

Med Klin Intensivmed Notfmed 2023 · 118:125–131
<https://doi.org/10.1007/s00063-022-00903-x>
Eingegangen: 12. August 2021
Überarbeitet: 14. Dezember 2021
Angenommen: 31. Januar 2022
Online publiziert: 10. März 2022
© Der/die Autor(en) 2022

Redaktion

Michael Buerke, Siegen



Prognosemodelle zur Steuerung von intensivmedizinischen COVID-19-Kapazitäten in Deutschland

Marlon Grodd¹ · Lukas Refisch¹ · Fabian Lorenz¹ · Martina Fischer² · Matthäus Lottes² · Maren Hackenberg¹ · Clemens Kreuzt¹ · Linus Grabenhenrich² · Harald Binder¹ · Martin Wolkewitz¹

¹ Institut für Medizinische Biometrie und Statistik, Medizinische Fakultät und Universitätsklinikum, Albert-Ludwigs-Universität Freiburg, Freiburg, Deutschland

² Robert Koch-Institut, Berlin, Deutschland

Zusammenfassung

Hintergrund: Zeitdynamische Prognosemodelle spielen eine zentrale Rolle zur Steuerung von intensivmedizinischen COVID-19-Kapazitäten im Pandemiegeschehen. Ein wichtiger Vorhersagewert (Prädiktor) für die zukünftige intensivmedizinische (ITS-)COVID-19-Bettenbelegungen ist die Anzahl der SARS-CoV-2-Neuinfektionen in der Bevölkerung, die wiederum stark von Schwankungen im Wochenverlauf, Meldeverzug, regionalen Unterschieden, Dunkelziffer, zeitabhängiger Ansteckungsrate, Impfungen, SARS-CoV-2-Virusvarianten sowie von nichtpharmazeutischen Eindämmungsmaßnahmen abhängt. Darüber hinaus wird die aktuelle und auch zukünftige COVID-ITS-Belegung maßgeblich von den intensivmedizinischen Entlassungs- und Sterberaten beeinflusst.

Methode: Sowohl die Anzahl der SARS-CoV-2-Neuinfektionen in der Bevölkerung als auch die intensivmedizinischen COVID-19-Bettenbelegungen werden bundesweit flächendeckend erfasst. Diese Daten werden tagesaktuell mit epidemischen SEIR-Modellen aus gewöhnlichen Differenzialgleichungen und multiplen Regressionsmodellen statistisch analysiert.

Ergebnisse: Die Prognoseergebnisse der unmittelbaren Entwicklung (20-Tage-Vorhersage) der ITS-Belegung durch COVID-19-Patienten*innen werden Entscheidungsträgern auf verschiedenen überregionalen Ebenen zur Verfügung gestellt.

Schlussfolgerung: Die Prognosen werden der Entwicklung von betreibbaren intensivmedizinischen Bettenkapazitäten gegenübergestellt, um frühzeitig Kapazitätsengpässe zu erkennen und kurzfristig reaktive Handlungssteuerungen, wie etwa überregionale Verlegungen, zu ermöglichen.

Schlüsselwörter

Pandemien · Intensivstationen · Bettenbelegung · Zuteilung von Ressourcen · Statistisches Modell

Einleitung

Ein zentrales Element der Pandemiebewältigung und Grundlage zur datenbasierten Handlungssteuerung ist eine aktuelle, flächendeckende Erfassung und Vorhersage der unmittelbaren Entwicklung der Belegung durch intensivpflichtige COVID-19-Patienten*innen [1].

Um diesem Ziel Rechnung zu tragen, initiierte das Robert Koch-Institut (RKI) das Forschungsprojekt „Steuerungs-Prognose von intensivmedizinischen COVID-19-Kapazitäten“ (SPoCK).

In diesem Artikel werden Einblicke in die im Rahmen dieses Projekts entwickelten und fortlaufend weiterentwickelten statistisch-mathematischen Modelle gegeben.



QR-Code scannen & Beitrag online lesen

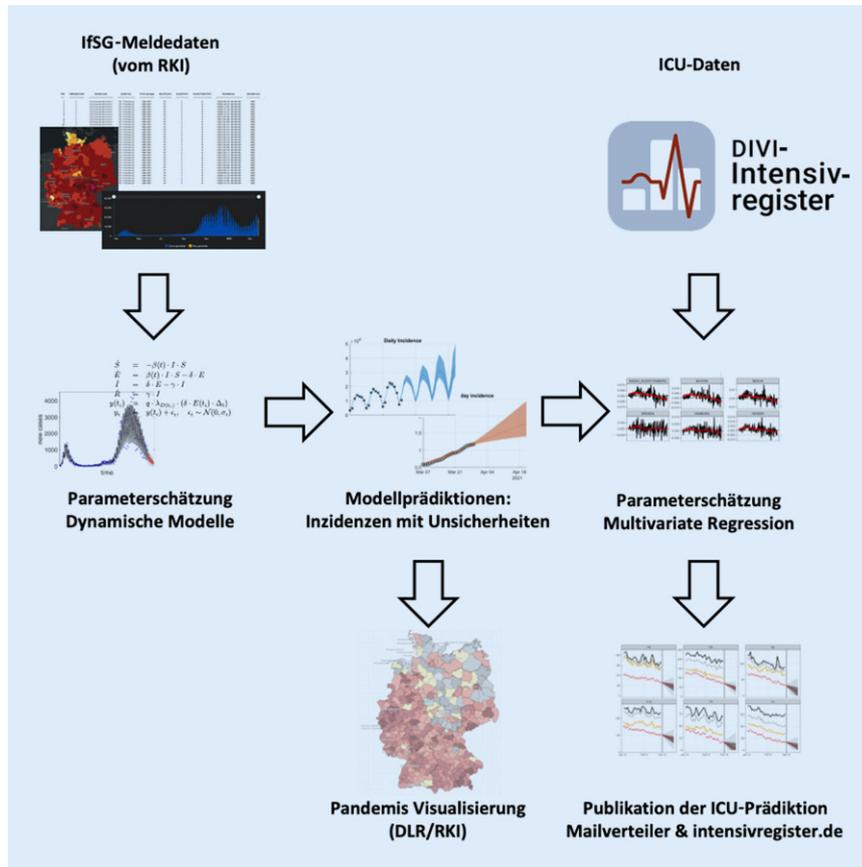


Abb. 1 ▲ Schematische Darstellung der Datenquellen, Verarbeitungsschritte und Prognosemodelle im Forschungsprojekt „Steuerungs-Prognose von intensivmedizinischen COVID-19-Kapazitäten“ (SPoCK)

Die **Abb. 1** zeigt die Struktur des Datenflusses und der Modellierung. In einem ersten Schritt werden die gemeldeten COVID-19-Neuinfektionen (gemäß den IfSG-Melddaten) und deren wahrscheinlich tatsächlicher Verlauf mit einem dynamischen Modell geschätzt und Vorhersagen zur Entwicklung der COVID-19-Neuinfektionen generiert. Diese Vorhersagen werden im zweiten Schritt als ein Prädiktor für das Prognosemodell der zu erwartenden COVID-19-Intensivbettenbelegung benutzt. Die Prognoseergebnisse werden Entscheidungsträgern auf verschiedenen Ebenen zur Verfügung gestellt.

Methoden

Datengrundlage

Die Modellierung der intensivmedizinischen Bettenbelegung mit COVID-19-Patient*innen basiert primär auf 2 Da-

tenquellen: 1) die durch das RKI täglich veröffentlichten Daten zu den inzidenten COVID-19-Neuinfektionen in der Bevölkerung (gemäß Meldeweg über die Gesundheitsämter) und 2) die täglich aktuellen Meldungen der intensivmedizinischen COVID-19-Belegung (prävalente Fälle) aus dem DIVI-Intensivregister, einem Kooperationsprojekt des RKI und der DIVI e.V. [2].

Schritt 1: Modellierung und Prognose der SARS-CoV-2-Neuinfektionen in der Bevölkerung

Zunächst wird aus den täglich publizierten Meldedaten der Gesundheitsämter der Verlauf der COVID-19-Neuinfektionen geschätzt, wie er am wahrscheinlichsten tatsächlich verlaufen ist, sowie die Entwicklung geschätzt, wie sie sich wahrscheinlich in der nahen Zukunft fortsetzen wird. Unter Verwendung eines epidemischen SEIR-Modells aus gewöhnlichen Differenzi-

algleichungen werden u. a. die folgenden Faktoren berücksichtigt:

1. Schwankungen im Wochenverlauf, z. B. weniger Meldungen an Wochenenden;
2. Meldeverzug der Daten durch Übermittlung und Qualitätsprüfung;
3. regionale Unterschiede bez. Prävalenz und Dunkelziffer infizierter/erkrankter aber nicht gemeldeter Fälle;
4. Veränderungen der zeitabhängigen Ansteckungsrate, z. B. durch Impfungen, Virusmutationen sowie die Veranlassung und Akzeptanz politischer Eindämmungsmaßnahmen usw.

Bei dem gewählten Modellansatz [3] werden alle Parameter sowie deren Unsicherheit vollständig auf Grundlage der Daten, basierend auf den gemeldeten Inzidenzen, geschätzt. Die Meldungen der COVID-19-Neuinfektionen können mit einem Zählprozess verglichen werden, daher wird ein an die Poisson-Verteilung angelehntes Fehlermodell angenommen. Dies entspricht einer Normalverteilung mit einer Varianz proportional zur Anzahl neuer Fälle. Für die Prognose der zukünftigen Entwicklung der Neuinfektionen muss die zeitabhängige Infektionsrate extrapoliert werden. Da sich die Effekte der unter 4. genannten Faktoren nicht verlässlich vorhergesagen lassen, wird der geschätzte Wert der Infektionsrate zum Zeitpunkt des letzten Datenpunkts fixiert, wobei dessen statistische Unsicherheit in die Vorhersageunsicherheit eingeht. Somit wird eine 20-Tage-Prognose unter der Annahme bzw. für ein Szenario erstellt, in dem sich die Infektionsrate durch die Effekte der unter 4. genannten Faktoren für den Prognosezeitraum nicht maßgeblich verändert. Zur Sicherstellung robuster Ergebnisse werden 2 unterschiedliche Modellansätze berechnet und zusammengeführt. Letztere unterscheiden sich in der Vorprozessierung der Meldedaten: Im ersten Ansatz werden die letzten beiden Tagesinzidenzen weggelassen, im zweiten Ansatz werden die Tagesinzidenzen mittels eines Nowcasting-Verfahrens korrigiert. Beide Ansätze tragen also dem Meldeverzug Rechnung, der insbesondere die aktuellsten Tagesinzidenzen in Richtung kleiner Werte verzerrt.

Ein zentraler Aspekt ist auch, die Unsicherheiten der Vorhersagen anzugeben.

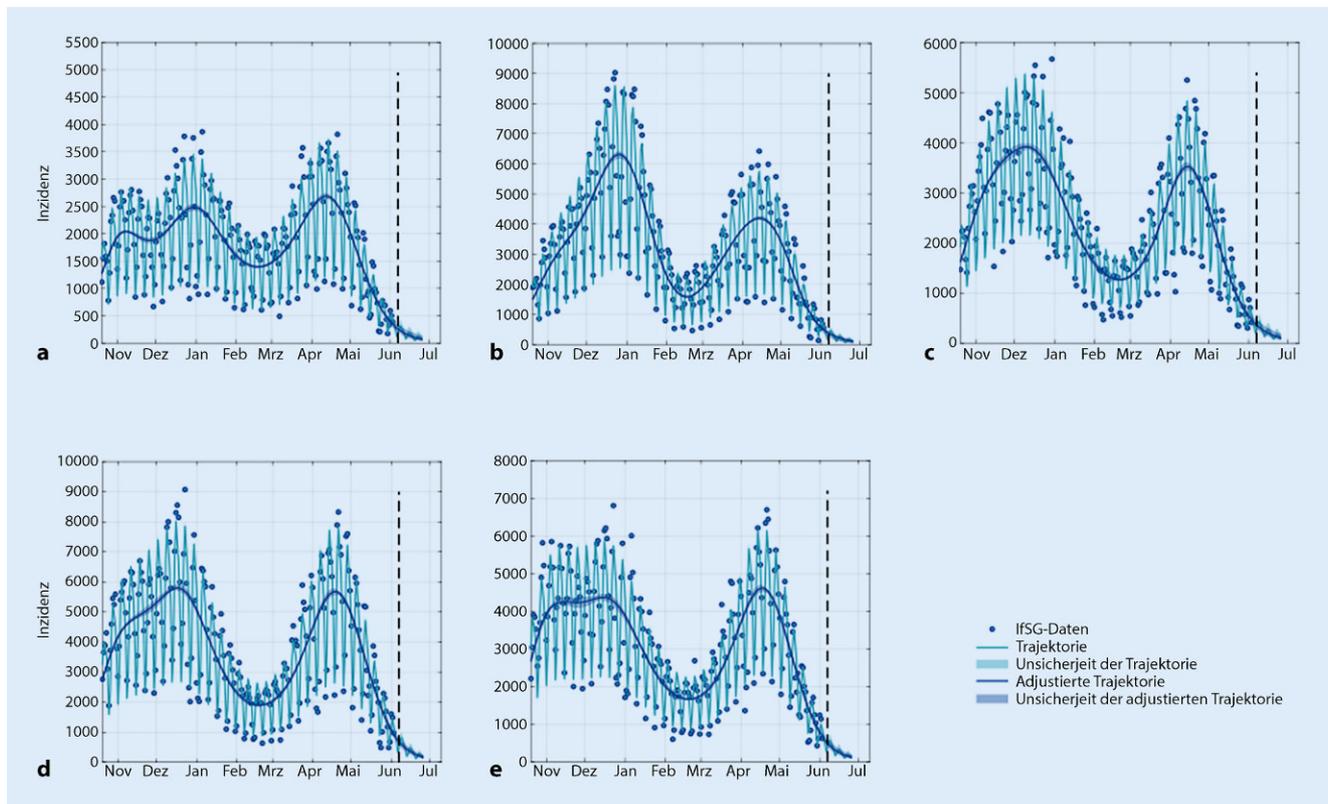


Abb. 2 ▲ Anzahl der inzidenten gemeldeten SARS-CoV-2-Fälle im Zeitverlauf in den jeweiligen Kleeblättern. Beobachtete Werte (Punkte vor der senkrechten Strichlinie), geschätzter Verlauf der Neuinfektionen sowie die Prognose. a Nord, b Ost, c Süd, d Süd-West, e West

Dazu wird neben der wahrscheinlichsten Trajektorie auch ein Intervall angegeben, indem sich der Verlauf mit einer gewissen (hier 95%igen) Wahrscheinlichkeit befinden wird. Diese Vorhersageunsicherheit basiert in dem hier vorgestellten Ansatz auf den Unsicherheiten aller Modellparameter und wird mit der Profile-Likelihood-Methode [4] berechnet. Für die Kalibrierung der Modelle werden die Daten aus dem gesamten Zeitraum seit Beginn der Pandemie verwendet.

In diesem Modell werden insgesamt 26 Parameter geschätzt. Diese enthalten 18 dynamische Parameter: 14 Parameter für den Spline, der die zeitabhängige Infektionsrate approximiert, 3 Übergangsraten und einen Startwert der Dynamik. Weitere 7 Parameter beschreiben die Beobachtungsfunktion inklusive Wochenmodulation. Außerdem gibt es einen Fehlerparameter, der die Unsicherheit in den Beobachtungen widerspiegelt. Alle Parameter werden täglich neu geschätzt, was unter anderem deshalb nötig ist, weil sich die Stützstellen der zeitabhängigen Infektionsra-

te verschieben. Die tägliche Berechnung auf täglichen Inzidenzdaten seit 03. März 2020 führt am Analysetag 07. Juni 2021 zu 458 Datenpunkten, die für die Parameterschätzung benutzt werden. Für weitergehende und mathematische Details verweisen wir auf die zugehörige Veröffentlichung [3].

Schritt 2: Modellierung und Prognose der COVID-19-Patient*innen in Intensivbehandlung

Im zweiten Schritt werden die Prognoseergebnisse aus Schritt 1 weiter für die Modellierung und Prognose der COVID-19-Patient*innen in Intensivbehandlung verwendet.

Datenaufbereitung

Im DIVI-Intensivregister meldet jedes Akutkrankenhaus die tägliche aktuelle Anzahl der belegten Intensivbetten durch COVID-19-Patient*innen (prävalente Fälle). Durch die räumliche Auflösung können folgende

Ebenen betrachtet werden: Versorgungscluster, Bundesländer, Kleeblätter (siehe Kleeblattregionen in Gräsner et al. [5]) und Deutschland.

Modellierung

Für jede der verschiedenen o.g. räumlichen Ebenen werden separate und analoge Modelle gerechnet. Wir stellen den Ansatz exemplarisch anhand der Kleeblattebene vor.

Zuerst werden die täglichen Veränderungen der intensivmedizinischen (ITS-)COVID-Belegung zum Vortag durch das jeweilige Prävalenzverhältnis (Quotient der aktuellen Prävalenz zum Vortag) betrachtet. Das Hauptinteresse liegt hierbei im zeitlichen Trend der Prävalenzquotienten: Ein Trend größer als 1 bedeutet, dass zunehmend mehr Intensivbetten zur COVID-19-Behandlung benötigt werden. Mit diesem Vorgehen werden insbesondere Wendepunkte im zeitlichen Verlauf der intensivmedizinischen Bettenbelegung durch COVID-19-Patient*innen erkennbar.

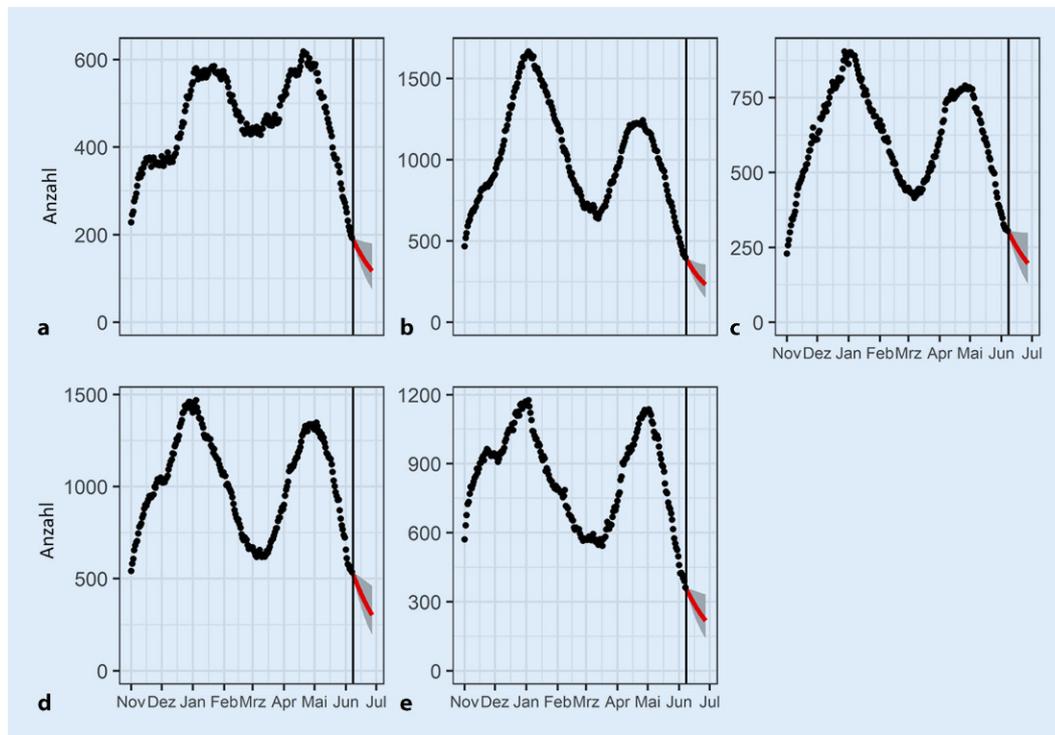


Abb. 3 ◀ Anzahl der prävalenten COVID-19-Patient*innen im Zeitverlauf in den jeweiligen Kleeblättern. Beobachtete Werte (schwarze Punkte vor der senkrechten Linie), Vorhersage (rote Linien nach der senkrechten Linie) und 95%-Prognoseintervall (grau). a Nord, b Ost, c Süd, d Süd-West, e West

Anschließend werden diese täglichen Veränderungen zum Vortag mithilfe linearer Regressionsmodelle in Abhängigkeit von mehreren Faktoren analysiert und modelliert. Zu den Hauptprädiktoren für die ITS-COVID-Belegung gehören der errechnete wahrscheinliche Verlauf und die zeitlichen Veränderungen der Neuinfektionen aus der Bevölkerung (Schritt 1). Die Datengrundlage weist ein durchschnittliches Zeitintervall von 5–7 Tagen zwischen einer COVID-19-Neuinfektion und der Aufnahme auf die Intensivstation auf. Infolgedessen wird die Anzahl der Neuinfektionen in der Bevölkerung als ein externer Prädiktor mit einem Zeitverzug von 5–7 Tagen für die Anzahl der COVID-19-Patient*innen in Intensivbehandlung in Korrelation gesetzt und repräsentiert den Außendruck auf die Intensivstationen. Weitere Prädiktoren sind u. a. die Altersverteilung in den Neuinfektionen basierend auf den Meldedaten der Gesundheitsämter. Weiter erlauben raum-zeitliche Interaktionsterme eine dynamische Flexibilität, d. h.: Die Effekte werden global mit allen Daten geschätzt, können aber lokal variieren. Für die Modellierung und Prognose der COVID-19-Patient*innen in Intensivbehandlung werden derzeit 20 Regressionskoeffizienten in

dem Regressionsmodell auf Kleeblattebene geschätzt und verwendet.

Dynamische Schätzung und dynamische Prognose

Sowohl die IfSG-Meldedaten als auch die Fallzahlen des DIVI-Intensivregisters werden täglich aktualisiert. Die Modellierung wird gleichermaßen dynamisch aktualisiert, d. h.: Die Parameter und der Verlauf der COVID-19-Neuinfektionen aus Schritt 1 und die Regressionskoeffizienten aus Schritt 2 werden täglich neu geschätzt. Durch diese dynamische Schätzung können zugrunde liegende zeitlich-regionale Prozesse und Effekte (z. B. regionaler R-Wert, Impfungen, Einfluss von Virusvarianten etc.) in Echtzeit indirekt über die Daten beobachtet, einbezogen und somit implizit gelernt werden (ohne dabei bestimmte externe Parameter festzulegen). Folglich werden alle Modellparameter ausschließlich basierend auf den Daten der 2 Systeme mit bundesweiter Vollabdeckung (siehe Datengrundlage) bestimmt. Aus der in Schritt 1 geschätzten Entwicklung der COVID-19-Neuinfektionen und den intensivmedizinischen Fallzahlen des DIVI-Intensivregisters wird dann die eigentliche 20-Tage-Prognose für den zu erwartenden Verlauf der Intensivbe-

legung mit COVID-19-Fällen berechnet. Dafür werden die Regressionskoeffizienten der jeweiligen Prädiktoren eingesetzt, wodurch man die Veränderung für die nächsten 20 Tage erhält.

Diese werden an den Wert der aktuellen Intensivbettenbelegung angeknüpft. Die prognostizierte Intensivbettenbelegung durch COVID-Patient*innen wird mit Prognoseintervallen graphisch dargestellt. Prognoseintervalle stellen einen Wertebereich dar, in dem zu einer gewissen Wahrscheinlichkeit die tatsächlichen Werte liegen. Somit ist es z. B. bei einem 95%-Prognoseintervall sehr unwahrscheinlich (kleiner als 5%), dass die tatsächliche Bettenbelegung außerhalb des Intervallbereichs (hier: hellgrauer Bereich) liegt.

Ergebnisse

Das Prognosemodell fokussiert auf eine differenzierte Vorhersage für die zu erwartende Anzahl von intensivpflichtigen COVID-19-Patient*innen auf unterschiedlichen Versorgungsebenen (Deutschland, Kleeblätter [1], Bundesländer, Versorgungscluster) für maximal 20 Tage (Abb. 2 und 3). Des Weiteren werden die Prognosen der Entwicklung von betriebsbaren intensivmedizinischen Bettenkapä-

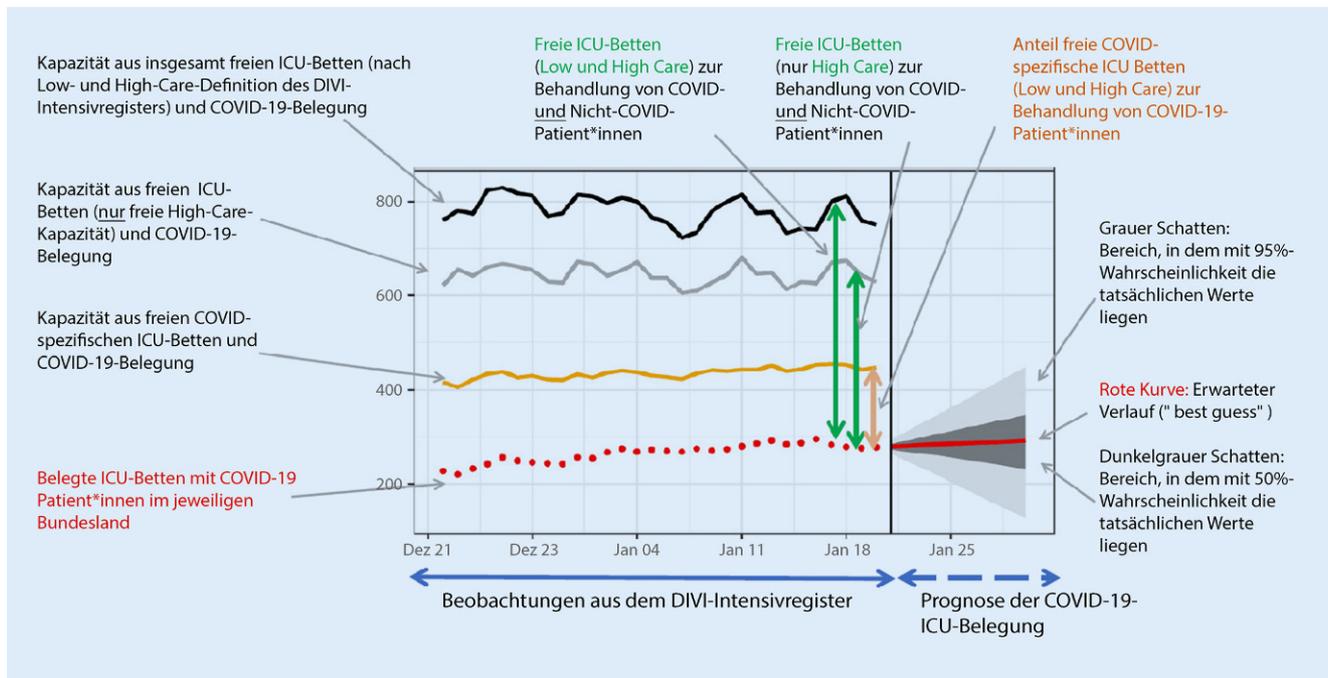


Abb. 4 ▲ Exemplarische Darstellung (Bsp. Berlin) mit Intensivbettenkapazitäten und Erläuterung im Bericht. Bisherige beobachtete Entwicklung der Anzahl intensivpflichtiger COVID-19-Patient*innen (rote Punkte) und 10-Tage-Prognose (rote Linie). Die darüber liegenden Linien zeigen den Verlauf der verfügbaren Bettenkapazität (schwarz Low und High Care, grau High Care, orange COVID-spezifische Kapazität). Der Trichter ist das Prognoseintervall

zitäten gegenübergestellt (■ Abb. 4), um frühzeitig Kapazitätsengpässe zu erkennen und kurzfristig reaktive Handlungssteuerungen, wie etwa überregionale Verlegungen, zu ermöglichen.

Somit orientieren sich die Prognosemodellierungen bewusst sehr nahe am aktuellen Lagebild. Die Prognosen verfolgen jedoch nicht das Ziel, den längerfristigen weiteren Pandemieverlauf vorherzusagen oder potenzielle Szenarien der Pandemieentwicklung über einen erweiterten Darstellungszeitraum abzubilden, um politische Entscheidungen zu unterstützen.

Diskussion

Mit den hier beschriebenen Verfahren werden 2 wichtige Datenquellen (Meldungen der Gesundheitsämter und des DIVI-Intensivregisters) und ihre Einflussfaktoren sowie deren Zusammenspiel untereinander berücksichtigt.

Die Modelle werden regelmäßig auf Plausibilität und Prognoseleistung untersucht und mit parallel laufenden Alternativansätzen (z.B. Modellierung der Prävalenzdifferenz zum Vortag statt des Quotienten, bzw. direkte Modellierung

der Prävalenz durch erweiterte Poisson-Regressionsmodelle) oder Erweiterungen (z.B. durch weitere Prädiktoren in den jeweiligen Regressionsmodellen) verglichen. Falls es zu einer Modelloptimierung kommt, werden unterschiedliche Modellansätze berechnet und zusammengeführt.

Unterschiede zu anderen Prognoseansätzen

Die hier beschriebenen Methoden sind rein datenbasierte kurzzeitige Prognosen und unterscheiden sich somit von annahmebasierten Modellrechnungen, die vor allem verschiedene Handlungsoptionen aufzeigen sollen. Solche reinen Simulationsmodelle arbeiten meist ohne Primärdaten und sind stark abhängig von eingesetzten Parametern, z. B. aus Vorwissen oder der Literatur. Solche Ansätze eignen sich eher für die Untersuchung hypothetischer Szenarien z. B. zu erwarteten Effekten politischer Maßnahmen.

Alternative Prognoseansätze zu Schritt 1

Es gibt zahlreiche Arbeiten, die mittels mathematischer Modellierung das Pandemiegeschehen prognostizieren. Auf dem European Forecast Hub [6] werden aktuell Prognosen von 23 Modellen oder Ensemble-Ansätzen für Deutschland veröffentlicht und wöchentlich aktualisiert (Stand 13.05.2021). Auf dem German and Polish COVID-19 ForecastHub [8] werden aktuell Prognosen von 17 Modellen oder Ensemble-Ansätzen für Deutschland veröffentlicht und wöchentlich aktualisiert ([7]; Stand 13.05.2021). Die deutschlandweit bekanntesten Ansätze sind unter anderem der COVID-19-Simulator [9] mit wöchentlichen Berichten der Universität Saarbrücken sowie verschiedene Onlinetools, bei denen unterschiedliche Parametrisierungen simuliert werden können.

Es sind dabei die jeweiligen Zielsetzungen in der Modellierung der Inzidenzen der Neuinfektionen zu unterscheiden: Simulationsstudien sind geeignet, unter verschiedenen Modellannahmen die Auswirkung von Maßnahmen zur Pandemiesteuerung zu untersuchen. Diese Resulta-

te haben meist langfristigen und qualitativen Charakter und erlauben nur sehr eingeschränkt, die Ergebnisunsicherheiten zu quantifizieren. Im Gegensatz dazu versuchen Nowcasting und Forecasting, mit Methoden der Zeitreihenanalyse quantitative Aussagen über den aktuellen und den unmittelbar zu erwartenden Pandemieverlauf zu treffen. Für diese Zielsetzung sind auch agentenbasierte Modelle, stochastische Differenzialgleichungen (SDEs) und *Mixed-Effects-Modelle* denkbar.

Alternative Prognoseansätze zu Schritt 2

Für die Prognose der COVID-19-Patient*innen in einer Intensivbehandlung gibt es einen sehr ähnlichen statistischen Ansatz von Farcomeni et al. [10], der ohne die raum-zeitliche Verknüpfung mit dem Außendruck auf Intensivstationen, d. h. die Anzahl der COVID-19-Neuinfektionen aus der Bevölkerung, auskommt. Der hier vorgestellte Ansatz erweitert prinzipiell den Ansatz von Farcomeni et al. [10] durch die Einbindung weiterer externer Prädiktoren.

Ein weiterer Ansatz ist das „Bundesweites Belastungsmodell für Intensivstationen durch COVID-19“ [11], das seinen Fokus vor allem auf den potenziellen Einfluss von hypothetischen Szenarien legt für einen zeitlich weiten Blick. Im Gegensatz dazu stützen sich die hier in dieser Arbeit beschriebenen Prognosemodelle primär auf die bisherige und aktuelle Situation, während keine Annahmen über die potenziell zukünftigen Veränderungen z. B. durch den Einfluss bevölkerungsweiter Maßnahmen getroffen werden. Eine Annahme für die Prognose ist, dass die aktuell vorliegende Entwicklung in dieser Form auch für die kommenden 20 Tage bestimmend ist, und fokussiert auf die unmittelbare Handlungssteuerung.

Limitationen

Eine Hauptlimitation dieser Modelle liegt in der Natur der Daten (absolute Häufigkeiten im Zeitreihenformat). Dieses Datenformat erlaubt zwar Prognosen basierend auf populationsaggregierten Korrelationen, doch sie sind prinzipiell nicht für die Evaluationen zugrunde liegender

Forecasting models to guide intensive care COVID-19 capacities in Germany

Background: Time-series forecasting models play a central role in guiding intensive care coronavirus disease 2019 (COVID-19) bed capacity in a pandemic. A key predictor of future intensive care unit (ICU) COVID-19 bed occupancy is the number of new severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) infections in the general population, which in turn is highly associated with week-to-week variability, reporting delays, regional differences, number of unknown cases, time-dependent infection rates, vaccinations, SARS-CoV-2 virus variants, and nonpharmaceutical containment measures. Furthermore, current and also future COVID ICU occupancy is significantly influenced by ICU discharge and mortality rates.

Methods: Both the number of new SARS-CoV-2 infections in the general population and intensive care COVID-19 bed occupancy rates are recorded in Germany. These data are statistically analyzed on a daily basis using epidemic SEIR (susceptible, exposed, infection, recovered) models using ordinary differential equations and multiple regression models.

Results: Forecast results of the immediate trend (20-day forecast) of ICU occupancy by COVID-19 patients are made available to decision makers at various levels throughout the country.

Conclusion: The forecasts are compared with the development of available ICU bed capacities in order to identify capacity limitations at an early stage and to enable short-term solutions to be made, such as supraregional transfers.

Keywords

Pandemics · Intensive care units · Bed occupancy · Resource allocation · Statistical models

Prozesse, wie z. B. veränderte Effekte bez. Impfungen, Altersverteilungen, Behandlungsmethoden, Virusvarianten, geeignet. Für entsprechend tiefergehende Studien sind patientenindividuelle Verlaufsdaten der gemeldeten SARS-CoV-2-Fälle und statistische Modelle sog. Multistadienmodelle notwendig [12, 13]. Dafür bedarf es einer entsprechenden Dateninfrastruktur, bei der Informationen der gemeldeten Neuinfektionsfälle aus der Bevölkerung mit individuellen Patientenverlaufsdaten sowie den Informationen der Behandlungskapazitäten der Krankenhäuser verknüpft sind.

Zusammenfassend lässt sich die Prognoseleistung wie folgt einordnen. Retrospektive Evaluationen zeigten, dass die kurzfristigen Prognosen (ca. 5–10 Tage) der COVID-19-Patient*innen in einer Intensivbehandlung relativ robust waren. Schwierig und herausfordernd sind sicherlich Wendepunkte, die zusätzlich noch regional unterschiedlich sind. Daher ist sowohl eine zeitnahe aktualisierte Modellierung und Schätzung als auch die Einbindung der Prognoseintervalle zur Einschätzung der Lage notwendig.

Schlussendlich sollte wie bei allen Prognosemodellen in der Infektionsepidemiologie auch hier das Prognoseparadoxon angesprochen werden: Wenn z. B. aufgrund der Prognosen überregionale Verlegungen oder politische Maßnahmen durchgeführt werden, kann die ursprüngliche Prognose nicht mehr wie vorhergesagt eintreten. Somit sollten die Annahmen, Stärken und Limitationen der zugrunde liegenden Prognosemodelle stets berücksichtigt werden, um die Vorhersagen differenziert bewerten zu können.

Korrespondenzadresse

Martin Wolkewitz

Institut für Medizinische Biometrie und Statistik, Medizinische Fakultät und Universitätsklinikum, Albert-Ludwigs-Universität Freiburg
Freiburg, Deutschland
wolke@imbi.uni-freiburg.de

Funding. Open Access funding enabled and organized by Projekt DEAL.

Einhaltung ethischer Richtlinien

Interessenkonflikt. H. Binder, M. Wolkewitz und L. Grabenhenrich machen folgende Angaben: BMG für die nichtwettbewerbsorientierte Finanzierung eines Forschungsprojekts zur Bewältigung der aktuellen COVID-Krise. Die Zahlungen erfolgten direkt an die Einrichtung IMBI und an das RKI. M. Grodd, L. Refisch, F. Lorenz, M. Fischer, M. Lottes, M. Hackenberg und C. Kreutz geben an, dass kein Interessenkonflikt besteht.

Für diesen Beitrag wurden von den Autoren keine Studien an Menschen oder Tieren durchgeführt. Für die aufgeführten Studien gelten die jeweils dort angegebenen ethischen Richtlinien.

Open Access. Dieser Artikel wird unter der Creative Commons Namensnennung 4.0 International Lizenz veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Artikel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.

Weitere Details zur Lizenz entnehmen Sie bitte der Lizenzinformation auf <http://creativecommons.org/licenses/by/4.0/deed.de>.

Literatur

1. Ärzteblatt DÄG Redaktion Deutsches (2021) COVID-19-Pandemie: Regionale Steuerung der Patienten. <https://www.aerzteblatt.de/archiv/217457/COVID-19-Pandemie-Regionale-Steuerung-der-Patienten>. Zugegriffen: 17. Mai 2021
2. www.intensivregister.de
3. Refisch L, Lorenz F, Riedinger T et al (2021) Data-driven prediction of COVID-19 cases in Germany for decision making. medRxiv. <https://doi.org/10.1101/2021.06.21.21257586>
4. Tönsing C, Timmer J, Kreutz C (2018) Profile likelihood-based analyses of infectious disease models. Stat Methods Med Res 27(7):1979–1998. <https://doi.org/10.1177/0962280217746444>
5. Gräsner JT, Hannappel L, Zill M, Alpers B, Weber-Carstens S, Karagiannidis C (2020) Innerdeutsche Verlegungen. Dtsch Arztebl 117(48):A 2321–3. <https://covid19forecasthub.eu>
6. Bracher J, Wolfrum D, Deuschel J et al (2021) Short-term forecasting of COVID-19 in Germany and Poland during the second wave—a preregistered study. medRxiv. <https://doi.org/10.1101/2020.12.24.20248826>
7. <https://kitmetricslab.github.io/forecasthub>
8. <https://covid-simulator.com/>
9. Farcomeni A, Maruotti A, Divino F, Jona-Lasinio G, Lovison G (2021) An ensemble approach to

short-term forecast of COVID-19 intensive care occupancy in Italian regions. Biom J 63(3):503–513. <https://doi.org/10.1002/bimj.202000189>

11. Schuppert A, Theisen S, Fränkel P, Weber-Carstens S, Karagiannidis C (2021) Bundesweites Belastungsmodell für Intensivstationen durch COVID-19. Med Klin Intensivmed Notfallmed. <https://doi.org/10.1007/s00063-021-00791-7>
12. Rieg S, von Cube M, Kalbhenn J et al (2020) COVID-19 in-hospital mortality and mode of death in a dynamic and non-restricted tertiary care model in Germany. PLoS ONE 15(11):e242127. <https://doi.org/10.1371/journal.pone.0242127>
13. Roimi M, Gutman R, Somer J et al (2021) Development and validation of a machine learning model predicting illness trajectory and hospital utilization of COVID-19 patients: a nationwide study. J Am Med Inform Assoc. <https://doi.org/10.1093/jamia/ocab005>

Ankündigung



Münchener Workshop „Kindernotfälle“ gemäß DIVI-Curriculum

20./21.10.2023

Die Behandlung von akuten lebensbedrohlichen Notfällen im Säuglings- und Kindesalter stellt immer wieder eine immense Herausforderung dar. Die Situationen sind selten und erfordern häufig in kurzer Zeit viele Therapieentscheidungen. Im 2-Tages-Seminar „Kindernotfälle gem. DIVI“ werden deshalb häufige Kindernotfälle sowie deren Erstversorgung näher erörtert. Kurzen Impulsvorträgen vermitteln zu den wichtigsten Notfällen im Kindesalter alltagsrelevante Informationen. Diese werden anschließend in Workshops Kleingruppen unter der Anleitung erfahrener Tutor*Innen umgesetzt. Der Kurs richtet sich an alle in der Erstversorgung lebensbedrohlicher Notfälle tätigen Kolleginnen und Kollegen aus Klinik und Rettungsdienst

Veranstalter: Kinderklinik und Kinderpoliklinik im Dr. von Haunerschen Kinderspital der LMU München

Teilnahmegebühr: (inkl. Verpflegung und Buch „Kindernotfall-ABC“) - **610 €** bei Anmeldung bis 31.08.2023 und **650 €** bei Anmeldung ab 01.09.2022

Veranstaltungsort: Institut für Notfallmedizin und Medizinmanagement (INM), Schillerstr. 53, 80336 München

Anmeldung: Online-Anmeldung und Programm unter COCS GmbH, München (siehe QR-Code)



www.cocs.de/veranstaltungen-und-kongresse