

MODUS-COVID Bericht vom 16.06.2023

Modellierung von Inzidenzwachstum nur basierend auf Mobilität und
Tageshöchsttemperatur

Sydney Paltra¹, Inan Bostanci², Kristina Maier²,
Sebastian Alexander Müller¹, Jakob Rehmann¹,
Christof Schütte², Tim Conrad², Kai Nagel¹

¹Verkehrssystemplanung und Verkehrstelematik ("VSP"), TU Berlin

nagel@vsp.tu-berlin.de

²Zuse-Inst. Berlin ("ZIB")

Available via TU Berlin repository: <https://doi.org/10.14279/depositonce-17851>

Date of this version: 16-June-2023

This work is licensed under a Creative Commons Attribution 4.0 International License (CC BY 4.0)

<https://creativecommons.org/licenses/by/4.0/>

Website: <https://covid-sim.info>

Zusammenfassung

Wir stellen ein neues datenbasiertes Modell vor, das einen Großteil der wöchentlichen Veränderung der Inzidenz nur mit Hilfe der aushäusigen Aktivitätsdauer und der Tageshöchsttemperatur erklären kann. Dafür betrachten wir den Zeitraum März 2020 bis Ende 2020, um die nach diesem Zeitraum durch Impfungen und Alpha-Variante verursachte zusätzliche Komplexität zu vermeiden. Unser finales einfaches Modell kann knapp 65% der Inzidenzveränderung erklären.

Mit diesem Modell lässt sich also die Annahme bestätigen, dass Kontaktreduktionen zur Eindämmung des Infektionsgeschehens zentral waren. Für die Wirksamkeit politischer Maßnahmen besteht allerdings die Notwendigkeit, die Maßnahmen sowie die Kommunikation von deren Notwendigkeit so zu gestalten, dass die Verhaltensänderungen der Bevölkerung tatsächlich stattfinden.

Einleitung

Im Rahmen der fortlaufenden Forschung innerhalb des MODUS-Covid Projekts haben wir eine Vielzahl von Berichten im Kontext der Corona-Pandemie erstellt. Diese Berichte befassen sich mit unterschiedlichen Aspekten der Modellierung und Simulation der Dynamik von Covid-19. Ein bedeutender Schwerpunkt unserer Arbeit ist die kontinuierliche Weiterentwicklung und Anwendung eines komplexen agenten-basierten Modells (ABM). Dieses Modell ermöglicht uns, wertvolle Einblicke in die Infektionsdynamik von Covid-19 zu gewinnen.

Mit dem ABM konnten wir während der Pandemie die Auswirkungen verschiedener Interventionsmaßnahmen simulieren und haben damit Strategien zur Eindämmung der Pandemie entwickelt und bewertet. Die mittlerweile erreichte Komplexität des Modells erlaubt uns,

tiefgehende Analysen und Simulationen im Kontext von Covid-19 durchzuführen. Allerdings hat die gestiegene Komplexität auch den Ressourcenbedarf (z.B. an immenser Rechenleistung, dadurch benötigter Zeit und Energie, aber auch an Arbeitskraft zur Erhaltung und Erweiterung des Modells) erhöht.

Wir konzentrieren uns daher aktuell auf die Entwicklung von zusätzlichen Modellen, beispielsweise Regressionsmodellen, die auf spezifische Aspekte der untersuchten Phänomene spezialisiert sind. Eines unserer zentralen Ziele ist es, Wirkungszusammenhänge, welche im ABM durch die Modellannahmen berechnet werden, retrospektiv und durch nun vorliegende empirische Daten nachzuweisen.

In diesem Bericht präsentieren wir ein solches Modell, das den Einfluss des Verhaltens der Bevölkerung auf das Inzidenzwachstum und damit die Reproduktionszahl (R-Wert) untersucht.

Wirkungskette nicht-pharmazeutischer Interventionen

In diesem Abschnitt beschreiben wir die Wirkungskette von politischen Maßnahmen auf die Infektionsdynamik im Hinblick auf nicht-pharmazeutische Interventionen (NPIs). Dadurch können wir die Zusammenhänge zwischen politischen Entscheidungen, dem Verhalten der Bevölkerung, dem R-Wert und letztendlich den Auswirkungen auf das Gesundheitssystem untersuchen. Die Teilschritte dieser Wirkungskette sind (Abb. 1):

- 1) Eine **NPI** wirkt mit einer gewissen Stärke auf das **Verhalten der Bevölkerung**. Beispiel: ob (und in welchem Maße) seitens der Politik angeordnete Kontaktbeschränkungen von der Bevölkerung tatsächlich befolgt werden.
- 2) Das **Verhalten der Bevölkerung** beeinflusst den **R-Wert**, also wie viele weitere Personen eine infizierte Person ansteckt.
- 3) Aus dem **R-Wert** (zusammen mit der Generationszeit¹ und der derzeitigen Inzidenz) entsteht die (zukünftige) **Inzidenz**, also die relative Häufigkeit von Neuinfektionen pro Zeiteinheit. Ist der R-Wert größer als eins, dann wächst die Inzidenz. Dieser Zusammenhang ist eine reine Umrechnung.
- 4) Ein Teil der angesteckten Bevölkerung hat einen schweren Verlauf und **belastet damit das Gesundheitssystem**. Die Wahrscheinlichkeit eines schweren Verlaufs hängt von verschiedenen Faktoren ab, z.B. dem Alter (Sharafutdinov et al. 2021; Schuppert et al. 2022).
- 5) Nicht alle Infizierten werden vom Meldesystem erfasst; es werden z.B. asymptomatische Infektionen nicht immer erfasst und auch symptomatische Infektionen werden manchmal nur mittels Antigen- und nicht mittels PCR-Test bestätigt und gehen in Deutschland nicht in die Meldeinzidenz ein. Ist der Faktor der Untererfassung bekannt, so kann Inzidenz in **Meldeinzidenz** übersetzt werden. Die Ermittlung der Größen erfolgt in der Praxis hingegen oft umgekehrt: Die Meldeinzidenz liegt vor, die Dunkelziffer wird geschätzt und damit werden Aussagen über die tatsächlich zugrunde liegende Inzidenz abgeleitet.

¹ Generationszeit beschreibt den durchschnittlichen zeitlichen Abstand zwischen einer Infektion einer Person und Sekundärinfektionen, die von ihr ausgehen.

6) Schließlich wird, unter der Verwendung der Generationszeit (s.o.), der **(berichtete) R-Wert²** aus der Veränderung der Meldeinzidenz geschätzt (RKI 2020b).

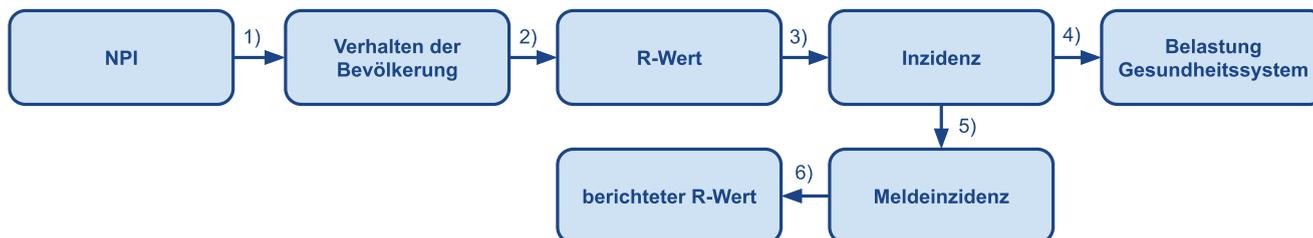


Abbildung 1: Darstellung der Wirkungskette nicht-pharmazeutischer Interventionen als Flow-Chart.

Zur Untersuchung des Zusammenhangs zwischen “Verhalten der Bevölkerung” und “R-Wert”, also Teilschritt 2, haben wir eine Regressionsanalyse durchgeführt. In diesem Bericht stellen wir die wesentlichen Ergebnisse dieser Untersuchungen vor.

Eingangsgrößen

Wir verwenden als Eingangsgrößen³ die aushäusigen Aktivitätendauern D sowie den Anteil der im Freien verbrachten Aktivitäten F .

Die aushäusige Aktivitätendauer (siehe Abbildung 2) gibt an, wie viele Stunden die Bevölkerung pro Tag außerhalb des eigenen Haushalts verbracht hat. Dieser Wert ist verwandt mit sog. Mobilitätsdaten, welche in verschiedenen anderen Studien verwendet werden (Schlosser et al. 2020), ist aber nicht identisch: Es ist durchaus möglich, bei gleichbleibender aushäusiger Aktivitätendauer (konstantem D) größere Entfernungen zu fahren (= höhere Mobilität).

Der Anteil der im Freien durchgeführten Freizeitaktivitäten F (siehe Abbildung 3) wird aus Wetterdaten hergeleitet. Wir gehen davon aus, dass dieser Mechanismus an beiden Enden begrenzt bzw. gesättigt ist, das bedeutet: Bei sehr kaltem Wetter finden fast alle Aktivitäten in Innenräumen statt, und noch kälteres Wetter ändert daran nichts mehr. Und umgekehrt: bei sehr warmem Wetter finden viele Aktivitäten außen (oder mit weit offenen Fenstern) statt, und noch wärmeres Wetter erhöht diesen Anteil nicht mehr weiter.

² Der berichtete R-Wert ist eine Approximation des tatsächlichen R-Werts: Das RKI erstellt im Rahmen des sog. Nowcastings eine Schätzung der bereits erfolgten Covid-19 Erkrankungen in Deutschland. Hierbei werden Diagnose-, Melde- und Übermittlungsverzögerungen berücksichtigt. Die Ergebnisse des Nowcastings und (die oben erwähnte) Generationszeit werden dann verwendet, um eine Schätzung des R-Werts zu ermitteln. Diese Schätzung wird berichtet.

³ = erklärende bzw. unabhängige Variablen.

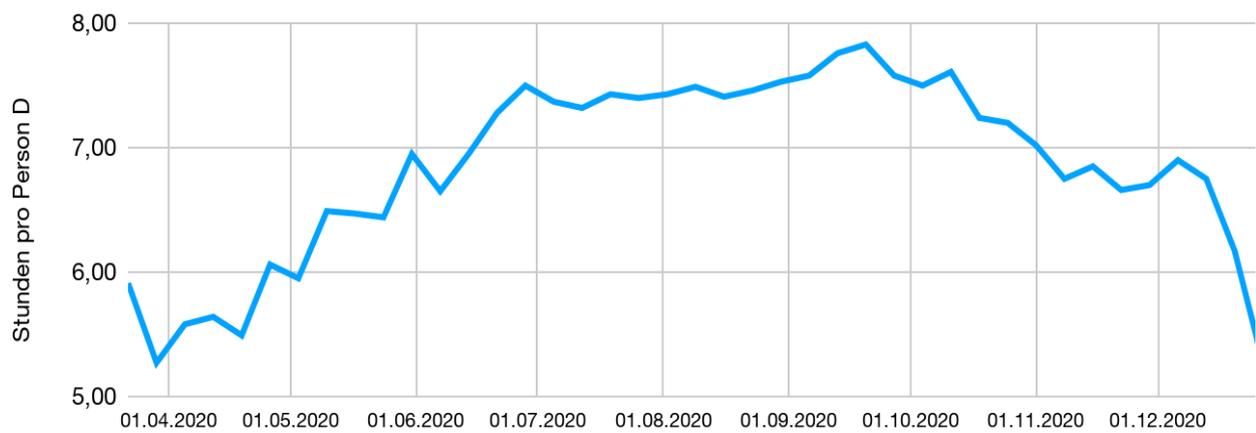


Abbildung 2: Im Mittel aushäusig verbrachte Zeit pro Person und Tag in Deutschland; ermittelt aus anonymisierten Mobilfunkdaten. Eigene Darstellung, Datenquelle: Senozon (2020).

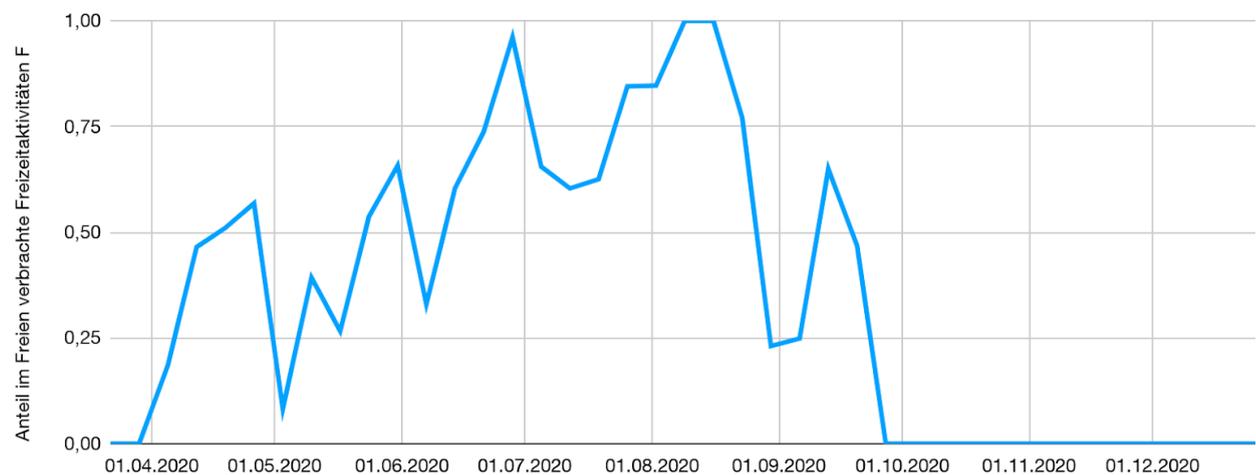


Abbildung 3: Anteil der im Freien durchgeführten Freizeitaktivitäten abgeleitet aus Wetterdaten (siehe Anhang). Erkennbar ist, dass im Sommer ein hoher Anteil von Freizeitaktivitäten im Freien stattfindet.

Veränderung der Inzidenz als Antwortvariable

Wir verwenden das wöchentliche relative Wachstum der deutschlandweiten Inzidenz⁴ des RKI (2023) als abhängige bzw. sogenannte Antwortvariable⁵ (vgl. Abb. 4). Das wöchentliche relative Wachstum der Inzidenz enthält fast die gleiche Information wie der R-Wert; z.B. entspricht ein R-Wert größer als 1 einem positiven Wachstum.⁶

⁴ Genauer: die 7-Tage-Inzidenz pro 100.000 Einwohner.

⁵ Die Definition für den Begriff "Antwortvariable" findet sich im Anhang.

⁶ Zur Umrechnung zwischen der wöchentlichen prozentualen Änderung und dem R-Wert benötigt man, wie oben bereits erwähnt, noch die sogenannte Generationszeit.

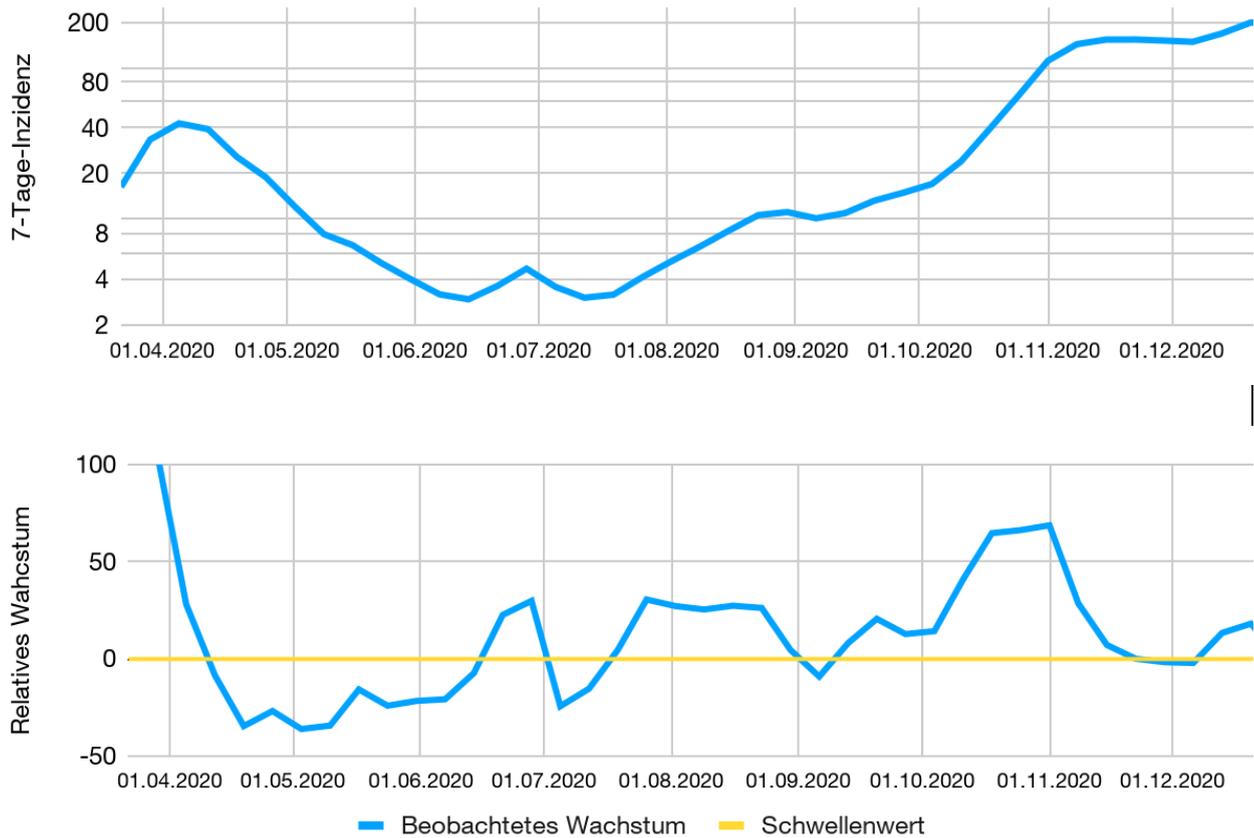


Abbildung 4: **Oben:** 7-Tage-Inzidenz, logarithmische Skala⁷. **Unten:** Wöchentliches relatives Wachstum der Inzidenz. Ab dem Schwellenwert (hier in gelb) von 0 steigt die Inzidenz, unterhalb der 0 fällt sie. Eigene Darstellung, Datenquelle: RKI (2023).

Zeitraum

Wir konzentrieren uns auf die Zeit vom Anfang der Pandemie (März 2020⁸) bis zum Ende des Jahres 2020. Damit vermeiden wir die durch das Aufkommen der Alpha-Variante eingetragene Inhomogenität sowie Beeinflussung durch die Impfkampagne ab Anfang 2021. In Bezug auf den beiden Eingangsgrößen und der Antwortvariable arbeiten wir jeweils mit wöchentlichen Mittelwerten.

⁷ Infektionswachstum ist multiplikativ: Ein R-Wert von z.B. 1,3 bedeutet immer, dass die Inzidenz in der nachfolgenden Generation 1,3 mal so groß ist wie in der vorherigen Generation, unabhängig von der Höhe der Inzidenz. Die logarithmische Skala ist für solche multiplikativen Prozesse eine angepasste Darstellung, weil gleiche Wachstumsraten als gleiche Steigungen dargestellt werden, unabhängig von der Höhe der Inzidenz.

⁸ Der erste in Deutschland laborbestätigte Fall lag am 28.01.2020 vor (RKI 2020a). Da die Meldeinzidenz im Februar 2020 allerdings noch sehr instabil war, die zu diesem Zeitpunkt bestätigten Fälle alle importiert waren und wir erst ab dem 01.03.2020 Zugriff auf Mobilitätsdaten haben, beginnt unsere Untersuchung erst im März 2020.

Regressionsmodell

Durch statistische Verfahren konnte ein Modell ermittelt werden, welches die zugrundeliegenden Daten sehr gut beschreibt. Dieses sogenannte Regressionsmodell hat folgende Form:

$$M_{w+2} = \beta_D D_w^2 - \beta_{DF} D_w^2 \times F_w,$$

wobei M der Wachstumsmultiplikator ist, D^2 das Quadrat der durchschnittlichen Dauer aushäusiger Aktivitäten, F der Anteil der im Freien durchgeführten Freizeitaktivitäten und w der Index für die betrachtete Woche. Der Wachstumsmultiplikator ist eine Umrechnung des oben beschriebenen relativen Wachstums: Um vom Prozentwert zum hier einzusetzenden Wert zu gelangen, muss die prozentuale Änderungsrate durch 100 geteilt und dann 1 addiert werden – z.B. übersetzt sich ein 30%iger Anstieg in einen Multiplikator von 1,3. Auch negatives Wachstum ist möglich – eine 20%ige Reduktion der Inzidenz von einer Woche zur nächsten übersetzt sich in einen Multiplikator von 0,8. Der Index “ $w+2$ ” drückt aus, dass die Wirkung der aushäusigen Aktivitätsdauern bzw. des Temperatureffektes auf die Meldeinzidenz zeitverzögert ist; wir haben die besten Resultate bei einem Zeitversatz von 2 Wochen erhalten.

Mittels der sogenannten Methode der kleinsten Quadrate erhalten wir für die Koeffizienten β_D und β_{DF} folgende (gerundete) Werte:

Variable	Koeffizient	Standardfehler	p-Wert	95% Konfidenzintervall
Quadrat aushäusiger Aktivitätendauer	$\beta_D = 0,024$	0,0008	<2e-16	(0,023; 0,026)
Quadrat aushäusiger Aktivitätendauer x Anteil Aktivitäten im Freien	$\beta_{DF} = 0,005$	0,0015	0,00171	(0,002; 0,008)
R²	0,644			
Adj. R²	0,625			

Tabelle 1: Während der Regressionsanalyse ermittelte (gerundete) Koeffizienten, Standardfehler (beschreibt die Genauigkeit der Schätzung der Koeffizienten, wird unter anderem zur Berechnung der Konfidenzintervalle genutzt), p-Wert (auch Signifikanzwert genannt, zeigt die Wahrscheinlichkeit an, dass ein gefundener Effekt sich rein zufällig aus dem verwendeten Datenausschnitt ergeben hat. Je kleiner der p-Wert, desto wahrscheinlicher liegt der gefundene Effekt auch in dem verwendeten Datenausschnitt vor. Üblicherweise wird bei einem p-Wert unter 0,05 der Effekt als signifikant eingestuft). Die Werte für R² beziehen sich auf ein Nullmodell vom Typ $f(x) = \bar{y}$, und nicht $f(x) = 0$ wie in manchen Softwarepaketen üblich für Regressionsmodelle ohne Schnittpunkt an der y-Achse.

Lesebeispiele:

- 1) Am 15.03.2020 beobachteten wir (noch vor Einführung der Kontaktbeschränkungen) bereits ein leicht reduziertes Aktivitätsniveau und die aushäusigen Aktivitätendauer lag bei 7,08 Stunden pro Person und Tag. Das Quadrat davon, D^2 , betrug also 50 (gerundet). Der Anteil der Freizeitaktivitäten im Freien lag bei 0,06.

Für zwei Wochen später, also für den 29.03.2020, ermittelt unser Regressionsmodell den Multiplikator $M = 0,024 * 50 - 0,005 * 50 * 0,06 \approx 1,2$, also eine wöchentliche Steigerung der Inzidenz um etwa 20%.⁹

- 2) Die ersten Kontaktbeschränkungen wurden am 22.03.2020 eingeführt. Wir beobachteten am 29.03.2020 ein deutlich reduziertes Aktivitätsniveau und die Bevölkerung verbrachte nur noch 5,27 Stunden pro Tag außer Haus. Der Quadrat der aushäusigen Aktivitätendauer D^2 betrug 27,8 (gerundet). Der Anteil der Freizeitaktivitäten im Freien lag bei 0.

Für zwei Wochen später ermittelt daher unser Regressionsmodell die Wachstumsrate $M = 0,024 * 27,8 - 0,005 * 27,8 * 0 \approx 0,7$, also ein wöchentliches *Absinken* der Inzidenz um etwa 30%.

- 3) Ab dem Beginn der Lockerungsphase im Mai 2020 stieg die aushäusige Aktivitätendauer D kontinuierlich und erreichte im Sommer 2020 ein prä-pandemisches Niveau. Am 09.08.2020 verbrachten die Menschen in Deutschland im Mittel 7,5 Stunden außer Haus, also betrug D^2 56,25. Der Anteil der Freizeitaktivitäten im Freien lag, bedingt durch die warmen Sommertemperaturen, bei 1. Damit erreicht der Koeffizient β_{DF} seinen vollen Effekt.

Unser Regressionsmodell ermittelt für zwei Wochen danach die Wachstumsrate $M = 0,024 * 56,25 - 0,005 * 56,25 * 1 \approx 1,07$, also eine wöchentliche Steigerung der Inzidenz um etwa 7%.

Dieses einfache Modell erklärt knapp 65% des relativen Wachstums der Inzidenz, was für ein solches reduziertes Modell ein hoher Wert ist.

Abb. 5 zeigt in rot die gemeldeten und in blau die aus diesem Regressionsmodell vorhergesagten Werte für die Wachstumsrate. Man sieht, dass das Modell (blau) gut den Beobachtungen (rot) entspricht. Überlegungen zu verbleibenden Abweichungen zwischen Modell und Realität finden sich im Anhang.

Die Aktivitätendauer geht in dieses Modell quadratisch ein. Dies entspricht dem aus unseren agenten-basierten Simulationen bekannten Effekt, dass Kontaktreduktionen doppelt wirken: Wenn z.B. nur noch 70% der Personen an einer Aktivität teilnehmen, dann werden zum einen nur noch 70% der möglichen Infektionen mitgebracht, und selbst wenn das passiert, können sich nur noch 70% der Personen anstecken. Eine Reduktion der Aktivitätenteilnahme auf 70% des ursprünglichen Niveaus senkt also die Infektionswahrscheinlichkeit bei dieser Aktivität bereits auf $70\% \times 70\% = 49\%$ des ursprünglichen Niveaus.

Es ist möglich, obiges Modell mathematisch umzuformulieren:

$$M_{w+2} = (\beta_D - \beta_{DF} F_w) D_w^2,$$

⁹ Wir verzichten hier auf die sonst für Schätzwerte übliche Notation \hat{M} .

Die zweite Darstellung unterstreicht, dass der quadratische Einfluss der Aktivitätendauer sich aus zwei Komponenten zusammensetzt: Einem Basis-Koeffizienten (β_D) sowie einer Reduktion durch den Wetterkoeffizienten (β_{DF}). Der Wettereffekt schwankt von $\beta_{DF} \cdot 0$ im Winter bis hin zu $\beta_{DF} \cdot 1$ im Sommer.

Insgesamt ist mit diesem Modell nachgewiesen, dass die aushäusigen Aktivitätendauern einen erheblichen Einfluss auf das Infektionsgeschehen haben. Dieser Effekt wird durch den "Wettereffekt" jeweils im Sommer abgeschwächt, wobei der Effekt der aushäusigen Aktivitätendauern denjenigen des Wetters überwiegt.

In Bezug auf die Wirkungskette (Abb. 1) ist damit der Zusammenhang zwischen "Verhalten der Bevölkerung" und "R-Wert" (Teilschritt 2) durch dieses Modell bestätigt. Weiterhin sind, wie oben bereits beschrieben, Teilschritt 3 (vom R-Wert zur Inzidenz) eine reine Umrechnung und Teilschritt 4 (von der Inzidenz zur Belastung des Gesundheitssystems) medizinisch zwangsläufig. Für ein erfolgreiches Pandemiemanagement ist vor allem ein besseres Verständnis von Teilschritt 1 notwendig – also die Frage, unter welchen Voraussetzungen die Bevölkerung politische Anordnungen in tatsächliche Reduktion der aushäusigen Aktivitätendauern umsetzt. Damit beschäftigt sich z.B. das infoXpand Projekt (infoXpand since 2022).

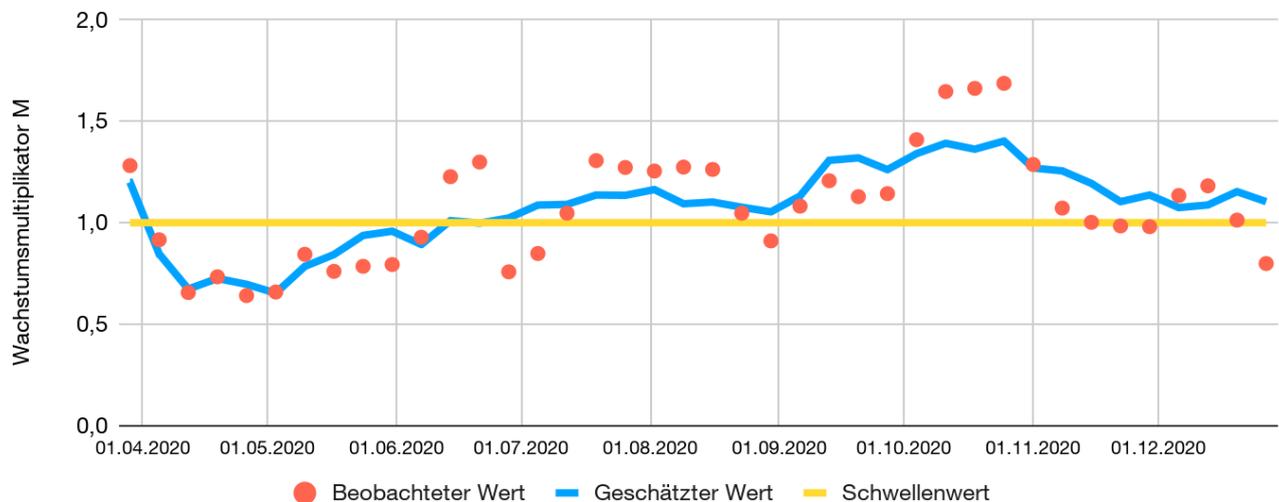


Abbildung 5: Beobachtete und geschätzte Wachstumsrate während des betrachteten Zeitraums.

Danksagung

Grundlage für diesen Bericht war unsere Arbeit im Rahmen des Forschungsprojekts [infoXpand](#). Eine wissenschaftliche Veröffentlichung der obigen Ideen ist in Arbeit und wird künftig, vorerst als Preprint, unter der DOI <https://doi.org/10.14279/depositonce-17965> zur Verfügung stehen. Im Rahmen des MODUS-Covid-Projekts haben wir nun die gewonnenen Kenntnisse für eine breitere Öffentlichkeit aufgearbeitet.

Quellen

Böttcher S, Oh DY, Staat D, Stern D, Albrecht S, Wilrich N, et al. Erfassung der SARS-CoV-2-Testzahlen in Deutschland (Stand 2.12.2020) [Internet]. Robert Koch-Institut; 2020 [cited 2023 Jun 2]. Available from: <https://edoc.rki.de/handle/176904/7532>

infoXpand. since 2022. Available from: https://webszh.uk-halle.de/monid/?page_id=1871

Meteostat. Historical Weather and Climate Data [Internet]. 2023 [cited 2023 May 25]. Available from: <https://meteostat.net/en/>

Müller SA, Balmer M, Charlton W, Ewert R, Neumann A, Rakow C, et al. Predicting the effects of COVID-19 related interventions in urban settings by combining activity-based modelling, agent-based simulation, and mobile phone data. PLoS One. 2021 Oct 28;16(10):e0259037.

RKI. Epidemiologisches Bulletin 7/2020 [Internet]. RKI.de. 2020a [cited 2023-05-30]. Available from: https://www.rki.de/DE/Content/Infekt/EpidBull/Archiv/2020/Ausgaben/07_20.pdf?__blob=publicationFile

RKI. Epidemiologisches Bulletin 17/2020 [Internet]. rki.de. 2020b [cited 2023 May 30]. Available from: https://www.rki.de/DE/Content/Infekt/EpidBull/Archiv/2020/Ausgaben/17_20.pdf?__blob=publicationFile

Robert Koch-Institut. 7-Tage-Inzidenz der COVID-19-Fälle in Deutschland [Internet]. 2023 [cited 2023 May 25]. Available from: <https://doi.org/10.5281/zenodo.7968896>

Schlosser F, Maier BF, Jack O, Hinrichs D, Zachariae A, Brockmann D. COVID-19 lockdown induces disease-mitigating structural changes in mobility networks. Proc Natl Acad Sci U S A. 2020 Dec 29;117(52):32883–90.

Schuppert A, Weber-Carstens S, Karagiannidis C. Intensivbettenbedarf für COVID-19 im Herbst/Winter 2021. Medizinische Klinik - Intensivmedizin und Notfallmedizin. 2022 Sep 1;117(6):439–46.

Senozon. The Senozon Mobility Model [Internet]. The Senozon Mobility Model. 2020 [cited 2020 Mar 19]. Available from: <https://senozon.com/en/model/>

Sharafutdinov K, Fritsch SJ, Marx G, Bickenbach J, Schuppert A. Biometric covariates and outcome in COVID-19 patients: are we looking close enough? BMC Infect Dis. 2021 Nov 4;21(1):1136.

Anhang

Wachstumsmultiplikator

Wir verwenden die täglich vorliegende nationale 7-Tage-Inzidenz pro 100,000 Einwohner des RKI. Mithilfe dieser täglichen Werte bestimmen wir den wöchentlichen Durchschnitt I_w für Woche w . Den Multiplikator M_w in der Woche w definieren wir als: $M_w := I_{w+1} / I_w$. Zum Beispiel entspricht eine 30%ige Erhöhung der Inzidenz einem Multiplikator von $M_w = 1,3$.

Anteil im Freien verbrachter Freizeitaktivitäten

Die Berechnung des Anteils der draußen verbrachten Freizeitaktivitäten erfolgt in 2 Schritten:

- Wir extrahieren für alle Landeshauptstädte während des Untersuchungszeitraums die Tageshöchsttemperatur von meteostat (Meteostat 2023). Aus den vorliegenden täglichen Zahlen berechnen wir wöchentliche Durchschnitte. Um nun eine mittlere Tageshöchsttemperatur auf nationaler Ebene zu berechnen, verwenden wir einen gewichteten Durchschnitt dieser wöchentlichen Werte: Die Gewichte hängen vom Bevölkerungsanteil des jeweiligen Bundeslandes ab. Im bevölkerungsreichsten Bundesland Nordrhein-Westfalen wohnen beispielsweise 17,9 Millionen Menschen, was ungefähr $\frac{1}{5}$ der Gesamtbevölkerung Deutschlands entspricht. Damit ist das Gewicht für Nordrhein-Westfalen $\frac{1}{5}$ und die Temperatur Düsseldorfs geht stärker in den nationalen Durchschnitt ein als beispielsweise die Temperatur der Stadt Bremen.

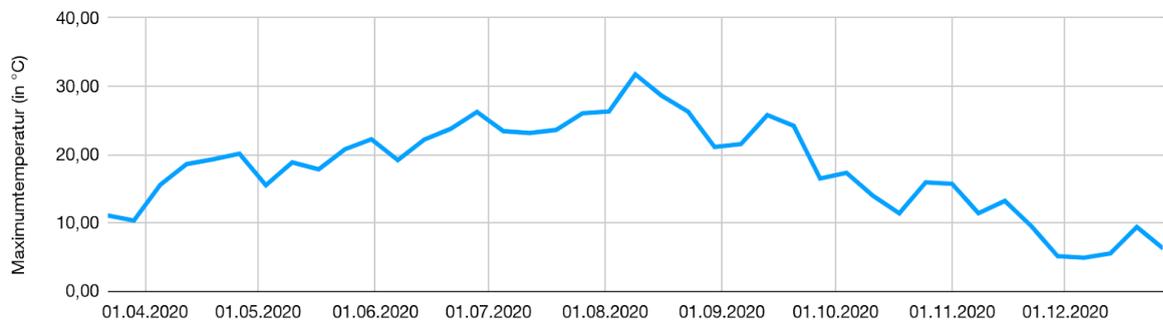


Abbildung 6: Mittlere Tageshöchsttemperatur in °C während des betrachteten Zeitraums. Eigene Darstellung, Datenquelle: (Meteostat 2023).

- Nach Berechnung der mittleren Tageshöchsttemperatur übersetzen wir diese in den “Anteil der im Freien durchgeführten Freizeitaktivitäten”. Hierbei übernehmen wir den Ansatz aus (Müller et al. 2021): Wir nehmen an, dass bis zu 100% der Freizeitaktivitäten im Sommer im Freien durchgeführt werden und dass dieser Anteil auf 0% während des Winters sinkt. Zur Berechnung des Anteils verwenden wir die im ersten Schritt (s.o.) berechnete Temperatur. Ist diese mittlere Tageshöchsttemperatur größer als $T^*+5^\circ\text{C}$, dann werden alle Aktivitäten im Freien durchgeführt, ist sie kleiner als $T^*-5^\circ\text{C}$, dann werden alle Aktivitäten in Innenräumen durchgeführt. Im Intervall $[T^*-5^\circ\text{C}, T^*+5^\circ\text{C}]$ wird interpoliert. Wir nehmen also eine Schwellenwert-Temperatur T^* an, ab welcher der Anteil der im Freien durchgeführten Freizeitaktivitäten nicht mehr steigen bzw. nicht mehr sinken kann. Im Frühling nutzen wir $T^* = 17,5^\circ\text{C}$ und lassen dann T^* linear wachsen bis zu $T^* = 25^\circ\text{C}$ im Herbst. Der daraus resultierende “Anteil der im Freien durchgeführter Freizeitaktivitäten” geht multipliziert mit dem Quadrat der aushäusigen Aktivitätendauer als unabhängige Variable in unsere Regressionsanalyse ein. – Dieser Ansatz hat sich im agenten-basierten Modell (ABM) bewährt. Wie haben auch einfachere Umrechnungen der Temperatur getestet, aber sowohl die Sättigung bei sehr hohen bzw. sehr niedrigen Temperaturen als auch die über den Sommer anwachsende Kälteempfindlichkeit haben sich als relevant herausgestellt.

Zeitlicher Abstand zwischen Mobilität + Temperatur und R-Wert

Veränderungen im Mobilitätsverhalten der Bevölkerung (und/oder der Temperatur) schlagen sich nur mit Zeitverzug im R-Wert nieder. Dieser Verzug basiert zum einen auf der Inkubationszeit, zum anderen aber auch auf dem Meldeverzug. Wir haben einen zeitlichen Verzug von 1 bis 4 Wochen in Betracht gezogen, schließlich aber einen Verzug von 2 Wochen als optimal ermittelt.

Mögliche Erklärungen für verbleibende Abweichungen

Aus Abbildung 5 ist abzuleiten, dass unsere geschätzten Werte grundsätzlich den tatsächlichen Werten folgen. Im Sommer allerdings (um Anfang Juli) fluktuieren die gemessenen Werte sehr stark: Während dieser Zeit waren die Inzidenzen sehr niedrig, woraus eine sehr hohe Messunsicherheit der Inzidenzen (und damit der Wachstumsrate) resultiert. Das Modell berücksichtigt diese Messunsicherheiten nicht. Ab August schafft es unser Modell wieder besser, die Infektionsdynamik abzubilden. Abweichungen finden wir erst wieder im Herbst 2020: Hier unterschätzt dieses Modell die Dynamik. Die Gründe hierfür sind nicht bekannt: Eine Änderung des Testregimes¹⁰ und Reiserückkehrer:innen aus den Herbstferien haben wir als mögliche weitere Faktoren in Betracht gezogen, allerdings wieder verworfen. Nach dem Beginn der Herbst- und Winterwelle überschätzt unser Regressionsmodell die tatsächliche Dynamik nur noch leicht.

Vokabeln

Regression: Eine Regressionsanalyse ist ein statistisches Analyseverfahren, das genutzt werden kann, um die Beziehung zwischen einer abhängigen und einer oder mehreren unabhängigen bzw. erklärenden Variablen zu beschreiben.

Abhängige Variable bzw. Antwortvariable: Variable, deren Wert vom Effekt einer oder mehrerer anderer Variablen abhängt. Ihre Variation wird versucht mithilfe der unabhängigen Variable(n) zu erklären.

Unabhängige/Erklärende Variable: Eine unabhängige Variable wird genutzt, um die Antwortvariable zu modellieren. Ihr Wert ist unabhängig von anderen Werten des Modells. Sie wird variiert, um ihre Auswirkungen zu untersuchen.

¹⁰ Am 03.11.2020 wurden die in Deutschland geltenden Testkriterien adaptiert. Nach Aussagen des RKIs ist es nicht möglich, die Testzahlen vor und nach der Umstellung direkt miteinander zu vergleichen (Böttcher et al. 2020).