

GOTTFRIED WILHELM LEIBNIZ UNIVERSITÄT HANNOVER  
FAKULTÄT FÜR ELEKTROTECHNIK UND INFORMATIK

# Der Weg wissenschaftlicher Erkenntnisse - Erforschung und Unterstützung der Wiederverwendung von Erkenntnissen in der Forschung

*Wissenschaftliche Arbeit, die für den Erwerb des folgenden Abschlusses eingereicht  
wird:*

**Master of Science in Informatik**

VON

**Verena Bolling**

Matrikelnummer: 3217540


E-mail: [verena.bolling@stud.uni-hannover.de](mailto:verena.bolling@stud.uni-hannover.de)

Erstprüfer: Prof. Dr. Sören Auer

Zweitprüfer: Dr. Markus Stocker

Betreuer: Dr. Markus Stocker

14.05.2024





# Eigenständigkeitserklärung

Ich, Verena Bolling, erkläre hiermit, dass die Masterarbeit mit dem Titel „Der Weg wissenschaftlicher Erkenntnisse - Erforschung und Unterstützung der Wiederverwendung von Erkenntnissen in der Forschung“ und die darin präsentierte Arbeit meine eigene ist. Weiterhin bestätige ich, dass:

- diese Arbeit während des Erwerbs eines Abschlusses an der Universität durchgeführt wurde.
- wenn Teile dieser Arbeit bereits für andere Abschlüsse oder Qualifikationen an dieser Universität oder anderen Institutionen eingereicht worden ist, dies klar gekennzeichnet ist.
- wo ich Publikationen anderer herangezogen habe, dies klar gekennzeichnet ist.
- wo ich die Arbeit anderer zitiert habe, immer die Quelle dessen genannt ist. Mit Ausnahme dieser Zitate, ist diese Abschlussarbeit vollständig mein Werk.
- ich alle wichtigen Quellen, die mir geholfen haben, angegeben habe.

Verena Bolling

Unterschrift: \_\_\_\_\_

Datum: \_\_\_\_\_



## *Danksagung*

Ich möchte mich bei meinem Betreuer Markus Stocker für die umfassende Unterstützung bedanken. Weiterhin möchte ich mich bei Mohamad Yaser Jaradeh und Allard Oelen aus dem ORKG-Team bedanken für die Hilfe und die Bereitschaft Probleme schnell und einfach zu lösen. Schlussendlich möchte ich auch einen Dank an meine Familie aussprechen, die mir das Studium ermöglicht hat und mich in allen Lebenslagen immer unterstützt hat.



## *Abstract*

Synthesis research is an approach to infer generalizations from various preceding publications. This makes them an appropriate subject matter of investigating how scientific knowledge spreads and is reused within research communities. While the internet has made scientific work more accessible, their unstructured format of plain-text documents lacks of machine readability. This thesis investigates in two case studies the role of *knowledge graphs* as a support of traceability, reusability and reproducibility of scientific knowledge in the context of synthesis research. The first study uses a bottom-up approach to recreate the results of synthesis about the air pollution during Covid-19 pandemic using the knowledge graph application ORKG. In the second case study a top-down approach is used to identify the provenance of the estimates for the impact of aerosols on the climate that is presented in the sixth Assessment Report of the Intergovernmental Panel on Climate Change (IPCC, 2021). The results suggest that the use of ORKG in a bottom-up approach can be a useful method to improve traceability and reproducibility.

*Keywords: synthesis research, scientific knowledge graphs, provenance, reproducibility*





## *Zusammenfassung*

Synthesearbeiten sind ein Ansatz, um aus verschiedenen vorangegangenen Veröffentlichungen Verallgemeinerungen abzuleiten. Dies macht sie zu einem geeigneten Untersuchungsobjekt, um zu analysieren, wie sich wissenschaftliche Erkenntnisse in Forschungsgemeinschaften verbreitet und wiederverwendet werden. Während das Internet den Zugang zu wissenschaftlichen Arbeiten erleichtert hat, ist ihr unstrukturiertes Format in Form von Klartextdokumenten nicht maschinenlesbar. Diese Arbeit untersucht in zwei Fallstudien die Rolle von Wissensgraphen als Unterstützung der Nachvollziehbarkeit, Wiederverwendbarkeit und Reproduzierbarkeit von wissenschaftlichen Erkenntnissen im Kontext der Syntheseforschung. Die erste Studie verwendet einen Bottom-Up-Ansatz, um die Ergebnisse der Synthese über die Luftverschmutzung während der Covid-19-Pandemie mit Hilfe der Wissensgraphenanwendung ORKG nachzubilden. In der zweiten Fallstudie wird ein Top-Down-Ansatz verwendet, um die Provenienz der Schätzungen für die Auswirkungen von Aerosolen auf das Klima zu ermitteln, die im sechsten *Assessment Report* des Intergovernmental Panel on Climate Change (IPCC) präsentiert werden. Die Ergebnisse lassen darauf schließen, dass eine Verwendung von ORKG im Bottom-Up-Ansatz eine sinnvolle Methode darstellen kann, um Nachvollziehbarkeit und Reproduzierbarkeit zu verbessern. *Schlüsselwörter: Synthesearbeiten, Scientific Knowledge Graphs, Provenienz, Reproduzierbarkeit*



# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
<b>2</b>	<b>Hintergrund</b>	<b>5</b>
2.1	Grundlagen . . . . .	5
2.1.1	Provenienz und Reproduzierbarkeit . . . . .	5
2.1.2	Scientific Knowledge Graphs und ORKG . . . . .	6
2.2	Ähnliche Arbeiten . . . . .	7
<b>3</b>	<b>Methoden</b>	<b>9</b>
3.1	Bottom-Up vs. Top-Down . . . . .	9
3.2	Synthesearbeit des Forschungszentrum Jülich . . . . .	11
3.2.1	Anwendung . . . . .	11
3.2.2	Implementierung . . . . .	16
3.3	Weltklimabericht des Intergovernmental Panel on Climate Change . .	17
<b>4</b>	<b>Ergebnisse</b>	<b>21</b>
4.1	Synthesearbeit des Forschungszentrum Jülich . . . . .	21
4.2	Weltklimabericht des Intergovernmental Panel on Climate Change . .	23
<b>5</b>	<b>Diskussion</b>	<b>35</b>
5.1	Einordnung hinsichtlich der Forschungsfragen . . . . .	35
5.2	Probleme und Schwierigkeiten bei der Umsetzung . . . . .	38
<b>6</b>	<b>Schlussfolgerungen und Aussicht</b>	<b>41</b>
	<b>Literatur</b>	<b>43</b>

# Abbildungsverzeichnis

2.1	Übersicht des W7-Modells von Ram et al. (2009) . . . . .	6
3.1	Ablauf der Analyse der Fallbeispiele . . . . .	10
3.2	Grundriss des Informationsflusses innerhalb der hier besprochenen Arbeiten	10
3.3	Aufbau des Templates für die <i>contributions</i> . <i>Resources</i> werden durch die ovalen und <i>literals</i> durch die rechteckigen Knoten dargestellt. . . . .	12
3.4	Aufbau des Templates für die Erfassung der Messungen. <i>Resources</i> werden durch die ovalen und <i>Literals</i> durch die rechteckigen Knoten dargestellt. . .	13
3.5	Aufbau des Templates für die Messresultate. <i>Resources</i> werden durch die ovalen und <i>Literals</i> durch die rechteckigen Knoten dargestellt. . . . .	13
3.6	Aufbau des Templates für den Ort der Messung. <i>Resources</i> werden durch die ovalen und <i>Literals</i> durch die rechteckigen Knoten dargestellt. . . . .	13
3.7	Beispiel für eine <i>contribution</i> . . . . .	14
3.8	Auszug aus der <i>Comparison</i> „Air Pollution Measurement during Covid-19 lockdown for Africa“. . . . .	15
4.1	Nachgebildetes Diagramm über die prozentuale Entwicklung (Median) von Feinstaubpartikeln (PM <sub>2.5</sub> ) pro Land . . . . .	22
4.2	Originales Diagramm über die prozentuale Entwicklung pro Land (Median) von Gkatzelis et al. (2021). (Abbildung 11, S. 27) . . . . .	23
4.3	Originales Diagramm von Gkatzelis et al. (2021) über die globale, prozentuale Median-Entwicklung von <i>NO<sub>2</sub></i> , <i>PM<sub>2.5</sub></i> und <i>O<sub>3</sub></i> . Die Daten sind nach Methode getrennt und wurden nach <i>Stringency Index</i> in Intervalle gruppiert. (Abbildung 6, S. 22) . . . . .	24
4.4	Auszug aus der Cross-Chapter Box 6.1, S. 875-878 im sechsten <i>Assessment Report</i> des IPCC . . . . .	24
4.5	Nachgestelltes Ergebnis der Analyse des globalen Rückganges von <i>PM<sub>2.5</sub></i> gruppiert nach <i>Stringency Index</i> . . . . .	25
4.6	Tabelle 7.6 aus dem siebten Kapitel des AR6, Seite 950 (Forster et al., 2021)	31
4.7	Tabelle 7.7 aus dem siebten Kapitel des AR6, Seite 951 (Forster et al., 2021)	32

4.8	Zusammensetzung des Aerosol-ERF in Bezug auf die Aerosol-Strahlungs-Interaktion. Knoten mit geringerer Farbsättigung zeigen Werte, die in der Auswertung weniger gewichtet wurden. . . . .	33
4.9	Zusammensetzung des Aerosol-ERF in Bezug auf die Aerosol-Wolken-Interaktion.	34
5.1	Die <i>comparisons</i> als Input für die Untersuchungen in ORKG. . . . .	36
5.2	Der Code, der zum Erzeugen der Ergebnisse genutzt wurde, kann in ORKG veröffentlicht werden . . . . .	38

# Tabellenverzeichnis

4.1 Übersicht über die Schätzungen für <i>Radiative Forcing</i> , die auf Observationsdaten basieren . . . . .	30
--	----

# Akronyme

**AOD** Aerosol Optical Depth

**AQI** Air Quality Index

**AR6** sechster Assessment Report des IPCC

**CAMS** Copernicus Atmosphere Monitoring Service

**CCN** Cloud Condensation Nuclei

**Cf** Cloud Fractional Coverage

**CMIP** Coupled Model Intercomparison Project. Meist mit Zahl dahinter, stehend für entsprechende Phase des Projekts

**ECMWF** European Centre for Medium-Range Weather Forecasts

**EDGAR** Emissions Database for Global Atmospheric Research

**ERF** Effective Radiative Forcing

**ERFaci** Effective Radiative Forcing from aerosol-cloud-interaction

**ERFari** Effective Radiative Forcing from aerosol-radiation-interaction

**ESM** Earth System Model

**IPCC** Intergovernmental Panel on Climate Change

**IRF** Instantaneous TOA Radiative Change

**IRFaci** IRF from aerosol-cloud-interaction

**IRFari** IRF from aerosol-radiation-interaction

**LWP** Liquid Water Path

**NASA** National Aeronautics and Space Administration

**ORKG** Open Research Knowledge Graph

**RDF** Resource Description Framework

**RFMIP** Radiative Forcing Model Intercomparison Project

**SKG** Scientific Knowledge Graph

**SOSA** Sensor, Observation, Sample, and Actuator

**TOA** Top of Atmosphere





# Kapitel 1

## Einleitung

Forschung basiert häufig auf den Ergebnissen vorangegangener Arbeiten. Sie werden durch neue Methoden oder Datensätze reevaluiert oder es wird versucht die Ergebnisse zu generalisieren. Cooper et al. (2009) beschreiben Synthesearbeiten als den Versuch, empirische Forschung zusammenzufassen, um so Verallgemeinerungen zu erstellen. Sie bieten somit ein Anschauungsbeispiel, wie sich wissenschaftliche Erkenntnisse innerhalb der Forschungsgemeinschaften bewegen und wiederverwenden lassen.

Leonelli (2020) schreibt in ihrer Arbeit, dass der heutige Wert von Daten in ihrer Mobilität, die die Ausbreitung von Daten in verschiedene Bereiche meint, und in ihrer Interoperabilität, die Fähigkeit verschiedene Typen von Daten aus diversen Quellen miteinander zu verknüpfen und zu verarbeiten, liege. Die Autorin bezieht sich hier auf Daten als mögliche Beweisgrundlage potenzieller Schlussfolgerungen. Jedoch kann dieses Prinzip auf wissenschaftliche Resultate übertragen werden, beziehungsweise können diese auch als Daten behandelt werden. In der Forschung werden häufig die gleichen Sachverhalte von verschiedenen Gruppen untersucht und nicht selten werden die Erkenntnisse von anderen damit verglichen oder eingeordnet, um ein umfängliches Bild oder verschiedene Quellen von Evidenz zu erhalten. Beispielsweise verarbeitet das Intergovernmental Panel on Climate Change (IPCC) tausende klimawissenschaftliche Veröffentlichungen, um eine umfängliche Zusammenfassung im Bezug auf den heutigen Zustand und mögliche Zukunftsszenarien für Fachfremde zu erstellen. Zwar ist dieser Bericht keine wissenschaftliche Publikation im eigentlichen Sinne, dennoch bietet sie einen Überblick darüber, wie sich Untersuchungen zum Klimawandel und dessen Treiber zu einer Gesamteinschätzung aggregieren lassen können und hat daher einige Parallelen zu Synthesearbeiten. Die Erkenntnisse werden in der Synthese also wie Eingabedaten behalten. Wenn Wissen auf den Out-

puts vorangegangener Publikationen aufbaut, ist es also folgerichtig, dass die Mobilität oder „Reise“, wie Leonelli (2020) die Bewegung von Daten nennt, nicht mit einer Erkenntnis endet, sondern eine Zwischenstation sein kann. Den Wissensgewinn als Reise zu verstehen, heißt auch, dass dieser nachvollziehbar und reproduzierbar sein kann.

Weiterhin schreibt Leonelli (2020), dass es ohne die Möglichkeit nachzuverfolgen, wie sich Daten und ihre Umgebung ändern, wenn sie sich in verschiedenen Kontexten bewegen, nicht möglich sei, neue Strategien zu entwickeln, Innovationen einzuführen oder auch Datenpraktiken und dessen Auswirkungen zu dokumentieren. Daraus folgert sie, dass es dann auch schwieriger sei, die Verantwortung für Fehler, Missverständnisse oder vorsätzliche Irreführung bei der Verwendung von Daten als Grundlage für Entscheidungen zu bestimmen. Angewendet auf Resultate wissenschaftlicher Arbeit, bedeutet dies, dass die Möglichkeit Resultate nachzuverfolgen wichtig ist, um die Transparenz wissenschaftlichen Arbeitens innerhalb und vor allem außerhalb der Peers zu erhöhen. Von dieser Nachvollziehbarkeit können sowohl fachfremde Forscher\*innen, als auch Studierende und wissenschaftliche Mitarbeiter\*innen des Fachs oder Randdisziplinen profitieren. Das nahtlose Anknüpfen an vorangegangene Forschung ist gängige Praxis und sollte somit analysiert werden.

Außerdem geht die Autorin auf die Problematik der Zitation ein. Eine Verlinkung auf verwendete Quellen ist durch das Zitieren von Arbeiten gegeben, wird aber vor allem dort unzuverlässiger, wo Daten aus Repositories stammen. Diese Verlinkungen könnten durch Scientific Knowledge Graphs hergestellt und nachvollziehbar gemacht werden. Gerade wenn Daten sich verändern, in anderer Form dargestellt und benutzt werden, leide die Integrität und eine klare Identifizierbarkeit (Leonelli, 2020). Das Gleiche ist auch auf wissenschaftliche Resultate zu übertragen. Je mehr Schlüsse sich aus ihnen in verschiedenen Kontexten ziehen lassen, desto mehr Wissen lässt sich aus ihnen ziehen. Jedoch wirkt sich dies negativ auf die Bestimmung der Provenienz aus.

Sowohl beim Bestimmen der Provenienz als auch beim Reproduzieren kann es einen großen Einfluss haben, in welcher Form Erkenntnisse zur Verfügung stehen. In einer zunehmend digitalisierten Welt liegt der Inhalt wissenschaftlicher Forschung noch immer hauptsächlich in nicht-maschinenlesbaren Klartextdokumenten vor. Ein für Maschinen lesbares Format ist heutzutage unabdingbar, um Daten zu verarbeiten. Wenn wissenschaftliche Erkenntnisse also wie Daten zu behandeln sind, müssen sie also digitalisiert und verwertbar gemacht werden. Eine Lösung dafür kann ein online verfügbarer Scientific Knowledge Graph (SKG) sein. Diese graphenbasierte Darstellung von Forschungsarbeiten ist sowohl für Menschen als auch Maschinen lesbar und kann daher beim Weiterverarbeiten von wissenschaftlichen Erkenntnissen,

---

insbesondere beim Zusammenfassen vieler verschiedener Arbeiten, eine Unterstützung sein und gleichzeitig durch die öffentliche Zugänglichkeit für mehr Transparenz im Prozess sorgen. Cooper et al. (2009) beschreiben diesen Prozess beim Erstellen von Synthesearbeiten in den folgenden Schritten:

1. Formulieren des Problems
2. Heraussuchen der relevanten Literatur
3. Extrahieren und Evaluieren der Daten
4. Analyse der Daten
5. Interpretation der Ergebnisse
6. Veröffentlichung

Das Generalisieren passiert vor allem in der Analyse der Daten. Es wird die Frage beantwortet, welche allgemeinen Aussagen sich aus den Daten schließen lassen. In genau diesem Schritt kann Transparenz und Nachvollziehbarkeit, welche Daten mit welcher Gewichtung einbezogen wurden, einen Mehrwert für die Leser\*innen der Arbeit haben.

Diese Arbeit soll sich mit der Frage beschäftigen, wie sich wissenschaftliche Erkenntnisse in der Forschung verbreiten. In diesem Zusammenhang werden sowohl die Reproduzierbarkeit als auch die Provenienz dieser untersucht. Durch das Analysieren von zwei Fallbeispielen sollen diese Reisen untersucht werden. Mit Hilfe dieser sollen in Bezug auf SKGs folgende **Forschungsfragen** beantwortet werden:

1. Wie können SKGs die Mobilität und Bestimmung der Provenienz wissenschaftlicher Erkenntnisse unterstützen?
2. Können sie Synthesearbeiten unterstützen?
3. Können sie die Reproduzierbarkeit von Forschungsergebnissen unterstützen?

Um diese Fragen zu beantworten, werden zwei Fallbeispiele untersucht. Im ersten Fall wird in einem Bottom-Up Verfahren die Synthesearbeit von Gkatzelis et al. (2021) reproduziert. Als zweites Anschauungsbeispiel dient der sechste *Assessment Report* des Intergovernmental Panel on Climate Change (IPCC). Hier wird dagegen in einem Top-Down Verfahren geprüft, ob sich einzelne Ergebnisse, die im Bericht präsentiert werden zurückverfolgen lassen. Zunächst werden in Kapitel 2 einige **Grundlagen** und andere **relevante Arbeiten** zu dem Thema besprochen. Anschließend werden

die **Methoden** der Arbeit, sowie die Fallbeispiele, die eine Reise darstellen, in Kapitel 3 erläutert. Die **Ergebnisse** der Untersuchungen werden in Kapitel 4 ausgeführt und zusammengefasst. In Kapitel 5 werden die Resultate hinsichtlich der oben aufgeführten Fragen **diskusiert**. Die Arbeit schließt mit einem **Fazit** in Kapitel 6.

# Kapitel 2

## Hintergrund

### 2.1 Grundlagen

#### 2.1.1 Provenienz und Reproduzierbarkeit

Der Frage wann eine Arbeit reproduzierbar ist, wurden zahlreiche Untersuchungen gewidmet. Fidler und Wilcox (2021) geben einen Überblick über verschiedene Definitionen, die sich insbesondere auf verschiedene Fachbereiche beziehen. Ihre Hauptunterscheidung liegt in zwei möglichen Auffassungen von Reproduzierbarkeit. Der ersten Definition nach seien Studien reproduzierbar, wenn diese sich grundsätzlich wiederholen ließen, vor allem wenn ihre Methoden, Abläufe und Analysen detailliert und transparent beschrieben sind. Zweitens könne eine Studie in dem Sinne reproduzierbar sein, dass sie bei erneuter Durchführung die gleichen oder hinreichend ähnliche Ergebnisse liefert. Da in dieser Arbeit zwei quantitative Untersuchungen als Fallbeispiele dienen, steht hier vor allem die Definition der **rechnerischen Reproduzierbarkeit** im Fokus. Fidler und Wilcox (2021) beschreiben diese als Reproduktion bestimmter Ergebnisse aus demselben Datensatz. Dies könne unter Verwendung desselben Codes und derselben Software oder durch Anwendung alternativer Ansätze, unterschiedlichen Modellen oder statistischen Rahmen passieren.

Ebenso gibt es viele Definitionen von Provenienz, die sich in vielen Fällen auf die von Daten bezieht. Wie in Kapitel 1 bereits beschrieben, können wissenschaftliche Ergebnisse aber in gewissen Kontexten wie Daten behandelt werden. Ram et al. (2009) geben beispielsweise eine Ontologie an, die sie das **W7-Modell** nennen. Der Name leite sich hierbei von den sieben W-Fragen ab (was, wann, wo, wie, wer, wodurch, warum). Wie diese Fragen zusammenhängen, stellen sie in einem Diagramm dar (siehe Abbildung 2.1). Zentral ist dabei das *Was*, welches sich auf ein Ereignis

bezieht, das die Daten beeinflusst hat. Alle anderen Fragen beziehen sich auf genau dieses Ereignis, also wie es dazu gekommen ist, wer daran beteiligt war etc.

Die Autor\*innen listen einige Anwendungsfälle auf, wobei auffällt, dass durch dieses umfangreiche Modell auch Reproduzierbarkeit eine Eigenschaft ist, die durch dieses Modell geprüft werden kann.

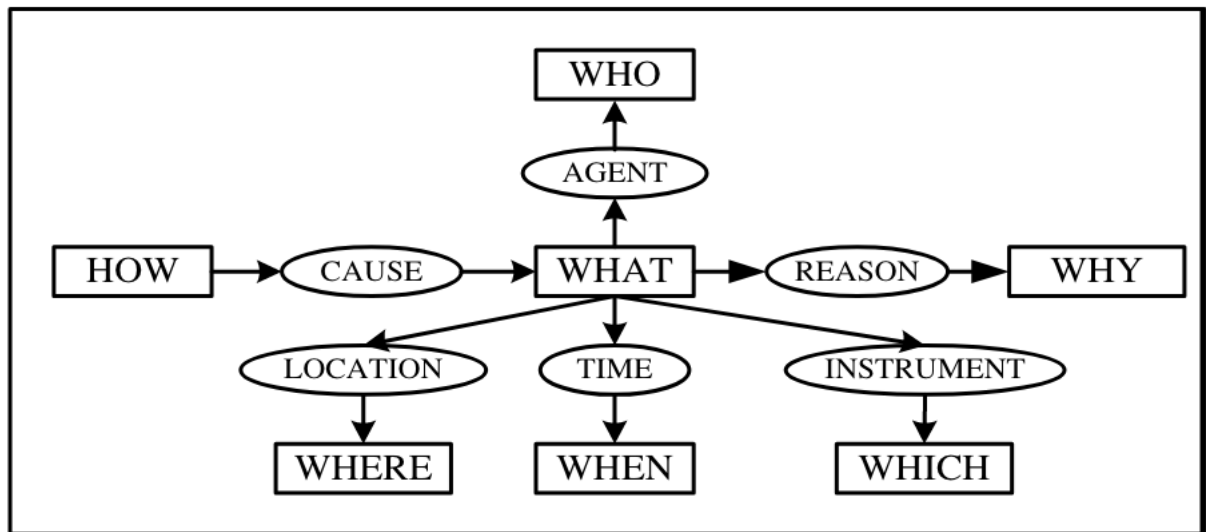


Abbildung 2.1: Übersicht des W7-Modells von Ram et al. (2009)  
(Abbildung 1, S. 3)

### 2.1.2 Scientific Knowledge Graphs und ORKG

Wissenschaftliche Arbeiten sind zwar digital über das Internet zugänglicher geworden, allerdings liegen sie immernoch in unstrukturierter Form als Textdokument vor. Ein (Scientific) Knowledge Graph kann den Inhalt dieser Arbeiten für Maschinen und Menschen lesbar darstellen. In einem Knowledge Graph werden Informationen über die reale Welt durch Verlinkungen von Entitäten modelliert. In diesem graphenbasierten Datenmodell werden Entitäten durch Knoten und ihre binäre Beziehung zueinander als Kante repräsentiert (Hogan et al., 2022).

Der Open Research Knowledge Graph (ORKG) ist eine Applikation, in der die Informationen wissenschaftlicher Arbeiten graphenbasiert modelliert und veröffentlicht werden können. Wie auch andere Anwendungen wie *Wikipedia* oder *OpenStreetMaps* setzt ORKG auf *Crowdsourcing*, sodass die Inhalte durch einige wenige

Expert\*innen eingepflegt und von vielen Nutzer\*innen aus verschiedenen Fachgebieten genutzt werden können. Eine ausführliche Übersicht der wichtigsten Features bietet die Arbeit von Auer et al. (2020). Im Folgenden werden die für diese Arbeit relevanten Konzepte von ORKG vorgestellt.

Eine Publikation wird repräsentiert durch ein *paper*, das zunächst die Metadaten wie Autor\*innen, Titel usw. enthält. Der Inhalt wird dargestellt durch *contributions*. Jede Erkenntnis in der Arbeit kann durch eine *contribution* modelliert werden und Aspekte wie Ergebnis, Methode etc. enthalten. Jede einzelne Information wird graphenbasiert nach dem Schema des Resource Description Framework (RDF), also *Subject-Prädikat-Objekt* repräsentiert.

Um verschiedene Arbeiten, die das gleiche Problem behandeln, einfacher vergleichen zu können, können *templates* erstellt werden. In ihnen kann festgelegt werden, welche Prädikate eine *resource* haben soll und welche Klasse an Objekten und Kardinalitäten für diese jeweils zulässig sind. Erstellte *templates* stehen dann für alle Nutzer\*innen zur Verfügung.

Um diese Vergleiche übersichtlich und für alle einsichtbar zu machen, können *comparisons* erstellt werden. Diese enthalten mehrere *contributions* und werden in eine tabellarische Übersicht gebracht.

Ein weiteres wichtiges Werkzeug für diese Arbeit ist das *Python-Package*<sup>1</sup> für ORKG. Es bietet einen Endpunkt, um in einem Python-Skript Daten auszulesen, neu zu erstellen oder zu bearbeiten.

## 2.2 Ähnliche Arbeiten

Das Buch „Data Journeys in the Sciences“ von Leonelli und Tempini (2020) widmet sich der Untersuchung von Datenbewegung durch Fallstudien. Für diese Bewegung nutzen die Autor\*innen die Metapher der Reise, die sie im Allgemeinen als die Bewegung vom Produktionsort zu anderen Orten, an denen sie verarbeitet, mobilisiert und wiederverwendet werden, definieren. Mit Orten meinen sie in diesem Zusammenhang nicht nur geographische Orte, sondern auch Zeit- und Standpunkte. Die Metapher der Reise begründen sie damit, dass wie auch bei Menschen die Reise von Daten anhängig von Infrastruktur und Organisationen sei. In den Fallstudien werden entsprechend verschiedene Stadien dieser Bewegung untersucht, von der Planung, die dem Produzieren von Daten vorausgeht, bis hin zu den verschiedenen Arten, wie Daten mobilisiert und neu verwendet werden, häufig mit dem Ziel, Wissen dadurch zu

---

<sup>1</sup>Die Dokumentation zu diesem *Package* ist unter <https://orkg.readthedocs.io/en/latest/> zu finden.



generieren. Im einleitenden Kapitel konzeptioniert Leonelli (2020) Daten als eine Art Stammbaum, die die Wandlungsfähigkeit von Daten verdeutlichen soll. Daten haben somit zu verschiedenen Zeitpunkten der Reise, verschiedene Formate oder wurden Modifikationen unterzogen, um in den jeweiligen Kontext zu passen. Diese Konzeptionierung würde die Frage aufwerfen, wie bei der Mobilität von Daten die Integrität und die Identifizierbarkeit erhalten werden kann. Dies ist auch, wie in Kapitel 1 angemerkt, eine zentrale Motivation dieser Arbeit.

In Kapitel 1 wurden die von Cooper et al. (2009) beschriebenen Arbeitsschritte bei der Erstellung von Syntheseforschung aufgezählt. Während sich diese Arbeit vor allem der Analyse der Daten widmet, bietet Münch (2022) in seiner Abschlussarbeit einen Ansatz zur automatisierten Extraktion von relevanten Daten aus der Literatur. Er präsentiert einen *rule-based matching* Ansatz, um in Texten gezielt nach Mustern zu suchen. Auch wenn er zu dem Schluss kommt, dass sein Vorgehen keine verlässliche Lösung für eine Vollautomatisierung ist, argumentiert er, dass durch das Hervorheben der möglicherweise relevanten Informationen die Recherchearbeit deutlich vereinfacht werden kann.

# Kapitel 3

## Methoden

### 3.1 Bottom-Up vs. Top-Down

Um die Reise von wissenschaftlichen Erkenntnissen zu analysieren, werden zwei verschiedene Methoden angewandt. Beginnend mit dem Bottom-Up-Verfahren wird eine Synthesearbeit des Forschungszentrum Jülich reproduziert, die verschiedene Publikationen zur Schadstoffbelastung der Luft zusammenträgt. Durch Reproduktion der Ergebnisse wird in dieser Arbeit getestet, ob sich ORKG eignet, die Daten zu sammeln und in einem geordneten Format wieder auszulesen, um zu den gleichen Ergebnissen zu kommen, wie Gkatzelis et al. (2021) in der ursprünglichen Arbeit. Die Methode, sowie die Ausgangsarbeit wird in Kapitel 3.2 näher beschrieben. Beispielhaft wird ein Diagramm reproduziert, das die Änderung der Feinstaubbelastung ( $PM_{2.5}$ ) darstellt. Weiterhin wird darauf aufbauend die Aussage über den internationalen Rückgang der Feinstaubbelastung, der zwischen 10% und 33% liegt und auch im sechsten *Assessment Report* des IPCC (2021) wiederzufinden ist, rekonstruiert. Dies bildet einen Übergang in das Top-Down-Verfahren. Von dort wird die Einschätzung darüber, welchen Einfluss Aerosole auf den Energiehaushalt und somit auf das Klima der Erde hat, zu den Quellen zurückverfolgt. In diesem Schritt wird unter anderem untersucht, wie weit die durch komplexe Berechnungen entstandenen Werte, zu den ursprünglichen Daten zurückverfolgbar sind. Eine Übersicht über den Ablauf dieser beiden Methoden ist in Abbildung 3.1 dargestellt. Im Vergleich dazu ist die eigentliche Mobilität der hier analysierten Daten in Abbildung 3.2 visualisiert.

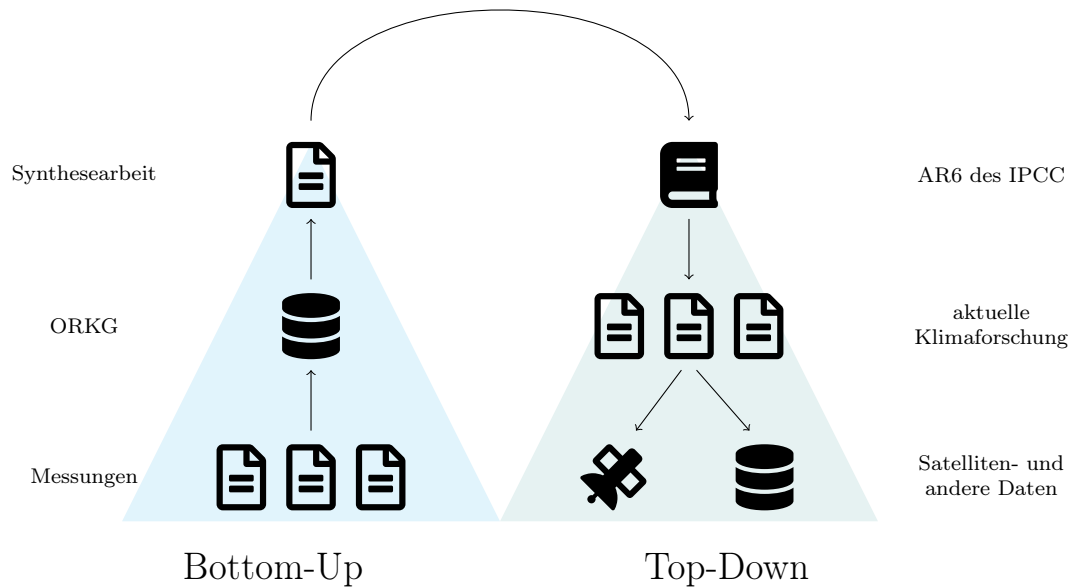


Abbildung 3.1: Ablauf der Analyse der Fallbeispiele

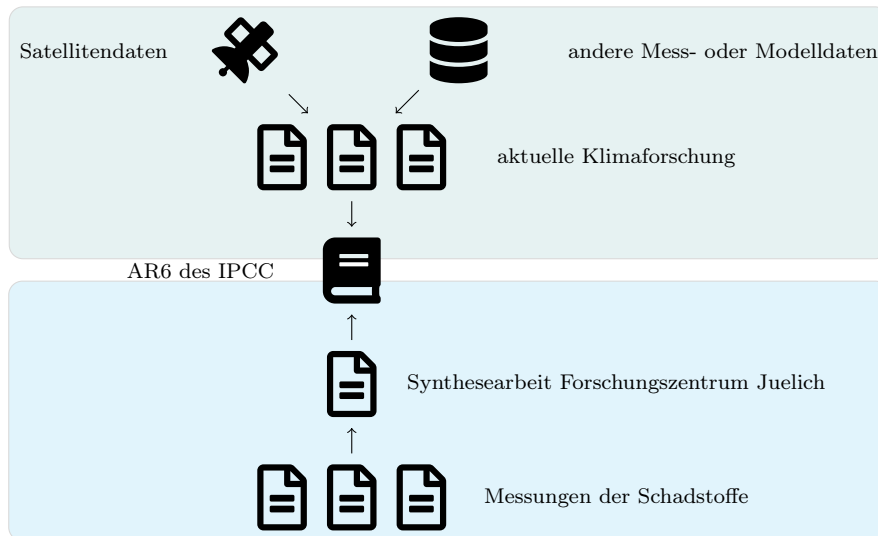


Abbildung 3.2: Grundriss des Informationsflusses innerhalb der hier besprochenen Arbeiten

## 3.2 Synthesearbeit des Forschungszentrum Jülich

Im Bottom-Up-Ansatz wird die Reise von Informationen am Beispiel der Synthesearbeit des Forschungszentrum Jülich angeschaut (Gkatzelis et al., 2021). Die Autor\*innen tragen hier Informationen aus verschiedenen wissenschaftlichen Veröffentlichungen zusammen, die die Luftverschmutzung während der Lockdowns, die im Zusammenhang mit der Covid-19 Pandemie im Jahr 2020 verhängt wurden. Somit ermöglichen sie einen Überblick darüber, wie sich die Luftverschmutzung im Hinblick auf verschiedene Schadstoffe im Zusammenhang mit dem *Stringency Index*, eine Metrik für die Tragweite der Lockdowns, verändert hat. Für diese Synthese suchten sie auf *Google Scholar* mit Schlagworten nach relevanten Arbeiten und digitalisierten die Ergebnisse in einer CSV-Datei, die öffentlich zur Verfügung steht <sup>1</sup>. Seit der Veröffentlichung der Arbeit sind mehrere Nachfolgeversionen dieser Daten erschienen. Da die erste Version die Grundlage ihrer präsentierten Resultate sind, wurde sie auch in dieser Arbeit verwendet. Die Datei besteht aus insgesamt 838 Zeilen mit Daten aus insgesamt 150 verschiedenen Publikationen. Jede Zeile stellt eine Messung dar, die einen bestimmten Ort und Zeitraum verknüpft und kann mehrere Schadstoffe beinhalten. Zusätzlich enthält die Zeile Informationen über die Art der Messung (Satelliten- oder Bodenmessung) und die Vergleichsmethode, zum Beispiel, ob meteorologische oder saisonale Effekte miteinbezogen oder nur ein direkter Vergleich durchgeführt wurde. Insgesamt werden 10 Schadstoffe und zwei Metriken gemessen. Eine Metrik ist der Air Quality Index (AQI), der von staatlichen Behörden benutzt wird, um verschiedene Schadstoffe in einer Metrik zu kombinieren, allerdings keine international-einheitliche Definition besitzt und daher von Staat zu Staat verschieden sein kann. Die zweite Metrik, die verwendet wird ist die Aerosol Optical Depth (AOD), welche ein Maß dafür ist, wie viel Sonnenlicht durch Aerosole durch Absorption oder durch Streuung nicht die Erdoberfläche erreicht. Für jeden Schadstoff oder Metrik sind bis zu sechs Werte angegeben: Referenzwerte (jeweils Durchschnitt und Standardabweichung), Lockdownwerte (jeweils Durchschnitt und Standardabweichung) und die prozentuale Veränderung (Durchschnitt und Fehlerintervall).

### 3.2.1 Anwendung

Im ersten Schritt werden die 150 Arbeiten bei ORKG hochgeladen. Hierzu wurde die Funktion der *Templates* verwendet, welche eine einheitliche Struktur für die Modellierung der Ergebnisdaten vorgeben. Eine Messung wird repräsentiert durch eine *contribution*. Für eine *contribution* wird das *template Air Quality Measurement* (sie-

---

<sup>1</sup>erwähnte Dateien sind unter [https://covid-aqs.fz-juelich.de/data\\_download](https://covid-aqs.fz-juelich.de/data_download) zu finden

he Abbildung 3.3) verwendet. In diesem ist der *Stringency Index* als Dezimalwert, die Methode und die Messplattform jeweils als Zeichenkette und der Messort, der Messzeitraum und die Messwerte jeweils als *resource*, die wieder einem eigenen *Template* folgen, umgesetzt. Die Namensgebung für die *contributions* folgt dem Schema *ORT-STARTDATUM*. Dies führt in Einzelfällen zwar zu Duplikaten, ist aber dennoch aussagekräftig und gleichzeitig kurz genug, um in der Web-Oberfläche und in der späteren Weiterverarbeitung übersichtlich zu sein.

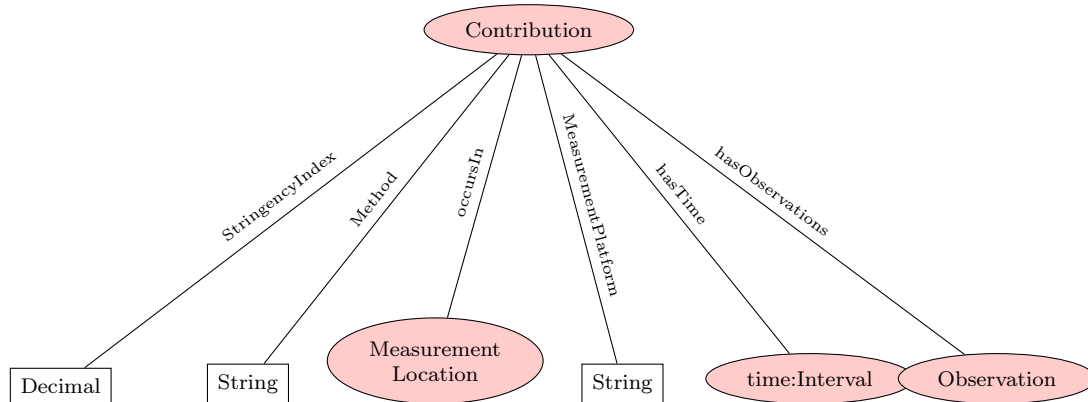


Abbildung 3.3: Aufbau des Templates für die *contributions*. *Resources* werden durch die ovalen und *literals* durch die rechteckigen Knoten dargestellt.

Die Messwerte selber werden im *Template sosa:Observation* modelliert (siehe Abbildung 3.4). Dieses *Template* folgt der Definition der Sensor, Observation, Sample, and Actuator (SOSA) Ontologie <sup>2</sup>. Das *Feature of Interest* stellt den gemessenen Schadstoff bzw. Metrik dar, welche gleichzeitig das *Label* für die *Observation* ist. Im Beispiel in der Abbildung 3.7 zeigt sich, dass die *contribution* zwei Messungen hat, eine für *CO* und eine für *NO<sub>2</sub>*. Außerdem wird mit *ObservableProperty* festgehalten, was gemessen wurde. Im Fall der Schadstoffe ist dies die Konzentration, während es im Fall der Metriken kein *ObservableProperty* gibt, da es hier die Metrik selbst ist und schon durch *FeatureOfInterest* abgebildet ist. Die numerischen Ergebnisse der Messung werden in *Result* (siehe Abbildung 3.5) modelliert. Diese bestehen aus dem Referenzwert (Durchschnitt), dem Lockdownwert (Durchschnitt) und dem prozentualen Unterschied der ersten beiden Werte. Jeder Wert ist nach dem *Template Quantity Value* aufgebaut, welcher aus einer Dezimalzahl (*Literal*) und einer Einheit (*Resource*) besteht. Die Messorte sind nach dem Aufbau in den Eingabedaten nach Stadt, Land, geographischer Region und zusätzlichen Informationen (beispielswei-

<sup>2</sup><https://www.w3.org/TR/vocab-ssn/#SOSAObservation>

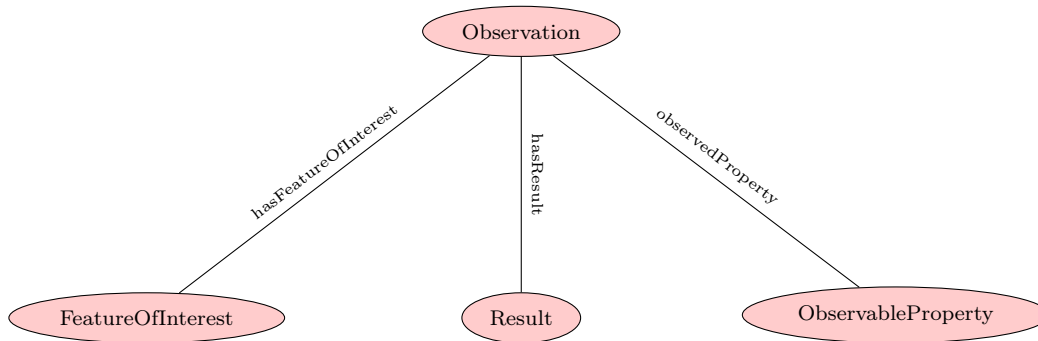


Abbildung 3.4: Aufbau des Templates für die Erfassung der Messungen. *Resources* werden durch die ovalen und *Literals* durch die rechteckigen Knoten dargestellt.

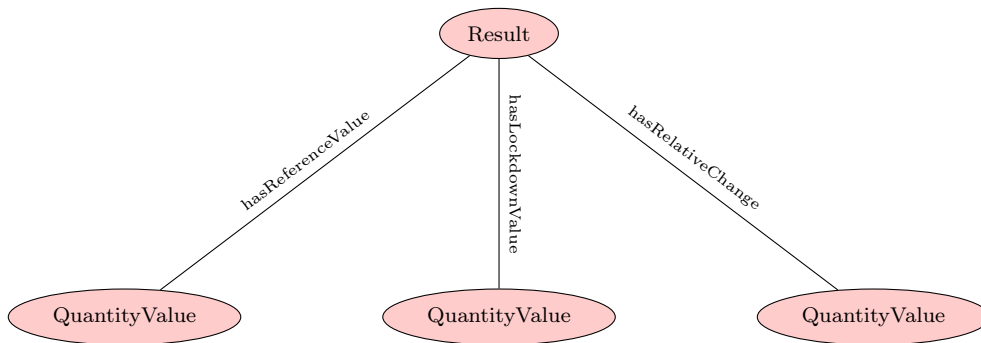


Abbildung 3.5: Aufbau des Templates für die Messresultate. *Resources* werden durch die ovalen und *Literals* durch die rechteckigen Knoten dargestellt.




Abbildung 3.6: Aufbau des Templates für den Ort der Messung. *Resources* werden durch die ovalen und *Literals* durch die rechteckigen Knoten dargestellt.

se ob es eine urbane Gegend war oder in wie vielen Städten gemessen wurde, falls es mehrere waren), aufgebaut. Stadt, Land und geographische Region sind jeweils eine *Resource*, während die Zusatzinformationen als *Literal* organisiert sind (siehe Abbildung 3.6). Die Benennung der *Location-Resource*, folgt in diesem Fall keinem aussagekräftigen Schema, da dies das spätere Auslesen der Daten deutlich vereinfacht hat und wird deshalb immer nur „Location“ genannt.

Seoul 2020-02-01	
Preferences	
Applied template: Air Quality Measurement	
occurs in	Location
method	Direct Comparison to a Reference Period
measurement platform	Satellites
has time	2020-02-01 - 2020-03-30
has observations	CO NO2
StringencyIndex	49.37

Abbildung 3.7: Beispiel für eine *contribution*.

Um die Daten in ORKG zusammen zu organisieren, wurden *comparisons* verwendet. Diese erstellt eine Tabelle aus den Daten der angegebenen *contributions*, die dann wiederum als CSV heruntergeladen werden können oder mithilfe der Python-Bibliothek in ein *Pandas Dataframe* geladen werden können. Der Implementierung sowohl des Einpflegens der Daten als auch des Weiterverarbeitens ist ein eigener Abschnitt gewidmet (siehe Kapitel 3.2.2). Es war nicht möglich eine *comparison* zu veröffentlichen, die alle 838 *contributions* enthält. Insgesamt sind die Daten auf elf *comparisons* aufgeteilt. Für jede geographische Region gibt es eine, außer für Süd-asien, welche auf Grund der Größe wiederum auf zwei *comparisons* aufgeteilt werden musste. Die Daten wurden dann über die Weboberfläche als CSV heruntergeladen,

da das Laden über die Python Bibliothek nicht funktionierte. Hierbei ist zu beachten, dass die Tabelle sehr viel größer ist als die ursprünglichen Daten, da die *comparison* immernoch die Graphenstrukturen mitabbildet. Beispielsweise zeigt sich in Abbildung 3.8, dass die Messdaten bezüglich Stickstoffdioxid ( $NO_2$ ), die ursprünglich in drei Spalten angegeben waren, nun in jeweils eine eigene Spalte pro *Resource* organisiert sind. Das bedeutet, dass für jede der fünf *contributions* jede Messung mindestens drei Spalten hat, die sich nur auf das eine Ergebnis beziehen. Diese Organisation führt dazu, dass die Tabellen schnell sehr groß werden und dass ORKG Zeilen weglässt, die zwar über die *select properties* ausgewählt werden können, aber dies bei sehr großen *comparisons* wie beispielsweise der zu Europa, die über 100 *contributions* enthält, zu sehr langen Ladezeiten führt.

has observations/no2	-	
↳ has feature of interest*	✕	<a href="#">Nitrogen dioxide</a>
↳ has result*	▼	<a href="#">ref:8.6ugm3,lockdown:4.2ugm3,change:-51.0%</a>
has result/ref:8.6ugm3,lockdown:4.2ugm3, change:-51.0%	-	
↳ has lockdown value*	✕	<a href="#">4.2 micrograms per cubic metre</a>
has lockdown value/4.2 micrograms per cubic metre	-	
↳ qudt:numericvalue*	✕	4.2
↳ qudt:unit*	✕	<a href="#">micrograms per cubic metre</a>
↳ qudt:unit/micrograms per cubic metre/same as*	✕	<a href="https://qudt.org/vocab/unit/MicroGM-PER-M3">https://qudt.org/vocab/unit/MicroGM-PER-M3</a>

Abbildung 3.8: Auszug aus der *Comparison* „Air Pollution Measurement during Covid-19 lockdown for Africa“.



### 3.2.2 Implementierung

Für die Implementierung wurde die Programmiersprache Python verwendet, da ORKG eine Bibliothek dafür anbietet. Wie im vorangegangenen Abschnitt beschrieben, besteht die Implementierung aus zwei Abschnitten: Das Einpflegen der Informationen aus den einzelnen Publikationen in ORKG und das Auslesen der zuvor hochgeladenen Informationen für die Weiterverarbeitung. Da Münch (2022) im Rahmen seiner Abschlussarbeit bereits einen Programmcode erstellt hat, um die Forschungsarbeiten bei *ORKG* hochzuladen, konnten Teile seines Codes wiederverwendet werden. Sowohl der hier beschriebene Code als auch die verwendeten Datensätze und Templates sind über GitLab einsehbar<sup>3</sup>.

Änderungen am Vorgehen von Münch (2022) wurden vor allem beim Modellieren der Informationen, welches durch die oben beschriebenen *Templates* erfolgt, und beim Hochladen selbst, das nun über den Harvester-Client funktioniert, vorgenommen. Das Programm erwartet beim Ausführen eine CSV-Datei als Eingabe. Nachfolgend werden die wichtigsten Bausteine des Codes beschrieben:

- Für jedes *paper* wird ein Ordner erstellt, der nach der DOI (die /" werden entfernt) benannt ist. So ist es später einfacher beim Hochladungsprozess.
- Der Ordner hat eine JSON-Datei, die die Metadaten enthält, und einen weiteren Ordner „contributions“, in dem alle JSON-Dateien mit den *contributions* enthalten sind.
- Die Funktion *create\_JSON\_Data* geht das Dataframe reihenweise durch und erstellt erst den Ordner für das Paper, falls dieser Ordner noch nicht existiert. Für die Metadaten wird dann *get\_crossref\_data* aufgerufen und für die Inhalte der Contributions wird *create\_contribution* aufgerufen.
- Für das Hochladen wird die JSON mit den Metadaten ausgelesen. Da diese nicht immer gleichmäßig vollständig sind, werden die *paper* zunächst mit den minimalen Metadaten (Titel und Research Field) hochgeladen. Alle anderen Informationen werden, wenn vorhanden, mit dem Statement-Client hinzugefügt.
- Für das Hochladen der *comparisons* werden zunächst die *contributions* (als ID-Liste) gebraucht, diese wird durch *get\_contributions* erstellt. Als Eingabe bekommt die Funktion einen Key nach dem die Comparisons aufgeteilt werden

---

<sup>3</sup>[https://gitlab.com/TIBHannover/orkg/orkg-papers/-/tree/master/gkatzelis21lockdowns?ref\\_type=heads](https://gitlab.com/TIBHannover/orkg/orkg-papers/-/tree/master/gkatzelis21lockdowns?ref_type=heads)

sollen (Hier nach Geographischer Region, Südasien musste noch einmal geteilt werden). Außerdem gibt man zusätzlich noch einen bestimmten Wert an, den der Key haben soll, und einen Schadstoff, der beobachtet werden soll. Es werden also nur *contributions* ausgegeben, die eine Messung zum angegebenen Schadstoff haben und in der spezifizierten Region stattgefunden hat.

- Mit *publish\_comparison* kann diese Liste dann als *comparison* hochgeladen werden. Der Titel und die Beschreibung enthalten dann immer die gleichen Informationen, es wird dann der Ort der Messung in Titel und Beschreibung eingefügt.
- Mit *organize\_data* werden die Daten aus den heruntergeladenen CSV-Dateien ausgelesen, die Medianwerte berechnet und in dictionaries gespeichert (keys sind Länder und Values sind Messwerte für PM2.5.) Mit *get\_stringency\_index* werden die Median-*StringencyIndex*-Werte nach dem gleichen Prinzip gespeichert.
- Danach wird mit *Pyplot* die Graphik erstellt. Nach dem Vorbild aus der Arbeit von Gkatzelis et al. (2021) wird für jeden Kontinent ein Subplot erstellt. Die Prozentwerte sind als Punkte dargestellt und nach Höhe des Stringency Index eingefärbt.

Der Pseudocode 3.1 bietet nocheinmal einen schnellen und vereinfachten Überblick über den Gesamtablauf des oben beschriebenen Programmes.

## 3.3 Weltklimabericht des Intergovernmental Panel on Climate Change

Dem gegenüber steht der Top-Down Ansatz, der im Folgenden beleuchtet wird. Als Fallbeispiel wird hier der sechste Weltklimabericht (AR6) des Intergovernmental Panel on Climate Change (IPCC) herangezogen. Der Beitrag der *Working Group I* zum sechsten *Assessment Report* konzentriert sich auf die physikalischen Grundlagen des Klimawandels auf Basis von mehr als 14000 wissenschaftlichen Veröffentlichungen. Im Kapitel 7 wird der Einfluss auf das Weltklima einzelner Treibhausgase und anderer Stoffe, die durch menschliche Aktivitäten die Atmosphäre beeinflussen, zusammengefasst. Um die Daten des 6. Assessment Report (AR6) des IPCC nachzuvollziehen, ist es zunächst wichtig zu verstehen, wie die Wirkung einzelner Antreiber der Klimaerwärmung bewertet wird. Dafür nutzt der Bericht die Metrik Effective Radiative Forcing (ERF), die in  $Wm^{-2}$  gemessen wird und das Energiegleichgewicht des

Listing 3.1: Pseudocode, der das Gesamtprogramm beschreibt

---

```
1 #Erstellen der benoetigten ressourcen
2 for each ressource:
3     if ressource not in ORKG:
4         create ressource
5 #Erstellen der JSON-Dateien
6 for each DOI:
7     create new directory
8     fetch metadata from CrossRef
9     save in JSON-File
10    create directory for contribution-files
11    for each row with current DOI:
12        create JSON-file according to template
13        save file to contribution-directory
14 #Hochladen der Daten
15 for each DOI:
16    open DOIs directory
17    read metadata
18    use Harvester with metadata + contribution-files
19 #Erstellen der comparisons
20 for each DOI:
21    if paper not a duplicate:
22        save IDs of all contributions
23 for each contribution:
24    get contribution with given region
25    get contribution with given pollutant
26 create comparison with filtered contributions
```

---

Erdklimasystems misst. In einem ausgeglichenen System entspricht die ankommende Energie der Sonne in etwa der, die wieder an den Weltraum abgegeben wird. Ein positiver Wert des ERF gibt somit eine positive Energiebilanz an, also einen Energieüberschuss in Form von Erwärmung. Analog dazu bezeichnet ein negativer Wert einen Energieverlust der Erde in Form von Abkühlung (IPCC, 2021). Der ERF in Bezug auf Aerosole besteht aus zwei Komponenten: dem ERF, der durch Wechselwirkungen zwischen Aerosolen und Wolken entsteht (Effective Radiative Forcing from aerosol-cloud-interaction (ERFaci)), und dem, der durch Wechselwirkungen mit Strahlungen entsteht (Effective Radiative Forcing from aerosol-radiation-interaction (ERFari)). Die erste Metrik wird auch als indirektes und die zweite als direktes *Radiative Forcing* bezeichnet. Der Gesamt-ERF wird dann durch die Summe dieser beiden Werte bestimmt. Ein verwandter Begriff zum ERF ist das Instantaneous TOA Radiative Change (IRF). Dieser beschreibt den Nettostrahlungsfluss am höchsten Teil der Atmosphäre, der keine Anpassung beinhaltet. Der ERF kann aus der Summe von IRF und diesen Anpassungen gebildet werden. Die Anpassungen, die beispielsweise bei den tropo- und stratosphärischen Temperaturen vorgenommen werden, beeinflussen auch den äußersten Teil der Atmosphäre und wirken somit auch auf den ERF ein. Auch beim IRF bezüglich der Aerosole wird in Wolken- und Strahlungs-Interaktionen unterschieden. So werden im AR6 die beiden Termini IRFari und IRFaci verwendet. Im Bezug auf Wolken nennt der IPCC zwei wichtige Einflussfaktoren auf den ERFaci. Da Aerosole als Kondensationskern (Cloud Condensation Nuclei (CCN)) dienen, beeinflussen sie den Liquid Water Path (LWP), welcher ein Maß für die Wassermenge ist, die vertikal zwischen zwei Punkten in der Atmosphäre gemessen wird, und der Cloud Fractional Coverage (Cf), welche sich auf Satellitenbilder bezieht und den prozentualen Anteil von Wolken bemisst. Es wird davon ausgegangen, dass mögliche Verzögerungen von Regen durch Aerosole zu einer Erhöhung von LWP und Cf führen und dass dadurch der ERFaci höher ist, als nur der IRFaci, der diese Anpassungen nicht enthält.

In dieser Arbeit wird der ERF im Bezug auf Aerosole, der im IPCC auf  $-1,3 W m^{-2}$  geschätzt wird angeschaut. Es soll nachvollzogen werden, aus welchen Komponenten sich dieser Wert zusammensetzt und woher diese Schätzungen kommen. Im AR6 ist dieser Schätzung das Kapitel 7.3.3 gewidmet. Dort wird zum einen in die oben genannten Wechselwirkungen unterschieden. Weiterhin wird für beide Submetriken in die Berechnungsmethoden unterschieden. Sie geben für beide Werte modell- und beobachtungsbasierte Evidenz an. Die Aufschlüsselung der Zusammensetzung des ERF, die der Bericht vornimmt, ist in Kapitel 4.2 in den Abbildungen 4.9 für den ERFaci und 4.8 für den ERFari zusammengefasst. Anschließend wird in Tabelle 4.1

eine Übersicht über alle Quellen, die sich auf beobachtungengestützte Berechnungen beziehen, und über die Eingabedaten geboten.

# Kapitel 4

## Ergebnisse

### 4.1 Synthesearbeit des Forschungszentrum Jülich

Das Diagramm, das durch den in Kapitel 3.2.2 beschriebenen Code generiert wurde, ist in Abbildung 4.1 zu sehen. Die Vorlage von Gkatzelis et al. (2021) ist in Abbildung 4.2 zum Vergleich dargestellt. Neben den visuellen Unterschieden, die durch das Verwenden verschiedener Programme zustande kommt, zeigt die Vorlage neben den gesammelten Daten aus der Recherche (mit Kreisen dargestellt) auch Vergleichsdaten. Diese stellen den von P. M. Forster et al. (2020) berechneten Emissionsrückgang dar und basieren auf Daten der Emissions Database for Global Atmospheric Research (EDGAR). In Abbildung 4.1 ist lediglich der jeweilige prozentuale Median-Rückgang von  $PM_{2.5}$  pro Land nachgebildet. Außerdem zeigen beide Diagramme neben den Ländern noch die jeweilige Anzahl der  $PM_{2.5}$ -Messungen in Proportion zu der Gesamtzahl der Messungen des Landes an. In dem nachgebildeten Diagramm fällt auf, dass diese Zahlen sich häufig unterscheiden. In der Regel ist die die Zahl im nachgebildeten Diagramm höher als im Original.

Weiterhin wurde in der Syntheserbeit des Forschungszentrum Jülich eine globale Analyse vorgenommen. Alle Daten wurden dazu nach der Methode sortiert. Die Messdaten wurden außerdem nach dem *Stringency Index* in die Intervalle 40-60, 60-80, und 80-100 eingeteilt. In Abbildung 4.3 ist das daraus entstandene Diagramm von Gkatzelis et al. (2021) zu sehen (Abbildung 6, S. 22). Die Datenpunkte geben den Median-Rückgang für das jeweilige Intervall an. Gkatzelis et al. (2021) weisen darauf hin, dass der globale Rückgang zwischen  $-10\%$  (für das Intervall 40-60) und  $-33\%$  (für das Intervall 80-100) liegt, wenn man die Messungen betrachtet, die meteorologische Effekte und die Emissionsentwicklung berücksichtigen. Genau diese Zahlen werden im AR6 in einem Abschnitt über die Auswirkungen der im Zusammenhang




Abbildung 4.1: Nachgebildetes Diagramm über die prozentuale Entwicklung (Median) von Feinstaubpartikeln (PM2.5) pro Land

mit der COVID-19 Pandemie auferlegten Restriktionen zitiert (siehe Abbildung 4.4). Das Ergebnis wurde mit den Daten der *comparisons* nachgestellt und als *contribution* in ORKG veröffentlicht. Der globale Rückgang, der daraus resultiert, liegt zwischen  $-10,0\%$  und  $-30,2\%$ . Dieser Wert entspricht nicht exakt dem, den die Autor\*innen selbst dokumentieren. Beim Untersuchen dieses Unterschiedes fiel auf, dass sich die Anzahl der Werte, die für die Berechnung des Medians in diesen Intervallen in die Berechnung miteingeflossen sind, auch hier unterschieden. In Abbildung 4.3 stehen über den Boxplots die Anzahl der Input-Werte. Für  $PM_{2,5}$  sind 58, 51 und 32 Werte für die jeweiligen Intervalle miteinbezogen worden. Zählt man nun die Werte aus der CSV-Datei, die die Autor\*innen veröffentlicht haben, ergeben sich für die gleichen Intervalle und betrachteten Methoden 55, 50 und 31 Werte. Die Abweichung ist zwar gering, es lässt sich aber keine Ursache dieser erkennen. Da die Unterschiede auch mit den originalen Input-Daten der Autor\*innen bestehen, ist es weniger wahrscheinlich, dass der Fehler auf die Unvollständigkeit der *comparisons* zurückzuführen ist.

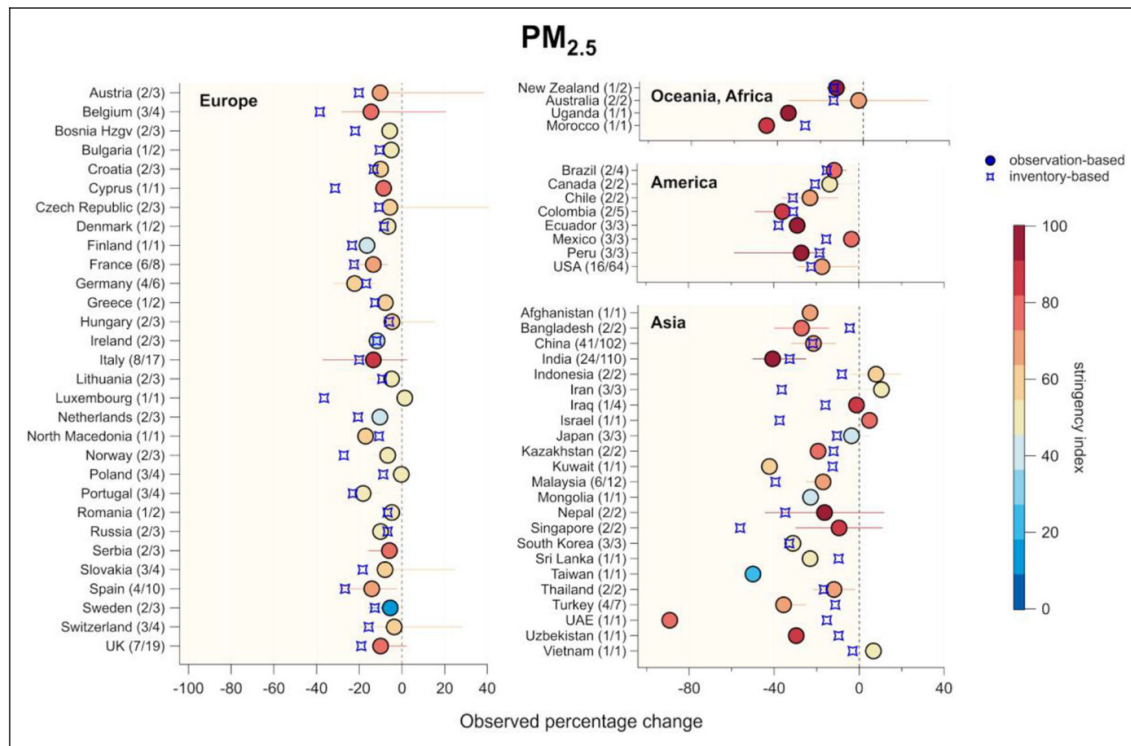


Abbildung 4.2: Originales Diagramm über die prozentuale Entwicklung pro Land (Median) von Gkatzelis et al. (2021). (Abbildung 11, S. 27)

## 4.2 Weltklimabericht des Intergovernmental Panel on Climate Change

Den Wert für den *Aerosol-ERF*, den der Bericht nennt, beläuft sich auf  $-1,3 [-2,0$  bis  $-0,6] Wm^{-2}$  für den Zeitraum 1750 bis 2014. Den Wert setzt der IPCC (2021) aus einem *ERF<sub>ari</sub>* von  $-0,3 \pm 0,3 Wm^{-2}$  und einem *ERF<sub>aci</sub>* von  $-1,0 \pm 0,7 Wm^{-2}$  zusammen. Für diese Werte unterscheiden sie jeweils zwei Quellen der Evidenz, diejenigen durch Beobachtungsstudien und diejenigen durch Simulationsmodelle.

Für die durch Beobachtung gestützte Evidenz benennen sie einen *IRF<sub>ari</sub>* von  $-0,4 \pm 0,4 Wm^{-2}$ . Als Quelle für diesen Wert wird hauptsächlich die Arbeit von Kinne (2019) angegeben. Weiterhin wird noch eine Publikation von Ma et al. (2014) genannt, die einen *IRF<sub>ari</sub>* von  $-0,6 Wm^{-2}$  bei klarem Himmel angeben. Dieser Wert ließe sich laut dem IPCC (2021) auf  $-0,3 Wm^{-2}$  auf alle Wolkenbedingungen verallgemeinern. Schließlich wird eine Veröffentlichung von Rémy et al. (2018) erwähnt, die



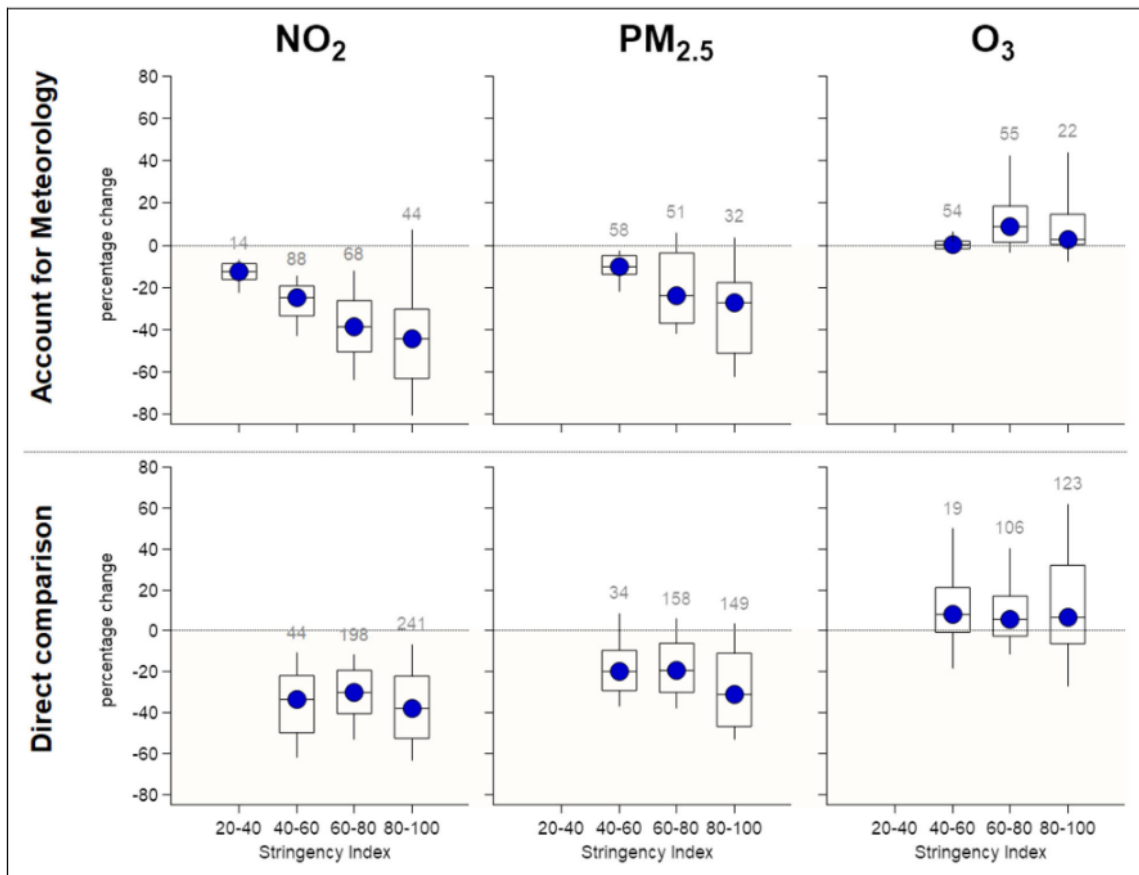


Abbildung 4.3: Originales Diagramm von Gkatzelis et al. (2021) über die globale, prozentuale Median-Entwicklung von  $NO_2$ ,  $PM_{2.5}$  und  $O_3$ . Die Daten sind nach Methode getrennt und wurden nach *Stringency Index* in Intervalle gruppiert. (Abbildung 6, S. 22)

Several studies have examined the effect of COVID-19 containment on air quality, showing that multi-year datasets with proper statistical/modelling analysis are required to discriminate the effects of meteorology from that of emissions reduction (Dhaka et al., 2020; L. Li et al., 2020; Wang et al., 2020; Zhao et al., 2020b). Accounting for meteorological influences and with an increasing stringency index, the median observed change in  $NO_2$  decreased from  $-13\%$  to  $-48\%$ , and in  $PM_{2.5}$  decreased from  $-10\%$  to  $-33\%$ , whereas the median change in ozone increased from  $0\%$  to  $4\%$  (Gkatzelis et al., 2021). The latter can be explained by the decrease of NO emissions that titrate ozone in specific highly polluted areas, leading to the observed increase in surface ozone concentration in cities (Le et al., 2020; Sicard et al., 2020; Huang et al., 2021).

Abbildung 4.4: Auszug aus der Cross-Chapter Box 6.1, S. 875-878 im sechsten *Assessment Report* des IPCC

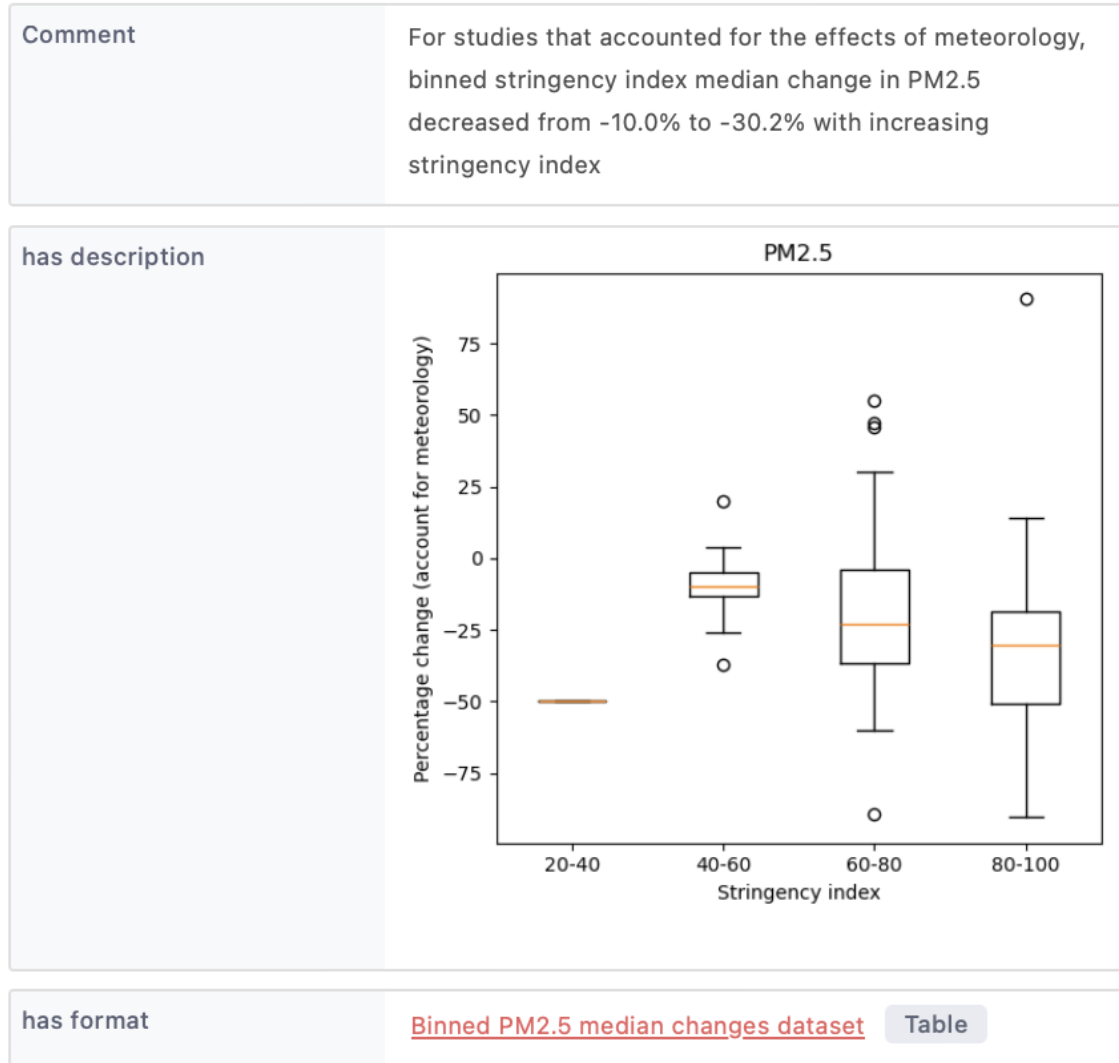


Abbildung 4.5: Nachgestelltes Ergebnis der Analyse des globalen Rückganges von  $PM_{2.5}$  gruppiert nach *Stringency Index*.

einen IRFari zwischen  $-0,5$  und  $-0,6Wm^{-2}$  schätzen. Allerdings wird argumentiert, dass diese Studie im Vergleich zu der von Kinne (2019) einige notwendige Überarbeitungen vernachlässige, weswegen der Schätzung von Kinne (2019) mehr Gewicht in der Gesamtschätzung zugerechnet wird. Wie dieser Wert genau berechnet wird, ist nicht angegeben, ebenso wie die genaue Gewichtung der oben genannten Werte.

Für den IRFari-Wert werden auch modellbasierte Werte herangezogen. Sie nennen dafür die Arbeiten von Lund et al. (2018), die einen IRFari von  $-0,17Wm^{-2}$  berechnen, von Petersik et al. (2018), die einen Wert von  $-0,19Wm^{-2}$  präsentieren und von Lurton et al. (2020), die ein negativeres Ergebnis von  $-0,38Wm^{-2}$  berichten. Diese modellbasierte Evidenz fassen sie zu einem Wert von  $0,2 \pm 0,2Wm^{-2}$  zusammen. Auch hier legen sie keine genaue Berechnung dar. Sie geben aber an, dass sie letzt genannten Wert weniger gewichten, da das verwendete Modell nur fest vorgegebene klimatologische Aerosolkonzentrationen enthalte und keine interaktiven Aerosole.

Beide Quellen der Evidenz werden zu einem Intervall von  $-0,45$  bis  $-0,05Wm^{-2}$  kombiniert. Begründet wird dies mit der Arbeit von Bellouin et al. (2013), die in ähnlicher Weise modell- und beobachtungs-basierte Werte miteinander verknüpfen. Schließlich kommen die Autor\*innen zu einer Gesamteinschätzung des IRFari von  $-0,25 \pm 0,2Wm^{-2}$ .

Als modellbasierte Evidenz für den ERFari geben sie einen Wert von  $0,25 \pm 0,4Wm^{-2}$  an. Diese Schätzung würde aus dem Radiative Forcing Model Intercomparison Project (RFMIP) hervorgehen und nennen als Quelle die Untersuchung von Smith et al. (2020), die Teil dieses Projektes ist. Unterstützt werde dieser Wert durch andere Veröffentlichungen von Zhang et al. (2016), Fiedler et al. (2017), Nazarenko et al. (2017), Zhou et al. (2017), Zhou et al. (2018) und Grandey et al. (2018), in denen jeweils nur ein einziges Modell untersucht wurde. Insgesamt wird der ERFari auf  $-0,3 \pm 0,3Wm^{-2}$  geschätzt, da der IRFari, der durch Modelle errechnet wurde, auf eine Anpassung nach unten hindeute.

Weiterhin wird ein *IRFaci* von  $-0,7 \pm 0,5 Wm^{-2}$  als beobachtungs-basierte Evidenz angegeben. Dieser ist als Durchschnitt verschiedener Arbeiten entstanden. Es werden hier die Veröffentlichungen von Bellouin et al. (2013), Gryspeerdt et al. (2017), D. T. McCoy et al. (2017), Gryspeerdt et al. (2016), Gryspeerdt et al. (2019), Rémy et al. (2018), Toll et al. (2019), Hasekamp et al. (2019), I. L. McCoy et al. (2020), Diamond et al. (2020), Chen et al. (2014), Christensen et al. (2016), Christensen et al. (2017) erwähnt. Die angegebenen Referenzen stimmen mit denen in Tabelle 7.7 auf Seite 951 überein (siehe Abbildung 4.7). Allerdings ist nicht nachvollziehbar, welche Werte sie genau in welcher Weise miteinbezo-gen haben. Nimmt man nur die Messungen, die einen konkreten IRFaci-Wert haben, ergibt sich ein Durchschnitt von etwa  $-0,74Wm^{-2}$ . Aus dem IRFaci schätzen sie einen ERFaci von  $-1,0 \pm 0,7Wm^{-2}$  durch Anpassungen von Cloud Fractional Coverage (Cf) und Liquid Water Path (LWP).

Für den *ERFaci* aus Modellsimulationen nehmen sie den durchschnittlichen CMIP6 Wert aus Tabelle 7.6 auf Seite 950 (siehe Abbildung 4.6) als Basis. Den Wert von  $-0,86 \pm 0,57$  korrigieren sie allerdings noch nach unten, um den Einfluss bezüglich

Eiswolken (Cirrus) miteinzubeziehen. Auch das Intervall erweitern sie, um mögliche Prozesse zu berücksichtigen, die in den aktuellen ESMS nicht enthalten sind. So schätzen sie den modellbasierten ERFaci auf einen Wert von  $-1,0 \pm 0,8 W m^{-2}$ . Für die einzelnen Modelle, die sie in der Tabelle aufführen, wurde nicht nachvollziehbar dargestellt, woher die Werte stammen. Sie geben nur an, dass die CMIP6-Werte von Smith et al. (2020) und späteren Modellen stammen. Die meisten Modelle finden sich bei Smith et al. (2020) zwar wieder, die Werte stimmen aber nicht mit denen in Tabelle 6 auf Seite 9606 aufgeführten Aerosol-ERF Werten überein, auch nicht, wenn man die vom IPCC angegebene 5% Korrektur miteinrechnet. Sie erwähnen auch nicht explizit, ob sie die Werte durch selbst durchgeführte Simulationen erhalten haben. Es wird jedenfalls keine einheitliche Quelle ersichtlich, die die CMIP6 Ergebnisse in dieser Weise zusammenfassen und mit denen in der Tabelle angegebenen Werte übereinstimmen. Zudem werden auch keine Quellen für die anderen Modelle genannt, die von Smith et al. (2020) nicht untersucht wurden.

Mit einem näheren Blick auf die observationsgestützten Einschätzungen der IR-Fari bzw. IRFaci lässt sich erkennen, dass die meisten Arbeiten Satellitendaten zur Berechnung verwendet. Oft kommen auch zusätzlich Modelloutputs zum Einsatz, vor allem wenn es um die Einschätzung der vorindustriellen Aerosolkonzentration und -emission geht. In der Untersuchung von Kinne (2019) findet sich der im AR6 gemeldete Wert  $-0,4 W m^{-2}$  nicht. Der Wert, der in der Arbeit explizit genannt wird, beläuft sich auf  $-0,36 W m^{-2}$  [0,2 bis 0,45  $W m^{-2}$ ]. Für die Berechnung verwendet Kinne (2019) das *Max Planck Institute Aerosol Climatology* in der zweiten Version (MACv2). Es handelt sich dabei um einen Datensatz an globalen Karten, die Aerosoleigenschaften darstellen. Diese Karten basieren auf Photometerdaten des *AERONET* Netzwerks und des *Maritime Aerosol Network* (MAN). Ma et al. (2014) verwenden hingegen Daten von MODIS und CERES, die hauptsächlich von Satelliten der National Aeronautics and Space Administration (NASA) stammen. Zusätzlich setzen sie die Berechnung des antropogenen Anteils des AOD aus dem Simulationsmodell *GEOS-Chem-APM* ein. Auch Gryspeerdt et al. (2017) verwenden MODIS- und CERES-Daten in Kombination mit Modelldaten. Letztere stammen aus diversen Modellen des AeroCom-Frameworks. Bei den Publikationen von Gryspeerdt et al. (2017) und Gryspeerdt et al. (2016) stimmen die in Abbildung 4.7 aufgeführten Werte überein, wenn man davon ausgeht, dass der Wert von 0,48 aufgerundet wurde. Jedoch konnte keine nominale Einschätzung über den LWP-Anteil am ERFaci in der Arbeit gefunden werden. Allerdings schlussfolgern sie einen positiven Effekt, der den *RFaci* um etwa 60% ausgleichen würde. Auch D. T. McCoy et al. (2017) und I. L. McCoy et al. (2020) verwenden in beiden Publikationen Modelle aus dem AeroCom-Framework. D. T. McCoy et al. (2017) arbeiten mit Satellitendaten von MODIS

und MERRA2, allerdings findet sich der angegebene Wert von  $-1,0 \pm 0,4 W m^{-2}$  nicht wieder. Sie geben einen Wert von  $-0,97 \pm 0,23 W m^{-2}$  für das *Aerosol Radiative Forcing* bezüglich des Twomey-Effektes an. In der Arbeit von I. L. McCoy et al. (2020) werden ausschließlich MODIS-Daten verwendet, jedoch werden zusätzlich zwei weitere Modelle miteinbezogen, die nicht zum AeroCom-Framework gehören. Auch Hasekamp et al. (2019) verwendet die Modelloutputs aus AeroCom-Modellen in Kombination mit MODIS- und POLDER-3-Satellitendaten. Diamond et al. (2020) wiederum verwenden nur Satellitendaten von MODIS, CERES und MERRA2. Zusätzlich erwähnen die Autor\*innen, dass sie die  $SO_2$  Emissionen aus der Emissions Database for Global Atmospheric Research (EDGAR) Datenbank verwenden. Christensen et al. (2016) verwenden Satellitendaten von MODIS, CERES und CALIPSO in Kombination mit Temperaturdaten des European Centre for Medium-Range Weather Forecasts (ECMWF). Rémy et al. (2018) stützen ihre Berechnungen auf den Datensatz *CAMSiRA* vom Copernicus Atmosphere Monitoring Service (CAMS), der unter anderem auch Satellitendaten enthält. Im Bericht des IPCC (2021) wird ein IRFari-Wert zwischen  $-0,5$  und  $-0,6 W m^{-2}$  für den Zeitraum von 2003 bis 2018 angegeben. Dieser Wert wird von Rémy et al. (2018) in dieser Form nicht erwähnt. Sie geben einen Wert von  $-0,68 W m^{-2}$  für das Jahr 2017 an. Abschließend lässt sich sagen, dass sich die Werte, die in der Tabelle 7.7 im IPCC-Bericht angegeben sind (siehe Abbildung 4.7), in fünf von dreizehn Fällen eindeutig in den Quellen wiederfinden. Bei dreien der restlichen acht Fälle sind die Werte sehr ähnlich, sodass die Werte gerundet sein könnten oder es noch Anpassungen gab, die aus dem Text eventuell hervorgehen könnten, aber nicht angewandt wurden. In den übrigen fünf Fällen ist das Ergebnis nicht nachvollziehbar gewesen. Dies könnte auch von den inkonsistenten Bezeichnungen ausgehen, die sich teilweise in den hier analysierten Publikationen unterscheiden. In einigen ist von *direct* und *indirect forcing* die Rede, in anderen wird die Metrik als *RFaci* bezeichnet. Ob dies einen Einfluss auf die Unterschiede hat oder ob Anpassungen überhaupt vorgenommen wurden, geht aus dem Text des AR6 nicht hervor.

Referenz	Satellitendaten	andere Daten	Modell(e)	<i>Radiative Forcing</i> Schätzung
Kinne (2019)		MACv2 (AERONET und MAN Photometerdaten)		$-0,36 W m^{-2}$ [ $-0,2$ bis $-0,45 W m^{-2}$ ]

4.2. Weltklimabericht des Intergovernmental Panel on Climate Change

Ma et al. (2014)	CERES und MODIS		GEOS-Chem-APM	$-0,59Wm^{-2}$ (clear-sky)
Rémy et al. (2018)	CAMSiRA			RFari: $-0,68Wm^{-2}$ (2003-2017) RFaci: $-0,8Wm^{-2}$ (2018)
Gryspeerd et al. (2016)	MODIS	MACv2		$-0,48Wm^{-2}$ ( <i>Cloud Fraction</i> )
Gryspeerd et al. (2019)	MODIS, AMSR-E und CERES			
Gryspeerd et al. (2017)	MODIS und CERES		mehrere AeroCom-Modelle	$-0,4Wm^{-2}$
D. T. McCoy et al. (2017)	MODIS und MERRA2		mehrere Modelle aus AeroCom phase II	$-0,97 \pm 0,23Wm^{-2}$ (Twomey-Effekt)
I. L. McCoy et al. (2020)	MODIS		mehrere AeroCom-Modelle, Had-GEM3-GA7.1 und Had-GEM3-GA4-UKCA	$-1,2$ bis $-0,6Wm^{-2}$
Hasekamp et al. (2019)	MODIS und POLDER-3		fünf AeroCom-Modelle	$-1,14Wm^{-2}$ [ $-0,84$ bis $-1,72Wm^{-2}$ ]
Bellouin et al. (2013)			HadGem CLASSIC-mode und HadGem GLOMAP-mode	indirect forcing: $-1,17$ und $-1,48Wm^{-2}$

Christensen et al. (2017)	AATSR und MODIS			
Christensen et al. (2016)	CALIPSO, MODIS und CERES	ECMWF-Temperaturdaten, 94GHz cloud profiling radar (CPR) (CALIPSO?)		
Diamond et al. (2020)	MODIS, CERES und MERRA2	SO <sub>2</sub> Emissionen aus der EDGAR-Datenbank		$-0,69Wm^{-2}$ [ $-0,99$ bis $0,44Wm^{-2}$ ]
Toll et al. (2019)	MODIS			$-0,52Wm^{-2}$
Chen et al. (2014)	MODIS, CALIPSO und CERES	ECMWF-Daten		<i>intrinsic forcing</i> von $0,49 \pm 0,33Wm^{-2}$

Tabelle 4.1: Übersicht über die Schätzungen für *Radiative Forcing*, die auf Observationsdaten basieren

Models	ERFari (W m <sup>-2</sup> )	ERFaci (W m <sup>-2</sup> )	ERFari+aci (W m <sup>-2</sup> )
ACCESS-CM2	-0.24	-0.93	-1.17
ACCESS-ESM1-5	-0.07	-1.19	-1.25
BCC-ESM1	-0.79	-0.69	-1.48
CanESM5	-0.02	-1.09	-1.11
CESM2	+0.15	-1.65	-1.50
CNRM-CM6-1	-0.28	-0.86	-1.14
CNRM-ESM2-1	-0.15	-0.64	-0.79
EC-Earth3	-0.39	-0.50	-0.89
GFDL-CM4	-0.12	-0.72	-0.84
GFDL-ESM4	-0.06	-0.84	-0.90
GISS-E2-1-G (physics_version=1)	-0.55	-0.81	-1.36
GISS-E2-1-G (physics_version=3)	-0.64	-0.39	-1.02
HadGEM3-GC31-LL	-0.29	-0.87	-1.17
IPSL-CM6A-LR	-0.39	-0.29	-0.68
IPSL-CM6A-LR-INCA	-0.45	-0.35	-0.80
MIROC6	-0.22	-0.77	-0.99
MPI-ESM1-2-HAM	+0.10	-1.40	-1.31
MRI-ESM2-0	-0.48	-0.74	-1.22
NorESM2-LM	-0.15	-1.08	-1.23
NorESM2-MM	-0.03	-1.26	-1.29
UKESM1-0-LL	-0.20	-0.99	-1.19
CMIP6 average and 5–95% confidence range (2014 relative to 1850)	-0.25 ± 0.40	-0.86 ± 0.57	-1.11 ± 0.38
CMIP5 average and 5–95% confidence range (2000 relative to 1860)	-0.27 ± 0.35	-0.96 ± 0.55	-1.23 ± 0.48

Abbildung 4.6: Tabelle 7.6 aus dem siebten Kapitel des AR6, Seite 950 (Forster et al., 2021)



IRFaci (W m <sup>-2</sup> )	Liquid Water Path (LWP) Adjustment (W m <sup>-2</sup> )	Cloud Fraction (Cf) Adjustment (W m <sup>-2</sup> )	Reference
-0.6 ± 0.6	n/a	n/a	Bellouin et al. (2013b)
-0.4 [-0.2 to -1.0]	n/a	n/a	Gryspeerd et al. (2017)
-1.0 ± 0.4	n/a	n/a	McCoy et al. (2017b)
n/a	n/a	-0.5 [-0.1 to -0.6]	Gryspeerd et al. (2016)
n/a	+0.3 to 0.0	n/a	Gryspeerd et al. (2019)
-0.8 ± 0.7	n/a	n/a	Rémy et al. (2018)
-0.53	+0.15	n/a	Toll et al. (2019)
-1.14 [-1.72 to -0.84]	n/a	n/a	Hasekamp et al. (2019)
-1.2 to -0.6	n/a	n/a	McCoy et al. (2020)
-0.69 [-0.99 to -0.44]	n/a	n/a	Diamond et al. (2020)
'Intrinsic Forcing'			
-0.5 ± 0.5		-0.5 ± 0.5	Chen et al. (2014)
-0.4 ± 0.3		n/a	Christensen et al. (2016a)
-0.3 ± 0.4		-0.4 ± 0.5	Christensen et al. (2017)

Abbildung 4.7: Tabelle 7.7 aus dem siebten Kapitel des AR6, Seite 951 (Forster et al., 2021)

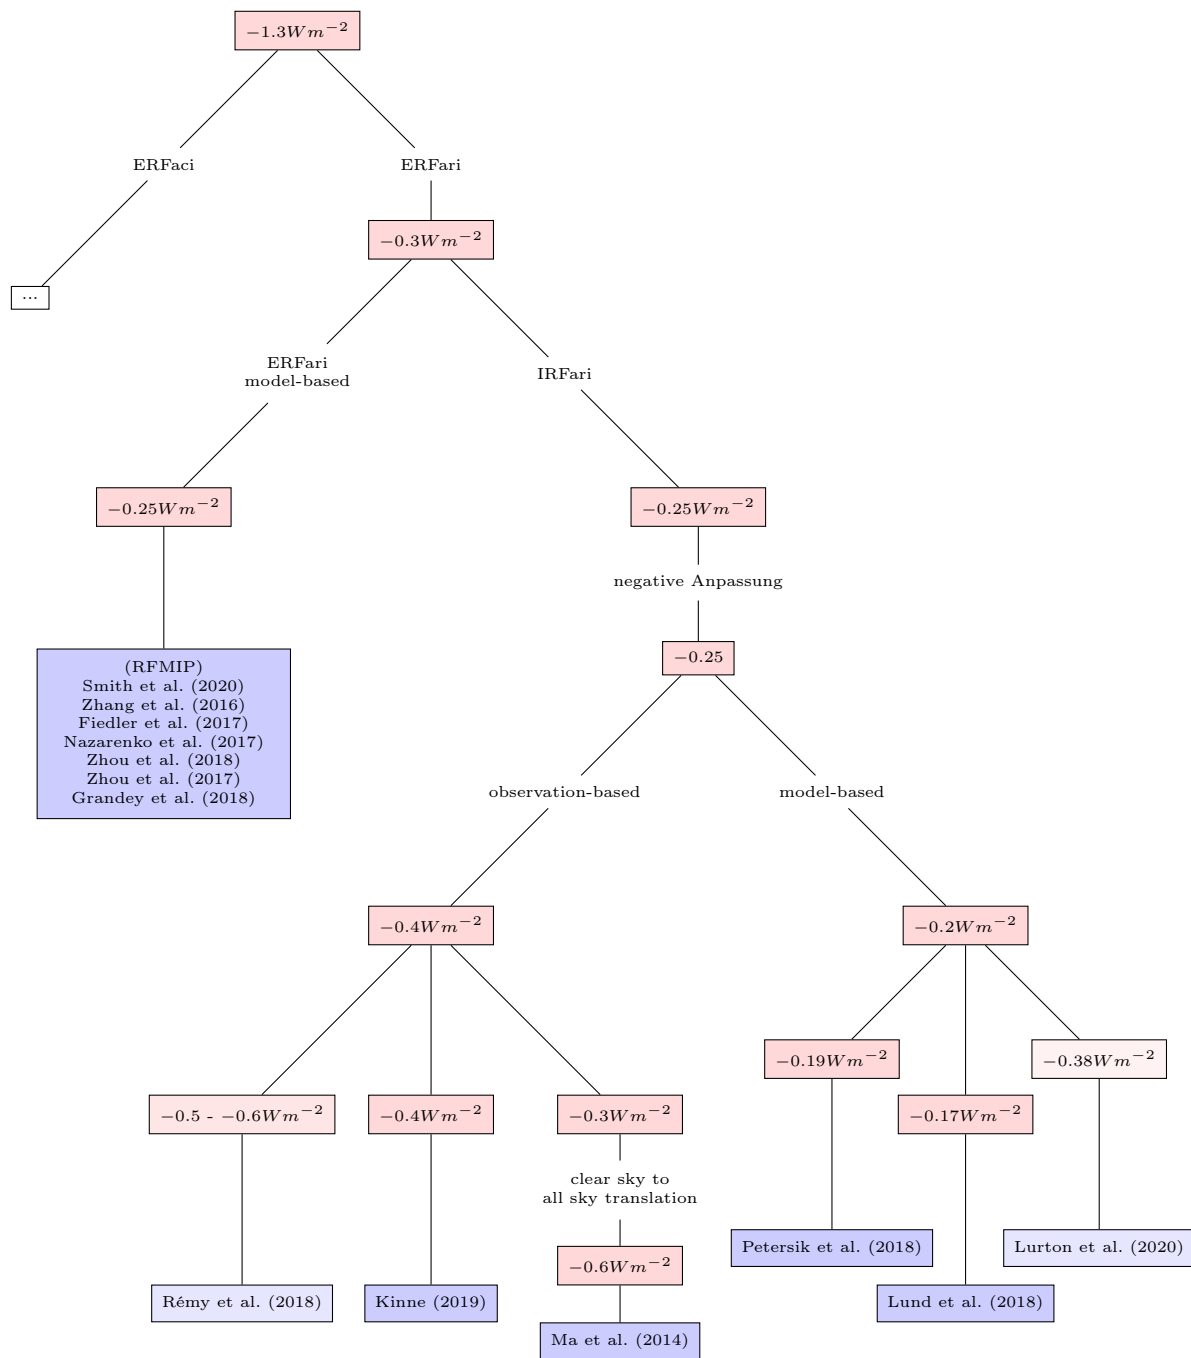


Abbildung 4.8: Zusammensetzung des Aerosol-ERF in Bezug auf die Aerosol-Strahlungs-Interaktion. Knoten mit geringerer Farbsättigung zeigen Werte, die in der Auswertung weniger gewichtet wurden.

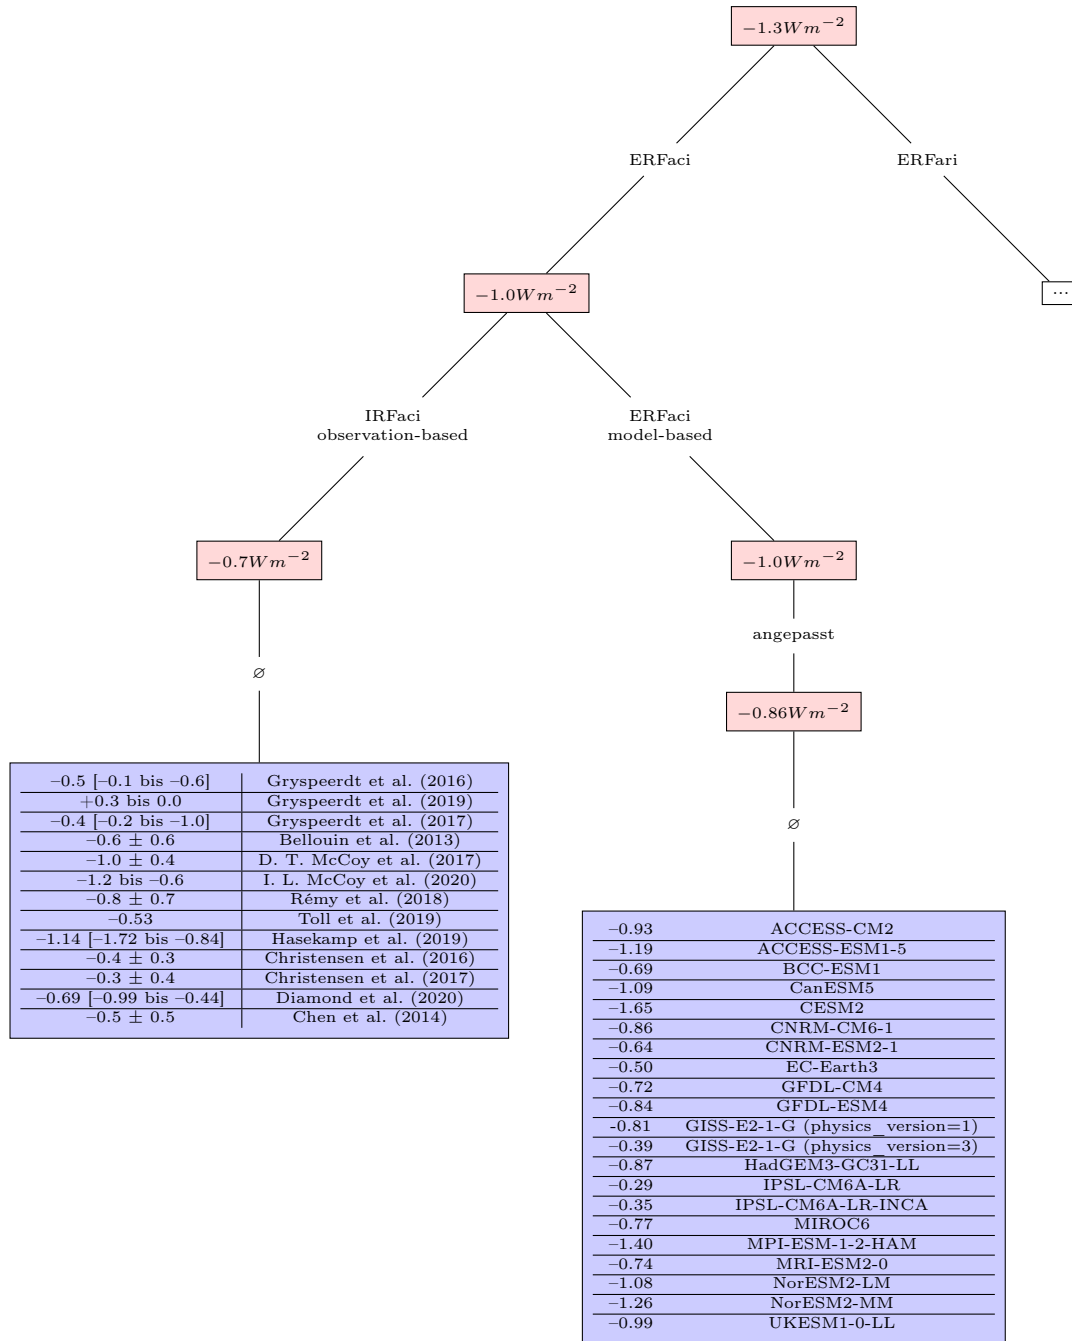


Abbildung 4.9: Zusammensetzung des Aerosol-ERF in Bezug auf die Aerosol-Wolken-Interaktion.

# Kapitel 5

## Diskussion

### 5.1 Einordnung hinsichtlich der Forschungsfragen

In diesem Abschnitt sollen die Ergebnisse noch einmal hinsichtlich der Fragen, die in Kapitel 1 aufgeworfen wurden, betrachtet werden.

Es wurde in dieser Arbeit untersucht, in wiefern *Scientific Knowledge Graphs* die **Mobilität** und die **Bestimmung der Provenienz** unterstützen können (Forschungsfrage 1). Im ersten Fallbeispiel wurde gezeigt, dass die Bewegung der Messwerte von ihren ursprünglichen Arbeiten, in denen sie veröffentlicht wurden, hin zu der Synthesearbeit von Gkatzelis et al. (2021) durch die *comparisons* nachvollziehbarer und offenkundiger dargelegt sind. In der Arbeit werden die Quellen in den Referenzen aufgeführt, allerdings wird nur in der bereitgestellten CSV-Datei spezifiziert, welche der Quellen als Daten-Input für die Schlussfolgerungen und die Abbildungen dienen. In Abbildung 5.1 ist zu sehen, dass die genauen Datensätze, die als Input für die Abbildung 4.1 verwendet wurden, klar aufgelistet und durch einen Klick einsehbar sind. Wie in Kapitel 4 angesprochen, wäre es jedoch besser, wenn alle *contributions* in einer *comparison* vereint wären. Die Einteilung in Geographische Regionen ist aber dahingehend ein guter Kompromiss, dass trotz der großen Anzahl an Inputdateien, diese semantische Unterteilung Übersichtlichkeit zurückbringt.

Im zweiten Fallbeispiel wurde jedoch auch offensichtlich, dass SKGs keine praktikable Lösung für eine Top-Down-Untersuchung der Provenienz wissenschaftlicher Erkenntnisse liefern. Im Rahmen dieser Arbeit wurden die Quellen, die der sechste Assessment Report des IPCC genutzt hat, nicht bei ORKG hochgeladen. Der zusätzliche Aufwand, den dies bedeutet hätte, hätte den Rahmen dieser Arbeit überstiegen. Im Vergleich zu dem Bottom-Up-Verfahren, in dem die Quellen in einem übersichtlichen Maße offenlagen, ist die Rechercharbeit mit und ohne eine Nutzung von ORKG

has specified input	<a href="#">Air pollution measurements during COVID-19 lockdown for Africa</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for Central Asia</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for East Asia</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for Europe</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for North America</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for Oceania</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for South America</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for South Asia 1</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for South Asia 2</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for Southeast Asia</a>
	<a href="#">Air pollution measurements during COVID-19 lockdown for West Asia</a>

Abbildung 5.1: Die *comparisons* als Input für die Untersuchungen in ORKG.

zu leisten. Der Top-Down-Ansatz ist lediglich als erster Schritt dazu geeignet, die Quellen und die damit verbundene Mobilität zu identifizieren. Die Untersuchung der Mobilität auf diese Weise breitflächig zu organisieren, ist wie in Kapitel 4 bereits beschrieben, zu arbeitsaufwendig und für fachfremde Personen überhaupt schwer umsetzbar. Allerdings liefert dieser Versuch auch guten Vergleich für das erste Fallbeispiel. So kann die Nutzung von ORKG nur im Bottom-Up Ansatz, also schon bei der Durchführung der Synthese, einen Vorteil bieten, auch wenn es im Nachhinein bei der Rückverfolgung keinen Mehrwert hat.

Weiterhin wurde in dieser Arbeit untersucht, inwiefern *Scientific Knowledge Graphs* **Synthesearbeiten** unterstützen können (Forschungsfrage 2). ORKG kann das Erstellen von Synthesearbeiten durchaus vereinfachen, allerdings hängt dies von mehreren Annahmen ab:

1. Die Arbeiten, die einfließen sollen, befinden sich bereits in ORKG. Die Autor\*innen von Synthesearbeiten müssten wie bisher selbst recherchieren, welche Arbeiten für ihre Untersuchung relevant sind, allerdings kann der Aufwand reduziert werden, wenn diese nicht selbst noch in ORKG eingepflegt werden müssten. Sonst wäre der Aufwand sogar noch größer als bislang.
2. Im besten Fall verwenden alle relevanten Publikationen das gleiche oder mindestens ein ähnliches *template*. So könnte das Vorverarbeiten der Daten effizienter gestaltet werden, da die Daten häufig in das gleiche Format gebracht werden müssen, um diese sinnvoll vergleichen, visualisieren oder anderweitig verarbeiten zu können.
3. Wie bereits angesprochen wäre es hilfreich, wenn alle *contributions* in einer einzigen *comparison* veröffentlicht werden könnten. Es würde eine spätere Zusammenführung der Daten überflüssig machen. Allerdings würde diese Bedingung bei vielen Synthesearbeiten vermutlich die derzeitige Kapazität übersteigen.

Da ORKG ein *Crowdsourcing*-Projekt ist, ist es zweifelhaft, ob die ersten beiden Punkte realistisch umsetzbar sind.

Als Letztes wurde die Frage aufgeworfen, ob *Scientific Knowledge Graphs* Forschungsergebnisse einfacher **reproduzierbar** machen können (Forschungsfrage 3). Wir haben bereits gesehen, dass die verwendeten Datensätze in ORKG sehr einfach verlinkt werden können. Aber auch der verwendete Code (siehe Abbildung 5.2), und die produzierten Ergebnisse, inklusive Abbildungen (siehe Abbildung 4.5) können nachvollziehbar veröffentlicht werden. So können alle Nutzer\*innen den Code und die Eingabe selbst verwenden, um die Ergebnisse zu reproduzieren und umgehen so

das in Kapitel 1 angeführte Problem der Zitation von Repositories, in denen oft nicht ganz klar erkenntlich gemacht werden kann, welche Dateien nun für welche Outputs verwendet wurden.

The screenshot shows the ORKG interface. At the top, it indicates 'Applied template: software\_method'. Below this, there is a section titled 'is implemented by' which contains a code block. The code block shows Python code for setting requirements and importing libraries. A red clipboard icon is visible in the top right of the code block. Below the code block is a 'Show all' link. At the bottom, there is a section titled 'uses software' which contains the link 'statistics.median'.

```

# Python version: 3.4
# Requirements: pandas==2.2.0, matplotlib==3.8.2

import statistics
import pandas as pd
...

```

[Show all](#)

uses software: [statistics.median](#)

Abbildung 5.2: Der Code, der zum Erzeugen der Ergebnisse genutzt wurde, kann in ORKG veröffentlicht werden

## 5.2 Probleme und Schwierigkeiten bei der Umsetzung

Vor allem bei der Implementierung, die in Abschnitt 3.2.2 beschrieben ist, sind einige Probleme aufgetreten. Obwohl der *template-client* problemfrei funktioniert und für diesen Anwendungsfall gut geeignet ist, wurde der Umgang mit den *templates* durch die Inkonsistenz der CSV-Daten erschwert. Da „none“ kein zulässiger Eintrag im *template* ist, mussten im Code viele Fallunterscheidungen gemacht werden, wann immer eine oder mehrere Zeilen die geforderte Daten nicht enthielten.

Am stärksten fällt die Problematik ins Gewicht, dass ORKG nicht auf so große *comparisons* ausgelegt ist. Das ursprüngliche Ziel war es, eine *comparison* für alle *contributions* zu erstellen, sodass alle Daten wieder zusammengeführt überblickt werden können. Leider ist das System schon bei den knapp über 100 *contributions*

an seine Grenzen gestoßen. Wobei es bei der *comparison* für die Messwerte in Europa mit 135 Messungen keine Probleme gibt, bei Südasien mit 114 *contributions* allerdings schon. Für den Anwendungsfall der Synthesearbeiten ist es aber inhärent wichtig, dass viele Daten als Input vorhanden sind. Leider war auch das Laden der *comparisons* als *pandas dataframe* nicht möglich, welches mit der Python-Bibliothek über den *contribution-client* funktioniert. Das Problem könnte möglicherweise mit der Größe in Zusammenhang stehen. Die Fehlermeldung „**RuntimeError: Failed to get thing <comparison\_id>**“ war jedoch nicht aussagekräftig genug, um die Ursache dessen genau zu benennen. Andererseits trat diese Fehlermeldung auch bei der *comparison* bezüglich Afrika auf, die nur fünf *contributions* enthält, was darauf schließen würde, dass die Größe hier nicht der Grund ist. Der Fehler tritt allerdings nicht bei dem Beispiel auf, das in der Dokumentation der Python-Bibliothek angebracht ist. Es scheint also kein allgemeiner Programmfehler in der Funktion oder des verwendeten *Incubating-Hosts* zu sein. Als Umgehung dieses Problems konnten die Daten der *comparisons* zwar als CSV-Datei in der Weboberfläche heruntergeladen werden, allerdings werden die Einträge automatisch gekürzt, welches eine manuelle Überprüfung mit der Funktion *select properties* notwendig macht. Da sich die Ladezeiten bei der Größe der *comparisons* massiv erhöht haben, hat dies inadäquat viel Zeit in Anspruch genommen und ist auch einige Male abgestürzt. Aus diesem Grund haben die *ressources* der Messorte aller *contributions* das Label „Location“. So konnte die Menge an Output für die *comparisons* gesenkt werden, auch wenn dieses Label die Aussagekraft deutlich verringert. Dafür enthalten die Labels der *contributions* selbst aber den Messort, welches wieder etwas Übersichtlichkeit zurückbringt.

Insgesamt wäre es deutlich einfacher gewesen, wenn es eine einfachere Möglichkeit gäbe, die Daten einer *contribution* auszulesen. Die einzige Alternative, die in diesem Anwendungsfall zu den *comparisons* existiert hätte, wäre der *statement-client* gewesen. Dies hätte den Aufwand beim Auslesen allerdings noch weit erhöht, da die Tiefe des Graphen zu hoch gewesen wäre. Das Verwenden des *statement*-Funktionen war allerdings trotzdem nötig um die *contributions* nach Kontinenten zu sortieren und nach den gemessenen Schadstoffen zu filtern. Der Prozess hat durch diese Aneinanderreihung von Anfragen sehr lange gedauert. Eine Funktion, die nur für eine *contribution* oder alle *contributions* eines *papers*, die Daten in tabellarisches Format bringt, wäre in diesem Fall möglicherweise eine einfachere Möglichkeit gewesen, die Daten für das Python-Programm weiterverarbeitbar zu machen.

Im zweiten Fallbeispiel war das Nachverfolgen der Provenienz von Ergebnissen in hohem Maß zeitaufwendig und ist in dieser Arbeit nicht zufriedenstellend gelungen. Da der AR6 keine wissenschaftliche Arbeit ist im eigentlichen Sinne, sondern eine Zusammenfassung des aktuellen Standes der Klimaforschung, wurden zwar viele Quellen



genannt und diskutiert, jedoch haben sie keine nachvollziehbaren Berechnungen offengelegt. Es war daher nicht klar, welche Quellen sie in welchem Maße gewichtet und miteinbezogen haben. Desweiteren war es häufig intransparent, welche Werte sich auf welchen Zeitraum beziehen. In ihrer Tabelle 7.6 (siehe Abbildung 4.6) geben sie Quellen an, die den ERFaci für 2014 bezüglich 1850 angeben. Ihre Gesamtbewertung bezieht sich dann allerdings auf 1750. Auch hier ist nicht klar, wie sie diese Lücke von 100 Jahren aufgelöst haben. Außerdem konnten einige Werte, die der IPCC (2021) genannt hat, in den angegebenen Bezugsquellen nicht als diese identifiziert werden. Es besteht die Möglichkeit, dass diese Problematik für fachinterne Expert\*innen nicht besteht. Hier zeigt sich die Grenze der Nachvollziehbarkeit für Wissenschaftler\*innen aus Nachbardisziplinen.

# Kapitel 6

## Schlussfolgerungen und Aussicht

In dieser Arbeit wurde die Mobilität vor allem hinsichtlich der Wiederverwendung von wissenschaftlichen Erkenntnissen untersucht. Der Fokus lag dabei vor allem auf Synthesearbeiten. Anhand von zwei Fallbeispielen wurde untersucht, welche Rolle SKGs, im Besonderen ORKG, dabei spielen können. Das Ziel war es zu testen, ob die Dokumentation der Arbeiten in ORKG dazu beitragen kann, die Erstellung von Synthesearbeiten zu vereinfachen und ob dies dazu führt, dass die Ergebnisse besser nachvollziehbar und reproduzierbar für Nutzer\*innen sind. Als erstes Fallbeispiel wurde die Arbeit von Gkatzelis et al. (2021) untersucht. Hierbei wurde festgestellt, dass ein Scientific Knowledge Graph wie ORKG durchaus eine Unterstützung sein könnte, wenn man die Funktion der *comparisons* verwendet, diese jedoch derzeit auf eine deutlich zu geringe Kapazität ausgelegt sind. Um ORKG für diesen Anwendungsfall sinnvoll einsetzen zu können, könnte auch das *Python-Package* in dieser Hinsicht angepasst werden. So könnte man eine Funktion einführen, mit der alle Daten einer einzelnen *contribution* abrufbar sind, ohne dies mühselig über die *statements* zu tun. So wäre es deutlich einfacher, alle relevanten *contributions* für eine *comparison* abzurufen und diese gegebenenfalls direkt zu filtern. Das Nachstellen der Synthesearbeit ist dennoch weitestgehend gelungen und kann so auch auf ORKG nachvollziehbar und auch für alle User\*innen reproduzierbar eingesehen werden. Dies kann als ein deutlicher Vorteil im Vergleich zu verteilt organisierten *Supplementary Materials*, wie es derzeit üblich ist, gesehen werden.

Im zweiten Fallbeispiel wurde versucht, die Erkenntnisse aus dem sechsten *Assessment Report* des IPCC (2021) durch eine Rückwärtssuche nachzuvollziehen. In diesem Fall haben wir gesehen, dass ORKG im Nachhinein keinen Vorteil mitbringen kann. Eine Dokumentation der Quellen und dessen Verlinkungen in ORKG sollte zu einem früheren Zeitpunkt erfolgen, denn diese Rückverfolgung ist in jedem Fall

mit hohem Aufwand in der Literaturrecherche verbunden und sollte auch von Expert\*innen des jeweiligen Fachgebiets durchgeführt werden.

Zusammenfassend bleibt festzuhalten, dass sich eine Einbindung von ORKG in den Prozess des Erstellens einer Synthesearbeit positiv auf die Dokumentation der **Mobilität von wissenschaftlichen Erkenntnissen** auswirken kann. Diese Dokumentation ist hinsichtlich der Reproduzierbarkeit und der Bestimmung der Provenienz sachdienlich.

Die Einbindung von ORKG in den Prozess des Erstellens von Synthesearbeiten könnte allerdings auch umfassender getestet werden. So wäre es interessant zu untersuchen, ob sich ORKG eignet, um relevante Literatur zu einem Problem herauszusuchen. Hier wäre allerdings die Grundannahme, dass ORKG eine ausreichend große Menge an Literatur zu einem Problem verfügbar hat und dass diese Menge ein ausgeglichenes Bild abgibt. Da die Inhalte von ORKG durch *Crowdsourcing* erstellt werden, ist es aber zweifelhaft, ob es jemals dieselbe Rolle bei der Literaturrecherche einnehmen kann, wie es derzeit beispielsweise *Google Scholar* tut.

Weiterhin könnte in Zukunft noch einmal das Problem des *Backtrackings* anders untersucht werden. Da der Weltklimabericht des IPCC nicht in ORKG verfügbar war, konnte in dieser Arbeit nicht untersucht werden, wie der Top-Down-Ansatz innerhalb der Anwendung funktionieren könnte. So wäre eine Untersuchung einer Synthesearbeit, die bereits in ORKG existiert, interessant. Und zwar in der Hinsicht, wie gut sich die Daten zurückverfolgen lassen, ohne dass bei der Erstellung, wie bei dem in dieser Arbeit vorgestellten Bottom-Up-Ansatz, besonders auf die Dokumentation der Provenienz geachtet wurde. Es wäre also zu klären, ob sich auch in diesem Fall ein *Backtracking* durchführen ließe.

Außerdem ist auch anzumerken, dass die Synthesearbeit von Gkatzelis et al. (2021) nur quantitative Daten zusammengefasst. Es bleibt also an dieser Stelle noch aus, wie sich eine Untersuchung wie in dieser Arbeit auf qualitative Ergebnisse anwenden lässt.

# Literatur

- Auer, S., Oelen, A., Haris, M., Stocker, M., D'Souza, J., Farfar, K. E., Vogt, L., Prinz, M., Wiens, V., & Jaradeh, M. Y. (2020). Improving Access to Scientific Literature with Knowledge Graphs. *Bibliothek Forschung und Praxis*, *44*(3), 516–529. <https://doi.org/10.1515/bfp-2020-2042>
- Bellouin, N., Mann, G. W., Woodhouse, M. T., Johnson, C., Carslaw, K. S., & Dalvi, M. (2013). Impact of the modal aerosol scheme GLOMAP-mode on aerosol forcing in the Hadley Centre Global Environmental Model. *Atmospheric Chemistry and Physics*, *13*(6), 3027–3044. <https://doi.org/10.5194/acp-13-3027-2013>
- Chen, ., Christensen, M. W., Stephens, G. L., & Seinfeld, J. H. (2014). Satellite-Based Estimate of Global Aerosol-Cloud Radiative Forcing by Marine Warm Clouds. *Nature Geosci*, *7*, 643–646.
- Christensen, M. W., Chen, Y.-C., & Stephens, G. L. (2016). Aerosol indirect effect dictated by liquid clouds. *Journal of Geophysical Research: Atmospheres*, *121*(24). <https://doi.org/10.1002/2016JD025245>
- Christensen, M. W., Neubauer, D., Poulsen, C. A., Thomas, G. E., McGarragh, G. R., Povey, A. C., Proud, S. R., & Grainger, R. G. (2017). Unveiling aerosol–cloud interactions – Part 1: Cloud contamination in satellite products enhances the aerosol indirect forcing estimate. *Atmospheric Chemistry and Physics*, *17*(21), 13151–13164. <https://doi.org/10.5194/acp-17-13151-2017>
- Cooper, H., Hedges, L., & Valentine, J. (2009). *The Handbook of Research Synthesis and Meta-Analysis*. Russell Sage Foundation.
- Diamond, M. S., Director, H. M., Eastman, R., Possner, A., & Wood, R. (2020). Substantial Cloud Brightening From Shipping in Subtropical Low Clouds. *AGU Advances*, *1*(1), e2019AV000111. <https://doi.org/10.1029/2019AV000111>
- Fidler, F., & Wilcox, J. (2021). Reproducibility of Scientific Results. In E. N. Zalta (Hrsg.), *The Stanford Encyclopedia of Philosophy* (Summer 2021). Metaphysics Research Lab, Stanford University.
- Fiedler, S., Stevens, B., & Mauritsen, T. (2017). On the sensitivity of anthropogenic aerosol forcing to model-internal variability and parameterizing a Twomey effect. *Journal of Advances in Modeling Earth Systems*, *9*(2), 1325–1341. <https://doi.org/10.1002/2017MS000932>
- Forster, P. M., Forster, H. I., Evans, M. J., Gidden, M. J., Jones, C. D., Keller, C. A., Lamboll, R. D., Quéré, C. L., Rogelj, J., Rosen, D., Schleussner, C.-F., Richardson, T. B., Smith, C. J., & Turnock, S. T. (2020). Current and future global climate impacts resulting from COVID-19. *Nature Climate Change*, *10*(10), 913–919. <https://doi.org/10.1038/s41558-020-0883-0>
- Forster, Storelvmo, T., Collins, W., Armour, K., Dufresne, J., Frame, D., Lunt, D., Mauritsen, T., Palmer, M., Watanabe, M., Wild, M., & Zhang, H. (2021). The Earth's Energy Bud-

- get, Climate Feedbacks and Climate Sensitivity. In *Climate Change 2021 – The Physical Science Basis: Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* (S. 923–1054). Cambridge University Press. <https://doi.org/10.1017/9781009157896.009>
- Gkatzelis, G. I., Gilman, J. B., Brown, S. S., Eskes, H., Gomes, A. R., Lange, A. C., McDonald, B. C., Peischl, J., Petzold, A., Thompson, C. R., & Kiendler-Scharr, A. (2021). The global impacts of COVID-19 lockdowns on urban air pollution. *Elementa: Science of the Anthropocene*, 9(1), 00176. <https://doi.org/10.1525/elementa.2021.00176>
- Grandey, B. S., Rothenberg, D., Avramov, A., Jin, Q., Lee, H.-H., Liu, X., Lu, Z., Albani, S., & Wang, C. (2018). Effective radiative forcing in the aerosol–climate model CAM5.3-MARC-ARG. *Atmospheric Chemistry and Physics*, 18(21), 15783–15810. <https://doi.org/10.5194/acp-18-15783-2018>
- Gryspeerd, E., Quaas, J., & Bellouin, N. (2016). Constraining the aerosol influence on cloud fraction. *Journal of Geophysical Research: Atmospheres*, 121(7), 3566–3583. <https://doi.org/10.1002/2015JD023744>
- Gryspeerd, E., Goren, T., Sourdeval, O., Quaas, J., Mülmenstädt, J., Dipu, S., Unglaub, C., Gettelman, A., & Christensen, M. (2019). Constraining the aerosol influence on cloud liquid water path. *Atmospheric Chemistry and Physics*, 19(8), 5331–5347. <https://doi.org/10.5194/acp-19-5331-2019>
- Gryspeerd, E., Quaas, J., Ferrachat, S., Gettelman, A., Ghan, S., Lohmann, U., Morrison, H., Neubauer, D., Partridge, D. G., Stier, P., Takemura, T., Wang, H., Wang, M., & Zhang, K. (2017). Constraining the instantaneous aerosol influence on cloud albedo. *Proceedings of the National Academy of Sciences*, 114(19), 4899–4904. <https://doi.org/10.1073/pnas.1617765114>
- Hasekamp, O. P., Gryspeerd, E., & Quaas, J. (2019). Analysis of polarimetric satellite measurements suggests stronger cooling due to aerosol-cloud interactions. *Nature Communications*, 10(1), 5405. <https://doi.org/10.1038/s41467-019-13372-2>
- Hogan, A., Blomqvist, E., Cochez, M., D’amato, C., Melo, G. D., Gutierrez, C., Kirrane, S., Gayo, J. E. L., Navigli, R., Neumaier, S., Ngomo, A.-C. N., Polleres, A., Rashid, S. M., Rula, A., Schmelzeisen, L., Sequeda, J., Staab, S., & Zimmermann, A. (2022). Knowledge Graphs. *ACM Computing Surveys*, 54(4), 1–37. <https://doi.org/10.1145/3447772>
- IPCC. (2021). *Climate Change 2021 – The Physical Science Basis: Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* (1. Aufl.). Cambridge University Press. <https://doi.org/10.1017/9781009157896>
- Kinne, S. (2019). Aerosol radiative effects with MACv2. *Atmospheric Chemistry and Physics*, 19(16), 10919–10959. <https://doi.org/10.5194/acp-19-10919-2019>
- Leonelli, S. (2020). Learning from Data Journeys. In S. Leonelli & N. Tempini (Hrsg.), *Data Journeys in the Sciences* (S. 1–24). Springer International Publishing. [https://doi.org/10.1007/978-3-030-37177-7\\_1](https://doi.org/10.1007/978-3-030-37177-7_1)
- Leonelli, S., & Tempini, N. (Hrsg.). (2020). *Data Journeys in the Sciences*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-37177-7>
- Lund, M. T., Myhre, G., Haslerud, A. S., Skeie, R. B., Griesfeller, J., Platt, S. M., Kumar, R., Myhre, C. L., & Schulz, M. (2018). Concentrations and radiative forcing of anthropogenic aerosols from 1750 to 2014 simulated with the Oslo CTM3 and CEDS emission inventory. *Geoscientific Model Development*, 11(12), 4909–4931. <https://doi.org/10.5194/gmd-11-4909-2018>

- Lurton, T., Balkanski, Y., Bastrikov, V., Bekki, S., Bopp, L., Braconnot, P., Brockmann, P., Cadule, P., Contoux, C., Cozic, A., Cugnet, D., Dufresne, J.-L., Éthé, C., Foujols, M.-A., Ghattas, J., Hauglustaine, D., Hu, R.-M., Kageyama, M., Khodri, M., . . . Boucher, O. (2020). Implementation of the CMIP6 Forcing Data in the IPSL-CM6A-LR Model. *Journal of Advances in Modeling Earth Systems*, 12(4), e2019MS001940. <https://doi.org/10.1029/2019MS001940>
- Ma, X., Yu, F., & Quaas, J. (2014). Reassessment of satellite-based estimate of aerosol climate forcing. *Journal of Geophysical Research: Atmospheres*, 119(17). <https://doi.org/10.1002/2014JD021670>
- McCoy, D. T., Bender, F. A.-M., Mohrmann, J. K. C., Hartmann, D. L., Wood, R., & Grosvenor, D. P. (2017). The global aerosol-cloud first indirect effect estimated using MODIS, MERRA, and AeroCom. *Journal of Geophysical Research: Atmospheres*, 122(3), 1779–1796. <https://doi.org/10.1002/2016JD026141>
- McCoy, I. L., McCoy, D. T., Wood, R., Regayre, L., Watson-Parris, D., Grosvenor, D. P., Mulcahy, J. P., Hu, Y., Bender, F. A.-M., Field, P. R., Carslaw, K. S., & Gordon, H. (2020). The hemispheric contrast in cloud microphysical properties constrains aerosol forcing. *Proceedings of the National Academy of Sciences*, 117(32), 18998–19006. <https://doi.org/10.1073/pnas.1922502117>
- Münch, Q. (2022). *Information Extraction from Arcticles on the Impacts of COVID-19 Lockdowns on Air Quality* (Bachelorarbeit). Leibniz Universität Hannover. Hannover.
- Nazarenko, L., Rind, D., Tsigaridis, K., Del Genio, A. D., Kelley, M., & Tausnev, N. (2017). Interactive nature of climate change and aerosol forcing. *Journal of Geophysical Research: Atmospheres*, 122(6), 3457–3480. <https://doi.org/10.1002/2016JD025809>
- Petersik, P., Salzmann, M., Kretzschmar, J., Cherian, R., Mewes, D., & Quaas, J. (2018). Subgrid-scale variability in clear-sky relative humidity and forcing by aerosol–radiation interactions in an atmosphere model. *Atmospheric Chemistry and Physics*, 18(12), 8589–8599. <https://doi.org/10.5194/acp-18-8589-2018>
- Ram, S., Liu, J., & Hall, J. M. (2009). A New Perspective on Semantics of Data Provenance. *SWPM*, 526.
- Rémy, S., Bellouin, N., Benedetti, A., & Boucher, O. (2018). Aerosol [in “State of the Climate in 2017”]. *Bulletin of the American Meteorological Society*, 99(8), Si–S310. <https://doi.org/10.1175/2018BAMSStateoftheClimate.1>
- Smith, C. J., Kramer, R. J., Myhre, G., Alterskjær, K., Collins, W., Sima, A., Boucher, O., Dufresne, J.-L., Nabat, P., Michou, M., Yukimoto, S., Cole, J., Paynter, D., Shiogama, H., O’Connor, F. M., Robertson, E., Wiltshire, A., Andrews, T., Hannay, C., . . . Forster, P. M. (2020). Effective radiative forcing and adjustments in CMIP6 models. *Atmospheric Chemistry and Physics*, 20(16), 9591–9618. <https://doi.org/10.5194/acp-20-9591-2020>
- Toll, V., Christensen, M., Quaas, J., & Bellouin, N. (2019). Weak average liquid-cloud-water response to anthropogenic aerosols. *Nature*, 572(7767), 51–55. <https://doi.org/10.1038/s41586-019-1423-9>
- Zhang, H., Zhao, S., Wang, Z., Zhang, X., & Song, L. (2016). The updated effective radiative forcing of major anthropogenic aerosols and their effects on global climate at present and in the future. *International Journal of Climatology*, 36(12), 4029–4044. <https://doi.org/10.1002/joc.4613>

- Zhou, C., Zhang, H., Zhao, S., & Li, J. (2017). Simulated effects of internal mixing of anthropogenic aerosols on the aerosol–radiation interaction and global temperature. *International Journal of Climatology*, *37*(S1), 972–986. <https://doi.org/10.1002/joc.5050>
- Zhou, C., Zhang, H., Zhao, S., & Li, J. (2018). On Effective Radiative Forcing of Partial Internally and Externally Mixed Aerosols and Their Effects on Global Climate. *Journal of Geophysical Research: Atmospheres*, *123*(1), 401–423. <https://doi.org/10.1002/2017JD027603>