

Abschlussbericht

Adaptives Windleistungsprognosesystem für Windenergieanlagen

Autoren:

Dr.-Ing. B. Thinius
TOSS GmbH, Potsdam

Mathematische Beratung:

Dr. H. Schachtzabel, WiSenT GmbH
Dr. V. Ahlers, WiSenT GmbH
Prof. Dr. M. Holschneider, Universität Potsdam
Prof. Dr. H. Läuter, Universität Potsdam
Prof. Dr. T. Schaub, Universität Potsdam

Anteilig gefördert durch das Bundesministerium für Wirtschaft und Arbeit
„Förderung von Forschung, Entwicklung und Innovation in kleinen und
mittleren Unternehmen und externen Industrieforschungseinrichtungen in
den neuen Bundesländern“

Juli 2003

Inhaltsverzeichnis

1. Einleitung	3
1.1 Zielstellung	3
1.2 Datengrundlage	3
1.3 Methodisches Vorgehen.....	3
2 Statistische Datenanalysen	6
2.1 Nutzung des gesamten Datensatzes	6
2.2 Gruppierung von Daten.....	6
3 Waveletbasierte Multiskalenanalyse	8
3.1 Vorbemerkungen.....	8
3.2 Kreuzkorrelation im Wavelet-Raum.....	9
4 Neuronale Netze	11
4.1 Vorbemerkungen.....	11
4.2 Lernphase.....	11
4.2.1 Prinzipielles Vorgehen	11
4.2.2 Wichtige Fakten der Modellentwicklung	12
4.2.3 Datenauswahl	14
4.3 Wesentliche Ergebnisse	14
5 Kalman-Filter	16
5.1 Optimalfilter.....	16
5.2 Ergebnisse.....	16
5.3 Verwendete Zustandsraummodelle.....	16
5.4 Vorhersage des Luftdrucks	17
5.4.1 Vorhersage der Windgeschwindigkeit	19
5.5 Fazit.....	21
6 Zukünftige Entwicklungen	21
7 Literatur	22

1. Einleitung

1.1 Zielstellung

Durch die nicht kontinuierliche und dezentrale Einspeisung der von Windenergieanlagen erzeugten Energie in die Versorgungsnetze ergeben sich Probleme für das Lastmanagement der Energieversorgungsunternehmen, den Windstrom bei der Kraftwerksplanung einzusetzen. Lang- und mittelfristige Schwankungen können entweder aus ihrem bekannten Verhalten (z.B. Sonnenstand) oder aus Wettervorhersagen rechtzeitig prognostiziert werden. Die kurzfristigen Schwankungen im Stunden- und Minutenbereich sind dagegen als Zufallsprozess¹ aufzufassen. Eine Vorhersage von kurzfristigen Fluktuationen der Windgeschwindigkeit ist damit nur unter Einbeziehung zusätzlicher Informationen realisierbar.

An das zu entwickelnde Prognosesystem werden folgende Anforderungen gestellt

- es soll ausschließlich auf lokal erfassten Wetterdaten basieren und
- sich auf der Grundlage des ständig vergrößernden Datenpools immer besser an die konkrete Situation anpassen (Systemadaption).

1.2 Datengrundlage

Grundlage für alle Untersuchungen bilden Wettermessdaten, die in den Wetterstationen Bork, Schönberg, Heringsdorf und Fehmarn gemessen wurden. Die ersten verfügbaren Daten wurden im Herbst 1999 erhoben. Von diesem Zeitpunkt an werden in jeder Wetterstation die nachfolgend aufgelisteten Größen im Abstand von 15 min aufgenommen: Lufttemperatur, relative Luftfeuchte, Windgeschwindigkeit, Windmaximum, Windrichtung, Beleuchtungsstärke, Luftdruck, Verdunstung (Haude), absolute Luftfeuchte, Änderung der absoluten Luftfeuchte.

1.3 Methodisches Vorgehen

Die angestrebte Verbesserung des Prognosesystems über den sich ständig erweiternden Datenpool präjudiziert den Einsatz von künstlichen neuronalen Netzen bzw. von Entscheidungsbäumen². Neben der Topologie und der Lernstrategien der eingesetzten neuronalen Netze spielt die Bereitstellung geeigneter Trainingsdaten eine zentrale Rolle für den Erfolg dieser Methode.

In einem ersten Schritt wurden das Datenmaterial mit verschiedenen statistischen beschreibenden Analyseverfahren untersucht

- Histogramme, Clusteranalyse, Faktoranalyse und Darstellung über Andrews-Funktion
- Semiparametrische lineare bzw. additive Modelle
- Parametrische lineare Modelle mit einigen Wechselwirkungstermen
- Multivariante Varianzanalyse
- Diskriminanzanalyse

Da sich die Fluktuationen der Windgeschwindigkeit an einem Ort aus verschiedenen Frequenzen zusammensetzen (vgl. HANDWERKER93, S. 8) und diese Frequenzen

¹ Diese Prozesse besitzen kein Gedächtnis. Wird die Windgeschwindigkeit allein betrachtet, dann hängt deren zukünftige Entwicklung nicht von der Vergangenheit ab.

² Solche Ansätze sind aus der Literatur bereits bekannt, vgl. z.B. MÜLLER99 oder HANDWERKER93. Entscheidungsbäume und neuronale Netze liefern in den meisten Anwendungen vergleichbare Ergebnisse.

selbst wiederum einen eigenen Zeitgang besitzen, wurden zur Analyse dieser komplexen Zusammenhänge Multiskalentechniken (Wavelets) eingesetzt.

Kalman-Filtertechniken und State-Base-Modelling stellen einen modernen, völlig anders gearteten Ansatz zur Vorhersage der Windgeschwindigkeit dar.

Aufsetzend auf diesen Techniken wurden die in Abbildung 1 dargestellten mathematischen Prognosemodule entwickelt, implementiert und in umfangreichen Tests mit dem im Punkt 1.2 beschriebenen Datenmaterial auf ihre Leistungsfähigkeit untersucht.

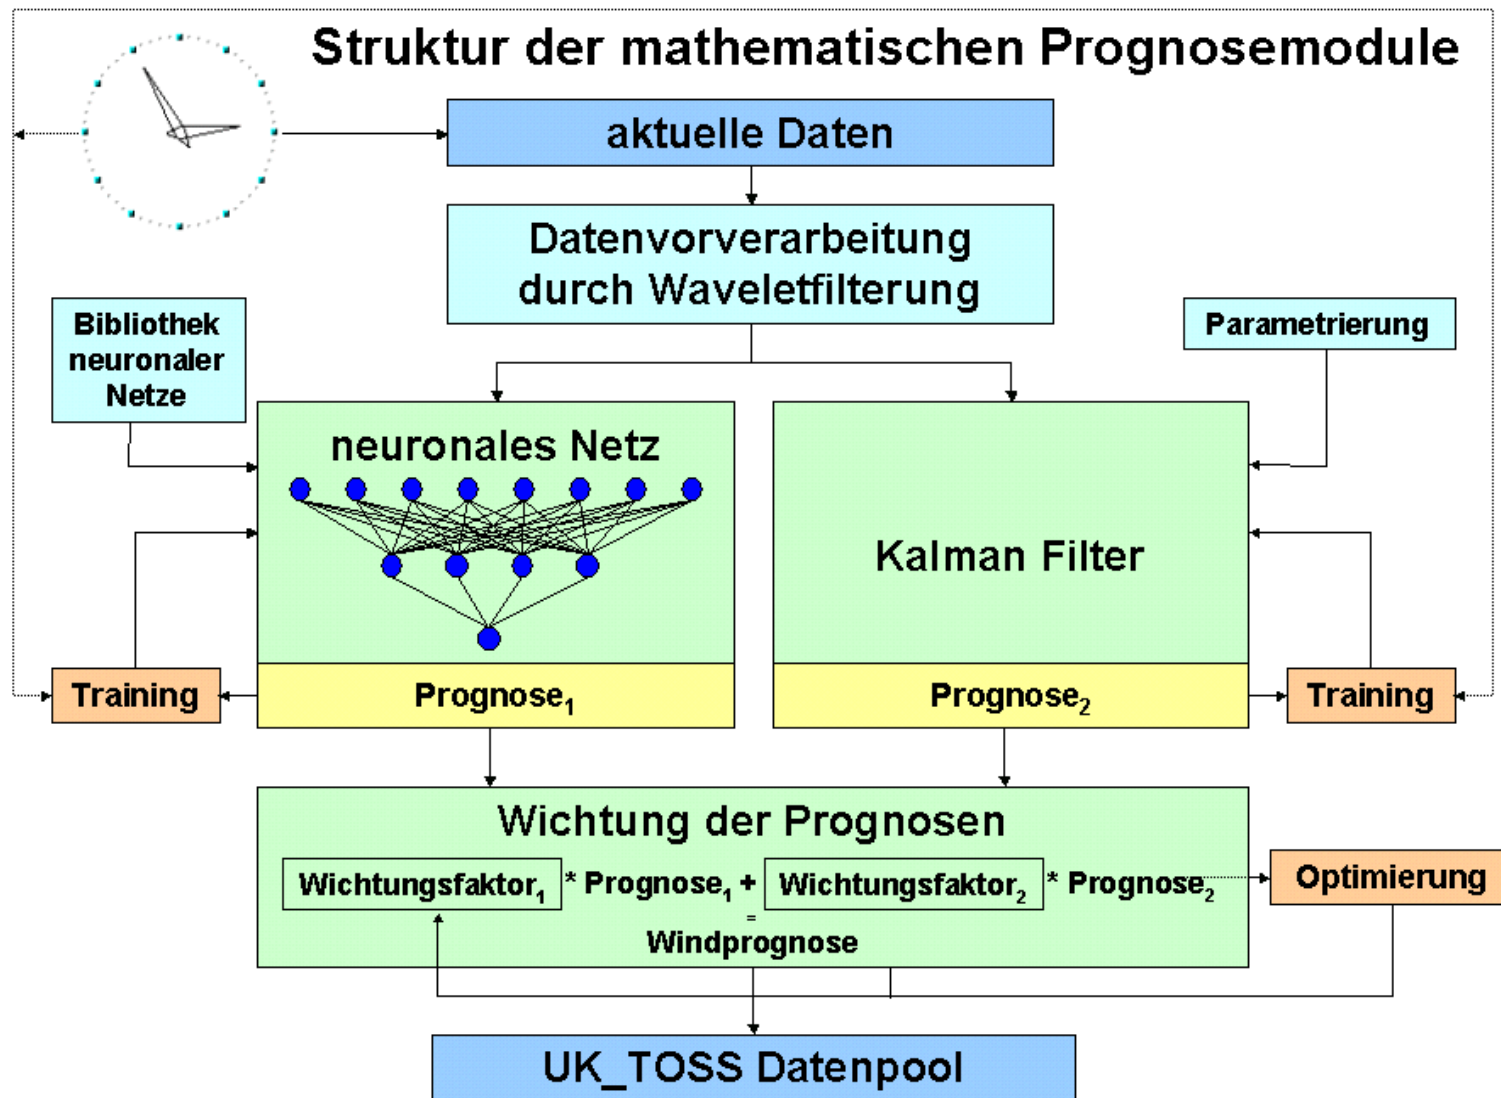


Abb. 1: Struktur des adaptiven Prognosemodells

2 Statistische Datenanalysen

2.1 Nutzung des gesamten Datensatzes

Gesucht wurde nach einem Zusammenhang zwischen der Windgeschwindigkeit und den Parametern Lufttemperatur, relative Luftfeuchte, Luftdruck, Beleuchtungsstärke und Windrichtung. Dabei wurden die statistischen Untersuchungen mit den kompletten Datensätzen (alle verfügbaren Daten in den Zeitreihen) durchgeführt.

Im Ergebnis dieser umfangreichen Analysen kann festgestellt werden, dass mit keiner der eingesetzten Methoden

- Histogramme, Clusteranalyse, Faktoranalyse und Darstellung über Andrews-Funktion
- semiparametrische lineare bzw. additive Modelle
- parametrische lineare Modelle mit einigen Wechselwirkungstermen

ein kausaler Zusammenhang zwischen der Windstärke und den anderen o.g. Parametern ermittelt werden konnte. Bei der Nutzung des gesamten Datensatzes³ ist die Streuung der Daten offenbar zu groß.

2.2 Gruppierung von Daten

Aus meteorologischen Gründen ist sinnvoll, insbesondere solche Daten miteinander zu vergleichen, die sich bezüglich der lang- und mittelfristigen Fluktuationen im gleichen Bereichen befinden

- Jahreszeitscheiben (Frühjahr, Sommer, Herbst, Winter oder feinere Aufteilung)
- Tageszeitscheiben (6 bis 9 Uhr, 9 bis 12 Uhr, ...)

Bei dieser Vorgehensweise sind Witterungsverhältnisse zu erwarten, die homogener als das komplette Ensemble sind und damit vorhandene Zusammenhänge in den Teil-)Zeitreihen erkennbar werden.

Als Methodik wurde die multivariate Varianzanalyse und Diskriminanzanalyse eingesetzt. Diese Verfahrensklasse hat sich besten bei der statistischen Analyse von komplexen medizinischen, technischen, biologischen und anderen naturwissenschaftlichen Problemstellungen bewährt. Die Vorzüge dieser multivariaten Verfahren bestehen darin, dass

- Wechselwirkungen zwischen den einbezogenen Parametern erkannt werden,
- die Existenz signifikanter Zusammenhänge geprüft werden kann,
- konstruktiv die als existent erkannten kausalen Zusammenhänge bestimmt werden können,
- häufig eine Reduktion der Dimensionen derart vorgenommen werden kann, dass graphische Darstellungen die Ergebnisse untermauern können und so besser motiviert sind.

Das Ergebnis der Analysen ist die Angabe von Bedingungen der messbaren Parameter unter denen die Zielvariablen (hier nur die Windgeschwindigkeit) mit hoher Wahrscheinlichkeit Werte aus gegebenen Intervallen⁴ annimmt.

³ Im Sinne des Multiskalenansatzes werden die relativ gut interpretierbaren niedrigen Frequenzen (mittel- und langfristige Fluktuationen) durch die kurzfristigen Einflüsse zeitabhängig gestört.

⁴ Es wird damit der punktweise Zusammenhang zwischen den Zielgrößen und den anderen Parametern aufgegeben. Die etwas vergrößerte Relation zwischen Zielgrößen und messbaren Parametern ist

Für die Untersuchungen wurden die Daten monatsweise und in Zeitscheiben von jeweils 3 Stunden analysiert. Als Intervalle für die Windgeschwindigkeit wurden diejenigen mit den Endpunkten

0; 1,505; 3,01; 4,515; 6,02; 6,03; 10,535; 15,05

gewählt.

Die Ergebnisse der durchgeführten Untersuchungen lassen sich allgemein wie folgt formulieren

1. Es ist statistisch gesichert, dass ein kausaler Zusammenhang zwischen der Windstärke und den fünf Parametern *Lufttemperatur, relative Luftfeuchte, Luftdruck, Beleuchtungsstärke, Verdunstung, Änderung der absoluten Luftfeuchte* existiert.
2. Eine Dimensionserniedrigung von fünf auf zwei ist gut begründet. Das ergibt sich aus der Berechnung der nichtelementaren Diskriminanzfunktionen, die sich aus einem Eigenwertproblem herleiten. Es ergeben sich bei der untersuchten Problemstellung Eigenwerte, die größenordnungsweise unterschiedlich sind. Ein oder zwei Eigenwerte sind meist wesentlich größer als die restlichen. Das ermöglicht eine graphische Veranschaulichung.
3. Den größten Einfluss haben die *Lufttemperatur, die Verdunstung* und die *Änderung der absoluten Luftfeuchte*.
4. Die Andrews-Funktionen liefern für diese Aufgabenstellung keine hinreichend sicheren Ergebnisse. Das steht im Widerspruch zu vielen unserer bisherigen Erfahrungen. Damit wird der Fakt unterstrichen, dass komplexe Wechselwirkungen⁵ zwischen den Parametern existieren, die nicht vernachlässigt werden können.

dem Sachverhalt der Windgeschwindigkeitsprognose durchaus angemessen, da eine punktuelle Vorhersage a priori eine nicht vorhandene Präzision vortäuscht.

⁵ Zur Beschreibung dieser Zusammenhänge konnten wir in der Literatur keine Hinweise finden. Dieses Problem konnte im Rahmen der Projektbearbeitung nicht gelöst werden.

3 Waveletbasierte Multiskalenanalyse

3.1 Vorbemerkungen

Eine Vielzahl von technischen Prozessen und natürlichen Abläufen ist durch instationäre Spektren charakterisiert. Mit der klassischen Fouriertransformation können diese Phänomene nicht adäquat erfasst und beschrieben werden.

Durch die Waveletanalyse werden Zeitreihen im Zeit-Frequenz-Raum zerlegt. Mit ihr ist es möglich, die Variabilität des Spektrums in der Zeit zu erfassen (Abb. 2). Daraus lassen sich dann dominante Zeitskalen ableiten, die häufig für physikalische Interpretationen relevant sind. Bezüglich der Details sei auf die umfangreiche Spezialliteratur verwiesen (z. B. LOUIS&MAAB&RIEDER97 und TORRENCE&COMPO98).

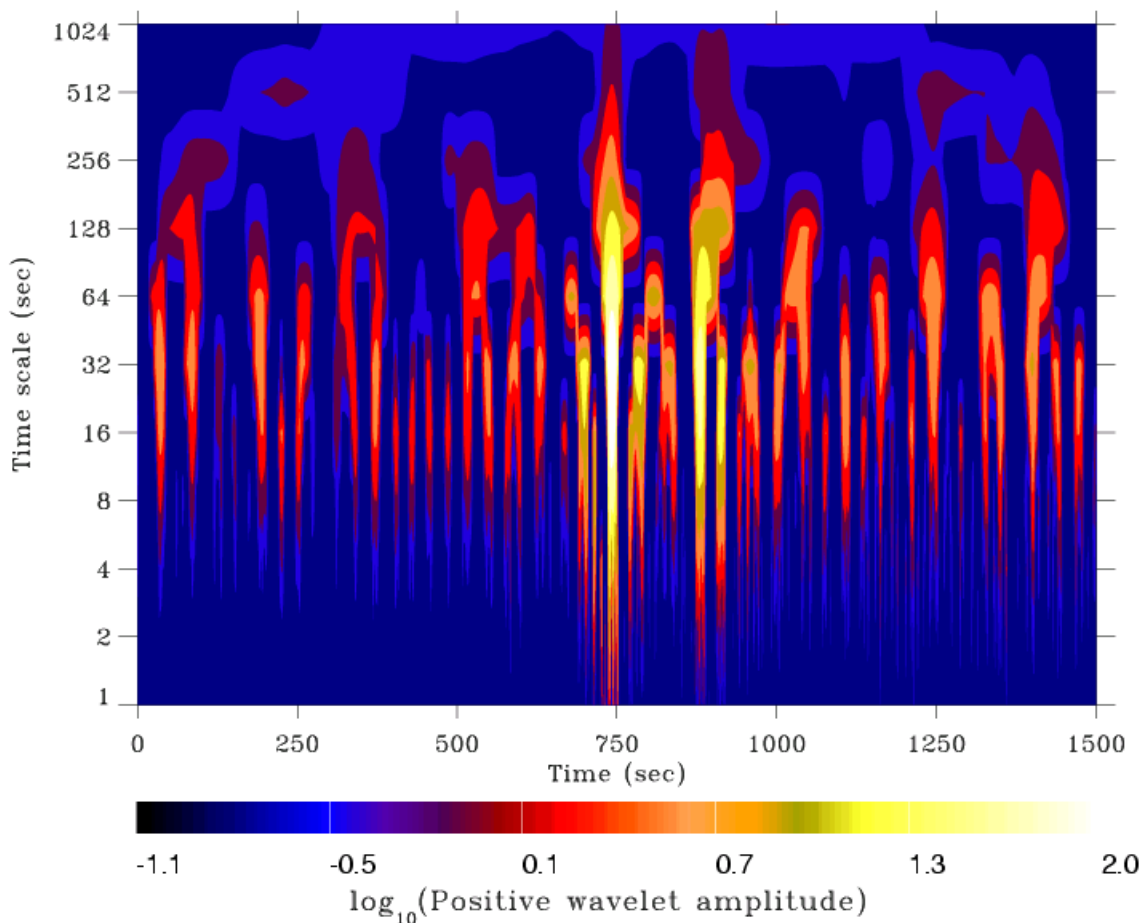


Abb. 2: Beispiel für die Waveletanalyse einer Zeitreihe mit instationärem Spektrum
Die zeitliche Variabilität des Einflusses einer Frequenz wird längs eines horizontalen Schnittes sichtbar.

Sowohl die zeitlichen Entwicklungen der (lokalen) Windgeschwindigkeit als auch der anderen, im Abschnitt 1.2 benannten klimatischen Kenngrößen zeigen ebenfalls instationäre Spektren. In Abb. 3 (b) und (d) wird deutlich sichtbar, wie sich die Skalenenergie in der Zeit verändert.

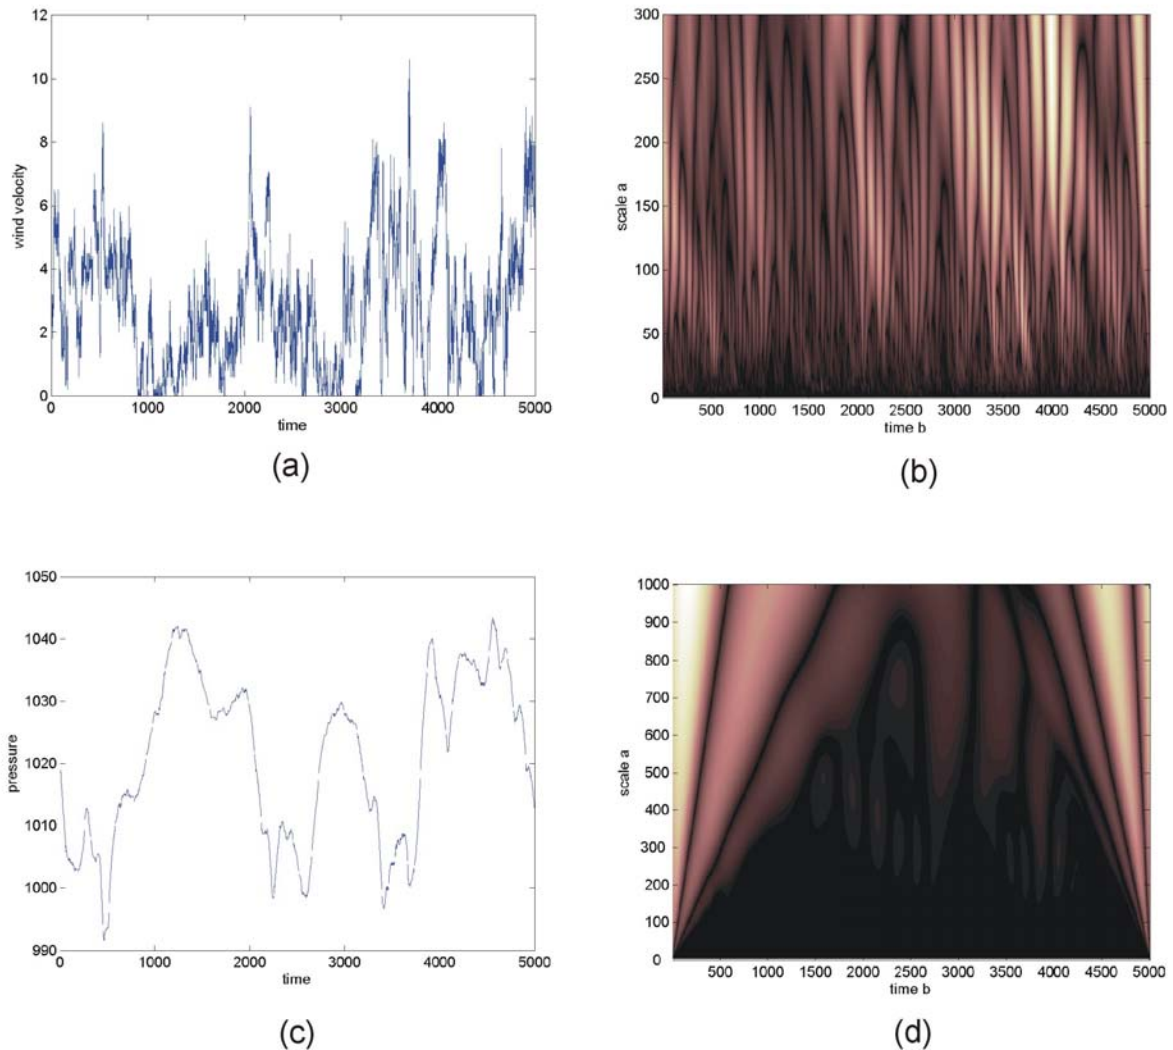


Abb. 3: Kontinuierliche Wavelet-Transformation mit dem Daubechies-4-Wavelet.
(a) Zeitreihe *Windgeschwindigkeit* an der Station Schönberg (ein Zeitschritt entspricht 25 min)
(b) Wavlettransformation der Zeitreihe *Windgeschwindigkeit*
(c) Zeitreihe *Luftdruck* an der Station Schönberg (ein Zeitschritt entspricht 25 min)
(d) Wavlettransformation der Zeitreihe *Luftdruck*

3.2 Kreuzkorrelation im Wavelet-Raum⁶

Grob gesprochen wird, wie in Abb. 3 dargestellt, durch die Multiskalenanalyse einer Zeitreihe die zeitliche Entwicklung der Anteile in den Frequenzbändern (Skalen-Energie-Verteilung) bestimmt. Aus dieser Zerlegung resultiert der Ansatz, für die Prognose der Windgeschwindigkeit nur solche Frequenzen einzusetzen, die sowohl in der Zeitreihe ‚Windgeschwindigkeit‘ als auch in den anderen klimatischen Messgrößen (vgl. Abschnitt 1.2).

⁶ Die Multiskalenanalyse und die anschließenden Berechnungen der Kreuzkorrelationen wurden mit einem in der Arbeitsgruppe von Herrn Prof. Dr. M. Holschneider entwickelten Programmsystem durchgeführt.

Zur Lösung dieser Aufgabenstellung steht mit der Kreuzkorrelation (bzgl. der Details sei auf STIER01 verwiesen) eine leistungsfähige und erprobte Methode zur Verfügung. Dazu werden zwei Klimazeitreihen (vgl. Abschnitt 1.2) zunächst einer Wavelettransformation unterworfen und danach aus gleichen Frequenzbändern im Wavelet-Raum die Kreuzkorrelationsfunktion bestimmt.

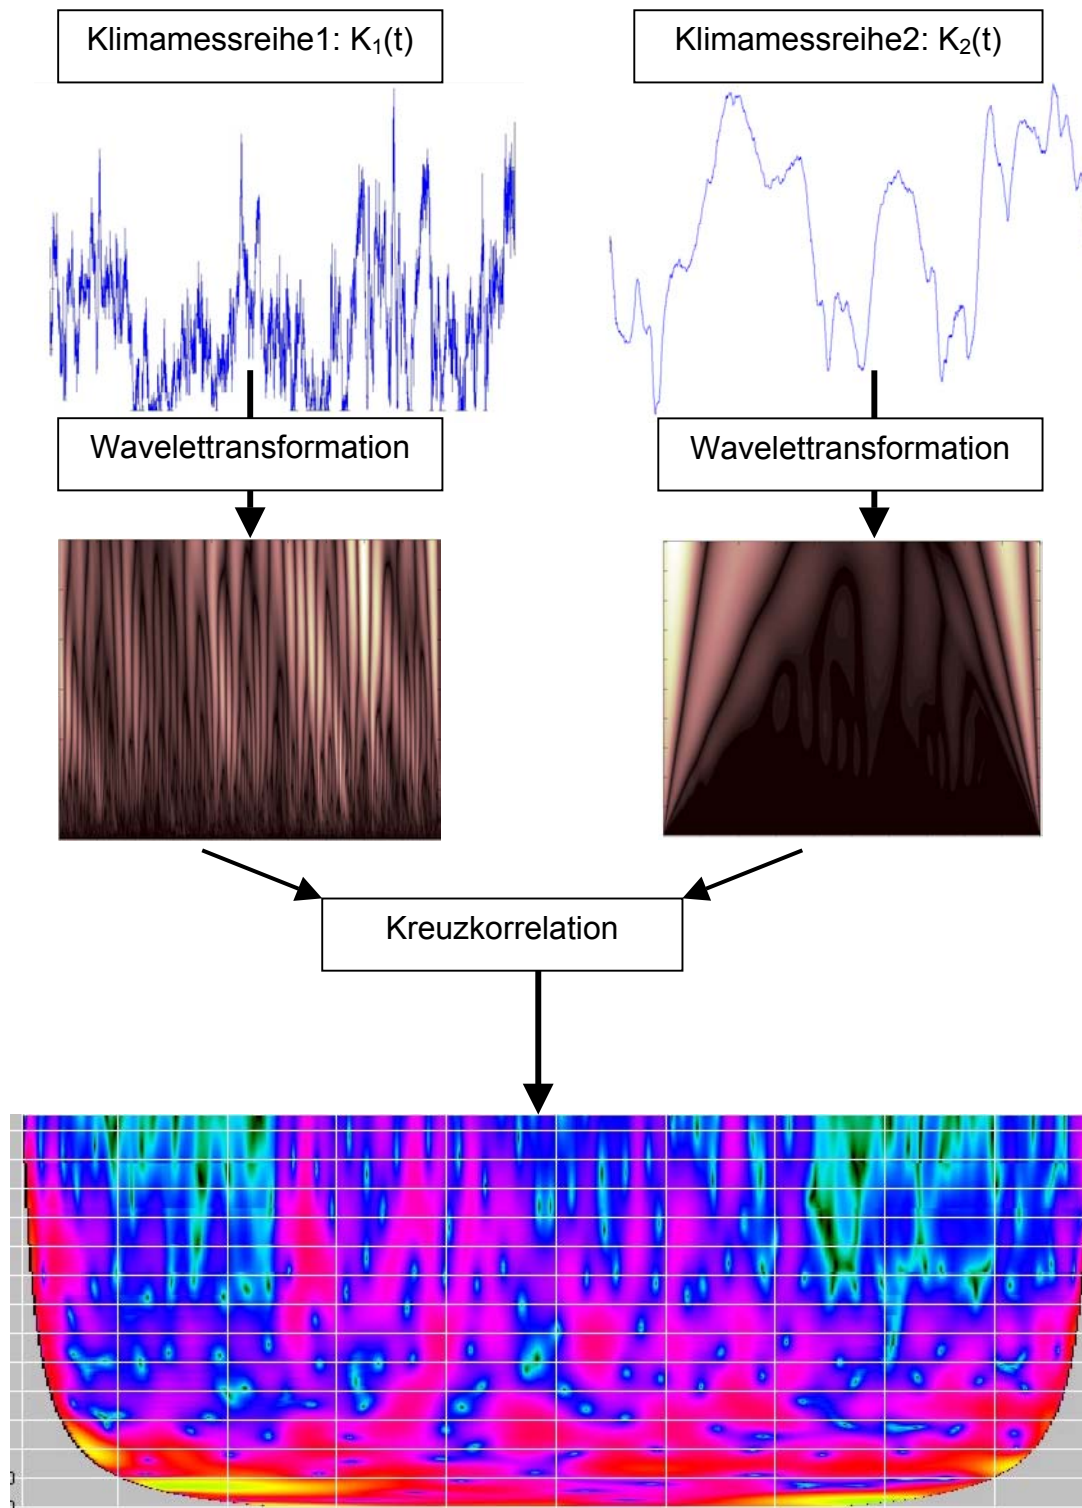


Abb. 4: Berechnung der Kreuzkorrelationsfunktion im Wavelet-Raum

4 Neuronale Netze

4.1 Vorbemerkungen

Neuronale Netze sind hochentwickelte, leistungsfähige Mustererkennungs- und Verarbeitungssysteme, die den biologischen Lernprozess imitieren und (auch nichtlineare) Beziehungen zwischen den Systemeingaben (Eingabegrößen) und den Systemausgaben (Ausgabegrößen) erkennen, sowie nachbilden können⁷. Damit ist es auch dann möglich, Beziehungen zwischen den Ein- und Ausgabegrößen zu identifizieren, wenn kein bzw. sehr wenig Wissen über die im untersuchten System ablaufenden Prozesse vorhanden ist. Es müssen also keinerlei Angaben über die Art der Zusammenhänge gemacht werden, wie dies in den meisten Regressionsmodellen notwendig ist.

Für die Anwendung ist zwischen der Lernphase und der Anwendungsphase zu unterscheiden.

Bezüglich der Details (Bestandteile und Funktionsweise Neuronaler Netze) sei auf die umfangreiche Spezialliteratur verwiesen (z. B. ZELL94 und SCHERER97).

4.2 Lernphase

4.2.1 Prinzipielles Vorgehen

Die Lernphase ist für den erfolgreichen Einsatz Neuronaler Netze von zentraler Bedeutung. Im Projektverlauf wurde diese Phase daher sehr intensiv und zeitaufwändig bearbeitet.

Beim überwachten Lernen wird dem Neuronalen Netz in der Trainingsphase eine möglichst große und für die Grundgesamtheit repräsentative Menge von Datentupeln, d.h. Eingabe- und Ausgabewerte, präsentiert. Das Neuronale Netz versucht nun gemäß der jeweiligen Lernregel die Gewichtsmatrix iterativ zu optimieren. Nach jedem Durchlaufen des Trainingssatzes (Epoche) wird der summierte quadratische Fehler (SSE) der Abweichungen der Ausgabewerte vom Sollwert bestimmt und, um diesen zu minimieren, die Gewichtsmatrix verändert.

$$SSE = \sum_n \sum_j (o_{jn} - t_{jn})^2$$

o_{jn} = Ausgabewert

t_{jn} = Sollwert

n = Anzahl der Trainingsmuster

j = Ausgabe-Neuron

Dabei muss berücksichtigt werden, dass ein Neuronales Netz im allgemeinen nicht auf einen speziellen Datensatz angepasst werden soll (dies wäre prinzipiell in einer endlichen Zahl von Trainingszyklen möglich), sondern in der Lage sein soll, generelle Eigenschaften der Grundgesamtheit, aus der jeweilige Datensatz entnommen wurde, aufzudecken (Generalisierungsfähigkeit). Adaptiert sich ein Neuronales Netz zu stark an den jeweiligen Trainingsdatensatz, spricht man vom Übertrainieren (*overfitting*).

⁷ Zur Anwendung kommen Neuronale Netze heute beispielsweise in der Texterkennung, bei der Prognose von Börsenkursen und ähnlichen Problemen. Auch das El-Niño-Phänomen wurde damit modelliert.

Um dies zu verhindern, präsentiert man nach jedem Trainingszyklus einen anderen Datensatz, den *Validierungsdatsatz*, der der gleichen Grundgesamtheit entstammt und bricht die Lernphase ab, sobald der SSE dieses Datensatzes wieder zu steigen beginnt (siehe Abb. 5). Ein dritter Datensatz, der Testdatensatz, dient dazu, die Leistungsfähigkeit Neuronalen Netzes nach Beendigung des Trainings an bisher völlig unbekanntem Daten der Grundgesamtheit zu prüfen.

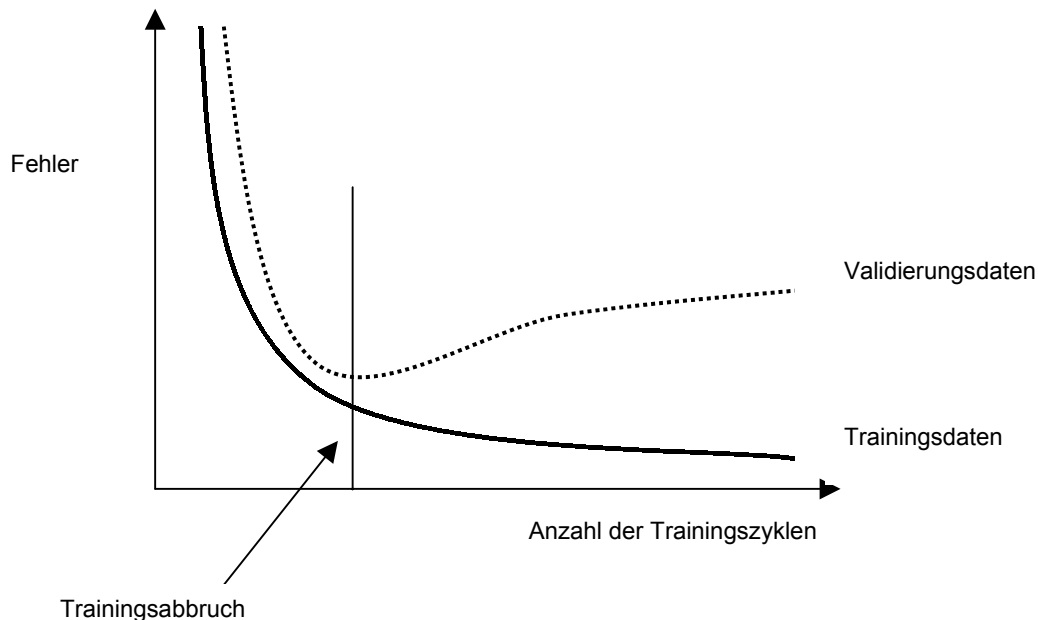


Abb. 5: Idealisierter Fehlerverlauf für Trainings- und Validierungsdaten

4.2.2 Wichtige Fakten der Modellentwicklung

Als *Lernregel* wurde das *Backpropagation* eingesetzt. Trotz ihrer langsamen Konvergenzgeschwindigkeit wird diese Methode häufig eingesetzt und hat sich in vielfältigen Anwendungen bestens bewährt.

Die gewählte *Topologie* des *Neuronalen Netzes* bestimmt weitestgehend dessen Leistungsfähigkeit. Dazu wurden von uns vielfältige Testrechnungen durchgeführt.

Dazu wurden Netze mit einer verdeckten Schicht mit 5, 10, 15, 20, 25 und 50 Neuronen untersucht. Hierbei wurde festgestellt, dass ab 15 Neuronen in der verdeckten Schicht keine weitere Verbesserung der Genauigkeit zu erwarten ist (vgl. Abb. 6). Vielmehr nimmt bei zunehmender Anzahl von Neuronen in der verdeckten Schicht die Generalisierungsfähigkeit eines Netzes ab und die Trainingsdauer aufgrund der gestiegenen Anzahl der Verbindungen nichtlinear zu.

Die oft in der Literatur zitierte Regel (PLÖTSCHER97), die Zahl der Verbindungen eines Netzes soll nicht größer sein als ein Zehntel der Anzahl der Trainingsmuster, konnte hier bestätigt werden.

Zusätzlich wurden noch Netze mit zwei bzw. drei verdeckten Schichten à fünf Neuronen getestet. Es wurde aber festgestellt, dass sich die Trainingszeit ohne Steigerung der Leistungsfähigkeit enorm erhöhte. Dieser Weg wurde daher nicht weiter verfolgt.




Abb. 6: Einfluss der Anzahl der Neuronen in der verborgenen Schicht

Zur Verkürzung der Entwicklungszeiten wurden die Untersuchungen zum Training der Neuronalen Netze zunächst mit dem *Stuttgarter Neuronale Netze Simulator* durchgeführt. Er wird im Internet unter

<http://www-ra.informatik.uni-tuebingen.de/forschung/snns/>

zur nicht-kommerziellen Benutzung kostenlos zur Verfügung gestellt.

In Zusammenarbeit mit der Universität Potsdam (Bereich Informatik, AG Prof.Dr. Schaub) wurde aufsetzend auf den dabei gewonnen Erfahrungen eigene *Tools Neuronale Netze* entwickelt und implementiert.

Als Fehlermaß wurde der Meteorologie bevorzugte und von der World Meteorological Organisation (WMO) empfohlene **Root Mean Square Error** (rms), also die Wurzel aus dem mittleren quadratischen Fehler (BALZER98):

$$rms = \sqrt{\sum_{i=1}^N \frac{(x_{\text{tatsächlich}} - x_{\text{vorhergesagt}})^2}{N}}$$

eingesetzt.

Als Vergleichs- bzw. Referenzmodell wurde die Persistenz herangezogen. Diese hat den Vorteil, sehr unkompliziert und oft erstaunlich leistungsfähig zu sein (LANDBERG94). Es gilt

$$\text{Messgröße}(t + \Delta t) = \text{Messgröße}(t).$$

Wenn ein Modell schlechter als die Persistenz ist, dann kann nicht von einer echten Vorhersageleistung gesprochen werden.

4.2.3 Datenauswahl

Die Auswahl und Zusammenstellung der Trainings- und Validierungsdaten erfolgte unter vielfältigen Aspekten

- Länge der einbezogenen Historie (1, 2, 3, 4, 5, 10 und 20 vorhergegangene Messungen)
- Mittelwerte aus mehreren vorhergegangenen Messwerten
- Auswahl verschiedenster Sensoren-Kombinationen (dabei steht jeder Sensor für eine der im Abschnitt 1.2 angegebenen Klimagrößen)
- Auswahl von Daten aus wohldefinierten Zeitfenstern
 - nach Jahreszeiten
 - nach Monaten
 - nach Tageszeiten (6 - 9 Uhr, 9 -12 Uhr, 12 - 15 Uhr, 15 - 18 Uhr, 18 - 21 Uhr)
- Einbeziehung verschiedener Standorte (Voruntersuchungen)
- Kreuzkorrelationsdaten gemäß Abschnitt 3

4.3 Wesentliche Ergebnisse

Die Neuronalen Netze wurden mit den ausgewählten Daten trainiert⁸ und danach für Prognosen für die Vorhersagezeiträume von 15, 30 und 60 Minuten durchgeführt. Nachfolgend sind die Hauptergebnisse stichpunktartig dargestellt

- Die Prognosequalität verringert sich mit steigender Länge der Vorhersagezeiträume. Bei optimaler Trainingsdatenauswahl konnte folgende Prognosequalität erzielt werden
 - 88% für 15 min – Prognosen
 - 81% für 30 min – Prognosen
 - 77% für 60 min – Prognosen
- Schwierigkeiten traten unabhängig von der Auswahl der Trainingsdaten immer dann auf, wenn Ereignisse prognostiziert werden sollten, die nicht oder nur unzureichend in den Trainingsdaten repräsentiert waren. Als typisch für diese Situation sind Starkwindereignisse (Windgeschwindigkeit $> 15 \text{ ms}^{-1}$) oder sehr schnelle (kurzzeitige) Veränderungen der Windgeschwindigkeit zu nennen. Es ist jedoch zu erwarten, dass sich diese Probleme durch das fortwährend Training der Neuronalen Netze auf der Basis des immer größer werdenden Datenpools zumindest teilweise beheben lassen.
- Durch die Einbeziehung längerer historischer Zeitabschnitte konnte keine Verbesserung der Prognosen erzielt werden. Die besten Ergebnisse wurden mit 2 bis 5 historischen Messwerten erzielt. Damit wird die These unterstützt, dass die Windgeschwindigkeit ein Vorgang ohne ‚Langzeitgedächtnis‘ ist.
- Die mit Mittelwerten aus mehreren vorhergegangenen Messwerten trainierten Neuronale Netze sind selbst für Kurzzeitprognosen (15 min) nur bedingt geeignet.

⁸ Das Training der Neuronalen Netze wurde auf Pentium 4-Rechnern mit Taktfrequenzen von 800 bis 1200 MHz durchgeführt. Die Rechenzeiten für das Training eines Netzes lagen zwischen 10 und 70 Stunden.

- Für die Vorhersage der Windgeschwindigkeit sind insbesondere die Messgrößen Lufttemperatur, Änderung der absoluten Luftfeuchte und Änderung des Luftdruckes von Bedeutung.
- Durch die Einbeziehung von Zeitfenstern werden die in den Messdaten auftretenden saisonalen Anteile berücksichtigt. Es hat sich dabei als qualitätssteigernd erwiesen, Neuronale Netze sowohl mit monatlichem Bezug als auch Tageszeitscheiben zu trainieren und entsprechend für die Prognose einzusetzen. Nur damit lässt sich die oben angegebene Vorhersagequalität erzielen.
- Durch den Einsatz der Kreuzkorrelation (Waveletfilterung) konnte die Qualität der Prognosen um 2 – 3% gesteigert werden.

In der nachfolgenden Abweichung ist die Qualität der Windprognose am Standort Schönberg dargestellt. Dabei fällt auf, dass in mehr als 70% der Fälle die Windgeschwindigkeit absolut mit einer Genauigkeit von einem Meter vorhergesagt wurde.




Abb. 7: Histogramm der absoluten Prognosefehler am Standort Schönberg

In Reflexion dieser Ergebnisse die in Abb. 1 dargestellte Struktur des mathematischen Prognosemodells entwickelt. Das im Verlauf der Projektbearbeitung generierte Know How ist hauptsächlich in der Datenvorbereitung durch geeignete *Waveletfilterungen* und in der generierten *Datenbank Neuronale Netze* enthalten.

5 Kalman-Filter

5.1 Optimalfilter

Eine Vorhersage von Zeitreihen kann mit Hilfe eines Optimalfilters durchgeführt werden. Die Anwendung des Filters auf die bereits bekannten Messdaten liefert dabei eine Vorhersage noch nicht bekannter Messdaten. Die Filterkoeffizienten werden automatisch bestimmt, indem der quadratische Vorhersagefehler für bereits bekannte Messdaten minimiert wird.

Die zwei bekanntesten Optimalfilter sind das Wiener-Filter und das Kalman-Filter. Während die Filterkoeffizienten des Wiener-Filters allein aus der Zeitreihe selbst bestimmt werden, liegt dem Kalman-Filter ein Zustandsraummodell (state space model) der Dynamik zugrunde.

Für das Wiener-Filter werden die Filterkoeffizienten aus der Autokorrelationsfunktion der bekannten Messdaten bestimmt. Dadurch ist die Anwendung grundsätzlich auf stationäre Zeitreihen beschränkt. Zwar lässt sich die Autokorrelationsfunktion separat für zeitlich begrenzte Abschnitte der Zeitreihe berechnen; werden diese Abschnitte jedoch zu kurz, leidet die Genauigkeit des Filters.

Im Gegensatz dazu werden die Filterkoeffizienten des Kalman-Filters mit jedem neu hinzukommendem Messwert verändert. Dieses adaptive Filter ist daher besser für instationäre Zeitreihen und für zeitkritische Anwendungen geeignet als das Wiener-Filter. Ein weiterer Vorteil ist die Robustheit des Filters gegenüber fehlenden Messwerten. Um das Kalman-Filter anzuwenden zu können, muss ein Modell der Dynamik bekannt sein; Modellparameter können während der Anwendung des Filters geschätzt und dynamisch an die Messdaten angepasst werden.

Weitere Einzelheiten sind der angegebenen Literatur zu entnehmen.

5.2 Ergebnisse

5.3 Verwendete Zustandsraummodelle

Für das Kalman-Filter wurden drei Zustandsraummodelle für univariate (skalarwertige) Zeitreihen verwendet (die Bezeichnungen sind Durbin & Koopman⁰¹ entnommen):

- local level model;
- local linear trend model;
- local linear trend model with seasonal component.

Im ersten Modell bestimmt ein Rauschterm die Dynamik, im zweiten Modell kommt ein zeitlich veränderlicher linearer Trend hinzu, im dritten Modell kommt weiterhin ein saisonaler (periodischer) Anteil hinzu. In allen Modellen wird davon ausgegangen, dass die Messdaten durch Messrauschen verfälscht sind.

Zu schätzende Parameter der Modelle sind:

- Stärke (Standardabweichung) des internen Rauschens;
- Stärke (Standardabweichung) des Messrauschens;
- Periode des saisonalen Anteils.

Derzeit werden die Parameter noch vor Anwendung des Filters manuell geschätzt. Ziel ist, diese Schätzung während der Anwendung des Filters automatisch und adaptiv vorzunehmen.

5.4 Vorhersage des Luftdrucks

Da der Luftdruck sich sehr viel langsamer verändert als die Windgeschwindigkeit, ist er für erste Tests des Vorhersagealgorithmus eine gut geeignete Größe. Das local linear trend model liefert hier die besten Ergebnisse. Dargestellt sind die Ein-Schritt-Vorhersage (Abb. 8) und die Vier-Schritte-Vorhersage (Abb. 9). In der Vier-Schritte-Vorhersage ist ein Überschwingen der Vorhersage an den Extrempunkten der Kurve zu beobachten, welches durch den angenommenen linearen Trend zu erklären ist.




Abb. 8: Ein-Schritt-Vorhersage des Luftdrucks (in hPa) mit dem local linear trend model (blaue Rauten: Messwerte, rote Kurve: Vorhersage).

In Abb. 10 ist der Ein-Schritt-Vorhersagefehler (die Differenz zwischen vorhergesagtem und gemessenem Wert) dargestellt. Der mittlere absolute Fehler beträgt 0.0989 hPa, der RMS-Fehler (Wurzel des mittleren quadratischen Fehlers) beträgt 0.1295 hPa.




Abb. 9: Vier-Schritte-Vorhersage des Luftdrucks (in hPa) mit dem local linear trend model (blaue Rauten: Messwerte, rote Kurve: Vorhersage).




Abb. 10: Ein-Schritt-Vorhersagefehler des Luftdrucks (in hPa).

5.4.1 Vorhersage der Windgeschwindigkeit

Die Windgeschwindigkeit ist durch sehr schnelle und sehr starke Änderungen gekennzeichnet; dadurch wird die Vorhersage enorm erschwert. Die besten Ergebnisse wurden mit dem einfachen local level model erzielt. Dargestellt sind auch hier die Ein-Schritt-Vorhersage (Abb. 11) und die Vier-Schritte-Vorhersage (Abb. 12). In der Vier-Schritte-Vorhersage ist deutlich zu erkennen, dass die Vorhersage den Messwerten hinterherläuft. Die schnelle Dynamik wird durch das Modell nicht reproduziert.




Abb. 11: Ein-Schritt-Vorhersage der Windgeschwindigkeit (in m/s) mit dem local level model (blaue Rauten: Messwerte, rote Kurve: Vorhersage).

In Abb. 13 ist wiederum der Ein-Schritt-Vorhersagefehler dargestellt. Der mittlere absolute Fehler beträgt hier 0.3942 m/s, der RMS-Fehler 0.5263 m/s.




Abb. 12: Vier-Schritte-Vorhersage der Windgeschwindigkeit (in m/s) mit dem local level model (blaue Rauten: Messwerte, rote Kurve: Vorhersage).




Abb. 13: Ein-Schritt-Vorhersagefehler der Windgeschwindigkeit (in m/s).

5.5 Fazit

Grundsätzlich ist das Kalman-Filter geeignet, Zeitreihen vorherzusagen, wie sie durch die im Projekt erhobenen Wettermessdaten gegeben sind. Im Falle der Windgeschwindigkeit stellen die schnellen und starken Änderungen ein Problem dar, welches durch Messungen in kürzeren Zeitabständen vermindert werden könnte.

Bisher wurden Modelle für univariate Zeitreihen (mit einer Messgröße) verwendet. Eine wesentlich bessere Vorhersage ist von Modellen für multivariate Zeitreihen zu erwarten, die mehrere Messgrößen berücksichtigen.

Für den saisonalen Anteil des local linear trend model with seasonal component wird momentan eine Periode von 24 h angenommen. Das Spektrum der Zeitreihe deutet darauf hin, dass auch schwächere saisonale Anteile mit Perioden von 12 h und 2.3 h vorhanden sind. Derzeit bringt ein saisonaler Anteil im Modell noch keine Verbesserung, sondern führt zu künstlichen Oszillationen der Vorhersage.

Eine weitere Verbesserung ist von einer automatischen, adaptiven Schätzung der Modellparameter während der Anwendung des Kalman-Filters zu erwarten. Dabei werden die Modellparameter automatisch so gewählt, dass der Vorhersagefehler minimiert wird.

Schließlich sollen nichtlineare Transformationen der Messgrößen (Potenzen, trigonometrische Funktionen, Wavelet-Transformationen o.ä.) nichtlineare Elemente in den ansonsten linearen Mechanismus des Kalman-Filters einbringen. Dazu sind weiterführende Untersuchungen in Zusammenarbeit mit der Universität Potsdam vorgesehen.

6 Zukünftige Entwicklungen

Kurz vor Abschluss des Projektes haben wir noch mit der Entwicklung und praktischen Erprobung von Kalman-Filter begonnen. Die dabei erzielten Ergebnisse stimmen durchweg optimistisch. Wir haben wesentliche Ansätze und erste Ergebnisse im Abschnitt 5 dargestellt. Wir erwarten eine Steigerung der Prognosequalität nach Einbeziehung der im Abschnitt 5.3 vorgestellten nichtlinearen Transformationen.

Das in Abb. 1 dargestellte Prognoseszenario, *gewichtetes Mittel aus der Neuronales Netz- und Kalman-Filter-Prognose*, wurde bisher ausschließlich mit gleichen Gewichten durchgeführt. Die damit erzielbaren Verbesserungen liegen bei 1 bis 2%.

Im Unterschied zu den Fourier-Techniken (nur trigonometrische Funktionen) gibt es unterschiedlichste Wavelet-Funktionen. Da wir bisher nur mit dem Morlet-Wavelet gearbeitet haben, lassen sich daraus Ansätze für zukünftige Weiterentwicklungen ableiten. Dabei könnten auch Indikatorfunktion eingesetzt werden, um die Dynamik der Windentwicklung näher zu charakterisieren. Diese Betrachtungen könnten dann unmittelbar nichtlineare Elemente in den ansonsten linearen Mechanismus des Kalman-Filters einbringen.

Die Einbeziehung mehrerer Standorte ist mit der entwickelten Software ohne prinzipielle Probleme möglich. Dabei bietet sich an, die Leistungsabgabe eines Windparks an Stelle der Windgeschwindigkeit als zu prognostizierende Kenngröße auszuwählen. Unter statistischen Gesichtspunkten ist zu erwarten, dass sich durch die damit

verbundene Mittelung der Windgeschwindigkeiten an verschiedenen Orten⁹ kurzfristige Fluktuationen weitestgehend ausgleichen (vgl. HANDWERKER93, S. 10ff).

Die mit dem Kalman-Filtern bzgl. des langsam veränderlichen Luftdruckes erzielbaren überaus positiven Prognoseergebnisse (Abb. 8 und Abb. 10) lassen eine signifikante Verbesserung der Leistungsprognosen erwarten.

7 Literatur

BALZER98 (K. Balzer, W. Enke, W. Wehry)

Wettervorhersage, Mensch, Computer – Daten und Modelle.- Springer, Berlin 1998.

BROWN & HWANG97 (R. G. Brown und P. Y. C. Hwang)

Introduction to Random Signals and Applied Kalman Filtering.- Wiley, New York 1997, 3. Auflage.

DURBIN & KOOPMAN01 (J. Durbin und S. J. Koopman), *Time Series Analysis by State Space Methods, Oxford University Press, Oxford 2001.*

HANDWERKER93 (J. Handwerker)

Untersuchung zur räumlichen und zeitlichen Struktur eines Windfeldes. - Diplomarbeit, Universität Oldenburg, 1993.

LANDBERG94 (L. Landberg)

Short-term Prediction of Local Wind Conditions.- Risø-R-702(EN), Risø National Laboratory, Roskilde 1994.

LOUIS & MAAß & RIEDER97 (A.K. Louis, P. Maaß und A. Rieder)

Wavelets: Theory and Applications.- Wiley, New York 1997.

MÜLLER99 (S. Müller)

Untersuchung zu einem Windleistungsprognosesystem mittels künstlicher neuronaler Netze auf der Grundlage des meteorologischen Messnetzes Mecklenburg-Vorpommern. – Diplomarbeit, Universität Bayreuth, 1999.

PLÖTSCHER97 (E. PLÖTSCHER)

Analyse von Zeitreihen aus der Ökosystemforschung mittels künstlicher neuronaler Netze.- Diplomarbeit, Universität Bayreuth, 1997.

SCHERER97 (A. Scherer)

Neuronale Netze.- Vieweg, Braunschweig 1997.

STIER01 (W. Stier)

Methoden der Zeitreihenanalyse.- Springer 2001.

TORRENCE&COMPO98 (Ch. Torrence and G.P. Compo)

A Practical Guide to Wavelet Analysis.- Bull. Of the American Meteorological Society, Vol. 79(1), S. 61 – 78, 1998.

ZELL94 (A. Zell)

Simulation neuronaler Netze.- Oldenburgverlag, München 1994.

⁹ Durch die Endlichkeit der Windgeschwindigkeiten ist damit durchaus auch eine zeitliche Mittelung verbunden. Insgesamt ist mit einer deutlichen Glättung kurzzeitiger Schwankungen zurechen, während langsame Fluktuationen nicht gedämpft werden.