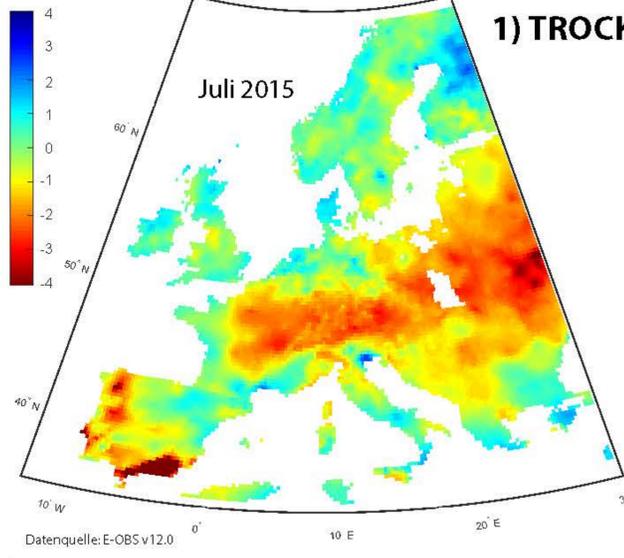


S. Bachmair, I. Kohn, V. Blauhut, A. Herber, K. Stahl

Einleitung und Zielstellung

Das Jahr 2015 war durch ausgeprägte Trockenheit in Teilen Europas gekennzeichnet und verdeutlichte erneut die Vulnerabilität Deutschlands gegenüber Trockenheit. Diese Studie gibt einen Überblick über die hydro-meteorologische Situation im Jahr 2015 und ökologische und sozio-ökonomische Auswirkungen von Trockenheit in Deutschland. Um rechtzeitig Maßnahmen

zu ergreifen, sind Frühwarnsysteme für Trockenheit unabdingbar. Gleichzeitig lassen gängige hydro-meteorologische Trockenheitsindikatoren nur indirekt Rückschlüsse auf negative Auswirkungen zu. Das Ziel ist deshalb, Trockenheitsindikatoren mit berichteten Auswirkungen durch Trockenheit zu verknüpfen. So können kritische Indikatorwerte abgeleitet und das Auftreten von Auswirkungen mithilfe von statistischen Modellen berechnet werden.



1) TROCKENHEITSINDIKATOREN



Die Europakarte zeigt den Standardized Precipitation Index für einen Akkumulationszeitraum von 3 Monaten (SPEI-3). Die untenstehenden Karten geben einen Überblick über den Verlauf der Trockenheit 2015. Die Einschätzung der hydro-meteorologischen Situation variiert je nach betrachtetem Indikator.

2) AUSWIRKUNGEN VON TROCKENHEIT = IMPACTS

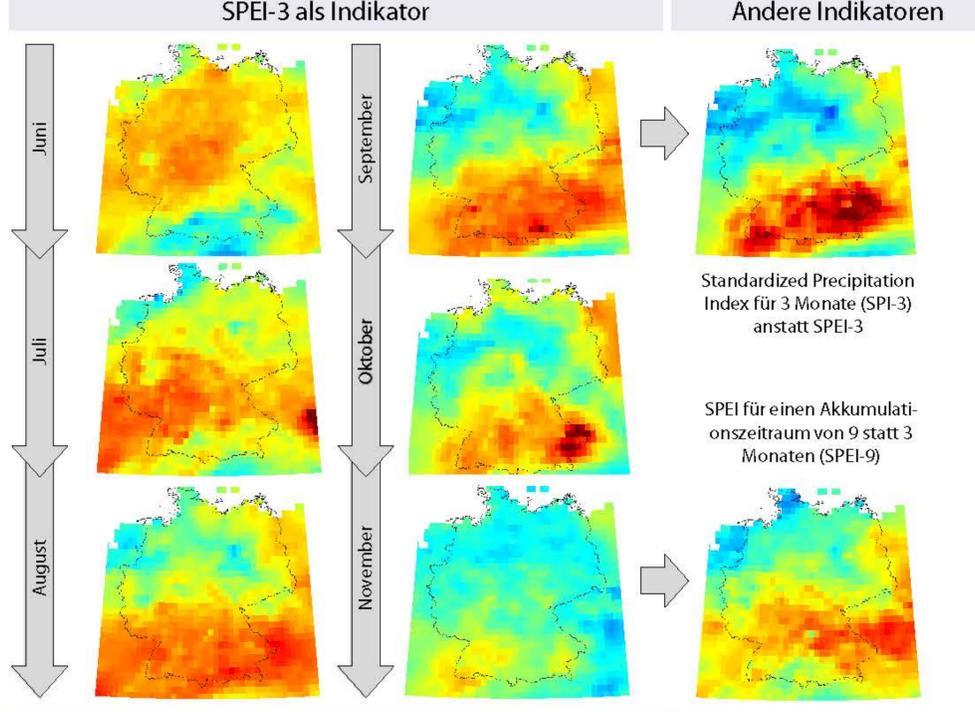
European Drought Impact report Inventory (EDII)

www.geo.uio.no/edc/droughtdb

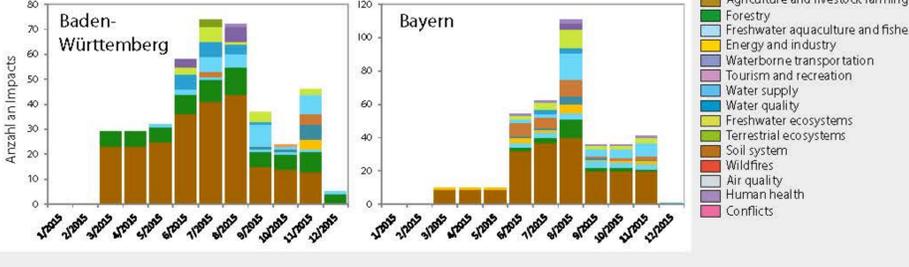


Die Informationen in der EDII Datenbank über aufgetretene Impacts stammen aus verschiedenen Quellen (z.B. wissenschaftlichen Publikationen, Berichten oder Zeitungsartikeln). Sie sind kategorisiert nach Auswirkung auf verschiedene Sektoren und zeitlich und räumlich verortet.

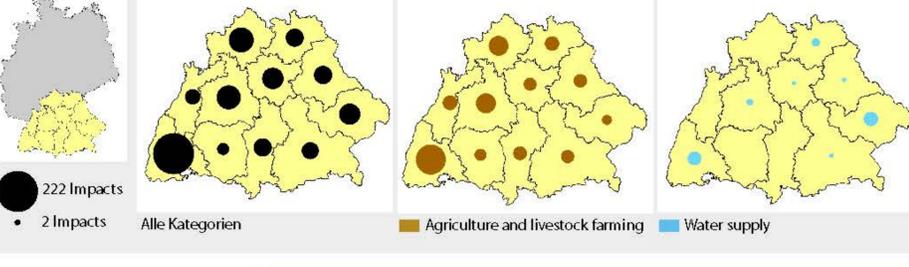
Die Information zu Auswirkungen von Trockenheit und die Quantifizierung dieser ist mit Unsicherheiten behaftet. Dies ist die zentrale Herausforderung bei der Verknüpfung von Indikatoren mit Impacts.



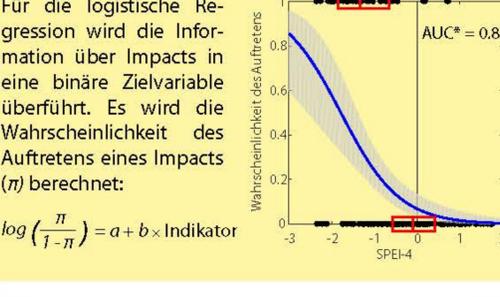
2015: Zeitliches Auftreten der Impacts und Aufteilung nach Kategorien



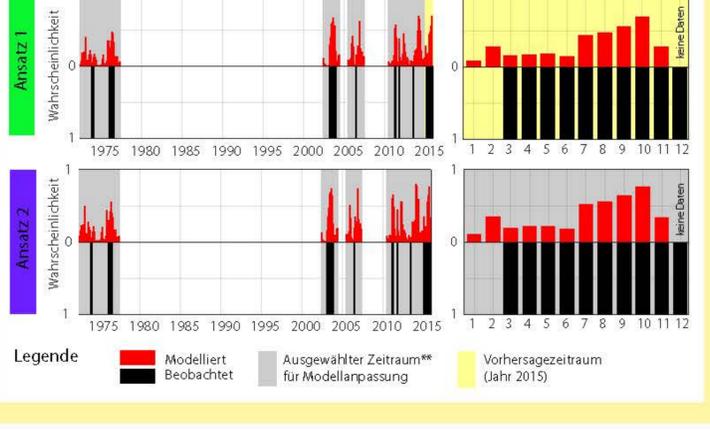
2015: Räumliche Verteilung der Impacts in Süddeutschland je Regierungsbezirk



Logistische Regression



Die Abbildung zeigt das nach Ansatz 1 angepasste Modell. Es basiert auf SPEI-4. Mittels Stepwise-Verfahren und Korrelation wurde SPEI-4 als bester Prädiktor ermittelt.

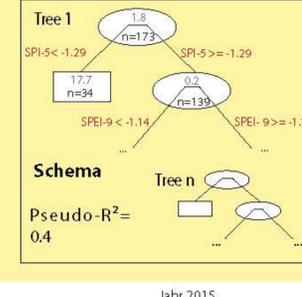


Verknüpfung

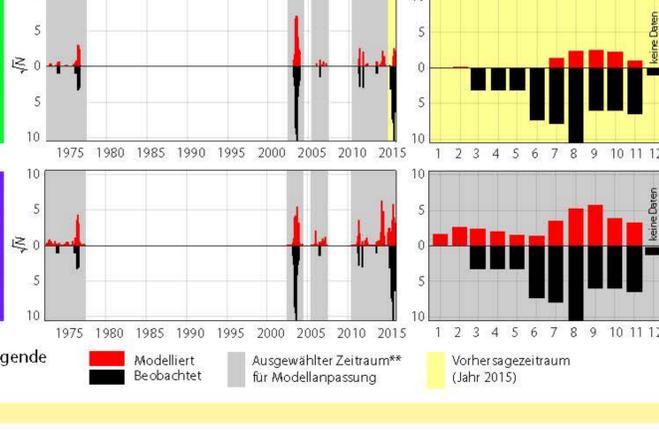
Am Beispiel Bayerns
Es werden je Modell zwei Ansätze verfolgt:
Ansatz 1: Modellanpassung für ausgewählten Zeitraum und Vorhersage für 2015
Ansatz 2: leave-one-out Kreuzvalidierung für ausgewählten Zeitraum inklusive 2015

Ensemble regression trees ("RandomForest")

RandomForest ist ein Verfahren des maschinellen Lernens, das aus mehreren unkorrelierten Entscheidungsbäumen besteht (Breiman, 2001). Die Zielvariable ist die wurzeltransformierte Anzahl an Impacts (\sqrt{n}). Folgende Prädiktoren gehen in das Modell ein: SPEI-1:6,-9,-12, SPEI-1:6,-9,-12, Monat und Jahr des Auftretens. Die wichtigsten Prädiktoren sind SPEI-5 und SPEI-5.



| Logistische Regression | RandomForest |
|--|---|
| Die mit Ansatz 1 modellierte Wahrscheinlichkeit des Auftretens von Impacts für 2015 wird deutlich unterschätzt. Lediglich im September und Oktober liegt die Wahrscheinlichkeit > 0.5. Mit Ansatz 2 sind die modellierten Wahrscheinlichkeiten etwas höher. Der Unterschied zwischen Ansatz 1 und 2 ist nur geringfügig. | Die mit Ansatz 1 modellierte Anzahl an Impacts für 2015 wird deutlich unterschätzt. Eine größere Anzahl an Impacts tritt zwischen Juli und November auf. Mit Ansatz 2 werden die Dynamik der Impacts und die Anzahl deutlich besser getroffen. Die Unterschiede zwischen beiden Ansätzen verdeutlichen den starken Einfluss des Trainingsdatensatzes. |
| Die Überführung der Impactinformation in eine binäre Zielvariable gegenüber der Anzahl an Impacts ist mit weniger Unsicherheiten behaftet. | Die Anzahl an Impacts kann als Schwere der Auswirkungen interpretiert werden und hat mehr Aussagekraft als binäre Information. |
| Die Aussagekraft der binären Information und der modellierten Wahrscheinlichkeiten ist geringer als bei der Anzahl an Impacts und schwieriger zu bewerten. | Für die Vorhersage von unbekanntem Trockenheitsereignissen mit neuen Mustern ist datenbasiertes maschinelles Lernen weniger robust. |



Schlussfolgerungen

Das Niederschlagsdefizit und erhöhte Temperaturen im Jahr 2015 riefen vielerorts negative Auswirkungen hervor. Die statistische Modellierung des Auftretens von Impacts für 2015 zeigt die Komplexität der Arbeit mit berichteten Impact-Daten. Mögliche Erklärungen für Abwei-

chungen sind eine veränderte Berichterstattung für 2015 gegenüber dem Trainingsdatensatz oder andere Muster des Trockenheitsverlaufs. Nichtsdestotrotz verdeutlicht unsere Analyse, dass die Einbeziehung von Impacts ein wichtiger zusätzlicher Baustein für Frühwarnsysteme ist. Dies unterstreicht die Relevanz, Informationen über Trockenheitsauswirkungen zukünftig zu erheben und zu archivieren.