

# OBJEKTIVE OPTIMIERUNG DER LOKALEN WETTERVORHERSAGE

M. ROHN, W. E. RAATZ und T. VOR DER BRÜCK

*Referat Entwicklung von Anwendungen  
Deutscher Wetterdienst, Offenbach am Main, Deutschland*

## 1 EINLEITUNG

Die lokale Wettervorhersage umfaßt einen Zeitraum von 0 bis 178 Stunden und muß daher die unterschiedlichsten Punktinformationen aus den Ergebnissen der numerischen Modellierung, konventioneller Beobachtungen von Bodenwetterelementen sowie Nowcasting-Produkten integrieren. Dabei liefern die Verfahren oft unterschiedliche Punktprognosen. Um eine Endvorhersage oder Guidance abzuleiten, müssen alle verfügbaren Informationen bezüglich ihrer Qualität bewertet werden, sodann eine Auswahl getroffen, und abschließend zu einer einzigen Aussage kombiniert werden. Dieses Problem von Selektion und Kombination verschiedener Vorhersageinformationen wird anschaulich von Winkler (1989) aus der Perspektive der Entscheidungstheorie beschrieben.

In der täglichen Routinearbeit des Vorhersagemeteorologen wird diese Integration „intuitiv“ vollzogen, basierend auf seiner meteorologischen Erfahrung über die synoptische Situation sowie seiner Kenntnisse der lokalen Charakteristika des Prognoseortes.

Der DWD plant, den Vorhersageprozeß durch ein Verfahren „Objektive Optimierung“ zu unterstützen, welches eine sog. Objektiv Optimierte Guidance (OOG) erzeugt. Das Verfahren umfaßt objektive Ansätze zur Kombination verschiedener Vorhersagedaten sowie die kontinuierliche Aktualisierung durch Beobachtungs- und Nowcastingdaten.

Im Deutschen Wetterdienst (DWD) werden verschiedene Ansätze verwendet, um lokale Vorhersagen (Punktterminprognosen) aus den Ergebnissen numerischer Modelle (NWV) abzuleiten. Zur Zeit werden ein Ansatz für Model Output Statistics (Glahn and Lowry, 1972, Haalman, 2003) auf die globalen Modelle des DWD (GME) und ECMWF sowie eine Kalman-Filterung auf das lokale hochauflösende Modell des DWD (LM) angewandt (Majewski *et al.*, 2002, Doms und Schättler, 1999). In naher Zukunft werden weitere Ergebnisse eines räumlich und zeitlich hochauflösenden nicht-hydrostatischen Modells mit dem Schwerpunkt der Kurzfristvorhersage (LMK) erwartet (Doms und Förstner, 2004). Die statistischen Postprocessingverfahren führen Korrekturen systematischer Modellfehler sowie eine Berücksichtigung lokaler Charakteristika durch. Aus diesem Grund stellen alle Ansätze wertvolle Informationsquellen zur Verfügung, die in der Endvorhersage berücksichtigt werden müssen. Aus dem Bereich der Ensemblevorhersage stammen eine Vielzahl von Erfahrungen und Ansätzen zur Konstruktion einer deterministischen Vorhersage durch Modellkombination (Raftery *et al.*, 2003, Ziehmann, 2000, Balzer, 1995). Diese Studien bieten wertvolle Vorschläge zur Integration verschiedener Punktterminprognosen in einer lokalen Vorhersage-Guidance.

Die NWV-Guidance wird auf der Grundlage von 2 Modellläufen erzeugt (00 und 12 GMT) und überdeckt ein Vorhersageintervall von 178 Stunden für das globale Modell sowie 48 h für das lokale hochauflösende Modell. Zwischen den Modellläufen stehen über einen Zeitraum von etwa 12 Stunden kontinuierlich Beobachtungen zur Verfügung, die zur Bewertung und Korrektur der verschiedenen Punktterminprognosen herangezogen werden. Ein oft zu beobachtendes Problem stellt dabei die Abweichung zwischen Prognose und bereits vorliegenden Beobachtungen dar. Ein kontinuierlicher Abgleich anhand der neuesten Beobachtung ist wünschenswert auch im Hinblick auf die Akzeptanz der Guidance. Ein Teil der täglichen Vorhersagearbeit besteht daher in dem Vergleich von NWV-Guidance

mit der beobachteten synoptischen Entwicklung und einer Korrektur anhand verfügbarer Beobachtungen. Der Kanadische Wetterdienst schätzt, daß ein beträchtlicher Teil der Vorhersagearbeit in einer manuellen Integration von Beobachtungen besteht (Landry *et al.*, 2003).

Die Analyse aller verfügbaren Prognosedaten zusammen mit der abschließenden Entscheidungsfindung zur Selektion und Kombination der Informationen erfordert beträchtliche personelle Ressourcen. Der Gesamtumfang einiger wichtiger Datenarten ist in Abb. 1 illustriert.

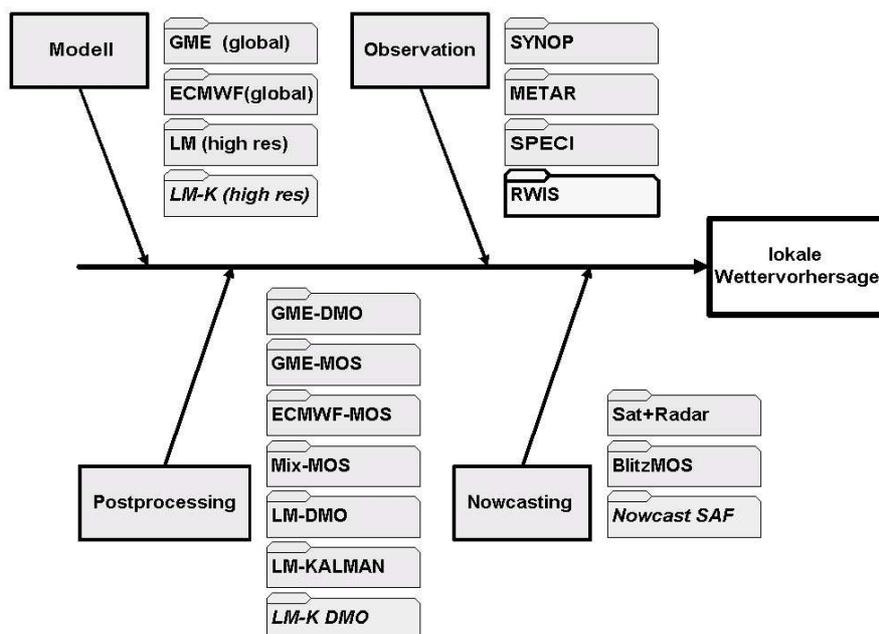


Abbildung 1: Zusammenstellung einiger wichtiger Datenarten zur lokalen Wettervorhersage im DWD.

Insbesondere in Situationen von markanten Fehlern in der synoptischen Entwicklung eines Modells sowie extremer Wetterereignisse kann auf die manuelle Kontrolle eines erfahrenen Vorhersagemeteorologen nicht verzichtet werden. Allerdings setzen die zeitlichen Anforderungen gerade im Nowcastingbereich für eine große Zahl von Prognoseorten klare Grenzen. Zur Zeit werden im DWD die verschiedenen Postprocessingverfahren auf etwa 3000 Stationen weltweit angewandt. Neben der Anzahl von Orten existieren auch Grenzen bezüglich der Menge an Datentypen, die in einem manuellen Prozeß berücksichtigt werden können. Dieser Konflikt wird verschärft durch die Vielzahl an Nowcasting-Daten, die in naher Zukunft im Rahmen der EUMETSAT Satellite Application Facility on Nowcasting and Very Short Range Forecasting (NWC SAF) zur Verfügung stehen werden (EUMETSAT, 1998).

## 2 KONZEPT

Für die zuvor beschriebenen Schritte der Modellkombination und Beobachtungskorrektur werden Lösungsansätze vorgestellt. Anhand eines Trainingsdatensatzes wird für ein ausgewähltes Element (z.B. 2m-Temperatur) die Bestimmung damit verbundener Parameter erläutert. Der Trainingsdatensatz ist in Tabelle 1 beschrieben.

Parameter	Beschreibung
Datentyp der Guidance	MOS-MIX: Kombination zweier Punktterminprognosen aus dem statistischen Postprocessing von GME und ECMWF. LM-DMO: Direct Model Output des hochauflösenden Lokal-Modells.
Trainingsstationen: 15 SYNOP Stationen	Die Stationsliste orientiert sich an den Stationen, die zur operatonellen Verifikation der lokalen Wettervorhersage im DWD dienen. (WMO-ID: 10147, 10170, 10224, 10338, 10400, 10469, 10488, 10554, 10609, 10637, 10738, 10763, 108065, 10870)
Trainingstermine	1-20 April 2004, Initialisierung um 00 UTC und 12 UTC: 20 Prognosetermine für 2 Modellläufe

Tabelle 1: Beschreibung des Testdatensatzes zur Parameterdefinition.

## 2.1 BEOBACHTUNGSKORREKTUR

Die Beobachtungskorrektur geht von einer Autokorrelation der Vorhersagefehler aus. Die aktuelle Abweichung zwischen Beobachtung und Vorhersage wird zeitlich extrapoliert. Der absolute Einfluß der aktuellen Korrektur auf zukünftige Prognosezeitpunkte nimmt mit der Zeit ab. Dieser Verlauf wird durch eine Strukturfunktion definiert, die die zeitliche Autokorrelation approximiert. Dieser Ansatz folgt einer Vorgehensweise nach Weingärtner (1987).

### 2.1.1 ALGORITHMUS

Die Beobachtungsabweichung ist definiert als die Differenz zwischen beobachtetem Element  $y_k^{OBS}(t_{OBS})$  und dem Vorhersagewert  $y_k^{MOD}(t_{OBS})$ .

$$\Delta y_k(i, t_{OBS}) = y_k^{OBS}(t_{OBS}) - y_k^{MOD}(i, t_{OBS}) \quad \text{Gl. 1}$$

Die Variablen in  $y_k^{MOD}(i, t)$  kennzeichnen den Prognosezeitpunkt ( $t$ ) sowie die Version nach der letzten Korrektur ( $i$ ). Verschiedene Bodenwetterelemente werden durch ( $k$ ) gekennzeichnet. Das Guidance-Inkrement ergibt sich aus der aktuellen Prognose korrigiert um einen Bruchteil der letzten Beobachtungsabweichung.

$$y_k^{MOD}(i+1, t) = y_k^{MOD}(i, t) + a_k(t - t_{OBS}) \cdot \Delta y_k(i, t_{OBS}) \quad \text{Gl. 2}$$

Der absolute Einfluß wird durch eine zeitabhängige Strukturfunktion  $a_k(t - t_{OBS})$  definiert.

### 2.1.2 PARAMETERWAHL

Für den Trainingsdatensatz wurden die Autokorrelationskoeffizienten der Vorhersagefehler zu einstündigen Prognoseschritten von 0 bis 6 h ermittelt. Die Werte sind in Abbildung 2 (links) durch Quadrate und gestrichelte Linie markiert. Die durchgezogene Linie zeigt die eingestellte Konfiguration. Zum Beobachtungszeitpunkt wird die Guidance durch die Beobachtung ersetzt. Die Extrapolation der Beobachtungskorrektur wurde gegenüber der Originalprognose verifiziert. Das Verifikationsmaß ist die reduzierte Varianz (RV). Das Ergebnis ist in Abbildung 2 (rechts) gezeigt.

$$RV = 1 - \left( \frac{rmse_{(REFERENZ+OBS\_KORREKTUR)}}{rmse_{(REFERENZ)}} \right)^2 \quad \text{Gl. 3}$$

Die beschriebene Korrektur beschränkt sich auf die ersten Stunden der Prognose im Bereich des Nowcasting. Die einfache Vorgehensweise führt zu einem konsistenten Übergang zwischen der Beobachtung und der ursprünglichen Prognose. Dies wird deutlich an dem kontinuierlichen Verlauf des RV-Masses zwischen der reinen Beobachtung zum Zeitpunkt t+0h gekennzeichnet durch RV=1 und dem Übergang in die originale Prognose mit RV=0. Dazwischen sind Verbesserungen durch die einfache Persistenz der Beobachtungskorrektur zu verzeichnen.

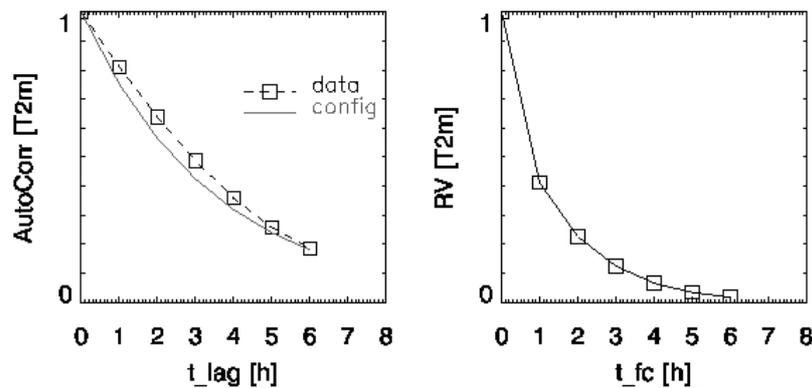


Abbildung 2: Autokorrelation des Beobachtungsfehlers (oben) und Verifikation der Beobachtungsextrapolation (unten). Die untersuchte Datenart ist MOS-MIX.

## 2.2 MODELLKOMBINATION

Die Modellkombination wird durch ein gewichtetes Mittel ausgedrückt. Der Ansatz ist allgemein formuliert, um eine Integration neuer Prognosedaten durch einfache Konfiguration eines Parametersatzes zu ermöglichen. Die Wahl der individuellen Gewichte reflektiert die relative Güte einer Prognose im Gesamtkollektiv. Viele Autoren haben den Nutzen von Modellensembles bereits dokumentiert (Palmer et al., 1992; Toth and Kalnay, 1993). Dies umfasst sowohl weitreichende Untersuchungen zur expliziten Wahl eines Ensembles als auch der Ableitung von deterministischen und probabilistischen Vorhersagen aus den Ensembleergebnissen. Für die operationelle Vorhersage haben verschiedene Untersuchungen den Vorteil von Modellkombination dokumentiert (Ziehmann, 2000, Balzer, 1995). In vielen Fällen kann bereits ein einfacher Mittelwert die einzelnen Prognosen übertreffen, falls jede individuelle Prognose unabhängige Information zum Gesamtensemble hinzufügt. Vor dem Hintergrund dieser Erfahrungen soll eine robuste und flexible Infrastruktur aufgebaut werden, die eine optimale Kombination der Vielzahl von Prognosedaten durch ein gewichtetes Mittel ermöglicht.

### 2.2.1 ALGORITHMUS

Der prognostizierte Wert eines Modells wird beschrieben mit  $z_k^m(t_0, t)$ , wobei (m) das entsprechende Modell kennzeichnet. Eine gewichtete Modellkombination  $y_k^{OOG}(t_0, t)$  lässt sich dann darstellen als

$$y_k^{OOG}(t_0, t) = \frac{\sum_m w_k^m(t) \cdot z_k^m(t_0, t)}{\sum_m w_k^m(t)}. \quad \text{Gl. 4}$$

Die zwei Zeitvariablen kennzeichnen den Zeitpunkt der Modellinitialisierung ( $t_0$ ) und den aktuellen Prognoseschritt ( $t$ ). Die Gewichte  $w_k^m(t)$  werden durch zeitabhängige Ratingfunktionen repräsentiert, die den individuellen Einfluß eines Modells ausdrücken.

## 2.2.2 PARAMETERWAHL DURCH EXPECTATION MAXIMIZATION

Ein allgemein akzeptierter Ansatz zur Bestimmung einer optimalen Kombination stammt aus der Ensemblevorhersage basierend auf einer Bayesian Interpretation der Fehlercharakteristik der individuellen Prognosedaten. Im Folgenden wird eine kurze Beschreibung des ‘‘Bayesian Model Averaging’’ (BMA) gegeben. Die Darstellung folgt der Dokumentation in Raftery *et al.* (2003). Der Ausgangspunkt dieser Betrachtungsweise ist das Wissen, daß es stets ein ‘‘bestes’’ Modell gibt, das sich allerdings nicht im Voraus identifizieren läßt. Sehr wohl läßt sich dagegen die Unsicherheit über die Wahl des ‘‘besten’’ Modells quantifizieren. Dies wird durch die Modellkombination ausgedrückt. Die Wahrscheinlichkeit einen Beobachtungswert ( $y$ ) mit einem Satz von Modellen ( $k$ ) auf der Grundlage eines Trainingsdatensatzes ( $y^T$ ) vorauszusagen, wird beschrieben durch

$$p(y) = \sum_k p(y | f_k) \cdot p(f_k | y^T). \quad \text{Gl. 5}$$

Die sogenannte Posterior-Wahrscheinlichkeit für ein Modell ( $f_k$ ) aus einem Trainingsdatensatz ( $y^T$ ) werden als Gewichte der Modellkombination betrachtet.

$$w_k = p(f_k | y^T) \quad \text{Gl. 6}$$

Der bedingte Erwartungswert für eine Vorhersage des Beobachtungswertes ( $y$ ) wird nun als gewichtetes Mittel aller Modelle betrachtet. Die Gewichte sind identisch zur beschriebenen Posterior-Wahrscheinlichkeit.

$$E[y | f_1, f_2, \dots, f_k] = \sum_k w_k \cdot f_k \quad \text{Gl. 7}$$

Das numerische Lösungsverfahren zur Ableitung der Gewichte ist die sogenannte Expectation-Maximization (EM). Für die betrachteten Trainingsdaten wurden exemplarisch die Gewichte für ein Modelmix aus MOS-MIX und LM-DMO abgeleitet. In Abbildung 3 (links) sind zunächst die Standardabweichungen für verschiedene Prognoseschritte und beide Modelle gezeigt. Der Algorithmus geht von einer Initialkombination aus, die beide Modelle gleich gewichtet. Die resultierende Gewichtung nach der iterativen Lösung des EM-Algorithmus ist in Abbildung 3 (rechts) gezeigt. Die Modelle sind durch verschiedene Linientypen markiert (durchgezogen: MOS-MIX, gestrichelt: LM-DMO).

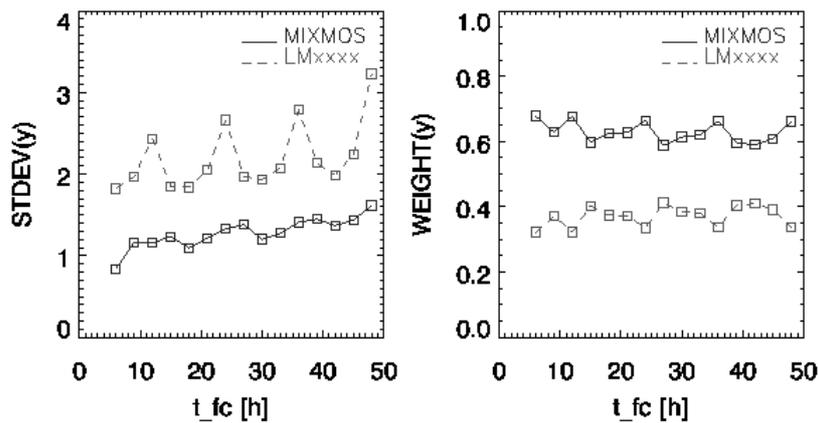


Abbildung 3: Resultierende Gewichte für eine Modellkombination aus MOS-MIX und LM-DMO. Das betrachtete Element ist T2m. Es wurden Gewichte für die Prognosetermine von t+6 bis t+48h ermittelt.

### 3 TECHNISCHE UMSETZUNG

Das Verfahren „Objektive Optimierung“ zur Ableitung der Objektiv Optimierten Guidance (OOG) wird unmittelbar in die meteorologische Workstation „NinJo“ des DWD integriert. NinJo ist ein Visualisierungssystem für Beobachtungs- und Vorhersagedaten, das zukünftig den gesamten Prozeß der Wettervorhersage im DWD unterstützen wird (Koppert, 1993). Aktuelle Entwicklungen führen darüberhinaus zu Erweiterungen, um Daten zu überwachen, zu editieren oder Vorhersagen neu zu erzeugen. Die gesamte Implementierung erfolgt in Java. Die unmittelbare Integration in NinJo ermöglicht einen schnellen Zugang zu allen relevanten Datentypen über standardisierte Schnittstellen. Gleichzeitig steht auch die resultierende Guidance zur Visualisierung sowie weiteren Anschlußverfahren unmittelbar zur Verfügung. Abbildung 4 demonstriert die Interaktion der Objektiven Optimierung mit anderen NinJo-Komponenten, die in der Abbildung durch blauen Hintergrund unterlegt sind. Geplante Datenflüsse werden dort durch geklammerte Ausdrücke visualisiert. Die Objektive Optimierung soll neu eintreffende Beobachtungen, Prognosen und Nowcastingprodukte kontinuierlich einarbeiten. Die Berechnung einer OOG wird durch den OOG-Control-Prozeß gesteuert, der in bestimmten Zeitabständen die OOG-Calculation-Komponente benachrichtigt, um eine neue Berechnung auszulösen.

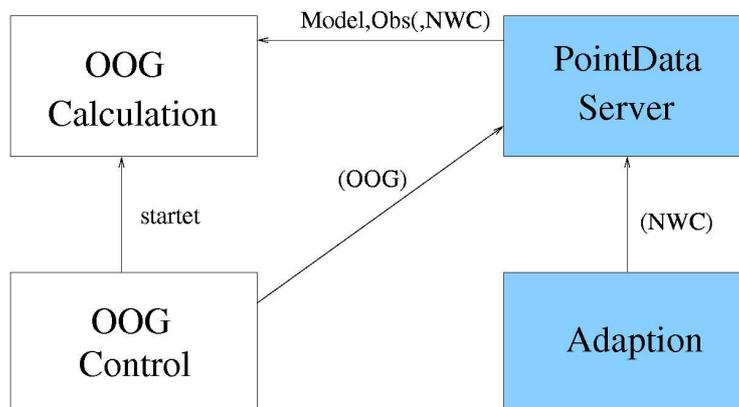


Abbildung 4: Einbettung der Objektiven Optimierung in die meteorologische Workstation NinJo.

Die OOG-Calculation-Komponente liest dafür Modell- und Beobachtungsdaten aus der Datenbasis. Zukünftig werden alle Beobachtungsinformationen und Punktterminprognosen vom Punktdatenserver verwaltet. Die Verarbeitung weiterer Datentypen ist geplant. Die Nowcasting-Daten, die sich meist auf Fernerkundungsdaten stützen, sollen dabei durch ein separates Adaptionmodul, das nicht Bestandteil der Objektiven Optimierung ist, als Punktvorhersagen bereitgestellt werden.

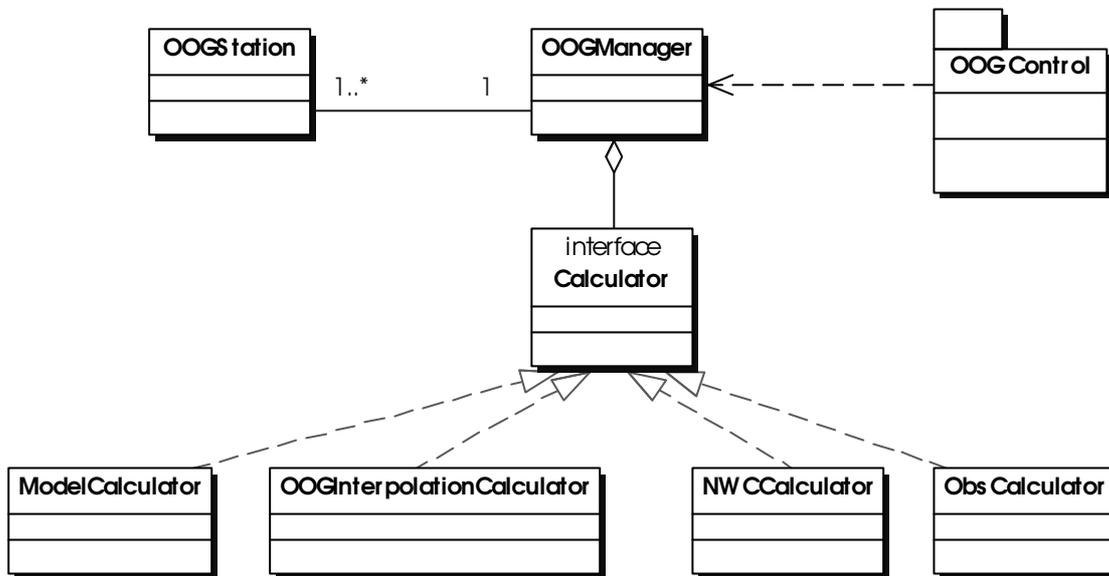


Abbildung 5: Klassendiagramm des Rechenkerns der Objektiven Optimierung.

Der OOG-Manager verwaltet alle Stationen, die in der Optimierung berücksichtigt werden. Die eigentliche Berechnung der OOG erfolgt in den Calculator-Klassen (Abbildung 5). Für jede Berechnungsart existiert eine eigene Calculator-Klasse. Der ModelCalculator realisiert die Modellkombination, der ObsCalculator rechnet Beobachtungen (siehe Abschnitt 2.1.1) und der NWCCalculator die Nowcasting-Daten in die OOG ein. Wenn eine Station für bestimmte meteorologische Elemente keine Beobachtungen besitzt, können Beobachtungen benachbarter Stationen durch eine Interpolation benachbarter Korrekturen berücksichtigt werden, wofür der OOGInterpolationCalculator zuständig ist. Die technische Umsetzung des Interpolationsnetzes wird im folgenden Abschnitt genauer dargestellt.

### 3.1 BERECHNUNG DES ABHÄNGIGKEITSNETZES

Falls für eine Station keine Beobachtungen existieren, werden die durch die Beobachtung verursachten OOG-Korrekturen benachbarter Stationen verwendet. Beim Systemstart wird dazu ein Abhängigkeitsnetz berechnet, welches als gerichteter Graph repräsentiert wird. Die Knoten entsprechen den Stationen, während die Kanten den Informationsfluss beschreiben. Abbildung 6 illustriert den Einfluß der OOG-Korrektur von Quellstation  $q$ , um eventuell fehlende Beobachtungen der Zielstation  $z$  zu ersetzen. Die Abbildung beschränkt sich auf die Darstellung einer Kante innerhalb des Abhängigkeitsnetzes. Das gesamte Netz berücksichtigt prinzipiell mehrere benachbarte Stationen. Einer Kante ist ein Gewicht zugeordnet, das den Einfluß der OOG-Korrektur von Station  $q$  auf Station  $z$  beschreibt. Die individuellen Gewichte sind abhängig von Entfernung, Höhenunterschied und Oberflächenbeschaffenheit. Die konkrete Ableitung der Gewichte folgt einem Ansatz zur Interpolation der statistischen Koeffizienten an sogenannten MOS-Interpolationsstationen (Haalman, 2003).

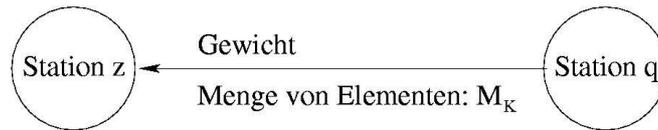


Abbildung 6: Illustration der Stationsabhängigkeit zur Beobachtungskorrektur.

Weiterhin enthält eine Kante die Menge aller meteorologischen Elemente, für die Interpolationen angewandt werden sollen. Für die Nachbarschaftssuche existieren elementabhängige Radien. So kann zum Beispiel eine Station von der Temperaturkorrektur einer Nachbarstation abhängen, nicht aber deren Niederschlagsinformation verwenden. Zu einem Zeitpunkt werden an Station z die Menge der meteorologischen Elemente  $M_z$  und an Station q  $M_q$  beobachtet. Die Menge der an der Kante stehenden Elemente sei  $M_k$ . Dann ergibt sich die Menge der zu übertragenden Elemente mit  $M_t = (M_q \setminus M_z) \cap M_k$ . Das sind alle Elemente, die von Station q, aber nicht von Station z beobachtet werden und gleichzeitig durch die Kante übertragbar sind. Dabei ist lediglich  $M_k$  beim Aufbau des Netzes bekannt. Die Mengen  $M_q$  und  $M_z$  der an den Stationen q und z beobachteten Elemente werden zu jedem Aktualisierungszeitpunkt neu ermittelt. Diese Mengen werden durch BitSets (java.lang.BitSet) repräsentiert, um eine möglichst performante Bearbeitung zu garantieren.

### 3.2 VISUALISIERUNG

Die berechneten OOG-Werte können in einer hierarchischen Baumstruktur visualisiert werden (Abbildung 7). Auf der obersten Ebene entscheidet man, welche Station angezeigt werden soll.

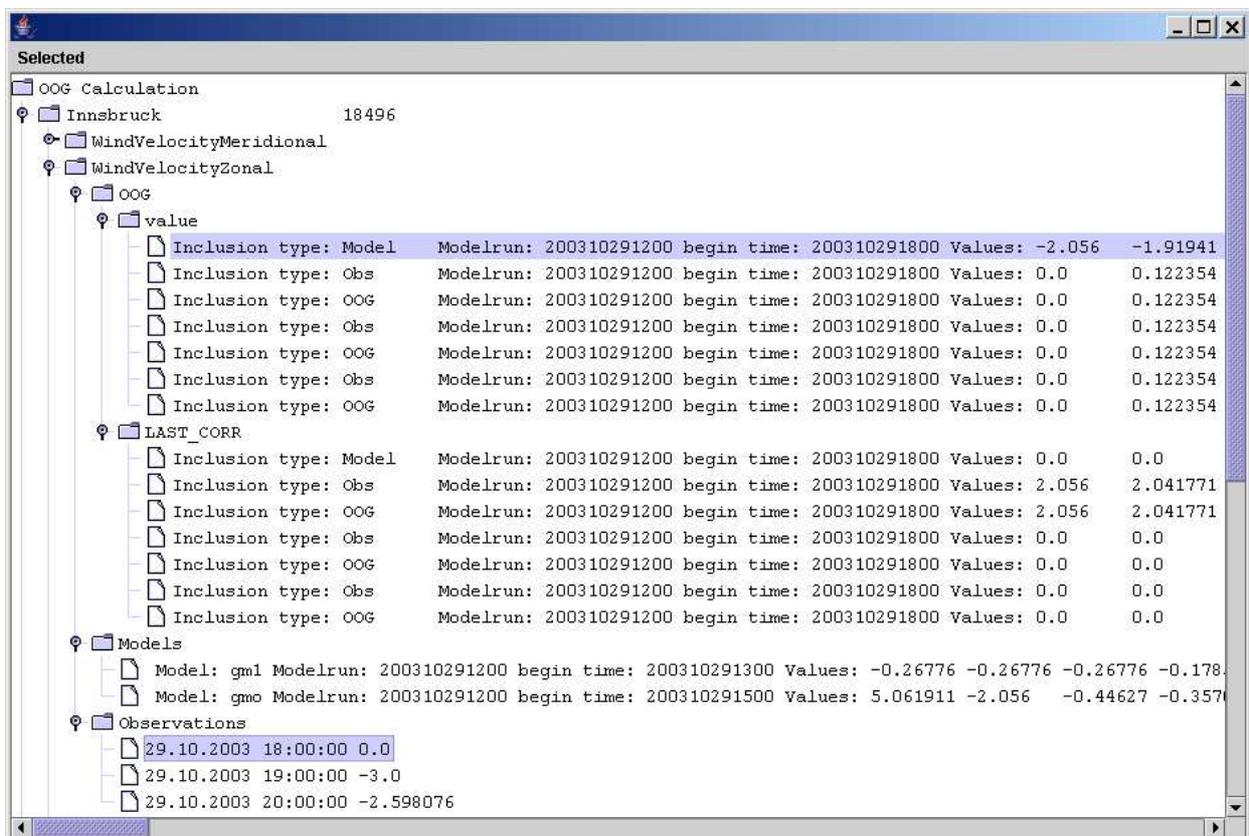


Abbildung 7: Baumdarstellung der OOG-Berechnung.

Auf der nächsten Ebene wählt man das meteorologische Element aus (z.B. zonale Windkomponente). Anschließend muss noch der Datentyp (Modell, Beobachtung oder OOG) festgelegt werden. Zusätzlich können unter dem Datentyp OOG die Korrekturen der einzelnen Berechnungen angezeigt werden. Es besteht weiterhin die Möglichkeit, die angezeigten Zahlenreihen in Listen zu exportieren, um eine detaillierte Verifikation zu unterstützen. Beispielhaft sind in Abbildung 8 zwei Prognoseverläufe gezeigt, die sich durch die Einarbeitung einer Beobachtung unterscheiden.

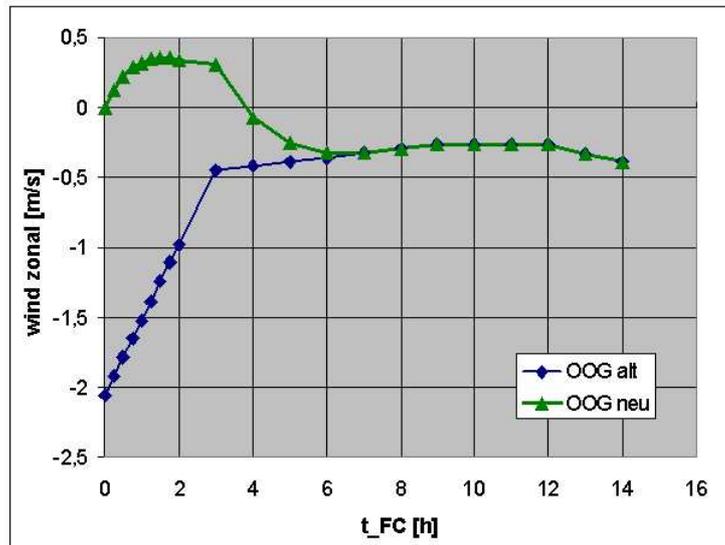


Abbildung 8: Einfluß der Beobachtungskorrektur zwischen aufeinanderfolgenden Korrekturen einer Punktprognose.

#### 4 ZUSAMMENFASSUNG

Der DWD entwickelt zur Zeit ein Verfahren „Objektive Optimierung“, das durch automatische Integration verschiedenster Beobachtungs- und Prognosedaten den Prozeß der lokalen Wettervorhersage unterstützen soll. Die Entwicklung konzentriert sich zunächst auf die Kombination von Prognosedaten und deren kontinuierliche Aktualisierung anhand neuester Beobachtungen. Die einfache zeitliche Extrapolation von Beobachtungskorrekturen bietet ein robustes Verfahren, um den gewünschten konsistenten Übergang zwischen der letzten Beobachtung und der Prognose zu gewährleisten. Die Verifikation einer prototypischen Anwendung läßt auf leichte Güteverbesserung im Übergangsbereich schließen. Für die Modellkombination wurde ein Verfahren implementiert, um ausgehend von einem Expectation-Maximization-Algorithmus individuelle Gewichte für einen Satz unterschiedlicher Modellprognosen abzuleiten. Das Verfahren „Objektive Optimierung“ wird in den neuen meteorologischen Arbeitsplatz „NinJo“ des DWD integriert. Eine erste Implementierung in NinJo liegt vor. Es ist geplant, die Objektive Optimierung auf weitere Bodenwetterelemente sowie auf Nowcastingdaten als unabhängige Prognosedaten zu erweitern. Eine Qualitätskontrolle und die Möglichkeit zur Korrektur durch den Meteorologen sollte die abschließende Instanz im Prozeß der lokalen Wettervorhersage darstellen.

#### DANKSAGUNG

Wir danken Kristine Schaal, Carsten Ehbrecht und dem NinJo-Projektteam für die Unterstützung bei konzeptionellen und technischen Problemstellungen.

## LITERATUR

- Balzer, K. (1995). Automatische Wettervorhersage mittels statistischer Interpretation. *Promet*, 24, 110-118.
- Doms, G. und Schättler, U. (1999). The Nonhydrostatic Limited-Area Model LM (Lokal-Modell) of DWD - Part I: *Scientific Documentation*., Deutscher Wetterdienst, Offenbach a. Main, January 1999, 134 pp.
- Doms, G. und Förstner, J., (2004). Development of a Kilometer-Scale NWP-System: LMK. *COSMO Newsletter*, No. 4, 159-167.
- EUMETSAT (1998). SAF Training Workshop – Nowcasting and Very Short Range Forecasting, *Proceedings*, EUMETSAT, Darmstadt, Germany, ISBN 92-9110-030-7, EUM P 25, 228 pp.
- Fraedrich, K., Leslie, L.M. (1987). Combining Predictive Schemes in Short-Term Forecasting., *Monthly Weather Review*, 115, 1640-1644.
- Glahn, H. R. und Lowry, D. (1972). The Use of Model Output Statistics (MOS) in Objective Weather Forecasting., *Journal of Applied Meteorology*, 11, 1203-1211.
- Haalman, D. (2003). MOS-MIX: Integrated statistical interpretation of multiple numerical models, *Sixth European Conference on Application of Meteorology, ECAM 2003*, Rome.
- Koppert, H. J. (2003). NinJo - The Current Status of the project, *14<sup>th</sup> Meeting of European Working Group on Operational Workstations (EGOWS)* , Tromsø 2003.
- Landry, C., Quellet, M., Parent, R. und Verret, R. (2003). Assimilation of observation data into SCRIBE., *19th International Conference on Interactive Information Processing Systems (IIPS) for Meteorology, Oceanography, and Hydrology*, 2003 AMS Annual Meeting, 9–13 February 2003.
- Majewski, D., Liermann, D., Prohl, P., Ritter, B., Buchhold, M., Hanisch, T., Paul, G., Wergen, W. und Baumgardner, J. (2002). The operational global icosahedral-hexagonal grid point model GME: Description and high resolution tests., *Mon. Wea. Rev.*, 130, 319-338.
- Palmer, T., Molteni, F., Mureau, R., Buizza, R., Chapelet, P. und Tribbia, J. (1992). Ensemble prediction. *Technical Report, Research Department Tech. Memo*, 188, Available from ECMWF, Shinfield Park, Reading RG2 9AX, UK.
- Raftery, A.E., Balabdou, F., Gneiting, T. und Polakowsky, M. (2003). Using Bayesian Model Averaging to Calibrate Forecast Ensembles, *Technical Report no. 440, Department of Statistics University of Washington*, December 15, 2003, 28 pp.
- Toth, Z. und Kalnay, E. (1993). Ensemble forecasting at NMC: The generation of perturbations., *Bull. Am Meteorol. Soc.*, 74, 2317-2330.
- Vislocky, R. L. und Fritsch, J. M. (1997). An Automated, Observations-Based System for Short-Term Prediction of Ceiling and Visibility., *Weather and Forecasting*, 12, 31-43.
- Weingärtner, H. (1987). Zur Bestimmung einer charakteristischen Zeitskala im Macro- und Mesoscale., *Meteorologische Rundschau*, 40, 1-6.
- Winkler, R. L. (1989). Combining Forecasts: A philosophical basis and some current issues, *International Journal of Forecasting*, 5, 605-609.
- Ziehmann, C. (2000). Comparison of a single-model EPS with a multi model ensemble consisting of a few operational models., *Tellus*, 52A, 280-299.