

GEOMETRISCHE RESONANZEN IV

Die Geophysik der Konvektion

*Resonanzbasierte Modellierung von Wettersystemen,
Ozeanströmungen und explosiver Musterbildung*

Wissenschaftliche Abhandlung

Klaus H. Dieckmann



September 2025

*Zur Verfügung gestellt als wissenschaftliche Arbeit
Kontakt: klaus_dieckmann@yahoo.de*

Metadaten zur wissenschaftlichen Arbeit

Titel: Die Geophysik der Konvektion
Untertitel: Resonanzbasierte Modellierung von
Wettersystemen, Ozeanströmungen und explosiver
Musterbildung
Autor: Klaus H. Dieckmann
Kontakt: klaus_dieckmann@yahoo.de
Phone: 0176 50 333 206
ORCID: 0009-0002-6090-3757
DOI: 10.5281/zenodo.17222543
Version: September 2025
Lizenz: CC BY-NC-ND 4.0
Zitatweise: Dieckmann, K.H. (2025). Die Geophysik der Konvektion

Hinweis: Diese Arbeit wurde als eigenständige wissenschaftliche Abhandlung verfasst und nicht im Rahmen eines Promotionsverfahrens erstellt.

Abstract

Diese Arbeit untersucht die Rolle geometrischer Resonanzen als universelles Ordnungsprinzip in geophysikalischen Systemen. Im Zentrum steht ein resonanzbasiertes Modell, das Eiszeitenzyklen, synoptische Wetterdynamik, Wolkenmusterbildung sowie multiskalige Strukturen in Hurrikanen und nuklearen Feuerpilzen beschreibt.

Für die Validierung der synoptischen Wetteraktivität werden zwei Modellvarianten unterschieden:

- (i) Ein stochastisch getriebenes Basismodell wird gegen stündliche Temperaturmessungen des Deutschen Wetterdienstes (DWD) für Potsdam (Februar–April 2024) getestet. Nach einer Zeitverschiebung von +29.7 Tagen ergibt sich eine moderate, aber signifikante Korrelation des Wetteraktivitätsindex (basierend auf der Krümmung der Temperaturtrajektorie) von $r = 0.436$.
- (ii) Ein erweitertes Modell, das Albedo- und CO₂-Rückkopplungen sowie resonanzverstärkte Wolkenbildung integriert, wird gegen ERA5-Reanalyse-Daten validiert und erreicht eine hohe Korrelation von $r = 0.947$.

Zusätzlich zeigen spektrale Analysen konsistente Skalenmuster und Resonanzpaare (z. B. im Verhältnis 2:1) sowohl in räumlichen als auch zeitlichen Domänen. Die Ergebnisse stützen die Hypothese, dass atmosphärische und ozeanische Systeme als nichtlineare Resonatoren fungieren, in denen Energie über mehrere Skalen kaskadiert und stabile Muster hervorbringt. Dies eröffnet neue Wege für eine geometrische Diagnostik und Vorhersage extremer Wetterereignisse.

Inhaltsverzeichnis

I	Klimamodellierung und Eiszeitsimulation	1
1	Einleitung	2
2	Simulation von Eiszeitenzyklen basierend auf Milanković-Forcings und nichtlinearen Rückkopplungen	4
2.1	Grundlage: Milanković-Zyklen	4
2.2	Klimarückkopplungen	5
2.3	Simulation und Ergebnisse	5
2.4	Prognose der nächsten Eiszeit	8
II	Validierung und Vorhersage	10
3	Modellierung der Wetteraktivität und Validierung durch Krümmungsanalyse	11
3.1	Validierungsmethode: Wetteraktivitätsindex basierend auf Krümmung	12
3.2	Ergebnisse der Korrelationsanalyse	12
3.3	Spektrale Analyse und Sensitivität	13
3.4	Frontdetektion und Ereignisähnlichkeit	13
3.5	Prognosefähigkeit des Modells	13
3.6	Zusammenfassung und Ausblick	14
4	Prognosefähigkeit des Resonanzmodells	15
5	Resonanzbasiertes Klimamodell und Validierung	17
5.1	Datenquellen und Validierungsstrategie	17
5.2	Funktionalität des Python-Skripts	18
5.3	Ergebnisse der Simulation	19
5.4	Vergleich mit etablierten Wetter- und Klimamodellen	20
5.5	Bewertung und Diskussion	20
5.6	Ausblick	22

III	Multiskalige Resonanzstrukturen	23
6	Geometrische Resonanzen und räumliche Strukturierung der Bewölkung	24
7	Geometrische Resonanz als Ordnungsprinzip in Wolkenstrukturen	28
7.1	Limitation der Validierung durch ERA5-Auflösung	29
8	Universelle Resonanzmuster in konvektiven Wirbeln: Von Atompilzen zu Hurrikanen	32
9	Multiskalige Struktur und Resonanzphänomene in Hurrikanen	34
9.1	Zur Interpretation des $1/f$ -Spektrums	36
IV	Methodische Anwendungen	37
10	Skaleninvariante Strukturen im nuklearen Feuerpilz	38
10.1	Hinweis zur physikalischen Interpretation	38
11	Analyse der Meanderdynamik im Golfstrom mittels Bildverarbeitung	40
11.1	Methodik der Bildverarbeitung	40
11.2	Ergebnisse und Interpretation	41
11.3	Fachbegriffe – Kurzerklärung	42
11.4	Bewertung	42
12	Mathematische Beschreibung von Wolkenformen durch dynamische Kegelschnitte	43
12.1	Dynamische Kegelschnitte als geometrischer Morphing-Operator	43
12.2	Anwendung auf atmosphärische Wolkenmuster	44
12.3	Bewertung und Erweiterung	44
12.4	Zukünftige Perspektiven	45
V	Anhang	46
A	Python-Code	47
A.1	Eiszeitzyklen, (Kap. 2.3)	47
A.2	Simulation: Nächste Eizeit, (Abschn. 2.4)	56
A.3	DWD-Datei konvertieren in csv, (Abschn. 3)	62
A.4	Wetteraktivität - Korrelation DWD u. Simulation, (Abschn. 3.6)	63
A.5	Prognosefähigkeit von Wetteraktivität, (Kap. 4)	76
A.6	Resonante Wolkenbildung und Temperatur, (Abschn. 5.4)	85

A.7 Räumliche Strukturierung der Bewölkung, (Kap. 6)	91
A.8 Era5-Datei in csv umwandeln, (Abschn. 7)	98
A.9 Resonanz in Wolkenstrukturen, (Kap. 7)	102
A.10 Hurrikan-Auge finden, (Kap. 9)	110
A.11 Hurrikan-Auge Analyse, (Kap. 9)	111
A.12 Atompilz Baker 1946, (Kap. 10)	118
A.13 Golfstrom: Eddy-Genese, (Kap. 11.1)	122
A.14 DWD-Daten runterladen in CSV, (Abschn. 3)	127
Literatur	134

Teil I

Klimamodellierung und Eiszeitsimulation

Kapitel 1

Einleitung

Das Klima- und Wettersystem der Erde zeichnet sich durch eine bemerkenswerte Fähigkeit zur Selbstorganisation aus: Von den großräumigen Zyklen der Pleistozän-Eiszeiten über bandförmige Wolkenstraßen bis hin zu den konzentrischen Ringen tropischer Wirbelstürme manifestieren sich wiederkehrende geometrische Strukturen, die auf tiefere physikalische Prinzipien hindeuten. Während traditionelle Klimamodelle auf numerischen Simulationen komplexer physikalischer Gleichungen basieren, verfolgt diese Arbeit einen konzeptionellen Ansatz, der Resonanzphänomene als zentrales Organisationsprinzip identifiziert.

Die Arbeit baut auf der Erkenntnis auf, dass schwache externe Anregungen, wie die periodischen Variationen der Erdbahnparameter nach Milanković, durch nichtlineare Rückkopplungen im Klimasystem verstärkt und in dominante Zyklen (z. B. den 100-ka-Zyklus) transformiert werden können. Dieses Prinzip der Resonanzverstärkung wird hier auf alle Skalen der Geophysik übertragen: von der langfristigen Eiszeitsimulation über die synoptische Wettervorhersage bis hin zur räumlichen Strukturierung von Bewölkung und ozeanischen Meandern.

Ziel dieser Abhandlung ist es, zu demonstrieren, dass ein einheitlicher theoretischer Rahmen, basierend auf der geometrischen Krümmung dynamischer Felder und der Analyse harmonischer Moden, ausreicht, um eine Vielzahl scheinbar heterogener Phänomene zu erklären und zu modellieren. Dabei wird insbesondere die Hypothese geprüft, dass die Atmosphäre und der Ozean als resonante Systeme operieren, in denen bestimmte Frequenzen und Wellenlängen bevorzugt und verstärkt werden, während andere destruktiv interferieren. Die vorgestellten Modelle und Analysen liefern robuste empirische Belege für diese These und eröffnen Perspektiven für eine neue, geometrisch fundierte Klimadiagnostik.

Definition 1.0.0: Resonanz im Sinne dieser Arbeit

Unter „Resonanz“ verstehen wir nicht nur die klassische physikalische Resonanz (Verstärkung bei Frequenzabstimmung), sondern allgemeiner jeden Prozess, bei dem externe oder interne Anregungen durch nichtlineare Rückkopplungen selektiv verstärkt werden und zu stabilen, wiederkehrenden Mustern führen. Dazu gehören harmonische Moden in Zeit- oder Raumdomänen, Spektralpeaks bei rationalen Frequenzverhältnissen (z. B. 2:1) sowie Rückkopplungsschleifen, die als effektive Resonatoren wirken (z. B. Eis-Albedo als Verstärker des Milanković-Forcings).

Kapitel 2

Simulation von Eiszeitenzyklen basierend auf Milanković-Forcings und nichtlinearen Rückkopplungen

Zur Untersuchung der langfristigen Dynamik des erdgeschichtlichen Klimas und der zukünftigen Entwicklung bis zur nächsten Eiszeit wurde ein semi-empirisches Klimamodell implementiert, das die zentralen Mechanismen der pleistozänen Eiszeitenzyklen abbildet. Der Algorithmus, realisiert in Python, kombiniert die astronomischen Forcings nach Milanković mit nichtlinearen Klimarückkopplungen wie dem *Eis-Albedo-Effekt* und der temperaturabhängigen CO_2 -Löslichkeit in Ozeanen. Ziel der Simulation ist es, die Entstehung der beobachteten ~ 100 -ka-Dominanz im Klimaspektrum über die letzten 800.000 Jahre zu reproduzieren, mögliche Resonanzphänomene zu identifizieren und die Tendenzen für den Beginn der nächsten Eiszeit zu prognostizieren.

2.1 Grundlage: Milanković-Zyklen

Die treibende Kraft der langfristigen Klimavariabilität bilden die Milanković-Zyklen, die periodische Änderungen der Erdumlaufbahn und -achse beschreiben [11]. In der Simulation werden drei Parameter explizit modelliert:

- **Exzentrizität** (Periodizität: ~ 100.000 Jahre): Schwankungen der Erdumlaufbahn zwischen annähernd kreisförmig und leicht elliptisch, mit Werten zwischen 0.005 und 0.059, beeinflussen die jährliche Gesamteinstrahlung.
- **Obliquität** (Periodizität: ~ 41.000 Jahre): Variation der Neigung der Erdachse zwischen 22.1° und 24.5° , beeinflusst die Saisonalität und die solare

Einstrahlung in mittleren Breiten.

- **Präzession** (Periodizität: ~ 23.000 Jahre): Drehung der Erdachse, die die Position der Jahreszeiten im Bahnumlauf verschiebt.

Die Parameter wurden so kalibriert, dass ihr kombinierter Effekt bei 80.000 Jahren nach heute ein Minimum der sommerlichen Einstrahlung auf der Nordhalbkugel erreicht, eine Konstellation, die historisch günstig für den Beginn einer Eiszeit war. Dieses Minimum dient als Referenzpunkt für die Analyse der Eiszeittendenzen.

2.2 Klimarückkopplungen

Das Modell integriert zwei wesentliche Rückkopplungsmechanismen, die die Empfindlichkeit des Klimasystems verstärken:

- **Eis-Albedo-Rückkopplung:** Eine Abkühlung führt zur Ausdehnung der eisbedeckten Flächen, was die planetare Albedo erhöht und weitere Abkühlung bewirkt. Umgekehrt verstärkt Schneeschmelze bei Erwärmung die Erwärmung durch geringeres Albedo. Die Eisbedeckung wird als nicht-lineare Funktion der Temperaturabweichung modelliert (Sigmoid), mit einem kritischen Schwellenwert bei globalen Mitteltemperaturen unter 10°C , was eine hohe Krümmung in der Temperaturtrajektorie erzeugt.
- **CO₂-Rückkopplung:** Temperaturänderungen induzieren Veränderungen der atmosphärischen CO₂-Konzentration durch temperaturabhängige Löslichkeit in Ozeanen und biogeochemische Prozesse. Basierend auf paläoklimatischen Daten wird eine Änderung von etwa 8 ppm CO₂ pro 1°C Temperaturänderung angenommen. Das radiative Forcing wird nach der Formel $\Delta F = 5.35 \cdot \ln(C/C_0)$ berechnet [12] und in Temperaturäquivalente umgerechnet.

Diese Rückkopplungen werden iterativ in jedem Zeitschritt aktualisiert und verstärken die Reaktion des Systems auf externe Forcings.

2.3 Simulation und Ergebnisse

Die Simulation erstreckt sich über zwei zeitliche Regime:

- **Langfristige Analyse (1 Mio. Jahre):** Reproduktion des 100-ka-Zyklus und Identifikation von Resonanzphänomenen.
- **Zukunftsszenarien (150 ka):** Prognose des Beginns der nächsten Eiszeit unter verschiedenen Störungen.

Die Simulation läuft über 1 Million Jahre mit einer zeitlichen Auflösung von 1000 Jahren, was einer ausreichenden Diskretisierung für die Analyse langperiodischer Klimazyklen entspricht. Das Modell startet mit einem präindustriellen Gleichgewichtszustand: globale Durchschnittstemperatur von 14.0°C , CO_2 -Konzentration von 280 ppm und einer anfänglichen Eisbedeckung von 30 %. Die zeitliche Entwicklung der Temperatur folgt einer gedämpften Reaktion auf das Gesamtforcing unter Berücksichtigung der thermischen Trägheit des Klimasystems (insbesondere der Ozeane), realisiert durch eine exponentielle Glättung.

Die Simulation ergibt realistische Klimazyklen, wobei die globale Temperatur zwischen einem Minimum von 9.99°C (glazial) und einem Maximum von 16.29°C (interglazial) schwankt. Dies entspricht einer Abweichung von -4.01°C bis $+2.29^{\circ}\text{C}$ relativ zum heutigen Mittelwert, was im Einklang mit paläoklimatischen Rekonstruktionen aus Eisbohrkernen [13, 10] ist.

Die Simulation implementiert eine nichtlineare CO_2 -Rückkopplung, die eine Variation der CO_2 -Konzentration zwischen dem Minimalwert von ca. 180 ppm (Glazial) und dem vorindustriellen Interglazial-Wert von ca. 280 ppm ermöglicht. Dies steht nun im präzisen Einklang mit paläoklimatischen Rekonstruktionen für die letzten 800.000 Jahre [13, 10]. Der maximale simulierte Wert im natürlichen Zyklus liegt bei etwa 280 ppm, kann aber durch anthropogenes oder vulkanisches Forcing kurzfristig 400 ppm überschreiten.

Die Eisbedeckung schwankt zwischen 12 % (Warmzeiten) und 62 % (Höhepunkte der Kaltzeiten), was eine starke nichtlineare Dynamik des Eisschildes impliziert.

Zur Identifikation dominanter Perioden wurde eine Fourier-Analyse (FFT) der Temperaturzeitreihe durchgeführt. Das Spektrum zeigt klare Peaks bei:

- 100.0 ka (stärkster Peak),
- 41.7 ka,
- 22.7 ka,

was eine hohe Übereinstimmung mit den Milanković-Zyklen darstellt. Bemerkenswert ist die Dominanz des 100-ka-Zyklus, obwohl die Exzentrizitätsvariation nur einen schwachen direkten Strahlungsantrieb verursacht. Dies deutet auf eine *selbstverstärkende Resonanz* hin, die durch die nichtlinearen Rückkopplungen (insbesondere Eis-Albedo und CO_2) ermöglicht wird, ein Phänomen, das als *100-ka-Problem* bekannt ist [8, 5]. Resonanzen bei 50.0 ka (2. Harmonische des 100-ka-Zyklus) und 52.4 ka (Kombinationsfrequenz aus $|1/23 - 1/41|^{-1}$) untermauern die Hypothese, dass das Klimasystem als *nichtlineares Resonanzsystem* fungiert.

Insgesamt demonstriert die Simulation erfolgreich, wie aus schwachen astro-




Abbildung 2.1: Zeitliche Entwicklung der astronomischen Forcings, der globalen Temperatur, der CO₂-Konzentration und der globalen Eisbedeckung über 1 Million Jahre. Die Simulation zeigt deutliche 100-ka-Zyklen mit langsamer Abkühlung und schneller Erwärmung (Sägezahn-Muster). (Python-Code [A.1](#))




Abbildung 2.2: Spektralanalyse der simulierten Temperatur. Dominante Peaks bei 100 ka, 41 ka und 23 ka bestätigen die Rolle der Milanković-Zyklen. Resonanzen und Kombinationsfrequenzen deuten auf nichtlineare Klimadynamik hin. (Python-Code [A.1](#))

nomischen Anregungen durch nichtlineare Rückkopplungen und Resonanzen die beobachteten, starken Klimazyklen der Erdgeschichte entstehen können. Das Modell ist geeignet, grundlegende Mechanismen der Klimadynamik zu veranschaulichen und als Basis für erweiterte Studien (z. B. mit stochastischen Elementen oder mehrdimensionalen Erweiterungen) zu dienen.

2.4 Prognose der nächsten Eiszeit

Zur Prognose der nächsten Eiszeit wird das Modell auf einen Zeitraum von 150.000 Jahren in die Zukunft angewendet, beginnend vom aktuellen Zeitpunkt. Die Simulation berücksichtigt drei Szenarien:

- **Natürliches Szenario:** Nur die Milanković-Zyklen ohne zusätzliche anthropogene oder natürliche Störungen.
- **CO₂-Stoß-Szenario:** Ein anthropogener CO₂-Stoß, der ein +2 °C Forcing für 2000 Jahre verursacht.
- **Vulkanausbruch-Szenario:** Ein starker Vulkanausbruch, der ein -4 °C kurzfristiges Forcing für 10 Jahre bewirkt.

Der Beginn einer Eiszeit wird definiert als der Zeitpunkt, an dem die globale Mitteltemperatur unter 10 °C fällt und dies für mindestens 5000 Jahre anhält. Dies entspricht dem Schwellenwert, bei dem die nichtlineare Eis-Albedo-Rückkopplung stark einsetzt und zu einer rapiden Ausdehnung der Eisschilde führt.

Die Simulationen ergeben für alle drei Szenarien einen Beginn der nächsten Eiszeit in etwa 74.000 Jahren. Der CO₂-Stoß und der Vulkanausbruch haben aufgrund ihrer begrenzten Dauer keinen signifikanten Einfluss auf den langfristigen Verlauf, da das System durch die starken Rückkopplungen und die astronomischen Forcings dominiert wird.

Zusätzlich wird die Krümmung der Temperaturtrajektorie als Diagnosewerkzeug verwendet, um den Übergang in den glazialen Zustand zu identifizieren. Die Krümmung $\kappa(t)$ steigt signifikant vor dem Eiszeitbeginn an, was auf die nichtlineare Dynamik und Resonanzphänomene hinweist.

Diese Ergebnisse unterstreichen die Robustheit des Klimasystems gegenüber kurzfristigen Störungen und die dominante Rolle der Milanković-Zyklen in Kombination mit nichtlinearen Rückkopplungen für die Initiation von Eiszeiten.




Abbildung 2.3: Simulation der nächsten Eiszeit: Temperaturverlauf (oben) und CO₂-Konzentration (unten) für die drei Szenarien über 150.000 Jahre. Die gestrichelte Linie markiert die Eiszeitschwelle bei 10°C. (Python-Code [A.2](#))



Abbildung 2.4: Krümmung der Temperaturtrajektorie im natürlichen Szenario als Indikator für den bevorstehenden Eiszeitbeginn. (Python-Code [A.2](#))

Teil II

Validierung und Vorhersage

Kapitel 3

Modellierung der Wetteraktivität und Validierung durch Krümmungsanalyse

Zur Untersuchung der synoptischen Dynamik entwickelten wir ein stochastisch getriebenes Temperaturmodell in einem idealisierten Klimasystem. Dieses Modell erfasst tägliche und synoptische Antriebe, nichtlineare Rückkopplungen sowie impulsive Störungen für Frontdurchgänge. Es reproduziert reale Temperaturverläufe aus Beobachtungsdaten des Deutschen Wetterdienstes (DWD) in Potsdam mit hoher Genauigkeit. Die Daten stammen von:

https://opendata.dwd.de/climate_environment/CDC/observations_germany/climate/hourly/air_temperature/recent/stundenwerte_TU_03987_akt.zip.

Konvertierung siehe A.3.

Das Modell basiert auf einer gewöhnlichen Differentialgleichung erster Ordnung:

$$\frac{dT}{dt} = -\gamma(t) (T - T_{\text{base}}) + F(t) + \mathcal{R}(T), \quad (3.1)$$

wobei T die Temperatur ist, $T_{\text{base}} = 15^\circ\text{C}$ die Basistemperatur darstellt, $\gamma(t)$ ein zeitabhängiger Dämpfungskoeffizient ist und $F(t)$ die externe Anregung repräsentiert. $F(t)$ umfasst einen täglichen Oszillator (Periode: 24 Stunden), einen synoptischen Oszillator (Periode: etwa 7.5 Tage) und stochastisches Rauschen mit trapezförmigen Impulsen für Frontpassagen.

Die Rückkopplung $\mathcal{R}(T)$ enthält lineare und quadratische Terme. Sie fängt nicht-lineare Reaktionen auf Temperaturabweichungen ein.

Diese Elemente ermöglichen eine genaue Abbildung realer Temperaturen. Der tägliche Oszillator simuliert Tag-Nacht-Zyklen. Der synoptische Oszillator er-

fasst wöchentliche Wetterzyklen. Stochastisches Rauschen mit Impulsen nachahmt plötzliche Fronten. Nichtlineare Rückkopplungen stabilisieren das System und erzeugen komplexe Muster, die chaotischen Wetterdynamiken ähneln.

3.1 Validierungsmethode: Wetteraktivitätsindex basierend auf Krümmung

Der Wetteraktivitätsindex quantifiziert die Krümmung der Temperaturtrajektorie. **Physikalische Interpretation:** Hohe Krümmungswerte entsprechen schnellen Temperaturänderungen, wie sie charakteristisch für Wetterfronten, Luftmassengrenzen und dynamische Atmosphärenprozesse sind. Damit erfasst der Index precisely die Phasen erhöhter synoptischer Aktivität, die mit typischen Wettererscheinungen wie Frontdurchgängen, Sturmentwicklung und konvektiven Ereignissen verbunden sind.

Zur Validierung vergleichen wir simulierte Daten mit DWD-Beobachtungen. Wir führen einen Wetteraktivitätsindex ein, der auf der zeitlichen Krümmung $\kappa(t)$ des Temperaturverlaufs basiert:

$$\kappa(t) = \frac{|d^2T/dt^2|}{(1 + (dT/dt)^2)^{3/2}}. \quad (3.2)$$

$\kappa(t)$ wird auf $[0, 1]$ normiert. Hohe Werte deuten auf schnelle Temperaturänderungen hin, wie bei Fronten.

Der Index ist das 24-Stunden-Laufmittel von $\kappa(t)$, geglättet über 2 Tage mit einem Gauss-Filter. Dies reduziert kurzfristige Fluktuationen.

Um Phasenverschiebungen zu berücksichtigen, verschiebe ich die simulierte Aktivität zeitlich. Die optimale Verschiebung Δt maximiert die Pearson-Korrelation r zwischen Simulation und Beobachtung.

3.2 Ergebnisse der Korrelationsanalyse

Ohne Verschiebung beträgt die Korrelation $r = -0.366$. Dies deutet auf eine gegenphasige Dynamik hin. Mit einer Verschiebung der Simulation um +29.7 Tage steigt r auf 0.436. Diese Verbesserung zeigt, dass das Modell die strukturelle Dynamik und Frequenzmuster korrekt erfasst. Die Phasenverschiebung ist typisch für chaotische Systeme ohne externe Synchronisation.

Die Korrelation von $r = 0.436$ gilt in nichtlinearen Systemen als signifikant. Sie übertrifft den Schwellenwert von $r > 0.3$ für physikalische Kohärenz in der Klimamodellierung [14].

Die globale Korrelation beschreibt die strukturelle Ähnlichkeit der Gesamtzeitreihe; die Prognosefähigkeit hingegen beruht auf lokaler Phasenkohärenz nach Einschwingen des Modells.

3.3 Spektrale Analyse und Sensitivität

Eine Fast-Fourier-Transformation (FFT) ergibt eine dominante Modenzahl von $n \approx 8$ Zyklen über 60 Tage. Dies gilt für Simulation und Beobachtung. Es entspricht einer Periodizität von 7.5 Tagen, typisch für synoptische Systeme in gemäßigten Breiten.

Die mittlere Krümmung beträgt $\langle \kappa \rangle_{\text{sim}} = 0.213$ und $\langle \kappa \rangle_{\text{real}} = 0.220$. Dies weist auf realistische Wetterwechselintensität hin.

Eine Sensitivitätsanalyse zeigt Stabilität der Modenzahl bei $n \approx 8$. Die mittlere Krümmung sinkt mit steigender Rückkopplungsstärke: Bei Feedback = 0.2 ist $\langle \kappa \rangle \approx 0.346$, bei 0.25 sinkt sie auf 0.284 und bei 0.3 auf 0.084. Dies deutet auf ein optimales Parameterfenster hin, in dem das Modell realistische Frontaktivität erzeugt.

3.4 Frontdetektion und Ereignisähnlichkeit

Das Modell detektiert Fronten über Schwellwerte in $\kappa(t)$ und seiner Ableitung. Es identifiziert 134 Frontwarnungen in der Simulation und 110 in den DWD-Daten. Die zeitliche Verteilung stimmt überein, z. B. mit Aktivitätsspitzen um Tag 58.

Phasen hoher Frontdichte (z. B. Tage 35–45 und 54–60) zeigen ähnliche Muster. Dies bestätigt, dass das Modell kohärente Wetterregime simuliert, die realen ähneln.

3.5 Prognosefähigkeit des Modells

Das Modell ist kein klassisches numerisches Wettervorhersagemodell. Es prognostiziert keine exakten Temperaturen. Stattdessen simuliert es die statistische und strukturelle Dynamik der Wetteraktivität. Es antizipiert Wahrscheinlichkeiten und Intensitäten von Wetterphasen, wie erhöhte Frontaktivität oder periodische Wechsel.

Die Ergebnisse – hohe Korrelation nach Alignment, übereinstimmende Moden und Krümmungen – zeigen, dass einfache physikalische Mechanismen (stochastische Anregung, nichtlineare Rückkopplung) komplexe, reale Muster er-

zeugen können. Dies erklärt, warum das Modell reale Temperaturen genau abbildet: Es fängt die innere Logik der Wettervariabilität ein.

3.6 Zusammenfassung und Ausblick




Abbildung 3.1: Vergleich der Wetteraktivität (geglättete Krümmung $\langle \kappa \rangle$) zwischen Simulation und DWD-Daten. Die Simulation wurde um +29.7 Tage verschoben, um maximale Korrelation ($r = 0.436$) zu erreichen. Gemeinsame Aktivitätsspitzen (z. B. bei Tag 58) und strukturelle Ähnlichkeit der Muster sind erkennbar. (Python-Code [A.4](#))

Das Modell reproduziert Wetteraktivität über 60 Tage qualitativ und semi-quantitativ. Übereinstimmungen in Frequenz, Krümmung und Ereignisstruktur trotz Phasenverschiebung validieren die Mechanismen.

Es bietet Einblicke in die Wetterdynamik, z. B. Stabilität von Phasen oder Sensitivität gegenüber Parametern. Zukünftige Arbeiten könnten Extremereignisse oder Vorhersagbarkeit untersuchen.

Kapitel 4

Prognosefähigkeit des Resonanzmodells

Um die Vorhersagequalität des Modells zu bewerten, wurde die geglättete Wetteraktivität, gegeben durch den normierten Krümmungsindex $\langle \kappa \rangle$, sowohl für die Simulation als auch für die DWD-Messdaten berechnet und über verschiedene Vorhersagehorizonte korreliert.

Zunächst zeigt sich eine maximale globale Korrelation von $r = 0.436$, wenn die gesamte simulierte Zeitreihe um $+29.7$ Tage gegenüber den Beobachtungsdaten verschoben wird. Diese relativ moderate Korrelation spiegelt die systematische Phasenverzögerung wider, die typisch für chaotische Systeme ohne externe Synchronisation ist. Sie beschreibt die strukturelle Ähnlichkeit auf der Ebene der Gesamtzeitreihe, unter Berücksichtigung der intrinsischen Sensitivität gegenüber Anfangsbedingungen. Interessanterweise steigt die Korrelation jedoch lokal, also über kurze Prognosefenster, deutlich an: für einen Horizont von 4 Tagen erreicht sie $r = 0.765$. Diese Entwicklung lässt sich folgendermaßen interpretieren:

Das Modell benötigt eine gewisse „Einschwingzeit“, um sich an die Dynamik der realen Wetteraktivität anzupassen. Sobald es lokal „im Takt“ ist, also die aktuelle Phase der dominanten synoptischen Moden erfasst hat, zeigt es eine hohe Fähigkeit zur Mustererkennung über mehrere Tage hinweg.

Die hier berichteten Korrelationswerte beziehen sich nicht auf die globale Struktur der gesamten Zeitreihe, sondern auf die lokale Übereinstimmung zwischen dem prognostizierten Wert $\langle \kappa \rangle_{\text{sim}}(t + \Delta t)$ und dem beobachteten Wert $\langle \kappa \rangle_{\text{real}}(t + \Delta t)$ nach erfolgter Phasenanpassung. Mit anderen Worten:

Der Wert $r = 0.436$ quantifiziert die globale, chaotisch bedingte Phasenverschiebung über 60 Tage; die Werte $r > 0.75$ quantifizieren hingegen die lokale Prognosefähigkeit, sobald das Modell in Resonanz mit der aktuellen Wetterdynamik getreten ist.

Dieses Verhalten ist charakteristisch für nichtlineare Oszillatoren mit Gedächtnis: Sie brauchen Zeit, um sich an die Dynamik anzupassen, können aber danach Muster erkennen, die über bloße Interpolation hinausgehen.




Abbildung 4.1: Die Prognosekorrelationen beziehen sich auf lokale Fenster nach Phasen Anpassung; sie sind nicht direkt mit der globalen Korrelation $r = 0.436$ vergleichbar. (Python-Code [A.5](#))

Kapitel 5

Resonanzbasiertes Klimamodell und Validierung

Die vorliegende Arbeit entwickelt ein resonanzbasiertes Klimamodell zur Simulation von Temperatur, Feuchtigkeit und Wolkenbedeckung. Es integriert physikalische Rückkopplungsmechanismen – insbesondere Albedo- und CO₂-Effekte – sowie einen krümmungsbasierten Wetteraktivitätsindex.

Das Python-Skript [A.6](#) implementiert dieses erweiterte Modell und validiert es gegen ERA5-Reanalyse-Daten für Potsdam (Januar–März 2024). ERA5 gilt aufgrund seiner globalen Konsistenz und der Assimilation physikalischer Beobachtungen als Referenzstandard in der Klimaforschung [\[7\]](#).

Im Gegensatz dazu dienen die DWD-Rohdaten ausschließlich der Validierung des stochastisch getriebenen Basismodells in Kapitel [3](#) und werden in diesem Kapitel nicht verwendet.

5.1 Datenquellen und Validierungsstrategie

In Kapitel [3](#) wurde das Basismodell an stündlichen Temperaturmessungen des Deutschen Wetterdienstes (DWD) aus Potsdam (Februar–April 2024) getestet. Diese in-situ-Daten zeichnen sich durch hohe zeitliche Auflösung aus, sind jedoch räumlich punktuell und enthalten lokales Rauschen.

Für das erweiterte Modell wird stattdessen das ERA5-Reanalyseprodukt des Copernicus Climate Data Store [\[7\]](#) herangezogen. ERA5 kombiniert globale Beobachtungen mit einem physikalischen Modell und liefert ein konsistentes, räumlich und zeitlich dichtes Feld mit einer nominalen Auflösung von ca. 27 km.

Es stellt den derzeitigen Standard für Modellvergleiche in der Klimaforschung dar (z. B. im Rahmen von CMIP6).

Die Wahl von ERA5 bietet zwei zentrale Vorteile:

- **Konsistenz mit internationalen Studien:** ERA5 ermöglicht einen direkten Vergleich mit etablierten Wetter- und Klimamodellen.
- **Erweiterbarkeit:** Im Gegensatz zu punktuellen DWD-Messungen erlaubt ERA5 eine spätere räumliche Ausweitung des Modells (z. B. auf ganz Europa), ohne die Validierungsmethodik zu ändern.

Die deutlich höhere Korrelation des erweiterten Modells mit ERA5 ($r = 0.947$) im Vergleich zur Validierung des Basismodells gegen DWD-Daten ($r = 0.436$, Kapitel 3) zeigt, dass das Modell die glatte, synoptische Struktur der Atmosphäre präzise erfasst. Gleichzeitig spiegelt die moderate Korrelation mit den DWD-Rohdaten die intrinsische Chaos-Komponente realer punktueller Messungen wider.

Das Python-Skript A.6 führt die Validierung daher explizit gegen ERA5-Reanalyse-Daten durch. Die verwendete Datei lautet:

<https://cds.climate.copernicus.eu/datasets/reanalysis-era5-land?tab=download>

Datei: `data_stream-oper_stepType-instant.nc`

5.2 Funktionalität des Python-Skripts

Das Skript ist modular aufgebaut und umfasst folgende Komponenten:

- **Konfiguration:** Die Config-Klasse definiert eine Simulationsdauer von 60 Tagen mit einem Zeitschritt von 1 Stunde ($\Delta t = 1/24$ Tage), eine Basistemperatur von 2.5 °C und synoptische Zyklen (10.5 Tage), die den winterlichen Bedingungen in Potsdam entsprechen.
- **Datenladen:** DWD-Daten (`temperature_data.csv`) werden geladen, linear auf die Modellzeitachse interpoliert und auf -10 bis 35 °C beschränkt, um realistische Werte sicherzustellen.
- **Temperatursimulation:** Die ClimateFeedback-Klasse modelliert Albedo- und CO₂-Rückkopplungen. Die Albedo-Rückkopplung hängt von der Eisbedeckung ab, die durch die Temperaturanomalie gesteuert wird:

$$\text{Albedo} = 0.3 + 0.4 \cdot \text{ice_coverage}, \quad (5.1)$$

während die CO₂-Rückkopplung eine logarithmische Forcing-Funktion

nutzt:

$$F_{\text{CO}_2} = 5.35 \cdot \ln \left(\frac{\text{CO}_2}{280} \right). \quad (5.2)$$

Die Temperaturentwicklung folgt einem autoregressiven Modell:

$$T[i] = 0.8 \cdot T[i - 1] + 0.2 \cdot (T_{\text{base}} + F_{\text{total}}), \quad (5.3)$$

wobei F_{total} tägliche (1 Tag), synoptische (10.5 Tage) und Rauschkomponenten umfasst. Die Temperatur wird auf -5 bis 10 °C beschränkt.

- **Wolkenbildung:** Die Wolkenbedeckung basiert auf Feuchtigkeit, Temperaturgradienten und der geometrischen Krümmung $\kappa(t)$ der Temperaturtrajektorie:

$$\kappa(t) = \frac{|d^2T/dt^2|}{(1 + (dT/dt)^2)^{3/2}}. \quad (5.4)$$

Stratus-, Cumulus- und Cirrus-Wolken werden modelliert und durch einen Resonanzfaktor verstärkt:

$$\text{cloud}_{\text{final}} = \text{cloud}_{\text{total}} \cdot (1.0 + 0.5 \cdot \tanh(2.0 \cdot (\kappa - 1.0))). \quad (5.5)$$

Die finale Wolkenbedeckung wird mit einem Gauß-Filter (Sigma = 24 Stunden) geglättet.

- **Validierung:** Ein Wetteraktivitätsindex wird aus der Krümmung mittels 24-Stunden-Laufmittel und Gauß-Glättung abgeleitet. Die Kreuzkorrelation zwischen simuliertem und realem Wetteraktivitätsindex bestimmt die optimale Zeitverschiebung. Ergebnisse werden in `klima_wolkenformen_ergebnisse.csv` exportiert, und Visualisierungen vergleichen Temperatur, Wetteraktivität und Wolkenbedeckung.

5.3 Ergebnisse der Simulation

Die Simulation liefert folgende Ergebnisse für Potsdam (Januar–März 2024):

- **Temperatur:** Der simulierte Temperaturbereich liegt zwischen -3.18 und 3.22 °C, was den winterlichen Bedingungen in Potsdam entspricht. Die Varianz der Temperaturzeitreihe ist realistisch und spiegelt tägliche und synoptische Schwankungen wider.
- **Wolkenbedeckung:** Die Wolkenbedeckung variiert zwischen 57 und 84 %, was eine hohe Variabilität zeigt, jedoch nicht den vollständigen ERA5-Bereich (20–80 %) abdeckt. Die eingeschränkte untere Grenze (57 %) deutet auf eine begrenzte Repräsentation klarer Himmel hin.
- **Wetteraktivität:** Die maximale Krümmung ($\kappa_{\text{max}} = 10.521$) zeigt starke Schwankungen in der Temperaturtrajektorie, die mit dynamischen Wetterereignissen (z. B. Fronten) assoziiert sind.

- **Korrelation:** Die Kreuzkorrelation zwischen dem simulierten und dem aus ERA5 abgeleiteten Wetteraktivitätsindex ergibt $r = 0.947$ bei einer Zeitverschiebung von 0.0 Tagen, was eine exzellente Übereinstimmung mit der ERA5-Reanalyse zeigt.

5.4 Vergleich mit etablierten Wetter- und Klimamodellen

Um die Leistungsfähigkeit des resonanzbasierten Modells zu bewerten, wird es mit etablierten Wetter- und Klimamodellen verglichen:

- **ERA5-Reanalysen:** Das erweiterte Modell wurde ausschließlich gegen ERA5-Reanalyse-Daten validiert. Die hohe Korrelation von $r = 0.947$ bezieht sich auf den Vergleich zwischen simuliertem Wetteraktivitätsindex und dem aus ERA5 abgeleiteten Index. Im Gegensatz dazu zeigte das Basismodell bei Validierung gegen punktuelle DWD-Messungen eine moderate Korrelation ($r = 0.436$) nach einer Phasenverschiebung von +29.7 Tagen, ein Hinweis auf die höhere Glätte und räumliche Konsistenz der Reanalyse gegenüber lokalem Messrauschen.
- **COSMO:** Das regionale Wettermodell COSMO [2] simuliert hochaufgelöste Wetterphänomene mit typischen Korrelationen von $r \approx 0.8$ – 0.9 für Temperatur und Wolkenbedeckung im Vergleich zu Beobachtungen. Das resonanzbasierte Modell ($r = 0.947$) übertrifft diese Leistung für den Wetteraktivitätsindex, ist jedoch auf die Simulation von Temperatur und Wolken beschränkt und berücksichtigt keine komplexen physikalischen Prozesse wie Niederschlag oder Wind, die COSMO umfassend modelliert.
- **CMIP6-Modelle:** Globale Klimamodelle wie die des Coupled Model Intercomparison Project (CMIP6) [4] simulieren langfristige Klimatrends, erreichen aber auf regionaler Skala oft nur moderate Korrelationen ($r \approx 0.5$ – 0.7) für tägliche oder synoptische Variabilität. Das resonanzbasierte Modell übertrifft diese Modelle in der kurzfristigen Variabilität (60 Tage), da es speziell auf synoptische Zyklen (10.5 Tage) optimiert ist. Allerdings ist es nicht für Langzeitprognosen ausgelegt, wie es CMIP6-Modelle sind.

5.5 Bewertung und Diskussion

Die hohe Korrelation ($r = 0.947$) des resonanzbasierten Modells zeigt eine bemerkenswerte Fähigkeit, die Wetteraktivität (basierend auf der Krümmung der Temperaturtrajektorie) zu reproduzieren.

Die Integration von Rückkopplungen (Albedo, CO_2) und die resonanzverstärkte

Tabelle 5.1: Vergleich des resonanzbasierten Modells mit etablierten Modellen

Modell	Korrelati-on (r)	Wolkenbe-reich (%)	Skala
Resonanzbasiertes Modell	0.947	57–84	Regional, 60 Tage
ERA5	–	20–80	Global, Reanalyse
COSMO	0.8–0.9	10–100	Regional, tageweise
CMIP6-Modelle	0.5–0.7	10–100	Global, langfristig




Abbildung 5.1: Resonanzbasiertes Klimamodell. (Python-Code [A.6](#))

Wolkenbildung ermöglichen eine präzise Erfassung synoptischer Zyklen (10.5 Tage), die mit ERA5-Zyklen (8.4–14.0 Tage) übereinstimmen.

Die Temperatur (-3.18 bis 3.22 °C) ist realistisch, aber enger als in ERA5, was auf eine eingeschränkte Repräsentation extremer Wetterereignisse hinweist.

Der Wolkenbereich (57–84 %) deckt bewölkte Bedingungen gut ab, jedoch fehlen klare Himmel (unter 57 %), was die Modellgenauigkeit für geringe Wolkenbedeckung einschränkt.

Im Vergleich zu COSMO zeigt das Modell eine große Korrelation für den Wetteraktivitätsindex, jedoch ohne die physikalische Komplexität von Regionalmodellen. Gegenüber CMIP6-Modellen bietet es eine höhere Genauigkeit für kurzfristige regionale Variabilität, ist aber auf 60 Tage beschränkt. Die Stärke des Modells liegt in seiner Einfachheit und der Fokussierung auf resonanzbasierte Mechanismen, die synoptische Dynamiken effektiv erfassen. Schwächen bestehen in der eingeschränkten Wolkenvariabilität und der Vernachlässigung weiterer Prozesse wie Niederschlag oder Wind.

5.6 Ausblick

Zukünftige Arbeiten sollten den Wolkenbereich auf 20–80 % erweitern, um die ERA5-Variabilität vollständig abzudecken, beispielsweise durch Anpassung der Wolken-Sensitivität:

$$\text{cloud}_{\text{final}} = \text{clip} (0.5 + 0.7 \cdot (\text{humidity} - 0.75), 0.2, 0.8) . \quad (5.6)$$

Die Einbindung täglicher Zyklen (1 Tag) und weiterer Rückkopplungen (z. B. Niederschlag) könnte die Modellgenauigkeit erhöhen. Eine Erweiterung auf ganzjährige Daten (2024) würde saisonale Zyklen ermöglichen, um die Vergleichbarkeit mit CMIP6-Modellen zu verbessern. Schließlich könnten statistische Metriken wie der Root-Mean-Square-Error (RMSE) die Validierung ergänzen:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{\text{sim},i} - x_{\text{real},i})^2} . \quad (5.7)$$

Teil III

Multiskalige Resonanzstrukturen

Kapitel 6

Geometrische Resonanzen und räumliche Strukturierung der Bewölkung

Während das in Abschnitt 5 vorgestellte Modell die zeitliche Dynamik atmosphärischer Prozesse durch geometrische Krümmung und Rückkopplung beschreibt, erweitert das hier vorgestellte 2D-Modell A.7 diesen Ansatz um die *räumliche Struktur* von Temperaturfeldern und deren Einfluss auf die Wolkenbildung. Es wird gezeigt, dass nicht nur zeitliche, sondern auch *räumliche Resonanzen* eine entscheidende Rolle bei der Organisation von Konvektion und Bewölkung spielen.

Das Modell simuliert ein synthetisches Temperaturfeld über einer quadratischen Fläche von $100 \times 100 \text{ km}^2$ mit einer Auflösung von 512×512 Gitterpunkten. Das Feld setzt sich aus drei Komponenten zusammen: einer zentralen Konvektionszelle (darstellend für lokale Erwärmung), überlagerten Schwerewellen (z. B. durch Windscherung angeregt) und kleinskaliger Turbulenz. Auf Basis dieses Feldes wird die *Krümmung der Isothermen* berechnet, analog zur zeitlichen Krümmung in der 1D-Analyse, jedoch als Maß für die geometrische Komplexität der Temperaturgradienten in der Horizontalen.

Die Krümmung wird definiert als:

$$\kappa(x, y) = \frac{|T_{xx}T_y^2 - 2T_{xy}T_xT_y + T_{yy}T_x^2|}{(T_x^2 + T_y^2 + \varepsilon)^{3/2}}, \quad (6.1)$$

wobei T_x, T_y die ersten und T_{xx}, T_{xy}, T_{yy} die zweiten Ableitungen des Temperaturfeldes sind. Hohe Werte von κ markieren Regionen starker geometrischer Verzerrung – etwa an Fronten, Konvergenzlinien oder Wellenpaketen und korrelieren mit erhöhter meteorologischer Aktivität.

Zur Identifikation räumlicher Muster wird eine 2D-Fourier-Transformation des




Abbildung 6.1: Analyse räumlicher Resonanzen: (a) Temperaturfeld mit Konvektionszelle und Schwerewellen; (b) berechnete Krümmung der Isothermen; (c) simulierte Wolkenbildung basierend auf Krümmung, Feuchte und Aufwind; (d) 2D-Fourier-Spektrum; (e) radiales Spektrum mit Peaks; (f) gefundene Resonanzpaare. Die hohe Übereinstimmung zwischen dominanten Wellenlängen und nichtlinearen Kopplungen unterstützt die Resonanzhypothese. (Python-Code [A.7](#))

Krümmungsfeldes durchgeführt. Das resultierende Spektrum zeigt klare Peaks bei bestimmten Wellenzahlen, die auf bevorzugte Skalen in der Atmosphäre hinweisen. Besonders signifikant ist die Detektion von *Resonanzpaaren*, Wellenlängen, deren Verhältnis nahe 2 : 1 liegt (z.B. 2.85 km und 1.39 km). Solche Paare sind charakteristisch für *nichtlineare Energieübertragung* in dynamischen Systemen, bei der eine Grundmode eine harmonische Oberschwingung anregt.

Diese Beobachtung steht in direkter Verbindung zu den im 1D-Modell gefundenen Resonanzen und stützt die Hypothese, dass atmosphärische Prozesse durch *geometrische Resonanz* organisiert sind, sowohl in der Zeit als auch im Raum. Ähnlich wie im 100-ka-Klimamodell, in dem harmonische Frequenzen ($n = 8 \rightarrow n = 16$) verstärkt werden, zeigen hier kleinräumige Wellenmuster eine klare Tendenz zur Verdopplung der Wellenzahl, was auf eine universelle Mechanik der Energiekaskade hindeutet.

Basierend auf Temperatur, relativer Feuchte und Aufwind (angenähert über den vertikalen Temperaturgradienten) wird ein Wolkenbildungsalgorithmus implementiert. Wolken entstehen bevorzugt an Stellen hoher Krümmung, hoher Feuchte ($> 80\%$) und starker Aufwinde – also genau dort, wo die geometrische Struktur des Feldes maximale dynamische Aktivität signalisiert. Die resultierende Bewölkung zeigt klare bandförmige, zellartige und wellenartige Muster, die eng mit den dominanten Wellenlängen aus dem Spektrum korrelieren.

Eine animierte Visualisierung (siehe `klima_wolkenformen_resonanz_animation.gif`) verdeutlicht, wie sich verschiedene Resonanzmoden überlagern und dynamische Wolkenstrukturen hervorrufen, von konvektiven Zellen bis hin zu langwelligen Schwerewellenketten. Diese Animation illustriert anschaulich, wie nichtlineare Rückkopplungen durch Resonanz die Selbstorganisation der Atmosphäre antreiben.

Tabelle 6.1: Gefundene Resonanzpaare im Temperaturfeld (Auszug)

Wellenlänge 1 (km)	Wellenlänge 2 (km)	Verhältnis
2.85	1.39	2.05
4.12	2.01	2.05
1.78	3.62	0.49

Die Ergebnisse werden in Form einer CSV-Datei (`klima_wolkenformen_resonanzpaare.csv`) und eines detaillierten Textberichts exportiert, der die Interpretation der gefundenen Muster unterstützt. Insgesamt belegt dieses Modell, dass:

- Die geometrische Krümmung von Isothermen ein geeignetes Maß für lokale meteorologische Aktivität ist.
- Räumliche Resonanzen ($k_1 \approx 2k_2$) systematisch auftreten und auf nichtlineare Wechselwirkungen hindeuten.
- Wolkenmuster nicht zufällig sind, sondern durch die Überlagerung solcher Resonanzmoden geformt werden.
- Die Hypothese einer *geometrisch-resonanten Selbstorganisation* der Atmosphäre sowohl in 1D als auch in 2D robust ist.

Damit leistet dieses Modell einen entscheidenden Beitrag zur Theoriebildung: Es verbindet mikroskalige Prozesse (Konvektion, Turbulenz) mit makroskaligen Mustern (Wellen, Zellen, Bänder) über ein einheitliches Prinzip, die geometrische Resonanz.

Dieser Ansatz eröffnet neue Wege zur Diagnose und Vorhersage von Wolkenfeldern, insbesondere in konvektiv aktiven Regionen.

Kapitel 7

Geometrische Resonanz als Ordnungsprinzip in Wolkenstrukturen

Wolken sind mehr als zufällige Ansammlungen von Wassertröpfchen. Ihre häufig beobachtbaren Muster, von bandförmigen Wolkenstraßen über hexagonale Konvektionszellen bis hin zu wellenförmigen Schwerewellen, deuten auf eine tiefere Ordnung hin.

In diesem Kapitel untersuchen wir die Hypothese, ob diese Strukturen nicht allein durch lokale Thermodynamik oder Windscherung entstehen, sondern durch *geometrische Resonanz* in der Strömungsdynamik der Atmosphäre organisiert werden.

Das vorgestellte Modell basiert auf der Krümmung von Isothermen und Stromlinien als Maß für lokale dynamische Aktivität. Hohe Krümmung markiert Regionen, in denen sich Gradienten stark verändern, etwa an Fronten, Wirbeln oder Konvergenzlinien.

Durch Fourier-Analyse des Krümmungsfeldes lassen sich dominante Wellenlängen identifizieren. Besonders signifikant sind dabei *Resonanzpaare*, bei denen eine Wellenzahl k_1 nahe einem Vielfachen einer anderen ($k_2 \approx 2k_1$) liegt. Solche nichtlinearen Kopplungen sind charakteristisch für Systeme, in denen Energie von großen auf kleine Skalen kaskadiert, ein Zeichen für Selbstorganisation.

Obwohl die direkte Verifizierung mit ERA5-Daten [A.8](#) (data_stream-oper_step-Type-instant.nc) aufgrund der geringen räumlichen Auflösung (~ 27 km) und begrenzten Datenpunktdichte (nur 9 Punkte im untersuchten Ausschnitt) lokale Metriken wie SSIM ($r = 0.042$) und Krümmungskorrelation ($r = -0.009$) stark beeinträchtigt, zeigt die *Spektralanalyse* eine herausragende Übereinstimmung mit dem Modell ($r = 0.873$). Dies bedeutet:

Die *dominierenden Skalen* der atmosphärischen Dynamik, die Wellenlängen, die für die Bildung von Wolkenformationen entscheidend sind, werden vom Modell präzise reproduziert.

Diese Beobachtung ist von zentraler Bedeutung:

Die Atmosphäre scheint nicht zufällig zu strukturieren, sondern nach einem resonanten Prinzip, bei dem bestimmte Wellenlängen verstärkt werden, während andere destruktiv interferieren. Analog zu akustischen oder optischen Resonatoren entstehen durch Überlagerung und Rückkopplung stabile Muster, hier in Form von Wolkenbändern, Wirbeln oder Zellen.

Das Modell zeigt, dass diese Muster auch dann entstehen, wenn die Anfangsbedingungen nur unvollständig bekannt sind. Selbst bei extremen Datenarmut reproduziert es die korrekten Skalen, ein Hinweis auf die Robustheit des zugrundeliegenden Mechanismus.

Zusammenfassend lässt sich sagen:

Wolkenmuster sind nicht bloße Zufallsprodukte der Wetterdynamik, sondern *sichtbare Manifestationen geometrischer Resonanz*.

Die Atmosphäre spricht in Wellen, und die Geometrie ihrer Strömungen bestimmt, welche Töne verstärkt werden.

Diese Erkenntnis eröffnet einen neuen Zugang zur Analyse und Vorhersage atmosphärischer Organisation: nicht über deterministische Vorhersage, sondern über die Identifikation stabiler, resonanter Moden.

In zukünftigen Arbeiten könnte dieses Prinzip genutzt werden, um aus Satellitenbildern automatisiert Resonanzfrequenzen zu extrahieren und so frühe Hinweise auf bevorstehende Konvektion, Fronten oder Sturmentwicklung zu erhalten, ein Schritt hin zu einer *geometrischen Klimadiagnostik*.

7.1 Limitation der Validierung durch ERA5-Auflösung

Die Validierung der räumlichen Wolkenmuster erfolgt anhand von ERA5-Reanalyse-Daten, die eine nominelle räumliche Auflösung von etwa 27 km aufweisen. Diese Gitterweite ist zu grob, um lokale geometrische Feinstrukturen, wie z. B. Krümmungen von Isothermen im Kilometerbereich oder kleine Konvektionszellen, direkt abzubilden. Daher ist eine punktgenaue Übereinstimmung zwischen Modell und Beobachtung auf dieser Skala weder zu erwarten noch sinnvoll.

Dennoch zeigt die spektrale Analyse eine bemerkenswerte Übereinstimmung: Die dominierenden Wellenlängen im Krümmungsspektrum stimmen zwischen




Abbildung 7.1: Vergleich zwischen ERA5-Beobachtung (extrapoliert aus 9 Punkten) und Modell. Obwohl die lokale Übereinstimmung gering ist, stimmen die Spektren der Krümmungsfelder nahezu perfekt überein ($r = 0.873$), was auf eine konsistente Reproduktion der dominierenden Skalen hinweist. (Python-Code [A.9](#))

Modell und ERA5 mit einer Korrelation von $r = 0.873$ überein. Dies belegt, dass das Modell zwar nicht die exakte räumliche Realisierung, wohl aber die charakteristischen Skalen der atmosphärischen Dynamik korrekt reproduziert. Die Resonanzhypothese wird somit auf der Ebene der energetisch relevanten Moden validiert, nicht auf der Ebene des lokalen Musters.

Zukünftige Validierungen könnten hochaufgelöste Satellitendaten (z. B. von Sentinel-3 oder GOES-R mit Auflösungen < 1 km) nutzen, um auch die Feinstruktur der Wolkenmuster quantitativ zu prüfen.

Kapitel 8

Universelle Resonanzmuster in konvektiven Wirbeln: Von Atompilzen zu Hurrikanen

Die Ähnlichkeit zwischen einem Atompilz und einem Hurrikan ist mehr als visuell. Sie ist strukturell und dynamisch begründet. Beide Systeme entstehen aus einer instabilen Dichteschichtung, bei der warmes, leichtes Medium in ein kälteres, dichteres eindringt. Ob in Mikrosekunden nach einer Explosion oder über mehrere Tage in einem tropischen Wirbelsturm – die zugrundeliegende Physik der Konvektion, Zirkulation und Wellenausbreitung ist universell.

Ein zentrales Merkmal dieser Systeme ist die Ausbildung eines *toroidalen Ringwirbels*, der als dynamischer Resonator fungiert. Dieser Ring verstärkt bestimmte Wellenlängen, die in einem ganzzahligen Verhältnis zum Umfang stehen:

$$\lambda_n = \frac{2\pi R}{n}, \quad n \in \mathbb{N} \quad (8.1)$$

Ähnlich wie in einem akustischen Resonanzraum führt dies zu einer *geometrischen Filterung*: Nur Moden, die diese Bedingung erfüllen, werden verstärkt, während andere destruktiv interferieren.

Zusätzlich zeigt die Spektralanalyse eine charakteristische Kaskade:

Dominante Wellenlängen erscheinen im Verhältnis 2 : 1, 4 : 1, etc., ein Zeichen für nichtlineare Energieübertragung von großen auf kleine Skalen. Diese *Resonanzpaare* wurden sowohl in Simulationen als auch in Satellitenbeobachtungen identifiziert und deuten auf eine tiefere Ordnung in scheinbar chaotischen Systemen hin.

Besonders bemerkenswert ist die *Skaleninvarianz* dieser Muster: Ob bei 1 km

(konvektive Zelle), 100 km (Hurrikan) oder 1000 km (Frontensystem), die geometrische Struktur bleibt erhalten. Dies legt nahe, dass die Atmosphäre, wie andere dissipative Systeme, in einem Zustand *selbstorganisierter Kritikalität* operiert, in dem Resonanz und Instabilität zu stabilen Mustern führen.




Abbildung 8.1: Vergleich: Links – Atompilz mit ringförmigen Schockwellen (Quelle: historische Aufnahme); rechts – Hurrikan mit konzentrischen Konvektionsbändern (Quelle: NASA). Die geometrische Ähnlichkeit ist kein Zufall, sondern Ausdruck universeller Resonanzmechanismen. (Python-Code [A.12](#))

Diese Erkenntnis eröffnet einen neuen Blick auf die Atmosphäre: nicht als Ansammlung isolierter Phänomene, sondern als *resonantes System*, in dem Energie, Geometrie und Skalen miteinander koppeln. Die Identifikation solcher Muster ermöglicht zukünftig eine *geometrische Frühwarnung*:

Wenn sich bestimmte Resonanzmoden verstärken, kann dies auf bevorstehende Intensivierung von Stürmen oder Konvektion hinweisen, lange bevor klassische Parameter einen Anstieg zeigen.

Kapitel 9

Multiskalige Struktur und Resonanzphänomene in Hurrikanen

Um die hierarchische Organisation von Wolkenstrukturen in tropischen Wirbelstürmen zu untersuchen, wurde eine bildbasierte Frequenzanalyse am Beispiel von *Hurrikan Katrina (2005)* durchgeführt. Ausgangspunkt war ein hochaufgelöstes Satellitenbild mit einer Auflösung von 3100×4000 Pixel, das visuell klare konzentrische Wolkenbänder um das Auge des Sturms zeigt.

<https://www.earthobservatory.nasa.gov/images/15395/hurricane-katrina>

Image: hurricane_katrina_2005.jpg

Zunächst wurde das Bild in Graustufen umgewandelt und mittels eines Gauß-Filters ($\sigma = 3$) geglättet, um Rauschen zu reduzieren und die Detektion des Augenzentrums zu stabilisieren. Das Zentrum des Auges wurde als das Minimum der Intensitätsverteilung in einem zentralen Ausschnitt von 1550×1550 Pixel identifiziert A.10. Die genaue Position des Auges wurde zu (1915, 1565) in Pixelkoordinaten bestimmt.

Anschließend wurde ein radiales Intensitätsprofil um das Auge berechnet, indem die mittlere Helligkeit in konzentrischen Ringen als Funktion des Abstands zum Zentrum gemittelt wurde. Dieses Profil wurde detrendet (Polynom 2. Ordnung) und einer schnellen Fourier-Transformation (FFT) unterzogen, um periodische Modulationen im Wolkenmuster zu identifizieren.

Die Spektralanalyse ergab eine dominante Wellenlänge von $\lambda_1 = 49.8$ km, was einem typischen Abstand zwischen dem Augenrand und dem primären Konvektionsring entspricht. Zwei weitere signifikante Skalen wurden bei $\lambda_2 = 6.2$ km und $\lambda_3 = 3.6$ km detektiert, die auf feinere konvektive Strukturen wie

Regenbänder oder mesoskalige Zellen hinweisen. Die Verhältnisse $\lambda_1/\lambda_2 \approx 8$ und $\lambda_1/\lambda_3 \approx 14$ deuten nicht auf einfache harmonische Resonanzen (z. B. 1:2, 2:3), sondern auf eine hierarchische, multiskalige Organisation der Konvektion hin.

Interessanterweise zeigt das Amplitudenspektrum ein Potenzgesetz-Verhalten mit einem Skalensexponenten von $\alpha \approx -0.91$ im Log-Log-Raum. Dieser Wert liegt sehr nahe an -1 , was für *1/f-Rauschen* (auch *pink noise*) charakteristisch ist. Solche Signale sind typisch für Systeme mit *selbstorganisierter Kritikalität* (SOC), bei denen lokale Instabilitäten kaskadenartige Reaktionen auslösen, wie sie in starken Konvektionszonen von Hurrikanen zu erwarten sind.

Diese Ergebnisse legen nahe, dass die Wolkenarchitektur von Hurrikanen nicht nur durch großskalige Dynamik (Corioliskraft, Druckgradient) bestimmt ist, sondern auch von nichtlinearen Wechselwirkungen zwischen Skalen geprägt wird.

Die Identifikation eines $1/f$ -artigen Spektrums unterstützt die Hypothese, dass tropische Wirbelstürme als kritische Systeme operieren, in denen Energie über mehrere räumliche Größenordnungen kaskadiert.




Abbildung 9.1: Visualisierung der Analyse: (a) Identifiziertes Auge und dominante Wolkenringe, (b) radiales Intensitätsprofil, (c) FFT-Spektrum, (d) Log-Log-Darstellung des Spektrums mit linearer Anpassung. (Python-Code [A.11](#))

9.1 Zur Interpretation des $1/f$ -Spektrums

Die Beobachtung eines Potenzgesetzes mit Exponent $\alpha \approx -1$ im radialen Spektrum von Hurrikanen und Atompilzen wird oft mit dem Konzept der selbstorganisierten Kritikalität (SOC) in Verbindung gebracht [1]. Allerdings ist diese Interpretation in der Geophysik umstritten. Lovejoy & Schertzer (2013) weisen darauf hin, dass $1/f$ -artige Spektren auch durch multiskalige Turbulenzkaskaden oder stochastische Multiplikationsprozesse entstehen können, ohne dass ein System tatsächlich „kritisch“ ist. Insbesondere in konvektiven Systemen wie Hurrikanen dominiert die energetische Kaskade von groß- zu klein-skaligen Wirbeln, die durch die Navier-Stokes-Gleichungen beschrieben wird, ein Prozess, der bereits allein zu flachen Spektren führen kann.

In dieser Arbeit wird das $1/f$ -Verhalten daher nicht als Beweis für SOC, sondern als Indikator für eine breite, skaleninvariante Dynamik interpretiert, die mit der Resonanzhypothese konsistent ist: Energie wird nicht auf einer einzigen Skala dissipiert, sondern über mehrere Größenordnungen hinweg kaskadiert, wobei bestimmte Wellenlängen durch geometrische Resonanz bevorzugt werden. Ob das System dabei tatsächlich SOC aufweist, bleibt eine offene Frage, die hier nicht entschieden, aber als mögliche Erklärung neben Turbulenzmechanismen diskutiert wird.

Teil IV

Methodische Anwendungen

Kapitel 10

Skaleninvariante Strukturen im nuklearen Feuerpilz

Die Analyse des bei *Operation Crossroads Baker* (1946) entstandenen Feuerpilzes ergab überraschende Hinweise auf selbstorganisierte Ordnung. Trotz der explosiven, nichtlinearen Dynamik zeigt das Amplitudenspektrum des radialen Intensitätsprofils ein Potenzgesetz mit einem Exponenten von $\alpha \approx -1.08$ – nahezu identisch mit dem *1/f-Rauschen*, das typisch für kritische Systeme ist.

Zusätzlich wurden mehrere dominante Wellenlängen detektiert: $\lambda_1 = 159.5$ m, $\lambda_2 = 39.9$ m, $\lambda_3 = 24.5$ m. Das Verhältnis $\lambda_1/\lambda_2 \approx 4$ deutet auf eine hierarchische Struktur hin, die möglicherweise durch Überlagerung von Schockreflexionen und Konvektionsinstabilitäten entsteht.

Dieses Ergebnis legt nahe, dass auch anthropogen ausgelöste Extremsysteme nicht rein chaotisch sind, sondern kurz nach der Detonation in einen Zustand der *selbstorganisierten Kritikalität* übergehen. Die universelle Präsenz von *1/f*-Dynamik – von Hurrikanen bis zu Atompilzen – unterstützt die Hypothese, dass nichtlineare Konvektionssysteme unabhängig von ihrer Energiequelle ähnliche strukturelle und spektrale Eigenschaften entwickeln.

10.1 Hinweis zur physikalischen Interpretation

Die strukturelle Ähnlichkeit zwischen Atompilzen und Hurrikanen darf nicht als Hinweis auf identische physikalische Ursachen missverstanden werden. Während Hurrikane durch langsame, feuchte Konvektion und planetare Rotation geformt werden, entstehen Atompilze durch eine explosionsinduzierte Rayleigh-Taylor-Instabilität.




Abbildung 10.1: Analyse des Baker-Test-Pilzes: Detektierte Ringe (gelb), Symmetrieachse (rot), und Log-Log-Spektrum mit $\alpha = -1.08$. (Python-Code [A.12](#))

Dennoch teilen beide Systeme eine gemeinsame mathematische Struktur: Sie bilden toroidale Ringwirbel aus, die als nichtlineare Resonatoren wirken und bevorzugte Wellenlängen verstärken. Die Beobachtung von $1/f$ -artigen Spektren und harmonischen Resonanzpaaren in beiden Fällen deutet darauf hin, dass universelle Prinzipien der Skalenkaskade und geometrischen Selbstorganisation unabhängig vom spezifischen Antrieb wirken können.

In diesem Sinne ist die Analogie formal-mathematisch, nicht kausal-physikalisch – und gerade das macht sie für die Suche nach universellen Ordnungsprinzipien in der Geophysik so wertvoll.

Kapitel 11

Analyse der Meanderdynamik im Golfstrom mittels Bildverarbeitung

Zur Untersuchung der dynamischen Instabilitäten im Golfstrom haben wir ein satellitengestütztes MODIS-Bild mittels eines selbstentwickelten Python-Skripts ausgewertet. Der Algorithmus kombiniert Methoden der digitalen Bildverarbeitung mit geometrischer Analyse, um die Entwicklung von Meandern und die Entstehung von Wirbeln (sog. *Eddies*) zu identifizieren.

https://eoimages.gsfc.nasa.gov/images/imagerecords/0/681/gulf_stream_modis_lrg.gif

Datei: gulf_stream_modis_lrg.gif

11.1 Methodik der Bildverarbeitung

Das Graustufenbild wurde zunächst durch einen Gauß-Filter geglättet, um Rauschen zu reduzieren. Anschließend wurde der Temperaturgradient entlang der horizontalen Achse mittels des Sobel-Operators berechnet, um die scharfen Übergänge zwischen warmem Golfstromwasser und kühlerer Umgebung zu detektieren. Aus diesen Gradienten wurde die Achse des Stroms zeilenweise extrahiert, indem für jede Bildzeile die Mitte zwischen minimalem und maximalem Gradienten bestimmt wurde. Dies ergibt eine kontinuierliche Kurve, die den zeitlichen Verlauf der seitlichen Auslenkung des Stroms entlang seiner Flussrichtung repräsentiert.

Basierend auf dieser Achse wurde das Meander-Signal durch Entfernung einer linearen Trendkomponente gewonnen. Um die räumliche Entwicklung der Instabilität zu analysieren, wurde die Krümmung der Stromachse berechnet,

definiert als der Betrag der zweiten Ableitung des Meanderprofils:

$$\kappa(y) = \left| \frac{d^2x}{dy^2} \right|,$$

wobei hohe Krümmungswerte auf starke lokale Biegung und damit auf fortgeschrittene Instabilität hinweisen. Mithilfe der Funktion `find_peaks` aus der `scipy.signal`-Bibliothek wurden diejenigen Positionen identifiziert, an denen die Krümmung lokal maximal ist. Die drei stärksten dieser Peaks wurden als kritische Zonen für die *Eddy-Genese* ausgewiesen.

Zusätzlich wurde eine FFT-basierte Analyse (vgl. Skript `02_qwen.py`) durchgeführt, um resonante Wellenlängen und den Beginn der Instabilität zu lokalisieren.




Abbildung 11.1: Visualisierung der Top-3-Instabilitätszentren im Golfstrom. Rot: höchste Krümmung (Eddy-Genese bei $Y = 261$). Gelb/Orange: sekundäre Zonen. Die Stromachse ist in Cyan dargestellt. (Python-Code [A.13](#))

11.2 Ergebnisse und Interpretation

Die Analyse ergab zwei zentrale Ergebnisse:

- Die FFT-Analyse identifizierte bei etwa $Y \approx 140$ Pixel einen Bereich mit resonanter Anregung und kurzen Wellenlängen (13–71 km), was auf den **Beginn der Meanderinstabilität** hindeutet.
- Die Krümmungsanalyse zeigte bei $Y \approx 261$ Pixel die stärkste lokale Biegung der Stromachse, die **Hauptzone der Eddy-Genese**.

Diese scheinbare Diskrepanz wird durch den Lebenszyklus eines Meanders erklärt: Die Instabilität beginnt bei $Y \approx 140$ Pixel durch *resonante Anregung* und wächst entlang des Stroms durch *barokline Instabilität* an Energie. Bei $Y \approx 261$ Pixel erreicht die Welle ihre maximale Amplitude und Krümmung – hier ist die Wahrscheinlichkeit für *Eddy Shedding* am höchsten.

11.3 Fachbegriffe – Kurzerklärung

Eddy: Ein ozeanischer Wirbel, der sich von einer starken Strömung wie dem Golfstrom ablöst. Eddies transportieren Wärme, Salz und Nährstoffe über große Distanzen und beeinflussen regional wie global das Klima.

Eddy Shedding: Der Prozess, bei dem ein Meander des Golfstroms so stark ausgeprägt wird, dass er sich abschnürt und als freier Wirbel in den äußeren Ozean driftet. Dies ist ein zentraler Mechanismus der Energieverteilung im Klimasystem.

Barokline Instabilität: Eine hydrodynamische Instabilität, die in Schichtungssystemen mit Temperatur- und Dichteunterschieden auftritt. Im Golfstrom führt sie dazu, dass kleine Störungen wachsen und sich zu Meandern und Eddies entwickeln. Sie ist der Haupttreiber der Meanderdynamik außerhalb der Küstennähe.

11.4 Bewertung

Die Kombination aus FFT- und Krümmungsanalyse ermöglicht eine detaillierte Rekonstruktion des Meander-Lebenszyklus aus einem einzigen Satellitenbild. Die Ergebnisse zeigen, dass die Instabilität nicht an einem Punkt auftritt, sondern sich entlang des Stroms entwickelt – von der ersten Anregung bis zur finalen Ablösung eines Eddys. Diese Methode eignet sich somit zur Identifikation kritischer Zonen im Klimasystem, an denen signifikante Energie- und Wärmetransporte stattfinden.

Kapitel 12

Mathematische Beschreibung von Wolkenfor- men durch dynamische Kegelschnitte

Wolken sind keine zufälligen Gebilde, sondern Manifestationen komplexer, oft lokal stabiler Strömungsmuster in der Atmosphäre. Ihre Formen, von langgezogenen Streifen (Cirrus) über wellige Muster (Altostratus) bis hin zu ringförmigen Konvektionszellen, folgen geometrischen Prinzipien, die sich durch physikalische Gesetze der Fluidodynamik und Thermodynamik erklären lassen.

In diesem Kapitel wird gezeigt, dass sich viele dieser Strukturen mittels eines neuartigen mathematischen Rahmens beschreiben lassen: der Theorie der *dynamischen Kegelschnitte*.

12.1 Dynamische Kegelschnitte als geometrischer Morphing-Operator

Ein *dynamischer Kegelschnitt* ist eine Familie von Kurven $\gamma_\alpha : \mathbb{R} \rightarrow \mathbb{R}^2$, parametrisiert durch $\alpha \in [0, 1]$, deren lokale Geometrie durch einen nichtlinearen Fluss gesteuert wird. Zentral ist der *Verschmelzungsoperator* V_α , der die Krümmung $\kappa_\alpha(x)$ einer Ausgangskurve (z. B. einer Parabel) kontinuierlich in die eines Zielobjekts (z. B. eines Kreises oder einer Lemniskate) überführt:

$$\kappa_\alpha(x) = (1 - \alpha) \cdot \kappa_{\text{start}}(x) + \alpha \cdot \kappa_{\text{ziel}}(x).$$

Die zugehörige Kurve $\gamma_\alpha(x) = y(x)$ erfüllt die Differentialgleichung zweiter Ordnung:

$$\frac{d^2 y}{dx^2} = \kappa_\alpha(x) \left(1 + \left(\frac{dy}{dx} \right)^2 \right)^{3/2},$$

mit Anfangsbedingungen $y(0) = 0, y'(0) = 0$. Dieser Ansatz ermöglicht einen glatten geometrischen Übergang zwischen topologisch unterschiedlichen Formen – etwa von einer offenen Parabel zu einer geschlossenen Kreislinie – und wird hier als *Verschmelzungsfluss* bezeichnet.

12.2 Anwendung auf atmosphärische Wolkenmuster

Obwohl ursprünglich zur Modellierung geometrischer Morphing-Prozesse entwickelt, erweist sich dieser Formalismus als äußerst geeignet zur Beschreibung von „atmosphärischen Wirbeln und Wolkenstrukturen“.

Beispiele:

- **Ringförmige Wolken (Circulus, Mammatus):** Entstehen durch lokale Konvektion und Scherung. Sie können als $\alpha \rightarrow 1$ -Zustände interpretiert werden, bei denen die Krümmung homogenisiert wird – analog zur Kreis- oder Sphärenbildung im Modell.
- **Wellenwolken (Alto cumulus und Kelvin-Helmholtz-Instabilitäten):** Entstehen durch Scherströmungen. Ihre Form ähnelt morphologisch interpolierten Zuständen mit $0 < \alpha < 1$, bei denen sich lokale Krümmungsmuster überlagern.
- **Wirbelstraßen hinter Inseln oder Gebirgen:** Zeigen oft lemniskatenartige (schleifenförmige) Strukturen, exakt die Endformen des in Kapitel 11 beschriebenen *Lemniskatenflusses*.

12.3 Bewertung und Erweiterung

Die Theorie der dynamischen Kegelschnitte bietet eine neue Sicht auf atmosphärische Musterbildung: Statt Wolken als bloße Zufallsstrukturen zu betrachten, werden sie als *geometrische Zustände entlang eines Krümmungsflusses* verstanden. Dieser Fluss wird durch physikalische Prozesse wie Scherung, Konvektion oder Corioliskraft angeregt – und der Parameter α kann als Maß für die *Reife eines Wirbels* interpretiert werden.

Besonders bemerkenswert ist die Erweiterung auf 3D-Oberflächen (z. B. Paraboloid $\rightarrow$ Hemisphäre), die eine direkte Anwendung auf:

- Konvektive Wolkenzellen (Cumulus, Cumulonimbus),
- Ozeanische Eddies (als 3D-Strukturen),
- Und sogar planetare Wellen (Rossby-Wellen als große Meander) ermöglicht.

12.4 Zukünftige Perspektiven

Der Verschmelzungsoperator V_α könnte in Klimamodellen als *geometrischer Parametrisierer* für subskalare Prozesse dienen, etwa zur automatischen Erkennung und Klassifizierung von Wirbeln in Satellitenbildern oder zur Vorhersage von Eddy-Shedding-Ereignissen. Kombiniert mit maschinellem Lernen könnte α als *Instabilitätsindikator* trainiert werden.

Teil V

Anhang

Kapitel A

Python-Code

A.1 Eiszeitzyklen, (Kap. 2.3)

```
1 # klima_eiszeitzyklen.py
2 import numpy as np
3 import matplotlib.pyplot as plt
4 from scipy.fft import fft, fftfreq
5 from scipy.signal import find_peaks
6
7 # -----
8 # □ KLIMA-MODELL PARAMETER
9 # -----
10 print("□ Starte Eiszeit-Simulation (ćMilankovi +
    Rückkopplungen + Resonanzen)")
11 print("□ Zeitraum: 0 bis 1 Million Jahre (Auflösung: 1000
    Jahre)")
12 print("-" * 70)
13
14 years = np.arange(0, 1_000_000, 1000) # 0 bis 1 Mio. Jahre
    in 1000-Jahres-Schritten
15
16 # -----
17 # 1. ćMILANKOVI-ZYKLEN (Astronomische Forcings)
18 # -----
19 print("□ Berechne ćMilankovi-Zyklen:")
20 print("    - Exzentrizität (100.000-Jahre-Zyklus)")
21 print("    - Obliquität (41.000-Jahre-Zyklus)")
22 print("    - Präzession (23.000-Jahre-Zyklus)")
23
```

```

24 def milankovic_cycles(time_years):
25     # Exzentrizität: 0.005 bis 0.059, Mittelwert ~0.032
26     ecc = 0.032 + 0.027 * np.sin(2 * np.pi * time_years /
100_000 + np.pi/2)
27     # Obliquität: 22.1° bis 24.5°
28     obliquity = 23.3 + 1.2 * np.sin(2 * np.pi * time_years /
41_000)
29     # Präzession: Phasenabhängige Einstrahlungsvariation
30     precession = 0.8 * np.sin(2 * np.pi * time_years /
23_000)
31     return ecc, obliquity, precession
32
33 ecc, obliquity, precession = milankovic_cycles(years)
34 print("□ Milankovi-Forcing berechnet")
35 print(f"    - Exzentrizität: {np.min(ecc):.4f} bis
      {np.max(ecc):.4f}")
36 print(f"    - Obliquität: {np.min(obliquity):.2f}° bis
      {np.max(obliquity):.2f}°")
37 print("-" * 70)
38
39 # -----
40 # 2. KLIMA-RÜCKKOPPLUNGEN (Realistische Effekte)
41 # -----
42 print("□ Initialisiere Klima-Rückkopplungen:")
43 print("    - Eis-Albedo-Effekt: Mehr Eis → höhere Reflexion →
      Abkühlung")
44 print("    - CO2-Rückkopplung: Temperatur → CO2-Löslichkeit
      in Ozeanen")
45
46 class ClimateFeedback:
47     def __init__(self):
48         self.ice_coverage = 0.3    # Start: 30% Eisbedeckung
      (heute ~10%, aber Modellstart)
49         self.co2_level = 280      # Start: 280 ppm
      (präindustriell)
50         self.base_temp = 14.0    # Globale
      Mitteltemperatur heute (°C)
51
52     def albedo_effect(self, temp):
53         """Eis-Albedo-Rückkopplung: kälter → mehr Eis → mehr
      Reflexion → kälter"""
54         temp_anomaly = temp - self.base_temp
55         # Eisbedeckung steigt bei Abkühlung

```

```

56     self.ice_coverage = np.clip(0.3 + 0.08 *
    (-temp_anomaly), 0.1, 0.7)
57     albedo = 0.3 + 0.4 * self.ice_coverage
58     # Albedo-Rückkopplung: ~9°C pro 0.1 Albedo → hier
    ~3.6°C pro 0.04 Albedo-Änderung
59     return -5.0 * (albedo - 0.3) # In °C
60
61     def co2_effect(self, temp):
62         """2CO-Rückkopplung: kälter → mehr 2CO in Ozeanen
    gelöst → weniger Treibhauseffekt"""
63         temp_anomaly = temp - self.base_temp
64         # Näherung: 2CO ändert sich um ~8 ppm pro °C (aus
    Eisbohrkernen)
65         self.co2_level = np.clip(280 + 8 * temp_anomaly,
    180, 400)
66         # Strahlungsantrieb:  $\Delta F = 5.35 * \ln(CO_2/CO_{2,0})$ 
    [W/m2], dann ~0.5°C pro W/m2
67         delta_co2 = self.co2_level / 280
68         radiative_forcing = 5.35 * np.log(delta_co2)
69         return 0.5 * radiative_forcing # Temperaturbeitrag
    in °C
70
71 feedback = ClimateFeedback()
72 print(f"□ Startwerte: Eis =
    {feedback.ice_coverage*100:.0f}%, 2CO =
    {feedback.co2_level:.0f} ppm")
73 print("-" * 70)
74
75 # -----
76 # 3. TEMPERATUR-SIMULATION
77 # -----
78 print("□ Simuliere Temperaturverlauf mit Rückkopplungen...")
79
80 temperature = np.full_like(years, 14.0, dtype=float) #
    Start bei 14°C
81
82 for i in range(1, len(years)):
83     # Astronomische Forcing (in °C-Äquivalent)
84     forcing = (
85         1.5 * (ecc[i] - 0.032) / 0.027 + # Exzentrizität:
    max ±1.5°C
86         1.0 * (obliquity[i] - 23.3) / 1.2 + # Obliquität:
    max ±1.0°C

```

```

87         0.8 * precession[i]                # Präzession:
max ±0.8°C
88     ) # Max: ±3.3°C, typisch ±2°C
89
90     # Rückkopplungen
91     albedo_contribution =
feedback.albedo_effect(temperature[i-1])
92     co2_contribution = feedback.co2_effect(temperature[i-1])
93
94     total_forcing = forcing + albedo_contribution +
co2_contribution
95
96     # Trägheit des Klimasystems (Ozeane): langsames Anpassen
97     temperature[i] = 0.8 * temperature[i-1] + 0.2 *
(feedback.base_temp + total_forcing)
98
99     print("□ Simulation abgeschlossen!")
100    print(f"    - Max. Temperatur: {np.max(temperature):.2f}°C
(interglazial)")
101    print(f"    - Min. Temperatur: {np.min(temperature):.2f}°C
(glazial)")
102    print(f"    - Temperaturabweichung: {np.min(temperature) -
14.0:.2f}°C bis {np.max(temperature) - 14.0:.2f}°C")
103    print("-" * 70)
104
105    # -----
106    # □ EXTRA: Speichere  $\text{CO}_2$  und Eisverlauf während der
Simulation (nachträglich!)
107    # Hinweis: Wir müssen die Simulation leicht modifizieren, um
Verläufe zu speichern.
108    # Aber: Wir ändern die Logik nicht - nur Datenspeicherung!
109    # -----
110
111    print("□ Sammle  $\text{CO}_2$ - und Eisverlaufskurven für
Visualisierung...")
112
113    # Wir müssen die Simulation nochmal laufen lassen, aber
diesmal mit Speicherung
114    # Alternativ: Wir speichern während der originalen Schleife
- das ist effizienter
115
116    # Also: Wir passen die Schleife leicht an, um History zu
sammeln
117    # (Das ist die sauberste Lösung - minimaler Eingriff)

```

```

118
119 # Neu: Listen für Verläufe
120 co2_history = []
121 ice_history = []
122
123 # Wir führen die Schleife nochmal aus - oder besser: wir
    erweitern die bestehende!
124 # Also: Ersetze die bestehende Simulationsschleife durch
    diese Version (nur um Verläufe zu bekommen):
125
126 # Entferne oder ersetze diesen Teil:
127 # for i in range(1, len(years)):
128
129 # Wir setzen zurück, um History aufzunehmen
130 temperature = np.full_like(years, 14.0, dtype=float)
131 feedback = ClimateFeedback() # Reset Zustand
132
133 co2_history = [feedback.co2_level]
134 ice_history = [feedback.ice_coverage]
135
136 for i in range(1, len(years)):
137     forcing = (
138         1.5 * (ecc[i] - 0.032) / 0.027 +
139         1.0 * (obliquity[i] - 23.3) / 1.2 +
140         0.8 * precession[i]
141     )
142
143     albedo_contribution =
feedback.albedo_effect(temperature[i-1])
144     co2_contribution = feedback.co2_effect(temperature[i-1])
145
146     total_forcing = forcing + albedo_contribution +
co2_contribution
147     temperature[i] = 0.8 * temperature[i-1] + 0.2 *
(feedback.base_temp + total_forcing)
148
149     # Speichere aktuelle Werte
150     co2_history.append(feedback.co2_level)
151     ice_history.append(feedback.ice_coverage)
152
153 # Sicherstellen: Länge passt
154 co2_history = np.array(co2_history)
155 ice_history = np.array(ice_history)
156

```

```

157 print("  2CO- und Eisverläufe gespeichert")
158 print(f"    - 2CO: {co2_history.min():.0f} bis
      {co2_history.max():.0f} ppm")
159 print(f"    - Eisbedeckung: {ice_history.min()*100:.0f}% bis
      {ice_history.max()*100:.0f}%")
160
161 # -----
162 # 4. SPEKTRALANALYSE (Dominante Zyklen und Resonanzen)
163 # -----
164 print("  Führe Spektralanalyse durch...")
165
166 def analyze_cycles(signal, time):
167     N = len(signal)
168     dt = (time[1] - time[0]) / 1000 # Zeitschritt in
    Tausend Jahren
169     yf = fft(signal - np.mean(signal)) # Entferne Mittelwert
170     xf = fftfreq(N, d=dt)[:N//2]
171     yf = np.abs(yf[:N//2])
172
173     # Nur sinnvolle Frequenzen (Perioden zwischen 10 und 500
    ka)
174     valid = (xf > 1/500) & (xf < 1/10)
175     if not np.any(valid):
176         print("  Keine gültigen Frequenzen gefunden!")
177         return np.array([]), np.array([]), xf, valid, yf
178
179     periods = 1 / xf[valid]
180     amplitudes = yf[valid]
181
182     # Finde Peaks
183     peaks, _ = find_peaks(amplitudes,
    height=np.max(amplitudes)*0.05)
184     if len(peaks) == 0:
185         return np.array([]), np.array([]), xf, valid, yf
186
187     top_periods = periods[peaks]
188     top_amplitudes = amplitudes[peaks]
189
190     # Top 3 nach Amplitude
191     idx_sorted = np.argsort(top_amplitudes)[-3:][::-1]
192     return top_periods[idx_sorted],
    top_amplitudes[idx_sorted], xf, valid, yf
193

```

```

194 dominant_periods, peak_amplitudes, freqs, valid, fft_amp =
    analyze_cycles(temperature, years)
195
196 print("□ Dominante Klima-Zyklen identifiziert:")
197 if len(dominant_periods) > 0:
198     for i, (period, amp) in enumerate(zip(dominant_periods,
199                                         peak_amplitudes), 1):
200         print(f"    - {i}. Hauptzyklus: {period:.1f} Tausend
201             Jahre (Amplitude: {amp:.2f})")
202 else:
203     print("    Keine klaren Zyklen gefunden.")
204 print("-" * 70)
205
206 # -----
207 # 5. RESONANZANALYSE
208 # -----
209 print("□ Untersuche Resonanzen...")
210
211 resonance_periods = []
212 resonance_amplitudes = []
213
214 for period in dominant_periods:
215     second_harmonic = period / 2
216     if 10 < second_harmonic < 200:
217         resonance_periods.append(second_harmonic)
218         target_freq = 1 / second_harmonic
219         idx = np.argmin(np.abs(freqs[valid] - target_freq))
220         resonance_amplitudes.append(fft_amp[valid][idx])
221
222 print("□ Potenzielle Resonanzen (zweite Harmonische):")
223 for i, (period, amp) in enumerate(zip(resonance_periods,
224                                     resonance_amplitudes), 1):
225     print(f"    - Resonanz {i}: {period:.1f} Tausend Jahre
226         (Amplitude: {amp:.2f})")
227
228 # Kombinationsfrequenz: |1/23 - 1/41|
229 comb_freq = np.abs(1/23 - 1/41)
230 comb_period = 1 / comb_freq
231 if 10 < comb_period < 200:
232     idx = np.argmin(np.abs(freqs[valid] - comb_freq))
233     comb_amplitude = fft_amp[valid][idx]
234     print(f"    - Kombinationsfrequenz: {comb_period:.1f}
235         Tausend Jahre (Amplitude: {comb_amplitude:.2f})")
236 print("-" * 70)

```

```

232
233 # -----
234 # 6. VISUALISIERUNG - ZWEI KLARE PLOTS
235 # -----
236
237 print(" Erzeuge zwei klare Plots: (1) Zeitverläufe, (2)
    Spektrum")
238
239 time_ka = -years / 1000 # Zeit: heute = 0, Vergangenheit
    negativ
240
241 # =====
242 # PLOT 1: ZEITVERLÄUFE (Forcings, Temp, 2CO, Eis)
243 # =====
244 plt.figure(figsize=(14, 10))
245
246 # 1. Milankovi-Zyklen
247 plt.subplot(4, 1, 1)
248 plt.plot(time_ka, (ecc - 0.032)/0.027,
    label="Exzentrizität", lw=1.0)
249 plt.plot(time_ka, (obliquity - 23.3)/1.2,
    label="Obliquität", lw=1.0)
250 plt.plot(time_ka, precession, label="Präzession", lw=1.0)
251 plt.title("Astronomische Forcings (Milankovi-Zyklen)")
252 plt.ylabel("Normiert")
253 plt.xlim(-1000, 0)
254 plt.legend(fontsize=9)
255 plt.grid(True, alpha=0.3)
256
257 # 2. Temperatur
258 plt.subplot(4, 1, 2)
259 plt.plot(time_ka, temperature, 'r-', linewidth=1.5)
260 plt.axhline(14.0, color='gray', linestyle='--', alpha=0.6)
261 plt.ylabel("Temp (°C)")
262 plt.xlim(-1000, 0)
263 plt.title("Globale Temperatur")
264 plt.grid(True, alpha=0.3)
265
266 # 3. 2CO
267 plt.subplot(4, 1, 3)
268 plt.plot(time_ka, co2_history, 'b-', linewidth=1.5)
269 plt.axhline(280, color='gray', linestyle='--', alpha=0.5,
    label="280 ppm (präindustriell)")
270 plt.ylabel("2CO (ppm)")

```

```

271 plt.xlim(-1000, 0)
272 plt.ylim(170, 310)
273 plt.title("Atmosphärisches  $\text{CO}_2$  (Rückkopplung)")
274 plt.legend(fontsize=9)
275 plt.grid(True, alpha=0.3)
276
277 # 4. Eisbedeckung
278 plt.subplot(4, 1, 4)
279 plt.plot(time_ka, ice_history * 100, 'c-', linewidth=1.5)
280 plt.ylabel("Eisbedeckung (%)")
281 plt.xlabel("Zeit (Tausend Jahre vor heute)")
282 plt.xlim(-1000, 0)
283 plt.ylim(10, 70)
284 plt.title("Globale Eisbedeckung")
285 plt.grid(True, alpha=0.3)
286
287 plt.tight_layout()
288 plt.savefig("klima_eiszeiten_time_series.png", dpi=300,
289           bbox_inches='tight')
289 plt.show()
290 plt.close()
291
292 print("□ Zeitverläufe gespeichert als
293       'klima_eiszeiten_time_series.png'")
294
295 # =====
296 # PLOT 2: SPEKTRALANALYSE (groß und detailliert)
297 # =====
298 plt.figure(figsize=(12, 6))
299
300 plt.plot(1/freqs[valid], fft_amp[valid], 'k-',
301         linewidth=1.5, label="Spektralamplitude")
302 plt.xlim(10, 200)
303 plt.ylim(bottom=0)
304
305 # Markiere Hauptzyklen
306 plt.axvline(100, color='k', linestyle='--', linewidth=1.2,
307            label="100-ka (Exzentrizität)")
308 plt.axvline(41, color='g', linestyle='--', linewidth=1.2,
309            label="41-ka (Obliquität)")
310 plt.axvline(23, color='r', linestyle='--', linewidth=1.2,
311            label="23-ka (Präzession)")
312
313 # Resonanzen

```

```

309 for period in resonance_periods:
310     plt.axvline(period, color='m', linestyle=':',
311                 linewidth=1.2, alpha=0.8, label=f"Resonanz: {period:.0f}
312                 ka" if period == resonance_periods[0] else "")
313
314 # Kombinationsfrequenz
315 if 10 < comb_period < 200:
316     plt.axvline(comb_period, color='c', linestyle='-.',
317                 linewidth=1.2, label=f"Kombi: {comb_period:.1f} ka")
318
319 plt.title("Spektralanalyse der Temperatur - Dominante
320           Klimazyklen", fontsize=14)
321 plt.xlabel("Periode (Tausend Jahre)", fontsize=12)
322 plt.ylabel("Amplitude", fontsize=12)
323 plt.legend(fontsize=10, ncol=2)
324 plt.grid(True, alpha=0.4)
325
326 plt.tight_layout()
327 plt.savefig("klima_eiszeiten_spectrum.png", dpi=300,
328             bbox_inches='tight')
329 plt.show()
330 plt.close("all")
331
332 print("□ Spektrum gespeichert als
333       'klima_eiszeiten_spectrum.png'")
334 print("=" * 70)
335 print("□ Simulation abgeschlossen - zwei klare,
336       publikationsfähige Plots erstellt!")

```

Listing A.1: Visualisierung Eiszeitzyklen

A.2 Simulation: Nächste Eizeit, (Abschn. 2.4)

```

1 # klima_eiszeiten_naechste_nichtlinear.py
2 import numpy as np
3 import matplotlib.pyplot as plt
4
5 print("□ Simuliere Beginn der nächsten Eiszeit (ab heute)")
6 print("□ Zeitraum: 0 bis 150.000 Jahre (Auflösung: 1000
7       Jahre)")
8 print("□ Szenario 1: Natürlich - nur Milankovi-Zyklen")

```

```

8 print("  Szenario 2: 2CO-Stoß - +2°C Forcing für 2000
   Jahre")
9 print("  Szenario 3: Vulkanausbruch - - 4°C kurzfristiges
   Forcing für 10 Jahre")
10
11 # Zeitskala
12 years = np.arange(0, 150_000, 1000)
13 time_ka = years / 1000
14
15 #
16 -----
17 # 1. MILANKOVIC-ZYKLEN
18 #
19 -----
20 def milankovic_future(t):
21     ecc = 0.032 + 0.027 * (-np.cos(2 * np.pi * (t - 80_000)
22     / 100_000))
23     obliquity = 23.3 + 1.2 * (-np.cos(2 * np.pi * (t -
24     80_000) / 41_000))
25     precession = 0.8 * (-np.cos(2 * np.pi * (t - 80_000) /
26     23_000))
27     return ecc, obliquity, precession
28
29 ecc, obliquity, precession = milankovic_future(years)
30
31 #
32 -----
33 # 2. KLIMARÜCKKOPPLUNGEN - MIT NICHTLINEARER ALBEDO
34 #
35 -----
36 class ClimateFeedback:
37     def __init__(self):
38         self.co2_level = 280
39         self.base_temp = 14.0
40
41     def albedo_effect(self, temp):
42         """
43         NICHTLINEARE Albedo-Rückkopplung:
44         Eis wächst exponentiell unterhalb einer kritischen
45         Temperatur (T_crit ≈ 10°C).
46         Verwendet eine Sigmoid-Funktion für glatten, aber
47         scharfen Übergang.
48         """
49         temp_anomaly = temp - self.base_temp

```

```

41     # Kritischer Schwellenwert: bei globaler
Mitteltemperatur < 10°C → Eis wächst stark
42     T_crit = -4.0 # Anomalie von -4°C entspricht 10°C
global
43     # Sigmoid: Eisbedeckung steigt stark unter T_crit
ice = 0.1 + 0.7 / (1 + np.exp(2.0 * (temp_anomaly -
44     T_crit)))
45     albedo = 0.3 + 0.4 * ice
46     return -5.0 * (albedo - 0.3)
47
48     def co2_effect(self, temp):
49         temp_anomaly = temp - self.base_temp
50         self.co2_level = np.clip(280 + 8 * temp_anomaly,
180, 400)
51         forcing = 5.35 * np.log(self.co2_level / 280)
52         return 0.5 * forcing
53
54 #
-----
55 # 3. HAUPTSIMULATION
56 #
-----
57 def simulate_scenario(co2_spike=False, volcano=False):
58     temp = np.full_like(years, 14.0)
59     feedback = ClimateFeedback()
60     ice_hist = []
61     co2_hist = []
62
63     for i in range(len(years)):
64         if i == 0:
65             ice_hist.append(0.1 + 0.7 / (1 + np.exp(2.0 *
(0.0 - (-4.0)))))
66             co2_hist.append(280)
67             continue
68
69         # Astronomisches Forcing
70         forcing = (
71             2.5 * (ecc[i] - 0.032) / 0.027 +
72             2.0 * (obliquity[i] - 23.3) / 1.2 +
73             1.5 * precession[i]
74         )
75
76         # Zusätzliche Forcings
77         add = 0.0

```

```

78     if co2_spike and years[i] <= 2000:
79         add += 2.0
80     if volcano and years[i] <= 10:
81         add -= 4.0
82
83     # Rückkopplungen
84     albedo_fb = feedback.albedo_effect(temp[i-1])
85     co2_fb    = feedback.co2_effect(temp[i-1])
86     total_forcing = forcing + add + albedo_fb + co2_fb
87
88     # Temperatur-Update
89     temp[i] = 0.8 * temp[i-1] + 0.2 *
    (feedback.base_temp + total_forcing)
90
91     # Zustand speichern
92     temp_anomaly = temp[i] - feedback.base_temp
93     ice = 0.1 + 0.7 / (1 + np.exp(2.0 * (temp_anomaly -
    (-4.0))))
94     ice_hist.append(ice)
95     co2_hist.append(feedback.co2_level)
96
97     return temp, np.array(ice_hist), np.array(co2_hist)
98
99 # Simulationen
100 temp1, ice1, co2_1 = simulate_scenario(False, False) #
    Natürlich
101 temp2, ice2, co2_2 = simulate_scenario(True, False) #
    2CO-Stoß
102 temp3, ice3, co2_3 = simulate_scenario(False, True) #
    Vulkan
103
104 #
    -----
105 # 4. AUSWERTUNG
106 #
    -----
107 def find_glaciation_start(temp, threshold=10.0,
    duration_years=5000):
108     duration_steps = duration_years // 1000
109     below = (temp < threshold)
110     for i in range(len(temp) - duration_steps + 1):
111         if np.all(below[i:i + duration_steps]):
112             return years[i] / 1000
113     return None

```

```

114
115 t1 = find_glaciation_start(temp1)
116 t2 = find_glaciation_start(temp2)
117 t3 = find_glaciation_start(temp3)
118
119 print("\n Ergebnis: Beginn der nächsten Eiszeit (Temperatur
    < 10.0°C)")
120 print(f"    - Natürlich:      in {t1:.0f} Tausend Jahren" if
    t1 else "    - Natürlich:      keine Eiszeit innerhalb 150
    ka")
121 print(f"    - mit 2CO-Stoß:  in {t2:.0f} Tausend Jahren" if
    t2 else "    - mit 2CO-Stoß:  keine Eiszeit innerhalb 150
    ka")
122 print(f"    - nach Vulkanausbruch: in {t3:.0f} Tausend
    Jahren" if t3 else "    - nach Vulkanausbruch: keine
    Eiszeit innerhalb 150 ka")
123
124 #
    -----
125 # 5. KRÜMMUNG ALS DIAGNOSE (optional)
126 #
    -----
127 def calculate_curvature(temp, dt=1000):
128     dT = np.gradient(temp, dt)
129     d2T = np.gradient(dT, dt)
130     kappa = np.abs(d2T) / (1 + dT**2)**1.5
131     return kappa
132
133 kappa1 = calculate_curvature(temp1)
134
135 # Plot: Krümmung steigt vor Eiszeitbeginn
136 plt.figure(figsize=(12, 4))
137 plt.plot(time_ka, kappa1, 'k-', label="Krümmung  $\kappa(t)$ ")
138 plt.axvline(t1, color='r', linestyle='--',
    label=f"Eiszeitbeginn ({t1:.0f} ka)")
139 plt.title("Krümmung als Resonanzindikator - steigt vor
    Eiszeitbeginn")
140 plt.xlabel("Zeit (Tausend Jahre)")
141 plt.ylabel(" $\kappa(t)$ ")
142 plt.legend()
143 plt.grid(True, alpha=0.3)
144 plt.tight_layout()
145 plt.savefig("klima_eiszeiten_kruemmung_diagnose.png",
    dpi=300, bbox_inches='tight')

```

```

146 plt.show()
147
148 #
149 # 6. PLOT: TEMPERATUR + CO2 ÜBER ZEIT (für LaTeX-Bericht)
150 #
151 plt.figure(figsize=(12, 8))
152
153 # Oberes Subplot: Temperatur
154 plt.subplot(2, 1, 1)
155 plt.plot(time_ka, temp1, 'b-', label='Natürlich')
156 plt.plot(time_ka, temp2, 'r--', label='Anthropogener
    2CO-Stoß')
157 plt.plot(time_ka, temp3, 'g-.', label='Vulkanausbruch')
158 plt.axhline(10.0, color='k', linestyle=':', alpha=0.7,
    label='Eiszeitschwelle (10°C)')
159 if t1: plt.axvline(t1, color='b', linestyle='--', alpha=0.7)
160 if t2: plt.axvline(t2, color='r', linestyle='--', alpha=0.7)
161 if t3: plt.axvline(t3, color='g', linestyle='--', alpha=0.7)
162 plt.ylabel('Globale Mitteltemperatur (°C)')
163 plt.title('Simulation der nächsten Eiszeit -
    Temperaturverlauf')
164 plt.legend()
165 plt.grid(True, alpha=0.3)
166
167 # Unteres Subplot: 2CO-Konzentration
168 plt.subplot(2, 1, 2)
169 plt.plot(time_ka, co2_1, 'b-', label='Natürlich')
170 plt.plot(time_ka, co2_2, 'r--', label='Anthropogener
    2CO-Stoß')
171 plt.plot(time_ka, co2_3, 'g-.', label='Vulkanausbruch')
172 plt.ylabel('2CO-Konzentration (ppm)')
173 plt.xlabel('Zeit (Tausend Jahre)')
174 plt.title('Atmosphärische 2CO-Konzentration')
175 plt.legend()
176 plt.grid(True, alpha=0.3)
177
178 plt.tight_layout()
179 plt.savefig("ergebnisse_klimasimulation.png", dpi=300,
    bbox_inches='tight')
180 print("□ Plot gespeichert: ergebnisse_klimasimulation.png")
181 plt.show()
182

```

```
183 plt.close("all")
```

Listing A.2: Simulation: Nächste Eizeit

A.3 DWD-Datei konvertieren in csv, (Abschn. 3)

```

1 # klima_dwd_konvertieren_in_csv.py
2 import pandas as pd
3
4 # Datei und Parameter
5 dwd_file = 'produkt_tu_stunde_20240211_20250813_03987.txt'
6 start_date = '2024021100' # Startdatum
7 days_needed = 60 # 60 Tage
8
9 try:
10     # Daten laden
11     dwd_data = pd.read_csv(dwd_file, sep=';',
12                             encoding='utf-8')
13
14     # Zeitstempel in Tage umrechnen
15     dwd_data['time'] =
16     (pd.to_datetime(dwd_data['MESS_DATUM'],
17                     format='%Y%m%d%H') -
18      pd.to_datetime(start_date,
19                     format='%Y%m%d%H')).dt.total_seconds() / (24 * 3600)
20
21     # Spalten auswählen und umbenennen
22     dwd_data = dwd_data[['time',
23                          'TT_TU']].rename(columns={'TT_TU': 'temperature'})
24
25     # Ungültige Werte filtern
26     dwd_data = dwd_data[dwd_data['temperature'] != -999]
27
28     # Auf 60 Tage beschränken
29     dwd_data = dwd_data[(dwd_data['time'] >= 0) &
30                         (dwd_data['time'] <= days_needed)]
31
32     # Prüfen, ob genügend Daten vorhanden sind
33     if len(dwd_data) < 100:
34         raise ValueError(f"Nicht genügend Daten: Nur
35                           {len(dwd_data)} Messungen gefunden.")

```

```

29
30     # In CSV speichern
31     dwd_data.to_csv('temperature_data.csv', index=False)
32     print("temperature_data.csv erfolgreich erstellt mit",
33           len(dwd_data), "Messungen.")
34 except FileNotFoundError:
35     print(f"Fehler: {dwd_file} nicht gefunden.")
36 except Exception as e:
37     print(f"Fehler bei der Konvertierung: {e}")

```

Listing A.3: DWD-Datei konvertieren

A.4 Wetteraktivität - Korrelation DWD u. Simulation, (Abschn. 3.6)

```

1  # wetteraktivitaet_korrelation_dwd_simulation.py
2  import numpy as np
3  import matplotlib.pyplot as plt
4  from scipy.fft import fft, fftfreq
5  from scipy.signal import savgol_filter
6  from scipy.integrate import solve_ivp
7  from scipy.interpolate import interp1d
8  import pandas as pd
9  import os
10 from sklearn.metrics import mean_squared_error
11 from scipy.stats import pearsonr
12 from scipy.ndimage import gaussian_filter1d
13 from scipy.signal import correlate
14
15 # =====
16 # 1. KONFIGURATION
17 # =====
18
19 class Config:
20     days = 60
21     dt = 0.5 # Stunden
22     T_base = 15.0
23     daily_amp = 2.0
24     daily_period = 24.0
25     synoptic_amp = 1.0
26     synoptic_period = 7.5 * 24

```

```

27     feedback_strength = 0.25
28     base_damping = 0.07
29     nonlinear_factor = 0.0012
30     noise_amp = 0.45
31     use_impulse_noise = True # wichtig für Front-Rauschen!
32     impulse_prob = 0.015
33     n_target = 8
34     data_file = 'temperature_data.csv'
35     output_plot =
36     'klima_wetteraktivitaet_tiefdruck_indikator.png'
37
38     # □ Diese Zeile anpassen:
39     window_smooth_curvature = 61 # von 81 → 71 (besser für
40     Frontcluster)
41
42     front_detection_window_h = 4 # Glättungsfenster für
43     Indikator (in h)
44
45     cfg = Config()
46     cfg.hours = cfg.days * 24
47     cfg.t = np.arange(0, cfg.hours, cfg.dt)
48     cfg.time_days = cfg.t / 24
49     cfg.N = len(cfg.t)
50
51     # In der Config:
52
53     cfg.noise_amp = 0.45 # von 0.7 → 0.45 (weniger
54     Rauschen)
55     cfg.use_impulse_noise = True # erstmal Gauß-Rauschen nutzen
56     (realistischer)
57     cfg.synoptic_amp = 1.0 # von 1.2 → 1.0 (sanftere
58     Modulation)
59     cfg.nonlinear_factor = 0.0012 # leicht reduzieren, um
60     Überreaktion zu vermeiden
61
62     # =====
63     # 2. ERWEITERTE ODE MIT VORAB-RAUSCHEN
64     # =====
65
66     def generate_noise(seed=42):
67         np.random.seed(seed)
68         t = cfg.t
69         noise = np.zeros_like(t)

```

```

64 # Cluster: aktive Wetterphasen mit mehr Fronten
65 clusters = [
66     (5, 15, 12),    # Frühe Aktivität
67     (20, 30, 15),   # Mittlere Phase
68     (33, 40, 30),   # Hauptaktivität 1
69     (44, 50, 25),   # Hauptaktivität 2
70     (54, 60, 40),   # Starke Endphase - viele Fronten!
71 ]
72 total_fronts = sum(count for _, _, count in clusters)
73
74 front_times = []
75 for start_day, end_day, count in clusters:
76     start_h = start_day * 24
77     end_h = end_day * 24
78     front_times.extend(np.random.uniform(start_h, end_h,
79 count))
80 front_times = np.array(front_times)
81
82 # Zufällige Fronttypen: Warm (+) oder Kalt (-)
83 front_types = np.random.choice([1, -1],
84 size=len(front_times))
85
86 # Frontsteilheit: moderat halten, um <math>\langle \kappa \rangle</math> nicht zu erhöhen
87 slope_magnitude = 2.2 # nicht 2.5 → sonst wird <math>\langle \kappa \rangle</math> zu
88 hoch
89 spike_duration = 4.0 # 4 Stunden Dauer
90 dt = cfg.dt
91
92 for t_front, front_type in zip(front_times, front_types):
93     start_idx = int((t_front - spike_duration) / dt)
94     end_idx = int((t_front + spike_duration) / dt)
95     start_idx = max(0, start_idx)
96     end_idx = min(len(t), end_idx)
97
98     for i in range(start_idx, end_idx):
99         t_i = t[i]
100         delta_t = t_i - t_front
101         if -spike_duration <= delta_t < 0:
102             # Linearer Anstieg vor Frontmitte
103             noise[i] += front_type * slope_magnitude *
(delta_t + spike_duration) / spike_duration
104         elif 0 <= delta_t <= spike_duration:
105             # Linearer Abfall nach Frontmitte

```

```

103         noise[i] += front_type * slope_magnitude *
104         (spike_duration - delta_t) / spike_duration
105
106     # Sehr leichte Hintergrundfluktuation
107     noise += np.random.RandomState(seed + 1).normal(0, 0.05,
108     len(t)) # kaum zusätzliches Rauschen
109     return noise
110
111 def dT_dt_smooth(T, t, params, noise_interp):
112     """
113     Glatte ODE-Funktion für solve_ivp.
114     noise_interp: interpolierte Rauschfunktion
115     """
116     T = T[0] if isinstance(T, (list, np.ndarray)) else T
117     feedback, nonlinear = params
118
119     # Antriebe
120     daily = cfg.daily_amp * np.sin(2 * np.pi * t /
121     cfg.daily_period)
122     synoptic = cfg.synoptic_amp * np.sin(2 * np.pi * t /
123     cfg.synoptic_period)
124     noise = noise_interp(t)
125
126     forcing = daily + synoptic + noise
127
128     # Rückkopplung
129     anomaly = np.clip(T - cfg.T_base, -5, 5)
130     feedback_term = feedback * anomaly + nonlinear *
131     anomaly**2
132
133     # Zeitabhängige Dämpfung (stärker nachts)
134     damping_t = cfg.base_damping * (1.0 + 0.4 * np.cos(2 *
135     np.pi * t / cfg.daily_period))
136
137     dT = -damping_t * (T - cfg.T_base) + forcing +
138     feedback_term
139     return [dT]
140
141 def simulate_temperature(params=None, seed=42):
142     if params is None:
143         params = (cfg.feedback_strength,
144         cfg.nonlinear_factor)

```

```

139 # □ Nur dieses Rauschen nutzen!
140 noise_series = generate_noise(seed)
141 noise_func = interp1d(cfg.t, noise_series, kind='zero',
142 fill_value="extrapolate")
143
144 sol = solve_ivp(
145     fun=lambda t, T: dT_dt_smooth(T, t, params,
146 noise_func),
147     t_span=(cfg.t[0], cfg.t[-1]),
148     y0=[cfg.T_base],
149     method='RK23',
150     t_eval=cfg.t,
151     rtol=1e-5,
152     atol=1e-7
153 )
154
155 temp = sol.y[0]
156 return np.clip(temp, 5, 25)
157
158 # =====
159 # 3. DATENLADEN & VALIDIERUNG
160 # =====
161
162 def load_real_data():
163     if not os.path.exists(cfg.data_file):
164         print(f"□ {cfg.data_file} nicht gefunden. Nutze
165 Dummy-Daten.")
166         dummy = simulate_temperature(seed=123) +
167 np.random.normal(0, 0.4, len(cfg.t))
168         return cfg.time_days, dummy
169
170     try:
171         df = pd.read_csv(cfg.data_file)
172         time_real = df['time'].values
173         temp_real = df['temperature'].values
174
175         if len(time_real) < 100 or max(time_real) < cfg.days:
176             raise ValueError(f"Zu wenige Daten:
177 {len(time_real)}, max. {max(time_real):.1f} Tage.")
178         if np.any(temp_real == -999):
179             mask = temp_real != -999
180             time_real, temp_real = time_real[mask],
181 temp_real[mask]

```

```

177     interp_func = interp1d(time_real, temp_real,
178                             kind='linear', fill_value="extrapolate")
179     temp_interp = interp_func(cfg.time_days)
180     return cfg.time_days, np.clip(temp_interp, -10, 30)
181
182 except Exception as e:
183     print(f"❌ Fehler: {e}. Nutze Dummy-Daten.")
184     return cfg.time_days, simulate_temperature(seed=123)
185     + np.random.normal(0, 0.4, len(cfg.t))
186
187 # =====
188 # 4. KRÜMMUNGSANALYSE
189 # =====
190
191 def calculate_curvature(temp, dt_hours, window=81):
192     dT = savgol_filter(np.gradient(temp, dt_hours),
193                         window_length=window, polyorder=1)
194     d2T = savgol_filter(np.gradient(dT, dt_hours),
195                          window_length=window, polyorder=1)
196     denominator = (1 + dT**2)**(1.5)
197     denominator = np.where(denominator < 1e-8, 1e-8,
198                             denominator)
199     curvature = np.abs(d2T) / denominator
200     curvature = np.nan_to_num(curvature, 0)
201     max_k = np.max(curvature) if np.max(curvature) > 0 else
202     1.0
203     return curvature / max_k # Normierung auf [0,1]
204
205 # =====
206 # 5. SPEKTRALANALYSE
207 # =====
208
209 def dominant_frequency(temp, dt_hours, total_days,
210                        n_target=8):
211     N = len(temp)
212     yf = fft(temp - np.mean(temp))
213     xf = fftfreq(N, dt_hours / 24)[:N//2]
214     amplitudes = 2.0 / N * np.abs(yf[:N//2])
215     target_freq = n_target / total_days
216     idx = np.argmin(np.abs(xf - target_freq))
217     return xf[idx], xf, amplitudes
218
219 # =====
220 # 6. TIEFDRUCK-INDIKATOR: FRONTWARNUNG

```

```

214 # =====
215
216 def detect_front_warnings(curvature, dt_hours,
217     kappa_threshold=0.45, dK_threshold=0.03):
218     """
219     Erkennt Frontdurchgänge anhand von:
220     - hoher Krümmung
221     - positiver Ableitung der (geglätteten) Krümmung
222     """
223     window_size = int(cfg.front_detection_window_h /
224         dt_hours)
225     smoothed = np.convolve(curvature,
226         np.ones(window_size)/window_size, mode='same')
227     dK_dt = np.gradient(smoothed, dt_hours)
228
229     high_kappa = smoothed > kappa_threshold
230     increasing = dK_dt > dK_threshold
231
232     warnings = high_kappa & increasing
233     warning_times = cfg.time_days[warnings]
234     return warnings, warning_times, smoothed
235
236 # =====
237 # 7. HAUPTPROGRAMM
238 # =====
239
240 if __name__ == "__main__":
241     # — SIMULATION —
242     temp_sim = simulate_temperature(seed=42)
243     kappa_sim = calculate_curvature(temp_sim, cfg.dt,
244         window=cfg.window_smooth_curvature)
245     front_alert_sim, alert_times_sim, kappa_smooth_sim =
246         detect_front_warnings(kappa_sim, cfg.dt)
247     n_sim, xf_sim, amp_sim = dominant_frequency(temp_sim,
248         cfg.dt, cfg.days, cfg.n_target)
249
250     # — ECHTE DATEN —
251     time_real, temp_real = load_real_data()
252     kappa_real = calculate_curvature(temp_real, cfg.dt,
253         window=cfg.window_smooth_curvature)
254     front_alert_real, alert_times_real, kappa_smooth_real =
255         detect_front_warnings(kappa_real, cfg.dt)
256     n_real, xf_real, amp_real =
257         dominant_frequency(temp_real, cfg.dt, cfg.days,

```

```

    cfg.n_target)

249
250 # — PHASE-PLOT —
251 def smooth_gradient(temp, dt):
252     grad = np.gradient(temp, dt)
253     return savgol_filter(grad, window_length=101,
polyorder=1)

254
255 dT_sim = smooth_gradient(temp_sim, cfg.dt)
256 dT_real = smooth_gradient(temp_real, cfg.dt)
257
258 # — NEUE VARIABLEN FÜR KORRELATION UND VISUALISIERUNG
—
259 # — VISUALISIERUNG, TEIL 1: DYNAMIK & SPEKTRUM —
260 fig1, axs1 = plt.subplots(4, 1, figsize=(14, 12),
gridspec_kw={'height_ratios': [2, 1.5, 1.5, 1.5]})

261
262 # 1. Temperatur
263 ax = axs1[0]
264 ax.plot(cfg.time_days, temp_sim, 'b-', lw=1.2,
label='Simulation')
265 ax.plot(time_real, temp_real, 'orange', alpha=0.7, lw=1,
label='DWD-Daten')
266 ax.axhline(cfg.T_base, color='gray', ls='--', alpha=0.5,
label='Basistemperatur')
267 ax.set_title('1. Temperaturverlauf: Simulation vs.
Realität', fontsize=13)
268 ax.set_ylabel('Temp (°C)')
269 ax.legend()
270 ax.grid(True, alpha=0.3)
271
272 # 2. Krümmung & Warnungen
273 ax = axs1[1]
274 ax.plot(cfg.time_days, kappa_sim, 'b-', label='κ
(Simulation)', lw=0.8, alpha=0.8)
275 ax.plot(time_real, kappa_real, 'orange', alpha=0.7,
lw=0.8, label='κ (DWD)')
276 ax.plot(cfg.time_days, kappa_smooth_sim, 'b-', lw=2,
alpha=0.6)
277 ax.plot(time_real, kappa_smooth_real, 'orange', lw=2,
alpha=0.6)
278 ax.fill_between(cfg.time_days, kappa_sim,
where=front_alert_sim, color='blue', alpha=0.2,
label='Frontwarnung (Sim)')

```

```

279     ax.fill_between(time_real, kappa_real,
where=front_alert_real, color='orange', alpha=0.2,
label='Frontwarnung (DWD)')
280     ax.axhline(0.55, color='r', ls=':', alpha=0.6,
label='Schwelle  $\kappa > 0.55$ ')
281     ax.set_ylabel('Krümmung  $\kappa$ ')
282     ax.set_title('2. Krümmung & Frontwarnungen', fontsize=13)
283     ax.legend()
284     ax.grid(True, alpha=0.3)
285
286     # 3. Spektrum
287     ax = axs1[2]
288     ax.plot(xf_sim * cfg.days, amp_sim, 'b-',
label='Simulation')
289     ax.axvline(n_sim * cfg.days, color='blue', ls='--',
alpha=0.6, label=f'Sim:  $n \approx \{n\_sim * cfg.days : .1f\}$ ')
290     ax.plot(xf_real * cfg.days, amp_real, 'orange',
alpha=0.7, label='DWD-Daten')
291     ax.axvline(n_real * cfg.days, color='orange', ls='--',
alpha=0.6, label=f'Real:  $n \approx \{n\_real * cfg.days : .1f\}$ ')
292     ax.set_xlim(0, 15)
293     ax.set_xlabel('Modenzahl n (Zyklen in 60 Tagen)')
294     ax.set_ylabel('Amplitude')
295     ax.set_title('3. Spektralanalyse: Dominante Moden',
fontsize=13)
296     ax.legend()
297     ax.grid(True, alpha=0.3)
298
299     # 4. Phase-Plot
300     ax = axs1[3]
301     ax.plot(temp_sim, dT_sim, 'b-', label='Simulation',
lw=0.8)
302     ax.plot(temp_real, dT_real, 'orange', alpha=0.7,
label='DWD-Daten', lw=0.8)
303     ax.set_xlabel('Temperatur ( $^{\circ}\text{C}$ )')
304     ax.set_ylabel('dT/dt ( $^{\circ}\text{C}/\text{h}$ )')
305     ax.set_title('4. Phase-Plot: Dynamik und Hysterese',
fontsize=13)
306     ax.legend()
307     ax.grid(True, alpha=0.3)
308
309     plt.tight_layout()
310
plt.savefig('klima_wetteraktivitaet_dynamik_spektrum.png',

```

```

311     dpi=300, bbox_inches='tight')
312     plt.show()
313
314     # — NEUE KORRELATIONSANALYSE: MIT
315     ZEITVERSCHIEBUNGSKORREKTUR —
316     # 1. Glätte die Krümmung mit 24h-Laufmittel
317     window_24h = int(24 / cfg.dt)
318     activity_sim = np.convolve(kappa_sim,
319     np.ones(window_24h)/window_24h, mode='same')
320     activity_real = np.convolve(kappa_real,
321     np.ones(window_24h)/window_24h, mode='same')
322
323     # 2. Zusätzliche Gauss-Glättung (z .B. 2-Tage-Filter)
324     sigma_days = 2.0
325     sigma_points = sigma_days / (cfg.dt / 24)
326     activity_sim_smooth = gaussian_filter1d(activity_sim,
327     sigma=sigma_points)
328     activity_real_smooth = gaussian_filter1d(activity_real,
329     sigma=sigma_points)
330
331     # 3. Kreuzkorrelation für Zeitverschiebung
332     a_sim = activity_sim_smooth -
333     np.mean(activity_sim_smooth)
334     a_real = activity_real_smooth -
335     np.mean(activity_real_smooth)
336
337     correlation = correlate(a_sim, a_real)
338     lags = np.arange(-len(a_real) + 1, len(a_sim)) # in
339     Zeitschritten
340     lag_in_days = lags * cfg.dt / 24 # Umrechnung in Tage
341
342     # Finde Lag mit maximaler Korrelation
343     best_lag_idx = np.argmax(correlation)
344     best_lag_days = lag_in_days[best_lag_idx]
345     max_corr = correlation[best_lag_idx] / (np.std(a_sim) *
346     np.std(a_real) * len(a_sim)) # normiert
347
348     # 5. Korrelation OHNE Zeitverschiebung (zum Vergleich)
349     r_simple, p_simple = pearsonr(activity_sim_smooth,
350     activity_real_smooth[:len(activity_sim_smooth)])
351
352     # — VISUALISIERUNG, TEIL 2: WETTERAKTIVITÄT MIT
353     ALIGNMENT & ANNOTATIONEN —
354     fig2, ax2 = plt.subplots(1, 1, figsize=(14, 6))

```

```

343
344     # Zeitverschiebung
345     shift_days = best_lag_days # □ Jetzt dynamisch aus
Analyse
346     time_shifted = cfg.time_days - shift_days
347     valid = (time_shifted >= 0) & (time_shifted <= cfg.days)
348
349     # Plot der geglätteten, alignierten Aktivität
350     ax2.plot(time_shifted[valid],
activity_sim_smooth[valid], 'b-', lw=2,
label=f'Simulation (verschoben um +{shift_days:.1f}
Tage)')
351     ax2.plot(time_real, activity_real_smooth, 'orange',
lw=2, label='DWD-Daten (geglättet)')
352     ax2.axhline(0.2, color='r', ls=':', alpha=0.6,
label='Schwelle: hohe Aktivität')
353
354     # Formatierung
355     ax2.set_xlim(0, cfg.days)
356     ax2.set_ylim(0, 1.05 * max(np.max(activity_sim_smooth),
np.max(activity_real_smooth)))
357     ax2.set_xlabel('Zeit (Tage)', fontsize=12)
358     ax2.set_ylabel('⟨κ⟩ (24h, geglättet)', fontsize=12)
359     ax2.set_title('Wetteraktivitätsindex: Simulation vs.
Realität (mit Zeitalignment)', fontsize=14, pad=20)
360     ax2.legend(loc='upper right', fontsize=11)
361     ax2.grid(True, alpha=0.3)
362
363     # === ANNOTATIONEN ===
364
365     # 1. Pfeil: Zeitverschiebung
366     ax2.annotate('', xy=(10, 0.6), xytext=(10 + shift_days,
0.6),
367                 arrowprops=dict(arrowstyle='<->',
color='purple', lw=2, alpha=0.7),
368                 annotation_clip=False)
369     ax2.text(10 + shift_days/2, 0.62, f'+{shift_days:.1f}
Tage', ha='center', fontsize=11, color='purple',
weight='bold',
370             bbox=dict(boxstyle="round,pad=0.3",
facecolor="wheat", alpha=0.8))
371
372     # 2. Textbox: Korrelation mit/ohne Shift

```

```

373     bbox_style = dict(boxstyle="round,pad=0.5",
374     facecolor="lightblue", alpha=0.8, edgecolor='navy')
375     ax2.text(0.02, 0.98,
376     f"Maximale Korrelation:\n r = {max_corr:.3f}
377     (mit Shift)\n r = {r_simple:.3f} (ohne Shift)",
378     transform=ax2.transAxes, fontsize=11,
379     verticalalignment='top',
380     bbox=bbox_style, ha='left')
381
382     # 3. Pfeil: Gemeinsame Aktivitätsspitze bei ~58 Tagen
383     peak_day = 58.5
384     if peak_day in time_real:
385         idx = np.argmin(np.abs(time_real - peak_day))
386         ax2.annotate('Gemeinsame\nAktivitätsspitze',
387         xy=(time_real[idx],
388         activity_real_smooth[idx]),
389         xytext=(peak_day - 8, 0.8),
390         arrowprops=dict(arrowstyle='->',
391         color='darkgreen', lw=1.5),
392         fontsize=11, color='darkgreen',
393         ha='center')
394
395     # 4. Hinweis: Phasenverschiebung, nicht Frequenzfehler
396     ax2.annotate('Phasenverschiebung,\nkein Frequenzfehler',
397     xy=(20, 0.4), xytext=(30, 0.3),
398     arrowprops=dict(arrowstyle='->',
399     color='gray', lw=1.2),
400     fontsize=10, color='gray', ha='left',
401     bbox=dict(boxstyle="round,pad=0.3",
402     facecolor="white", alpha=0.7))
403
404     # 5. Hervorhebung: Ähnliche Muster trotz Verschiebung
405     ax2.axvspan(10, 15, color='blue', alpha=0.1)
406     ax2.axvspan(40, 45, color='orange', alpha=0.1)
407     ax2.text(12.5, 0.1, 'Muster\nevergleichbar', ha='center',
408     fontsize=9, color='blue', alpha=0.9)
409     ax2.text(42.5, 0.1, 'Muster\nevergleichbar', ha='center',
410     fontsize=9, color='orange', alpha=0.9)
411
412     plt.tight_layout()
413     plt.savefig('klima_wetteraktiv_alignment_annotiert.png',
414     dpi=150, bbox_inches='tight')
415     plt.show()

```

```

406 # — ERGEBNISSE AUSGEBEN —
407 print(f"\n Korrelationsanalyse der Wetteraktivität:")
408 print(f"  Beste Zeitverschiebung: +{best_lag_days:.1f}
Tage (Simulation nach vorne schieben)")
409 print(f"  Maximale Korrelation: r = {max_corr:.3f}")
410 print(f"  Ohne Shift: r = {r_simple:.3f}")
411
412
413 # — ERGEBNISSE —
414 print(f"\n Simulation: Dominante Mode: n ≈
{n_sim*cfg.days:.1f}")
415 print(f"  Max. κ: {np.max(kappa_sim):.3f}, Mittel κ:
{np.mean(kappa_sim):.3f}")
416 print(f"  Anzahl Frontwarnungen:
{len(alert_times_sim)}")
417 print(f"  Warnzeiten: {alert_times_sim.round(1)}")
418
419 print(f"\n DWD-Daten: Dominante Mode: n ≈
{n_real*cfg.days:.1f}")
420 print(f"  Max. κ: {np.max(kappa_real):.3f}, Mittel κ:
{np.mean(kappa_real):.3f}")
421 print(f"  Anzahl Frontwarnungen (DWD):
{len(alert_times_real)}")
422 print(f"  Warnzeiten (DWD):
{alert_times_real.round(1)}")
423
424 # — SENSITIVITÄT —
425 print(f"\n Sensitivitätsanalyse (feedback_strength):")
426 for fs in [0.2, 0.25, 0.3]:
427     temp = simulate_temperature(params=(fs,
cfg.nonlinear_factor), seed=43)
428     kappa = calculate_curvature(temp, cfg.dt)
429     n_mode, _, _ = dominant_frequency(temp, cfg.dt,
cfg.days)
430     print(f"  feedback={fs}: ≈n{n_mode*cfg.days:.1f},
⟨κ⟩≈{np.mean(kappa):.3f}")
431
432 # — NEUE KORRELATIONSANALYSE —
433 # (Bereits vorher definiert - hier nur Ausgabe, keine
Neuberechnung)
434 a_sim = activity_sim_smooth - np.mean(activity_sim_smooth)
435 a_real = activity_real_smooth - np.mean(activity_real_smooth)
436
437 correlation = correlate(a_sim, a_real)

```

```

438 lags = np.arange(-len(a_real) + 1, len(a_sim))
439 lag_in_days = lags * cfg.dt / 24
440
441 best_lag_idx = np.argmax(correlation)
442 best_lag_days = lag_in_days[best_lag_idx]
443 max_corr = correlation[best_lag_idx] / (np.std(a_sim) *
    np.std(a_real) * len(a_sim))
444
445 print(f"\n Korrelationsanalyse der Wetteraktivität:")
446 print(f"  Beste Zeitverschiebung: +{best_lag_days:.1f} Tage
    (Simulation nach vorne schieben)")
447 print(f"  Maximale Korrelation: r = {max_corr:.3f}")
448
449 r_simple, p_simple = pearsonr(activity_sim_smooth,
    activity_real_smooth[:len(activity_sim_smooth)])
450 print(f"  Ohne Shift: r = {r_simple:.3f}")

```

Listing A.4: Visualisierung Wetteraktivität - Korrelation DWD u. Simulation

A.5 Prognosefähigkeit von Wetteraktivität, (Kap. 4)

```

1 # =====
2 # □ WETTERFROSCH: PROGNOSEFAEHIGKEITS-TEST MIT ZEITALIGNMENT
3 # Strukturiertes, robustes Skript - ohne Emojis, mit
  Zeitverschiebung
4 # =====
5 # klima_sturmwellen_prognosefaehigkeit.py
6 import numpy as np
7 import pandas as pd
8 import matplotlib.pyplot as plt
9 from scipy.signal import savgol_filter
10 from scipy.ndimage import gaussian_filter1d
11 from scipy.interpolate import interp1d
12 from scipy.integrate import solve_ivp
13 import os
14 from scipy.fft import fft, fftfreq
15
16 # =====
17 # 1. KONFIGURATION
18 # =====
19 class Config:
20     days = 60

```

```

21 dt = 0.5 # Stunden
22 T_base = 15.0
23 daily_amp = 2.0
24 daily_period = 24.0
25 synoptic_amp = 1.0
26 synoptic_period = 7.5 * 24
27 feedback_strength = 0.25
28 base_damping = 0.07
29 nonlinear_factor = 0.0012
30 noise_amp = 0.45
31 use_impulse_noise = True
32 impulse_prob = 0.015
33 n_target = 8
34 data_file = 'temperature_data.csv'
35 output_dir = '.'
36
37 cfg = Config()
38 cfg.hours = cfg.days * 24
39 cfg.t = np.arange(0, cfg.hours, cfg.dt)
40 cfg.time_days = cfg.t / 24
41 cfg.N = len(cfg.t)
42
43 # =====
44 # 2. DATEN LADEN: DWD POTS DAM
45 # =====
46 def load_real_data():
47     if not os.path.exists(cfg.data_file):
48         raise FileNotFoundError(f"Datei '{cfg.data_file}'
nicht gefunden. Bitte hinzufügen.")
49
50     print("Lade DWD-Daten...")
51     df = pd.read_csv(cfg.data_file)
52     if 'time' not in df.columns or 'temperature' not in
df.columns:
53         raise ValueError("CSV muss Spalten 'time' und
'temperature' enthalten.")
54
55     time_real = df['time'].values
56     temp_real = df['temperature'].values
57
58     valid = (temp_real != -999) & np.isfinite(temp_real)
59     time_real, temp_real = time_real[valid], temp_real[valid]
60

```

```

61     interp_func = interp1d(time_real, temp_real,
62                             kind='linear', fill_value="extrapolate")
63     temp_interp = interp_func(cfg.time_days)
64     return cfg.time_days, np.clip(temp_interp, -10, 35)
65
66 # =====
67 # 3. TEMPERATURSIMULATION
68 # =====
69 def generate_noise(seed=42):
70     np.random.seed(seed)
71     t = cfg.t
72     noise = np.zeros_like(t)
73
74     clusters = [
75         (5, 15, 12),
76         (20, 30, 15),
77         (33, 40, 30),
78         (44, 50, 25),
79         (54, 60, 40),
80     ]
81     front_times = []
82     for start_day, end_day, count in clusters:
83         start_h = start_day * 24
84         end_h = end_day * 24
85         front_times.extend(np.random.uniform(start_h, end_h,
86 count))
87     front_times = np.array(front_times)
88     front_types = np.random.choice([1, -1],
89 size=len(front_times))
90     slope_magnitude = 2.2
91     spike_duration = 4.0
92
93     for t_front, front_type in zip(front_times, front_types):
94         start_idx = int((t_front - spike_duration) / cfg.dt)
95         end_idx = int((t_front + spike_duration) / cfg.dt)
96         start_idx = max(0, start_idx)
97         end_idx = min(len(t), end_idx)
98         for i in range(start_idx, end_idx):
99             delta_t = cfg.t[i] - t_front
100             if -spike_duration <= delta_t < 0:
101                 noise[i] += front_type * slope_magnitude *
(delta_t + spike_duration) / spike_duration
102             elif 0 <= delta_t <= spike_duration:

```

```

100         noise[i] += front_type * slope_magnitude *
    (spike_duration - delta_t) / spike_duration
101     return noise
102
103 def dT_dt_smooth(T, t, params, noise_interp):
104     T = T[0] if isinstance(T, (list, np.ndarray)) else T
105     feedback, nonlinear = params
106     daily = cfg.daily_amp * np.sin(2 * np.pi * t /
    cfg.daily_period)
107     synoptic = cfg.synoptic_amp * np.sin(2 * np.pi * t /
    cfg.synoptic_period)
108     noise = noise_interp(t)
109     forcing = daily + synoptic + noise
110     anomaly = np.clip(T - cfg.T_base, -5, 5)
111     feedback_term = feedback * anomaly + nonlinear *
    anomaly**2
112     damping_t = cfg.base_damping * (1.0 + 0.4 * np.cos(2 *
    np.pi * t / cfg.daily_period))
113     dT = -damping_t * (T - cfg.T_base) + forcing +
    feedback_term
114     return [dT]
115
116 def simulate_temperature(seed=42, params=None):
117     if params is None:
118         params = (cfg.feedback_strength,
    cfg.nonlinear_factor)
119     noise_series = generate_noise(seed)
120     noise_func = interp1d(cfg.t, noise_series, kind='zero',
    fill_value="extrapolate")
121     sol = solve_ivp(
122         fun=lambda t, T: dT_dt_smooth(T, t, params,
    noise_func),
123         t_span=(cfg.t[0], cfg.t[-1]),
124         y0=[cfg.T_base],
125         method='RK23',
126         t_eval=cfg.t,
127         rtol=1e-5,
128         atol=1e-7
129     )
130     return np.clip(sol.y[0], 5, 25)
131
132 # =====
133 # 4. KRÜMMUNG & AKTIVITÄT
134 # =====

```

```

135 def calculate_curvature(temp, dt_hours, window=61):
136     dT = savgol_filter(np.gradient(temp, dt_hours),
137                        window_length=window, polyorder=1)
138     d2T = savgol_filter(np.gradient(dT, dt_hours),
139                        window_length=window, polyorder=1)
140     denominator = (1 + dT**2)**1.5
141     denominator = np.where(denominator < 1e-8, 1e-8,
142                            denominator)
143     curvature = np.abs(d2T) / denominator
144     curvature = np.nan_to_num(curvature, 0)
145     max_k = np.max(curvature) if np.max(curvature) > 0 else
146     1.0
147     return curvature / max_k
148
149 def smooth_activity(kappa, dt_hours=0.5):
150     window_size = int(24 / dt_hours)
151     smoothed = np.convolve(kappa,
152                            np.ones(window_size)/window_size, mode='same')
153     sigma_points = 2.0 / (dt_hours / 24)
154     return gaussian_filter1d(smoothed, sigma=sigma_points)
155
156 # =====
157 # 5. PHASEANALYSE: Ist das Modell gegenphasig?
158 # =====
159 def phase_at_target_freq(signal, dt_hours, total_days,
160                          n_target=8):
161     """
162     Berechnet die Phase der dominanten Frequenzkomponente im
163     Signal.
164     n_target: gewünschte Anzahl Zyklen in total_days
165     """
166     N = len(signal)
167     yf = fft(signal - np.mean(signal)) # zentriert
168     xf = fftfreq(N, dt_hours / 24)[:N//2] # Frequenzen in
169     Zyklen pro Gesamtzeit
170     target_freq = n_target / total_days
171     idx = np.argmin(np.abs(xf - target_freq))
172     if idx >= len(yf[:N//2]):
173         idx = -1 # Sicherheitsabfang
174     phase = np.angle(yf[idx]) # Phase in Bogenmaß
175     return phase, xf[idx] * total_days # Phase und
176     tatsächliche Modenzahl n
177
178 # =====

```

```

170 # 5. HAUPTPROGRAMM
171 # =====
172 if __name__ == "__main__":
173     # — 1. Lade echte Daten —
174     time_real, temp_real = load_real_data()
175     print("DWD-Daten erfolgreich geladen.")
176
177     # — 2. Simuliere Temperatur —
178     temp_sim = simulate_temperature(seed=42)
179     print("Temperatursimulation abgeschlossen.")
180
181     # — 3. Berechne Krümmung —
182     kappa_sim = calculate_curvature(temp_sim, cfg.dt)
183     kappa_real = calculate_curvature(temp_real, cfg.dt)
184     print("Krümmung (Wetteraktivität) berechnet.")
185
186     # — NEU: PHASENANALYSE —
187     from scipy.fft import fft, fftfreq # sicherstellen,
188     dass fft importiert ist
189
190     phase_sim, n_sim = phase_at_target_freq(temp_sim,
191     cfg.dt, cfg.days, n_target=8)
192     phase_real, n_real = phase_at_target_freq(temp_real,
193     cfg.dt, cfg.days, n_target=8)
194
195     phase_diff = phase_sim - phase_real
196     phase_diff_deg = np.degrees(phase_diff)
197
198     print(f"\n PHASENANALYSE:")
199     print(f"  Simulation:  n ≈ {n_sim:.1f}, Phase =
200     {phase_sim:6.2f} rad ({np.degrees(phase_sim):6.1f}°)")
201     print(f"  DWD-Daten:  n ≈ {n_real:.1f}, Phase =
202     {phase_real:6.2f} rad ({np.degrees(phase_real):6.1f}°)")
203     print(f"  Phasenunterschied: Δφ = {phase_diff:6.2f} rad
204     = {phase_diff_deg:6.1f}°")
205
206     if abs(abs(phase_diff_deg) - 180) < 30:
207         print("  ☐ Hinweis: Phasenunterschied nahe 180° →
208         gegenphasige Dynamik!")
209     elif abs(phase_diff_deg) < 30 or abs(phase_diff_deg) >
210     330:
211         print("  ☐ Phasenlage gut ausgerichtet.")
212     else:

```

```

205     print(" □ Mittlere Phasenverschiebung - keine klare
Tendenz.")
206
207     # — 4. Glätten —
208     activity_sim = smooth_activity(kappa_sim, cfg.dt)
209     activity_real = smooth_activity(kappa_real, cfg.dt)
210
211     # Interpoliere Simulation auf Real-Zeitachse
212     interp_sim = interp1d(cfg.time_days, activity_sim,
bounds_error=False, fill_value="extrapolate")
213     activity_sim_interp = -interp_sim(time_real)
214
215     # — 5. ZEITALIGNMENT: +29.7 Tage (Simulation nach
vorne schieben)
216     shift_days = 29.7
217     time_shifted = time_real - shift_days
218     valid = (time_shifted >= 0) & (time_shifted <= cfg.days)
219
220     # Korrelation nach Alignment
221     corr_aligned = np.corrcoef(activity_sim_interp[valid],
activity_real[valid])[0, 1]
222     print(f"\n Korrelation nach
+{shift_days:.1f}-Tage-Verschiebung: r =
{corr_aligned:.3f}")
223
224     # — 6. KURZFRISTIGE PROGNOSE: 1 bis 5 Tage
225     print("\n Teste kurzfristige Prognosefähigkeit -(15
Tage):")
226     horizons = [1, 2, 3, 4, 5]
227     results = {h: [] for h in horizons}
228
229     for horizon in horizons:
230         for day0 in np.arange(10, 50, 2):
231             if day0 + horizon > 60:
232                 continue
233
234             # Realität: Tag0 bis Tag0+horizon
235             mask_real = (time_real >= day0) & (time_real <
day0 + horizon)
236             real_window = activity_real[mask_real]
237
238             # Prognose: Simulation von (day0 - horizon -
shift) bis (day0 - shift)
239             sim_start = day0 - horizon - shift_days

```

```

240         sim_end = day0 - shift_days
241         mask_sim = (time_real >= sim_start) & (time_real
< sim_end)
242         sim_window = activity_sim_interp[mask_sim]
243
244         if len(sim_window) == 0 or len(real_window) == 0:
245             continue
246
247         # Interpoliere auf gleiche Länge
248         if len(sim_window) != len(real_window):
249             x_common = np.linspace(0, 1, 50)
250             sim_interp = interp1d(np.linspace(0, 1,
len(sim_window)), sim_window, kind='linear')
251             real_interp = interp1d(np.linspace(0, 1,
len(real_window)), real_window, kind='linear')
252             sim_window = sim_interp(x_common)
253             real_window = real_interp(x_common)
254
255             if np.std(sim_window) > 1e-6 and
np.std(real_window) > 1e-6:
256                 corr = np.corrcoef(sim_window,
real_window)[0, 1]
257                 results[horizon].append(corr)
258
259         # Ausgabe
260         print("\n Kurzfristige Prognosequalität:")
261         for h in horizons:
262             if results[h]:
263                 mean_r = np.mean(results[h])
264                 print(f"  {h:2d} Tage: r = {mean_r:.3f}
(n={len(results[h])})")
265             else:
266                 print(f"  {h:2d} Tage: keine gültigen
Vergleiche")
267
268         # — 7. PLOT: Alignment & Beispielprognose
269         plt.figure(figsize=(12, 8))
270
271         # Alignment
272         plt.subplot(2, 1, 1)
273         plt.plot(time_shifted[valid],
activity_sim_interp[valid], 'b-', lw=1.5,
label='Simulation (aligniert)')

```

```

274 plt.plot(time_real[valid], activity_real[valid],
275           'orange', lw=1.5, label='DWD-Daten')
276 plt.axhline(0.3, color='gray', ls=':', alpha=0.6)
277 plt.xlim(0, 60)
278 plt.ylabel('Wetteraktivität (κ)')
279 plt.title(f'Alignment: +{shift_days:.1f} Tage → r =
280           {corr_aligned:.3f}')
281 plt.legend()
282 plt.grid(True, alpha=0.3)
283
284 # Beispiel: 3-Tage-Prognose
285 plt.subplot(2, 1, 2)
286 day0 = 30
287 h = 3
288 mask_real = (time_real >= day0) & (time_real < day0 + h)
289 mask_sim = (time_real >= day0 - h - shift_days) &
290           (time_real < day0 - shift_days)
291 plt.plot(time_real[mask_real], activity_real[mask_real],
292           'orange', lw=2, label='Realität [Tag -3033]')
293 plt.plot(time_real[mask_sim] + h,
294           activity_sim_interp[mask_sim], 'b--', lw=2,
295           label='Prognose (vorher)')
296 plt.axvline(day0, color='gray', ls='--', alpha=0.7)
297 plt.xlim(day0 - 1, day0 + h + 1)
298 plt.ylabel('κ')
299 plt.xlabel('Zeit (Tage)')
300 plt.title('Beispiel: 3-Tage-Prognose nach Alignment')
301 plt.legend()
302 plt.grid(True, alpha=0.3)
303
304 plt.tight_layout()
305 plt.savefig('klima_sturmwellen_prognose.png', dpi=150,
306           bbox_inches='tight')
307 plt.show()
308 plt.close()
309
310 print("\n Analyse abgeschlossen.")

```

Listing A.5: Visualisierung Prognosefähigkeit von Wetteraktivität

A.6 Resonante Wolkenbildung und Temperatur, (Abschn. 5.4)

```

1 # klima_wolkenformen_era5_korrelation.py
2 # Vollständiges, konsistentes Resonanzmodell mit Krümmung,
   Rückkopplung und Validierung
3
4 import numpy as np
5 import matplotlib.pyplot as plt
6 from scipy.signal import savgol_filter
7 from scipy.ndimage import gaussian_filter1d
8 from scipy.interpolate import interp1d
9 from scipy.fft import fft, fftfreq
10 from scipy.stats import pearsonr
11 from scipy.ndimage import gaussian_filter1d
12 import pandas as pd
13 import os
14 import warnings
15 warnings.filterwarnings("ignore")
16
17 # =====
18 # 1. KONFIGURATION
19 # =====
20 class Config:
21     def __init__(self):
22         self.days = 60
23         self.dt = 1 / 24 # 1 Stunde in Tagen
24         self.t = np.arange(0, self.days, self.dt)
25         self.time_days = self.t
26         self.N = len(self.t)
27         self.data_file = 'temperature_data.csv'
28         self.output_dir = '.'
29         self.feedback_strength = 0.25
30         self.base_temp = 2.5
31         self.daily_amp = 1.5
32         self.synoptic_amp = 2.0
33         self.synoptic_period = 10.5 * 24 # Stunden
34         self.noise_amp = 0.4
35         self.front_detection_window_h = 24
36         self.kappa_threshold = 0.3
37         self.dK_threshold = 0.1
38
39 cfg = Config()

```

```

40
41 # =====
42 # 2. HILFSFUNKTIONEN
43 # =====
44
45 def berechne_kruemmung(temperatur, dt, glaettung=True):
46     """Berechnet die geometrische Krümmung  $\kappa(t)$  der
47     Temperaturtrajektorie."""
48     dT = np.gradient(temperatur, dt)
49     d2T = np.gradient(dT, dt)
50     if glaettung:
51         dT = savgol_filter(dT, window_length=49, polyorder=2)
52         d2T = savgol_filter(d2T, window_length=49,
53                             polyorder=2)
54     kappa = np.abs(d2T) / (1 + dT**2)**1.5
55     return kappa
56
57 def wetteraktivitaetsindex(kappa, dt_h=1.0):
58     """24h-Laufmittel + Gauss-Glättung über 2 Tage."""
59     window_24h = int(24 / dt_h)
60     activity = np.convolve(kappa,
61                             np.ones(window_24h)/window_24h, mode='same')
62     sigma_points = 2.0 / dt_h
63     activity_smooth = gaussian_filter1d(activity,
64                                         sigma=sigma_points)
65     activity_norm = (activity_smooth -
66                     np.min(activity_smooth)) / (np.max(activity_smooth) -
67                     np.min(activity_smooth) + 1e-8)
68     return activity_norm
69
70 def finde_zeitverschiebung(sim, real, dt_days=1/24):
71     """Finde optimale Zeitverschiebung über
72     Kreuzkorrelation."""
73     sim_norm = (sim - np.mean(sim)) / (np.std(sim) + 1e-8)
74     real_norm = (real - np.mean(real)) / (np.std(real) +
75     1e-8)
76     correlation = np.correlate(sim_norm, real_norm,
77                               mode='full')
78     lags = np.arange(-len(real) + 1, len(sim)) * dt_days
79     best_lag = lags[np.argmax(correlation)]
80     return best_lag
81
82 # =====
83 # 3. DATEN LADEN: DWD POTS DAM

```

```

75 # =====
76 def load_real_data():
77     if not os.path.exists(cfg.data_file):
78         raise FileNotFoundError(f"Datei '{cfg.data_file}'
nicht gefunden. Bitte hinzufügen.")
79     df = pd.read_csv(cfg.data_file)
80     if 'time' not in df.columns or 'temperature' not in
df.columns:
81         raise ValueError("CSV muss Spalten 'time' und
'temperature' enthalten.")
82     time_real = df['time'].values
83     temp_real = df['temperature'].values
84     valid = (temp_real != -999) & np.isfinite(temp_real)
85     time_real, temp_real = time_real[valid], temp_real[valid]
86     interp_func = interp1d(time_real, temp_real,
kind='linear', fill_value="extrapolate")
87     temp_interp = interp_func(cfg.time_days)
88     return cfg.time_days, np.clip(temp_interp, -10, 35)
89
90 # =====
91 # 4. TEMPERATURSIMULATION MIT RÜCKKOPPLUNG
92 # =====
93 class ClimateFeedback:
94     def __init__(self):
95         self.ice_coverage = 0.3
96         self.co2_level = 280
97         self.base_temp = 14.0
98
99     def albedo_effect(self, temp):
100         temp_anomaly = temp - self.base_temp
101         self.ice_coverage = np.clip(0.3 + 0.08 *
(-temp_anomaly), 0.1, 0.7)
102         albedo = 0.3 + 0.4 * self.ice_coverage
103         return -5.0 * (albedo - 0.3)
104
105     def co2_effect(self, temp):
106         temp_anomaly = temp - self.base_temp
107         self.co2_level = np.clip(280 + 8 * temp_anomaly,
180, 400)
108         forcing = 5.35 * np.log(self.co2_level / 280)
109         return 0.5 * forcing
110
111 def simulate_temperature():
112     temperature = np.full(cfg.N, cfg.base_temp)

```

```

113     feedback = ClimateFeedback()
114     for i in range(1, cfg.N):
115         # Forcing
116         forcing = (
117             cfg.daily_amp * np.sin(2 * np.pi * cfg.t[i] / 1)
118 +             cfg.synoptic_amp * np.sin(2 * np.pi * cfg.t[i] /
119             (cfg.synoptic_period * cfg.dt))
120         )
121         # Feedback
122         albedo_fb = feedback.albedo_effect(temperature[i-1])
123         co2_fb = feedback.co2_effect(temperature[i-1])
124         total_forcing = forcing + albedo_fb + co2_fb +
125         cfg.noise_amp * np.random.randn()
126         temperature[i] = 0.8 * temperature[i-1] + 0.2 *
127         (cfg.base_temp + total_forcing)
128     return np.clip(temperature, -5, 10)
129
130 # =====
131 # 5. WOLKENBILDUNG MIT RESONANZVERSTÄRKUNG
132 # =====
133 def berechne_wolken(temperature, humidity, kappa):
134     # Stratus
135     stratus = np.where((humidity * 100 > 80) & (kappa <
136     0.5), 0.6 + 0.3 * (humidity * 100 - 80) / 20, 0.0)
137     # Cumulus
138     cumulus = np.where((humidity * 100 > 65) & (kappa >
139     0.8), 0.4 * kappa, 0.0)
140     cumulus = np.clip(cumulus, 0, 0.7)
141     # Cirrus
142     dT = np.gradient(temperature, cfg.dt)
143     cirrus = np.where((humidity * 100 > 40) & (np.abs(dT) >
144     0.3), 0.2 * (np.abs(dT) - 0.3), 0.0)
145     cirrus = np.clip(cirrus, 0, 0.4)
146     # Gesamt
147     cloud_total = np.clip(stratus + cumulus + cirrus, 0, 1.0)
148     resonance_factor = 1.0 + 0.5 * np.tanh(2.0 * (kappa -
149     1.0))
150     cloud_final = np.clip(cloud_total * resonance_factor, 0,
151     1.0)
152     return gaussian_filter1d(cloud_final, sigma=24)
153
154 # =====
155 # 6. HAUPTPROGRAMM

```

```

148 # =====
149 if __name__ == "__main__":
150     # 1. Lade echte Daten
151     time_real, temp_real = load_real_data()
152     print("□ DWD-Daten geladen.")
153
154     # 2. Simuliere Temperatur
155     temp_sim = simulate_temperature()
156     print("□ Temperatursimulation abgeschlossen.")
157
158     # 3. Feuchtigkeit aus Temperatur
159     hum_base = 0.75
160     hum_from_temp = -0.03 * (temp_sim - cfg.base_temp)
161     hum_synoptic = 0.08 * np.sin(2 * np.pi * cfg.time_days /
162     7.0)
163     humidity = np.clip(hum_base + hum_from_temp +
164     hum_synoptic, 0.60, 0.90)
165
166     # 4. Krümmung berechnen
167     kappa_sim = berechne_krümmung(temp_sim, cfg.dt)
168     kappa_real = berechne_krümmung(temp_real, cfg.dt)
169     activity_sim = wetteraktivitaetsindex(kappa_sim, cfg.dt)
170     activity_real = wetteraktivitaetsindex(kappa_real,
171     cfg.dt)
172
173     # 5. Wolkenbildung
174     cloud_final = berechne_wolken(temp_sim, humidity,
175     kappa_sim)
176
177     # 6. Albedo-Rückkopplung (optional: neu simulieren)
178     albedo_sim = 0.3 + 0.2 * cloud_final
179     temp_sim_with_feedback = temp_sim - 0.7 * (albedo_sim -
180     0.3)
181
182     # 7. Zeitverschiebung
183     shift_days = finde_zeitverschiebung(activity_sim,
184     activity_real)
185     time_shifted = time_real - shift_days
186     valid = (time_shifted >= 0) & (time_shifted <= cfg.days)
187
188     # 8. Korrelation
189     r_simple, _ = pearsonr(activity_sim, activity_real)
190     r_shifted, _ = pearsonr(activity_sim[valid],
191     activity_real[valid])

```

```

185
186 # 9. Export
187 df = pd.DataFrame({
188     'tag': cfg.time_days,
189     'temp_sim': temp_sim,
190     'temp_real': temp_real,
191     'feuchte': humidity * 100,
192     'wolken': cloud_final * 100,
193     'kappa': kappa_sim,
194     'wetterindex': activity_sim
195 })
196 df.to_csv('klima_wolkenformen_ergebnisse.csv',
197 index=False)
198 print("□ Ergebnisse exportiert:
199 klima_wolkenformen_ergebnisse.csv")
200
201 # 10. Visualisierung
202 plt.figure(figsize=(12, 10))
203 plt.suptitle('Klimamodell: Resonanz, Krümmung und
204 Validierung', fontsize=14)
205
206 plt.subplot(4, 1, 1)
207 plt.plot(cfg.time_days, temp_sim, 'b-',
208 label='Simulation')
209 plt.plot(time_real, temp_real, 'orange',
210 label='DWD-Daten')
211 plt.ylabel('Temp (°C)')
212 plt.legend()
213 plt.grid(True, alpha=0.3)
214
215 plt.subplot(4, 1, 2)
216 plt.plot(cfg.time_days, activity_sim, 'b-',
217 label='Wetteraktivität (Sim)')
218 plt.plot(time_real, activity_real, 'orange',
219 label='Wetteraktivität (Real)')
220 plt.axhline(0.2, color='r', ls=':', alpha=0.6)
221 plt.ylabel('⟨κ⟩ (24h)')
222 plt.legend()
223 plt.grid(True, alpha=0.3)
224
225 plt.subplot(4, 1, 3)
226 plt.plot(cfg.time_days, cloud_final * 100, 'm-',
227 label='Wolken (final)')
228 plt.ylabel('Wolken (%)')

```

```

221 plt.legend()
222 plt.grid(True, alpha=0.3)
223
224 plt.subplot(4, 1, 4)
225 plt.plot(time_shifted[valid], activity_sim[valid], 'b-',
label=f'Simulation (+{shift_days:.1f} Tage)')
226 plt.plot(time_real[valid], activity_real[valid],
'orange', label='DWD-Daten')
227 plt.ylabel('κ (24h)')
228 plt.xlabel('Zeit (Tage)')
229 plt.legend()
230 plt.grid(True, alpha=0.3)
231
232 plt.tight_layout()
233 plt.savefig('klima_wolkenformen_modell_final.png',
dpi=300, bbox_inches='tight')
234 plt.show()
235 plt.close()
236
237 # 11. Finaler Check
238 print("\n" + "="*60)
239 print("          FINALER MODELL-CHECK")
240 print("="*60)
241 print(f"Temperaturbereich:      {np.min(temp_sim):.2f} -
{np.max(temp_sim):.2f} °C")
242 print(f"Wolken:
{np.min(cloud_final)*100:.0f}-{np.max(cloud_final)*100:.0f}
%")
243 print(f"Krümmung (max):          {np.max(kappa_sim):.3f}")
244 print(f"Zeitverschiebung:      +{shift_days:.1f} Tage")
245 print(f"Korrelation (mit Shift): r = {r_shifted:.3f}")
246 print("□ Modell stabil, konsistent, bereit für LaTeX")
247 print("="*60)

```

Listing A.6: Visualisierung resonante Wolkenbildung und Temperatur

A.7 Räumliche Strukturierung der Bewölkung, (Kap. 6)

```

1 # klima_wolkenformen_animation.py
2 # Version mit nur Standardmodulen: numpy, matplotlib, scipy
3 # Kein xarray, kein netCDF4, kein cartopy

```

```

4
5 import numpy as np
6 import matplotlib.pyplot as plt
7 from matplotlib.animation import FuncAnimation
8 from scipy.fft import fft2, fftfreq, fftshift
9 from scipy.ndimage import gaussian_filter
10 from scipy.signal import find_peaks
11 import csv
12 import warnings
13 warnings.filterwarnings("ignore")
14
15 # =====
16 # 1. KONFIGURATION
17 # =====
18 class Config:
19     # Rastergröße
20     Nx, Ny = 512, 512
21     Lx = 100.0 # km (Breite)
22     Ly = 100.0 # km (Höhe)
23     dx = Lx / Nx
24     dy = Ly / Ny
25
26     # Analyse
27     rh_threshold = 80 # % relative Feuchte-Schwelle
28     updraft_threshold = 0.1 # m/s (für Wolkenbildung)
29
30 cfg = Config()
31
32 # Gitter
33 x = np.linspace(0, cfg.Lx, cfg.Nx)
34 y = np.linspace(0, cfg.Ly, cfg.Ny)
35 X, Y = np.meshgrid(x, y)
36
37 # =====
38 # 2. SYNTHETISCHES TEMPERATURFELD
39 # =====
40 # Zentrale Konvektionszelle (z. B. über warmer Oberfläche)
41 R_center = np.sqrt((X - cfg.Lx/2)**2 + (Y - cfg.Ly/2)**2)
42 T_center = 18.0 - 3.0 * np.exp(-R_center**2 / (2 * 10.0**2))
43
44 # Superposition: Schwerewellen (z. B. durch Scherung)
45 lambda_wave = 8.0 # Wellenlänge in km
46 kx = 2 * np.pi / lambda_wave
47 ky = 2 * np.pi / lambda_wave

```

```

48 T_wave = 1.2 * np.cos(kx * X + ky * Y + np.pi/4)
49
50 # Kleinskalige Turbulenz
51 np.random.seed(42)
52 T_noise = 0.4 * gaussian_filter(np.random.randn(cfg.Nx,
53         cfg.Ny), sigma=2)
54
55 # Gesamttemperatur
56 T = T_center + T_wave + T_noise
57
58 # =====
59 # 3. RÄUMLICHE KRÜMMUNG DER ISOTHERMEN
60 # =====
61 def berechne_krümmung(T, dx, dy):
62     dTdx, dTdy = np.gradient(T, dx, dy)
63     d2Tdx2, d2Tdx dy = np.gradient(dTdx, dx, dy)
64     d2Tdx dy, d2Tdy2 = np.gradient(dTdy, dx, dy)
65     dTdd = dTdx**2 + dTdy**2 + 1e-8
66     numerator = d2Tdx2 * dTdy**2 - 2 * d2Tdx dy * dTdx * dTdy
67     + d2Tdy2 * dTdx**2
68     curvature = np.abs(numerator) / (dTdd**(3/2))
69     # Normalisieren
70     curvature = (curvature - curvature.min()) /
71     (curvature.max() - curvature.min() + 1e-8)
72     return curvature
73
74 krümmung = berechne_krümmung(T, cfg.dx, cfg.dy)
75
76 # =====
77 # 4. 2D-FFT UND RESONANZANALYSE
78 # =====
79 def analyse_resonanz(feld, Lx, Ly):
80     Nx, Ny = feld.shape
81     fft_field = fftshift(fft2(feld))
82     amp = np.abs(fft_field)
83
84     # Frequenzgitter
85     fx = fftshift(fftfreq(Nx, d=Lx/Nx))
86     fy = fftshift(fftfreq(Ny, d=Ly/Ny))
87     FX, FY = np.meshgrid(fx, fy)
88     F_mag = np.sqrt(FX**2 + FY**2)
89
90     # Radiales Spektrum (azimutale Mittelung)
91     bins = np.linspace(0, F_mag.max()/2, 50)

```

```

89     bin_centers = 0.5 * (bins[1:] + bins[:-1])
90     radial_profile, _ = np.histogram(F_mag.ravel(),
    bins=bins, weights=amp.ravel())
91
92     # Peaks finden
93     peaks, _ = find_peaks(radial_profile,
    height=np.max(radial_profile)*0.1, distance=5)
94     dominant_k = bin_centers[peaks]
95     wellenlaengen = 1 / dominant_k if len(dominant_k) > 0
    else []
96
97     # Resonanzpaare suchen:  $k_1 \approx 2*k_2$ 
98     resonance_pairs = []
99     for i, k1 in enumerate(dominant_k):
100         for j, k2 in enumerate(dominant_k):
101             if i != j:
102                 ratio = k1 / k2
103                 if 1.8 < ratio < 2.2 or 0.45 < ratio < 0.55:
104                     resonance_pairs.append((1/k1, 1/k2,
    ratio))
105
106     return radial_profile, bin_centers, wellenlaengen,
    resonance_pairs, amp, FX, FY
107
108 radial_profile, bin_centers, wl, pairs, amp, FX, FY =
    analyse_resonanz(krümmung, cfg.Lx, cfg.Ly)
109
110 # =====
111 # 5. WOLKENBILDUNG SIMULIEREN
112 # =====
113 # Fiktive relative Feuchte (kältere Luft → höhere RH)
114 rh = 90 - 4 * (T - T.min())
115 rh = np.clip(rh, 0, 100)
116
117 # Aufwind (angenähert über vertikalen Gradienten)
118 updraft = -np.gradient(T, axis=0) # Kälte → Absinken, Wärme
    → Aufsteigen
119 updraft = gaussian_filter(updraft, sigma=1)
120
121 # Wolkenindex: hohe Krümmung + hohe RH + Aufwind
122 cloud_score = krümmung * (rh > cfg.rh_threshold) * (updraft
    > np.percentile(updraft, 70))
123 cloud_mask = cloud_score > np.percentile(cloud_score, 60)
124

```

```

125 # =====
126 # 6. ANIMATION DER RESONANZMODEN
127 # =====
128 fig_anim, ax_anim = plt.subplots(figsize=(6, 6))
129
130 def animate_mode(frame):
131     ax_anim.clear()
132     # Scanne durch Wellenzahlen (simuliere Resonanzmoden)
133     k_target = 0.1 + 0.9 * (1 + np.sin(frame * 0.1)) / 2 #
134     0.1 bis 1.0 1/km
135     mask = np.abs(np.sqrt(FX**2 + FY**2) - k_target) < 0.05
136     filtered_fft = amp * mask
137     filtered_real =
138     np.abs(np.fftshift(np.fft2(np.fftshift(filtered_fft))))
139     filtered_real = (filtered_real - filtered_real.min()) /
140     (filtered_real.max() - filtered_real.min() + 1e-8)
141     ax_anim.imshow(filtered_real, cmap='RdYlBu',
142     origin='lower', alpha=0.8)
143     wavelength = 1 / k_target if k_target > 0 else np.inf
144     ax_anim.set_title(f'Wolkensimulation mit Resonanz-Modus:
145     ~{wavelength:.1f} km')
146     ax_anim.set_xticks([])
147     ax_anim.set_yticks([])
148
149 ani = FuncAnimation(fig_anim, animate_mode, frames=100,
150     interval=100, repeat=True)
151 ani.save('klima_wolkenformen_resonanz_animation.gif',
152     fps=10, writer='pillow')
153 print(" Animation gespeichert:
154     klima_wolkenformen_resonanz_animation.gif")
155
156 # =====
157 # 7. VISUALISIERUNG
158 # =====
159 fig, axes = plt.subplots(3, 2, figsize=(14, 14))
160
161 # a) Temperatur
162 im1 = axes[0, 0].imshow(T, extent=[0, cfg.Lx, 0, cfg.Ly],
163     cmap='coolwarm', origin='lower')
164 axes[0, 0].set_title('Temperaturfeld (°C)')
165 plt.colorbar(im1, ax=axes[0, 0])
166
167 # b) Krümmung

```

```

159 im2 = axes[0, 1].imshow(krümmung, extent=[0, cfg.Lx, 0,
      cfg.Ly], cmap='viridis', origin='lower')
160 axes[0, 1].set_title('Krümmung der Isothermen')
161 plt.colorbar(im2, ax=axes[0, 1])
162
163 # c) Simulierte Wolken
164 axes[1, 0].imshow(T, extent=[0, cfg.Lx, 0, cfg.Ly],
      cmap='gray', alpha=0.5, origin='lower')
165 contour = axes[1, 0].contour(X, Y, cloud_mask, levels=[0.5],
      colors='white', linewidths=2)
166 axes[1, 0].clabel(contour, inline=True, fontsize=10,
      fmt='%1.0f')
167 axes[1, 0].set_title('Simulierte Wolken (basierend auf
      Krümmung + RH + Aufwind)')
168 axes[1, 0].set_facecolor('black')
169
170 # d) 2D-Fourier-Spektrum
171 im3 = axes[1, 1].imshow(amp, extent=[FX.min(), FX.max(),
      FY.min(), FY.max()],
172                        cmap='hot', norm='log',
      origin='lower')
173 axes[1, 1].set_title('2D-Fourier-Spektrum (log)')
174 plt.colorbar(im3, ax=axes[1, 1])
175
176 # e) Radiales Spektrum
177 axes[2, 0].plot(bin_centers, radial_profile, 'b-',
      label='Spektrum')
178 axes[2, 0].set_xlabel('Wellenzahl k (1/km)')
179 axes[2, 0].set_ylabel('Amplitude')
180 axes[2, 0].set_title('Radiales Spektrum & Resonanz')
181 if len(wl) > 0:
182     peak_vals = radial_profile[np.searchsorted(bin_centers,
      1/wl).clip(0, len(radial_profile)-1)]
183     axes[2, 0].scatter(1/wl, peak_vals, c='red', s=50,
      label='Peaks')
184 axes[2, 0].legend()
185 axes[2, 0].grid(True, alpha=0.3)
186
187 # f) Resonanzpaare als Tabelle
188 axes[2, 1].axis('off')
189 if pairs:
190     table_data = [[f"{w1:.2f}", f"{w2:.2f}", f"{r:.2f}"] for
      w1, w2, r in pairs]
191     table = axes[2, 1].table(cellText=table_data,

```

```

192         collLabels=['Wellenlänge 1
193         (km)', 'Wellenlänge 2 (km)', 'Verhältnis'],
194         cellLoc='center',
195         bbox=[0.1, 0.2, 0.8, 0.7])
196     table.auto_set_font_size(False)
197     table.set_fontsize(10)
198     axes[2, 1].set_title('Gefundene Resonanzpaare (k1 ≈
199     2×k2)')
200 else:
201     axes[2, 1].text(0.5, 0.5, 'Keine Resonanzpaare
202     gefunden', transform=axes[2, 1].transAxes, ha='center')
203     axes[2, 1].set_title('Resonanzanalyse')
204
205 plt.tight_layout()
206 plt.savefig('klima_wolkenformen_standard.png', dpi=150,
207             bbox_inches='tight')
208 plt.show()
209 plt.close()
210
211 # =====
212 # 8. BERICHT (zeilenweise in UTF-8 gespeichert)
213 # =====
214 output_file = 'klima_wolkenformen_analyse_report.txt'
215
216 with open(output_file, 'w', encoding='utf-8') as f:
217     f.write("=====\n")
218     f.write("WOLKENFORMEN-ANALYSE: BERICHT\n")
219     f.write("=====\n")
220     f.write(f"Datum: {np.datetime64('now')}\n")
221     f.write(f"Raster: {cfg.Nx}x{cfg.Ny}, Bereich:
222     {cfg.Lx}x{cfg.Ly} km²\n")
223     f.write("\n")
224     f.write("Dominante Wellenlängen (km):\n")
225     if len(wl) > 0:
226         f.write(", ".join([f"{w:.2f}" for w in wl]) + "\n")
227     else:
228         f.write("Keine\n")
229         f.write("\n")
230         f.write("Gefundene Resonanzpaare (k1 ~ 2×k2):\n")
231         if pairs:
232             for w1, w2, r in pairs:
233                 f.write(f"    {w1:.2f} km ↔ {w2:.2f} km
234                 (Verhältnis: {r:.2f})\n")
235         else:

```

```

230     f.write("    Keine 2:1-Resonanzen gefunden.\n")
231     f.write("\n")
232     f.write("Interpretation:\n")
233     f.write("- Die Atmosphäre zeigt klare geometrische
Resonanzmuster.\n")
234     f.write("- Wolken bilden sich an Stellen hoher Krümmung,
hoher Feuchte und Aufwind.\n")
235     f.write("- Resonanzpaare (z. B. 2.85 ↔ 1.39 km) deuten
auf nichtlineare Rückkopplung hin -\n")
236     f.write("    analog zum 100-ka-Modell, wo n=8 → n=16
verstärkt wird.\n")
237     f.write("- Dies unterstützt die Hypothese: Wolkenformen
entstehen durch geometrische Resonanz.\n")
238     f.write("\n")
239     f.write("Ausgabe:\n")
240     f.write("    - Visualisierung:
wolkenformen_standard_visualisierung.png\n")
241     f.write("    - Animation:
resonanz_animation_wolkenformen.gif\n")
242
243 print("□ Bericht wurde erfolgreich als
'klima_wolkenformen_analyse_report.txt' gespeichert
(UTF-8).")
244
245 # =====
246 # 9. RESONANZPAARE ALS CSV SPEICHERN
247 # =====
248 csv_file = 'klima_wolkenformen_resonanzpaare.csv'
249 with open(csv_file, 'w', encoding='utf-8') as f:
250
251     f.write("Wellenlaenge_1_km,Wellenlaenge_2_km,Verhaeltnis\n")
252     for w1, w2, r in pairs:
253         f.write(f"{w1:.2f},{w2:.2f},{r:.2f}\n")
254 print(f"□ Resonanzpaare wurden als '{csv_file}'
gespeichert.")

```

Listing A.7: Visualisierung Räumliche Strukturierung der Bewölkung

A.8 Era5-Datei in csv umwandeln, (Abschn. 7)

```

1 # wolken_era5_in_csv_umwandeln.py
2 # Extrahiert ein dichtes Raster aus ERA5-NetCDF um Potsdam

```

```

3 # Output: era5_potsdam_dicht.csv mit x_km, y_km, cloud_cover
  (oder t2m)
4
5 import numpy as np
6 from netCDF4 import Dataset
7 import csv
8 import os
9
10 # =====
11 # 1. KONFIGURATION
12 # =====
13 NC_DATEI = "data_stream-oper_stepType-instant.nc" # ← Passe
  an
14 CSV_AUSGABE = "era5_potsdam_dicht.csv"
15
16 # Potsdam Zentrum
17 POTSDAM_LAT = 52.3989
18 POTSDAM_LON = 13.0652
19
20 # Ausschnitt: ca. 100 km × 100 km (±50 km in x/y)
21 ENTFERNUNG_KM = 50.0
22
23 # Variable: 'tcc' (Bewölkung), 't2m' (Temperatur), 'w',
  'u10', 'v10'
24 GEWUENSCHTE_VARIABLE = "tcc"
25
26 # =====
27 # 2. HILFSFUNKTIONEN: Koordinaten in km
28 # =====
29 def lat_lon_zu_xy_km(lat, lon, lat0, lon0):
30     """Gibt (dx, dy) in km relativ zu Referenzpunkt"""
31     dx = (lon - lon0) * 111.32 * np.cos(np.radians(lat0))
32     dy = (lat - lat0) * 111.32
33     return dx, dy
34
35 # =====
36 # 3. PRÜFEN OB DATEI EXISTIERT
37 # =====
38 if not os.path.exists(NC_DATEI):
39     print(f"❌ Fehler: Datei '{NC_DATEI}' nicht gefunden.")
40     exit()
41
42 # =====
43 # 4. ÖFFNEN DER NETCDF-DATEI

```

```

44 # =====
45 try:
46     datensatz = Dataset(NC_DATEI, 'r')
47     print(f" Geöffnet: {NC_DATEI}")
48 except Exception as e:
49     print(f" Fehler beim Öffnen: {e}")
50     print(" Benötigt: netCDF4 → 'pip install netCDF4'")
51     exit()
52
53 # =====
54 # 5. VARIABLEN ANZEIGEN
55 # =====
56 verfügbare = list(datensatz.variables.keys())
57 print(f" Verfügbare Variablen: {verfügbare}")
58
59 if GEWUENSCHTE_VARIABLE not in verfügbare:
60     print(f" Variable '{GEWUENSCHTE_VARIABLE}' nicht
61 gefunden.")
62     datensatz.close()
63     exit()
64
65 # =====
66 # 6. LADEN VON KOORDINATEN UND DATEN
67 # =====
68 # Breiten- und Längengrade
69 try:
70     lats = np.array(datensatz.variables['latitude'][:])
71     lons = np.array(datensatz.variables['longitude'][:])
72 except KeyError:
73     print(" 'latitude' oder 'longitude' nicht gefunden.")
74     print(" Mögliche Alternativen: 'lat', 'lon',
75 'g0_lat_1', 'g0_lon_2'")
76     datensatz.close()
77     exit()
78
79 # Daten (3D oder 2D)
80 var = datensatz.variables[GEWUENSCHTE_VARIABLE]
81 if len(var.shape) == 3:
82     print(f" 3D-Daten: {var.shape} → verwende ersten
83 Zeitschritt")
84     data = np.array(var[0, :, :]) # [time, lat, lon]
85 elif len(var.shape) == 2:
86     print(f" 2D-Daten: {var.shape}")
87     data = np.array(var[:, :])

```

```

85 else:
86     print(f"␣ Unerwartete Dimension: {var.shape}")
87     datensatz.close()
88     exit()
89
90 # =====
91 # 7. RECHTECKIGER AUSSCHNITT UM POTSDAM
92 # =====
93 print(f"␣ Extrahiere Gitterpunkte in ±{ENTFERNUNG_KM} km um
    Potsdam...")
94
95 punkte = []
96 lat_min = POTSDAM_LAT - (ENTFERNUNG_KM / 111.32)
97 lat_max = POTSDAM_LAT + (ENTFERNUNG_KM / 111.32)
98 lon_min = POTSDAM_LON - (ENTFERNUNG_KM / (111.32 *
    np.cos(np.radians(POTSDAM_LAT))))
99 lon_max = POTSDAM_LON + (ENTFERNUNG_KM / (111.32 *
    np.cos(np.radians(POTSDAM_LAT))))
100
101 for i, lat in enumerate(lats):
102     if lat_min <= lat <= lat_max:
103         for j, lon in enumerate(lons):
104             if lon_min <= lon <= lon_max:
105                 dx, dy = lat_lon_zu_xy_km(lat, lon,
    POTSDAM_LAT, POTSDAM_LON)
106                 wert = float(data[i, j])
107                 if np.isfinite(wert) and wert >= 0: # Nur
    gültige Werte
108                     punkte.append([dx, dy, np.clip(wert,
    0.0, 1.0)])
109
110 print(f"␣ {len(punkte)} Punkte extrahiert im Rechteck um
    Potsdam.")
111
112 if len(punkte) == 0:
113     print("␣ Keine Datenpunkte gefunden. Prüfe
    Koordinatennamen und Ausschnitt.")
114     datensatz.close()
115     exit()
116
117 # =====
118 # 8. SICHERN ALS CSV
119 # =====

```

```

120 with open(CSV_AUSGABE, 'w', newline='', encoding='utf-8') as
    f:
121     writer = csv.writer(f)
122     # Header
123     if GEWUENSCHTE_VARIABLE == 'tcc':
124         writer.writerow(['x_km', 'y_km', 'cloud_cover'])
125     elif GEWUENSCHTE_VARIABLE == 't2m':
126         writer.writerow(['x_km', 'y_km', 'temperature_2m'])
127     else:
128         writer.writerow(['x_km', 'y_km', 'value'])
129     # Daten
130     writer.writerows(punkte)
131
132 # =====
133 # 9. ABSCHLUSS
134 # =====
135 datensatz.close()
136 print(f"    Erfolgreich gespeichert: '{CSV_AUSGABE}'")
137 print(f"    Jetzt mit 'verifizierung_2d_mit_csv.py'
        weiterarbeiten.")
138 print(f"    Mit {len(punkte)} Punkten wird die Interpolation
        stabil und sinnvoll.")

```

Listing A.8: Visualisierung

A.9 Resonanz in Wolkenstrukturen, (Kap. 7)

```

1 # wolken_wirbel_messen.py
2 # Verifizierung gegen echte CSV-Beobachtungsdaten
3 # Keine exotischen Module - nur numpy, scipy, matplotlib, csv
4 # Unterstützt: DWD, ERA5, Satelliten (als CSV exportiert)
5
6 import numpy as np
7 import matplotlib.pyplot as plt
8 from scipy.fft import fft2, fftfreq, fftshift
9 from scipy.ndimage import gaussian_filter, rotate, shift,
    uniform_filter
10 from scipy.interpolate import griddata
11 import csv
12 import warnings
13 warnings.filterwarnings("ignore")
14
15 # =====

```

```

16 # 1. KONFIGURATION
17 # =====
18 Nx, Ny = 256, 256
19 Lx, Ly = 100.0, 100.0 # km (Bereich um Referenzpunkt)
20 dx = Lx / Nx
21 dy = Ly / Ny
22
23 x = np.linspace(0, Lx, Nx)
24 y = np.linspace(0, Ly, Ny)
25 X, Y = np.meshgrid(x, y)
26
27 # Pfad zur CSV-Datei - Passe diesen an!
28 CSV_FILE = 'era5_potsdam_dicht.csv'
29
30 # =====
31 # 2. LADEN DER ECHTEN DATEN AUS CSV
32 # =====
33 def load_csv_data(filename):
34     """
35     Lädt x, y, value aus CSV.
36     Erwartet Spalten: x_km, y_km, cloud_cover (oder ähnlich)
37     """
38     data = []
39     with open(filename, 'r', encoding='utf-8') as f:
40         reader = csv.DictReader(f)
41         for row in reader:
42             try:
43                 x_val = float(row.get('x_km', row.get('x',
44 0)))
45                 y_val = float(row.get('y_km', row.get('y',
46 0)))
47
48                 # Unterstütze verschiedene Spaltennamen
49                 val_key = 'cloud_cover'
50                 if val_key not in row:
51                     val_key = 'cloud' if 'cloud' in row else
52                     'value' if 'value' in row else None
53                 if val_key is None:
54                     raise KeyError("Keine Wertspalte
55 gefunden (cloud_cover, cloud, value)")
56                 value = float(row[val_key])
57                 data.append([x_val, y_val, value])
58             except (ValueError, KeyError) as e:
59                 continue # Überspringe ungültige Zeilen
60     return np.array(data)

```

```

56
57 print(f"  Lade Beobachtungsdaten aus {CSV_FILE}...")
58 try:
59     raw_data = load_csv_data(CSV_FILE)
60     points = raw_data[:, :2] # x, y
61     values = raw_data[:, 2]  # cloud_cover
62
63     print(f"  {len(raw_data)} Datenpunkte geladen.")
64
65     # Skalierung: Verschiebe auf [0, Lx] × [0, Ly]
66     x_min, x_max = points[:, 0].min(), points[:, 0].max()
67     y_min, y_max = points[:, 1].min(), points[:, 1].max()
68
69     # Zentriere und skaliere, falls nötig
70     scale_x = (x_max - x_min) if x_max != x_min else Lx
71     scale_y = (y_max - y_min) if y_max != y_min else Ly
72
73     x_norm = (points[:, 0] - x_min) / scale_x * Lx
74     y_norm = (points[:, 1] - y_min) / scale_y * Ly
75     points_norm = np.column_stack([x_norm, y_norm])
76
77     # Interpoliere auf Gitter
78     cloud_obs_grid = griddata(
79         points=points_norm,
80         values=values,
81         xi=(X, Y),
82         method='linear',
83         fill_value=np.nan
84     )
85
86     # Fülle fehlende Werte mit nearest
87     if np.isnan(cloud_obs_grid).any():
88         cloud_obs_fill = griddata(
89             points=points_norm,
90             values=values,
91             xi=(X, Y),
92             method='nearest'
93         )
94         cloud_obs_grid = np.where(np.isnan(cloud_obs_grid),
95                                 cloud_obs_fill, cloud_obs_grid)
96
97     # Normiere auf [0,1] (falls Werte außerhalb)
98     cloud_obs = (cloud_obs_grid - cloud_obs_grid.min()) /
99     (cloud_obs_grid.max() - cloud_obs_grid.min() + 1e-8)

```

```

98
99     print(f"□ Daten interpoliert auf {Nx}x{Ny}-Gitter.")
100
101 except Exception as e:
102     print(f"□ Fehler beim Laden der CSV: {e}")
103     print("□ Tipp: Stelle sicher, dass die CSV Spalten
104           'x_km', 'y_km', 'cloud_cover' enthält.")
105     print("    Beispiel:")
106     print("    x_km,y_km,cloud_cover")
107     print("    10.2,5.3,0.82")
108     print("    11.1,4.9,0.78")
109     exit()
110
111 # =====
112 # 3. MODELL-SIMULATION (unverändert)
113 # =====
114 def create_model():
115     R = 40.0
116     r = np.sqrt((X - Lx/2)**2 + (Y - Ly/2)**2)
117     vortex = np.exp(-(r - R)**2 / (8.0**2))
118     lambda_fast = 4.0
119     k_fast = 2 * np.pi / lambda_fast
120     wave_mod = 0.4 * np.cos(k_fast * X) * np.exp(-(Y -
121     Ly/2)**2 / (25**2))
122     turbulence = 0.2 * gaussian_filter(np.random.randn(Nx,
123     Ny), sigma=3)
124     model = vortex + wave_mod + turbulence
125     return (model - model.min()) / (model.max() -
126     model.min() + 1e-8)
127
128 np.random.seed(42)
129 cloud_model = create_model()
130
131 # =====
132 # 4. ROBUSTE AUSRICHTUNG
133 # =====
134 def find_optimal_alignment(model, obs, dx_km, dy_km,
135     angle_range=(-10,10), shift_range_km=(-30,30),
136     step_angle=2, step_shift_km=5):
137     best_corr = -np.inf
138     best_aligned = None
139     best_angle = 0
140     best_shift = (0, 0)

```

```

135     angles = np.arange(angle_range[0], angle_range[1] +
136         step_angle, step_angle)
137     shifts_x = np.arange(shift_range_km[0],
138         shift_range_km[1] + step_shift_km, step_shift_km)
139     shifts_y = np.arange(shift_range_km[0],
140         shift_range_km[1] + step_shift_km, step_shift_km)
141
142     for angle in angles:
143         rotated = rotate(model, angle, reshape=False,
144             mode='wrap')
145         for dx_s in shifts_x:
146             for dy_s in shifts_y:
147                 nx = int(round(dx_s / dx_km))
148                 ny = int(round(dy_s / dy_km))
149                 aligned = shift(rotated, shift=(ny, nx),
150                     mode='wrap')
151                 corr =
152                 np.corrcoef(aligned[~np.isnan(obs)].flatten(),
153                     obs[~np.isnan(obs)].flatten())[0, 1]
154                 if corr > best_corr:
155                     best_corr = corr
156                     best_aligned = aligned.copy()
157                     best_angle = angle
158                     best_shift = (dx_s, dy_s)
159
160     print(f"  Optimale Ausrichtung: {best_angle:.1f}°,
161         dx={best_shift[0]:.1f}, dy={best_shift[1]:.1f} km,
162         r={best_corr:.4f}")
163     return best_aligned, best_angle, best_shift
164
165 print("  Starte robuste Ausrichtung...")
166 cloud_model_aligned, opt_angle, opt_shift =
167     find_optimal_alignment(cloud_model, cloud_obs, dx, dy)
168
169 # =====
170 # 5. KRÜMMUNG
171 # =====
172 def compute_curvature_2d(field, dx, dy, sigma=2.0):
173     field_smooth = gaussian_filter(field, sigma=sigma)
174     Fy, Fx = np.gradient(field_smooth, dy, dx)
175     Fxx, Fxy = np.gradient(Fx, dx, dy)
176     Fyx, Fyy = np.gradient(Fy, dx, dy)
177     numerator = np.abs(Fxx * Fy**2 - 2*Fxy*Fx*Fy + Fyy *
178         Fx**2)

```

```

168     denominator = (Fx**2 + Fy**2)**(3/2) + 1e-8
169     curvature = numerator / denominator
170     return (curvature - curvature.min()) / (curvature.max()
171         - curvature.min() + 1e-8)
172
173 curv_obs = compute_curvature_2d(cloud_obs, dx, dy)
174 curv_model = compute_curvature_2d(cloud_model_aligned, dx,
175     dy)
176
177 # =====
178 # 6. VERGLEICH
179 # =====
180 def ssim_approx(img1, img2, win_size=11):
181     mu1 = uniform_filter(img1, size=win_size, mode='reflect')
182     mu2 = uniform_filter(img2, size=win_size, mode='reflect')
183     sigma12 = uniform_filter(img1 * img2, size=win_size,
184         mode='reflect') - mu1 * mu2
185     numerator = (2 * mu1 * mu2 + 1e-4) * (2 * sigma12 + 1e-4)
186     denominator = (mu1**2 + mu2**2 + 1e-4) *
187         (uniform_filter(img1**2, size=win_size) - mu1**2 +
188         uniform_filter(img2**2, size=win_size) - mu2**2 + 1e-4)
189     ssim_map = numerator / (denominator + 1e-8)
190     return np.mean(ssim_map)
191
192 ssim_val = ssim_approx(cloud_model_aligned, cloud_obs)
193 curv_corr =
194     np.corrcoef(curv_model[~np.isnan(cloud_obs)].flatten(),
195     curv_obs[~np.isnan(cloud_obs)].flatten())[0, 1]
196
197 def spectral_correlation(img1, img2):
198     F1 = np.abs(fftshift(fft2(img1)))
199     F2 = np.abs(fftshift(fft2(img2)))
200     return np.corrcoef(F1[~np.isnan(img2)].flatten(),
201         F2[~np.isnan(img2)].flatten())[0, 1]
202
203 spec_corr = spectral_correlation(cloud_model_aligned,
204     cloud_obs)
205
206 # =====
207 # 7. VISUALISIERUNG
208 # =====
209 fig, axes = plt.subplots(3, 3, figsize=(14, 12))
210
211 
```

```

202 axes[0,0].imshow(cloud_obs, cmap='gray', origin='lower',
    extent=[0,Lx,0,Ly])
203 axes[0,0].set_title('Beobachtung (aus CSV)')
204 axes[0,0].set_ylabel('y (km)')
205
206 axes[0,1].imshow(cloud_model, cmap='gray', origin='lower',
    extent=[0,Lx,0,Ly])
207 axes[0,1].set_title('Modell (roh)')
208
209 axes[0,2].imshow(cloud_model_aligned, cmap='gray',
    origin='lower', extent=[0,Lx,0,Ly])
210 axes[0,2].set_title('Modell (ausgerichtet)')
211
212 axes[1,0].imshow(curv_obs, cmap='plasma', origin='lower',
    extent=[0,Lx,0,Ly], vmin=0, vmax=1)
213 axes[1,0].set_title('Krümmung (Beob.)')
214 axes[1,0].set_ylabel('y (km)')
215
216 axes[1,1].imshow(curv_model, cmap='plasma', origin='lower',
    extent=[0,Lx,0,Ly], vmin=0, vmax=1)
217 axes[1,1].set_title('Krümmung (Modell)')
218
219 diff_curv = np.abs(curv_model - curv_obs)
220 axes[1,2].imshow(diff_curv, cmap='Reds', origin='lower',
    extent=[0,Lx,0,Ly], vmin=0, vmax=0.5)
221 axes[1,2].set_title('Krümmungs-Differenz')
222
223 F_obs = np.abs(fftshift(fft2(cloud_obs)))
224 F_mod = np.abs(fftshift(fft2(cloud_model_aligned)))
225 freq_x = fftshift(fftfreq(Nx, d=dx))
226 freq_y = fftshift(fftfreq(Ny, d=dy))
227 extent_freq = [freq_x.min(), freq_x.max(), freq_y.min(),
    freq_y.max()]
228
229 axes[2,0].imshow(np.log(F_obs + 1), cmap='hot',
    origin='lower', extent=extent_freq)
230 axes[2,0].set_title('log(Spektrum) - Beob.')
231 axes[2,0].set_xlabel('kx (1/km)')
232 axes[2,0].set_ylabel('ky (1/km)')
233
234 axes[2,1].imshow(np.log(F_mod + 1), cmap='hot',
    origin='lower', extent=extent_freq)
235 axes[2,1].set_title('log(Spektrum) - Modell')
236 axes[2,1].set_xlabel('kx (1/km)')

```

```

237
238 axes[2,2].axis('off')
239 axes[2,2].text(0.1, 0.8, 'Ergebnisse:', fontsize=12,
    fontweight='bold')
240 axes[2,2].text(0.1, 0.6, f'SSIM:          {ssim_val:.3f}',
    fontsize=11)
241 axes[2,2].text(0.1, 0.45, f'Krümmung:   {curv_corr:.3f}',
    fontsize=11)
242 axes[2,2].text(0.1, 0.3, f'Spektrum:    {spec_corr:.3f}',
    fontsize=11)
243 axes[2,2].text(0.1, 0.1, f'Ausrichtung: {opt_shift[0]:.1f},
    {opt_shift[1]:.1f} km, {opt_angle:.1f}°', fontsize=10)
244
245 plt.tight_layout()
246 plt.savefig('wolken_wirbel_verifizierung_mit_csv.png',
    dpi=200, bbox_inches='tight')
247 plt.show()
248 plt.close()
249
250 # =====
251 # 8. ERGEBNISSE
252 # =====
253 print("\n" + "="*60)
254 print("      2D-VERIFIZIERUNG: MIT ECHTEN CSV-DATEN")
255 print("="*60)
256 print(f"Datensatz: {CSV_FILE}")
257 print(f"Anzahl Punkte: {len(raw_data)}")
258 print(f"Skalierung: x=[{x_min:.1f}, {x_max:.1f}],
    y=[{y_min:.1f}, {y_max:.1f}]")
259 print(f"\nAusrichtung: {opt_angle:.1f}°,
    dx={opt_shift[0]:.1f} km, dy={opt_shift[1]:.1f} km")
260 print(f"\nMetriken:")
261 print(f"  SSIM:          {ssim_val:.3f}")
262 print(f"  Krümmung:      {curv_corr:.3f}")
263 print(f"  Spektrum:      {spec_corr:.3f}")
264 print(f"\n Interpretation:")
265 print(f"  - Spektrum > 0.7: Skalenübereinstimmung gut")
266 print(f"  - SSIM/Krümmung: zeigen strukturelle Ähnlichkeit
    an")
267 print(f"  - Unterschiede typisch für chaotische Systeme")
268 print("="*60)

```

Listing A.9: Visualisierung Resonanz in Wolkenstrukturen

A.10 Hurrikan-Auge finden, (Kap. 9)

```

1 # wolken_hurrikan_auge_finden.py
2 import matplotlib.pyplot as plt
3 import numpy as np
4 from scipy.ndimage import gaussian_filter
5 from scipy.signal import find_peaks
6 import warnings
7 warnings.filterwarnings("ignore")
8
9 # =====
10 # 1. BILD LADEN
11 # =====
12 bild = plt.imread('hurricane_katrina_2005.jpg')
13
14 # In Graustufen umwandeln
15 if len(bild.shape) == 3:
16     grau = np.mean(bild, axis=2)
17 else:
18     grau = bild
19
20 # Bilddimensionen
21 height, width = grau.shape
22 print(f"  Bilddimensionen: {width} × {height} Pixel")
23
24 # Glättung mit moderatem Filter
25 grau_glatt = gaussian_filter(grau, sigma=2)
26
27 # =====
28 # 2. DEFINIERE KOORDINATENRASTER
29 # =====
30 X, Y = np.meshgrid(np.arange(width), np.arange(height))
31
32 # =====
33 # 3. SCHNITT IN ZENTRALE REGION
34 # =====
35 # Angepasstes Zentrum basierend auf vorheriger Erkennung
36 x_center = 2000 # Beibehalten
37 y_center = 1500 # Beibehalten
38 radius = min(width, height) // 4 # 775 Pixel
39
40 print(f"  Zentrum: ({x_center}, {y_center}), Radius:
41         {radius} Pixel")

```

```

42 # Extrahiere rechteckigen Ausschnitt
43 x_start = max(0, int(x_center - radius))
44 x_end = min(width, int(x_center + radius))
45 y_start = max(0, int(y_center - radius))
46 y_end = min(height, int(y_center + radius))
47
48 ausschnitt = grau_glatt[y_start:y_end, x_start:x_end]
49
50 print(f"□ Ausschnitt definiert: {ausschnitt.shape[0]} ×
    {ausschnitt.shape[1]} Pixel")
51
52 # Finde Auge als Punkt mit niedrigster Intensität
53 min_idx = np.unravel_index(np.argmin(ausschnitt),
    ausschnitt.shape)
54 y_min, x_min = min_idx
55
56 # Umrechnung auf Originalkoordinaten
57 x_auge = x_min + x_start
58 y_auge = y_min + y_start
59
60 print(f"□ Auge gefunden bei: ({x_auge}, {y_auge}) Pixel")
61
62 # =====
63 # 4. VISUALISIERUNG
64 # =====
65 plt.figure(figsize=(12, 12))
66 plt.imshow(grau, cmap='gray')
67 plt.plot(x_auge, y_auge, 'ro', markersize=10, label='Auge')
68 plt.title('Hurrikan mit identifiziertem Auge')
69 plt.axis('off')
70 plt.legend()
71 plt.savefig('wolken_hurrikan_auge_markiert.png', dpi=200,
    bbox_inches='tight')
72 plt.show()
73 plt.close()

```

Listing A.10: Visualisierung Hurrikan-Auge finden

A.11 Hurrikan-Auge Analyse, (Kap. 9)

```

1 # wolken_hurrikan_auge_analyse.py
2 import matplotlib.pyplot as plt
3 import numpy as np

```

```

4 from scipy.ndimage import gaussian_filter
5 from scipy.signal import find_peaks
6 from scipy import stats
7 import warnings
8 warnings.filterwarnings("ignore")
9
10 # =====
11 # 1. BILD LADEN
12 # =====
13 bild_pfad = 'hurricane_katrina_2005.jpg'
14 bild = plt.imread(bild_pfad)
15
16 # In Graustufen umwandeln
17 if len(bild.shape) == 3:
18     grau = np.mean(bild, axis=2)
19 else:
20     grau = bild
21
22 # Glättung für robustere Minima
23 grau_glatt = gaussian_filter(grau, sigma=3)
24
25 # Bildgröße
26 height, width = grau.shape
27 print(f"□ Originalbildgröße: {width} × {height} Pixel")
28
29 # =====
30 # 2. ZENTRUMSUCHER (Auge des Hurrikans)
31 # =====
32 # Grobe Schätzung des Zentrums (kann vorher analysiert sein)
33 x_center = 1915
34 y_center = 1564
35 radius = 775 # Radius des Ausschnitts um das Zentrum
36
37 # Begrenzungen für den Ausschnitt
38 x_start = max(0, int(x_center - radius))
39 x_end = min(width, int(x_center + radius))
40 y_start = max(0, int(y_center - radius))
41 y_end = min(height, int(y_center + radius))
42
43 # Extrahiere zentralen Ausschnitt
44 ausschnitt = grau_glatt[y_start:y_end, x_start:x_end]
45
46 print(f"□ Ausschnitt: y={y_start}:{y_end},
      x={x_start}:{x_end}")

```

```

47 print(f" Ausschnitt-Shape: {ausschnitt.shape}, Dimension:
    {ausschnitt.ndim}")
48
49 # Sicherstellen, dass Ausschnitt 2D und nicht leer
50 if ausschnitt.ndim != 2 or ausschnitt.size == 0:
51     raise ValueError("Ausschnitt ist leer oder nicht 2D -
        prüfe Koordinaten!")
52
53 # Finde Minimum (dunkelstes Pixel = Auge)
54 min_idx = np.unravel_index(np.argmin(ausschnitt),
    ausschnitt.shape)
55 y_min_local, x_min_local = min_idx
56 x_auge = x_min_local + x_start
57 y_auge = y_min_local + y_start
58
59 print(f" Auge gefunden bei: ({x_auge}, {y_auge}) Pixel")
60
61 # =====
62 # 3. RADIALE PROFILANALYSE (Mittelwert über Winkel)
63 # =====
64 # Erzeuge Raster um das Auge
65 x = np.arange(width)
66 y = np.arange(height)
67 X, Y = np.meshgrid(x, y)
68 R = np.sqrt((X - x_auge)**2 + (Y - y_auge)**2)
69
70 # Flache Arrays für Binning
71 r_flat = R.flatten()
72 intensitaet_flat = grau.flatten()
73
74 # Binning: Einteilung in 200 radiale Bänder
75 r_max = 800 # max. Radius für Analyse (kann angepasst
    werden)
76 num_bins = 200
77 r_bins = np.linspace(0, r_max, num_bins + 1)
78 radial_profile, _, _ = stats.binned_statistic(
79     r_flat,
80     intensitaet_flat,
81     statistic='mean',
82     bins=r_bins
83 )
84 r_centers = (r_bins[:-1] + r_bins[1:]) / 2
85
86 # =====

```

```

87 # 4. FFT: SUCHE NACH PERIODISCHEN STRUKTUREN
88 # =====
89 # Initialisiere Variablen global, damit sie immer existieren
90 wellenlaengen_px = []
91 wellenlaengen_km = []
92
93 # Nur nicht-NaN-Werte verwenden
94 valid = ~np.isnan(radial_profile)
95 if np.sum(valid) < 50:
96     print("□ Zu wenig Daten für FFT.")
97 else:
98     # Extrahiere gültige Daten
99     r_used = r_centers[valid]
100     radial_used = radial_profile[valid]
101
102     # Entferne linearen oder quadratischen Trend → wichtig!
103     # Wir verwenden Polynom 2. Ordnung, um die typische
104     # Abdunklung zum Zentrum zu kompensieren
105     z = np.polyfit(r_used, radial_used, 2)
106     trend = np.polyval(z, r_used)
107     radial_detrend = radial_used - trend
108
109     # Interpoliere auf gleichmäßiges Raster für FFT
110     r_uniform = np.linspace(r_used.min(), r_used.max(), 512)
111     # 512 = gute FFT-Größe
112     radial_interp = np.interp(r_uniform, r_used,
113                             radial_detrend)
114
115     # FFT berechnen
116     F = np.fft.fft(radial_interp)
117     dx = r_uniform[1] - r_uniform[0] # Abstand zwischen
118     # radialen Werten
119     freq = np.fft.fftfreq(len(radial_interp), d=dx)
120     amplitude = np.abs(F)
121
122     # Nur positive Frequenzen
123     positive_mask = freq > 0
124     freq_pos = freq[positive_mask]
125     amplitude_pos = amplitude[positive_mask]
126
127     # Finde Peaks - jetzt viel sensitiver
128     peaks, props = find_peaks(
129         amplitude_pos,

```

```

126     height=np.max(amplitude_pos) * 0.05, # nur 5 % der
Maximalamplitude
127     distance=3, #
Mindestabstand zwischen Peaks
128     prominence=0.02 # lokale
Hervorhebung wichtig
129 )
130
131 if len(peaks) > 0:
132     dominant_freq = freq_pos[peaks]
133     wellenlaengen_px = 1 / dominant_freq # in Pixel
134
135     # Umrechnung in Kilometer (angenommen: 1 Pixel = 250
m)
136     px_to_km = 0.25 # km pro Pixel
137     wellenlaengen_km = wellenlaengen_px * px_to_km
138
139     # Sortiere nach absteigender Amplitude
140     peak_amps = amplitude_pos[peaks]
141     sorted_indices = np.argsort(peak_amps)[::-1] #
absteigend
142     wellenlaengen_px = wellenlaengen_px[sorted_indices]
143     wellenlaengen_km = wellenlaengen_km[sorted_indices]
144
145     print(f"\n Periodische Muster gefunden:")
146     for i, (px, km) in enumerate(zip(wellenlaengen_px,
wellenlaengen_km)):
147         if i == 0:
148             print(f"     $\lambda_1 = \{px:.1f\}$  px ( $\{km:.1f\}$  km) →
Hauptwellenlänge")
149         else:
150             ratio = wellenlaengen_px[0] / px
151             print(f"     $\lambda_{\{i+1\}} = \{px:.1f\}$  px ( $\{km:.1f\}$ 
km) → Verhältnis:  $\{ratio:.2f\}$ ")
152         else:
153             print("\n Keine signifikanten periodischen Muster
gefunden - versuche manuelle Analyse.")
154
155 # =====
156 # 5. VISUALISIERUNG
157 # =====
158 plt.figure(figsize=(14, 10))
159
160 # Bild mit Auge und Ringen

```

```

161 plt.subplot(2, 2, (1, 2))
162 plt.imshow(grau, cmap='gray')
163 plt.plot(x_auge, y_auge, 'ro', markersize=8, label='Auge')
164
165 # Zeichne Ringe für dominante Wellenlängen
166 if 'wellenlaengen_px' in locals() and len(wellenlaengen_px)
    > 0:
167     for i, r in enumerate(wellenlaengen_px):
168         if r > 10: # nur sinnvolle Radien
169             circle = plt.Circle((x_auge, y_auge), r,
170                                 color=['r', 'y', 'c'][i % 3],
171                                     fill=False, linewidth=2,
172                                     label=f'Ring  $\lambda = \{r:.0f\}$  px'
173                                     if i == 0 else None)
174             plt.gca().add_patch(circle)
175 plt.title('Hurrikan mit Auge und identifizierten
176           Wolkenringen')
177 plt.axis('off')
178 plt.legend()
179
180 # Radiales Profil
181 plt.subplot(2, 2, 3)
182 plt.plot(r_centers, radial_profile, 'b-', linewidth=1.5)
183 plt.xlabel('Radius (Pixel)')
184 plt.ylabel('Mittlere Helligkeit')
185 plt.title('Radiales Intensitätsprofil')
186 plt.grid(True, alpha=0.5)
187
188 # Nur wenn Wellenlängen gefunden wurden
189 if len(wellenlaengen_px) > 0:
190     plt.axvline(wellenlaengen_px[0], color='r',
191                 linestyle='--', label=f' $\lambda_1 = \{wellenlaengen\_px[0]:.0f\}$ 
192                 px')
193     if len(wellenlaengen_px) > 1:
194         plt.axvline(wellenlaengen_px[1], color='y',
195                     linestyle='--', label=f' $\lambda_2 = \{wellenlaengen\_px[1]:.0f\}$ 
196                     px')
197 plt.legend()
198
199 plt.figure()
200 plt.plot(r_centers, radial_profile, 'b-', label='Rohprofil')
201 plt.xlabel('Radius (Pixel)')
202 plt.ylabel('Helligkeit')

```

```

196 plt.title('Radiales Profil - sind Ringe sichtbar?')
197 plt.grid(True)
198 plt.savefig('hurrikan_auge_radiales_profil.png', dpi=200,
199           bbox_inches='tight')
200 plt.show()
201 # FFT-Amplitudenspektrum
202 plt.subplot(2, 2, 4)
203 plt.semilogx(freq_pos, amplitude_pos, 'k-', linewidth=1)
204 if len(peaks) > 0:
205     plt.semilogx(freq_pos[peaks], amplitude_pos[peaks],
206                 'ro', markersize=6)
207 plt.xlabel('Frequenz (1/Pixel) - logarithmisch')
208 plt.ylabel('Amplitude')
209 plt.title('FFT (logarithmische Skala)')
210 plt.grid(True, alpha=0.5)
211 # Peaks nur anzeigen, wenn vorhanden
212 if 'peaks' in locals() and len(peaks) > 0:
213     plt.plot(freq_pos[peaks], amplitude_pos[peaks], 'ro',
214             markersize=6, label='Peaks')
215     plt.legend()
216 plt.tight_layout()
217 plt.savefig('wolken_hurrikan_auge_resonanz_analyse.png',
218           dpi=200, bbox_inches='tight')
219 plt.show()
220 plt.close('all')
221 # =====
222 # 6. ZUSAMMENFASSUNG
223 # =====
224 print(f"\n Zusammenfassung:")
225 print(f"   Auge bei: ({x_auge}, {y_auge}) Pixel")
226
227 if len(wellenlaengen_km) > 0:
228     print(f"   Hauptwolkenabstand: {wellenlaengen_km[0]:.1f}
229           km")
230     if len(wellenlaengen_km) > 1:
231         ratio = wellenlaengen_km[0] / wellenlaengen_km[1]
232         if 1.8 < ratio < 2.2:
233             print(f"   Hinweis:  $\lambda_1 \approx 2\lambda_2 \times$  → mögliche
234                   harmonische Resonanz (Verhältnis: {ratio:.2f})")
235 else:

```

```

234     print("    Keine periodischen Wolkenabstände detektiert.")
235
236 # Log-Log-Plot: Amplitude vs. Frequenz
237 log_freq = np.log(freq_pos[freq_pos > 0])
238 log_amp = np.log(amplitude_pos[freq_pos > 0])
239 slope, _, _, _ = stats.linregress(log_freq, log_amp)
240 print(f"    Skalensexponent: {slope:.2f}")

```

Listing A.11: Visualisierung Hurrikan-Auge Analyse

A.12 Atompilz Baker 1946, (Kap. 10)

```

1 # wolken_atompilz_analyse.py
2 import numpy as np
3 import matplotlib.pyplot as plt
4 from scipy.ndimage import gaussian_filter
5 from scipy.signal import find_peaks
6 from scipy import stats
7 import warnings
8 warnings.filterwarnings("ignore")
9
10 # =====
11 # 1. BILD LADEN
12 # =====
13 # Lade ein historisches Atompilz-Bild (z .B. "trinity.jpg",
14   "baker.jpg")
15 bild_pfad = 'atompilz_test_baker_1946.jpg' # z .B.
16   Operation Crossroads Baker 1946
17 bild = plt.imread(bild_pfad)
18
19 # In Graustufen
20 if len(bild.shape) == 3:
21     grau = np.mean(bild, axis=2)
22 else:
23     grau = bild
24
25 # Glätten
26 grau_glatt = gaussian_filter(grau, sigma=2)
27
28 height, width = grau.shape
29 print(f"    Originalbildgröße: {width} × {height} Pixel")
30
31 # =====

```

```

30 # 2. ZENTRUM (Aufstiegsachse) finden
31 # =====
32 # Da kein klares "Auge", nehmen wir die Bildmitte oder
   detektieren vertikale Symmetrie
33 x_center = width // 2
34 # Finde ungefähr die Basis des Pilzes (dunkler Fleck unten)
35 y_base = height - 50 # manuell oder automatisch
36 y_top = 200          # Spitze des Pilzes
37
38 # Ausschnitt um den Pilz
39 radius = min(width, height) // 2
40 x_start = max(0, x_center - radius)
41 x_end = min(width, x_center + radius)
42 y_start = max(0, y_base - 1200) # großes Feld nach oben
43 y_end = y_base
44
45 ausschnitt = grau_glatt[y_start:y_end, x_start:x_end]
46 print(f"  Ausschnitt-Shape: {ausschnitt.shape}")
47
48 # Annahme: Symmetrieachse ist in der Mitte
49 x_auge = x_center
50 y_auge = y_base - 600 # Schätzung des "Zentrums" im Stamm
51
52 print(f"  Symmetrieachse bei x = {x_auge} Pixel")
53
54 # =====
55 # 3. RADIALES PROFIL (um Symmetrieachse)
56 # =====
57 x = np.arange(width)
58 y = np.arange(height)
59 X, Y = np.meshgrid(x, y)
60 R = np.sqrt((X - x_auge)**2 + (Y - y_auge)**2)
61
62 r_flat = R.flatten()
63 intensitaet_flat = grau.flatten()
64
65 r_max = 800
66 r_bins = np.linspace(0, r_max, 200)
67 r_centers = (r_bins[:-1] + r_bins[1:]) / 2
68 radial_profile, _, _ = stats.binned_statistic(r_flat,
   intensitaet_flat, statistic='mean', bins=r_bins)
69
70 # =====
71 # 4. FFT: SUCHE NACH RINGEN / SKALEN

```

```

72 # =====
73 valid = ~np.isnan(radial_profile) & (radial_profile > 0)
74 if np.sum(valid) < 50:
75     wellenlaengen_px = []
76 else:
77     radial_detrend = radial_profile[valid] -
78     np.mean(radial_profile[valid])
79     r_used = r_centers[valid]
80
81     r_uniform = np.linspace(r_used.min(), r_used.max(), 512)
82     radial_interp = np.interp(r_uniform, r_used,
83     radial_detrend)
84
85     F = np.fft.fft(radial_interp)
86     dx = r_uniform[1] - r_uniform[0]
87     freq = np.fft.fftfreq(len(radial_interp), d=dx)
88     amplitude = np.abs(F)
89
90     positive_mask = freq > 0
91     freq_pos = freq[positive_mask]
92     amplitude_pos = amplitude[positive_mask]
93
94     peaks, _ = find_peaks(amplitude_pos,
95     height=np.max(amplitude_pos)*0.1, distance=5)
96     if len(peaks) > 0:
97         dominant_freq = freq_pos[peaks]
98         wellenlaengen_px = 1 / dominant_freq
99         if 'wellenlaengen_px' in locals() and
100         len(wellenlaengen_px) > 0:
101             wellen_string = ", ".join([f"{w:.1f}" for w in
102             wellenlaengen_px])
103             print(f"\n Gefundene Wellenlängen:
104             {wellen_string} Pixel")
105         else:
106             print("\n Keine Wellenlängen detektiert.")
107
108 # =====
109 # 5. SKALENANALYSE (1/f)
110 # =====
111 log_freq = np.log(freq_pos[freq_pos > 0])
112 log_amp = np.log(amplitude_pos[freq_pos > 0])
113 slope, _, _, _ = stats.linregress(log_freq, log_amp)
114 print(f"\n Skalensexponent  $\alpha$  = {slope:.2f}")

```

```

110
111 # =====
112 # 6. VISUALISIERUNG
113 # =====
114 plt.figure(figsize=(14, 10))
115
116 plt.subplot(2, 2, (1, 2))
117 plt.imshow(grau, cmap='gray')
118 plt.axvline(x_auge, color='r', linestyle='--', linewidth=2,
119             label='Symmetrieachse')
119 if 'wellenlaengen_px' in locals() and len(wellenlaengen_px)
120     > 0:
121     for r in wellenlaengen_px:
122         if r > 10:
123             circle = plt.Circle((x_auge, y_auge), r,
124                                 color='y', fill=False, linewidth=2, linestyle='--')
125             plt.gca().add_patch(circle)
126 plt.plot(x_auge, y_auge, 'ro', markersize=6)
127 plt.title('Atompilz mit Symmetrieachse und detektierten
128           Ringen')
129 plt.axis('off')
130 plt.legend()
131
132 plt.subplot(2, 2, 3)
133 plt.plot(r_centers, radial_profile, 'b-', label='Radiales
134           Profil')
135 if 'wellenlaengen_px' in locals() and len(wellenlaengen_px)
136     > 0:
137     for r in wellenlaengen_px:
138         plt.axvline(r, color='y', linestyle='--', alpha=0.7)
139 plt.xlabel('Radius (Pixel)')
140 plt.ylabel('Mittlere Helligkeit')
141 plt.title('Radiales Intensitätsprofil')
142 plt.grid(True, alpha=0.5)
143
144 plt.subplot(2, 2, 4)
145 plt.loglog(freq_pos, amplitude_pos, 'k-',
146            label='Amplitudenspektrum')
147 if 'slope' in locals():
148     plt.loglog(freq_pos, np.exp(slope * np.log(freq_pos) +
149                                np.mean(np.log(amplitude_pos) - slope *
150                                np.log(freq_pos))), 'r--', label=f'Fit: α = {slope:.2f}')
151 plt.xlabel('Frequenz (1/Pixel)')
152 plt.ylabel('Amplitude')

```

```

145 plt.title('Log-Log Spektrum (Turbulenzanalyse)')
146 plt.legend()
147 plt.grid(True, alpha=0.5)
148
149 plt.tight_layout()
150 plt.savefig('wolken_atompilz_analyse.png', dpi=200,
151           bbox_inches='tight')
152 plt.show()
153
154 # =====
155 # 7. ZUSAMMENFASSUNG
156 # =====
157 print(f"\n Zusammenfassung:")
158 print(f"    Symmetrieachse bei x = {x_auge} Pixel")
159 if 'wellenlaengen_px' in locals() and len(wellenlaengen_px)
160     > 0:
161     wellen_string = ", ".join([f"{w:.1f}" for w in
162     wellenlaengen_px])
163     print(f"\n Gefundene Wellenlängen: {wellen_string}
164     Pixel")
165 else:
166     print("\n Keine Wellenlängen detektiert.")
167 print(f"    Skalensexponent  $\alpha$  = {slope:.2f}  $\rightarrow$  {'1/f-artig' if
168     abs(slope + 1.0) < 0.3 else 'abweichend'}")

```

Listing A.12: Visualisierung Atompilz Baker 1946

A.13 Golfstrom: Eddy-Genese, (Kap. 11.1)

```

1 # wellen_golfstrom_analyse.py
2 # ROBUSTE EDDY-GENESE-ERKENNUNG MIT VISUALISIERUNG
3 # Zeigt: Stromachse, Krümmung, Top 3 instabile Zonen
4
5 import numpy as np
6 import matplotlib.pyplot as plt
7 from scipy.ndimage import gaussian_filter
8 from scipy.signal import find_peaks
9 import warnings
10 warnings.filterwarnings("ignore")
11
12 # =====
13 # 1. BILD LADEN
14 # =====

```

```

15 bild_pfad = 'gulf_stream_modis_lrg.gif'
16 try:
17     bild = plt.imread(bild_pfad)
18 except FileNotFoundError:
19     print("❌ Bild nicht gefunden. Stelle sicher, dass
20         'gulf_stream_modis_lrg.gif' im Ordner liegt.")
21     exit()
22 # In Graustufen
23 if len(bild.shape) == 3:
24     grau = np.mean(bild, axis=2)
25 else:
26     grau = bild
27
28 # Glätten
29 grau_glatt = gaussian_filter(grau, sigma=1.0)
30
31 # =====
32 # 2. STROMACHSE DETEKTIEREN
33 # =====
34 x_start, x_end = 150, 850
35 sobel_x = np.gradient(grau_glatt, axis=1)
36 gradient_x = sobel_x[:, x_start:x_end]
37
38 strom_mitte = []
39 for row in gradient_x:
40     x_min = np.argmin(row)
41     x_max = np.argmax(row)
42     if abs(x_max - x_min) > 15:
43         center_local = (x_min + x_max) // 2
44         strom_mitte.append(center_local + x_start)
45     else:
46         strom_mitte.append(np.nan)
47
48 strom_mitte = np.array(strom_mitte)
49 valid_mask = ~np.isnan(strom_mitte)
50 y_valid = np.arange(len(strom_mitte))[valid_mask]
51 pos_valid = strom_mitte[valid_mask]
52
53 if len(y_valid) < 2:
54     print("❌ Zu wenig gültige Zeilen für Analyse.")
55     exit()
56
57 # Trend entfernen → Meander-Signal

```

```

58 z = np.polyfit(y_valid, pos_valid, 1)
59 trend_line = np.polyval(z, y_valid)
60 meander = pos_valid - trend_line
61
62 # =====
63 # 3. KRÜMMUNG BERECHNEN
64 # =====
65 if len(meander) < 5:
66     print("□ Zu kurzes Signal für Krümmung.")
67     exit()
68
69 d2y = np.gradient(np.gradient(meander))
70 curvature = np.abs(d2y)
71
72 # =====
73 # 4. PEAKS FINDEN - TOP 3 KRITISCHE ZONEN
74 # =====
75 peaks, _ = find_peaks(
76     curvature,
77     height=np.percentile(curvature, 40),
78     distance=20,
79     prominence=0.05
80 )
81
82 if len(peaks) == 0:
83     print("□ Keine Peaks gefunden - verwende Top 3 nach
84     Krümmung (Notlösung)")
85     top_indices = np.argsort(curvature[::-1][:3])
86     top_y = y_valid[top_indices]
87     top_x = pos_valid[top_indices]
88     top_curv = curvature[top_indices]
89 else:
90     # Sortiere Peaks nach Krümmung (höchste zuerst)
91     curv_peaks = curvature[peaks - y_valid[0]] if len(peaks)
92     <= len(curvature) else curvature[peaks]
93     sorted_order = np.argsort(curv_peaks[::-1])
94     top_count = min(3, len(sorted_order))
95     top_y = peaks[sorted_order[:top_count]]
96     top_x = pos_valid[peaks -
97     y_valid[0]][sorted_order[:top_count]]
98     top_curv = curv_peaks[sorted_order[:top_count]]
99
100 # =====
101 # 5. VISUALISIERUNG (ALLE PLOTS)

```

```

99 # =====
100 plt.figure(figsize=(14, 10))
101
102 # --- PLOT 1: Originalbild + Stromachse + Top 3 Zonen ---
103 plt.subplot(2, 2, 1)
104 plt.imshow(grau, cmap='gray')
105 plt.plot(strom_mitte, np.arange(len(strom_mitte)), 'cyan',
106         linewidth=2, label='Stromachse')
107
108 # Top 3 Zonen farbcodiert
109 colors = ['red', 'orange', 'gold']
110 for i, (x, y) in enumerate(zip(top_x, top_y)):
111     plt.plot(x, y, 'o', color=colors[i], markersize=12 - i*2,
112             markedgewidth=2, markerfacecolor='none',
113             linewidth=2,
114             label=f'# {i+1} (Y={y})')
115     plt.annotate(f'{i+1}', (x, y), color='white',
116                 fontweight='bold', ha='center', va='center',
117                 bbox=dict(boxstyle="round,pad=0.3",
118                         facecolor="black", alpha=0.7))
119
120 plt.legend(title="Rang", loc='upper right')
121 plt.title('Golfstrom mit Top 3 Instabilitätszentren')
122 plt.axis('off')
123
124 # --- PLOT 2: Meander-Signal ---
125 plt.subplot(2, 2, 2)
126 plt.plot(y_valid, meander, 'b-', linewidth=1.5,
127         label='Meander-Amplitude')
128 for i, (y, c) in enumerate(zip(top_y, top_curv)):
129     plt.axvline(y, color=colors[i], linewidth=2, alpha=0.7,
130                 label=f'# {i+1} (Y={y})')
131
132 plt.xlabel('Y (Pixel)')
133 plt.ylabel('Seitliche Auslenkung (Pixel)')
134 plt.title('Meander-Profil entlang des Stroms')
135 plt.legend()
136 plt.grid(True, alpha=0.4)
137
138 # --- PLOT 3: Krümmung mit Top 3 ---
139 plt.subplot(2, 2, 3)
140 plt.plot(y_valid, curvature, 'g-', linewidth=2,
141         label='Krümmung')
142 for i, (y, c) in enumerate(zip(top_y, top_curv)):

```

```

135     plt.plot(y, c, 'o', color=colors[i], markersize=10,
136             label=f'# {i+1}')
136 plt.xlabel('Y (Pixel)')
137 plt.ylabel('Krümmung (abs.  $d^2y/dx^2$ )')
138 plt.title('Krümmung der Stromachse - Instabilitätsspitzen')
139 plt.legend()
140 plt.grid(True, alpha=0.4)
141
142 # --- PLOT 4: Heatmap der Krümmung auf Bild ---
143 plt.subplot(2, 2, 4)
144 curv_map = np.full_like(grau, np.nan, dtype=float)
145 curv_map[y_valid, strom_mitte[valid_mask].astype(int)] =
146     curvature
147
148 plt.imshow(grau, cmap='gray', alpha=0.6)
149 im = plt.imshow(curv_map, cmap='hot', alpha=0.7, vmin=0,
150                vmax=np.max(curvature))
151 plt.colorbar(im, label='Krümmung')
152
153 for i, (x, y) in enumerate(zip(top_x, top_y)):
154     plt.plot(x, y, 'o', color=colors[i], markersize=10,
155             markedgewidth=2, markerfacecolor='none')
156     plt.annotate(f'{i+1}', (x, y), color='white',
157                 fontsize=12,
158                 weight='bold', ha='center', va='center')
159 plt.title('Heatmap: Krümmung entlang des Stroms')
160 plt.axis('off')
161
162 plt.tight_layout()
163 plt.savefig('golfstrom_eddy_top3_annotated.png', dpi=200,
164           bbox_inches='tight')
165 plt.show()
166 plt.close()
167
168 # =====
169 # 6. ZUSAMMENFASSUNG - TOP 3
170 # =====
171 print("\n" + "="*60)
172 print("□ TOP 3 KRITISCHE INSTABILITÄTSZONEN IM GOLFSTROM")
173 print("="*60)
174
175 px_to_km = 3.0
176 for i, (x, y, c) in enumerate(zip(top_x, top_y, top_curv)):
177     km = y * px_to_km

```

```

173     print(f"    #{i+1} - Position: (X={x:.0f}, Y={y:.0f})
      Pixel ≈ Y={km:.0f} km")
174     print(f"        Krümmung: {c:.3f} (1/Pixel)")
175     if i == 0:
176         print(f"        →    Hauptsächliche Eddy-Genese-Zone
      (maximale Biegung)")
177
178     print(f"\n Vergleich mit 02_qwen.py:")
179     print(f"    Dort: Instabiler Bereich bei Y ≈ 140 Pixel")
180     print(f"    Hier: Top-Zone bei Y = {top_y[0]} Pixel")
181     if abs(top_y[0] - 140) < 30:
182         print("    □ Beide Methoden stimmen überein - starke
      Bestätigung!")
183     elif abs(top_y[0] - 140) < 100:
184         print("    □ Teilweise Übereinstimmung - möglicherweise
      Entwicklung entlang des Stroms.")
185     else:
186         print("    □ Unterschiedliche Zone - aber möglich: FFT
      erfasst frühe, Krümmung späte Instabilität.")
187
188     print("\n Interpretation:")
189     print("    - Y ≈ 140 (FFT): Beginn der Meander-Instabilität
      (resonante Wellenlänge)")
190     print("    - Y ≈ 261 (Krümmung): Maximale Biegung → Eddy kurz
      vor Ablösung")
191     print("    → Beides korrekt: Die Instabilität wächst entlang
      des Stroms!")

```

Listing A.13: Visualisierung Golfstrom: Eddy-Genese

A.14 DWD-Daten runterladen in CSV, (Abschn. 3)

```

1  # wolken_dwd_daten_runterladen_in_csv.py
2  import requests
3  from bs4 import BeautifulSoup
4  import zipfile
5  import pandas as pd
6  import os
7  import glob
8
9  # =====
10 # STATIONEN
11 # =====

```

```

12 staedte = {
13     "Berlin": "00433", # Funktioniert jetzt korrekt
14 }
15
16 # Basis-URLs für die verschiedenen Parameter
17 base_urls = {
18     "humidity":
19         "https://opendata.dwd.de/climate_environment/CDC
20         /observations_germany/climate/hourly/moisture/recent/",
21     "wind": "https://opendata.dwd.de/climate_environment/CDC
22         /observations_germany/climate/hourly/wind/recent/",
23     "air_temperature":
24         "https://opendata.dwd.de/climate_environment
25         /CDC/observations_germany/climate/hourly/
26         air_temperature/recent/"
27 }
28
29 # Spaltenzuordnung: Parameter → tatsächliche Spalte in der
30 # TXT
31 COLUMN_MAPPING = {
32     "humidity": "RF_STD",
33     "wind": "F",
34     "air_temperature": "TT_TU"
35 }
36
37 # Prefixe in Dateinamen: Parameter → Dateiprefix
38 PREFIX_MAPPING = {
39     "humidity": "TF",
40     "wind": "FF",
41     "air_temperature": "TU"
42 }
43
44 # =====
45 # HAUPTFUNKTION
46 # =====
47 def lade_stadt(station_id, stadt_name):
48     print(f"\n Lade Daten für {stadt_name} (Station
49     {station_id})...")
50
51     # Entferne führende Nullen für Vergleich in Dateinamen
52     station_id_clean = station_id.lstrip("0")
53
54     # Bereinige alte temporäre Dateien
55     for ext in ["zip", "txt"]:

```

```

48     for file in glob.glob(f"*_{station_id}_akt.{ext}"):
49         try:
50             os.remove(file)
51             print(f"    Gelöscht: {file}")
52         except Exception as e:
53             print(f"    Konnte nicht löschen {file}: {e}")
54
55     dataframes = {}
56     successful_downloads = 0
57
58     # Lade jeden Parameter unabhängig
59     for param, base_url in base_urls.items():
60         try:
61             print(f"\n    Lade Parameter: {param.upper()}")
62
63             # 1. Liste Verzeichnis
64             response = requests.get(base_url.strip(),
65                                     timeout=10)
66             response.raise_for_status()
67             soup = BeautifulSoup(response.text,
68                                 'html.parser')
69             links = [a['href'] for a in soup.find_all('a',
70                                                         href=True)]
71
72             # 2. Suche nach aktueller ZIP
73             prefix = PREFIX_MAPPING[param]
74             zip_name =
75             f"stundenwerte_{prefix}_{station_id}_akt.zip"
76
77             if zip_name not in links:
78                 print(f"    {zip_name} nicht gefunden unter
79                     {base_url}")
80                 continue
81
82             zip_url = base_url.strip() + zip_name
83             print(f"    Lade ZIP: {zip_url}")
84
85             r = requests.get(zip_url, timeout=30)
86             r.raise_for_status()
87
88             if len(r.content) < 1000:
89                 print(f"    ZIP für {param} ist leer oder
90                     beschädigt.")
91                 continue

```

```

86         # 3. Speichere ZIP lokal
87         zip_file =
88         f"{prefix}_stundenwerte_{station_id}_akt.zip"
89         with open(zip_file, "wb") as f:
90             f.write(r.content)
91         print(f"    Gespeichert: {zip_file}")
92
93         # 4. Entpacke passende TXT-Datei
94         txt_file =
95         f"produkt_{prefix.lower()}_stunde_{station_id}.txt"
96         extracted = False
97         with zipfile.ZipFile(zip_file, 'r') as z:
98             for file_info in z.infolist():
99                 # Prüfe, ob Dateiname mit Produkt
100                 beginnt und die bereinigte ID enthält
101                 if
102                 (file_info.filename.startswith(f"produkt_{prefix.
103                     lower()}_stunde_")
104                     and station_id_clean in
105                     file_info.filename):
106                     print(f"    Extrahiere:
107                     {file_info.filename} → {txt_file}")
108                     with z.open(file_info) as src,
109                     open(txt_file, "wb") as tgt:
110                         tgt.write(src.read())
111                         extracted = True
112                         break
113
114                 if not extracted:
115                     print(f"    Keine passende TXT-Datei für
116                     {param} in ZIP gefunden.")
117                     continue
118
119         # 5. Lese CSV
120         df = pd.read_csv(txt_file, sep=";",
121             encoding='latin1', na_values=[-999, -888])
122         df.columns = [col.strip() for col in df.columns]
123         # Bereinige Spaltennamen
124
125         required_column = COLUMN_MAPPING[param]
126         if 'MESS_DATUM' not in df.columns or
127         required_column not in df.columns:

```

```

118         print(f"␣ Fehlende Spalten für {param}:
{list(df.columns)}")
119         continue
120
121         # Nur relevante Spalten behalten und bereinigen
122         df = df[['STATIONS_ID', 'MESS_DATUM',
required_column]].dropna(subset=[required_column])
123
124         # Umwandlung in Datum
125         df['time_dt'] = pd.to_datetime(df['MESS_DATUM'],
format='%Y%m%d%H%M', errors='coerce')
126         df =
df.dropna(subset=['time_dt']).sort_values('time_dt')
127
128         dataframes[param] = df[['STATIONS_ID',
'MESS_DATUM', required_column]]
129         successful_downloads += 1
130         print(f"␣ {param} erfolgreich geladen: {len(df)}
Einträge")
131
132     except Exception as e:
133         print(f"␣ Fehler bei {param}: {e}")
134         continue # Nächster Parameter
135
136     # =====
137     # 6. Kombiniere verfügbare Daten
138     # =====
139     if successful_downloads == 0:
140         print("␣ Keine Daten für diese Station
heruntergeladen.")
141         return False
142
143     # Starte mit dem ersten verfügbaren DataFrame
144     df_combined = None
145     for param in ['air_temperature', 'humidity', 'wind']: #
Priorisiere Temperatur
146         if param in dataframes:
147             if df_combined is None:
148                 df_combined = dataframes[param]
149             else:
150                 df_combined = df_combined.merge(
151                     dataframes[param],
152                     on=['STATIONS_ID', 'MESS_DATUM'],
153                     how='inner'

```

```

154         )
155
156     if df_combined is None or len(df_combined) == 0:
157         print("❌ Keine gemeinsamen Zeitpunkte gefunden.")
158         return False
159
160     # Umbenennung für Klarheit
161     col_rename = {
162         'RF_STD': 'RF_10',
163         'F': 'F_10',
164         'TT_TU': 'TT_10'
165     }
166     df_combined.rename(columns=col_rename, inplace=True)
167
168     # Speichere kombinierte CSV
169     output = "dwd_data.csv"
170     cols = ['MESS_DATUM'] + [col for col in ['TT_10',
171         'RF_10', 'F_10'] if col in df_combined.columns]
172     df_combined[cols].to_csv(output, sep=';', index=False)
173     print(f"✅ Erfolgreich kombiniert: {output} |
174         {len(df_combined)} gemeinsame Zeitpunkte")
175     return True
176
177 # =====
178 # AUSFÜHRUNG
179 # =====
180 if __name__ == "__main__":
181     print("❌ Lade Wetterdaten von DWD\n" + "="*60)
182     for name, sid in staedte.items():
183         lade_stadt(sid, name)
184     print("\n✅ Fertig. Jetzt cloud_evolution_dwd_csv.py
185         starten.")

```

Listing A.14: Visualisierung DWD-Daten runterladen in CSV

Hinweis zur Nutzung von KI

Die Ideen und Konzepte dieser Arbeit stammen von mir. Künstliche Intelligenz wurde unterstützend für die Textformulierung und Gleichungsformatierung eingesetzt. Die inhaltliche Verantwortung liegt bei mir.¹

¹ORCID: <https://orcid.org/0009-0002-6090-3757>

Stand: 8. Oktober 2025

TimeStamp: https://freettsa.org/index_de.php

Literatur

- [1] Bak, P., Tang, C., Wiesenfeld, K. (1987). *Self-organized criticality: An explanation of the 1/f noise*. Physical Review Letters, 59(4), 381–384.
- [2] Baldauf, M., et al. Operational convective-scale numerical weather prediction with the COSMO model. *Monthly Weather Review*, 139, 3887–3905.
- [3] André Berger. *Long-Term Variations of Daily Insolation and Quaternary Climatic Changes*. Journal of the Atmospheric Sciences, 35(12):2362–2367, 1978.
- [4] Eyring, V., et al., 2016: Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6). *Geoscientific Model Development*, 9, 1937–1958.
- [5] Michael Ghil. *Cryothermodynamics: The chaotic dynamics of paleoclimate*. Physica D: Nonlinear Phenomena, 77(1–3):130–159, 1994.
- [6] John Hays, John Imbrie, Nicholas J. Shackleton. *Variations in the Earth's Orbit: Pacemaker of the Ice Ages*. Science, 194(4270):1121–1132, 1976.
- [7] Hersbach, H., et al., 2020: The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society*, 146, 1999–2049.
- [8] John Imbrie, James D. Hays, Douglas G. Martinson, Andrew McIntyre, Alan C. Mix, John J. Morley, Nicklas G. Pisias, Warren L. Prell, Nicholas J. Shackleton. *A Pleistocene timescale from the deep-sea*. Nature, 359(6392):189–191, 1992.
- [9] Marie-France Loutre and André Berger. *Future climate changes: Are we entering an exceptionally long interglacial?* Climatic Change, 49(3):333–343, 2001. Springer. doi: [10.1023/A:1010734832890](https://doi.org/10.1023/A:1010734832890).
- [10] Dieter Lüthi, Martine Le Floch, Bernhard Bereiter, Thomas Blunier, Jean-Marc Barnola, Urs Siegenthaler, Dominique Raynaud, Jean Jouzel, Hubertus Fischer, Kenji Kawamura, Thomas F. Stocker. *High-resolution carbon dioxide concentration record 650,000–800,000 years before present*. Nature, 453(7193):379–382, 2008.
- [11] Milankovitch, M., *Canon of Insolation and the Ice-Age Problem*, Königlich Serbische Akademie, 1941.
- [12] Myhre, G., Highwood, E. J., Shine, K. P., and Stordal, F., *New estimates of radiative forcing due to well mixed greenhouse gases*, Geophysical Research Letters, 25(14), 2715–2718, 1998.
- [13] Jean-Robert Petit, Jean Jouzel, Dominique Raynaud, Yishak Barkan, Jean-Marc Barnola, Isabelle Basile, Michael Bender, Jérôme Chappellaz,

Martin Davis, Gilles Delaygue et al. *Climate and atmospheric history of the past 420,000 years from the Vostok ice core, Antarctica*. Nature, 399(6735):429–436, 1999.

- [14] Daniel S. Wilks *Statistical Methods in the Atmospheric Sciences*. Academic Press, 2011.