

Schlussbericht:

DAM Schutz und Nutzen – CoastalFutures: Zukunftsszenarien zur Förderung einer nachhaltigen Nutzung mariner Räume

Vorhaben: UHH-ExtreMari - Klimabedingte Extremereignisse und ihre Auswirkungen auf das marine Ökosystem

Förderkennzeichen: 03F0911E

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 03F0911E gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung

Schlussbericht: CoastalFutures, UHH - ExtreMari

Zuwendungsempfänger: Universität Hamburg Institut für Meereskunde Bundesstr. 53 20146 Hamburg	Förderkennzeichen: 03F0911E
---	--------------------------------

Vorhabenbezeichnung:
DAM Schutz und Nutzen – CoastalFutures: Zukunftsszenarien zur Förderung einer nachhaltigen Nutzung mariner Räume;
Vorhaben: ExtreMari - Klimabedingte Extremereignisse und ihre Auswirkungen auf das marine Ökosystem

Projektleiter: PD Dr. Thomas Pohlmann¹
Mitarbeiter: Dr. Johannes Becherer¹
¹) Universität Hamburg, Institut für Meereskunde

Berichtsperiode: Gesamtlaufzeit des Vorhabens:
01.12.2021 – 30.11.2024

Autor:

Thomas Pohlmann, Universität Hamburg, Institut für Meereskunde

I. Kurzdarstellung

I.1. Aufgabenstellung

Im Teilprojekt ExtreMari sollte das Verständnis von Auswirkungen des globalen Klimawandels auf regionale Extremereignisse in der Nord- und Ostsee bzw. dem angrenzenden Nordwest-Europäischen Schelf verbessert werden. Effekte des Klimawandels in der Atmosphäre und im Ozean können das Risiko von regionalen und lokalen Extremereignissen potentiell erhöhen. Starkwindereignisse, Sturmfluten und insbesondere marine Hitzewellen stellen für marine Lebensräume bereits unter heutigen klimatischen Bedingungen eine erhebliche Belastung dar. Basierend auf Modellergebnissen von hochaufgelösten Klimaprojektionen für das 21. Jahrhundert sollten sowohl Antriebsmechanismen und dominierende Variabilitätsmoden dieser Ereignisse als auch mögliche zukünftige Änderungen in der Dynamik damit verbundener Wetterverhältnisse identifiziert werden.

Das spezifische Ziel des Projektes war die Entwicklung eines Modellsystems, das die realistische hochfrequente Variabilität (auf täglicher Zeitskala) der Oberflächentemperatur (SST) aus niederfrequenten (monatlichen) Daten eines globalen Klimamodells (GCM) zurückgewinnen kann. Dafür wurde ein KI-Modell trainiert, um die hochfrequente SST-Variabilität auf Grundlage bestimmter niederfrequenter Eingabeparameter vorherzusagen. Das Training erfolgte mit auf Beobachtungen basierenden Daten (ERA5). Nach dem Training wurde die KI-Komponente in ein Hybridmodell integriert. In diesem Hybridmodell wurden die niederfrequenten Eingabeparameter für das KI-Modul aus Daten von GCM-Simulationen

bereitgestellt. Abschließend wurden die niederfrequenten SST-Informationen des GCM mit der Vorhersage des KI-Modells kombiniert, um eine hochfrequente SST-Zeitreihe zu erzeugen.

Mit diesem Modellsystem ließen sich sowohl projizierte Klimaänderungssignale als Ursache von anthropogenen Treibhausgasemissionen als auch die natürliche Variabilität des dynamischen Systems über eine große Bandbreite räumlicher wie zeitlicher Skalen analysieren (regional bis großskalig, interannual bis multidekadisch). Im Speziellen konnten Extremwertstatistiken für alle relevanten Parameter abgeleitet werden, die zur Beschreibung von marinen Hitzewellen verwendet werden. Auf diese Weise können die Ergebnisse auch dazu dienen, Hypothesen über zukünftige klimabedingte Änderungen zu testen.

I.2. Voraussetzungen

Satellitengestützte Beobachtungen der Oberflächentemperatur (SST) sind detailliert und Ihrer Natur nach, ein direktes Abbild aller physikalischer Prozesse, die die SST beeinflussen können. Die beobachteten Prozesse finden auf allen räumlichen und zeitlichen Skalen statt, weshalb ihre Reproduktion in globalen Klimamodellen schwierig bis unmöglich ist. Dies gilt im Besonderen für kleinskalige Prozesse, die aufgrund der groben Auflösung und mangelnder Parametrisierung in den Klimamodellen oft nicht berücksichtigt werden können. In diesem Punkt sind Beobachtungsdaten und dementsprechende Reanalyse-Produkte klar im Vorteil gegenüber globalen Klimasimulationen.

Der große Vorteil der Klimasimulationen ist demgegenüber der sehr große Umfang von verfügbaren Daten und vor allem die Möglichkeiten, alternative, sowie vergangene und zukünftige Klimabedingungen zu simulieren. Hierbei spielt eine Rolle, dass zuverlässige satellitengestützte Beobachtung erst seit circa vier Dekaden existieren, was oft zu kurz ist, um statistisch belastbare Aussagen über die langfristige Veränderung von Extremereignissen treffen zu können. Ensemble-Simulationen von globalen Klimamodellen sind hier ein ausgezeichnetes Werkzeug, da sie aufgrund Ihres sehr großen Datenumfangs eine klare Trennung von zufälligen und klimabedingten Veränderungen sowie eine robuste Extremwertstatistik erlauben.

I.3. Planung und Ablauf des Vorhabens

Zur Untersuchung mariner Hitzewellen auf Basis von Klimasimulationen haben wir eigens ein hybrides Modellsystem entwickelt, das eine KI-Komponente mit Simulationsdaten eines herkömmlichen globalen Klimamodells kombiniert. Die KI-Komponente wurde mit Reanalyse-Daten (ERA5) trainiert, die auf Beobachtungen basieren. Die Grundidee ist, dass man die Vorteile von Beobachtung (realistisches Abbild aller in der Natur vorkommenden physikalischen Prozesse) und globalen Klimasimulationen (umfangreiche Ensemble-Simulationen der Vergangenheit und Zukunft) zusammenführt, um auf diese Weise die Vorteile beider Ansätze zu kombinieren.

Mit dem Hybrid-Modell haben wir einen komplett neuen Modellansatz entwickelt, der großes Potential auch über die hier bearbeitete Aufgabenstellung hinaus bietet. Alle nötigen Programmskripte, das austrainierte Modell selbst und eine ausführliche Dokumentation wurden vollumfänglich öffentlich gemacht (https://github.com/jbecherer/MHW_hybrid_model). Unsere Hoffnung ist, dass im Sinne des Open-Source-Gedankens andere Arbeitsgruppen auf unsere Pionierarbeit aufbauen können und den Ansatz weiterentwickeln, auch in Bezug auf andere Fragestellungen. Hierbei ist es auch von großem Vorteil, dass alle zugrunde liegenden Daten frei zugänglich und im Internet verfügbar sind.

Für unser Projektvorhaben birgt das Hybridmodell einige entscheidende Vorteile. Durch die Modularität des Hybridmodells waren wir in der Lage, diverse verschiedene globale Klimamodelldaten zu verwenden, also auch auf die die aktuellsten SSP-Klimaszenarien zurückzugreifen, was die Hoffnung birgt, dass unsere hier gewonnenen Ergebnisse länger aktuell bleiben. Außerdem war es uns möglich, verschiedene Klimamodelle miteinander zu vergleichen, auch wenn wir uns letztlich bei unserer detaillierten Analyse nur für ein Klimamodell (MPIESM1.2-LR) entschieden haben.

I.4. Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

Die Forschung zu marinen Extremereignissen und insbesondere von marinen Hitzewellen sowie deren Einfluss auf das marine Ökosystem hat in den letzten Jahren große Fortschritte gemacht. Für das Gebiet der Nord- und Ostsee allerdings beschränken sich einschlägige Studien hauptsächlich auf die statistische Analyse von Sturmfluten in verschiedenen Küstenregionen (Woth et al., 2006; Weisse et al., 2012; Lang et al., 2019).

Marine Hitzewellen sind Perioden, in denen die Wassertemperatur im Ozean über mehrere Wochen hinweg einen kritischen Wert übersteigt. Derartige Temperatur-Anomalien können verheerende Folgen für marine Ökosysteme haben und sind häufig mit Beeinträchtigungen oder sogar Verlusten der ökologischen Integrität und den damit zusammenhängenden Serviceleistungen verbunden (Hoegh-Guldberg et al., 2018; Di Biagio et al. 2020; Sen Gupta et al., 2020). Die teilweise folgenschweren Auswirkungen auf die Populationsdynamik von ökologisch wichtigen Arten, einschließlich des lokalen Aussterbens, sowie die Umstrukturierung ganzer mariner Lebensräume und entsprechender Einbrüche von Fangquoten der Fischereiindustrie ist jedoch nur sehr lückenhaft verstanden. Das liegt unter anderem daran, dass Extremereignisse naturgemäß relativ selten auftreten und gleichermaßen schwer vorhersagbar sind. Die Ergebnisse von statistischen Untersuchungen sind daher oft erheblich von der Wahl der statistischen Methode beeinflusst, insbesondere von der an die Daten angepassten Extremwertverteilung (Arns et al., 2013; Lang et al., 2020).

Es ist allgemein bekannt, dass aktuelle globale Klimamodelle die hochfrequente Variabilität der Meeresoberflächentemperatur (SST) nicht adäquat wiedergeben. Dies liegt sowohl an ihrer groben räumlichen Auflösung als auch an der unzureichenden Darstellung relevanter Prozesse, was erhebliche Konsequenzen für die aus GCM-Daten abgeleiteten Statistiken mariner Hitzewellen (MHWs) hat (Pilo et al, 2019; Oliver et al, 2021).

I.5. Wesentliche Projektergebnisse und Zusammenarbeit mit anderen Stellen

Ein wesentliches Projektergebnis ist das entwickelte neuartige Hybridmodell. Das Modell wurde öffentlich zugänglich gemacht und kann von anderen Gruppen und Organisationen genutzt werden (https://github.com/jbecherer/MHW_hybrid_model). Außerdem haben wir das Modell verwendet, um eine Analyse der vergangenen und zukünftigen Entwicklungen mariner Hitzewellen auf dem Nordwest-Europäischen Schelf, inklusive der Nordsee, durchzuführen. Die Ergebnisse dieser Analyse wurden in einem wissenschaftlichen Artikel zusammengefasst, der aktuell zur Begutachtung in der Zeitschrift "Climate Dynamics" eingereicht wurde (Becherer und Pohlmann, 2025).

Durch die Verwendung monatlich gemittelter GCM-Daten als Eingabe konnten wir demonstrieren, dass das Hybridmodell MHW-Statistiken erzeugt, die besser mit ERA5-Reanalysedaten übereinstimmen als solche, die aus täglichen SST-Daten desselben GCM abgeleitet wurden. Insbesondere das bekannte Problem, dass GCMs die Dauer von MHWs

tendenziell überschätzen und deren Häufigkeit unterschätzen (Pilo et al, 2019), wird mit dem Hybridmodell nahezu vollständig behoben.

In einer ersten Anwendung nutzen wir das Hybridmodell, um die zeitliche Entwicklung der MHW-Statistiken auf dem Nordwest-Europäischen Schelf (NWES) unter verschiedenen Klimaszenarien zu analysieren. Wir stellen fest, dass sich die aktuellen Klimabedingungen bereits erheblich von denen der vorindustriellen Zeit unterscheiden, mit etwa zehnmal mehr Hitzewellentagen und fünfmal mehr Hitzewellenereignissen, die im Durchschnitt doppelt so lange dauern. In Bezug auf die Dauer ereignen sich Ereignisse mit einer 900-jährigen Wiederkehrperiode in vorindustrieller Zeit im aktuellen Klima bereits alle 10 Jahre und werden unter dem SSP5-8.5-Szenario in der Zukunft voraussichtlich 2-jährige Ereignisse werden.

Die mittlere Intensität von MHW-Ereignissen zeigt zwischen den verschiedenen Zeiträumen keine signifikanten Veränderungen, während die Spitzenintensität ansteigt und weitgehend dem allgemeinen Klimatrend der SST folgt. Jedoch scheint die Spitzenintensität von Ereignissen mit Wiederkehrperioden von 100 Jahren und darüber schneller zuzunehmen als der mittlere SST-Trend, was auf sehr komplexe Prozesse hinweist, die für die extremsten Ereignissen mitverantwortlich sind.

Die Statistiken zu marinen Hitzewellen (MHWs) erreichen in der Zukunft einen Sättigungszustand, in dem die meisten Tage des Jahres als MHW-Tage eingestuft werden. Diese Sättigung führt zu dem kontraintuitiven Ergebnis, dass die Ereignishäufigkeit in der Zukunft gegenüber ihrem Höchstwert in der Gegenwart voraussichtlich abnehmen wird. Die durchschnittliche Dauer von MHW-Ereignissen nimmt jedoch in der Zukunft weiterhin zu.

Im Rahmen unseres Teilprojektes haben wir gezeigt, dass es möglich ist, realistische hochfrequente (tägliche) SST-Verläufe aus niederfrequenten (monatlichen) Informationen mithilfe von maschinellem Lernen zu erzeugen. Ausgehend von dieser Erkenntnis haben wir ein neuartiges Hybridmodell entwickelt, das die statistische Repräsentation hochfrequenter SST beeinflussender Prozesse in GCM-Daten verbessert. Das Hybridmodell integriert eine Machine Learning (ML)-Komponente, die mit ERA5-Reanalysedaten trainiert wird, um hochfrequente SST-Variabilität auf Basis niederfrequenter GCM-Eingaben zu erzeugen.

Außerdem haben wir die Simulationsergebnisse unserer regionalen Ensemble-Klimasimulation so aufbereitet, dass sie unseren Projektpartnern (Darios Fiorentino, Anna Akimova, Ismael Nunez-Riboni) vom Thünen-Institut zur Verfügung gestellt werden konnten. Dort wurden unsere Simulationsdaten für den Antrieb verschiedener biologischer Modelle verwendet. Die gemeinsamen Daten wurden veröffentlicht und sind frei verfügbar (<https://doi.pangaea.de/10.1594/PANGAEA.969374>).

Des Weiteren wurden unsere aufbereiteten Daten auch von Nadya Ramirez Martinez von der Stiftung Tierärztliche Hochschule Hannover (ITAW) für die Untersuchung klimabedingter Veränderungen in der Verbreitung und Dichte von Schweinswalpopulationen verwendet.

II. Eingehende Darstellung der Projektergebnisse

1. Wissenschaftliche Ergebnisse

1.1. Motivationen und technische Ausrichtung

Im Teilprojekt ExtreMari wurde ein neuartiges Hybridmodell entwickelt, um die statistische Darstellung hochfrequenter Prozesse, insbesondere der Meeresoberflächentemperatur (SST), in globalen Klimamodellen (GCMs) zu verbessern (Becherer und Pohlmann, 2025). Das Ziel war es, robustere Statistiken mariner Hitzewellen (MHW) zu generieren, um klimabedingte Änderungen des MHWs vorhersagen zu können. Dieses Modell kombiniert traditionelle GCM-Daten mit maschinellem Lernen (ML), um realistische, hochfrequente SST-Variabilität zu erzeugen. Die Ergebnisse zeigen, dass das Hybridmodell in der Lage ist, die bekannten Schwächen von GCMs bei der Vorhersage von MHW zu überwinden, indem es genauere Statistiken zu Dauer, Frequenz und Spitzenintensität von MHWs liefert. Insbesondere wird das bekannte Problem von Klimamodellen der Überschätzung der MHW-Dauer und der Unterschätzung der Ereignisfrequenz nahezu vollständig behoben.

Eine erste Anwendung des Modells auf den Nordwest-Europäischen Schelf (NWES) zeigt, dass die aktuellen Klimabedingungen bereits deutlich von denen der vorindustriellen Zeit abweichen und dass extreme MHW-Ereignisse in Zukunft noch häufiger und intensiver werden.

Obwohl das Modell einige Einschränkungen aufweist, wie den Verlust der physikalischen Konsistenz mit anderen hochfrequenten Variablen und die Erzeugung räumlich dekohärenter SST-Zeitreihen, bietet es dennoch einen vielversprechenden Ansatz zur Verbesserung der Vorhersage von Extremereignissen und anderer Prozessen, die realistische Statistiken spezifischer Größen erfordern.

Das eigens für ExtreMari entwickelte hybride Modellsystem, kombiniert eine KI-Komponente mit Simulationsdaten eines herkömmlichen globalen Klimamodells. Die KI-Komponente wird mit Reanalyse-Daten (ERA5) trainiert, die auf Beobachtungen basieren. Die Grundidee ist, dass man die Vorteile von Beobachtung (realistisches Abbild aller in der Natur vorkommenden physikalischen Prozesse) und globalen Klimasimulationen (umfangreiche Ensemble-Simulationen der Vergangenheit und Zukunft) zusammenführt, um die Stärken beider Ansätze zu kombinieren.

Satellitengestützte Beobachtung der Oberflächentemperatur (SST) sind detailliert und Ihrer Natur nach, ein direktes Abbild aller physikalischer Prozesse, die die SST beeinflussen können. Diese Prozesse finden auf allen räumlichen und zeitlichen Skalen statt, weshalb ihre Reproduktion in globalen Klimamodellen schwierig bis unmöglich ist. Dies gilt im Besonderen für kleinskalige Prozesse, die aufgrund der groben Auflösung und mangelnder Parametrisierung in den Klimamodellen oft nicht berücksichtigt werden können. In diesem Punkt sind Beobachtungsdaten und dementsprechende Reanalyse-Produkte klar im Vorteil gegenüber globalen Klimasimulationen.

Der große Vorteil der Klimasimulationen ist demgegenüber der große Umfang der Daten und vor allem die Möglichkeiten, alternative, sowie vergangene und zukünftige Klimabedingungen zu simulieren. Hinzu kommt, dass zuverlässige satellitengestützte Beobachtung erst seit circa vier Dekaden existieren, was oft zu kurz ist, um statistisch belastbare Aussagen über die langfristige Veränderung von vielen Arten von Extremereignissen treffen zu können. Ensemble-Simulationen von globalen Klimamodellen sind hier ein ausgezeichnetes Werkzeug, da sie aufgrund Ihres Datenumfangs eine klare Trennung von zufälligen und klimabedingten Veränderungen sowie eine robuste Extremwertstatistik erlauben.

Mit dem Hybrid-Modell haben wir einen komplett neuen Modellansatz entwickelt, der großes Potential auch über die hier bearbeitete Aufgabenstellung hinaus bietet. Alle nötigen Programmskripte, das austrierte Modell selbst und eine ausführliche Dokumentation wurden vollumfänglich öffentlich gemacht (https://github.com/jbecherer/MHW_hybrid_model). Unsere Hoffnung ist, dass im Sinne des Open-Source-Gedankens andere Arbeitsgruppen auf unsere Pionierarbeit aufbauen können und den Ansatz weiterentwickeln, auch in Bezug auf andere Fragestellungen. Hierbei ist auch von großem Vorteil, dass alle zugrundeliegenden Daten frei zugänglich und im Internet verfügbar sind.

1.2. Methoden

1.2.1. Modellkonzept

Ziel war die Entwicklung eines Modellsystems, das die realistische hochfrequente Variabilität (auf täglicher Zeitskala) der Oberflächentemperatur (SST) aus niederfrequenten (monatlichen) Daten eines globalen Klimamodells (GCM) zurückgewinnen kann. Dafür wurde ein KI-Modell trainiert, um die hochfrequente SST-Variabilität auf Grundlage bestimmter niederfrequenter Eingabeparameter vorherzusagen. Das Training erfolgte mit auf Beobachtungen basierenden Daten (ERA5). Nach dem Training wurde die KI-Komponente in ein Hybridmodell integriert. In diesem Hybridmodell wurden die niederfrequenten Eingabeparameter für das KI-Modul aus Daten von GCM-Simulationen bereitgestellt. Abschließend wurden die niederfrequenten SST-Informationen des GCM mit der Vorhersage des KI-Modells kombiniert, um eine hochfrequente SST-Zeitreihe zu erzeugen. Diese hochfrequente SST-Zeitreihe konnte anschließend für die Berechnung von Statistiken mariner Hitzewellen (MHW) verwendet werden.

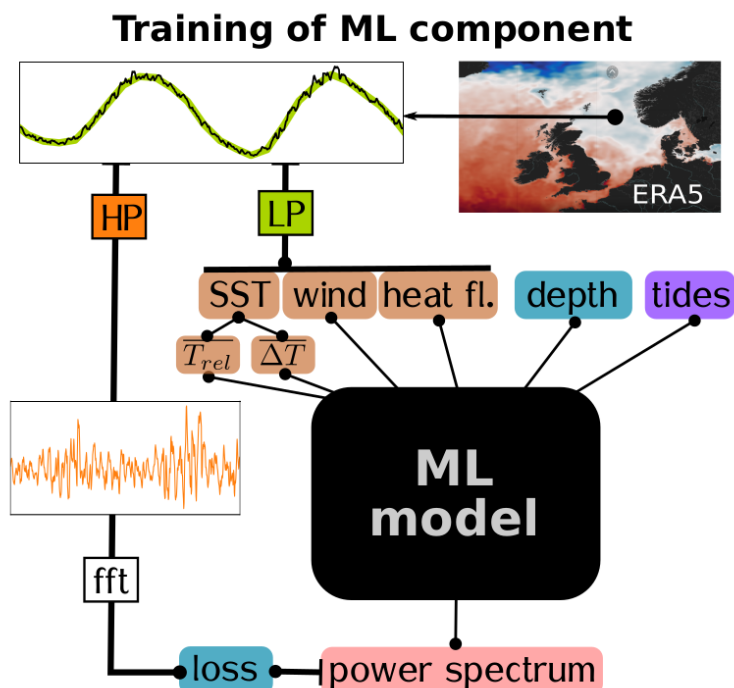


Abb. 1: Schema des Trainingszyklus für maschinelles Lernen (ML). Das ML-Modell lernt, ein SST-Spektrum aus niederfrequenten (NF) ERA5-Daten vorherzusagen, welches dann mit dem Spektrum der originalen hochfrequenten (HF) ERA5-SST-Daten verglichen wird.

1.2.2. Technische Schritte

Zur Konstruktion des Hybridmodells sind mehrere technische Schritte notwendig:

1. Auswahl eines Satzes niederfrequenter Eingabeparameter für das ML-Modell
2. Auswahl geeigneter Ausgabevariablen für das ML-Modul
3. Identifizierung und Aufbereitung eines Datensatzes zum Trainieren des ML-Moduls
4. Auswahl einer geeigneten ML-Modellarchitektur
5. Trainieren des ML-Modells
6. Validierung der Vorhersagefähigkeit des ML-Modells
7. Identifizierung eines Klimamodell-Datensatzes für das Hybridmodell
8. Verwendung des Hybridmodells zur Umwandlung monatlicher Klimamodell-Eingabedaten in tägliche SST-Zeitreihen

1.2.3. Ein- und Ausgabeparameter

Es wurden verschiedene mögliche Eingabeparameter für das ML-Modul untersucht. Ziel war es, mit einer möglichst geringen Anzahl an Parametern ein möglichst großes Spektrum an relevanten physikalischen Prozessen abzudecken. Außerdem wurde die Korrelation verschiedener möglicher Eingabeparameter mit der hochfrequenten SST-Variabilität quantifiziert. Nach eingehenden Untersuchungen haben wir uns schließlich für einen Satz von sechs Eingangsvariablen entschieden: relative SST, monatliche SST-Differenz, Windgeschwindigkeit, Oberflächenwärmefluss, Gezeitenamplitude und Wassertiefe.

Als Ausgabeparameter des ML-Moduls haben wir ein bandbegrenzt (zehn Amplituden) Leistungsspektrum der täglichen SST ausgewählt. Eine direkte Ausgabe einer hochfrequenten SST-Zeitreihe ist aus technischen Gründen nicht zu empfehlen. Das Leistungsspektrum kann mit Hilfe frei wählbarer Phasen in eine Zeitreihe übersetzt werden. Die Berücksichtigung aller möglichen Phasen erlaubt bei diesem Ansatz eine zusätzliche Abschätzung des Fehlers, der durch die zufällige Überlagerung verschiedener Prozesse zustande kommt.

1.2.4. Datenquellen

Wir verwenden vier verschiedene, öffentlich zugängliche Datensätze für unsere Studie: ERA5-Reanalysedaten, TPXO-Gezeitenmodell-Output, GEBCO-Bathymetriedaten und MPI-ESM1.2-LR Outputdaten.

ERA5 ist ein global verfügbares Reanalyse-Produkt, das ein 4D-Var-Verfahren verwendet, um eine große Anzahl von Beobachtungsdaten in ein gekoppeltes Atmosphäre-Land-Ozean-Modellsystem zu assimilieren (Hersbach et al., 2020). Obwohl ERA5 kein direktes Beobachtungsprodukt ist, dient es aufgrund der umfangreichen Assimilation von Beobachtungsdaten als geeigneter Datensatz, um die reale Welt in unserer Machbarkeitsstudie darzustellen. Ein wesentlicher Vorteil von ERA5 gegenüber einzelnen Beobachtungen ist, dass es einen konsistenten Satz von Eingabeparametern für das ML-Modell bereitstellt.

Das TPXO-Gezeitenmodell verwendet ein Inversionsverfahren, um Satellitenaltimetrie-Daten zu assimilieren, um damit verschiedene Gezeitenkomponenten auf einem globalen Gitter vorhergesagt werden können (Egbert und Erofeeva, 2002).

Die Wassertiefe (H) wird unter Verwendung des GEBCO-Bathymetrie-Datensatzes berechnet (GEBCO Bathymetric Compilation Group, 2024).

Das für unsere Studie ausgewählte GCM ist MPI-ESM1.2-LR (Mauritsen et al., 2019), das im Folgenden als MPIESM bezeichnet wird. Ein wesentlicher Vorteil von MPIESM ist die Verfügbarkeit von Grand-Ensemble-Simulationen für die neuesten CMIP6-Szenarien, die jeweils 30-50 Ensemble-Mitglieder umfassen (Olonscheck et al., 2023). Neben Zukunftsszenarien steht auch die Ensemble-Simulation einer historischen Periode von 1850 bis 2015 zur Verfügung. Der Output wird auf einem globalen Ein-Grad-Gitter erzeugt und liefert monatliche Outputdaten für alle in Abschnitt 1.2.3 beschriebenen Eingabeparameter. Darüber hinaus sind tägliche SST-Outputdaten verfügbar, die wir als Referenz verwenden, um die Verbesserung der MHW-Statistiken des Hybridmodells gegenüber normalen Klimamodelldaten beurteilen zu können.

1.2.5. KI-Architektur

Um das beste Machine-Learning (ML) Modell für unsere Zwecke zu identifizieren, untersuchten wir eine Vielzahl verschiedener Modellarchitekturen, einschließlich neuronaler Netze, Random-Forest-Modelle und ein einfaches lineares Regressionsmodell zum Vergleich.

Alle Modelle verwenden den gleichen Satz von sechs Eingangsparametern zusammen mit zehn Ausgabeparametern (zehn Amplituden des Leistungsspektrums). Sie werden mit ERA5-Daten trainiert, die auf ein Ein-Grad-Gitter des Nordwest-Europäischen-Schelfs (NWES) interpoliert werden (siehe roter Kasten in Abbildung 2). Wir verwenden Daten aus den Jahren 1982 bis 2023 für das Training. Von diesem Zeitraum wählen wir zufällig acht Jahre aus (2009, 2003, 1994, 1989, 2019, 1984, 2010, 2017), die wir für die Validierung reservieren und daher nicht für das Training verwenden.

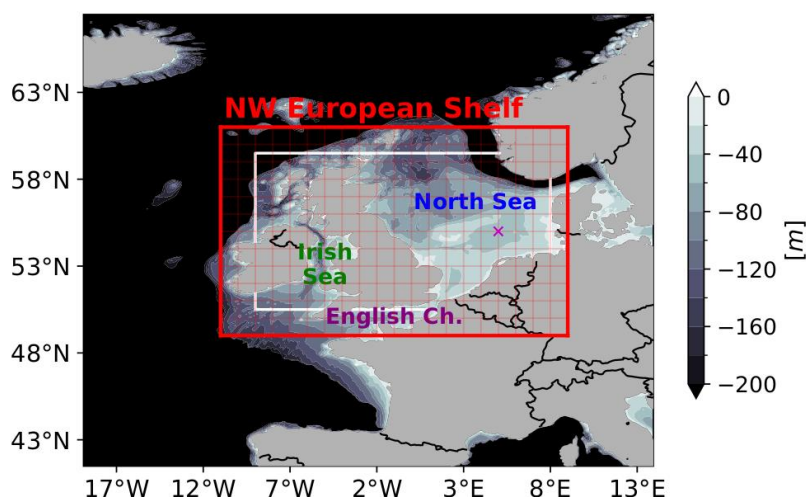


Abb. 2: Bathymetrische Karte des Nordwest-Europäischen Schelfs (NWES). Der rote Kasten hebt das Gebiet hervor, das zum Training der ML-Modelle verwendet wurde. Die dünnen roten Linien stellen das Ein-Grad-Gitter dar, auf das die verschiedenen Datenprodukte interpoliert werden.

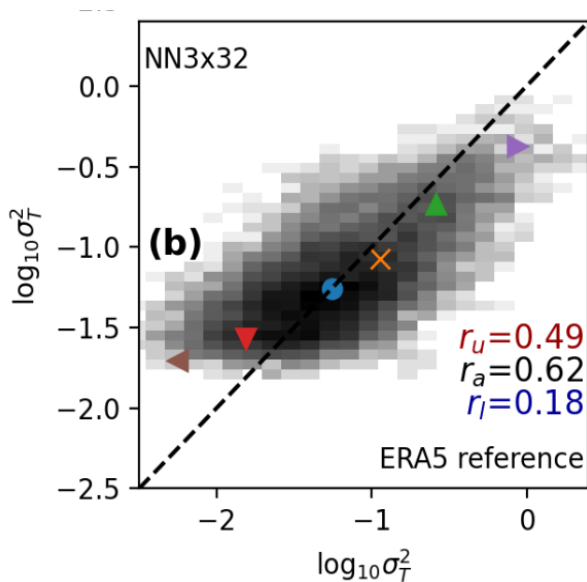


Abb. 3: Histogramm der SST-Varianz für den gesamten NWES für den Validationszeitraum. Die y-Achse zeigt die Vorhersagen des ML-Modells, während die x-Achse die tatsächlichen ERA5-Werte darstellt. Die gestrichelte Linie repräsentiert das 1:1-Verhältnis. Symbole zeigen die Verhältnisse verschiedener statistischer Eigenschaften der jeweiligen Verteilungen: Der blaue Kreis markiert den Median, das orangefarbene Kreuz den arithmetischen Mittelwert, das braune nach links gerichtete Dreieck das 1% Perzentil, das rote abwärts gerichtete Dreieck das 10% Perzentil, das grüne aufwärts gerichtete Dreieck das 90% Perzentil und das violette nach rechts gerichtete Dreieck das 99% Perzentil. Die Korrelationskoeffizienten für alle Daten (r_a), das untere Viertel (r_l) und das obere Viertel (r_u) sind auf der rechten Seite jedes Teilbildes angegeben.

Um die Leistungsfähigkeit der verschiedenen ML-Modelle zu evaluieren, vergleichen wir sie mit den ERA5-Referenzdaten. Hierfür nutzen wir die Varianz der hochfrequenten SST als komprimiertes Maß für das Leistungsspektrum (gezeigt exemplarisch für ein neuronales Netzwerk in Abbildung 3).

Es hat sich gezeigt, dass die neuronalen Netze unterschiedlicher Größe ähnlich gute Ergebnisse zeigen. Auch das Random-Forrest-Modell ist vergleichbar gut. Die lineare Regression ist allerdings erheblich schlechter, besonders für Situationen mit hoher Varianz.

Zusammenfassend zeigt sich, dass die Vorhersage hochfrequenter SST-Variabilität aus niederfrequenten Eingabeparametern mithilfe eines ML-Modells möglich ist, wobei ein überraschend hohes Maß an Vorhersagegüte erreicht wird. Diese Beziehung kann effektiv durch relativ kleine neuronale Netze mit etwa 100 freien Parametern erfasst werden. Schließlich wählen wir ein neuronales Netz mit fünf versteckten Schichten a 64 Neuronen (NN5x64) als endgültige ML-Komponente im Hybridmodell aus, da es unter allen getesteten Modellen die höchste Korrelation im Validierungsdatensatz erzielte.

1.2.6. Hybridmodell

Nach der Auswahl eines geeigneten ML-Modells und dessen erfolgreichem Training mit ERA5-Daten wird das Modell in das Hybridmodell integriert (siehe Abb. 4). Im Hybridmodell werden die niederfrequenten Eingabeparameter für das ML-Modul aus globalen Klimamodell-Simulationen (GCM) anstelle von ERA5 bezogen. Das ML-Modul sagt das Leistungsspektrum der hochfrequenten SST vorher. Dieses Leistungsspektrum wird dann in eine tägliche Zeitreihe der SST-Anomalie umgewandelt, indem eine zufällige Phase jeder der zehn spektralen Komponenten in einer inversen Fourier-Transformation zugewiesen wird. Dies wird für jede Gitterzelle separat durchgeführt. Die vom ML-Modul generierten SST-Anomalien werden anschließend mit der monatlichen SST-Zeitreihe aus dem GCM kombiniert, um die gesamte tägliche SST-Zeitreihe des Hybridmodells zu erhalten.

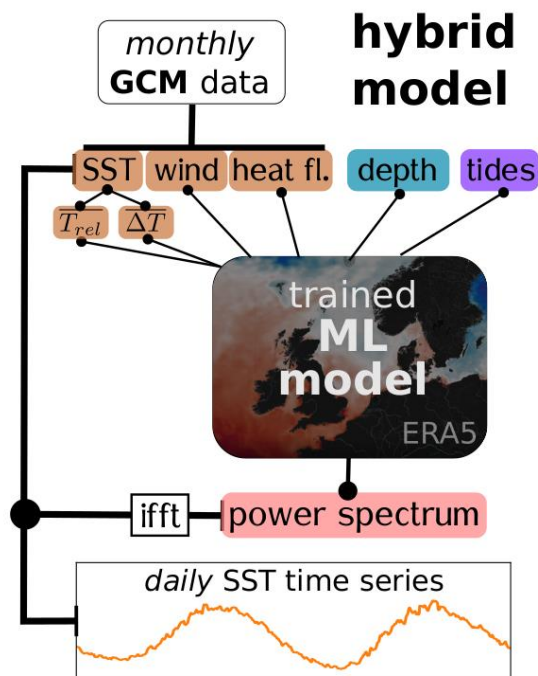


Abb. 4: Schematische Darstellung des Hybridmodells. Die monatlichen Eingangsparameter werden aus Ensemble-Simulationen eines globalen Klimamodells (GCM) entnommen, während das entsprechende Spektrum der hochfrequenten SST von der ML-Modellkomponente vorhergesagt wird. Die Kombination der niederfrequenten SST aus dem GCM mit der hochfrequenten SST aus dem ML-Modell führt zu einer täglichen SST-Zeitreihe für jeden Gitterpunkt des zugrundeliegenden GCM.

Die Beispielzeitreihe in Abbildung 5 zeigt, wie die verschiedenen Datenprodukte kombiniert werden, um den Hybridmodelloutput zu erhalten. Die niederfrequente GCM-Zeitreihe (MPIESM-m, grüne Linie in Abb. 5a) wird mit der hochfrequenten SST-Anomalie, die vom ML-Modul vorhergesagt wird (orange Linie Abb. 5b), kombiniert, um die vollständige tägliche SST-Zeitreihe des Hybridmodells zu erhalten (orange Linie in Abb. 5a). Zum Vergleich stellen wir auch die tägliche SST-Zeitreihe dar, wie sie vom GCM allein berechnet wird (MPIESM-d, blaue Linie Abb. 5a). Das Hybridmodell erzeugt eine SST-Anomalie, die völlig unabhängig von MPIESM-d ist, aber eine vergleichbare Variabilität aufweist (Abb. 5b).

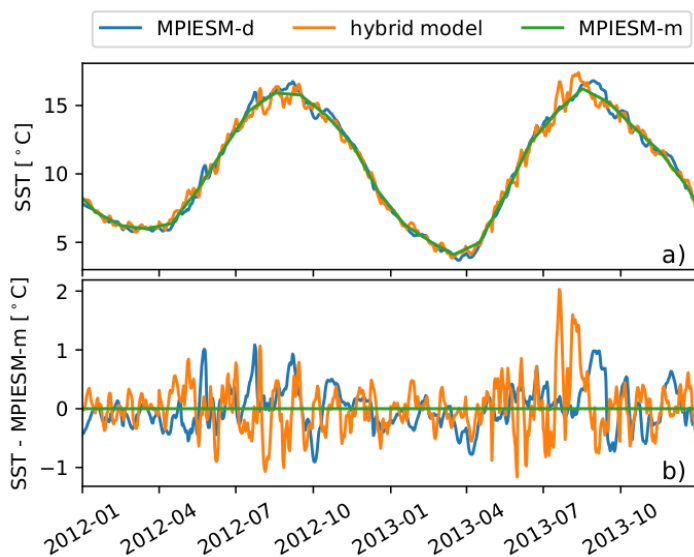


Abbildung 5: Beispielzeitreihe eines Ensemble-Mitglieds (Position durch das magentafarbene Kreuz in Abbildung 2 markiert) für die Jahre 2012-2013. Teilbild (a) zeigt die SST und Teilbild (b) die hochfrequente SST-Anomalie für drei Datensätze: (grün) MPIESM-m, die monatlich gemittelte MPIESM-SST interpoliert auf einen täglichen Zeitschritt; (orange) das Ergebnis des Hybridmodells; und (blau) MPIESM-d, die täglichen Ausgabewerte von MPIESM ohne Hybridansatz.

Es ist wichtig zu erwähnen, dass das Hybridmodellssystem modular aufgebaut ist und leicht angepasst werden kann, um andere Datenquellen einzubinden. Das ML-Modell kann durch ein anderes Modell ersetzt werden, das mit einem alternativen Datensatz trainiert wurde. Darüber hinaus können die GCM-Daten problemlos durch Daten aus einer anderen Quelle ausgetauscht werden, sofern alle erforderlichen Eingabeparameter vorhanden sind.

1.3. Verbesserung der Marine-Hitzewellen Statistik durch das Hybridmodell

1.3.1. Definition mariner Hitzewellen

Für unser Projekt verwenden wir die gängige Definition von marinen Hitzewellen (MHWs), die von Hobday et al. (2016) eingeführt wurde. MHWs sind definiert als Ereignisse, bei denen die SST einen spezifischen Schwellenwert für mindestens fünf aufeinanderfolgende Tage überschreitet. Dieser Schwellenwert wird auf das 90. Perzentil der Klimatologie festgelegt, die üblicherweise mit einem 30-Jahres-Fenster berechnet wird – in unserem Fall von 1982 bis 2011.

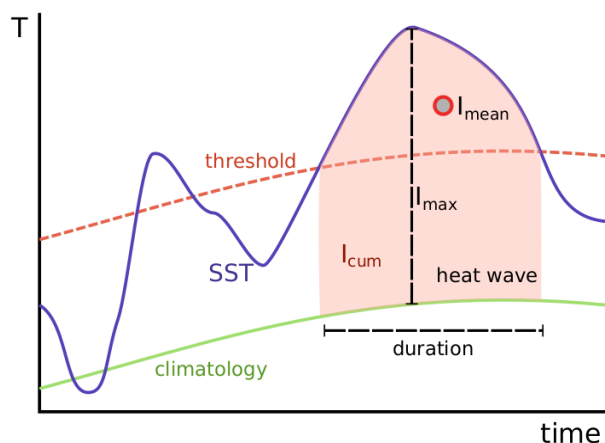


Abb. 6: Schema verschiedener Messgrößen für Hitzewellen (nach Hobday et al. (2016)): Dauer (Tage), mittlere Intensität (I_{mean} , °C), Spitzenintensität (I_{max} , °C), kumulative Intensität (I_{cum} , °C·Tage), rot schattierte Fläche.

Jedes MHW-Ereignis wird durch verschiedene Messgrößen quantifiziert (siehe Abbildung 6). Zu den gängigsten Messgrößen zählen die Dauer in Tagen, die mittlere Intensität über dem klimatologischen Mittelwert, die Spitzenintensität und die kumulative Intensität.

Die Statistiken dieser Maße umfassen: (1) die Anzahl der Ereignisse pro Jahr, (2) die mittlere Dauer der Ereignisse, (3) die Dauer des längsten Ereignisses im Datensatz, (4) die durchschnittliche mittlere Intensität aller Ereignisse, (5) die durchschnittliche kumulative Intensität, (6) die kumulative Intensität des stärksten Ereignisses, (7) die durchschnittliche Spitzenintensität und (8) die Spitzenintensität des stärksten Ereignisses.

1.3.2. Vergleich von MHW-Statistiken verschiedener Datenquellen für 1982-2023

Um zu beurteilen, inwiefern das Hybridmodell die MHW-Statistiken verbessert, vergleichen wir vier verschiedene Datensätze: (1) ERA5-Reanalyse (Referenz), (2) das Hybridmodell, (3) tägliche SST-Daten von MPIESM (als MPIESM-d bezeichnet) und (4) monatlich gemittelte SST-Daten von MPIESM, die linear auf einen täglichen Zeitschritt interpoliert wurden (als MPIESM-m bezeichnet). Aus Konsistenzgründen beschränken wir unseren Vergleich auf die Jahre 1982 bis 2023, in denen ERA5-Daten verfügbar sind.

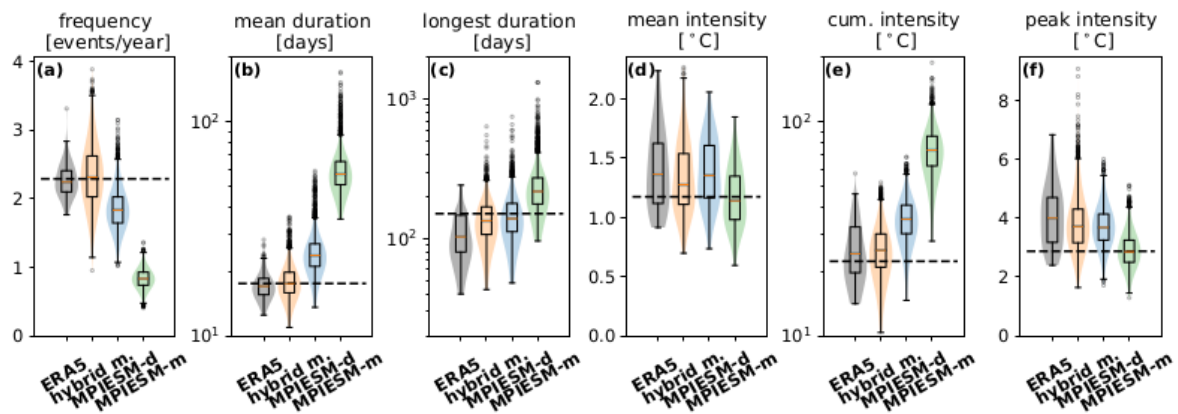


Abb. 7: Boxplots verschiedener MHW-Statistiken für den Zeitraum 1982 bis 2023, basierend auf der Referenzklimatologie 1982 bis 2011. Alle Gitterzellen innerhalb des weißen Rahmens in Abbildung 2 wurden zusammengefasst. Die Statistiken umfassen: (a) Ereignishäufigkeit, (b) mittlere Ereignisdauer, (c) Dauer des längsten aufgezeichneten Ereignisses, (d) die durchschnittliche mittlere Intensität, (e) die durchschnittliche kumulative Intensität und (f) die Spitzenintensität des stärksten Ereignisses. Die Farben der entsprechenden Violinen-Diagramme repräsentieren verschiedene Datensätze: schwarz für ERA5, orange für das Hybridmodell, blau für den täglichen GCM-Output (MPIESM-d) und grün für die monatlichen GCM-Daten (MPIESM-m). Es ist zu beachten, dass ERA5 nur 42 Jahre an realen historischen Daten umfasst, während das Hybridmodell und MPIESM Ensembles von 30 verschiedenen möglichen Vergangenheitsrealisierungen darstellen, die zusammen 1260 Datenjahre ergeben. Dementsprechend spiegelt die ERA5-Verteilung lediglich die räumliche Variabilität innerhalb des weißen Rahmens in Abbildung 2 wider, wohingegen die Modellergebnisse auch die Variabilität zwischen den einzelnen Ensemble-Mitgliedern veranschaulichen.

Abbildung 7 zeigt eine Auswahl von MHW-Statistiken für den gesamten NWES, wobei die verschiedenen Datensätze verglichen werden. Wir beginnen mit dem Vergleich von ERA5 (grau, als Grundwahrheit betrachtet) mit den niederfrequenten Daten von MPIESM (MPIESM-m - grün in Abb. 7). MPIESM-m weist deutlich weniger MHW-Ereignisse (< 1 Ereignisse/Jahr) auf, die im Durchschnitt deutlich länger dauern (> 50 Tage) als typische MHW-Ereignisse in ERA5 (≈ 20 Tage).

Insgesamt, ergeben diese Unterschiede ein konsistentes Bild des niederfrequenten SST-Signals: weniger, länger andauernde MHW-Ereignisse von geringerer mittlerer und Spitzenintensität ergeben aufgrund ihrer verlängerten Dauer eine größere kumulative Intensität. Dies zeigt, dass monatliche Daten nicht ausreichen, um realistische MHW-Statistiken zu erfassen, was die Notwendigkeit einer realistischen hochfrequenten SST-Variabilität bei der Untersuchung von MHW-Ereignissen unterstreicht.

Die MHW-Statistiken der täglichen Klimamodelldaten (MPIESM-d, blau in Abb. 8) zeigen eine bessere Übereinstimmung mit ERA5 als die monatlichen Daten (MPIESM-m). Die Anzahl der MHW-Ereignisse ist in MPIESM-d größer als in MPIESM-m, obwohl sie immer noch deutlich geringer ist als in ERA5 (Abb. 7(a)). Die seltenen Ereignisse in MPIESM-d dauern tendenziell länger (≈ 25 Tage) als die in ERA5 (≈ 20 Tage). Die längsten Ereignisse in MPIESM-d sind im Durchschnitt ebenfalls etwas länger als die in ERA5. Die mittlere Intensität der MHW in MPIESM-d ist vergleichbar mit der von ERA5, während die kumulative Intensität deutlich größer ist. Die Spitzenintensität des stärksten Ereignisses ist vergleichbar, aber etwas geringer in MPIESM-d als in ERA5.

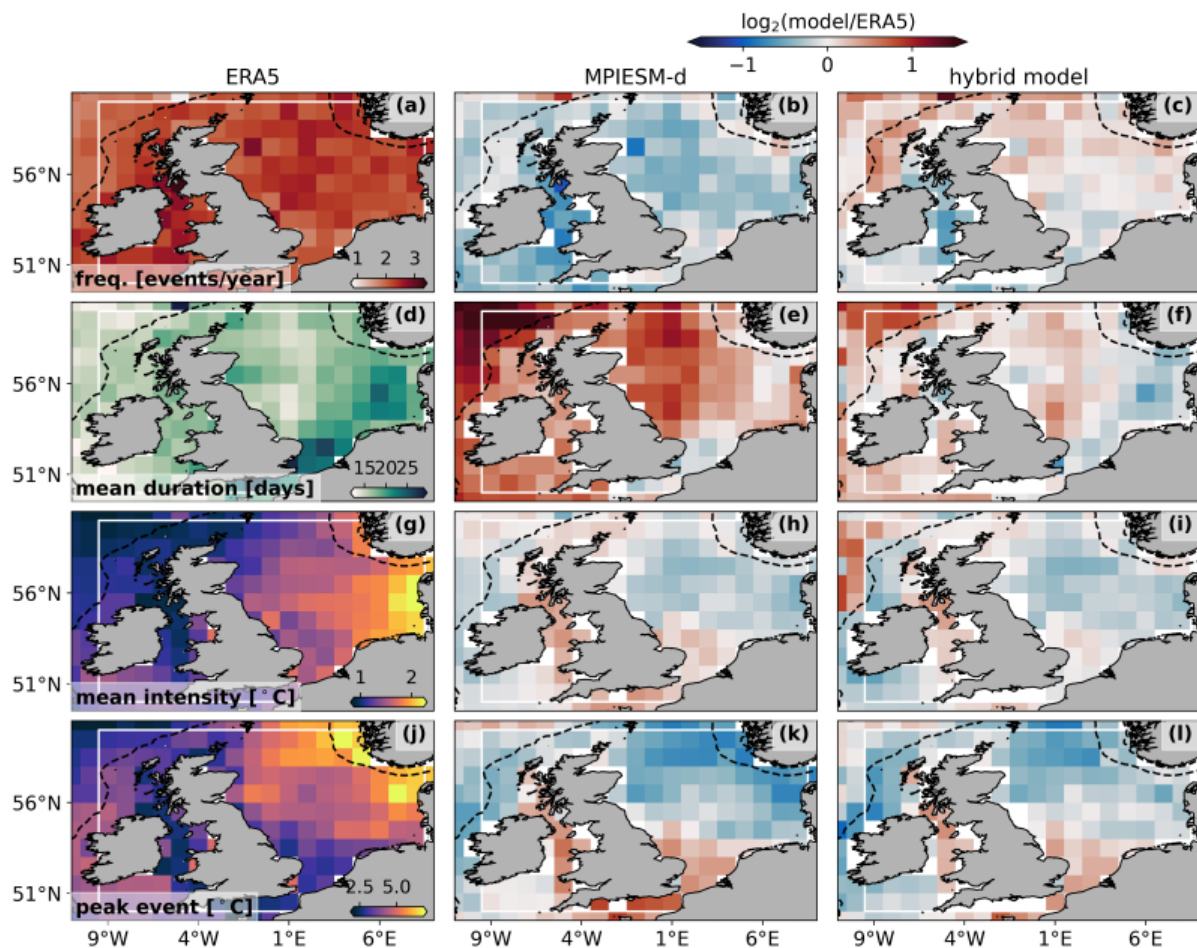


Abb. 8: Die erste Spalte zeigt Karten von vier MHW-Statistiken für den ERA5-Datensatz von 1982 bis 2023: (a) Ereignisfrequenz, (d) mittlere Ereignisdauer, (g) mittlere Ereignisintensität und (j) Spitzenintensität. Das Verhältnis der Modellausgabe zu ERA5 für die jeweilige Statistik ist in der zweiten Spalte für MPIESM-d und in der dritten Spalte für das Hybridmodell dargestellt. Zu beachten ist, dass die Verhältnisse in \log_2 angezeigt werden, wobei ein Wert von +1 (-1) einer relativen Zunahme (Abnahme) um den Faktor zwei entspricht.

Abbildung 8 veranschaulicht die räumliche Verteilung der Abweichungen in MPIESM-d im Vergleich zu ERA5 für ausgewählte MWH-Statistiken. Die Anzahl der MWH-Ereignisse wird von MPIESM-d im gesamten NWES durchweg unterschätzt (Abb. 8(b)). Ebenso ist die mittlere Dauer in MPIESM-d im Allgemeinen überhöht, mit Ausnahme des Ärmelkanals (Abb. 8(e)). Interessanterweise zeigen mittlere und Spitzenintensität in MPIESM-d – trotz einer Übereinstimmung mit ERA5 bei Mittelung über den gesamten Schelf ((siehe Abb. 7)(d,f)) – systematische regionale Abweichungen (Abb. 8(h,k)).

In der nördlichen Nordsee ist die mittlere und Spitzenintensität in MPIESM-d geringer als in ERA5 (Abb. 8(h,k)). In der südlichen Nordsee, im Ärmelkanal und in der Irischen See überschätzt MPIESM-d die Intensität. Diese Regionen werden von unterschiedlichen dynamischen Regimen bestimmt: Die nördliche Nordsee ist saisonal geschichtet, während die südliche Nordsee, der Ärmelkanal und die Irische See durch starke Gezeitenkräfte ganzjährig gut durchmischt sind.

Die beobachteten Abweichungen deuten darauf hin, dass MPIESM beide Regime nicht präzise erfasst. Fehlende Gezeitenkräfte in MPIESM führen wahrscheinlich zu übermäßiger Schichtung in gezeitendominierten Gebieten, was eine flachere Durchmischungsschicht zur Folge hat. Diese flachere Schicht trägt zu einer größeren SST-Variabilität bei gegebenem

Oberflächenwärmefluss bei und führt so zu einer Überschätzung der MHW-Intensität. In Regionen mit starker saisonaler Schichtung erzeugt MPIESM aufgrund seiner groben vertikalen Auflösung der Sprungschicht und des Fehlens von entsprechenden Prozessparametrisierungen eine zu tiefe Oberflächenschicht (Pätsch et al., 2017). Dies führt zu einer geringeren SST-Variabilität und einer Unterschätzung der MHW-Intensität.

Zusammenfassend ist festzustellen, dass die aus MPIESM-d abgeleiteten MHW-Statistiken im Vergleich zu ERA5 systematisch verzerrt sind. Insbesondere gibt es eine deutliche Tendenz zu weniger und längeren Ereignissen mit einer höheren kumulativen Intensität. Dies steht im Einklang mit der gut dokumentierten Tendenz von GCMs, Abweichungen zu längeren und weniger häufigen MHWs zu zeigen (Pilo et al., 2019; Oliver et al., 2019). Während MPIESM-d in Bezug auf die mittlere und Spitzenintensität in einer schelfweit gemittelten Ansicht recht gut abschneidet, hat es systematisch Schwierigkeiten, die räumlichen Variationen der MHW-Intensität zu erfassen, die auf unterschiedliche dynamische Regime zurückzuführen sind.

Im Vergleich zu MPIESM-d schneidet das Hybridmodell bei den MHW-Statistiken deutlich besser ab (siehe Abb. 7). Die systematischen Abweichungen in der Anzahl der Ereignisse sowie in der mittleren Dauer und der kumulativen Intensität werden fast vollständig beseitigt. Die leichte Überschätzung der längsten Ereignisse, die in MPIESM-d im Vergleich zu ERA5 beobachtet wurde, wird im Hybridmodell jedoch nicht wesentlich verbessert.

Schelfweit gemittelt ist die mittlere Intensität im Hybridmodell etwas geringer als in MPIESM-d (Abb. 7(d)). Die Gründe dafür werden in der räumlich aufgelösten Ansicht deutlicher (Abb. 8(i)). Die systematische Abweichung der mittleren Intensität von MPIESM-d in gezeitendominierten Regionen ist im Hybridmodell deutlich reduziert (vergleiche rote Bereiche in Abb. 8(h) und (i)). Dies ist ermutigend, da es darauf hindeutet, dass das ML-Modell einige der Gezeitenmischungseffekte wieder einführen kann, die im GCM fehlen. Die negative Abweichung der mittleren Intensität in saisonal geschichteten Regionen verbessert sich im Hybridmodell im Vergleich zu MPIESM-d nicht wesentlich (vergleiche blaue Bereiche in Abb. 8(h) und (i)). Zusammengenommen ergibt sich eine etwas geringere schelfgemittelte Intensität für das Hybridmodell als für MPIESM-d (Abb. 7(d)). Auch die räumlichen Abweichungen der Spitzenintensität in MPIESM-d werden im Hybridmodell deutlich reduziert, selbst in stärker geschichteten Regionen (weniger Blau in Abb. 8(l) im Vergleich zu (k)).

Es ist wichtig zu beachten, dass sowohl MPIESM-d als auch das Hybridmodell das gleiche niederfrequente Verhalten (MPIESM-m) teilen. Folglich sind die im Hybridmodell im Vergleich zu MPIESM-d beobachteten Verbesserungen der MHW-Statistiken allein auf die unterschiedlichen hochfrequenten SST-Beiträge zurückzuführen. Die ML-Komponente des Hybridmodells ermöglicht offensichtlich eine bessere Darstellung des hochfrequenten SST-Verhaltens, die sich auch in verbesserten MHW-Statistiken niederschlägt.

1.4. Zukunftsprojektionen für den Nordwest-Europäischen Schelf

Nachdem wir gezeigt haben, dass das Hybridmodell bessere MHW-Statistiken als das alleinstehende MPIESM für den ERA5-Referenzzeitraum (1982-2023) liefert, wenden wir es auf den vollständigen CMIP6-Datensatz (1850-2100) des MPIESM-Modells an (Olonscheck et al., 2023). Dies ermöglicht die Untersuchung langfristiger Änderungen der MHW-Statistiken für den NWES unter verschiedenen Klimawandelszenarien. Die MPIESM-Ensemble-Simulationen umfassen den historischen Zeitraum 1850-2015 und Zukunftsprojektionen 2015-2100 für vier CMIP6-Szenarien (SSP1-2.6, SSP2-4.5, SSP3-7.0, SSP5-8.5), jeweils mit 30 Ensemble-Mitgliedern.

1.4.1. Marine Hitzewellen in einem sich verändernden Klima

In diesem Abschnitt werden wir zeigen, dass sich die heutigen Bedingungen auf dem NWES in Bezug auf marine Hitzewellen bereits deutlich von der jüngeren Vergangenheit unterscheiden. Darüber hinaus werden wir beobachten, dass es bzgl. der MHW-Statistiken in Zukunft zu einer Sättigung kommt, ein Phänomen, das sich bei verschiedenen MHW-Parametern unterschiedlich manifestiert.

Abbildung 9 zeigt die zeitliche Entwicklung der MHW-Statistiken für den NWES. Die Ereignisfrequenz steigt von unter einem Ereignis pro Jahr in vorindustrieller Zeit auf etwa vier bis fünf Ereignisse unter aktuellen Klimabedingungen (Abb. 9(a)). Die Anzahl der Ereignisse zeigt in der Zukunft keinen signifikanten Anstieg mehr; für die extremeren Szenarien, SSP3-7.0 und SSP5-8.5, gibt es sogar einen Frequenzrückgang gegen 2100 (Abb. 10(f)). Der stärkste Anstieg der Ereignisfrequenz tritt in den vergangenen vier Jahrzehnten (1980-2020) auf. Das zeigt, dass die heutigen Bedingungen bereits deutlich anders sind als in der jüngeren Vergangenheit.

Abb. 9(c) zeigt den Anteil der MHW-Tage pro Jahr. Dieser Anteil beginnt bei etwa 2 % (ca. 7 Tage/Jahr) in vorindustrieller Zeit. Im klimatologischen Zeitraum (1982-2011) liegt er knapp unter 10 % (ca. 30 Tage/Jahr). Heute ist dieser Anteil im Vergleich zum klimatologischen Zeitraum bereits um das Dreifache gestiegen (mehr als das Zehnfache des vorindustriellen Niveaus), was etwa 100 Tagen/Jahr unter MHW-Bedingungen entspricht. Für die Szenarien SSP3-7.0 und SSP5-8.5 nähert sich der Anteil der MHW-Tage bis Ende des Jahrhunderts einer Sättigung (knapp unter 100 %) (Abb. 9(h)). Auch für die moderateren Szenarien SSP1-2.6 und SSP2-4.5 sind Sättigungsanzeichen erkennbar.

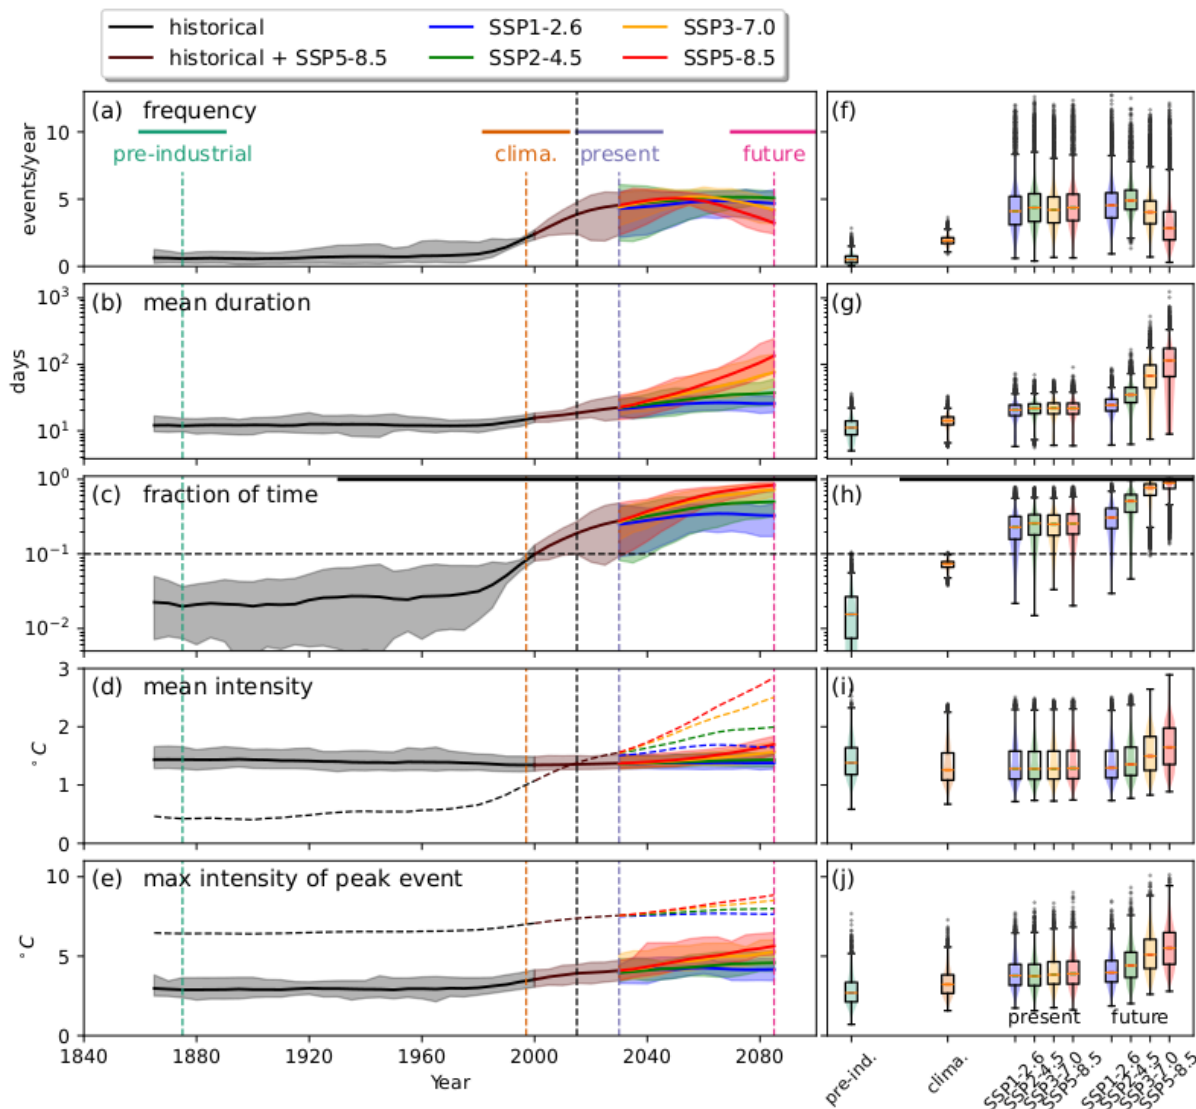


Abb. 9: (a-e) Klimatrends verschiedener MHW-Statistiken auf dem Nordwest-Europäischen Schelf (NWES), basierend auf Daten des Hybridmodells. Die Farben repräsentieren verschiedene CMIP6-Szenarien: Schwarz für den historischen Zeitraum (1850-2014), blau für das SSP1-2.6-Szenario (2015-2100), grün für SSP2-4.5, Orange für SSP3-7.0, rot für SSP5-8.5 und eine dunkelrote Überlappungsperiode (2000-2030), die den historischen Zeitraum (2000-2014) und das SSP5-8.5-Szenario (2015-2030) kombiniert. Durchgezogene Linien zeigen die Mittelwerte, während die Schattierung die Streuung darstellt. (f-j) Die Boxplots veranschaulichen die räumlichen Verteilungen für vier spezifische Zeiträume (a): vorindustriell (1860-1890), klimatologisch (1982-2011), gegenwärtig (2015-2045) und zukünftig (2070-2100). Die gestrichelten Linien in den Teilbildern (d) und (e) veranschaulichen den Klimatrend der schelfweiten mittleren SST, die zu Illustrationszwecken um 1 °C (d) bzw. 7 °C (e) verschoben sind.

Die Sättigungstendenz der MHW-Statistiken in einem wärmer werdenden Klima manifestiert sich unterschiedlich in der mittleren Ereignisdauer und Ereignisfrequenz (vergleiche Abb. 9(a) und (b)). Der Anstieg der Hitzewellentage beginnt mit einer Zunahme der Ereignisfrequenz, die unter aktuellen Klimabedingungen bereits ein Plateau erreicht. Die mittlere Dauer nimmt jedoch in der Zukunft weiter zu. Im extremsten Szenario, SSP5-8.5, führt dies zu einer Verzehnfachung der Ereignisdauer (Abb. 9(g)).

Die mittlere Intensität von MHW-Ereignissen ändert sich im Laufe der Zeit nicht wesentlich (Abb. 9(d)). Nur für SSP3-7.0 und SSP5-8.5 ist gegen Ende des Jahrhunderts ein Anstieg der mittleren Intensität erkennbar. Dieser Anstieg ist deutlich geringer als der SST-Klimatrend auf dem Schelf (gestrichelte Linien in Abb. 9(d)). Solange die Sättigung nicht erreicht ist, zählt die

Statistik mehr MHW-Tage mit steigender SST. Die durchschnittliche Intensität bleibt relativ stabil, da extreme Ereignisse durch weniger extreme ausgeglichen werden. Erst bei vollständiger Sättigung gegen Ende des Jahrhunderts steigt die mittlere Intensität, da fast alle Tage MHW-Tage sind.

Die Spitzenintensität der stärksten Ereignisse nimmt im Laufe der Zeit deutlich zu (Abb. 9(e)). Der Ensemble-Mittelwert beginnt bei ca. 2,5 °C in vorindustrieller Zeit, steigt auf 3 °C im klimatologischen Zeitraum und erreicht ca. 3,5 °C unter aktuellen Bedingungen (Abb. 9(j)). Für die Zukunft zeigt SSP1-2.6 keine signifikante Veränderung der Spitzenintensität, während SSP5-8.5 durchschnittlich ca. 5,5 °C bis Ende des Jahrhunderts vorhersagt (Abb. 9(e)). In extremen Fällen können die Spitzenintensitäten für SSP5-8.5 bis zu 10 °C erreichen (Abb. 9(j)), verglichen mit ca. 8 °C unter aktuellen Bedingungen. Der Anstieg der Spitzenintensität ist vergleichbar mit dem SST-Klimatrend (gestrichelte Linien in Abb. 9(e)).

1.4.2. Veränderung der Wiederkehrperioden mariner Hitzewellen

Die Analyse von Wiederkehrperioden ist eine nützliche Methode zur Untersuchung von Extremereignisse. Wir verwenden 30-Jahres-Fenster mit 30 Ensemble-Mitgliedern (insgesamt 900 Jahre Daten). So entspricht das extremste Ereignis einer 900-jährigen, das zweitstärkste einer 450-jährigen Wiederkehrperiode usw.

In diesem Abschnitt wird gezeigt, dass extrem lange MHWs (über 100 Tage) bis Ende des Jahrhunderts über 100-mal wahrscheinlicher werden als in vorindustrieller Zeit. Das Gleiche gilt für extreme kumulative Intensitätsereignisse (≥ 300 °C-Tage), obwohl die mittlere MHW-Intensität relativ stabil bleibt. Zudem zeigt sich, dass die Spitzenintensität weitgehend dem SST-Klimatrend folgt, jedoch bei den extremsten Ereignissen einen dadurch nicht zu erklärenden Überschuss aufweist.

Wir vergleichen typische MHW-Ereignisse über verschiedene Zeiträume anhand der 2-jährigen Wiederkehrperiode (schwarze gestrichelte Linie in Abb. 10(a)). Im klimatologischen Zeitraum (1982-2011) dauerte ein typisches MHW-Ereignis ca. 10 Tage (orange Linie in Abb. 10(a)). Unter aktuellen Bedingungen (2015-2045, lila Linie) tritt bereits jedes zweite Jahr ein Ereignis von ca. 40 Tagen Dauer auf. In der Zukunft (2070-2100, SSP5-8.5, magentafarbene Linie) steigt die 2-jährige Wiederkehrperiode voraussichtlich auf 200 Tage (Abb. 10(a)).

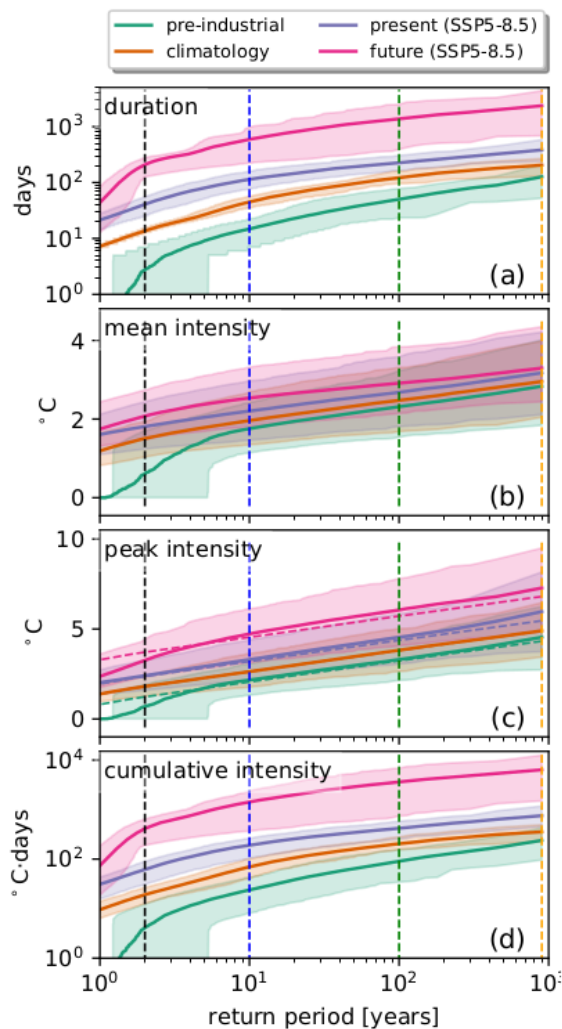


Abb. 10: Wiederkehrperioden für vier Merkmale von marinen Hitzewellen (MHW): (a) Ereignisdauer, (b) mittlere Intensität, (c) Spitzenintensität und (d) kumulative Intensität. Die verwendeten Daten stammen aus 30 Ensemble-Simulationen der historischen und der SSP5-8.5-Szenarien. Die Wiederkehrperioden werden für jeden Gitterpunkt über 30 Ensemblemitglieder berechnet, wobei ein gleitendes 30-Jahres-Fenster verwendet wird, was 900 Datenjahre pro Fenster und Gitterzelle ergibt. Die durchgezogenen Linien zeigen räumliche Mittelwerte der Wiederkehrzeiten, während die Schattierungen die 95%-Variation darstellen. Die Farben repräsentieren unterschiedliche Zeiträume gemäß der Legende. Die vertikalen gestrichelten Linien markieren spezifische Wiederkehrzeiten, wie in Abbildung 11 dargestellt. Bitte beachten Sie, dass die x-Achse eine logarithmische Skala (Jahre) verwendet.

Ereignisse mit 10-jähriger Wiederkehrperiode dauern in vorindustrieller Zeit ca. 15 Tage, im klimatologischen Zeitraum 30 Tage, unter aktuellen Bedingungen ca. 100 Tage und in der Zukunft ca. 500 Tage (blaue gestrichelte Linie in Abb. 10(a)). In einigen NWES-Regionen kann ein 10-jähriges Ereignis in der Zukunft bis zu drei Jahre dauern (siehe oberes Ende der magentafarbenen Hüllkurve Abb. 10(a)). Ereignisse mit 900-jähriger Wiederkehrperiode dauern in der Zukunft voraussichtlich ca. vier Jahre, verglichen mit ca. 100 Tagen in vorindustrieller Zeit (orange gestrichelte Linie in Abb. 10(a)).

Abbildung 11 zeigt Zeitreihen für vier Wiederkehrperioden (2-jährig, 10-jährig, 100-jährig, 900-jährig). Die Kurven für die Ereignisdauer bleiben bis ca. 1980 relativ flach (Abb. 11(a)). Danach steigt die Dauer bei allen Perioden steil an (Abb. 11(a)). Eine typische Ereignisdauer in 2080 (schwarze Linie) war noch um 1970 so gut wie ausgeschlossen (900-Jahr-Wiederkehrperiode - gelbe Linie).

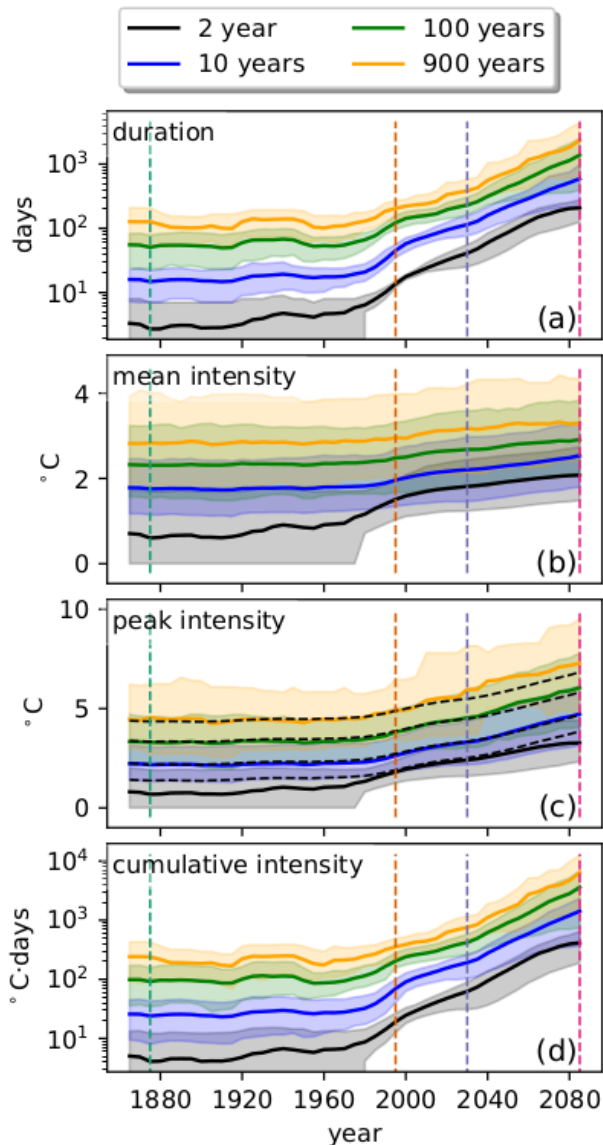


Abb. 11: Klimatrend von vier Wiederkehrperioden (siehe Legende) für die in Abb. 10 dargestellten MHW-Merkmale. Durchgezogene Linien stellen räumliche Mittelwerte dar und schattierte Bereiche die 95%-Variation. Die zugrundeliegenden Daten stammen aus dem historischen und dem SSP5-8.5-Szenario, mit einem gleitenden 30-Jahres-Fenster über 30 Ensemble-Mitglieder. Gestrichelte vertikale Linien heben die in Abb. 10 dargestellten Zeiträume hervor. Die schwarzen gestrichelten Linien in (c) zeigen den Klimatrend der schelfweit gemittelten SST. Jede der vier gestrichelten Linien ist vertikal verschoben, um der jeweiligen Spitzenintensität während der klimatologischen Periode (gestrichelte vertikale orangefarbene Linie) zu entsprechen.

Die mittlere Ereignisintensität steigt im Laufe der Zeit nur leicht an (Abb. 10(b), Abb. 11(b)). Die Hüllkurven der räumlichen Variationen überlappen sich für alle Zeiträume weitgehend (Abb. 10(b)). Dies deutet darauf hin, dass räumliche Unterschiede in der mittleren Intensität größer sind als die Veränderung durch den Klimawandel.

Die Wiederkehrperiode der Spitzenintensität von MHW-Ereignissen zeigt über die vier Zeiträume hinweg einen deutlichen Anstieg (Abbildung 10(c)). Das extremste Ereignis in vorindustrieller Zeit, welches einer 900-jährigen Wiederkehrperiode entspricht, hat eine Spitzenintensität von etwa 4 °C. In der Zukunft würde diese Spitzenintensität in etwa einer 10-jährigen Wiederkehrperiode entsprechen (Abbildung 10(c)). Dies deutet darauf hin, dass Ereignisse dieser Größenordnung bis 2100 (im SSP5-8.5) etwa 100-mal wahrscheinlicher sind als in vorindustrieller Zeit.

Die kumulative Intensität von MHW-Ereignissen ergibt sich im Wesentlichen aus der Multiplikation von Dauer und mittlerer Intensität. Die Kurven, die die Wiederkehrperioden für die kumulative Intensität darstellen, sind über die verschiedenen Zeiträume hinweg deutlich voneinander getrennt (Abbildung 10(d)). Wir beobachten einen Anstieg um etwa den Faktor drei über alle Wiederkehrperioden hinweg, wenn wir den klimatologischen Zeitraum mit den aktuellen Klimabedingungen vergleichen (Abbildung 10(d)). Für das zukünftige SSP5-8.5-

Szenario finden wir im Vergleich zu den aktuellen Bedingungen einen weiteren Anstieg um eine weitere Größenordnung. Es wird prognostiziert, dass ein durchschnittliches 10-Jahres-Ereignis in der Zukunft eine kumulative Intensität von etwa 1000 °C·Tagen haben wird, verglichen mit nur 30 °C·Tagen im klimatologischen Zeitraum (blaue Linie in Abbildung 12(d)). Selbst typische MHW-Ereignisse (2-jährige Wiederkehrperiode) werden voraussichtlich eine kumulative Intensität von etwa 300 °C·Tagen in der Zukunft haben, was die kumulative Intensität selbst der extremsten Ereignisse (900-jährige Wiederkehrperiode) in vorindustrieller Zeit übersteigt (Abbildung 10(d)).

1.5. Zusammenfassung

Es ist allgemein bekannt, dass aktuelle globale Klimamodelle die hochfrequente Variabilität der Meeresoberflächentemperatur (SST) nicht adäquat wiedergeben. Dies liegt sowohl an ihrer groben räumlichen Auflösung als auch an der unzureichenden Darstellung Wärmebilanz relevanter Prozesse, was erhebliche Konsequenzen für die aus GCM-Daten abgeleiteten Statistiken mariner Hitzewellen (MHWs) hat (Pilo et al, 2019; Oliver et al, 2021).

Im Rahmen unseres Teilprojektes haben wir gezeigt, dass es möglich ist, realistische hochfrequente (tägliche) SST-Verläufe aus niederfrequenten (monatlichen) Informationen mithilfe von maschinellem Lernen (ML) zu erzeugen. Ausgehend von dieser Erkenntnis haben wir ein neuartiges Hybridmodell entwickelt, das die statistische Repräsentation hochfrequenter SST beeinflussender Prozesse in GCM-Daten verbessert. Das Hybridmodell integriert eine ML-Komponente, die mit ERA5-Reanalysedaten trainiert wird, um hochfrequente SST-Variabilität auf Basis niederfrequenter GCM-Eingaben zu generieren.

Durch die Verwendung monatlich gemittelter GCM-Daten als Eingabe konnten wir demonstrieren, dass das Hybridmodell MHW-Statistiken erzeugt, die besser mit ERA5-Reanalysedaten übereinstimmen als solche, die aus täglichen SST-Daten desselben GCM abgeleitet wurden. Insbesondere das bekannte Problem, dass GCMs die Dauer von MHWs tendenziell überschätzen und deren Häufigkeit unterschätzen (Pilo et al, 2019), wird mit dem Hybridmodell nahezu vollständig behoben.

In einer ersten Anwendung nutzen wir das Hybridmodell, um die zeitliche Entwicklung der MHW-Statistiken auf dem Nordwest-Europäischen Schelf (NWES) unter verschiedenen Klimaszenarien zu analysieren. Wir stellen fest, dass sich die aktuellen Klimabedingungen bereits erheblich von denen der vorindustriellen Zeit unterscheiden, mit etwa zehnmal mehr Hitzewellentagen und fünfmal mehr Hitzewellenereignissen, die im Durchschnitt doppelt so lange dauern. In Bezug auf die Dauer ereignen sich Ereignisse mit einer 900-jährigen Wiederkehrperiode in vorindustrieller Zeit im aktuellen Klima bereits alle 10 Jahre und werden unter dem SSP5-8.5-Szenario in der Zukunft voraussichtlich 2-jährige Ereignisse werden.

Die mittlere Intensität von MHW-Ereignissen zeigt zwischen den verschiedenen Zeiträumen keine signifikanten Veränderungen, während die Spitzenintensität ansteigt und weitgehend dem allgemeinen Klimatrend der SST folgt. Jedoch scheint die Spitzenintensität von Ereignissen mit Wiederkehrperioden von 100 Jahren und mehr schneller zuzunehmen als der mittlere SST-Trend, was auf komplexere Prozesse hinweist, die bei den extremsten Ereignissen eine Rolle spielen.

Die Statistiken zu marinen Hitzewellen (MHWs) erreichen in der Zukunft einen Sättigungszustand, in dem die meisten Tage als MHW-Tage eingestuft werden. Diese Sättigung führt zu dem kontraintuitiven Ergebnis, dass die Ereignishäufigkeit in der Zukunft gegenüber ihrem Höchstwert in der Gegenwart voraussichtlich abnehmen wird. Die durchschnittliche Dauer von MHW-Ereignissen nimmt jedoch in der Zukunft weiterhin zu.

Das Hybridmodell bietet sowohl zahlreiche Vorteile als auch einige Einschränkungen. Ein wesentlicher Vorteil besteht darin, dass es realistische hochfrequente SST-Statistiken generiert, die mit GCMs allein nicht erzielt werden können. Darüber hinaus ist das Hybridmodell im Vergleich zu GCM-Simulationen relativ kostengünstig in der Anwendung. Ein weiterer Nutzen ist, dass das Hybridmodell modular aufgebaut ist und somit als Ergänzung zu jedem GCM oder anderen niederfrequenten Datensatz verwendet werden kann.

Das hier präsentierte Hybridmodell ist für eine spezifische Anwendung entwickelt worden: die Verbesserung der statistischen Repräsentation hochfrequenter SST-Variabilität. Die resultierende hochfrequente SST verliert jedoch die physikalische Konsistenz mit anderen hochfrequenten Variablen im GCM, was einen gewissen Nachteil darstellt, da sie nicht zur Untersuchung einzelner hochfrequenter Prozesse und deren Wechselwirkungen verwendet werden kann. Eine weitere Einschränkung ist, dass das Hybridmodell räumlich dekohärente SST-Zeitreihen erzeugt, was bedeutet, dass seine Ergebnisse nur in einem statistischen Kontext interpretiert werden sollten.

In dieser ersten Machbarkeitsstudie haben wir uns auf den Nordwest-Europäischen Schelf (NWES) konzentriert. Der allgemeine Ansatz des Hybridmodells könnte jedoch auch auf andere Regionen und möglicherweise sogar auf ein globales Modell übertragen werden. Obwohl das Hybridmodell in unserem Projekt mit dem Ziel entwickelt wurde, die SST-Statistiken zu verbessern, ist es leicht vorstellbar, dass ein ähnlicher Ansatz auch bei der Untersuchung anderer Ereignisse und Prozesse eingesetzt werden könnte, wenn realistische (hochfrequente) Statistiken für spezielle Modellparameter benötigt werden.

Referenzen

- Arns, A., T. Wahl, I. D. Haigh, J. Jensen, C. Pattiaratchi (2013). Estimating extreme water level probabilities: A comparison of the direct methods and recommendations for best practice. *Coast. Eng.*, 81, 51-66.
- Becherer, J, T. Pohlmann (2025). Improving Marine Heatwave Statistics in Global Climate Models Using Machine Learning: A Case Study for the North-West European Shelf. Under Review: *Climate Dynamics*.
- Di Biagio, Valeria, Gianpiero Cossarini, Stefano Salon, Cosimo Solidor (2020) Characterisation of extreme events waves in marine ecosystems: the case of Mediterranean Sea <https://doi.org/10.5194/bg-2020-34>.
- Egbert GD, Erofeeva SY (2002) Efficient inverse modeling of barotropic ocean tides. *Journal of Atmospheric and Oceanic Technology* 19(2):183 – 204.
- GEBCO Bathymetric Compilation Group (2024) The GEBCO_2024 Grid - a continuous terrain model of the global oceans and land. doi:10.5285/1c44ce99-0a0d-5f4f-e063-7086abc0ea0f.
- Hersbach H, Bell B, Berrisford P, et al (2020) The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society* 146(730):1999–2049. <https://doi.org/https://doi.org/10.1002/qj.3803>.
- Hobday AJ, Alexander LV, Perkins SE, et al (2016) A hierarchical approach to defining marine heatwaves. *Progress in Oceanography* 141:227–238. Publisher: Elsevier.
- Hoegh-Guldberg, O, Jacob, D, Bindi, M, Brown, S, Camilloni, I, Diedhiou, A, Djalante, R, Ebi, K, Engelbrecht, F, Guiot, J, Hijjoka, Y, Mehrotra, S, Payne, A, Seneviratne, S I, Thomas, A, Warren, R, Zhou, G, Halim, S A, Achlatis, M, Alexander, L V, Allen, M, Berry, P, Boyer, C, Byers, E, Brilli, L, Buckeridge, M, Cheung, W, Craig, M, Ellis, N, Evans, J, Fischer, H, Fraedrich, K, Fuss, S, Ganase, A, Gattuso, J P, Greve, P, Bolaños, T G, Hanasaki, N, Hasegawa, T, Hayes, K, Hirsch, A, Jones, C, Jung, T, Kanninen, M, Krinner, G, Lawrence, D, Lenton, T, Ley, D, Liverman, D, Mahowald, N, McInnes, K, Meissner, K J, Millar, R, Mintenbeck, K, Mitchell, D, Mix, A C, Notz, D, Nurse, L, Okem, A, Olsson, L, Oppenheimer, M, Paz, S, Petersen, J, Petzold, J, Preuschmann, S, Rahman, M F, Rogelj, J, Scheuffele, H, Schleussner, C-F, Scott, D, Séférian, R, Sillmann, J, Singh, C, Slade, R, Stephenson, K, Stephenson, T, Sylla, M B, Tebboth, M, Tschakert, P, Vautard, R, Wartenburger, R, Wehner, M, Weyer, N M, Whyte, F, Yohe, G, Zhang, X & Zougmore, R B 2018, Impacts of 1.5°C Global Warming on Natural and Human Systems. in V Masson-Delmotte, P Zhai, H O Pörtner, D Roberts, J Skea, P R Shukla, A Pirani, W Moufouma-Okia, C Péan, R Pidcock, S Connors, J B R Matthews, Y Chen, X Zhou, M I Gomis, E Lonnoy, T Maycock,

M Tignor & T Waterfield (eds) , Global warming of 1.5°C. : An IPCC Special Report . IPCC Secretariat , pp. 175-311.

Lang, A. and Mikolajewicz, U. (2019) The long-term variability of extreme sea levels in the German Bight, *Ocean Sci.*, 15, 651–668, <https://doi.org/10.5194/os-15-651-2019>.

Mauritsen, T., Bader, J., Becker, T., Behrens, J., Bittner, M., Brokopf, R., et al. (2019). Developments in the MPI-M Earth System Model version 1.2 (MPI-ESM1.2) and its response to increasing CO₂. *Journal of Advances in Modeling Earth Systems*, 11, 998–1038. <https://doi.org/10.1029/2018MS001400>.

Oliver, E C. J., Burrows M. T., Donat M. G., Sen Gupta A., Alexander L. V., Perkins-Kirkpatrick S. E., Benthuisen J. A., Hobday A. J., Holbrook N. J., Moore P. J., Thomsen M. S. (2019) Projected Marine Heatwaves in the 21st Century and the Potential for Ecological Impact. <https://doi.org/10.3389/fmars.2019.00734>.

Oliver EC, Benthuisen JA, Darmaraki S, et al (2021) Marine heatwaves. *Annual Review of Marine Science* 13:313–342. Publisher: Annual Reviews.

Olonscheck D, Suarez-Gutierrez L, Milinski S, et al (2023) The New Max Planck Institute Grand Ensemble With CMIP6 Forcing and High-Frequency Model Output. *Journal of Advances in Modeling Earth Systems* 15(10):e2023MS003790.

Pätsch J, Burchard H, Dieterich C, et al (2017) An evaluation of the North Sea circulation in global and regional models relevant for ecosystem simulations. *Ocean Modelling* 116:70–95.

Pilo GS, Holbrook NJ, Kiss AE, et al (2019) Sensitivity of marine heatwave metrics to ocean model resolution. *Geophysical Research Letters* 46(24):14604–14612.

Sen Gupta, A., Thomsen, M., Benthuisen, J.A. et al. (2020) Drivers and impacts of the most extreme marine heatwave events. *Sci Rep* 10, 19359. <https://doi.org/10.1038/s41598-020-75445-3>.

Weisse, R., H. von Storch (2009). *Marine Climate and Climate Change: Storms, Wind Waves and Storm Surges*. Springer-Verlag, Berlin Heidelberg New York, ISBN 978-3-540-25316-7.

Weisse, R., H. von Storch, H. D. Niemeier, H. Knaack (2012). Changing North Sea storm surge climate: An increasing hazard? *Ocean Coast. Manage.*, 68, 58-68.

Woth, K. (2005). North Sea storm surge statistics based on projections in a warmer climate: How important are the driving GCM and the chosen emission scenario? *Goephys. Res. Lett.*, 32, 22.

Die wichtigsten Positionen des zahlenmäßigen Nachweises

Position 812 (wissenschaftliches Personal), 134.448,11 €: In dieser Position wurde durchgängig der wissenschaftliche Mitarbeiter Herr Dr. Johannes Becherer angestellt. Dr. Becherer war für die Entwicklung des Hybridmodellsystem sowie für die Auswertung und Interpretation der Simulationsergebnisse verantwortlich. Er war außerdem für den Kontakt mit den anderen CoastalFutures-Projektpartnern verantwortlich, soweit es um die modell- und datentechnischen Details ging.

Notwendigkeit und Angemessenheit der durchgeführten Arbeiten

Die geleisteten Arbeiten waren zur Erreichung der Projektziele unbedingt erforderlich und in ihrem Umfang und ihrer Ausführung in vollem Umfang angemessen. Die Zuwendung durch das BMBF war unbedingt erforderlich, um das beantragte Projekt durchführen zu können. Die dem Institut für Meereskunde zur Verfügung stehenden Grundausrüstungsmittel von der Universität Hamburg reichten nicht aus, um die Personalmittel für den angestellten Wissenschaftler bereitzustellen.

Der voraussichtliche Nutzen und insbesondere die Verwertbarkeit der Ergebnisse des Projektes

Mit dem Hybrid-Modell haben wir einen komplett neuen Modellansatz entwickelt, der großes Potential auch über die hier bearbeitete Aufgabenstellung hinaus bietet. Alle nötigen Programmskripte, das austrierte Modell selbst und eine ausführliche Dokumentation wurden vollumfänglich öffentlich gemacht. Unsere Hoffnung ist, dass im Sinne des Open-Source-Gedankens andere Arbeitsgruppen auf unsere Pionierarbeit aufbauen können und den Ansatz weiterentwickeln, auch in Bezug auf andere Fragestellungen. Hierbei ist es auch von großem Vorteil, dass alle zugrundeliegenden Daten frei zugänglich und im Internet verfügbar sind (https://github.com/jbecherer/MHW_hybrid_model).

Der Mehrwert der Hybridmodell-Simulationen bestand zum einen in der realistischeren Reproduktion der vergangenen, heutigen und zukünftigen Entwicklung von marinen Hitzewellen in der Nordsee-Region unter Berücksichtigung von Wechselwirkungen zwischen Ozean und Atmosphäre. Insbesondere die durchgeführten Zukunftsprojektionen bilden eine wertvolle Basis für die Untersuchung potentieller klimabedingter Änderungen in der Nordsee, die von globalen Klimamodellen in dieser Auflösung nicht abgebildet werden können.

Bekannt gewordene Ergebnisse von dritter Seite

Während der Projektlaufzeit sind uns keine relevanten Ergebnisse von anderen Stellen zu der hier bearbeiteten speziellen Thematik bekannt geworden.

Im Rahmen des Projektes entstandene Publikationen

Becherer, J., Pohlmann, T. (2025). Improving Marine Heatwave Statistics in Global Climate Models Using Machine Learning. In review: Climate Dynamics.

Autor:

Thomas Pohlmann, Universität Hamburg, Institut für Meereskunde