

# Kurzfristvorhersagen von Niederschlagswahrscheinlichkeit und Temperatur

## 1 Einleitung

Zu den wichtigen Komponenten der täglichen Wetterprognose gehören die Vorhersagen der Höchst- und Tiefsttemperaturen, sowie des Niederschlags. Diese Größen werden von den Modellen der numerischen Wettervorhersage (**numerical weather prediction**, NWP) für kurz- bis mittelfristige Vorhersagezeiträume gut vorhergesagt. Neben den deterministischen Kurzfristvorhersagen stehen aber auch Produkte von statistischen Modellen zur Verfügung; eine dritte Kategorie sind statistisch-dynamische Hybride. Statistische Modelle, wie z. B. Markov-Modelle, haben Vorteile sobald sie an die Klima-Zeitreihen von Bodenbeobachtungen einzelner Stationen angepaßt sind. Ihre Vorhersagen sind sofort nach beendeter Beobachtung verfügbar. Außerdem erfordern sie nur minimale Rechenzeit, nachdem die klimatologische Zeitreihe in geeigneter Weise einmal ausgewertet worden ist. Im Gegensatz zu diesen statistischen Ansätzen sind die numerischen Wetterprognosen deterministische Anfangswert-Vorhersagen auf der Basis von dynamischen Modellen, die nur in geringem Maß die lokale Klimatologie des Prognose-Gebietes berücksichtigen. Sie liefern Flächenmittel und nicht Stations- oder Punktvorhersagen.

So werden statistische Modelle entwickelt, die das Kurzzeitgedächtnis der Atmosphäre ausnutzen. Dazu gehören Markov-Prozesse, wie sie z.B. von Gabriel und Neumann (1962) an die Niederschlagsmenge in Tel Aviv angepaßt wurden. Fraedrich und Müller (1983) verwendeten Markov-Ketten für Bewölkungs- und Niederschlagswahrscheinlichkeiten (**Probability of Precipitation, PoP**) sowie für die Sonnenscheindauer in Berlin; Fraedrich und Dümmel (1983) benutzten autoregressive Modelle für die geopotentielle Höhe. Nach Erweiterung um zusätzliche Einflußgrößen (Miller 1984, ‚Generalized Equivalent Markov‘ System) ist die Markov-Kettenprognose der Niederschlagswahrscheinlichkeit vom Berliner Universitätswetterdienst 1984 eingeführt worden (Müller 1986; Fraedrich und Müller 1986). Im australischen Bureau of Meteorology sind diese Ansätze für die Hauptstädte des Kontinents in den mittleren Breiten (Miller und Leslie 1985; Fraedrich und Leslie 1987b) und in den Tropen (Fraedrich und Leslie 1988) getestet und operationell übernommen worden (Hess et al. 1989). Darüber hinaus führte die fehlerminimierende Linearkombination der statistischen PoP-Vorhersagen mit den numerischen Niederschlagsprognosen in allen Klimaten zur erheblichen Verbesserung gegenüber den Einzelvorhersagen (Fraedrich und Leslie 1987a). Basierend auf diesen Ergebnissen wurde dann an der Universität Hamburg

Mitte der 90er Jahre die statistische Wettervorhersage in Projektstudien und Diplomarbeiten weitergeführt (Kirk und Fraedrich 1998; Raible et al. 1999; 2002): der Einfluß von Nachbarstationen auf die lokale Niederschlagswahrscheinlichkeit, der Temperaturverlauf, die Kombination mit NWP-Modellen und der tägliche automatische Einsatz (<http://puma.dkrz.de/wetter/prognosen>).

Im folgenden werden die zugrundeliegenden statistischen Verfahren für die Prognosen der Niederschlagswahrscheinlichkeit am Beispiel der Station Hamburg vorgestellt und die Verifikationsmethoden erläutert (Abschnitt 2). Die Temperaturvorhersage wird in Abschnitt 3 diskutiert, wobei die Verbesserung der Prognosegüte durch die fehlerminimierende Linearkombination mit NWP-Modellen sowie Fallbeispiele für Sommer und Winter im Vordergrund stehen. Als Datenbasis für die statistischen Modelle werden die Standardsynopdaten (World Meteorological Organization 1988) der Station Hamburg (1949-95) und Helgoland (1966-95) verwendet.

## 2 Vorhersage der Niederschlagswahrscheinlichkeit

Die Vorhersage des Niederschlags stellt eine besondere Herausforderung dar, da der Niederschlag sowohl räumlich, als auch zeitlich hoch variabel ist. Eine Vorhersage der Niederschlagswahrscheinlichkeit statt der Niederschlagsmenge trägt diesem Verhalten Rechnung und läßt sich gut mit statistischen Verfahren bestimmen. In einem ersten Schritt wird ein einfaches diskretes Markov-Modell erster Ordnung vorgestellt, das die Basis für die Erweiterung mit Hilfe einer multivariaten Regression liefert, die im zweiten Schritt diskutiert wird. Daran anschließend wird das Modell am Beispiel der Station Hamburg verifiziert und die Verbesserung durch Hinzunahme weiterer Variablen der Station Helgoland aufgezeigt.

**Das Markov-Modell:** Grundlage der hier eingeführten Wahrscheinlichkeitsprognose ist die Markov-Kette (siehe z.B. Gabriel und Neumann 1962; Kemeny und Snell 1976; Fraedrich und Müller 1983; Cox und Miller 1992). Allgemein gilt, daß ein Markov-Prozeß erster Ordnung die Information vom gegenwärtigen Zustand benutzt, um die zukünftige Entwicklung vorherzusagen. Mit Hilfe langer Zeitreihen von lokalen Wetterbeobachtungen ist es möglich, bedingte Wahrscheinlichkeiten (oder Übergangswahrscheinlichkeiten) von einem gegenwärtigen zu einem zukünftigen Zustand zu schätzen. Werden Gegenwart und Zukunft von mehre-

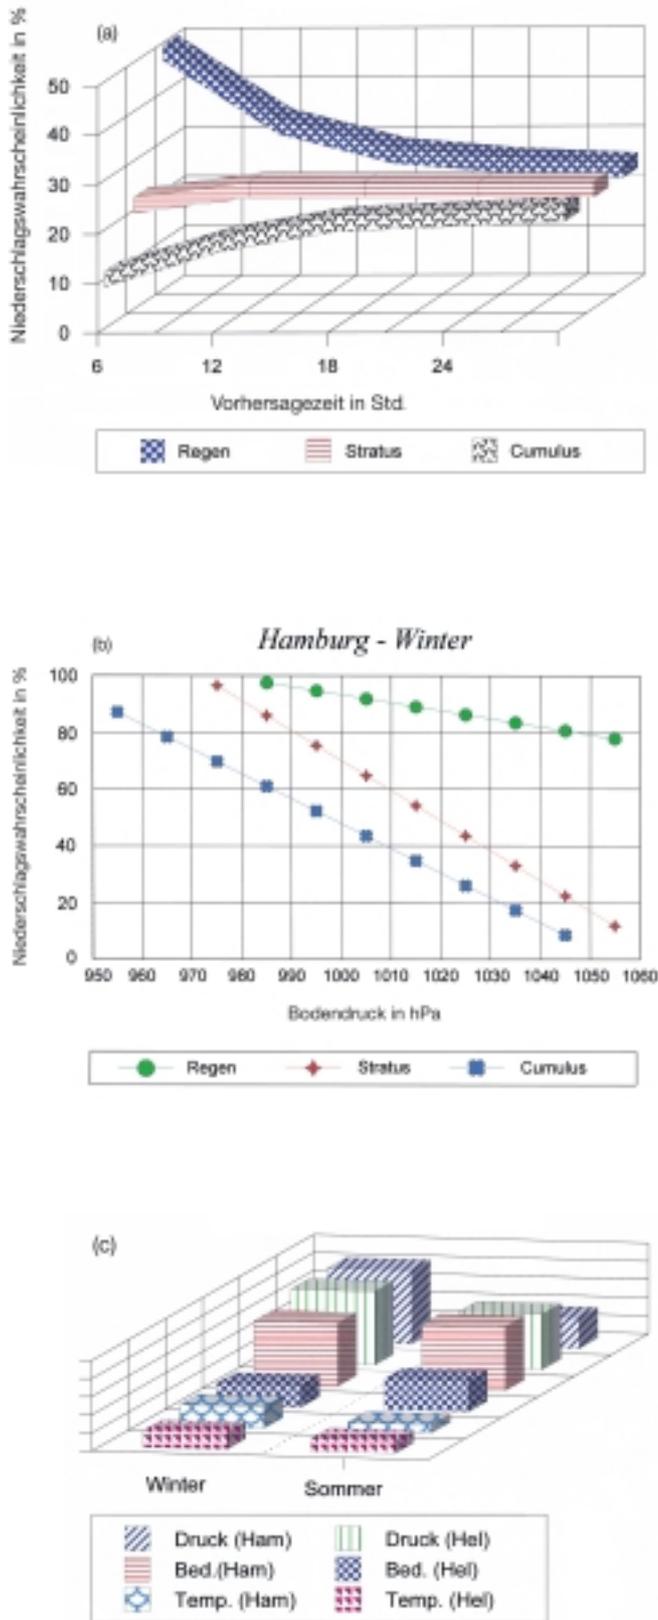


Abb. 1: (a) Vorhersagen der Niederschlagswahrscheinlichkeit (PoP) des reinen Markov-Modells mit zunehmender Vorhersagezeit für Hamburg; (b) 12-stündige PoP-Vorhersage mit dem Markov-Kovariaten Modell für die Wintersaison, wobei nur der Bodendruck in Hamburg als Kovariate verwendet wurde; (c) Einfluß der Kovariaten für das B-Modell (Hamburg – Helgoland) für die 12-stündige PoP-Vorhersage im Winter und Sommer.

ren sich gegenseitig ausschließenden Zuständen charakterisiert – als Komponenten eines stochastischen Vektors, deren Summe eins ergibt, z. B. (NR, RR) = (kein Regen, Regen) – so bilden die entsprechenden bedingten Wahrscheinlichkeiten eine Übergangsmatrix (z. B. von NR zu NR; NR zu RR; RR zu NR; RR zu RR).

Für die Kurzfristprognose des Niederschlags sind primär mesoskalige Prozesse von Bedeutung, die im Wetterschlüssel durch die unterschiedlichen Wolkentypen charakterisiert werden. Die phänomenologische Wolkeneinteilung geht auf Howard (Essay on the Modification of Clouds, 1802/03) zurück und ist von Goethe (um 1816) in einem Gedicht beschrieben worden. Es sind vor allem die Typen der niedrigen (nicht aber der hohen bzw. mittelhohen) Wolken von größter Bedeutung für die Niederschlagsprognose. So beruht das hier verwendete Markov-Modell zunächst auf drei sich gegenseitig ausschließenden Zuständen, zwei Zustände für tiefe Wolken und der W1-Niederschlag. Sie charakterisieren das mesoskalige Wetter der vergangenen sechs Stunden: (1) Cumulus-Wolken oder keine tiefen Wolken, (2) Stratus oder Stratocumulus und (3) Niederschlag. Der Niederschlagszustand (3) ist den signifikanten Wettererscheinungen der letzten sechs Stunden entnommen, die ebenfalls von Wetterbeobachtern routinemäßig verschlüsselt werden. Der W1-Niederschlag tritt nach der Klassifikation signifikanter Wettererscheinungen immer dann auf, wenn in den letzten sechs Stunden oder zum Zeitpunkt der Beobachtung mindestens einmal Niederschlag (Niesel, Regen, Schnee usw.) beobachtet worden ist. Liegt dieser Zustand nicht vor, dann werden die 6-stündlichen Beobachtungsintervalle anhand der oben angegebenen Zustände niedriger Wolken in die Zustände (1) oder (2) eingeteilt.

Die Hamburger Vorhersagen des Markov-Modells für Vorhersagezeiten von 6 bis 24 Stunden sind in Abb. 1a dargestellt. Zeigt der aktuelle Synop von Hamburg im Feld W1 Niederschlag, so ergibt sich nach diesem Modell eine Wahrscheinlichkeit von 50 %, daß es auch im nächsten 6-Stunden Zeitraum zu Niederschlägen kommt. Liegt eine niedrige Stratusbewölkung vor, ohne daß es zur Zeit Niederschläge gibt, so führt das zu einer Niederschlagswahrscheinlichkeit von 20 %. Liegt keiner der beiden erstgenannten Fälle vor, d.h. die tiefen Wolken sind cumulusartig oder nicht vorhanden, dann reduziert sich die Niederschlagswahrscheinlichkeit auf 10 %. Die Abbildung zeigt aber auch die Grenzen des Modells. Für längere Vorhersagezeiträume konvergieren die Werte der drei Zustände zur Klimawahrscheinlichkeit, so daß die Anwendung nur bis zu Zeiträumen von 12 Stunden sinnvoll erscheint.

**Das Markov-Kovariaten Modell:** Das mesoskalige Wetter, hier charakterisiert durch Wolken und Niederschlagszustände, ist eingebettet in die großräumige synoptische Skala. Im Markov-Kovariaten Modell werden zusätzliche Variablen, die die synoptische Skala

charakterisieren sollen, als Kovariate eingeführt (Miller und Leslie 1985). Es sind kontinuierliche Variablen, wie z. B. der Luftdruck oder die Temperatur zum Beobachtungstermin, und nicht wie bei den mesoskaligen Informationen diskrete und sich gegenseitig ausschließende Wetterzustände. Dadurch erfährt das Modell eine wesentliche Verbesserung, wie das Beispiel des Bodendrucks in Hamburg als zusätzliche Kovariate (Abb. 1b) für die 12-stündige Vorhersage in der Wintersaison veranschaulicht. Für einen Bodendruck von 1025 hPa wird im Falle von Cumulus Bewölkung 25 %, von Stratus Bewölkung 45 % und im Fall, daß Regen beobachtet wurde, 85 % Niederschlagswahrscheinlichkeit für die nächsten 12 Stunden vorhergesagt. Das Markov-Modell liefert entsprechend des aktuellen Zustands den Basiswert der Niederschlagswahrscheinlichkeit; durch ein ausgewähltes Ensemble von Kovariaten wird dieser Zustand modifiziert. Mit Hilfe einer multivariaten linearen Regression werden aus langen Zeitreihen Regressionskoeffizienten für die Kovariaten gewonnen, die dann für die Vorhersage benutzt werden. Das Regressionsverfahren liefert außerdem Informationen über den relativen Einfluß der Kovariaten auf die Prognose, so daß ihre Zahl reduziert werden kann. Dies gewährleistet gleichzeitig die Stabilität der Regression. Die Kovariaten müssen nicht notwendigerweise alle von der Station stammen, für die die Vorhersage erfolgt (Kirk und Fraedrich 1998). Abb. 1c zeigt die wichtigsten Kovariaten für die 12-stündige Vorhersage in Hamburg, wenn außerdem auch noch Beobachtungen der Station Helgoland hinzugezogen werden. Im Winter dominieren Bodendruck und Gesamtbedeckung von Hamburg neben dem Druck von Helgoland. Im Sommer ist der Druck Helgolands sogar wichtiger als der in Hamburg und auch die Helgoländer Bedeckung spielt eine wichtige Rolle. Dies hängt mit der Tatsache zusammen, daß Helgoland bei den sehr häufigen Westwinden stromaufwärts liegt und somit den advektiven Teil des Hamburger Wettergeschehens beschreiben kann.

**Verifikation:** Das Verifikationskonzept für Vorhersagen der Niederschlagswahrscheinlichkeit ist von Murphy und Winkler (1987; 1992) entwickelt worden. Es beurteilt die Vorhersagen nicht nur nach einfachen Maßzahlen wie den „Half-Brier-Score“ (Brier 1950) oder den „Skill-Score“, der das Modell gegen ein Referenzmodell (z.B. Klima) vergleicht, sondern es zeigt auch die „Zuverlässigkeit“ und die „Schärfe“ der Modelle. Die Bewertung der Modelle wird an zwei Beispielen gezeigt. Das A-Modell ist das Markov-Kovariaten Modell für Hamburg; das B-Modell erweitert das A-Modell um die Kovariaten von Helgoland. Alle Abbildungen beziehen sich auf die Vorhersage des Intervalls 6 bis 18 UTC ausgehend von den 6 UTC Daten und auf den vom Modellbildungszeitraum (1949–78) unabhängigen Verifikationszeitraum 1979–95.

Die Schärfe- und Zuverlässigkeitsdiagramme des A- und B-Modells (Abb. 2a, b) liefern mehr Details als

jede Maßzahl. Zusammengefaßt in zwanzig 5 % Wahrscheinlichkeitsklassen werden die bedingten Verteilungen in der Ordinate angezeigt. Der obere Teil zeigt die Schärfe, wobei hohe Schärfe durch eine U-förmige Verteilung mit einer Häufung der Prognosen bei 0 % und 100 % gekennzeichnet ist. Dabei sind jeweils die bedingten Verteilungen der PoP-Vorhersagen für trockene (○) und Regenzustände (●) des Verifikationszeitraums dargestellt. Die Aufspaltung der Verteilungen in trockene und Regenzustände ist im A-Modell nicht sehr deutlich. Das Maximum für trockene Zustände liegt bei 20 %, für Regen bei 50 %. Der Bereich über 80 % wird durch die PoP-Vorhersagen nicht abgedeckt. Dennoch haben die Vorhersagen eine Güte, da die Maxima voneinander getrennt sind. Im Vergleich dazu zeigt das B-Modell eine deutliche Verbesserung; es liefert eine U-förmige Verteilung mit maximalen relativen Häufigkeiten an den Rändern. Die Zuverlässigkeitsdiagramme, also die beobachtete relative Häufigkeit des Niederschlags für eine gegebene PoP-Vorhersage, ist für jedes Modell in der unteren Abbildung dargestellt. Dabei veranschaulicht die Diagonale das Verhalten eines perfekten Modells; die schattierte Fläche gibt den Bereich an, in dem das Modell positiven Skill gegenüber der Klimavorhersage besitzt. Das A-Modell ist im Bereich von 0 - 40 % nahe an der Diagonalen; zwischen 40 % und 80 % zeigt sich aber eine Unterschätzung des Niederschlags; die beobachtete relative Häufigkeit des Niederschlags übersteigt um etwa 20 % die PoP-Vorhersagen. Über 80 % werden, wie schon das Schärfediagramm andeutet, nur selten PoP-Vorhersagen registriert. Die Zuverlässigkeit des B-Modells zeigt dagegen ein deutliche Nähe zum perfekten Modell über den gesamten Bereich (0 - 100 %). Die maximalen Abweichungen betragen 5 %, was der Wahrscheinlichkeitsklassenbreite entspricht. Somit kann das B-Modell als sehr zuverlässig bezeichnet werden.

### 3 Vorhersage der Temperaturanomalie

Die Temperatur ist eine weitere häufig nachgefragte Variable bei Wettervorhersagen. Im vorliegenden Fall wird die Temperaturanomalie vorhergesagt. Diese Anomalie ist definiert als Abweichung von einem Mittelwert aller Jahre des Modellbildungszeitraums für einen Kalendertag und einen Haupttermin (00, 6, 12, 18 UTC). Man erhält somit vier Jahresgänge für die vier Haupttermine, die mit einem 7-tägigen gleitenden Mittel geglättet werden. Die Wahl der Anomalie ist entscheidend für die Güte des statistischen Modells, dessen Methode im folgenden beschrieben wird. Daran anschließend wird das Modell am Beispiel der Station Hamburg verifiziert und eine Verbesserung der Vorhersagegüte durch eine fehlerminimierende Linearkombination mit einem NWP-Modell vorgestellt (Raible et al. 1999).

**Das multivariate Regressionsmodell:** Ein klassisches multivariates Regressionschema (z.B. von Storch und

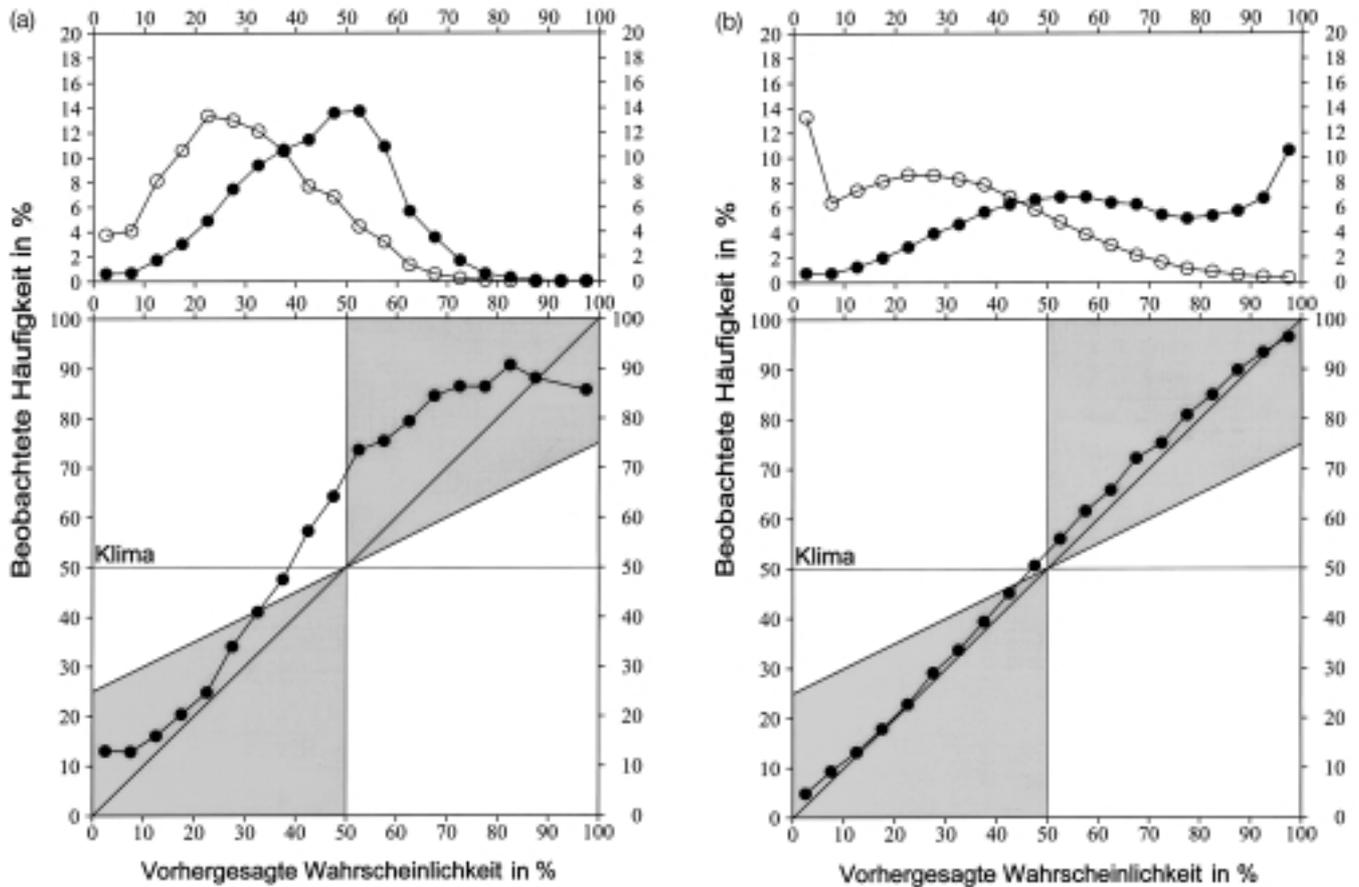


Abb. 2: Das Schärfe- (oben) und Zuverlässigkeitsdiagramm (unten) für die 12-stündige PoP-Vorhersage ausgehend vom Zeitpunkt 6 UTC: (a) A-Modell (Hamburg) und (b) B-Modell (Hamburg – Helgoland). Dabei sind die bedingten Verteilungen der PoP-Vorhersagen für trockene (○) und Regenzustände (●) dargestellt. Die Diagonale in der unteren Abbildung zeigt die Zuverlässigkeit eines perfekten Modells; schattiert ist der Bereich eingezeichnet, in dem ein Modell positiven Skill gegenüber dem Klimamodell besitzt.

Zwiers 1998) wird jeweils einzeln für die vier Temperaturanomalien entsprechend der Haupttermine angewendet. Exemplarisch wird das Schema für das gesamte Jahr vorgestellt. Eine weitere Unterscheidung in einzelne Jahreszeiten ist möglich. Der gesamte Zeitraum wird in einen Modellbildungszeitraum 1949–79 und einen Verifikationszeitraum 1980–95 unterteilt. Als Eingangsdatensatz dienen die Standardsynop- und daraus abgeleitete Daten. Somit stehen 20 Variablen als Prädiktoren zur Verfügung. Wie bei der PoP-Vorhersage wird aus Modellstabilitätsgründen die Anzahl der Prädiktoren reduziert, wobei sich letztendlich 12 Prädiktoren als ausreichend erwiesen haben (Raible et al. 1999). Die den Prädiktoren entsprechenden Regressionskoeffizienten werden im Modellbildungszeitraum geschätzt und zwar jeweils einzeln für die vier Haupttermine und die 4 Vorhersagezeiten (+6 Std., +12 Std., +18 Std. und +24 Std.).

**Verifikation und Kombination mit einem NWP-Modell:** Die Grundlage der Verifikation des statistischen Modells im Zeitraum 1980–95 liefert die gemeinsame Verteilung der Vorhersage und Beobachtung. Mit Hilfe dieser Verteilung lassen sich traditionelle Verifi-

kationsmaße, wie z. B. der RMS-Fehler (**root-mean-square**), ableiten (Murphy et al. 1989).

In Abb. 3a ist exemplarisch für die 12-stündige Vorhersage der Temperaturanomalie in Hamburg das bivariate Histogramm von Vorhersage und Beobachtung dargestellt. Die darunterliegende Punktwolke um die Hauptdiagonale (die das Verhalten eines perfekten Modells aufzeigt) vermittelt einen qualitativen Eindruck der Zuverlässigkeit des statistischen Modells. Dabei ist zu beachten, daß bei extrem starken Temperaturanomalien die Streuung nicht zunimmt. Die gemeinsame Verteilung, die eine Gaußsche Struktur aufweist, ist symmetrisch entlang der und um die Hauptdiagonale, wo die größten relativen Häufigkeiten auftreten. 70 % aller Vorhersagen haben eine geringere Abweichung als  $\pm 2^\circ \text{C}$ . Der RMS-Fehler, der ein mittleres Maß der gemeinsamen Verteilung darstellt, beträgt für die 12-stündige Vorhersage  $2,2^\circ \text{C}$ .

Eine zusätzliche Vorhersageverbesserung wird durch die fehlerminimierende Linearkombination der Vorhersagen des statistischen Regressionsmodells mit numerischen Wetterprognosen des Europa-Modells

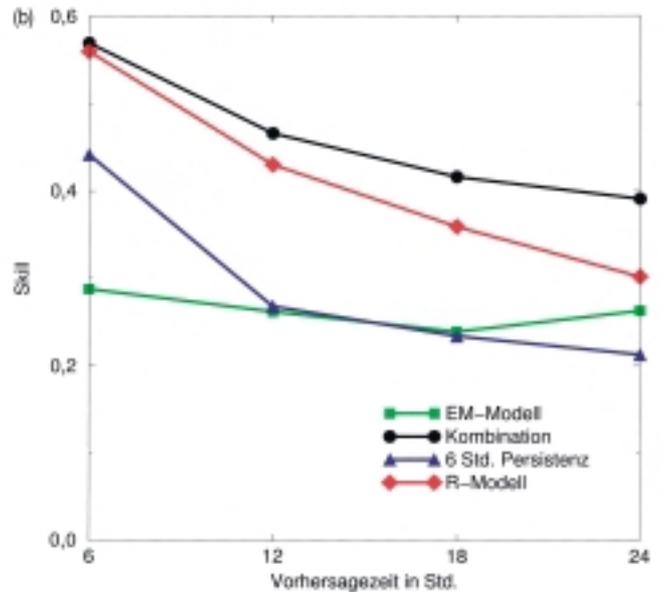
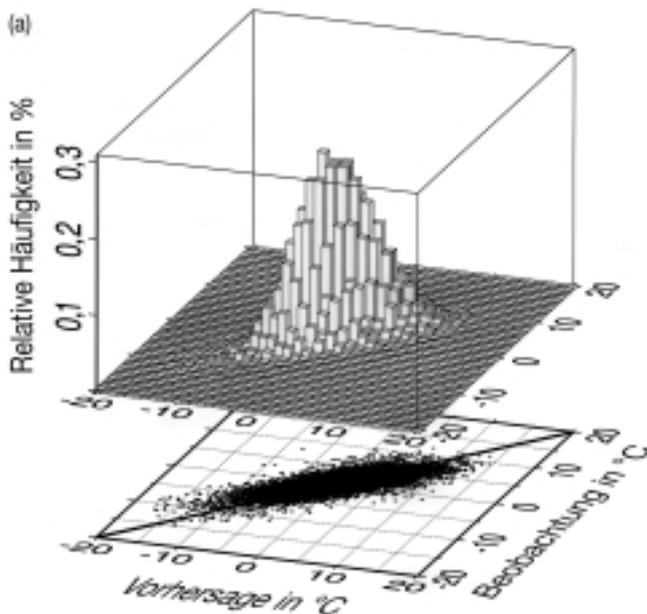


Abb. 3: (a) Bivariates Histogramm der gemeinsamen Verteilung der 12-stündigen Vorhersagen der Temperaturanomale versus Beobachtungen und zugehörige Punktwolke für Hamburg. Die Diagonale stellt das Verhalten eines perfekten Modells dar. (b) Skill-Score der Temperaturvorhersagen für vier verschiedene Modelle mit zunehmender Vorhersagezeit; als Referenzmodell dient der klimatologische Mittelwert.

(EM-Modell; Majewski 1991) erreicht. Da diese Vorhersagen Flächenmittel repräsentieren, müssen zunächst die 'optimalen' Gitterpunkte zur Vorhersage der Temperaturanomale in Hamburg identifiziert werden. Beim direkten Vergleich mit Beobachtungen an der Station Hamburg zeigt sich, daß der nächste Gitterpunkt die beste Vorhersage liefert. Die für den Zeitraum 1991–95 verwendeten Vorhersagen wurden allerdings nur alle 24 Stunden (Haupttermin 00 UTC) neu erstellt und umfassen für alle 6 Stunden-Intervalle Vorhersagen bis zu 72 Stunden. Für die Kombination wird aber eine 6-stündige zeitliche Auflösung benötigt, so daß für die weiteren Haupttermine (6, 12, 18 UTC) die Vorhersagen des 00 UTC Termins benutzt werden. So ist z.B. die 6-stündige Vorhersage, die zum Zeitpunkt 12 UTC starten soll, die 18-stündige Vorhersage des vorangegangenen 00 UTC Laufs. Die Gewichte der linearen Kombination werden durch Fehlerminimierung bestimmt (Fraedrich und Leslie 1987; Raible et al. 1999). Dafür werden die zur Verfügung stehenden Jahre 1991–95 wiederum in einen Zeitraum (1991–93), der zur Schätzung der Wichtungskoeffizienten der einzelnen Vorhersagen benutzt wird, und einen unabhängigen Verifikationszeitraum (1994–95) aufgeteilt.

Um die Güte verschiedener Modelle miteinander zu vergleichen, wird ein Skill-Score im Verifikationszeitraum 1994–95 verwendet. Dabei wird der RMS-Fehler des zu testenden Modells mit dem eines Referenzmodells (hier die Vorhersage des Klimamittels) benutzt:  $SKILL = 1 - RMS / RMS_{ref}$ . Positive (negative) Werte bedeuten, daß das zu testende Modell bessere (schlechtere) Vorhersagen liefert als das Referenz-

modell. In Abb. 3b ist der Skill-Score für vier verschiedene Modelle dargestellt: (i) das statistische Regressionsmodell (R-Modell), (ii) das 6-stündige Persistenzmodell, das als Vorhersage die aktuelle Temperaturanomale benutzt, (iii) numerische Wetterprognosen des EM-Modells und (iv) die fehlerminimierende Linearkombination vom EM- und R-Modell. Der Skill-Score des EM-Modells ist für alle Vorhersagezeiten nahezu konstant, was auf die spezielle Konstruktion der Zeitreihe mit 6-stündiger Auflösung zurückzuführen ist. Das Persistenzmodell zeigt nur für die 6-stündige Vorhersage deutlichen Skill; für längere Vorhersagezeiten fällt er stark ab. Das statistische Regressionsmodell allein zeigt gegenüber dem EM-Modell eine deutliche Verbesserung. Der Skill nimmt jedoch mit zunehmender Vorhersagezeit ab. Die Kombination beider Modelle (EM- und R-Modell) zeigt den besten Skill, wobei die Verbesserung gegenüber dem reinen R-Modell für die 6-stündige Vorhersage vernachlässigbar ist. Bei der 24-stündigen Vorhersage ergibt sich eine deutliche Verbesserung. Für diesen Fall gewinnt man durch die Kombination nahezu 12 Stunden an Vorhersagezeit gegenüber dem statistische Regressionsmodell.

Zusätzlich werden das R-Modell, das EM-Modell und die Kombination beider für zwei Wettersituationen getestet (Abb. 4, Raible et al. 2002). Dafür wird die 24-stündige Vorhersage (das liegt an der oberen Vorhersagbarkeitsgrenze von statistischen Kurzfristprognosen) für alle 6 Stunden einer Woche bestimmt und mit den eingetretenen Beobachtungen verglichen. Die Woche im Winter (1. bis 8. Januar 1995) stellt ein Phase extrem niedriger Temperaturen dar. Das EM-Modell

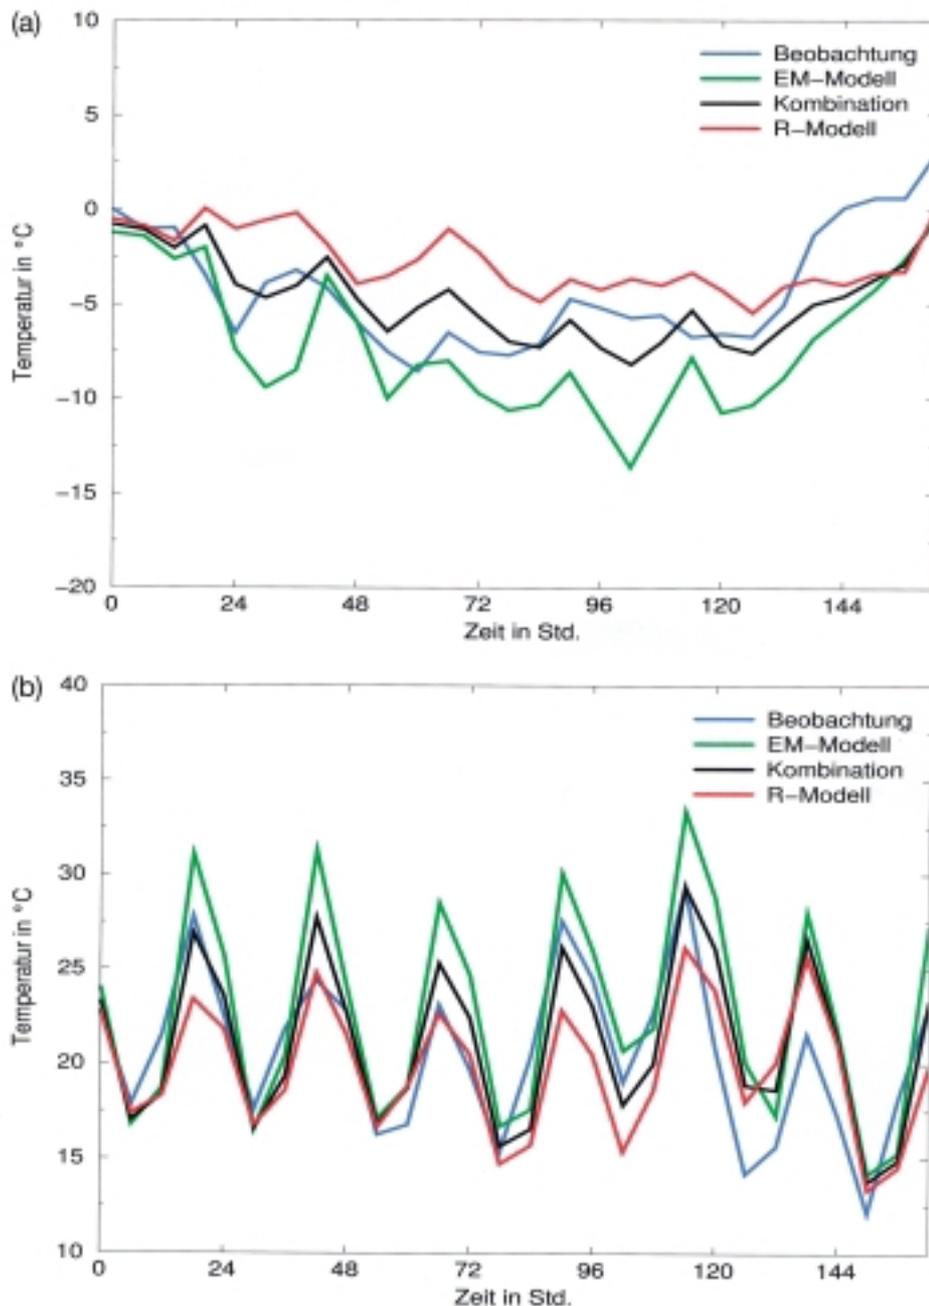


Abb. 4:  
 Fallbeispiel für die 24-stündige Temperaturvorhersage in Hamburg für (a) eine Woche im Winter (1.1. bis 8.1.1995) und (b) eine Woche im Sommer (1.7. bis 8.7.1995) für drei verschiedene Modelle.

sagt zu kalte, das R-Modell zu warme Temperaturen vorher; nur die Kombination beider Modelle reproduziert diese Kaltphase ausreichend gut. In der Sommerwoche vom 1. bis 8. Juli 1995 zeigen beide Modelle einen ausgeprägten Tagesgang, der wiederum am besten von der Kombination vorhergesagt wird.

#### 4 Diskussion

Zwei statistische Modelle zur Stationsvorhersage der Variablen Niederschlagswahrscheinlichkeit (PoP) und Temperatur für einen Zeitraum bis zu 24 Stunden werden vorgestellt. Die PoP-Vorhersagen werden mit einem Markov-Kovariaten Modell erzeugt. Wenn zusätzliche Variablen einer weiteren Station (Helgoland)

hinzu genommen werden, um advektive Prozesse in das Vorhersagesystem besser zu implementieren, so ergibt sich eine deutliche Verbesserung der Vorhersagegüte. Gerade in den vorgestellten Schärfe- und Zuverlässigkeitsdiagrammen, die eine detaillierte Bewertung der Modelle zulassen, schneidet das Modell mit den zusätzlichen Kovariaten besser ab. Die Vorhersagen der Temperaturanomalie, die auf dem multivariaten Regressionsmodell basieren, zeigen bei der Betrachtung der gemeinsamen Verteilung von Beobachtungen und Vorhersagen, daß selbst bei extremen Temperaturanomalien die Streuung der Vorhersagen nicht wesentlich zunimmt. Stehen neben den statistischen Prognosen auch Vorhersagen anderer Modelle zur Verfügung, so ermöglicht die fehlerminimierende Linearkombination eine deutliche Verbesserung der Güte gegenüber

den Einzelvorhersagen (vom reinen statistischen Modell oder reinen NWP-Modell). Damit liefern die statistischen Modelle ein Potential für weitere zukünftige Anwendung in der operationellen Wettervorhersage. Aktuelle Vorhersagen, die mit den statistischen Modellen allein erzeugt wurden, können jederzeit auf der Internetseite „<http://puma.dkrz.de/wetter/prognosen>“ abgerufen werden. Empirische Vorhersagen durch statistische oder dynamisch-statistische Modelle müssen um Extremwert- und Fehlerprognosen erweitert werden. Dies erfordert die Verwendung von nichtlinearen Methoden und Ensemblevorhersagen, wie das Beispiel der Ensembleprognosen von Hurrikanzugbahnen mit einem Analog-Verfahren veranschaulicht (Fraedrich und Rückert 1998, Sievers et al. 2000, Fraedrich et al. 2000).

## Literatur

- BRIER, G. W., 1950: Verification of forecasts expressed in terms of probability. *Mon. Wea. Rev.*, **78**, 1-3.
- COX, D. R., H. D. MILLER, 1992: *The Theory of Stochastic Processes*. Chapman and Hall, 398pp.
- FRAEDRICH, K., K. MÜLLER, 1983: On single station forecasting: Sunshine and rainfall Markov chains. *Contrib. Atmosph. Phys.* **56**, 108-134.
- FRAEDRICH, K., T. DÜMMEL, 1983: On single station forecasting: The geopotential height, its vertical times structures and 500mbar ARMA prediction. *Contrib. Atmosph. Phys.* **56**, 221-239.
- FRAEDRICH, K., K. MÜLLER, 1986: On single-station forecasting: Probability of precipitation in Berlin. *Contrib. Atmosph. Phys.* **59**, 427-434.
- FRAEDRICH, K., L. M. LESLIE, 1987a: Combining predictive schemes in short-term forecasting. *Mon. Wea. Rev.*, **115**, 1640-1644.
- FRAEDRICH, K., L. M. LESLIE, 1987b: Evaluation of techniques for operational, single station, short-term forecasting of rainfall at a midlatitude station (Melbourne). *Mon. Wea. Rev.*, **115**, 1645-1654.
- FRAEDRICH, K., L. M. LESLIE, 1988: Real-time short-term forecasting of precipitation at an Australian tropical station. *Wea. Forecasting*, **3**, 104-114.
- FRAEDRICH, K., R. MORRISON, L. M. LESLIE, 2000: Improved tropical cyclone track predictions by error recycling. *Meteorol. Atmos. Phys.*, **74**, 51-56.
- FRAEDRICH, K., B. RÜCKERT, 1998: Metric adaption for analog forecasting. *Physica A*, **253**, 379-393.
- GABRIEL, K. R., J. NEUMANN, 1962: A Markov chain model for daily rainfall occurrence at Tel Aviv. *Quart. J. Roy. Meteor. Soc.*, **88**, 90-95.
- HESS, G. D., L. M. LESLIE, A. E. GUYMER, K. FRAEDRICH, 1989: Application of Markov technique to the operational, short-term forecasting of rainfall. *Aust. Meteor. Mag.*, **37**, 83-91.
- KEMENY, J. G., J. L. SNELL, 1976: *Finite Markov chains*. Springer-Verlag, 210 ff.
- KIRK, E., K. FRAEDRICH, 1998: Probability of precipitation: Short-term forecasting and verification. *Contrib. Atmos. Phys.*, **72**, 263-271.
- MAJEWSKI, D., 1991: Numerical methods in atmospheric models. Seminar Proc. *ECMWF*, **2**, 147-191.
- MILLER, R. G., 1884: GEM: A statistical weather forecasting procedure. *Short- and medium-range weather prediction research program (PSMP)*, WMO Publi. Series, **10**, 102pp.
- MILLER, A. J., L. M. LESLIE, 1985: Short-term, single-station probability of precipitation forecasting using linear and logistic models. *Contrib. Atmosph. Phys.*, **58**, 517-527.
- MÜLLER, K., 1986: Prognose von Niederschlagswahrscheinlichkeiten an einer Station (Berlin). *Meteorologische Abhandlungen, Freie Universität Berlin*, 146pp.
- MURPHY, A. H., R. L. WINKLER, 1987: A general framework for forecast verification. *Mon. Wea. Rev.*, **115**, 1330-1338.
- MURPHY, A. H., B. G. BROWN, Y. S. CHEN, 1989: Diagnostic verification of temperature forecasts. *Wea. Forecasting*, **4**, 485-501.
- MURPHY, A. H., R. L. WINKLER, 1992: Diagnostic verification of probability forecasts. *Int. J. Forecasting*, **7**, 435-455.
- RAIBLE, C. C., G. BISCHOF, K. FRAEDRICH, E. KIRK, 1999: Statistical single-station short-term forecasting of temperature and probability of precipitation: Area interpolation and NWP combination. *Wea. Forecasting*, **14**, 203-214.
- RAIBLE, C. C., G. BISCHOF, K. FRAEDRICH, E. KIRK, 2002: Reply to „Statistical single-station short-term forecasting of temperature and probability of precipitation: Area interpolation and NWP combination.“ *Wea. Forecasting*, **17**, in press.
- SIEVERS, O., K. FRAEDRICH, C. C. RAIBLE, 2000: Self-adapting analog ensemble predictions of tropical cyclone tracks. *Wea. Forecasting*, **15**, 623-629.
- VON STORCH, H., F. W. ZWIERS, 1998: *Statistical Analysis in Climate Research*. Cambridge University Press, 510pp.
- WORLD METEOROLOGICAL ORGANIZATION, 1988: *Manual of Codes*. International Codes, **1**, No. 306.

Anschrift der Autoren:  
 Meteorologisches Institut der Universität Hamburg,  
 Bundesstraße 55, 20146 Hamburg