

**Methoden zur Beschreibung der Wolkenentwicklung
in Satellitenbildern
und ihre Anwendung zur Solarstrahlungsvorhersage**

Von der Fakultät
Mathematik und Naturwissenschaften der
Carl von Ossietzky Universität Oldenburg
zur Erlangung des Grades einer
Doktorin der Naturwissenschaften
(Dr. rer. nat.)
genehmigte Dissertation

von

Elke Lorenz

geboren am
7. Juni 1968 in Rehau

Erstgutachter: Prof. Dr. Jürgen Parisi

Zweitgutachterin: Prof. Dr. Ulrike Feudel

Tag der Disputation: 22. 1. 2004

Inhaltsverzeichnis

| | | |
|----------|---|-----------|
| 1 | Einleitung | 6 |
| 2 | Berechnung der Solarstrahlung aus Satellitendaten | 10 |
| 2.1 | Meteosat-Satellitenbilder | 10 |
| 2.2 | Heliosat-Methode | 11 |
| 2.2.1 | Normierung der Satellitencounts | 11 |
| 2.2.2 | Cloud-Index | 12 |
| 2.2.3 | Clearsky-Index | 12 |
| 2.2.4 | Clearsky-Modell und Globalstrahlung | 13 |
| 3 | Vorhersage von Wolkenbildern mit neuronalen Netzen | 15 |
| 3.1 | Grundlagen der zur Vorhersage verwendeten Methoden | 16 |
| 3.1.1 | Theoretische Grundlagen neuronaler Netze | 16 |
| 3.1.2 | Theorie der Hauptkomponenten-Transformation | 20 |
| 3.2 | Anwendung von neuronalen Netzen zur Vorhersage von Bewölkungsbildern | 23 |
| 3.2.1 | Konstruktion von Eingabe-Ausgabe-Paaren für das neuronale Netz | 23 |
| 3.2.2 | Hauptkomponenten-Transformation von Cloud-Index Bildern | 24 |
| 3.2.3 | Klassifizierung der Cloud-Index Bilder | 25 |
| 3.2.4 | Vorhersagealgorithmus unter Verwendung von neuronalen Netzen und Hauptkomponenten-Transformation | 25 |
| 3.3 | Definition der Fehlerfunktion | 28 |
| 3.4 | Test der Vorhersagemethode an einfachen Beispielen | 28 |
| 3.4.1 | Verschiebung einer einfachen, künstlichen Struktur | 29 |
| 3.4.2 | Verschiebung eines Bewölkungsbildes | 30 |
| 3.5 | Datenbasis für die Vorhersage von Cloud-Index Bildern | 31 |

| | | |
|----------|--|-----------|
| 3.6 | Bestimmung der optimalen Parameter | 32 |
| 3.6.1 | Kriterien zur Unterscheidung verschiedener Typen von Cloud-Index Bildern | 32 |
| 3.6.2 | Festlegung der Netzarchitektur und des Lernverfahrens | 36 |
| 3.7 | Ergebnisse und Fehleranalyse | 47 |
| 4 | Vorhersage von Wolkenbildern mit Bewegungsvektoren | 53 |
| 4.1 | Methoden zur Bestimmung von Bewegungsvektoren | 54 |
| 4.1.1 | Statistische Methode | 54 |
| 4.1.2 | Minimierung mittlerer quadratischer Pixeldifferenzen | 58 |
| 4.2 | Anwendung von Bewegungsvektorfeldern zur Vorhersage | 59 |
| 4.2.1 | Extrapolation der Bewegung | 59 |
| 4.2.2 | Berücksichtigung der Veränderung von Wolkenstrukturen | 60 |
| 4.2.3 | Überblick über den Vorhersagealgorithmus | 61 |
| 4.3 | Bestimmung der optimalen Parameter | 61 |
| 4.3.1 | Parameter für Bewegungsvektorfelder auf der Basis minimaler mittlerer quadratischer Pixeldifferenzen | 63 |
| 4.3.2 | Parameter zur nachträglichen Bearbeitung der vorhergesagten Cloud-Index Bilder | 65 |
| 4.4 | Ergebnisse und Fehleranalyse | 67 |
| 4.5 | Kombination von neuronalen Netzen mit Bewegungsinformation | 72 |
| 5 | Genauigkeitsanalyse der Einstrahlungsvorhersage | 74 |
| 5.1 | Datenbasis | 75 |
| 5.2 | Methoden der Fehleranalyse | 76 |
| 5.2.1 | Fehlermaße | 76 |
| 5.2.2 | Grundlagen der zweidimensionalen Fehleranalyse | 78 |
| 5.3 | Fehleranalyse für Einzelstandorte | 80 |
| 5.3.1 | Vergleich des Fehlers der Heliosat-Methode mit dem Fehler der Bewölkungsvorhersage | 80 |
| 5.3.2 | Zweidimensionale Fehleranalyse der Heliosat-Methode | 81 |
| 5.3.3 | Fehleranalyse der Vorhersage | 92 |
| 5.4 | Fehleranalyse für eine Region | 101 |
| 5.4.1 | Regionale Fehleranalyse der Heliosat-Methode | 101 |
| 5.4.2 | Fehleranalyse der Vorhersage | 103 |

| | |
|--|------------|
| 6 Zusammenfassung und Ausblick | 106 |
| 7 Anhang | 108 |
| 7.1 Korrelation der Vorhersage mit Bodenmeßwerten im Vergleich zur Persistenz für einzelne Standorte | 108 |
| 7.2 Korrelation der Vorhersage mit Bodenmeßwerten im Vergleich zur Persistenz für regionale Vorhersagen | 111 |

Kapitel 1

Einleitung

Eine Vorhersage der Solarstrahlung stellt für viele Bereiche der Solarenergienutzung einen wichtigen Beitrag dar, eine effiziente und wirtschaftliche Anwendung dieser Energiequelle zu ermöglichen.

Die Produktion von Solarenergie ist aufgrund der Abhängigkeit von meteorologischen Randbedingungen, in erster Linie der Solarstrahlung, starken Fluktuationen unterworfen. Dies führt zur Unsicherheiten der Verfügbarkeit, was für viele Anwendungen zu Problemen führt. Mit einer zuverlässigen Vorhersage der Solarstrahlung läßt sich die solare Energieproduktion für einen bestimmten Zeitraum im Voraus abschätzen. Dies ermöglicht eine an die variable Energieproduktion angepaßte Steuerung von Systemen mit einem hohen Anteil an Solarenergie. Zur Steuerung eines solchen Systems gehört auf der einen Seite ein Last- und Speichermanagement, auf der anderen Seite ist die rechtzeitige Bereitstellung zusätzlicher Energiequellen notwendig, wenn der Energiebedarf nicht vollständig solar gedeckt werden kann. Für die Wirtschaftlichkeit ist es dabei entscheidend, daß die Zusatzenergieproduktion den tatsächlichen Bedarf nicht unnötig überschreitet.

An zwei Anwendungsbeispielen soll näher erläutert werden, wie eine Vorhersage der solaren Einstrahlung die zuverlässige und wirtschaftliche Anwendung von Solarenergie unterstützen kann. Die Infrastruktur zukünftiger elektrischer Netze wird durch dezentral einspeisende Erzeuger und einen hohen Anteil an erneuerbaren Energien bestimmt sein. Dabei ist angestrebt, daß die Einspeisung von Solarstrom im nächsten Jahrzehnt stark zunimmt. Um das Zusammenspiel der regelbaren Erzeuger und Verbraucher mit dem diskontinuierlichen Energieangebot von Wind und Sonne regeln zu können, sind entsprechende Wetter- und Leistungsprognosen unumgänglich. Zur Kraftwerkseinsatzplanung werden ein bis zwei Tage im voraus Leistungsfahrpläne erstellt, in die, neben Lastprognosen, Vorhersageinformationen über die erwartete Wind- und Solarleistung integriert werden. Unvorhergesehene Verbraucherlasten oder Fehleinschätzung der Wind- und Solarleistungsproduktion rufen Differenzen zu den veranschlagten 15-Minuten-Leistungsfahrplänen hervor. Mit Wind- und Solarleistungsprognosen für Zeiträume von einigen Stunden werden diese Differenzen frühzeitig festgestellt, und Ausgleichsmaßnahmen können rechtzeitig eingeleitet werden.

Ein weiteres wichtiges Anwendungsgebiet der Solarstrahlungsvorhersage ist der Einsatz im Rah-

men der thermischen Steuerung von Gebäuden (siehe [Nygard-Ferguson 2000]). Eine Vorhersage der Solarstrahlung in Kombination mit einer Temperaturvorhersage unterstützt die Steuerung von Systemen, die auf entsprechende Steuerungsmaßnahmen nur träge reagieren. Träge Reaktionen können dabei u.a. durch langsame Transportvorgänge oder durch begrenzte Leistung von Heiz- und Kühlsystemen bedingt sein. Vorhersageinformationen sind, entsprechend den Zeitkonstanten der Reaktionszeit des Systems, im Bereich von einigen Stunden bis hin zu wenigen Tagen erforderlich. Sie tragen dazu bei, daß die Energiezufuhr oder -abfuhr vorausschauend mit den anderen Energieströmen, wie Transmissions- und Lüftungsverlusten oder solaren Gewinnen bzw. Überschüssen, so kombiniert werden kann, daß die Innentemperatur möglichst nahe am Idealwert liegt.

Für beide dieser Anwendungen sind Vorhersageinformationen über die solare Einstrahlung auf verschiedenen zeitlichen Skalen, von einigen Stunden bis hin zu Tagen, von Interesse. Für die Vorhersage der Solarstrahlung für Zeiträume von einigen Tagen wurde ein Verfahren auf der Basis von numerischen Wetter Vorhersage Modellen von [Jenseniuss 1989] entwickelt. Die vorliegende Arbeit befaßt sich mit Kurzzeitvorhersagen der Solarstrahlung für Vorhersagezeiträume bis zu 6 Stunden.

Eine grundlegende Voraussetzung für die Vorhersage der solaren Einstrahlung ist die Kenntnis der aktuellen Einstrahlung und ihrer zeitlichen Entwicklung. Der neben dem deterministischen Tagesgang bestimmende Faktor für die Solarstrahlung am Boden ist der Bewölkungsgrad. Zur Beschreibung der zeitlichen Entwicklung der Bewölkung, die in hohem Maß durch Bewegung von Wolkenstrukturen beeinflusst ist, ist Information mit hoher räumlicher und zeitlicher Auflösung notwendig. So ist die Genauigkeit von Vorhersageverfahren, die ausschließlich auf Bodenmeßwerten beruhen (z.B. [Chowdhury 1987]), wegen fehlender räumlicher Information prinzipiell begrenzt. Dagegen kann aus Satellitendaten Information, sowohl über Bewölkung als auch über Globalstrahlung, mit hoher räumlicher und zeitlicher Auflösung gewonnen werden. Die Vorhersage der Solarstrahlung wurde in dieser Arbeit deshalb auf der Basis von Satellitendaten durchgeführt. Die entwickelten Verfahren zur Solarstrahlungsprognose beruhen auf einer Vorhersage der Wolkenentwicklung in Satellitenbildern.

Zur Beschreibung der Wolkenentwicklung in Satellitenbildern wurden zwei verschiedene Ansätze gewählt. Zum einen wurde ein Verfahren unter Verwendung von neuronalen Netzen entwickelt. Dies stellt in dieser Form einen neuen Ansatz zur Beschreibung der Wolkenentwicklung dar. Dieser Ansatz ist dadurch motiviert, daß neuronale Netze bereits in vielen Gebieten zur Bearbeitung komplexer Probleme mit Erfolg eingesetzt wurden.

Die zeitliche Entwicklung der Bewölkungssituation ist wesentlich von der Bewegung von Wolkenstrukturen bestimmt. So wurden bereits von [Beyer et al. 1994], [Bahner et al. 1996] und [Cote et al. 1995] Verfahren zur Beschreibung der Wolkenentwicklung über die Bestimmung von Bewegungsvektorfeldern eingesetzt. In der vorliegenden Arbeit werden eine statistische Methode und eine Methode, die auf der Minimierung mittlerer quadratischer Pixeldifferenzen beruht, zur Berechnung von Bewegungsvektorfeldern aus aufeinander folgenden Satellitenbildern untersucht. Die Vorhersage der Bewölkungssituation erfolgt durch Extrapolation der Bewegung in die Zukunft. Auf die optimale Anpassung der Vorhersageverfahren an die verschiedenen Vorhersagezeiträume, die im Bereich von 30 Minuten bis zu 6 Stunden liegen, wurde dabei besonderes Gewicht ge-

legt. Von den betrachteten Methoden zur Beschreibung der Bewölkungsentwicklung wurde die am besten geeignete als Basis für die Vorhersage der Solarstrahlung am Boden ausgewählt.

Ein Schwerpunkt dieser Arbeit liegt in der Genauigkeitsanalyse der Vorhersagemethode. Für die Anwendung der Vorhersage ist es wichtig, die mit der Vorhersage verbundene Unsicherheit möglichst genau zu kennen. Ein Standardverfahren zur Abschätzung der Genauigkeit einer Vorhersage besteht in der Angabe von mittleren Vorhersagefehlern. Darüber hinaus werden im Rahmen dieser Arbeit Situationen unterschiedlicher Vorhersagequalität unterschieden. Damit kann das Potential der Vorhersage in Situationen mit hoher Vorhersagegenauigkeit voll genutzt werden, da die Vorhersagefehler nicht, wie bei der Angabe eines mittleren Fehlers, überschätzt werden. Auf der anderen Seite werden in Situationen, die schwer vorhersagbar sind und deren Vorhersagegenauigkeit unterhalb der mittleren Genauigkeit liegt, die Vorhersagefehler nicht unterschätzt. Die Charakterisierung von Situationen mit verschiedener Vorhersagequalität trägt so dazu bei, daß die Vorhersage effizient eingesetzt werden kann.

Nach der Einleitung wird im zweiten Kapitel dieser Arbeit zunächst eine Einführung in das Heliosat-Verfahren gegeben, das zur Berechnung der Solarstrahlung aus Satellitendaten verwendet wird. Ein Zwischenprodukt des Heliosat-Verfahrens stellen Bilder des Cloud-Index dar, die die Bewölkung charakterisieren. Auf Basis der Cloud-Index Bilder erfolgt die Vorhersage der Bewölkungsentwicklung mit zwei verschiedenen Verfahren. Das erste dieser beiden Verfahren, der Vorhersagealgorithmus auf der Basis von neuronalen Netzen, wird im dritten Kapitel vorgestellt. Nach einer Darstellung der theoretischen Grundlagen wird auf den Einsatz und die Anpassung des Verfahrens zur Vorhersage von Cloud-Index Bildern eingegangen und die Ergebnisse werden diskutiert. Der zweite Ansatz zur Vorhersage der Wolkenentwicklung über die Bestimmung von Bewegungsvektoren wird im vierten Kapitel beschrieben. Dort werden zunächst zwei Verfahren zur Bestimmung von Bewegungsvektoren und ihre Anwendung zur Vorhersage vorgestellt. Zur Auswertung wurden die Ergebnisse der beiden Modelle zur Bestimmung von Bewegungsvektoren und die Vorhersageergebnisse mit neuronalen Netzen verglichen. Um eine Vorhersage der Bodeneinstrahlung zu erhalten, wird aus den vorhergesagten Cloud-Index Bildern mit dem Heliosat-Verfahren die Solarstrahlung abgeleitet. Die Genauigkeit dieser Vorhersage wird in Kapitel 5 untersucht, wobei besonderes Gewicht auf der Unterscheidung von Situationen verschiedener Vorhersagequalität liegt. Eine Zusammenfassung der Ergebnisse erfolgt in Kapitel 6. Eine Zuordnung der Kapitel dieser Arbeit zu den entsprechenden Verfahrensschritten der Vorhersage der Solarstrahlung ist in Abb. 1.1 gegeben.

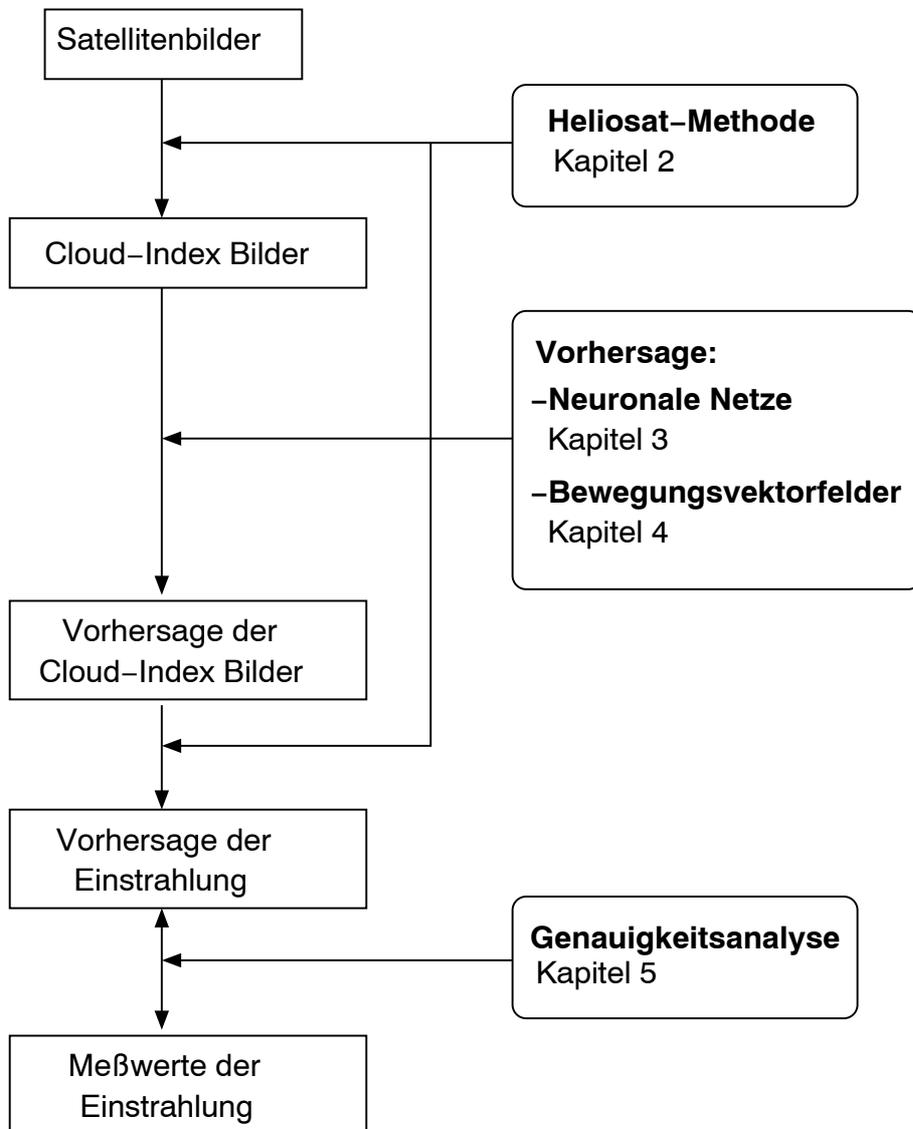


Abbildung 1.1: Überblick über die einzelnen Schritte des Vorhersagealgorithmus und Zuordnung zu den Kapiteln dieser Arbeit.

Kapitel 2

Berechnung der Solarstrahlung aus Satellitendaten

Wie in der Einleitung dargelegt, stellen Satellitendaten, aus denen Information über die Einstrahlung in hoher räumlicher und zeitlicher Auflösung gewonnen werden kann, eine geeignete Datenbasis für die Solarstrahlungsvorhersage dar. Zur Bestimmung der Globalstrahlung am Boden aus Satellitendaten wurde eine modifizierte Version der ursprünglich in [Cano et al. 1986] entwickelten Heliosat-Methode verwendet. Modifikationen zur Verbesserung des Verfahrens wurden u.a. in [Costanzo 1995], [Hammer 2000] und [Dumortier 1995] durchgeführt.

Das Heliosat-Verfahren beruht wesentlich auf der unterschiedlichen Reflektion der Solarstrahlung durch Wolken und Boden. So ist das vom Satelliten empfangene Rückstreusignal von der Atmosphäre und vom Boden dadurch bestimmt, wie hoch der Bewölkungsanteil im jeweils betrachteten Raumwinkel ist, und aus dem Satellitenmeßwert läßt sich ein Maß für den Bewölkungsgrad ableiten. Aus dem Bewölkungsgrad kann direkt auf die Transmissionseigenschaften der Atmosphäre geschlossen und die Bodeneinstrahlung berechnet werden.

In Abschnitt 2.1 werden zunächst grundlegende Informationen zu den in dieser Arbeit verwendeten Satellitenbildern gegeben. Der darauf folgende Abschnitt 2.2 befaßt sich mit der Heliosat-Methode und beschreibt die einzelnen Verfahrensschritte zur Berechnung der Globalstrahlung.

2.1 Meteosat-Satellitenbilder

Als Datenbasis für diese Arbeit wurden Bilder der europäischen Wettersatelliten-Reihe Meteosat verwendet, die von der Eumetsat ¹ betrieben wird. Die Satelliten befinden sich geostationär über 0° N, 0° O. Es werden Bilder der gesamten, dem Satelliten zugewandten Erdhalbkugel aufgenommen, auf denen u.a. Europa und Afrika zu sehen sind.

¹European Organisation for the Exploitation of Meteorological Satellites

Ein Überblick über die wichtigsten technischen Daten der Satelliten, wie räumliche und zeitliche Auflösung und Spektralbereiche der verschiedenen Radiometer, ist in Tabelle 2.1 gegeben.

| Position: geostationär, 35 800 km Höhe, 0° N, 0° O | | | |
|--|---------------------|--|----------------|
| Radiometer | zeitliche Auflösung | räumliche Auflösung am Sub Satellite Point | Detektoren |
| 0.5 – 0.9µm VIS | 30 min | 2.5 × 2.5 km ² | Si-Photodioden |
| 5.7 – 7.1µm WV | 30 min | 5 × 5 km ² | HgCdTe |
| 10.5 – 12.5µm IR | 30 min | 5 × 5 km ² | HgCdTe |

Tabelle 2.1: Technische Informationen zu Meteosat (aus [Hammer 2000]).

Zur Bestimmung der Einstrahlung werden die Bilder des sichtbaren Spektralbereichs (VIS) genutzt, die als Grauwerte zwischen 0 und 255 (8bit Counts) gespeichert sind. Die Berechnungen in dieser Arbeit beruhen auf Bildausschnitten von Mitteleuropa, wo die räumliche Auflösung ca. 3 × 5 km² beträgt.

2.2 Heliosat-Methode

Zur Berechnung von Bodenwerten der Globalstrahlung aus Satellitenbildern wird das Heliosat-Verfahren verwendet. Ausgehend von den Satellitenmeßwerten wird zunächst durch eine Normierung die relative Reflektivität bestimmt, die das Reflexionsvermögen von Erdatmosphäre und Boden für einen Raumwinkelbereich charakterisiert. In einem nächsten Schritt wird der Cloud-Index als Maß für den Bewölkungsgrad berechnet. Daraus leitet sich über eine im wesentlichen lineare Beziehung der Clearsky-Index als Maß für die Transmissivität der Atmosphäre ab. Unter Verwendung eines Clearsky-Modells zur Bestimmung der Einstrahlung bei klarem Himmel ergibt sich schließlich die Bodeneinstrahlung. Im Folgenden werden die einzelnen Verfahrensschritte kurz erläutert, eine ausführliche Darstellung findet sich in [Hammer 2000].

2.2.1 Normierung der Satellitencounts

Der Satellitencount bezeichnet das am Satelliten gemessene Rückstreusignal der Solarstrahlung von Erde und Erdatmosphäre. Nach Abzug eines Offsets C_0 ist der Satelliten-Count C proportional zu der reflektierten Einstrahlung G und zum Reflexionsvermögen der reflektierenden Schichten. So läßt sich als normierter Rückstreuwert die relative Reflektivität ρ definieren:

$$\rho := \frac{C - C_0}{G}. \quad (2.1)$$

Der Offset C_0 des Satellitensignals, der bei klarem Himmel über dem Meer gemessen wird, setzt sich dabei aus zwei Komponenten zusammen:

$$C_0 = C_{off} + C_{atm}. \quad (2.2)$$

Der das Instrument charakterisierende Radiometeroffset C_{off} wird dabei auf $C_{off} = 5$ gesetzt ([Moulin et al. 1996]). Der Atmosphärenoffset C_{atm} beschreibt die Schwächung der Strahlung durch Streuung auf dem Weg durch die Atmosphäre bei wolkenlosem Himmel, die von der Weglänge durch die Atmosphäre abhängig ist. Entsprechend variiert der Atmosphärenoffset mit dem Sonnenstand und der Position des Satelliten zum betrachteten Pixel (siehe [Hammer 2000]).

2.2.2 Cloud-Index

Die im vorangehenden Abschnitt definierte relative Reflektivität ist für Boden und Wolken deutlich verschieden. So zeigen Wolken eine hohe Albedo (= relative Reflektivität) ρ_c , während das Rückstreusignal vom Boden ρ_g , mit Ausnahme von schneebedecktem Boden, geringe Werte annimmt. Diese Tatsache wird zur Bestimmung des Bewölkungsgrads eines Pixels genutzt. Dabei wird davon ausgegangen, daß sich die relative Reflektivität für ein bestimmtes Pixel aus einem bewölkten und einem unbewölkten Anteil zusammensetzt:

$$\rho = n\rho_c + (1 - n)\rho_g. \quad (2.3)$$

Durch den Cloud-Index n , der beschreibt, welcher Anteil eines Pixel bewölkt ist, ist ein Maß für den Bewölkungsgrad gegeben. Die Referenzwerte für die Bodenreflektivität ρ_g werden als minimale Werte einer Zeitreihe für das Rückstreusignal bestimmt. Da die Bodenreflektivität sowohl örtlich als auch mit der Jahres- und Tageszeit variiert, werden für die Bodenalbedo monatliche Karten für die verschiedenen Tageszeiten berechnet. Der Referenzwert für die Wolkenalbedo ρ_c ist als Maximum der normierten Rückstreuwerte definiert und wird als konstant angenommen. Mit Gleichung (2.3) ergibt sich die Definition des Cloud-Index zu:

$$n = \frac{\rho - \rho_g}{\rho_c - \rho_g}. \quad (2.4)$$

2.2.3 Clearsky-Index

Als Maß für die Transmissivität der Atmosphäre wird der Clearsky-Index als Verhältnis der tatsächlichen Einstrahlung zu der bei unbewölktem Himmel erwarteten Einstrahlung definiert:

$$k^* := \frac{G}{G_{cl}}. \quad (2.5)$$

Die Transmission durch die Atmosphäre ist direkt mit dem Bewölkungsgrad korreliert. [Costanzo 1995] nahm eine lineare Beziehung zwischen Clearsky-Index und Cloud-Index an:

$$k^* = 1 - n. \quad (2.6)$$

Diese Relation wurde von [Fontoynt et al. 1998] unter besonderer Berücksichtigung der Verhältnisse bei vollständig bewölktem Himmel zu

$$k^* = \begin{cases} 1.2 & \text{für } n \leq -0.2 \\ 1 - n & \text{für } -0.2 < n \leq 0.8 \\ 2.0667 - 3.6667n + 1.6667n^2 & \text{für } 0.8 < n \leq 1.1 \\ 0.05 & \text{für } 1.1 < n \end{cases} \quad (2.7)$$

modifiziert. Durch diese Beschreibung wird wiedergegeben, daß auch bei vollständig bedecktem Himmel die Einstrahlung noch etwa 5% der entsprechenden Clearsky-Einstrahlung beträgt.

2.2.4 Clearsky-Modell und Globalstrahlung

Nach Berechnung der Transmissivität durch die Atmosphäre erfolgt als letzter Schritt die Bestimmung der Globalstrahlung am Boden über die Beziehung

$$G = k \cdot G_{clear}. \quad (2.8)$$

Die Einstrahlung bei wolkenlosem Himmel G_{clear} wird über ein Clearsky-Modell berechnet, in das der Einfallswinkel der Strahlung, Streuung auf dem Weg durch die Atmosphäre und die Weglänge der Strahlung durch die Atmosphäre eingehen. Der Einfluß von Streueffekten bei klarem Himmel wird durch den Linke-Trübungsfaktor T_L charakterisiert, der ein Maß für die Trübung der Atmosphäre darstellt ([Linke 1922]). Gemäß [Hammer 2000] wird die Clearsky-Strahlung dabei als Summe aus Direkt- und Diffusstrahlung aufgefaßt:

$$G_{clear}(T_L) = G_{dir}(T_L) \cos \theta + G_{diff}(T_L). \quad (2.9)$$

Beide Komponenten dieser Gleichung hängen dabei von Sonnenstand und Trübung ab. Die Direktstrahlung wird nach [Page 1996] berechnet, die Diffusstrahlung ergibt sich nach der Parametrisierung von [Dumortier 1995].

An Gleichung (2.9) wird deutlich, daß die Modellierung der Trübung, die sowohl zeitlich als auch räumlich variabel ist, einen wichtigen Faktor für ein optimal angepaßtes Clearsky-Modell darstellt. Die mittlere jahreszeitliche Schwankung der Trübung wird in dem empirischen Modell von [Bourges 1992] durch die Gleichung

$$T_L = T_0 + u \cdot \cos((2\pi/365) \cdot J) + v \cdot \sin((2\pi/365) \cdot J) \quad (2.10)$$

beschrieben, wobei J für den Tag des Jahres steht. Die Parameter T_0 , u und v wurden von [Dumortier 1998] für 13 verschiedene europäische Trübungszonen angepaßt.

Ein Überblick über die Schritte zur Berechnung der Globalstrahlung aus Satellitendaten ist in Abb. 2.1 gegeben. Aus einer Zeitreihe von Bildern werden Karten der Bodenalbedo bestimmt. Diese werden als Referenzwerte für die Bestimmung des Cloud-Index genutzt. Aus dem Cloud-Index ergibt sich über die Berechnung des Clearsky-Index und unter Anwendung eines Clearsky-Modells die Globalstrahlung am Boden.

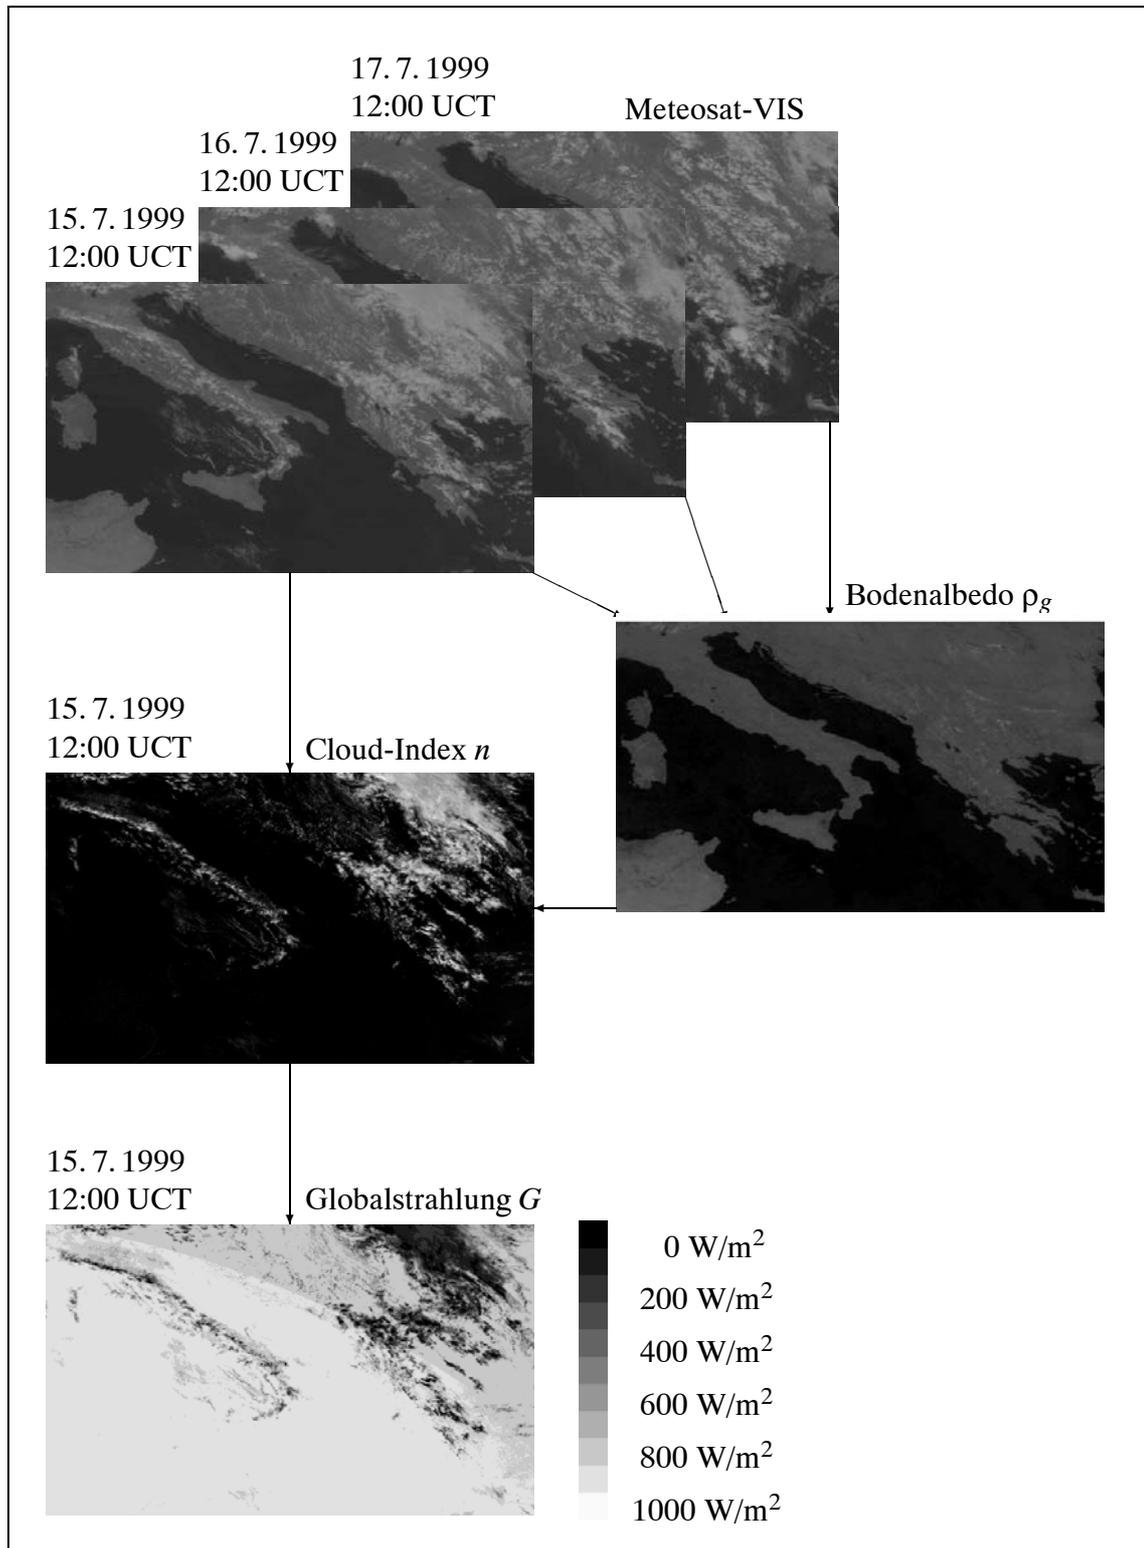


Abbildung 2.1: Für die Bestimmung der Globalstrahlung verwendete Satellitenbilder und Produkte der Heliosat-Methode. Die Bodenalbedo wurde aus 17 aufeinanderfolgenden 12:00-Bildern bestimmt. Aus einem Vergleich des Original-Bildes mit der Bodenalbedo erhält man den Cloud-Index und daraus schließlich die Globalstrahlung (aus [Hammer 2000]).

Kapitel 3

Vorhersage von Wolkenbildern mit neuronalen Netzen

Die Entwicklung von Bewölkungsstrukturen ist ein komplexer Vorgang, bei dem verschiedene Phänomene überlagert sind. Bestimmend sind advektive Prozesse, die zu einer Verlagerung der Strukturen führen, sowie lokale, oft thermische, Einflüsse, die zur Veränderung der Strukturen führen. Die Beschreibung dieser Vorgänge in einem mathematischen Modell ist nur mit starken Vereinfachungen möglich, so wird z.B. bei der in Kapitel 4 beschriebenen Methode im Wesentlichen die Wolkenbewegung berücksichtigt.

Mit neuronalen Netzen können prinzipiell komplexe und hochdimensionale deterministische Probleme erkannt und modelliert werden, ohne daß der zugrundeliegende Zusammenhang explizit bekannt sein muß. Neuronale Netze lernen den funktionalen Zusammenhang durch Beispielpaare. Die Idee bei der Verwendung von neuronalen Netzen zur Vorhersage der Entwicklung von Wolkenstrukturen liegt darin, daß alle zugrunde liegenden Phänomene gemeinsam beschrieben werden können und keine vereinfachenden Annahmen gemacht werden müssen.

Als Eingabe des Netzes werden die wesentlichen Informationen über die Bewölkungssituation aus zwei aufeinander folgenden Satellitenbildern verwendet und das darauf folgende, vorherzusagende Bild wird als Ausgabe des Netzes berechnet. Dabei ist es jedoch nicht möglich, genügend große Ausschnitte von Satellitenbildern direkt als Eingabe zu verwenden, da dies zu viel zu großen Eingabedimensionen führen würde. Die Bildausschnitte werden vor der Eingabe in das Netz durch Hauptkomponentenanalyse (engl.: principle component analysis, PCA) transformiert, so daß in wenigen Komponenten die erforderliche Information enthalten ist. Zusätzlich zur Reduktion der Eingabedimension hat dies den Vorteil, daß kleinskalige Strukturen, die von Bild zu Bild nicht erhalten bleiben und somit auch nicht vorhergesagt werden können, herausgefiltert werden.

In diesem Kapitel wird zunächst eine kurze Einführung in neuronale Netze und die Hauptkomponentenanalyse gegeben und das Vorhersagemodell unter Verwendung dieser Methoden beschrieben. Anschließend folgt ein Test des Verfahrens an einfachen, künstlich generierten Beispielen. Um ein an das vorliegende Problem optimal angepaßtes neuronales Netz zu erhalten, muß eine Vielzahl von Parametern eingestellt werden, was im nächsten Abschnitt dargestellt wird. Das Kapitel

wird durch eine Fehleranalyse der vorgestellten Methode abgeschlossen, wobei die Vorhersage der Bewölkung für Vorhersagezeiträume bis zu 2 Stunden ausgewertet wird.

3.1 Grundlagen der zur Vorhersage verwendeten Methoden

3.1.1 Theoretische Grundlagen neuronaler Netze

Neuronale Netze bestehen aus einer großen Anzahl von einfachen grundlegenden Einheiten, den Neuronen, die Information über gewichtete Verbindungen weitergeben. Dies ermöglicht eine effektive parallele Datenverarbeitung, mit der auch komplexe Aufgaben schnell bearbeitet werden können. Ein weiterer wichtiger Aspekt von neuronalen Netzen ist ihre Lernfähigkeit. Neuronale Netze können an Beispielpaaren lernen, eine Eingabe auf eine bestimmte Ausgabe abzubilden, ohne daß die zugrunde liegende Funktion, die Eingabe und Ausgabe verbindet, bekannt ist. Dabei wird vorausgesetzt, daß es sich um ein deterministisches System handelt, stochastische Abbildungen können nicht wiedergegeben werden. Die Darstellung der Grundlagen ist an [Zell 1999] und [Hausmann und Hoffmann 1995] angelehnt. Dort findet sich auch eine ausführliche Beschreibung des biologischen Vorbilds der Signalverarbeitung im Gehirn.

Wesentliche Merkmale der biologischen neuronalen Netze, die als Motivation für das mathematische Modell dienen, sind:

- Das System ist aus einer großen Zahl einfacher Einzelbausteine, den Neuronen, aufgebaut.
- Die einzelnen Neuronen erhalten ihre Eingabe als gewichtete Summe von anderen Neuronen und von außen. Überschreitet die Eingabe einen Schwellwert, gibt das Neuron ein Signal weiter, entweder zu anderen Zellen oder nach außen.
- Die Signalweitergabe zwischen den Neuronen erfolgt über gerichtete und verschieden stark gewichtete Verbindungen.
- Die Lernfähigkeit des Systems beruht darauf, daß sich die Stärke der Gewichte modifizieren läßt und durch Training einem bestimmten Zusammenhang angepaßt werden kann.

Im Folgenden wird zunächst das mathematische Modell für ein einzelnes Neuron dargestellt. Anschließend wird die Verbindung der Neuronen zu einem Feed-Forward-Netzwerk beschrieben und schließlich der verwendete Lernalgorithmus zum Training der neuronalen Netze erläutert.

Modell eines Neurons

Ein Neuron erhält seine Eingabe i als gewichtete Summe von Eingabesignalen:

$$i = \sum_{i=1}^N w_i x_i. \quad (3.1)$$

Ist der Eingabewert größer als ein vorgegebener Schwellwert, hat das Neuron eine positive Ausgabe. Dies wird im Modell wie folgt realisiert: Um die Ausgabe o eines Neurons zu erhalten, wird von der Eingabe i ein Schwellwert Θ abgezogen. Auf das Ergebnis wird eine, häufig sigmoide, Aktivierungsfunktion σ angewandt und eventuell noch mit einer Amplitude o_0 multipliziert:

$$o(i, \Theta) = o_0 \sigma(i - \Theta) = o_0 \sigma \left(\sum_{i=1}^N w_i x_i - \Theta \right). \quad (3.2)$$

Für Simulationen ist es vorteilhaft, den variablen Schwellwert als zusätzliches Neuron mit konstanter Ausgabe eins zu modellieren. Die Eingabe des Neurons wird damit zu:

$$i = \sum_{i=1}^{N+1} w_i x_i \quad \text{mit} \quad w_{N+1} = -\Theta, x_{N+1} = 1. \quad (3.3)$$

Die Berechnungen in dieser Arbeit wurden mit der logistischen Funktion als Aktivierungsfunktion durchgeführt und die Ausgangsamplitude $o_0 = 1$ gesetzt. Für die Ausgabe des Neurons ergibt sich so:

$$o(i) = \sigma(i) = \frac{1}{1 + e^{-i}} = \frac{1}{1 + e^{-\sum_{i=1}^{N+1} w_i x_i}}. \quad (3.4)$$

Zur Bearbeitung komplexer nichtlinearer Probleme werden viele Neuronen in einem Netzwerk verbunden.

Feed-Forward-Netze

In einem neuronalen Netz sind die Neuronen in verschiedenen Schichten angeordnet. Daraus ergibt sich eine Unterscheidung von verschiedenen Zelltypen:

- Über Eingabeneuronen wird die Eingabe von außen in das Netz aufgenommen.
- Neuronen der Ausgabeschicht geben die Ausgabe des Netzes nach außen weiter.
- Die verdeckten Neuronen der Zwischenschicht(en) haben keine Verbindung nach außen, sie dienen der Informationsverarbeitung innerhalb des Netzes.

In Feed-Forward-Netzen wird die Information von den Neuronen der jeweils vorausgehenden zu den nachfolgenden Schichten über gewichtete Verbindungen weitergeleitet (siehe Abb. 3.1). Es treten keine rückwärtsgerichteten Verbindungen oder Verknüpfungen innerhalb einer Schicht auf, so daß keine Rückkopplung der Neuronen mit sich selbst stattfindet. Für die meisten Anwendungen werden die Neuronen ebenenweise von einer Schicht zur nächsten verbunden. Es ist aber auch möglich, die Neuronen der aufeinander folgenden Schichten nicht alle miteinander zu verbinden oder über 'short-cut connections' Ebenen zu überspringen.

Für ein Feed-Forward-Netz muß festgelegt werden, wie viele Schichten das Netz hat, welche Anzahl an Neuronen in jeder Schicht liegen und welche Neuronen miteinander verknüpft sind. Ist

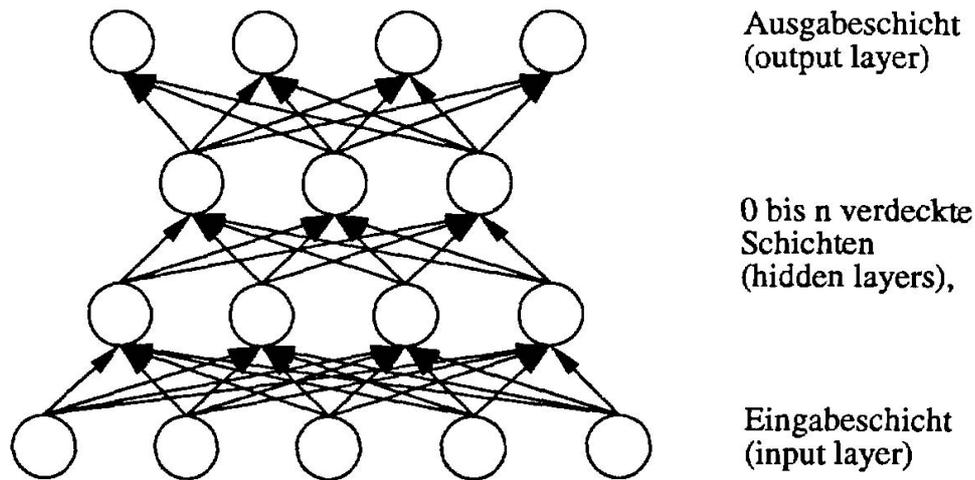


Abbildung 3.1: Schematische Darstellung eines Feed-Forward-Netzes (aus [Zell 1999]).

die Netzarchitektur für ein gegebenes Problem festgelegt, müssen noch die Gewichte so eingestellt werden, daß aus einer Eingabe die gewünschte Ausgabe möglichst genau reproduziert werden kann. Dieser Vorgang wird als Training des Netzes bezeichnet. Die optimale Netzarchitektur für ein Problem kann durch systematischen Vergleich der Ergebnisse auf einer Testmenge für verschiedene trainierte Netzwerke ermittelt werden.

Lernverfahren: Backpropagation

Ziel des Lernens ist es, die Verbindungen im Neuronalen Netz so einzustellen, daß sie an ein vorgegebenes Problem angepaßt sind und den Zusammenhang zwischen Ein- und Ausgabe möglichst genau approximieren. Bei überwachtem Lernen werden die Gewichte zunächst für eine Trainingsmenge von Ein- und Ausgabepaaren optimiert. Der gelernte Zusammenhang kann dann auf unbekannte Eingabemuster übertragen werden, wobei man davon ausgeht, daß für diese die gleiche Abbildungsvorschrift gilt, wie für die Trainingsmenge.

Die Optimierung der Gewichte erfolgt nach dem folgenden Prinzip: Zunächst werden die Gewichte initialisiert. Dann werden die nachfolgenden Schritte wiederholt, bis das Verfahren konvergiert oder eine maximale Anzahl von Trainingsschritten erreicht ist:

- Präsentation der Eingabe
- Berechnung der Ausgabe
- Vergleich der berechneten Ausgabe mit der gewünschten Ausgabe über eine Fehlerfunktion
- Veränderung der Gewichte zur Minimierung der Fehlerfunktion mit einem Gradientenabstiegsverfahren

Diese Schritte werden im Weiteren für das in dieser Arbeit verwendete Trainingsverfahren spezifiziert und näher ausgeführt, wobei der Schwerpunkt auf dem Verfahren zur Minimierung der Fehlerfunktion liegt. Zunächst muß festgelegt werden, ob die Gewichte nach der Präsentation aller Beispiele der Trainingsmenge geändert werden (offline- oder batch-Verfahren) oder ob nach der Präsentation jedes einzelnen Musters eine Veränderung der Gewichte erfolgt (online-Verfahren). In dieser Arbeit wurde mit dem online-Verfahren gerechnet, da diese Methode sich praktisch zur Durchführung von Simulationen als geeignet erwiesen hat ([Zell 1999]). Dementsprechend hängt die Fehlerfunktion E nur von dem jeweiligen Beispielpaar (\vec{x}, \vec{y}) und dem Gewichtsvektor \vec{w} ab:

$$E(\vec{w}) = \frac{1}{2} \sum_{i=1}^N (y_i - N_{\vec{w},i}(\vec{x}))^2 = \frac{1}{2} \sum_{i=1}^N (y_i - o_i)^2, \quad (3.5)$$

wobei N die Dimension des Ausgabevektors bezeichnet.

Diese Fehlerfunktion soll nun mit einem Gradientenabstiegsverfahren minimiert werden:

$$\Delta \vec{w} = -\eta \nabla E(\vec{w}). \quad (3.6)$$

Die Lernschrittweite η legt dabei fest, wie weit die Gewichte in Richtung des negativen Gradienten, also in Richtung des Minimums, verändert werden. Wird die Lernschrittweite zu groß gewählt, kann das Minimum verfehlt werden, wird sie zu klein gewählt, dauert das Verfahren sehr lange, bis Konvergenz erreicht wird.

Aus Gleichung (3.6) ergibt sich für die Änderung der Verbindung w_{ij} von Neuron i zu Neuron j :

$$\Delta w_{ij} = -\eta \frac{\partial}{\partial w_{ij}} E(\vec{w}). \quad (3.7)$$

Die Ableitung der Fehlerfunktion bezüglich der Gewichte wird mit der Kettenregel berechnet:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial i_j} \frac{\partial i_j}{\partial w_{ij}} = \delta_j o_i \quad \text{mit} \quad \delta_j = \frac{\partial E}{\partial i_j}, \quad (3.8)$$

wobei Gleichung (3.3) benutzt wurde.

Für die Ausgabeneuronen ist die gewünschte Ausgabe für die Muster der Trainingsmenge bekannt. Der Fehler $\frac{\partial E}{\partial o_j}$ und damit δ_j läßt sich unter Verwendung der Gleichungen (3.4) und (3.5) direkt berechnen:

$$\delta_j = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial i_j} = (y_j - o_j) \sigma'(i_j). \quad (3.9)$$

Für die Neuronen der versteckten Schicht ist die Ausgabe nicht direkt festgelegt, δ_j kann nur indirekt bestimmt werden. Die Abhängigkeit des Fehlers von der Ausgabe j einer Zelle ergibt sich als Summe der gewichteten Fehler δ_k der n Zellen der nachfolgenden Schicht:

$$\delta_j = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial i_j} = \sigma'(i_j) \sum_{k=1}^n \frac{\partial E}{\partial i_k} \frac{\partial i_k}{\partial o_j} = \sigma'(i_j) \sum_{k=1}^n \delta_k w_k. \quad (3.10)$$

So lassen sich die Fehlersignale δ_j rekursiv für die verschiedenen Schichten berechnen, wobei das Fehlersignal von der Ausgabeschicht rückwärts weitergegeben wird (backpropagation).

Zusammengefaßt ergibt sich für die Änderung der Gewichte:

$$\begin{aligned} \Delta w_{ij} &= -\eta o_i \delta_j \\ \text{mit } \delta_j &= \begin{cases} (y_j - o_j) \sigma'(i_j) & \text{für Ausgabeneuronen} \\ \sigma'(i_j) \sum_{k=1}^n \delta_k w_k & \text{für versteckte Neuronen} \end{cases} \end{aligned} \quad (3.11)$$

Die Gewichtsänderungen werden in jedem Trainingsschritt für jeweils alle Muster der Trainingsmenge durchgeführt.

Das Verfahren wird bei Konvergenz oder nach einer maximalen Anzahl von Trainingsschritten beendet. Es wird davon ausgegangen, daß die Fehlerfunktion dann ein Minimum erreicht hat. Bei der Minimierung der Fehlerfunktion können Probleme auftreten, die darauf zurückzuführen sind, daß es sich bei dem backpropagation-Algorithmus um ein lokales Verfahren handelt. Die Änderung der Gewichte bezieht über die Berechnung der Gradienten nur die unmittelbare Umgebung des betrachteten Punktes und nicht die gesamte Fehlerfläche ein. Auf einen Lösungsansatz für dieses Problem wird in Abschnitt 3.6 im Rahmen der optimalen Anpassung von Neuronalen Netzen an die Vorhersage näher eingegangen.

Ist der Lernprozeß für ein neuronales Netz beendet, ist durch das Netz der funktionale Zusammenhang zwischen Ein- und Ausgabe parametrisiert. Das trainierte Netz kann nun zur Berechnung der Ausgabe für neue Eingabemuster verwendet werden.

3.1.2 Theorie der Hauptkomponenten-Transformation

Wie in der Einleitung dieses Kapitels beschrieben, erfordert die Verwendung von neuronalen Netzen zur Beschreibung der Entwicklung der Bewölkungsstrukturen Vorverarbeitung der Satellitenbilder. Der Informationsgehalt der Bilder bezüglich Wolkenstrukturen wird dem neuronalen Netz in komprimierter Form präsentiert, so daß Eingabe- und Ausgabedimension des Netzes möglichst klein bleiben.

Zur Datenkompression wurde die im Folgenden beschriebene Hauptkomponenten-Transformation verwendet. Ziel dabei ist es, die in einem Vektor enthaltene Information durch möglichst wenige Komponenten einerseits und bei möglichst geringem Informationsverlust andererseits wiederzugeben. Dies wird durch Hauptkomponentenanalyse wie folgt realisiert: Es wird eine neue orthogonale Basis bestimmt, die an eine Menge von Vektoren so angepaßt ist, daß für einen zufällig ausgewählten Vektor der erwartete Fehler, wenn der Vektor durch eine vorgegebene Anzahl von Komponenten repräsentiert wird, kleiner ist, als für alle andere Basissysteme. In Abb 3.2 ist dies an einem zwei-dimensionalen Beispiel veranschaulicht. In dem Koordinatensystem (\vec{x}, \vec{y}) ist der Fehler sehr groß, wenn ein Vektor nur durch die x -Komponente beschrieben wird, während im Koordinatensystem (\vec{x}', \vec{y}') die Vektoren durch Angabe der x' -Koordinate deutlich besser repräsentiert werden.

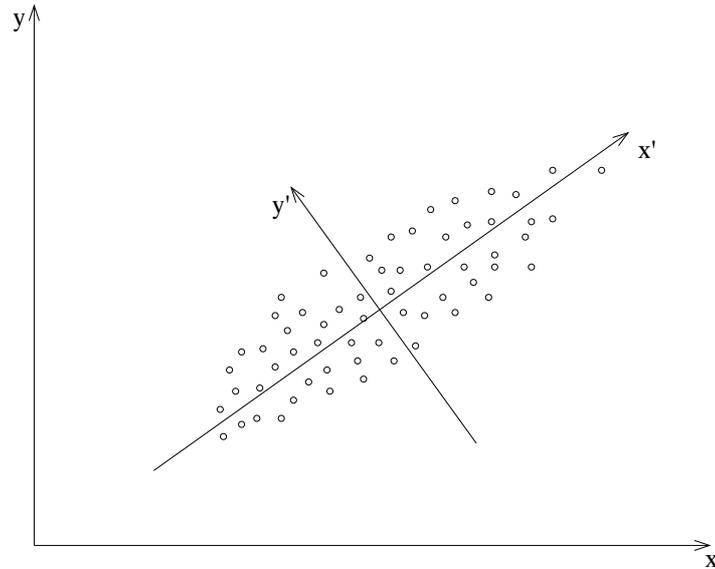


Abbildung 3.2: Veranschaulichung des Prinzips der Hauptkomponentenanalyse in 2 Dimensionen.

Im Folgenden wird, der Beschreibung in [Fukunaga 1972] folgend, dargestellt, wie das optimale Basissystem ermittelt wird. Ein n -dimensionaler Zufallsvektor \mathbf{X} läßt sich in einem orthonormalen Basissystem Φ darstellen als

$$\mathbf{X} = \sum_{i=1}^n y_i \Phi_i = \Phi \mathbf{Y}$$

mit $\Phi = [\Phi_1 \dots \Phi_n]$ und $\mathbf{Y} = [y_1 \dots y_n]^T$. (3.12)

Die Komponenten von \mathbf{Y} sind unter Verwendung der Orthogonalität von Φ dann gegeben als

$$y_i = \Phi_i^T \mathbf{X}, \tag{3.13}$$

wobei \mathbf{Y} als orthonormale Transformation des Vektors \mathbf{X} ebenfalls einen Zufallsvektor darstellt. \mathbf{X} soll nun durch die Verwendung von $m < n$ Komponenten von \mathbf{Y} abgeschätzt werden. Die Komponenten, die nicht angegeben werden, werden durch vorher festgelegte Konstanten ersetzt, so daß sich

$$\tilde{\mathbf{X}}(m) = \sum_{i=1}^m y_i \Phi_i + \sum_{i=m+1}^n b_i \Phi_i \tag{3.14}$$

ergibt.

Der Fehler in dieser Darstellung berechnet sich zu:

$$\Delta \mathbf{X}(m) = \mathbf{X} - \tilde{\mathbf{X}}(m) = \mathbf{X} - \sum_{i=1}^m y_i \Phi_i - \sum_{i=m+1}^n b_i \Phi_i = \sum_{i=m+1}^n (y_i - b_i) \Phi_i. \tag{3.15}$$

Sowohl $\tilde{\mathbf{X}}$ als auch $\Delta\mathbf{X}$ sind dabei Zufallsvektoren. Als Maß für die Qualität der Abschätzung wird der mittlere quadratische Fehler von $\Delta\mathbf{X}$ angenommen:

$$\begin{aligned}\bar{\varepsilon}^2(m) &= E\{\|\Delta\mathbf{X}(m)\|^2\} \\ &= E\left\{\sum_{i=m+1}^n \sum_{j=m+1}^n (y_i - b_i)(y_j - b_j)\Phi_i^T \Phi_j\right\} \\ &= \sum_{j=m+1}^n E\{(y_i - b_i)^2\},\end{aligned}\quad (3.16)$$

wobei E für den Erwartungswert der Zufallsgröße steht. Der Fehler hängt von der Wahl des Basissystems und den konstanten Termen b_i ab. Diese sollen nun so gewählt werden, daß $\bar{\varepsilon}^2(m)$ minimiert wird. Bei vorgegebenem Basissystem Φ ergibt sich unter Verwendung von

$$\frac{\partial}{\partial b_i} E\{(y_i - b_i)^2\} = -2[E\{y_i\} - b_i] = 0 \quad (3.17)$$

die optimale Wahl für b_i zu

$$b_i = E\{y_i\} = \Phi_i^T E\{\mathbf{X}\}, \quad (3.18)$$

d.h. die Komponenten von \mathbf{Y} , die nicht angegeben sind, werden durch ihre Erwartungswerte ersetzt. Mit Gleichung (3.16) folgt dann für den mittleren quadratischen Fehler:

$$\begin{aligned}\bar{\varepsilon}^2(m) &= \sum_{j=m+1}^n E[y_i - E\{y_i\}]^2 \\ &= \sum_{j=m+1}^n \Phi_i^T E[(\mathbf{X} - E\{\mathbf{X}\})(\mathbf{X} - E\{\mathbf{X}\})^T] \Phi_i \\ &= \sum_{j=m+1}^n \Phi_i^T \Sigma_x \Phi_i.\end{aligned}\quad (3.19)$$

Dabei ist $\Sigma_x = E[(\mathbf{X} - E\{\mathbf{X}\})(\mathbf{X} - E\{\mathbf{X}\})^T]$ die Kovarianzmatrix von \mathbf{X} . Es läßt sich zeigen (siehe [Fukunaga 1972]), daß die optimale Basis aus den Eigenvektoren der Kovarianzmatrix besteht, die

$$\Sigma_x \Phi_i = \lambda_i \Phi_i \quad (3.20)$$

erfüllen. Der minimale erwartete Fehler beträgt so

$$\bar{\varepsilon}^2(m) = \sum_{j=m+1}^n \lambda_j. \quad (3.21)$$

Wird eine Komponente y_i im Basissystem der Eigenvektoren durch den entsprechenden Erwartungswert b_i ersetzt, so erhöht sich der Fehler um λ_i . Die Komponenten sollten demzufolge der Größe der zugehörigen Eigenwerte entsprechend berücksichtigt werden. Werden die Basisvektoren Φ_i so angeordnet, daß

$$\lambda_1 > \lambda_2 > \dots > \lambda_n > 0 \quad (3.22)$$

gilt, erhält man die bestmögliche Repräsentation eines Zufallsvektors \mathbf{X} mit nur m Komponenten, wenn der Vektor durch die ersten m Komponenten im Basissystem der Eigenvektoren der Kovarianzmatrix dargestellt wird.

3.2 Anwendung von neuronalen Netzen zur Vorhersage von Bewölkungsbildern

Nach der Darstellung der theoretischen Grundlagen der verwendeten Methoden im vorangehenden Abschnitt wird in diesem Abschnitt darauf eingegangen, wie diese Methoden zur Vorhersage von Bewölkungsbildern eingesetzt werden können. Wesentliche Punkte sind hierbei die Konstruktion von Eingabe-Ausgabe-Paaren für das neuronale Netz, die Anwendung der Hauptkomponenten-Transformation auf die Satellitenbilder und eine Klassifizierung der Satellitenbilder.

3.2.1 Konstruktion von Eingabe-Ausgabe-Paaren für das neuronale Netz

Voraussetzung dafür, daß neuronale Netze zur Vorhersage von Bewölkung angewendet werden können, ist, daß zwischen dem vorherzusagenden Bewölkungsbild und der Eingabe ein funktionaler Zusammenhang besteht. Dieser Zusammenhang wird empirisch durch Anpassung von Gewichten an Beispielpaare approximiert. So erhält man eine Vorhersagefunktion, die dann auf neue Situationen angewendet werden kann. Dabei ist es auf der einen Seite um so schwerer, die optimale Vorhersagefunktion numerisch zu finden, je mehr freie Parameter festgelegt werden müssen. Auf der anderen Seite müssen jedoch genügend freie Parameter vorhanden sein, um den gesuchten Zusammenhang zu beschreiben. Einen wichtigen Einfluß hat hier die Konstruktion der Eingabe-Ausgabe-Paare. Die Eingabevariablen sollen einerseits alle für die Berechnung der Ausgabe wichtigen Informationen enthalten, andererseits sollte ihre Anzahl aber so gering wie möglich bleiben. Dies kann zum Beispiel durch die Vernachlässigung vergleichsweise unwichtiger Variablen oder durch Mittelung über mehrere Variablen erreicht werden.

Die zur Verfügung stehende Informationsquelle zur Berechnung eines zukünftigen Bewölkungsbildes sind gegenwärtige und vergangene Bewölkungsbilder. Dabei wurden in einem ersten Ansatz als Eingabe Ausschnitte des gegenwärtigen und des 30 Minuten zurückliegenden Bildes verwendet. Es wurde auch untersucht, drei aufeinander folgende Bilder als Eingabe zu nutzen oder den zeitlichen Abstand der Bilder auf eine Stunde zu erhöhen. Da dies jedoch zu keiner Verbesserung führte, wurde der ursprüngliche Ansatz beibehalten.

Neben der Anzahl und dem zeitlichen Abstand der als Eingabe verwendeten Bildausschnitte ist die Größe der Eingabe- und Ausgabebildausschnitte ein weiterer Wert, der festgelegt werden muß. Da Bewegung ein wesentliches Element der Bewölkungsentwicklung ist, müssen die Eingabebildausschnitte so groß gewählt werden, daß die Wolken, die sich bis zum Vorhersagezeitpunkt in den relevanten Teil des vorherzusagenden Bildausschnitt verschieben können, im Bildausschnitt enthalten sind. Die Ausschnitte der Eingabebilder und des Ausgabebildes wurden gleich groß gewählt. Versuche mit verschiedenen großen Bildausschnitten, bei denen die Eingabebildausschnitte, entsprechend einer angenommenen maximalen Geschwindigkeit der Wolkenbewegung, größer als der Ausgabebildausschnitt gewählt wurden, ergaben keine Verringerung der Vorhersagefehler. Abschätzungen bezüglich einer Mindestgröße der Bildausschnitte in Abschnitt 3.6 ergaben, daß genügend große Bildausschnitte mehrere tausend Pixel umfassen. Werden die einzelnen Pixel direkt als Eingabe für das neuronale Netz verwendet, führt dies zu einer viel zu hohen Anzahl

von freien Parametern, und die numerische Suche nach den optimalen Gewichten ist nicht mehr durchführbar.

Die in den Bildausschnitten enthaltene Information muß also über eine geringere Anzahl von Eingabevariablen weitergegeben werden. Die erste Frage, die sich hier stellt, ist, welche Anteile dieser Information für die Berechnung des Vorhersagebildes wichtig bzw. unwichtig sind. Je kleinskaliger die Strukturen sind, desto schneller verändern sie sich. Werden Bilder im Abstand von 30 Minuten oder mehr betrachtet, läßt sich für Strukturen, die durch Variation von Bewölkung im Bereich von wenigen Pixeln charakterisiert sind, kein deterministischer Zusammenhang für die verschiedenen Zeitpunkte erkennen. Dies läßt darauf schließen, daß Information über sehr kleinskalige Strukturen vernachlässigt werden kann, ohne die Vorhersagequalität zu beeinträchtigen. Dies könnte u.a. auch durch Verwendung von Fourier- oder Wavelet-Moden als Eingabe für das neuronale Netz realisiert werden. Für diese Arbeit wurde die an eine bestimmte Menge von Bildern optimal angepaßte Hauptkomponenten-Transformation eingesetzt.

3.2.2 Hauptkomponenten-Transformation von Cloud-Index Bildern

Um für die Bewölkungsbilder durch Hauptkomponenten-Analyse eine optimale Basis zu finden, werden die Bildausschnitte als eindimensionale Vektoren aufgefaßt, indem die einzelnen Bildzeilen aneinandergereiht werden. So kann das in Abschnitt 3.1.2 beschriebene Verfahren angewendet werden. Als Grundlage für die Hauptkomponenten-Analyse dient eine feste Menge A von Bildausschnitten. Die aktuellen Bilder, die zur Vorhersage genutzt werden, sind nicht Teil dieser Menge. Sie lassen sich nur dann gut durch die für die Menge A ermittelte Basis repräsentieren, wenn in A eine dem aktuellen Bild ähnliche Situation enthalten war. Die Menge A muß deshalb genügend Bildausschnitte umfassen.

Für die Verarbeitung im neuronalen Netz werden sowohl die Eingabe- als auch die Ausgabebilder als Hauptkomponenten-Transformierte dargestellt. Abb. 3.3 zeigt an einem Beispiel, neben einem Cloud-Index-Bildausschnitt in voller Auflösung, die Hauptkomponenten-transformierten Bilder unter Verwendung von 20 bzw. 90 Moden ($\hat{=}$ Komponenten). Es wird deutlich, daß durch die Vernachlässigung der höheren Komponenten die kleinskaligen Strukturen unterdrückt werden. In dem Bild, das aus 20 Moden rekonstruiert wurde, wird die Bewölkungsstruktur nur sehr grob wiedergegeben, für 90 Moden ist die Darstellung wesentlich detaillierter. Die Anordnung der Basisvektoren nach dem Beitrag zum mittleren Fehler entspricht auch einer Anordnung nach der Größe der Strukturen, die durch die jeweiligen Moden repräsentiert werden.

Die für die Vorhersage relevante Information kann durch eine Anzahl von Moden dargestellt werden, die im Bereich von zehn bis mehreren Hundert liegt. Dies ist gegenüber der Repräsentation durch mehrere tausend Pixel eine große Verbesserung. In Kapitel 3.6 wird zur Vorhersage verwendete Anzahl von Moden in Abhängigkeit vom Vorhersagezeitraum bestimmt.

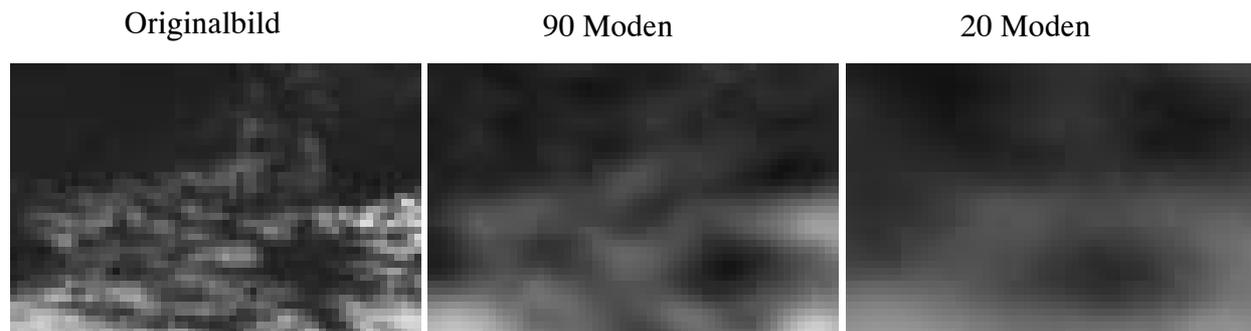


Abbildung 3.3: Beispiel eines Hauptkomponenten-transformierten Cloud-Index Bildausschnitts vom 1.6.1997, 14:00 Uhr, von links nach rechts: Originalbild, aus 90 Moden rekonstruiertes Bild, aus 20 Moden rekonstruiertes Bild.

3.2.3 Klassifizierung der Cloud-Index Bilder

Eine durch Hauptkomponenten-Analyse festgelegte Basis ist für eine bestimmte Menge von Bildern optimal. Je ähnlicher sich diese Bilder sind, desto weniger Moden reichen aus, um die Bilder bei gleichem mittleren Fehler zu beschreiben. Das legt nahe, die Bewölkungsbilder in verschiedene Klassen einzuteilen, innerhalb derer sich die Bilder weniger unterscheiden, und für jede Klasse eine eigene Basis zu suchen. Die Klassen müssen dabei so allgemein bleiben, daß sich auch die bei der Vorhersage auftretenden neuen Strukturen einordnen lassen.

Auch für die Beschreibung der Bewölkungsentwicklung mit neuronalen Netzen kann es vorteilhaft sein, wenn ähnliche Ausgangssituationen zusammen gefaßt werden. Voraussetzung dabei ist es, daß in jeder Klasse genügend Trainings-Beispiele zur Verfügung stehen, so daß das neuronale Netz nicht an spezielle Situationen überangepaßt wird. Es ergaben sich gute Ergebnisse für die Unterteilung in vier Klassen (siehe Abschnitt 3.6). Für jede Klasse wurde eine eigene Basis ermittelt und ein eigenes Netz trainiert. Die Kriterien für die Klassifikation sind in Abschnitt 3.6 dargestellt.

3.2.4 Vorhersagealgorithmus unter Verwendung von neuronalen Netzen und Hauptkomponenten-Transformation

Der Algorithmus zur Vorhersage von Cloud-Index Bildern setzt sich aus verschiedenen, aufeinander folgenden Teilen zusammen. Ein Überblick, wie die Vorhersagefunktion berechnet und der Vorhersagealgorithmus auf die Bewölkungsbilder angewendet wird, ist in Abbildung 3.4 gegeben.

Im oberen Teil der Graphik ist dargestellt, wie die verschiedenen Verfahrensschritte aneinandergefügt werden, um zunächst die Vorhersagefunktion zu bestimmen. Dabei wird davon ausgegangen, daß die Parameter bezüglich der Klassifizierung und der Netzarchitektur bereits festgelegt sind. Im ersten Schritt wird die zugrunde liegende Menge von Bildausschnitten nach Bewölkungssituation in vier Klassen unterteilt. Für jede der Klassen wird mit Hauptkomponenten-Analyse

eine Basis bestimmt. Dann folgt für jede Klasse die Transformation der Cloud-Index Bilder in die entsprechende Basis. Nach Klassen getrennt werden die komprimierten Bilder dann zu Bildfolgen von jeweils drei Bildern (zwei Eingabebilder, ein Ausgabebild) zusammengestellt. Die Bildfolgen für die verschiedenen Klassen ergeben die Trainingsmengen für die neuronalen Netze. Als letzter Schritt wird für jede Klasse ein neuronales Netz trainiert.

Der untere Teil der Graphik zeigt den eigentlichen Vorhersagealgorithmus. Die aufeinander folgenden Bildausschnitte, die als Grundlage für die Vorhersage dienen, werden zunächst einer Klasse zugeordnet. Mit der zu dieser Klasse gehörenden Basis wird die Hauptkomponenten-Transformation vorgenommen, und die Bilder werden komprimiert. Die komprimierten Bilder dienen als Eingabe für das Netz der entsprechenden Klasse, das Vorhersagebild ergibt sich als Ausgabe des Netzes. Abschließend wird das vorhergesagte Bild in die ursprüngliche Basis, die der Ortsdarstellung entspricht, zurücktransformiert.

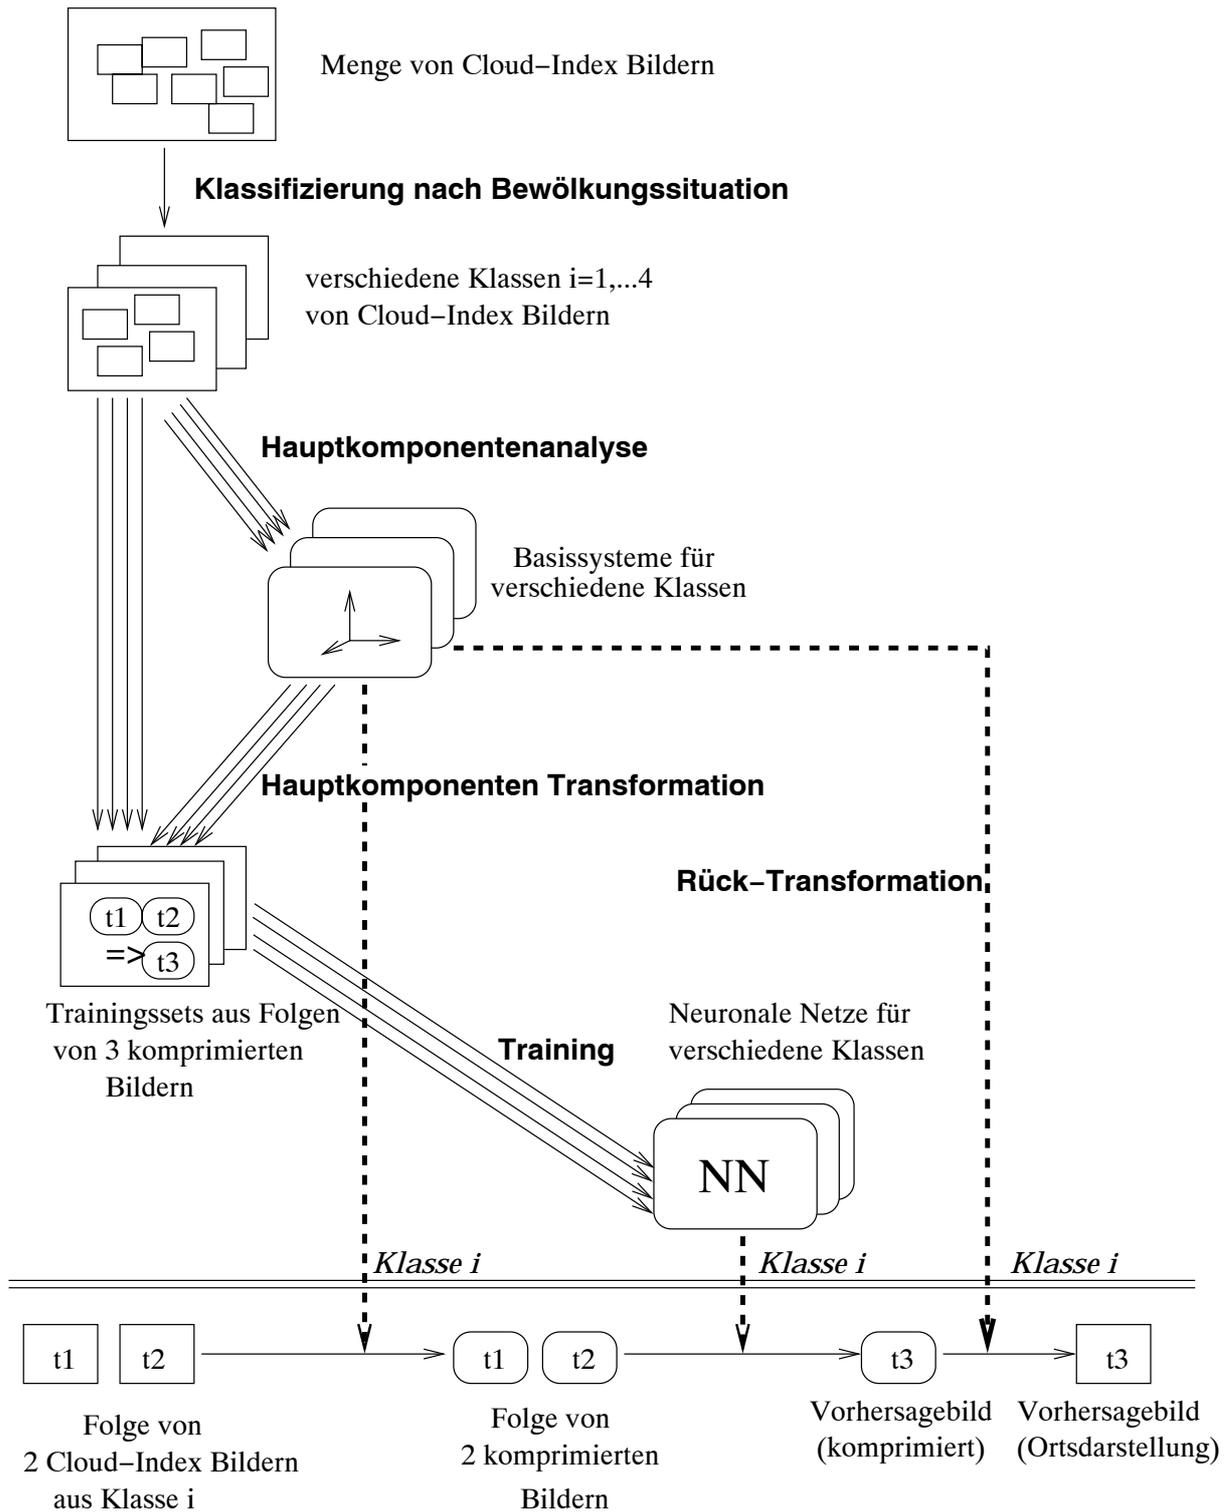


Abbildung 3.4: Schematische Darstellung der Berechnung der Vorhersagefunktion und des Vorhersagealgorithmus unter Verwendung von neuronalen Netzen.

Zur Überprüfung der Vorhersagequalität werden auf einer Testmenge die vorhergesagten mit den tatsächlichen Bildern verglichen. So läßt sich durch systematische Variation der freien Parameter die Vorhersagequalität für verschiedene Eingabe-Ausgabe-Paare, Netzarchitekturen und Klassifikationskriterien vergleichen und die optimale Parameterkonfiguration bestimmen (siehe Abschnitt 3.6).

3.3 Definition der Fehlerfunktion

Eine Bewertung der Vorhersagequalität ist, abgesehen von der abschließenden Auswertung, auch wichtig, um die beste Vorhersagefunktion zu bestimmen.

Die Güte der Vorhersage einer Einzelsituation läßt sich durch Vergleich der Vorhersage mit der tatsächlich eingetretenen Situation ermitteln. Dazu wird die Wurzel des mittleren quadratischen Fehlers (engl. root mean square error: *rmse*) zwischen dem vorhergesagten Bild und dem Originalbild zum Vorhersagezeitpunkt gebildet:

$$rmse = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x'_i)^2}, \quad (3.23)$$

wobei x_i die Werte der Pixel des Originalbildes, x'_i die Werte der Pixel des vorhergesagten Bildes zum entsprechenden Zeitpunkt und N die Anzahl der Bildpunkte bezeichnen.

Die Vorhersagefehler variieren stark für verschiedene Situationen. Um eine Vorhersagefunktion zu bewerten, wird deshalb der mittlere Vorhersagefehler ε für eine Zeitreihe berechnet:

$$\varepsilon = \frac{1}{M} \sum_{j=1}^M rmse(j). \quad (3.24)$$

Dabei ist M die Anzahl der ausgewerteten Vorhersagen und $rmse(j)$ der Fehler für das j -te Beispiel der Testserie. Der Fehler, der sich durch die Darstellung der Bildausschnitte als Hauptkomponenten-Transformierte ergibt, ist analog definiert, anstelle der Vorhersagebilder treten hier die aus einer reduzierten Anzahl von Moden rücktransformierten Bilder. Die Fehler werden im Rahmen der Bewölkungsvorhersage, entsprechend der Darstellung in den Bildern, auf einer Skala von 0 bis 255 angegeben.

3.4 Test der Vorhersagemethode an einfachen Beispielen

Bevor der Algorithmus zur Vorhersage der Bewölkungsentwicklung angewendet wurde, wurden Tests mit einer Reihe von künstlich generierten Beispielen durchgeführt. Ziel dabei war es zum einem, herauszufinden, wie gut sich verschiedene Bewölkungssituationen mit komprimierten Bildern wiedergeben lassen. Zum anderen sollte getestet werden, ob sich Bewegungen und Veränderungen von Strukturen prinzipiell mit neuronalen Netzen erfassen lassen.

Da nur eine begrenzte Anzahl an Beispielen untersucht wurde, wurde keine Klassifizierung vorgenommen. Für die freien Parameter bezüglich der Eingabe- und Ausgabedimension und der Netzarchitektur wurden folgende Einschränkungen getroffen: Die Anzahl der zur komprimierten Darstellung benutzten Moden wurde im Bereich von 10 bis 70 variiert. Es wurden zwei- und dreischichtige Netze betrachtet, bei denen die einzelnen Schichten von einer Ebene zur nächsten vollständig verbunden waren. Als Maß für die Vorhersagequalität wurde der *rmse* (siehe Abschnitt 3.3) zwischen dem vorhergesagten Bild und dem Originalbild zum Vorhersagezeitpunkt betrachtet. Die Vorhersagefehler wurden jeweils mit dem Persistenzfehler verglichen, wobei Persistenz bedeutet, daß das vorhergesagte Bild dem aktuellen Bild entspricht. Die betrachteten Beispiele wurden zunächst sehr einfach gewählt und zu komplexeren Strukturen hin verändert.

3.4.1 Verschiebung einer einfachen, künstlichen Struktur

In der ersten Testserie wurde die komplexe Bewölkungsstruktur durch eine einfache Struktur ersetzt. Mit einem hellen Quadrat ($\hat{=}$ Wolke) vor dunklem Hintergrund ($\hat{=}$ Boden) lassen sich leicht Veränderungen der Struktur in Bezug auf Größe, Helligkeit und Variabilität realisieren. Die Bewegung der Struktur bleibt auf Verschiebung mit verschiedenen Geschwindigkeiten beschränkt. Um genügend Beispiele zur Verfügung zu haben, wurden den Quadraten wechselnde Zufallsmuster aufgeprägt, so daß die Helligkeit innerhalb der Quadrate variiert, diese aber trotzdem noch deutlich vom Hintergrund zu unterscheiden sind (siehe Abb. 3.5).

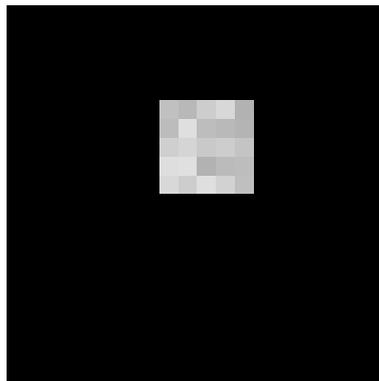


Abbildung 3.5: Testbild (20x20 Pixel) mit quadratischer Struktur (5x5 Pixel) vor dunklem Hintergrund.

Die Größe der Bilder betrug 20x20 Pixel, die Seitenlänge der Quadrate wurde zwischen vier und zwölf Pixeln variiert. Wie bei den Cloud-Index Bildern wird jedem Pixel ein Wert zwischen 0 und 255 zugeordnet.

In [Oey 1999] wurde ausführlich der Einfluß der Parameter Wolkengröße, Wolkenhelligkeit und Homogenität der Wolke (Varianz der aufgeprägten Zufallswerte) auf den Fehler durch die Hauptkomponenten-Transformation untersucht. Aus den Ergebnissen sollen folgende Punkte hervorgehoben werden:

- Position und Größe der Strukturen lassen sich schon bei Rekonstruktion aus wenigen Moden klar erkennen.
- Große Strukturen lassen sich bei gleichem Fehler mit weniger Moden repräsentieren als kleine Strukturen. Dies bestätigt die Betrachtungen in Abschnitt 3.1.2.
- Die Helligkeit der Strukturen und die Schwankungsbreite des aufgeprägten Rauschens haben einen geringen Einfluß auf den Fehler durch die Datenkompression.

Die Versuchsreihe zur Erfassung der Veränderung des Quadrats und der Verschiebung mit verschiedenen Geschwindigkeiten wurde von [Oey 1999] begonnen und im Rahmen dieser Arbeit fortgesetzt. Es wurden dabei Verschiebungen um bis zu 8 Pixel in beide Richtungen pro Zeitschritt betrachtet. Die Seitenlänge der Quadrate wurde um max. 2 Pixel pro Zeitschritt verändert und die Helligkeit in Schritten von ± 20 variiert. Daraus ergaben sich im Wesentlichen folgende Schlußfolgerungen:

- Durch die Vorhersage mit neuronalen Netzen läßt sich eine deutliche Verbesserung gegenüber der Persistenz erreichen.
- Zur Unterscheidung verschiedener Geschwindigkeiten und Änderungen in der Größe des Quadrats ist es notwendig, eine versteckte Schicht zu verwenden.
- Während der Vorhersagefehler auf der Trainingsmenge mit der Anzahl der benutzten Moden kleiner wird, gibt es für die Testmenge (andere Startpunkte der Bewegungsfolge, andere Geschwindigkeiten) eine optimale Anzahl von Moden im Bereich von 30 bis 40. Die Information aus höheren Moden kann nicht von der Trainingsmenge auf die Testmenge übertragen werden.

3.4.2 Verschiebung eines Bewölkungsbildes

Für die nächste Testreihe wurde anstelle der einfachen geometrischen Struktur ein 60x40 Pixel großer Bildausschnitt aus einem Cloud-Index Bild mit klar erkennbarer Wolkenstruktur gewählt. Eine Bewegung der Wolkenstruktur wurde durch Auswahl von zueinander verschobenen Bildausschnitten realisiert (siehe Abb. 3.6) Eine genügend große Beispielmenge für das Training des neuronalen Netzes ergibt sich, wenn Bildfolgen aus Ausschnitten mit leicht variierender Position und verschiedenen Geschwindigkeiten zusammengestellt werden.

Bezüglich der Hauptkomponenten-Transformation sind die Resultate für Bewölkungsbilder in Abschnitt 3.6 ausgeführt. Die Vorhersageergebnisse entsprechen den Versuchen mit der einfachen Struktur. Auch wenn die einfache geometrische Struktur durch eine reale Wolkenstruktur ersetzt wird, ist es möglich, verschiedene Geschwindigkeiten mit einem dreischichtigen Netz zu unterscheiden. Als Zusammenfassung der Untersuchung der Vorhersagemethode an einfachen Beispielen ergibt sich in Bezug auf die Datenkompression durch Hauptkomponenten-Transformation, daß die wesentlichen Informationen in den komprimierten Bildern enthalten sind und verschiedene

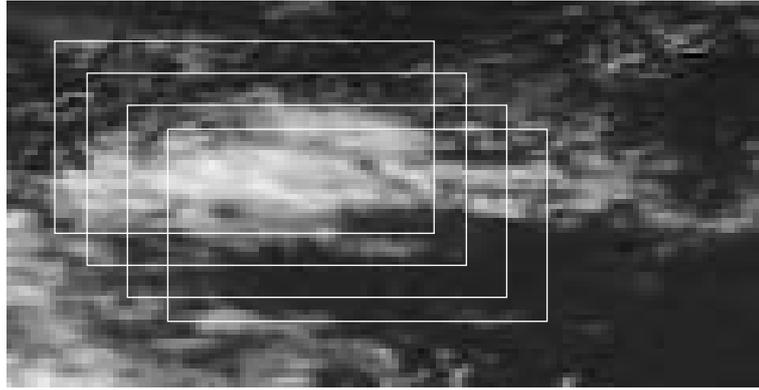


Abbildung 3.6: Auswahl von Bildausschnitten (60x40 Pixel) mit deutlich erkennbarer Wolkenstruktur. Bewegung wird durch Betrachtung von zueinander verschobenen Bildausschnitten simuliert.

Strukturen erfaßt werden können. Bei der Beschreibung von Bewegung mit neuronalen Netzen hat sich gezeigt, daß die Verschiebung einer Wolkenstruktur mit einem neuronalen Netz erfaßt werden kann, wobei zur Unterscheidung verschiedener Geschwindigkeiten ein dreischichtiges Netz erforderlich ist.

3.5 Datenbasis für die Vorhersage von Cloud-Index Bildern

Als Datenbasis für die Vorhersage wurden Ausschnitte aus Cloud-Indexbildern vom 1.1.96 bis zum 29.11.97 (700 Tage) verwendet. Der größte Teil dieser Datenbasis wurde als Grundlage für die Hauptkomponenten-Analyse und zum Training der neuronalen Netze genutzt. So ergaben Untersuchungen bezüglich der Länge der Ausgangsmenge A für die Hauptkomponenten-Analyse, daß eine Datenbasis von mindestens 500 Tagen erforderlich ist, damit auch Situationen, die nicht in der Ausgangsmenge enthalten sind, gut charakterisiert werden können. Angaben zur Länge der Trainingsmenge für die neuronalen Netze finden sich in Abschnitt 3.6.2. Die Auswertung der Vorhersage und der Hauptkomponenten-Transformation wurde für eine Zeitreihe von 50 Tagen, vom 14.5.97 bis zum 2.7.97, durchgeführt. Im Folgenden beziehen sich alle Vorhersagefehler auf diese Testmenge, sofern nicht anders angegeben.

Die Größe der verwendeten Bildausschnitte ist durch Speicherplatzbedarf bei der Hauptkomponenten-Analyse auf ca. 2500 Pixel begrenzt, was in etwa der schon in der Testserie verwendeten Bildgröße von 60x40 Pixeln entspricht. Da die Auflösung der Satellitenbilder in die beiden Richtungen verschieden ist, ergibt sich durch die unterschiedliche Anzahl von Pixeln in x- und y-Richtung ein Gebiet mit ähnlicher räumlicher Ausdehnung in beide Richtungen. Untersuchungen mit dem in Kapitel 4 dargestellten Vorhersageverfahren mit Bewegungsvektoren ergaben, daß für gute Vorhersageergebnisse eine Mindestgröße von ca. 120x80 Bildpunkten erforderlich ist. Um für die Vorhersage mit neuronalen Netzen Bildausschnitte mit entsprechendem Informationsgehalt zugänglich zu machen, wurden Bildausschnitte der Größe 120x80 durch Mittelung von jeweils

4 benachbarten Pixeln auf die Größe von 60x40 Pixeln reduziert. Der gemittelte Bildausschnitt entspricht einem Gebiet von 250km x 300km, das über Norddeutschland gewählt wurde.

3.6 Bestimmung der optimalen Parameter

Bei jedem Modell, mit dem ein komplexer Vorgang vereinfacht beschrieben wird, müssen eine Reihe von Annahmen und Festlegungen getroffen werden. Bei empirischen Modellen wird dann innerhalb dieses vorgegebenen Rahmens das Modell an eine Datenmenge angepaßt. Voraussetzung dafür, daß mit dem Modell der zugrunde liegende Zusammenhang gut approximiert werden kann, ist, daß der Rahmen passend gewählt wird. So wäre es z. B. wenig sinnvoll zu versuchen, einen stark nichtlinearen Zusammenhang mit einem linearen Modell zu beschreiben. Als erster Schritt zur Festlegung eines Modells wird die Methode bestimmt, mit der vorgegangen werden soll, hier neuronale Netze und Hauptkomponenten-Analyse. Der nächste Schritt ist die Konkretisierung des Modells durch Festlegen von Parametern. Dies stellt einen sehr wichtigen Punkt dar, da der Erfolg des Verfahrens, neben der Wahl der Methode, davon abhängt, daß die Parameter geeignet gesetzt werden.

Im Fall der Vorhersage mit neuronalen Netzen gibt es eine Vielzahl von freien Parametern, dazu gehören z.B. die Kriterien für die Klassifikation, die Ein- und Ausgabedimension des Netzes oder die Parameter im Lernverfahren. Diese Parameter sind nicht unabhängig voneinander, sondern beeinflussen sich in unterschiedlichem Maß gegenseitig, so wirkt z. B. die Art der Klassifikation auf die Anzahl der Moden, durch die die Bilder repräsentiert werden. Um die beste Parameterkonfiguration zu finden, muß deshalb eine große Zahl von Kombinationsmöglichkeiten untersucht werden. Der Reihenfolge der Verfahrensschritte im Vorhersagealgorithmus folgend, wird zunächst auf die Kriterien zur Klassifikation der Cloud-Index Bilder eingegangen. Den Schwerpunkt des Kapitels bildet die Bestimmung der Parameter, die das neuronale Netz festlegen.

3.6.1 Kriterien zur Unterscheidung verschiedener Typen von Cloud-Index Bildern

Sowohl bei der Hauptkomponenten-Analyse als auch bei neuronalen Netzen wird für eine vorgegebene Menge von Beispielen die optimal an diese Beispielmenge angepaßte Lösung gesucht. Wie bereits in Abschnitt 3.2 dargestellt, läßt sich so erwarten, daß die Vorhersagefehler kleiner werden, wenn ähnliche Beispiele zu Klassen zusammengefaßt und für diese Klassen dann getrennte Basissysteme bestimmt bzw. verschiedene Netze trainiert werden. Für die Hauptkomponenten-Analyse sind die zugrunde liegenden Beispiele einzelne Bildausschnitte. Diese sollen nun in verschiedene Klassen unterteilt werden. Damit ergibt sich auch für die neuronalen Netze, wo die Elemente der Beispielmenge Folgen von Bildausschnitten sind, eine Klassifizierung, indem jede Bildfolge der Klasse des mittleren Bildes der Folge zugeordnet wird.

In diesem Abschnitt wird zunächst eine Motivation für die Festlegung der Klassifikationskriterien gegeben. Anschließend wird untersucht, wie sich die Klassifikation auf den Fehler durch die

Hauptkomponenten-Transformation auswirkt.

Zur Unterteilung der Bilder in verschiedene Klassen wurden zwei Kriterien herangezogen. Das erste Kriterium ist der mittlere Bewölkungsgrad. Klarer Himmel führt zu einem niedrigen Mittelwert eines Cloud-Index Bilds, starke Bewölkung zu einem hohen Mittelwert. In beiden Fällen ist die Bewölkungsdecke relativ homogen. Für mittlere Cloud-Index Werte lassen sich 2 Typen von Bildern unterscheiden. Auf der einen Seite treten Bilder mit großflächigen Wolkenstrukturen auf, die in sich homogen sind. Auf der anderen Seite gibt es Bilder mit starker Variabilität der Wolken auch auf kleinen Skalen. Als zweites Kriterium zur Klassifikation soll somit die räumliche Variabilität der Bilder berücksichtigt werden. Durch die Varianz läßt sich die Variabilität eines Bildausschnittes nur ungenügend beschreiben. Die Varianz ermöglicht die Unterscheidung, wie stark einzelne Pixelwerte vom Mittelwert abweichen. Groß- bzw. kleinskalige Strukturen lassen sich mit Hilfe der Varianz nur insoweit unterscheiden, als die Variabilität auf kleinen Skalen mit geringeren Abweichungen vom Mittelwert verbunden ist, als bei großskaligen Strukturen. Als besser geeignetes Maß für die Variabilität wird der Mittelwert über die Beträge der Differenzen zwischen benachbarten Pixeln in x- bzw. y-Richtung definiert:

$$var_x = \frac{1}{(N_x - 1)N_y} \sum_{i,j=1}^{N_x-1, N_y} |x_{i,j} - x_{i+1,j}|, \quad (3.25)$$

$$var_y = \frac{1}{N_x(N_y - 1)} \sum_{i,j=1}^{N_x, N_y-1} |x_{i,j} - x_{i,j+1}|. \quad (3.26)$$

Die Variabilität in y-Richtung und diejenige in x-Richtung sind stark korreliert, die Variabilität in y-Richtung wurde zur Klassifikation herangezogen.

In Abb. 3.7 ist die Variabilität in y-Richtung über dem Mittelwert aufgetragen. Anhand dieser Graphik wurden die Grenzen für Mittelwert und Variabilität so festgesetzt, daß sich für jede Klasse ausreichend viele Beispiele ergeben und im Wesentlichen die oben beschriebenen Fälle charakterisiert werden, was zu den in Tabelle 3.1 spezifizierten Klassen führt.

| Menge | Klasse 1 | Klasse 2 | Klasse 3 | Klasse 4 |
|--------------|-----------|------------|-----------------------|-----------------------|
| Mittelwert | mean ≤ 60 | mean > 160 | 60 < mean ≤ 160 | 60 < mean ≤ 160 |
| Variabilität | | | var _y ≤ 15 | var _y > 15 |

Tabelle 3.1: Einteilung der Cloud-Index Bilder in 4 Klassen: Zur Klassifikation werden Mittelwert und Variabilität der Bilder herangezogen.

Typische Beispiele für die Klassen sind in Abbildung 3.8 gezeigt. Klasse 1 steht für Situationen mit klarem Himmel und niedriger Variabilität. Bei Klasse 2, die Situationen mit einer dichten Wolkendecke umfaßt, ist die Variabilität meistens ebenfalls niedrig. Es treten jedoch auch einige Fälle mit relativ hoher Variabilität auf, da bei starker Bewölkung die Einstrahlungsverteilung nicht so

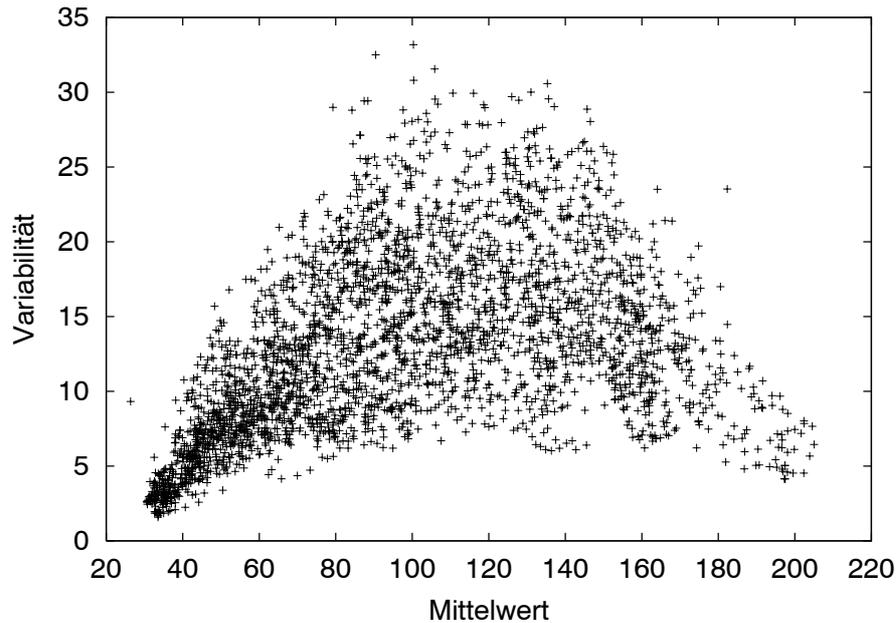


Abbildung 3.7: Variabilität eines Cloud-Index Bildes in y-Richtung in Abhängigkeit vom Mittelwert des Bildes.

gleichmäßig wie bei klarem Himmel ist (siehe Abb. 3.7). Beispiele mit klar erkennbaren Wolkenstrukturen sind in Klasse 3 zusammengefaßt, sie sind durch geringe Variabilität bei Mittelwerten im Bereich von 60 bis 160 gekennzeichnet. Die Bilder aus Klasse 4 mit stark variabler Bewölkung sind am schwersten vorherzusagen.

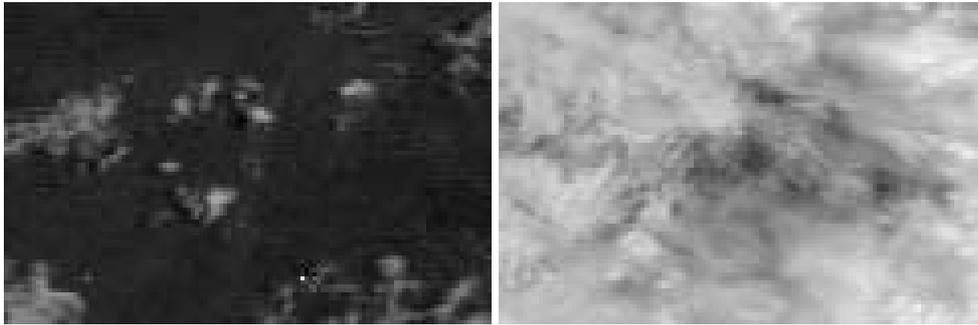
Zur Bewertung der Klassifikationskriterien wurden die Fehler, die durch die Hauptkomponenten-Transformation bei vorheriger Klassifikation entstehen, mit den entsprechenden Fehlern ohne Klassifikation verglichen. Dazu wurden in Abb. 3.9 die jeweiligen Fehler für die verschiedenen Klassen dargestellt. Im klassifizierten Fall enthielt die Ausgangsmenge für die Hauptkomponenten-Analyse nur Bildausschnitte der jeweiligen Klasse, im unklassifizierten Fall wurde die Hauptkomponenten-Analyse für alle Beispiele durchgeführt. Die Hauptkomponenten-Transformation wurde dann für jede Klasse mit den beiden verschiedenen Basissystemen durchgeführt. Es zeigt sich, daß für alle Klassen der Fehler durch die Klassifizierung deutlich sinkt. Je weniger Moden berücksichtigt werden, desto größer ist der Abstand zwischen den jeweiligen Kurven. Zur Beurteilung der Fehler durch die Hauptkomponenten-Analyse sind in Abb. 3.9 zum Vergleich die Persistenzfehler für 30-Minuten-Vorhersage eingetragen, die eine untere Grenze für die zu erreichende Vorhersagequalität darstellen. Bei der Transformation mit den klassifizierten Basissystemen wird der Persistenzfehler oberhalb von 20 Moden unterschritten. So ist die Grundlage dafür gegeben, daß mit dem Vorhersagealgorithmus bessere Ergebnisse als durch Persistenz erreicht werden können.

Ein Vergleich der Klassen ergibt, daß, bei gleicher Anzahl von Moden, der mittlere Fehler für Klasse 1 am niedrigsten ist, für die Klassen 2 und 3 deutlich höher liegt und für Klasse 4 der größte mittlere Fehler auftritt. Bilder mit niedriger Variabilität lassen sich bei gleicher Anzahl von

homogene Bewölkung:

Klasse 1: niedriger Mittelwert

Klasse 2: hoher Mittelwert



inhomogene Bewölkung:

Klasse 3: niedrige Variabilität

Klasse 4: hohe Variabilität

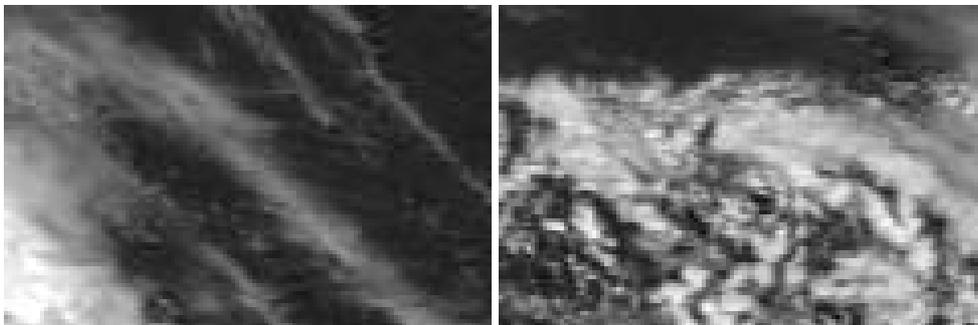


Abbildung 3.8: Beispiele verschiedener Bewölkungs-Klassen nach der Einteilung aus Tabelle 3.1. Oben sind Beispiele für Klasse 1 und Klasse 2 mit homogener Bewölkungsstruktur gegeben, unten Beispiele für Klasse 3 und Klasse 4 mit inhomogener Bewölkungsstruktur.

Moden mit wesentlich geringerem Fehler beschreiben als Bilder mit hoher Variabilität. Dies ist darauf zurückzuführen, daß hohe Moden für höhere Frequenzen stehen (siehe Abschnitt 3.2.2). Je niedriger die Variabilität ist, desto weniger tragen hohe Frequenzen zum Gesamtbild bei, und desto weniger fällt infolgedessen die Vernachlässigung dieser Moden ins Gewicht.

Da die Klassifikation den Fehler durch die Hauptkomponenten-Transformation so deutlich verringert, wurden Tests für eine weitere, feinere Unterteilung der Klassen durchgeführt. Dies führte jedoch zu keiner weiteren Verbesserung, weshalb die ursprüngliche Unterteilung beibehalten wurde.

Als Zusammenfassung ergibt sich, daß der Fehler durch die Hauptkomponenten-Transformation durch die Klassifizierung der Cloud-Index Bilder deutlich reduziert werden kann. So kann ein Bildausschnitt ohne Informationsverlust mit einer geringeren Anzahl von Moden beschrieben werden. Dies ist für die Weiterverarbeitung mit neuronalen Netzen ein großer Vorteil (siehe Abschnitt

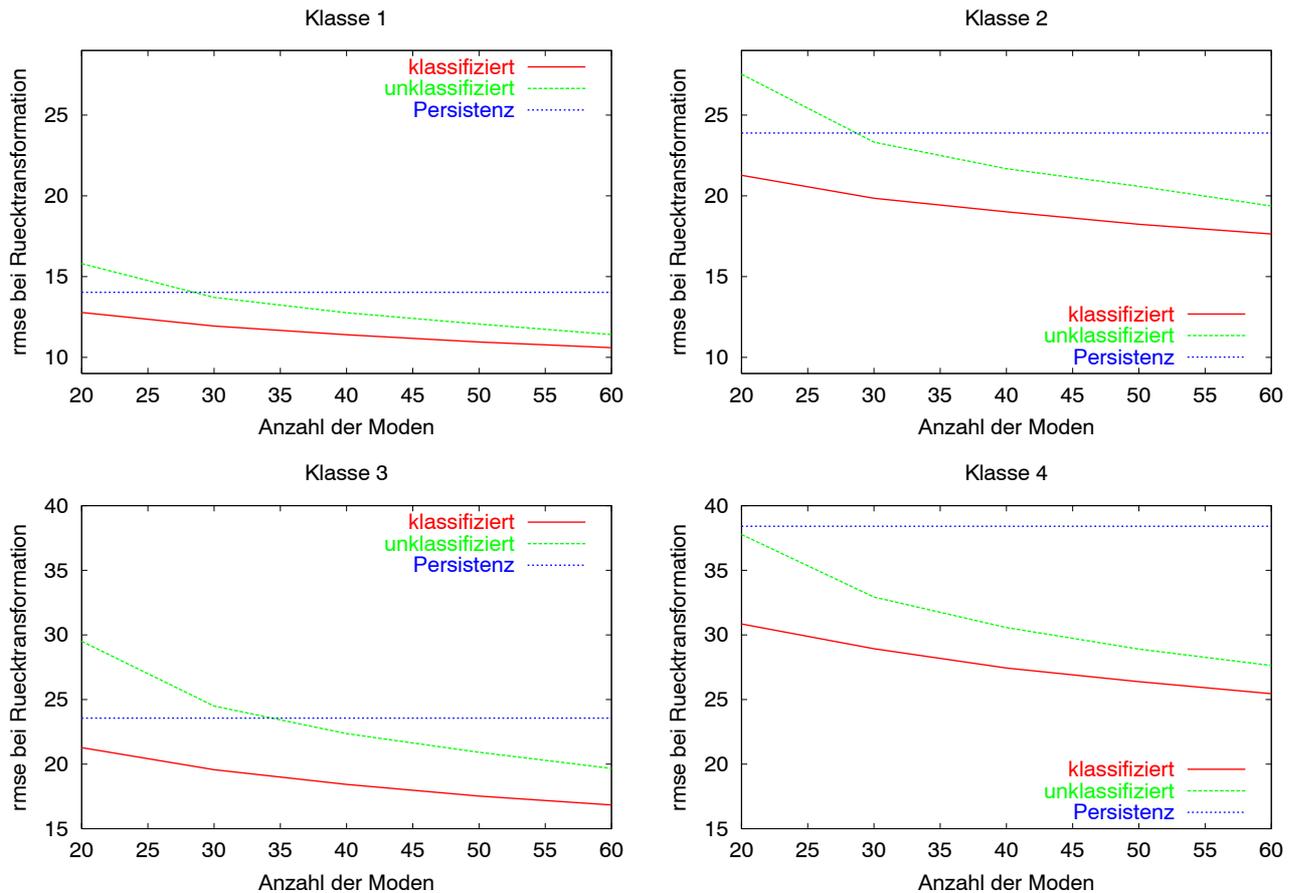


Abbildung 3.9: Fehler durch die Hauptkomponenten-Transformation in Abhängigkeit von der Anzahl der Moden für die verschiedenen Bewölkungs-Klassen. Es werden die Fehler mit Klassifikation und ohne Klassifikation verglichen. Oben: Klasse 1 und Klasse 2, unten: Klasse 3 und Klasse 4.

3.2.1). Nach der Festlegung der Klassifikationskriterien wurden die Basissysteme für die verschiedenen Klassen bestimmt. Diese wurden als Grundlage für alle weiteren Rechnungen verwendet.

3.6.2 Festlegung der Netzarchitektur und des Lernverfahrens

Der umfangreichste Teil der Parameteroptimierung betrifft die Parameter, die das neuronale Netz bestimmen. Dazu gehören zum einen die Parameter, die direkt die Netzarchitektur betreffen, wie die Eingabe- und Ausgabedimension, die Anzahl der Schichten und die Art der Verbindung der Schichten untereinander. Zum anderen ist ein geeignetes Lernverfahren für das neuronale Netz auszuwählen, wobei ebenfalls verschiedene Parameter festzulegen sind. Schließlich ist noch der Einfluß der Länge der Trainingsmenge zu untersuchen.

Die optimale Parameterkonfiguration ist vom Vorhersagezeitraum und von der Bewölkungs-Klasse

abhängig, darüberhinaus beeinflussen sich die Parameter wechselseitig. Wegen der Vielzahl der Parameter, die die Qualität der Vorhersage mit neuronalen Netzen bestimmen, wäre es zu aufwendig, die optimale Parameterkonfiguration durch systematische Variation aller Parameter über den gesamten möglichen Wertebereich zu ermitteln. Deshalb wird zunächst der Einfluß einzelner Parameter untersucht, wobei die anderen Parameter mit Erfahrungswerten belegt werden. Dies ermöglicht eine Einschränkung der Wertebereiche oder für manche Parameter auch eine Festlegung der Werte. Darüberhinaus trägt die Auswertung für die verschiedenen Parameter zum Verständnis dazu bei, welche Bedeutung die einzelnen Parameter für die Vorhersage haben und welche Faktoren die Vorhersagequalität begrenzen.

In diesem Abschnitt wird zunächst die Auswahl der Trainings- und Testbeispiele motiviert. Anschließend werden im Rahmen der Auswertungen für die einzelnen Parameter folgende Punkte betrachtet:

- Parameter für das Lernverfahren,
- Länge der Trainingsmenge,
- Eingabe- und Ausgabedimension, entsprechend der Anzahl der Moden, durch die ein Bildausschnitt repräsentiert wird,
- Anzahl der Schichten,
- Art der Verbindung der Schichten untereinander.

Die Untersuchungen wurden dabei jeweils am Beispiel von Klasse 3 und den Vorhersagezeiträumen 30 Minuten und 2 Stunden durchgeführt. Aufbauend auf die Auswertung für die einzelnen Parameter werden im letzten Teil dieses Abschnitts die optimalen Parameter für die verschiedenen Klassen und Vorhersagezeiträume durch systematische Variation festgelegt.

Ergänzend sei noch bemerkt, daß die Simulation neuronaler Netze in dieser Arbeit mit dem „Stuttgart Neuronal Network Simulator“ (SNNS, siehe [Zell 1999]) durchgeführt wurde.

Auswahl der Bildfolgen

Die Trainings- und Testbeispiele wurden nur aus einem Teil der in Abschnitt 3.5 beschriebenen Datenbasis ausgewählt. Es werden Bildfolgen aus den Tagen 100-250 bis 17:00 Uhr verwendet. Im Mittel ist für die Wintermonate und die Abendstunden aufgrund des niedrigen Sonnenstands die Qualität der zugrunde liegenden Cloud-Index Bilder geringer (siehe Abschnitt 5.3.2), weshalb diese Beispiele zur Parameteroptimierung nicht miteinbezogen werden. So ergeben sich für den Vorhersagezeitraum 30 Minuten für die verschiedenen Bewölkungs-Klassen die in Tabelle 3.2 dargestellten Längen der Test- bzw. Trainingsmengen. Die Trainingsmengen entsprechen hier dem realistischen Fall, daß die Testmenge disjunkt zur Trainingsmenge ist. Für längere Vorhersagezeiträume stehen jeweils etwas weniger Beispiele zur Verfügung.

| Menge | Klasse 1 | Klasse 2 | Klasse 3 | Klasse 4 |
|----------------|----------|----------|----------|----------|
| Testmenge | 247 | 76 | 353 | 346 |
| Trainingsmenge | 1028 | 405 | 2000 | 1346 |

Tabelle 3.2: Anzahl der Test- und Trainingsbeispiele für den Vorhersagezeitraum 30 Minuten.

Lernverfahren

Zum Training der neuronalen Netze wurde der in Abschnitt 3.1.1 beschriebene Backpropagation-Algorithmus verwendet. Dazu muß gemäß Gleichung (3.6) die Lernschrittweite festgelegt werden. Da im hier verwendeten online-Verfahren die Gewichte nach jedem Trainingsbeispiel geändert werden, spielt es außerdem eine Rolle, wie die Trainingsbeispiele präsentiert werden.

Als Beispiel wurde für den Vorhersagezeitraum 30 Minuten ein zweischichtiges Netz mit vollständiger Verbindung der Schichten betrachtet, wobei $N = 60$ Moden zur Repräsentation der Bilder verwendet wurden. Die Vorhersagefehler in Abhängigkeit von der Anzahl der Trainingsschritte sind für verschiedene Lernschrittweiten von $\eta = 0.01$ bis $\eta = 0.1$ in Abb. 3.10 dargestellt. Werden die Trainingsbeispiele bei jedem Trainingsschritt in der gleichen Reihenfolge präsentiert (siehe Abb. 3.10, linkes Bild), werden für die größeren der betrachteten Werte von η die optimalen Gewichte nicht gefunden. Je kleiner die Lernschrittweite, desto besser werden die Ergebnisse, desto mehr Trainingsschritte sind aber auch erforderlich. Schnellere Konvergenz kann erreicht werden, wenn die Trainingsbeispiele bei jedem Trainingsschritt in zufällig wechselnder Reihenfolge präsentiert werden (siehe Abb. 3.10, rechtes Bild). Auch bei größeren Werten von η , bei denen das Verfahren vergleichsweise schnell konvergiert, wird die gleiche Vorhersagequalität erreicht, wie für kleinere Werte von η . Wegen der wechselnden Reihenfolge der Beispiele, an die die Gewichte angepaßt werden, ergeben sich, auch nach Konvergenz, Schwankungen in den Kurven. Diese sind um so größer, je größer die Lernschrittweite ist.

Es wurde weiterhin versucht, das Lernverfahren durch Addition eines Momentum-Terms zu verbessern (siehe [Zell 1999]). Da dies die Ergebnisse jedoch verschlechtert, wurde dieses Verfahren im Weiteren nicht angewandt.

Für die Parameteroptimierung ist, wegen der Vielzahl der Trainingsläufe, die durchgeführt werden müssen, schnelle Konvergenz ein wichtiger Faktor. Deswegen werden für die folgenden Betrachtungen die Beispiele in zufällig wechselnder Reihenfolge präsentiert. Soweit nicht anders angegeben, ist die Lernschrittweite auf $\eta = 0.1$ gesetzt, und das Training wird nach 4000 Trainingsschritten beendet. Für das Training der Netze nach Festlegung der optimalen Parameter wurden die Trainingsbeispiele, bei einem genügend kleinen Wert von η , für alle Trainingsschritte in der gleichen Reihenfolge berücksichtigt, da die Ergebnisse hier stabiler sind.

Länge der Trainingsmenge

Das neuronale Netz soll anhand der Trainingsbeispiele den Zusammenhang zwischen Ein- und Ausgabe lernen. Der Zusammenhang zwischen Ein- und Ausgabe ist dabei nicht völlig determi-

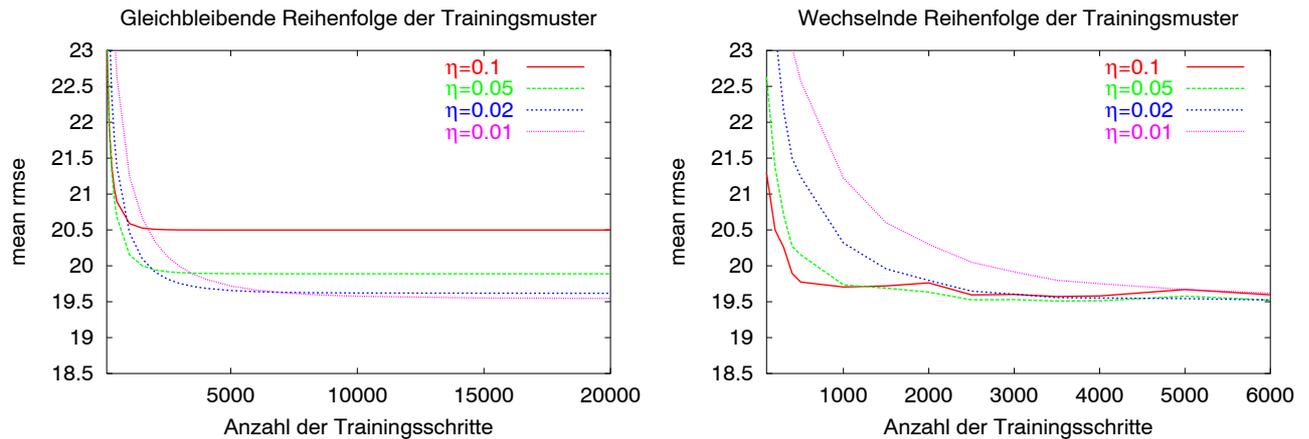


Abbildung 3.10: Mittlerer Vorhersagefehler in Abhängigkeit von der Anzahl der Trainingsschritte für verschiedene Lernschrittweiten am Beispiel von Klasse 3, Vorhersagezeitraum 30 Minuten, $N=60$ und vollständiger Verbindung der Schichten. Im linken Bild wurden die Trainingsbeispiele in gleichbleibender Reihenfolge präsentiert, im rechten Bild wechselte die Reihenfolge bei jedem Trainingsschritt.

nistisch, es gibt einen Anteil in der Entwicklung der Bewölkungssituation, der nicht berechenbar ist. Die Ein- und Ausgabepaare sind daher gegenüber der zugrunde liegenden deterministischen Dynamik verrauscht. Ist die Anzahl der Trainingsbeispiele im Vergleich zu der Anzahl der festzulegenden Verbindungen zu klein, wird das neuronale Netz durch das Training auch an das Rauschen angepaßt, was als Übertraining bezeichnet wird. Das neuronale Netz kann dann weniger gut generalisieren, neue Beispiele können weniger gut vorhergesagt werden.

Zur Vereinfachung der Ausdrucksweise wird im Weiteren eine zur Trainingsmenge disjunkte Testmenge als unabhängige Testmenge bezeichnet. Ist die Testmenge ein Teil der Trainingsmenge, wird sie integrierte Testmenge genannt.

Der Einfluß der Länge der Trainingsmenge wurde am Beispiel des Vorhersagezeitraums 30 Minuten für Netze mit 2 Schichten und vollständiger Verbindung der Schichten untereinander untersucht. Die Lernschrittweite wurde auf $\eta = 0.2$ gesetzt, und es wurden jeweils 500 Trainingsschritte durchgeführt.

In Abb. 3.11 sind die Vorhersagefehler auf der Testmenge für zwei verschiedene Anzahlen von Moden zur Repräsentation der Bilder, $N = 20$ und $N = 60$, in Abhängigkeit von der Anzahl der Trainingsbeispiele dargestellt. Dabei wird der Fehler für unabhängige Testmengen zu integrierten Testmengen in Bezug gesetzt. Wie zu erwarten, sinkt der Fehler für unabhängige Testmengen mit der Anzahl der Trainingsbeispiele. Der Vergleich der beiden Bilder für $N = 20$ und $N = 60$ zeigt, daß bei einer geringeren Anzahl von Moden weniger Trainingsbeispiele notwendig sind, um Übertraining zu vermeiden. Dies läßt sich darauf zurückführen, daß zum einen bei Verwendung von weniger Moden der Rauschanteil geringer ist. Zum anderen steigt die Anzahl der Verbindungen M mit der Anzahl der Moden, die verwendet werden (für ein zweischichtiges Netz: $M = 2N^2$) und verstärkt so die Überanpassung an die Trainingsmenge zusätzlich.

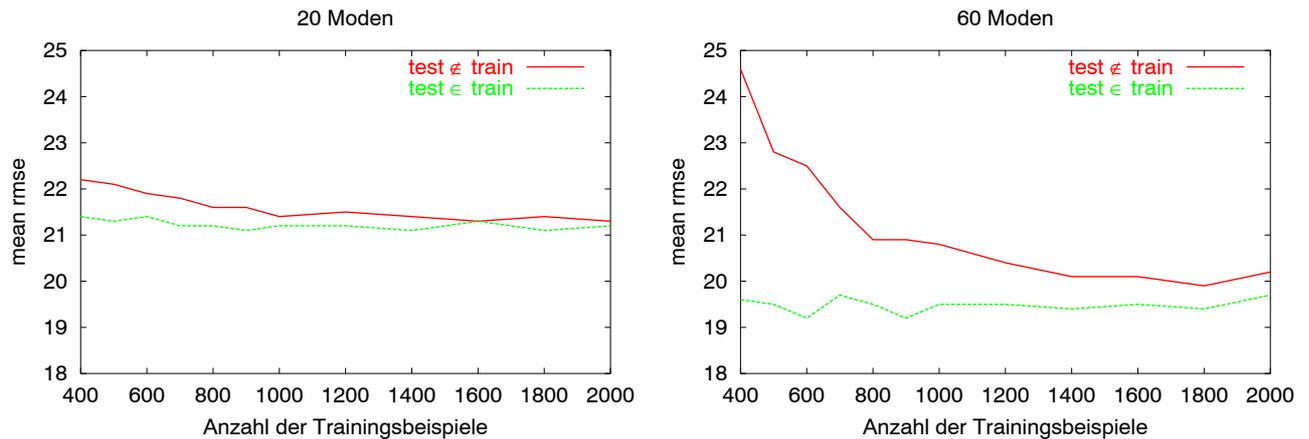


Abbildung 3.11: Mittlere Vorhersagefehler in Abhängigkeit von der Anzahl der Trainingsbeispiele am Beispiel von Klasse 3 und Vorhersagezeitraum 30 Minuten für 20 Moden (links) und 60 Moden (rechts). Bei den oberen Kurven ist die Testmenge disjunkt zur Trainingsmenge, bei den unteren Kurven ist die Testmenge Teil der Trainingsmenge.

Für alle weiteren Untersuchungen wurden jeweils alle gemäß Tabelle 3.2 zur Verfügung stehende Beispiele zum Training genutzt. Nach der Festlegung der optimalen Parameter wird abschließend getestet, ob diese Länge der Trainingsmengen ausreichend ist, oder ob durch eine Verlängerung der Trainingsmenge Verbesserungen erwartet werden können.

Anzahl der Moden zur Repräsentation eines Bildausschnitts

Im Folgenden soll untersucht werden, welche Anzahl von Moden zur Repräsentation eines Bildausschnitts bei vorgegebener Länge der Trainingsmenge zu den besten Ergebnissen führt. Durch die Festlegung der Anzahl von Moden ist auch die Eingabe- und Ausgabedimension des neuronalen Netzes bestimmt. Entsprechend den Ausführungen in Abschnitt 3.2.1 wird als Eingabe des Netzes die wesentliche Bewölkungs-Information aus zwei aufeinander folgenden Bildern verwendet, so beträgt die Eingabedimension des Netzes $2N$. Die Ausgabe des neuronalen Netzes entspricht dem vorhergesagten Bildausschnitt, und die Ausgabedimension ist damit gleich N . Wie bisher werden zunächst Netze mit zwei Schichten und vollständiger Verbindung der Schichten untereinander betrachtet.

Neben dem Vorhersagefehler in Abhängigkeit von der Anzahl der Moden für eine unabhängige Testmenge, sind in Abb. 3.12, als obere Grenze für die Vorhersagequalität, die Vorhersagefehler für eine integrierte Testmenge aufgetragen. Zum Vergleich sind weiterhin die Persistenzfehler für die jeweiligen Vorhersagezeiträume und die Fehler durch die Hauptkomponenten-Transformation dargestellt. Da es bei der Wolkenentwicklung einen Anteil gibt, der durch das neuronale Netz nicht wiedergegeben werden kann, liegen die Vorhersagefehler, auch für die integrierte Testmenge, über dem Fehler durch die Transformation der Originalbilder. Dieser Unterschied steigt mit der Anzahl der Moden. Großflächige Strukturen, die durch die ersten Moden repräsentiert werden, verhalten

sich auf den betrachteten Zeiträumen weitgehend deterministisch. Je kleiner die Strukturen sind, desto leichter zerfallen sie (siehe Abschnitt 3.2.1). So ergibt sich, abhängig vom Vorhersagezeitraum, eine Grenze für die Anzahl der Moden, oberhalb der eine weitere Erhöhung der Anzahl der Moden nicht mehr zu einer Verbesserung führt. Die durch die hohen Moden beschriebenen Strukturen sind nicht vorhersagbar und können deshalb bei der Vorhersage vernachlässigt werden. Für den Vorhersagezeitraum 30 Minuten verbessert sich für die integrierte Testmenge die Vorhersagequalität bis zu etwa 100 Moden. Bei Vorhersagen für 2 Stunden ist der nicht deterministisch beschreibbare Anteil deutlich größer, und es genügt, 10 bis 20 Moden zu berücksichtigen.

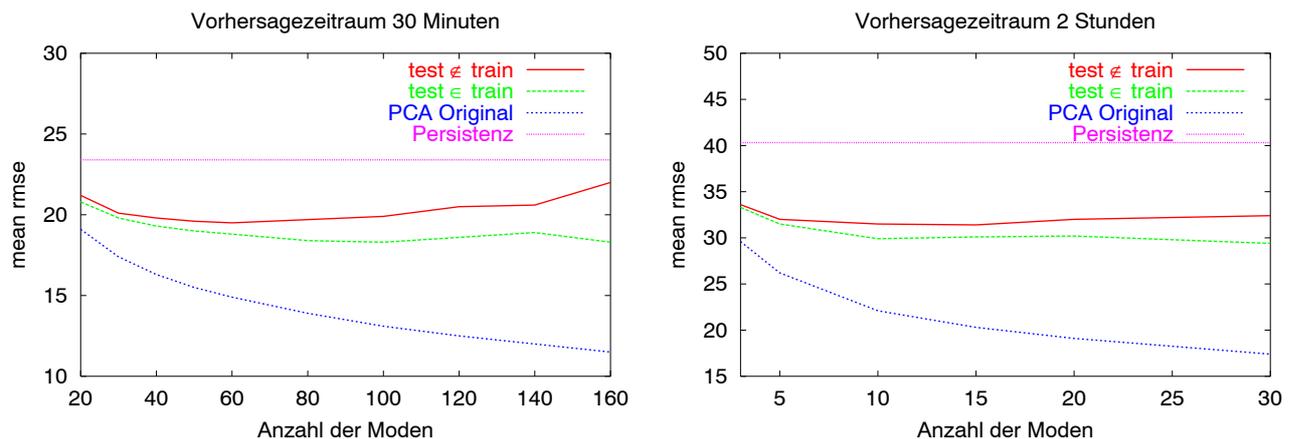


Abbildung 3.12: Mittlere Vorhersagefehler in Abhängigkeit von der Anzahl der Moden am Beispiel von Klasse 3 für die Vorhersagezeiträume 30 Minuten (links) und 2 Stunden (rechts).

Nach der Betrachtung des Vorhersagefehlers für die integrierte Testmenge soll nun der realistische Fall analysiert werden, daß die vorherzusagenden Beispiele nicht in der Trainingsmenge enthalten sind. Für eine bestimmte Anzahl von Moden ergibt sich ein Minimum des Vorhersagefehlers. Auf der linken Seite des Minimums folgt der Graph für die unabhängige Testmenge weitgehend der Kurve für die integrierte Testmenge. Der Fehler wird bei Erhöhung der Modenzahl geringer, da die Bilder mit mehr Komponenten besser beschrieben werden. Die Erhöhung des Vorhersagefehlers mit der Anzahl der Moden rechts vom Minimum ist auf das im vorangehenden Abschnitt beschriebene Übertraining zurückzuführen. Ist die Anzahl der Verbindungen im Vergleich zur Anzahl der Trainingsbeispiele zu hoch, werden auch nicht deterministische Entwicklungen vom Netz gelernt. Dies hat zur Folge, daß die Fehler für eine unabhängige Testmenge größer werden. Für den Vorhersagezeitraum 30 Minuten wird dadurch die optimale Anzahl von Moden von $N = 100$ auf $N = 60$ reduziert. Für den Vorhersagezeitraum 2 Stunden bleibt die optimale Anzahl von Moden auch für die unabhängige Testmenge bei $N = 10$ bis $N = 20$, die Fehler sind aber etwas höher als für die integrierte Testmenge.

Zusammenfassend läßt sich feststellen, daß für die verschiedenen Klassen und Vorhersagezeiträume jeweils getrennt die optimale Anzahl von Moden zur Darstellung eines Bildausschnitts bestimmt werden muß. Diese ist wesentlich dadurch bestimmt, durch welche Moden Strukturen repräsentiert werden, die sich weitgehend deterministisch entwickeln. Zusätzlich führt Übertraining zu einer

Verringerung der optimalen Anzahl von Moden und zu einer Erhöhung des Vorhersagefehlers.

Anzahl der Schichten

Bei der Testserie mit einfachen Beispielen (siehe Abschnitt 3.4) führte die Einführung einer versteckten Schicht zu einer deutlich besseren Unterscheidung der verschiedenen Geschwindigkeiten. Dies soll hier für die Vorhersage untersucht werden. Dazu wurden Netze mit vollständiger Verbindung der Schichten für eine jeweils feste Anzahl von Moden betrachtet.

In Abb. 3.13 ist der mittlere Fehler der Ausgabe des neuronalen Netzes in Abhängigkeit von der Anzahl der Trainingsschritte für den Vorhersagezeitraum 30 Minuten ($N = 80$) und für den Vorhersagezeitraum 2 Stunden ($N = 20$) aufgetragen¹. Es wurden 3 verschiedene Netzkonfigurationen verglichen, auf der einen Seite die schon vorher betrachteten Netze mit zwei Schichten, auf der anderen Seite Netze mit drei Schichten. Dabei betrug die Anzahl der Neuronen der versteckten Schicht einmal $N + a$ und einmal $2N + a$ ($a = 10$ für den Vorhersagezeitraum 30 Minuten, $a = 5$ für den Vorhersagezeitraum 2 Stunden).

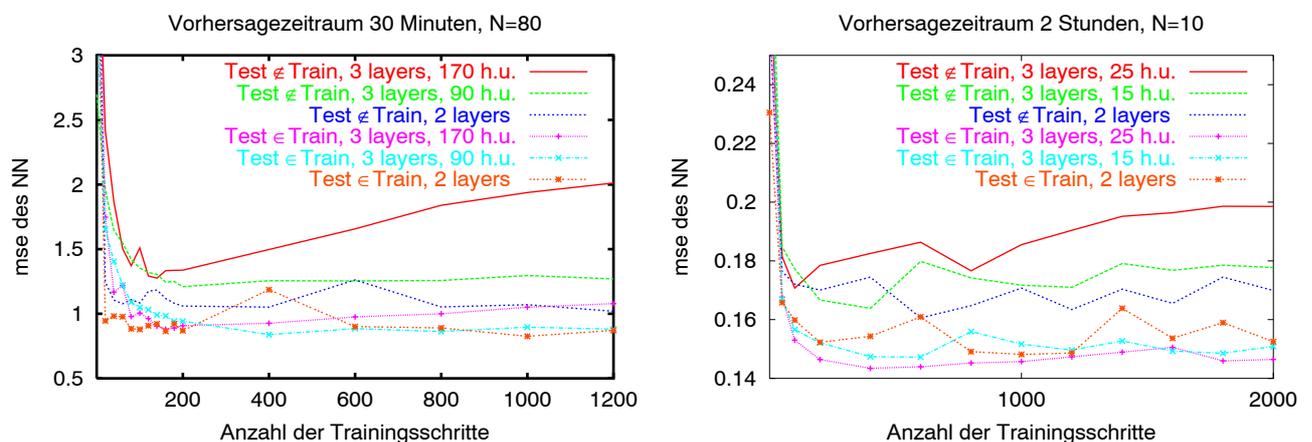


Abbildung 3.13: Mittlerer Fehler der Ausgabe des neuronalen Netzes in Abhängigkeit von der Anzahl der Trainingsschritte am Beispiel von Klasse 3 bei vollständiger Verbindung aller Schichten für die Vorhersagezeiträume 30 Minuten (links) und 2 Stunden (rechts). Es werden neuronale Netze mit 2 Schichten und 3 Schichten verglichen.

Für die integrierte Testmenge ergeben sich für den Vorhersagezeitraum 30 Minuten durch Einführung der versteckten Schicht keine Verbesserungen. Für $2N + a$ versteckte Neuronen sind die Ergebnisse sogar schlechter, was bedeutet, daß die optimalen Gewichte nicht gefunden wurden. Für den Vorhersagezeitraum 2 Stunden sind die Ergebnisse mit drei Schichten etwas besser als mit zwei Schichten. Die Verbesserung ist jedoch wesentlich geringer als nach dem Test mit einfachen

¹Da der Fehler für verschiedene Netzkonfigurationen für eine feste Anzahl von Moden untersucht wird, ist es ausreichend, den Fehler der Ausgabe des neuronalen Netzes in Bezug auf die gewünschte Ausgabe zu betrachten. Es ist nicht notwendig, die Vorhersagefehler zu berechnen.

Beispielen erwartet wurde. Die Ursache dafür ist, daß entweder das Minimum der Fehlerfunktion nicht gefunden wurde oder die Dynamik so komplex ist, daß sie auch mit drei Schichten nicht erfaßt werden kann. Die Untersuchung für den realistischen Fall mit unabhängiger Testmenge zeigt, daß für drei Schichten starkes Übertraining auftritt. Dadurch liegen die Fehler deutlich höher als für zwei Schichten.

Es wurde nicht versucht, das Verfahren mit drei Schichten und vollständiger Verbindung der Schichten zu verbessern, da der Aufwand hierfür zu groß wäre. Das Training eines neuronalen Netzes mit drei Schichten für 80 Moden dauert in etwa einen Tag, so daß das Testen verschiedener Trainingsverfahren zu zeitaufwendig wäre. Hinzu kommt, daß die Trainingsmenge wesentlich vergrößert werden müßte. Die Anzahl der Beispiele sollte mindestens so groß sein, wie die Anzahl der Verbindungen, um zu starkes Übertraining zu vermeiden. Für eine Netz mit drei Schichten ist die Anzahl der Verbindungen proportional zu $2N^3$, für $N = 80$ würde das über 1.000.000 Gewichte bzw. Trainingsbeispiele bedeuten.

Zusammenfassend läßt sich sagen, daß es bei der verwendeten Trainingsmethode und Trainingsmenge bei vollständiger Verbindung der Schichten günstiger ist, ein Netz mit nur zwei Schichten zu verwenden.

Verbindung der Schichten

In diesem Abschnitt wird dargestellt, inwieweit Übertraining durch eine Reduktion der Anzahl der Verbindungen zwischen den Schichten vermindert werden kann. Dazu wurden zunächst wieder zweischichtige Netze betrachtet. Um herauszufinden, auf welche Verbindungen verzichtet werden kann, ohne die Vorhersagequalität zu beeinträchtigen, wurden für die Vorhersagezeiträume 30 Minuten und 2 Stunden die Beträge der einzelnen Gewichte in Abb. 3.14 veranschaulicht. Der Wert eines Gewichts $w_{i,j}$ ist dabei durch den Grauwert eines Pixels gegeben. Durch die Position eines Pixels ist festgelegt, um welche Verbindung es sich handelt (x-Richtung: Eingabeneuronen, y-Richtung: Ausgabeneuronen). Die rechten Quadrate stehen jeweils für die Verbindungen vom Bild zum Zeitpunkt t (aktuelles Bild) zum vorherzusagenden Bild zum Zeitpunkt $t + \Delta t$, wobei Δt den Vorhersagezeitraum bezeichnet. Die linken Quadrate stehen für die Verbindungen vom vergangenen Bild ($t - 30min$) zum Bild ($t + \Delta t$). Wie zu erwarten war, sind die Verbindungen vom aktuellen Bild zum vorherzusagenden Bild stärker ausgeprägt als die Verbindungen vom vergangenen Bild zum vorherzusagenden Bild.

Bei der 30 Minuten Vorhersage sind die Verbindungen zwischen sich entsprechenden Moden, repräsentiert durch die Diagonalen in Abb. 3.14, deutlich stärker als alle anderen Verbindungen. Im Wesentlichen wirken auf eine vorherzusagende Mode aus dem Bild ($t + \Delta t$) nur die entsprechenden Moden aus den Eingabebildern. Bei der Vorhersage über einen Bereich von 2 Stunden sind die Verbindungen zwischen sich entsprechenden Moden zwar ebenfalls am deutlichsten ausgeprägt, die Verbindungen zu anderen Moden tragen jedoch deutlich bei. Im Besonderen wirken die hohen Moden aus den Bildern t und ($t - 30min$) auf die niedrigen Moden aus dem folgenden Bild ($t + \Delta t$) (großflächige Strukturen haben Einfluß auf kleinskalige Strukturen zu einem späteren Zeitpunkt).

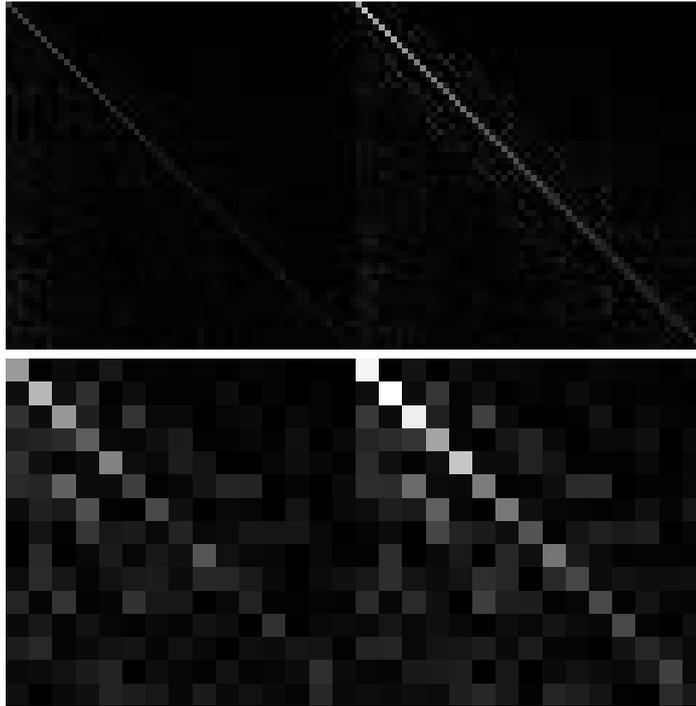


Abbildung 3.14: Visualisierung der Gewichtsmatrizen $w_{i,j}$ eines neuronalen Netzes. Der Grauwert eines Pixels steht für den Wert eines Gewichts, i und j sind durch die Position in der Graphik gegeben. Die rechten Quadrate stehen für die Verbindungen vom aktuellen Bild zum vorherzusagenden Bild, die linken Quadrate stehen für die Verbindungen vom vergangenen Bild zum vorherzusagenden Bild. oben: Vorhersagezeitraum 30 Minuten, $N = 60$, unten: Vorhersagezeitraum 2 Stunden, $N = 15$.

Die Darstellung der Gewichte läßt für die 30 Minuten Vorhersage erwarten, daß die Vorhersagefehler für die integrierte Testmenge nur sehr geringfügig ansteigen, wenn die Moden der Ausgangsschicht jeweils nur mit den entsprechenden Moden der Eingabeschicht verbunden sind. Andererseits verringert sich dadurch die Anzahl der Verbindungen von $2N^2$ auf $2N$, und es ist eine deutliche Reduktion des Übertrainings zu erwarten. Dies wird durch Abb. 3.15 bestätigt, wo die Vorhersagefehler für die beiden Modelle, vollständige Verbindung der Schichten und Verbindung einzelner Neuronen, aufgetragen sind. Dabei werden die Vorhersagefehler jeweils für die integrierte und die unabhängige Testmenge betrachtet.

Es wird deutlich, daß für das Modell mit der reduzierten Anzahl an Verbindungen kaum noch Übertraining auftritt, die Kurven für die integrierte und die unabhängige Testmenge liegen sehr nahe zusammen. Dadurch ist für die unabhängige Testmenge der Fehler gegenüber vollständiger Verbindung der Schichten reduziert. Entsprechend des relativ geringen Unterschiedes der Fehler für integrierte und unabhängige Testmenge, auch für das Modell mit vollständiger Verbindung der Schichten ($\epsilon_1(te \in tr) = 18.3, \epsilon_1(te \notin tr) = 19.5$), ist die Verbesserung nicht sehr groß ($\epsilon_2(te \notin tr) = 19.0$).

Die Anzahl der Verbindungen kann für den Vorhersagezeitraum 30 Minuten für Netze mit zwei

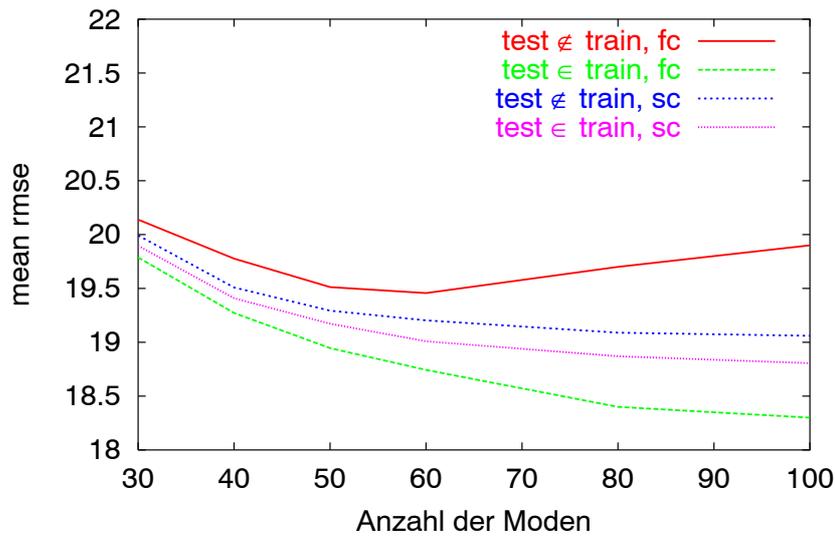


Abbildung 3.15: Mittlere Vorhersagefehler in Abhängigkeit von der Anzahl der Moden am Beispiel von Klasse 3 und Vorhersagezeitraum 30 Minuten. Verglichen werden Netze mit vollständiger Verbindung der Schichten (full connection: fc) mit Netzen, bei denen die Moden der Ausgabeschicht nur mit den entsprechenden Moden der Eingabeschicht verbunden sind (single connection: sc).

Schichten erheblich reduziert werden. Da die hohe Anzahl der Gewichte ein wesentliches Problem bei der Einführung einer dritten Schicht darstellte, wurde nun untersucht, ob eine versteckte Schicht die Ergebnisse bei dem Modell mit reduzierter Anzahl von Verbindungen verbessern kann. Dazu sind in Abb. 3.16 die Vorhersagefehler in Abhängigkeit von der Anzahl der Trainingsschritte aufgetragen. Bei dem Netz mit drei Schichten wurden für jede Mode zwei versteckte Neuronen verwendet, eine Erhöhung der Anzahl der versteckten Neuronen führte nicht zu einer Verbesserung. Es wird deutlich, daß der Fehler von Netzen mit drei Schichten gegenüber Netzen mit zwei Schichten um ca. 2% verringert ist.

Für den Vorhersagezeitraum 2 Stunden wurden entsprechend den Ergebnissen aus Abb. 3.14 Verbindungskonfigurationen getestet, bei denen die Moden aus dem Bild $(t + \Delta t)$ jeweils nur mit den entsprechenden und niedrigeren Moden aus den Bildern t und $(t - 30min)$ verbunden wurden. Dies führte jedoch zu keiner Verbesserung, weshalb das ursprüngliche Modell beibehalten wurde.

Als Zusammenfassung ergibt sich, daß für den Vorhersagezeitraum 30 Minuten durch die Reduktion auf Verbindung zwischen sich entsprechenden Moden die Vorhersagequalität erhöht wird. Die Verwendung einer versteckten Schicht führt für dieses Modell zu einer weiteren Verbesserung. Für 2 Stunden Vorhersage werden mit dem Modell mit vollständiger Verbindung aller Neuronen die besten Ergebnisse erzielt. Für die anderen Vorhersagezeiträume bleibt die beste Konfiguration noch festzulegen. Durch die Reduktion der Anzahl der Verbindungen gelingt es, Übertraining zu reduzieren. Die zugrunde liegende Dynamik kann jedoch nicht besser beschrieben werden. Dementsprechend sind die Verbesserungen nur klein.

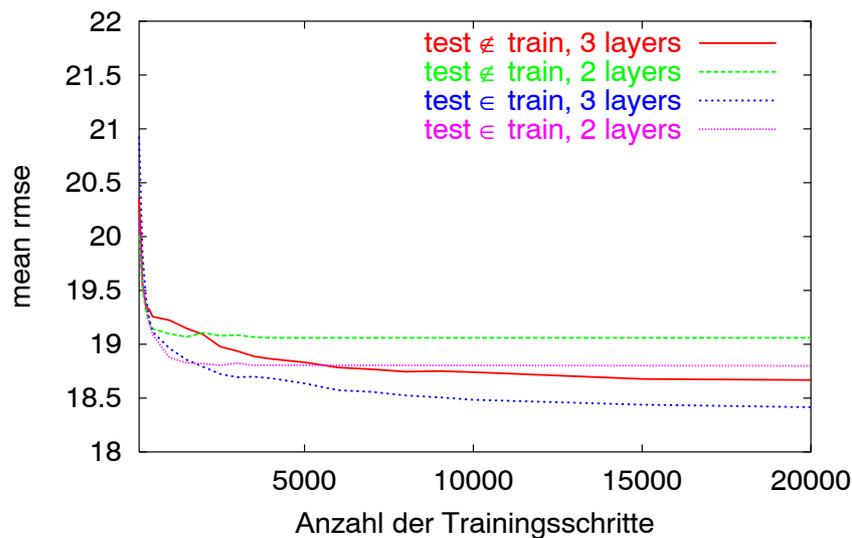


Abbildung 3.16: Mittlere Vorhersagefehler in Abhängigkeit von der Anzahl der Trainingsschritte am Beispiel von Klasse 3, Vorhersagezeitraum 30 Minuten und $N = 100$. Vergleich von neuronalen Netzen mit 2 Schichten und 3 Schichten, bei denen die Moden der Ausgabeschicht nur mit den entsprechenden Moden der Eingabeschicht verbunden sind.

Optimale Netz-Parameter für die verschiedenen Bewölkungs-Klassen und Vorhersagezeiträume

In diesem Abschnitt werden für die verschiedenen Klassen und Vorhersagezeiträume die optimalen Netzkonfigurationen und die dazugehörigen Anzahlen von Moden festgelegt. Die optimale Netzkonfiguration muß für jede Klasse und für jeden Vorhersagezeitraum getrennt bestimmt werden. Dabei lassen sich Netze mit 3 Schichten und vollständiger Verbindung aller Neuronen für alle Situationen ausschließen, da sich für diese Netzkonfiguration wegen starken Übertrainings hohe Vorhersagefehler ergeben. Dagegen führte die Reduktion der Anzahl der Verbindungen gegenüber vollständiger Verbindung der Schichten zu Verbesserungen der Vorhersagequalität für Klasse 3 für den Vorhersagezeitraum 30 Minuten. So wurden zur weiteren Untersuchung die folgenden Netzkonfigurationen ausgewählt: Netze mit 2 Schichten mit vollständiger Verbindung aller Neuronen, Netze mit 2 Schichten mit Verbindung der sich entsprechenden Moden und Netze mit 3 Schichten mit Verbindung der sich entsprechenden Moden über eine versteckte Schicht.

Für die drei Netztypen wurde durch systematische Variation die jeweils optimale Anzahl von Moden gesucht. Ein Vergleich der Vorhersagefehler für die verschiedenen Netztypen bei der jeweiligen optimalen Anzahl von Moden ergibt dann, welches Netz für eine bestimmte Situation am besten geeignet ist. Die Ergebnisse sind in Tabelle 3.3 zusammengefaßt. Für jeden Vorhersagezeitraum ist für alle Bewölkungs-Klassen die optimale Netzkonfiguration mit der entsprechenden Anzahl von Moden und dem Vorhersagefehler gegeben.

| Vorhersage- zeitraum | Klasse 1 | | | Klasse 2 | | | Klasse 3 | | | Klasse 4 | | |
|-------------------------|----------|-----|------|----------|----|------|----------|----|------|----------|----|------|
| | Netz | N | rmse | Netz | N | rmse | Netz | N | rmse | Netz | N | rmse |
| 30 min | sc2 | 120 | 12.4 | sc2 | 80 | 20.4 | sc3 | 80 | 18.7 | sc2 | 60 | 30.0 |
| 60 min | sc2 | 60 | 15.6 | sc2 | 20 | 24.6 | sc3 | 30 | 24.0 | sc2 | 20 | 35.7 |
| 90 min | sc2 | 20 | 17.6 | sc2 | 15 | 27.5 | sc3 | 20 | 28.0 | fc2 | 15 | 39.1 |
| 120 min | fc2 | 10 | 19.5 | fc2 | 5 | 29.7 | fc2 | 10 | 31.3 | fc2 | 5 | 42.5 |

Tabelle 3.3: Optimale Netzkonfiguration und Vorhersagefehler für die verschiedenen Klassen und Vorhersagezeiträume. Bezeichnung der Netztypen: fc (full connection): Netz mit vollständiger Verbindung der Schichten, sc (single connection): Netz, bei dem die Moden der Ausgabeschicht nur mit den entsprechenden Moden der Eingabeschicht verbunden sind. Die Anzahl der Schichten ist direkt neben dem Netztyp gegeben.

Bezüglich der Netzkonfiguration läßt sich feststellen, daß für die Vorhersagezeiträume 30 Minuten bis zu 90 Minuten für alle Klassen die Netzkonfigurationen mit reduzierten Verbindungen zu den besten Ergebnissen führen (Ausnahme: Klasse 4, Vorhersagezeitraum 90 Minuten). Für Klasse 3 kann eine zusätzliche Verbesserung durch Einführung einer versteckten Schicht erreicht werden. In den anderen Klassen ist die zur Verfügung stehende maximale Anzahl von Trainingsbeispielen kleiner (siehe Tabelle 3.2), so daß sich hier wegen stärkeren Übertrainings bei Einführung der dritten Schicht keine Verbesserung mehr ergibt. Für den Vorhersagezeitraum 2 Stunden (für Klasse 4 auch für den Vorhersagezeitraum 90 Minuten) ist ein zweischichtiges Netz mit Verbindung aller Neuronen untereinander am günstigsten. Die optimale Anzahl der Moden sinkt für längere Vorhersagezeiträume. Außerdem zeigt sich, daß die günstigste Anzahl der Moden auch von der Klasse abhängt. Je größer die mittlere Variabilität einer Klasse ist, desto größer ist der Vorhersagefehler und desto kleiner die optimale Anzahl von Moden.

Abschließend wurde untersucht, inwieweit durch Verlängerung der Trainingsmenge die Ergebnisse verbessert werden können. Es ergab sich, daß für Klasse 3, die gemäß Tabelle 3.2 die meisten Trainingsbeispiele enthält, die Länge der Trainingsmenge ausreichend ist. Für die anderen Klassen, insbesondere für Klasse 2 mit einer sehr geringen Anzahl von Trainingsbeispielen, wären bei Verlängerung der Trainingsmenge etwas bessere Vorhersageergebnisse zu erwarten. Im Vergleich zu der in Kapitel 4 verwendeten Vorhersagemethode sind die Vorhersagefehler mit neuronale Netzen jedoch auch nach dieser zu erwartenden Verbesserung deutlich höher. Deshalb wurde auf eine weitere diesbezügliche Optimierung verzichtet.

3.7 Ergebnisse und Fehleranalyse

Nachdem durch Optimierung der Parameter und Training der neuronalen Netze die Vorhersagefunktionen für die verschiedenen Klassen und Vorhersagezeiträume festgelegt wurden, wird abschließend die Vorhersagequalität bewertet. Dazu wurden zum einen die Vorhersagefehler be-

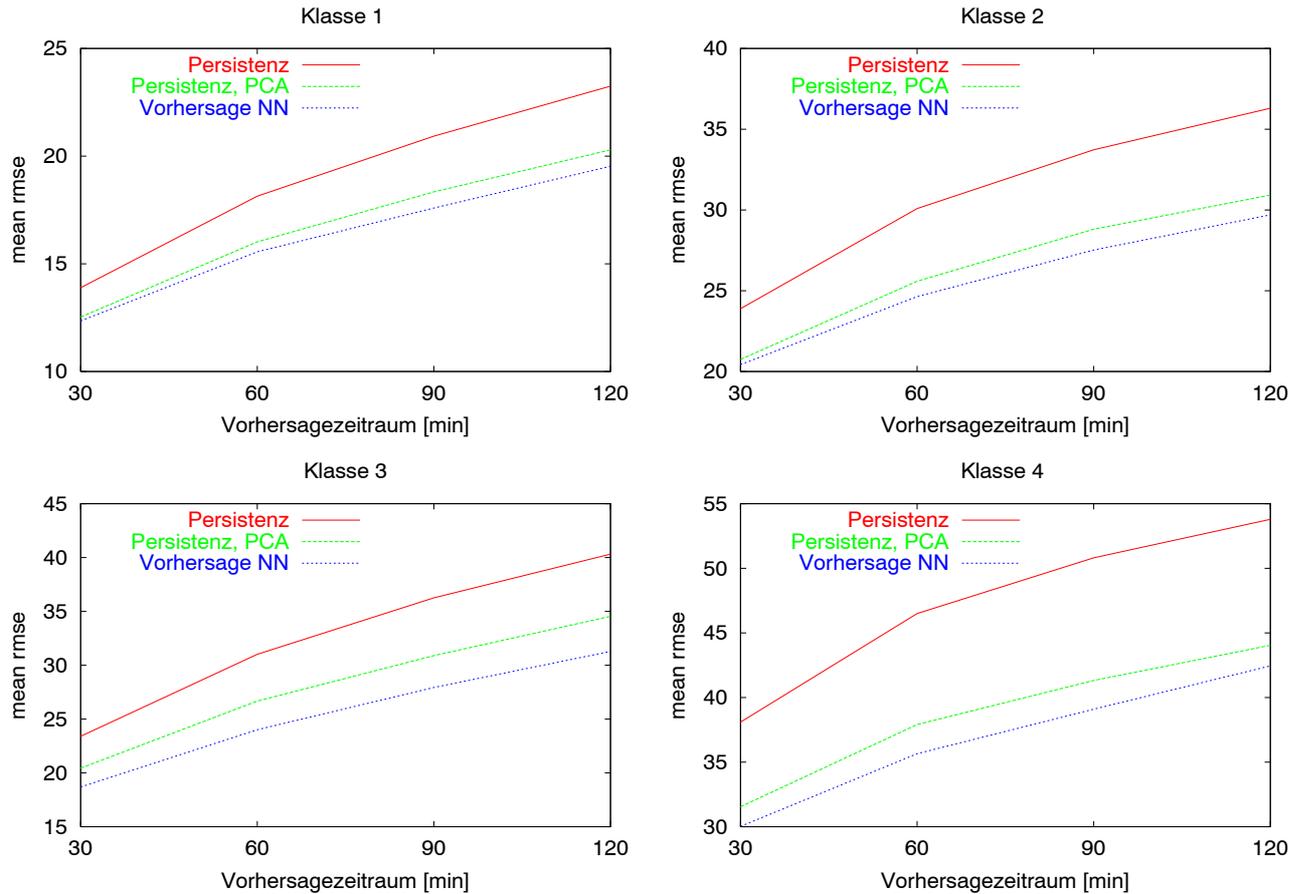


Abbildung 3.17: Mittlere Vorhersagefehler in Abhängigkeit vom Vorhersagezeitraum für die verschiedenen Bewölkungs-Klassen. Oben: Klasse 1 und Klasse 2, unten: Klasse 3 und Klasse 4.

stimmt und mit Persistenz verglichen. Zum anderen wurde untersucht, welche Bedingungen die Vorhersagequalität bestimmen.

Zunächst werden, wie in den vorangehenden Abschnitten, die mittleren Fehler der Zeitreihe betrachtet. In Abb. 3.17 sind für die verschiedenen Klassen die Vorhersagefehler über dem Vorhersagezeitraum aufgetragen. Zum Vergleich sind die entsprechenden Persistenzfehler und die Persistenzfehler der Hauptkomponenten-transformierten Bilder eingezeichnet. Die Anzahl der Moden für die transformierten Bilder wurde dabei so gewählt, daß die Persistenzfehler minimiert werden.

Ergänzend zu den mittleren Fehlern zeigt Abb. 3.18 für Persistenz und Vorhersage den *rmse* für einzelne Bildausschnitte in Abhängigkeit von der Variabilität. Dabei sind zusätzlich Kurven der mittleren und der maximal erwarteten Fehler für die Vorhersage eingezeichnet. Die Berechnung der mittleren und maximal erwarteten Fehler erfolgte dabei für diskrete Intervalle der Variabilität der Intervallbreite $\Delta I = 5$. Als maximale Fehler werden für jedes Intervall die Werte angegeben, unterhalb derer 95% aller Fehler liegen.

Weiterhin ist in Abb. 3.19 ein Beispiel eines vorhergesagten Bildes neben dem zugehörigen Ori-

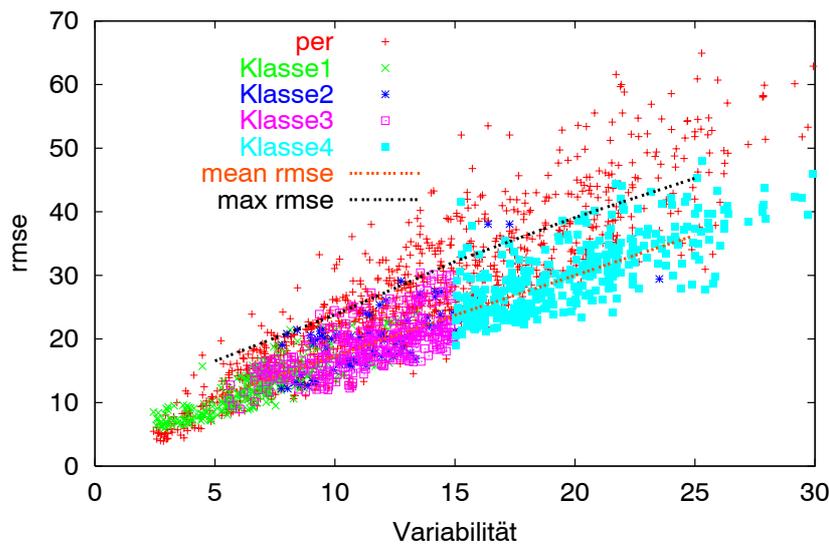


Abbildung 3.18: Vorhersagefehler in Abhängigkeit von der Variabilität im Vergleich zur Persistenz für den Vorhersagezeitraum 30 Minuten.

nalbild und dem Persistenzbild gezeigt (linke Spalte). Zusätzlich sind ein Bild der lokalen Variabilität und Fehlerbilder für Persistenz und Vorhersage gegeben (rechte Spalte). Die lokale Variabilität ist dabei definiert als:

$$var_i = \max_n |x_i - x_{n,i}| \quad \text{mit } x_{n,i} \text{ Nachbar von } x_i. \quad (3.27)$$

In den Fehlerbildern ist der Absolutbetrag des Fehlers

$$e_i = |m_i - f_i| \quad (3.28)$$

zwischen den Pixeln im Originalbild m_i und den entsprechenden Pixeln des Vorhersagebildes f_i aufgetragen.

Anhand der drei Abbildungen sollen nun zwei Fragestellungen, die für die Vorhersagequalität wesentlich sind, näher untersucht werden:

- Welchen Einfluß hat die Glättung der Bilder auf den Vorhersagefehler?
- Inwieweit läßt sich Wolkenbewegung durch die Vorhersage erfassen?

Einfluß der Glättung der Bilder auf den Vorhersagefehler

Ein Vergleich des Persistenzfehlers mit dem Fehler der Persistenz von Hauptkomponenten-transformierten Bildern in Abb. 3.17 zeigt, daß durch die Verwendung der transformierten Bilder als

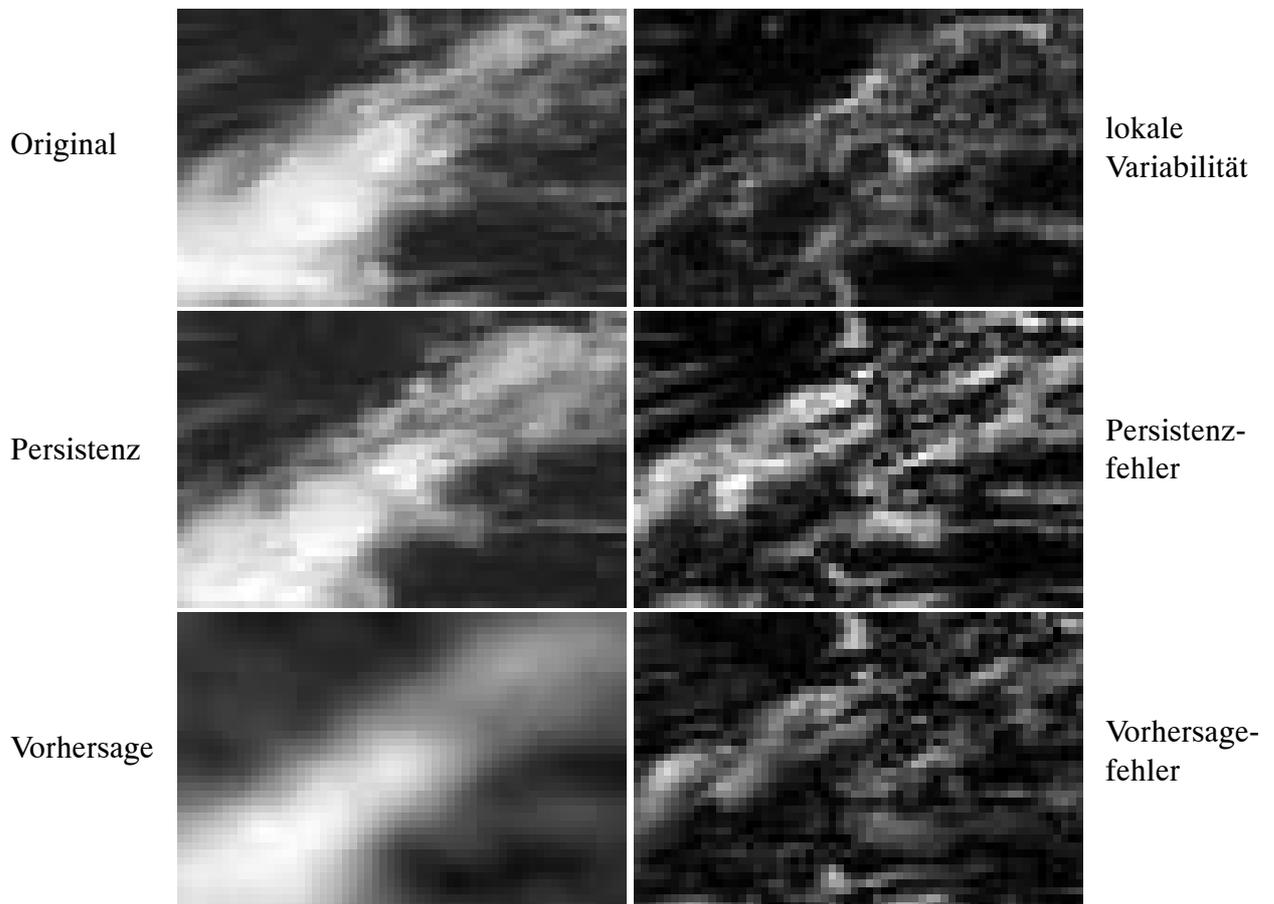


Abbildung 3.19: Beispiel der Vorhersage für den 29.6.1997, 10:30 und den Vorhersagezeitraum 30 Minuten. In der linken Spalte sind von oben nach unten das vorherzusagende Bild, das Persistenzbild und das Vorhersagebild dargestellt. Die rechte Spalte zeigt von oben nach unten ein Bild der lokalen Variabilität, Persistenzfehler und Vorhersagefehler. Zur besseren Visualisierung sind Werte der lokalen Variabilität verdreifacht und die Fehler verdoppelt dargestellt.

Ausgangspunkt der Persistenz der Persistenzfehler deutlich reduziert wird. Dies ist darauf zurückzuführen, daß die Hauptkomponenten-Transformation zu einer Glättung der Bilder führt (siehe Abschnitt 3.2.2 und Abb. 3.3). Durch Glättung läßt sich, unter bestimmten Voraussetzungen, die Vorhersagequalität erhöhen, was im Folgenden kurz theoretisch motiviert werden soll:

Die Entwicklung der Bewölkung ist, wie schon in Abschnitt 3.2.1 dargestellt, nicht vollständig deterministisch, sondern durch Rauschen überlagert. Durch die Anwendung eines Tiefpaßfilters kann der Rauschanteil reduziert werden, was zu einer besseren Übereinstimmung des berechneten Bildes mit der tatsächlichen zu beschreibenden Situation führt (siehe [Jähne 1989] und [Schowen-gerdt 1997]). Die Faltung mit einem Tiefpaßfilter führt zur Unterdrückung kleinskaliger Strukturen, was einer Glättung der Bilder gleichkommt.

Auch der deterministische Anteil der Bewölkungsentwicklung ist durch die Anwendung eines Glättungsfilters beeinflusst. So würde im Fall einer perfekten Beschreibung des deterministischen

Anteils durch die Vorhersage die Anwendung eines Tiefpaßfilters aufgrund der Unterdrückung von Detail-Informationen zu einer Verringerung der Vorhersagequalität führen. Wird jedoch die der Verschiebung von Bewölkungsstrukturen zugrunde liegende Geschwindigkeit durch den Vorhersagealgorithmus nicht exakt beschrieben, so kann auch für den deterministischen Anteil durch Glättung eine Verbesserung erreicht werden. Dies soll anhand eines einfachen Beispiels erläutert werden:

Man gehe davon aus, daß die Bewegung in einem unendlich ausgedehnten Bild exakt einer konstanten Verschiebung in x-Richtung um v Pixel pro Zeitschritt entspricht. Der Meßwert $m_{i,j}$ nach einem Zeitschritt berechnet sich dann aus dem ursprünglichen Bild $x_{i,j}$ gemäß

$$m_{i,j} = x_{i+v,j}. \quad (3.29)$$

Die bei der Vorhersage angenommene Geschwindigkeit sei gegenüber der tatsächlichen Geschwindigkeit v um einen kleinen Betrag a erhöht, so daß sich die Vorhersage zu

$$f_{i,j} = x_{i+v+a,j} \quad (3.30)$$

ergibt. Der Vorhersagefehler für das gesamte Bild beträgt dann nach Gleichung (3.23):

$$rmse = \sqrt{\frac{1}{N} \sum_{i,j} (f_{i,j} - m_{i,j})^2} = \sqrt{\frac{1}{N} \sum_{i,j} (x_{i+v+a,j} - x_{i+v,j})^2} \quad (3.31)$$

$$= \sqrt{\frac{1}{N} \sum_{i,j} (x_{i+a,j} - x_{i,j})^2}. \quad (3.32)$$

Durch Glättung werden die Unterschiede zwischen nicht zu weit voneinander entfernt liegenden Pixeln kleiner. So ist es unmittelbar einsichtig, daß der Wert des Ausdrucks auf der rechten Seite dieser Gleichung, und somit auch der Vorhersagefehler, durch Anwendung eines geeigneten Glättungsfilters verringert wird. Welcher Glättungsfiler für ein bestimmtes Problem optimal ist, hängt von verschiedenen Faktoren ab. Bestimmend sind u.a. das Verhältnis des deterministischen Anteils zum Rauschanteil, die Rauschfrequenzen und die Qualität des Vorhersagemodells in Bezug auf den deterministischen Anteil. Da mit steigendem Vorhersagezeitraum der nichtdeterministische Anteil der Bewölkungsentwicklung stärker ins Gewicht fällt, ist für höhere Vorhersagezeiträume eine stärkere Glättung erforderlich.

Die Ausführungen zur Glättung tragen auch zum Verständnis des Zusammenhangs zwischen Variabilität und Vorhersagefehler bei, der in den Abb. 3.18 und 3.19 deutlich wird. So zeigt Abb. 3.18 den Anstieg des Vorhersagefehlers mit der Variabilität. Ebenso veranschaulicht ein Vergleich der Bilder der rechten Spalte in Abb. 3.19, daß für die Bildausschnitte Bereiche hoher Variabilität mit Bereichen hoher Fehler übereinstimmen. Auf der einen Seite ist eine höhere Variabilität im Allgemeinen mit einem größeren Rauschanteil verbunden, was zu höheren Vorhersagefehlern führt. Auf der anderen Seite erhöht sich auch der nichtdeterministische Anteil des Vorhersagefehlers mit der Variabilität, wenn die Vorhersage nicht perfekt ist. Dies wird an Gleichung (3.32) deutlich, da der Ausdruck auf der rechten Seite ein Maß für die Variabilität eines Bildes darstellt.

Beschreibung der Wolkenbewegung durch Vorhersage mit neuronalen Netzen

Ein zentraler Faktor bei der Wolkenentwicklung ist die Bewegung von Wolkenstrukturen. Wenn die Verschiebung von Wolkenstrukturen durch den Vorhersagealgorithmus erfaßt wird, sollte die Vorhersage zu einer deutlichen Verbesserung gegenüber der Persistenz führen. Abb. 3.17 zeigt jedoch, daß die Fehler im Vergleich zur Persistenz von Hauptkomponenten-transformierten Bildern nur wenig sinken. Dies läßt darauf schließen, daß Wolkenbewegung durch die Vorhersage mit neuronalen Netzen nicht erfaßt wird. Auch an dem Beispiel in Abb. 3.19 wird dies deutlich. Ein Vergleich des Originalbildes sowie des Persistenzbildes mit dem vorhergesagten Bild zeigt, daß sich die Wolkenstruktur im vorhergesagten Bild an der gleichen Stelle wie im Persistenzbild befindet. Die Wolkenstruktur wurde durch den Vorhersagealgorithmus nicht verschoben. Dementsprechend sind im Fehlerbild für die Vorhersage (Abb. 3.19, rechts unten) die Fehler an den Wolkenkanten besonders hoch.

Zusammenfassung und Ausblick

Zusammenfassend läßt sich feststellen, daß der entwickelte Algorithmus mit neuronalen Netzen zur Vorhersage wenig geeignet ist, da Bewegungen von Wolkenstrukturen nicht erfaßt werden. Die Reduktion des Vorhersagefehlers bei Verwendung des Vorhersagealgorithmus gegenüber der Persistenz ist im Wesentlichen auf den Effekt der Glättung der Bilder durch Hauptkomponenten-Transformation zurückzuführen. Es wurde eine ausführliche Optimierung bezüglich der Netzarchitektur durchgeführt. Dies läßt darauf schließen, daß allgemein Feed-Foward-Netze keine geeignete Methode zur Beschreibung der Wolkenentwicklung darstellen.

Neuronale Netze sind eine rein statistische Methode, physikalische Informationen über die Wolkenentwicklung gehen in das Modell nicht ein. So wird auch das Wissen, daß die durch das Windfeld verursachte Bewegung einen wesentlichen Aspekt der Wolkenentwicklung darstellt, nicht genutzt. Im Kapitel 4 wird ein Vorhersagemodell vorgestellt, das diese Tatsache als grundlegende Modellannahme verwendet. Weiterhin wird die Kombination dieses Modells mit neuronalen Netzen untersucht.

Kapitel 4

Vorhersage von Wolkenbildern mit Bewegungsvektoren

Die zeitliche Entwicklung der Bewölkungssituation ist stark von der Bewegung von Wolkenstrukturen geprägt. Auch andere Phänomene wie Auflösung und Entstehung von Bewölkung und Veränderung kleinskaliger Strukturen spielen eine Rolle. Die Betrachtung von Bildfolgen zeigt jedoch, daß die Verschiebung von Wolkenstrukturen für den hier interessierenden Kurzzeitbereich in den meisten Situationen den entscheidenden Faktor darstellt.

So ist zu erwarten, daß die zeitliche Entwicklung der Bewölkung für kurze Zeiträume durch Bewegungsvektorfelder gut charakterisiert werden kann. Von [Bahner et al. 1996] wurde eine funktionalanalytische Methode zur Bestimmung von Bewegungsvektorfeldern aus Satellitendaten entwickelt. [Cote et al. 1995] nutzten Hopfield-Netze, um in Folgen von Satellitenbildern übereinstimmende Strukturen zu identifizieren und diese durch Bewegungsvektoren zu verbinden. [Beyer et al. 1994] und [Hamil et al. 1993] berechneten Bewegungsvektorfelder durch Maximierung der Kreuzkorrelation zwischen verschiedenen Bildausschnitten und setzten diese zur Vorhersage ein.

Die in diesem Kapitel vorgestellten Vorhersagealgorithmen beruhen ebenfalls auf der Beschreibung der Wolkenbewegung. In einem ersten Schritt werden aus zwei aufeinander folgenden Bildausschnitten Bewegungsvektoren berechnet. Diese Bewegungsvektoren werden auf die aktuellen Bilder angewendet, um die Vorhersagebilder zu erhalten. Die Vorhersage wurde dabei für Vorhersagezeiträume von 30 Minuten bis zu 2 Stunden durchgeführt. Da durch Glättung die Vorhersagequalität erhöht werden kann, wie in Abschnitt 3.7 dargelegt wurde, wird in einem letzten Schritt ein Glättungsfilter auf die Bilder angewandt. Der zentrale Punkt in den Vorhersagemodellen ist die Bestimmung von Bewegungsvektoren, die für die verschiedenen Modelle auf unterschiedliche Art durchgeführt wird. Dazu werden zunächst vereinfachende, grundlegende Annahmen über die Bewegung festgelegt. Diese werden in Bewegungsmodellen mathematisch formuliert und dienen als Grundlage der Berechnung der Bewegungsvektoren.

Im ersten Abschnitt dieses Kapitels werden zwei verschiedene Methoden zur Berechnung von Bewegungsvektoren eingeführt. Im nächsten Abschnitt wird der vollständige Vorhersagealgorithmus unter Verwendung von Bewegungsvektoren beschrieben. Anschließend wird die optimale Anpas-

sung des Verfahrens zur Vorhersage durch Einstellen verschiedener Parameter behandelt. Die Vorhersageergebnisse werden in Abschnitt 4.4 analysiert und mit den Ergebnissen der Vorhersage mit neuronalen Netzen verglichen. Im letzten Abschnitt des Kapitels wird ein Verfahren, das neuronale Netze mit Bewegungsinformation kombiniert, vorgestellt und bewertet.

4.1 Methoden zur Bestimmung von Bewegungsvektoren

Verfahren zur Bestimmung von Bewegung in Bildsequenzen beruhen allgemein darauf, in den aufeinander folgenden Bildern Bildpunkte zu identifizieren, die aufeinander abgebildet werden, und diese durch Bewegungsvektoren zu verbinden. Die Bestimmung der sich entsprechenden Bildpunkte kann dabei pixelweise, für Blöcke oder für Regionen und Objekte geschehen. Eine umfassende Darstellung verschiedener Methoden der Bewegungserkennung und ihrer Vor- und Nachteile findet sich in [Stiller et al. 1999].

Um die Identifikation der sich entsprechenden Bildteile zu ermöglichen, müssen Annahmen über die Bewegung getroffen werden, die u.a. festlegen, welche charakteristischen Eigenschaften eines Bildelements bei der Bewegung erhalten bleiben. Bei den in dieser Arbeit verwendeten Verfahren zur Beschreibung der Bewegung wurden folgende Annahmen zugrunde gelegt:

- Der Bewölkungsgrad eines Pixels verändert sich während der Bewegung nicht. Für kurze Vorhersagezeiträume ist diese Annahme eine gute Näherung.
- Das Vektorfeld, das die Bewegung beschreibt, ist glatt, d.h. benachbarte Vektoren zeigen in Bezug auf ihre Richtung und ihren Betrag nur geringe Unterschiede. Dies ist dadurch motiviert, daß die Wolkenbewegung im Wesentlichen durch das in Wolkenhöhe weitgehend glatte Windfeld verursacht wird.

Im Folgenden wird zunächst ein statistisches Verfahren zur Bewegungserkennung dargestellt. Das zweite vorgestellte Verfahren beruht auf der Minimierung mittlerer quadratischer Pixeldifferenzen zwischen verschiedenen Bildausschnitten.

4.1.1 Statistische Methode

Die hier vorgestellte Methode zur Bewegungserkennung beruht auf einem Verfahren von [Konrad et al. 1992] und wurde von [Lückehe 1999] zur Vorhersage von Cloud-Index Bildern eingesetzt und modifiziert. Die Grundzüge der Methode lassen sich in drei Punkte gliedern. Zunächst wird ein Kriterium zur Bewertung der Qualität eines Vektorfelds festgelegt. Die grundlegenden Annahmen über die Bewegung werden in einem wahrscheinlichkeitstheoretischen Modell formuliert. Schließlich wird das Vektorfeld, das die Bewegung zwischen zwei vorgegebenen Bildern mit der größten Wahrscheinlichkeit beschreibt, über einen Monte Carlo Algorithmus bestimmt.

Terminologie

Das zugrunde liegende Bild, hier die reale Bewölkungssituation, wird mit u bezeichnet. Das beobachtete Bild n (Cloud-Index Bild) wird als Realisierung eines Zufallsfelds N angenommen. Die Bilder u_0 und n_0 stehen dabei jeweils für die Situation zum Zeitpunkt t_0 , während die Bilder u_1 und n_1 die darauffolgenden Bilder zum Zeitpunkt $t_1 = t_0 + \Delta t$ bezeichnen. Das Verschiebungsfeld d ist die Realisierung eines Zufallsvektorfeldes D .

Bewertungskriterium

Ziel des Verfahrens ist es, das Vektorfeld zu finden, das die Bewegung zwischen zwei vorgegebenen Bildern mit der größten Wahrscheinlichkeit beschreibt. Über ein „maximum a posteriori“ Kriterium wird das wahrscheinlichste Vektorfeld d^* definiert, das folgende Relation erfüllt:

$$P(D = d^* | n_0, n_1) \geq P(D = d | n_0, n_1) \quad \forall d \in D, \quad (4.1)$$

wobei P die bedingte Wahrscheinlichkeit für das Vektorfeld d bezeichnet, wenn die Bilder n_0 und n_1 gegeben sind. Zur Berechnung dieser Wahrscheinlichkeit wird der Satz von Bayes (siehe [Konrad et al. 1992]) angewendet:

$$P(D = d | n_0, n_1) = \frac{P(n_1 = n_1 | d, n_0) P(D = d | n_0)}{P(n_1 = n_1 | n_0)}. \quad (4.2)$$

Da $P(n_1 = n_1 | n_0)$ nicht von d abhängt, bleibt noch das Maximum von $P(n_1 = n_1 | d, n_0) * P(D = d | n_0)$ zu bestimmen. Zur Lösung dieses Problems müssen die Wahrscheinlichkeitsverteilungen bekannt sein. Sie werden durch die mathematische Formulierung der Grundannahmen festgelegt.

Modell der Bewegung

Die Annahme, daß sich die Pixelintensitäten für die zugrunde liegende Bewölkungssituation während der Bewegung nicht ändern, wird über die Beziehung

$$u_0(\vec{x}) = u_1(\vec{x} + \vec{d}(\vec{x})) \quad (4.3)$$

berücksichtigt. Zusätzlich wird für diese Methode angenommen, daß auch die Gradienten der Pixelintensität für die zugrunde liegende Bewölkungssituation während der Bewegung erhalten bleiben:

$$\nabla u_0(\vec{x}) = \nabla u_1(\vec{x} + \vec{d}). \quad (4.4)$$

Die Bedingung konstanter Pixelintensität ist in der Realität nur näherungsweise erfüllt, da die Bewegung durch kleinskalige nichtdeterministische Veränderungen der Bewölkungssituation überlagert ist. Hinzu kommt, daß die beobachteten Bilder n_0 und n_1 durch einen Meßprozeß aus den zugrunde liegenden Bildern gewonnen werden, wodurch u.a. Rauschen hinzugefügt wird und die

Bilder diskretisiert werden. Um die Annahme konstanter Pixelintensität von u auf n auszuweiten, werden zunächst „versetzte Pixeldifferenzen“ definiert:

$$r(\vec{d}(\vec{x}_i), \vec{x}_i) = n_1(\vec{x}_i + \vec{d}(\vec{x}_i)) - n_0(\vec{x}_i). \quad (4.5)$$

Gleichung (4.3) läßt sich dann für die beobachteten Bilder n als unabhängiger Gauß'scher Zufallsprozeß modellieren:

$$P(r) \approx e^{-r^2/2\sigma^2}, \quad (4.6)$$

i.e. die Wahrscheinlichkeit für kleine Differenzen zwischen $n_1(\vec{x}_i + \vec{d}(\vec{x}_i))$ und $n_0(\vec{x}_i)$ ist groß. Für ein Bild n_0 und ein festgelegtes Vektorfeld d ergibt sich mit den Gleichungen (4.5) und (4.6) dann die bedingte Wahrscheinlichkeit für n_1 , wenn d auf n_0 angewendet wird:

$$P(n_1 = n_1 | d, n_0) = c_1 e^{-U_n/2\sigma^2}. \quad (4.7)$$

Hierbei ist c_1 eine Normalisierungskonstante und die Energie U_n ist definiert als

$$U_n = \sum_i r(\vec{d}(\vec{x}_i), \vec{x}_i)^2. \quad (4.8)$$

Das Bild n_1 ist also eine wahrscheinliche Realisierung von n_1 , wenn die Differenzen zwischen $n_1(\vec{x}_i + \vec{d}(\vec{x}_i))$ und $n_0(\vec{x}_i)$ für alle betrachteten Gitterpunkte klein sind. Hierbei sei noch bemerkt, daß nicht für alle Bildpunkte Vektoren berechnet werden, sondern ein Subgitter gewählt wird.

Für die Annahme konstanter Pixelgradienten läßt sich analog zu Gleichung (4.5)

$$r_{grad}(\vec{d}(\vec{x}_i), \vec{x}_i) = \nabla n_1(\vec{x}_i + \vec{d}(\vec{x}_i)) - \nabla n_0(\vec{x}_i) \quad (4.9)$$

definieren. Unter Verwendung der gleichen Argumentation wie oben ergibt sich schließlich

$$P(n_1 = n_1 | d, n_0) = c_2 e^{-U_n/2\sigma^2 - U_{grad}/2\sigma_{grad}^2}, \quad (4.10)$$

mit der Normalisierungskonstante c_2 und

$$U_{grad} = \sum_i r_{grad}(\vec{d}(\vec{x}_i), \vec{x}_i)^2. \quad (4.11)$$

Für kleine Unterschiede zwischen $n_1(\vec{x}_i + \vec{d}(\vec{x}_i))$ und $n_0(\vec{x}_i)$ bzw. zwischen $\nabla n_1(\vec{x}_i + \vec{d}(\vec{x}_i))$ und $\nabla n_0(\vec{x}_i)$ für alle betrachteten Punkte sind die Energiefunktionen klein, und somit ist die Wahrscheinlichkeit $P(n_1 = n_1 | d, n_0)$ groß.

Zur Festlegung der Verteilungsfunktion für $P(D = d | n_0)$ wird die zweite Grundannahme, die Glattheit des Vektorfeldes, genutzt. Dabei geht man davon aus, daß ein einzelnes Bild wenig Information zu der Wahrscheinlichkeit für ein Vektorfeld beiträgt, weshalb nur Eigenschaften des Vektorfeldes selbst betrachtet werden. Die Glattheit des Vektorfeldes ist dadurch charakterisiert, daß sich benachbarte Vektoren in Länge und Richtung nur wenig unterscheiden. Unter Verwendung wahrscheinlichkeitstheoretischer Annahmen ([Konrad et al. 1992], führt dies zu

$$P(D = d | n_0) = c_3 e^{-U_d/\beta}, \quad (4.12)$$

wobei c_3 wieder eine Normalisierungskonstante ist und β eine Konstante, die Eigenschaften des Vektorfeldes charakterisiert. U_d ist definiert als

$$U_d = \sum_{i,j \in N} \|\vec{d}(\vec{x}_i) - \vec{d}(\vec{x}_j)\|^2, \quad (4.13)$$

wobei $\vec{d}(\vec{x}_i)$ und $\vec{d}(\vec{x}_j)$ benachbarte Vektoren sind. Ein Vektorfeld mit großen Unterschieden zwischen benachbarten Vektoren hat somit eine hohe Energie, was gleichbedeutend mit einer geringen Wahrscheinlichkeit ist.

Nachdem die beiden gesuchten Wahrscheinlichkeitsverteilungen bestimmt sind, ergibt sich die bedingte Wahrscheinlichkeit für ein Vektorfeld d , bei vorgegebenen Bildern n_0 und n_1 zu

$$P(D = d | n_0, n_1) = \frac{1}{Z} e^{-U}, \quad (4.14)$$

mit der Normalisierungskonstante Z und der Gesamtenergiefunktion

$$U = \lambda_1 U_n + \lambda_2 U_{grad} + \lambda_3 U_d. \quad (4.15)$$

Die Parameter $\lambda_1 = 1/2\sigma^2$, $\lambda_2 = 1/2\sigma_{grad}^2$ und $\lambda_3 = 1/\beta$ gewichten die Beiträge der verschiedenen Einzelenergien zu U . Das wahrscheinlichste Vektorfeld gemäß Beziehung 4.1 kann jetzt als Minimum der Energiefunktion U bestimmt werden.

Monte Carlo Methode

Das Minimum der Energiefunktion wird mit einer Monte Carlo Methode ermittelt. Dazu wird zunächst die Energiefunktion um einen „Temperaturfaktor“¹ T erweitert:

$$P(D = d | n_0, n_1) = \frac{1}{Z} e^{-U/T}. \quad (4.16)$$

Um das Minimum der Energiefunktion zu erhalten, wird zunächst ein Vektorfeld zufällig initialisiert. Anschließend werden die folgenden Schritte bis zur Konvergenz wiederholt:

- Zufällige Auswahl eines Vektors.
- Zufällige Veränderung des Vektors und Berechnung der Wahrscheinlichkeit für den neuen Vektor.
- Wenn

$$P(D = d_{neu} | n_0, n_1) \geq P(D = d_{alt} | n_0, n_1), \quad (4.17)$$

wird der neue Vektor akzeptiert.

¹Die Methode wird in Analogie zu einem chemischen Prozeß als „simulated annealing“ bezeichnet, daher stammt auch die Bezeichnung Temperaturfaktor.

- Wenn

$$P(D = d_{neu} | n_0, n_1) < P(D = d_{alt} | n_0, n_1), \quad (4.18)$$

wird der neue Vektor mit der Wahrscheinlichkeit

$$P(D = d_{neu} | d_{alt}, n_0, n_1) = \frac{1}{Z} e^{-(U_{neu} - U_{alt})/T} \quad (4.19)$$

angenommen.

Ein neuer Vektor kann also auch akzeptiert werden, wenn er eine geringere Wahrscheinlichkeit als der vorherige Vektor hat. So kann das Verfahren lokale Minima wieder verlassen. Je höher der Temperaturfaktor ist, desto größer wird die Wahrscheinlichkeit, daß ein weniger wahrscheinlicher Vektor akzeptiert wird. Ein hoher Temperaturfaktor ist also für den Beginn des Suchverfahrens, wenn das globale Minimum noch weit entfernt ist, von Vorteil. Es wird mit einer Ausgangstemperatur T_0 begonnen, der Temperaturfaktor wird dann mit jedem Iterationsschritt k erniedrigt:

$$T_k = T_0 e^{\alpha k}. \quad (4.20)$$

So wird die Wahrscheinlichkeit, ein einmal gefundenes Minimum zu verlassen, im Laufe des Iterationsverfahrens immer geringer, und das Verfahren kann schließlich konvergieren. Die Parameter α und T_0 und die Anzahl der Iterationsschritte wurden von [Lückehe 1999] festgelegt. Das mit dem Monte Carlo Algorithmus gefundene Vektorfeld wird als das Vektorfeld angenommen, das die Bewegung von einem Bild zum nächsten am besten beschreibt.

4.1.2 Minimierung mittlerer quadratischer Pixeldifferenzen

Auch das zweite in dieser Arbeit angewandte Verfahren zur Bewegungserkennung beruht auf der Grundannahme, daß sich die Pixelintensitäten während der Bewegung nicht verändern. Diese Annahme wird hier durch die Minimierung mittlerer quadratischer Pixeldifferenzen zwischen rechteckigen Blöcken in aufeinander folgenden Bildern umgesetzt, was im Folgenden näher erläutert wird.

Wie schon im vorangehenden Abschnitt dargestellt, ist für die Cloud-Index Bilder die Bedingung konstanter Pixelintensität nur näherungsweise erfüllt ²:

$$n_0(\vec{x}_{i,j}) \approx n_1(\vec{x}_{i,j} + \vec{d}(\vec{x}_{i,j})). \quad (4.21)$$

Diese Relation ist zur Bestimmung eines Vektors \vec{d} nicht ausreichend. Unter Berücksichtigung der Glattheit des Vektorfeldes kann man davon ausgehen, daß ein Vektor, der die Bewegung für einen Punkt $\vec{x}_{0,0}$ gut beschreibt, die Bewegung auch für die Nachbarpunkte von $\vec{x}_{0,0}$ gut annähert. Die Differenz $n_1(\vec{x}_{i,j} + \vec{d}(\vec{x}_{i,j})) - n_0(\vec{x}_{i,j})$ ist somit für alle Pixel in der Umgebung von $\vec{x}_{0,0}$ klein. Als

²In diesem Abschnitt und in Abschnitt 4.2.2 wird die Notationsweise $\vec{x}_{i,j}$ benutzt, da dies für einige Gleichungen notwendig ist. In den anderen Abschnitten wird der Übersichtlichkeit halber die Notation \vec{x}_i verwendet.

am besten geeigneter Vektor $\vec{d}(\vec{x}_{0,0})$ wird der Vektor gewählt, für den die mittlere quadratische Abweichung

$$mse = \frac{1}{(2p+1)(2q+1)} \sum_{i=-p}^{i=p} \sum_{j=-q}^{j=q} \left(n_1(\vec{x}_{0,0} + \vec{x}_{i,j} + \vec{d}(\vec{x}_{0,0} + \vec{x}_{i,j})) - n_0(\vec{x}_{0,0} + \vec{x}_{i,j}) \right)^2 \quad (4.22)$$

zwischen einem rechteckigen Gebiet um $\vec{x}_{0,0}$ aus Bild n_0 und dem entsprechenden Gebiet um $\vec{x}_{0,0} + \vec{d}(\vec{x}_{0,0})$ aus Bild n_1 minimiert wird. Die Ausdehnung der Gebiete ist durch $(2p+1)(2q+1)$ gegeben. Die Variation der Geschwindigkeitsvektoren ist jeweils durch einen maximalen Betrag der Geschwindigkeit in x- und y-Richtung beschränkt:

$$\begin{aligned} -d_{x,max} &\leq d_x \leq d_{x,max} \\ -d_{y,max} &\leq d_y \leq d_{y,max}. \end{aligned} \quad (4.23)$$

Entsprechend der unterschiedlichen Auflösung der Satellitenbilder in x- und y- Richtung werden die auf Pixel bezogenen Werte $d_{x,max}$ und $d_{y,max}$ verschieden groß gewählt.

Durch den mse als Maß zur Übereinstimmung zwischen zwei Gebieten wird die Summe aus systematischer und statistischer Abweichung minimiert, was in Abschnitt 5.2.1 ausführlich dargelegt wird. Die systematische Abweichung charakterisiert die Übereinstimmung der Mittelwerte und der Standardabweichungen der Gebiete. Der statistische Anteil der Abweichung, die Dispersion, stellt ein Maß dafür dar, wie weit die Strukturen in den betrachteten Gebieten übereinstimmen. Dieser Anteil ist wesentlich durch die Kreuzkorrelation zwischen den beiden Gebieten bestimmt (siehe Gleichung (5.8)). Die Gebiete, für die mittlere quadratische Pixeldifferenzen berechnet werden, sollten so einerseits groß genug sein, um Strukturinformation zu enthalten. Zusätzlich wird durch die Mittelung Rauschen unterdrückt. Andererseits ist die Bedingung, daß $\vec{d}(\vec{x}_{0,0})$ die Bewegung für alle Pixel der betrachteten Fläche beschreibt, um so besser erfüllt, je kleiner die Fläche ist. Eine geeignete Gebietsgröße wird im Rahmen der Parameteroptimierung in Kapitel 4.3 ausgewählt.

Im Gegensatz zum ersten Modell, wo über die Annahme der Glattheit des Vektorfeldes das gesamte Vektorfeld Einfluß auf einen einzelnen Vektor hat, liegt hier ein lokales Modell vor. Zur Berechnung eines Vektors geht nur Information über die unmittelbare Umgebung ein. Benachbarte Vektoren sind aber auch im zweiten Modell nicht unabhängig voneinander, da sich die Mittelungsgebiete für benachbarte Vektoren überschneiden.

4.2 Anwendung von Bewegungsvektorfeldern zur Vorhersage

4.2.1 Extrapolation der Bewegung

Zur Berechnung des Vorhersagebildes wird das berechnete Vektorfeld auf das aktuelle Bild angewendet. Die Extrapolation der Bewegung in die Zukunft ist durch die Annahme motiviert, daß

die zeitliche Änderung der Geschwindigkeitsfelder für die betrachteten kurzen Zeiträume vernachlässigt werden kann. Die Pixelintensität im Vorhersagebild n_2 für den Vorhersagezeitraum 30 Minuten berechnet sich damit wie folgt:

$$n_2(\vec{x}_i) = n_1(\vec{x}_i - \vec{d}(\vec{x}_i)), \quad (4.24)$$

wobei n_1 das aktuelle Bild bezeichnet. Da $\vec{d}(\vec{x}_i)$ nicht für alle Pixel, sondern nur auf einem Subgitter S berechnet wird, muß für $\vec{d}(\vec{x}_i)$ für alle $\vec{x}_i \notin S$ aus den Werten $\vec{d}(\vec{x}_i)$ für $\vec{x}_i \in S$ abgeleitet werden. Es wurden zwei Möglichkeiten untersucht. Zum einen wird $\vec{d}(\vec{x}_i)$ zwischen den 4 nächstliegenden Vektoren aus dem Subgitter interpoliert. Zum anderen wird $\vec{d}(\vec{x}_i)$ dem nächstliegenden Vektor des Subgitters zugeordnet, was zu blockweiser Verschiebung von rechteckigen Gebieten um die Aufhängepunkte der Vektoren führt. Ein Vergleich der beiden Interpolationsansätze für beide Vorhersageverfahren ergab, daß für die mit minimalen mittleren quadratischen Pixeldifferenzen bestimmten Vektoren blockweise Verschiebung günstiger ist. Für die statistische Methode führen kontinuierlich interpolierte Vektoren zu geringeren Fehlern.

Für Vorhersagezeiträume $\Delta t > 30$ Minuten wurden zwei Wege zur Bestimmung des Vorhersagebildes betrachtet:

- Das Vektorfeld wird mit dem Faktor $\alpha = \frac{\Delta t}{30min}$ skaliert, so daß sich für das Vorhersagebild

$$n_3(\vec{x}_i) = n_1(\vec{x}_i - \alpha \vec{d}(\vec{x}_i)) \quad (4.25)$$

ergibt.

- Das Vorhersagebild ergibt sich durch mehrmalige Anwendung des Vektorfeldes auf das aktuelle Bild. So erhält man z.B. für $\Delta t = 60$ min:

$$n_3(\vec{x}_i) = n_1(\vec{x}_i - \vec{d}(\vec{x}_i) - \vec{d}(\vec{x}_i - \vec{d}(\vec{x}_i))). \quad (4.26)$$

Eine Analyse der Vorhersagequalität für die beiden Ansätze ergab, daß es günstiger ist, das Vorhersagebild gemäß Gleichung (4.26) zu bestimmen.

4.2.2 Berücksichtigung der Veränderung von Wolkenstrukturen

Wie bereits ausführlich dargestellt, spielen für die Entwicklung der Bewölkungssituation neben der Bewegung der Wolkenstrukturen auch andere Prozesse eine Rolle. So verändern sich bestehende Wolken bezüglich ihrer Struktur und bezüglich des Bewölkungsgrades mit der Zeit, außerdem können neue Wolken entstehen. Veränderungen der Struktur einer Wolke, wie z.B. Vergrößerung und Verkleinerung, können mit den verwendeten Methoden prinzipiell durch ein nicht divergenzfreies Vektorfeld erfaßt werden. Voraussetzung dabei ist eine genügend hohe räumliche Auflösung des Vektorfeldes. In Abschnitt 4.4 wird untersucht, wie gut die Veränderung von Wolkenstrukturen über Bewegungsvektorfelder beschrieben werden kann.

Eine Veränderung des Bewölkungsgrades, die mit den beiden beschriebenen Methoden nicht modelliert wird, soll nachträglich über folgenden Ansatz berücksichtigt werden: Zunächst wird die Änderung der Pixelintensität zwischen Anfangs- und Endpunkt eines Vektors bestimmt. Dabei wird über rechteckige Gebiete $(2m + 1)(2n + 1)$ gemittelt:

$$\bar{r}(\vec{x}_{a,b}) = \sum_{i=-l}^{i=l} \sum_{j=-k}^{j=k} (n_1(\vec{x}_{a,b} + \vec{x}_{i,j} + \vec{d}(\vec{x}_{a,b} + \vec{x}_{i,j})) - n_0(\vec{x}_{a,b} + \vec{x}_{i,j})). \quad (4.27)$$

Die Änderung der Pixelintensität wird ebenso wie die Bewegung extrapoliert, so daß schließlich

$$n_2(\vec{x}_{i,j}) = n_1(\vec{x}_{i,j} - \vec{d}(\vec{x}_{i,j})) + \bar{r}(\vec{x}_{i,j}) \quad (4.28)$$

ergibt, wobei $\bar{r}(\vec{x}_{i,j})$ für Punkte $\vec{x}_{i,j} \notin S$ analog zu $\vec{d}(\vec{x}_{i,j})$ berechnet wird.

4.2.3 Überblick über den Vorhersagealgorithmus

Eine Darstellung der wesentlichen Schritte des Vorhersagealgorithmus unter Verwendung von Bewegungsvektorfeldern ist in Abb 4.1 gegeben. Aus zwei aufeinander folgenden Cloud-Index Bildern wird mit einem der beiden beschriebenen Bewegungserkennungsverfahren ein Vektorfeld berechnet, das die Wolkenbewegung von einem Bild zum nächsten beschreibt. Für das statistische Verfahren werden die Bilder vor Berechnung der Bewegungsvektoren geglättet (siehe [Lückehe 1999]). Zur Berechnung des Vorhersagebilds durch Extrapolation der Bewegung wird das berechnete Vektorfeld auf das aktuelle (ungeglättete) Bild angewendet. In einem letzten Schritt werden die Bilder geglättet, wobei die Größe des Glättungsfilters vom Vorhersagezeitraum abhängig ist.

4.3 Bestimmung der optimalen Parameter

Zur optimalen Anpassung der Verfahren zur Vorhersage wurden die freien Parameter so eingestellt, daß die Vorhersagefehler minimiert werden. Die entsprechenden Untersuchungen wurden für die in Abschnitt 3.5 spezifizierte Testzeitreihe durchgeführt. Die Bewertung der Vorhersagequalität erfolgte über die in Abschnitt 3.3 definierte Fehlerfunktion. Zur Berechnung des *rmse* gemäß Gleichung (3.23) werden dabei nicht die vollständigen Bildausschnitte verwendet. Am Bildrand können die Bewegungsvektoren und die zukünftige Bewölkungssituation nicht bestimmt werden, da dazu Information von außerhalb der Bildausschnitte notwendig wäre. Demzufolge werden zur Auswertung nur Punkte herangezogen, die einen Mindestabstand vom Rand haben.

Die Parameter für die Vorhersage mit Bewegungsvektorfeldern lassen sich in zwei Gruppen unterteilen. Der erste Parametersatz betrifft die Parameter, die mit der Bestimmung der Bewegungsvektorfelder in Zusammenhang stehen, wie z. B. Auflösung der Vektorfelder oder die Parameter der Energiefunktion für das statistische Verfahren. Der zweite Parametersatz betrifft die abschließende

**Folge von 2
Cloud-Index Bildern**

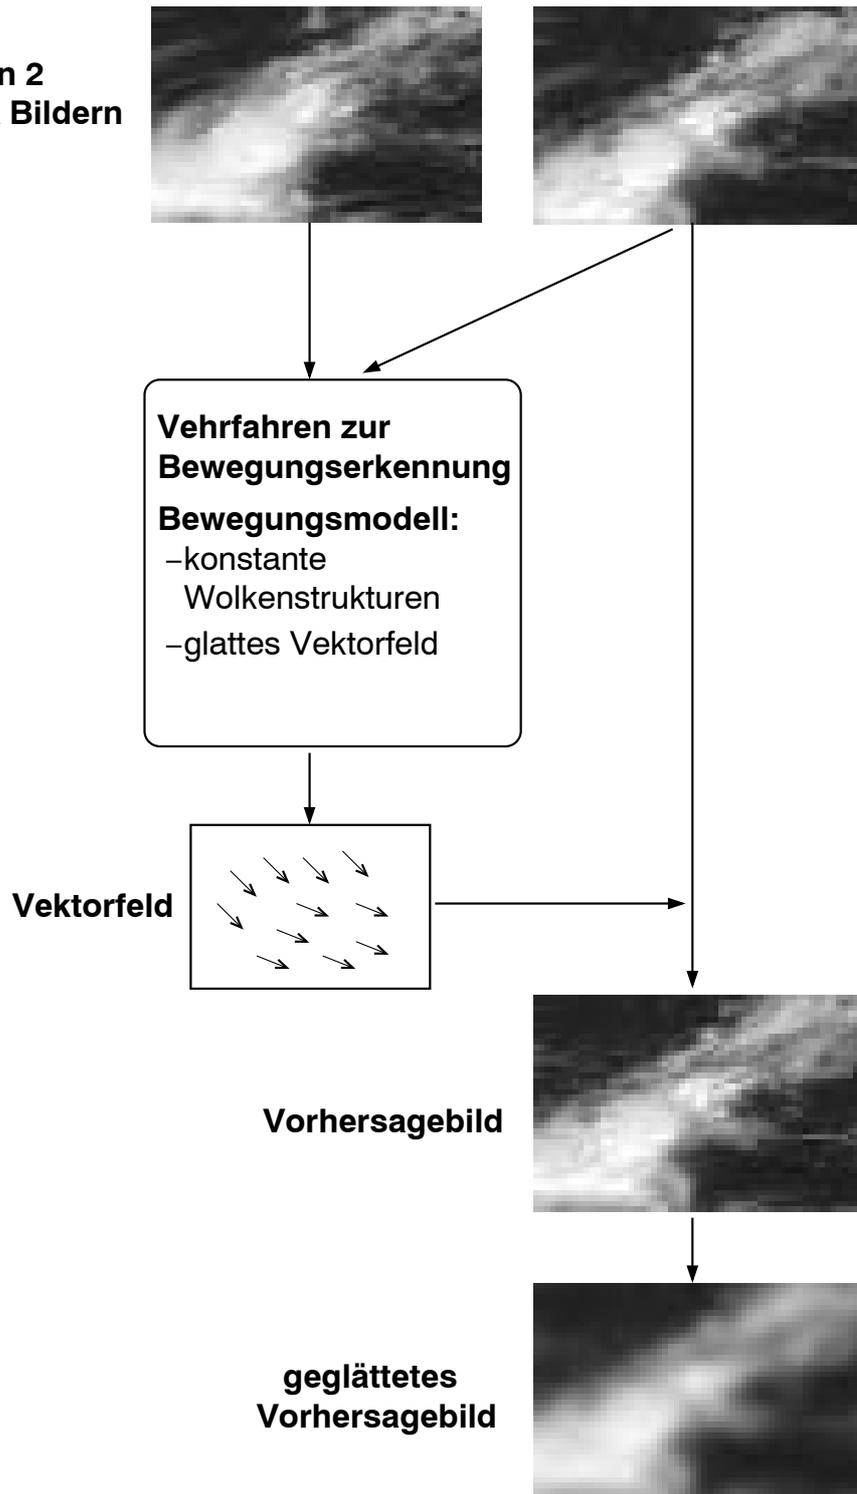


Abbildung 4.1: Wesentliche Schritte des Vorhersagealgorithmus mit Bewegungsvektorfeldern.

Verarbeitung der Bilder, wobei insbesondere die Festlegung der Glättungsfilter für die vorhergesagten Bilder eine wichtige Rolle spielt.

Im Folgenden wird zunächst auf die Bestimmung der Parameter für die Berechnung der Bewegungsvektorfelder durch Minimierung mittlerer quadratischer Pixeldifferenzen eingegangen. Die Auswahl der Parameter für das statistische Verfahren wurde von [Lückehe 1999] durchgeführt. Im Anschluß wird der Einfluß der Parameter zur nachträglichen Bearbeitung der vorhergesagten Cloud-Index Bilder in Abhängigkeit vom Vorhersagezeitraum untersucht. Es sei noch bemerkt, daß im Folgenden für alle Parameter, die auf eine räumliche Auflösung bezogen sind, die Parameter in x-Richtung doppelt so groß gewählt wurden wie in y-Richtung. Dies gleicht die unterschiedliche Auflösung der Satellitenbilder in x- und y-Richtung aus (siehe Abschnitt 2.1).

4.3.1 Parameter für Bewegungsvektorfelder auf der Basis minimaler mittlerer quadratischer Pixeldifferenzen

Die optimale Einstellung eines Parameters ist von der Gesamtparameterkonfiguration abhängig, da sich die verschiedenen Parameter gegenseitig beeinflussen. Zunächst wird der Einfluß einzelner Parameter auf den Vorhersagefehler betrachtet. In der Zusammenfassung werden die im Weiteren verwendeten Werte festgelegt. Die charakteristischen Parameter für die Berechnung von Bewegungsvektorfeldern auf der Basis minimaler mittlerer quadratischer Pixeldifferenzen sind zum einen die Gebietsgröße zur Bestimmung der mittleren quadratischen Pixeldifferenzen und zum anderen die Auflösung des Vektorfeldes.

Die Bilder wurden vor der Berechnung der Vektorfelder nicht geglättet, da dies für das hier betrachtete Verfahren, anders als bei der statistischen Methode, nicht zu einer Verbesserung führte. Die Analyse des Einflusses einzelner Parameter auf den Vorhersagefehler wurde zunächst für die verschiedenen in Abschnitt 3.6.1 definierten Bewölkungs-Klassen getrennt durchgeführt. Es hat sich jedoch gezeigt, daß sich die optimalen Parameter für die verschiedenen Klassen nicht unterscheiden. Die hier dargestellten Untersuchungen wurden am Beispiel von Klasse 3, Vorhersagezeitraum 30 Minuten und, wie für Neuronale Netze, mit halber Auflösung der Satellitenbilder durchgeführt. Die nachträgliche Veränderung der Pixelintensität wurde vorerst nicht berücksichtigt.

Gebietsgröße zur Bestimmung der mittleren quadratischen Pixeldifferenzen

Als erster Parameter wurde die Gebietsgröße der Mittelungsgebiete für die Berechnung der mittleren quadratischen Pixeldifferenzen untersucht. Die Gebietsgröße ist dabei durch den Parameter p charakterisiert, der das Mittelungsgebiet auf $(4p+1)(2p+1)$ festlegt. In Abb. 4.2 sind die mittleren Vorhersagefehler über dem Parameter p aufgetragen. Es werden die Fehlerkurven ohne abschließende Glättung und mit optimaler abschließender Glättung dargestellt. Es zeigt sich, daß eine Mindestgröße der Mittelungsgebiete erforderlich ist, um gute Vorhersageergebnisse zu erzielen. Werden die Berechnungen für Satellitenbilder mit reduzierter Auflösung durchgeführt, entspricht die Mindestgröße in etwa 9×17 Pixeln. Oberhalb der Mindestgröße verlaufen die Kurven flach, eine weitere Vergrößerung der Gebiete hat keinen großen Einfluß auf den Vorhersagefehler mehr.

Dies gilt unabhängig davon, ob die Bilder nach der Verschiebung geglättet werden oder nicht. Mit den geglätteten Bildern wird jedoch eine deutlich höhere Vorhersagequalität erzielt.

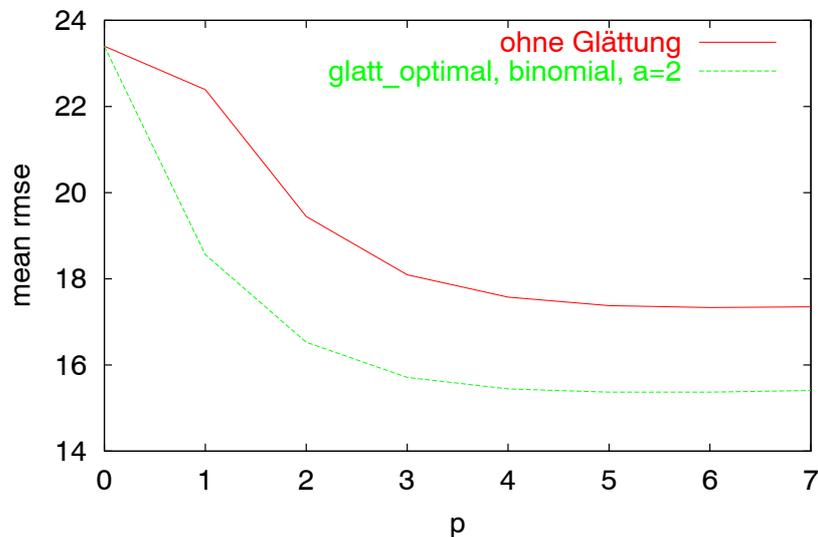


Abbildung 4.2: Mittlere Vorhersagefehler in Abhängigkeit von Parameter p , der die Größe der Mittelungsgebiete charakterisiert, am Beispiel von Vorhersagezeitraum 30 Minuten, Klasse 3 und halber Auflösung der Satellitenbilder.

Auflösungsvermögen des Vektorfelds

Eine weitere Größe, die den Vorhersagefehler beeinflusst, ist das Auflösungsvermögen des Vektorfeldes. Zur Charakterisierung des Auflösungsvermögens des Vektorfeldes wurde der Parameter m eingeführt, der die Abstände zwischen den einzelnen Vektoren beschreibt. So beträgt der Abstand zwischen Vektoren in x-Richtung jeweils $4m + 1$ Pixel und in y-Richtung $2m + 1$ Pixel. Die Untersuchung wurde für Mittelungsgebiete der Größe 13×25 Pixel durchgeführt und die Vorhersagefehler für geglättete Bilder ausgewertet.

In Tabelle 4.1 sind die Vorhersagefehler für verschiedene Auflösungen des Vektorfeldes gegeben. Es wird deutlich, daß für den betrachteten Bereich die Auflösung des Vektorfeldes nur einen sehr geringen Einfluß hat. Auch das Vektorfeld mit der im Vergleich größten Auflösung führt zu einer nahezu gleichwertigen Vorhersagequalität.

Zusammenfassung

Zusammenfassend läßt sich feststellen, daß die Vorhersageergebnisse bei Variation der beiden betrachteten Parameter im Bereich des jeweiligen Optimums nur sehr geringfügige Änderungen zeigen. Dies hat den Vorteil, daß eine gute Parameterkonfiguration relativ einfach zu bestimmen ist

| Auflösung | 3x5 | 5x9 | 7x16 |
|-----------|------|------|------|
| mean rmse | 15.3 | 15.4 | 15.5 |

Tabelle 4.1: Mittlere Vorhersagefehler für verschiedene Auflösungen des Vektorfelds, am Beispiel von Vorhersagezeitraum 30 Minuten, Klasse 3 und halber Auflösung der Satellitenbilder.

und die Vorhersageergebnisse in Bezug auf Abweichungen von der optimalen Konfiguration stabil sind. Bezüglich die Größe der Mittelungsgebiete zur Bestimmung der mittleren quadratischen Pixeldifferenzen ist es wichtig, daß die Gebiete eine Mindestgröße überschreiten. Für Satellitenbilder mit halber Auflösung beträgt die Mindestgröße 9x17 Pixel, für Bilder in voller Auflösung 17x33 Pixel. Die Auflösung des Vektorfeldes wird im weiteren auf 3x5 Pixel für Bilder mit halber Auflösung und auf 5x9 Pixel für Bilder mit voller Auflösung gesetzt.

4.3.2 Parameter zur nachträglichen Bearbeitung der vorhergesagten Cloud-Index Bilder

Nachdem die Verfahren zur Berechnung der Bewegungsvektoren durch Einstellen der entsprechenden Parameter festgelegt sind, wird in diesem Abschnitt untersucht, inwieweit die Vorhersageergebnisse durch nachträgliche Weiterverarbeitung der Bilder verbessert werden können. So wird zunächst analysiert, ob eine eventuelle Änderung des Bewölkungsgrads durch nachträgliche Addition einer mittleren Pixeldifferenz beschrieben und so die Vorhersagequalität erhöht werden kann (siehe Abschnitt 4.2.2). In diesem Zusammenhang ist auch die Größe des entsprechenden Mittelungsgebiets festzulegen. Einen sehr wichtigen Einfluß auf die Vorhersagequalität hat die Anwendung von Glättungsfiltern auf die vorhergesagten Bilder, was in Abschnitt 3.7 theoretisch motiviert wurde. Im zweiten Teil dieses Abschnitts ist die Auswahl eines geeigneten Glättungsfilters beschrieben. Die entsprechenden Untersuchungen wurden für die gesamte Testmenge ohne Unterteilung in Bewölkungsklassen bei voller Auflösung der Satellitenbilder durchgeführt.

Gebietsgröße zur Bestimmung der Änderung des Bewölkungsgrades

Zur Berücksichtigung der Änderung der Pixelintensität wurden nachträglich mittlere Pixeldifferenzen gemäß Gleichung (4.27) addiert. Inwieweit durch dieses Verfahren eine Verbesserung der Vorhersagequalität erreicht werden kann, wurde am Beispiel von Vorhersagezeitraum 30 Minuten untersucht. Dazu sind in Tabelle 4.2 mittlere Vorhersagefehler in Abhängigkeit des Parameters k gegeben, wobei durch $(4k + 1)(2k + 1)$ die Größe der Mittelungsgebiete zur Bestimmung der Pixeldifferenz charakterisiert ist. Es wird deutlich, daß die Verbesserung gegenüber dem einfachen Verfahren ohne Addition von mittleren Pixeldifferenzen nur gering ist. Dabei werden die Vorhersagefehler für ein Mittelungsgebiet der Größe von 25x13 Pixeln am kleinsten. Für längere Vorhersagezeiträume wurden die besten Ergebnisse erzielt, wenn die mittlere Änderung der Pixelintensität nur im ersten Zeitschritt addiert wird.

| k | 0 | 3 | 6 | 9 | 12 | 15 | 18 |
|-----------|------|------|------|------|------|------|------|
| mean rmse | 18.5 | 18.4 | 18.2 | 18.3 | 18.4 | 18.5 | 18.5 |

Tabelle 4.2: Mittlere Vorhersagefehler in Abhängigkeit von Parameter k , der die Größe der Mittelungsgebiete zur Bestimmung der Pixeldifferenz charakterisiert, am Beispiel des Vorhersagezeitraums 30 Minuten.

Glättung der vorhergesagten Cloud-Index Bilder

Den letzten Verarbeitungsschritt im Vorhersagealgorithmus mit Bewegungsvektoren stellt die Glättung der vorhergesagten Cloud-Index Bilder dar. Es wurden zwei verschiedene Typen von Glättungsfiltern untersucht. Zum einen wurde ein einfacher Rechteckfilter angewendet, jedem Punkt wird der Mittelwert über ein rechteckiges Gebiet um diesen Punkt zugeordnet. Zum anderen wurde die Verwendung von Binomial-Filtern in Betracht gezogen, die aufgrund gleichmäßiger Unterdrückung hoher Wellenzahlen besser zur Reduzierung von Rauschen geeignet sind (siehe [Jähne 1989]). Bei Faltung mit Binomial-Filtern werden die Pixel, über die gemittelt wird, entsprechend ihres Abstands zum mittleren Pixel mit Binomial-Koeffizienten gewichtet.

In Abb. 4.3 sind für die Vorhersagezeiträume 30 Minuten und 2 Stunden die mittleren Vorhersagefehler für die beiden Filtertypen über dem Glättungsparameter a gegeben, der die Filtergröße $(2a + 1)(2a + 1)$ festlegt. Es werden jeweils Vorhersagefehler und Persistenzfehler betrachtet.

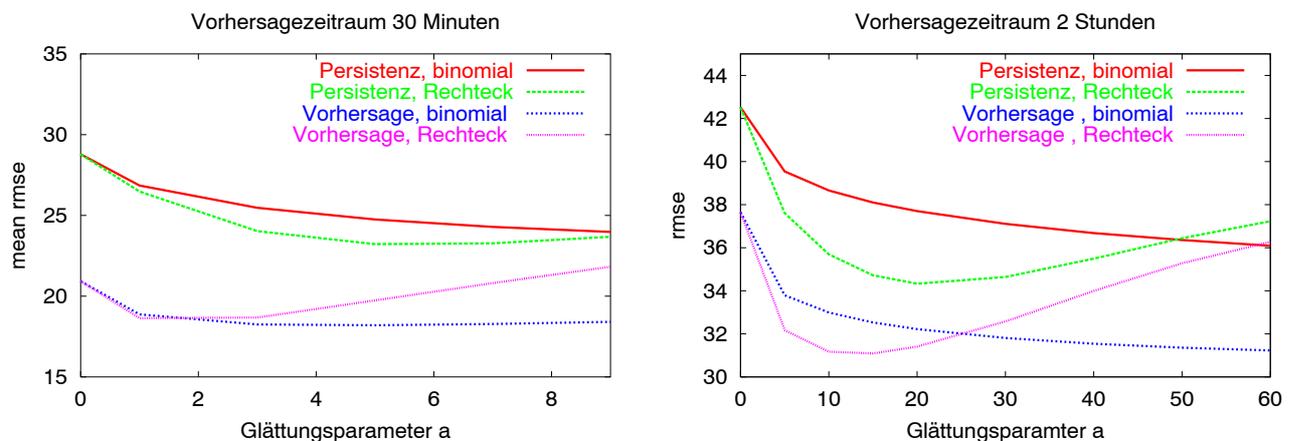


Abbildung 4.3: Mittlere Vorhersagefehler und Persistenzfehler in Abhängigkeit von Glättungsparameter a , der die Größe der Glättungsfilter charakterisiert. Für die Vorhersagezeiträume 30 Minuten (links) und 2 Stunden (rechts) werden Rechteckfilter und Binomial-Filter verglichen.

Es wird deutlich, daß durch Glättung die Vorhersagefehler erheblich reduziert werden. Für den Vorhersagezeitraum 30 Minuten werden dabei erwartungsgemäß mit dem Binomial-Filter sowohl für die Persistenz als auch für die Vorhersage etwas bessere Ergebnisse erzielt. Der optimale Glättungsparameter ist für Binomial-Filter dabei deutlich höher, als für Rechteckfilter. Zur Un-

terdrückung der Moden oberhalb einer bestimmten Frequenz sind bei Anwendung von Binomial-Filtern wesentlich größere Filter nötig als bei Anwendung von Rechteckfiltern. Für den Vorhersagezeitraum 2 Stunden sind Rechteckfilter besser geeignet als Binomial-Filter. Wie auch die Auswertung der Vorhersage mit neuronalen Netzen gezeigt hat, werden für den Vorhersagezeitraum 2 Stunden die besten Vorhersageergebnisse erzielt, wenn nur sehr niedrige Wellenzahlen berücksichtigt werden. Dies ist mit Binomial-Filtern, die an die Unterdrückung kleinskaliger Strukturen angepaßt sind, nur ungenügend zu realisieren.

| Vorhersagezeitraum | Verfahren | Glättungsfilter | mean rmse |
|--------------------|-------------|------------------|-----------|
| 30 min | mmqpd | 11x11 binomial | 18.2 |
| | statistisch | | 18.5 |
| 60 min | mmqpd | 41x41 binomial | 23.9 |
| | statistisch | 61x61 binomial | 24.0 |
| 90 min | mmqpd | 121x121 binomial | 27.8 |
| | statistisch | | 27.8 |
| 120 min | mmqpd | 31x31 Rechteck | 31.1 |
| | statistisch | | 31.0 |

Tabelle 4.3: Optimale Glättungsparameter und Vorhersagefehler für die beiden untersuchten Verfahren für verschiedene Vorhersagezeiträume, „mmqpd“ steht dabei für „Minimierung mittlerer quadratischer Pixeldifferenzen“.

Die optimalen Glättungsparameter für die verschiedenen Vorhersagezeiträume und die entsprechenden Vorhersagefehler sind für die beiden vorgestellten Verfahren in Tabelle 4.3 zusammengefaßt. Es wird deutlich, daß die am besten geeigneten Glättungsparameter für beide Verfahren fast identisch sind. Der optimale Glättungsparameter erhöht sich dabei mit dem Vorhersagezeitraum. Für Vorhersagezeiträume bis zu 90 Minuten sind Binomial-Filter günstiger, während für 2 Stunden mit einem Rechteckfilter die besten Ergebnisse erzielt werden. Ein Vergleich der Fehler der beiden Verfahren zeigt, das beide Methoden Vorhersagen gleicher Qualität liefern.

4.4 Ergebnisse und Fehleranalyse

Zur Bewertung der Vorhersagealgorithmen mit Bewegungsvektorfeldern wurden die Vorhersageergebnisse mit Persistenz und neuronalen Netzen verglichen. Dazu werden, wie bei der Auswertung für die Vorhersage mit neuronalen Netzen mittlere Fehler, Fehler in Abhängigkeit von der Variabilität und ein Beispiel für die Vorhersage gegeben. Um den Vergleich mit neuronalen Netzen zu ermöglichen, wurde die Auswertung für Bildausschnitte mit halber Auflösung durchgeführt.

In Abb. 4.4 sind mittlere Vorhersagefehler über dem Vorhersagezeitraum aufgetragen. Dabei sind zum einen die Vorhersagefehler für die Vorhersage mit Bewegungsvektoren mit der statistischen

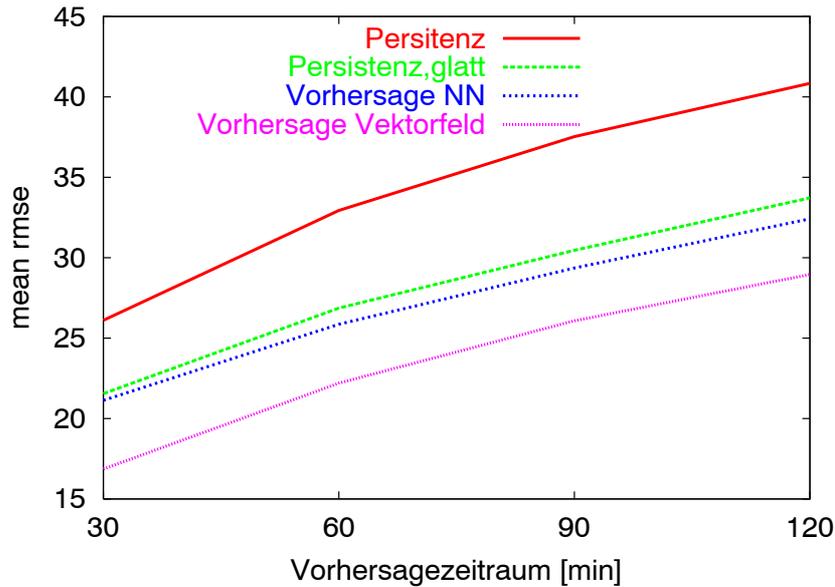


Abbildung 4.4: Mittlere Vorhersagefehler in Abhängigkeit vom Vorhersagezeitraum für halbe Auflösung der Bilder. Es werden die Vorhersagefehler für Vorhersage mit neuronalen Netzen, für Vorhersage mit Bewegungsvektoren und Persistenz (geglättet und ungeglättet) verglichen.

Methode gegeben. Zum Vergleich sind Persistenzfehler, Fehler für Persistenz mit optimal geglätteten Bildern und Fehler für Vorhersage mit neuronalen Netzen dargestellt. Es zeigt sich, daß die Vorhersage mit Bewegungsvektoren zu deutlich besseren Ergebnissen führt als geglättete Persistenz oder Vorhersage mit neuronalen Netzen. Dies wird auch an Abb. 4.5 deutlich, wo die Fehler für Persistenz, Vorhersage mit neuronalen Netzen und Vorhersage mit Bewegungsvektoren aus minimalen mittleren quadratischen Pixeldifferenzen über der Variabilität gegeben sind. Im linken Bild sind dabei zusätzlich mittlere Fehler für die verschiedenen Vorhersagen aufgetragen³. Die Reduktion des mittleren Fehlers der Vorhersage mit Bewegungsvektorfeldern gegenüber der Vorhersage mit neuronalen Netzen wird um so größer, je höher die Variabilität ist. Gegenüberstellung mit den maximalen Fehlern im rechten Bild zeigt, daß die Obergrenzen für die Fehler noch deutlicher als die Mittelwerte verringert werden und die Fehlerverteilung schmaler wird.

Anhand der Beispielbilder in Abb. 4.6 soll veranschaulicht werden, daß die Reduktion des Fehlers darauf zurückzuführen ist, daß die Bewegung der Wolken vorhergesagt werden kann.

³Die Berechnung der mittleren und maximalen Fehler erfolgt analog zu der Beschreibung in Abschnitt 3.7.

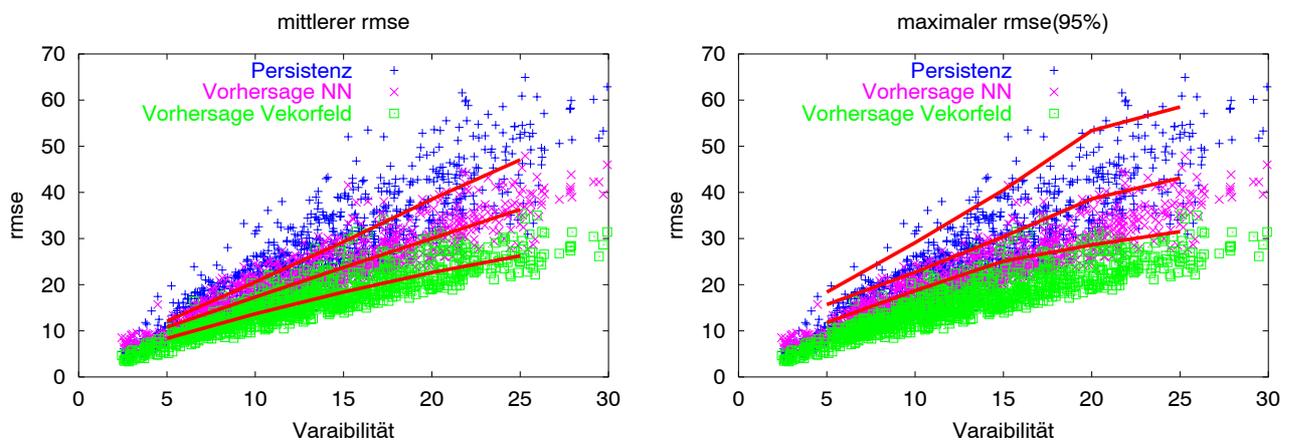


Abbildung 4.5: Vorhersagefehler in Abhängigkeit von der Variabilität für den Vorhersagezeitraum 30 Minuten. Die Kurven der mittleren Fehler (links) und der maximalen Fehler (rechts) entsprechen von oben nach unten: Persistenz, Vorhersage mit neuronalen Netzen und Vorhersage mit Bewegungsvektorfeldern.

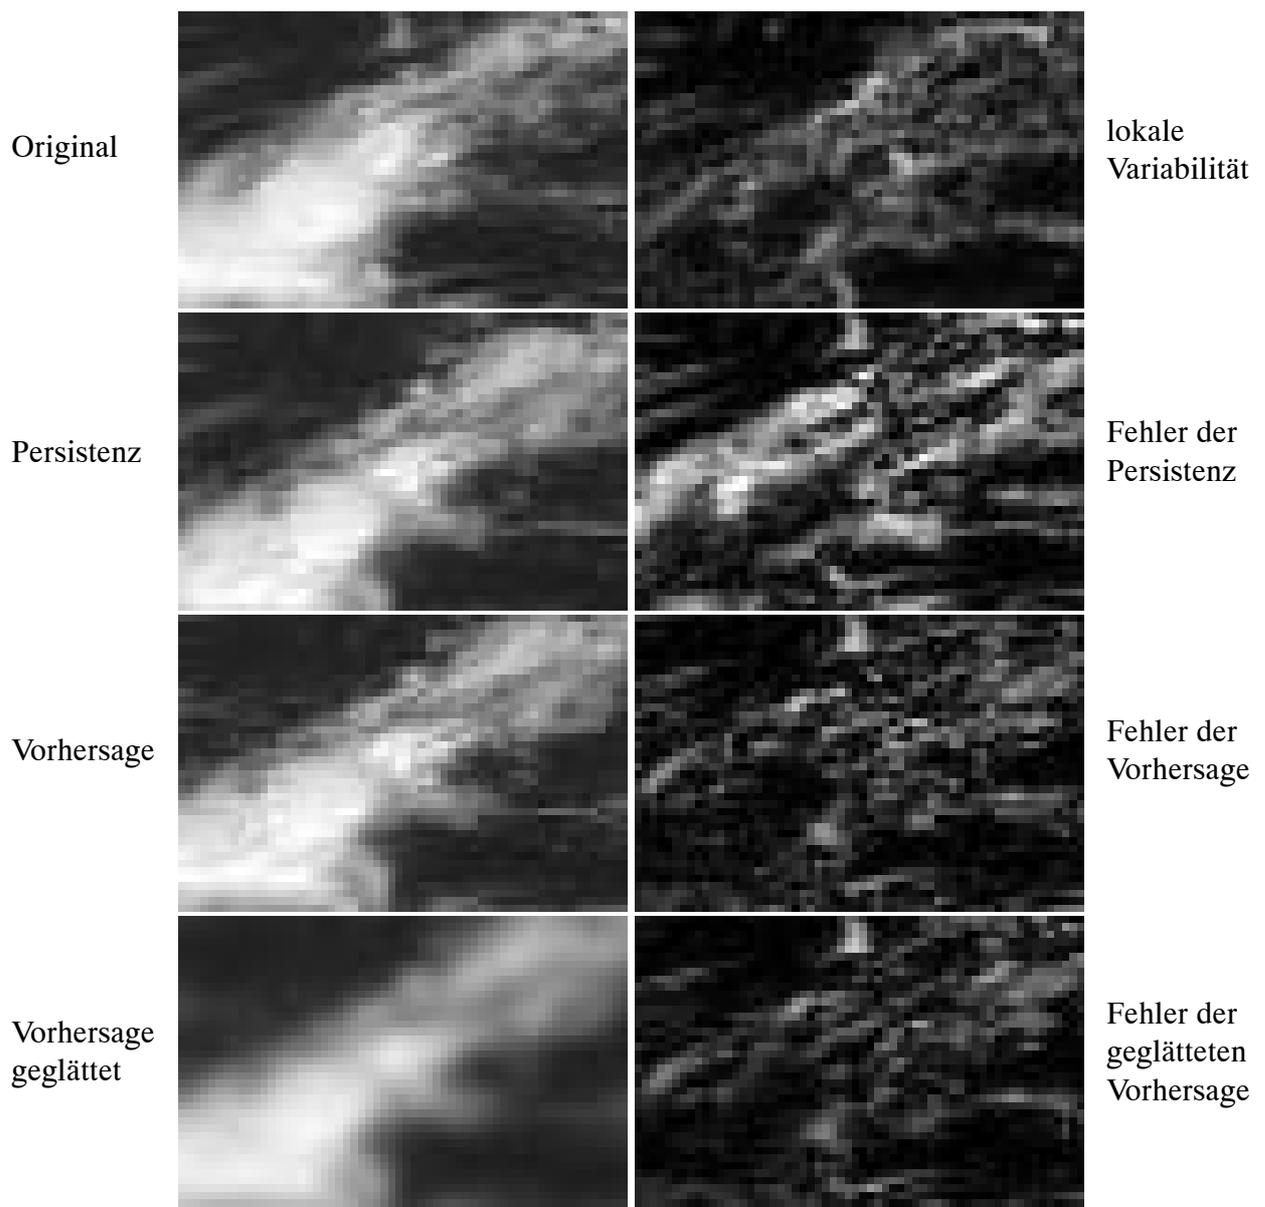


Abbildung 4.6: Beispiel der Vorhersage für den 29.6.1997, 10:30 und den Vorhersagezeitraum 30 Minuten. In der linken Spalte sind von oben nach unten das vorherzusagende Bild, das Persistenzbild, das Vorhersagebild und das geglättete Vorhersagebild dargestellt. Die rechte Spalte zeigt von oben nach unten ein Bild der lokalen Variabilität, Persistenzfehler, Vorhersagefehler und Fehler der geglätteten Vorhersage. Zur besseren Visualisierung sind Werte der lokalen Variabilität verdreifacht und die Fehler verdoppelt dargestellt.

In der linken Spalte von Abb. 4.6 sind, von oben nach unten, ein Originalbild, ein Persistenzbild, ein Vorhersagebild und ein geglättetes Vorhersagebild gezeigt. Diese werden durch entsprechende Fehlerbilder in der rechten Spalte und ein Bild der lokalen Variabilität (siehe Gleichung (3.27)) ergänzt. Der Vergleich des Originalbildes mit dem vorhergesagten Bild und die Betrachtung des Fehlerbildes neben dem vorhergesagten Bild machen deutlich, daß für dieses Beispiel die Bewegung der Wolkenstruktur weitgehend erfaßt wurde. An den Wolkenkanten treten nur wesentlich geringere Fehler auf als bei dem entsprechenden Persistenz-Fehlerbild. Es zeigt sich aber auch, daß die Änderung der Bewölkungsintensität (obere rechte Ecke des Bildes) nur sehr ungenügend beschrieben wird. Eine Gegenüberstellung des Bildes der lokalen Variabilität mit den Fehlerbildern bestätigt, daß, wie zu erwarten, Bereiche hoher Variabilität mit Bereichen großer Fehler verknüpft sind. Auch die Veränderung von großflächigen, klar definierten Wolkenstrukturen läßt sich mit Bewegungsvektoren beschreiben, was analog zur Beschreibung der Bewegung anhand von Beispielen gezeigt werden kann.

Abschließend wurden in Abb. 4.7 die Vorhersagefehler für die beiden verschiedenen Ansätze zur Berechnung von Bewegungsvektoren zueinander in Beziehung gesetzt. Die schmale Fehler-Verteilung zeigt, daß nicht nur die Mittelwerte für die Testzeitreihe übereinstimmen, sondern auch für einzelne Situationen die Vorhersageergebnisse für beide Methoden nicht stark voneinander abweichen.

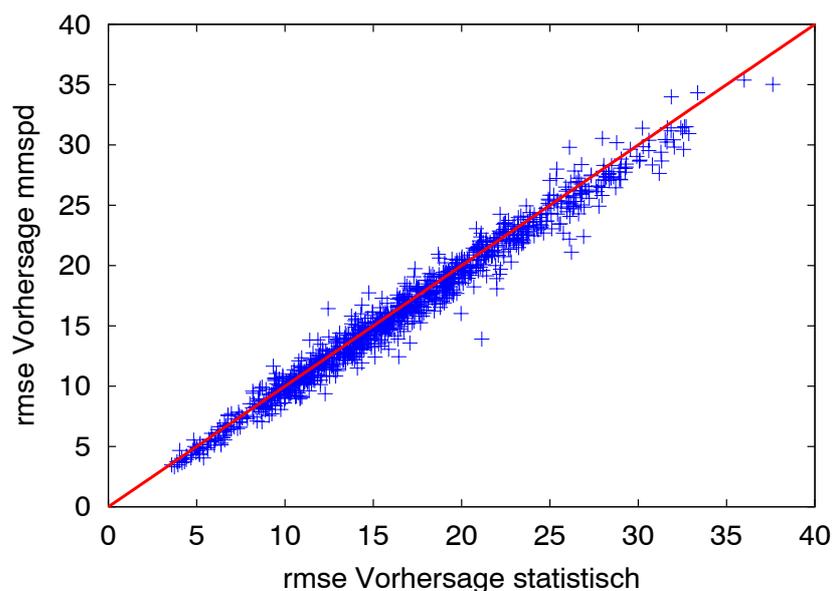


Abbildung 4.7: Vorhersagefehler mit Bewegungsvektoren, die mit der statistischen Methode bestimmt wurden, über den Vorhersagefehlern mit Bewegungsvektoren, die über Minimierung mittlerer quadratischer Pixeldifferenzen bestimmt wurden, für den Vorhersagezeitraum 30 Minuten.

Zusammenfassung und Ausblick

Die Auswertung der Vorhersage mit Bewegungsvektorfeldern ergab, daß diese Methode geeignet ist, um die Entwicklung der Bewölkungssituation vorherzusagen. Mit zwei verschiedenen Methoden wurden Bewegungsvektorfelder bestimmt, die die Bewegung von Wolkenstrukturen gut beschreiben. Durch Extrapolation der Bewegung in die Zukunft wird eine deutlich bessere Übereinstimmung mit der tatsächlich eintretenden Situation erreicht als durch Persistenz oder Vorhersage mit neuronalen Netzen. Dabei ergaben sich für beide Verfahren zur Bestimmung von Bewegungsvektorfeldern gleichwertige Ergebnisse.

Eine Glättung der vorhergesagten Bilder mit einem geeigneten Glättungsfilter führt zu einer deutlichen Reduktion der Vorhersagefehler. Der optimale Glättungsparameter erhöht sich dabei mit dem Vorhersagezeitraum. Die Vorhersage der Bewölkungssituation mit Bewegungsvektorfeldern wird im Weiteren als Grundlage der Vorhersage der solaren Einstrahlung verwendet.

4.5 Kombination von neuronalen Netzen mit Bewegungsinformation

Die Auswertung der Vorhersage mit Bewegungsvektorfeldern hat gezeigt, daß durch Beschreibung der Bewegung der Wolkenstrukturen gute Vorhersageergebnisse erzielt werden. An den Beispielen aus Abb. 4.6 wird jedoch auch deutlich, daß mit diesem Ansatz nicht alle Phänomene, die die Wolkenentwicklung beeinflussen, erfaßt werden. Im Folgenden wird ein Verfahren beschrieben, das die Modellierung der Wolkenbewegung mit neuronalen Netzen kombiniert. Ziel dabei ist eine verbesserte Beschreibung des Anteils der Entwicklung der Bewölkungssituation, der nicht auf Bewegung zurückzuführen ist.

Zur Kombination der Vorhersage mit neuronalen Netzen mit Bewegungsinformation werden in einem ersten Schritt Bewegungsvektorfelder aus aufeinander folgenden Bildern bestimmt. Aus diesen werden dann mittlere Bewegungsvektoren ermittelt. Als Eingabe-Information für das neuronale Netz werden Bildausschnitte des gegenwärtigen und des 30 Minuten zurückliegenden Bildes verwendet. Diese werden so gewählt, daß sie gegenüber dem vorherzusagenden Bildausschnitt um den mittleren Bewegungsvektor, skaliert entsprechend dem Zeitabstand zum vorherzusagenden Bild, verschoben sind. In den Eingabebildausschnitten sollten damit die Wolkenstrukturen enthalten sein, die sich zum Vorhersagezeitpunkt in den vorherzusagenden Bildausschnitt bewegt haben. So ist zum einen Bewegungsinformation vorgegeben und die mittlere Bewegung muß nicht von neuronalen Netzen beschrieben werden. Darüber hinaus ergibt sich gegenüber dem ersten Ansatz mit neuronalen Netzen der Vorteil, daß auch für Randbereiche des betrachteten Bildausschnitts die nötigen Informationen zur Vorhersage der Bewölkungssituation gegeben sind. Die weiteren Schritte sind analog zu dem in Kapitel 3 dargestellten Vorhersagealgorithmus unter Verwendung neuronaler Netze: Zur Verarbeitung im neuronalen Netz werden die Bildausschnitte wie in Abschnitt 3.2 dargestellt, in Klassen unterteilt und als Hauptkomponenten-Transformierte beschrieben. Die Einstellung der optimalen Parameterkonfiguration erfolgte analog zur Parameteroptimierung in

Abschnitt 3.6. Abschließend werden für die verschiedenen Klassen und Vorhersagezeiträume neuronale Netze trainiert und zur Vorhersage genutzt.

Die Auswertung des Verfahrens ergab eine deutliche Verbesserung gegenüber dem einfachen Ansatz mit neuronalen Netzen. Die Vorhersagequalität der Vorhersage mit Bewegungsvektorfeldern konnte jedoch nicht erreicht werden. Durch die Verarbeitung im neuronalen Netz werden der einfachen Bewegungsinformation keine zusätzlichen Informationen zugefügt.

Kapitel 5

Genauigkeitsanalyse der Einstrahlungsvorhersage

Zur Vorhersage der Bodeneinstrahlung wird aus den vorhergesagten Bewölkungsbildern die Einstrahlung bestimmt (siehe Abb 1.1). Die Vorhersage der Cloud-Index Bilder erfolgte dabei über die Bestimmung von Bewegungsvektorfeldern und anschließender Extrapolation der Bewegung. Zur Berechnung der Einstrahlung wird die in Kapitel 2 beschriebene Heliosat-Methode verwendet. Zur Auswertung des gesamten Vorhersagealgorithmus werden die vorhergesagten Werte mit Bodenmeßwerten verglichen. Die Analyse der Vorhersagequalität wurde für den Clearsky-Index k^* durchgeführt, da dieser im Gegensatz zur Globalstrahlung keinen Tagesgang aufweist. So sind die Werte für verschiedene Sonnenstände vergleichbar, und die Fehler der Einzelmessungen sind bei der Berechnung mittlerer Fehler dementsprechend gleichgewichtet.

Ziel der Auswertung ist zum einen die Bewertung der Qualität des entwickelten Vorhersagealgorithmus durch Angabe von Vorhersagefehlern und einen Vergleich mit der Persistenz. Zum anderen sollen durch die Analyse Fehlerursachen identifiziert und ihr Beitrag zum Gesamtfehler der Methode beschrieben werden. Weiterhin werden im Rahmen der Auswertung optimale Glättungsparameter für das gesamte Verfahren bestimmt. Zur detaillierten Fehleranalyse wird der bisher als Fehlermaß betrachtete *rmse* in verschiedene Komponenten zerlegt. Des weiteren wird die Abhängigkeit des Fehlers von verschiedenen meteorologischen Parametern untersucht, so daß Situationen unterschiedlicher Vorhersagequalität unterschieden werden können. Schließlich wird die Abhängigkeit des Vorhersagefehlers vom Vorhersagezeitraum betrachtet, wobei der Fehler der Berechnung der Einstrahlung aus Satellitendaten ohne Vorhersage als untere Grenze für den Vorhersagefehler miteinbezogen wird. Im Rahmen der Auswertung konnte gezeigt werden, daß sich die Solarstrahlungsvorhersage auf Vorhersagezeiträume bis zu 6 Stunden ausdehnen läßt.

Die Vorhersage der Einstrahlung ist, je nach Anwendung, auf unterschiedlichen räumlichen Skalen von Interesse. So sind z.B. für die Netzeinspeisung von Solarstrom aus räumlich verteilten Anlagen Einstrahlungswerte für eine Region vorherzusagen. Für Anwendungen der Vorhersage für stand-alone Systeme oder zur Steuerung der Heiz- und Kühlsysteme von Gebäuden wird eine Vorhersage für einen einzelnen Standort benötigt. Die Genauigkeitsanalyse der Vorhersage wurde deshalb,

neben der Auswertung für einzelne Stationen, auch für regionale Einstrahlungswerte durchgeführt. Der erste Abschnitt dieses Kapitels beschreibt die verwendete Bodendatenbasis. Im Folgenden wird auf die Methoden der Fehleranalyse eingegangen. Anschließend wird die Auswertung zunächst für die Strahlungsvorhersage für eine einzelne Station und schließlich für regionale Vorhersagen durchgeführt.

5.1 Datenbasis

Zur Evaluierung der Vorhersage mit Bodendaten wurden Strahlungsmessungen eines regionalen Meßnetzes für ein Gebiet um Saarbrücken verwendet ([Luther et al. 1996]). Die hohe räumliche Auflösung dieses Meßnetzes ermöglicht die Bestimmung regionaler Einstrahlungswerte. Aus dem Meßnetz wurden 8 Stationen, verteilt auf einem Gebiet von ca. $45 \times 31 \text{ km}^2$ ausgewählt, deren Position in Bezug auf das METEOSAT-Bild in Abb. 5.1 dargestellt ist. Die Stationen befinden sich zwischen $49^\circ 12' \text{N}$ und $49^\circ 22' \text{N}$ sowie $6^\circ 41' \text{O}$ und $7^\circ 11' \text{O}$. Die mit Pyranometern gemessenen Einstrahlungswerte stehen als 30 Sekunden Mittelwerte zur Verfügung.

| | | | | | | | | | | | | | | | | | | | | |
|-----|--|--|--|-----|-----|--|--|--|--|----|----|----|--|--|--|--|-----|--|-----|--|
| S12 | | | | | | | | | | | | | | | | | | | | |
| | | | | | | | | | | | S9 | | | | | | | | | |
| | | | | | | | | | | | | | | | | | | | | |
| | | | | | | | | | | | | | | | | | | | | |
| | | | | S11 | | | | | | S1 | | | | | | | | | | |
| | | | | | | | | | | | | S2 | | | | | S13 | | S10 | |
| | | | | | S15 | | | | | | | | | | | | | | | |

Abbildung 5.1: Position der Bodenstationen im Gebiet um Saarbrücken (S2) in Beziehung zum METEOSAT Bild. Die Quadrate entsprechen den Pixeln des METEOSAT-Bilds mit einer Ausdehnung von $3 \times 5 \text{ km}^2$.

Für die Auswertungen im Rahmen dieser Arbeit wurden Daten für 1 Jahr, von April 1995 bis März 1996, genutzt, so daß die Fehleranalyse für verschiedene meteorologische Bedingungen durchgeführt werden konnte. Entsprechend der Verfügbarkeit von Satellitenbildern wurde zur Auswertung der Zeitraum von 7:00 bis 18:30 Uhr berücksichtigt. Zur Auswertung der Vorhersage stehen dann, den Vorhersagezeiträumen entsprechend, die ersten vorhergesagten Bilder erst ab einem späteren Zeitpunkt zur Verfügung. Für jeden Vorhersagezeitraum wurde die größtmögliche Anzahl an Bildern genutzt, die Auswertungsmenge ist so für die verschiedenen Vorhersagezeiträume

nicht identisch. Da die Bilder im Rahmen der zweidimensionalen Analyse auch nach Sonnenstand und Variabilität sortiert wurden, ergeben sich jedoch durch die verschiedenen Auswertungsmengen keine systematischen Änderungen des Fehlers.

Zum Vergleich der Bodenmessungen mit der Vorhersage wurden jeweils Halbstundenmittelwerte des Clearsky-Index k^* gebildet. Für die Bodendaten wurden zunächst mit dem Clearsky-Modell von Dumortier (siehe Kapitel 2) aus den gemessenen Einstrahlungswerten die entsprechenden k^* -Werte bestimmt und anschließend über 30 Minuten gemittelt. Zur Berechnung von Halbstundenmittelwerten aus Satellitendaten wird ein gewichtetes Mittel aus den entsprechenden Pixeln von 2 Satellitenbildern gebildet. Die Beiträge der beiden k^* -Werte zum Mittelwert sind gemäß dem zeitlichen Abstand des Aufnahmezeitpunkts des Pixels zum Mittelpunkt der betrachteten halben Stunde gewichtet. Die Einstrahlung für eine Region wurde als Mittelwert der Einstrahlungen der einzelnen, über dieses Gebiet verteilten Stationen bestimmt.

5.2 Methoden der Fehleranalyse

Zur abschließenden Auswertung mit Bodendaten wird das in den beiden vorangehenden Kapiteln zur Bewertung der Vorhersagequalität verwendete Verfahren erweitert. Zum einen werden zur Beschreibung unterschiedlicher Aspekte der Vorhersagequalität verschiedene mittlere Fehlermaße verwendet, die sich aus einer Zerlegung des *rmse* ergeben ([Hou et al. 2000]). Zum zweiten wird die in den Abschnitten 3.7 und 4.4 dargestellte Auswertung in Abhängigkeit von der Variabilität in Bezug auf die Abhängigkeit vom Sonnenstand ergänzt, so daß sich insgesamt eine zweidimensionale Fehleranalyse ergibt.

5.2.1 Fehlermaße

Im Folgenden werden verschiedene Fehlermaße definiert und ihr Zusammenhang untereinander angegeben. Anschließend werden die einzelnen Größen interpretiert.

Der Fehler einer Einzelmessung ist definiert als

$$\varepsilon_i = k_{sat}^* - k_{ground}^* \quad (5.1)$$

Für eine Zeitreihe ergibt sich die Wurzel aus dem mittleren quadratischen Fehler zu

$$rmse = \sqrt{\frac{1}{N} \sum_i \varepsilon_i^2} \quad (5.2)$$

Der Mittelwert des Fehlers wird über

$$bias = \bar{\varepsilon} = \frac{1}{N} \sum_i \varepsilon_i = \bar{k}_{sat}^* - \bar{k}_{ground}^* \quad (5.3)$$

berechnet, und die Standardabweichung des Fehlers ist definiert als

$$stderror = \sigma(\varepsilon) = \sqrt{\frac{1}{N} \sum_i (\varepsilon_i - \bar{\varepsilon})^2}. \quad (5.4)$$

Die Fehlermaße hängen über die Gleichung

$$rmse^2 = bias^2 + stderror^2 \quad (5.5)$$

zusammen. Die Standardabweichung des Fehlers läßt sich weiter zerlegen in

$$stderror^2 = stdbias^2 + disp^2, \quad (5.6)$$

wobei der Standardbias als Differenz der Standardabweichungen der beiden betrachteten Zeitreihen definiert ist:

$$stdbias = \sigma(k_{sat}^*) - \sigma(k_{ground}^*). \quad (5.7)$$

Die Dispersion ist mit der Kreuzkorrelation der beiden Zeitreihen durch folgende Beziehung verknüpft:

$$disp^2 = 2\sigma(k_{sat}^*)\sigma(k_{ground}^*)(1 - korr). \quad (5.8)$$

Insgesamt ergibt sich damit die gesamte Zerlegung des mittleren quadratischen Fehlers zu

$$rmse^2 = bias^2 + stdbias^2 + 2\sigma(k_{sat}^*)\sigma(k_{ground}^*)(1 - korr). \quad (5.9)$$

Die beiden ersten Terme dieser Gleichung geben an, inwieweit die charakteristischen statistischen Werte der ersten und der zweiten Zeitreihe miteinander übereinstimmen. Durch den *bias* wird die Abweichung der Mittelwerte voneinander angegeben (siehe Gleichung (5.3)), der *stdbias* (siehe Gleichung (5.7)) gibt die Differenz der Standardabweichungen der beiden Zeitreihen an. Der letzte Term in Gleichung (5.9), die Dispersion, beschreibt den statistischen Anteil des Fehlers. Dieser Fehler bleibt bestehen, wenn die statistischen Mittelwerte der betrachteten Zeitreihen in Übereinstimmung gebracht werden. Die Dispersion ist durch die Korrelation der Zeitreihen und die Standardabweichungen der betrachteten Zeitreihen bestimmt (siehe Gleichung (5.8)). Bei gleicher Korrelation der Zeitreihen ist die Dispersion umso größer, je mehr die beiden Zeitreihen um ihre Mittelwerte variieren.

Durch die Korrelation zwischen Meßzeitreihe und Vorhersagezeitreihe ist bei vorgegebener Standardabweichung der Meßzeitreihe die Qualität der Vorhersage bestimmt, die sich durch lineare Umformung der Vorhersagezeitreihe bestenfalls erreichen läßt. Mittelwerte und Standardabweichung der Vorhersagezeitreihe lassen sich durch lineare Regression an eine entsprechende Bodenzeitreihe so anpassen, daß der *stderror* minimiert wird und der *bias* verschwindet. Dieses Verfahren wird als Model Output Statistics (MOS) bezeichnet (siehe [Storch et al. 1999]). Mit der Ableitung von Gleichung (5.9) nach $\sigma(k_{sat}^*)$ ergibt sich, daß bei positiver Korrelation das Minimum des *stderror* bei

$$\sigma(k_{sat}^*) = \sigma(k_{ground}^*)korr \quad (5.10)$$

liegt. Der *stderror* wird demzufolge bei einer Übereinstimmung von $\sigma(k_{sat}^*)$ und $\sigma(k_{ground}^*)$ nur für die Korrelation $korr = 1$ minimal. Für $korr < 1$ ergeben sich geringere Fehler, wenn die Standardabweichung der Vorhersagezeitreihe gegenüber der Standardabweichung der Meßzeitreihe entsprechend durch Multiplikation mit der Korrelation verringert ist. Für die Korrelation $korr = 0$ ergibt sich ein minimaler Fehler, wenn die Vorhersagezeitreihe durch den Mittelwert der Bodenzeitreihe ersetzt wird. Mit den Gleichungen (5.9) und (5.10) ergeben sich die mit MOS erreichbaren Fehler zu

$$rmse^2 = stderror^2 = \sigma(k_{ground}^*)^2(1 - korr^2). \quad (5.11)$$

In Abb. 5.2 ist der Zusammenhang zwischen $stderror/\sigma(k_{ground}^*)$ und der Korrelation dargestellt. Es wird deutlich, daß sich bei hoher Korrelation eine Veränderung der Korrelation stark auf den *stderror* auswirkt. Bei Korrelation $korr < 0.5$ verläuft die Kurve flach, und der *stderror* ist nur geringfügig kleiner als $\sigma(k_{ground}^*)$.

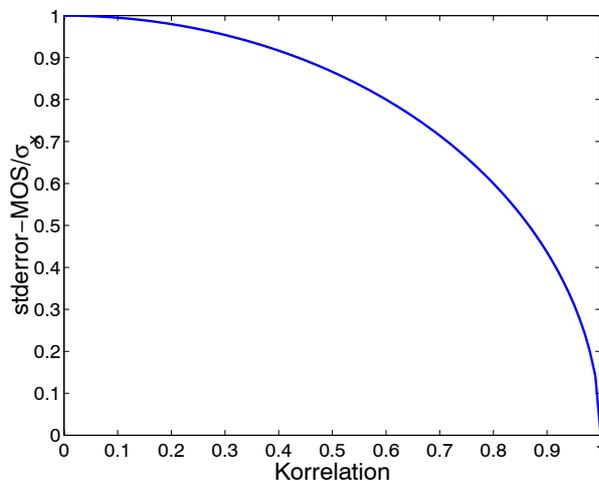


Abbildung 5.2: Theoretischer Verlauf von $stderror/\sigma(k_{ground}^*)$ in Abhängigkeit von der Korrelation für Model Output Statistics.

Vom Standpunkt eines Anwenders der Vorhersage ist es wichtig, anzugeben, in welchem Intervall um den angegebenen Wert für k^* der tatsächliche Wert liegt. Dies ergibt sich durch Angabe des Mittelwerts des Fehlers (*bias*) und der Standardabweichung des Fehlers (*stderror*). Im Fall einer Normalverteilung liegen 68.3 % aller Werte im Intervall $[k_{sat}^* - bias - stderror, k_{sat}^* - bias + stderror]$. Zur Charakterisierung der Vorhersagequalität werden in der folgenden Auswertung insbesondere die Korrelation der Zeitreihen und Standardabweichung und Mittelwert des Fehlers betrachtet.

5.2.2 Grundlagen der zweidimensionalen Fehleranalyse

Zur Unterscheidung von Situationen unterschiedlicher Vorhersagequalität wird die Fehleranalyse in Abhängigkeit von zwei Parametern durchgeführt. Als erster Parameter wird ein Variabilitätsmaß

verwendet. Dies ist zum einen durch die Abhängigkeit des Vorhersagefehlers der Bewölkungssituation von der Variabilität der Bilder motiviert (siehe Abschnitte 3.7 und 4.4). Zum anderen hängt auch der Fehler der Umrechnung von Satellitendaten in Einstrahlungswerte am Boden von der Homogenität der Bewölkung ab. So wurden in [Hammer 2000] Situationen homogener und inhomogener Bewölkung mit entsprechend niedrigem und hohem Fehler unterschieden. Als weiterer Parameter, der die Qualität der k^* -Werte beeinflusst, wird der Sonnenstand berücksichtigt.

Als Grundlage zur Definition eines Variabilitätsmaßes wird wie in Abschnitt 3.6.1 die Differenz zwischen Nachbarpixels gewählt. Anders als in den vorangehenden Kapiteln, in denen die Vorhersagequalität über den mittleren *rmse* zwischen vorhergesagtem und gemessenem Cloud-Index Bildausschnitt bewertet und dementsprechend die Variabilität der gesamten Bildausschnitte betrachtet wurde, wird hier jedoch ein lokales Variabilitätsmaß gewählt. Zur Berechnung der Variabilität gemäß:

$$var = \sqrt{\frac{1}{(N_x - 1)N_y + N_x(N_y - 1)} \left(\sum_{i,j=1}^{N_x-1,N_y} (x_{i,j} - x_{i+1,j})^2 + \sum_{i,j=1}^{N_x-1,N_y} (x_{i,j} - x_{i,j+1})^2 \right)} \quad (5.12)$$

werden nur die Punkte aus einer 7x7 Umgebung um das dem Bodenstandort entsprechende Pixel berücksichtigt. Für die regionale Vorhersage wird entsprechend der Ausdehnung des betrachteten Gebiets die Variabilität über 21x21 Pixel um Station 1, die annähernd im Mittelpunkt der betrachteten Region liegt, berechnet (siehe Abb. 5.1). Da insgesamt weniger Werte zur Verfügung stehen als bei der Berechnung der Variabilität für das gesamte Bild, wird die Variabilität in x- und y-Richtung zusammengefaßt.

Der Sonnenstand für einen Halbstundenmittelwert der Einstrahlung wird, analog zur Bestimmung von k^* , als gewichteter Mittelwert der beiden Sonnenstände zu den Aufnahmezeitpunkten der entsprechenden Pixel berechnet.

Zur Analyse der mittleren Fehler in Abhängigkeit von einem Parameter wurde der Wertebereich für den jeweiligen Parameter in Intervalle unterteilt und für jedes Intervall mittlere Fehlermaße berechnet¹. Die in der weiteren Auswertung verwendeten relativen Fehler sind dabei jeweils auf den mittleren Bodenmeßwert für das entsprechende Intervall bezogen. Die Intervallbreite wurde dabei so gewählt, daß in den einzelnen Intervallen genügend Punkte liegen, in dem Sinne, daß die Unsicherheit bei der Berechnung der mittleren Fehler kleiner sein sollte als die systematischen Unterschiede der Fehler für die verschiedenen Intervalle. Dies führte zu einer Einteilung nach dem Sonnenstand in Schritten von 10°, von $\alpha = 0^\circ$ bis zu Sonnenständen $\alpha > 50^\circ$. Bezüglich der Variabilität, die einen Wertebereich zwischen $var = 0$ und $var = 0.3$ abdeckt, erfolgt die Einteilung in 6 Intervalle der Breite von 0.025 zwischen $var = 0$ und $var = 0.15$. Die Werte oberhalb von $var = 0.15$ wurden zusammengefaßt, da die Häufigkeitsverteilung dort sehr niedrige Werte annimmt und nur wenige Punkte zur Verfügung stehen (siehe Abb. 5.4).

¹Die Fehler sind in den folgenden Graphiken immer über der Intervallmitte dargestellt.

5.3 Fehleranalyse für Einzelstandorte

In diesem Kapitel erfolgt eine detaillierte Fehleranalyse der Einstrahlungsvorhersage für Einzelstandorte. In den vorausgehenden Kapiteln wurde ausschließlich die Qualität der Bewölkungsvorhersage mit aus Satellitenbildern berechneten Cloud-Index Werten als Referenz betrachtet. Der Gesamtfehler der Vorhersage setzt sich aus dem Fehler der Bewölkungsvorhersage und dem Fehler der Berechnung von k^* aus Satellitendaten im Vergleich zu bodengemessenen Werten zusammen. Im folgenden Abschnitt wird anhand von Beispielrechnungen untersucht, in welchem Maß die beiden Fehler zum Gesamtfehler beitragen. Da der Fehler der Heliosat-Methode die Vorhersagequalität wesentlich beeinflusst, folgt eine ausführliche zweidimensionale Analyse des Fehlers der Heliosat-Methode in Abschnitt 5.3.2. Im abschließenden Abschnitt wird der Gesamtvorhersagefehler in Abhängigkeit vom Vorhersagezeitraum untersucht.

5.3.1 Vergleich des Fehlers der Heliosat-Methode mit dem Fehler der Bewölkungsvorhersage

Zur Abschätzung des Beitrags des Fehlers der Heliosat-Methode zum Gesamtvorhersagefehler sind in Tabelle 5.1 am Beispiel der Vorhersagezeiträume 30 Minuten und 2 Stunden die Gesamtvorhersagefehler, Bewölkungsvorhersagefehler und Heliosat-Fehler aufgeführt. Es werden jeweils absolute Fehler von k^* miteinander verglichen². Für die Auswertung wurden alle Variabilitäten und Sonnenstände $\alpha > 10^\circ$ zusammengefaßt. Sonnenstände $\alpha < 10^\circ$ wurden nicht berücksichtigt, da die Vorhersage-Qualität für sehr niedrige Sonnenstände sehr gering ist (siehe Abschnitte 5.3.2 und 5.3.3). Die bezüglich des Vorhersagezeitraums optimierten Glättungsparameter sind Tabelle 5.3 entnommen.

| <i>stderror</i> | Heliosat | Vorhersage, gesamt | Vorhersage der Bewölkung |
|-------------------|----------|--------------------|--------------------------|
| 30min ($a=3$) | 0.173 | 0.177 | 0.056 |
| 120min ($a=20$) | 0.181 | 0.217 | 0.114 |

Tabelle 5.1: Vergleich des *stderror* der Heliosat-Methode, der Bewölkungsvorhersage und der Vorhersage von k^* .

Tabelle 5.1 zeigt, daß der Gesamtfehler der Vorhersage ganz wesentlich durch den Fehler der Heliosat-Methode bestimmt ist. Für den Vorhersagezeitraum 30 Minuten ist der Fehler durch die Bewölkungsvorhersage im Verhältnis zum Fehler der Einstrahlungsberechnung klein und trägt kaum zum Gesamtfehler bei. Am Beispiel des Vorhersagezeitraums 2 Stunden wird deutlich, daß auch für höhere Vorhersagezeiträume der Heliosat-Fehler in Bezug auf den Fehler durch die

²Dabei ist zu beachten, daß in den Kapiteln 3.7 und 4.4 der Bewölkungsindex und dementsprechend auch die Fehler auf einer Skala zwischen 0 und 255 dargestellt wurden, was der Darstellung der Satellitenbilder in Grauwerten entspricht. Hier werden direkt Werte von k^* zwischen Null und Eins betrachtet.

Bewölkungsvorhersage noch eine wichtige Rolle spielt. (Der Fehler durch die Heliosat-Methode liegt für 2 Stunden wegen Verwendung des optimalen Glättungs-Parameters $a = 20$ höher als für 30 Minuten mit dem optimalen Glättungs-Parameter $a = 3$.) Im Folgenden wird deshalb zunächst eine ausführliche Fehleranalyse der Heliosat-Methode durchgeführt, bevor im darauffolgenden Abschnitt die Gesamtvorhersagefehler evaluiert werden.

5.3.2 Zweidimensionale Fehleranalyse der Heliosat-Methode

Zur Fehleranalyse der Heliosat-Methode werden zunächst die optimalen Glättungsparameter festgelegt, alle weiteren Auswertungen werden mit optimiertem Glättungsparameter durchgeführt. Im Folgenden wird der Zusammenhang von Korrelation und Dispersion zu den Parametern Variabilität und Sonnenstand analysiert und diskutiert. Der nächste Teil der Auswertung befaßt sich mit dem systematischen Anteil des Fehlers, die statistischen Mittelwerte der bodengemessenen Zeitreihe und der aus Satellitendaten berechneten Zeitreihe werden verglichen. Anschließend wird kurz auf die Genauigkeit der berechneten mittleren Fehlermaße eingegangen. Vor der abschließenden Zusammenfassung wird der Einfluß der Glättung näher erläutert.

Optimierung der Glättung

Durch eine Glättung können Vorhersageergebnisse deutlich verbessert werden. Dies wurde in Abschnitt 3.7 bezüglich der Bewölkungsvorhersage gezeigt. Auch bezüglich der Umrechnung von Satellitendaten in Werte der Bodeneinstrahlung läßt sich durch Mittelung über mehrere Pixel eine Verringerung der Fehler erreichen, wie in [Hammer 2000] dargestellt wurde. Im Folgenden wird die Auswirkung der Glättung in Abhängigkeit von Sonnenstand und Variabilität untersucht. Zur Glättung werden im Weiteren ausschließlich Rechteckmasken verwendet. Für die Heliosat-Methode und kurze Vorhersagezeiträume ergeben sich bei Verwendung von Binomial-Filtern nur unwesentlich bessere Ergebnisse, während für die längeren Vorhersagezeiträume ($> 1h$) Rechteck-Filter deutlich besser geeignet sind.

In Abb. 5.3 ist am Beispiel der Sonnenstände $\alpha < 10^\circ$ und $30^\circ < \alpha < 40^\circ$ der *stderror* für die verschiedenen Variabilitätsklassen über dem Glättungsparameter aufgetragen. Es werden folgende Punkte deutlich:

- Die Kurven haben keine stark ausgeprägten Minima. So kann ein guter Glättungsparameter aus einem Intervall gewählt werden. Die Veränderung der Fehler durch Glättung ist um so deutlicher, je mehr die Werte, über die gemittelt wird, voneinander abweichen, also je höher die lokale Variabilität ist.
- Für jeden Sonnenstand läßt sich unabhängig von der Variabilität ein geeigneter Glättungsparameter auswählen. Bei Erhöhung der Variabilität erhöht sich auf der einen Seite der Fehler, was größere Glättungsparameter erfordern würde, andererseits erhöht sich mit steigen-

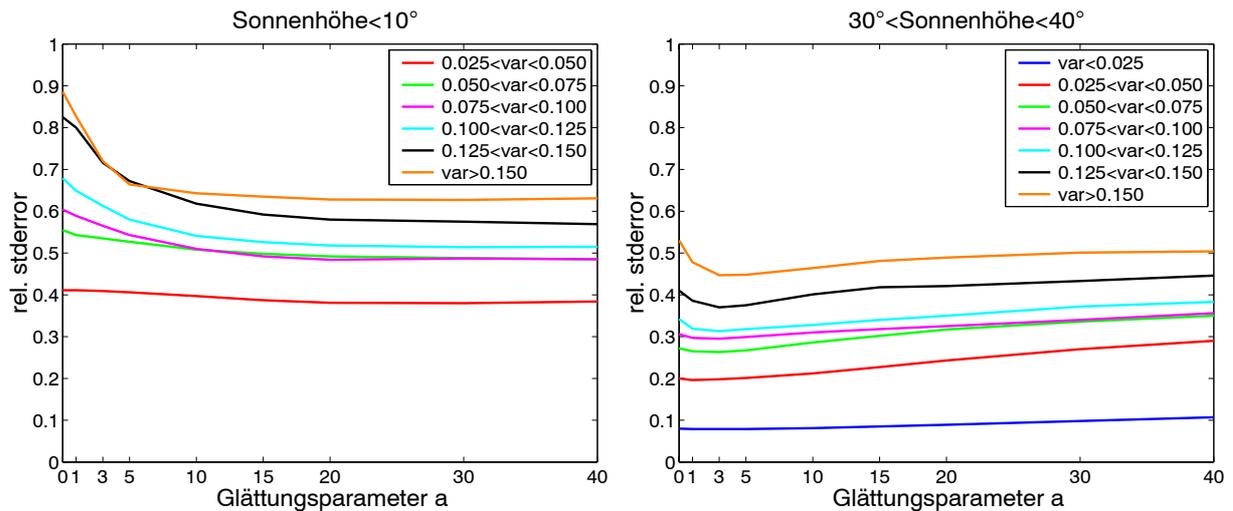


Abbildung 5.3: *stderror* in Abhängigkeit vom Glättungsparameter für die verschiedenen Variabilitätsklassen am Beispiel von Sonnenständen $\alpha < 10^\circ$ (links) und $30^\circ < \alpha < 40^\circ$ (rechts).

dem Glättungsparameter der Fehler, der durch die Glättung gemacht wird. Diese beiden Effekte gleichen sich weitgehend aus.

- Der optimale Glättungsparameter hängt vom Sonnenstand ab. Für niedrigen Sonnenstand mit hohem *stderror* werden die Fehler für Mittelwerte über ein großes Gebiet (81x81 Pixel für $\alpha < 10^\circ$) minimal. Mit steigendem Sonnenstand verschieben sich die optimalen Glättungsparameter zu niedrigeren Werten (3x3 Pixel für $\alpha > 40^\circ$).

Insgesamt folgt aus der zweidimensionalen Analyse, daß zur Bestimmung der optimalen Glättungsparameter die Variabilitätsklassen zusammengefaßt werden können, es jedoch sinnvoll ist, nach Sonnenstand zu klassifizieren. Die optimalen Glättungsparameter für die verschiedenen Sonnenhöhen sind in Tabelle 5.2 zusammengefaßt.

| Sonnenhöhe α | Glättungsparameter a |
|---------------------|------------------------|
| $\alpha < 10$ | 40 |
| $10 < \alpha < 20$ | 10 |
| $20 < \alpha < 30$ | 3 |
| $30 < \alpha < 40$ | 3 |
| $40 < \alpha < 50$ | 1 |
| $50 < \alpha$ | 1 |

Tabelle 5.2: Optimaler Glättungsparameter a in Abhängigkeit vom Sonnenstand.

Statistischer Anteil des Fehlers

In diesem Abschnitt wird der statistische Anteil des Fehlers betrachtet. Die Korrelation und die Dispersion werden in Bezug auf ihre Abhängigkeit von Sonnenstand und Variabilität untersucht. Dazu sind in Abb. 5.4 Dispersion und $(1-korr)$ in Abhängigkeit von den genannten Parametern dargestellt. Zur Charakterisierung der Korrelation wird im Folgenden die Auftragung als die Differenz zwischen eins und der Korrelation, $(1-korr)$, gewählt. Über diese Darstellung kann, wie an Gleichung (5.9) deutlich wird, der Zusammenhang zwischen der Korrelation und den Fehlermaßen besser veranschaulicht werden.

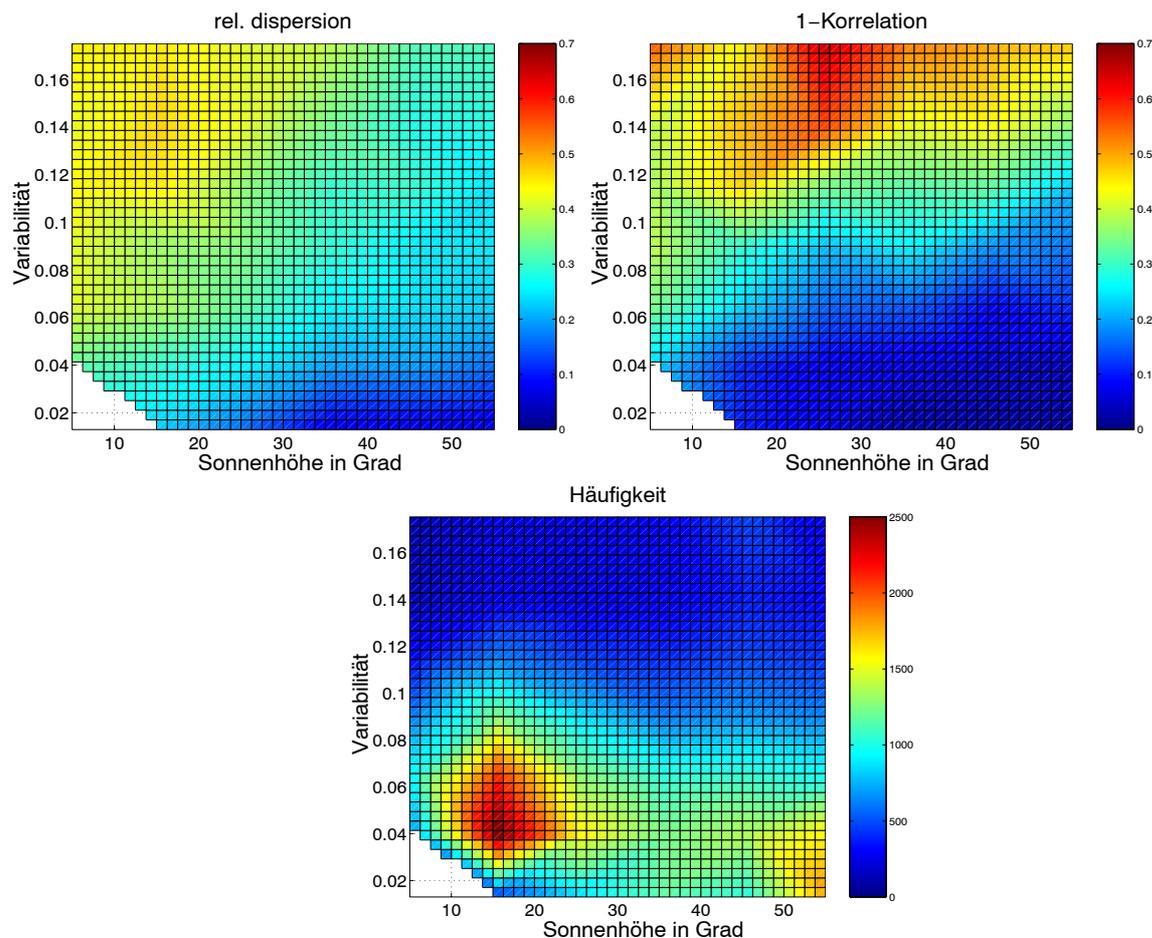


Abbildung 5.4: Relative Dispersion (links oben), $(1-korr)$ (rechts oben) und Häufigkeitsverteilung (unten) in Abhängigkeit vom Sonnenstand und der Variabilität. Die Fehlermaße und die Häufigkeiten sind durch die Farbskala charakterisiert.

Es wird deutlich, daß beide Größen einen wesentlichen Einfluß auf die Vorhersagequalität haben. Beide Fehlermaße nehmen mit der Variabilität zu und mit steigender Sonnenhöhe ab. Die Häufigkeitsverteilung in Abb. 5.4 zeigt, daß Situationen mit sehr hoher Variabilität und damit sehr hohen Fehlern vergleichsweise selten auftreten. Für über 80% aller Fälle ist die Variabilität kleiner als

0.1, wo bei Sonnenständen $\alpha > 10^\circ$ die Korrelation zwischen $korr = 0.7$ und $korr = 0.98$ liegt und die Dispersion im Wesentlichen unter 35% bleibt. Das Maximum der Häufigkeitsverteilung liegt bei einer Variabilität von $0.025 < var < 0.05$ mit Dispersion zwischen 15% und 30% und Korrelation über $korr = 0.9$.

Im Folgenden wird zunächst der Einfluß der Variabilität auf die Korrelation und die sich entsprechend ergebende Dispersion näher beschrieben: In Ergänzung zu Abb. 5.4 ist in Abb. 5.5 am Beispiel der Sonnenstandsklassen $\alpha < 10^\circ$ und $30^\circ < \alpha < 40^\circ$ (repräsentativ für $\alpha > 10^\circ$), die Abhängigkeit der beiden Fehlermaße von der Variabilität dargestellt. Je inhomogener die Bewölkungsstruktur ist, desto geringer wird die Korrelation zwischen berechneter und gemessener Bodeneinstrahlung. Für $\alpha > 10^\circ$ steigt $(1-korr)$ in etwa linear mit der Variabilität an. Im Vergleich dazu ist der Verlauf der Dispersion für sehr niedrige Variabilitäten steiler, während die Kurve hin zu hohen Variabilitäten stark abflacht. Dies ist zum einen durch den in Gleichung (5.8) gegebenen Zusammenhang

$$disp \sim \sqrt{(1-korr)} \quad (5.13)$$

bedingt, der in Abb. 5.5 durch die gestrichelte blaue Kurve

$$disp^* = \sqrt{2\sigma(k_{sat,ges}^*)\sigma(k_{ground,ges}^*)}(1-korr) \quad (5.14)$$

dargestellt ist. Dabei bezeichnen $\sigma(k_{sat,ges}^*)$ und $\sigma(k_{ground,ges}^*)$ die Standardabweichungen für die gesamten Zeitreihen, ohne Aufteilung nach Variabilität und Sonnenstand.

Der Verlauf der Standardabweichungen von gemessener und berechneter Einstrahlung über der Variabilität, der ebenfalls in Abb. 5.5 gegeben ist, trägt dazu bei, diesen Effekt zu verstärken. Sehr niedrige Variabilität entspricht Clearsky-Situationen, so daß die Standardabweichung für beide Zeitreihen sehr klein ist (siehe Abb. 3.7). Aus Abb. 3.7³ wird weiterhin ersichtlich, daß etwas höhere Variabilität für das gesamte Spektrum an Einstrahlungswerten auftreten kann, was zu einer hohen Standardabweichung führt. Je höher die Variabilität wird, desto schmaler wird der Bereich an Strahlungswerten, die auftreten können, da bei hoher Variabilität keine Extremwerte der Strahlung mehr auftreten. Damit erklärt sich das Sinken der Standardabweichung hin zu hohen Variabilitäten. Die Standardabweichung der aus Satellitendaten berechneten Einstrahlung liegt insgesamt unter der Standardabweichung der Bodenmeßreihe. Dies ist durch die Glättung bei der Berechnung der Einstrahlung aus Satellitendaten bedingt. Der Glättungseffekt und damit die Verringerung der Standardabweichung wird um so deutlicher, je höher die Variabilität ist. Gemäß Gleichung (5.8) ergibt sich durch Abfall der Standardabweichungen hin zu hoher Variabilität der flachere Verlauf der Dispersion gegenüber $disp^*$. Der steilere Anstieg für niedrige Variabilität ist durch das Absinken der Standardabweichungen hin zu sehr niedriger Variabilität bedingt.

Für Sonnenstände $\alpha < 10^\circ$ ist die Korrelation auch für die niedrigen Variabilitäten vergleichsweise gering. Die Abhängigkeit von der Variabilität ist weniger stark ausgeprägt als für höhere Sonnenstände und nicht mehr linear. Der Zusammenhang zwischen Dispersion und Korrelation ergibt

³Diese Graphik kann hier zur Veranschaulichung des Prinzips herangezogen werden, auch wenn die beiden benutzten Variabilitätsmaße nicht identisch sind und außerdem hier lokale Variabilität und Mittelwert und in der Graphik Mittelwert und Variabilität für ein Bild betrachtet werden.

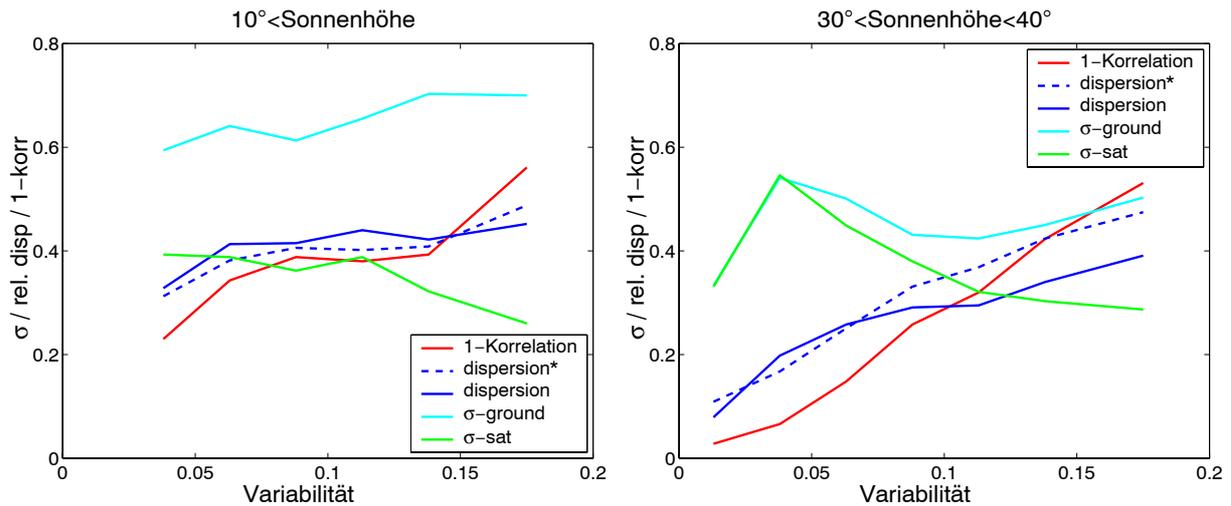


Abbildung 5.5: $disp$, $disp^*$, $(1-korr)$ und Standardabweichungen der gemessenen und der berechneten Zeitreihe in Abhängigkeit von der Variabilität am Beispiel von Sonnenständen $\alpha < 10^\circ$ (links) und $30^\circ < \alpha < 40^\circ$ (rechts). Die Legende des rechten Bildes gilt auch links.

sich analog zu den Überlegungen für höhere Sonnenstände. Wegen der starken Glättung ($a = 40$) für diesen Sonnenstand liegt die Standardabweichung der simulierten Zeitreihe deutlich unter der Standardabweichung der Meßzeitreihe.

Ein Überblick über die Standardabweichungen der berechneten Zeitreihe und der Meßzeitreihe für alle Sonnenstände ist in Abb. 5.6 gegeben. Zur Vervollständigung wird auch der Mittelwert der Bodenmessung in zweidimensionaler Auftragung dargestellt. Für Sonnenstände $\alpha > 10^\circ$ ist der Mittelwert k^* in etwa konstant, nur für niedrigste Variabilität im Clearsky-Fall ergeben sich höhere k^* -Werte. Die niedrigeren Mittelwerte des Clearsky-Index für $\alpha < 10^\circ$ deuten darauf hin, daß das verwendete Clearsky-Modell mit kontinentalem Trübungsparameter den mittleren Bedingungen in Saarbrücken nicht optimal entspricht, was sich insbesondere für niedrige Sonnenstände stark auswirkt.

Die Abhängigkeit der Vorhersagequalität vom Sonnenstand ist in Abb. 5.7 am Beispiel von $0.05 < var < 0.075$ verdeutlicht. Die Kurven der anderen Variabilitätsklassen entsprechen qualitativ dem gezeigten Beispiel. Die Korrelation sinkt zu niedrigen Sonnenständen hin stark ab. Ab $\alpha = 20^\circ$ ist der Verlauf der Kurve flacher. Gemäß der Beziehung 5.13 erklärt sich der flachere Verlauf der Kurve für die Dispersion im Vergleich zu $1 - korr$.

Zusammenfassend kann festgestellt werden, daß sowohl Korrelation als auch Dispersion wesentlich von Variabilität und Sonnenstand abhängen. Die Korrelation sinkt im Wesentlichen linear mit der Variabilität. Diese Abhängigkeit überwiegt die Abhängigkeit vom Sonnenstand, nur für niedrige Sonnenstände verringert sich die Korrelation stark (siehe rechtes Bild Abb. 5.4). Für die Dispersion ist die Zunahme des Fehlers für hohe Variabilitäten im Vergleich zu $(1-korr)$ durch Bildung der Quadratwurzel und Multiplikation mit der Standardabweichung verringert. Der Einfluß von Sonnenstand und Variabilität auf den Fehler ist hier in etwa gleich (siehe linkes Bild Abb. 5.4).

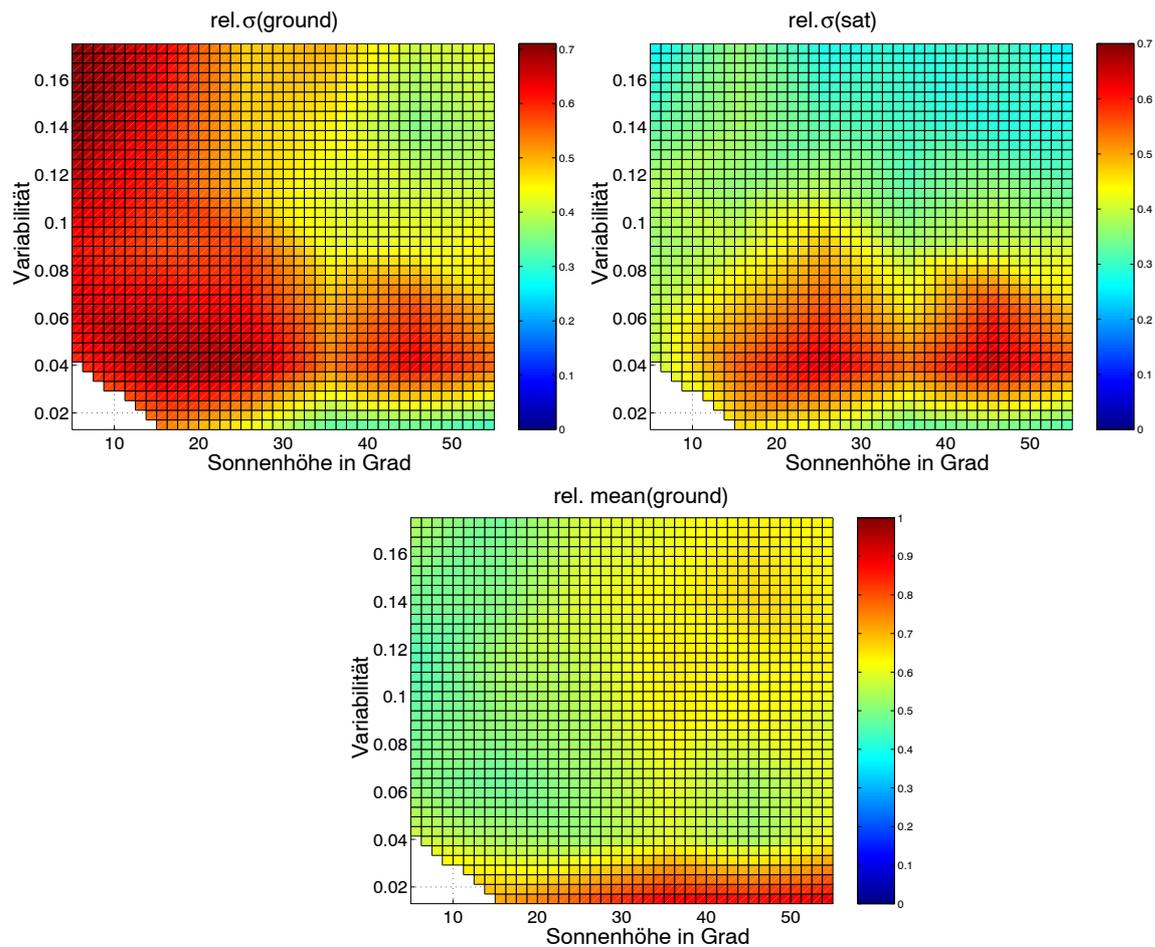


Abbildung 5.6: Standarabweichung der Bodenzeitreihe (links oben), Standarabweichung der berechneten Zeitreihe (rechts oben) und Mittelwerte der Bodenzeitreihe (unten) in Abhängigkeit von Sonnenstand und Variabilität. Die Standarabweichungen und die Mittelwerte sind durch die Farbskala charakterisiert.

Aus der Häufigkeitsverteilung ergibt sich, daß Situationen mit stark inhomogener Bewölkung und hohen Vorhersagefehlern vergleichsweise selten auftreten.

Systematischer Anteil des Fehlers

Nach der Untersuchung des statistischen Anteils des Vorhersagefehlers wird hier der Anteil des Fehlers betrachtet, der durch systematische Abweichung der Zeitreihen voneinander bedingt ist. Weiterhin werden die verschiedenen Anteile des Fehlers zueinander in Beziehung gesetzt. Dazu sind in Abb. 5.8 *rmse*, *stderror*, *bias* und *stdbias* über Sonnenstand und Variabilität aufgetragen.

Es zeigt sich, daß für Sonnenstände $\alpha > 20^\circ$ und Variabilität $var \leq 0.1$ *rmse*, *stderror* und *disp* im Wesentlichen übereinstimmen, *bias* und *stdbias* tragen nur geringfügig zum *rmse* bei. Dies wird

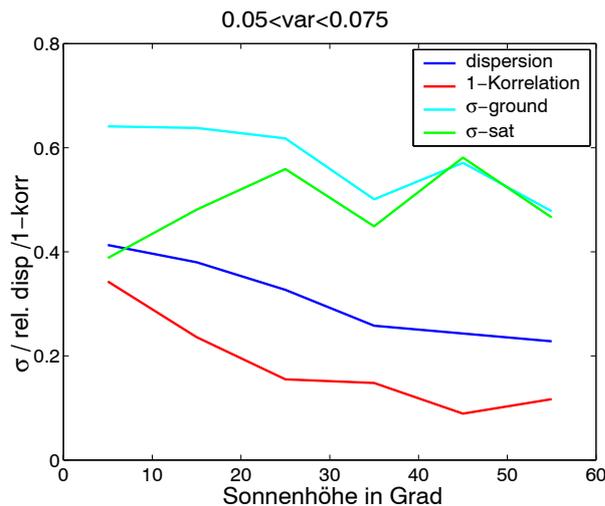


Abbildung 5.7: Dispersion, ($1-korr$) und Standardabweichung der gemessenen und berechneten Zeitreihe in Abhängigkeit vom Sonnenstand am Beispiel der Variabilitätsklasse $0.05 < var < 0.075$.

auch am rechten Bild von Abb. 5.9 deutlich, wo am Beispiel von Sonnenstandsklasse $30^0 < \alpha < 40^0$ die genannten Fehlermaße im direkten Vergleich gezeigt sind. Die ohnehin gegenüber der Dispersion geringen Werte des *bias* und des *stdbias* zwischen -10% bis 10% fallen durch die Quadrierung bei der Berechnung des *rmse* gemäß Gleichung (5.9) noch weniger ins Gewicht. Insgesamt läßt sich sagen, daß für diesen Wertebereich sowohl Mittelwert als auch Standardabweichung von berechneter und gemessener Einstrahlung gut übereinstimmen. Für niedrige Sonnenstände trägt der *bias* deutlich zum Gesamtfehler bei. Die Bodeneinstrahlung wird bei Berechnung aus Satellitendaten gegenüber Meßwerten deutlich überschätzt (siehe Abb. 5.8 und 5.9).

Die Differenz der Standardabweichungen der beiden Zeitreihen, gegeben durch den *stdbias*, ist im Wesentlichen durch die Glättung bei Berechnung der Einstrahlung aus Satellitendaten bedingt. Dabei wirkt sich bei gleichem Sonnenstand und damit gleichem Glättungsparameter die Verringerung der Standardabweichung mit steigender Variabilität um so stärker aus (siehe Abb. 5.9 und Abb. 5.5). Für niedrige Sonnenstände mit hohem Glättungsparameter ist der *stdbias* ebenfalls vergleichsweise hoch (siehe Abb. 5.9 und Abb. 5.5). Trotz des durch Glättung erhöhten *stdbias*, wird durch die Glättung insgesamt der *stderror* verringert, was im übernächsten Abschnitt zum Einfluß der Glättung ausführlich erläutert wird.

Genauigkeit der Fehlermaße

Die angegebenen mittleren Fehlermaße sind Abschätzungen der wahren mittleren Fehler durch Stichproben. Im Folgenden wird kurz darauf eingegangen, welche Unsicherheit mit dieser Abschätzung verbunden ist. Theoretisch läßt sich die Genauigkeit des Mittelwerts einer Zeitreihe über die Standardabweichung der Mittelwerte charakterisieren, wenn eine große Anzahl von Stichproben gegeben ist ([Adunka 2000]). Unter der Voraussetzung, daß die Einzelmessungen voneinan-

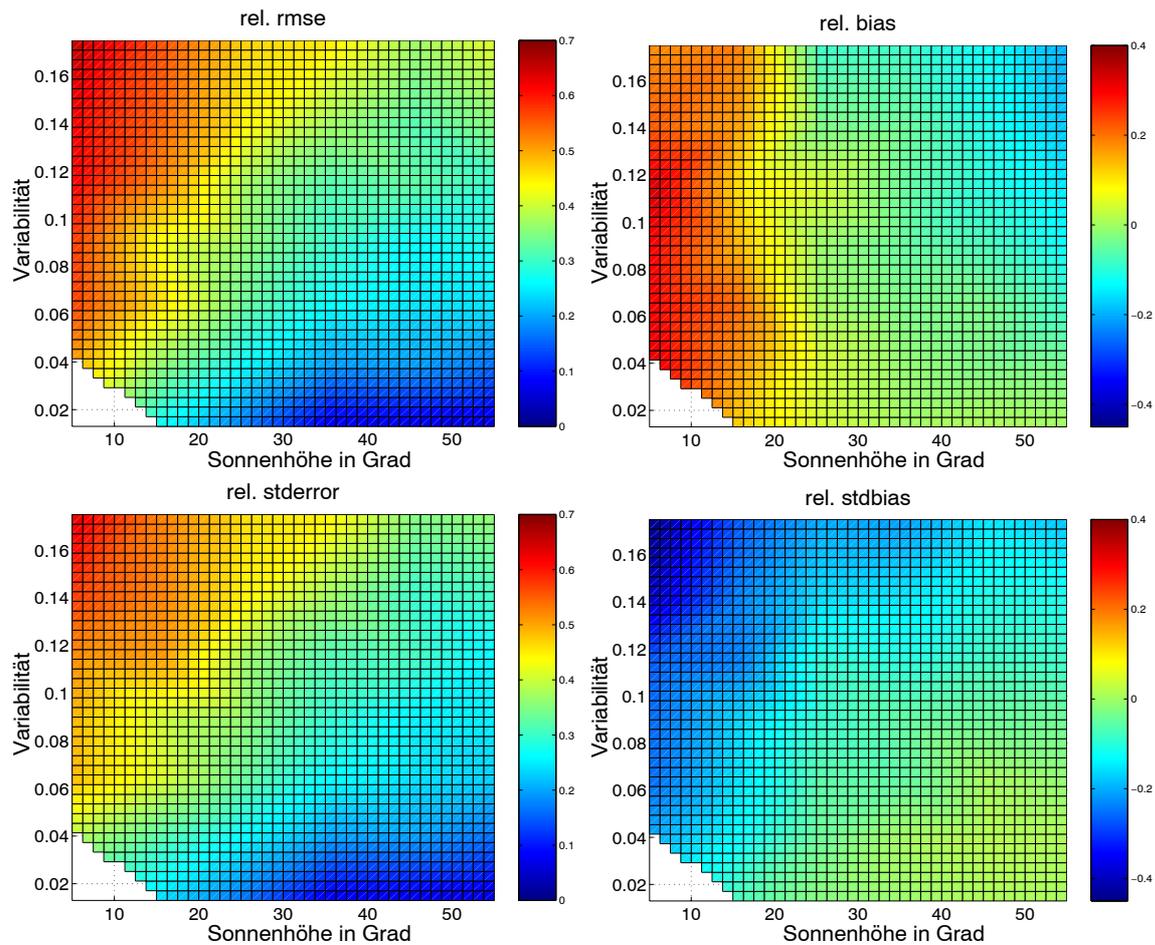


Abbildung 5.8: *rmse* (links oben), *stderror* (links unten), *bias* (rechts oben) und *stdbias* (rechts unten) in Abhängigkeit vom Sonnenstand und der Variabilität. Die Fehlermaße sind durch die Farbskala charakterisiert. (Man beachte die unterschiedliche Farbskala für *rmse* /*stderror* auf der eine Seite und *bias* /*stdbias* auf der anderen Seite.)

der unabhängig sind, ergibt sich diese zu:

$$\sigma(\bar{x}) = \frac{1}{\sqrt{N}}\sigma(x). \quad (5.15)$$

Bei der Berechnung der Solarstrahlung aus Satellitendaten sind die Einzelmessungen einer Zeitreihe nicht statistisch unabhängig. So ergibt sich z.B. durch Über- oder Unterschätzung der Trübung für einen bestimmten Tag eine Unter- bzw. Überschätzung der Strahlung für diesen Zeitraum. Dieser Fehler wird durch Mittelung über mehrere Werte nicht geringer. Gleiches gilt für Fehler, die durch die Ungenauigkeit der Bodenalbedo bedingt sind.

Da die Bedingung der statistischen Unabhängigkeit der Einzelmessungen nicht erfüllt ist, wäre eine quantitative Abschätzung der Unsicherheit der Fehler vergleichsweise aufwendig. Es gilt jedoch qualitativ gemäß den oben angegebenen Formeln, daß die Fehler kleiner werden, je mehr Punkte

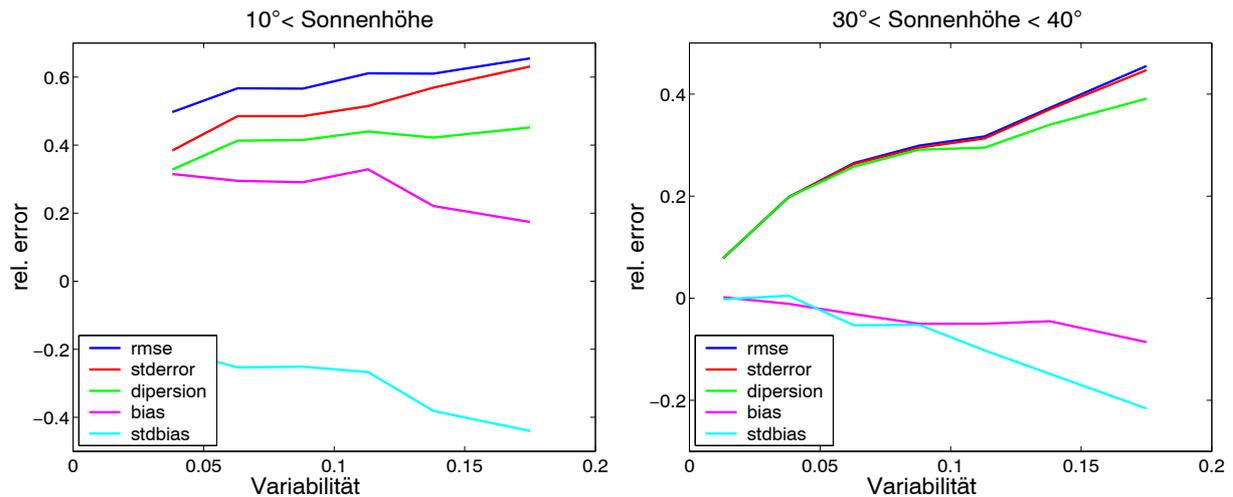


Abbildung 5.9: *rmse*, *stderror*, *disp*, *bias* und *stdbias* in Abhängigkeit von der Variabilität für die Sonnenstände $\alpha < 10^\circ$ (links) und $30^\circ < \alpha < 40^\circ$ (rechts).

zum einen in die Auswertung einbezogen werden und je kleiner zum anderen die Standardabweichung der Meßreihen ist. Einen Anhaltspunkt zur Genauigkeit der angegebenen Fehlermaße ergibt sich aus den unsystematischen Variationen der in diesem Kapitel gezeigten Graphen. So verlaufen für niedrige Variabilitäten mit niedrigem *stderror* die Kurven relativ glatt, und die angegebenen Fehler haben eine entsprechend geringe Unsicherheit. Für hohe Variabilitäten und niedrige Sonnenhöhen treten dagegen starke Schwankungen auf, die durch die Ungenauigkeit der Mittelwerte bedingt sind.

Anhand der Abbildungen ergibt sich weiterhin, daß die mittleren Fehlermaße ausreichend genau sind, Situationen unterschiedlicher Vorhersagequalität zu unterscheiden. Die systematischen Änderungen der Vorhersagequalität durch den Einfluß von Variabilität, Sonnenstand und Vorhersagezeitraum sind trotz unsystematischer Schwankungen durch die Ungenauigkeit bei der Bestimmung der Mittelwerte klar erkennbar.

Einfluß der Glättung auf den Vorhersagefehler

Der Einfluß der Glättung auf den Vorhersagefehler läßt sich durch Betrachtung verschiedener Fehlermaße verdeutlichen. Zum einen verbessert eine Glättung die Korrelation zwischen berechneter und gemessener Zeitreihe. Dies wird an Abb. 5.10 deutlich, wo am Beispiel der Sonnenstände $\alpha < 10^\circ$ und $30^\circ < \alpha < 40^\circ$ für verschiedene Glättungsparameter (*I-korr*) über der Variabilität aufgetragen ist. Besonders für niedrige Korrelationen bei niedrigen Sonnenständen und hoher Variabilität hat die Optimierung der Glättung einen deutlichen Einfluß

Dazu kommt, daß durch Glättung die Standardabweichung der Satellitenzeitreihe so verändert wird, daß der *stderror* sich dem mit MOS minimal erreichbaren Fehler annähert. Durch Optimierung der Glättung wird $\sigma(k_{sat}^*)$ in Richtung des Optimums gemäß Gleichung (5.10) verschoben.

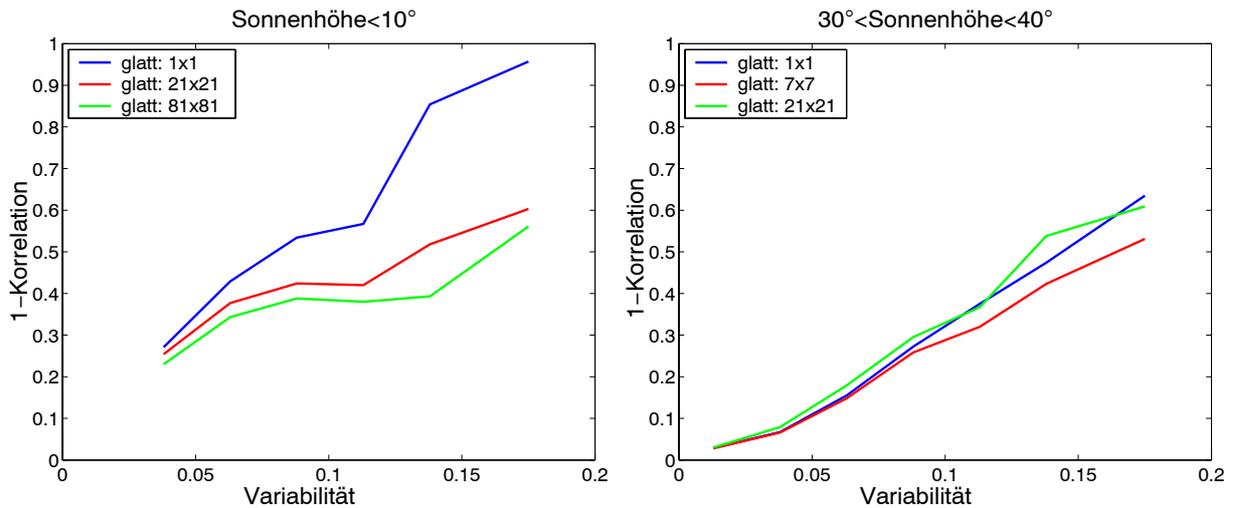


Abbildung 5.10: ($1-korr$) in Abhängigkeit von der Variabilität für verschiedene Glättungsparameter am Beispiel von Sonnenständen $\alpha < 10^\circ$ (links) und $30^\circ < \alpha < 40^\circ$ (rechts).

Dies wird an den oberen Bildern in Abb. 5.11 deutlich, wo am Beispiel von Sonnenstandsklassen $\alpha < 10^\circ$ und $30^\circ < \alpha < 40^\circ$ die Standardabweichung der Satellitenzeitreihe ohne Glättung und mit optimaler Glättung im Vergleich zum gemäß MOS optimalen Wert für $\sigma(k_{sat}^*)$ über der Variabilität aufgetragen ist. Die geglätteten Kurven liegen für hohe Variabilität und niedrige Sonnenstände deutlich näher beim Optimum als die ungeglätteten Kurven. Daraus ergibt sich der in den unteren beiden Bildern von Abb. 5.11 dargestellte Verlauf des $stderror$ in Bezug zu mit MOS minimal erreichbaren Fehlern. Ohne Glättung liegen die berechneten Kurven deutlich über den mit MOS erreichbaren Fehler-Kurven. Für optimale Glättung stimmt die Kurven mit den theoretisch erreichbaren Kurven nahezu überein.

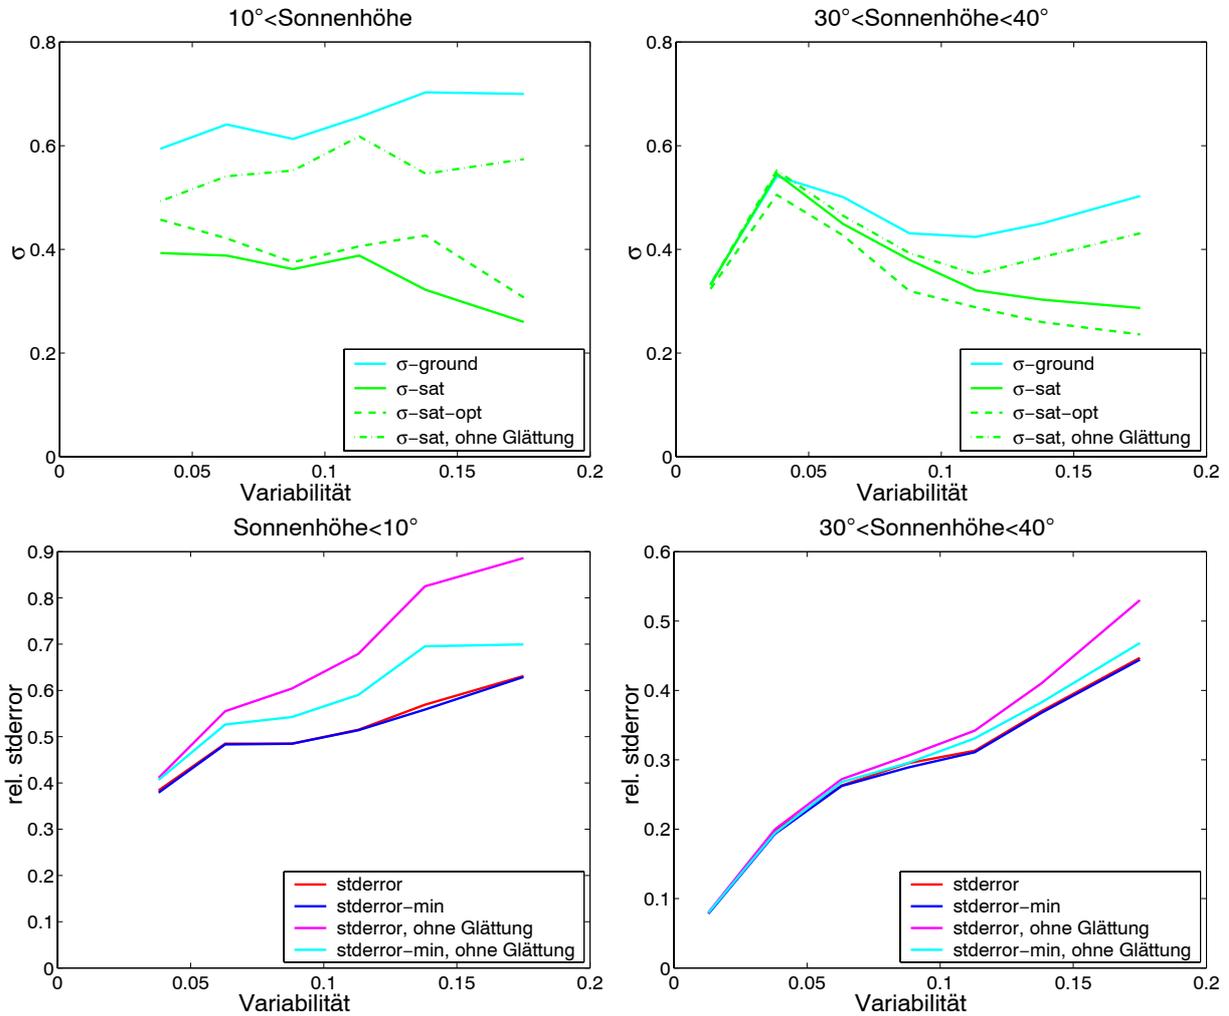


Abbildung 5.11: Standardabweichung der Bodenzeitreihe und Standardabweichung der Satellitenzeitreihe ohne Glättung und mit optimaler Glättung, im Vergleich zum optimalen Wert für $\sigma(k_{sat}^*)$ in Abhängigkeit von der Variabilität (oben), *stderror* ohne Glättung und mit optimaler Glättung im Vergleich zu den mit MOS minimal erreichbaren Werten in Abhängigkeit von der Variabilität (unten) am Beispiel von Sonnenständen $\alpha < 10^\circ$ (linke Bilder) und $30^\circ < \alpha < 40^\circ$ (rechte Bilder).

Zusammenfassung

Die wesentlichen Ergebnisse der zweidimensionalen Auswertung für die Heliosat-Methode werden im Folgenden aufgelistet:

- Durch die Darstellung des Fehlers in Abhängigkeit von Variabilität und Sonnenstand lassen sich Situationen unterschiedlicher Genauigkeit der Heliosat-Methode unterscheiden.
- Bezüglich des Sonnenstandes wurde festgestellt, daß sich die relativen Fehler mit steigendem Sonnenstand verringern. Ab Sonnenstand $\alpha = 20^\circ$ ergeben sich gute Ergebnisse. Zu niedrigeren Sonnenständen hin fällt die Qualität der Heliosat-Methode stark ab. Für Sonnenstände $\alpha < 10^\circ$ liegt der *stderror* zwischen 40% und 60%, hier ergeben Mittelwerte über sehr große Gebiete die besten Ergebnisse. Zusätzlich tritt für niedrige Sonnenstände eine deutliche Überschätzung der Einstrahlung auf.
- Die mittleren Fehler der Solarstrahlungsberechnung steigen mit der Variabilität. Dabei treten Situationen mit niedriger bis mittlerer Variabilität mit *stderror* $< 20\%$ für Sonnenstände $\alpha > 20^\circ$ vergleichsweise häufig auf. Für sehr hohe Variabilität steigt der *stderror* für Sonnenstände $\alpha > 20^\circ$ auf bis zu 40%.
- In Situationen mit hoher Einstrahlung (hoher Sonnenstand, niedrige Variabilität) kann die Bodeneinstrahlung aus Satellitendaten mit hoher Qualität bestimmt werden. Dagegen führen die sehr hohen prozentualen Fehler für niedrige Sonnenstände wegen der niedrigen Einstrahlung nur zu geringen Absolutwerten des Fehlers. Dies ist ein großer Vorteil für Anwendungen, bei denen Absolutwerte der Einstrahlung betrachtet werden.

5.3.3 Fehleranalyse der Vorhersage

Aufbauend auf die zweidimensionale Fehleranalyse für die Heliosat-Methode wird in diesem Abschnitt die Genauigkeit der Vorhersage für Vorhersagezeiträumen bis zu 6 Stunden analysiert. Dazu wird zunächst wieder die Glättung für jeden Vorhersagezeitraum und Sonnenstand optimiert. Weiterhin wird anhand von Beispielen untersucht, wie sich die Abhängigkeit der Vorhersagequalität von Variabilität und Sonnenstand mit dem Vorhersagezeitraum entwickelt. Im Folgenden wird dann ein Überblick über *bias* und *stderror* in Abhängigkeit von Vorhersagezeitraum, Variabilität und Sonnenstand gegeben. Abschließend werden die Vorhersagefehler mit der Persistenz von Satellitenwerten und Bodenmeßwerten verglichen.

Optimierung der Glättung

Die Glättungsparameter werden für die verschiedenen Vorhersagezeiträume gemäß dem vorangehenden Abschnitt für jeden Sonnenstand getrennt eingestellt. Es zeigt sich, daß die Unterschiede

zwischen den optimalen Glättungsparametern für die einzelnen Sonnenstände mit steigendem Vorhersagezeitraum abnehmen. Ab einem Vorhersagezeitraum von 90 Minuten zeigen die Glättungsparameter keinen systematischen Abfall mit dem Sonnenstand mehr. Insgesamt sind die optimalen Glättungsparameter für Sonnenstände $\alpha > 20$ für alle Vorhersagezeiträume nur wenig verschieden. Diese sind in Tabelle 5.3 zu mittleren Glättungsparametern zusammengefaßt. Es wird deutlich, daß die optimale Glättung, wie auch bei der Vorhersage von Bewölkungsbildern, mit dem Vorhersagezeitraum steigt (siehe Tabelle 4.3). Die optimalen Glättungsparameter für die Persistenz liegen dabei immer etwas über den optimalen Glättungsparametern für die Vorhersage, bedingt durch die höheren Fehler, die bei Persistenz auftreten (siehe auch Abschnitt 4.3.2).

| Vorhersagezeitraum | Glättungsparameter a Vorhersage | Glättungsparameter a Persistenz |
|--------------------|--------------------------------------|--------------------------------------|
| 0.5h | 3 | 5 |
| 1h | 5 | 15 |
| 1.5h | 10 | 20 |
| 2h | 20 | 30 |
| 3h | 30 | 40 |
| 4h | 40 | 60 |
| 5h | 50 | 60 |
| 6h | 60 | 60 |

Tabelle 5.3: Mittlere optimale Glättungsparameter in Abhängigkeit vom Vorhersagezeitraum.

Vorhersagefehler in Abhängigkeit von Vorhersagezeitraum und Variabilität

Die Entwicklung der Abhängigkeit der Vorhersagefehler von der Variabilität mit steigendem Vorhersagezeitraum wird zunächst für die Korrelation betrachtet und am Beispiel der Sonnenstände $30 < \alpha < 40$ dargestellt. In Abb. 5.12 ist im linken Bild (*l-korr*) für die verschiedenen Variabilitätsklassen aufgetragen. Zur Einordnung nach der Variabilität wird dabei die tatsächlich eingetretene Variabilität zum Vorhersagezeitpunkt verwendet. Es zeigt sich, daß, wie erwartet, für alle Variabilitätsklassen bis zu 6 Stunden die Korrelation mit dem Vorhersagezeitraum abfällt. Die Aufteilung der Vorhersagequalität nach der Variabilität bleibt bestehen.

In der Realität steht die Variabilität zum Vorhersagezeitpunkt nicht zur Verfügung. In Abb. 5.12 im rechten Bild erfolgte die Einordnung deshalb nach der Variabilität des Ausgangsbildes, das verschoben wird⁴. Für Vorhersagezeiträume bis zu etwa 4h steigt für alle Variabilitäten (*l-korr*) mit dem Vorhersagezeitraum an. Ab etwa 4-5h kehrt sich dieser Verlauf für hohe Variabilität um, für niedrige Variabilität wird der Anstieg steiler.

Der Vergleich der beiden Abbildungen zeigt, daß die Vorhersagequalität wesentlich stärker durch die Variabilität der vorhergesagten Situation beeinflusst ist (Umrechnung Satellit-Boden) als durch

⁴Vorhersage der Variabilität führt nicht zu besseren Ergebnissen.

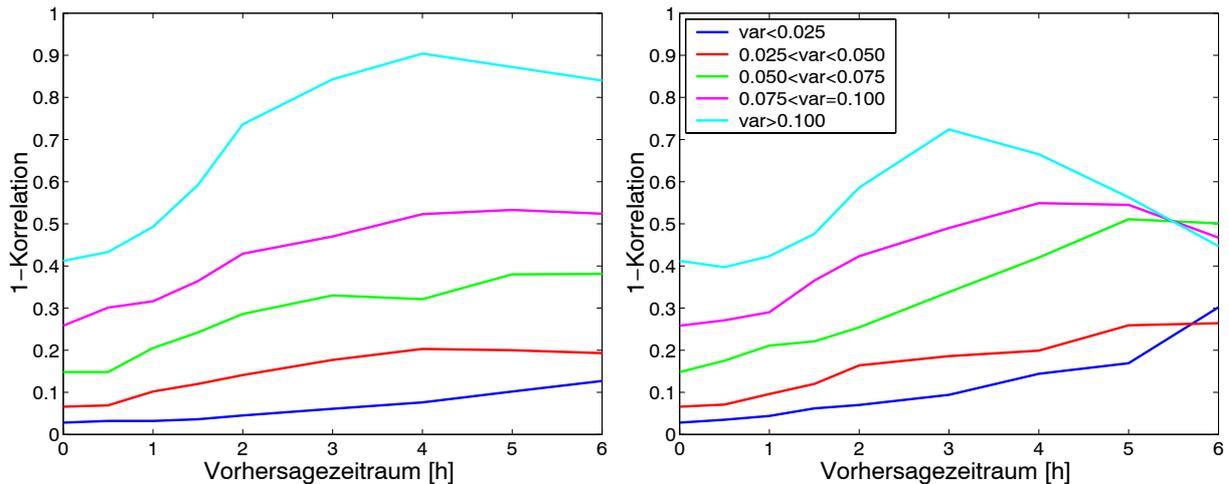


Abbildung 5.12: (1-korr) in Abhängigkeit vom Vorhersagezeitraum für verschiedene Variabilitätsklassen am Beispiel der Sonnenstände $30^\circ < \alpha < 40^\circ$, die Zuordnung zur Variabilität erfolgte im linken Bild nach der Variabilität zum Zeitpunkt, für den die Vorhersage gemacht wird, im rechten Bild erfolgte die Zuordnung nach der Variabilität am Ausgangspunkt für die Vorhersage (realistischer Fall). Die Legende des rechten Bildes gilt auch links.

die Variabilität des Ausgangsbildes und der Qualität des Vektorfelds. Damit läßt sich der Verlauf der Kurven im rechten Bild von Abb. 5.12 erklären. Für Vorhersagezeiträume länger als 4h wird die Variabilität durch Persistenz nicht mehr gut vorhergesagt, und die Zuordnung zur Variabilitätsklasse erfolgt nicht mehr korrekt. So werden z.B. einer Klasse hoher Variabilität auch tatsächlich niedrigere Variabilitäten zugeordnet. Da die Abhängigkeit von der Variabilität die Abhängigkeit vom Vorhersagezeitraum dominiert, verringert sich so der Vorhersagefehler für diese Klasse mit dem Vorhersagezeitraum.

Der Verlauf des $stderror$ in bezug auf Variabilität und Vorhersagezeitraum ist in Abb. 5.13 dargestellt, wo für die verschiedenen Variabilitätsklassen der Fehler in Abhängigkeit vom Vorhersagezeitraum gegeben ist. Die Fehler der Variabilitätsklassen $var > 0.05$ zeigen ab dem Vorhersagezeitraum eine Stunde keine systematischen Genauigkeitsunterschiede mehr. Der Unterschied zwischen dem Verlauf der Kurven für die Korrelation und dem $stderror$ ist dadurch bedingt, daß sich für niedrige Korrelation die Änderung der Korrelation wenig auf den $stderror$ auswirkt (siehe Abb. 5.2). Änderungen des $stderror$ bei niedriger Korrelation liegen innerhalb der Genauigkeitsgrenzen des $stderror$. Für die beiden niedrigsten Variabilitätsklassen mit deutlich höherer Korrelation ergeben sich über den gesamten Vorhersagebereich deutlich bessere Ergebnisse als für höhere Variabilitäten.

Zusammenfassend läßt sich sagen, daß für niedrige Variabilität ($var < 0.05$) für alle betrachteten Vorhersagezeiträume eine deutlich höhere Vorhersagequalität erzielt werden kann als für Variabilitäten $var > 0.05$. Da sich für $var > 0.05$ für Vorhersagezeiträume länger als einer Stunde eine vergleichbare Genauigkeit ergibt, werden zur weiteren Auswertung alle Variabilitätsklassen

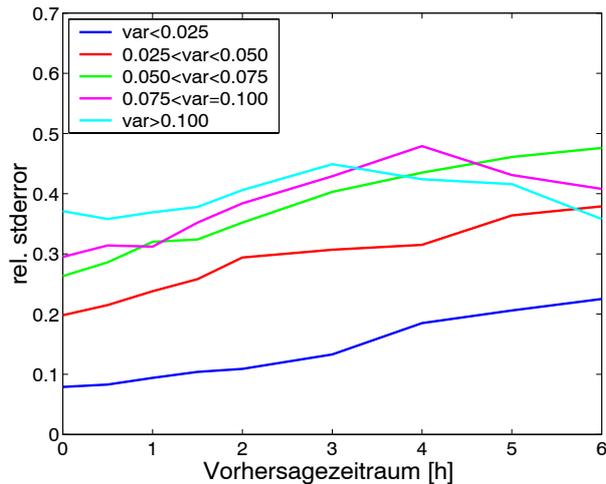


Abbildung 5.13: *stderror* in Abhängigkeit vom Vorhersagezeitraum für verschiedene Variabilitätsklassen am Beispiel der Sonnenstände $30^\circ < \alpha < 40^\circ$, die Zuordnung zur Variabilität erfolgt nach der Variabilität am Ausgangspunkt für die Vorhersage (realistischer Fall).

$var > 0.05$ zusammengefaßt.

Vorhersagefehler in Abhängigkeit von Vorhersagezeitraum und Sonnenstand

Bezüglich der Abhängigkeit der Vorhersagefehler vom Sonnenstand ergibt sich mit dem Vorhersagezeitraum die im Folgenden beschriebene Entwicklung. In Abb. 5.14 ist am Beispiel niedriger und mittlerer Variabilität (*1-korr*) für die verschiedenen Sonnenstände die Abhängigkeit vom Vorhersagezeitraum gegeben. Die Zuordnung zum Sonnenstand erfolgt dabei nach dem Sonnenstand der vorherzusagenden Situation. Da der Sonnenstand theoretisch berechnet wird, ist dies auch in der Anwendung möglich. Für niedrige Variabilität bleibt eine deutlich höhere Korrelation für Sonnenstände $\alpha > 20^\circ$ im Vergleich zu niedrigeren Sonnenhöhen bis zum Vorhersagezeitraum 6 Stunden bestehen (siehe linkes Bild, Abb. 5.14). Die rechte Graphik in Abb. 5.14 verdeutlicht, daß sich für höhere Variabilitäten für Vorhersagezeiträume ab etwa einer Stunde die Vorhersagegenauigkeiten für die verschiedenen Sonnenstände nicht mehr systematisch unterscheiden. Aus der Darstellung in Abb. 5.14 ergibt sich, daß Sonnenstände $\alpha > 20^\circ$ für die weitere Auswertung zusammengefaßt werden können. Für Sonnenstände $\alpha < 10^\circ$ sind bereits die Fehler der Heliosat-Methode sehr hoch, durch Vorhersage ändern sich die Fehler kaum. Die Fehler liegen hier für alle Vorhersagezeiträume deutlich über denen für andere Sonnenstände.

Überblick über *stderror* und *bias* in Abhängigkeit vom Vorhersagezeitraum

Zur vollständigen quantitativen Charakterisierung der Vorhersagequalität ist in diesem Abschnitt in Abb. 5.15 ein Überblick über *stderror* und *bias* in Abhängigkeit vom Vorhersagezeitraum für al-

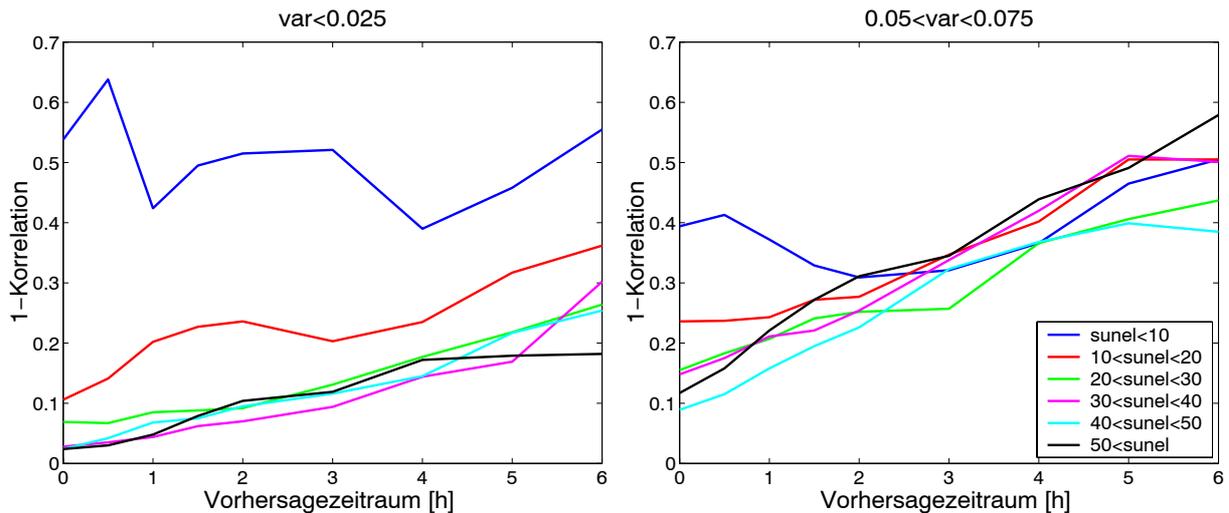


Abbildung 5.14: ($1-korr$) in Abhängigkeit vom Vorhersagezeitraum für verschiedene Sonnenstände am Beispiel von Variabilität $var < 0.025$ (links) und $0.05 < var < 0.075$ (rechts). Die Legende des rechten Bildes gilt auch links.

le Situationen gegeben. Dabei wird gemäß der Resultate der vorangehenden Abschnitte bezüglich des Sonnenstands zwischen $\alpha < 10^\circ$, $10^\circ < \alpha < 20^\circ$ und $\alpha > 20^\circ$ unterschieden. In Bezug auf die Variabilität wurden Klassen mit $var < 0.025$, $0.025 < var < 0.05$ und $var < 0.05$ gebildet. So ergeben sich, wie Abb. 5.15 zeigt, Klassen mit deutlich unterscheidbarer Vorhersagequalität. Für Sonnenstand $\alpha < 10^\circ$ sind entsprechend der hohen Fehler der Heliosat-Methode sowohl *bias* als auch *stderror* für alle Variabilitäten und Vorhersagezeiträume sehr hoch. Mit steigendem Sonnenstand verbessert sich die Vorhersagequalität sowohl bezüglich des *stderror* als auch bezüglich des *bias*. Für $\alpha > 20^\circ$ ergibt sich für Vorhersagen mit Clearsky-Ausgangssituation ($var < 0.025$) bis zu 6 Stunden eine hohe Vorhersagegenauigkeit mit *stderror* $< 25\%$. Im bewölkten Fall ist die Vorhersagequalität geringer. Entsprechend der Inhomogenität der Wolkendecke, charakterisiert durch die Variabilität, steigt der *stderror* von Werten zwischen 20% und 30% für die Heliosat-Methode auf Werte zwischen 35% und 45% für einen Vorhersagezeitraum von 6 Stunden an.

Bezüglich des *bias* fällt auf, daß der *bias* für Variabilität $var > 0.025$ für alle Sonnenstände mit dem Vorhersagezeitraum sinkt. Die Überschätzung der Einstrahlung für niedrige Sonnenstände wird so für höhere Vorhersagezeiträume verringert. Für Sonnenstände $\alpha > 20^\circ$, bei denen durch die Heliosat-Methode eine geringfügige Unterschätzung der Einstrahlung bedingt ist, ergibt sich dagegen ein negativer *bias* bis zu 10%. Für niedrige Variabilität ist für $\alpha > 20^\circ$ der *bias* über alle Vorhersagezeiträume konstant und sehr niedrig.

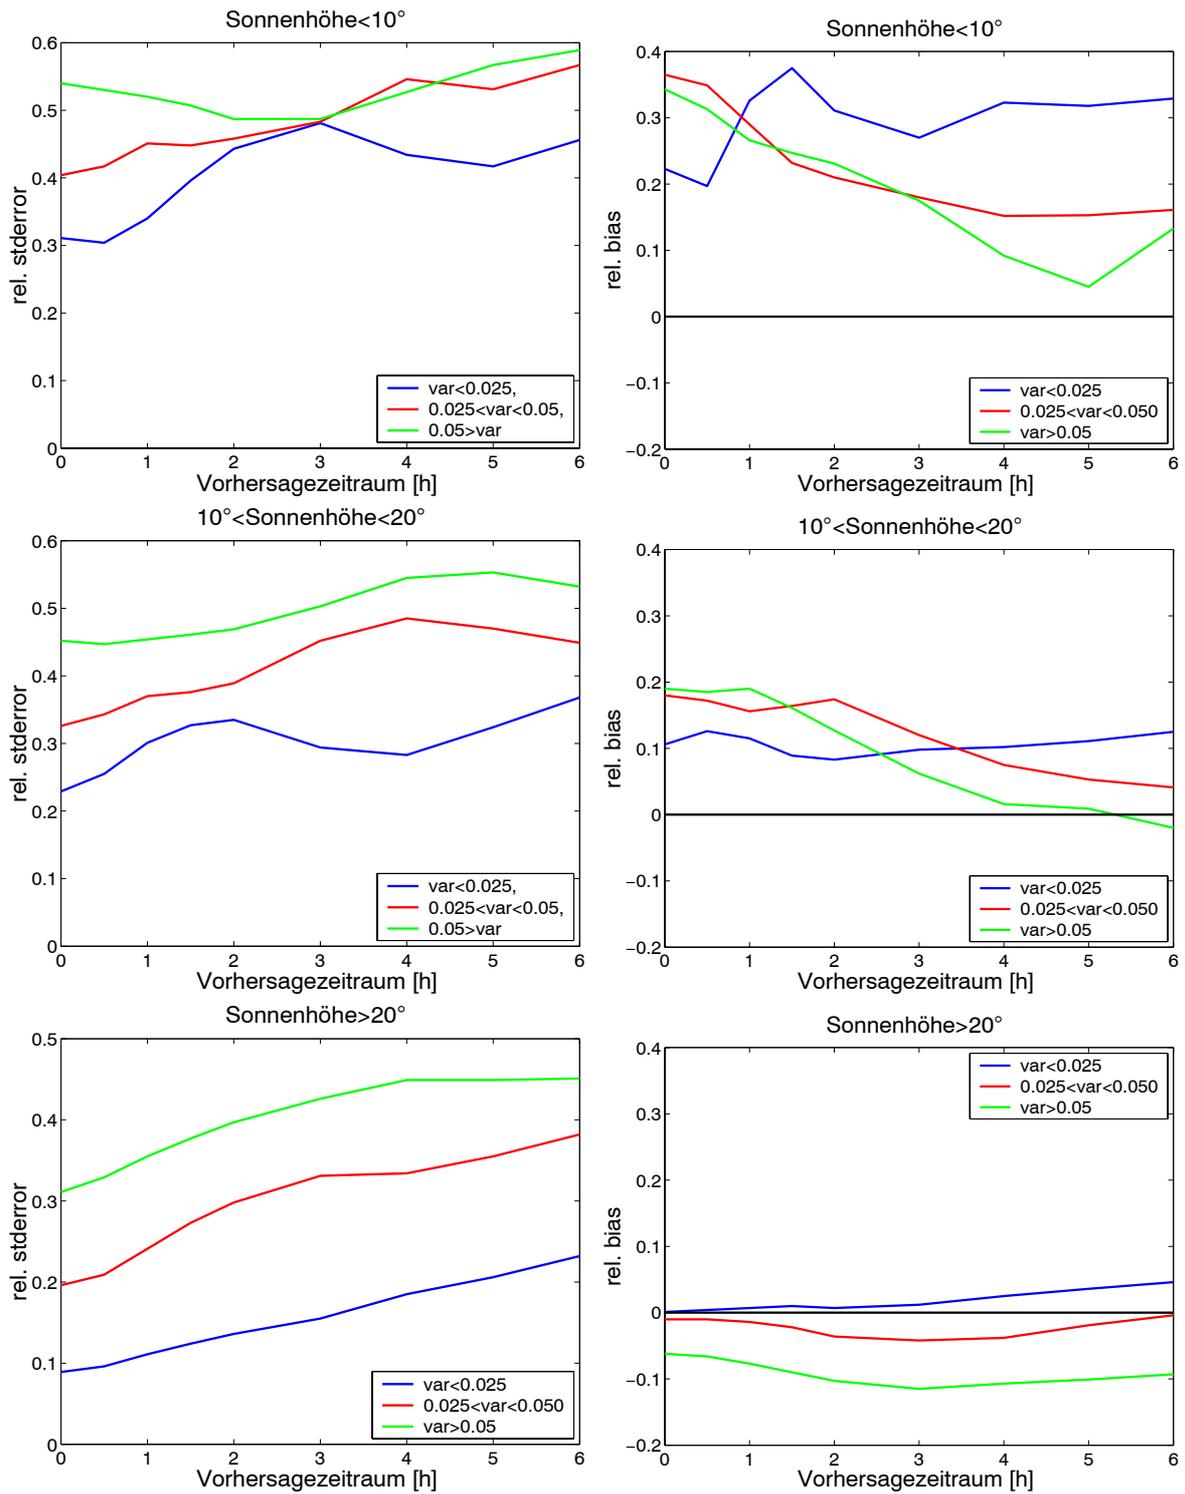


Abbildung 5.15: *stderror* (linke Spalte) und *bias* (rechte Spalte) in Abhängigkeit vom Vorhersagezeitraum. Überblick über alle Situationen: Für die 3 Sonnenstandsklassen $\alpha < 10^\circ$ (oben), $10^\circ < \alpha < 20^\circ$ (Mitte) und $\alpha > 20^\circ$ (unten) wird jeweils zwischen $var < 0.025$, $0.025 < var < 0.05$ und $var > 0.05$ unterschieden.

Vorhersagefehler im Vergleich zur Persistenz

Zur Bewertung der Vorhersagequalität wurden die Vorhersagefehler mit Persistenz von k^* -Werten aus Satellitendaten und Persistenz von k^* -Werten aus Bodendaten verglichen. Der Vergleich der Vorhersagefehler erfolgt am Beispiel der Sonnenstände $\alpha > 20^\circ$ für die beiden niedrigen Variabilitätsklassen und der Sonnenstände $\alpha < 10^\circ$ für $0.025 < var < 0.05$. Für diese Fälle ist in Abb. 5.16 in der linken Spalte der *stderror* und in der rechten Spalte die (*1-korr*) über dem Vorhersagezeitraum aufgetragen. Eine vollständige Übersicht über alle Situationen ist im Anhang gegeben (Abb. 7.1, Abb. 7.2).

Der Vergleich der Korrelation von Vorhersage und Persistenz aus Satellitendaten mit der Meßzeitreihe zeigt, daß durch die Vorhersage für alle Vorhersagezeiträume eine deutlich höhere Korrelation mit der Meßzeitreihe erreicht wird. In Bezug auf den Vergleich mit der Persistenz von Bodendaten sind verschiedene Situationen zu unterscheiden. Für sehr kurze Vorhersagezeiträume ergibt sich für die Bodenpersistenz eine bessere Korrelation mit den vorherzusagenden Werten als für die Satellitenvorhersage. Dies ist durch den hohen Anteil des Fehlers durch Berechnung von k^* -Werten aus Satellitendaten bedingt. Die Korrelation von Bodenpersistenz und Meßzeitreihe nimmt mit steigenden Vorhersagezeiträumen jedoch deutlich schneller ab als die entsprechende Korrelation für Vorhersage und Persistenz auf der Basis von Satellitendaten. Je nach Sonnenstand und Variabilität ergibt sich so ab einem bestimmten Vorhersagezeitraum eine höhere Korrelation zwischen Vorhersage bzw. Persistenz von Satellitendaten mit der Meßzeitreihe als für Bodenpersistenz. Für Sonnenstände $\alpha > 20^\circ$ sind die Satellitenverfahren für Vorhersagezeiträume größer als eine Stunde der Persistenz von Bodendaten deutlich überlegen, wobei der Unterschied mit steigendem Vorhersagezeitraum zunimmt. Die höhere Genauigkeit der Persistenz von Satellitendaten gegenüber Persistenz von Bodendaten für die entsprechenden Vorhersagezeiträume ist auf die in den Satellitenbildern enthaltenen räumlichen Informationen und den Glättungseffekt zurückzuführen.

Die Darstellung des *stderror* für Vorhersagefehler, Persistenz von k^* -Werten aus Satellitendaten und Persistenz von k^* -Werten aus Bodendaten in Abb. 5.16 ist durch die mit MOS minimal erreichbaren Fehler und die Standardabweichung der Bodenzeitreihe ergänzt. Es werden folgende Punkte deutlich:

- Der *stderror* der Vorhersage liegt nicht nur für die Heliosat-Methode, sondern auch für die Vorhersage durch Glättung sehr nah am mit MOS erreichbaren Optimum. Daraus folgt mit den entsprechenden Kurven für die Korrelation, daß für die Vorhersage der *stderror* für alle Vorhersagezeiträume deutlich unter der Standardabweichung der Bodenzeitreihe liegt.
- Für Persistenz von Bodendaten, für die im Gegensatz zu den Satellitenverfahren keine Vorverarbeitung durch Glättung durchgeführt wurde, wird durch MOS eine deutliche Verbesserung erreicht.

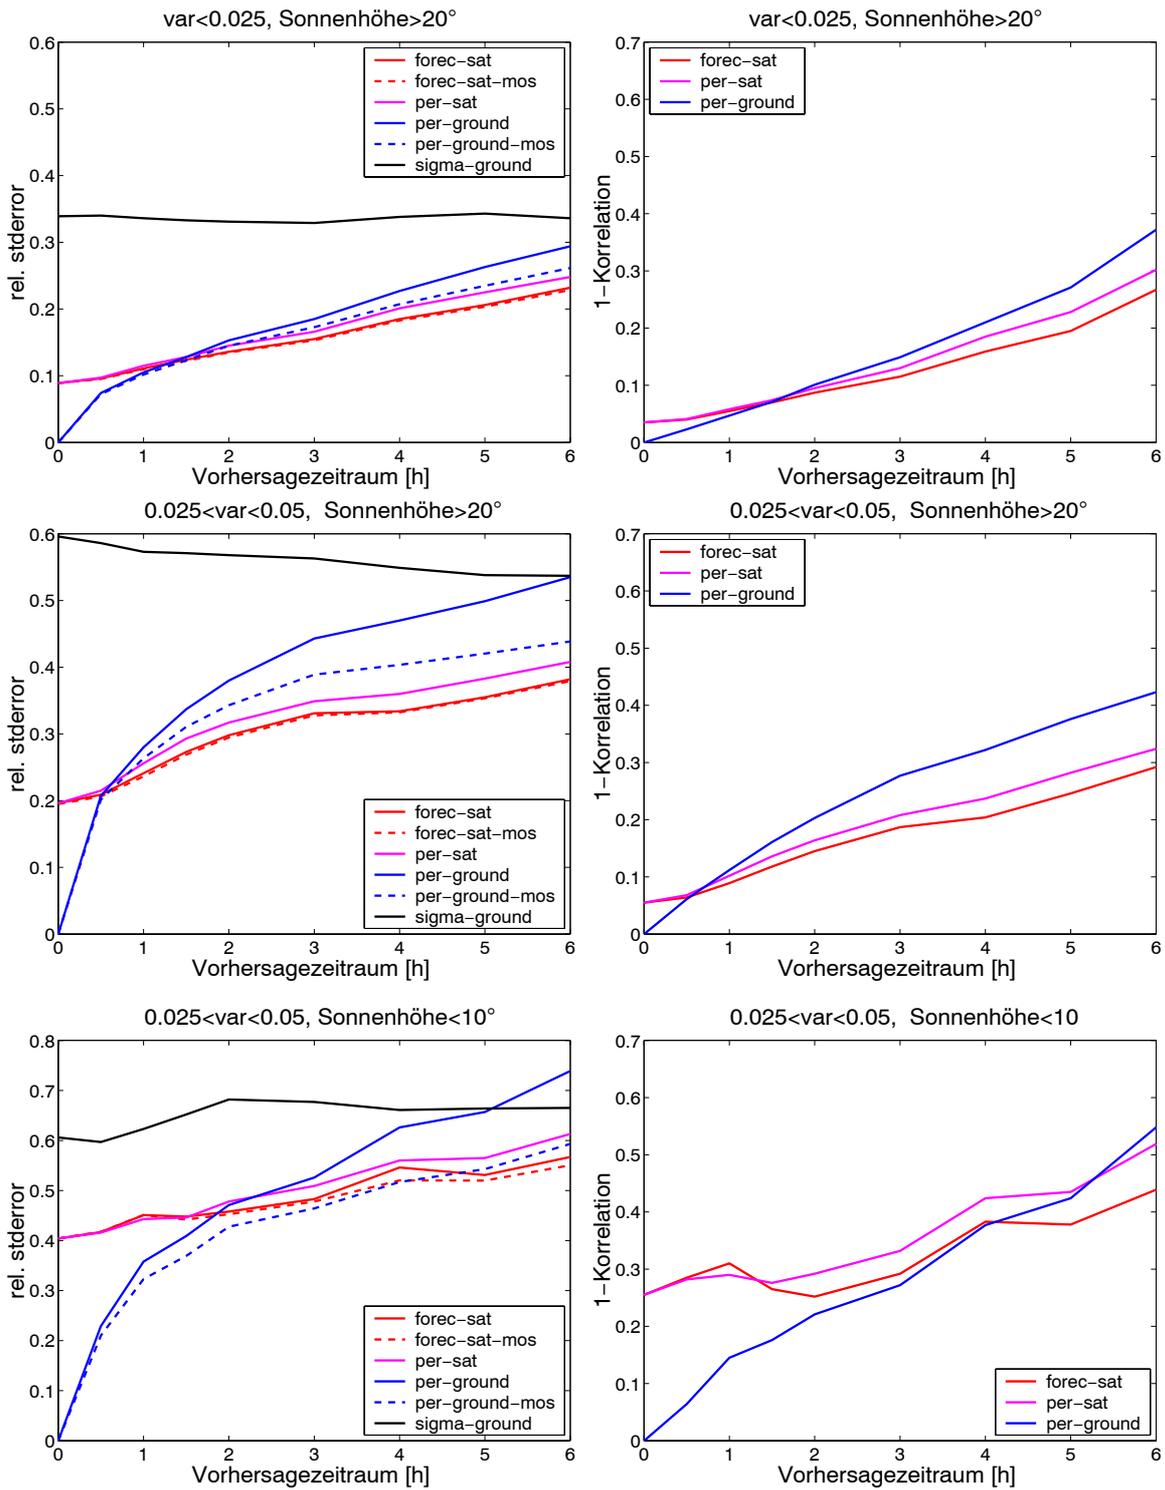


Abbildung 5.16: *stderror* (linke Spalte) und $(1-korr)$ (rechte Spalte) in Abhängigkeit vom Vorhersagezeitraum für Vorhersage, Persistenz von k^* -Werten aus Satellitendaten und aus Bodendaten für verschiedene Beispiele. Oben: Sonnenstände $\alpha > 20^\circ$ und $var < 0.025$, Mitte: Sonnenstände $\alpha > 20^\circ$ und $0.025 < var < 0.05$ und unten: Sonnenstände $\alpha < 10^\circ$ und $0.025 < var < 0.05$.

- Auch wenn anstelle der einfachen Persistenz von Bodendaten mit MOS optimierte Werte verwendet werden, führen die Satellitenverfahren ab einem Mindest-Vorhersagezeitraum zu einem geringeren *stderror*. Entsprechend den Korrelationskurven ist für Sonnenstände $\alpha > 20^\circ$ die Vorhersage ab dem Vorhersagezeitraum eine Stunde besser als Bodenpersistenz.
- Durch Verwendung des Vorhersagealgorithmus wird der *stderror* gegenüber Persistenz von Satellitenwerten im Mittel um etwa 10% reduziert. Die Verringerung des Vorhersagefehlers ist kleiner als bei der Vorhersage von Bewölkungsbildern, da ein großer Anteil des Fehlers durch den Fehler der Heliosat-Methode bedingt ist.

Zusammenfassung und Ausblick

Im Folgenden sind die wichtigsten Punkte der Auswertung der Solarstrahlungsvorhersage für einen Einzelstandort zusammengefaßt.

Für Vorhersagezeiträume bis zu 6 Stunden ergeben sich für $\alpha > 10^\circ$ gute Vorhersageergebnisse bezüglich folgender Kriterien:

- Durch Verwendung des Vorhersagealgorithmus wird die Vorhersagequalität gegenüber Persistenz von Satellitendaten erhöht.
- Die Vorhersage der Einstrahlung unter Verwendung von Satellitendaten ist genauer als Persistenz von Bodendaten. Dies gilt für Vorhersagezeiträume größer als eine Stunde ($\alpha > 20^\circ$) bzw. 2 Stunden ($10^\circ < \alpha < 20^\circ$).
- Die Korrelation zwischen Vorhersage und Meßreihe liegt deutlich über 0.5. Entsprechend liegt der *stderror* deutlich unter der Standardabweichung der Meßreihe, die eine Obergrenze für den *stderror* darstellt.

Für Sonnenstände $\alpha > 20^\circ$ liegt der *stderror* je nach Variabilität zwischen 10% und 40% für 30 Minuten Vorhersage und steigt auf Fehler zwischen 20% und 50% für 6 Stunden an. Die Vorhersagequalität ist dabei in hohem Maß durch die Umrechnung von Satellitendaten in Bodeneinstrahlung bestimmt. Eine Verbesserung der Einstrahlungsbestimmung aus Satellitendaten, wie sie z.B. durch das neue Verfahren für die folgende Wetter-Satellitengeneration MSG erwartet wird (siehe [Müller et al. 2002], [Müller et al. 2003]), wird so auch zu einer deutlichen Verbesserung der Einstrahlungsvorhersage führen.

Durch Unterscheidung nach Variabilität und Sonnenstand lassen sich Situationen verschiedener Vorhersagequalität voneinander trennen. Dabei können hohe Einstrahlungswerte mit größerer Genauigkeit vorhergesagt werden als niedrige Einstrahlungswerte, was für viele Anwendungen günstig ist.

5.4 Fehleranalyse für eine Region

Nach der Auswertung der Fehler für einen einzelnen Standort wird die Einstrahlungsvorhersage nun regional ausgewertet. Die Einstrahlung für ein Gebiet wird dabei als Mittelwert mehrerer über eine Region verteilter Stationen berechnet. Die Analyse wird am Beispiel der in Abschnitt 5.1 beschriebenen Datenbasis aus Saarbrücken durchgeführt, wobei alle zur Verfügung stehenden Stationen in die Auswertung einbezogen wurden. Vorhersagefehler für regionale Vorhersage hängen zum einen von der Größe des Mittelungsgebiets und zum anderen von der Anzahl und Lage der über dieses Gebiet verteilten Stationen ab. Mit der hier durchgeführten Auswertung für eine bestimmte Konfiguration von Meßstationen kann qualitativ dargestellt werden, wie sich die Vorhersagefehler bei Mittelung über eine Region verändern.

Wie für Einzelstandorte, so ist auch für die regionale Vorhersage die Glättung der Cloud-Index Bilder ein wichtiger Faktor zur Reduzierung der Vorhersagefehler. Die optimalen Glättungsparameter entsprechen den in Tabelle 5.2 bestimmten Glättungsparametern für eine Einzelstation.

Die Fehleranalyse baut auf der Auswertung für Einzelstandorte auf, entsprechend wird insbesondere auf Änderungen der Vorhersagequalität durch Mittelung über mehrere Stationen eingegangen. Es erfolgt als erster Schritt wieder die Analyse des Fehlers der Heliosat-Methode, bevor abschließend die Entwicklung der Vorhersagefehler mit dem Vorhersagezeitraum untersucht wird.

5.4.1 Regionale Fehleranalyse der Heliosat-Methode

Zur Auswertung der Berechnung der Einstrahlung für ein Gebiet werden im Folgenden *stderror* und *(1-korr)* zweidimensional analysiert. Der *bias* für die regionale Auswertung entspricht aufgrund der gleichen Datengrundlage dem *bias* für Einzelstandorte.

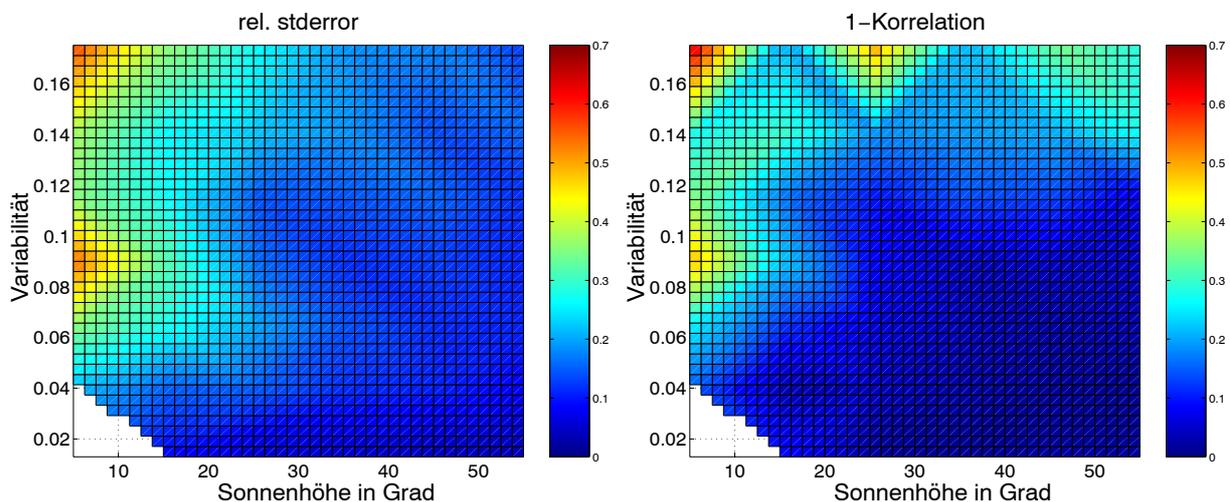


Abbildung 5.17: *stderror* (links) und *(1-korr)* (rechts) in Abhängigkeit von Sonnenstand und Variabilität für regionale Vorhersage. Die Fehlermaße sind durch die Farbskala charakterisiert.

In Abb. 5.17 sind *stderror* und $(1-korr)$ in Abhängigkeit von Sonnenstand und Variabilität aufgetragen. Es wird deutlich, daß im Vergleich zu Einzelstandorten die Fehler insgesamt signifikant niedriger liegen (siehe Abbildungen 5.4 und 5.8 mit gleicher Farbskala). Weiterhin fällt auf, daß für den *stderror* der Einfluß des Sonnenstandes dominiert. Die Variabilität hat einen wesentlich geringeren Einfluß auf die Fehler als bei Einzelstandorten. Dies ist am Beispiel der Sonnenstände $30^\circ < \alpha < 40^\circ$ in Abb. 5.18 für $(1-korr)$ und *stderror* verdeutlicht. Bei Situationen mit durchbrochener Bewölkung wird die Strahlung in der betrachteten Region zufällig teilweise über- und teilweise unterschätzt. Die Mittelung über mehrere Werte reduziert diesen Fehler somit. Da dieser Effekt durch die Inhomogenität der Wolkensituation bedingt ist, verstärkt er sich mit steigender Variabilität. Der *stderror* wird für Sonnenstände $\alpha > 20^\circ$ so auch für hohe Variabilitäten auf unter 30% reduziert, für $\alpha > 30^\circ$ bleibt der *stderror* unter 20%. Trotzdem bleibt für diese Sonnenhöhen die Abhängigkeit der Fehler von der Variabilität klar erkennbar.

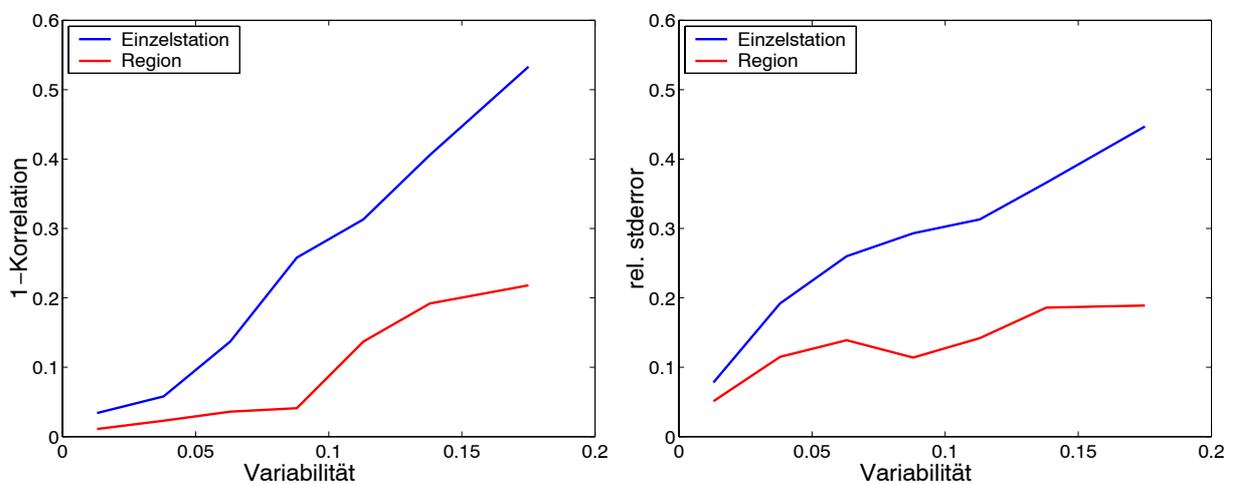


Abbildung 5.18: *stderror* (links) und $(1-korr)$ (rechts) in Abhängigkeit von der Variabilität am Beispiel der Sonnenstände $30^\circ < \alpha < 40^\circ$, Vorhersage für Einzelstandorte und ein Gebiet im Vergleich.

Die hohen Fehler für niedrige Sonnenstände werden durch Mittelung nicht in gleichem Maß reduziert wie die Fehler für hohe Variabilität (siehe Abb. 5.17). Die gemessenen Werte für k^* weichen für die gesamte betrachtete Region tendenziell in die gleiche Richtung von den berechneten Werten ab. Dies ist möglicherweise durch für den jeweiligen Zeitpunkt nicht optimal angepasste Trübungsparameter bedingt. Fehler im Trübungsparameter wirken sich besonders für niedrigen Sonnenstand stark aus und führen für das gesamte betrachtete Gebiet, für das im Wesentlichen eine konstante Trübung angenommen werden kann, jeweils zur Über- oder Unterschätzung der Einstrahlung. Da für niedrige Sonnenhöhen $\alpha < 20^\circ$ so die Abhängigkeit des *stderror* vom Sonnenstand deutlich stärker ausgeprägt ist als die Abhängigkeit von der Variabilität, werden für die folgenden Auswertungen für Sonnenstände $\alpha < 10^\circ$ und $10^\circ < \alpha < 20^\circ$ jeweils alle Variabilitäten zusammengefaßt.

5.4.2 Fehleranalyse der Vorhersage

Im Anschluß an die regionale Auswertung der Heliosat-Methode wird in diesem Abschnitt die Entwicklung der regionalen Vorhersagegenauigkeit mit dem Vorhersagezeitraum untersucht und mit Persistenz von aus Satellitendaten und Bodendaten berechneten k^* -Werten verglichen. Zur übersichtlichen Darstellung wurde, entsprechend den Ergebnissen aus Abschnitt 5.4.1 und Abschnitt 5.3.3, die zweidimensionale Fehleranalyse der Vorhersage auf die Unterscheidung von 5 Klassen reduziert. So wurde für niedrige Sonnenstände $\alpha < 10^\circ$ und $10^\circ < \alpha < 20^\circ$ nicht nach Variabilität klassifiziert, während für $\alpha > 20^\circ$ alle Sonnenstände zusammengefaßt und 3 Variabilitätsklassen ($0.025 > var$, $0.025 < var < 0.05$, $var > 0.05$) unterschieden wurden.

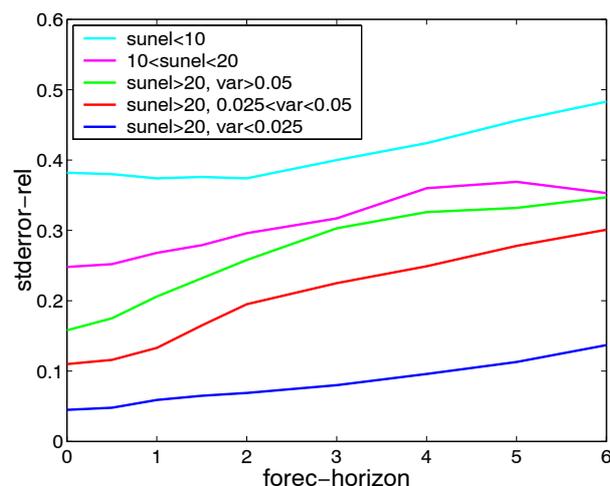


Abbildung 5.19: *stderror* in Abhängigkeit vom Vorhersagezeitraum, Überblick über alle Situationen für regionale Vorhersage.

In Abb. 5.19 ist für die beschriebenen Klassen zur Charakterisierung der Vorhersagequalität der *stderror* in Abhängigkeit vom Vorhersagezeitraum dargestellt. Die wesentlichen Ergebnisse dieser Darstellung sind im Folgenden zusammengefaßt:

- Der Fehler der Heliosat-Methode, gegeben durch den Fehler zum Vorhersagezeitraum Null Stunden, trägt einen großen Teil zum Gesamtfehler bei.
- Für Sonnenstände $\alpha < 10^\circ$ liegen die Fehler auch für die regionale Vorhersage sehr hoch, die Fehler sind nur wenig kleiner als die Fehler für eine Einzelstation (vgl. Abb. 5.15). Der *stderror* steigt mit dem Vorhersagezeitraum etwas an (40% für Heliosat-Methode bis zu ca. 50% für die 6 Stunden Vorhersage).
- Die Vorhersageergebnisse werden mit steigendem Sonnenstand bis zu $\alpha > 20^\circ$ deutlich besser. Dies entspricht sowohl den Ergebnissen der regionalen Analyse der Heliosat-Methode im vorangehenden Abschnitt, als auch den Vorhersageergebnissen für eine Einzelstation.

- Für Sonnenstände $\alpha > 20^\circ$ lassen sich die Ergebnisse für die 3 Variabilitätsklassen deutlich unterscheiden. Ein Vergleich mit Abb. 5.15 zeigt, daß gegenüber der Vorhersage für eine Einzelstation der *stderror* für alle Vorhersagezeiträume deutlich reduziert ist. So steigt der Fehler für die niedrigste Variabilitätsklasse von 5% der Heliosat-Methode auf ca. 15% für 6 Stunden Vorhersage an, im Vergleich zu 10% bis 25% für eine Einzelstation. Für $0.025 < var < 0.05$ erhöht sich der *stderror* mit steigendem Vorhersagezeitraum für regionale Vorhersage von 11% auf 30% gegenüber 20% bis 38% für einen Einzelstandort. Für Variabilität $var > 0.05$ liegen die regionalen Fehler zwischen ca. 15% für die Heliosat-Methode und ca. 35% für 6 Stunden Vorhersage, während für Einzelstandorte der *stderror* zwischen ca 30% und 45% liegt.

Neben der Betrachtung der prozentualen Fehler und dem Vergleich zu Einzelstandorten ist der Vergleich mit Persistenz ein weiteres wichtiges Kriterium zur Beurteilung der Vorhersagequalität. Dabei wurde zum einen wieder Persistenz von k^* -Werten aus Satellitenbildern betrachtet. Für Bodenpersistenz wurden 2 Ansätze unterschieden. Persistenz des Mittelwerts aller Stationen nutzt alle verfügbaren Informationen aus dem gegebenen Bodendatensatz. In der Realität steht ein so dichtes Meßnetz meist nicht zur Verfügung, weshalb auch Persistenz einer einzelnen Station zum Vergleich miteinbezogen wurde. Da Station 1 etwa in der Mitte des betrachteten Gebiets liegt (siehe Abb. 5.1), wurden die Meßwerte dieser Station zur Abschätzung der Einstrahlung der Region verwendet.

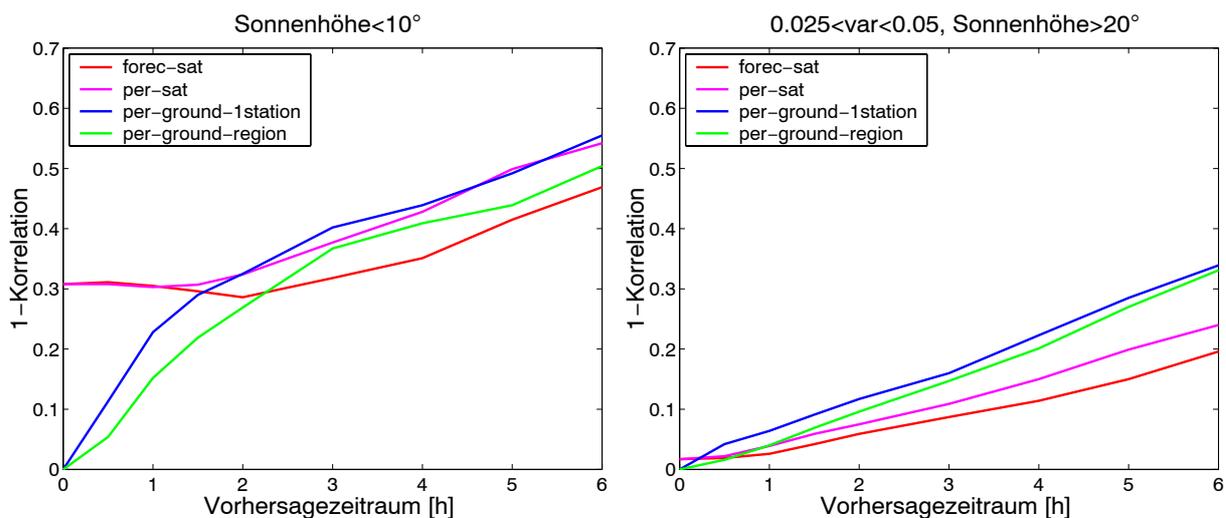


Abbildung 5.20: (*1-korr*) in Abhängigkeit vom Vorhersagezeitraum für Vorhersage, Persistenz von k^* -Werten aus Satellitendaten und aus Bodendaten für Sonnenstände $\alpha < 10^\circ$ (links) und $\alpha > 20^\circ$ und $0.025 < var < 0.05$ (rechts).

Der Vergleich der Vorhersage mit Persistenz wurde für (*1-korr*) durchgeführt. In Abb. 5.20 sind die Vorhersagefehler und die Fehler für die verschiedenen Ansätze von Persistenz am Beispiel von $\alpha < 10^\circ$ und $\alpha > 20^\circ$, $0.025 < var < 0.05$ über dem Vorhersagezeitraum aufgetragen. Die

Darstellung für die anderen Klassen ist im Anhang gegeben (Abb. 7.3). Die Ergebnisse entsprechen in wesentlichen Punkten der Auswertung für Einzelstandorte:

- Für alle Situationen ist die Vorhersage immer besser als die Persistenz aus Satellitendaten.
- Im Vergleich zur Bodenpersistenz gibt es einen Mindest-Vorhersagezeitraum, oberhalb dessen Vorhersage besser als Bodenpersistenz wird. Dies gilt sowohl für Persistenz einer Einzelstation als auch für Persistenz des gesamten Ensembles an Bodenstationen. Dabei ist für alle Situationen, wie zu erwarten, die Bodenpersistenz des regionalen Ensembles besser als die Bodenpersistenz einer Einzelstation, da mehr räumliche Information gegeben ist.
- Für Sonnenstände $\alpha < 10^\circ$ ist die Vorhersage auch für höhere Vorhersagezeiträume (>2 Stunden) nur wenig besser als Persistenz des Mittelwertes über alle Stationen. Für kürzere Vorhersagezeiträume führt Persistenz von Bodendaten zu klar besseren Ergebnissen.
- Für Sonnenstände $\alpha > 20^\circ$ sind Vorhersage und Persistenz von Satellitenbildern schon ab 30 Minuten besser als Persistenz einer einzelnen Bodenstation und ab einer Stunde besser als Persistenz eines Ensembles von Bodenstationen. Für höhere Vorhersagezeiträume ist die Überlegenheit der Vorhersage gegenüber Persistenz von Bodendaten sehr deutlich.

Zusammenfassung

Zusammenfassend läßt sich für die regionale Vorhersage feststellen, daß durch Mittelung die Fehler gegenüber der Vorhersage für Einzelstandorte insgesamt signifikant verringert sind. Wie bei der punktuellen Vorhersage können durch Klassifikation nach Sonnenstand und Variabilität Situationen unterschiedlicher Genauigkeit unterschieden werden, wobei auch hier die Vorhersage für hohe Einstrahlungen eine größere Genauigkeit hat. Für sehr niedrige Sonnenstände entsprechen die relativen Fehler bei regionaler Mittelung in etwa den Fehlern für Einzelstandorte. Dagegen nimmt die Genauigkeit der Vorhersage für Sonnenstände $\alpha > 10^\circ$ insbesondere bei hoher Variabilität deutlich zu. Ein hoher Anteil des Fehlers ist, wie für Einzelstandorte, auch bei der regionalen Vorhersage durch die Umrechnung von Satellitendaten in Bodenwerte bedingt. Entsprechend wird auch hier eine Verbesserung der Einstrahlungsbestimmung aus Satellitendaten die Vorhersagequalität erhöhen.

Kapitel 6

Zusammenfassung und Ausblick

Ziel dieser Arbeit war die Entwicklung eines Verfahrens zur Kurzzeitvorhersage der Solarstrahlung für die Anwendung im Solarenergiebereich.

Die Berechnung der Strahlungsvorhersage beruht auf einer Vorhersage der Bewölkungsentwicklung in Satellitenbildern. Aus den vorhergesagten Bewölkungssituationen wurde mit dem Heliosat-Verfahren eine Vorhersage der Solarstrahlung am Boden abgeleitet. Zur Beschreibung der Wolkenentwicklung in Satellitenbildern wurden zwei verschiedene Ansätze untersucht.

Es wurde ein Verfahren unter Verwendung von Neuronalen Netzen und Hauptkomponenten-Transformation entwickelt. Die Auswertung für dieses Verfahren hat gezeigt, daß Feed-Forward-Netze keine geeignete Methode zur Beschreibung der Bewölkungsentwicklung darstellen. Die Vorhersageergebnisse dieser Methode sind nur wenig besser als die, bezüglich der Glättung der Bilder optimierte, Persistenz.

Zur Beschreibung der Wolkenentwicklung in Satellitenbildern über die Bestimmung von Bewegungsvektorfeldern wurden eine statistische Methode und eine Methode, die auf der Minimierung mittlerer quadratischer Pixeldifferenzen beruht, untersucht. Die Ergebnisse für die beiden Verfahren sind gleichwertig und dem Verfahren mit Neuronalen Netzen und der Persistenz deutlich überlegen. Durch die verwendeten Methoden werden die Bewegung und die Veränderung klar definierter Wolkenstrukturen erfaßt. Dagegen sind Situationen mit stark inhomogener Bewölkung nur schwer vorhersagbar. Eine wesentliche Verbesserung der Vorhersagequalität wird durch eine an den Vorhersagezeitraum angepaßte Glättung der Vorhersagebilder erzielt.

Da über die Bestimmung von Bewegungsvektorfeldern die Wolkenentwicklung deutlich besser vorhergesagt werden konnte, wurde dieses Verfahren zur Vorhersage der Bodeneinstrahlung eingesetzt. Mit dieser Methode werden für die Vorhersage der Solarstrahlung am Boden für Vorhersagezeiträume bis zu 6 Stunden insgesamt gute Ergebnisse erzielt. Die Vorhersage auf der Basis von Satellitendaten ist für die meisten Situationen schon ab Vorhersagezeiträumen von einer Stunde wesentlich genauer als die Persistenz von Bodendaten.

Eine detaillierte Genauigkeitsanalyse der Strahlungsvorhersage ergab, daß Klassen unterschiedlicher Vorhersagegenauigkeit durch die Variabilität der Satellitenbilder und den Sonnenstand charakterisiert werden können. Dabei steigt die Vorhersagegenauigkeit mit der Sonnehöhe und nimmt

mit zunehmender Variabilität ab. Für sehr niedrigen Sonnenstand kann die Einstrahlung für alle betrachteten Vorhersagezeiträume nur mit hohem relativen Fehler von über 40% vorhergesagt werden. Für die Klasse mit der höchsten Vorhersagegenauigkeit, die mit hohen Einstrahlungen verbunden ist, beträgt der mittlere relative Vorhersagefehler für den Vorhersagezeitraum 30 Minuten 10% und steigt auf 25% für den Vorhersagezeitraum 6 Stunden an. Für regionale Vorhersagen werden die Fehler durch Mittelungseffekte deutlich reduziert.

Das entwickelte Verfahren zur Solarstrahlungsvorhersage ist bezüglich der Genauigkeitsanforderungen für die Anwendung im Solarenergiebereich geeignet, insbesondere können Situationen mit hoher Einstrahlung mit großer Genauigkeit vorhergesagt werden.

Im Folgenden wird kurz auf Verbesserungsansätze und eine Erweiterung der Solarstrahlungsvorhersage für längere Vorhersagezeiträume eingegangen:

Für den betrachteten Kurzzeitbereich läßt sich über die Bestimmung von Bewegungsvektoren die Entwicklung der Bewölkungssituation gut beschreiben. Eine Erhöhung der Qualität der Solarstrahlungsvorhersage kann vor allem durch eine verbesserte Einstrahlungsbestimmung aus Satellitendaten erreicht werden, da die Vorhersagefehler maßgeblich durch die Umrechnung der Satellitendaten in Bodenwerte bestimmt sind. Mit der Einführung der neuen Satelliten-Generation MSG werden in naher Zukunft genauere Verfahren zur Einstrahlungsbestimmung zur Verfügung stehen.

Das hier entwickelte Vorhersageverfahren ist auf die Anwendung für Vorhersagezeiträume von wenigen Stunden begrenzt. Die zugrunde liegenden Annahmen, daß Geschwindigkeitsänderungen und thermische Prozesse, die Entstehung und Auflösung von Bewölkung beeinflussen, vernachlässigbar sind, gelten in guter Näherung nur für kurze Zeiträume. Für längere Vorhersagezeiträume muß die Veränderung des Zustands der Atmosphäre durch ein numerisches Wettermodell berücksichtigt werden. Dies kann z.B. durch die Anpassung eines regionalen Wettermodells an die speziellen Anforderungen der Solarstrahlungsvorhersage realisiert werden.

Kapitel 7

Anhang

Der Anhang beinhaltet Abbildungen zur Vervollständigung der Übersicht über die Vorhersagefehler in Abhängigkeit vom Vorhersagezeitraum für die verschiedenen Sonnenstands- und Variabilitätsklassen.

7.1 Korrelation der Vorhersage mit Bodenmeßwerten im Vergleich zur Persistenz für einzelne Standorte

In den Abbildungen 7.1 und 7.2 wird ein Überblick über *stderror* und (*1-korr*) in Abhängigkeit vom Vorhersagezeitraum für Vorhersage, Persistenz von k^* -Werten aus Satellitendaten und aus Bodendaten für die verschiedenen Sonnenstands- und Variabilitätsklassen gegeben. Es werden alle Beispiele gezeigt, die nicht in Abschnitt 5.3.3 dargestellt wurden.

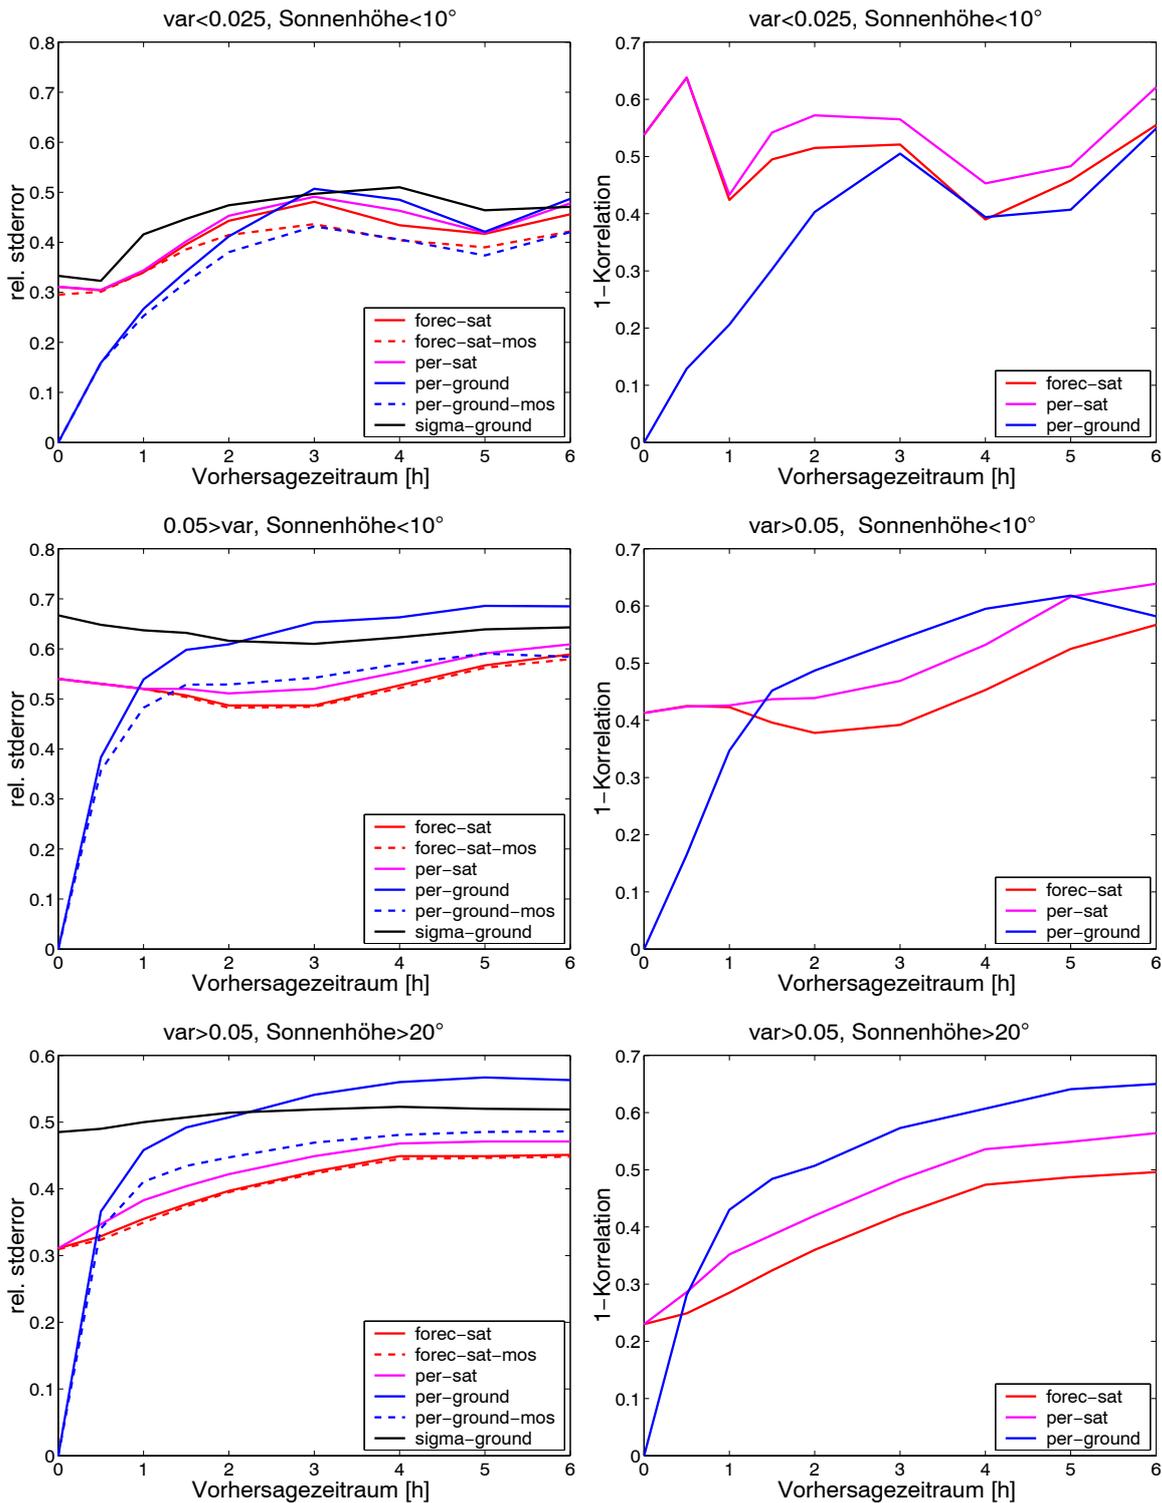


Abbildung 7.1: *stderror* (linke Spalte) und *(1-korr)* (rechte Spalte) in Abhängigkeit vom Vorhersagezeitraum für Vorhersage, Persistenz von k^* -Werten aus Satellitendaten und aus Bodendaten. Oben: Sonnenstände $\alpha < 10^\circ$ und $\text{var} < 0.025$, Mitte: Sonnenstände $\alpha < 10^\circ$ und $\text{var} > 0.05$ und unten: Sonnenstände $\alpha > 20^\circ$ und $\text{var} > 0.05$.

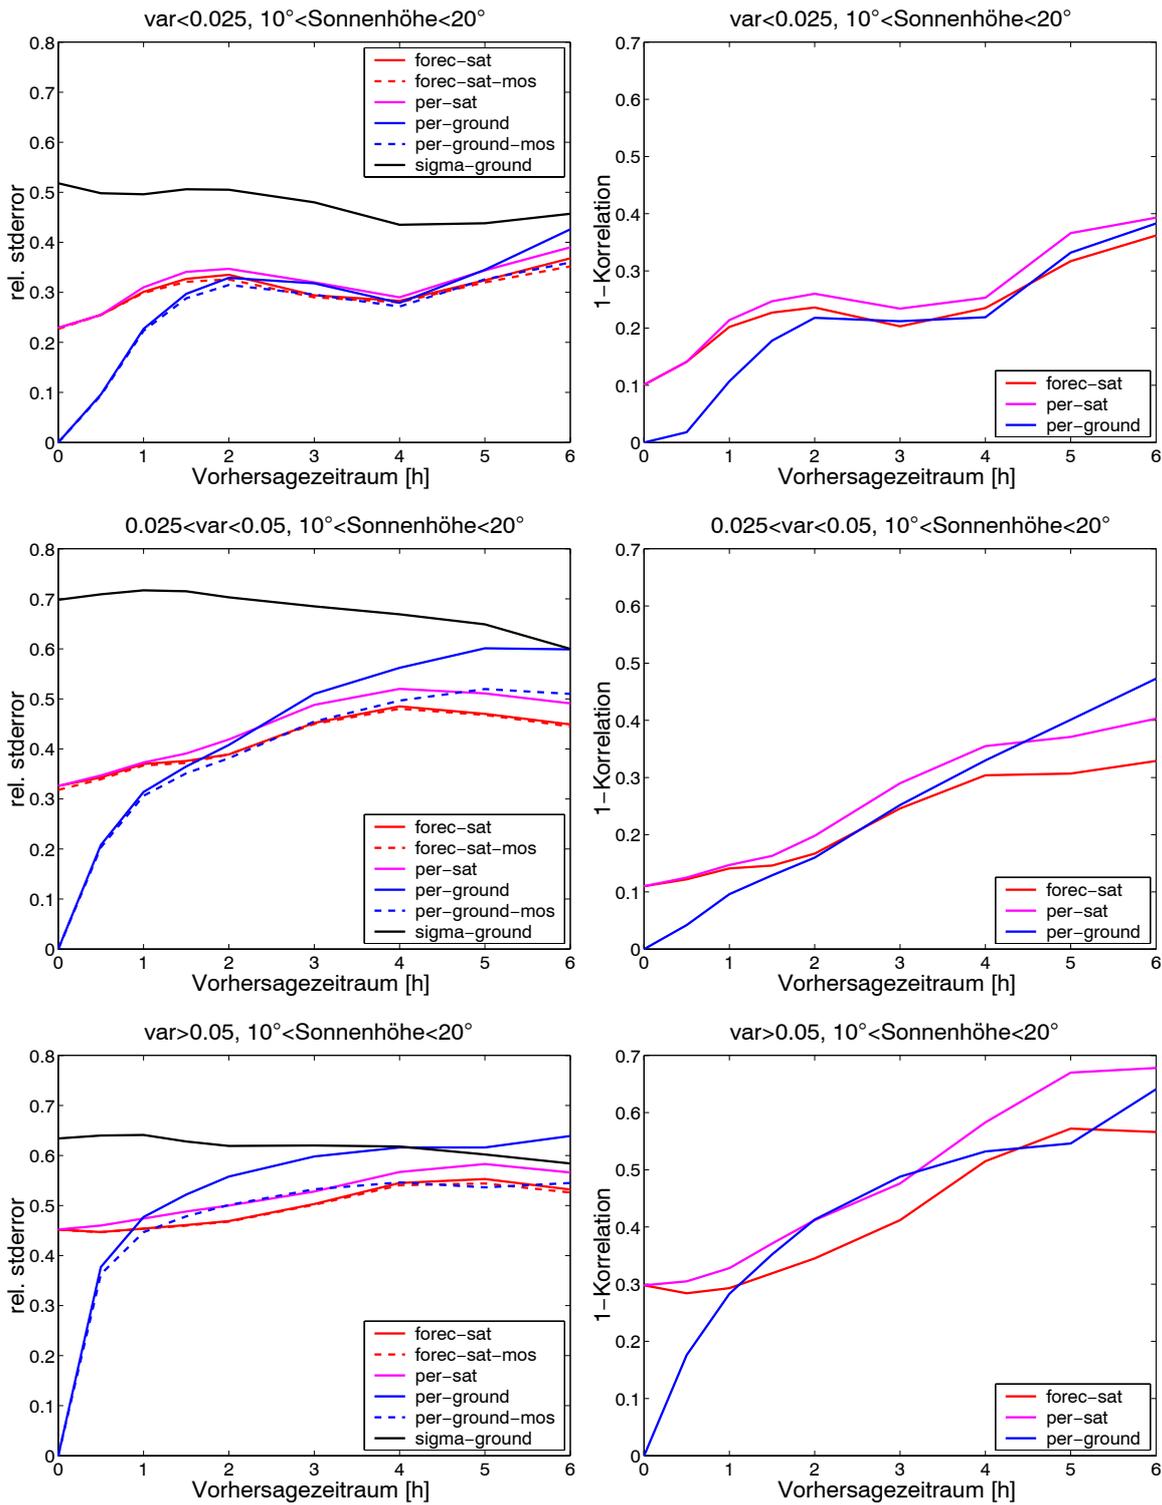


Abbildung 7.2: *stderror* (linke Spalte) und *(1-korr)* (rechte Spalte) in Abhängigkeit vom Vorhersagezeitraum für Vorhersage, Persistenz von k^* -Werten aus Satellitendaten und aus Bodendaten. Oben: Sonnenstände $10^\circ < \alpha < 20^\circ$ und $\text{var} < 0.025$, Mitte: Sonnenstände $10^\circ < \alpha < 20^\circ$ und $0.025 < \text{var} < 0.05$ und unten: Sonnenstände $10^\circ < \alpha < 20^\circ$ und $\text{var} > 0.05$.

7.2 Korrelation der Vorhersage mit Bodenmeßwerten im Vergleich zur Persistenz für regionale Vorhersagen

In Abbildung 7.3 wird ($1-korr$) in Abhängigkeit vom Vorhersagezeitraum für Vorhersage, Persistenz von k^* -Werten aus Satellitendaten und aus Bodendaten für die verschiedenen Sonnenstands- und Variabilitätsklassen für regionale Vorhersage gegeben. Es werden alle Beispiele gezeigt, die nicht in Abschnitt 5.4.2 dargestellt wurden.

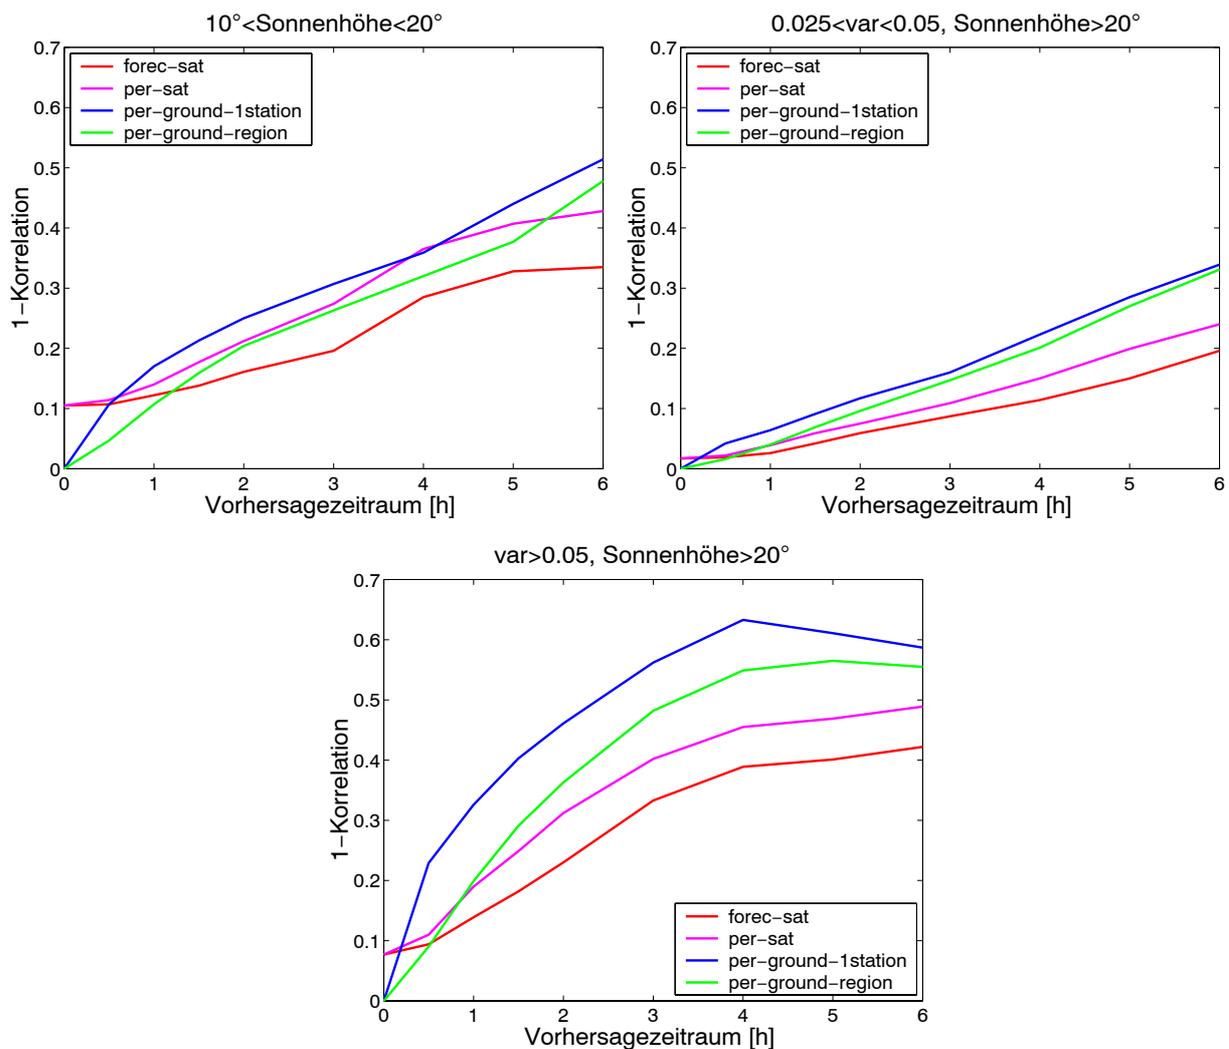


Abbildung 7.3: ($1-korr$) in Abhängigkeit vom Vorhersagezeitraum für Vorhersage, Persistenz von k^* -Werten aus Satellitendaten und aus Bodendaten. Links oben: Sonnenstände $10^\circ < \alpha < 20^\circ$, rechts oben: Sonnenstände $\alpha > 20^\circ$ und $0.025 < \text{var} < 0.05$ und unten: Sonnenstände $\alpha > 20^\circ$ und $\text{var} > 0.05$.

Literaturverzeichnis

- [Adunka 2000] F. Adunka, *Meßunsicherheiten*. Vulkan-Verlag Essen, 2000
- [Bahner et al. 1996] L. Bahner, M. Rohn, G. Warnecke, *A functional analytic method to derive displacement vector fields from satellite image sequences*. Int. J. Remote Sensing **17**, pp 383–392, 1996
- [Beyer et al. 1994] H. G. Beyer, C. Costanzo, D. Heinemann, C. Reise, *Short range forecast of PV energy production using satellite image analysis*. Proceedings of 12th European Photovoltaic Solar Energy Conference, 11-15 April, Amsterdam, The Netherlands, pp 1718–1721, 1994
- [Beyer et al. 1996] H. G. Beyer, C. Costanzo, D. Heinemann, *Modifications of the Heliosat procedure for irradiance estimates from satellite data*. Solar Energy, **56**, pp 207–212, 1996
- [Bourges 1992] B. Bourges, *Yearly variations of the Linke turbidity factor*. In: Climatic Data Handbook of Europe, Dordrecht, pp 61–64. Kluwer Academic Publishers, 1992.
- [Cano et al. 1986] D. Cano, J. M. Monget, M. Albussion, H. Guillard, N. Regas, L. Wald, *A method for the determination of global solar radiation from meteorological satellite data*. Solar Energy **37**, pp 31–39, 1986
- [Chowdhury 1987] B. H. Chowdhury, *Irradiance Forecasting and Dispatching Central Station PhotoVoltaic Power Plants*. Ph. D. Thesis, Virginia Polytechnic Institute and State University, 1987
- [Costanzo 1995] C. Costanzo, *Bestimmung der solaren Einstrahlung am Boden aus Meteosat-Daten – Untersuchung und Erweiterung einer statistischen Methode*. Diplomarbeit, Fachbereich Physik, Carl von Ossietzky Universität, Oldenburg 1995.
- [Cote et al. 1995] S. Cote and A.R.L.A Tatnall, *Neural network based method for tracking features from satellite sensor images*. Int. J. Remote Sensing, **16**, pp 3695–3701, 1995
- [Dumortier 1995] D. Dumortier, *Modelling global and diffuse horizontal irradiances under cloudless skies with different turbidities*. Daylight II, JOU2-CT92-0144, Final Report Vol. 2, 1995
- [Dumortier 1998] D. Dumortier, *The Satellight model of turbidity variations in Europe*. Technical Report, 1998

- [Erker 1992] H. Erker, *Vorausschauende Regelung von Heizungsanlagen basierend auf einer lokalen Wettervorhersage*. Dissertation, Shaker Verlag GmbH, 1992
- [Eumetsat] Eumetsat, *Meteorological Archive and Retrieval Facility - User Handbook. Kap. 5: Data geolocation and geocoding*. Eumetsat, Darmstadt, 1999
- [Fontoynont et al. 1998] M. Fontoynont, *Satellite: A WWW server which provides high quality daylight and solar radiation data for Western and Central Europe*. 9th Conference on Satellite Meteorology and Oceanography, pp 434–437, Paris, 1998
- [Fukunaga 1972] K. Fukunaga, *Introduction to Statistical Pattern Recognition*. Acad. Press, New York, 1972
- [Hamil et al. 1993] T.M. Hamil and T. Nehrkorn, *A short-term cloud forecast scheme using cross correlation*. *Weather and Forecasting*, **8**, pp 401–411, 1993
- [Hammer et al. 1999] A. Hammer, D. Heinemann, E. Lorenz, B. Lückehe, *Short-term forecasting of solar radiation based on image analysis of meteosat data*. Proceedings of EUMETSAT Meteorological Satellite Data Users' Conference, pp 331–337, 1999
- [Hammer 2000] A. Hammer, *Anwendungsspezifische Solarstrahlungsinformationen aus Meteosat-Daten*. Dissertation, Fachbereich Physik, Carl von Ossietzky Universität, Oldenburg, 2000
- [Hammer et al. 1999] A. Hammer, D. Heinemann, A. Westerhellweg, *Daylight and solar irradiance data derived from satellite observations - The Satellite Project*. Proc. ISES Solar World Congress, Jerusalem, 1999
- [Hammer et al. 2000] A. Hammer, D. Heinemann, E. Lorenz, B. Lueckehe, *Short-term forecasting of solar radiation: a statistical approach using satellite data*. *Solar Energy*, **67**, pp 139–150, 2000
- [Hammer et al. 2001] A. Hammer, D. Heinemann, C. Hoyer, E. Lorenz, *Satellite based short-term forecasting of solar irradiance - comparison of methods and error analysis*. Proceedings of the 2001 EUMETSAT Meteorological Satellite Data Users' Conference pp 677–684, Antalya, 2001
- [Hausmann und Hoffmann 1995] J. Hausmann und M. Hoffmann, *Zeitreihenvorhersage und Steuerung autonomer Wind-Diesel-Systeme mit neuronalen Netzwerken*. Diplomarbeit, Fachbereich Physik, Carl von Ossietzky Universität, Oldenburg, 1995
- [Heinemann 1990] D. Heinemann, *Zur Steuerung regenerativer Energieversorgungssysteme unter Verwendung von Energiewettervorhersagen*. Dissertation, Fachbereich Physik, Carl von Ossietzky Universität, Oldenburg, 1990
- [Hou et al. 2000] D. Hou, E. Kalnay, K. K. Droegemeier, *Objective Verification of the SAMEX'98 Ensemble Forecast*. *Monthly Weather Review*, **129**, pp 73–91, 2000

- [Jähne 1989] B. Jähne, *Digitale Bildverarbeitung*. Springer-Verlag, Berlin, 1989
- [Jensenius 1989] J. Jensenius, *Insolation Forecasting in Solar Resources*. R. L. Hulstrom (Ed.) MIT Press, Cambridge, pp 335–349, 1989
- [Konrad et al. 1992] J. Konrad and E. Dubois, *Bayesian estimation of motion vector fields*. IEEE transactions on pattern analysis and machine intelligence, **14**, pp 910–927, 1992
- [Linke 1922] F. Linke: *Transmissions-Koeffizient und Trübungsfaktor*. Beitr. Phys. Atmos. **10**, pp 91–103, 1922
- [Lückehe 1999] B. Lückehe, *Kurzzeitvorhersage der solaren Einstrahlung aus Satellitendaten*. Diplomarbeit, Fachbereich Physik, Carl von Ossietzky Universität, Oldenburg, 1999
- [Luther 1993] G. Luther, *A measuring network for estimating the regional function of solar energy*. Proceedings ISES Solar World Congress, Budapest 1993 Vol. II, pp 261–266, 1993
- [Luther et al. 1996] G. Luther and F. Schirra, *Consequences of decentralized PV on local network management*. Final Report, Staatliches Institut für Gesundheit und Umwelt, Saarbrücken, 1996
- [Mönnich 2000] K. Mönnich, *Vorhersage der Leistungsabgabe netzeinspeisender Windkraftanlagen zur Unterstützung der Kraftwerkeinsatzplanung*. Dissertation, Fachbereich Physik, Carl von Ossietzky Universität, Oldenburg, 1999
- [Moulin et al. 1996] C. Moulin, C. E. Lambert, J. Poitou, F. Dulac, *Long term 1983-1994 calibration of the Meteosat solar VIS channel using desert and ocean targets*. International Journal of Remote Sensing, **17**, pp 1183–1200, 1996
- [Müller et al. 2002] R. W. Müller, D. Heinemann, R. Kuhlemann, C. Hoyer, K. F. Dagestad, J. A. Olseth, A. Skartveit, S. Cros, L. Wald, M. Schroedter, D. Dumortier, P. Ineichen, G. Piernavieja, *A new generation of satellite based solar irradiance calculation schemes*. Proceedings of the 22nd EARSeL Symposium (Geo-Information for European-Wide Integration), Prague, Czech Republic, 2002
- [Müller et al. 2003] R. W. Müller, D. Heinemann, R. Kuhlemann, C. Reise, K. F. Dagestad, J. A. Olseth, S. Cros, L. Wald, M. Schroedter, D. Dumortier, P. Ineichen, G. Piernavieja, *Rethinking satellite based solar irradiance modelling- The SOLIS clear sky module*. Submitted to Remote Sensing of the Environment, 2003
- [Nygard-Ferguson 2000] A. M. Nygard-Ferguson, *Predictive Thermal Control of Building Systems*. Dissertation, Ecole Polytechnique Fédérale Lousanne, 1990
- [Oey 1999] H. Oey, *Vorhersage von Bildfolgen in Satellitenbildern mit neuronalen Netzen: Untersuchung an einfachen Beispielen*. Studienarbeit, Fachbereich Physik, Carl von Ossietzky Universität, Oldenburg, 1999
- [Page 1996] J. Page, *Algorithms for the satellight programme*. Technical Report. June 1996

- [Schowengerdt 1997] R. A. Schowengerdt, *Remote Sensing Models and Methods for Image Processing*. Academic Press, San Diego, 1997
- [Stiller et al. 1999] C. Stiller and J. Konrad, *Estimating motion in image sequences: A tutorial on modeling and computation of 2D motion*. IEEE Signal Processing Magazine, **16**, pp. 70-91, 1999
- [Sfetsos et al. 2000] A. Sfetsos and A.H. Coonick, *Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques*. Solar Energy, **8**, pp 169–178, 2000.
- [Storch et al. 1999] H. v. Storch and F. W. Zwiers, *Statistical Analysis in Climate Research*. Cambridge University Press, Cambridge, 1999
- [Takacs 1985] L. Takacs, *A two-step scheme for the advection equation with minimized dissipation and dispersion errors*. Monthly Weather Review, **113**, pp 1050–1065, 1985
- [Taniguchi et al. 2001] A. Taniguchi, K. Otnai, K. Kurokawa, *Hourly forecast of global irradiation using GMS satellite images*. Solar Energy Materials and Solar Cells, **67**, pp 551–557, 2001
- [Weichert 1997] A. Weichert, *Zeitreihenanalyse natürlicher Systeme mit neuronalen Netzen und Methoden der statistischen Physik sowie der nichtlinearen Dynamik*. Dissertation, Fachbereich Physik, Carl von Ossietzky Universität, Oldenburg, 1997
- [Zell 1999] A. Zell, *Simulation neuronaler Netze*. Addison-Wesley Longmann Verlag, Bonn, 1999.

Danksagung

Ich möchte mich herzlich bei allen bedanken, die zum Gelingen der Arbeit beigetragen haben.

Vielen Dank an Detlev Heinemann, der diese Arbeit betreut und mich während der ganzen Zeit mit Vorschlägen und Ideen und bei der Strukturierung der Arbeit unterstützt hat.

Bei Jürgen Parisi möchte ich mich dafür bedanken, daß er diese Arbeit ermöglicht und mir Anregungen und Korrekturvorschläge zur Gestaltung der Arbeit gegeben hat.

In die Verfahren zur Berechnung der Solarstrahlung bin ich von Annette Hammer eingearbeitet worden. Für das letzte Kapitel habe ich wichtige Anregungen durch Diskussionen mit Matthias Lange erhalten. Annette Hammer, Richard Müller und Arne Wessel haben mich in der Endphase der Arbeit durch Korrekturlesen und Ideen zur Gestaltung der Arbeit unterstützt. Durch die gute Zusammenarbeit im Rahmen des EU-Projekts PVSAT-2 haben Anja Drews und Jethro Betcke zum Gelingen der Arbeit beigetragen. Bei Computer-Problemen konnte ich mich an Marco Girodo, Carsten Hoyer und Andreas Braukmann wenden. Bei allen genannten und den anderen Mitgliedern der Arbeitsgruppe möchte ich mich außerdem für die schöne Zeit und die nette Zusammenarbeit bedanken.

Danken möchte ich auch meinen Eltern und Geschwistern, die mich während der letzten Jahre insbesondere bei der Betreuung meiner Kinder unterstützt haben. Auch Freunden aus Oldenburg danke für die Unterstützung bei der Kinderbetreuung. Besonders möchte ich Ivo Gohsmann erwähnen, bei dem Dominik und Raquel viele schöne Nachmittage verbracht haben. In diesem Zusammenhang möchte ich mich auch bei Detlev Heineman und Jürgen Parisi bedanken, daß die Rahmenbedingungen für diese Arbeit mit flexiblen Arbeitszeiten so waren, daß ich die Arbeit in weiten Teilen gut mit den Kindern vereinbaren konnte.

Ganz besonders möchte ich mich bei Dominik und Raquel bedanken, für ihre Geduld vor allem im letzten Jahr und dafür, daß sie die ganze Zeit über gut mitgemacht haben.

Erklärung

Hiermit erkläre ich, dass ich die vorliegende Dissertation selbständig verfasst und nur die angegebenen Hilfsmittel benutzt habe.

Oldenburg den 6. 11. 2003

Elke Lorenz

Lebenslauf

Elke Lorenz

geboren am 7.6.68 in Rehau

ledig, zwei Kinder

Schulbildung

1974-1978 Pestalozzi Schule, Rehau

1978-1987 J.C. Reinhardt Gymnasium, Hof
Allgemeine Hochschulreife

Studium

Diplom-Physik
1988-1990 Ruprecht Karls Universität Heidelberg
1990-1996 Carl von Ossietzky Universität Oldenburg
Abschlussnote: sehr gut

Promotion

seit 1996 Wissenschaftliche Mitarbeiterin am Fachbereich Physik
der Carl von Ossietzky Universität Oldenburg