



Prof. Dr. Göran Kauermann
+49 (0)89 2180-6253
goeran.kauermann@lmu.de
Institut für Statistik
Ludwigstr. 33
80539 München

Prof. Dr. Helmut Küchenhoff
+49 (0)89 2180-2789
kuechenhoff@stat.uni-muenchen.de
Institut für Statistik
Akademiestr. 1/IV
80799 München

Dr. Ursula Berger
+49 (0)89 440077486
ursula.berger@lmu.de
IBE
Marchioninstr. 15
81377 München

CODAG Bericht Nr. 16
28.05.2021

1. Das aktuelle Ausbruchs- und Infektionsgeschehen in Schulen und an Arbeitsplätzen

Ursula Berger, Jana Gauß, Göran Kauermann

2. Belegung der Intensivbetten - wie ist der Zusammenhang mit den altersspezifischen Inzidenzen

Cornelius Fritz, Martje Rave, Göran Kauermann

3. Bewertung des Epidemie-Geschehens in Deutschland: Zeitliche Trends in der effektiven Reproduktionszahl

Annika Hoyer, Lara Rad, Ralph Brinks

4. Analyse der aktuellen pandemischen Situation anhand von Neuaufnahmen auf die Intensivstation


Felix Günther, Daniel Schlichting, Wolfgang Hartl¹, Helmut Küchenhoff

¹ Klinik für Allgemeine, Viszeral-, und Transplantationschirurgie, Campus Großhadern, KUM

1. Das aktuelle Ausbruchs- und Infektionsgeschehen in Schulen und an Arbeitsplätzen

Ursula Berger, Jana Gauß, Göran Kauermann

Verschiedene Maßnahmen zur Pandemiebekämpfung zielen auf die Kontrolle von Infektionsausbrüchen an Ausbruchsorten wie Schulen, Krankenhäusern, Seniorenheimen und Arbeitsplätzen ab. In diesem Zusammenhang ist auch die Einführung der Testpflicht in Schulen und das verpflichtende Testangebot an Arbeitsplätzen Mitte bzw. Ende April zu sehen. Von Interesse ist dabei zu untersuchen, wie sich die Zahlen der Infektionen aus Ausbrüche nach Einführung dieser Maßnahmen in den letzten Wochen entwickelt haben. Wir nutzen, wie schon in [CODAG-Bericht Nr. 12](#), Daten des Bayerischen Landesamts für Gesundheit und Lebensmittelsicherheit (LGL). Das LGL erfasst "Ausbrüche" und definiert diese als zwei oder mehr Infektionen, die epidemiologisch in einem Zusammenhang stehen. Zu jedem Ausbruch wird das Infektionsumfeld erfasst, also der "Ort" an dem Neuinfizierungen stattgefunden haben. Dabei ordnen wir einen gemeldeten COVID-19-Fall immer dem Umfeld zu, in dem die Infektion stattgefunden hat, d.h. wir betrachten das direkte Infektionsumfeld und nicht „übergeordnete Ausbrüche“.² Alle Auswertungen basieren auf den Daten zum Stichtag 26.5.2021. In Abbildung 1.1. zeigen wir die Anzahl der gemeldeten COVID-19 Infektion für unterschiedliche Ausbruchsorte nach Meldedatum.



Daten: Bayerisches Landesamt für Gesundheit und Lebensmittelsicherheit LGL
Visualisierung: CODAG LMU München

Abbildung 1.1.: Anzahl der Infektionen bei Ausbrüchen an den Ausbruchsorten Schule, Arbeitsplatz, Krankenhaus und Senioreneinrichtungen über die Zeit (Kalenderwochen).

² Beispiel zur Erläuterung "direktes Infektionsumfeld" und „übergeordnete Ausbrüche“: Wenn beispielsweise ein infizierter Beschäftigter die Infektion aus einem Ausbruch am Arbeitsplatz in den familiären Kreis trägt und dort Familienmitglieder ansteckt, so werden die Fälle in der Familie dem direkten Infektionsumfeld Haushalt zugeordnet. Der "übergeordnete Ausbruch" wäre der Ausbruch am Arbeitsplatz.

Die vier betrachteten Ausbruchsorte zeigen ein ganz unterschiedliches zeitliches Muster. Bekanntermaßen war die Zahl der gemeldeten Infektionen aus Ausbrüchen in Seniorenheimen Mitte Dezember mit einem Maximum von knapp 3000 gemeldeten Infizierten pro 7-Tage unvergleichbar höher als in einem der anderen Ausbruchsorte. In den Senioreneinrichtung und in den Krankenhäusern sind seit Ende 2020 die Zahlen der gemeldeten Fälle aus Ausbrüchen stark zurückgegangen und verbleiben seit März bzw. April auf einem niedrigen Niveau. In den Schulen gab es während der Schulschließung keine Ausbrüche. Aber auch **nach der schrittweisen Öffnung der Schulen für den Präsenzunterricht seit Mitte Februar (KW 8) ist die Anzahl der Fälle, die aus Infektionen an der Schule resultieren, sehr gering geblieben. Anders verhält es sich bei Infektionen, die nachweislich am Arbeitsplatz stattgefunden haben: Hier nimmt die Anzahl der gemeldeten Fälle seit Jahresbeginn zu.** Ein sprunghafter Rückgang in den Infektionen am Arbeitsplatz ist während der Osterfeiertage zu erkennen. Dieser Rückgang ist deutlich stärker als etwa im Krankenhaus oder in Senioreneinrichtungen und ist somit sicherlich nur teilweise auf Meldeverzug zurückzuführen, sondern vor allem darauf, dass die meisten Erwerbstätigen in dieser Zeit dem Arbeitsplatz fern blieben. Seit dem 20.04.2021 (KW 16) gilt das "Verbindliche Testangebot in Betrieben", d.h. Arbeitgeber müssen allen Beschäftigten mindestens zweimal wöchentlich einen Corona-Test anbieten³. Dies spiegelt sich direkt in den Daten durch einen sprunghaften Anstieg an gemeldeten Infektionen am Arbeitsplatz wider. Danach fallen die Infektionen an Arbeitsplätzen jüngst deutlich ab.

Wir sehen sowohl am Arbeitsplatz wie schon in den Schulen den deutlichen Effekt der Reihentestungen: Die Testpflicht bzw. das verpflichtende Testangebot führt zunächst zu einem sprunghaften Anstieg der Covid-19 Fällen. Langfristig sinken die Inzidenzzahlen aus Ausbrüchen wieder. Dieses Muster kann dadurch erklärt werden, dass Infektionsketten erkannt und unterbrochen werden können, was langfristig zu einer Reduktion der Inzidenzen führt.

Um das Ausbruchsgeschehen zu kontrollieren, sind effektive Maßnahmen notwendig, die ganz gezielt dort ansetzen, wo die Infektionsgefahr hoch ist. Im Vergleich zum Ausbruchsort Schule ist der Ausbruchsort Arbeitsplatz sehr viel heterogener (Büros mit wenigen Beschäftigten vs. große Produktionshallen, Beschäftigte mit vs. ohne Kundenkontakt etc.). Um hier die Ausbrüche richtig einzuschätzen und das Ausbruchsgeschehen am Arbeitsplatz effektiv zu reduzieren, ist es wesentlich, detailliertere Informationen zum Umfeld der Ausbrüche zur Verfügung zu stellen, die eine differenzierte Betrachtung erlauben, etwa zu Art der Arbeitsstätte, oder ob ein Ausbruch in einem großen Betrieben stattgefunden hat, wo eine hohe Zahl an betroffenen Beschäftigten in einem Raum zusammenarbeiten. Diese Daten liegen uns aktuell leider nicht vor.

Die Daten in Abbildung 1.1. zeigen den zeitlichen Verlauf, lassen aber die unterschiedlichen Größen der Ausbrüche im Vergleich zueinander nur schwer erkennen. Daher stellen wir in Abbildung 1.2. die Daten für die Wochen der dritte Welle nochmal in anderer Form dar. **Anhand dieser Darstellung ist sofort ersichtlich, dass derzeit die Ausbrüche an Arbeitsplätzen zahlenmäßig klar dominieren**, während die Gesamtzahl der Fälle bei Ausbrüchen in Seniorenheimen und Krankenhäusern jetzt deutlich niedriger liegen. **Die Fallzahlen aus Ausbrüchen in Schulen sind weiterhin unbedeutend gering.**

³ https://www.gesetze-im-internet.de/corona-arbschv/___5.html




Abbildung 1.2.: Anzahl der Infektionen bei Ausbrüchen an den Ausbruchsorten Schule, Arbeitsplatz, Krankenhaus und Senioreneinrichtungen über die Zeit (Kalenderwochen), dargestellt in einer Abbildung.




Abbildung 1.3.: Anzahl von Infektionen bei Kindern mit Ausbruchsort Schule (durchgezogene Linien) und anderweitigen Infektionsorten (gestrichelte Linie) über die Zeit (Kalenderwochen).

Die untergeordnete Rolle von Schulausbrüchen sowie der Effekt von Reihentests an Schulen auf die Meldeinzidenzen wird in Abbildung 1.3. noch einmal auf andere Weise gezeigt. Hier ist die Zahl der gemeldeten Infektion bei Kindern, die sich nachweislich an Schulen infiziert haben (durchgezogene untere Linien, im Vergleich zu allen anderen Infektionen bei Kindern (gestrichelte Linien) dargestellt. Den sprunghaften Anstieg der Gesamtzahl gemeldeter Fälle unter den Schülern in KW 15, der die Reduktion der Dunkelziffer durch die in Schultests identifizierten Fälle widerspiegelt, haben wir bereits in [CODAG Bericht Nr. 14](#)⁴ aufgezeigt. Die aktuellen Daten zeigen überraschenderweise, dass die Meldeinzidenzen insgesamt in allen drei Altersgruppen der Schulkinder nach diesem ersten Anstieg nun absinken. Der Anteil der Infektionen aus Schulausbrüchen bleibt auch in den folgenden Wochen KW 16-19 verschwindend gering. Im Mittel waren etwa 1% der gemeldeten Fälle bei Kindern auf Infektionen an der Schule zurückzuführen. Dieser Anteil hat sich nach den Osterferien tendenziell verringert. **Das bedeutet, dass nach der weiteren Öffnung der Schulen für den Präsenzunterricht nach den Osterferien die Infektionen bei den Schulkindern letztlich zurückgegangen sind und es nicht zu vermehrten Infektionen in der Schule kam und. Dabei kann davon ausgegangen werden, dass durch die Reihentestung unter Schülerinnen und Schülern die Dunkelziffer in diesen Altersgruppen gegen Null geht, also in diesen Altersgruppen durch die Meldeinzidenzen das Infektionsgeschehen jetzt so gut wie vollständig wiedergegeben wird.**

Der Untersuchungszeitraum schließt dabei jetzt auch den Pandemiephase ein, in dem die neuen Virusvarianten präsent waren und dabei zeigt sich, dass sich die Rolle der Schulkinder bei der Verbreitung des Virus⁵ offenbar nicht verändert hat. Darüber hinaus konnte wir bereits in [CODAG Berichte Nr. 10 und Nr. 12](#) zeigen, dass sich Infektionen bei Kindern und Jugendlichen kaum auf die Inzidenzentwicklung in anderen Altersgruppen auswirken.

Die Zahlen spiegeln erneut die untergeordnete Rolle der Schule am Infektionsgeschehen wider. Diese Ergebnisse können in der aktuellen Diskussion um Impfungen für Schulkinder zur Vermeidung von Infektionen an Schulen helfen und zur Versachlichung beitragen.

Literatur

Berger, U., Fritz C., Kauermann, G.: Eine statistische Analyse des Effekts von verpflichtenden Tests an Schulen mit Präsenzunterricht im Vergleich zum Distanzunterricht. Department of Statistics: Technical Reports, Nr. 23, Mai 2021, <https://epub.ub.uni-muenchen.de/76005/>

⁴ siehe auch: <https://epub.ub.uni-muenchen.de/76005/>

⁵https://www.rki.de/DE/Content/InfAZ/N/Neuartiges_Coronavirus/Situationsberichte/Maerz_2021/2021-03-30-de.pdf?__blob=publicationFile

2. Belegung der Intensivbetten - wie ist der Zusammenhang mit den altersspezifischen Inzidenzen

Cornelius Fritz, Martje Rave, Göran Kauermann

Die nachfolgenden Analysen betrachten die Belegung der Intensivstationen in Deutschland und vergleichen die zweite und dritte Welle. Wir wollen herausarbeiten welche unterschiedlichen Dynamiken es gegeben hat und welche altersspezifischen Inzidenzen die treibenden Kräfte bei der Belegung der Intensivstationen sind. Hierzu benutzen wir Daten der Deutschen Interdisziplinären Vereinigung der Intensiv- und Notfallmedizin (DIVI).

In Abbildung 2.1. zeigen wir für die 16 Bundesländer den Verlauf der Bettenbelegung auf den Intensivstationen während der zweiten und dritten Welle. Dargestellt ist jeweils der prozentuale Anteil an mit COVID-19 Patient*innen belegten Betten, an sonstig belegten Betten und an freien Betten, jeweils getrennt für die zweite und dritte Welle. Der untere orange Bereich zeigt die COVID-19 Betten, der mittlere blaue Teil die anderweitig belegten Betten und der obere graue Teil zeigt die freien Betten. Die zweite Welle, hier dargestellt für den Zeitraum November 2020 bis Anfang Januar 2021, zeigt einen kontinuierlichen Anstieg an Bettenauslastung durch COVID-19 Patient*innen. Die einzelnen Bundesländer sind dabei unterschiedlich betroffen. **Herauszuheben sind die ostdeutschen Bundesländer Brandenburg, Sachsen, Sachsen-Anhalt und Thüringen, welche mit einem erst moderaten und dann steilen Anstieg der Bettenbelegung durch COVID-19 Fälle auffallen.**

Die dritte Welle, dargestellt in der unteren Graphik in Abbildung 2.1, unterscheidet sich im Verlauf von der zweiten Welle durch einen weniger dynamischen Anstieg, der in allen Bundesländern nun in einen Rückgang der Belegungsquote übergegangen ist. In der zweiten Welle ist der Anteil der freien Betten fast konstant zwischen 10 und 15% geblieben, siehe dazu auch die Analysen der Neuaufnahmen in Abschnitt 4.

Der Blick auf diese Zahlen offenbart, dass sich zweite und dritte Welle auch in Hinblick auf die Auslastung der Intensivstationen anders verhalten haben. Wir wollen daher der Frage nachgehen, welche altersspezifischen Inzidenzen den höchsten Erklärungsgehalt für die Rate an COVID Betten in den Intensivstationen haben. Hierbei geht es um die Fragestellung, inwieweit Inzidenzen in bestimmten Altersgruppen und versetzt um eine bestimmte Anzahl an Wochen gute Proxys für die Auslastung der Intensivstationen sind. Diese Fragestellung geht auch in Richtung von effizienten und guten Vorhersagemodellen. Wir beschränken uns hierbei auf die Analyse von bayerischen Daten und fassen die DIVI Daten der Kreise auf so genannte Integrierte Leitstellen zusammen⁶. Dies sind räumlich zusammengefasste Regionen mit gemeinsamem Versorgungsauftrag in Bezug auf Krankenhäuser und sonstige Gesundheitsversorgung. Als erklärende Größen benutzen wir altersspezifische Inzidenzen der Vorwoche sowie in den zwei davor liegenden Wochen, um die aktuelle Belegung der Intensivstation mit COVID-19 Patient*innen vorherzusagen. Wir betrachten dazu die Altersgruppen 30-39, 40-49, 50-65, 66-79 und > 80 Jahre. Die Ergebnisse sind, jeweils getrennt für die zweite und dritte Welle, in Abbildung 2.2.

⁶ siehe: <https://www.freistaat.bayern/dokumente/behoerde/5760175134101>

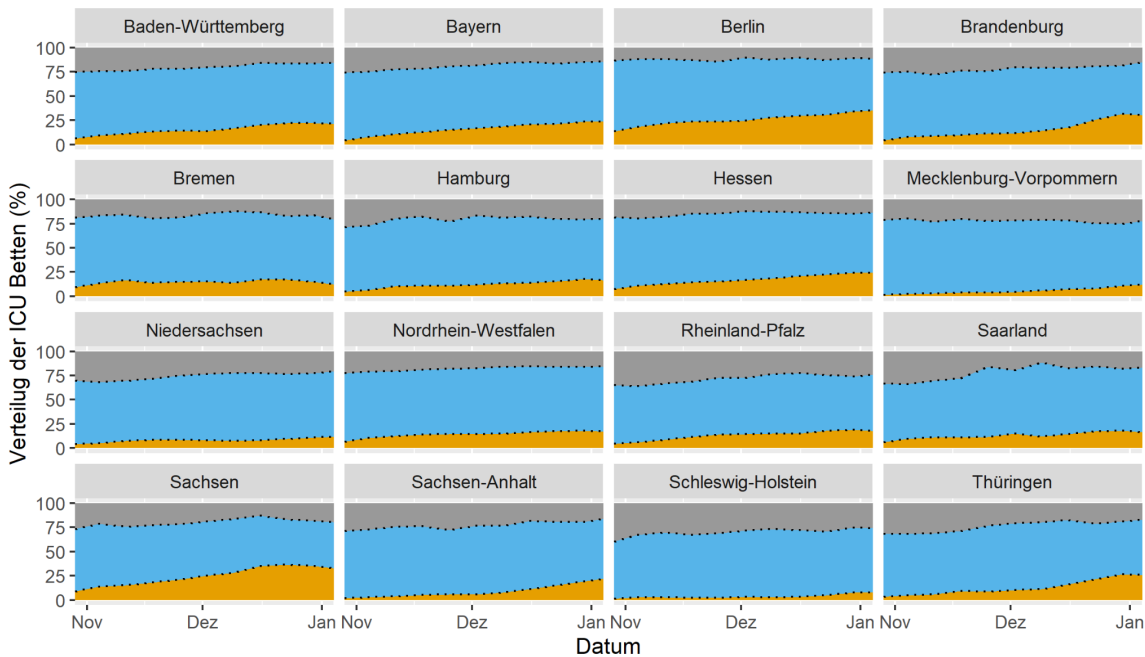
dargestellt. Für die zweite Welle verwenden wir Daten von KW 45 -51 in 2020 und für die dritte Welle KW 11-17 in 2021.

In der zweiten Welle lässt sich die Bettenbelegung durch COVID-19 Patient*innen am besten durch die Infektionen bei den über 80-Jährigen und bei den 40-49-Jährigen vorhersagen, jeweils versetzt um eine und zwei Wochen. Anders sieht es in der dritten Welle aus. Hier liefern die Inzidenzen bei den 50-65-Jährigen den größten Beitrag zur Vorhersage der Bettenbelegung mit COVID-19 Patient*innen, jeweils in allen drei Vorwochen. Ebenso zeigen die Inzidenzen bei den 40-49-Jährigen und bei den 66-79-Jährigen einen Erklärungsgehalt, wenngleich deutlich geringer. Insgesamt zeigt sich damit in der dritten Welle, dass die Inzidenzen in der Altersgruppe der arbeitenden Bevölkerung, hier primär die Inzidenzen bei den 50-65-Jährigen, den größten Beitrag zur Vorhersage der Intensivbettenbelegung von COVID-19 Patient*innen leisten.

Verteilung der ICU Betten, nach Kategorie der Belegung

Zweite Welle


zweite Welle



Verteilung der ICU Betten, nach Kategorie der Belegung

Dritte Welle

dritte Welle



Datenquelle: DIVI
Analyse und Visualisierung: CODAG@LMU

Abbildung 2.1. Verlauf der Beanspruchung der Intensivstationen durch COVID-19 Patient*innen in der zweiten Welle für die 16 Bundesländer. Der untere orange Bereich gibt den Anteil an COVID-19 Intensivbetten an, der mittlere blaue Bereich zeigt die sonstige Belegung, der obere graue Bereich zeigt den Anteil der freien Betten. Die obere Graphik zeigt den Zeitraum der zweiten Welle, die untere Graphik bezieht sich auf die dritte Welle.

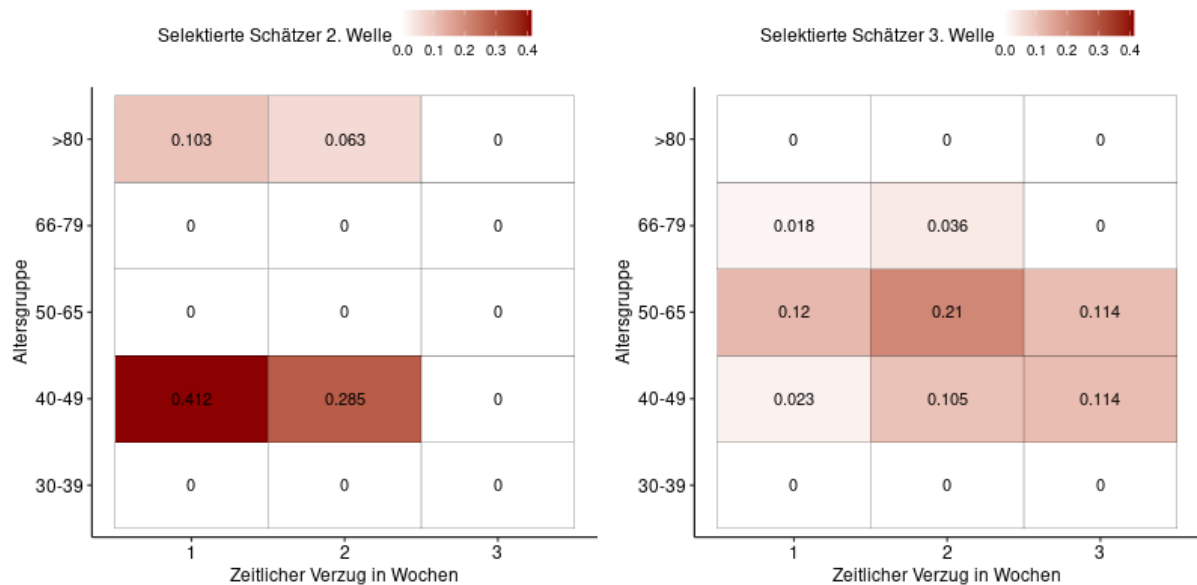


Abbildung 2.2. Einfluß von altersspezifischen Inzidenzen auf die Vorhersage der COVID-19 Belegung auf den Intensivstationen. Linke Abbildung für die zweite Welle, rechte Seite für die dritte Welle

Methodik: Um die oben beschriebene Fragestellung adäquat untersuchen zu können, müssen die hohen Kolinearitäten zwischen den einzelnen Kovariablen berücksichtigt werden. Generell sind diese Kolinearitäten erwartbar, da Inzidenzen in einer Woche oft stark von den Inzidenzen in der vorherigen Woche abhängen und auch simultane Abhängigkeiten zwischen altersspezifischen Inzidenzen oft vorkommen. Um dieses Problem zu lösen, verwenden wir den Lasso-Ansatz aus dem statistischen Lernen, welcher es uns erlaubt, nur Kovariablen mit hohem Erklärungswert zu selektieren (Tibshirani, 1996). Sollten beispielsweise zwei Kovariablen mit den gleichen Informationen und somit hoher Kolinearität in einer Regression verwendet werden, kann man so nur eine der beiden Kovariablen selektieren.

Die Zielvariable in unserem Modell ist die mittlere Rate an COVID-19 Patienten in einer Woche auf allen Intensivstation einer integrierten Leitstelle (ILS). Wir führen diese Berechnung auf Basis der ILS Regionen durch, da dementsprechend auch Patienten zwischen Krankenhäusern transportiert werden. Wir nehmen an, dass die Anzahl an Betten mit COVID-19 Patienten einer Poisson-Verteilung folgt und verwenden als Kovariablen alle oben genannten altersspezifischen Inzidenzen (30-39, 40-49, 50-65, 66-79 und > 80) verzögert um 1 bis 3 Wochen. Zusätzlich korrigieren wir für den zeitlichen Trend anhand wöchentlicher Dummy-Effekte. Die grundlegende Idee der Variablen-Selektion anhand der Lasso-Methode ist es, die Summe der absoluten Koeffizienten anhand eines Tuning-Parameters zu penalisieren. Wir penalisieren in unserer Anwendung nur alle Inzidenz-spezifischen Kovariablen und exkludieren die Dummyvariablen bei der Penalisierung, um für zeitliche Trends flexibel zu korrigieren. Anhand von Kreuzvalidierung können wir einen Tuning-Parameter bestimmen der zu einem minimalen Vorhersagefehler (hier die Devianz der Poisson-Verteilung) führt. In Abbildung 2.3. sind die Pfade der Schätzer für verschiedene Werte der Tuningparameter aus der zweiten und dritten Welle dargestellt. Die beiden vertikalen gestrichelten Linien indizieren jeweils die Penalisierung, welche zu den minimalen Vorhersagefehler führen. Fixieren wir diesen Tuningparameter dementsprechend, werden die Einflüsse von mehreren Einflussgrößen auf 0 geschätzt. Aufgrund der oben beschriebenen Penalisierung sind die so gefundenen Parameter jedoch verzerrt und können nicht ohne weiteres interpretiert werden. Aus diesem Grund schätzen wir in einem zweiten Schritt das Modell neu, verwenden jedoch nur die Kovariablen in dem Modell, welche in dem oben geschriebenen Lasso-Modell einen Schätzer ungleich 0 haben, und penalisieren nicht mehr die Parameter, um diese wie gewohnt interpretieren zu können (diese Schätzer sind in Abbildung 2.2 dargestellt).

Die Lasso-Modelle wurde in dem R-Paket "glmnet" (Friedman, 2010) und die generalisierten linearen Modelle der 2. Stufe mit "stats" (R Core Team, 2021) implementiert.

Literatur

Tibshirani, R. (1996), *Regression Shrinkage and Selection Via the Lasso*. Journal of the Royal Statistical Society: Series B (Methodological), 58: 267-288. DOI: <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>

Jerome Friedman, Trevor Hastie, Robert Tibshirani (2010). *Regularization Paths for Generalized Linear Models via Coordinate Descent*. Journal of Statistical Software, 33(1), 1-22. URL <https://www.jstatsoft.org/v33/i01/>.

R Core Team (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

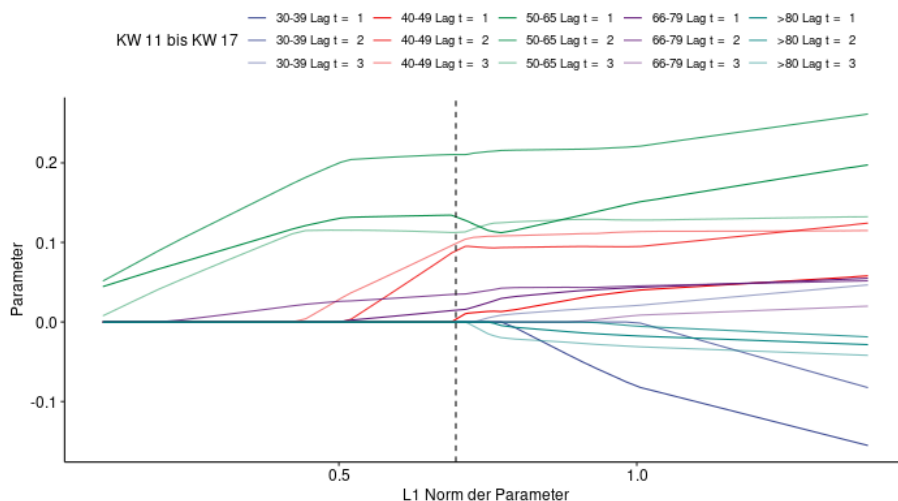



Abbildung 2.3. Pfad-Plots der Variablen Selektion

3. Bewertung des Epidemie-Geschehens in Deutschland: Zeitliche Trends in der effektiven Reproduktionszahl

Annika Hoyer, Lara Rad, Ralph Brinks

Eine Bewertung des Infektionsgeschehens des Erregers SARS-CoV-2 in der deutschen Allgemeinbevölkerung anhand der Anzahlen berichteter Fälle oder darauf basierender Raten, wie beispielsweise der 7-Tages-Inzidenz, ist aufgrund des variierenden Testverhaltens nur sehr eingeschränkt möglich. Unter variierendem Testverhalten soll hier der Sachverhalt verstanden werden, dass sich im Laufe der aktuell mehr als 14 Monate währenden Epidemie, die Durchführung von Tests sowohl zeitlich als auch regional sehr stark verändert und verändert hat. Wer zu welchem Zeitpunkt an welchem Ort mit welchem Verfahren getestet wird und dann ggf. zur Meldeinzidenz beiträgt, ändert sich dynamisch. Auf Bevölkerungsebene erkennt man das an der zeitlichen Schwankung der Testzahlen [RKIa]. Regionale Veränderungen manifestieren sich z.B. durch die sich oft ändernden Zugangskriterien, der Ausstattung und Verfügbarkeit von mobilen Testteams oder Testzentren.

Vor dem Hintergrund der Dynamik im Testverhalten muss man sich die Frage stellen, welches epidemiologische Maß geeignet ist, das Infektionsgeschehen angemessener zu beschreiben als die Meldeinzidenz. Es zeigt sich, dass die effektive Reproduktionszahl (R-Wert) verglichen mit der Anzahl der berichteten Fälle und 7-Tages-Inzidenz verhältnismäßig robust und deutlich unabhängiger vom Testgeschehen ist [Bri20]. Zwar birgt auch die Schätzung des R-Wertes einige statistische Schwierigkeiten wie z.B. das notwendige Nowcasting, aber der wesentliche Nachteil der Abhängigkeit vom Testverhalten, der große Schwankungen implizieren kann, entfällt.

Um zeitliche Veränderungen im Verlauf der effektiven Reproduktionszahl zu ermitteln, bietet sich das statistische Verfahren der Bruchpunktanalyse an. Führt man diese für den Verlauf des R-Wertes im Zeitraum vom 25. März 2020 bis zum 19. Mai 2021 wie vom RKI [RKIb] berechnet, so ergibt sich die Darstellung wie in Abbildung 3.1. Basierend auf den Daten, die das Statistische Beratungslabor der LMU München (<https://corona.stat.uni-muenchen.de/nowcast/>) zur Verfügung stellt, ergeben sich Verläufe für Bayern und München wie in Abbildungen 3.2 und 3.3 dargestellt.

Abbildung 3.1 Bruchpunktanalyse der effektiven Reproduktionszahl für Gesamtdeutschland im Zeitraum März 2020 bis Mai 2021 [RKIb].

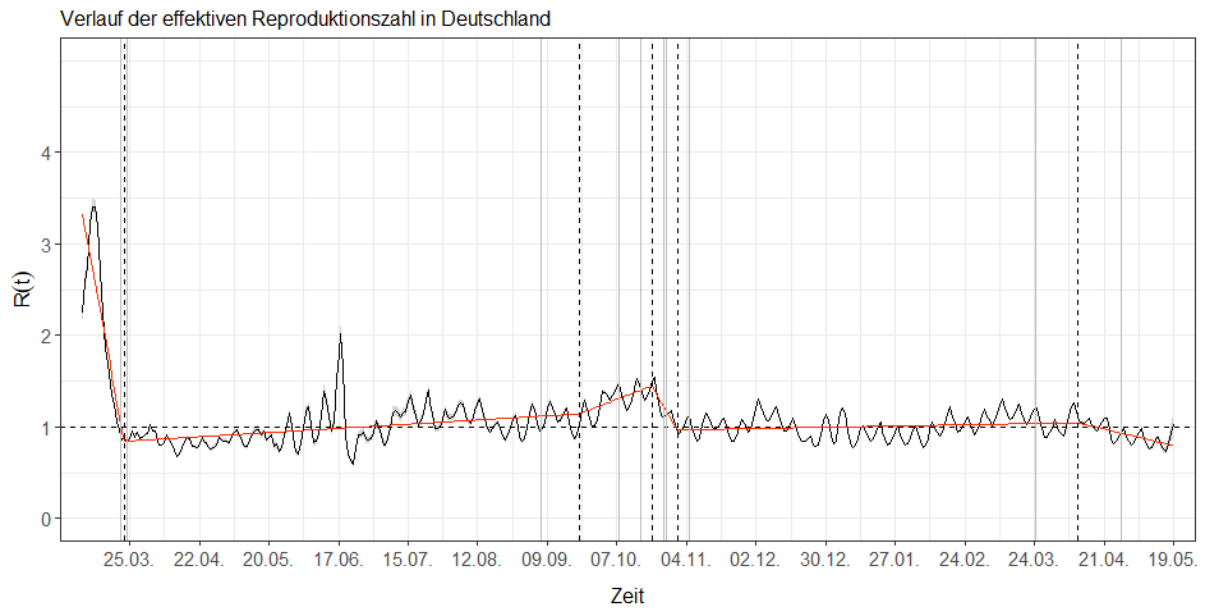


Abbildung 3.2 Bruchpunktanalyse der effektiven Reproduktionszahl für Bayern im Zeitraum März 2020 bis Mai 2021 [Datenquelle: <https://corona.stat.uni-muenchen.de/maps/>]





Abbildung 3.3 Bruchpunktanalyse der effektiven Reproduktionszahl für München im Zeitraum März 2020 bis Mai 2021 [Datenquelle: <https://corona.stat.uni-muenchen.de/maps/>]



Die schwarzen durchgezogenen Linien in Abbildung 3.1 – 3.3 stellen den geschätzten Verlauf der tagesaktuellen R-Werte dar, wobei der umgebende graue Bereich den Unsicherheitsbereich angibt. Als vertikale gestrichelte Linien werden die geschätzten Bruchpunkte mit ihren Unsicherheitsbereichen dargestellt. Die roten Linien beschreiben den geschätzten linearen Verlauf des R-Werts. Punkte mit Änderungen des zeitlichen Trends erscheinen als Knicke in den roten Geradensegmenten.

Betrachtet man den Verlauf des R-Wertes für Deutschland, so erkennt man fünf geschätzte Bruchpunkte. Die erste Veränderung fand Ende März 2020 statt. Vor diesem Zeitpunkt fiel der R-Wert deutlich ab, was mit einer gestiegenen öffentlichen Diskussion und ersten Maßnahmen, wie beispielsweise der Absage großer Veranstaltungen, zusammenhängen kann. Ende März war der R-Wert etwas unter 1, stieg im Laufe des ersten Lockdowns jedoch leicht an, sodass auch Werte größer als 1 erkennbar sind. Damit wird der Verlauf der ersten Welle der Pandemie deutlich. Der verlangsamte Anstieg des R-Wertes könnte hierbei mit saisonalen Effekten und ersten Maßnahmen zu Kontaktbeschränkungen assoziiert sein. Der zweite Bruchpunkt ergibt sich Ende September 2021. Der effektive R-Wert steigt dann bis in die zweite Oktoberhälfte an (dritter Bruchpunkt), um danach bis Anfang November abzufallen. Jedoch ist der Wert fast durchgängig größer als 1, was auf ein zunehmendes Infektionsgeschehen im Rahmen der zweiten Welle hindeutet. Von Anfang November 2020 bis Mitte April 2021 ist ein leichter Anstieg des R-Werts erkennbar, wobei dieser konstant im Mittel um den Wert 1 schwankt. Man erkennt dabei, dass der R-Wert bereits vor dem „Lockdown-Light“ am 2. November 2020, sowie der „Verschärfung“ am 16. Dezember 2020 sank, was somit auf eine Abschwächung des Infektionsgeschehens bereits vor den ergriffenen Maßnahmen hindeutet. Ende 2020/ Anfang 2021 war der R-Wert zeitweise kleiner als 1, was mit einem Rückgang der absoluten Fallzahlen einherging, was aber ein Kurzzeiteffekt über die Feiertage zum Jahreswechsel sein könnte. Danach steigt der R-Wert leicht an, sodass die dritte Welle erkennbar ist. Ab Mitte April fällt der R-Wert erneut. Der

Abfall ist auch hier schon vor der „Bundesnotbremse“ erkennbar, sodass die ergriffenen Maßnahmen den Verlauf des Infektionsgeschehens durchaus positiv beeinflusst haben könnten, jedoch nicht allein ursächlich für den Rückgang verantwortlich sind. Für Bayern und München ergeben sich ähnliche Verläufe der effektiven Reproduktionszahl. Für Bayern ergeben sich sechs Bruchpunkte. Dabei wird im Vergleich mit Deutschland ein zusätzlicher Bruchpunkt Anfang August identifiziert, nach dem der R-Wert leicht abfällt, um dann ab Ende September wieder anzusteigen. Für München ergeben sich analog zu Bayern sechs Bruchpunkte.

Um die zeitlichen Veränderungen der effektiven Reproduktionszahl genauer zu untersuchen, haben wir neben einem Modell mit linearen Effekten (Abbildungen 3.1 – 3.3) auch ein Modell mit stückweise konstant geschätzten Werten betrachtet (Abbildungen 3.4 – 3.6). Diese Abbildungen unterstreichen die Veränderungen im zeitlichen Verlauf noch etwas deutlicher. Für Deutschland erhält man beispielsweise sechs konstante Segmente. Nach einem sehr hohen R-Wert zu Beginn der Pandemie im März 2020, fällt dieser in zeitlicher Nähe mit ersten Maßnahmen zu Kontaktbeschränkungen, Ende März stark ab. Im Sommer erfolgt dann ein erneuter leichter Anstieg, welcher im Herbst deutlich zunimmt und somit die zweite Welle der Pandemie beschreibt. Es erfolgt dann ab November ein Abfall der effektiven Reproduktionszahl auf einen Wert nahe 1, der bis jetzt anhält. Ein vergleichbarer Verlauf zeigt sich für Bayern und München.

Abbildung 3.4 Verlauf der effektiven Reproduktionszahl für Gesamtdeutschland unter Annahme stückweise konstanter Segmente




Abbildung 3.5 Verlauf der effektiven Reproduktionszahl für Bayern unter Annahme stückweise konstanter Segmente


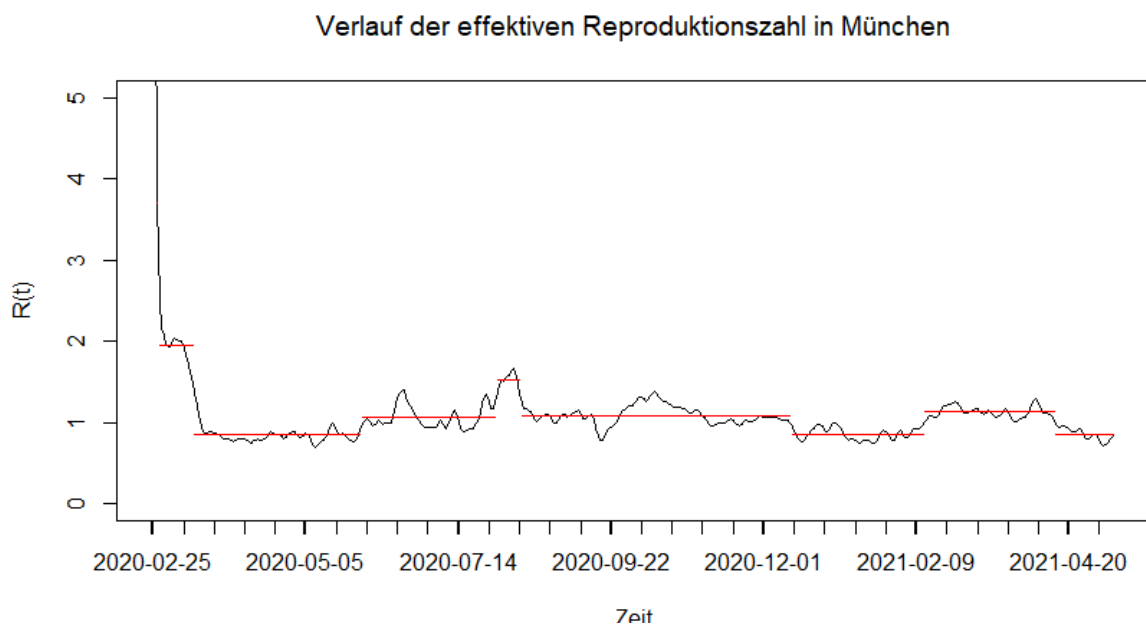


Abbildung 3.6 Verlauf der effektiven Reproduktionszahl für München unter Annahme stückweise linearer Segmente



Fazit: Um den zeitlichen Verlauf des Infektionsgeschehens mit dem Coronavirus zuverlässig zu beurteilen, sollte man neben anderen Indikatoren auch die effektive Reproduktionszahl (R-Wert) heranziehen. Im Gegensatz zur Anzahl der berichteten Fälle und der 7-Tages-Inzidenz hängt der R-Wert nur wenig vom Testverhalten und den berichteten positiven Befunden ab. Bei den R-Werten wie sie vom Robert-Koch-Institut täglich bestimmt werden, ergibt sich seit September kein unmittelbarer Zusammenhang mit den getroffenen Maßnahmen - weder mit dem Lockdown-Light am 2. November und der Verschärfung am

16. Dezember 2020, noch mit der „Bundesnotbremse“, die Ende April 2021 beschlossen wurde.

Literatur

[Bri20] Brinks R, Küchenhoff H, Timm J, Kurth T, Hoyer A (2020) Epidemiological measures for informing the general public during the SARS-CoV-2-outbreak: simulation study about bias by incomplete case-detection (under peer-review) doi: 10.1101/2020.09.23.20200089

[RKIa] Robert-Koch-Institut: Tabellen zu Testzahlen, Testkapazitäten und Probenrückstau pro Woche (Zugriff 24.05.2021)
https://www.rki.de/DE/Content/InfAZ/N/Neuartiges_Coronavirus/Daten/Testzahlen-gesamt.html

[RKIb] Robert-Koch-Institut:
https://www.rki.de/DE/Content/InfAZ/N/Neuartiges_Coronavirus/Projekte_RKI/Nowcasting_Zahlen_csv.csv?__blob=publicationFile (Zugriff 24.05.2021)

4. Analyse der aktuellen pandemischen Situation anhand von Neuaufnahmen auf die Intensivstation

Felix Günther, Daniel Schlichting, Wolfgang Hartl, Helmut Küchenhoff

Analog zu unseren früheren Berichten analysieren wir zunächst die Anzahl der auf Intensivstationen (Intensive Care Unit - ICU) aufgenommenen COVID-19 Patient*innen. Das Robert-Koch-Institut stellt gemeinsam mit der Deutschen Interdisziplinäre Vereinigung für Notfall- und Intensivmedizin (DIVI) täglich Daten zur Belegung von Betten mit COVID-19 Patienten auf Intensivstationen zur Verfügung⁷. Diese Daten werden vollständig und zeitnah gemeldet. Die tägliche Anzahl der ICU-Neuaufnahmen wird jedoch im Intensivregister, bzw. den öffentlichen Tagesberichten nur auf Bundesebene veröffentlicht. Um die entsprechenden Zahlen auf der Ebene der Bundesländer abzuschätzen, verwenden wir ein statistisches Modell: Die Belegungszahl an einem bestimmten Tag setzt sich aus der Anzahl der Neuaufnahmen am selben Tag, der Zahl der an diesem Tag verlegten oder verstorbenen Patienten, sowie der Anzahl neu aufgenommener Personen der Vortage zusammen, die weiterhin auf der Intensivstation behandelt werden. Wenn die Verteilung der Liegedauern auf den Intensivstationen bekannt ist, kann aus der Anzahl der belegten Betten die Anzahl an Neuaufnahmen pro Tag geschätzt werden⁸, siehe Günther (2021). Bei der Modellierung ist zu beachten, dass die Zahl der echten Neuaufnahmen niedriger sein dürfte, da aufgrund von Verlegungen zwischen verschiedenen Intensivstationen Doppelzählungen auftreten. Ist der relative Anteil dieser sogenannten Sekundärverlegungen näherungsweise konstant über die Zeit, ändert sich die Interpretation der Bruchpunktanalysen nicht. Da viele Patient*innen aus Brandenburg in Berliner Kliniken behandelt werden, werden die Daten aus Berlin und Brandenburg zusammengefasst. Ähnliches gilt für die Kliniken in den Bundesländern Hamburg und Bremen. Daher fassen wir die Daten aus Hamburg und Schleswig-Holstein und die Daten aus Bremen und Niedersachsen jeweils zusammen. Die Daten und Ergebnisse der Schätzung der täglichen Neuaufnahmen stellen wir in regelmäßig aktualisierter Form auf einer Website bereit⁹.

Ziel der aktuellen Analyse ist es, Trends und strukturelle Veränderungen bei der Zahl an Neuaufnahmen zu erkennen. Dafür verwenden wir Bruchpunktmodelle. Hierbei wird der Verlauf der Kurven datengesteuert in unterschiedliche Phasen gleichen Wachstums bzw. Rückgangs eingeteilt. Details zur Methodik siehe Küchenhoff et al. (2020). Wir betrachten hier die aktuellsten Entwicklungen.

In Abbildung 4.1. sind die Ergebnisse für die Bundesländer grafisch dargestellt. Sie zeigen, über alle Bundesländer hinweg eine anhaltende Abnahme der geschätzten täglichen Neuaufnahmen und damit eine deutliche Entspannung der Lage. Die allgemeine Trendwende weg von einem Anstieg der täglichen Neuaufnahmen ist dabei über die Bundesländer hinweg ungefähr Mitte April eingetreten. In einigen Bundesländern folgt darauf ein bis zum aktuellen Zeitpunkt anhaltend stabiler Rückgang der täglichen Anzahl an Neuaufnahmen. In den meisten Bundesländern kann jedoch zunächst nur eine Stabilisierung bzw. ein leichter Rückgang beobachtet werden der sich dann aber ab Ende

⁷ www.divi.de / <https://www.intensivregister.de>


⁸ CODAG Bericht Nr 9: https://www.covid19.statistik.uni-muenchen.de/pdfs/codag_bericht_9.pdf

⁹ <https://corona.stat.uni-muenchen.de/icu/>

April bis Mitte Mai verstärkt. Zum aktuellen Zeitpunkt gibt es in keinem Bundesland Anzeichen für eine Veränderung/Abschwächung des Abwärtstrends.

Tabelle 4.1 stellt die aktuellen Steigungsfaktoren und die Zeitpunkte der jeweils letzten Trendänderungen, sowie weitere Kennzahlen zur Belastung der Intensivstationen dar. Die höchste Anzahl an belegten Intensivbetten sowie die höchste Anzahl an geschätzten täglichen Neuaufnahmen, jeweils pro 100.000 Einwohnern, ist weiterhin in Sachsen und Thüringen zu beobachten. Auch in diesen Bundesländern ist jedoch im Wochenvergleich die Zahl der mit COVID-Patient*innen belegten Betten um 19.0% bzw. 16.8% zurück gegangen. Insgesamt variiert dieser prozentuale Rückgang im Vergleich zur Vorwoche über die Bundesländer hinweg zwischen 13.5% (Baden-Württemberg) und 33.0% (Sachsen-Anhalt).

Abbildung 4.1. Geschätzter Verlauf der täglichen Neuaufnahmen auf Intensivstationen in den deutschen Bundesländern. Dargestellt sind jeweils die Zahlen pro 100 000 Einwohner. Die blauen Linien markieren jeweils die geschätzten Punkte der Trendänderung (Bruchpunkte) mit den zugehörigen Konfidenzintervallen. Datenstand: 26.05.21.



Datenquelle: DIVI
 Visualisierung: Statistisches Beratungslabor StaBLab, LMU München

Tabelle 4.1 Vergleich der Indikatoren für das Infektionsgeschehen in den verschiedenen Bundesländern. Angegeben ist das Datum der letzten Trendänderung bei den ICU Neuaufnahmen entsprechend dem Bruchpunktmodell, der aktuelle tägliche Steigungsfaktor (geschätzt aus Bruchpunktmodell), die belegten Betten pro 100.000 Einwohner und die prozentuale Veränderung im Vergleich zur Vorwoche. Schließlich wird die geschätzte Anzahl an täglichen Neuaufnahmen pro 100.000 und deren prozentuale Veränderung im Vergleich zur Vorwoche angegeben. Alle Angaben zum Datenstand 26.05.21.

Bundesland	Datum der letzten Trend-Änderung ICU-Aufnahmen	aktueller tägl. Steigungsfaktor der ICU-Aufnahmen	Belegte ICU Betten pro 100.000	Änderung der belegten ICU Betten in %	Geschätzte Anzahl tägl. Neuaufnahmen pro 100.000	Änderung der tägl. Neuaufnahmen in %
Sachsen	13.05.21	0.95 [0.95, 0.96]	6.6	-19.0	0.38	-29.8
Thüringen	10.04.21	0.98 [0.97, 0.98]	5.8	-16.8	0.38	-16.6
Hessen	06.05.21	0.97 [0.96, 0.97]	4.5	-15.8	0.27	-20.3
Saarland	06.05.21	0.96 [0.95, 0.97]	4.1	-30.2	0.26	-26.8
Baden-Württemberg	07.05.21	0.97 [0.96, 0.97]	4.0	-13.5	0.25	-21.7
Berlin & Brandenburg	28.04.21	0.96 [0.96, 0.97]	3.7	-19.6	0.22	-18.8
Nordrhein-Westfalen	28.04.21	0.96 [0.96, 0.96]	3.6	-19.0	0.20	-23.7
Bayern	29.04.21	0.97 [0.96, 0.97]	3.6	-15.6	0.21	-21.6
Mecklenburg-Vorpommern	27.04.21	0.96 [0.96, 0.97]	2.6	-15.3	0.17	-13.7
Sachsen-Anhalt	14.04.21	0.97 [0.96, 0.97]	2.6	-33.0	0.16	-32.8
Rheinland-Pfalz	18.04.21	0.97 [0.97, 0.98]	2.5	-22.9	0.15	-24.7
Bremen & Niedersachsen	05.05.21	0.97 [0.96, 0.97]	2.4	-16.5	0.15	-14.0
Hamburg & Schleswig-Holstein	16.04.21	0.98 [0.97, 0.98]	2.0	-18.8	0.13	-17.1

Literatur

Günther, F. *Code to estimate the daily numbers of new ICU admissions from the number of occupied beds*. 2021, https://github.com/FelixGuenther/backcalc_icu

Küchenhoff, H., Günther, F., Höhle, M. und Bender, A. *Analysis of the early COVID-19 epidemic curve in Germany by regression models with change points*. *Epidemiology and Infection*, 2021 Vol 149, e68. DOI: <https://doi.org/10.1017/S0950268821000558>