de cuidados intensivos.