

Johannes Oberpriller, Almut Arneth, Christine Herschlein, Anja Rammig und Florian Hartig

Modellunsicherheiten in Klimafolgeprojektionen

Eine Einführung

Um Folgen des Klimawandels abzuschätzen, erzeugen Klimaforscher oft Modellvorhersagen basierend auf einem Emissionsszenario, sogenannte Klimafolgeprojektionen. Solche Modellprojektionen sind mit Unsicherheiten behaftet, die sich aus den Unsicherheiten der einzelnen Modellkomponenten (z.B. Treibern, Parametern oder Struktur) ergeben. Die Quantifizierung dieser Unsicherheiten ist für die Interpretation der Projektionen durch Forschung, Entscheidungsträger und Öffentlichkeit von essenzieller Wichtigkeit. Ziel dieses Artikels ist es, eine Einführung in die Berechnung von Modellunsicherheiten im Kontext von Klimafolgeprojektionen zu geben. Wir diskutieren hierzu zunächst die Gründe und Typen von Modellunsicherheiten und erklären danach wie man diese quantifizieren (=Unsicherheitsanalyse) und über den Abgleich mit Beobachtungsdaten reduzieren (=Modellinversion) kann. Wir veranschaulichen die besprochenen Konzepte durch eine Fallstudie, in der wir eine Unsicherheitsanalyse des terrestrischen Ökosystemmodells LPJ-GUESS für einen Standort in Franken vornehmen.

Schlagwörter: **Unsicherheitsanalyse, Sensitivitätsanalyse, Klimafolgeprojektionen**

1 Einleitung

Um die Folgen des Klimawandels abzuschätzen und alternative Szenarien zu vergleichen, werden in der Klimaforschung häufig sogenannte Klimafolgeprojektionen (engl.: climate impact projections) erstellt. Eine solche Projektion berechnet die zeitliche Entwicklung eines Systems (z.B. Klima, Vegetation), basierend auf einem Szenario (z.B. das Szenario, dass sich CO₂ Emissionen ungebremst weiterentwickeln). Projektionen unterscheiden sich von Vorhersagen darin, dass die Wahrscheinlichkeiten der zugrunde liegenden Szenarien unbekannt sind, d.h. es handelt sich hierbei nicht um Prognosen mit einer absoluten Wahrscheinlichkeit, sondern um bedingte (d.h. wenn-dann) Berechnungen, denen bestimmte Annahmen, z.B. ein Szenario der globalen Wirtschaftsentwicklung zugrunde liegt (z.B. O'NEILL 2004; BRAY/VON STORCH 2009; MOSS et al. 2010; O'NEILL et al. 2014).

Aufgrund der hohen Komplexität und Interkonnektivität von Klima- und Ökosystemen sind bei der Beschreibung solcher Projektionen intuitive oder auf Überschlagsrechnungen basierende Überlegungen nur beschränkt nützlich. Numerisch genaue Projektionen können jedoch nur mit Hilfe von mathematischen Beschreibungen der Zusammenhänge eines abgegrenzten Systems (z.B. Klima, terrestrische oder marine Ökosysteme) gemacht werden. Solche Systemmodelle werden typischerweise am Computer angefertigt und für verschiedene Simulationen verwendet (HARTIG 2017). Die meisten solcher Modelle im Kontext des Klimawandels zeichnen sich durch

eine relative hohe Komplexität aus, d.h. durch viele hunderte Zustandsgrößen (für Vegetationsmodelle z.B. Kohlenstoff-, Wasser- und Stickstoffhaushalt eines Baumes), die wiederum mittels zahlreicher (tausender), oft nichtlinearer Prozesse miteinander interagieren (SCHNEIDER/HELD 2002). Die zeitliche Entwicklung des Systems emergiert dann während der Simulation aufgrund der Startbedingung des Systems, den Treibern (externen Rahmenbedingungen, in der Mathematik auch Randbedingungen genannt) und den im Modell implementierten Prozessen.

Die hohe Komplexität der im Umfeld der Klimafolgenforschung benutzten Modelle macht einerseits Zukunftsprojektionen dieser Systeme überhaupt möglich, andererseits bringt sie aber auch gewisse Nachteile mit sich (z.B. HELD 2014). Insbesondere lassen sich Vorhersagen kaum intuitiv auf ihre Korrektheit überprüfen. Wissenschaftler sind deshalb auf einen genauen und zeitraubenden Abgleich der Modelle mit Beobachtungsdaten angewiesen, um sowohl die Wahl der im Modell repräsentierten Prozesse, als auch deren korrekte Implementierung zu überprüfen (ORESQUES/SHRADER-FRECHETTE/BELITZ et al. 1994).

Darüber hinaus stellt sich bei der Anwendung von komplexen Systemmodellen die Frage nach der Präzision der Vorhersage. Es ist grundsätzlich unmöglich, alle Parameter und Annahmen, die die Modellergebnisse beeinflussen, mit beliebiger Genauigkeit zu bestimmen (DESER et al. 2012). Beispiele für solche unsicheren Parameter sind die Anfangsbedingungen der Simulation, deren Randbedingungen, die Parametrisierung der implementierten Prozesse (d.h. die exakten Werte von Parametern in den kodierten

Gleichungen), oder die Struktur der Prozesse selbst (SCHNEIDER/HELD 2002). Die Unsicherheit jeder dieser Komponenten trägt potenziell zu der Unsicherheit der Modellvorhersage bei. Die genaue Bestimmung der zusammengesetzten Unsicherheit erfordert aber aufgrund der komplexen Natur der eingesetzten Modelle zusätzliche Berechnungen.

Für Entscheidungen in Forschung und Politik ist die genaue Berechnung dieser Unsicherheiten aber von großer Bedeutung (MEARNS 2010). Hat eine Projektion eine kleine Unsicherheit, so ist es ausreichend bei Entscheidungen mit der mittleren Entwicklung, also dem Erwartungswert, zu rechnen. Hat die Projektion jedoch eine große Unsicherheit, so muss mit einer Reihe von möglichen Entwicklungen des Systems gerechnet werden. In diesem Fall wären Entscheidungen, die nur die mittlere Entwicklung bedenken, potenziell dramatisch falsch. Stellen Sie sich zum Beispiel vor, eine Projektion sagt einen mittleren Meeresspiegelanstieg um zwei Meter voraus, ohne die Angabe von Unsicherheiten. Aufgrund einer solchen Projektion würden dann z.B. Entscheidungsträger die Konstruktion von geeigneten Dämmen beschließen, z.B. in einer Höhe von 3 m. Wäre allerdings die Information vorhanden, dass die Unsicherheit der Projektion ± 2 m ist, so würde sich die Entscheidung über die notwendige Höhe der Dämme sicher deutlich verschieben.

Ziel dieses Artikels ist es, den Leser in das Problem der Unsicherheitsanalyse von komplexen Modellen einzuführen, und dieses insbesondere im Kontext der Abschätzung von Klimafolgen zu diskutieren. Wir erläutern hierzu zunächst die Definition von Risiko und Unsicherheit in der System- und Entscheidungstheorie, und führen den Leser danach in die wichtigsten Techniken zur Quantifizierung von Modellunsicherheiten ein. Diese Erklärungen werden im dritten Teil dieses Textes durch eine Fallstudie ergänzt, in der wir exemplarisch eine Berechnung der Vorhersageunsicherheit des Ökosystemmodell LPJ-GUESS für einen Standort in Franken diskutieren.

2 Definitionen von Unsicherheit

Bevor wir uns den Techniken der Unsicherheitsanalyse widmen, lohnt es sich zunächst den Begriff der Unsicherheit selbst noch etwas genauer zu erläutern. Grundsätzlich verstehen wir unter Unsicherheit das Phänomen, dass eine Zielgröße nicht genau bekannt ist, sondern mehrere mögliche Werte annehmen kann. Bei diesen möglichen Werten kann es sich um eine Reihe von kategorischen Möglichkeiten (z.B. rot, grün, blau) oder um ein kontinuierliches Spektrum handeln. Wenn Wahrscheinlichkeiten für die jeweiligen

Ergebnisse bekannt sind (siehe folgende Diskussion), so lässt sich die Unsicherheit durch diskrete oder kontinuierliche Wahrscheinlichkeitsverteilungen ausdrücken.

2.1 Gründe für Vorhersageunsicherheiten in Systemmodellen

Im Kontext dieses Artikels sind wir vor allem an der Unsicherheit von Modellvorhersagen interessiert. Eine Modellvorhersage basiert immer auf einer Reihe von Annahmen und numerischen Werten (z.B. Inputs, Parameter). Diese werden von dem Modellierer normalerweise gewählt, um die Realität möglichst genau (im Rahmen der notwendigen Vereinfachungen eines Modells) abzubilden.

Trotz aller Sorgfalt ist es in der Regel unmöglich, alle Modellannahmen exakt zu bestimmen. Messungen von physikalischen Parametern haben immer einen gewissen Fehler (z.B. RABINOVICH 2006). Annahmen über Prozesse in komplexen Systemen beinhalten notwendigerweise gewisse Vereinfachungen, die auch wieder zu Fehlern führen (EVANS et al. 2013). All diese Fehler oder Unsicherheiten tragen dazu bei, dass die Vorhersagen des Modells selbst mit einer gewissen Unsicherheit behaftet sind (z.B. MCKAY/MORRISON/UPTON 1999). Grundsätzlich kann jeder Aspekt der Modellierung, der die Vorhersagen oder Projektionen eines Modells beeinflusst, unsicher und somit ein Grund für Vorhersageunsicherheiten sein.

Eine Auflistung der Gründe ist deshalb praktisch identisch mit der Auflistung der wichtigsten Modellkomponenten. Diese sind: Anfangsbedingungen, Randbedingungen, Modellstruktur, Parameter und Kippunkte (LATIF 2011) (Tabelle 1). Unter Anfangsbedingungen versteht man den Anfangszustand des Modells, also den Zustand des Klima- oder Ökosystems zu Beginn der Simulation (z.B. COLLINS 2002). Unter Randbedingungen versteht man die Modellinputs (auch Treiber oder Forcings genannt) (COLLINS/ALLEN 2002). Für ein Klimamodell könnte das die ankommende Sonnenstrahlung und die anthropogenen CO₂ Emissionen sein, für ein Ökosystemmodell typischerweise das Klima/Wetter oder die derzeitige Landnutzung in einer Region. Die Modellstruktur bezeichnet im Allgemeinen alle strukturellen Entscheidungen im Modell, im engeren Sinn normalerweise die Struktur der implementierten Prozesse, also z.B. die Gleichungen oder Differentialgleichungen, die die zeitliche Entwicklung des Systems beschreiben. Parameter sind veränderbare Größen in der mathematischen Beschreibung des Systems. Für ein Ökosystemmodell ist dies z.B. die Langlebigkeit der Blätter eines Baumes.

Einen weiteren Beitrag zur strukturellen Unsicherheit leisten sogenannte Kippunkte. Diese sind kritische Werte, bei denen Änderungen über diesen Schwellenwert hinaus zu einer qualitative Änderung der Struktur des Systems führt (LENTON et al. 2008). In der Klimaforschung stellt z.B. das Abschmelzen des grönländischen Eisschildes einen solchen Kippunkt dar (BEVIS et al. 2019). Kippunkte und strukturelle Unsicherheiten sind eng mit parametrischen Unsicherheiten verknüpft.

2.2 Typisierungen von Unsicherheiten

Jeder der besprochen Modellkomponenten kann mehr oder weniger unsicher sein. Bezüglich der Stärke oder auch Tiefe der Unsicherheit werden in der Entscheidungstheorie oft drei Typen unterschieden: Risiko, Ungewissheit, und vollkommene Unsicherheit (MORGAN/HENRION/SMALL 1990) (siehe Abbildung 1).

Mit Risiko bezeichnen wir eine Situation, in der wir die Wahrscheinlichkeiten der möglichen zukünftigen Szenarien kennen. Als Beispiel: Stellen Sie sich vor, ein genetischer Test ergibt, dass Sie eine 1% Wahrscheinlichkeit haben, an grauem Star zu erkranken. Welches der beiden Szenarien eintritt können wir nicht mit Sicherheit vorhersagen (d.h. es gibt eine Vorhersageunsicherheit), aber die Wahrscheinlichkeiten der möglichen Szenarien sind bekannt, also sprechen wir hier von einem Erkrankungsrisiko.

Unter Ungewissheit verstehen wir die Situation, in der mögliche zukünftige Szenarien bekannt sind, aber nicht deren Wahrscheinlichkeit. Als Beispiel: Stellen Sie sich vor, Sie überlegen von einem Felsen ins Meer zu springen. Sie wissen nicht, ob das Wasser tief genug ist. Es gibt also 2 Szenarien: Sie stoßen am Grund an, oder nicht. Da Sie aber zum ersten Mal in dieser Region sind, können Sie den beiden Möglichkeiten keinerlei Wahrscheinlichkeiten zuordnen, d.h. Sie müssen sich unter Ungewissheit entscheiden.

Oft wird noch eine dritte Stufe der Unsicherheit aufgezählt, die sogenannte vollkommene/tiefe oder auch Knight'sche Unsicherheit (KNIGHT 1921). Hierunter verstehen wir Situationen, in denen nicht einmal alle möglichen Zukunftsszenarien bekannt sind. Der ehemalige Verteidigungsminister der Vereinigten Staaten Donald Rumsfeld hatte Ungewissheit und tiefe Unsicherheit in einem berühmt geworden Ausschnitt einer Pressekonferenz mit "known unknowns" (= Ungewissheit) und "unknown unknowns" (= tiefe Unsicherheit) bezeichnet (RUMSFELD/GEN MYERS 2002). Um das anschaulich zu machen, könnten wir das letzte Beispiel erweitern: Sie waren davon ausgegangen, dass Sie entweder auf den Grund aufkommen oder

im Wasser untertauchen. Sie könnten aber auch auf einen großen Fisch springen. Dieses Szenario hatten Sie in ihrer Unsicherheitsanalyse komplett übersehen.

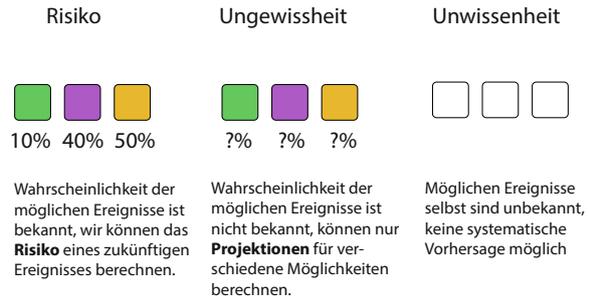


Abb. 1: Unsicherheiten können in verschiedenen Abstufungen auftreten. Die bekannteste Typisierung unterscheidet Risiko, Ungewissheit und Unwissenheit.

2.3 Wichtige Unsicherheiten in der Klimafolgenforschung

All die bisher besprochenen Gründe und Typen von Unsicherheiten sind relevant für die Klimafolgenforschung, aber nicht in gleichem Maße. Natürlich ist es schwer, exakte Zahlen für einen ganzen Forschungsbereich anzugeben, aber es lassen sich doch bestimmte Trends bezüglich des Typs und der Wichtigkeit der verschiedenen Unsicherheiten bestimmen.

Unsicherheit in den Anfangsbedingungen des Modells ist tendenziell vor allem dann wichtig, wenn die Vorhersagen kurzfristig, und deshalb stark von den Anfangsbedingungen beeinflusst sind, oder wenn es sich um sogenannte chaotische Systeme handelt. Dies ist z.B. bei Wettervorhersagen der Fall, wo die Anfangsbedingungen (d.h. die exakte Konfiguration der Wolken, Druckverteilungen etc.) der dominante Faktor für die Vorhersageunsicherheit sind. Man spricht hier auch manchmal von einem sogenannten Anfangswertproblem (engl. initial value problem) (COLLINS 2002).

Je weiter die Vorhersage in die Zukunft geht, desto stärker wird die Dynamik des Modells durch interne Prozesse und die Treiber (= Randbedingungen) des Systems bestimmt (z.B. WANG/POST/WILSON 2011). Da es in den Klimawissenschaften oft um langfristige Vorhersagen geht (d.h. z.B. für das Jahr 2100 oder länger), in denen die interne Dynamik die Entwicklung des Systems bestimmt, sind für die meisten Klimafolgeprojektionen Unsicherheiten im jetzigen Zustand des Erdsystems von geringerer Bedeutung als Unsicherheiten in den Treibern und Prozessen des Modells. Man spricht hier deshalb auch von einem Randwertproblem (engl: boundary value problem) (z.B. TEBALDI/ KNUTTI 2007).

Für Erdsystemmodelle wird die Unsicherheit der Treiber normalerweise noch einmal in zwei Komponenten aufgespalten: der Einfluss des Menschen, und die intrinsische Unsicherheit der Treiber (z.B. SCHURER et al. 2013). Der Einfluss des Menschen (insbesondere der anthropogene CO₂ Ausstoß) wird praktisch immer als Ungewissheit behandelt, d.h. es werden Szenarien gebildet, die aber nicht mit einer Wahrscheinlichkeit belegt werden. In wissenschaftlichen Veröffentlichungen und Berichten wie denen des Weltklimarats (Intergovernmental Panel on Climate Change, IPCC) wird diese Unsicherheit dann normalerweise so kommuniziert, dass Projektionen für alle möglichen Szenarien berechnet werden (IPCC 2014). Die zweite Unsicherheitsquelle besteht aus allen anderen Berechnungen, die zu den eigentlichen Treibern führen (z.B. werden oftmals die Treiber von Vegetationsmodellen durch Klimamodelle berechnet, und deren Unsicherheiten bzgl. der Klimaentwicklung können in einer Unsicherheitsanalyse als Wahrscheinlichkeitsverteilung behandelt werden). Soweit möglich werden in diesem Fall die Unsicherheiten als Wahrscheinlichkeiten weitergegeben (siehe folgende Diskussion) (MYHRE et al. 2013).

Der letzte große Komplex von Modellunsicherheiten ist die Unsicherheit der implementierten Prozesse und deren Parameter (z.B. KENNEDY/O'HAGAN 2001). Insbesondere in der Klimaforschung sind diese Unsicherheiten relativ schlecht untersucht, weil die langen Laufzeiten der großen Klimamodelle die Variation von Modellparametern und Annahmen erschwert. Darüber hinaus sind diejenigen wichtigen Prozesse, die zur Vorhersage des heutigen Klimas wichtig sind, nicht zwangsweise dieselben wie für zukünftiges Klima (QIAN et al. 2016). In früheren IPCC Berichten wurden deshalb die Modellunsicherheiten oft nur durch die Unterschiede der Projektionen der verschiedenen

Forschungsgruppen dargestellt (sogenannte "spaghetti graphs", siehe z.B. IPCC AR 4 Kapitel 8) (RANDALL et al. 2007), die in gewisser Weise strukturelle und parametrische Unsicherheiten gleichzeitig abhandeln. In den letzten Jahren wurde allerdings ein erheblicher Aufwand getrieben, um diese Unsicherheiten besser darzustellen. So wurde ab IPCC AR5 (FLATO et al. 2013) durch Parametervariationen (sogenannte Perturbationen) der beteiligten Modelle zum ersten Mal parametrische und strukturelle Unsicherheiten getrennt.

Als Resultat dieser Aktivitäten haben wir heute zum einen ein besseres Verständnis der Wichtigkeit verschiedener Unsicherheiten, zum anderen steht im Fall von gekoppelten Modellen (so z.B. bei Vegetationsmodellen, die von Klimamodellen getrieben werden) eine Abschätzung der Unsicherheit der Treiber bereit. Die Analyse von Unsicherheiten in Klima und Vegetationsmodellen in den IPCC Berichten zeigt dass die Vorhersageunsicherheit der Modelle zum Teil erheblich ist, und dass neben den Anfangsbedingungen auch alle verbleibenden Prozesse (Treiber, Parametrisierung, Modellstruktur) substantiell zu dieser Unsicherheit beitragen (FLATO et al. 2013). Insbesondere wenn Modelle eigentlich komplexe Prozesse stark vereinfachen hat sich die strukturelle Unsicherheit oft als ein bedeutender Faktor herausgestellt. So zeigen z.B. BUGMANN et al. (2019), dass die Vorhersagen von Vegetationsmodellen mit erheblicher Sensitivität auf Veränderungen der Mortalitätsfunktionen im Modell reagieren.

Ein weiteres wichtiges Thema im Kontext von Unsicherheit sind sogenannte Kippunkte (engl. tipping points) (CAI 2020). Kippunkte werden in der wegweisenden Arbeit von LENTON et al. 2008 als Prozesse definiert, bei denen eine geringfügige Überschreitung eines kritischen Wertes unweigerlich

Tab. 1: Gründe für Unsicherheiten und deren typischer Eigenschaften in Klimafolgeprojektionen

Typische Eigenschaften in Klimafolgeprojektionen				
Modellbereich	Typ	Unsicherheit	Sensitivität	Einfluss auf die Vorhersageunsicherheit
Anfangsbedingungen	Risiko	groß	klein	klein
Randbedingungen (auch: Treiber/Forcing)	CO ₂ : Ungewissheit			
Klimareaktion: Risiko	mittel	groß	groß	
Parametrische Unsicherheit	Risiko	groß	mittel	mittel
Strukturelle Unsicherheit	Risiko, Ungewissheit, Unwissenheit	mittel, ?	mittel, ?	mittel, ?

eine substantielle Veränderung des Systemzustands bewirkt. Ein wichtiger Kipppunkt im Klimasystem ist z.B. das Abschmelzen des grönländischen Eisschildes, welches durchschnittlich 3000 Meter hoch ist. Bei einer globalen Temperaturzunahme von 1,5–2 °C gibt es Jahreszeiten, in denen die Oberfläche des Eisschildes zu Schmelzen beginnt, wodurch sich dessen Höhe erniedrigt. Da die Lufttemperatur aber gleichzeitig mit der Höhe abnimmt, beschleunigt sich der Schmelzprozess von selbst und würde bei einem vollständigen Abschmelzen des Eisschildes zu einer Erhöhung des Meeresspiegels um 6 Meter führen. Der exakte kritische Wert für den Kipppunkt, und auch der Zeitraum, bis das komplette grönländische Eisschild geschmolzen ist, sind nicht bekannt, haben aber potenziell massive Auswirkungen auf das Klimasystem (LENTON et al. 2019).

Aus der Sicht der Unsicherheitsanalyse ist der wichtige Aspekt von Kipppunkten, dass diese durch eine stark nichtlineare Reaktion des Systems charakterisiert sind (THOMPSON/SIEBER 2012). Diese Nichtlinearität führt dazu, dass eine kleine Unsicherheit in den zeitlichen Eingangsgrößen (z.B. durch andere Unsicherheiten) oder in den Prozessen zu einer großen Unsicherheit bezüglich der Entwicklung der Kipppunkte führt. Kipppunkte potenzieren also die vorher beschriebenen Unsicherheiten.

3 Techniken der Unsicherheitsanalyse

Wie können Wissenschaftler die Vorhersageunsicherheit eines Modells bestimmen oder die Wichtigkeit verschiedener Modellkomponenten zur Vorhersageunsicherheit vergleichen? Hierzu verwendet man eine Reihe von Methoden, insbesondere die Sensitivitätsanalyse, die Unsicherheitsanalyse, und die Inversion von Modellen, die wir im Folgenden etwas genauer erklären.

3.1 Sensitivität

Ein Grundkonzept für die Analyse von Unsicherheiten ist die Modellsensitivität. Man sagt ein Modell ist sensitiv gegenüber einer Änderung der Modellannahmen (z.B. Anfangsbedingungen, Randbedingungen, Struktur, Parameter), wenn sich die Modellvorhersage bei einer solchen Änderung stark verändert (SALTELLI/TARANTOLA/CAMPOLONGO 2000). Mathematisch kann man das durch eine Ableitung oder Differenz schreiben:

$$S(a) = \frac{dM}{da} \text{ oder } \frac{DM}{Da}$$

Dabei berechnet man die Sensitivität $S(a)$ des Modeloutput M bezüglich des Parameter a aus dem Quotienten der Änderung in M (dM oder DM), welcher durch eine Änderung des Wertes von Parameter a (da oder DA) hervorgerufen wird. Hierbei unterscheidet man zwischen einer lokalen und globalen Sensitivitätsanalyse. Die Erstere betrachtet die Sensitivitäten in einem kleinen Bereich um die Referenzparametrisierung und verändert meist nur einen Parameter zur gleichen Zeit. Dadurch benötigt eine lokale Sensitivitätsanalyse weniger Modellevaluation und ist auch für Modelle mit langen Laufzeiten wie Klimamodelle umsetzbar (PIANOSI et al. 2016). Eine globale Sensitivitätsanalyse berechnet die Sensitivitäten im Raum aller plausiblen Parameterwerte und Inputs und benötigt dadurch auch mehr Modellevaluationen. Dadurch eignet sich diese Analyse für Modelle mit kürzerer Laufzeit wie etwa Vegetationsmodelle. So wurden z.B. globale Sensitivitätsanalysen von Vegetationsmodellen für die Schweiz (PAPPAS et al. 2013) oder sogar ganz Europa (HUBER/BUGMANN/LAFOND et al. 2018) durchgeführt. Der IPCC Bericht (FLATO et al. 2013) nennt die Änderungen der Modellannahmen ausgehend von den Standardparametern Störungen (engl. Perturbations), aber benutzt dieselbe Vorgehensweise.

3.2 Fehlerfortpflanzung und Unsicherheitsanalyse

Es ist wohl direkt einsichtig, dass bei einer stärkeren Modellsensitivität eine gewisse Unsicherheit in einem Modellinput auch zu einer stärkeren Unsicherheit in der Vorhersage führt. Ganz grob kann man sagen:

$$\text{Vorhersageunsicherheit} = \text{Unsicherheit} * \text{Sensitivität}$$

Man kann also aus bekannter Sensitivität den Einfluss einer Unsicherheit im Modell auf die Vorhersageunsicherheit grob abschätzen. Eine solche Abschätzung ist auch unter dem Begriff "Fehlerfortpflanzung" bekannt.

In der Praxis werden Modellunsicherheiten oft durch Verteilungen angegeben. Da Systemmodelle oft nichtlinear sind und damit Sensitivitäten nicht unbedingt konstant sind (und diese auch interagieren können), ist die Rechnung Vorhersageunsicherheit = Unsicherheit * Sensitivität in den meisten Fällen zu stark vereinfacht.

Die gebräuchlichste Lösung für die Berechnung von Vorhersageunsicherheiten aus den Unsicherheiten der einzelnen Modellkomponenten ist die sogenannte Monte-Carlo Methode (HELTON 1994). Diese besteht darin, zufällig aus allen hier genannten Unsicherheitskomponenten zu ziehen, die Vorhersagen durch das Modell mit den jeweiligen Realisierungen vorwärts zu propagieren, und so eine Verteilung der

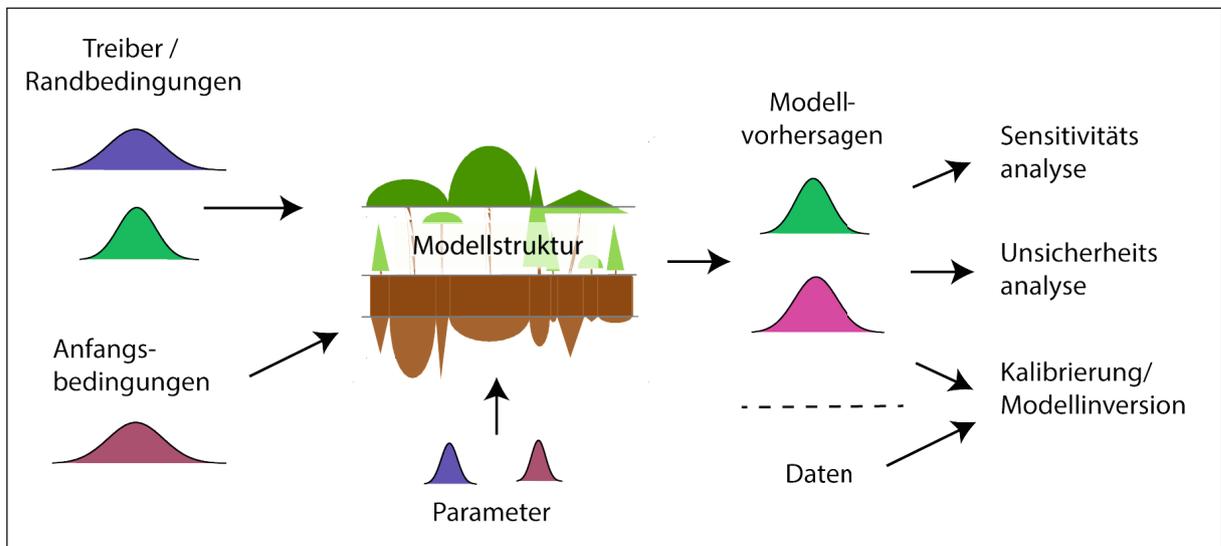


Abb. 2: Unsicherheitsanalyse über eine Monte-Carlo Fehlerfortpflanzung. Neben der direkten Interpretation der Vorhersageunsicherheit können die Ergebnisse der Monte-Carlo Fehlerfortpflanzung auch genutzt werden um den Beitrag der verschiedenen Modellkomponenten zur Vorhersageunsicherheit (Unsicherheitsanalyse) oder deren Sensitivität (Sensitivitätsanalyse) zu bestimmen, oder die möglichen Modellentwicklungen mit Daten zu vergleichen, und so die Modellunsicherheiten zu reduzieren (Modellinversion).

Vorhersageunsicherheit zu generieren (Abbildung 2) (siehe auch HELTON/DAVIS 2003). Die Methode kann auch angewandt werden, wenn die Wahrscheinlichkeit für bestimmte Unsicherheiten nicht bekannt ist. In diesem Fall spalten sich auch die Vorhersagen in bestimmte Szenarien/Projektionen auf.

3.3 Modellinversion und Kalibrierung

Die Unsicherheitsanalyse propagiert die Unsicherheiten der Inputs und Komponenten eines Modells auf dessen Outputs. Wenn man Beobachtungsdaten für diese Outputs hat, kann man diesen Prozess auch umkehren, um über die Daten die Unsicherheiten im Modell zu reduzieren. Man spricht hierbei von einer Modellinversion, oder einer sogenannten inversen Modellierung (z.B. HARTIG et al. 2012).

Das Ziel der inversen Modellierung besteht darin, aus Informationen über die beobachteten Outputs auf die plausiblen Wertebereiche der Komponenten oder Inputs eines Modells zu schließen und so deren Unsicherheit zu reduzieren. Man kann sich die Inversion auch als einen Filter vorstellen: die Unsicherheit bzgl. eines bestimmten Parameters gibt den *möglichen* Wertebereich für diesen vor. Durch das Abgleichen der hieraus generierten Modellvorhersagen mit beobachteten Daten können wir hieraus den *wahrscheinlichen* Parameterbereich bestimmen, indem wir die Parameterwerte verwerfen, die keine mit den Daten übereinstimmenden Outputs generieren.

In der Praxis werden verschiedene Methoden benutzt, um Modelle zu invertieren. Für die Reduzierung von Unsicherheit in den Parametern (= Kalibrierung) werden insbesondere Optimierungs- oder sogenannte Markov-Chain Monte-Carlo Algorithmen benutzt (z.B. NADAL-SALA et al. 2019, TROTSIUK et al. 2020). Ihnen allen gleich ist aber die Eigenschaft, den möglichen Raum der Modellparameter abzusuchen, und den Bereich zu finden, der am besten zu den Beobachtungsdaten passt.

4 Fallstudie – Unsicherheiten in dem Ökosystemmodell LPJ-GUESS an einem Standort in Franken

Um die besprochenen Konzepte zu veranschaulichen, präsentieren wir eine Fallstudie, in der wir exemplarisch die Vorhersageunsicherheit des Ökosystemmodells LPJ-GUESS für einen Standort in Franken untersuchen.

4.1 LPJ-GUESS

LPJ-GUESS (SMITH et al. 2014) ist ein dynamisches Systemmodell für das terrestrische Vegetations-Ökosystem. Es simuliert die Entwicklung der Vegetation global oder in einer bestimmten Region, und kann dazu benutzt werden sowohl Vegetationsstruktur als auch -zusammensetzung unter zukünftigen Klimabedingungen

zu untersuchen. Eine Beschreibung der Modellprozesse findet sich in SMITH et al. (2014), oder in KRAUSE/PAPASTEFANO/RAMMIG (2020) in diesem Heft.

Die Treiber (Randbedingungen) des Modells sind primär die regionalen Klimabedingungen und die atmosphärische CO₂ Konzentration. Darüber hinaus hat LPJ-GUESS auch die Möglichkeit weitere Randbedingungen wie das Management der Vegetation (LINDESKOG et al. 2013), also z.B. die Bewirtschaftung des Waldes in die Projektion mit einzubeziehen. Für die Simulation muss man dem Modell als Parameter für jede einzelne Baumart, die es simuliert, spezifische Werte für z.B. Dürretoleranz oder Langlebigkeit der Blätter zuweisen.

Ein Modelllauf beginnt mit einem sogenannten Spin-up, d.h. einem Zeitraum, in dem die Zustandsgrößen des Modells in ein Gleichgewicht konvergieren können. Nach diesem Spin-up wächst die Vegetation von einem Kahlschlag aus entstehend. Die Anfangsbedingungen sind deshalb die Zustandsvariablen zum Zeitpunkt nach dem Kahlschlag (z.B. wie viel Kohlenstoff im Boden ist). Mit diesen Inputs kann LPJ-GUESS unter anderem die Vegetationsstruktur, Biomasse, Blattflächenindex, Kohlenstoffspeicher aber auch Evapotranspiration berechnen.

4.2 Material und Methodenbeschreibung

Wir benutzen das Vegetationsmodell LPJ-GUESS und simulieren für eine 0.5°x0.5° Gitterzelle (49.5°–50.0° Nord, 11.0°–11.5° Ost) in Franken das natürliche Wachstum der Stieleiche *Quercus robur* (entstehend von einem Kahlschlag im Jahre 1550 und einem vorhergehenden Spin Up von 300 Jahren), welche außer im hochalpinen Raum in ganz Bayern vorkommt.

Als unsicher behandeln wir die gängigsten Modellparameter, die die Entwicklung der Stieleiche beeinflussen können. Dazu gehören Umweltpassungsparameter wie z.B. Stickstofffixierung, Wasserhaushalt, Konkurrenz und Demographieparameter (wie z.B. Parameter, die die Allometrie des Baumes beschreiben), Photosyntheseparameter (wie z.B. den Temperaturbereich, in dem Photosynthese bestmöglich funktioniert) und bioklimatische Limits wie die minimale Temperatur, die noch Wachstum zulässt. Da die genauen Unsicherheiten dieser Parameter nicht bekannt sind, nehmen wir als plausible Bereiche jeweils $\pm 10\%$ des Standardwertes im Modell an.

Um die Unsicherheiten in den Parametern auf die Modellvorhersagen zu projizieren, benutzen wir eine Monte Carlo Simulation mit 1000 Parameterkombinationen.

Um bewerten zu können, ob der Klimawandel die Sensitivitäten verschiebt, vergleichen wir die relativen Parametersensitivitäten (d.h. den prozentualen Anteil

eines Parameters an der Gesamtsensitivität) für vorindustrielles Klima (1850–1950) und heutiges Klima (1950–2010) für die jährlich produzierte überirdische Kohlenstoffmasse (Biomasse inkl. Blätter, jedoch ohne Bodenkohlenstoff) und Blattflächenindex (den Quotienten aus Blattfläche und Bodenoberfläche). Diese beiden Kenngrößen dienen als Indikatoren für Kohlenstoffspeicherung und deshalb betrachten wir die Sensitivität der gewichteten Summe von jährlich produzierter überirdischer Kohlenstoffmasse und Blattflächenindex.

Für die Berechnung der Sensitivitäten benutzen wir ein sogenanntes Morris-Screening (MORRIS 1991), welches im gesamten möglichen Parameterraum lokale Parametervariationen vornimmt und die Sensitivitäten (bzw. Unsicherheiten) dann durch Mittelwert und Standardabweichung zusammenfasst. Als Ergebnis erhält man die gemittelte Sensitivität eines Parameters über den ganzen Bereich und dessen Standardabweichung, welche die Interaktionen mit anderen Parametern beschreibt.

4.3 Ergebnisse

Die Unsicherheiten von jährlich produzierter überirdische Kohlenstoffmasse sind zu Beginn der Simulation, also in der Wachstumsphase, am kleinsten, da dort andere Parameterkombinationen noch nicht zu so großen Schwankungen in der Kohlenstoffproduktion führen können (Abbildung 3). Daraufhin nehmen sie zwar zu, sind aber zwischen 1850 und 1950, also 300 bis 400 Jahre nach Beginn der Simulation, nicht signifikant größer als im heutigen Klima (Abbildung 3). Die Unsicherheiten für heutiges Klima sind jedoch nicht mehr so symmetrisch um die Vorhersage verteilt. So sind z.B. im heutigen Klima Abweichungen, die zu geringerer Kohlenstoffproduktion führen, deutlich plausibler als Abweichungen, die zu höherer Kohlenstoffproduktion führen. Des Weiteren sehen wir im Vergleich mit der atmosphärischen CO₂ Kurve einen starken Anstieg der Biomasse durch steigendes CO₂. Die Unsicherheiten in dieser Fallstudie sind recht groß, da einerseits die Parameterunsicherheit als groß angenommen wurde und andererseits nur eine Gitterzelle betrachtet wurde. Durch Vergleiche mit Daten oder eine genauere Literaturrecherche bzgl. der Parameter könnten die Unsicherheiten nun noch reduziert werden.

Um die Sensitivitäten in den Zeiträumen von 1850–1950 und 1950–2010 vergleichen zu können, berechnen wir die relativen Effekte, sodass die Summe aller Effektgrößen eins ergibt. Der Vergleich zeigt, dass das Wachstum der Stieleiche in beiden Simulationsperioden besonders auf Konkurrenz und

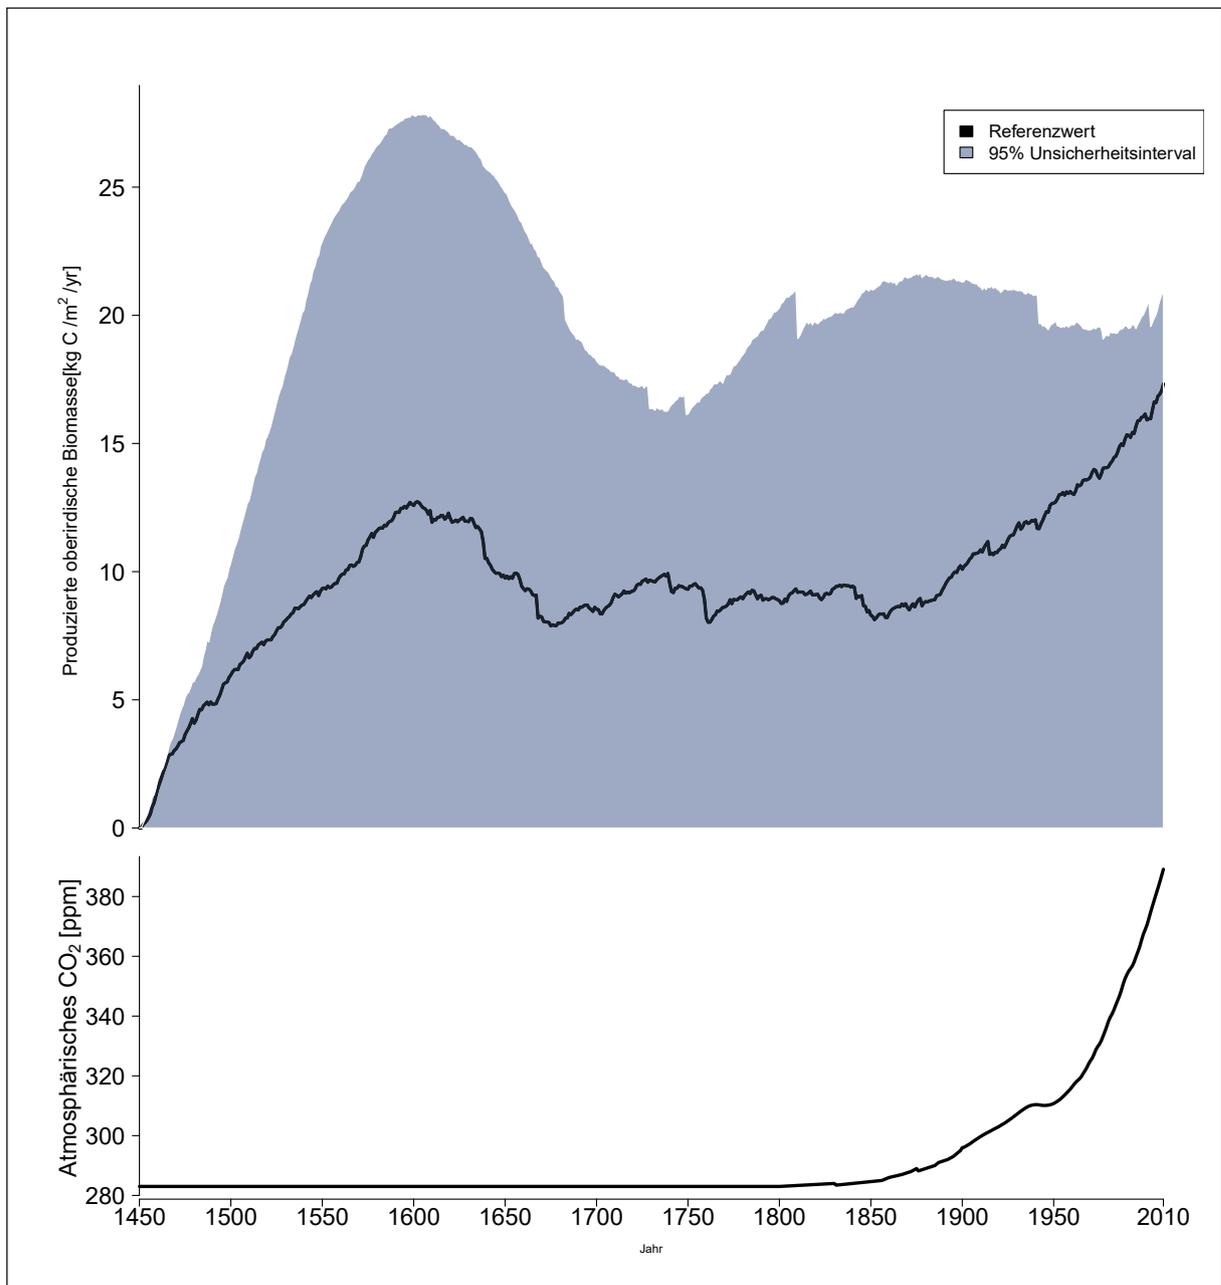


Abb. 3: Gezeigt ist eine Unsicherheitsprojektion der jährlich produzierten überirdischen Kohlenstoffmasse der Stieleiche. Die Referenzdaten (rot) befinden sich immer in den 95% Kreditäritätsintervall (hellblau). In der zweiten Abbildung sieht man, dass die Erhöhung des atmosphärischen CO₂ Gehalts auch zu einer Erhöhung der produzierten Kohlenstoffmasse führt.

Demographieparameter sensitiv ist (Abbildung 4). Die drei größten Beiträge kommen von turnover_{sap} (Splintholz-Umsatzrate), k_{latosa} (Verhältnis Baumblatt zu Splintholz x Fläche) und k_{allom2} (relative Zuwachsrate von Baumzuwachs zu Baumgröße), aber auch Photosynthese Parameter wie respcoeff (Verhältnis des produzierten Kohlendioxids zum verbrauchten Sauerstoff) haben einen großen Einfluss (Abbildung 4). Während in vorindustriellen

Umweltbedingungen vorrangig Demographieparameter eine entscheidende Rolle gespielt haben, nimmt die relative Sensitivität von Photosyntheseparametern in heutigen Umweltbedingungen zu (alle Parameter dieser Gruppe liegen oberhalb der Diagonale) (Abbildung 4). Darüber hinaus reagiert das Wachstum der Stieleiche unter heutigen Klimabedingungen auch auf deutlich mehr Parameter sensitiver als noch im vorindustriellen Klima (Abbildung 4).

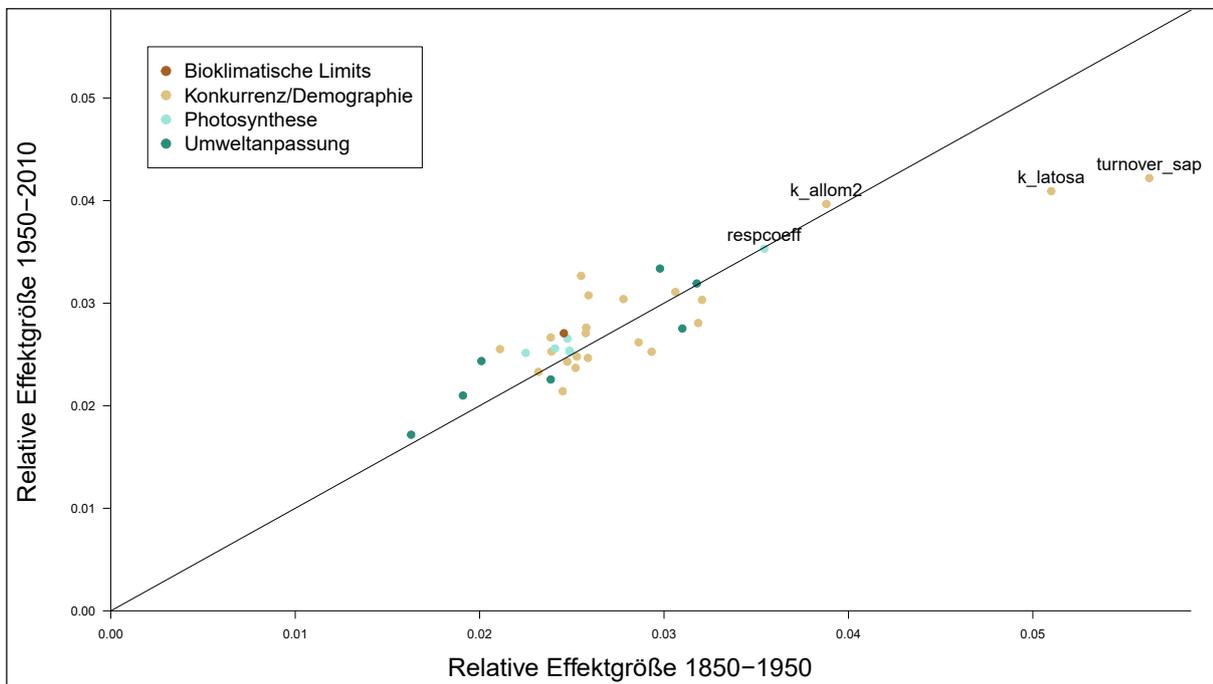


Abb. 4: Gezeigt sind die relativen Effektgrößen für die Jahre 1850–1950 (x-Achse) und 1950–2010 (y-Achse) für *Quercus robur* auf einer Simulationsfläche in Franken. Die Parameter sind nach ihrer Zugehörigkeit im Modell in die Gruppen Bioklimatische Limits (dunkelbraun), Konkurrenz und Demographie (hellbraun), Photosynthese (hellgrün) und Umweltanpassung Parameter (dunkelgrün) zugeordnet. In beiden Perioden ist die Stieleiche auf unserer Simulationsfläche besonders sensitiv auf Parameter der Konkurrenz und Demographie. Durch die veränderten Umweltbedingungen in der Periode von 1950–2010 verteilt sich die Sensitivität jedoch auf mehrere Parameter.

5 Zusammenfassung und Ausblick

Wir haben in diesem Artikel eine Einführung in die Berechnung von Vorhersageunsicherheiten von Systemmodellen gegeben. Die hier vorgestellten Techniken sind generell anwendbar, aber von besonderer Relevanz im Kontext des Klimawandels. Um die Unsicherheiten möglicher Klimaszenarien besser einschätzen zu können, ist es trotz der hohen Laufzeit sinnvoll, eine Modellinversion durchzuführen und statistische Verfahren zum Umgang mit Extremwerten anzuwenden (KATZ et al. 2013).

5.1 Kommunikation von Unsicherheit

In diesem Artikel haben wir hauptsächlich die technischen Aspekte von Unsicherheiten beleuchtet. Jedoch spielt auch die Kommunikation von Unsicherheiten eine wichtige Rolle. Der IPCC hat hierzu einen Leitfaden zur einheitlichen Kommunikation von Unsicherheiten entwickelt (MASTRANDREA et al. 2010). Trotz all dieser Vorsicht ist die Kommunikation von Unsicherheiten gegenüber der Öffentlichkeit immer noch eine Herausforderung (STERMAN 2011). So wird Unsicherheit oft mit fehlenden wissenschaftlichen

Erkenntnissen verwechselt (FUNTOWICZ/RAVETZ 1990). Oft ist es auch so, dass Menschen mathematisch äquivalente Darstellungen von Unsicherheiten unterschiedlich interpretieren. So stellten z.B. Psychologen fest, dass die meisten Menschen eine Unsicherheit bezüglich des Zeitpunktes einer Bedrohung als deutlich schlimmer wahrnehmen als die Unsicherheit bezüglich des Ausmaßes (LEWANDOWSKY/BALLARD/PANCOST et al. 2015). Darüber hinaus nehmen große Teile der Öffentlichkeit den Begriff Risiko bedrohlicher als den Begriff der Unsicherheit wahr (CORNER et al. 2015). Deshalb sollte die Politik und Wissenschaft im Zuge des Klimawandels einen besonderen Augenmerk auf die Kommunikation von Unsicherheiten legen.

5.2 Ausblick

Obwohl die Bedeutung des Themas Unsicherheit für die Klimafolgenabschätzung schon lange anerkannt ist, stellt die praktische Umsetzung Wissenschaftler und Entscheidungsträger immer noch vor Herausforderungen.

Auf der wissenschaftlichen Seite schlägt hier zum einen die Komplexität der benutzten Modelle und die damit verbundene Komplexität von Sensitivitäts- und

Unsicherheitsanalysen und Modellinversionen zu Buche. Ein weiteres Problem ist, dass entscheidende Unsicherheiten (insbesondere in Struktur oder Kippunkten) oft schwer probabilistisch zu quantifizieren sind, was die weitere Auswertung schwierig macht. Auf der Seite der Entscheidungsträger ergeben sich weitere Herausforderungen, die mit der Kommunikation und Interpretation von Unsicherheiten, insbesondere in einem demokratischen Prozess, verbunden sind.

Danksagung

JO, AR und FH wurden im Rahmen des BLIZ Projektes durch das Bayerische Staatsministerium für Wissenschaft und Kunst im Rahmen des Bayerischen Klimaforschungsnetzwerks (bayklif) gefördert. Des Weiteren möchten wir uns noch bei Andreas Krause und Sven Rubanschki für hilfreiche Kommentare bedanken.

Literatur

- BEVIS, M. et al. 2019: Accelerating changes in ice mass within Greenland, and the ice sheet's sensitivity to atmospheric forcing. In: *Proc. Natl. Acad. Sci.* 116: 1934–1939.
- BRAY, D.; VON STORCH, H. 2009: "Prediction" or "Projection"? The Nomenclature of Climate Science. In: *Sci. Commun.* 30, 534–543.
- BUGMANN, H. et al. 2019: Tree mortality submodels drive simulated long-term forest dynamics: assessing 15 models from the stand to global scale. In: *Ecosphere* 10, e02616.
- CAI, Y. 2020: The Role of Uncertainty in Controlling Climate Change. *ArXiv200301615 Econ Q-Fin*.
- COLLINS, M. 2002: Climate predictability on interannual to decadal time scales: the initial value problem. In: *Clim. Dyn.* 19: 671–692.
- COLLINS, M.; ALLEN, M.R. 2002: Assessing the Relative Roles of Initial and Boundary Conditions in Interannual to Decadal Climate Predictability. In: *J. Clim.* 15: 3104–3109.
- CORNER, A. et al. 2015: *The Uncertainty Handbook*. Bristol: University of Bristol.
- DESER, C. et al. 2012. Uncertainty in climate change projections: the role of internal variability. In: *Clim. Dyn.* 38: 527–546.
- EVANS, M.R. et al. 2013: Do simple models lead to generality in ecology? In: *Trends Ecol. Evol.* 28: 578–583.
- FLATO, G. et al. 2013: Evaluation of Climate Models. In: *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [STOCKER, T.F. et al. (Hg.)]. Camb. Univ. Press.
- FUNTOWICZ, S.O.; RAVETZ, J.R. 1990: Uncertainty and Quality in Science for Policy. Springer Science & Business Media.
- HARTIG, F. 2017: Simulation Modeling. *Oxf. Bibliogr.*
- HARTIG, F. et al. 2012: Connecting dynamic vegetation models to data – an inverse perspective. In: *J. Biogeogr.* 39: 2240–2252.
- HELD, I. 2014: Simplicity amid Complexity. In: *Science* 343: 1206–1207.
- HELTON, J.C. 1994: Treatment of Uncertainty in Performance Assessments for Complex Systems. In: *Risk Anal.* 14: 483–511.
- HELTON, J.C.; DAVIS, F.J. 2003: Latin hypercube sampling and the propagation of uncertainty in analyses of complex systems. In: *Reliab. Eng. Syst. Saf.* 81: 23–69.
- HUBER, N.; BUGMANN, H.; LAFOND, V. 2018: Global sensitivity analysis of a dynamic vegetation model: Model sensitivity depends on successional time, climate and competitive interactions. In: *Ecol. Model.* 368: 377–390.
- IPCC 2014. 2014: *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Core Writing Team, R.K. Pachauri and L.A. Meyer (Hg.)]. IPCC, Geneva, Switzerland, 151 pp.
- KATZ, R.W. et al. 2013: Uncertainty analysis in climate change assessments. In: *Nat. Clim. Change* 3: 769–771.
- KENNEDY, M.C.; O'HAGAN, A. 2001: Bayesian calibration of computer models. In: *J. R. Stat. Soc. Ser. B Stat. Methodol.* 63: 425–464.
- KNIGHT, F.H. 1921: Risk, Uncertainty and Profit (SSRN Scholarly Paper No. ID 1496192). Social Science Research Network, Rochester, NY.
- KRAUSE, A.; PAPAŞTEFANOU, P.; RAMMIG, A. 2020: Wie werden häufigere Störungsereignisse die Kohlenstoffspeicherung und Vermeidung durch Ökosysteme in Bayern beeinflussen? – eine Abschätzung mit einem dynamischen Vegetationsmodell. *Fränk. Geogr. Ges.*
- LATIF, M. 2011: Uncertainty in climate change projections. In: *J. Geochem. Explor., Sustainability of Geochemical Cycling* 110: 1–7.
- LENTON, T.M. et al. 2008: Tipping elements in the Earth's climate system. In: *Proc. Natl. Acad. Sci.* 105: 1786–1793.
- LEWANDOWSKY, S.; BALLARD, T.; PANCOST, R.D. 2015: Uncertainty as knowledge. *Philos. Trans. R. Soc. Math. Phys. Eng. Sci.* 373: 20140462.
- LINDESKOG, M. et al. 2013: Implications of accounting for land use in simulations of ecosystem carbon cycling in Africa. In: *Earth Syst. Dyn.* 4: 385–407.
- MASTRANDREA, M.D. et al. 2010: Guidance Note for Lead Authors of the IPCC Fifth Assessment Report on Consistent Treatment of Uncertainties. Intergov. Panel Clim. Change IPCC.
- MCKAY, M.D.; MORRISON, J.D.; UPTON, S.C. 1999: Evaluating prediction uncertainty in simulation models. In: *Comput. Phys. Commun.* 117: 44–51.
- MEARNS, L.O. 2010: Quantification of Uncertainties of Future Climate Change: Challenges and Applications. In: *Philos. Sci.* 77: 998–1011.
- MORGAN, M.G.; HENRION, M.; SMALL, M. 1990: *Uncertainty: A Guide to Dealing with Uncertainty in Quantitative Risk and Policy Analysis*. Cambridge University Press.
- MORRIS, M.D. 1991: Factorial Sampling Plans for Preliminary Computational Experiments. In: *Technometrics* 33: 161–174.
- MOSS, R.H. et al. 2010: The next generation of scenarios for climate change research and assessment. In: *Nature* 463: 747–756.
- MYHRE, G. et al. 2013: Anthropogenic and Natural Radiative Forcing. *Camb. Univ. Press, Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [STOCKER, T.F. et al. (Hg.)]: 82.
- NADAL-SALA, D., et al. 2019: Global warming likely to enhance black locust (*Robinia pseudoacacia* L.) growth in a Mediterranean riparian forest. In: *For. Ecol. Manag.* 449: 117448.

- O'NEILL, B.C. 2004: Conditional Probabilistic Population Projections: An Application to Climate Change. In: *Int. Stat. Rev.* 72: 167–184.
- O'NEILL, B.C. et al. 2014: A new scenario framework for climate change research: the concept of shared socioeconomic pathways. In: *Clim. Change* 122: 387–400.
- ORESQUES, N.; SHRADER-FRECHETTE, K.; BELITZ, K. 1994: Verification, Validation, and Confirmation of Numerical Models in the Earth Sciences. In: *Science* 263: 641–646.
- PAPPAS, C. et al. 2013: Sensitivity analysis of a process-based ecosystem model: Pinpointing parameterization and structural issues. In: *J. Geophys. Res. Biogeosciences* 118: 505–528.
- PIANOSI, F. et al. 2016: Sensitivity analysis of environmental models: A systematic review with practical workflow. In: *Environ. Model. Softw.* 79: 214–232.
- QIAN, Y. et al. 2016: Uncertainty Quantification in Climate Modeling and Projection. In: *Bull. Am. Meteorol. Soc.* 97: 821–824.
- RABINOVICH, S.G. 2006: *Measurement Errors and Uncertainties: Theory and Practice*. Springer Science & Business Media.
- RANDALL, D.A. et al. 2007: Climate Models and Their Evaluation. In: *Climate Change 2007: The Physical Science Basis*. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [SOLOMON, S. et al. (Hg.)]. Camb. Univ. Press 74.
- RUMSFELD, D.; GEN MYERS, R. 2002: Defense.gov Transcript: DoD News Briefing – Secretary Rumsfeld and Gen. Myers. Online: <https://archive.defense.gov/Transcripts/Transcript.aspx?TranscriptID=2636>, (11.05.2020).
- SALTELLI, A.; TARANTOLA, S.; CAMPOLONGO, F. 2000: Sensitivity Analysis as an Ingredient of Modeling. In: *Stat. Sci.* 15: 377–395.
- SCHNEIDER, T.; HELD, H. 2002: Uncertainty Propagation in Earth System Models. In: *AGU Fall Meet. Abstr.* 61, A61C-0091.
- SCHURER, A.P. et al. 2013: Separating Forced from Chaotic Climate Variability over the Past Millennium. In: *J. Clim.* 26: 6954–6973.
- SMITH, B. et al. 2014: Implications of incorporating N cycling and N limitations on primary production in an individual-based dynamic vegetation model. *Biogeosciences* 11: 2027–2054.
- STERMAN, J.D. 2011: Communicating climate change risks in a skeptical world. In: *Clim. Change* 108: 811.
- TEBALDI, C.; KNUTTI, R. 2007: The use of the multi-model ensemble in probabilistic climate projections. In: *Philos. Trans. R. Soc. Math. Phys. Eng. Sci.* 365: 2053–2075.
- THOMPSON, J.M.T.; SIEBER, J. 2012: Climate predictions: the influence of nonlinearity and randomness. In: *Philos. Trans. R. Soc. Math. Phys. Eng. Sci.* 370: 1007–1011.
- TROTSIUK, V. et al. 2020: Assessing the response of forest productivity to climate extremes in Switzerland using model–data fusion. *Glob. Change Biol.* 26: 2463–2476.
- WANG, D.; POST, W.; WILSON, B. 2011: Climate Change Modeling: Computational Opportunities and Challenges. In: *Comput. Sci. Eng.* 13: 36–42.

Abstract: Model uncertainties in climate impact projections – a primer

To estimate the consequences of climate change, climate researchers regularly generate model predictions based on an emission scenario, so-called climate impact projections. Such model projections are subject to uncertainties resulting from the uncertainties of the individual model components (e.g. drivers, parameters or structure). The quantification of these uncertainties is essential for the interpretation of the projections by research, decision makers and the public. This article provides an introduction to calculating model uncertainties in the context of climate impact projections. We first discuss the reasons for and types of model uncertainties, and then explain how to quantify them (=uncertainty analysis) and how to reduce them by reconciliation comparison with observational data (=model inversion). We illustrate the discussed concepts with a case study, in which we perform an uncertainty analysis of the terrestrial ecosystem model LPJ-GUESS for a site in Franconia.

Keywords: uncertainty analysis, sensitivity analysis, climate impact projections

Autor*innen: Johannes Oberpriller, johannes.oberpriller@ur.de, Forschungsgruppe für Theoretische Ökologie der Universität Regensburg; Prof. Dr. Almut Arneth, Professur für Atmosphäre-Ökosystem Interaktionen am Karlsruher Institut für Technologie; Dr. Christine Herschlein, Karlsruher Institut für Technologie; Prof. Dr. Anja Rammig, TUM School of Life Sciences, Technische Universität München; Prof. Dr. Florian Hartig, Forschungsgruppe für Theoretische Ökologie der Universität Regensburg.

