

---

# Integration von Lightning-Jumps in CellMOS zur Verbesserung der Hagelvorhersage im Nowcasting

---

Bachelorarbeit  
Freie Universität Berlin  
Fachbereich Geowissenschaften

Autor: Feige, Hendrik  
Matrikelnummer: 9753404  
Studiengang: B.Sc. Meteorologie  
Abgabedatum: 13. Juli 2024  
Gutachter: Univ.-Prof. Dr. Henning Rust  
Dr. Kathrin Wapler



---

## Zusammenfassung

Präzise Hagelvorhersagen sind für die Versicherungswirtschaft von großer Bedeutung, da Hagelereignisse jedes Jahr zu erheblichen Schäden an Fahrzeugen, Gebäuden und landwirtschaftlichen Flächen führen. Im Rahmen dieser Arbeit soll untersucht werden, inwieweit die Hinzunahme von Lightning-Jump-Prädiktoren die Vorhersagegüte von Nowcasting-Systemen, wie beispielhaft das von METEO SERVICE weather research GmbH bereitgestellte CellMOS, verbessern kann. Im Fokus soll dabei der Vorhersagezeitraum bis 30 min stehen. Als Grundlage dienen die von Schultz et al. [2009, 2011] entwickelten Lightning-Jump-Algorithmen, welche hierfür in eine bereits bestehende Regressionsgleichung integriert werden. Anschließend wird ihr Beitrag zur Prognoseverbesserung durch Modellselektion im Sinne der Varianzanalyse und Kreuzvalidierung verifiziert. Die Datengrundlage bilden Tracking-Daten von Gewitterzellen in 5-minütiger Auflösung sowie Blitzdaten in sekundlicher Auflösung vom Schweizer Radarverbund für den Zeitraum von 2017 bis 2022. Die Tracking-Daten beinhalten alle relevanten Zelleigenschaften sowie die daraus hervorgehenden Lightning-Jump-Prädiktoren. Es wird vermutet, dass zwischen der Blitzintensität eines Gewitters und der Größe des Hagels eine Korrelation besteht, welche allgemein für die Vorhersage einer Hagelwahrscheinlichkeit im Nowcasting genutzt werden kann.

## Abstract

Accurate hail forecasts are very important for the insurance sector, as hail events lead to considerable damage to vehicles, buildings and agricultural land every year. The goal of this thesis is to investigate the extent to which the addition of lightning-jump-predictors can improve the prediction quality of nowcasting systems, such as the CellMOS provided by METEO SERVICE weather research GmbH. The main focus will be on the forecast period up to 30 min. For this purpose, the lightning-jump-algorithms developed by Schultz et al. [2009, 2011] will serve as a basis and will be integrated into an already existing regression equation. Subsequently, their contribution to forecast improvement is verified by model selection in terms of analysis of variance and cross-validation. The data basis consists of tracking data of thunderstorm cells in 5-minute resolution as well as lightning data in second resolution, from the Swiss radar network in the period from 2017 to 2022. The tracking data include all relevant cell characteristics as well as the resulting lightning-jump-predictors. It is hypothesized that there is a correlation between lightning intensity in thunderstorms and the size of hail, which can be generally used to predict the probability of hail in terms of nowcasting.

---

## Eidesstattliche Erklärung

Hiermit versichere ich, Hendirk Feige, geboren am 06.07.2000 mit der Matrikelnummer 5397404, der Freien Universität Berlin, dass ich die vorliegende Abschlussarbeit selbstständig und nur unter Verwendung der von mir angegebenen Quellen und Hilfsmittel verfasst habe. Sowohl inhaltlich als auch wörtlich entnommene Inhalte wurden als solche kenntlich gemacht. Die Arbeit hat in dieser oder vergleichbarer Form noch keiner anderen Universität vorgelegen.

Datum: \_\_\_\_\_ Unterschrift: \_\_\_\_\_

## Einverständniserklärung

Hiermit stimme ich der Weitergabe des Titels und Autorenschaft meiner Abschlussarbeit an den Deutschen Wetterdienst zur Veröffentlichung in der Weiterbildungszeitschrift „ProMet“ zu.

Datum: \_\_\_\_\_ Unterschrift: \_\_\_\_\_

# Inhaltsverzeichnis

<b>1. Motivation und Einleitung</b>	<b>7</b>
<b>2. Grundlagen</b>	<b>9</b>
2.1. Fernerkundung . . . . .	9
2.1.1. Niederschlagsradar . . . . .	9
2.1.2. Blitzortung . . . . .	10
2.2. Das MOS-Prinzip . . . . .	11
2.2.1. MOS auf beweglichen Systemen . . . . .	11
2.3. Das CellMOS . . . . .	11
2.3.1. Zellobjekte . . . . .	12
2.3.2. Zellerkennung . . . . .	12
2.3.3. Zelltracking . . . . .	13
2.4. Hagelerkennung . . . . .	14
2.5. Lightning-Jumps . . . . .	18
<b>3. Daten</b>	<b>22</b>
3.1. Radardaten . . . . .	22
3.2. Blitzdaten . . . . .	24
3.3. Modelldaten . . . . .	25
3.4. Trackingdaten . . . . .	25
<b>4. Methodik</b>	<b>27</b>
4.1. Transformation des Prädiktanden . . . . .	27
4.1.1. Verteilung der Hagelgröße . . . . .	28
4.2. Statistische Modellierung . . . . .	28
4.2.1. Lineares Regressionsmodell . . . . .	28
4.2.2. Bestimmtheitsmaß . . . . .	31
4.3. Modellauswahl . . . . .	32
4.4. Kreuzvalidierung . . . . .	34
4.5. Verifikation . . . . .	35
4.5.1. Mean absolute Error . . . . .	35
4.5.2. Mean Squared Error . . . . .	35
4.5.3. Root Mean Squared Error . . . . .	35
4.5.4. Bias . . . . .	36
4.5.5. Skill Score . . . . .	36

<b>5. Ergebnisse</b>	<b>38</b>
5.1. Modelle zur Hagelvorhersage . . . . .	38
5.1.1. Varianzanalyse . . . . .	39
5.1.2. Vergleich der Regressionsmodelle . . . . .	40
5.1.3. Korrelation der Prediktoren . . . . .	41
5.1.4. Verifikation . . . . .	42
5.2. Fallstudien zu Lightning-Jumps . . . . .	47
<b>6. Zusammenfassung und Diskussion</b>	<b>49</b>
<b>7. Ausblick</b>	<b>52</b>
<b>Abbildungsverzeichnis</b>	<b>54</b>
<b>Tabellenverzeichnis</b>	<b>55</b>
<b>A. Anhang</b>	<b>56</b>
A.1. Datengrundlage . . . . .	57
A.2. Weitere Ergebnisse . . . . .	61
A.2.1. Legende der CellMOS-Gleichung . . . . .	61
A.2.2. Ergebnisse der Varianzanalyse . . . . .	62
A.2.3. Korrelation der Prediktoren . . . . .	63
<b>Literaturverzeichnis</b>	<b>66</b>

# 1. Motivation und Einleitung

Jedes Jahr im Sommer gelangen schwülheiße Luftmassen aus Südeuropa nach Mitteleuropa, sodass sich im schweizer Alpenraum teils heftige Unwetter bilden. Damit verbunden steigt auch die Gefahr von Großhagel ( $> 2$  cm nach Definition ESSL [Stand: 2016]). Hagel entsteht im Zusammenspiel mit starken Aufwinden in einem Gewitter, welche unter Idealbedingungen Vertikalgeschwindigkeiten bis 200 km/h erreichen können. Oft verursacht ein kräftiger Hagelsturm große Schäden an Fahrzeugen, Gebäuden und landwirtschaftlichen Nutzflächen. Dass bei Hagelschlag auch ein ernsthaftes Gefahrenpotential für Mensch und Tier besteht, zeigen Extremwetterereignisse wie am 30.08.2022, bei dem ein Kleinkind in Katalonien von Riesenhagel tödlich verletzt wurde, sowie ein weiterer Fall aus Süddeutschland, wo während eines Hagelunwetters am 26.08.2023 über ein Dutzend Rehe in einem Wildtiergehäge nahe des Starnberger Sees ihr Leben verloren. Erst am 24. Juli 2023 fiel in der italienischen Stadt Verona ein Hagelkorn mit einem geschätzten Durchmesser von 19 cm, welches aufgrund seiner enormen Größe den neuen europäischen Hagelrekord aufstellte. Extremwetterereignisse wie diese weisen auf die dringende Notwendigkeit präziser Hagelvorhersagen für die Öffentlichkeit hin.

Vorhersagemeteorologen wissen schon länger, dass starke Gewitter, speziell diejenigen, welche einen rotierenden Aufwind besitzen (sog. Superzellen), mit einer hohen absoluten Blitzaktivität (Wolken- und Erdblitz) einhergehen. Besonders die Blitzaktivität innerhalb der Gewitterwolke nimmt im Entstehungsstadium einer Gewitterzelle oft sprunghaft zu. Der Versuch, das Gefahrenpotential eines Gewitters auf Basis der totalen Blitzaktivität vorherzusagen, wurde bereits von Schultz et al. [2009, 2011] unternommen.

”The use of total lightning data, especially through the filter of a lightning jump algorithm, may provide an expedient means to help forecasters understand what is physically happening in select thunderstorms (e.g., updraft strength and trends in updraft).“

Schultz et al. 2009

Dabei entwickelte er verschiedene Lightning-Jump-Algorithmen, welche im Kern darauf abzielen, schwere Gewitter mit Unwetterpotential von nicht-schweren Gewittern zu unterscheiden. So kann ein Lightning-Jump-Algorithmus nachweislich die Echtzeit-Erkennung von Gewittern mit unwetterartigen Begleiterscheinungen verbessern Schultz et al. [2009].

Der allgemeine Erfolg der Studie von Schultz et al. [2009] deutet darauf hin, dass es einen physikalischen Zusammenhang zwischen der Blitzaktivität und dem Unwetterpotential eines Gewitters gibt, welcher im besten Fall auch für die Verbesserung der Hagelvorhersage im Nowcasting genutzt werden kann.

Bereits im Jahr 2008 ebnete Jan Hoffmann in seiner Dissertation den Weg für das heute von der Firma METEO SERVICE weather research GmbH (METEO SERVICE) operationell betriebene CellMOS-Verfahren. „Damit ist ein System entstanden, das in der Lage ist, die Zugbahn und die Eigenschaften individueller Gewitterzellen auf Basis des MOS-Prinzips vorherzusagen“ Hoffmann [2008].

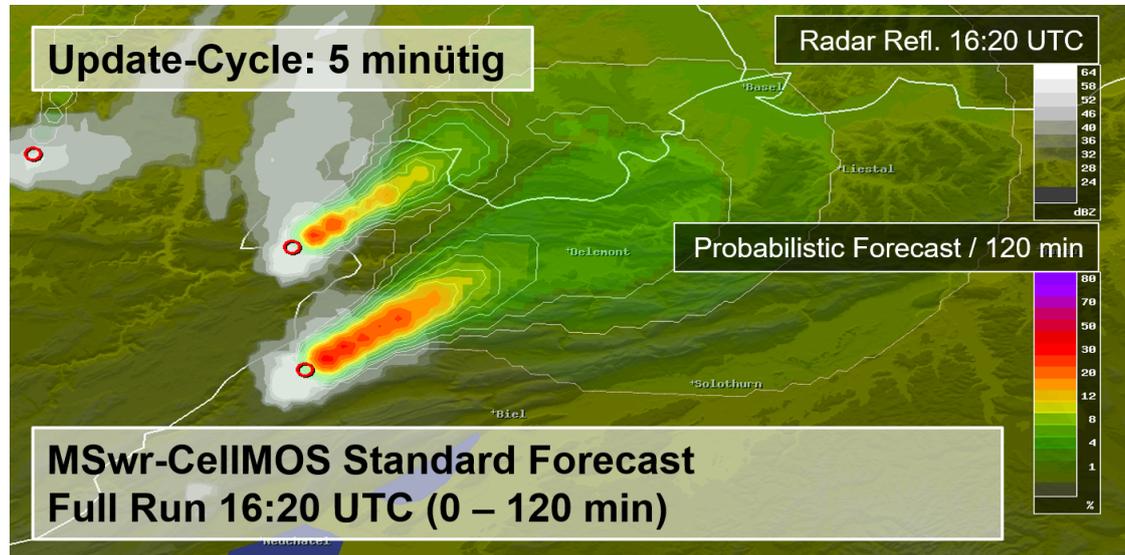


Abb. 1.1.: Die Abbildung zeigt das für die Schweiz entwickelte CellMOS von METEO SERVICE während einer Gewitterlage. Das System detektiert Gewitterzellen und prognostiziert deren Verlagerung sowie die probabilistische Änderung bestimmter Zelleigenschaften. Jede Gewitterzelle erhält dabei eine individuelle Zell-ID. Die Zeitspanne zwischen der Entstehung (Zelldetektion) und dem Zerfall (Zellauflösung) markiert den Lebenszyklus des Gewitters. Der Vorhersagezeitraum beträgt 0 bis 2 Stunden.

Ziel der Arbeit soll es sein zu untersuchen, inwieweit die Hinzunahme von Lightning-Jump-Prädiktoren die Modellgüte der Hagelvorhersage von Nowcasting-Systemen wie dem CellMOS-Verfahren von METEO SERVICE verbessern kann. Im Fokus soll dabei der Vorhersagezeitraum von 0 bis 30 min stehen. Für das gewählte Vorhersagemodell muss der Prädiktand des Modells zunächst passend transformiert werden. Die eigentliche Fragestellung wird durch die Erweiterung einer linearen Regressionsgleichung mit den Lightning-Jump-Prädiktoren unter Berücksichtigung der asymptotischen Theorie untersucht. In Kapitel 2 werden zunächst die wichtigsten Methoden zur Fernerkundung vorgestellt, sowie die Notwendigkeit der Beobachtungsdaten für das Nowcasting verdeutlicht. Außerdem gibt das Kapitel eine Einführung zum MOS-Prinzip und einen Einstieg in das CellMOS-Verfahren. Weiterhin werden hier die Grundlagen zur Hagelerkennung und Lightning-Jumps geklärt. In Kapitel 3 wird die Datengrundlage dieser Arbeit vorgestellt, bevor das Kapitel 4 die angewandte Methodik zur Modellentwicklung beschreibt. Das Kapitel 5 präsentiert die Ergebnisse der Arbeit, welche in Kapitel 6 noch einmal zusammengefasst und diskutiert werden. Das Kapitel 7 gibt abschließend einen Ausblick.

## 2. Grundlagen

### 2.1. Fernerkundung

Räumlich hochauflösende und zeitlich präzise Fernerkundungsdaten bieten heutzutage die grundlegende Basis für die Erfassung und Beobachtung von Gefahrenwetterlagen. Gerade in den letzten Jahrzehnten hat die Nutzung dieser Daten in der operationellen Wettervorhersage immens an Bedeutung gewonnen. Dabei liefern insbesondere Niederschlagsradarsysteme sowie die Blitzortung einen unersetzlichen Beitrag zur flächendeckenden Datengewinnung. Die statistische Aufbereitung dieser Daten hat ein hohes Potential, wenn es um die zukünftige Verbesserung von Nowcastvorhersagen bei Unwetterlagen geht.

#### 2.1.1. Niederschlagsradar

Das Niederschlagsradar hat sich bei der Ortung von konvektivem Niederschlag als vorteilhaft erwiesen und ist bei vielen Wetterdiensten als Komposit-Produkt zum flächigen Monitoring von Gefahrenwetterlagen nicht mehr wegzudenken. Das Radar sendet elektromagnetische Wellen aus, welche vom Niederschlag in der Atmosphäre reflektiert werden. Das reflektierte Signal wird vom Radar empfangen und in ein Bild umgewandelt, das die Intensität der Niederschlagsteilchen in der Umgebung der Radarstation zeigt. Mit modernen Radarsystemen lässt sich heutzutage alle 5 Minuten ein hoch aufgelöstes, dreidimensionales Bild der Niederschlagsverteilung in der Atmosphäre erzeugen. Dabei wird mithilfe eines Abtastzyklus zunächst ein bodennaher, der Orografie angepasster Antennenumlauf erzeugt (Niederschlagsscan), welchem mehrere Antennenumläufe in verschiedenen Elevationswinkeln der Radarantenne folgen (Volumenscan). In der Folge werden die gewonnenen Daten über Verarbeitungsalgorithmen prozessiert und visualisiert. Als Endprodukt steht dem Nutzer ein sogenanntes CAPPI-Produkt, also eine horizontale, zweidimensionale Darstellung der Niederschlagsreflektivität über die Höhe des Radarscans, zur Verfügung.

Mit modernen Radarverfahren wie der Dual Polarisation, mit der eine Echtzeitmessung verschiedener Niederschlagsarten möglich ist, oder Doppler-Verfahren, mit denen eine Aussage über die Geschwindigkeit und Bewegungsrichtung der Niederschlagsteilchen getroffen werden kann, lassen sich zusätzliche Informationen über die Niederschlagsteilchen einer Gewitterzelle gewinnen. Aufgrund der hohen Aktualisierungsrate und der Geschwindigkeit, mit der diese Produkte berechnet werden, sind diese ebenfalls für Nowcasting-Systeme mit hoher räumlicher und zeitlicher Frequenz geeignet.

### 2.1.2. Blitzortung

Moderne Blitzortungssysteme sind heutzutage in der Lage, die in Zusammenhang mit Gewittern auftretenden Blitzschläge automatisch zu orten und nach Wolken- und Erdblitz zu unterscheiden. Mittels des sogenannten "Time of Arrival" Verfahrens (TOA) empfangen dabei mehrere Sensoren des Messnetzes die elektromagnetischen Wellen, die ein Blitz aussendet. Über die Laufzeitdifferenzen des Signals lässt sich der Blitzentladung eine 4D-Position (Ort, Zeit) und eine Intensität (Stromstärke) zuordnen. Auf diese Weise erhält man ein sekundlich aufgelöstes Bild der aktuellen Blitzaktivität in der Atmosphäre. Zusammen mit den 5-minütigen Niederschlagsreflektivitäten des Niederschlagsradars lassen sich damit Rückschlüsse auf die Intensität einer aktiven Gewitterzelle ziehen.

Bereits Jan Hoffmann wies in seiner Dissertation auf den Vorteil einer Integration von Blitzdaten in Nowcasting-Vorhersagesysteme hin:

„Eine besondere Bedeutung kommt Blitzortungsdaten im Vergleich zu Radardaten deswegen zu, weil im frühen Lebensstadium einer Gewitterzelle die ersten Entladungen oft schon registriert werden, bevor der erste Niederschlag den Boden erreicht Steinacker et al. [2000]. Genau diese Eigenschaft der Echtzeit-Erkennung macht Blitzortungsdaten zu wertvollen Prediktoren für Nowcasting-Vorhersagesysteme.“

Jan Hoffmann, 2008

## 2.2. Das MOS-Prinzip

Das MOS-Verfahren (“Model Output Statistics”) ist ein weit verbreitetes Verfahren zur automatischen Vorhersage von verschiedenen meteorologischen Parametern. Dabei werden die Ergebnisse numerischer Wettermodelle anhand historischer Datensätze mittels statistischer Verfahren adaptiert Hoffmann [2008].

„Allgemein beschreibt MOS die statistische Nachbearbeitung von Vorhersagedaten anhand historischer Beobachtungsdatensätze.“

Glahn und Lowry, 1972

Ein grundsätzlicher Vorteil von MOS-Systemen ist die Fähigkeit, unterschiedliche Datenquellen zu vereinen und deren maximal mögliche gemeinsame prognostische Information zu nutzen. Auf diese Weise können systematische Fehler der Modelle korrigiert und ortsspezifische Besonderheiten berücksichtigt werden, was zu akkurateren Prognosen führt. Neben dem klassischen MOS-Verfahren auf Basis von Beobachtungsdaten an einer ortsfesten Wetterstation haben sich in jüngerer Zeit weitere MOS-Ansätze entwickelt Hoffmann [2008].

### 2.2.1. MOS auf beweglichen Systemen

Wie Hoffmann [2008] in seiner Arbeit klarstellt, lassen sich MOS-Systeme auch auf bewegte Systeme übertragen, da rein mathematisch keine Notwendigkeit dafür besteht, dass die Orte, die der entsprechenden Beobachtungsdatenreihe zugeordnet sind, fix sein müssen.

„Dass MOS-Systeme prinzipiell vom Eulerschen auf ein Lagrangesches Bezugssystem umgestellt werden können steht außer Frage.“

Jan Hoffmann, 2008

„Hintergrund dieser Überlegungen ist die Tatsache, dass beispielsweise individuelle Gewitterzellen im Verlauf ihres Lebenszyklus bestimmte Eigenschaften besitzen, die sich prinzipiell für die statistische Vorhersage mittels linearer Regression eignen“ Hoffmann [2008]. Die sich durch den geografischen Raum bewegenden Konvektionszellen, lassen sich demnach als sogenannte “MOS-Objekte” auffassen (vgl. Abschnitt 2.3.1).

## 2.3. Das CellMOS

Auf Basis der Erkenntnis, dass sich MOS-Systeme auch auf bewegte Systeme übertragen lassen Hoffmann [2008], wurde von METEO SERVICE das sogenannte CellMOS entwickelt, welches in Zusammenarbeit mit METEO SCHWEIZ und im Auftrag des Schweizer Fernsehens (SRF) betrieben wird.

Das CellMOS ist ein MOS-basiertes Vorhersageverfahren für automatisierte Gewitterwarnungen. Es dient der gezielten Verfolgung und Vorhersage von Gewitterzellen. Das System berechnet die Wahrscheinlichkeiten verschiedener meteorologischer Parameter mittels linearer Regression bis zu 120 min im Voraus eines aufziehenden Gewitters.

Dabei nutzt das CellMOS-Verfahren den MOS-Ansatz, um Modelldaten mit hochauflösenden Beobachtungsdaten zu vereinen. Die gezielte Kombination von Wetterradar- und Blitzortungsdaten hat sich bei der Erkennung und der Vorhersage von Hagelgewittern im Nowcasting als hilfreich erwiesen [u.a. Wapler, 2017].

In dieser Arbeit wird mit dem Verfahren versucht, vor Hagel zu warnen (siehe Abb. 1.1, Motivation 1). Mit CellMOS kann aber auch vor anderen prognoserelevanten Zellattributen gewarnt werden (Niederschlagrate, maximale Böen, etc.).

Da beim Nowcasting oft einfache Extrapolationsverfahren verwendet werden, hängt die Prognose überwiegend von den aktuellen Beobachtungsdaten ab. So ist CellMOS in der Lage, selbst mit bereits veralteten Modelldaten eine der aktuellen Beobachtungssituation angepasste Vorhersage zu erstellen Hoffmann [2008].

### 2.3.1. Zellobjekte

Auf dem Radar sind Gewitterzellen kleinräumige Gebiete ( $\sim 10$  km), welche mit einer hohen Radarreflektivität und einer Blitzaktivität verbunden sind (siehe Abb. 3.3). Diese Gebiete hoher Radarreflektivität werden von CellMOS genutzt, um die Konvektionszellen als Zellobjekte zu detektieren (Abschnitt 2.3.2). Der Grund für diese vereinfachte Art der Auffassung einer Gewitterzelle ist die Erkennung und Verfolgung von Konvektionszellen auf Basis von flächig verfügbaren Radardaten. Demnach wird die pseudodreidimensionale Reflektivität einer Gewitterzelle im CAPPI-Format von CellMOS als "MOS-Objekt" aufgefasst, dem anschließend verschiedene Zelleigenschaften zugeordnet werden können. Beispielsweise wird über die geografischen Raumkoordinaten einer Gewitterzelle mittels des Zellradius die Anzahl der Blitze zugeordnet. Um letztendlich Wahrscheinlichkeitsvorhersagen im Raum zu erstellen, werden die Konvektionszellen mit ihren Zelleigenschaften als „Gauss-Berge“ aufgefasst [siehe Knüpper, 2017, Folie 13].

### 2.3.2. Zellerkennung

Zur Erkennung von Zellobjekten verwendet CellMOS vereinfachte Ansätze des vom National Weather Service in den USA entwickelten SCIT-Algorithmus Johnson et al. [1998]. Das Prinzip beruht im Wesentlichen darauf, mittels definierter Schwellenwerte kleine zusammenhängende Gebiete sehr hoher Reflektivität aus den radial angeordneten Radarpixeln zu erkennen und deren Schwerpunkte den tatsächlichen Gewitterzellen zuzuordnen Hoffmann [2008]. Mit einem einfachen Algorithmus zur Mustererkennung wird dabei nach Reflektivitätseigenschaften gesucht, denen bei Überschreitung bestimmter Definitionskriterien eine individuelle Zell-ID, ein Zeitstempel und eine Position zugeordnet wird.

Zunächst werden aus dem Radarpixelbild (Abb. 3.3) die Zellmittelpunkte bestimmt. Hierfür werden zusammenhängende Flächen der Überschreitung bestimmter Reflektivitätsschwellenwerte gesucht, wobei sich bei METEO SERVICE nach einer Reihe von Tests

eine Konfiguration mit drei Reflektivitäts-Schwellenwerten (bei 40, 47.5 und 55 dBZ) als stabil erwiesen hat. Um eine falsche Erkennung durch Störsignale (Fehlpixel oder Clutter), zu vermeiden, wird für jeden Schwellenwert ein unterer Grenzwert für den Flächeninhalt festgelegt. Dadurch werden nur ausreichend große Flächen zur Zellerkennung herangezogen. Mittels empirischer Untersuchungen und Analysen haben sich hier die Schwellenwerte bei 9 km<sup>2</sup>, 4 km<sup>2</sup> und 2 km<sup>2</sup> als geeignete Minimalwerte herausgestellt Hoffmann [2008]. Um eine Konvektionszelle nicht zu groß werden zu lassen, wird im CellMOS von METEO SERVICE der niedrigste Reflektivitäts-Schwellenwert von 40 dBZ mit einer maximalen Fläche von 500 km<sup>2</sup> belegt. „Abschließend werden die gefundenen Flächen einander zugeordnet, d.h. Flächen der Überschreitung eines höheren Schwellenwertes werden der Fläche des entsprechend nächstniedrigeren Schwellenwertes zugeordnet. Enthält eine gefundene Fläche keine Unterfläche mit höherem Schwellenwert mehr, wird ein Reflektivitätsschwerpunkt dieser Fläche berechnet und als (erkannter) Zellmittelpunkt festgelegt“ Hoffmann [2008]. Damit eine Konvektionszelle als ein Gewitter in den Trackingdatensatz von CellMOS aufgenommen wird, muss während ihres gesamten Lebenszyklus mehr als ein Blitz auftreten.

### 2.3.3. Zelltracking

Um die Verlagerung einer Gewitterzelle prognostizieren zu können, bedarf es einem Algorithmus, welcher die Gewitterzelle nach ihrer Erkennung verfolgt, und dabei die zeitliche Änderung ihrer Eigenschaften berücksichtigt. Jan Hoffmann beschreibt die Herausforderungen bei der Entwicklung eines geeigneten „Tracking“-Verfahrens in seiner Arbeit wie folgt: „Um die zukünftige Zugbahn einer Gewitterzelle und deren Lebenszyklus statistisch vorherzusagen, werden nicht nur statische Angaben über die Eigenschaften einer Gewitterzelle zu einem bestimmten Zeitpunkt (z.B. zum Zeitpunkt eines Radarscans) benötigt, sondern auch Informationen über den zeitlichen Verlauf dieser Eigenschaften. Dieser zeitliche Verlauf stellt letztendlich den kompletten Lebenszyklus einer Gewitterzelle dar. Hierzu reichen aber die aus dem reinen Zellerkennungsmechanismus (Abschnitt 2.3.2) gewonnenen Daten nicht aus, da mit diesen keine Aussage über die Zugehörigkeit bestimmter Gewitterzellorte zueinander in aufeinander folgenden Radarbildern gemacht werden kann. Es ist also ein zusätzlicher „Tracking“-Mechanismus notwendig, der die Zellortungen in einem Radarbild, wenn möglich, entsprechenden erkannten Zellen im vorhergehenden Bild zuordnet. Dann erst können durch Differenzbildung Aussagen über die zeitliche Veränderung der Zelleigenschaften (wie Verlagerung oder Entwicklung) gemacht werden. Schließlich sind es genau diese Veränderungen, die von besonderem prognostischem Interesse sind“ Hoffmann [2008].

In seiner Arbeit verweist Hoffmann beispielsweise auf Korrelationsmethoden, die durch Vergleich von zueinander verschobenen, aufeinander folgenden Radarbildern die Verlagerungsvektoren der Zellen abschätzen Li et al. [1995], Rinehart and Garvey [1978].

Außerdem ließ er sich bei der Entwicklung eines Tracking-Verfahrens für das in dieser Arbeit vorgestellte CellMOS von Steinacker et al. [2000] inspirieren, welcher ein System entwickelt hat, dass auf Basis von Blitzortungs- und Radardaten ein automatisches Erkennen und Tracking von Gewitterzellen leistet.

## 2.4. Hagelerkennung

Im Laufe der letzten Jahrzehnte wurden verschiedene operationelle Ansätze für die Vorhersage von Hagel entwickelt. Daraus sind unterschiedliche Algorithmen für die Bewertung des Hagelrisikos einer Gewitterzelle hervorgegangen. Sie liefern alle eine radarbasierte Schätzung für das Auftreten von Hagel am Boden.

Das einfachste Hagelkriterium nach Mason [1971] besagt, dass bei einem Schwellenwert des MaxCappi von über 55 dBZ Hagel am Boden auftritt. „Bei einem MaxCappi wird die höchste gemessene Reflektivität von dreidimensionalen Daten auf eine zweidimensionale Fläche projiziert. Dabei wird die Höhe, in der diese Radarreflektivität auftritt, nicht berücksichtigt“ Kugel [2012]. Später entwickelte Waldvogel et al. [1979] an der ETH-Zürich das sogenannte Waldvogelkriterium, welches aussagt, dass die Höhe der 45 dBZ Radarreflektivität für das Auftreten von Hagel mindestens 1,4 km über der Höhe der 0°C Grenze liegen muss. Waldvogel stellte dabei auch das grundlegende Kriterium für die sogenannte Probability of Hail (POH) auf, welche das Verhältnis zwischen der Konturhöhe der 45 dBZ-Reflektivität ( $H_{45}$ ) und dem Schmelzpunkt ( $H_{T_0}$ ) beschreibt. Das Kriterium wurde von Witt et al. [1998] weiterentwickelt, welcher die Hagelwahrscheinlichkeit als Dichtefunktion von  $H_{45} - H_{T_0}$  definierte. Nach seiner Erkenntnis tritt bei einer Höhendifferenz von 5,5 km mit fast 100 %iger Wahrscheinlichkeit Hagel (beliebiger Größe) am Boden auf [siehe Witt et al., 1998, S. 287, Abb. 2].

Des Weiteren entwickelte Witt et al. [1998] auf der Suche nach einem zuverlässigeren Detektionsalgorithmus für das amerikanische WSR 88 Radarsystem zwei neue Algorithmen, die als Probability of severe Hail (POSH) und Maximum Estimated Size of Hail (MESH) bezeichnet werden. Beide Algorithmen nutzen den sogenannten Severe Hail Index (SHI) als wesentliche Inputgröße (vgl. Abschnitt 2.4). Während der POSH-Algorithmus die Wahrscheinlichkeit für das Auftreten von Hagel mit einem Durchmesser von  $\geq 0.75$  inch ( $\sim 1,9$  cm) angibt, ist der MESH-Algorithmus ein skalares Maß für die erwartete Hagelgröße am Boden.

Für die Wahl des Hagelprädiktanden der Hagelvorhersage im CellMOS hat sich der MESH-Algorithmus nach Witt et al. [1998] als geeignetes Maß erwiesen, da er der einzige Algorithmus ist, welcher die potentielle Größe des Hagels am Boden berücksichtigt. Die größenbasierte Warnung vor Hagelkörnern, speziell vor Großhagelereignissen, stellt während sommerlicher Unwetterlagen ein grundlegendes Interesse im operationellen Dienst dar (siehe Abschnitt 1, vgl. Hagelklassifikation nach Thilo Kühne [2019]).

Außerdem wurde der MESH-Algorithmus bereits in einer aktuellen Studie zur radargestützten Hageldetektion und Größenabschätzung von Hagel beim Deutschen Wetterdienst untersucht. In der darin präsentierten Vorhersageverifikation von [Schultze et al., 2023, Tabelle 4] mit einer Vielzahl von Hagelbeobachtungen aus der ESWD (European Severe Weather Database) erweist er sich als ein verlässliches Maß für das Auftreten von Hagel am Boden. Mit einer Erkennungsgenauigkeit (POD) von gut 98% kann der Algorithmus auch für die radargestützte Hageldetektion im CellMOS herangezogen werden.

Abschließend sei erwähnt, dass heutzutage viele Radarstationen mit Dual-Polarisation ausgestattet sind, was die Detektion von Hagel verbessern kann Illingworth et al. [1986]. Spezielle Niederschlagsklassifikationsverfahren, die in Kombination mit Radar-, Modell- und Stationsdaten arbeiten, können zukünftig ebenfalls zu einer besseren Erkennung von Hagelereignissen beitragen. Ein Beispiel für einen operationellen Algorithmus dieser Art ist die Hydrometeoriklassifikation (HYMEC) nach Steinert et al. [2021] vom Deutschen Wetterdienst (DWD).

### MESH - Maximum Estimated Size of Hail (NOAA)

Der Hagelindex gibt eine Schätzung der maximal zu erwartenden Hagelgröße an.

Die Maximum Estimated Size of Hail (MESH, Virtual Lab [a]) ergibt sich aus:

$$MESH = \sqrt{SHI} \quad (2.1)$$

wobei SHI der Severe Hail Index ist. Mit der Multiplikation eines Umrechnungsfaktors lässt sich die Einheit der amerikanischen Hagelgröße in cm angeben:

$$MESH \text{ (cm)} = 2,54 \cdot MESH \text{ (inch)} \quad (2.2)$$

### SHI - Servere Hail Index (NOAA)

Der Servere Hail Index (SHI, Virtual Lab [b]) ist eine thermisch gewichtete vertikale Integration des Reflektivitätsprofils einer Gewitterzelle (Gl. 2.6). Er wird genutzt, um die Maximum Estimated Size of Hail (Gl. 2.1) zu berechnen.

Um das Vorhandensein von schwerem Hagel zu bestimmen, wird zunächst eine Reflektivitäts-Hagel-Beziehung ( $Z-\dot{E}$ -Relation, Abb. 2.1) verwendet, um die Reflektivitätsdaten vom Niederschlagsradar in Flusswerte der kinetischen Energie des Hagels ( $\dot{E}$ ) umzuwandeln:

$$\dot{E} = 5 \cdot 10^{-6} \cdot 10^{0,084Z} W(z), \quad (2.3)$$

$\dot{E}$  steht in engem Zusammenhang mit dem Schadenspotenzial des Hagels am Boden. Dabei werden die Flusswerte des Hagels mit spezifischen Schwellenwerten der Niederschlagsreflektivität ( $Z$ ) gewichtet, um eine Übergangszone zwischen der Regen- und Hagelreflektivität zu definieren:

$$W(Z) = \begin{cases} 0 & \text{for } Z \leq Z_L \\ \frac{Z-Z_L}{Z_U-Z_L} & \text{for } Z_L < Z < Z_U \\ 1 & \text{for } Z \geq Z_U \end{cases} \quad (2.4)$$

Die Reflektivitätsschwellenwerte der Wichtungsfunktion liegen demnach bei  $Z_L = 40$  dBZ (untere Grenze) und  $Z_U = 50$  dBZ (obere Grenze). Es sei darauf hingewiesen, dass die Grenzwerte der Wichtungsfunktion beliebig angepasst werden können.

Während die Z-Ë-Relation darauf abzielt, dass nur die hohen Reflexionsgrade, die typischerweise mit Hagel assoziiert werden, eine Wichtung finden, nutzt das vielfach bekannte Vertical Integrated Liquid (VIL, Virtual Lab [c]) zur Berechnung des Flüssigwassergehalts der Atmosphäre hauptsächlich niedrigere Reflexionsgrade, welche typischerweise mit flüssigen Wassertropfen assoziiert werden, und filtert die hohen Reflexionsgrade der Niederschlagsreflektivität heraus (vgl. Abb. 2.1).

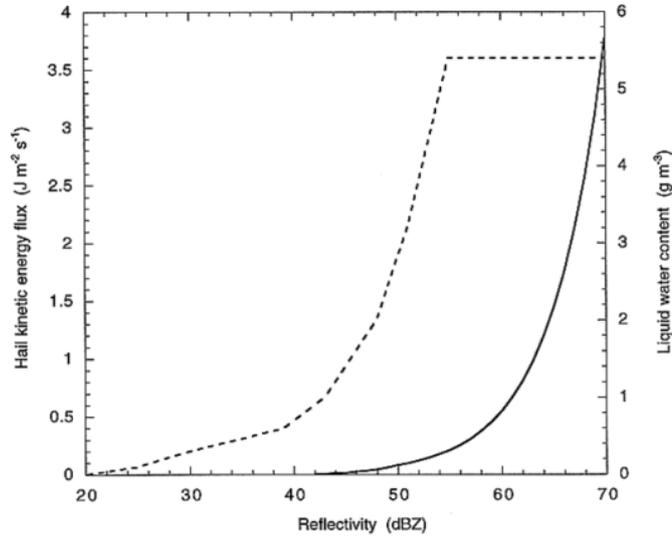


Abb. 2.1.: Darstellung des kinetischen Energieflusses des Hagels (durchgezogene Kurve) und des Flüssigwassergehalts zur Berechnung der VIL (gestrichelte Kurve) als Funktion der Reflektivität [nach Witt et al., 1998, S. 288].

Als Nächstes wird eine vertikale Temperaturwichtung verwendet, um die Zone des optimalen Hagelwachstums abzubilden, die es gemäß den empirischen Erkenntnissen der Hagelforschung zu berücksichtigen gilt.

$$W_T(H) = \begin{cases} 0 & \text{for } H \leq H_0 \\ \frac{H-H_0}{H_{-20}-H_0} & \text{for } H_0 < H < H_{-20} \\ 1 & \text{for } H \geq H_{-20}. \end{cases} \quad (2.5)$$

Während bei Temperaturen über  $0^\circ\text{C}$  kein Hagelwachstum auftritt, findet das meiste Wachstum der Hagelkörner bei einem Temperaturniveau nahe  $-20^\circ\text{C}$  oder kälter statt. Die vertikale Schicht zwischen den gegebenen Grenzwerten wird in der Literatur häufig als “Hail Growth Zone” (HGZ) oder “Hail Growth Layer” (HGL) bezeichnet, und beschreibt den Temperaturbereich, in dem Hagelkörner heranwachsen können. Sowohl das Freezing Level ( $H_0$ ) als auch die Höhe der  $-20^\circ\text{C}$ -Isotherme ( $H_{-20}$ ) können aus dem Temperaturprofil numerischer Modellfelder, hier also dem IFS ( $0.4^\circ$ ), ermittelt werden.

Zusammenfassend ergibt sich damit ein Index zur Erkennung von Hagel, der als Severe Hail Index (SHI) bezeichnet wird. Er ist definiert als:

$$SHI = 0.1 \int_{H_0}^{H_t} W_T(H_T) \dot{E} \, dH \quad (2.6)$$

Dabei ist  $W_T(H_T)$  die thermisch gewichtete Höhe der Gewitterzelle über der 0°C-Grenze (Gl. 2.5).  $\dot{E}$  wird unter Verwendung der Niederschlagsreflektivität innerhalb des Reflektivitätsprofils der Gewitterzelle (Gl. 2.3 & 2.4) berechnet. Die Einheit des SHI ist  $\frac{\text{J}}{\text{ms}}$ .

## 2.5. Lightning-Jumps

Als ‐Lightning-Jump‐ bezeichnet man den sprunghaften Anstieg der Gesamtblitzrate in einem Gewitter. In dieser Arbeit stehen dem CellMOS die Lightning-Jump-Algorithmen von Schultz et al. [2009] zur Verfugung. In seiner Arbeit stellt er zwei Arten von Algorithmen vor. Einerseits sind das Schwellenwert-Algorithmen, die auf der einfachen Änderung der Spitzenblitzrate eines Gewitters basieren, andererseits entwickelte er sogenannte Sigma-Algorithmen, welche sich die Standardabweichung („Sigma“) der gemittelten Gesamtblitzrate für das Auftreten eines Blitzsprungs zu nutze machen. Beide Algorithmen stützen sich auf die Änderung der Spitzenblitzrate eines Gewitters, welche von C. Schultz als DFRDT-Wert  $\left(\frac{d \text{FR}(t)}{dt}\right)$  angegeben wird.  $\text{FR}(t)$  steht hierbei für ‐Flash rate‐ und bezeichnet die Gesamtblitzrate der Gewitterzelle.

### Laufendes Mittel der Gesamtblitzrate

Beide Lightning-Jump-Algorithmen verwenden zunächst eine gemittelte Spitzenblitzrate des Gewitters. Diese neue Gesamtblitzrate ( $\text{FR}_{avg}$ ) besteht aus Wolken- und Erdblitzten und wird von Schultz et al. [2009] auch als laufendes Mittel (‐Rolling Mean‐) bezeichnet.

$$\text{FR}_{avg}(t_i) = \frac{\text{FR}_{(t_{n-1})} + \text{FR}_{(t_n)}}{2} \quad \text{mit } t_i = (t_1, \dots, t_n) \quad (2.7)$$

Dabei ist  $\text{FR}_{avg}(t_i)$  die über 2 Minuten hinweg gemittelte 1-minütige Gesamtblitzrate nach Gatlin [2006]. Das Mittel hilft, einen Teil des Rauschens der Blitzdaten zu eliminieren und hat sich nach Gatlin and Goodman [2010] als die effektivste Technik der zeitlichen Mittelung erwiesen.

### Der Schwellenwert-Algorithmus

Der Schwellenwert-Algorithmus ist die einfachste Methode zur Untersuchung der Gesamtblitzaktivität. Sein Ziel ist die Unterscheidung zwischen einem schweren und einem nicht-schweren Gewitter auf Basis von klimatologischen Beobachtungsdaten.

Die Herleitung des Schwellenwert-Algorithmus umfasst einen zweistufigen Prozess.

Der erste Schritt basiert auf der Auswertung von 1-minütigen Spitzenblitzraten [u. a. Williams et al., 1999] einer Vielzahl von nicht-schweren Gewittern aus den Vereinigten Staaten (Abb. 2.2).

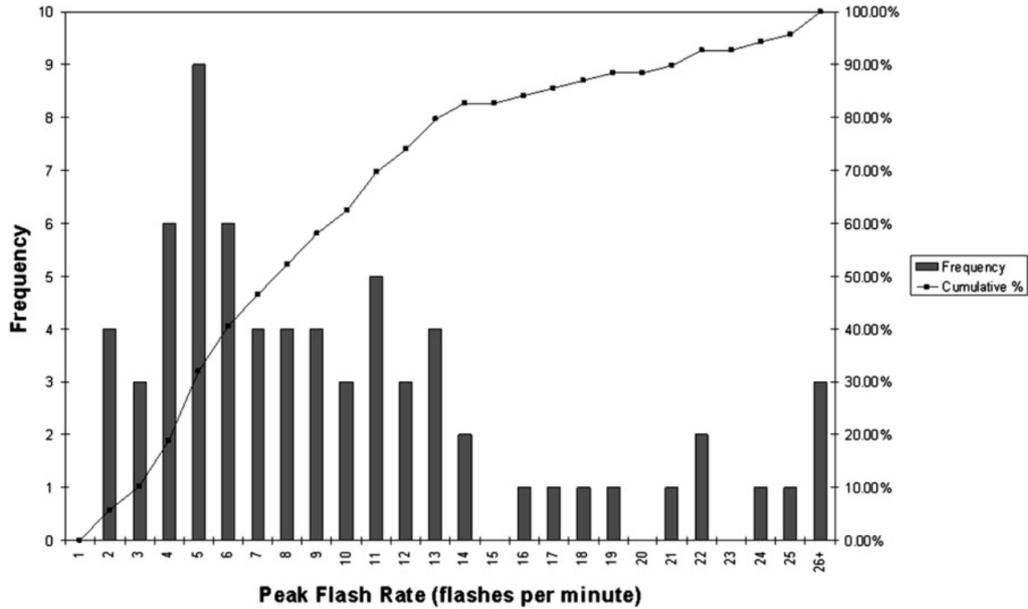


Abb. 2.2.: Das Histogramm zeigt die Spitzenblitzraten (Blitze pro Minute) von 69 nicht-schweren Gewittern ( 47 aus Nord-Alabama, 9 aus Dallas/Fort Worth, 13 aus Houston). Die durchschnittliche Spitzenblitzrate des gesamten Datensatzes beträgt 10 Blitze pro Minute. Wie aus der kumulativen Häufigkeitsverteilung hervorgeht, haben fast 60 % der nicht-schweren Gewitter eine Spitzenblitzrate von weniger als 10 Blitzen pro Minute, und 90 % dieser Gewitter haben eine Spitzenblitzrate von weniger als 20 Blitzen pro Minute [vgl. Schultz et al., 2009, Abb. 2, S. 2549].

In der Abbildung 2.2 wird ersichtlich, dass die durchschnittliche 1-minütige Spitzenblitzrate der Gewitter bei rund 10 Blitzen pro Minute liegt. Dieser allgemeine Schwellenwert der Gesamtblitzrate schaltet den Algorithmus ein und soll zunächst unterscheiden, ob die Blitzaktivität mit einem nicht-schweren oder einem schweren Gewitter verbunden ist.

$$\text{FR}_{avg}(t_i) > 10 \frac{\text{Flashes}}{\text{min}} \quad (2.8)$$

Der zweite Schritt verwendet den DFRDT-Wert als die zeitliche Änderung der Spitzenblitzrate. Dieser Wert beschreibt den Trend der gemittelten Gesamtblitzrate (Gl. 2.7).

$$\frac{d \text{FR}_{avg}(t_i)}{dt} = \frac{\text{FR}_{avg}(t_i) - \text{FR}_{avg}(t_{i-1})}{t_i - (t_{i-1})} > 10 \frac{\text{Flashes}}{\text{min}^2} \quad (2.9)$$

Ein hinreichend signifikanter Anstieg der Gesamtblitzrate soll anschließend bestimmen, ob ein Lightning Jump auftritt oder nicht. Dabei wurde der Schwellenwert willkürlich auf das 93. Perzentil gesetzt, was im Fall der untersuchten Gewitter einer Abweichung von 10 Blitzen pro Minute zum Quadrat entspricht (vgl. Abb. 2.3).

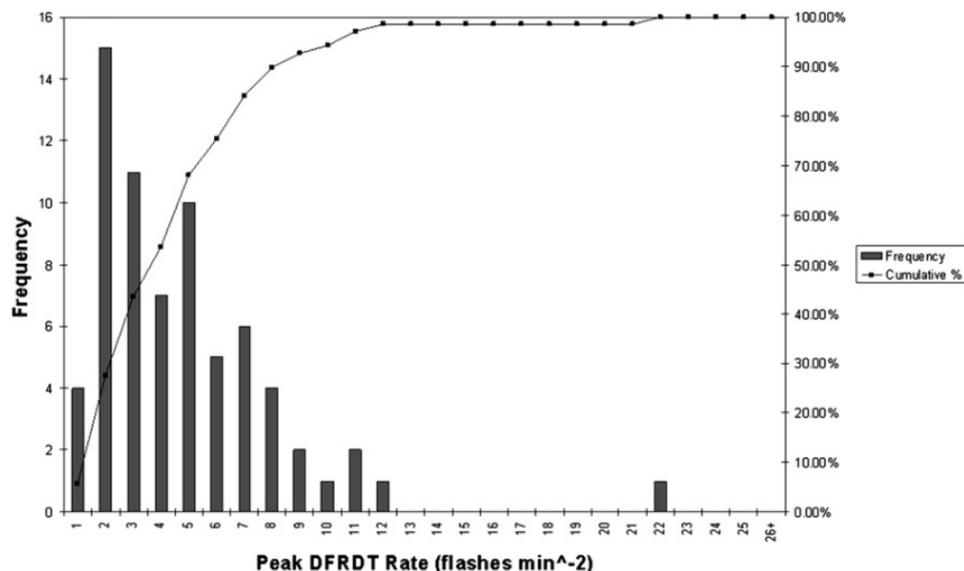


Abb. 2.3.: Das Histogramm zeigt die DFRDT-Spitzenwerte (Blitze pro Minute zum Quadrat) für dieselben 69 nicht-schweren Gewitter aus Abb. 2.2. Wie aus der kumulativen Frequenzlinie hervorgeht, liegt das 93. Perzentil bei 10 Blitze pro Minute zum Quadrat [vgl. Schultz et al., 2009, Abb. 3, S. 2550].

Ein Nachteil des Schwellenwert-Algorithmus ist, dass bei der Definition eines willkürlichen Schwellenwertes auf Basis einer Blitzklimatologie immer eine gewisse Überschneidung bei der Klassifizierung eines schweren oder nicht schweren Gewitters zu erwarten ist. Dennoch kann diese einfache Form eines Lightning-Jumps nützliche Informationen in Echtzeitsituationen liefern, da der Algorithmus nicht rechenaufwendig ist [Schultz et al. 2009].

### Der Sigma-Algorithmus

Der von Schultz et al. [2009] entwickelte Sigma-Algorithmus stellt die verbesserte Variante des Gatlin-Algorithmus nach Gatlin [2006] dar. Beide Algorithmen arbeiten mit der Standardabweichung ( $\sigma$ ) einer mittleren Blitzrate. Im Vergleich zum Gatlin-Algorithmus verwendet der Schultz-Algorithmus eine geringere Glättung der Daten (sog. “Smoothing”) und einem höheren  $\sigma$ -Schwellenwert, um die False-Alarm-Rate zu senken.

Wie beim Schwellenwert-Algorithmus wird zunächst ein 1-minütiges laufendes Mittel berechnet, um die natürliche Variabilität der Blitzaktivität zu reduzieren (vgl. Gl. 2.7).

Danach wird auf Basis der gemittelten Gesamtblitzrate ein gleitendes Mittel über einen Zeitraum von 10 Minuten gebildet.

In diesem Fall wird jeder zweite  $\text{FR}_{avg}(t_i)$ -Wert genutzt, um einen  $\overline{\text{FR}_{avg}(t_i)}$ -Mittelwert zu berechnen:

$$\overline{\text{FR}_{avg}(t_i)} = \frac{\text{FR}_{avg}(t_1) + \text{FR}_{avg}(t_3) + \text{FR}_{avg}(t_5) + \text{FR}_{avg}(t_7) + \text{FR}_{avg}(t_9)}{5} \quad (2.10)$$

Um ein abnormales Blitzverhalten zu identifizieren, wird von diesem laufenden Mittelwert eine  $2\sigma$ -Abweichung betrachtet. Nach Schultz eliminiert eine Abweichung von  $2\sigma$  dabei kleinere Sprünge, ermöglicht aber dennoch die Erkennung einer signifikanten Zunahme der Blitzaktivität Schultz et al. [2009].

Zum Schluss wird auf der Grundlage des laufenden Mittelwertes wieder ein DFRDT-Wert berechnet (vgl. Schwellenwert-Algorithmus, Gl. 2.9):

$$\frac{d \overline{\text{FR}_{avg}(t_i)}}{dt} = \frac{\overline{\text{FR}_{avg}(t_i)} - \overline{\text{FR}_{avg}(t_{i-1})}}{t_i - (t_{i-1})} \quad (2.11)$$

Nach dem Sigma-Algorithmus ( $2\sigma$ ) findet ein Lightning-Jump statt, sobald die folgenden zwei Bedingungen erfüllt sind:

$$\text{FR}_{avg}(t_i) > 10 \frac{\text{Flashes}}{\text{min}} \quad (2.12)$$

$$\frac{d \overline{\text{FR}_{avg}(t_i)}}{dt} > \frac{d \overline{\text{FR}_{avg}(t_{i-1})}}{dt} + 2\sigma \quad (2.13)$$

Demnach wird wie beim Schwellenwert-Algorithmus (vgl. Abb. 2.2) eine Gesamtblitzrate von 10 Blitzen pro Minute benötigt, um den Algorithmus zu aktivieren (Gl. 2.12).

Ein Lightning-Jump tritt auf, sobald ein DFRDT-Wert die Summe von Mittelwert und dessen zweifacher Standardabweichung überschreitet (Gl. 2.13), d.h. signifikant von der mittleren Blitzrate des Gewitters abweicht (Gl. 2.10). Die  $2\sigma$ -Abweichung kann hierbei als Schwellenwert betrachtet werden. Er endet, sobald der darauffolgende DFRDT-Wert kleiner oder gleich 0 wird. Es sei darauf hingewiesen, dass zwischen zwei Lightning-Jumps mindestens sechs Minuten vergehen müssen, sonst werden die aufeinanderfolgenden DFRDT-Werte als ein Lightning-Jump gezählt Schultz et al. [2009].

### Der Logarithmus der Gesamtblitzrate

Als ein zusätzlicher Blitzprädiktor wird im CellMOS die logarithmierte 5-minütige Spitzenblitzrate einer Gewitterzelle verwendet. Diese Transformation ist ein einfacher Ansatz, die Blitzrate eines Gewitters als einen Prädiktor für die Hagelvorhersage zu nutzen.

$$\text{FR}(t_{5\text{min}}) \xrightarrow{\text{Transformation}} \ln(\text{FR}(t_{5\text{min}})) \quad (2.14)$$

## 3. Daten

Die folgenden Modell- und Beobachtungsdaten liegen für den Zeitraum 2017-2021 vor. Aufgrund der Hauptsaison für Hagelgewitter wurde sich in dieser Arbeit auf die Monate Mai bis September beschränkt. Der Tagesgang wurde dabei nicht berücksichtigt.

### 3.1. Radardaten

METEO SCHWEIZ betreibt ein Netz von fünf Niederschlagsradarstationen, welches den Niederschlag und die Gewitter in Echtzeit, vollautomatisch, rund um die Uhr und flächendeckend über der Schweiz erfasst MeteoSwiss [Stand: 2023].



Abb. 3.1.: Standorte der Niederschlagsradare in der Schweiz MeteoSwiss [Stand: 2023]

Der Informationsgehalt des Radarbilds liegt im pgm-Bildformat vor, welches im Falle der Schweiz rund 256 Unterscheidungsklassen enthält.

Mittels einer empirischen Z-R-Beziehung für Regen im Sommer lässt sich die Reflektivität (dBZ) in eine Regenrate (mm/h) umrechnen:

$$\text{mm/h} = 300 \cdot \text{dBz}^{1.6} \quad (3.1)$$

Mit einem Index pro Unterscheidungsklasse lässt sich auf diese Art und Weise jedem Reflektivitätswert die entsprechende Regenintensität zuordnen.

Anhand der Tabelle 3.1 können die Reflektivitätswerte der einzelnen Unterscheidungsklassen in eine stündliche Niederschlagsintensität umgewandelt werden.

Tabelle 3.1.: Indizierung der Niederschlagsreflektivitäten nach Z-R-Beziehung in Gl. 3.1. Für alle 256 Unterscheidungsklassen siehe Tabelle A.1

Index	mm/h	dBZ
20	1	25
30	2	32.5
38	10	40
58	30	47.5
128	100	55
...	...	...

Anschließend lassen sich die indizierten Niederschlagsreflektivitäten über die vordefinierte Radardomain (Abb. 3.2) in ein vollständiges Radarkomposit (Abb. 3.3) übertragen.

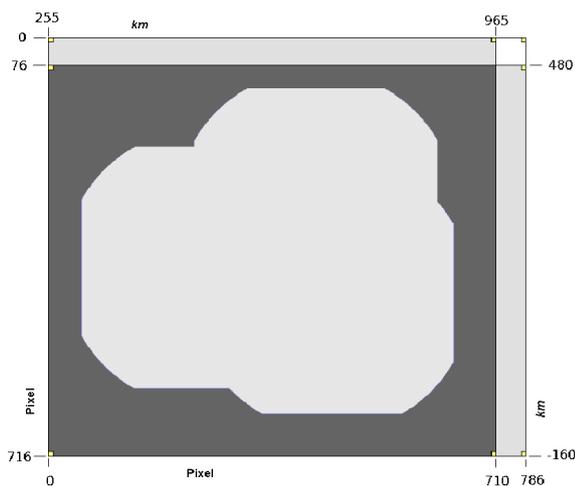


Abb. 3.2.: Horizontale Auflösung und Vertikalaufnahme im PPI-Format [SF-Meteo-Systemguide, 2011, S.3]

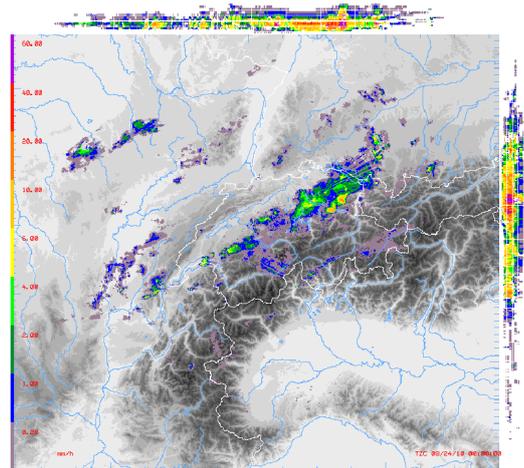


Abb. 3.3.: Fertiges Radarbild mit den zugeordneten Pixeln (hier farbig) [SF-Meteo-Systemguide, 2011, S.4]

Auf Basis der vom Radar detektierten Niederschlagsreflektivitäten der Gewitterzellen lassen sich verschiedene Größen ableiten, welche im weiteren Verlauf als Prediktoren in einer CellMOS-Vorhersagegleichung genutzt werden können. Im Folgenden sei ein Überblick der Radarprediktoren gegeben, von denen sich bei METEO SERVICE nach aktuellem Stand der Forschung ein Mehrwert für die Hagelvorhersage erhofft wird.

Tabelle 3.2.: Ausgabeformat der in dieser Arbeit verwendeten Radardaten. Für eine vollständige Ausführung der Radarprädiktoren, sei auf die Tabelle A.2 bzw. die Legende A.5 verwiesen.

ln(MESH(0:00))	MaxRefl(0:00)	ECHOTOP 15	ECHOTOP 45
2.17	56	12.7	12.0
2.14	56	12.6	10.3
1.97	56	12.7	12.1
...	...	...	...

### Qualität & Verfügbarkeit

Alle Radarprodukte decken als Komposit-Produkt die Schweiz und die an sie angrenzenden Regionen ab. Die zeitliche Auflösung der Radardaten beträgt 5 Minuten und die räumliche Auflösung 1 km x 1 km je Pixel. Ihre Qualität ist dank der höheren Dichte an Radarbeobachtungsstandorten innerhalb der Schweiz besser als in den grenznahen Regionen. Je größer die Entfernung vom Radarstandort ist, desto weniger zuverlässig sind die Radarprodukte. Dies zeigt sich insbesondere in den Seitenaufzissen (Abb. 3.3), wo auf Grund der Abstrahlwinkel die untersten Kilometer im Seitenaufziss nicht mehr zur Verfügung stehen.

## 3.2. Blitzdaten

Für das CellMOS stehen außerdem Blitzdaten in sekundlicher Auflösung zur Verfügung. Die Blitzdaten liegen seit März 2008 in der Datenbank von METEO SERVICE und wurden für das Trackingprogramm des Systems spezifisch aufbereitet (Abschnitt 2.5).

Tabelle 3.3.: Ausgabeformat der in dieser Arbeit verwendeten Blitzdaten. Für eine vollständige Ausführung der Blitzprädiktoren sei auf die Tabelle A.3 bzw. die Legende A.5 verwiesen.

Lightning Ln	LJ Sigma	LJ Threshold
123.55	1	1
123.25	1	1
123.21	1	1
...	...	...

Die Blitzdaten stammen vom LINET-Blitzortungssystem der Firma "Nowcast", welche moderne Sensoren für die weltweite Blitzortung herstellt (Nowcast [Stand: 01.12.2023]). Das System kann Erd- und Wolkenblitze mittels TOA-Verfahren bis auf eine mittlere Genauigkeit von 150 m lokalisieren und Angaben zur Intensität der Blizentladungen machen. Damit liefert das Blitzortungssystem ein flächendeckendes Netzwerk mit räumlich und zeitlich hoher Genauigkeit für die Schweiz.

### 3.3. Modelldaten

Als weiterer Input werden die Modelldaten vom IFS (Integrated Forecasting System) des ECMWF (European Centre for Medium-Range Weather Forecasts) genutzt. Für die Schweiz stehen diese flächendeckend in  $0.4^\circ \times 0.4^\circ$  horizontaler Auflösung und einer vertikalen Staffelung von 1.000 hPa, 925 hPa, 850 hPa, 700 hPa, 500 hPa und 300 hPa zur Verfügung.

Tabelle 3.4.: Ausgabeformat der in dieser Arbeit verwendeten Modelldaten. Für eine vollständige Ausführung der Modellprädiktoren sei auf die Tabelle A.4 bzw. die Legende A.5 verwiesen.

ModelHgt0TT	RH Prd	DLS	SRH
4037	28.5	13.5	118.1
4028	19.0	14.8	7.3
4425	10.8	24.4	230.1
...	...	...	...

Die Modelldaten liefern dem CellMOS alle relevanten Zelleigenschaften, welche nicht aus den Radar- und Blitzdaten abgeleitet werden können. Auf Basis eines Wettermodells lassen sich verschiedene Parametrisierungen definieren, welche sich bei der Vorhersage von Gewittern als hilfreich erwiesen haben. Primär zielen die Parametrisierungen auf kinematische oder thermodynamische Aspekte der Konvektionsdynamik ab. Beispielsweise kann der Modellwind auf dem Niveau von 700 hPa als eine vereinfachte Annahme für die Verlagerungsrichtung einer Gewitterzelle herangezogen werden, bevor durch das Tracking-Verfahren die Verlagerungsrichtung der Zelle berechnet werden kann. Besonders nach der ersten Dedektion einer Gewitterzelle bieten die aktuellen Modelldaten eine prognostische Unterstützung, da zu diesem Zeitpunkt noch keine Persistenzprädiktoren aus den Beobachtungsdaten berechnet werden können.

### 3.4. Trackingdaten

Aus den bereits vorgestellten Radar-, Blitz- und Modelldaten (Abschnitt 3.1, 3.2, 3.3) ergeben sich die Trackingdaten der einzelnen Gewitterzellen. Die Trackingdaten sind sozusagen die finale Datenausgabe des Tracking-Verfahrens von CellMOS. Mit der Dedektion einer Gewitterzelle wird zunächst ein MOS-Objekt erzeugt. Im nächsten Schritt werden dem MOS-Objekt bestimmte Eigenschaften aus den Radar-, Blitz- und Modelldaten hinzugefügt. Dann beginnt das Trackingverfahren, wobei dem MOS-Objekt weitere Attribute hinzugefügt werden, welche die zeitliche Entwicklung der Zelle berücksichtigen (siehe Abschnitt 2.3.3). Zum Schluss werden alle relevanten Zelleigenschaften in einer Datentabelle zusammengefasst.

Tabelle 3.5.: Ausgabeformat des Trackingprogramms von CellMOS. Gegeben sei die Zell-ID, der Zeitstempel, die Position und die Lebensdauer einer Gewitterzelle. Des Weiteren sei exemplarisch ein Radar-, Blitz- und Modellprädiktor, sowie die Zielgröße MESH gegeben. Für eine vollständigen Übersicht der Prediktoren des Trackingprogramms sei auf die Tabellen 3.2, 3.3, 3.4 sowie die Legende A.5 im Anhang der Arbeit verwiesen.

ID	date	Lat	Lon	lifetime	dBz FZL	Lighting	DLS	MESH
12747	2017-07-09	48.38	10.23	40	62.5	3272	13.5	8.8
12747	2017-07-09	48.37	10.20	35	62.5	3240	14.8	8.5
19406	2017-08-01	47.40	9.16	45	58.5	3236	24.4	7.2
...	...	...	...	...	...	...	...	...

## 4. Methodik

In diesem Kapitel wird die in dieser Bachelorarbeit verwendete Methodik vorgestellt. Dabei wird sich am modelltheoretischen Ansatz für die Entwicklung linearer Modelle orientiert Rust [Stand: 01.11.2023]. Die folgende Abbildung gibt einen schematischen Überblick über die angewandten Methoden der Modellentwicklung.



Abb. 4.1.: Schematische Darstellung der fünf Schritte der Modellentwicklung von der Transformation des Prädiktanden, über die Modellanpassung- und auswahl bis hin zur Validierung und Verifikation der Modellergebnisse. Dunkelblauer Kasten: Allgemeiner modelltheoretischer Entwicklungsschritt. Weißer Kasten: Angewandte Methodik in dieser Arbeit.

### 4.1. Transformation des Prädiktanden

Für die statistische Modellierung der nicht-probabilistischen Hagelgröße (MESH) im Cell-MOS benötigt der Prädiktand zunächst ein statistisches Preprocessing. Dabei muss die abhängige Modellvariable zunächst so transformiert werden, dass mit den aus der Theorie abgeleiteten Unsicherheiten (Residuen) des Modells statistisch sinnvoll weitergearbeitet werden kann. Der Grund dafür ist, dass sich der Fehlerterm eines linearen Modells in der Regel nicht deterministisch modellieren lässt. Mithilfe der natürlichen Logarithmustransformation lässt sich eine näherungsweise  $\gamma$ -verteilte Größe in eine gaußverteilte Größe überführen, was die Annahme normalverteilter, homoskedastischer Residuen erlaubt. Nach der asymptotischen Theorie können die Koeffizienten eines linearen Modells (Abschnitt 4.2) somit auf Signifikanz getestet und die Modelle untereinander verglichen werden.

Eine aufgrund der natürlichen Verteilung der Hagelgröße des Datensatzes ( $\sim \gamma$ -Verteilung) passende Transformation der Zielvariable lautet:

$$\hat{y} \xrightarrow{\text{Transformation}} \ln(\hat{y}) \quad (4.1)$$

Die Transformation einer Zielgröße mit bereits gaußverteilten Residuen wäre für die statistische Modellierung mithilfe eines linearen Regressionsmodells nicht mehr notwendig Rust [Stand: 01.11.2023].

### 4.1.1. Verteilung der Hagelgröße

Im Folgenden sei links die Verteilung des MESH (Abb. 4.2) und rechts die Logarithmus-Transformation des MESH (Abb. 4.3) dargestellt. Dabei lässt sich mit der roten Linie in der Abb. 4.3 eine Aussage hinsichtlich einer Normalverteilung der transformierten Hagelgröße treffen.

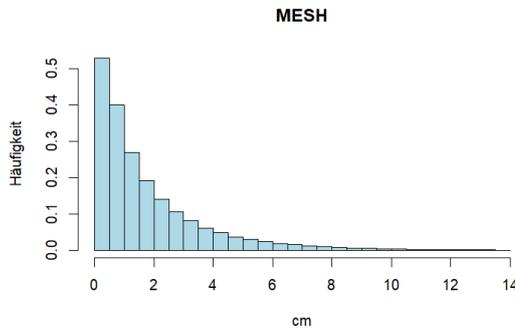


Abb. 4.2.: Verteilung des Prädiktanden

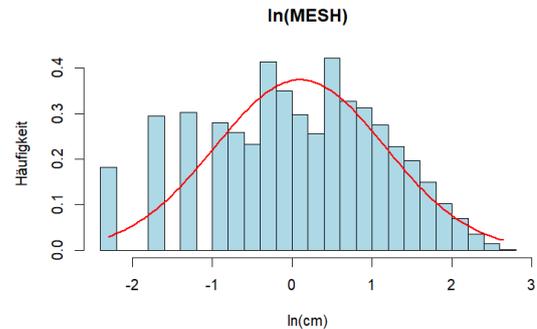


Abb. 4.3.: Transformation des Prädiktanden

## 4.2. Statistische Modellierung

Im folgenden Abschnitt werden die Methoden der statistischen Modellierung vorgestellt. Dabei wird sich zunächst eingehender mit der linearen Theorie des Vorhersagemodells auseinandergesetzt. Anschließend wird auf die angewandte Methodik zur Modellauswahl und die Leistungsbewertung des Modells eingegangen. Zum Schluss werden das Validierungsverfahren und die in der Arbeit verwendeten Verifikationsmaße erläutert. Das Ziel ist es, die Vorhersage der Hagelgröße (MESH) einmal unter der Verwendung von Lightning-Jumps und einmal ohne die Verwendung von Lightning-Jumps durchzuführen und die Vorhersageergebnisse zu quantifizieren. Auf diese Weise kann der Nutzen von Blitzprädiktoren für die statistische Hagelvorhersage genauer beurteilt werden.

### 4.2.1. Lineares Regressionsmodell

Zur Untersuchung der Zielstellung dieser Arbeit, wird ein lineares Regressionsmodell Wilks [2011], Wood [2017], McCullagh [1989] verwendet. Dieses mathematische Modell basiert auf der Annahme, dass die Beziehung zwischen einer abhängiger Variablen (Prädiktand) und einer oder mehrerer unabhängigen Variablen (Prädiktor/en) linear ist. Es wird verwendet, um Vorhersagen über den Wert des Modellprediktanden auf der Grundlage der Werte verschiedener Modellprediktoren zu treffen. Das Verfahren hat sich für Vorhersagen im Nowcasting als hilfreich erwiesen und stellt die mathematische Grundlage einer Prognosegleichung des CellMOS-Systems von METEO SERVICE dar (Abschnitt 2.3).

## Einfachregression

In der einfachsten Form besteht die lineare Regression aus einer einzigen unabhängigen Variable, welche mit der abhängigen Variable in Beziehung gesetzt wird. Beide Variablen werden als Beobachtungspaare  $(y_i, x_i)$  aufgefasst. Daraus wird ein Modell entwickelt, welches den linearen Zusammenhang zwischen den beiden Variablen am besten widerspiegeln kann. Die lineare Abhängigkeit wird durch die folgende Funktion beschrieben:

$$\hat{y}_i = \beta_0 + \beta_1 x_i \quad (4.2)$$

wobei  $\hat{y}_i$  den Prädiktanden darstellt,  $x_i$  der Prädiktor ist und  $\beta_1$  die Steigung der Regressionsgeraden beschreibt. Die Konstante  $\beta_0$  beschreibt den Schnittpunkt mit der Y-Achse.

Die Konstanten  $\beta_0$  und  $\beta_1$ , werden auch als Modellparameter bezeichnet, welche es mittels der Regressionsgeraden  $\hat{y}_i(x_i)$  zu schätzen gilt. Durch das Anpassen von  $\beta_0$  und  $\beta_1$  wird dabei versucht, die bestmögliche Übereinstimmung zwischen der tatsächlichen Verteilung der Daten und der Regressionsgeraden zu erzielen (siehe Abb. 4.4).

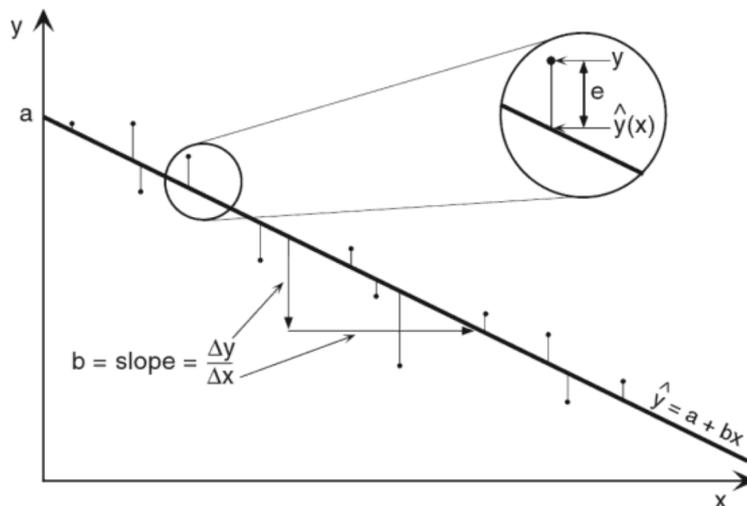


Abb. 4.4.: Schematische Skizze einer einfachen linearen Regression. Die Ausgleichsgerade  $\hat{y} = a + bx$  beschreibt den bestmöglichen Zusammenhang zwischen Prädiktor  $x$  und Prädiktand  $\hat{y}$ . Dies gelingt mithilfe der Minimierung der Quadratsumme der Residuen  $e$ . (Methode der kleinsten Quadrate, auch LS-Schätzer genannt.) [aus Wilks, 2011, S.216]

In der Abbildung 4.4 ist der Fehler zwischen den Beobachtungen  $y_i$  und der Regressionsgeraden  $\hat{y}_i$  zu erkennen, welcher als Residuum  $e_i$  bezeichnet wird. Er ist definiert als der Abstand zwischen den Beobachtungen und der Ausgleichsgeraden:

$$e_i = y_i - \hat{y}_i(x_i) \quad (4.3)$$

Um die passende Steigung der Regressionsgeraden zu finden, wird die Methode der kleinsten Quadrate ("Least Squares") verwendet. Das bedeutet, dass die Summe der quadrierten Abweichungen zwischen den Beobachtungswerten und der Regressionsgeraden minimiert wird (LS-Optimierung, siehe Abb. 4.4).

$$\sum_{i=1}^n (e_i)^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - [\beta_0 + \beta_1 x_i])^2 \quad (4.4)$$

Allgemein gilt, dass die Beobachtung  $y_i$  die Summe aus dem Regressand  $\hat{y}_i$  und dem Residuum  $e_i$  ist. Dieser Zusammenhang ergibt sich aus den Gleichungen 4.2 und 4.3.

$$y_i = \hat{y}_i + e_i = \beta_0 + \beta_1 x_i + e_i \quad (4.5)$$

Mit der Annahme, dass die Residuen normalverteilte Zufallsvariablen, mit dem Erwartungswert  $E[e_i] = 0$  und konstanter Varianz  $\sigma^2$  sind folgt, dass auch die Beobachtungen  $y_i$  als Realisierungen der Zufallsvariablen  $Y_i$  aufgefasst werden können.

$$Y_i = \mu_i + e_i \quad \text{mit } E[\hat{y}_i] = \mu_i = \beta x_i \quad (4.6)$$

Dabei bezeichnet  $E[\hat{y}_i]$  den Erwartungswert der Zufallsvariablen  $Y_i$ . Die „normalverteilte“ Eigenschaft der Residuen überträgt sich in der Folge auch auf die Zufallsvariable  $Y_i$ . Letztendlich erhält man einen normalverteilten Schätzer mit konstanter Varianz  $\sigma^2$  und variablem Erwartungswert  $E[\hat{y}_i] = \mu_i$ .

$$Y_i \sim N(\mu_i, \sigma^2) \quad (4.7)$$

### Mehrfachregression

Die multiple lineare Regression, auch Mehrfachregression genannt, ist die Erweiterung der Einfachregression. Dabei werden für die Vorhersage der Regressionsgeraden  $\hat{y}$  anstelle eines Prädiktors  $x$ , mehrere Prädiktoren  $x_1, \dots, x_n$  verwendet. So kann ein lineares Regressionsmodell additiv mit beliebig vielen Regressionsvariablen erweitert werden.

Die Formel für die multiple lineare Regression lautet:

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (4.8)$$

wobei  $x_1, x_2, \dots, x_n$  die unabhängigen Variablen sind und  $\beta_0, \beta_1, \beta_2, \dots, \beta_n$  die gesuchten Modellparameter beschreiben.

Unter der Annahme, dass die Beobachtungen  $y_i$  wieder als Realisierungen einer Zufallsvariable  $Y_i$  aufgefasst werden, deren Erwartungswert  $E[\hat{y}_i] = \mu_i$  modelliert werden soll, kann die deterministische Beziehung zwischen dem Erwartungswert des Prädiktanden und den Prädiktoren wie folgt beschrieben werden:

$$\mu_i = \mathbf{X}_i \boldsymbol{\beta} \quad (4.9)$$

Hierbei werden alle Modellparameter  $\beta_j$  in einen Parametervektor  $\boldsymbol{\beta}$  und die Komponenten des Prädiktors  $x_{i,j}$  in einer sogenannten Modellmatrix  $\mathbf{X}$  zusammengefasst [siehe Rust, Stand: 01.11.2023, Abb. 7.28, S. 143].

Mit dieser Art eines linearen Modells ist es möglich, komplexere Zusammenhänge in großen Datensätzen zu modellieren. Durch die Analyse der Modellparameter  $\widehat{\beta}_n$ , also den zu schätzenden Koeffizienten des Modells, kann abgeleitet werden, wie sich eine Änderung in einer unabhängigen Variable auf die abhängige Variable auswirkt Wilks [2011]. Als statistisches Hilfsmittel können dabei Hypothesentests verwendet werden, um den Zusammenhang zwischen den Variablen auf Signifikanz beurteilen (Konfidenzintervalle). Wichtig ist dabei die Annahme normalverteilter, homoskedastischer Residuen. Außerdem ist es mit einer Mehrfachregression möglich, gezielt den Einfluss unabhängiger Variablen auf die abhängige Variable zu kontrollieren. Diese Eigenschaft macht multiple lineare Modelle besonders dann attraktiv, wenn man den Einfluss bestimmter Prädiktoren isoliert betrachten möchte. Im Kontext dieser Arbeit eignet sich die Mehrfachregression demnach gut, um den Erklärungsbeitrag der Lightning-Jump-Prädiktoren genauer zu untersuchen (siehe Motivation 1, S. 8).

#### 4.2.2. Bestimmtheitsmaß

Das Bestimmtheitsmaß (RV bzw.  $R^2$ ) misst den vom Modell beschriebenen Anteil der Varianz. Es gibt also Auskunft darüber, wie gut die abhängige Variable mit den gegebenen unabhängigen Variablen vorhersagt werden kann. Dafür vergleicht es die Regressionsvarianz (SSR) mit der totalen Varianz (SST) des Modells. Eine Reduktion der Residuenvarianz (SSE) führt demnach zum Anstieg der Anpassungsgüte (Gl. 4.10). Allgemein kann das Bestimmtheitsmaß einen Wert zwischen 0 und 1 annehmen. In dieser Arbeit wird es als ein prozentuales Maß genutzt.

$$RV = R^2 = \left( \frac{SSR}{SST} \right) \cdot 100 \% = \left( 1 - \frac{SSE}{SST} \right) \cdot 100 \% \quad (4.10)$$

Bei einem RV-Wert von 0 % liefert das Modell keinen Erklärungsbeitrag. Nimmt der RV-Wert 100 % an, beschreibt das Modell die gegebene Verteilung der Daten perfekt. Folglich kann beurteilt werden, welches der Modelle die Variabilität in den Beobachtungsdaten am besten beschreibt.

### 4.3. Modellauswahl

„So einfach wie möglich, so komplex wie nötig.“

Albert Einstein, in mehreren Varianten

Für Modelle mit einer höheren Anzahl an Parametern  $(\beta_0, \beta_1, \dots, \beta_n)$ , folgt insgesamt auch immer eine größere Likelihood, da mit der Hinzunahme eines Terms im Prädiktor, auch immer mehr Variabilität beschrieben werden kann. Jedoch kann eine höhere Anzahl an Parameter auch zu einer Überanpassung des Modells führen (“Overfitting”). Demnach passen sich Modelle mit mehr Parametern nicht nur stärker an die Beobachtungsdaten an, sondern bergen auch die Gefahr, den Störanteil der Beobachtung stärker widerzuspiegeln Wood [2017]. Um dieser Überanpassung entgegen zu wirken, wird die mehrfaktorielle Varianzanalyse, in der Fachliteratur auch als “Analysis of Varianz” (ANOVA) bezeichnet, angewendet. Sie ist eine systematische Strategie, um den Einfluss der Hinzunahme einzelner Terme im Prädiktor quantitativ zu bewerten. Das dabei beschriebene Vorgehen bedeutet, solange je einen Term mehr im Prädiktor hinzuzunehmen, bis sich die Regression nicht mehr signifikant verbessert. Das Verfahren wird umgangssprachlich auch als schrittweise Regression (“stepwise regression”) oder Vorwärtsregression (“forward regression”) bezeichnet und soll die Anzahl der Parameter auf die wesentlichen Prädiktoren beschränken, die einen Erklärungsbeitrag für die Regression liefern.

In der Theorie ist die mehrfaktorielle Varianzanalyse eine Erweiterung der Idee, die Regressionsvarianz (SSR) mit der Residuenvarianz (SSE) des Modells zu vergleichen. Hierfür wird der F-Test verwendet, welcher im Allgemeinen die Varianzen zweier Verteilungen von Zufallsvariablen auf Gleichheit prüft (Gl. 4.11). Das Verfahren wird umgangssprachlich auch als „systematisches F-Testen“ bezeichnet.

Für die erste Komponente einer multiplen Regressionsgleichung ( $\hat{y} = \beta_0 + \beta_1 x_1 + \dots$ ) wird dabei nach der allgemein bekannten Teststatistik des F-Tests verfahren.

$$F = \frac{SSR/p}{SSE/(N - 1 - p)} \quad (4.11)$$

Gegeben sei die Regressionsvarianz (SSR), die Residuenvarianz (SSE), sowie die Anzahl der Datenpunkte (N) und die Anzahl der Parameter (p+1).

Für alle hinzugenommenen Terme im Prädiktor wird daraufhin der Zugewinn an Regressionsvarianz ( $SSR - SSR_{\beta_0}$ ) mit der Residuenvarianz des Modells (SSE) verglichen.

$$F = \frac{(SSR - SSR_{\beta_0})/p}{SSE/(N - 1 - p)} \quad (4.12)$$

Für die Interpretation des Ergebnisses wird ein Hypothesentest verwendet. Dafür wird eine Null-Hypothese  $H_0$  (Gleichheit der Varianzen), d.h. Teststatistik  $F = 1$  und eine Alternativ-Hypothese  $H_A$  (Ungleichheit der Varianzen), d.h. Teststatistik  $F > 1$  aufgestellt. Anschließend wird der ermittelte F-Wert der Teststatistik ( $F_{obs}$ ) mit der bereits

bekanntem F-Verteilung unter  $H_0$  verglichen (Gl. 4.13). Mithilfe des zuvor subjektiv festgelegten Niveaus des Test  $\alpha = 0,05$ , kann beurteilt werden, ob der F-Wert statistisch signifikant ist oder nicht, d.h. ob die Nullhypothese  $H_0$  korrekt abgelehnt werden kann oder nicht. Der Wert für die Entscheidungsfindung heißt p-Wert. Er berechnet sich wie folgt:

$$p = 1 - F(F_{obs}) \quad (4.13)$$

Ein p-Wert  $< 0,05$  bedeutet, dass der Prädiktorterm für die Regression statistisch signifikant ist, bei einem p-Wert  $> 0,05$  ist er das nicht (siehe Signifikanzniveaus A.2.2).

Um die Ergebnisse der Varianzanalyse übersichtlich darstellen, werden in dieser Arbeit nur die p-Werte der Blitzprädiktoren präsentiert. So kann beurteilt werden, ob die Blitzprädiktoren einen signifikanten Erklärungsbeitrag für das jeweilige Regressionsmodell liefern oder nicht (siehe Motivation 1, S. 8).

## 4.4. Kreuzvalidierung

Um beurteilen zu können, wie Leistungsstark das Modell ist, wird mit dem entwickelten Regressionsmodell der Lightning Jumps eine Kreuzvalidierung durchgeführt. Das Ziel der Kreuzvalidierung ist es, die Modellvorhersage einmal anhand unabhängiger Daten zu testen. Mithilfe von Verifikationsmaßen und Skill Scores (Abschnitt 4.5), wird anschließend eine objektive Leistungsbewertung des Modells durchgeführt.

Für eine zuverlässige Schätzung der Modelleistung wird der fünfjährige Datensatz der Trackingdaten (2017-2021) zunächst in Trainings- und Testdaten aufgeteilt. Dabei wird der Trackingdatensatz A.5, bestehend aus dem Trackingdaten der Gewitterzellen, zunächst in fünf gleichgroße Teile aufgeteilt. Neben den Trackingdaten des Testdatensatzes (Jahr: 2021) werden für das Validierungsverfahren jeweils die Trackingdaten des Trainingsdatensatzes (Jahr: 2017-2020) herangezogen (Tabelle 4.1).

Die aus dem Trainingsdatensatz erhaltenen Modellparameter der Modelle können mit den Trackingdaten des Testdatensatzes nicht-probabilistische Hagelvorhersagen simulieren. Da für jede simulierte Hagelvorhersage auch eine Vorhersage der potentiellen Hagelgröße (MESH) auf Basis der Trainingsdaten (Klimatologie) vorhanden ist, können die Vorhersagen anschließend verifiziert werden.

Auf diesem Weg kann die Robustheit meines Modells gegenüber der Datenvariation beurteilt, sowie ein potentielles „Overfitting“ des Modells erkannt werden. Mithilfe des Testdatensatzes wird die Modellgenauigkeit berechnet und gezeigt, wie die Hagelvorhersage mit zukünftigen Daten generalisiert werden kann. Die Daten des Testdatensatzes haben also auf die Koeffizienten der Modelle keinen Einfluss und sind somit unabhängig.

Tabelle 4.1.: Aufteilung der Trackingdaten für die Kreuzvalidierung.  
Weiße Kästen: Trainingsdaten, Blauer Kasten: Testdaten (unabhängige Daten)

1	2	3	4	5
2017	2018	2019	2020	2021

## 4.5. Verifikation

Nach Wilks [2011] gibt es für nicht-probabilistische Vorhersagen mit kontinuierlichen Prädiktanden im Wesentlichen zwei Verifikationsmaße, welche für eine Vorhersageverifikation herangezogen werden können. Dabei handelt es sich um den Mean absolute Error (Abschnitt 4.5.1), und den Mean Squared Error (Abschnitt 4.5.2). Diese skalaren Maße für die Akkuratess sind Funktionen, welche die mittlere Übereinstimmung zwischen der Vorhersage und der korrespondierenden Beobachtung messen. Darüber hinaus werden in dieser Arbeit noch der Root Mean Squared Error (Abschnitt 4.5.3) und der Bias (Abschnitt 4.5.4) verwendet. Die Metriken werden im Folgenden genauer vorgestellt.

### 4.5.1. Mean absolute Error

Der mittlere absolute Fehler, kurz MAE, ist definiert als der Durchschnitt der absoluten Differenz zwischen der Vorhersage und der Beobachtung.

$$MAE = \frac{1}{n} \sum_{k=1}^n |f_k - o_k| \quad (4.14)$$

Er gibt an, wie groß der Fehler ist, den wir im Durchschnitt von der Vorhersage erwarten können. Die Einheit des MAE ist in den ursprünglichen Einheiten der prognostizierten Werte angegeben. Ein MAE von 0 bedeutet, dass die Vorhersage keinen Fehler aufweist.

### 4.5.2. Mean Squared Error

Der mittlere quadratische Fehler, kurz MSE, ist definiert als der erwartete quadratische Abstand zum Erwartungswert der Vorhersage. Er wird auch als die Metrik bezeichnet, welche die Qualität des Prognosemodells bewertet. Der MSE beinhaltet sowohl die Varianz (die Streuung der vorhergesagten Werte zueinander) als auch die Verzerrung (der Abstand des vorhergesagten Wertes von seinem wahren Wert).

$$MSE = \frac{1}{n} \sum_{k=1}^n (f_k - o_k)^2 \quad (4.15)$$

Der MSE ist fast immer positiv. Aufgrund des quadratischen Terms (siehe Gl. 4.15), bestraft diese Metrik große Fehler oder Ausreißer mehr als kleine Fehler. Fehlerwerte näher an Null sind deshalb als „besser“ zu interpretieren. Ein Nachteil dieser Metrik ist, dass sie Probleme übersehen kann, wenn es sich um geringe Datenmengen handelt.

### 4.5.3. Root Mean Squared Error

Der Root Mean Squared Error, kurz RMSE ergibt sich, wie der Name schon sagt, aus der Quadratwurzel des mittleren quadratischen Fehlers.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (f_k - o_k)^2} \quad (4.16)$$

Auch diese Metrik ist immer positiv. Kleinere Werte sind besser, da der RMSE genauso wie der MSE, größere Fehler stärker bestraft. Ein Vorteil dieser Berechnung ist, dass der RMSE-Wert in der gleichen Einheit wie der prognostizierte Erwartungswert angegeben wird. Dadurch ist er im Vergleich zum MSE leichter zu verstehen. Des Weiteren kann der RMSE mit dem MAE verglichen werden, um festzustellen, ob eine Vorhersage große, aber seltene Fehler enthält. Je größer die Differenz zwischen RMSE und MAE ist, desto inkonsistenter ist der Vorhersagefehler. Jedoch kann auch diese Metrik Probleme überdecken, die mit geringem Datenvolumen zu tun haben.

#### 4.5.4. Bias

Der Bias, oder auch systematischer Fehler genannt, misst die Übereinstimmung zwischen mittlerer Vorhersage und mittlerer Beobachtung.

$$BIAS = \frac{1}{n} \left( \sum_{k=1}^n f_k - \sum_{k=1}^n o_k \right) = \bar{f} - \bar{o} \quad (4.17)$$

Eine mittlere Abweichung der Vorhersage vom wahren Wert wird auch als Verzerrung bezeichnet. Dabei kann das Modell den Wert des nicht-probabilistischen Prädiktanden mit kontinuierlicher Ausprägung im Mittel zu hoch oder zu niedrig vorhersagen. Die Einheit des systematischen Fehlers entspricht der Einheit der Vorhersage.

#### 4.5.5. Skill Score

Der Skill einer Vorhersage ist ein Maß für die relative Genauigkeit der Vorhersage in Bezug auf eine Referenzvorhersage. Typische Referenzvorhersagen sind beispielsweise die Klimatologie, die Persistenz oder die Zufallsvorhersage. In der Meteorologie werden Skill Scores häufig verwendet, um die Leistung bzw. Qualität einer Vorhersage zu bewerten.

Allgemein geben Skill Scores den Gewinn bzw. Verlust einer Vorhersage gegenüber der Referenzvorhersage in Prozent an. Dabei bezieht man sich i. d. R. auf ein Akkuratessesmaß der Vorhersage ( $A$ ) gegenüber dem Akkuratessesmaß der Referenzvorhersage ( $A_{ref}$ ).

$$SS_{ref} = \frac{A - A_{ref}}{A_{pref} - A_{ref}} \cdot 100 \% \quad \text{mit } A_{ref} = \text{Referenz} \quad (4.18)$$

Für kontinuierliche Vorhersagen wird als Akkuratessesmaß  $A$  typischerweise der MAE bzw. MSE/RMSE verwendet. Aber auch der Bias, als skalares Maß für die Verzerrung, kann für die Berechnung des Skills herangezogen werden.

Für den Fall, dass gilt  $A_{perf} = 0$  (z.B. A ist MSE) reduziert sich die Gl. 4.18 zu:

$$SS_{ref} = 1 - \frac{A}{A_{ref}} \cdot 100 \% \quad \text{mit } A_{ref} = \text{Referenz} \quad (4.19)$$

„An diesem Ausdruck lässt sich erkennen, warum der  $SS_{ref}$  auch als Varianzreduktionsmaß betrachtet wird. Im Zähler des letzten Terms steht der Vorhersagefehler (Residuanvarianz) und im Nenner die Varianz der Beobachtungen“Rust [Stand: 01.11.2023].

Für die Interpretation des Skil scores gilt:

- Super:  $A = A_{perf}$ ,  $SS_{ref} = 100\%$
- Besser:  $A < A_{ref}$ ,  $SS_{ref} > 0\%$  (positiv orientiert)
- Unnützlich:  $A = A_{ref}$ ,  $SS_{ref} = 0\%$
- Schlechter:  $A > A_{ref}$ ,  $SS_{ref} < 0\%$  (negativ orientiert)

## 5. Ergebnisse

### 5.1. Modelle zur Hagelvorhersage

Zur statistischen Untersuchung der Vorhersageleistung der Lightning Jumps wurden die in Abschnitt 2.5 definierten Blitzprädiktoren in eine von METEO SERVICE entwickelte CellMOS-Gleichung für die Hagelvorhersage integriert. Per Modellvergleich wird anschließend untersucht, inwieweit die Hinzunahme der Lightning Jumps zu einer Verbesserung der Regression beiträgt.

Mit der gegebenen Auswahl von CellMOS-Prädiktoren in Tabelle 5.1 wurden zunächst fünf verschiedene Modelle entwickelt.

Tabelle 5.1.: Zusammensetzung der CellMOS-Gleichungen 5.1-5.5. Siehe Legende A.6

Prädiktand	Modellprädiktoren	Radarprädiktoren	Blitzprädiktoren
ln(MESH)	ModellHgt0TT	ECHOTOP15	LJ Sigma
	SRH	ECHOTOP45	LJ Threshold
	RH Prd	ln(MESH(0:00))	Lightning Ln
	DLS	MaxRelff(0:00)	

Das **Modell 1** ist ein einfaches Persistenzmodell. Es setzt sich einzig und allein aus dem Prädiktanden (als die abhängige Modellvariable) und dem Persistenzprädiktor des Prädiktanden (als die unabhängige Modellvariable) zusammen.

$$\ln(\text{MESH}) \sim \ln(\text{MESH}(0:00)) \quad (5.1)$$

Mit diesem Modell soll zunächst untersucht werden, wie viel Residuenvarianz des Prädiktanden bereits durch den Persistenzprädiktor erklärt werden kann.

Das **Modell 2** ist die von METEO SERVICE entwickelte CellMOS-Gleichung für die Hagelvorhersage. Sie besteht aus einer Kombination verschiedener Modell- und Radarprädiktoren, einschließlich des Persistenzprädiktors.

$$\begin{aligned} \ln(\text{MESH}) \sim & \ln(\text{MESH}(0:00)) + \text{ModellHgt0TT} + \text{SRH} + \text{RH Prd} + \text{DLS} \\ & + \text{ECHOTOP15} + \text{ECHOTOP45} + \text{MaxRelff}(0:00) \end{aligned} \quad (5.2)$$

Das **Modell 3** ist die Erweiterung der CellMOS-Gleichung des Modells 2. In diesem Modell wurden die in Abschnitt 2.5 definierten Blitzprädiktoren in die bestehende Regressionsgleichung integriert (vgl. Gl. 5.2 & 5.3).

$$\begin{aligned} \ln(\text{MESH}) \sim & \ln(\text{MESH}(0:00)) + \text{ModellHgt0TT} + \text{SRH} + \text{RH Prd} + \text{DLS} \\ & + \text{ECHOTOP15} + \text{ECHOTOP45} + \text{MaxRelfl}(0:00) \\ & + \text{LJ Sigma} + \text{LJ Threshold} + \text{Lightning Ln} \end{aligned} \quad (5.3)$$

Dieses Modell stellt die neue CellMOS-Gleichung dar, mit der die operationelle Hagelvorhersage bei METEO SERVICE in Zukunft verbessert werden soll.

Nach einem Modellvergleich zwischen dem Modell 2 und dem Modell 3 wurden zwei weitere Modelle unter Vernachlässigung des Persistenzprädiktors entwickelt.

Das **Modell 4** entspricht der Modellgleichung 5.2, ohne Berücksichtigung der Persistenz.

$$\begin{aligned} \ln(\text{MESH}) \sim & \text{ModellHgt0TT} + \text{SRH} + \text{RH Prd} + \text{DLS} \\ & + \text{ECHOTOP15} + \text{ECHOTOP45} + \text{MaxRelfl}(0:00) \end{aligned} \quad (5.4)$$

Das **Modell 5** entspricht der Modellgleichung 5.3, ohne Berücksichtigung der Persistenz.

$$\begin{aligned} \ln(\text{MESH}) \sim & \text{ModellHgt0TT} + \text{SRH} + \text{RH Prd} + \text{DLS} \\ & + \text{ECHOTOP15} + \text{ECHOTOP45} + \text{MaxRelfl}(0:00) \\ & + \text{LJ Sigma} + \text{LJ Threshold} + \text{Lightning Ln} \end{aligned} \quad (5.5)$$

Das **Modell 4** und **Modell 5** kann demnach als das Äquivalent zum **Modell 2** und **Modell 3** betrachtet werden.

### 5.1.1. Varianzanalyse

Bei der Entwicklung der **Modelle 1 bis 5** wurde für das **Modell 3** (Gl. 5.2) und das **Modell 5** (Gl. 5.5) eine mehrfaktorielle Varianzanalyse durchgeführt (Abschnitt 4.2.1). Dabei wurden die Blitzprädiktoren per Hypothesentest (F-Test) auf ihre Signifikanz getestet und geschaut, ob diese einen ausreichend signifikanten Erklärungsbeitrag für das Modell liefern (testtheoretischer Ansatz: Interpretation des p-Werts).

Die Ergebnisse zeigen, dass die Lightning-Jumps in **Modell 3** (mit Persistenz) und in **Modell 5** (ohne Persistenz) fast durchweg einen ausreichend signifikanten Erklärungsbeitrag für die Regression liefern. Lediglich für den Vorhersagezeitraum von 15 min liefert die Blitzrate (Lightning Ln) im **Modell 3** keinen signifikanten Beitrag zur Varianzaufklärung in der Prognosegleichung. Für eine ausführliche Übersicht der Ergebnisse der Varianzanalyse sei auf die Tabellen A.7 - A.12 im Anhang der Arbeit verwiesen.

### 5.1.2. Vergleich der Regressionsmodelle

In diesem Abschnitt werden die entwickelten Regressionsmodelle 1-5 verglichen. Für den Modellvergleich wurde das Bestimmtheitsmaß (RV) für alle fünf CellMOS-Gleichungen über den Vorhersagezeitraum bis 30 min herangezogen (Abschnitt 4.2.2).

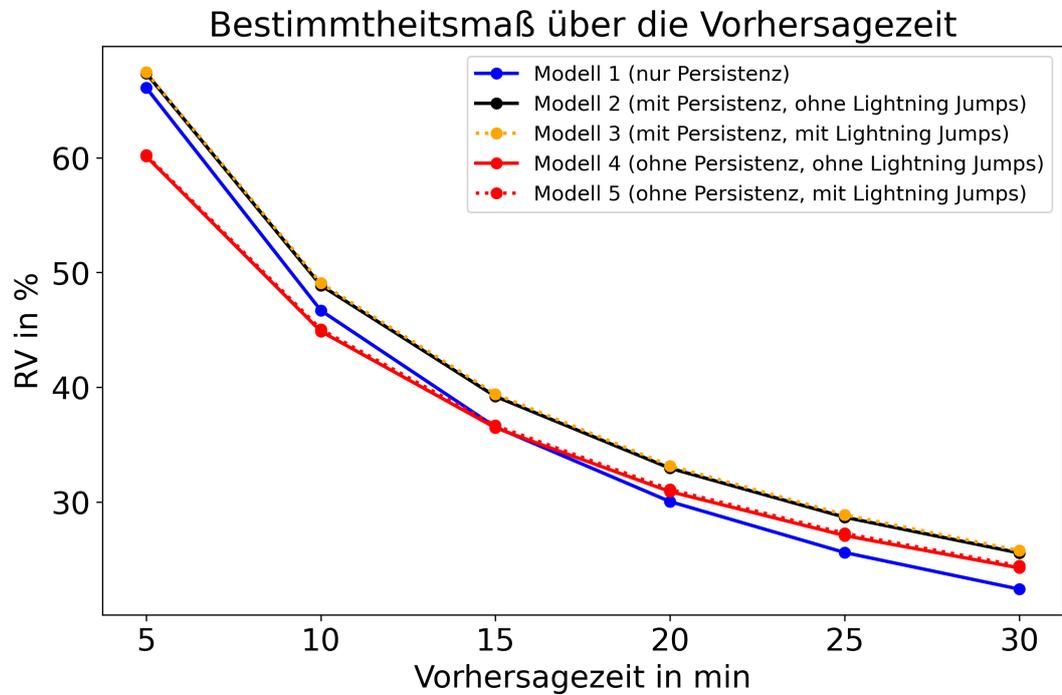


Abb. 5.1.: Modellvergleich. Die Abbildung zeigt das Bestimmtheitsmaß (RV) der Modelle 1-5 über den Vorhersagezeitraum bis 30 min. Dabei gibt die Y-Achse das prozentuale Bestimmtheitsmaß an, während die X-Achse den 5-minütigen Vorhersagezeitschritt der Modellvorhersage bis zu einer halben Stunde in die Zukunft angibt. Mit der Grafik lässt sich die Anpassungsgüte der verschiedenen Modelle beurteilen.

Das **Modell 1 (blau)**, als reines Persistenzmodell (Einfachregression), dient der Interpretation der Modellergebnisse. Es kann als die einfachste Prognosegleichung für das CellMOS zur Orientierung herangezogen werden. Demnach können Persistenzprädiktoren vor allem im Nowcasting bereits einen großen Anteil der Residuenvarianz des Modellprädiktanden beschreiben Hoffmann [2008].

Das **Modell 2 (schwarz)** beschreibt die CellMOS-Gleichung für die Hagelvorhersage, die es im Kontext dieser Arbeit zu verbessern gilt. Die Gleichung beinhaltet neben dem Persistenzprädiktor weitere Radar- und Modellprädiktoren (vgl. Gl. 5.2). Die Gleichung kann die Varianz der abhängigen Variable im Vergleich zur Persistenz (Modell 1) deutlich besser beschreiben. Dabei erzielen die unabhängigen Variablen des Modells besonders gegen Ende des Vorhersagezeitraums eine bessere Anpassungsgüte. (siehe Abb. 5.1).

Das **Modell 3 (gelb, gestrichelt)** ist die Erweiterung des Modells 2 (siehe Gl. 5.3). Dieses Modell liefert gegenüber Modell 2 nur eine verschwindend geringe Verbesserung der Modellgüte. Die Regression mit Blitzprädiktoren liefert somit keine Verbesserung der Varianzaufklärung, wie sie für die operationelle Vorhersage von Bedeutung wäre.

Das **Modelle 4 (rot)** und das **Modell 5 (rot, gestrichelt)** wurde entwickelt, um den Erklärungsbeitrag der Blitzprädiktoren im Regressionsmodell einmal ohne Verwendung der Persistenz beurteilen zu können. Auch ohne Persistenz liefern die Blitzprädiktoren, wie im Vergleich von Modell 2 und 3, nicht die erhoffte Verbesserung zur Varianzaufklärung. Die beiden Modelle werden deshalb in der Verifikation und Validierung vernachlässigt.

### 5.1.3. Korrelation der Prediktoren

Während der Modellentwicklung für die Hagelvorhersage (Tabelle 5.1), wurden neben der Korrelation der Lightning-Jumps auch die Korrelationen der übrigen CellMOS-Prediktoren zum Prediktanden  $\ln(\text{MESH})$  untersucht. Mithilfe des Korrelationskoeffizienten nach Bravais-Pearson kann der lineare Zusammenhang jedes einzelnen Prediktors zur Zielvariable untersucht werden. Dabei kann der Korrelationskoeffizient Werte zwischen eins (positive Korrelation) und minus eins (negative Korrelation) annehmen. Schaut man sich nur den Betrag des Korrelationskoeffizienten an, kann beurteilt werden, welches Potenzial die einzelnen Prediktoren für die Vorhersage von  $\ln(\text{MESH})$  besitzen (Tabelle 5.2).

Tabelle 5.2.: Korrelation der CellMOS-Prediktoren zum Prediktand  $\ln(\text{MESH})$  über den gesamten Zeitraum der Daten (2017-2021)

Platz im Ranking	Name des Prediktors	Korrelation: 5 min	Korrelation: 30 min
1	$\ln(\text{MESH}(0:00 \text{ min}))$	0.83	0.50
2	ECHOTOP45	0.76	0.48
3	ECHOTOP15	0.51	0.38
4	MaxRefl(0:00)	0.47	0.26
5	Lightning Ln	0.43	0.27
6	LJ Threshold	0.27	0.20
7	LJ Sigma	0.22	0.17
8	ModellHgt0TT	0.18	0.17
9	DLS	0.09	0.12
10	SRH	0.05	0.05
11	RH Prd	0.02	0.02

Für eine ausführliche Übersicht der Korrelationen der CellMOS-Prediktoren zum Prediktanden  $\ln(\text{MESH})$  sei auf die Abbildungen A.1-A.5 im Anhang der Arbeit verwiesen.

#### 5.1.4. Verifikation

In Abschnitt 5.1 wurden die Modelle für die nicht-probabilistische Hagelvorhersage vorgestellt. Nun sollen die Vorhersagen der Modelle 1-3 anhand der in Kapitel 4.4 beschriebenen Metriken verifiziert werden. Danach wird der Vorhersage-Skill des Modells 3 in Referenz zum Modell 1 und zum Modell 2, anhand der abgebildeten Metriken, beurteilt. Für die Validierung wurden unabhängige Daten verwendet (Abschnitt 4.5).

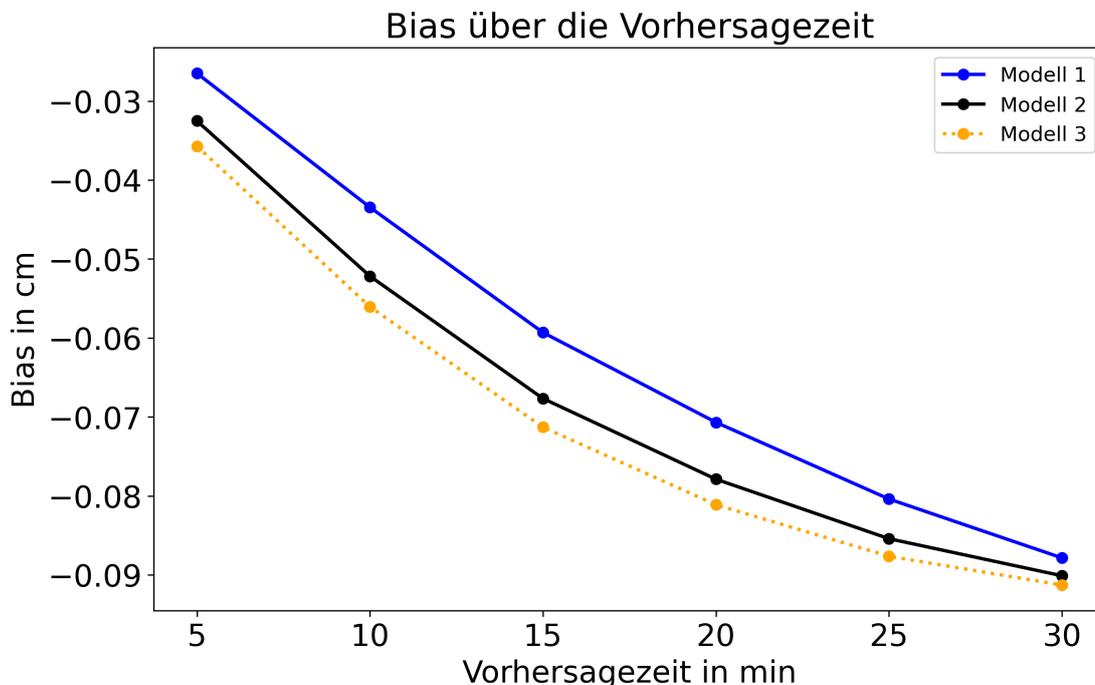


Abb. 5.2.: Bias der Modelle 1-3 über den Vorhersagezeitraum bis 30 min.

Als erstes wird der Bias der Modellvorhersagen untersucht. Er ist ein Maß dafür, wie sehr das Modell mit der geschätzten Hagelgröße ( $\ln(\text{MESH})$ ) im Durchschnitt danebenliegt, und kann als systematischer Fehler interpretiert werden. Ein Modell mit hohem Bias tendiert dazu, zu stark zu vereinfachen und somit wesentliche Zusammenhänge in den Daten nicht richtig zu erfassen.

Wie in Abbildung 5.2 ersichtlich, ist der Bias aller Modelle, also die Differenz zwischen dem erwarteten Modelloutput (Vorhersage) und dem wahren Wert (Beobachtung), negativ. Das heißt, dass alle Modelle die logarithmierte Hagelgröße ( $\ln(\text{MESH})$ ) im Durchschnitt rund 0.03 bis 0.09 cm zu klein vorhersagen. Der systematische Fehler aller Modelle nimmt über die Vorhersagezeitspanne zu. Dabei nimmt sein (negativer) Wert für die Modelle 2 und 3 (schwarz, gelb gestrichelt) bis zur Vorhersagezeitspanne von 15 min stärker zu als danach (siehe Steigung der Graphen). Für das Modelle 1 (blau) nimmt der Bias mehr kontinuierlich zu. Die Verzerrung der erwarteten Hagelgröße ist im Modell 3 am

größten. Für das Modell 1 (Persistenzmodell) ist die Abweichung am kleinsten.

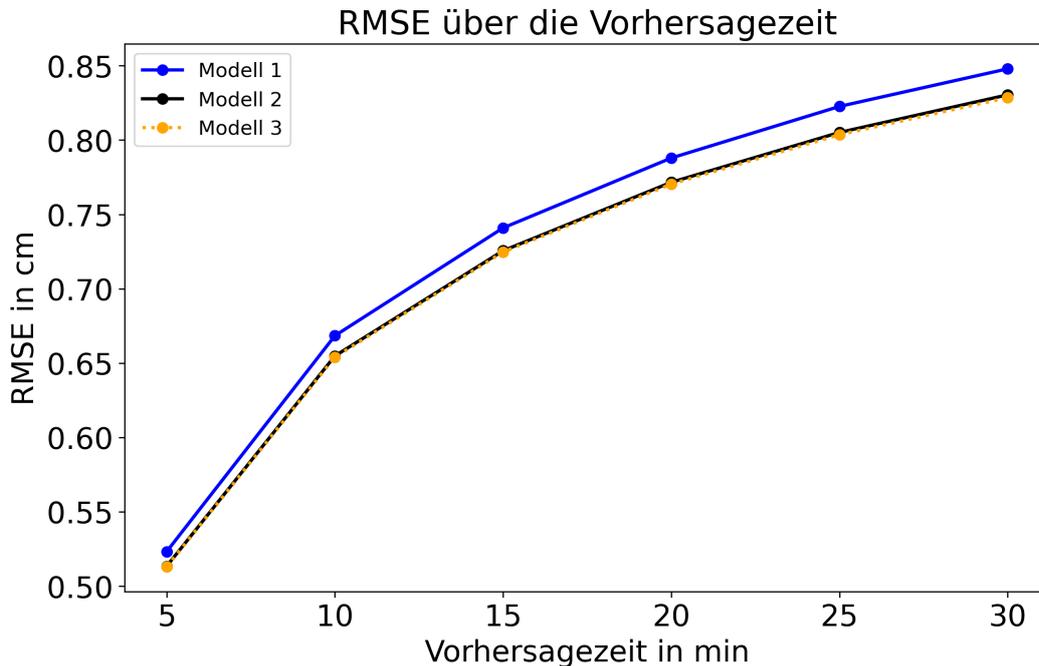


Abb. 5.3.: RMSE der Modelle 1-3 über den Vorhersagezeitraum bis 30 min.  
Hinweis: Die Graphen der Modelle 2 und 3 liegen fast übereinander (siehe Legende)

In der Abbildung 5.3 ist der Root Mean Squared Error (RMSE) der Modelle 1-3 über den gegebenen Vorhersagezeitraum abgebildet. Der RMSE hilft, die Performance der 3 Modelle zu bewerten. Er zeigt, wie nah die vorhergesagten Werte im Durchschnitt an den tatsächlichen Beobachtungen liegen. Ein niedriger RMSE weist darauf hin, dass das gewählte Modell gut zur Verteilung der Beobachtung passt, während ein hoher RMSE auf eine schlechte Passgenauigkeit des Modells hindeutet. Dabei bestat das Fehlermaß besonders große Abweichungen von der Beobachtung (Abschnitt 4.5.3).

Wie erwartet, nimmt die Performance der Modelle mit größerer Vorhersagezeitspanne ab. Während der RMSE aller 3 Modelle zum Vorhersagezeitschritt von 5 min am geringsten ist ( $\sim 0,52$  cm), ist er ab dem Vorhersagezeitschritt von 30 min am größten ( $\sim 0,83$  cm). Gut zu sehen ist, dass der RMSE durch die Hinzunahme weiterer Prädiktoren mit den Modellen 2 und 3 (schwarz, gelb gestrichelt), gegenüber dem Modell 1 (blau) insgesamt reduziert werden kann. Dabei nimmt die Fehlerdifferenz ( $\Delta$  RMSE) mit größerer Vorhersagezeitspanne zugunsten der Modelle 2 und 3 zu, bleibt aber im Mittel eher gering. Zwischen den Modellen 2 und 3 ist nach RMSE kein Performanceunterschied zu erkennen. Für die Beurteilung des "quadratischen Fehlers" (MSE), wurde bewusst der RMSE gewählt, da er aufgrund seiner Einheit einfacher zu interpretieren ist (vgl. Gl. 4.16).

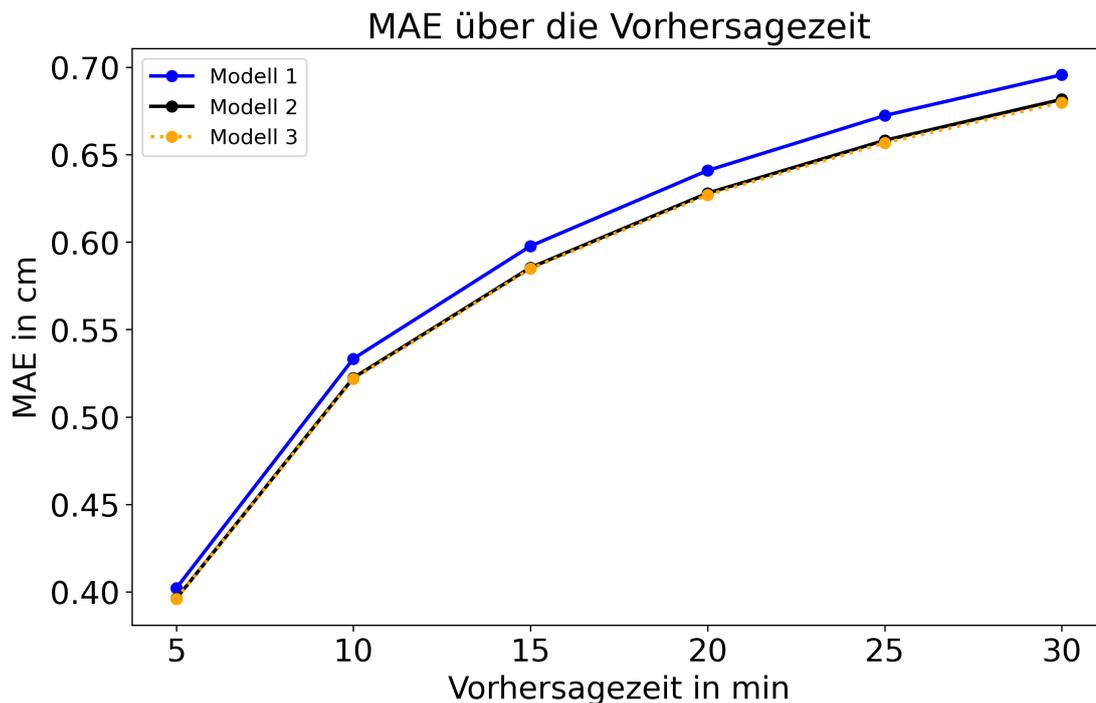


Abb. 5.4.: MAE der Modelle 1-3 über den Vorhersagezeitraum bis 30 min.  
Hinweis: Die Graphen der Modelle 2 und 3 liegen fast übereinander (siehe Legende)

Als weitere Metrik zur Beurteilung der Modellgenauigkeit ist in Abbildung 5.4 der Mean Absolute Error (MAE) der Modelle 1-3 über den Vorhersagezeitraum bis 30 min gegeben. Der MAE gibt die durchschnittliche absolute Abweichung der Vorhergesage von der Beobachtung an. Im Gegensatz zum MSE und RMSE, gewichtet der MAE alle Fehler gleich. Das macht ihn robuster gegenüber Ausreißern (siehe Gl. 4.14).

Der MAE weist beinahe einen identischen Verlauf wie der RMSE (Abb. 5.3) auf. Während auch der MAE aller 3 Modelle zum Vorhersagezeitschritt von 5 min am geringsten ist ( $\sim 0,40$  cm), ist er ab dem Vorhersagezeitschritt von 30 min am größten ( $\sim 0,68$  cm). Gut zu sehen ist, dass auch der MAE durch die Hinzunahme weiterer Prädiktoren mit den Modellen 2 und 3 (schwarz, gelb gestrichelt) gegenüber dem Modell 1 (blau) insgesamt reduziert werden kann. Dabei nimmt die Fehlerdifferenz ( $\Delta$  MAE) mit größerer Vorhersagezeitspanne zugunsten der Modelle 2 und 3 zu, bleibt aber im Mittel eher gering. Auch zwischen den Modellen 2 und 3 ist nach MAE kein Performanceunterschied zu erkennen.

Wie ersichtlich, sind die Fehlerwerte des MAE nicht ganz so groß wie die des RMSE (kein quadratischer Fehlerterm). Da der Verlauf des MAE stark dem RMSE ähnelt und die absoluten Fehlerdifferenzen zwischen MAE und RMSE nicht allzu groß sind, sind die Modelle 1-3 im Allgemeinen zu gebrauchen und weisen keine abnormalen Ausreißer auf. Kurz gesagt, die Regressionen passen in etwa zur Verteilung der Daten.

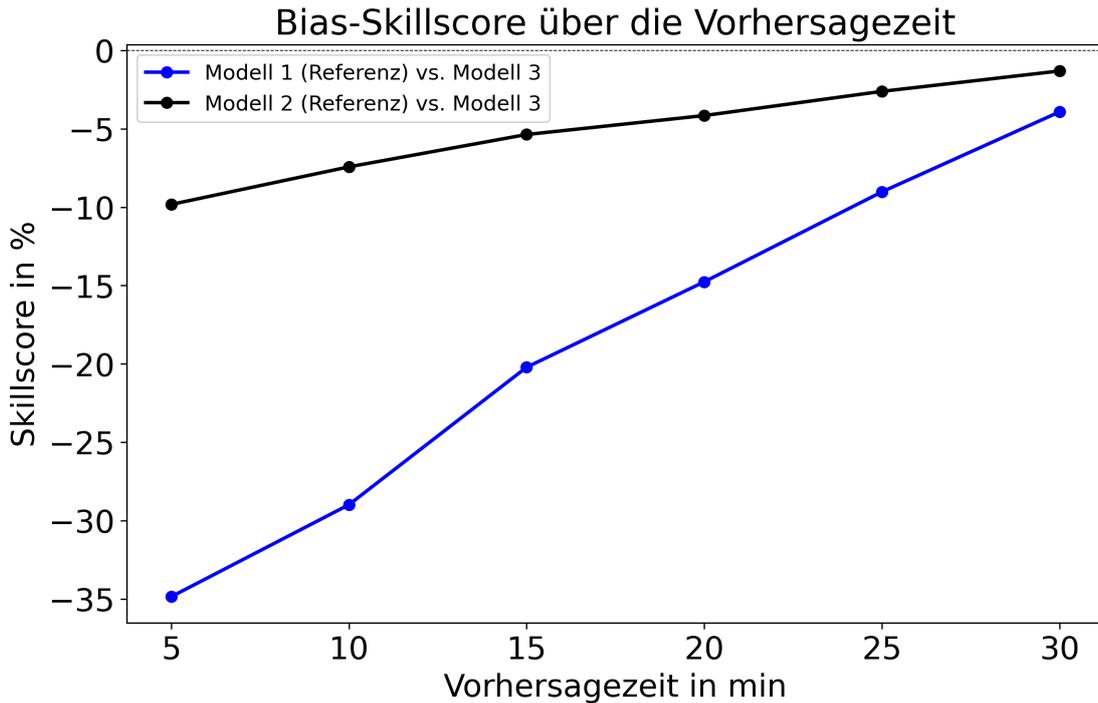


Abb. 5.5.: Bias-Skillscore des Modells 3 über den Vorhersagezeitraum bis 30 min

In Abbildung 5.5 ist der Skill des Modells 3 (mit Blitzprädiktoren) gegenüber dem Modell 1 und 2 (ohne Blitzprädiktoren) bezogen auf den systematischen Fehler gegeben. In Bezug auf den Bias liefert das Modell 3 keine Verbesserung. Wie in Abb. 5.2 gegeben, nimmt die Verzerrung im Modell 3 sogar zu was zu einem negativen Bias-Skillscore führt. Zwar wird der Bias-Skill des Modells über den Vorhersagezeitraum insgesamt etwas besser (Steigung der Graphen), bleibt aber durchgehend schlechter als das jeweilige Referenzmodell. In Bezug auf den Bias bedeutet dies, dass die Integration von Blitzprädiktoren in das Modell 3 den systematischen Fehler verstärkt, anstatt ihn zu reduzieren. Die Folge ist ein größerer Modell-Bias im Modell 3 und damit eine Verschlechterung der Vorhersageleistung auf dieser Metrik.

In den Abbildungen auf S. 46 ist der Skill des Modells 3 (mit Blitzprädiktoren) gegenüber dem Modell 1 und 2 (ohne Blitzprädiktoren) bezogen auf den RMSE (Abb. 5.6) und MAE (Abb. 5.7) abgebildet. Wie in Abb. 5.3 und Abb. 5.4 gegeben, nimmt die Akkuratess der Modellvorhersagen 1-3 über den Vorhersagezeitraum ab, d.h. heißt der Fehler (RMSE & MAE) nimmt zu. Dabei liefert das Modell 3 im Vergleich zur Referenz die akkurateste Vorhersage, das heißt die Vorhersage mit dem kleinsten Fehler. Daraus folgt, dass auch der Akkuratess-Skill (RMSE-Skill & MAE-Skill) des Modells zunimmt (positiv ist). Die Folge ist eine Verbesserung der Vorhersageleistung auf dieser Metrik. Während der Akkuratess-Skill des Modells 3 in Referenz zu Modell 1 zunimmt, ist die Zunahme der Akkuratess in Bezug auf Modell 2 nur verschwindend gering.

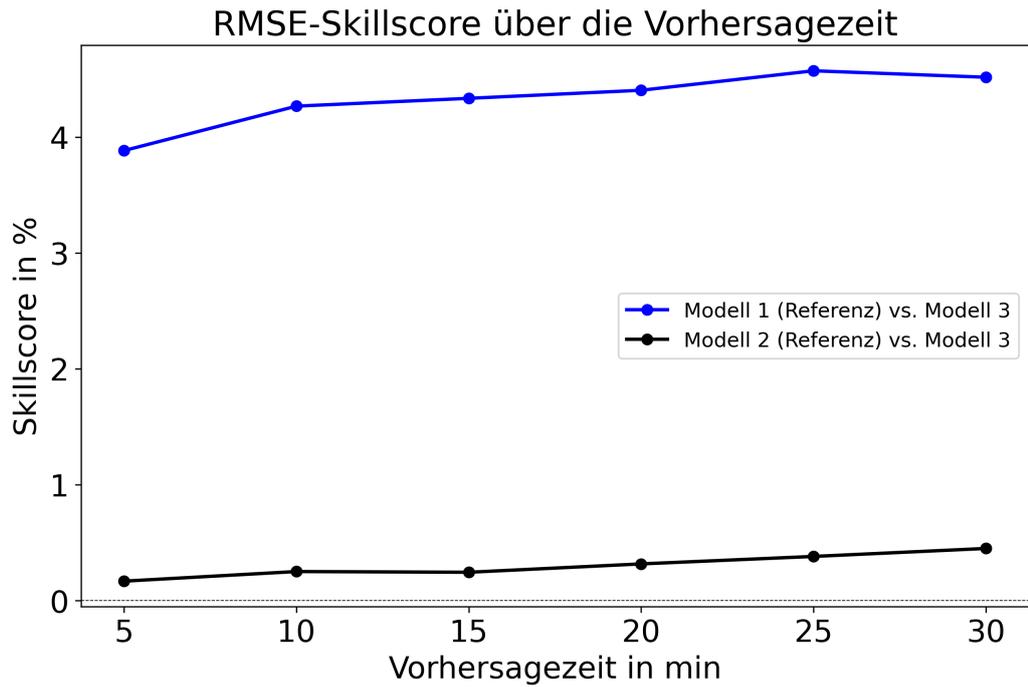


Abb. 5.6.: RMSE-Skillscore des Modells 3 über den Vorhersagezeitraum bis 30 min

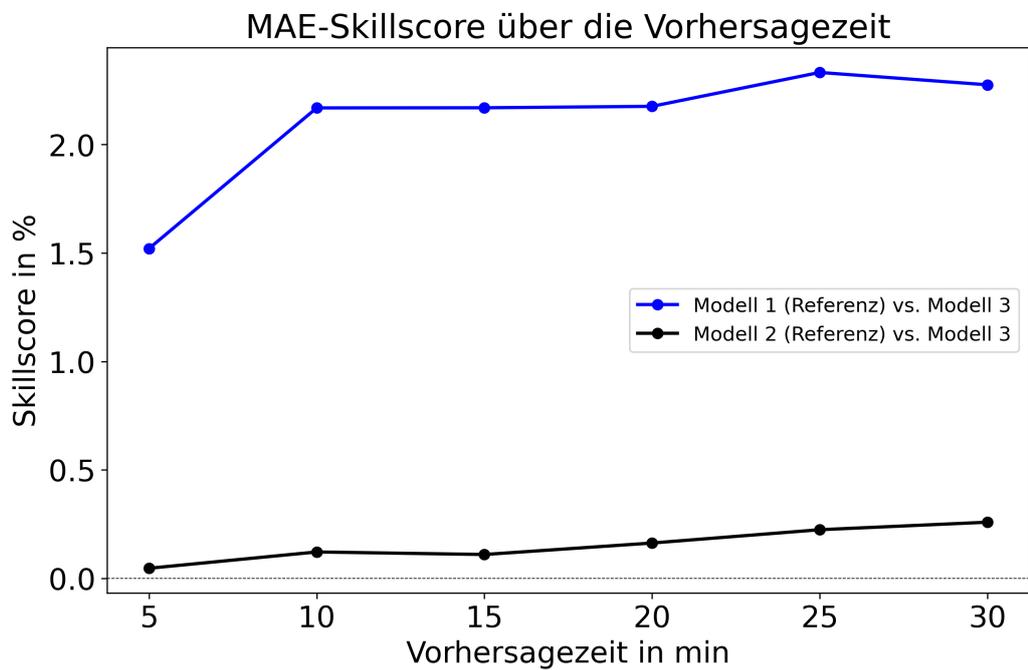


Abb. 5.7.: MAE-Skillscore des Modells 3 über den Vorhersagezeitraum bis 30 min

## 5.2. Fallstudien zu Lightning-Jumps

Um das zeitliche Auftreten der Lightning Jumps im Kontext der Lebensdauer der Gewitterzelle einmal zu untersuchen, werden im folgenden zwei Fallbeispiele genauer analysiert.

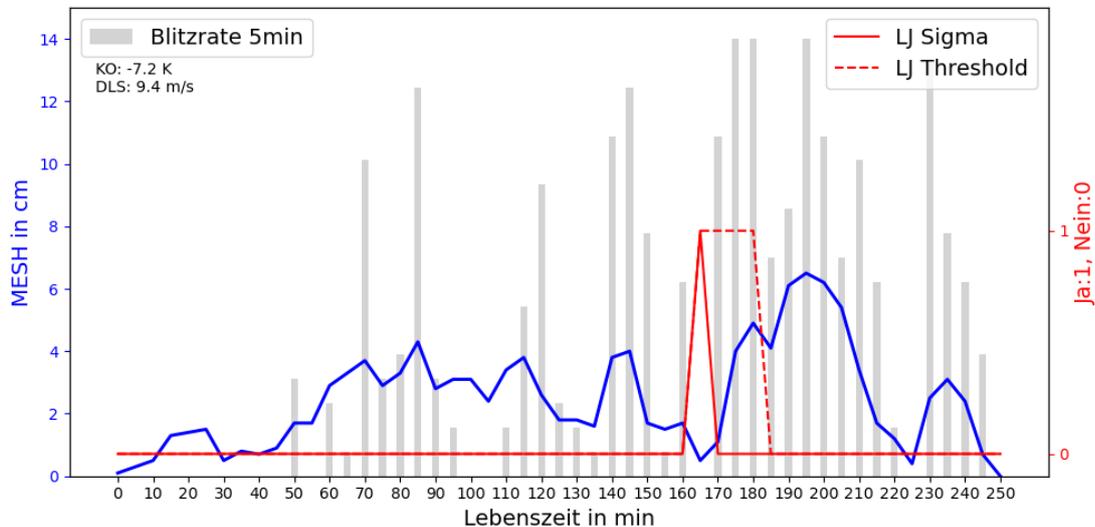


Abb. 5.8.: Gegeben ist der Celltrack einer Gewitterzelle (ID: 482). Die Abbildung gibt auf der linken Seite die maximale Hagelgröße (blau, y-Achse) und auf der rechten Seite das Auftreten eines Lightning-Jumps (rot, y-Achse) über die Lebensdauer des Gewitters (x-Achse) an. Dazu wird die mit der maximalen Blitzrate des Gewitters gewichtete 5-minütige Blitzrate (grau) dargestellt.

Die Abbildung 5.8 zeigt das Auftreten eines Lightning Jumps ca. 30 min vor dem Auftreten der maximalen Hagelgröße des Gewitters. In diesem Fall wird die Eingangshypothese der Arbeit bestätigt und der Lightning Jump könnte als ein potenzieller Indikator für eine Hagelwarnung mit ausreichender Vorlaufzeit vor dem Hagelereignis verwendet werden.

Des Weiteren wird deutlich, dass ein Anstieg der Blitzrate (graue Balken) auch immer unmittelbar mit einem Anstieg der Hagelgröße (blaue Linie) verbunden ist. Diese zeitliche Synchronisierung zwischen den Maxima der Blitzrate und den Maxima der potentiellen Hagelgröße, erklärt im Allgemeinen auch die höhere Korrelation der Gesamtblitzrate (Lightning Ln) im vgl. zu den Lightning-Jumps (siehe Abb. A.1). Der Zusammenhang konnte auch in einer Vielzahl weiterer Gewitterzellen beobachtet werden.

Nach der Analyse weiterer Gewitterzellen musste festgestellt werden, dass die überwiegende Mehrheit der Zelltracks (Zell-IDs) jedoch ein zeitlich synchronisiertes Auftreten von Lightning Jumps und Hagelereignis besitzt. Die Abbildung 5.9 repräsentiert beispielhaft eine Gewitterzelle, bei der das Auftreten eines Lightning Jumps (rote Linie) direkt mit dem Auftreten der maximalen Hagelgröße (blaue Linie) verbunden ist.

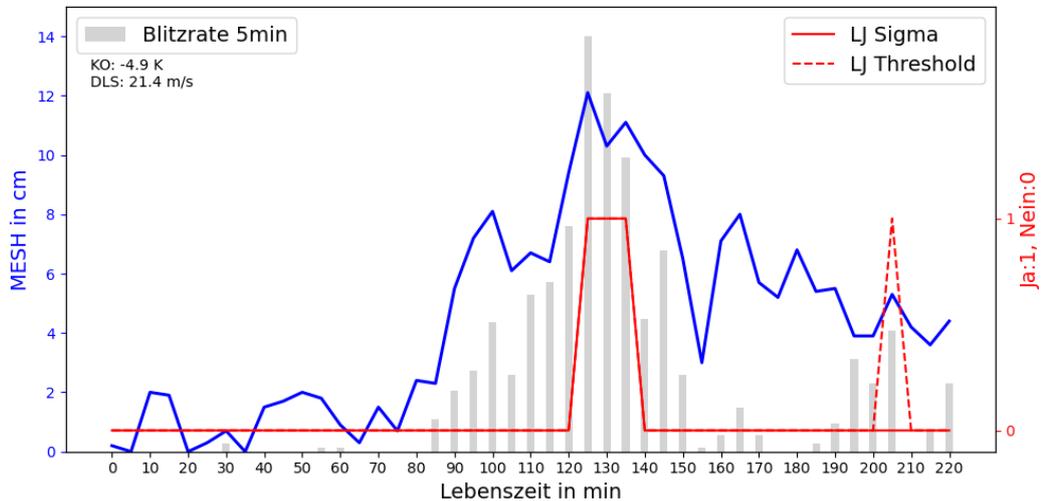


Abb. 5.9.: Gegeben ist der Celltrack einer Gewitterzelle (ID: 482). Die Abbildung gibt auf der linken Seite die maximale Hagelgröße (blau, y-Achse) und auf der rechten Seite das Auftreten eines Lightning-Jumps (rot, y-Achse) über die Lebensdauer des Gewitters (x-Achse) an. Dazu wird die mit der maximalen Blitzrate des Gewitters gewichtete 5-minütige Blitzrate (grau) dargestellt.

Eine direkte zeitliche Korrelation zwischen dem Lightning Jump und dem Hagelereignis, wie sie in Abbildung 5.9 zu sehen ist, wäre für eine operationelle Warnung auf Basis einer Vorlaufzeit nutzlos. Demnach hätte der Empfänger der Warnung keine Zeit rechtzeitig Schutzvorkehrungen zu treffen und wäre dem Hagelereignis schutzlos ausgeliefert. In diesem Fall müssten andere meteorologische Anhaltspunkte für eine Vorwarnung gefunden werden.

## 6. Zusammenfassung und Diskussion

In diesem Kapitel werden die wichtigsten Ergebnisse und Erkenntnisse der Arbeit zusammengefasst. Das Ziel der Arbeit war der Versuch, Blitzdaten in Form von Lightning-Jumps als statistische Prediktoren für die Hagelvorhersage im CellMOS zu verwenden, um damit die Hagelvorhersage im CellMOS zu verbessern. Vermutet wurde dabei zunächst eine zeitliche Differenz zwischen dem Anstieg der Blitzaktivität (“Lightning-Jump”) und dem ersten Hagelschlag am Boden (siehe Abb. 5.8). Ein ausreichend zeitlicher Unterschied beider Ereignisse hätte als mögliche Vorlaufzeit für eine Hagelwarnung dienen können und somit einen operationellen Mehrwert für die Vorhersage von Hagelereignissen dargestellt (vgl. Kapitel 5.2). Nach der Auswertung einer Vielzahl von Gewitterzellen (“Zell-IDs”) musste jedoch festgestellt werden, dass der größte Hagel am Boden in den meisten Fällen zeitgleich mit einem Lightning-Jump im Gewitter auftritt (siehe Abb. 5.9). In Bezug auf den vorliegenden Datensatz bedeutet das, dass die Lightning-Jump-Algorithmen von Schultz et al. [2009] keinen direkten Hinweis auf eine Hagelwarnung mit ausreichender Vorlaufzeit liefern können. Die Ergebnisse der Fallstudien in Abschnitt 5.2 weisen darauf hin, dass die Verwendung von Lightning-Jumps zur operationellen Vorhersage der Hagelgröße noch mit großer Vorsicht zu genießen ist. Die Ursachen für die unzureichenden Ergebnisse sind vielseitig.

Zunächst sei erwähnt, dass die Lightning-Jump-Algorithmen aus den USA stammen und sich nicht ohne Weiteres auf Europa übertragen lassen. Grund dafür sind die teils willkürlich ermittelten Schwellenwerte (Gl. 2.8 & Gl. 2.9) auf Basis einer Klimatologie von Gewittern aus den Vereinigten Staaten (Abb. 2.2 & 2.3). Demnach empfiehlt es sich bei der Definition passender Schwellenwerte für die Lightning-Jumps auch auf die Blitzklimatologien der entsprechenden Region zurückzugreifen, in welcher die Algorithmen später operationell verwendet werden sollen. In diesem Fall müssten dafür mehrjährige Blitzdaten aus der Schweiz ausgewertet werden. Regionale Unterschiede in der Blitzaktivität der Gewitterzellen können demnach zu anderen Schwellenwerten führen, welche für die Definition der Lightning-Jumps eventuell besser geeignet sind.

Auch der in dieser Arbeit verwendete MESH-Algorithmus für die Hageldetektion (Abschnitt 2.4), unterliegt dem Einfluss regionaler Unterschiede, welche in diesem Fall auf die Technik der Fernerkundung zurückzuführen sind. Der MESH-Algorithmus für S-Band-Radarsysteme in den USA erworben. Die Radargeräte in der Schweiz arbeiten aber im Frequenzspektrum des C-Bandes. Das kann zu Abweichungen in der Reflektivitäts-Hagel-Beziehung ( $Z-E$ -Relation) und der damit verbundenen Wichtungsfunktion der Reflektivität ( $Z$ ) führen. Demnach reflektiert ein C-Band-Radar aufgrund seiner höheren Frequenz den Niederschlag tendenziell stärker. Umgekehrt erfasst das S-Band-Radar den Nieder-

schlag nicht so deutlich, wie das C-Band-Radar. Die Folge wäre ein systematischer Fehler bei der geschätzten Größe des Hagels. Im Allgemeinen sind 2-D-Radardaten-basierte Algorithmen wie MESH nur begrenzt in der Lage, Hagel zu erkennen. Das Potenzial, dass eine konvektive Zelle Hagel erzeugt, wird nicht nur durch eine sehr hohe Reflektivität in einer bestimmten Höhe bestimmt, sondern durch hohe Reflektivitätswerte im gesamten Auf- und Abwind der Gewitterzelle. Daher können zusätzliche Informationen aus 3-D-Radarmessungen, wie die vertikal integrierte Flüssigkeit VIL Greene and Clark [1972], nützliche Informationen für die Erkennung von Hagel liefern Wapler et al. [2012].

Wichtig ist auch zu erwähnen, dass der MESH-Algorithmus nur eine radarbasierte Schätzung der Hagelgröße und keine Beobachtung der tatsächlichen Hagelgröße darstellt. Eine quantitative Verifikation des Algorithmus mithilfe einer Kontingenztabelle (“Matrix of Confusion”) kann nicht umfassend durchgeführt werden, da die Hagelbeobachtungen immer nur Informationen über “positive Ereignisse“ liefern. Kein Eintrag in der Datenbank oder keine Beobachtung an einem Standort bedeutet nicht, dass kein Hagel aufgetreten ist. Das heißt, dass “hits” (Ereignis beobachtet und vorhergesagt) und “missed” (Ereignis beobachtet, aber nicht vorhergesagt) bestimmt werden können, nicht aber die “false alarms” (Ereignis vorhergesagt, aber nicht beobachtet) und die “correct rejected” (Ereignis weder vorhergesagt noch beobachtet). Eine Strategie, wie man mit den Daten quantitativ am besten arbeitet, muss also noch entwickelt werden Wapler et al. [2012].

Nach dem Vergleich der Modelle 1-3 (Abb. 5.1) musste festgestellt werden, dass eine Integration der Lightning-Jumps nicht den erhofften Verbesserungsbeitrag zur Hagelvorhersage (Varianzaufklärung des Prädiktanden) liefert. Das Bestimmtheitsmaß für die Modelle 2 und 3 ist über den gesamten Vorhersagezeitraum von 30 min in etwa gleich groß (Abb. 5.1). Auch mit einer Vernachlässigung des Persistenzprädiktors konnte durch die Blitzprädiktoren in der CellMOS-Gleichung keine Verbesserung der Anpassungsgüte erzielt werden (vgl. Modell 4 und 5). Nach dem Ergebnis der mehrfaktoriellen Varianzanalyse liefern jedoch alle Blitzprädiktoren einen statistisch signifikanten Erklärungsbeitrag zur Varianzaufklärung der Hagelgröße. Dies konnte mit dem Hypothesentest der F-Teststatistik und der Interpretation des p-Wertes bewiesen werden (siehe Varianzanalyse, Abschnitt 5.1.1).

Insgesamt hat sich der empirische Ansatz, über einen Reflektivitätsschwellenwert im (oberen) Bereich der Gewitterzelle zu gehen für die Vorhersage der potentiellen Hagelgröße am besten erwiesen. Das zeigt die hohe lineare Korrelation der drei Radarprädiktoren ECHOTOP 45, ECHOTOP 15, sowie MaxRefl(0:00) in Tabelle 5.2. Dies entspricht im Allgemeinen auch dem grundlegenden Ansatz des Hagelkriteriums nach Mason [1971], welches sich gut für die Abschätzung des Vorhandenseins von Hagel am Boden auf der Grundlage einer 2D-Radarreflektivität eignet (Abschnitt 2.4). Wapler [2017] fand heraus, dass das Schwellenwert-Kriterium der Reflektivität in fast allen 600 Hagelfällen einer achtjährigen Hagelklimatologie während des beobachteten Hagels oder oft sogar weit im Voraus erreicht wurde.

Auch in Bezug auf die Blitzprädiktoren lässt sich über die Korrelation in Tabelle 5.2 eine Aussage über den (linearen) Zusammenhang zur Hagelgröße treffen. Insgesamt erwies sich die logarithmierte Gesamtblitzrate (Lightning Ln) als der Blitzprädiktor mit dem größ-

ten linearen Zusammenhang zum Hagel-Prädiktanden. Der Zusammenhang spiegelt sich gut in den Fallstudien (Abb. 5.8 & Abb. 5.9) wider. Bei den Lightning-Jumps korreliert der Threshold-Algorithmus besser als der Sigma-Algorithmus zur Zielgröße. Dies liegt wahrscheinlich daran, dass das Schwellenwertskriterium des Threshold-Algorithmus in der Regel schneller erreicht wird als das Schwellenwertskriterium des Sigma-Algorithmus (Abschnitt 2.5). Die übrigen Prädiktoren der Kinematik (DLS, SRH) und der Thermodynamik (ModelHgt0TT, RH Prd) wiesen eine geringere Korrelation zum Prädiktanden auf. Als aussageräftige Konvektionsparametrisierungen haben sie aber dennoch ihre Daseinsberechtigung in der CellMOS-Gleichung.

Die Verifikation des Modells 3 (mit Blitzprädiktoren) zeigt das folgende Ergebnis: Der Bias der prognostizierten Hagelgröße nimmt im Modell 3 zu. Demnach ist der Bias-Skill der Vorhersage in Bezug auf die Referenzmodelle 1 und 2 negativ. Jedoch nimmt durch die Integration der Blitzprädiktoren auch die Akkuratessse im Modell 3 zu, sodass der Fehler, der die mittlere Übereinstimmung zwischen der Vorhersage und der korrespondierenden Beobachtung misst (RMSE & MAE), kleiner wird. Die Blitzprediktoren sorgen also dafür, dass der Modell-Bias zwar zunimmt, die Vorhersage aber in Bezug auf ihre Akkuratessse genauer wird.

Ein Vorteil von Blitzdaten für die Hagelvorhersage im CellMOS zu verwenden ist, dass sie räumlich genau und in Echtzeit verfügbar sind (Abschnitt 2.1.2). Jedoch kann es mit der Zellerkennung und dem Zelltracking im CellMOS zu Ungenauigkeiten bei der Zuordnung der Blitze auf die Radardaten kommen (Abschnitt 2.3). Ist die Zuordnung der Blitzdaten bei einer isolierten Konvektionszelle mit einem festen Zellradius gut zu generalisieren, kann es bei Gewitterclustern mit mehreren Reflektivitätskernen zu Doppelzählungen bzw. Auslassungen von Blitzen kommen. Probleme wie diese zeigen, dass Gewitter chaotische Systeme sind, die sich mit dem CellMOS-Verfahren und dem Ansatz vereinfachter linearer Statistik nur bedingt vorhersagen lassen.

Die Ergebnisse der Arbeit zeigen, dass die Hagelvorhersage mit Blitzdaten durchaus ein komplexes Thema ist. Für die Bearbeitung der Fragestellung lohnt es sich zukünftig auch, komplexere Modellierungsverfahren, wie neuronale Netze oder logistische Regressionsmodelle, in Betracht zu ziehen.

## 7. Ausblick

Die Integration von Lightning-Jumps in Nowcasting-Systeme wie CellMOS ist ein erster Ansatz, um die Hagelvorhersage auf Basis von Blitzdaten zu verbessern. Dennoch ist der allgemeine Zusammenhang zwischen dem Auftreten von Lightning-Jumps und dem Auftreten von Hagel am Boden noch nicht ausreichend belegt und kann hier nur in ausgewählten Fallstudien nachgewiesen werden (Abb. 5.8). Die reine Präsentation von Einzelfällen, bei denen ein optimaler Zusammenhang zwischen Lightning-Jumps und Hagelereignis besteht, sogenanntes "Cherry-Picking", stellt jedoch keine Repräsentation der Gesamtheit der Daten da und wäre schlichtweg irreführend.

Dennoch liefert der Ansatz, die Blitzdaten für die statistische Regression im CellMOS zu verwenden, Raum für weitere Entwicklungen und Experimente. Neben der Möglichkeit, eigene Schwellenwerte der Blitzrate auf der Basis regionaler Gewitterklimatologien aus der Schweiz zu definieren (Abschnitt 6), besteht weiterhin die Möglichkeit, das gesamte Potential der verfügbaren Blitzdaten zu nutzen. Wie in Abschnitt 3.2 beschrieben, detektiert ein modernes Blitzortungssystem nicht nur Informationen zur Anzahl der Blitze (Blitzrate), sondern auch zur Intensität der Blitzentladungen (Blitzstärke). So kann beispielsweise die gemessene Stromstärke der Entladungen verwendet werden, um die Lightning-Jumps mit der Intensität der Blitze zu gewichten. Bereits Wapler [2017] führte in ihrer Studie zum Lebenszyklus von Hagelstürmen eine Blitzsprungintensität ein, die nicht auf Basis fester Schwellenwerte arbeitet. Dabei stellt sie eine Matrix als Funktion der Gesamtblitzrate ( $\frac{\text{Flashes}}{5 \text{ min}}$ ) und der Stärke des Anstiegs der Blitzrate ( $\alpha$ ) auf [siehe Wapler, 2017, Abb. 12]. Auf diese Weise kann die Intensität des Blitzsprungs berücksichtigt werden.

Insgesamt wird vermutet, dass großer Hagel nach MESH häufiger mit dem Auftreten eines Lightning-Jumps korreliert. Diese Vermutung basiert auf der Erkenntnis, dass Schwergewitter mit hoher, teils pulsierender Blitzaktivität, auch häufiger mit dem Auftreten von Großhagel verbunden sind. Wapler [2017] konnte in ihrer Studie auf Grundlage einer achtjährigen Klimatologie von Hagelgewittern in Deutschland beweisen, dass Gewitter mit Großhagel  $> 5$  cm mit einer höheren Blitzdichte einhergehen [siehe Wapler, 2017, Abb. 3 b)]. Demnach müssten Gewitterzellen mit großen Hagelkorngrößen, d.h. hohen MESH-Werten, auch eine höhere Korrelation zum Auftreten von Lightning-Jumps besitzen. Diese Vermutung könnte genauer mit dem Korrelationskoeffizienten nach Bravais-Pearson untersucht werden, indem bei der Auswahl der Trackingdaten der MESH-Schwellenwert der Gewitterzellen (Zell-IDs) angehoben wird. Folglich müsste auch die positive Korrelation des Prädiktanden zu den Lightning-Jump-Prädiktoren im Datensatz zunehmen.

Um eine höhere Korrelation zu den Lightning-Jumps zu erzielen, kann es sinnvoll sein, den Tagesgang bei der Auswahl der Daten zu berücksichtigen. Nisi et al. [2020] konnte nachweisen, dass die meisten Hagelereignisse in der Schweiz nach Mittag auftreten und bis in die frühen Abendstunden andauern. Dies entspricht der allgemeinen “Prime-time” für kräftige Gewitter in den Sommermonaten. Zu dieser Tageszeit ist meist der Antrieb durch hochreichende atmosphärische Instabilität am stärksten, was wiederum die Intensivierung der Gewitter und damit auch die einhergehende Blitzaktivität im Entwicklungsstadium der Stürme beeinflussen kann.

Bei der Entwicklung einer möglichst aussagekräftigen CellMOS-Gleichung ist es hilfreich, weitere Prädiktoren zu finden, welche sich für die Vorhersage der Hagelgröße eignen und die Gesamtvarianz der MESH-Beobachtung erklären können. Wie in Tabelle 5.2 ersichtlich wurde, eignen sich die maximale Höhe der 45 dBz Niederschlagsreflektivität (ECHOTOP 45) und 15 dBz Niederschlagsreflektivität (ECHOTOP 15) deutlich besser als die Blitzprädiktoren, um Rückschlüsse auf das Hagelpotential einer Gewitterzelle zu ziehen. Es ist jedoch auch lohnenswert, andere kinematische oder thermodynamische Aspekte der Konvektionsdynamik zu berücksichtigen.

Peters et al. [2020] fand heraus, dass stärkerer Inflow, d.h. der Massenfluss in ein Gewitter, breitere Aufwinde verursacht, was wiederum das Hagelwachstum begünstigt. Auf der Grundlage dieser Erkenntnis wurde bei METEO SERVICE ein Inflow-Prädiktor entwickelt, welcher sich aus dem Mittel des sturm-relativen Modellwindes auf 850 hPa und 925 hPa zusammensetzt. In einem ersten Test erzielte der Prädiktor jedoch nur eine Korrelation von 0.06 zum Vorhersagezeitschritt von 5 min und eine Korrelation von 0.04 zum Vorhersagezeitschritt von 30 min.

Wapler [2017] fand heraus, dass in drei Vierteln der untersuchten Hagelstürme automatisch eine Mesozyklone in den Radardaten erkannt wurde. Bei vier Fünfteln dieser Fälle konnte bereits vor dem gemeldeten Hagel eine Mesozyklone festgestellt werden. Diese Erkenntnis legt nahe, für die Entwicklung neuer CellMOS-Prädiktoren zukünftig auch polarimetrische Radardaten mit integrierter Mesozyklonen-Erkennung zu verwenden. 3D-Mesozyklonendaten können heutzutage bereits im 5-Minuten-Intervall berechnet werden.

Aus den beschriebenen Ansätzen wird ersichtlich, dass zukünftig neben der Integration von Blitzdaten auch noch weitere Prädiktorvariablen für CellMOS definiert werden können, wenn die zur Verfügung stehende Datengrundlage von METEO SCHWEIZ es zulässt.

# Abbildungsverzeichnis

1.1. CellMOS (Systemvorstellung) . . . . .	8
2.1. Reflektivitäts-Hagel-Beziehung (Witt et al. 1998) . . . . .	16
2.2. Histogramm der Spitzenblitzraten (Schultz et al. 2009) . . . . .	19
2.3. Histogramm der DFRDT-Spitzenwerte (Schultz et al. 2009) . . . . .	20
3.1. Standorte der Niederschlagsradarstationen (Schweiz) . . . . .	22
3.2. Horizontale Auflösung und Vertikalaufriß (Radardomain) . . . . .	23
3.3. Komposit-Radarbild der Schweiz (farbig) . . . . .	23
4.1. Modellentwicklung (Schema) . . . . .	27
4.2. Verteilung des Prädiktanden . . . . .	28
4.3. Transformation des Prädiktanden . . . . .	28
4.4. Einfachregression (Wilks 2011) . . . . .	29
5.1. Vergleich der Modelle (Bestimmtheitsmaß) . . . . .	40
5.2. Bias der Modelle 1-3 (Metrik) . . . . .	42
5.3. RMSE der Modelle 1-3 (Metrik) . . . . .	43
5.4. MAE der Modelle 1-3 (Metrik) . . . . .	44
5.5. Bias-Skill-Score (Validierung) . . . . .	45
5.6. RMSE-Skill-Score (Validierung) . . . . .	46
5.7. MAE-Skill-Score (Validierung) . . . . .	46
5.8. Fallstudie 1 (Positivbeispiel) . . . . .	47
5.9. Fallstudie 2 (Negativbeispiel) . . . . .	48
A.1. Korrelation der Blitzprädiktoren . . . . .	63
A.2. Korrelation der Radarprädiktoren . . . . .	64
A.3. Korrelation der kinematischen Modellprädiktoren . . . . .	64
A.4. Korrelation der thermodynamischen Modellprädiktoren . . . . .	65
A.5. Korrelation der Persistenzprädiktoren . . . . .	65

# Tabellenverzeichnis

3.1. Indizierung der Niederschlagsreflektivitäten . . . . .	23
3.2. Ausgabeformat der Radardaten . . . . .	24
3.3. Ausgabeformat der Blitzdaten . . . . .	24
3.4. Ausgabeformat der Modelldaten . . . . .	25
3.5. Ausgabeformat der Trackingdaten . . . . .	26
4.1. Kreuzvalidierung . . . . .	34
5.1. Überblick: MOS-Gleichung . . . . .	38
5.2. Korrelationen der CellMOS-Prediktoren . . . . .	41
A.1. Fortsetzung: Indizierung der Niederschlagsreflektivitäten . . . . .	57
A.2. Fortsetzung: Ausgabeformat der Radardaten . . . . .	58
A.3. Fortsetzung: Ausgabeformat der Blitzdaten . . . . .	59
A.4. Fortsetzung: Ausgabeformat der Modelldaten . . . . .	59
A.5. Legende der Trackingdaten . . . . .	60
A.6. Legende der CellMOS-Gleichung . . . . .	61
A.7. Ergebnisse der Varianzanalyse (Vorhersage: 5 min) . . . . .	62
A.8. Ergebnisse der Varianzanalyse (Vorhersage: 10 min) . . . . .	62
A.9. Ergebnisse der Varianzanalyse (Vorhersage: 15 min) . . . . .	62
A.10. Ergebnisse der Varianzanalyse (Vorhersage: 20 min) . . . . .	62
A.11. Ergebnisse der Varianzanalyse (Vorhersage: 25 min) . . . . .	63
A.12. Ergebnisse der Varianzanalyse (Vorhersage: 30 min) . . . . .	63



# A. Anhang

## A.1. Datengrundlage

### Indizierung der Niederschlagsreflektivitäten

Tabelle A.1.: Fortsetzung: Indizierung der Niederschlagsreflektivitäten

Index	mm/h	Index	mm/h	Index	mm/h	Index	mm/h
0	-10.0	64	36.05	128	100.05	192	164.05
1	0.0001	65	37.05	129	101.05	193	165.05
2	0.10	66	38.05	130	102.05	194	166.05
3	0.15	67	39.05	131	103.05	195	167.05
4	0.20	68	40.05	132	104.05	196	168.05
5	0.25	69	41.05	133	105.05	197	169.05
6	0.30	70	42.05	134	106.05	198	170.05
7	0.35	71	43.05	135	107.05	199	171.05
8	0.40	72	44.05	136	108.05	200	172.05
9	0.45	73	45.05	137	109.05	201	173.05
10	0.50	74	46.05	138	110.05	202	174.05
11	0.55	75	47.05	139	111.05	203	175.05
12	0.60	76	48.05	140	112.05	204	176.05
13	0.65	77	49.05	141	113.05	205	177.05
14	0.70	78	50.05	142	114.05	206	178.05
15	0.75	79	51.05	143	115.05	207	179.05
16	0.80	80	52.05	144	116.05	208	180.05
17	0.85	81	53.05	145	117.05	209	181.05
18	0.90	82	54.05	146	118.05	210	182.05
19	0.95	83	55.05	147	119.05	211	183.05
20	1.00	84	56.05	148	120.05	212	184.05
21	1.10	85	57.05	149	121.05	213	185.05
22	1.25	86	58.05	150	122.05	214	186.05
23	1.35	87	59.05	151	123.05	215	187.05
24	1.45	88	60.05	152	124.05	216	188.05
25	1.55	89	61.05	153	125.05	217	189.05
26	1.65	90	62.05	154	126.05	218	190.05
27	1.75	91	63.05	155	127.05	219	191.05
28	1.85	92	64.05	156	128.05	220	192.05
29	1.95	93	65.05	157	129.05	221	193.05
30	2.00	94	66.05	158	130.05	222	194.05
31	3.05	95	67.05	159	131.05	223	195.05
32	4.05	96	68.05	160	132.05	224	196.05
33	5.05	97	69.05	161	133.05	225	197.05
34	6.05	98	70.05	162	134.05	226	198.05

Index	mm/h		Index	mm/h		Index	mm/h		Index	mm/h
35	7.05		99	71.05		163	135.05		227	199.05
36	8.05		100	72.05		164	136.05		228	200.05
37	9.05		101	73.05		165	137.05		229	201.05
38	10.05		102	74.05		166	138.05		230	202.05
39	11.05		103	75.05		167	139.05		231	203.05
40	12.05		104	76.05		168	140.05		232	204.05
41	13.05		105	77.05		169	141.05		233	205.05
42	14.05		106	78.05		170	142.05		234	206.05
43	15.05		107	79.05		171	143.05		235	207.05
44	16.05		108	80.05		172	144.05		236	208.05
45	17.05		109	81.05		173	145.05		237	209.05
46	18.05		110	82.05		174	146.05		238	210.05
47	19.05		111	83.05		175	147.05		239	220.05
48	20.05		112	84.05		176	148.05		240	230.05
49	21.05		113	85.05		177	149.05		241	240.05
50	22.05		114	86.05		178	150.05		242	250.05
51	23.05		115	87.05		179	151.05		243	260.05
52	24.05		116	88.05		180	152.05		244	270.05
53	25.05		117	89.05		181	153.05		245	280.05
54	26.05		118	90.05		182	154.05		246	290.05
55	27.05		119	91.05		183	155.05		247	300.05
56	28.05		120	92.05		184	156.05		248	310.05
57	29.05		121	93.05		185	157.05		249	320.05
58	30.05		122	94.05		186	158.05		250	330.05
59	31.05		123	95.05		187	159.05		251	340.05
60	32.05		124	96.05		188	160.05		252	350.05
61	33.05		125	97.05		189	161.05		253	360.05
62	34.05		126	98.05		190	162.05		254	370.05
63	35.05		127	99.05		191	163.05		255	380.05

### Radardaten

Tabelle A.2.: Fortsetzung: Ausgabeformat der Radardaten.

ln(MESH(-0:05))	ln(MESH(-0:10))	Size1	Size2	Size3	dBzFZL
2.14	2.29	500	349	158	62.5
2.29	2.31	500	351	135	62.5
2.11	1.94	416	228	15	58.5

**Blitzdaten**

Tabelle A.3.: Fortsetzung: Ausgabeformat der Blitzdaten.

Lightning	LightTend	LightningW	LightTendW
3272	32	-	-
3240	1276	-	-
3236	236	-	-
...	...	...	...
LJ ThresholdW	LJ SigmaW	LJ Sigma value	LJ Sigma prob
-	-	39.0	0.0
-	-	171.6	0.0
-	-	57.0	0.0
...	...	...	...

**Modelldaten**

Tabelle A.4.: Fortsetzung: Ausgabeformat der Modelldaten.

ModelDD	ModelFF	rModelff500	rModelff700	rModelff850
191.2	5.7	12.27	6.96	2.38
250.4	6.5	14.21	8.49	2.30
229.6	11.3	25.92	2.48	4.42
...	...	...	...	...
rModeldd700	rModeldd850	rModelRH700	rModelRH850	rModelRHA
191.42	128.38	71.99	64.77	73.60
264.87	172.53	70.46	72.17	66.54
204.96	282.17	59.87	58.51	57.30
...	...	...	...	...
rModelRHW	rModelRHP	rModelRHX	rModelGUST	rModelSWEAT
71.82	28.53	88.47	33.8	-
65.52	19.00	72.17	35.3	-
57.24	10.75	59.87	38.1	208.8
...	...	...	...	...
KO	ModelHgtN20TT	CAmean	Inflow	-
-4.8	7044	21.2	15.3	-
-7.2	7037	11.2	15.2	-
-6.9	7222	80.5	15.4	-
...	...	...	...	-

## Legende der Trackingdaten

Tabelle A.5.: Legende der Trackingdaten für das CellMOS.

Geodaten	Beschreibung
ID	Identifikationsnummer
Date/Time	Datum (Jahr-Monat-Tag) / Uhrzeit (MESZ)
Lat	geografische Breite
Lon	geografische Länge
Lifetime	Lebenszeit einer Gewitterzelle
Prediktand (Hagel)	Beschreibung
ln(MESH)	Logarithmus von MESH
Persistenzpediktoren	Beschreibung
ln(MESH(0:00))	Persistenz von MESH (0:00 min)
ln(MESH(-0:05))	Persistenz von MESH (-0:05 min)
ln(MESH(-0:10))	Persistenz von MESH (-0:10 min)
MaxRefl(0:00)	Persistenz der maximalen Reflektivität (0:00 min)
Radarpediktoren	Beschreibung
Size1	Größe der 40 dBz Fläche
Size2	Größe der 47.5 dBz Fläche
Size3	Größe der 55 dBz Fläche (begrenzt auf 500 km <sup>2</sup> )
dBzFZL	Max. Reflektivität über dem Freezing Level
ECHOTOP15	Max. Höhe der 15 dBz Niederschlagsreflektivität
ECHOTOP45	Max. Höhe der 45 dBz Niederschlagsreflektivität
Blitzpediktoren	Beschreibung
Lightning Ln	Logarithmus der 5-minütigen Blitzrate
LJ Sigma	Sigma Algorithmus (nach C. Schultz)
LJ Threshold	Schwellenwert Algorithmus (nach C. Schultz)
Lightning	Anzahl der Blitze (5-minütig)
LightningWeight	Blitzstärke (5-minütig)
LightTend	Tendenz der Blitzaktivität (Differenz)
LightTendW	Blitzstärke gewichtete Tendenz der Blitzaktivität
LJ ThresholdW	Blitzstärke gewichteter Schwellenwert Algorithmus
LJ SigmaW	Blitzstärke gewichteter Sigma Algorithmus
LJ Sigma value	Differenz zum Sigma-Wert des Sigma-Algorithmus
LJ Sigma prob	Wahrscheinlichkeit für Lightning Jump nach Sigma-Algorithmus
Modellpediktoren	Beschreibung
RH Prd	Produkt der Relative Feuchte (925 hPa, 850 hPa, 700 hPa)
DLS	Deep Layer Shear (500 hPa - 925 hPa)
SRH	Storm Relative Helicity
ModelDD	Windrichtung
ModelFF	Mittelwind
rModelff500	Mittelwind auf 500 hPa
rModelff700	Mittelwind auf 700 hPa
rModelff850	Mittelwind auf 850 hPa

Abkürzung	Beschreibung
rModeldd700	Windrichtung auf 700 hPa
rModeldd850	Windrichtung auf 850 hPa
rModelRH700	Relative Feuchte auf 700 hPa
rModelRH850	Relative Feuchte auf 850 hPa
rModelRHA	Mittel der relativen Feuchte (500 hPa, 700 hPa, 850 hPa, 925 hPa)
rModelRHW	Wichtung der relativen Feuchte (500 hPa, 700 hPa, 850 hPa, 925 hPa)
rModelRHP	Produkt der relativen Feuchte (500 hPa, 700 hPa, 850 hPa, 925 hPa)
rModelRHX	Maximum der relativen Feuchte (500 hPa, 700 hPa, 850 hPa, 925 hPa)
rModelGUST	Maximale Böe
rModelSWEAT	SWEAT-Index
KO	KO-Index
ModelHgt0TT	Höhe der 0°C-Isotherme
ModellHGtN20TT	Höhe der -20°C-Isotherme
CAmean	Critical Angel (Differenz aus SR-Wind am Boden und in 500 m Höhe)
Inflow	Storm Relative Inflow (Mittel aus 850 hPa und 925 hPa)

## A.2. Weitere Ergebnisse

### A.2.1. Legende der CellMOS-Gleichung

Tabelle A.6.: Legende der MOS-Gleichung für die Hagelvorhersage.

Abkürzung	Beschreibung
ln(MESH)	Logarithmus von MESH
ModelHgt0TT	Höhe der 0°C-Grenze (Freezing Level)
SRH	Storm Relative Helicity
RH Prd	Produkt der Relative Feuchte (925 hPa, 850 hPa, 700 hPa)
DLS	Deep Layer Shear (500 hPa - 925 hPa)
ECHOTOP15	Max. Höhe der 15 dBz Reflektivität
ECHOTOP45	Max. Höhe der 45 dBz Reflektivität
ln(MESH(0:00))	Persistenz von ln(MESH)
MaxRefl(0:00)	Persistenz der maximalen Reflektivität
LJ Sigma	Sigma Algorithmus (nach C. Schultz)
LJ Threshold	Schwellenwert Algorithmus (nach C. Schultz)
Lightning Ln	Logarithmus der 5-minütigen Blitzrate

### A.2.2. Ergebnisse der Varianzanalyse

Signifikanzniveaus der p-Werte: 0 \*\*\* 0.001 \*\* 0.01 \* 0.05

Tabelle A.7.: Ergebnisse der mehrfaktoriellen Varianzanalyse der Blitzprediktoren in Form des p-Wertes für die 5-minütige Hagelvorhersage der CellMOS-Gleichung.

Prediktor	Modell 3 (mit Persistenz)	Modell 5 (ohne Persistenz)
LJ Threshold	2.51e-13 ***	<2e-16 ***
LJ Sigma	<2e-16 ***	<2e-16 ***
Lightning Ln	0.0419 *	<2e-16 ***

Tabelle A.8.: Ergebnisse der mehrfaktoriellen Varianzanalyse der Blitzprediktoren in Form des p-Wertes für die 10-minütige Hagelvorhersage der CellMOS-Gleichung.

Prediktor	Modell 3 (mit Persistenz)	Modell 5 (ohne Persistenz)
LJ Threshold	<2e-16 ***	<2e-16 ***
LJ Sigma	<2e-16 ***	<2e-16 ***
Lightning Ln	1.44e-05 ***	<2e-16 ***

Tabelle A.9.: Ergebnisse der mehrfaktoriellen Varianzanalyse der Blitzprediktoren in Form des p-Wertes für die 15-minütige Hagelvorhersage der CellMOS-Gleichung.

Prediktor	Modell 3 (mit Persistenz)	Modell 5 (ohne Persistenz)
LJ Threshold	<2e-16 ***	<2e-16 ***
LJ Sigma	<2e-16 ***	<2e-16 ***
Lightning Ln	0.4564	<2e-16 ***

Tabelle A.10.: Ergebnisse der mehrfaktoriellen Varianzanalyse der Blitzprediktoren in Form des p-Wertes für die 20-minütige Hagelvorhersage der CellMOS-Gleichung.

Prediktor	Modell 3 (mit Persistenz)	Modell 5 (ohne Persistenz)
LJ Threshold	<2e-16 ***	<2e-16 ***
LJ Sigma	<2e-16 ***	<2e-16 ***
Lightning Ln	0.00976 **	<2e-16 ***

Tabelle A.11.: Ergebnisse der mehrfaktoriellen Varianzanalyse der Blitzprediktoren in Form des p-Wertes für die 25-minütige Hagelvorhersage der CellMOS-Gleichung.

Prediktor	Modell 3 (mit Persistenz)	Modell 5 (ohne Persistenz)
LJ Threshold	$<2e-16$ ***	$<2e-16$ ***
LJ Sigma	$<2e-16$ ***	$<2e-16$ ***
Lightning Ln	$8.85e-10$ ***	$<2e-16$ ***

Tabelle A.12.: Ergebnisse der mehrfaktoriellen Varianzanalyse der Blitzprediktoren in Form des p-Wertes für die 30-minütige Hagelvorhersage der CellMOS-Gleichung.

Prediktor	Modell 3 (mit Persistenz)	Modell 5 (ohne Persistenz)
LJ Threshold	$<2e-16$ ***	$<2e-16$ ***
LJ Sigma	$<2e-16$ ***	$<2e-16$ ***
Lightning Ln	$<2e-16$ ***	$<2e-16$ ***

### A.2.3. Korrelation der Prediktoren

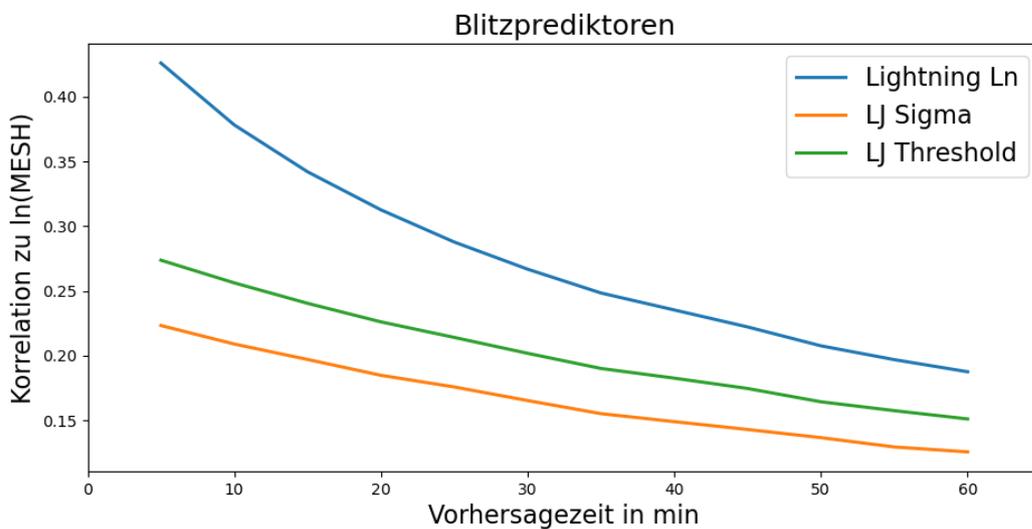


Abb. A.1.: Korrelation der Blitzprädiktoren zu  $\ln(\text{MESH})$  über den Vorhersagezeitraum von 60 min.

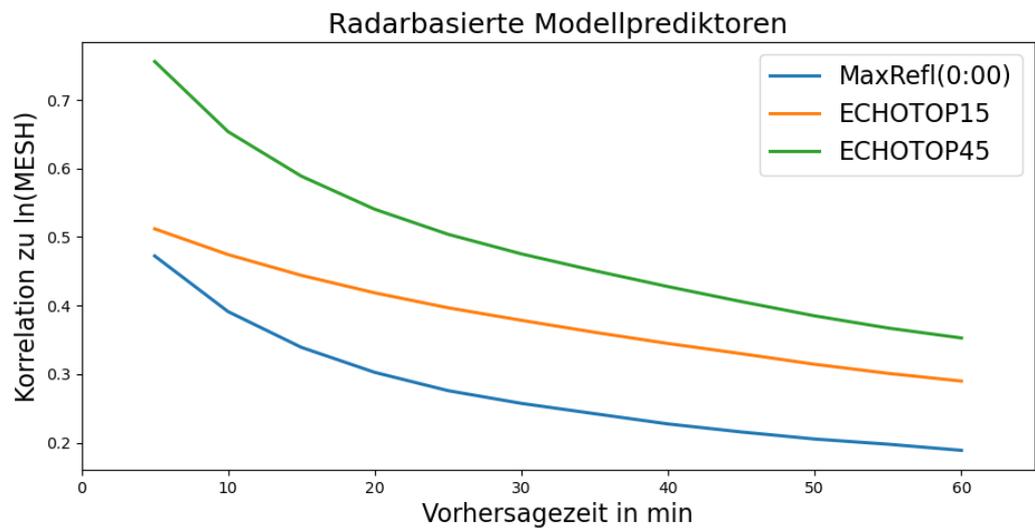


Abb. A.2.: Korrelation der Radarprädiktoren zu  $\ln(\text{MESH})$  über den Vorhersagezeitraum von 60 min.

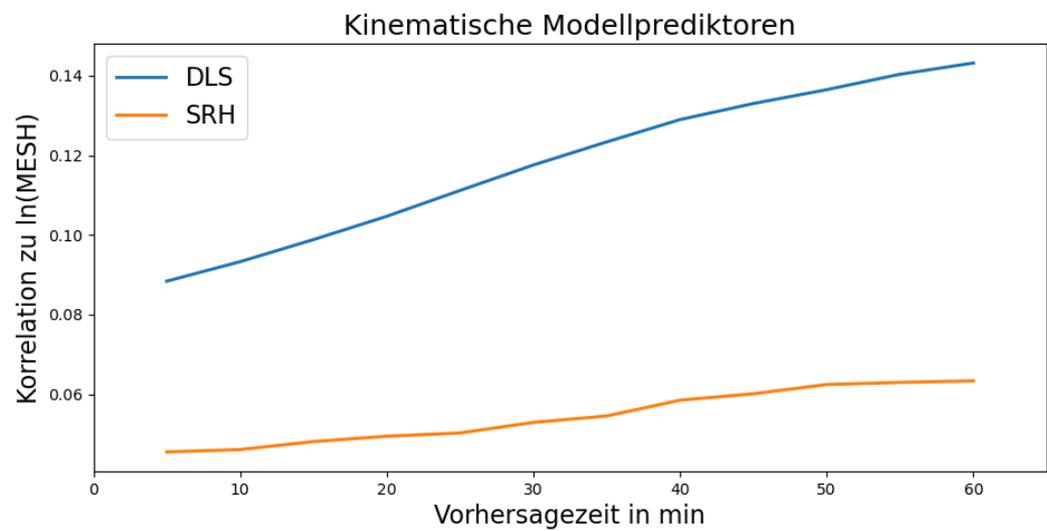


Abb. A.3.: Korrelation der kinematischen Modellprädiktoren zu  $\ln(\text{MESH})$  über den Vorhersagezeitraum von 60 min.

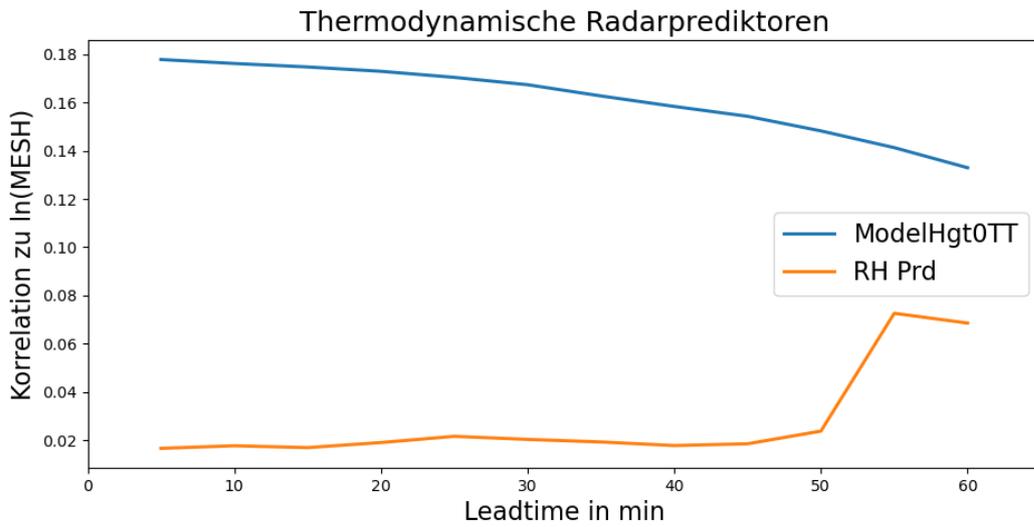


Abb. A.4.: Korrelation der thermodynamischen Modellprädiktoren zu  $\ln(\text{MESH})$  über den Vorhersagezeitraum von 60 min.

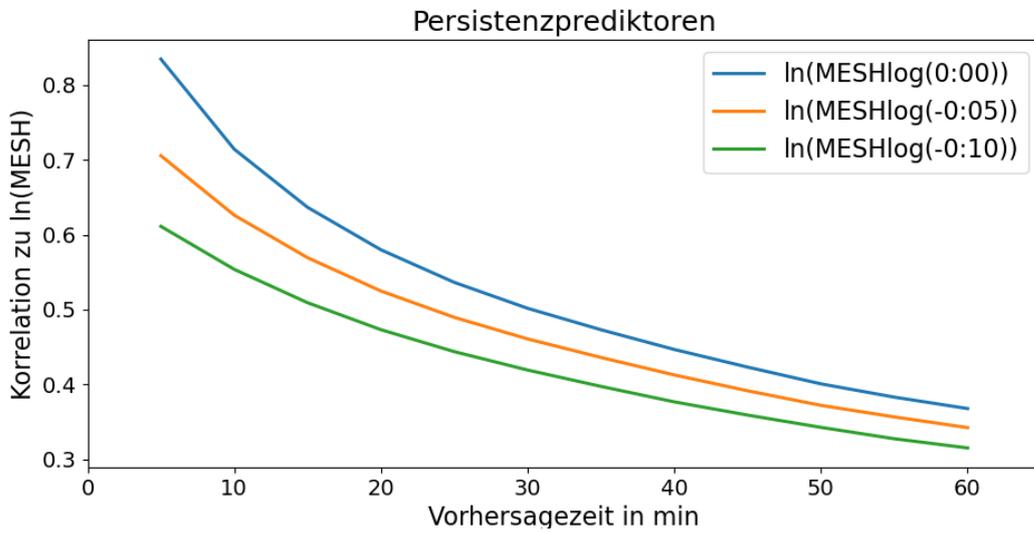


Abb. A.5.: Korrelation der Persistenzprädiktoren zu  $\ln(\text{MESH})$  über den Vorhersagezeitraum von 60 min.

# Literaturverzeichnis

- ESSL. ESWD Meldekriterien, Stand: 2016. URL [https://www.essl.org/cms/wp-content/uploads/20160416-ESWD\\_criteria\\_DE.pdf](https://www.essl.org/cms/wp-content/uploads/20160416-ESWD_criteria_DE.pdf).
- Patrick N. Gatlin. Severe weather precursors in the lightning activity of Tennessee Valley thunderstorms. Master's thesis, The University of Alabama in Huntsville, 2006.
- Patrick N Gatlin and Steven J Goodman. A Total Lightning Trending Algorithm to Identify Severe Thunderstorms. *Journal of atmospheric and oceanic technology*, 27(1): 3–22, 2010. URL <https://doi.org/10.1175/2009JTECHA1286.1>.
- Douglas R Greene and Robert A Clark. Vertically integrated liquid water—a new analysis tool. *Monthly Weather Review*, 100(7):548–552, 1972.
- Jan Hoffmann. *Entwicklung und Anwendung von statistischen Vorhersage-Interpretationsverfahren für Gewitternowcasting und Unwetterwarnungen unter Einbeziehung von Fernerkundungsdaten*. PhD thesis, 2008. URL <http://dx.doi.org/10.17169/refubium-15903>.
- AJ Illingworth, JWF Goddard, and SM Cherry. Detection of hail by dual-polarization radar. *Nature*, 320(6061):431–433, 1986. URL <https://doi.org/10.1038/320431a0>.
- JT Johnson, Pamela L MacKeen, Arthur Witt, E De Wayne Mitchell, Gregory J Stumpf, Michael D Eilts, and Kevin W Thomas. The storm cell identification and tracking algorithm: An enhanced wrs-88d algorithm. *Weather and forecasting*, 13(2):263–276, 1998. URL [https://doi.org/10.1175/1520-0434\(1998\)013%3C0263:TSCIAT%3E2.0.CO;2](https://doi.org/10.1175/1520-0434(1998)013%3C0263:TSCIAT%3E2.0.CO;2).
- K. Knüpper. 2nd European Hail Workshop. In *Hail protection – simply automatic Automatic Hail Detection and Forecasting with MSwr-CellMOS*, page 13, 2017. URL [https://www.oeschger.unibe.ch/services/events/conferences/past\\_conferences/2nd\\_european\\_hail\\_workshop/presentations/index\\_eng.html](https://www.oeschger.unibe.ch/services/events/conferences/past_conferences/2nd_european_hail_workshop/presentations/index_eng.html).
- Petra S. I. Kugel. *Anwendung verschiedener Verfahren zur Detektion von Hagel aus dreidimensionalen C-Band Radardaten*. Department Troposphere Research (IMK-TRO), 2012. URL [https://www.imk-tro.kit.edu/english/4327\\_5419.php](https://www.imk-tro.kit.edu/english/4327_5419.php).
- L Li, Willi Schmid, and J Joss. Nowcasting of Motion and Growth of Precipitation with Radar over a Complex Orography. *Journal of applied meteorology and climatology*, 34(6):1286–1300, 1995. URL [https://doi.org/10.1175/1520-0450\(1995\)034<1286:NOMAGO>2.0.CO;2](https://doi.org/10.1175/1520-0450(1995)034<1286:NOMAGO>2.0.CO;2).

- Mason. *The physics of clouds*. Clarendon Press. Oxford, 1971. URL <https://cir.nii.ac.jp/crid/1130282269415610240>.
- Nelder McCullagh. *Generalized Linear Models*. CRC Press, Boca Raton, Fla, 2 edition, 1989. URL <https://www.utstat.toronto.edu/~brunner/oldclass/2201s11/readings/glmbook.pdf>.
- MeteoSwiss. *Weather Radar Network*, Stand: 2023. URL <https://www.meteoswiss.admin.ch/weather/measurement-systems/atmosphere/weather-radar-network.html>.
- L Nisi, A Hering, U Germann, K Schroeer, H Barras, M Kunz, and O Martius. Hailstorms in the alpine region: Diurnal cycle, 4d-characteristics, and the nowcasting potential of lightning properties. *Quarterly Journal of the Royal Meteorological Society*, 146(733): 4170–4194, 2020.
- Nowcast. *Lightning Detection Network (LINET)*, Stand: 01.12.2023. URL <https://www.nowcast.de/en/solutions/linet-systems/>.
- John M Peters, Christopher J Nowotarski, Jake P Mulholland, and Richard L Thompson. The influences of effective inflow layer streamwise vorticity and storm-relative flow on supercell updraft properties. *Journal of the Atmospheric Sciences*, 77(9):3033–3057, 2020.
- RE Rinehart and ET Garvey. Three-dimensional storm motion detection by conventional weather radar. *Nature*, 273(5660):287–289, 1978. URL <https://doi.org/10.1038/273287a0>.
- Henning Rust. *Statistische Klimatologie - Skript zu den Vorlesungen Einführung in die Statistik und Wahrscheinlichkeitstheorie und Statistische Modelle in den Geowissenschaften*, Stand: 01.11.2023. URL [https://users.met.fu-berlin.de/~HenningRust/teaching/StatKlim\\_Skript.pdf](https://users.met.fu-berlin.de/~HenningRust/teaching/StatKlim_Skript.pdf).
- Christopher J Schultz, Walter A Petersen, and Lawrence D Carey. Preliminary development and evaluation of lightning jump algorithms for the real-time detection of severe weather. *Journal of Applied Meteorology and Climatology*, 48(12):2543–2563, 2009. URL <https://doi.org/10.1175/2009JAMC2237.1>.
- Christopher J Schultz, Walter A Petersen, and Lawrence D Carey. Lightning and severe weather: A comparison between total and cloud-to-ground lightning trends. *Weather and forecasting*, 26(5):744–755, 2011. URL <https://doi.org/10.1175/WAF-D-10-05026.1>.
- Markus Schultze, Tabea Wilke, and Christian Berndt. Radar-based Hail Detection and Hail Size Estimation at DWD. 2023. URL <https://doi.org/10.5194/ecss2023-130>.
- SF-Meteo-Systemguide. *Radar- und Blitzdaten für Cell-MOS*, 2011.

- Reinhold Steinacker, Manfred Dorninger, Friedrich Wölfelmaier, and T Krennert. Automatic Tracking of Convective Cells and Cell Complexes from Lightning and Radar Data. *Meteorology and Atmospheric Physics*, 72:101–110, 2000. URL <https://doi.org/10.1007/s007030050009>.
- Jörg Steinert, Patrick Tracksdorf, and Dirk Heizenreder. Hymec: Surface Precipitation Type Estimation at the German Weather Service. *Weather and Forecasting*, 36(5): 1611–1627, 2021. URL <https://doi.org/10.1175/WAF-D-20-0232.1>.
- Chris Castellano Thilo Kühne. HAIL Size Comparisons for ESWD Reports. ESSL, 2019. URL [https://www.essl.org/cms/wp-content/uploads/ESSL\\_hail\\_size\\_comparisons.pdf](https://www.essl.org/cms/wp-content/uploads/ESSL_hail_size_comparisons.pdf).
- NOAA Virtual Lab. *Maximum Estimated Size of Hail (MESH)*, a. URL <https://vlab.noaa.gov/web/wdtd/-/maximum-estimated-size-of-hail-mes-1>.
- NOAA Virtual Lab. *Severe Hail Index (SHI)*, b. URL <https://vlab.noaa.gov/web/wdtd/-/severe-hail-index-shi->.
- NOAA Virtual Lab. *Vertically Integrated Liquid (VIL)*, c. URL <https://vlab.noaa.gov/web/wdtd/-/vertically-integrated-liquid-vil->.
- A Waldvogel, B Federer, and Peter Grimm. Criteria for the detection of hail cells. *Journal of Applied Meteorology and Climatology*, 18(12):1521–1525, 1979. URL [https://doi.org/10.1175/1520-0450\(1979\)018<1521:CFTDOH>2.0.CO;2](https://doi.org/10.1175/1520-0450(1979)018<1521:CFTDOH>2.0.CO;2).
- K Wapler, M Goeber, and S Trepte. Comparative verification of different nowcasting systems to support optimisation of thunderstorm warnings. *Advances in Science and Research*, 8(1):121–127, 2012.
- Kathrin Wapler. The life-cycle of hailstorms: Lightning, radar reflectivity and rotation characteristics. *Atmospheric Research*, 193:60–72, 2017. ISSN 0169-8095. doi: <https://doi.org/10.1016/j.atmosres.2017.04.009>. URL <https://www.sciencedirect.com/science/article/pii/S0169809516306020>.
- Daniel S Wilks. *Statistical Methods in the atmospheric sciences*. Academic Press, 2011. URL [https://is.gd/wiks\\_2011](https://is.gd/wiks_2011).
- Earle Williams, Bob Boldi, Anne Matlin, Mark Weber, Steve Hodanish, Dave Sharp, Steve Goodman, Ravi Raghavan, and Dennis Buechler. The behavior of total lightning activity in severe florida thunderstorms. *Atmospheric Research*, 51(3-4):245–265, 1999. URL [https://doi.org/10.1016/S0169-8095\(99\)00011-3](https://doi.org/10.1016/S0169-8095(99)00011-3).
- Arthur Witt, Michael D Eilts, Gregory J Stumpf, JT Johnson, E De Wayne Mitchell, and Kevin W Thomas. An enhanced hail detection algorithm for the wrs-88d. *Weather and Forecasting*, 13(2):286–303, 1998. URL [https://doi.org/10.1175/1520-0434\(1998\)013<0286:AEHDAF>2.0.CO;2](https://doi.org/10.1175/1520-0434(1998)013<0286:AEHDAF>2.0.CO;2).

Simon N Wood. *Generalized Additive Models: An Introduction with R*. CRC press, 2017.  
URL <https://is.gd/wood2017>.