



Doctoral Thesis

Case studies in estimation and representation of uncertainty in climate modelling

Author(s):

Tomassini, Lorenzo Franco

Publication Date:

2007

Permanent Link:

<https://doi.org/10.3929/ethz-a-005463784> →

Rights / License:

[In Copyright - Non-Commercial Use Permitted](#) →

This page was generated automatically upon download from the [ETH Zurich Research Collection](#). For more information please consult the [Terms of use](#).

Diss. ETH No. 17109

Case studies in estimation and representation of uncertainty in climate modelling

A dissertation submitted to the
SWISS FEDERAL INSTITUTE OF TECHNOLOGY
ZURICH

for the degree of
DOKTOR DER WISSENSCHAFTEN

presented by
LORENZO FRANCO TOMASSINI
Dipl. Math. ETH
born 23.11.69 in Basel
citizen of Switzerland and Italy

accepted on the recommendation of
Prof. Peter Reichert, examiner
Prof. Hans-Rudolf Künsch, co-examiner
Prof. Thomas F. Stocker, co-examiner
Prof. Mark E. Borsuk, co-examiner

2007

Kurzfassung

Das erste Kapitel enthält eine Bayessche Unsicherheitsanalyse von 12 Parametern des Bern2.5D Klimamodells. Dies umfasst eine ausführliche Untersuchung zur Sensitivität bezüglich der statistischen Annahmen. Besondere Aufmerksamkeit wird dem Parameter Klimasensitivität S gewidmet. Wir definieren eine nicht-parametrische Menge von Verteilungen für S . Mit Hilfe von Bayes Theorem wird die daraus resultierende Menge der a posteriori Verteilungen bestimmt. Die obere und untere Wahrscheinlichkeit, dass S grösser ist als $4.5\text{ }^{\circ}\text{C}$, wird berechnet. Zudem schätzen wir a posteriori Verteilungen unter verschiedenen Annahmen an die Likelihood Funktion. Die wichtigsten Eigenschaften der Randverteilungen für die Klimasensitivität erweisen sich dabei als ziemlich robust bezüglich statistischen Annahmen an den Beobachtungsfehler und die Klimavariabilität. Der Einfluss von a priori Annahmen haben aber einen beträchtlichen Einfluss auf die Schwänze der Verteilungen. Es zeigt sich auch, dass die Daten zur Änderung des Wärmeinhalts des Ozeans während der letzten Jahre massgeblich zur Einschränkung der Verteilung von S beitragen.

Im zweiten Kapitel werden probabilistische Klimaprojektionen mit dem Bern2.5D Klimamodell durchgeführt. Als Grundlage dienen zwei SRES Szenarien, ein IMAGE Referenzszenario und fünf IMAGE Stabilisierungsszenarien. Alle Szenarien sind Multi-Gas Szenarien. Die (Menge von) Wahrscheinlichkeitsverteilungen aus Kapitel 1 werden dazu durch das Modell propagiert. Die Abhängigkeit der Resultate von a priori Annahmen wird untersucht. Obere und untere Wahrscheinlichkeiten für den Temperaturzuwachs im Jahr 2100 werden für die verschiedenen Szenarien berechnet. A priori Annahmen haben eine geringe Bedeutung für die Temperaturprojektionen in der ersten Hälfte des Jahrhunderts, werden aber für spätere Zeitpunkte wichtig. Wir gehen einen Schritt weiter und leiten Verteilungen für den Schaden des Temperaturzuwachses her. Dieser Schaden hängt allerdings sehr stark von den ökonomischen Annahmen und dem gewählten Skontosatz ab.

Wenn für die Schätzung von Unsicherheiten vereinfachte Modelle verwendet werden, dann sind oft grundlegende statistische Annahmen nicht erfüllt. Im dritten Kapitel wird ein Algorithmus vorgeschlagen, der es erlaubt, zeitabhängige stochastische Parameter und ihre Unsicherheiten zu schätzen. Durch die Einführung der Zeitabhängigkeit können statistische Annahmen besser erfüllt werden. Der Algorithmus ist

ein Markov-chain-Monte-Carlo Algorithmus mit einigen besonderen Anpassungen. Das Zeitintervall wird in Teilintervalle aufgeteilt. Auf jedem Teilintervall wird ein bedingter Ornstein-Uhlenbeck Prozess mit festen Endpunkten als Parameterprozess vorgeschlagen. Die Hyperparameter des stochastischen Prozesses werden durch ein Kreuzvalidierungsverfahren ausgewählt. Der Algorithmus wird anhand eines einfachen Klimamodells getestet, dem ein zusätzlicher stochastischer Forcingterm hinzugefügt wurde. Die Resultate zeigen, dass der Algorithmus schnell konvergiert und die Übereinstimmung zwischen Modell und Daten verbessert. Das zusätzliche stochastische Forcing beeinflusst allerdings die Schätzung der anderen, konstanten Parameter beträchtlich. Ein Modellstrukturdefizit konnte als Ursache für dieses Verhalten identifiziert werden.

Im kurzen vierten Kapitel geht es um eine Wahrscheinlichkeitsverteilung für die transiente Klimaänderung (transient climate response TCR). Eine solche Verteilung, die durch Beobachtungen eingeschränkt ist, wird berechnet aufgrund der Resultate des ersten Kapitels. Der Zusammenhang zwischen TCR und der Änderung im Wärmehalt des Ozeans wird im Rahmen einer Sensitivitätsanalyse untersucht. Die Resultate legen nahe, dass selbst wenn Modelle die Aufnahme von Wärme durch den Ozean überschätzen, die nötigen Korrekturen in den Oberflächentemperaturprojektionen nicht sehr gross sind im Vergleich mit den Unsicherheiten in atmosphärischen Rückkopplungsprozessen.

Abstract

In Chapter 1 a Bayesian uncertainty analysis of 12 parameters of the Bern2.5D climate model is presented. This includes an extensive sensitivity study with respect to the major statistical assumptions. Special attention is given to the parameter representing climate sensitivity. Using the framework of robust Bayesian analysis, we first define a non-parametric set of prior distributions for climate sensitivity S and then update the entire set according to Bayes' theorem. The upper and lower probability that S lies above 4.5 °C is calculated over the resulting set of posterior distributions. Furthermore, posterior distributions under different assumptions on the likelihood function are computed. We find that the main characteristics of the marginal posterior distributions of climate sensitivity are quite robust with regard to statistical models of climate variability and observational error. However, the influence of prior assumptions on the tails of distributions are substantial considering the important political implications. Moreover, we find that ocean heat change data have a considerable potential to constrain climate sensitivity.

Chapter 2 contains probabilistic climate projections based on two SRES scenarios, an IMAGE reference scenario and five IMAGE mitigation scenarios (all of them multi-gas scenarios) using the Bern2.5D climate model. To this end the (sets of) probability distributions of climate model parameters that were derived in Chapter 1 are fed in the climate model. The sensitivity of the resulting distributions with respect to prior assumptions on the parameter climate sensitivity are assessed. Upper and lower probabilities for temperature increase in the year 2100 are calculated for the different scenarios. While prior assumptions on climate sensitivity play a minor role in the case of temperature projections for the first half of the 21st century, these assumptions have a considerable influence on the distributions of the projected temperature increase in the year 2100. Going one step further, we also calculate probability distributions of damage costs for the different scenarios assuming a wide range of damage cost functions. Also the sensitivity of these distributions with respect to the assumed discount rate is investigated. Absolute values of damage costs depend heavily on the chosen damage cost function and discount rate. Nevertheless our analysis allows for putting into context various figures that are published in the literature.

In estimating uncertainties using climate models of reduced complexity systematic

discrepancies between model simulations and measured data are often encountered. In Chapter 3 we propose to make selected parameters in the model time-variant by modeling them as continuous-time stochastic processes. We present an algorithm for Bayesian estimation of such parameters that includes some special adaptations of the Markov chain Monte Carlo method. The algorithm consists of splitting the overall time period into subintervals, over each of which we use a conditional Ornstein-Uhlenbeck process with fixed endpoints as the proposal distribution in a Metropolis-Hastings algorithm. The hyperparameters of the stochastic process are then selected using a cross-validation criterion which maximizes a pseudo-likelihood value, for which we have derived a computationally efficient estimator. We tested our algorithm using a simple climate model in which an additional stochastic forcing component is introduced. The results show that the algorithm behaves well, is computationally tractable, and improves model fit to the data. The additional forcing term was found to strongly alter the posterior density of the other, time-constant parameters. By a careful analysis of the results, we are able to identify a structural deficit of the simple climate model as the cause of this unexpected behavior.

In Chapter 4 a Bayesian framework and the Bern2.5D climate model are used to calculate a probability density function of the transient climate response (TCR), constrained by observations of surface warming and ocean heat uptake. The TCR range of current climate models agrees well with the PDF constrained by observations. Uncertainties in the observed ocean warming are shown to potentially affect the TCR. It is proposed, however, that even if models were found to overestimate ocean heat uptake, correcting that bias would lead to revisions in surface temperature projections over the twenty-first century that are relatively small compared to uncertainties caused by atmospheric feedbacks.