



Universität der Bundeswehr München

Institut für Wasserwesen

Mitteilungen

Heft 71 / 2000

Thomas Hügel

Abflussberechnung mit Hilfe Neuronaler Netze

20030108 081

REPORT DOCUMENTATION PAGE

Form Approved OMB No. 0704-0188

Public reporting burden for this collection of information is estimated to average 1 hour per response, including the time for reviewing instructions, searching existing data sources, gathering and maintaining the data needed, and completing and reviewing the collection of information. Send comments regarding this burden estimate or any other aspect of this collection of information, including suggestions for reducing this burden to Washington Headquarters Services, Directorate for Information Operations and Reports, 1215 Jefferson Davis Highway, Suite 1204, Arlington, VA 22202-4302, and to the Office of Management and Budget, Paperwork Reduction Project (0704-0188), Washington, DC 20503.

1. AGENCY USE ONLY (Leave blank)		2. REPORT DATE 2000	3. REPORT TYPE AND DATES COVERED Dissertation	
4. TITLE AND SUBTITLE Abflussberechnung mit Hilfe Neironaler Netze Drainage Calculation with the help of Neural Nets			5. FUNDING NUMBERS	
6. AUTHOR(S) Thomas Huegel				
7. PERFORMING ORGANIZATION NAME(S) AND ADDRESS(ES) Institut fuer Wasserwesen, Universitaet der Bundeswehr Muenchen			8. PERFORMING ORGANIZATION Report Number REPORT NUMBER Heft 71/2000	
9. SPONSORING/MONITORING AGENCY NAME(S) AND ADDRESS(ES)			10. SPONSORING/MONITORING AGENCY REPORT NUMBER ISBN 3-486-26499-0	
11. SUPPLEMENTARY NOTES Text in German. Title and abstract in German and English, 109 pages, ISBN 3-486-26499-0, Heft 71/2000.				
12a. DISTRIBUTION/AVAILABILITY STATEMENT Distribution A: Public Release.			12b. DISTRIBUTION CODE	
ABSTRACT (Maximum 200 words) The study revolves around Artificial Neural Nets (KNN) and seeks to answer six main questions: 1) How is meteorological input treated? 2) How is spatial information integrated into KNN? 3) How are the flowtimes in the collection area broken down? 4) How does information regarding land use from the National Oceanic and Atmospheric Administration (NOAA) and the Advanced Very High Resolution Radiometer (AVHRR) have to be treated and processed? 5) How is the learning process represented? 6) How is the net topology represented? The goal is to link the information-rich, highly resolved, and detailed observation of the planar Precipitation-Drainage-Processes with the simple breaking-down of the equally strongly non-linear functions by means of KNN.				
14. SUBJECT TERMS German, UNIBW, Artificial neural nets, Precipitation, Weather patterns, NOAA, Advanced ver high resolution radiometer, Meteorological input, Net topology			15. NUMBER OF PAGES	
			16. PRICE CODE	
17. SECURITY CLASSIFICATION OF REPORT UNCLASSIFIED	18. SECURITY CLASSIFICATION OF THIS PAGE UNCLASSIFIED	19. SECURITY CLASSIFICATION OF ABSTRACT UNCLASSIFIED	20. LIMITATION OF ABSTRACT UNLIMITED	

Universität der Bundeswehr München

Institut für Wasserwesen

Mitteilungen

Heft 71 / 2000

Abflussberechnung mit Hilfe Neuronaler Netze

Dipl.-Geogr. T. Hügel

Kommissionsverlag Oldenbourg Industrieverlag GmbH
München 2000

AQ F03-02-0427

Hügel, Thomas:

Abflussberechnung mit Hilfe Neuronaler Netze / Thomas Hügel. Universität der Bundeswehr München, Institut für Wasserwesen. – München : Oldenbourg-Industrieverl., 2000

(Mitteilungen / Institut für Wasserwesen : Heft 71)
Zugl.: München, Univ. der Bundeswehr, Diss., 2000
ISBN 3-486-26499-0

Herausgeber:

- Univ.-Prof. Dr.-Ing. Wilhelm Bechteler
Hydromechanik und Hydrologie
- Univ.-Prof. Dr.-Ing. F. Wolfgang Günthert
Siedlungswasserwirtschaft und Abfalltechnik
- Univ.-Prof. Dr.-Ing. Hans-B. Kleeberg
Wasserwirtschaft und Ressourcenschutz

Institut für Wasserwesen
der Universität der Bundeswehr München
85577 Neubiberg

Tel.: 089/6004-3493, -3484, -3490; Fax: 089/6004-3858
<http://www.bauv.unibw-muenchen.de/institute/inst6.html>

ISBN 3-486-26499-0

© 2000 Alle Rechte vorbehalten

Satz: Institut für Wasserwesen
der Universität der Bundeswehr München
85577 Neubiberg

Druck: Universität der Bundeswehr München

Printed in Germany

Vorwort

Bei der Modellierung des Abflußprozesses wird versucht, die nichtlinearen Zusammenhänge der Transformation des gefallenen Niederschlages in den resultierenden Abfluß vereinfacht, aber den empirischen Befunden entsprechend mathematisch abzubilden. Weil der gefallene Niederschlag sowohl einer Aufteilung in laterale und vertikale Wasserflüsse (einschl. der Verdunstung) als auch einer Speicherung der Wasserflüsse innerhalb verschiedener Kompartimente und im Raum unterliegt, sind die Zusammenhänge nicht einfach, sondern komplex. Sie werden meistens mit Hilfe unterschiedlicher und gekoppelter Übertragungsbedingungen in Form von Regressionsgleichungen beschrieben. Der zeitlichen Variabilität ist eine hohe räumliche Variabilität des Antriebs (z.B. Regen, Strahlung) und der Randbedingungen (z.B. Gewässernetz, Topographie, Landnutzung, Boden) überlagert. Die meisten wesentlichen Modellparameter sind räumlich verteilt.

In der vorliegenden Arbeit werden Möglichkeiten geprüft, die Regressionsbeziehungen mit Hilfe Künstlicher Neuronaler Netze (KNN) darzustellen. Neuronale Netze sind ein geeignetes Werkzeug und sehr leistungsfähig bei der Erkennung von Mustern und Grundstrukturen, bei denen eine kurzzeitige Dynamik keine Rolle spielt, z.B. in Karten oder Schriften. Ob sie auch geeignet sind, die Übertragungsbeziehungen abzubilden, bei denen die Eingangsgrößen kurzzeitigen Änderungen unterliegen, das System laufend gestört wird, diese Störungen zusätzlich von sich ändernden und vorherigen Systemzuständen abhängig sind und außerdem die Systemantwort auf den Antrieb nur verzögert und verzerrt reagiert, ist noch nicht bewiesen. KNN bilden das physikalische System und die in ihm ablaufenden Vorgänge nur eingeschränkt ab. Sie arbeiten mit sehr vielen Modellparametern, z.B. den Gewichten der Knotenverbindungen. Sie werden in Lernverfahren anhand von Beobachtungsdaten kalibriert und sind physikalisch nicht erklärbar.

Ziel der Arbeit ist es, die in ihrer allgemeinen Form und Vielfältigkeit bekannte und erprobte Methode der KNN für die Anwendung bei hydrologischen Fragestellungen weiterzu-entwickeln und Grenzen und Einsatzbereiche abzustecken.

Hans-B. Kleeberg

Danksagung

Allen Personen und Institutionen, die die Durchführung dieser Arbeit ermöglicht haben, sei an dieser Stelle Dank gesagt.

Mein großer Dank gilt Herrn. Prof. Dr.-Ing. Hans-B. Kleeberg als meinen Doktorvater. Ohne Seine Anregungen und Anstöße hätte ich die Arbeit sicher nicht realisieren können.

Herzlichsten Dank möchte ich auch Herrn. Prof. Dr.-Ing. Fritz G. Rohde aussprechen für die Übernahme des zweiten Berichtes zu meiner Dissertation.

Meiner Frau Gabi danke ich ganz besonders. Sie hat es ermöglicht, dass ich so viele dringend anstehenden Arbeiten im Hinblick auf die Dissertation verschieben konnte oder Sie sie mir ganz abgenommen hat. Bei meiner Tochter Janina bedanke ich mich, indem ich in Zukunft alle die Zuwendungen nachhole, die Sie während der Erstellung der Arbeit leider nicht bekommen konnte.

Meinen Freunden Herrn Manfred Rank und seiner Lebensgefährtin Andrea Stemmer danke ich für die Durchsicht der Arbeit. Dank Ihnen hat die Rechtschreibung etwas ihren Schrecken verloren.

Die Forschungsarbeit, aus der heraus letztlich meine Dissertation entstanden ist, wurde von der Deutschen Forschungsgemeinschaft finanziell gefördert. Für diese Finanzierung sei hiermit in der Überzeugung gedankt, dass ohne diese hilfreiche Unterstützung weder die Forschungsarbeit noch meine Dissertation möglich gewesen wäre.

Thomas Hügel

Inhaltsverzeichnis

1	Allgemeines	1
2	Zusammenfassung	3
3	Stand der Forschung	7
3.1	Geschichte der Künstlichen Neuronalen Netze	7
3.2	Theorie Künstlicher Neuroner Netze	8
3.3	Vergleich von KNN mit statistischen Modellen	13
3.4	Künstliche Neuronale Netze in der Hydrologie	15
4	Ziel	19
5	Methodik	21
5.1	Die Abflußmodellierung aus hydrologischer Sicht	21
5.2	Klassische Art der Abflußmodellierung	22
5.3	Abflußmodellierung mit Hilfe von Künstlichen Neuronalen Netzen	25
5.4	Vorgehensweise	27
5.5	Arbeitsschritte	29
5.5.1	Trivialer Ansatz	29
5.5.2	Einfache Netztopologie	31
5.5.3	Komplexe Netztopologie	32
5.5.4	Prognose	39
5.6	Untersuchungsgebiete	40
5.7	Eingangsdaten	41
6	Ergebnisse	45
6.1	Allgemeines	45
6.2	Ergebnisse der Vorarbeiten und Voruntersuchungen (trivialer Ansatz)	49
6.2.1	Allgemeines	49
6.2.2	Kontinuumssimulation	49
6.2.3	Hochwasservorhersage	54
6.2.4	Bewertung der Ergebnisse der Voruntersuchung	57
6.3	Einfache Netztopologie	59

6.3.1	Allgemeines	59
6.3.2	Kontinuumssimulation	60
6.3.3	Bewertung der Ergebnisse der Kontinuumssimulation	69
6.3.4	Hochwasserereignisse	69
6.3.5	Bewertung der Ergebnisse der Hochwasservorhersage	76
6.4	Komplexe Netztopologie	77
6.4.1	Allgemeines	77
6.4.2	Kontinuumssimulation	78
6.4.3	Bewertung der Ergebnisse der Kontinuumssimulation	88
6.4.4	Hochwasserereignisse	89
6.4.5	Bewertung der Ergebnisse der Hochwasservorhersage	93
6.5	Bewertung alternativer Netztopologien und Ansätze	94
7	Einsatz von Künstlichen Neuronalen Netzen zur Abflußprognose	95
7.1	Allgemeines	95
7.2	Vorgehensweise	96
7.3	Ergebnisse	98
7.4	Bewertung der Abflußprognose mit KNN	103
8	Literatur	107
 Anhang A: Ergebnisse der flächenhaften Kontinuumssimulation im Einzugsgebiet des Oberen Mains		
Anhang B: Ergebnisse der flächenhaften Hochwasservorhersage im Einzugsgebiet der Oberpfälzer Vils		

Liste der verwendeten Abkürzungen

AVHRR	Advanced Very High Resolution Radiometer
BP	Backpropagation
DFD	Deutsches Fernerkundungsdatenzentrum
DHM	Digitales Höhenmodell
EZG	Einzugsgebiet
HL	Hidden Layer
IL	Input Layer
KNN	Künstliches Neuronales Netz
LfW	Landesamt für Wasserwirtschaft
LN	Landnutzung
LVQ	Lernende Vektor-Quantifizierung
MLP	Multi-Layer-Perceptron
N-A-Prozeß	Niederschlag-Abfluß-Prozeß
NDVI	Normalized Differential Vegetation Index
NOAA	National Oceanic and Atmospheric Administration
OL	Output Layer
PR	Partiell Rekurrentes Netz
QP	Quick Prop
RBF	Radial-Basisfunktion-Netz
RP	RProp
SNNS	Stuttgarter Neuronaler Netz Simulator
TDNN	Time Delay Neural Network

Liste der verwendeten Symbole

D_i	$[m^3/s]$	gewünschte Ausgabe des KNN
$Diff$	$[-]$	Differenz
E	$[-]$	Effizienz
∂E	$[-]$	Ableitung der Fehlerfunktion
F	$[-]$	Abweichung der tatsächlichen von der gewünschten Ausgabe
G	$[-]$	Grauwert
HQ	$[m^3/s]$	Scheitelabfluß
I	$[-]$	Intervallgrenze
LL	$[-]$	Laufweitenindex
MQ	$[m^3/s]$	mittlerer Abfluß
N	$[mm]$	Niederschlag
Of	$[-]$	Offset
Q	$[m^3/s]$	Abfluß
Q_g	$[m^3/s]$	gemessener Abfluß
Q_b	$[m^3/s]$	berechneter Abfluß
Q_{maxg}	$[m^3/s]$	maximal gemessener Abfluß
S	$[m^3/s]$	Standardabweichung
Sd	$[h]$	Sonnenscheindauer
Sh	$[mm]$	Schneehöhe
Sk	$[-]$	Skalierungsfaktor
St	$[-]$	Steigung einer Funktion
$SumN$	$[mm]$	Summe der Niederschläge
SZ_i	$[-]$	gewichtete Zustandsvariable des Neurons i
T	$[^{\circ}C]$	Temperatur
VN	$[-]$	Vorregenindex
W_{ij}	$[-]$	Gewicht der Verbindung zweier Neuronen i und j
X_i	$[-]$	Eingangsdaten des Neurons i
Y_i	$[-]$	Ausgangsdaten des Neurons i
Z	$[-]$	Zeitindex
dir	$[-]$	Richtung des Gefälles im Höhenmodell
$dist$	$[-]$	Distanz zwischen zwei Punkten im Höhenmodell
e	$[m]$	Höhe eines Punktes im Höhenmodell
$f_{act}()$	$[-]$	Aktivierungsfunktion eines Neurons
g	$[-]$	abwärtsgerichtetes Gefälle
g_F	$[-]$	Fließrichtung
n	$[-]$	Anzahl Zeitschritte
r	$[-]$	Korrelationskoeffizient
sgn	$[-]$	Vorzeichen
t	$[-]$	Zeitschritt
x	$[-]$	Zeilen im digitalen Modell
y	$[-]$	Spalten im digitalen Modell
Δ	$[-]$	Änderung einer Größe
η	$[-]$	Lernfaktor oder Schrittweite
ϑ_i	$[-]$	Schwellwert des Neurons i

1 Allgemeines

Seitdem es leistungsfähige Computer erlauben, zählt die flächenhafte Niederschlag-Abfluß-Modellierung (N-A-Modellierung) zu einem weitverbreiteten Verfahren in der Hydrologie. Eine Vielzahl unterschiedlicher physikalischer Modelle sind entwickelt worden, die neben reinen Forschungsanwendungen inzwischen auch in der Praxis Einzug halten. Mit ihnen ist es möglich, den N-A-Prozeß physikalisch und räumlich hoch aufgelöst nachzubilden. Solch eine detaillierte Beschreibung ist allerdings sehr komplex und rechenintensiv.

Demhingegen lassen sich komplexe Prozesse mit Künstlichen Neuronalen Netzen (KNN) aufgrund ihres holistischen Ansatzes relativ einfach beschreiben. Das abzubildende System wird ganzheitlich betrachtet und nicht auf der Basis der zugrundeliegenden Teilprozesse in Einzelbausteine zerlegt.

In der vorliegenden Arbeit wird der Versuch unternommen, beide Verfahren mit dem Ziel zusammenzuführen, die informationsreiche, hochaufgelöste und detaillierte Betrachtung des flächenhaften Niederschlag-Abfluß-Prozesses mit der einfachen Abbildung auch stark nicht-linearer Funktionen durch KNN miteinander zu verbinden. Der Vorteil einer solchen kombinierten Methode liegt darin, die schwierige Beschreibung der nichtlinearen physikalischen Prozesse bei der Abflußbildung und -konzentration umgehen zu können.

Im Mittelpunkt der Arbeit stehen die Möglichkeiten einer flächenhaften Abflußmodellierung mit KNN bei Integration raumbezogener Daten in die Struktur des Netzes und Verwendung flächenhafter Eingangsdaten. Weiterhin wird untersucht, inwieweit KNN zur Prognose des Abflußkontinuums eingesetzt werden können. In diesen Bereichen zeigt sich ein großes Forschungsdefizit. Auf eine ganze Reihe von offenen Fragen, wie:

- Wie wird der meteorologische Input behandelt ?
- Wie werden räumliche Informationen ins KNN integriert ?
- Wie werden die Fließzeiten im Einzugsgebiet abgebildet ?
- Wie müssen die Landnutzungsinformationen aus NOAA/AVHRR-Daten behandelt und verarbeitet werden ?
- Wie stellen sich Lernprozeß und
- Netztopologie dar ?

werden in der vorliegenden Arbeit Antworten gegeben.

Die prinzipielle Machbarkeit flächenhafter hydrologischer Modellierung mittels KNN wird untersucht, indem zunächst mit einem einfachen Netzentwurf die Möglichkeiten der Integration grober räumlicher Informationen analysiert werden („einfache Netztopologie“). Aufbauend auf diesen Erfahrungen werden weitere raumbezogene Daten wie Topographie des Einzugsgebietes, Landnutzungsinformationen und Bodenarten integriert. Das KNN wird dementsprechend angepaßt und komplexer gestaltet („komplexe Netztopologie“).

Um die tatsächlichen Änderungen und möglichen Vorteile der Integration raumbezogener flächenhafter Daten in die Struktur der KNN aufzuzeigen und zu belegen, werden als Vergleichsbasis zusätzliche Berechnungen durchgeführt, die den in der Literatur zu findenden, herkömmlichen Ansätzen der Abflußvorhersage mittels KNN entsprechen („trivialer Ansatz“).

2 Zusammenfassung

Die physikalisch basierte Abflußmodellierung ist aufgrund der notwendigen detaillierten Beschreibung der komplexen Teilprozesse der Abflußbildung und Abflußkonzentration sehr aufwendig. Ein Hauptproblem bei allen Ansätzen ist die Bereitstellung der räumlich verteilten gebiets- und ereignisspezifischen Modellparameter.

Der datenbasierte holistische Ansatz Künstlicher Neuronaler Netze sollte es erlauben, die abzubildenden Prozesse integral über die Beziehung zwischen Eingangs- und Ausgangsdaten zu beschreiben und dabei auf die Quantifizierung verschiedener Modellparameter in ihrer räumlichen Verteilung zu verzichten.

In der Arbeit wird daher untersucht, inwieweit die Modellierung der flächenhaften Abflußbildung und Abflußkonzentration mittels KNN in der Fläche, d. h. unter Berücksichtigung der Raum- und Lagebeziehungen im Untersuchungsgebiet, in einem natürlichen Einzugsgebiet mit gemessenen Daten durchgeführt werden kann. Dabei werden raumbezogene Eingangsdaten ohne aufwendiges Preprocessing direkt in die Netzstruktur integriert (Höhen- und Fließweginformationen) oder als zusätzliche Eingangsdaten (Landnutzung, Boden) verwendet.

Eine Untersuchung der Möglichkeiten zur Prognose des Abflusses mit KNN soll zeigen, inwieweit die Netze geeignet sind, auch langfristige Untersuchungen über Abflußcharakteristik und -änderungen durchzuführen.

Der Arbeitsablauf teilt sich in vier Phasen auf, die sich durch zunehmende Integration von Lage- und Flächeninformationen in die Berechnungen auszeichnen (Abbildung 1).




1. Phase		
Trivialer Ansatz		Keine räumlichen Informationen Q an Pegeln N an Stationen
Vorhersage		
2. Phase		
Einfache Netztopologie		Lagebeziehungen der Meßstellen im Einzugsgebiet Q an Pegeln N an Stationen
Vorhersage		
3. Phase		
Komplexe Netztopologie		Rasterpunktbezogene Modellierung räuml. verteilte Daten Keine Q
Vorhersage		
4. Phase		
Prognose	Trivialer Ansatz	Keine räumlichen Informationen Q an Pegeln Keine N

Abb. 1: Zunehmende Integration räumlicher Information von der stationsbezogenen hin zur flächenhaften Modellierung mittels KNN und Abflußprognose

Die Möglichkeiten der Abflußvorhersage mit KNN in der klassischen, bisher häufig angewandten Form werden in der ersten Phase näher untersucht. Hier werden keinerlei Rauminformationen oder Lagebeziehungen berücksichtigt („trivialer Ansatz“). Das KNN ist vollständig verbunden, alle Eingangsdaten gehen gleich gewichtet in die Berechnungen ein. Diese Berechnungen dienen als Basis einen Vergleich mit den weiterführenden Berechnungen.

In der zweiten Phase finden die Informationen über Lagebeziehungen der Meßstellen oder der Gewässerstruktur im Einzugsgebiet Verwendung („einfache Netztopologie“). Die Netzform zeichnet diese Lagebeziehungen vereinfacht nach, die Schichten des KNN sind selektiv miteinander verbunden. Über die Entfernung der Stationen zum Gebietsauslaß (=Anzahl der Verknüpfungen im Netz) werden die Stationen entsprechend ihres Abstandes gewichtet. Eine flächendetaillierte Modellierung findet hier noch nicht statt.

In der dritten Phase des Projektes fließen die Eingangsdaten räumlich detailliert in die Modellierung ein („komplexe Netztopologie“). Die Modellierung erfolgt rasterpunktbezogen. Die Netzform entspricht über die Anzahl der Neuronen und Schichten der Anzahl und Lage der Rasterelemente im Einzugsgebiet. Die Fließwege werden detailliert nachgebildet.

Die Ergebnisse der Arbeit lassen sich für alle drei Ansätze wie folgt zusammenfassen:

- In den untersuchten Einzugsgebieten ist eine Abflußvorhersage ohne hydrologische Eingangsdaten der Oberliegerpegel (Phase 1 bis 3) weder auf Tages- noch auf Stundenbasis möglich.
- Durch die Berücksichtigung einfacher Lagebeziehungen der Meßstellen im Einzugsgebiet sowie der Gewässerstruktur und der Nachbildung dieser in der Netztopologie des KNN („einfache Netztopologie“, Phase 2) können geringe Verbesserungen bei der Berechnung des Abflußkontinuums erzielt werden. Eine Hochwasservorhersage ist erst durch diese Netzstruktur möglich, hier zeigen sich die deutlichsten Verbesserungen gegenüber der trivialen Methode.
- Mit der komplexen Netztopologie (Phase 3) ist bei alleiniger Verwendung meteorologischer Eingangsdaten weder eine Prognose des Kontinuums noch eine Vorhersage von Hochwasserereignissen möglich. Weitere flächenbezogene Eingangsdaten verbessern die Berechnungsergebnisse nicht.

Durch die Integration der Informationen über Fließwege und Gefälle im Einzugsgebiet können mit der komplexen Netztopologie zwar sehr gute Trainingsergebnisse erzielt werden, die Generalisierungsleistung der KNN, d. h. die Möglichkeit der Reaktion auf geänderte Randbedingungen und die Anwendbarkeit auf bisher nicht bekannte Daten, geht vollkommen verloren. Die erlernten Fähigkeiten können weder für die Vorhersage auf Stundenbasis noch für die Prognose auf Tagesbasis in hinreichend genaue Berechnungen umgesetzt werden. In diesem Fall ist aufgrund der Größe der KNN die Anzahl der adaptierbaren Parameter im Netz zu hoch, es findet auch bereits bei sehr kurzen Trainingszeiten eine Überbestimmung der Trainingsmuster statt.

Eine Abbildung der Transferfunktion vom Niederschlag zum Abfluß über eine flächenbezogene N-A-Modellierung mittels KNN („komplexe Netztopologie“) allein auf der Basis meteorologischer Eingangsdaten und weiterer Flächeninformationen ist nicht durchführbar. Nur durch die alleinige oder zusätzliche Verwendung hydrologischer Eingangsdaten von Oberliegerpegeln können sinnvolle Berechnungsergebnisse erzielt werden.

Die den Daten zugrundeliegende Beziehung zwischen Niederschlag und Abfluß kann vom KNN zwar erlernt, nicht aber für eine Vorhersage umgesetzt werden. Das KNN ist zu stark durch die Trainingsdaten bestimmt, auch nur geringfügig geänderte Randbedingungen können aufgrund der starren und unveränderbaren Strukturen in einem trainierten Netz nicht mehr abgebildet und berücksichtigt werden. Das Abflußgeschehen ist durch viele variable und interagierende Einflußgrößen definiert. Vor allem diese Interaktionen können allein durch die verwendeten Eingangsdaten nicht beschrieben werden.

Die besten Resultate für vorhergesagte Abflüsse bei geringstem Aufwand an Datenaufbereitung und Netztraining sind mit dem Ansatz der einfachen Netztopologie zu erreichen. Hier werden die Lagebeziehungen der verwendeten Pegel und meteorologischen Stationen im Einzugsgebiet beim Netzdesign mit berücksichtigt. Trotz eines nur geringen Mehraufwandes liegt die Güte dieses Berechnungsansatzes zum Teil deutlich über der der klassischen trivialen Anwendungen von KNN.

In der vierten Arbeitsphase wird die grundsätzliche Eignung Künstlicher Neuronaler Netze im Bezug auf die Prognose des Abflußkontinuums in der zeitlichen Auflösung von Tagen untersucht.

Es zeigt sich, daß KNN prinzipiell ungeeignet für die Prognose des Abflußkontinuums sind. Sie sind vollkommen vom Trainingsmuster abhängig und durch dieses bestimmt. Diese Abhängigkeit verhindert jegliche Möglichkeit, Abflußkontinua, die außerhalb der durch die Lernmuster bekannten Spannweite liegen, richtig zu prognostizieren.

Die Höhe möglicher Abflüsse in der Zukunft ist aber nicht exakt bestimmbar, sie sollen ja erst durch die Prognose berechnet werden. Fallen nun aber prognostizierte Eingangsdaten außerhalb des Dynamikbereiches der Trainingsphase, so ist es unmöglich, auf deren Basis hinreichend genaue Abflüsse zu prognostizieren. Es zeigt sich hier sehr deutlich, daß KNN immer „Gefangene der angelegten Trainingsmuster“ [Minns et al., 1996] sind.

3 Stand der Forschung

3.1 Geschichte der Künstlichen Neuronalen Netze

Der Versuch, die Arbeitsweise des menschlichen Gehirns mit all seinen Fähigkeiten (Lernen und Generalisieren) mittels Künstlichen Neuronalen Netzen am Computer zu simulieren, ist fast so alt wie die Computertechnik selbst und damit sogar noch älter als die Geschichte der symbolischen Künstlichen Intelligenz [Zell, 1994]. Solche Netze finden seit neuerer Zeit auch Einsatz in der hydrologischen Abflußberechnung.

Bereits 1943 erschienen die ersten Arbeiten zu dieser Thematik von dem Neurophilosophen McCulloch [McCulloch et al., 1943]. McCulloch und Pitts stellten fest, daß Nervenzellen, wenn sie ein Reiz erreicht, entweder aktiv sind oder nicht, sie leiten einen Impuls weiter oder bleiben stumm. Dies war eigentlich die Basis für die Vorstellung von Nervennetzen, die sich logische Funktionen errechnen. Der Weg von hier zum KNN in einem Computer war bereitet. 1949 stellte Hebb seine Arbeiten in Richtung Lernverfahren für KNN der Fachwelt vor. Dieses als Hebb'sche Lernregel bekannt gewordene Verfahren ist bis heute für viele KNN gültig. Caianiello entwickelte 1961 auf der Basis der Hebb'schen Regel den „mnemonic“ Lernalgorithmus, mit dem die Bestimmung der Gewichte in einem KNN möglich ist. Ende der 50er Jahre präsentierte Rosenblatt und seine Gruppe erfolgreich den ersten Neurocomputer sowie eine neue Netzwerktopologie, die sie „Perceptron“ nannten. Sie zeigten, daß ein Perceptron mit dem von ihnen entwickelten Perceptron-Konvergenz-Theorem alles erlernen kann, was es repräsentieren kann. Dieses Perceptron war der erste, voll vorwärtsverbundene (Feed-Forward) Netztypus, wie er auch heute noch bei vielen Anwendungen von KNN Standard ist.

Nach Jahren theoretischer Grundlagenarbeit erlangten KNN durch die Arbeiten von Rumelhart [Rumelhart et al., 1986] einen erneuten Aufschwung. Sie stellten in Anlehnung an die 1974 erschienene Dissertation von Werbos das Lernverfahren „Backpropagation“ für mehrschichtige Feed-Forward-Netze vor. Dieses schnelle und robuste Lernverfahren ist auch heute noch Grundlage fast aller KNN. Seit dieser Zeit gab es durch die zunehmende Nutzung von KNN zahlreiche Varianten an Netztopologien und Lernverfahren. Diese Entwicklung scheint bis heute noch nicht abgeschlossen.

Obwohl die Hauptanwendungsgebiete heutiger Nutzung von KNN in den klassischen Bereichen Muster- und Spracherkennung liegen, finden sich doch, verstärkt seit Beginn der 90er Jahre, auch hydrologische und wasserwirtschaftliche Anwendungen sowie Beispiele für Fernerkundungsanwendungen. Während im Bereich der Hydrologie und Wasserwirtschaft wie auch in starkem Maße in der Meteorologie die Anwendung auf die Vorhersage von Ereignissen im Vordergrund stehen, beziehen sich die Fernerkundungsanwendungen meist auf eine Klassifizierung der Daten.

Prognostische Anwendungen sind im Bereich der Abflußberechnungen sehr selten. Lediglich eine Arbeit von [Clair et al., 1998] liefert den Versuch, mit Hilfe von prognostizierten Temperaturen und Niederschlägen aus Klimamodellrechnungen die mögliche Änderung mittlerer monatlicher Abflüsse in 14 Einzugsgebieten in Kanada aufzuzeigen. Die zeitliche Auflösung der Modellberechnungen ist mit monatlichen Mittelwerten allerdings sehr grob.

3.2 Theorie Künstlicher Neuronaler Netze

Künstliche Neuronale Netze sind Modelle für kognitive Anwendungen, wie Lernen oder Optimierung, deren Konzepte auf Forschungen natürlicher Prozesse im Gehirn basieren [Müller et al., 1990]. Das Studium der KNN ist motiviert durch die Informationsverarbeitung von Lebewesen, bei denen im Verhältnis zum Gesamtsystem sehr einfache, aber sehr viele Nervenzellen den Grad ihrer Erregung über Nervenfasern an andere Nervenzellen weiterleiten [Zell, 1994]. Es handelt sich somit um massiv parallele Systeme, deren wesentliches Element ihre Lernfähigkeit ist. Dies macht KNN neben der Erforschung des Gehirns auch für andere Bereiche der Naturwissenschaften so interessant.

Im menschlichen Gehirn nimmt ein typisches Neuron über seine zahlreichen Dendriten die Signale anderer Neuronen auf und leitet eigene Signale über das Axon an andere Nervenzellen weiter. Die Stärke der Signale hängt von der Effizienz der Synapsen ab. Durch die Veränderung der synaptischen Übertragungsfunktionen findet der Lernprozeß statt (Tabelle 1).

Tab. 1: Vergleich zwischen biologischem und künstlichem Neuron [Peschke et al., 1997]

Biologische Zelle	Künstliches Neuron
Neuronen als Informationsträger	Neuronen als Prozessoren mit der Fähigkeit, elektrische Impulse zu senden
Axonen zur Weitervermittlung des Erregungszustandes	Verbindungen zur Weitervermittlung der Impulse
Synapsen bestimmen, wie sich der Erregungszustand eines anderen Zellkörpers als Input für ein Neuron auswirkt	Gewichte bestimmen, wie sich der Impuls eines Vorgängerneurons als Input für ein Nachfolgeneuron auswirkt
Synaptisch gefilterte Eingangserregungen werden über Rezeptoren auf den Zellkörper übertragen	Gewichtete Impulse werden über die Transferfunktion auf das Neuron übertragen

In Abbildung 2 entspricht das künstliche Neuron b) einem biologischen Neuron im Gehirn a). Vergleichbar seinem biologischem Vorbild sammelt das künstliche Neuron alle eingehenden Informationen, summiert sie zu einem Eingangssignal auf und sendet dieses nach Modifikation durch einen optionalen Schwellwert und der Transferfunktion an alle nachfolgenden, in Verbindung stehenden Neuronen weiter. Die Verknüpfung mehrerer künstlicher Neuronen zu einem Netz c) bildet dann das KNN. Die Verbindungen zwischen den Neuronen im Netz bilden die Synapsen des Gehirns nach. Die Veränderung der synaptischen Übertragungsfunktionen im Gehirn wird durch Veränderung von, den Verbindungen zugeordneten, Gewichten erreicht. Künstliche Neuronen und deren Verbindungen bilden dabei die innere Struktur eines neuronalen Netzes.




Abb. 2: Entwicklung eines KNN aus künstlichen Neuronen als Nachbildung einer biologischen Nervenzelle

Mathematisch beschrieben ist ein KNN definiert als ein gerichteter Graph mit folgenden Eigenschaften:

- einer Zustandsvariablen SZ_i für jeden Knoten i
- einem reellen Gewicht W_{ij} für jede Verbindung zwischen zwei Knoten i und j
- einem reellen Schwellwert ϑ_i für jeden Knoten i
- einer Übertragungsfunktion $f_{act}()$ für jeden Knoten i .

Ein Knoten berechnet somit zuerst eine gewichtete Summe ($SZ_j = \sum_i \sum_j W_{ij} \cdot X_i$) der Eingangsdaten X_i , die mittels der Transferfunktion in das Ausgangssignal Y_i transformiert wird. Es existieren eine ganze Reihe verschiedener Transferfunktionen, die in Abhängigkeit der Anwendung und der Natur der Eingangsdaten zum Einsatz kommen (Abbildung 3).




Abb. 3: Verschiedene Transferfunktionen

Vergleichbar den Veränderungen der synaptischen Übertragungsfunktionen beim natürlichen Lernen müssen die Wichtungen an den einzelnen Kanten bei dem sogenannten (überwachten) Trainingsprozeß mit historischen Ereignissen durch Vergleich zwischen gemessenen und simulierten Ausgangsdaten angeeicht werden. Das hierfür meist verwendete Verfahren ist der sogenannte Backpropagation-Algorithmus oder eine seiner vielen, in der Zwischenzeit entwickelten Modifikationen. Hierbei werden beim Lernen über die Abweichung der tatsächlichen von der gewünschten Ausgabe die Gewichte des KNN in der Art verändert, daß der Fehler minimiert wird (Abbildung 4).




Abb. 4: Überwachtes Trainieren eines KNN

Zunächst wird die Zielfunktion F , die Abweichung der berechneten von der gewünschten Ausgabe des Netzes, als Abweichungsquadratsumme minimiert.

$$F = \frac{1}{2} \sum_i (Y_i - D_i)^2 = \min$$

Y_i tatsächliche Ausgabe des KNN

D_i gewünschte Ausgabe des KNN

Die Minimierung erfolgt von der Ausgabeschicht (Output Layer) zurück (daher der Name „Backpropagation“) durch alle verdeckten Schichten (Hidden Layer) bis zur Eingabeschicht (Input Layer) in vier Schritten.

1. Es wird berechnet, wie schnell sich der Fehler ändert, wenn die Aktivität eines Ausgabeneurons verändert wird.
2. Danach wird berechnet, wie schnell sich der Fehler ändert, wenn sich die Gesamteingabe eines Ausgabeneurons ändert.
3. Weiter wird berechnet, wie schnell sich der Fehler ändert, wenn sich das Gewicht einer Verbindung zu einem Ausgabeneuron ändert.
4. Zuletzt wird berechnet, wie schnell sich der Fehler ändert, wenn sich die Aktivität eines Neurons der vorhergehenden Schicht ändert.

Die Adaption des KNN an die zu erlernende Funktion verläuft somit in der Weise, daß für jedes angelegte Eingabemuster alle Gewichte von der Ausgabeschicht über alle versteckten Schichten bis hin zur Eingabeschicht mit dem Ziel geändert werden, den aufgetretenen Fehler zu minimieren.

Mathematisch kann dies über Gleichung (1) beschrieben werden:

$$\Delta_p W_{ij} = \eta \cdot Y_{pi} \cdot F_{pj} \quad (1)$$

mit

$$F_{pj} = \begin{cases} f'_{act}(X_{pj}) \cdot (Y_{pj} - D_{pj}) & \text{falls } j \text{ Ausgabezelle} \\ f'_{act}(X_{pj}) \cdot \sum_k F_{pk} \cdot W_{jk} & \text{falls } j \text{ verdeckte Zelle} \end{cases}$$

$\Delta_p W_{ij}$	Änderung der Gewichte zwischen Zelle i und j bei Muster p
η	Lernfaktor oder Schrittweite
Y_{pi}	Ausgabe der Zelle i bei Muster p
F_{pj}	Fehlersignal der Zelle j bei Muster p
f_{act}	Aktivierungsfunktion
X_{pj}	Netzeingabe der Zelle j bei Muster p
D_{pj}	Gewünschte Ausgabe der Zelle j bei Muster p

Dieses Standard-Backpropagation-Lernverfahren erfuhr eine Vielzahl von Modifikationen, die zum Teil auch im Projekt getestet werden.

Quickprop

Quickprop ist ebenfalls ein iteratives Verfahren, daß nun aber im Gegensatz zum Backpropagation-Verfahren die Ableitung der Fehlerfunktion $\partial E / \partial w_{ij}(t-1)$ mit dem Gewicht w_{ij} zum vorherigen Zeitpunkt t-1, die Steigung $\partial E / \partial w_{ij}(t)$ der Fehlerfunktion in Richtung w_{ij} zum aktuellen Zeitpunkt t und die letzte Änderung Δw_{ij} des Gewichts verwendet, um daraus das erwartete Minimum der Fehlerfunktion zu bestimmen und direkt dorthin zu springen. Dies kann den Lernprozeß gegenüber dem Standard-Verfahren beschleunigen [Zell, 1994].

$$\Delta w_{ij}(t) = \frac{\frac{\partial E}{\partial w_{ij}}(t)}{\frac{\partial E}{\partial w_{ij}}(t-1) - \frac{\partial E}{\partial w_{ij}}(t)} \cdot \Delta w_{ij}(t-1)$$

Rprop

Bei diesem Lernverfahren kommt zur Bestimmung der Gewichtsänderung nicht der Gradient der Fehlerfunktion, sondern nur das Vorzeichen dieses Gradienten zum Einsatz. Die Größe der Änderung wird über einen Parameter η festgelegt, zu Beginn werden alle Werte $\Delta_{ij}(t)$ auf einen Initialwert Δ_0 gesetzt (nach [Zell, 1994]):

$$\Delta_{ij}(t) = \begin{cases} \Delta_{ij}(t-1) \cdot \eta_+ & \text{falls } St(t-1)St(t) > 0 \\ \Delta_{ij}(t-1) \cdot \eta_- & \text{falls } St(t-1)St(t) < 0 \\ \Delta_{ij}(t-1) & \text{sonst} \end{cases}$$

mit

$$0 < \eta_- < 1 < \eta_+$$

$St(t) = \frac{\partial E}{\partial w_{ij}}(t)$ Steigung der Fehlerfunktion in Richtung des Gewichtes w_{ij} zum Zeitpunkt t

Die neuen Gewichte berechnen sich nach Gleichung (2) über:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \quad (2)$$

wobei die Gewichtsänderung $\Delta w_{ij}(t)$ nur vom Vorzeichen der Steigung abhängt, nicht von deren Betrag:

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}(t) & \text{falls } St(t-1)St(t) > 0 \wedge St(t) > 0 \\ \Delta_{ij}(t) & \text{falls } St(t-1)St(t) > 0 \wedge St(t) < 0 \\ -\Delta w_{ij}(t-1) & \text{falls } St(t-1)St(t) < 0 \\ -sgn(St(t))\Delta_{ij}(t) & \text{sonst} \end{cases}$$

Allen Lernverfahren ist aber gemeinsam, daß Künstliche Neuronale Netze nichtalgorithmisch operieren, sie arbeiten datenbasiert. Sie entwickeln durch 'trial and error' eine Beziehung zwischen Stimulus (Eingangsdaten) und der Impulsantwort (Ausgangsdaten). Das KNN trainiert sich selbst, es generiert seine eigenen Abbildungsregeln für die zugrundeliegenden Funktion zwischen Input und Output [Madhok, 1994]. Die mathematisch-physikalischen Gesetze sind für die Güte der Anpassung nicht von Relevanz.

3.3 Vergleich von KNN mit statistischen Modellen

Eine nähere Betrachtung der KNN weist eine Reihe von Ähnlichkeiten zu klassischen Methoden und Modellen in der Statistik auf. So wird z. B. häufig darauf verwiesen, daß mehrschichtige Feed-Forward-Netze ihre Entsprechung in den klassischen Regressionsmodellen finden ([Cheng et al., 1994], [Kanal, 1993], [Sarle, 1994], [Schmitz et al., 1997]) und die Wahl der Aktivierungsfunktion im KNN bestimmt, ob es linear oder nichtlinear ist (Abbildung 5). Vergleichbare Modellansätze gibt es noch in den Bereichen Hauptkomponentenanalyse, Cluster- und Diskriminanzanalyse.




Abb. 5: Multivariate lineare Regression und logistische Regression [Sarle, 1994]

Nur wenige Modelle im Bereich der KNN haben kein äquivalentes Gegenstück auf statistischer Seite. Hier sind v. a. die selbstorganisierenden Karten (Kohonen-Karten) und die Lernende-Vektor-Quantifizierung LVQ zu nennen.

Sarle zeigt auf, daß sich bei näherer Betrachtung die zu behandelnden Größen in der Statistik wie bei KNN lediglich in der Terminologie unterscheiden (Tabelle 2), die grundsätzliche Betrachtungsweise und der daran anhänglichen Probleme und Fragestellungen aber eigentlich gleich sind.

Tab. 2: Vergleich der Terminologie im Bereich der Statistik und KNN

Terminologie in der Statistik	Terminologie bei KNN
Unabhängige Variable	Input
Abhängige Variable, Schätzgröße	Output
Beobachtungen	Muster, Trainingsdaten
Schätzung	Training, Lernen, Adaption, Selbstorganisation
Parameterschätzung	Gewichtsanpassung
Regressionskoeffizienten	Gewichte
Abbruchbedingung	Schwellwerte
Residuen	Schätzfehler
Interaktionen	Neuronen höherer Ordnung
Regressionsanalyse	Überwachtes Lernen
Diskriminanzanalyse	Überwachtes Lernen
Zeitreihenanalyse	Überwachtes Lernen
Nicht-parametrische Regression	Radiale-Basis-Funktion-Netze
Clusteranalyse	Unüberwachtes Lernen
Hauptkomponentenanalyse	Unüberwachtes Lernen
Interpolation, Extrapolation	Generalisierung

In ähnlicher Weise zeigen Cheng und Titterington [Cheng et al., 1994] die Verwandtschaft dieser beiden Forschungsfelder auf. Am Beispiel der Muster- und Spracherkennung zeigen sie, wie eng Statistik und KNN miteinander verknüpft und vergleichbar sind. So stellen sie ein Feed-Forward-KNN der Regressions-, Diskriminanz- und Zeitreihenanalyse gegenüber, vergleichen rekurrente Netze mit Markov-Ketten und die Clusteranalyse mit Kohonens selbstorganisierenden Karten.

Zu jeder Anwendung mit KNN zeigen sie die entsprechende statistische Anwendung und Lösung und betonen im Bezug auf diesen doppelten Lösungsweg die Gefahr, daß „einige Räder neu erfunden“, einige Methoden und Verfahren aber auch sinnvoll anderweitig eingesetzt werden können. Diese Möglichkeiten der gegenseitigen Befruchtung werden am Anschluß an ihre Arbeit zwar heftig diskutiert, nicht aber grundsätzlich in Frage gestellt.

Kanal [1993] geht noch weiter mit seiner Behauptung, vergleichbare einfache statistische Ansätze liefern häufig gleich gute oder bessere Ergebnisse als KNN. Ziel sollte sein, hybride Modelle für die Behandlung komplexer Probleme zu entwickeln oder die verschiedenen Verfahren für unterschiedliche Fragestellungen zusammenzuführen. Es ist zu wünschen, daß diese Diskussion fortgeführt und deren Ergebnisse sinnvoll umgesetzt werden.

3.4 Künstliche Neuronale Netze in der Hydrologie

Dartus et al. [1993] verwendet zur Vorhersage einer Flutwelle in einem offenen Kanal ein Künstliches Neuronales Netz. Ziel ihrer Untersuchung ist es zu zeigen, daß dieser Ansatz bei Kanalsystemen in einem Echtzeitmanagement eingesetzt werden kann. Sie kommen zu dem Schluß, daß die mit dem KNN erzielten Resultate vielversprechend sind und einen Einsatz und Entwicklung in der Industrie lohnen.

Veldkamp et al. [1994] vergleicht die Ergebnisse der Abfluvorhersage eines klassischen hydrologischen Modells, basierend auf einem linearen Regressionsansatz, mit verschiedenen Neuronalen Netzen in Einzugsgebieten von Rhein und Donau. Unterschieden wird nach Kontinuumsberechnungen (Einzugsgebiete am Rhein) und Hochwasserbetrachtungen (Fließstrecken an der Donau). Für die Kontinuumsbetrachtung am Rhein kommen die Autoren zu dem Ergebnis, daß für niedrige bis mittlere Abflüsse das KNN bessere Ergebnisse als das hydrologische Modell liefert. Im Bereich größerer Abflüsse sind die Ergebnisse gleichwertig.

Für den Vergleich bei Hochwasserereignissen werden die gemessenen Abflüsse von zwei Pegeln an der Donau als Eingangsdaten verwendet. Die Kontrollpegel liegen in unterschiedlichen Distanzen zu diesen beiden Pegeln. Veldkamp et al. kommen zu dem Ergebnis, daß bei kurzen Distanzen Künstliche Neuronale Netze deutlich bessere Ergebnisse liefern (siehe Abbildung 6). Sie führen dies darauf zurück, daß Neuronale Netze die während des Wellenablaufs bestehenden Nichtlinearitäten erfassen können und damit gegenüber einem herkömmlichen Modell im Vorteil sind. Veldkamp et al. fügen an, daß eine Berücksichtigung weiterer Daten, wie zum Beispiel der Verdunstung, zu einer weiteren Verbesserung der Ergebnisse führen dürfte.




Abb. 6: Vergleich der Ergebnisse der Vorhersage für einen Pegel mit einem neuronalen Netz und einem linearen Regressionsmodell [nach Veldkamp et al., 1994]

Crespo [1994] versucht mit Hilfe eines KNN für das Einzugsgebiet des Pisuena in Spanien, Trockenheiten vorherzusagen. Hierbei dienen auf das gesamte Einzugsgebiet gemittelte Niederschlagsdaten als Eingangsgröße und der beobachtete Abfluß als Ziel- und Lerngröße. Abbildung 7 zeigt einen Ausschnitt ihrer Abflußberechnungen mittels des KNN. Sie betonen, daß selbst mit einfachen KNN auf schnelle und einfache Weise sehr gute Ergebnisse erzielt werden können.




Abb. 7: Vergleich zwischen gemessenem und mit KNN berechnetem Abfluß [nach Crespo, 1994]

Karunanithi et al. [1994] vergleicht am Einzugsgebiet des Huron River, USA die Leistungsfähigkeit zweier unterschiedlicher KNN und die eines klassischen hydrologischen Regressionsmodells (Power Modell). Als KNN verwendeten sie einerseits ein gebräuchliches Perceptron (vollständig verbundenes, vorwärtsgerichtetes KNN, dessen Gewichte zwischen Input und ersten Hidden Layer nicht veränderbar sind), andererseits ein Cascade-Correlation-Netz. Diese Netze passen während der Trainingsphase durch Hinzufügen von Neuronen und Hidden Layers selbständig die Netztopologie an den abzubildenden Prozeß an. Sie kommen zu dem Schluß, daß die Güte der Ergebnisse vom KNN-Typ 2 deutlich über dem Power Modell liegt und beide KNN Vorteile in Flexibilität und Handhabung haben.

Rogers et al. [1994] untersucht die Optimierung der Grundwassersanierung unter Zuhilfenahme von KNN. Zur Kontrolle und zum Management der Grundwasserhaltung, in ihrem Fall untersuchen die Autoren den Teilchentransport, trainieren sie das Netz, um das Aufkommen und die Transportrichtung vorherzusagen. Anschließend setzen sie dieses „trainierte“ Netz ein, um durch viele Pumpsimulationen die optimale Lösung, nämlich minimale Anzahl an Pumpen bei maximalem Sanierungsgrad, für eine erfolgreiche Grundwassersanierung zu bestimmen. Als Vergleich ziehen sie ein nichtlinear programmiertes Modell heran.

Sie kommen zu dem Schluß, daß

- Ihre Lösung flexibler und zeitgünstiger gegenüber herkömmlichen Methoden sei, da das Netz nur ein einziges Mal trainiert werden müßte
- Das Neuronale Netz eine höhere Unabhängigkeit von den Fluß- und Transportdaten als die herkömmlichen Optimierungsmethoden erlaubt
- Daß der Lösungsvorschlag des Neuronalen Netzes besser ist als das von ihnen ebenfalls verwendete klassische Modell.

Büttner [1997] untersucht in einem kleinen Einzugsgebiet die Möglichkeit der Durchflußvorhersage mit KNN. Hierzu verwendet er als Eingangsdaten neben Niederschlagssummen und Niederschlagsgebietsmitteln auch Durchflußmessungen des zu untersuchenden Pegels. Er verweist in seinem Beispiel auf die Abhängigkeit der KNN von den Trainingsdatensätzen und kommt zu dem Schluß, daß KNN zwar durchaus das Potential für Vorhersage und Prognose haben, dieses aber noch viele Fragen offen läßt.

Die einzige in der Literatur gefundene Anwendung der Abflußmodellierung mit KNN, basierend ausschließlich auf gemessenen meteorologischen Daten, zeigen Clair und Ehrmann [Clair et al., 1998]. Ihr Ansatz ist es, mit Niederschlag, Temperatur, Schnee, Einzugsgebietsgröße und Gefälle (nicht räumlich verteilt) sowie einem Parameter für die Zeit, neben anderen Größen das Monatsmittel des Abflusses zu berechnen. Es zeigt sich, daß zumindest auf dieser zeitlichen Basis die Vorhersage hinreichend gute Ergebnisse liefert, obgleich auch hier teilweise deutliche Abweichungen vom gemessenen Abfluß auftreten. Die zeitliche Auflösung des Modells ist allerdings sehr grob und eine operationelle Abflußvorhersage ist so nicht möglich.

Ebenso selten finden sich Arbeiten zu flächenhaften Abflußmodellierungsansätzen mittels KNN. Bisher haben dies lediglich Smith und Eli [Smith et al., 1995] in einem künstlichen Einzugsgebiet (5 x 5 Rasterelemente) und simulierten Niederschlägen versucht. Als KNN verwenden sie ein vollständig verbundenes dreischichtiges Perceptron mit 25 Neuronen im Input Layer, 15 Neuronen im Hidden Layer und 1 oder 2 Neuronen im Output Layer. Die generierten räumlich verteilten Niederschlagsereignisse werden dem Netz in binärer Kodierung (1 = Rasterelement mit Niederschlag, 0 = Rasterelement ohne Niederschlag) angeboten (Abbildung 8).




Abb. 8: Generierte Niederschlagsmuster und daraus resultierende Hydrographen in einem künstlichen Einzugsgebiet [Smith et al., 1995]

Sie vergleichen die Ergebnisse zwischen der klassischen Modellierung mittels linearer Speicherkaskaden mit denen eines KNN. Die KNN werden auf einzelne wie mehrere Niederschlagsereignisse (hier allerdings nicht in zeitlicher Abfolge) trainiert, um Höhe wie Zeitpunkt des Hochwasserscheitels vorherzusagen. Sie kommen zu dem Schluß, daß für keine der beiden Anwendungen das KNN in der Lage ist, die Abflüsse in Höhe und Zeitpunkt direkt zu berechnen oder korrekt vorherzusagen.

Diese Arbeiten zeigen, daß gerade in Richtung der

- Prognose von Abflüssen mit KNN und
- der flächenhaften Abflußmodellierung mittels KNN
- in einem natürlichen Einzugsgebiet
- mit gemessenen Eingangsdaten

noch erheblicher Forschungsbedarf besteht. Bei den bisherigen Ansätzen der Abflußmodellierung mittels KNN fehlt in der Regel eine Integration von Raum- und Lageinformation oder gar flächenhaft verteilter Informationen.

Die prognostische Arbeit mit KNN [Clair et al., 1998] zeigt zwar gute Ergebnisse, wenngleich in grober zeitlicher Auflösung. Es fehlt aber eine grundsätzliche Untersuchung der Eignung von KNN für diesen Zweck. Viele Autoren betonen in diesem Zusammenhang die enge Bindung der KNN an die Trainingsdaten, was dann aber einen starken Hinderungsgrund für einen solchen Einsatz bedeuten würde.

Die vorliegende Arbeit behandelt die hier noch offenen Fragen und zeigt auf, inwieweit KNN für eine flächenbasierte Abflußvorhersage und -prognose geeignet sind, welche Eingangsdaten hierfür sinnvoll verwendet werden können oder müssen, welche räumlichen Informationen in welcher Netztopologie mit welchem Lernprozeß eingesetzt werden, um letztendlich die o. a. Fragen zu beantworten.

4 Ziel

Die herkömmliche hydrologische Modellierung stößt mit der physikalisch basierten Beschreibung (Differentialgleichungen oder Transferfunktionen) des komplexen und nichtlinearen Abflußprozesses sowie der Gewinnung der dafür notwendigen Modellparameter durch aufwendiges Preprocessing oft an ihre Grenzen. Ein Ausweg ist schon immer in systemtechnischen konzeptionellen Modellen gesehen worden.

Der holistische Ansatz Künstlicher Neuronaler Netze erlaubt es, diese komplizierte Beschreibung zu umgehen. Der abzubildende Prozeß muß nicht in seine logischen Teilprozesse zerlegt werden (Abbildung 9). Dieses Potential des datenbasierten Ansatzes von Künstlichen Neuronalen Netzen im Bereich der Modellierung nichtlinearer Prozesse ist auch in der Hydrologie bereits länger bekannt. Die zusätzlichen Informationen des Raumbezuges blieben bei den bisherigen Arbeiten allerdings stets unberücksichtigt.




Abb. 9: Vergleich zwischen herkömmlicher hydrologischer Modellierung und N-A-Modellierung mittels KNN

In der Arbeit wird nun versucht, die Modellierung der flächenhaften Abflußbildung und Abflußkonzentration mittels Künstlicher Neuronaler Netze in der Fläche, d. h. unter Berücksichtigung der Raum- und Lagebeziehungen im Untersuchungsgebiet, durchzuführen. In der Abfluß- und Hochwasservorhersage (Tages- und Stundenschritte) wird mit aktuellen hydrologischen und meteorologischen Eingangsdaten sowie Höhen- und Fernerkundungsdaten mit dem Ziel gerechnet, den Abfluß der nächsten Zeit mit hoher Treffsicherheit und geringer Streuung anzugeben.

Zudem wird untersucht, inwieweit KNN zur Prognose der Abflüsse mit dem Ziel eingesetzt werden können, langfristige charakteristische Abflußganglinien (Tagesschritte) mit der gesamten Breite ihrer Streuungen, wie sie das langfristig variable Niederschlagsgeschehen induziert, vorauszuberechnen.

Die sich bei dieser Vorgehensweise stellenden Fragen, wie zum Beispiel

- Können zeitlich invariante raumbezogene Daten in die Netzstruktur des KNN integriert werden ?
- Können darüber die Fließzeiten im Einzugsgebiet abgebildet werden ?
- Können zeitlich variable raumbezogene Daten in die Berechnung einfließen ?
- Müssen die raumbezogenen Daten, hier v. a. Höhendaten und Landnutzung, für die Nutzung im KNN vorverarbeitet werden ?
- Wie muß der meteorologische Input behandelt werden ?
- Wie stellt sich bei dieser Vorgehensweise der Lernprozeß dar ?
- Wie muß hierfür das KNN gestaltet werden ?
- Inwieweit lassen sich durch die flächenhafte Modellierung Verbesserungen gegenüber den bisherigen Methoden der Abflußmodellierung mit KNN erzielen ?

werden in der Arbeit erstmals diskutiert und beantwortet.

Ziel der Arbeit ist die Aussage, mit wieviel Aufwand auf Seiten des Preprocessings und des Netzdesigns eine flächenhafte Abflußmodellierung mittels KNN mit welcher Ergebnisqualität zu erreichen ist.

5 Methodik

5.1 Die Abflußmodellierung aus hydrologischer Sicht

Die Analyse des Niederschlag-Abfluß-Prozesses ist eine Hauptaufgabe hydrologischen Forschens. Sie beschäftigt sich mit der Untersuchung der Beziehungen zwischen den abflußwirksamen Niederschlägen, der Transformation dieser durch das Einzugsgebiet und den daraus resultierenden Abflüssen an einem bestimmten Flußquerschnitt.

Die N-A-Modellierung dient im allgemeinen folgenden Zielen:

- Ermittlung der Bemessungswerte für wasserbauliche Maßnahmen
- Nachweis der Wirksamkeit von Hochwasser-Schutzmaßnahmen
- Echtzeitvorhersage von Hoch- und Niedrigwasserabflüssen
- Nachweis der Abflußveränderung durch Veränderung von Randbedingungen und meteorologischem Antrieb

Als effektives Mittel zur vereinfachten Beschreibung der komplexen, häufig interagierenden, in der Natur ablaufenden Prozesse gilt die Systemtheorie. Zur quantitativen Beschreibung eines hydrologischen Systems dienen mathematische Modelle. Kernstück dieser mathematischen Modelle ist eine Systemfunktion U , die die Transformation eines Impulses (Eingabesignale $X(t)$) in eine Zeitfunktion des Abflusses (Ausgabesignale $Y(t)$) in der Zeit (t) bewirkt.




Abb. 10: Konzept der Systemoperation eines Eingabe-Ausgabe-Modells (nach [Dyck/Peschke, 1995])

Die Beziehungen in hydrologischen Systemen werden meistens als deterministisch angesehen. Somit ist es möglich, bei bekanntem Systemoperator U die Systemausgänge (Abflüsse, Verdunstung, ...) aus gegebenen Systemeingängen (Niederschlag, Zuflüsse, ...) zu berechnen und vorherzusagen. Voraussetzung dafür ist aber die Ermittlung des Systemoperators, d. h. die Systemidentifikation, und dessen Nachbildung durch ein Modell.

An diesem Systemoperator, der Transformation des Niederschlags in den Abfluß, sind eine Vielzahl von Prozessen beteiligt, die physikalisch erklärbar und damit auch berechenbar sind. Dies führt zwangsläufig zu Modellen, die eine idealisierte Beschreibung (Abstraktion) der Realität darstellen, sie sind Stellvertreter der durch sie abgebildeten Systeme [Dyck/Peschke, 1995].

5.2 Klassische Art der Abflußmodellierung

Heute steht die hydrologische Forschung vor der Aufgabe, Modelle für eine Systembeschreibung zu entwickeln, die einerseits in der Lage sind, die hydrologischen Prozesse in ihrer ganzen Komplexität möglichst gut nachzubilden und andererseits den Anforderungen an verfügbarer Datenlage zu genügen. Dies stellt aber gerade in größeren Einzugsgebieten meist ein unlösbares Problem dar.

Üblicherweise wird die Abflußmodellierung in drei Hauptphasen unterteilt (Abbildung 11):

- Abflußbildung
- Abflußkonzentration
- Abflußveränderung (Wellenabflachungsphase)




Abb. 11: Hauptphasen der Transformation des Niederschlags in Abfluß [nach Dyck/Peschke, 1995]

Die Abflußbildung beschränkt sich auf die Ermittlung des direkten Abflusses. Hier entscheidet sich, welcher Teil des Niederschlags auf der Landoberfläche oder im Boden festgehalten und im wesentlichen durch Verdunstung ausgeschöpft wird und welcher Anteil in Form von Landflächenabfluß (= Oberflächenabfluß), Zwischenabfluß (= Interflow) und Grundwasserabstrom (= Basisabfluß) abfließt. Bei der Abflußkonzentration wird der flächenhaft verteilte Effektivniederschlag (= Direktabfluß) durch laterale Fließvorgänge ober- oder unterirdisch dem nächsten Vorfluter zugeleitet. Die Effektivniederschlagsganglinie wird über Translation (zeitliche Verschiebung) und Retention (Dämpfung) in die Durchflußganglinie des Pegelquerschnittes transformiert. Die Abflußveränderung letztendlich beschreibt die Abflachung der aus den Einzugsgebieten ablaufenden Hochwasserwellen im Wasserlauf.

Diese Hauptphasen, hier v. a. die Abflußbildung, beinhalten eine Vielzahl von Teilprozessen und Einzelkomponenten. Diese Einzelvorgänge können sich überlagern und gegenseitig beeinflussen, die für die Teilvorgänge maßgeblichen Parameter können räumlich variieren und durch andere Teilprozesse zeitlich verändert werden. Die Teilprozesse sind in ihrer Gesamtheit nur schwer zu überschauen. Es muß notwendigerweise eine Abstraktion vom komplexen und komplizierten Naturgeschehen vorgenommen werden. Abbildung 12 zeigt die Vielfalt der Einzelkomponenten, die Einfluß auf die Abflußbildung haben sowie das Abflußereignis modifizieren.




Abb. 12: Teilprozesse des N-A-Prozesses

Zu den vertikalen Transportvorgängen der Abflußbildung kommt noch eine laterale Komponente, die die Abflußkonzentration (Fließzeiten) prägt. All diese Prozesse unterliegen kurzfristigen ereignisbezogenen Modifikationen und langfristigen Veränderungen im Jahresgang und interagieren noch miteinander.

Während dank der Computerentwicklung die Rechenleistung heute kaum noch limitierenden Einfluß auf die Modellierung hat, erfährt deren Genauigkeit häufig eine Einschränkung durch die verfügbare Datenlage für die Berechnungen.

Im Laufe der Zeit sind eine Vielzahl unterschiedlicher Modellansätze entwickelt worden, die sich wie folgt klassifizieren lassen (Abbildung 13):




Abb. 13: Klassifizierung hydrologischer Modellansätze [Dyck/Peschke, 1995]

Stochastische Modelle berücksichtigen vorrangig nicht die Kausalität des zugrundeliegenden Prozesses. Hier ist entweder die Eingabe eine Zufallsfunktion oder ihre Parameter sind Zufallsvariablen. Demgegenüber werden durch deterministische Modelle mehr oder weniger detailliert die Abflußbildung und Abflußkonzentration flächenhaft und nach Komponenten beschrieben. Je nach Komplexität der Art und Menge der beschriebenen physikalischen Prozesse können sie eingeteilt werden in:

- White-Box-Modelle mit umfassender Berücksichtigung der Grundgesetze der Physik
- Gray-Box-Modelle mit vereinfachter Beschreibung der Physik (Konzeptionelle Modelle)
- Black-Box-Modelle ohne Berücksichtigung der Physik, nur die Ursache-Wirkungsbeziehung zwischen Input und Output wird betrachtet

Bei den Black-Box-Modellen wird die Übertragungsfunktion aus den beobachteten Ein- und Ausgangsgrößen ohne Berücksichtigung der Feinstruktur der Systemübertragungsfunktion bestimmt [Maniak, 1992]. Hierzu können alle Ansätze mit KNN gerechnet werden.

5.3 Abflußmodellierung mit Hilfe von Künstlichen Neuronalen Netzen

Der datenbasierte Ansatz von KNN erfordert das Erlernen der Beziehung zwischen Eingangsdaten (Niederschlag, Temperatur, Abfluß der Oberliegerpegel, ...) und der Zielfunktion „Gemessener Abfluß am Untersuchungspegel“. Dies erfolgt durch überwachtes Training des Netzes, d. h. dem Netz werden in der Lernphase sowohl die gemessenen Eingangsdaten wie auch die gemessenen Ausgangsdaten präsentiert. Der Lernprozeß besteht nun darin, die zugrundeliegende Beziehung zwischen Input und Output in den Gewichten des Netzes abzubilden. Ein auf diese Weise trainiertes Netz kann dann mit neuem, nicht im Lernprozeß repräsentierten Input den entsprechenden Output berechnen.

Abbildung 14 stellt für eine Hochwasserbetrachtung einen Vergleich zwischen der klassischen Modellierung und dem Ansatz mittels KNN dar.




Abb. 14: Vergleich zwischen klassischem Modellierungsansatz und dem Ansatz mittels KNN für die Hochwasservorhersage

Die Betrachtung des Abflußkontinuums ist sehr ähnlich, wenngleich sich hier nach der klassischen Methode die betrachteten Teilprozesse etwas von denen der Hochwassermodellierung unterscheiden (Abbildung 15).




Abb. 15: Vergleich zwischen klassischem Modellierungsansatz und dem Ansatz mittels KNN für die Prognose des Abflußkontinuums

Für beide Ansätze zeigt sich die integrale Arbeitsweise der KNN im Hinblick auf die Abflußbildung. Nicht die einzelnen Teilprozesse werden nachgebildet, das KNN entwickelt seine Systemübertragungsfunktion aus der Beziehung zwischen Eingangs- und Ausgangsdaten. Die Art und Relevanz der einzelnen Teilprozesse kann hier nur über die Auswahl an sinnvollen und relevanten Eingangsdaten erfolgen. Die Abflußkonzentration, die die Fließzeiten im Einzugsgebiet bestimmt, muß bei einem klassischen Feed-Forward-Netz durch das Netz selbst erlernt werden. Über die Anzahl der Verknüpfungen zwischen Meßstation/Rasterelement und dem Auslaßpegel kann zwar eine gewisse Dämpfung des Impulssignals für weiter entfernte Punkte erreicht werden, eine zeitliche Transformation ist so aber nicht möglich.

Die Eingangsdaten können im einfachsten Fall zeitlich versetzte Abflüsse $Q(t-1)$ der Oberliegerpegel sein, um damit den Abfluß $Q(t)$ am untersuchten Auslaßpegel zu berechnen. In diesem Fall reduziert sich ein KNN auf ein lineares Regressionsmodell.

Generell wurden die hydrologischen wie meteorologischen Trainingsdaten, um eine Vorhersage der Abflüsse zu erreichen, dem Netz zeitversetzt gegenüber den gemessenen Zieldaten angelegt. Durch $Q(t) = Q(t-1) \dots Q(t-n)$ werden sie zeitlich verschoben, die Größe dieses Zeitversatzes ist variabel. Untersucht wurden auf diese Weise Vorhersagen bis zu 24 Zeitschritten hin.

Komplexer wird die Abflußberechnung mittels meteorologischer Eingangsdaten, da hier eine stark nichtlineare Beziehung zwischen Input und Output besteht. Hierbei gilt es, die möglichen Einflußfaktoren über die verwendeten Eingangsdaten zu erfassen und sie dem Netz anzubieten. In Anlehnung an Abbildung 14 und 15 zeigt Tabelle 3 eine Auflistung der zu berücksichtigenden Teilprozesse und ihre Substitution über Eingangsdaten bei der flächenhaften Abflußmodellierung mittels KNN.

Tab. 3: Einflußgrößen auf den Abflußprozeß und ihre Berücksichtigung über Eingangsdaten bei der flächenhaften Abflußmodellierung mittels KNN

Einflußgrößen auf den Abflußprozeß	Ihre Berücksichtigung im KNN
Unveränderliche gebietsspezifische Faktoren	
Größe und Form des Einzugsgebietes	Anzahl Neuronen und Verbindungen
Fließwege	Verknüpfung der Neuronen im Hidden Layer
Geländeneigung	Initialgewichte der Verknüpfungen
Bodenart	Flächenhafte Bodeninformation
Aufschluß des Geländes	Vernachlässigt
Periodisch veränderliche gebietsspezifische Faktoren	
Natürliche Vegetation	Normalized Differential Vegetation Index NDVI
Landwirtschaftliche Nutzung	NDVI
Evapotranspiration	Temperatur, NDVI
Anthropogene Faktoren	
Landnutzung	NDVI
Veränderliche ereignisspezifische Faktoren	
Niederschlagsmenge und -dauer	Zeitreihe der Niederschläge
Zeitliche Verteilung der Niederschläge	Zeitreihe der Niederschläge
Räumliche Verteilung der Niederschläge	Regionalisierung mittels der Thiessen-Methode
Bodenfeuchte zu Beginn der Ereignisse	Vorfeuchteindex

5.4 Vorgehensweise

Gerade im Bereich Künstlicher Neuronaler Netze ist es im Vorfeld, lediglich auf theoretischen Erkenntnissen aufbauend, sehr schwer, eine gewählte Netztopologie als praktikabel zu klassifizieren. Die vielen Freiheitsgrade in der Netztopologie (Anzahl der Layer und Neuronen, Art und Anzahl der Verbindungen und deren Gewichte, Transferfunktion, Schwellwerte, Lernverfahren) erlauben keine allgemeingültige Aussage über dessen Charakteristik. Das Netz und seine Struktur bildet sich an und mit der aktuellen Anwendung heraus.

Daher ist zunächst mit einfachen Ansätzen in der Netztopologie und den Eingangsdaten begonnen worden, um prinzipiell die Machbarkeit der Abflußmodellierung mittels KNN rechnerisch zu prüfen („trivialer Ansatz“). Darauf aufbauend werden weitere Datenebenen integriert und das KNN komplexer gestaltet.

Dadurch ist gewährleistet, daß frühzeitig Ergebnisse über die Machbarkeit des Verfahrens und die Qualität der Ergebnisse vorliegen. Zudem ist es so möglich, die Relevanz verschiedener Daten für den Abflußprozeß zu bestimmen und eventuell auf Daten mit geringem oder fehlendem Einfluß auf das Abflußgeschehen zu verzichten. Zudem steht somit eine Datenbasis zum Vergleich zur Verfügung, die Aussagen über Güte, Nutzen und Erfolg weiterführender Ansätze erlaubt.

In der zweiten Projektphase werden neben zunehmend mehr Eingangsdaten auch die Raum- und Lagebeziehungen der Meßstellen untereinander sowie die Gewässerstruktur des Untersuchungsgebietes in die Topologie des KNN integriert („einfache Netztopologie“). Eine flächenhafte Berechnung findet hier noch nicht statt.

Weiterführend ist in der dritten Phase die Abflußbildung und -konzentration in einem Einzugsgebiet unter Einbeziehung von punkt- wie flächenbezogenen Eingangsdaten mit KNN rasterpunktbezogen berechnet worden („komplexe Netztopologie“). Mittels KNN werden Fernerkundungsdaten (NOAA-AVHRR), Höhenmodell, hydrologische und meteorologische Zeitreihen ohne vorherige Bearbeitung direkt dem KNN zur Verfügung gestellt. Hierdurch wird die aufwendige Vorverarbeitung der Eingangsdaten weitgehend vermieden. Dies gilt für die Vorhersage wie auch für die Prognose.

Abbildung 16 zeigt in Anlehnung an Abbildung 10 die Komplexität der untersuchten Ansätze. Mit zunehmender Intergration der Lage- und Rauminformation ins KNN oder zunehmender Anzahl von punktuellen oder räumlichen Eingangsdaten werden mehr und mehr systemtechnische Faktoren mit berücksichtigt.




Abb. 16: Schematische Darstellung der Komplexität der untersuchten Ansätze am Beispiel der Systemtheorie

5.5 Arbeitsschritte

Die Entwicklung der Arbeit über ihre drei Phasen der zunehmenden Verwendung verfügbarer raumbezogener Informationen (Repräsentation in den Eingangsdaten oder Intergration in das KNN) sowie den Untersuchungen zur Abflußprognose stellt sich somit wie in Abbildung 17 dar.




1. Phase		
Trivialer Ansatz		Keine räumlichen Informationen Q an Pegeln N an Stationen
2. Phase		
Einfache Netztopologie		Lagebeziehungen der Meßstellen im Einzugsgebiet Q an Pegeln N an Stationen
3. Phase		
Komplexe Netztopologie		Rasterpunkt-bezogene Modellierung räuml. verteilte Daten Keine Q
4. Phase		
Prognose	Trivialer Ansatz	Keine räumlichen Informationen Q an Pegeln Keine N

Abb. 17: Zunehmende Integration räumlicher Information von der stationsbezogenen hin zur flächenhaften Modellierung mittels KNN und Abflußprognose

5.5.1 Trivialer Ansatz

Zur Einarbeitung in den verwendeten Stuttgarter Neuronaler Netz Simulator (SNNS, Version 4.1 der Universität Stuttgart, Fakultät für Informatik), zur Entwicklung der notwendigen Programme für die Anwendung und Auswertung mit SNNS und zur Untersuchung der prinzipiellen Machbarkeit verschiedener Ansätze und Relevanz hydrologischer und meteorologischer Eingangsdaten wurden zunächst entsprechend den meisten bisherigen Ansätzen der Abflußmodellierung mittels KNN einfache Ansätze gewählt. Darauf aufbauend wurden zunehmend mehr meteorologische Eingangsdaten und aufwendigere Netztopologien verwendet. Diese Arbeiten erfolgen zu Beginn noch ohne Berücksichtigung von Raum- und Lageinformationen der Meßstellen im Einzugsgebiet („trivialer Ansatz“).

Als Basis für die Berechnung dient hier ein vollständig verbundenes Feed-Forward-Netz mit einem Input Layer, einem oder mehreren Hidden Layern und einem Neuron im Output Layer. Die Anzahl der Neuronen im Input Layer entspricht der Anzahl der zu berücksichtigenden Stationen, das Neuron im Output Layer repräsentiert den zu untersuchenden Zielpegel (Abbildung 18).




Abb. 18: Vollständig verbundenes Feed-Forward-Netz

Die Anzahl der Hidden Layer sowie die Anzahl der Neuronen darin wird aus Ermangelung an gesicherten Verfahren durch „trial and error“ ermittelt. Es zeigt sich, daß meist die doppelte Anzahl der Neuronen im Hidden Layer bezogen auf den Input Layer die besten Ergebnisse liefern. Die Verwendung mehrerer Hidden Layer liefert hier keine wesentlichen Verbesserungen.

Das Training der KNN erfolgt immer überwacht. Die zu erlernende Zielfunktion ist je nach Anwendung die Abflußganglinie des Kontinuums oder eines Hochwasserereignisses. Um vorherige Zustände des Einzugsgebietes mit erfassen zu können, werden als Eingangsdaten unterschiedlich weit zurückliegende hydrologische und/oder meteorologische Meßwerte verwendet. Diese reichen von aktuell zum Berechnungszeitpunkt gemessenen bis hin zu 24 Stunden bzw. Tagen vorher (Zeitfenster von 0,1,2,...,24). Die Fließzeiten im Untersuchungsgebiet können hier nur vom KNN selbst erlernt werden.

In dieser Projektphase werden eine Vielzahl verschiedener Lernverfahren und Aktivierungsfunktionen in unterschiedlichen Kombinationen getestet. Hierbei zeigt sich, daß ein einfaches Feed-Forward-Netz mit Backpropagation-Lernverfahren die besten Ergebnisse mit hinreichend kurzen Trainingszeiten liefert. Daher wird dieser Netztypus verwendet, alle im Folgenden aufgeführten Berechnungen werden mit dieser Art von KNN durchgeführt.

Aufgrund der in der Literatur genannten guten Ergebnisse bei der Abflußmodellierung mit ausschließlich meteorologischen Eingangsdaten in grober zeitlicher Auflösung (Monatsmittel) werden auch hier Arbeiten dazu durchgeführt. Es werden verschiedene Zeitschrittweiten von 1 bis 60 Tagen getestet. Die daneben getesteten Varianten dienen der Ergebnisbestätigung und -überprüfung, unterscheiden sich aber nicht grundsätzlich von den dargestellten Resultaten.

5.5.2 Einfache Netztopologie

Sind in einem Einzugsgebiet mehrere Pegel in Form von Ober- und Unterliegerpegeln vorhanden, können sich deren Meßergebnisse ergänzen, zusätzliche Informationen beinhalten wie auch mögliche Fehler in den Abflußmessungen aufdecken oder ausgleichen.

Zu Beginn wird versucht, die Informationen über Lage- und Raumbeziehungen zwischen Ober- und Unterlieger mehrerer hydrologischer Pegel im gesamten Einzugsgebiet in einem Künstlichen Neuronalen Netz zu verarbeiten. Danach werden auch die Lagebeziehungen vorhandener meteorologischer Stationen im Netz so verknüpft, daß diese Informationen bei der Simulation mit einfließen können. In einem dritten Schritt werden dann beide Ansätze in einem Netz miteinander verbunden, hier fließen sowohl die Lagebeziehungen der meteorologischen Meßstellen wie die Gewässerstruktur mit ein. So ist es bereits möglich, die Fließzeiten über die Anzahl der Verknüpfungen und somit Anzahl der Modifikationen des Inputsignals zu berücksichtigen.




Abb. 19: Gewässernetzstruktur am Beispiel des Mains mit Pegeln bis zum Pegel Schwürbitz (links) und entsprechende Netztopologie des KNN (rechts)

Wie beim trivialen Ansatz werden auch hier verschiedene Eingangsdaten, Lernverfahren, Aktivierungsfunktionen und Netztopologien getestet. Tabelle 5 zeigt die hier durchgeführten Varianten. Es zeigt sich wieder, daß ein klassisches Feed-Forward-Netz mit Backpropagation-Lernverfahren die besten Ergebnisse liefert. Hier ist die Anzahl der Neuronen und Hidden Layer durch die Strukturen im Einzugsgebiet vorgegeben, sie müssen nicht iterativ ermittelt werden.

Neben den hier verwendeten meteorologischen und hydrologischen Eingangsdaten wird für den trivialen Ansatz wie für die einfache Netztopologie weiterhin untersucht, inwieweit sich die Berechnungsergebnisse durch Hinzunahme weiterer Informationsebenen verbessern lassen. Ein wichtiger Einflußfaktor auf den Abflußprozeß ist die Jahreszeit. Als ein Maß hierfür ist ein Zeitindex (1 bis 365 Tage) als weiterer Input ins KNN getestet worden. Bei hydrologischen Eingangsdaten kann die Information, ob man sich auf einem auf- oder absteigenden Ast der Abflußganglinie befindet, sehr wichtig sein. Um dies mit ins Netz einfließen zu lassen wird die Differenz der Eingangsdaten zu ihren Werten vom vorherigen Zeitschritt mit angelegt (siehe hierzu auch 5.5.3).

5.5.3 Komplexe Netztopologie

Den Vorteilen der einfachen Netztopologie (leichte Handhabung, schnelles Training) steht der Nachteil gegenüber, daß zum einen die Rauminformation nicht in der vollen Auflösung einfließt, zum anderen die den Abfluß stark modifizierende Komponente Vegetation gänzlich unberücksichtigt bleibt. Diese Informationen v. a. der Vegetation können mit dem komplexen Ansatz berücksichtigt werden, die raumbezogenen Daten werden entweder direkt in die Netzgestaltung integriert oder in die Eingangsdaten mit aufgenommen.

Höheninformationen

Bereits im Vorfeld werden die relevanten, zeitlich invarianten Informationen aus Höhendaten abgeleitet, um sie im Netzdesign zu berücksichtigen und zu integrieren. So können die großen Eingangsdatenmengen reduziert und die für KNN ohnehin großen Rechenzeiten verkürzt oder die Berechnung gar erst ermöglicht werden.

Zur Analyse des Höhenmodells wird ein Verfahren von Tarboton [Tarboton, 1997] adaptiert. Dieses extrahiert aus einem Höhenmodell die Pixel, die zu einem wählbaren Pegel hin entwässern und speichert diese in einer Karte des Einzugsgebietes. Die Anzahl der Pixel in der Karte bestimmt die Größe des Einzugsgebietes, dessen Form wird über deren Lage definiert. Für jedes Pixel wird zudem die Richtung und Größe des lokalen Gefälles (=Fließrichtung) berechnet.




Abb. 20: Definition der Variablen zur Berechnung des lokalen Gefälles eines Pixels (hier grau)

Nach Abbildung 20 ist die Größe des abwärtsgerichteten Gefälles g und dessen Richtung dir für das aktuell betrachtete Pixel in Beziehung zu seinen jeweiligen 8 Nachbarn definiert durch

$$g_m = \sqrt{(s_{x_m}^2 + s_{y_m}^2)}$$

und

$$dir_m = \tan^{-1}(s_{y_m}/s_{x_m})$$

wobei gilt:

$$s_{x_m} = (e_0 - e_1)/dist_{x_m}$$

und

$$s_{y_m} = (e_1 - e_2)/dist_{y_m}$$

mit:

e_0, e_1, e_2 Höhe [m] des entsprechenden Pixels

$dist_{x_m}, dist_{y_m}$ Distanz [m] zwischen den Pixeln.

m Laufindex 1 bis 8 für alle 8 Nachbarn

Für jede der acht möglichen Entwässerungsrichtungen eines Pixels wird die Größe des Gefälles ($g_1, g_2, \dots, g_8$) berechnet. Die Fließrichtung g_F ergibt sich aus der Richtung dir_m mit dem Maximum des Gefälles g_m über alle benachbarten Pixel.

$$g_F = dir_m \text{ wenn gilt } g_m = \max\{g_1, g_2, \dots, g_8\}$$

Das Programm von Tarboton wurde so angepaßt, daß aus den Ergebnissen dieser Berechnungen automatisch die entsprechenden Netzwerkdateien für den Netzwerksimulator SNNS erstellt werden. Die Anzahl der Pixel im Einzugsgebiet bestimmt die Anzahl der Neuronen im Input und Hidden Layer (Abbildung 21). Zur Eingabe der Informationen ist der Input Layer 1:1 mit dem Hidden Layer verbunden. Die Verbindungen der Neuronen im Hidden Layer werden dann über die Fließwege im Einzugsgebiet definiert. Die Größe der Gewichte (Vorbelegung) auf den Verbindungen im Hidden Layer werden durch die Größe des Gefälles zwischen den Rasterelementen bestimmt. Die Abbildung des Einzugsgebietes findet somit im Hidden Layer statt, der Input Layer dient nur zur Dateneingabe ins KNN (Abbildung 22).




Abb. 21: Entwicklung der Netztopologie des KNN aus dem Höhenmodell

Die Fließzeiten im Einzugsgebiet können wie bei den vorherigen Ansätzen vom KNN erlernt und über die Anzahl der Verknüpfungen berücksichtigt werden. Hinzu kommt hier die Möglichkeit, für jedes Rasterelement im Einzugsgebiet einen Lauflängenindex anzugeben, der als ein Maß für den Abstand vom Rasterelement zum Gebietsauslaß definiert ist. Dies kann dem Netz als weitere Informationsquelle angeboten werden. So kann über die Distanzen im Einzugsgebiet auch eine zeitliche Transformation des Niederschlags erfolgen.




Abb. 22: Rasterpunktbezogene Abbildung des Einzugsgebietes im KNN

Landnutzungsinformationen

Informationen über die flächenhafte Landnutzung werden aus dem Normalized Differential Vegetation Index (NDVI) des NOAA-AVHRR gewonnen. Dieser berechnet sich aus Kanal 1 (im roten Bereich des Spektrums) und Kanal 2 (Nahes Infrarot) des Sensors nach Gleichung (3):

$$G = \frac{ch2 - ch1}{ch2 + ch1} \quad (3)$$

mit

G neuer Grauwert

ch1, ch2 Kanal 1 und 2 des Sensors

Als Funktion der Grünfärbung eines Pixels in Abhängigkeit der Vegetation kann dieser direkt als quantitative Größe im KNN verwendet werden. Die zeitliche Veränderung der Vegetation im Jahresgang wird über eine Differenzbildung zweier aufeinanderfolgender Datensätze erzielt (Abbildung 23). Monatliche Mittel der NDVI-Datensätze von Europa sind für die letzten drei Jahre akquiriert worden. Die Differenzbildung eines Jahresgangs des NDVI erfolgt über das Geoinformationssystem Arc/Info. Ein Vergleich der Jahresserien zeigt nur geringe Unterschiede im Jahresgang der Landnutzung zwischen den einzelnen Monatsmittelwerten, daher wurde die Serie 1996-1997 als repräsentativ angenommen.




Abb. 23: Schematische Darstellung der Berechnung der Differenzdatensätze des NDVI

Die Datengridweite des Höhenmodells wie der NDVI-Datensätze wurde auf 1 km^2 gesetzt, da dies ein gerade noch gangbarer Kompromiß zwischen Einzugsgebietsgröße und Größe der daraus resultierenden KNN ist.

Boden

Flächenhafte digitale Bodendaten liegen als Arc-Info-Grid in einem 50 m-Raster vor (Abbildung 24 am Beispiel des Einzugsgebietes der Vils/Oberpfalz). Die Daten repräsentieren insgesamt 7 Bodenklassen. Für die Anwendung im Neuronalen Netz werden sie über Zahlenwerte (1-7) kodiert, die die Abflußbereitschaft der unterschiedlichen Bodenarten werten.

- | | |
|------------------|--------------------|
| 1 Sand | 5 lehmiger Schluff |
| 2 anehmiger Sand | 6 schluffiger Lehm |
| 3 sandiger Lehm | 7 Moor |
| 4 Lehm | |

Die Daten werden entsprechend der räumlichen Auflösung der Landnutzungsdaten mit Hilfe des Nearest-Neighbourhood-Verfahren auf 1 km^2 resampelt.



Abb. 24: Bodenarten am Beispiel Einzugsgebiet der Vils/Oberpfalz

Regionalisierung der meteorologischen Eingangsdaten

Der Niederschlag wie auch die Temperatur muß bei dieser Anwendung sowohl für stündliche als auch tägliche Meßwerte als flächenhafte Größe eingehen und somit auf die Fläche extrapoliert werden. Bei den vorliegenden Untersuchungen wird die Thiessen-Methode verwendet. Das Einzugsgebiet wird entsprechend der Entfernung der Rasterelemente zu den meteorologischen Meßstationen aufgeteilt und der an der nächstgelegenen Station gemessene Niederschlag als gültig und repräsentativ angenommen. Andere Alternativen (Residuenverfahren, Inverse-Distance-Weight-Verfahren) wurden aufgrund der schlechten Simulationsergebnisse nicht mehr getestet.

Zeitindex $Z(t)$

Um beim trivialen Ansatz wie bei der einfachen Netztopologie für die Prognose des Abflußkontinuums einen Faktor für die Jahreszeit berücksichtigen zu können, ist als ein Maß hierfür die Tagnummer des Datensatzes im Jahr $Z(t) = 1$ bis 365 verwendet und als zusätzlicher Eingangsdatensatz angewendet worden.

Differenz zum Vortag $Diff(t)$

Bei der Anwendung hydrologischer Eingangsdaten kann es sinnvoll sein, als zusätzliche Information die aktuelle Steigung der angelegten Abflußganglinie zum entsprechenden Datensatz mit zu verwenden. Hierfür wird aus den Abflußdaten Q_i jedes Eingabepegels über die Differenz zeitlich aufeinander folgender Daten $Diff(t) = Q_i(t) - Q_i(t-1)$ ein zusätzlicher Eingabevektor erzeugt und dem KNN mit angeboten.

Vorregenindex $VN_{m,i}$

Neben den oben aufgeführten Eingangsdaten ist weiterhin der regionalisierte Vorregenindex $VN_{m,i}$ als ein Maß der Vorfeuchte der einzelnen Rasterelemente m im Einzugsgebiet verwendet worden.

$$VN_{m,i} = \sum_{t=1}^{30} N_{x,y}(t) \cdot 0.9^t$$

mit

t	1 bis 30 in Tagen
i	Untersuchungszeitraum
x	Zeilen im digitalen Modell
y	Spalten im digitalen Modell

Diese Information dient dazu, die Bodenfeuchteverhältnisse zu Beginn eines Ereignisses und so das Infiltrationsvermögen des Bodens abzuschätzen.

Lauflängenindex LL_m

Je weiter eine Rasterfläche m vom Untersuchungspegel entfernt ist, desto später trägt diese Fläche zum Abfluß des Flußquerschnitts bei. Um diese Fließzeiten im Einzugsgebiet als Input mit ins KNN einfließen lassen zu können, ist der inverse Abstand der Rasterelemente vom Gebietsauslaß verwendet worden.

$$LL_m = \frac{1}{dist_{x,y}}$$

wobei gilt:

$$dist_{x,y} = \sqrt{a^2 + b^2}$$

mit:

- a Abstand des Pixels vom Untersuchungspegel in Richtung der Spalten y [Pixel]
- b Abstand des Pixels vom Untersuchungspegel in Richtung der Zeilen x [Pixel]
- x Zeilen im digitalen Modell
- y Spalten im digitalen Modell

Summe der Niederschläge $Sum N_i$

Zur Abschätzung des Einflusses der räumlich verteilten Niederschläge sind zum Vergleich auch Berechnungen mit der Summe der vorher regionalisierten Niederschlagsmengen durchgeführt worden. Dies soll zeigen, ob grundsätzliche Fehler aus der Regionalisierung der Niederschläge resultieren oder ob die Berechnungsergebnisse unabhängig von der Art und Form des Niederschlagsdargebots sind. Die Summe wird gebildet über ein Aufaddieren der vorher mit dem Thiessen-Verfahren regionalisierten Niederschläge zu einem Eingabedatensatz:

$$Sum N_i = \sum_{m=1}^n N_m$$

mit:

- i Untersuchungszeitraum
- n Anzahl der Teilgebiete im Einzugsgebiet
- N Niederschlagsmenge im Teilgebiet m

5.5.4 Prognose

Eine Prognose kann als stochastische Vorhersage auf der Basis geschätzter oder prognostizierter Eingangsdaten bezeichnet werden. Ziel ist nicht die möglichst exakte Kurzzeithorhersage sondern eine Aussage über ein generelles langfristiges Prozeßverhalten.

Der Vorteil von KNN in diesem Bereich ist, daß kein umfangreiches Expertenwissen bekannt sein, keine komplexen Differentialgleichungen gelöst oder aufwendige Akquisition, Aufbereitung und Formalisierung des Problemwissens betrieben werden muß. Die „Black-Box“ KNN erlaubt keine Erklärung der gefundenen Lösung. Sie liefert lediglich ein implizites Modell des untersuchten Problems, dieses kann aber nicht weiter analysiert werden.

Die grundsätzliche Frage hierbei ist, wie KNN nach der Trainingsphase, wenn keine Änderungen mehr im Netz stattfinden, auf Eingangsdaten reagieren, die in ihrer Dynamik nicht mehr der des Trainingsdatensatzes entsprechen. Wie reagiert das KNN, wenn:

- Der bisher bekannte und angelernte Wertebereich deutlich über- oder unterschritten wird?
- Kann das KNN bei geänderter Eingangsdynamik noch ausreichend generalisieren?
- Ist der angelernte Systemoperator bei geändertem Input noch gültig?

Da prognostizierte Abflußganglinien schwer zu erstellen sind, werden die Untersuchungen mit gemessenen Ganglinien durchgeführt, die hinsichtlich ihrer Dynamik unterschiedlich normiert werden (10 %, 20 %, 40 %, ...). Die Charakteristik der Abflüsse bleibt erhalten, lediglich deren Höhe wird modifiziert. Untersucht wird nun die Reaktion des KNN, wenn es z. B. mit unveränderten Eingangsdaten trainiert, dann aber mit Daten eines lediglich noch 20 % umfassenden Dynamikbereiches angetrieben wird und umgekehrt. Dies wurde mit verschiedenen Kombinationen von Eingangs- und Validierungsdaten durchgeführt.

Dies erlaubt grundsätzliche Aussagen, inwieweit KNN nach der Trainingsphase, nach der keine Änderungen mehr im Netz stattfinden, auf extreme Wertebereiche reagieren und wie sie mit solchen Eingangsdaten den Abfluß propagieren. Diese Vor- und Nachteile sollen im Hinblick auf die Anwendbarkeit von KNN im Bereich der Prognose des Abflußkontinuums hier näher untersucht werden.

5.6 Untersuchungsgebiete

Aufgrund der Datenlage werden die Untersuchungen für Abflußkontinuum und Hochwasservorhersage in unterschiedlichen Einzugsgebieten durchgeführt. Als Testgebiet für die Kontinuumssimulationen dient der Obere Main in den nördlichen bayerischen Mittelgebirgen. Für die Hochwasservorhersage dient als Testgebiet die Oberpfälzer Vils. Diese Gebiete eignen sich aufgrund ihrer Topographie und Hydrologie für die Forschungsarbeiten, der Mittelgebirgscharakter gewährleistet das Auftreten vieler in Deutschland typischer Abflußereignisse wie Hochwasser, Taufluten usw. Das Einzugsgebiet des Oberen Mains umfaßt 2424km^2 bis Pegel Schwürlitz, das der Oberpfälzer Vils 756km^2 bis zum Pegel Schmidmühlen. Zu jedem der Einzugsgebiete liegen zudem die Daten mehrerer Teileinzugsgebiete (Bayreuth und Theisau für den Main, Vilseck und Amberg für die Vils) vor.




Abb. 25: Testgebiete Oberer Main und Oberpfälzer Vils

5.7 Eingangsdaten

Im Oberen Main liegen meteorologische Daten zu Niederschlag, Temperatur, Schneehöhe und Sonnenscheindauer des Deutschen Wetterdienstes für Klima- und Niederschlagsstationen in täglicher Auflösung vor. Über das bayerische Landesamt für Wasserwirtschaft (LfW) konnten mittlere tägliche Abflüsse zu 22 Pegelmeßstellen bezogen werden. Für die Oberpfälzer Vils werden meteorologische Meßwerte (Niederschlag N, Temperatur T, Schneehöhe Sh, Sonnenscheindauer Sd) des Agrarmeteorologischen Dienstes Bayern in stündlicher Auflösung verwendet, die Abflußdaten des LfW liegen hier für 11 Pegel in stündlicher Auflösung vor (Tabelle 4).

Tab. 4: Verwendete Eingangsdaten

Eingangsdaten	Einzugsgebiet	Anzahl der Stationen	Zeitraum
Meteorologische Tageswerte	Oberer Main	33	1961-1990
Meteorologische Stundenwerte	Oberpfälzer Vils	17	1989-1995
Mittlere tägliche Abflüsse	Oberer Main	22	1960-1993
Stündliche Abflußmengen	Oberpfälzer Vils	11	1990-1992

Mit dem Ziel, aus den Daten der Oberliegerpegel die zu erwartenden Abflüsse am Untersuchungspegel vorherzusagen, dienen die hydrologischen Daten dieser Oberliegerpegel als Input für diese Berechnungen. Sie liegen sowohl der Prognose des Abflußkontinuums auf Tagesbasis als auch der Hochwasservorhersage in stündlicher zeitlicher Auflösung zugrunde.

Die Berechnungen im klassischen Sinn der N-A-Modellierung werden mit meteorologischen Eingangsdaten durchgeführt. Hierbei kommen Temperatur (T), Niederschlag (N), Schneehöhe (Sh) und Sonnenscheindauer (Sd) zum Einsatz. Während bei der Hochwasservorhersage nur Temperatur und Niederschlag Eingang in die Berechnung findet, werden für die Prognose des Abflußkontinuums alle verfügbaren meteorologischen Daten verwendet. Bei der einfachen Netztopologie wie der trivialen Methode werden die punktbezogenen Meßwerte der Stationen verwendet, beim flächenbasierten Ansatz der komplexen Netztopologie gehen sie räumlich verteilt in die Berechnungen ein.

Als flächenhafte Eingangsdaten stehen physiographische Informationen des Einzugsgebietes zur Verfügung, die aus einem digitalen Höhenmodell berechnet werden. Höhendaten sind zu beiden Einzugsgebieten vorhanden. Die Fernerkundungsdaten liegen als Zeitreihe der Monatsmittelwerte des Normalized Differential Vegetation Index (NDVI) für den Zeitraum von Oktober 1995 bis Dezember 1997 vor. Da ältere Datensätze zum Zeitraum der vorliegenden meteorologischen und hydrologischen Daten nur schwer zu beschaffen sind, wurde das Jahr 1996 als repräsentativ für die Landnutzung in den Einzugsgebieten angenommen. Die Berechnungen über längere Zeiträume beziehen sich immer auf den Jahresgang des NDVI des Jahres 1996.

Tabelle 5 zeigt zusammenfassend, welcher Netztypus mit welchen Eingangsdaten und welchen Lernverfahren getestet wird.

Tab. 5: Verwendete Eingangsdaten, Netztopologien, Lernverfahren und zeitlicher Rahmen der Untersuchungen

Eingangsdaten	Netztypen	Lernverfahren	Netztopologie	zeitliche Auflösung	Zeitraum Training	Zeitraum Validierung
Hydrologische Daten: Q	MLP, PR TDNN RBF	BP, QP RP	trivial einfach komplex	1 d	10, 2, 1 Jahre	30, 10, 5, 2, 1 Jahre
				1 h	34 d	18-27 d
Meteorologische Daten: N, T, Sh, Sd	MLP, PR TDNN RBF	BP, QP RP	trivial einfach komplex	60, 30, 21 14, 7, 1 d	10, 2, 1 Jahre	30, 10, 5, 2, 1 Jahre
				1 h	34 d	18-27 d
Zeitindex $Z(t) = 1, 2, \dots, 365$	MLP, PR	BP, QP RP	trivial einfach	1 d	10, 2, 1 Jahre	30, 10, 5, 2, 1 Jahre
Differenz zum Vortag $D(t) = Q_i(t) - Q_i(t-1)$	MLP, PR TDNN	BP, QP RP	trivial einfach	1 d	10, 2, 1 Jahre	30, 10, 5, 2, 1 Jahre
				1 h	34 d	18-27 d
Topographische Daten: <i>Fliewege, EZG - Form</i>	MLP	BP	komplex	1 d	52-365 d	59-1095 d
				1 h	21-34 d	18-27 d
Bodenart <i>7 Klassen</i>	MLP	BP	komplex	1 d	52-365 d	59-1095 d
				1 h	21-34 d	18-27 d
Landnutzung <i>4 Klassen</i>	MLP	BP	komplex	1 d	52-365 d	59-1095 d
				1 h	21-34 d	18-27 d
Vorregenindex $VN_{m,t} = \sum_{i=1}^{30} N_{x,y}(t) \cdot 0.9^i$	MLP	BP	komplex	1 d	52-365 d	59-1095 d
				1 h	21-34 d	18-27 d
Lauflängenindex $LL_m = \frac{1}{dist_{x,y}}$	MLP	BP	komplex	1 d	52-365 d	59-1095 d
				1 h	21-34 d	18-27 d
Summe der täglichen Niederschläge $SumN_i = \sum N_m$	MLP	BP	komplex	1 d	52-365 d	112-1095 d
				1 h	17-34 d	18-27 d

MLP Multi-Layer-Perceptron

PR Partiiell rekurrente Netze

TDNN Time Delay Netze

RBF Radial-Basisfunktion-Netz

BP Backpropagation

QP Quickprop

RP Rprop

trivial

einfach

komplex

EZG-Form

trivialer Ansatz

einfache Netztopologie

komplexe Netztopologie

Einzugsgebietsform

Es zeigt sich, daß die Eingangsdaten sinnvollerweise normiert werden sollten, um numerische Probleme im KNN zu vermeiden und die Lernphasen zu verkürzen. Hierfür wird folgendes Normierungsschema nach Schöneburg [Schöneburg et al., 1990] angewendet:

$$Sk = \frac{I_{max}}{X_{max} - X_{min}}$$

$$Of = I_{min} - (X_{min} \cdot Sk)$$

$$X'_i = X_i \cdot Sk + Of$$

mit:

Sk	Skalierungsfaktor
Of	Offset
X_i	Originalwert
X'_i	Skalierter Wert
I_{min}, I_{max}	untere und obere Intervallgrenze des neuen Wertebereiches, auf den die Originaldaten normiert werden
X_{min}, X_{max}	kleinster und größter Wert der Originaldaten

Die hydrologischen wie meteorologischen Eingangsdaten werden für die Vorhersage zeitlich gegen die gewünschten Ausgangsdaten der zu erlernenden Zielgröße versetzt. Die Daten für das Training des KNN werden um $X(t) = X(t-1) \dots X(t-n)$ verschoben, um damit den Abfluß $Q(t)$ am untersuchten Auslaßpegel vorherzusagen. Die Größe dieses Versatzes ist variabel bis hin zu 24 Zeitschritten untersucht worden.

6 Ergebnisse

6.1 Allgemeines

Verlässliche Aussagen bezüglich der Eignung von KNN zur flächenbezogenen Abflußberechnung müssen auf der Basis von und dem Vergleich mit gemessenen historischen Daten beruhen. Nur so können gesicherte und überprüfbare Aussagen über die Qualität der Berechnungsergebnisse getroffen werden, nur so stehen verlässliche Vergleichsdaten für die Ergebnisvalidierung zur Verfügung. Die in diesem Kapitel dargestellten Ergebnisse resultieren daher auf der Verwendung und Analyse gemessener historischer Abflußganglinien. Die Synthese von Daten wird hier noch nicht betrachtet.

Die Untersuchungen sind für die Arbeiten mit unterschiedlichen Netztopologien gleich gegliedert. Nach der Betrachtung der Kontinuumssimulation auf Tagesbasis mit der Darstellung der Ergebnisse und einer Bewertung folgt im selben Stil die Beschreibung der Hochwasserbetrachtung auf Stundenbasis. Die Kapitel gliedern sich somit jeweils für trivialen Ansatz, einfache wie komplexe Netztopologie in:

- Kontinuumssimulation
 - untersuchte Varianten
- Bewertung der Ergebnisse der Kontinuumssimulation
- Hochwasservorhersage
 - untersuchte Varianten
- Bewertung der Ergebnisse der Hochwasservorhersage

Eine Übersicht über alle untersuchten Varianten gibt Tabelle 6. Gegliedert nach trivialem Ansatz, einfacher und komplexer Netztopologie sind die unterschiedlichen Kombinationen an Eingangsdaten und ihrer zeitlichen Auflösung dargestellt.

Tab. 6: Untersuchte Varianten

Eingangsdaten	Zeitliche Auflösung	Varianten
Varianten beim trivialen Ansatz		
Q_d	Tage	Variante 1
Q_h	Stunden	Variante 5
N	Tage	Variante 2
	Stunden	Variante 6
N, T, Sh, Sd	Tage	Variante 3
Q_d, N, T, Sh, Sd	Tage	Variante 4
Q_h, N	Stunden	Variante 7
Varianten der einfachen Netztopologie		
Q_d	Tage	Variante 8
N	Tage	Variante 9, selektive Verbindung der Layer
		Variante 10, vollständige Verbindung der Layer
	Stunden	Variante 15
N, T, Sh, Sd	Tage	Variante 11
Q_d, N, T, Sh, Sd	Tage	Variante 12, ein Oberliegerpegel
		Variante 13, alle Oberliegerpegel
Q_h	Stunden	Variante 14
Q_h, N	Stunden	Variante 16, ein Oberliegerpegel
		Variante 17, alle Oberliegerpegel
Varianten der komplexen Netztopologie		
DHM, N	Tage	Variante 18
	Stunden	Variante 30
$DHM, N, VN_{m,i}$	Tage	Variante 19
	Stunden	Variante 31
DHM, N, LL_m	Tage	Variante 20
	Stunden	Variante 32
$DHM, N, VN_{m,i}, LL_m$	Tage	Variante 21
DHM, N, T	Tage	Variante 22
	Stunden	Variante 33
$DHM, N, T, VN_{m,i}, LL_m$	Tage	Variante 23
DHM, N, LN	Tage	Variante 24, Differenz der Landnutzung
	Stunden	Variante 34, Differenz der Landnutzung
$DHM, N, VN_{m,i}, LL_m, LN$	Tage	Variante 25
DHM, N, LN	Tage	Variante 26, reale Landnutzung
		Variante 27, invertierte Landnutzung
		Variante 28, binarisierte Landnutzung
	Stunden	Variante 35, reale Landnutzung
		Variante 36, invertierte Landnutzung
		Variante 37, binarisierte Landnutzung
		Variante 38
DHM, N, T, LN	Tage	Variante 29
	Stunden	Variante 38
Varianten 30-38 mit Boden	Stunden	Varianten 39-46

Q_d : mittlere tägliche Abflüsse; Q_h : stündliche Abflüsse; N : Niederschlag; T : Temperatur; Sh : Schneehöhe; Sd : Sonnenscheindauer; DHM : digitales Höhenmodell; $VN_{m,i}$: Vorregenindex; LL_m : Lauflängenindex; LN : Landnutzung

Die gemessenen Abflüsse während der Trainingszeiträume sind jeweils zu Beginn jeden Kapitels charakterisiert. Angegeben sind der mittlere Abfluß MQ_g und dessen Standardabweichung S_{MQ_g} sowie die aufgetretenen Scheitelabflüsse HQ_{max} , alle in der Dimension $\left[\frac{m^3}{s}\right]$. Der Verlauf der gemessenen Abflußganglinie wird am Anfang der Kapitel graphisch dargestellt.

In den nachfolgenden Tabellen der Ergebnisse sind als Maß für die Güte der Berechnungen im Vergleich zu den gemessenen Abflüssen aufgeführt:

1. Der berechnete mittlere Abfluß MQ_b für den Berechnungszeitraum:

$$MQ_b = \frac{1}{n} \sum_{i=1}^n Q_{b_i} \left[\frac{m^3}{s}\right]$$
2. Als relatives Maß die prozentuale Abweichung ΔMQ des berechneten (MQ_b) vom gemessenen (MQ_g) mittleren Abfluß: $\Delta MQ = \frac{MQ_b - MQ_g}{MQ_g} \cdot 100 [\%]$
3. Als quantitatives Maß das Mittel der täglichen bzw. stündlichen Abweichung MQ_{diff} der berechneten von den gemessenen Abflüssen: $MQ_{diff} = \frac{1}{n} \sum_{i=1}^n (Q_{b_i} - Q_{g_i}) \left[\frac{m^3}{s}\right]$
4. Die Standardabweichung $S_{MQ_{diff}}$ der mittleren täglichen bzw. stündlichen Abweichung

$$S_{MQ_{diff}} \left[\frac{m^3}{s}\right]$$
5. Als qualitatives Maß für die Güte der Vorhersage den Korrelationskoeffizienten $r_{MQ_b, MQ_g} [-]$ zwischen täglich bzw. stündlich berechneten und den entsprechenden gemessenen mittleren Abflüssen
6. Zur Überprüfung der Güte der Modellergebnisse der komplexen Netztopologie wird zusätzlich das dimensionslose logarithmierte Nash-Sutcliffe-Gütekriterium E_{log} für den Vergleich diskretisierter Ganglinien eingeführt:

$$E_{log} = 1 - \frac{\sum_1^n [\log Q_{b_i} - \log Q_{g_i}]^2}{\sum_1^n [\log Q_{g_i} - \log MQ_g]^2} [-] \quad (4)$$

MQ_b	Mittlerer berechneter Abfluß, in $\left[\frac{m^3}{s}\right]$
ΔMQ	Prozentuale Abweichung, in $[\%]$
MQ_g	Mittlerer gemessener Abfluß, in $\left[\frac{m^3}{s}\right]$
MQ_{diff}	Mittel der täglichen bzw. stündlichen Abweichung, in $\left[\frac{m^3}{s}\right]$
$S_{MQ_{diff}}$	Standardabweichung der mittleren täglichen bzw. stündlichen Abweichung, in $\left[\frac{m^3}{s}\right]$
r_{MQ_b, MQ_g}	Korrelationskoeffizient $[-]$
E_{log}	log Effizienz $[-]$

$Q_{b,i}$	Berechneter Abfluß im Zeitpunkt i , in $\left[\frac{m^3}{s}\right]$
$Q_{g,i}$	Gemessener Abfluß im Zeitpunkt i , in $\left[\frac{m^3}{s}\right]$
n	Anzahl der betrachteten Zeitschritte i

Das Gütekriterium in Gleichung 4 kann Werte von $[1, \dots, -\infty]$ annehmen, es deckt damit den Bereich von sehr guter bis sehr schlechter Simulation ab. Es setzt streng genommen normalverteilte Stichproben $Q_{g,i}$ und $Q_{b,i}$ voraus. Zeitreihen von Abflüssen erfüllen diese Voraussetzung nicht.

So werden bei der Verwendung nicht normalverteilter Abflußwerte $Q_{g,i}$ die Hochwasser gegenüber den niedrigen Abflüssen sehr stark überbewertet. Dies ist im Bereich der Hochwasservorhersage durchaus sinnvoll, wenn die Simulation eine besonders gute Wiedergabe der Hochwasser zum Ziel hat.

Liegt der Schwerpunkt der Modellierung jedoch einer der möglichst guten Simulation des Abflußkontinuums, so kann das Gütekriterium zur Einschätzung der Simulationsgüte genutzt werden, wenn die simulierten und gemessenen Abflüsse vorher näherungsweise in eine Normalverteilung transformiert werden. Als einfachste Form dieser Transformation kann die Bildung der Logarithmen angesehen werden. Damit kann eine Einschätzung für Hoch- und Niedrigwasser gleichermaßen gut erfolgen.

In den Abbildungen als graphische Darstellung der Ergebnisse werden exemplarisch am Beispiel eines Pegels für den Validierungszeitraum die berechnete und gemessene Abflußganglinie sowie deren Differenz voneinander dargestellt. Für die komplexe Netztopologie werden generell die Trainingsergebnisse hinzugenommen, da hier der Unterschied zwischen Lern- und Validierungsphase groß und dementsprechend von Bedeutung ist.

Die Skalierung der Graphiken zeigt jeweils auf der Abszissenachse den Beobachtungszeitraum in Tagen bzw. Stunden. Auf der Ordinatenachse sind die normierten gemessenen Q_g/Q_{maxg} bzw. normierten berechneten Q_b/Q_{maxg} Abflüsse aufgetragen. Um die Differenz und somit die Qualität der Simulation noch zu verdeutlichen, ist zudem die Abweichung der Berechnung von der Messung über $Q_b/Q_{maxg} - Q_g/Q_{maxg}$ dargestellt.

6.2 Ergebnisse der Vorarbeiten und Voruntersuchungen (trivialer Ansatz)

6.2.1 Allgemeines

Als Basis für einen Vergleich der Qualität der später in 6.3 und 6.4 näher dargestellten Ergebnissen zur einfachen wie komplexen Netztopologie werden zahlreiche Simulationen mit einem trivialen Ansatz durchgeführt. Hierbei kommen unterschiedliche hydrologische wie meteorologische Eingangsdaten, unterschiedlich große Zeitfenster, verschiedene Netztopologien, Lern- und Aktivierungsfunktionen zur Anwendung. Die Gewässerstruktur und die Lagebeziehungen im Einzugsgebiet werden hierfür nicht berücksichtigt. Eine Übersicht über alle untersuchten Varianten gibt Tabelle 7 wieder.

Tab. 7: Untersuchte Varianten beim trivialen Ansatz

Eingangsdaten	Zeitliche Auflösung	Varianten
Q_d	Tage	Variante 1
Q_h	Stunden	Variante 5
N	Tage	Variante 2
	Stunden	Variante 6
N, T, Sh, Sd	Tage	Variante 3
Q_d, N, T, Sh, Sd	Tage	Variante 4
Q_h, N	Stunden	Variante 7

Eine ausführliche Darstellung all dieser Ergebnisse würde den Rahmen der Arbeit sprengen, die Ergebnisse der Berechnungen ohne Rauminformationen seien hier nur zusammengefaßt dargestellt.

6.2.2 Kontinuumssimulation

Die im folgenden dargestellten Ergebnisse wurden durch die Anwendung eines KNN gewonnen, das mit Daten des Zeitraums 1.1.1980 - 31.10.1989 trainiert worden ist und dann auf Validierungsdaten des Zeitraums 1.11.1976 - 31.10.1977 angewendet wurde. Für den Trainingszeitraum sowie den Zeitraum der Berechnung zeigen die drei untersuchten Pegel folgendes Abflußverhalten (Tabelle 8):

Tab. 8: Statistik der gemessenen Abflüsse für den Trainingszeitraum 1.11.1980 - 31.10.1989 und den Validierungszeitraum 1.11.1976 - 31.10.1977 für die Pegel Bayreuth, Theisau und Schwüribitz

Pegel	Gemessener mittlerer Abfluß MQ_g $\left[\frac{m^3}{s}\right]$	Standardabweichung S_{MQ_g} $\left[\frac{m^3}{s}\right]$	Gemessener Scheitel- abfluß HQ_{max} $\left[\frac{m^3}{s}\right]$
Trainingszeitraum 1.1.1980 - 31.10.1989			
Bayreuth (333km ²)	3.47	4.86	55.5
Theisau (1244km ²)	16.65	21.52	211.00
Schwüribitz (2424km ²)	34.48	41.94	557.00
Validierungszeitraum 1.11.1976 - 31.10.1977			
Bayreuth (333km ²)	2.35	2.15	18.70
Theisau (1244km ²)	9.69	8.43	53.70
Schwüribitz (2424km ²)	23.75	22.29	138.39

a) Hydrologische Eingangsdaten, Variante 1

Bei der Anwendung werden zur Erfassung der zurückliegenden hydrologischen wie meteorologischen Situation im Einzugsgebiet verschiedene Zeitfenster über den Eingangsdaten verwendet, vom aktuellen Meßwert $Q_i(t)$ zum jeweiligen Berechnungszeitpunkt der Oberliegerpegel („aktuelle Eingangsdaten“) bis hin zu Meßwerten der 12 Vortage $Q_i(t - 1, 2, \dots, 12)$. Es zeigt sich hierbei generell:

- Simulationen nur mit hydrologischen Eingangsdaten der Oberliegerpegel zeigen sehr gute Ergebnisse (Tabelle 9).
- Bereits nach kurzen Trainingszeiten bildet das KNN die Ganglinie in Qualität und Quantität gut ab. Die Abflußspitzen sowie der Basisabfluß werden sehr gut nachgebildet.
- Die Abflußkonzentration wird sehr gut nachgebildet, lediglich in der Rückgangphase kann eine leichte Verzögerung im KNN auftreten.
- Obwohl die Korrelation bei Verwendung aktueller Eingangsdaten höher ist, zeigen die geringeren Abweichungen, daß die Verwendung der Daten zweier Vortage bessere Ergebnisse liefern.

Tab. 9: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, *Variante 1*, hydrologische Eingangsdaten

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten					
Bayreuth	3.28	39.71	0.94	1.46	0.95
Theisau	12.45	28.48	2.76	4.35	0.95
Schwüribitz	21.72	-8.55	-2.03	3.50	0.99
Eingangsdaten der zwei vorherigen Tage					
Bayreuth	2.76	17.31	1.41	2.38	0.78
Theisau	9.80	1.09	0.08	6.52	0.73
Schwüribitz	21.44	-9.71	-2.31	8.16	0.93

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

b) Meteorologische Eingangsdaten, Variante 2 - 3

- Die Anwendung von ausschließlich mit meteorologischen Daten trainierten Netzen auf Validierungsdatensätze zeigt generell schlechte Ergebnisse (Tabelle 10).
- Simulationen nur mit Niederschlag als Eingangsdatensatz liefern auch nach sehr langen Trainingsphasen oder großen Zeitfenstern über den Eingangsdaten (z.B. Niederschläge der sechs Vortage oder länger) keine Ergebnisse. Es wird lediglich zum Teil die Qualität der Abflußganglinie nachgezeichnet, die Quantität hingegen kann nicht nachgebildet werden.
- Tabelle 10 zeigt durch die hohen negativen Abweichungen die deutliche Unterschätzung der Abflüsse im KNN. Die geringe Korrelation zeigt, daß auch die Form der Abflußganglinie nicht vorhergesagt wird.
- Die hohe Standardabweichung zeigt zudem die große Streuung der Ergebnisse, es treten z. T. sehr hohe Einzelabweichungen von über 90 % auf.
- Durch Hinzunahme der Temperatur als Eingangsdatensatz wird eine geringe Verbesserung der Ergebnisse erzielt. Diese beschränkt sich aber auf eine bessere Vorhersage der Höhen der Extremwerte, der Basisabfluß wird weiterhin schlecht vorhergesagt.
- Durch Hinzunahme der Sonnenscheindauer als einen weiteren Indikator der Verdunstung wird eine weitere, allerdings sehr geringe Verbesserung in der Vorhersage der Extremwerte erreicht, die Modellierung der Ganglinie im Ganzen, der Abflußspitzen und des Basisabflusses ist weiterhin schlecht.
- Mit der Schneehöhe als weiteren, für dieses Gebiet wichtigen Eingangsparameter (Schneesmelze) konnte eine weitere geringe Verbesserung der Berechnungen erreicht werden.

Tab. 10: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, Variante 2, Niederschlag als Eingangsdaten

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten					
Bayreuth	1.02	-56.47	-1.33	2.11	0.19
Theisau	4.03	-58.40	-5.67	8.55	0.03
Schwüribitz	5.05	-78.72	-18.74	22.45	-0.04
Eingangsdaten der zwei vorherigen Tage					
Bayreuth	0.75	-68.19	-1.63	2.10	0.27
Theisau	3.28	-66.18	-6.53	9.76	0.21
Schwüribitz	7.72	-67.48	-16.34	22.00	0.41

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

- Generell zeigt sich aber bei alleiniger Verwendung meteorologischer Eingangsdaten eine schlechte Kontinuumssimulation (Tabelle 11). Die Abflußspitzen werden zwar meist vom Termin richtig getroffen, deren Höhe aber in der Regel viel zu gering berechnet. Auch der Basisabfluß wird nicht korrekt wiedergegeben, meist ist ein deutlicher Versatz zu erkennen.
- Die Verwendung längerer Zeitfenster erzielt bei meteorologischen Eingangsdaten bessere Ergebnisse, die allgemeine Vorhersagequalität ist aber weiterhin schlecht. Viele Abflußspitzen werden nicht korrekt in Höhe und Andauer vorhergesagt, der Basisabfluß wird meist deutlich unterschätzt.

Tab. 11: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, Variante 3, meteorologische Eingangsdaten

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten					
Bayreuth	1.03	-56.31	-1.33	2.04	0.32
Theisau	3.76	-61.23	-5.94	9.10	0.08
Schwüribitz	6.83	-71.24	-16.96	21.84	0.21
Eingangsdaten der zwei vorherigen Tage					
Bayreuth	0.86	-63.41	-1.52	1.94	0.47
Theisau	5.56	-42.62	-4.21	7.01	0.62
Schwüribitz	9.07	-61.81	-14.97	17.02	0.66

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

- Alle Arbeiten in gröberer zeitlicher Auflösung (Mittelwerte für 7, 14, 21, 30, 60 Tage) ergaben keinerlei sinnvolle Ergebnisse. Das KNN neigt in dieser zeitlichen Auflösung sehr stark zu einer Mittelung der Abflüsse. Weder die Abflußspitzen noch der Basisabfluß werden korrekt vorhergesagt.

c) Hydrologische und meteorologische Eingangsdaten, Variante 4

- Die Verwendung sowohl der hydrologischen wie meteorologischen Eingangsdaten erbringt im Vergleich zu a) eine kleine Verbesserung. Lediglich am Pegel Bayreuth treten mit aktuellen Eingangsdaten höhere Abweichungen auf (Tabelle 12).
- Im Vergleich zu b) werden die Ergebnisse deutlich besser.

Tab. 12: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, *Variante 4*, meteorologische und hydrologische Eingangsdaten

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]
Aktuelle Eingangsdaten					
Bayreuth	3.57	52.03	1.23	1.67	0.91
Theisau	9.52	-1.71	-0.17	3.94	0.91
Schwürlitz	22.21	-6.50	-1.55	3.27	0.99
Eingangsdaten der zwei vorherigen Tage					
Bayreuth	2.86	21.47	0.50	1.80	0.73
Theisau	7.19	-25.77	-2.49	4.06	0.88
Schwürlitz	20.59	-13.30	-3.15	7.55	0.95

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

- Im trainierten KNN stellt sich eine starke Bewertung der hydrologischen Daten gegenüber den meteorologischen ein. Dies zeigt die Dominanz der darin enthaltenen Informationen für die Kontinuumsberechnung.
- Die, wenn gleich auch geringe Verbesserung der Vorhersage gegenüber der alleinigen Verwendung hydrologischer Eingangsdaten zeigt, daß meteorologische Daten relevante Informationen für das Abflußgeschehen beinhalten, die nicht vernachlässigt werden sollten.

Allgemein zeigt sich, daß in den untersuchten Einzugsgebieten nur mit hydrologischen Eingangsdaten (separat oder in Verbindung mit meteorologischen Daten) eine Vorhersage des Abflußkontinuums sinnvoll möglich ist. Eine Vorhersage bei alleiniger Verwendung meteorologischer Eingangsdaten ist mit dem trivialen Ansatz ohne Berücksichtigung der Rauminformationen nicht möglich. Dies deckt sich mit anderen Arbeiten aus der Literatur, die ebenfalls meist hydrologische Eingangsdaten mit verwenden (Hsu et al., 1995, Ichiyangi et al., 1995, Karunanithi et al., 1994, Minns et al., 1996, Veldkamp et al., 1994).

6.2.3 Hochwasservorhersage

Für diese Anwendungen dient das Einzugsgebiet der Oberpfälzer Vils als Untersuchungsgebiet. Hier liegen Eingangsdaten für Abfluß und Niederschlag in stündlicher Auflösung vor. Die Arbeiten wurden an mehreren Pegeln (Vilseck, Amberg, Schmidmühlen) mit ähnlichen Ergebnissen durchgeführt, wobei im folgenden exemplarisch die Ergebnisse des Pegels Amberg aufgeführt sind.

Das Training des KNN erfolgte immer mit dem Hochwasserereignis vom 10.12.1991-10.1.1992, das so trainierte Netz wurde auf Ereignisse vom 25.12.1990 - 20.1.1991, 8.5. - 25.5.1991, 15.6. - 5.7.1991 angewendet (Tabelle 13).

Tab. 13: Statistik der gemessenen Abflüsse der einzelnen Ereignisse am Pegel Amberg

Ereignis	Gemessener mittlerer Abfluß MQ_g $\left[\frac{m^3}{s}\right]$	Standardabweichung S_{MQ_g} $\left[\frac{m^3}{s}\right]$	Gemessener Scheitel- abfluß HQ_{max_g} $\left[\frac{m^3}{s}\right]$
10.12.1991 - 10.1.1992	4.51	2.58	14.05
25.12.1990 - 20.1.1991	4.96	1.62	9.42
8.5. - 25.5.1991	3.15	1.54	9.75
15.6. - 5.7.1991	4.20	1.98	11.32

Auch hier wurden verschiedene Zeitfenster über den Eingangsdaten angewendet. Zum einen die aktuell zum jeweiligen Berechnungszeitpunkt gemessenen Daten der Oberliegerpegel bzw. Niederschlagsmeßstellen (aktuell), zum anderen die Meßwerte der zum jeweiligen Berechnungszeitpunkt vorangegangenen 1, 2, 6, 12 Stunden (z. B. 12 Stunden vor).

a) Hydrologische Eingangsdaten, Variante 5

- Es zeigt sich, daß bei der Hochwasservorhersage lediglich zum aktuellen Berechnungszeitpunkt gemessene hydrologische Eingangsdaten sinnvolle Ergebnisse liefern. Hier wird der Abflußscheitel richtig erkannt und in der Höhe fast richtig nachgebildet (Tabelle 14).
- Bereits bei der Verwendung der Eingangsdaten vom vorherigen Zeitschritt stellt sich ein deutlicher Fehler in den Berechnungen ein. Die Abflußscheitel werden zwar teilweise noch in ihrer Lage nachgebildet, deren Höhe wie auch der restliche Verlauf der Kurve (Abflußkonzentration, -ablauf und Basisabfluß) werden aber vollkommen falsch vorhergesagt.

Tab. 14: Differenz und Korrelation zwischen berechneten und gemessenen stündlichen Abflüssen am Pegel Amberg, *Variante 5*, hydrologische Eingangsdaten

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]
Aktuelle Eingangsdaten						
25.12.-20.1.91	8.57	6.07	20.72	1.55	0.21	0.87
8.5.-25.5.91	8.87	3.49	9.30	0.43	0.81	0.94
15.6.-5.7.91	10.30	5.74	34.51	1.83	1.81	0.77
Eingangsdaten der 12 vorherigen Stunden						
25.12.-20.1.91	3.67	1.40	-72.22	-5.31	3.46	-0.33
8.5.-25.5.91	0.88	0.23	-92.96	-4.15	2.51	-0.36
15.6.-5.7.91	0.03	0.01	-99.75	-5.16	2.58	0.07

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

- Bei Verwendung noch größerer Zeitfenster treten teilweise Abweichungen von 100% auf, die Korrelationen gehen gegen Null oder werden sogar negativ. Die Berechnungsergebnisse spiegeln in keiner Weise mehr den Verlauf der gemessenen Abflußkurve dar.

b) Meteorologische Eingangsdaten, Variante 6

Für diese Untersuchung steht nur der Niederschlag in stündlicher Auflösung zur Verfügung, für das Ereignis vom 25.12.1990 - 20.1.1991 liegen keine gemessenen Niederschläge vor. Es mußte aus dieser Betrachtung ausgenommen werden.

- Mit stündlichen Niederschlägen als Eingangsdatensatz zeigt sich durchweg über alle Ereignisse wie auch bei allen betrachteten Pegeln keine Möglichkeit der Vorhersage der gemessenen Abflüsse (Tabelle 15).

- Bei Verwendung größerer Zeitfenster (bis 12 Stunden zurückliegende Werte) werden die ohnehin sehr schlechten Ergebnisse noch schlechter. Die Berechnungsergebnisse scheinen mit zunehmender Fenstergröße eher zufällig zu sein als in irgendeiner Weise mit den gemessenen Abflüssen in Verbindung zu stehen.
- Die scheinbar gute Berechnung der Scheitelabflüsse zeigt sich in einer graphischen Darstellung als Spitzen, die scheinbar zufällig über den gesamten Berechnungszeitraum verteilt sind. Der gemessene Abflussscheitel wird vom Termin her nie nachgebildet.
- Das KNN ist nicht in der Lage, mit diesen Eingangsdaten ein Hochwasserereignis vorherzusagen.

Tab. 15: Differenz und Korrelation zwischen berechneten und gemessenen stündlichen Abflüssen am Pegel Amberg, *Variante 6*, Niederschlag als Eingangsdaten

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten						
8.5.-25.5.91	6.04	2.78	-12.88	-0.59	2.44	0.03
15.6.-5.7.91	7.02	3.27	-23.40	-1.25	2.51	0.12
Eingangsdaten der 12 vorherigen Stunden						
8.5.-25.5.91	9.75	3.96	24.24	1.12	4.16	-0.05
15.6.-5.7.91	11.32	4.46	4.36	0.24	4.53	0.07

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

Die in Tabelle 15 aufgeführten geringen Abweichungen zeigen besonders deutlich eine Auffälligkeit bei der Anwendung von KNN. Sie haben die Tendenz, Mittelwerte anzugleichen, wobei teilweise die Charakteristik der nachzubildenden Funktion vollkommen verloren geht. Das Modellergebnis kann sogar teilweise gegenläufige Form haben, wobei die Mittelwerte trotz allem übereinstimmen.

c) Hydrologische und meteorologische Eingangsdaten, Variante 7

Bei diesem Ansatz werden alle zur Verfügung stehenden hydrologischen Daten wie Niederschlagsmessungen verwendet, auf eine räumliche Organisation innerhalb des KNN, beruhend auf den Lagebeziehungen der Meßstellen im Untersuchungsgebiet, wird noch verzichtet.

- Auch hier sind die Ergebnisse lediglich mit den aktuellen Eingangsdaten hinreichend gut (Tabelle 16).

Tab. 16: Differenz und Korrelation zwischen berechneten und gemessenen stündlichen Abflüssen am Pegel Amberg, Variante 7, meteorologische und hydrologische Eingangsdaten

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten						
8.5.-25.5.91	9.46	3.54	10.88	0.50	3.03	0.94
15.6.-5.7.91	11.04	5.55	30.06	1.60	1.59	0.82
Eingangsdaten der 12 vorherigen Stunden						
8.5.-25.5.91	9.55	2.59	-18.88	-0.84	2.60	0.69
15.6.-5.7.91	10.25	3.58	-16.21	-0.85	2.50	0.63

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

- Bereits bei der Verwendung der Daten eines vorherigen Zeitschrittes sind die Berechnungsergebnisse schlechter, die gemessene Abflußganglinie wird nur mehr im Hochwasserscheitel vorhergesagt. Der restliche Verlauf der Ganglinie weist zum Teil deutliche Abweichungen auf.
- Die Ergebnisse verschlechtern sich auch hier mit zunehmender Größe des Zeitfensters über den Eingangsdaten.
- Lediglich bei dem 12stündigen Zeitfenster über den Eingangsdaten sind die Ergebnisse zumindest in der Vorhersage der Abflußspitzen akzeptabel. Allerdings treten auch hier v. a. in der Ablaufphase deutliche Abweichungen von der Messung auf. Alle anderen Zeitfenster liefern sehr schlechte bis keine Ergebnisse.

6.2.4 Bewertung der Ergebnisse der Voruntersuchung

Allgemein läßt sich festhalten, daß mit der trivialen Methode eine Hochwasservorhersage ohne Verwendung hydrologischer Eingangsdaten kaum möglich ist. Bei Verwendung hydrologischer Daten liegt die Hauptinformation in den Daten, die aktuell zum Berechnungszeitpunkt gemessen sind. Dies deutet darauf hin, daß die Fließzeiten in den Einzugsgebieten sehr gering sind oder exogene Einflüsse eine große Rolle spielen, die nicht vom KNN erlernt werden können.

Der N-A-Prozeß kann mit KNN nicht einfach durch eine triviale Beziehung zwischen Niederschlag und dem daraus resultierenden Abfluß abgebildet werden. Die Randbedingungen, die diesen Prozeß erheblich modifizieren, können so in keiner Weise mit berücksichtigt werden. Es liegt daher nahe, weitere Informationen für die Berechnung heranzuziehen. Im einfachsten Fall ist dies die Lage der verwendeten hydrologischen wie meteorologischen Meßstellen im Einzugsgebiet. Dies geschieht im nächsten Kapitel, in dem die durch die Lage der Meßstellen erzeugte Struktur in die Topologie des KNN eingearbeitet wird.

6.3 Einfache Netztopologie

6.3.1 Allgemeines

Sind in einem Einzugsgebiet mehrere Pegel in Form von Ober- und Unterliegerpegeln vorhanden, können sich deren Meßergebnisse ergänzen, zusätzliche Informationen beinhalten wie auch mögliche Fehler in den Abflußmessungen aufdecken oder ausgleichen.

Zu Beginn wird versucht, die Informationen über Lage- und Raumbeziehungen zwischen Ober- und Unterlieger mehrerer hydrologischer Pegel im gesamten Einzugsgebiet in einem Künstlichen Neuronalen Netz zu verarbeiten. Danach werden auch die Lagebeziehungen vorhandener meteorologischer Stationen im Netz so verknüpft, daß diese Informationen bei der Simulation mit einfließen können. In einem dritten Schritt werden dann beide Ansätze in einem Netz miteinander verbunden, hier fließen sowohl die Lagebeziehungen der meteorologischen Meßstellen wie die Gewässerstruktur mit ein.

Auch hier werden wieder die drei Pegel mit ihrer in Tabelle 8 aufgeführten Abflußstatistik für Training wie Validierung verwendet. In Tabelle 17 sind die untersuchten Varianten aufgeführt.

Tab. 17: Untersuchte Varianten der einfachen Netztopologie

Eingangsdaten	Zeitliche Auflösung	Varianten
Q_d	Tage	Variante 8
N	Tage	Variante 9, selektive Verbindung der Layer
		Variante 10, vollständige Verbindung der Layer
	Stunden	Variante 15
N, T, Sh, Sd	Tage	Variante 11
Q_d, N, T, Sh, Sd	Tage	Variante 12, ein Oberliegerpegel
		Variante 13, alle Oberliegerpegel
Q_h	Stunden	Variante 14
Q_h, N	Stunden	Variante 16, ein Oberliegerpegel
		Variante 17, alle Oberliegerpegel

6.3.2 Kontinuumssimulation

a) Hydrologische Eingangsdaten, Variante 8

Es zeigt sich, daß die Kontinuumsvorhersage mit hydrologischen Eingangsdaten mit der einfachen Netztopologie des KNN gute Ergebnisse liefert (Tabelle 18). Im Vergleich zur trivialen Verwendung der Eingangsdaten ohne Berücksichtigung der Lagebeziehungen (Tabelle 9) zeigt sich allerdings nur eine geringe Verbesserung für größere Einzugsgebiete.

Tab. 18: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß dreier Pegel für den Zeitraum 1.11.1976 - 31.10.1977, Variante 8, hydrologische Eingangsdaten

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten					
Bayreuth	3.62	53.99	1.27	1.47	0.92
Theisau	10.40	7.31	0.71	2.27	0.98
Schwürlitz	21.49	-9.53	-2.26	4.16	0.99
Eingangsdaten der zwei vorherigen Tage					
Bayreuth	2.69	14.41	0.34	1.48	0.78
Theisau	10.24	5.63	0.54	3.58	0.91
Schwürlitz	21.08	-11.25	-2.66	7.48	0.94

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

Mit Ausnahme des Pegels Bayreuth bei aktuellen Eingangsdaten sind hier die Vorhersageergebnisse sehr gut. Die durchweg hohe Korrelation zwischen berechneter und gemessener Abflußganglinie sowie die geringen Abweichungen zeigen die Güte dieser Anwendung. Der Basisabfluß sowie die Abflußspitzen werden sehr gut vorhergesagt, lediglich in der Konzentrationsphase treten geringe Verzögerungen bei den Berechnungen im KNN auf. Die Höhe der Scheitelabflüsse werden sehr gut vorhergesagt, nur der höchste Abfluß wird leicht unterschätzt (Abbildung 26).

Dies zeigt die Abhängigkeit der KNN von den Trainingsdaten, sind dort diese hohen Abflüsse nicht aufgetreten, können diese auch nach der Lernphase nicht abgebildet werden. KNN sind Gefangene ihrer Lernmuster [Minns et al., 1996].




Abb. 26: Berechnete und gemessene Abflußganglinie des Pegels Schwürbitz, 1.11.1976 - 31.10.1977 mit dem Trainingsmuster 1.11.1980 - 31.10.1989, Variante 8, Zeitfenster zwei Tage, hydrologische Eingangsdaten

Allgemein läßt sich sagen, daß die Berechnung des Abflußkontinuums mit dieser Art der Netztopologie im Vergleich zu trivialen Anwendungen, wie sie häufig in der Literatur zu finden sind, etwas bessere Ergebnisse bei gleichen Eingangsdaten und lediglich geringem Mehraufwand an Trainingszeit liefern kann.

b) Meteorologische Eingangsdaten, Variante 9 - 11

Bei dieser Anwendung bilden die im Untersuchungsgebiet vorhandenen meteorologischen Stationen den Input Layer (IL). Die Anzahl der vorhandenen Pegel bestimmt die Anzahl der Neuronen im Hidden Layer (HL). Die Lagebeziehungen zwischen meteorologischen und hydrologischen Stationen bestimmen die Verknüpfungen zwischen Input und Hidden Layer („selektive Verbindung“).

Wie bereits bei den Vorarbeiten ohne Berücksichtigung der Lagebeziehungen zeichnet sich auch hier ab, daß eine Abflußmodellierung auf Tagesbasis unter alleiniger Verwendung von Niederschlagsdaten keine zufriedenstellenden Ergebnisse liefert (Tabelle 19).

Tab. 19: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, Variante 9, Niederschlag als Eingangsdaten, selektiv verbundene IL und HL

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten					
Bayreuth	0.94	-59.94	-4.19	6.29	0.18
Theisau	2.24	-76.89	-7.45	8.40	0.11
Schwürlitz	7.13	-69.99	-16.62	22.20	0.11
Eingangsdaten der 12 vorherigen Tage					
Bayreuth	0.64	-72.83	-4.93	6.02	0.38
Theisau	2.28	-76.47	-7.19	8.24	0.23
Schwürlitz	6.32	-73.40	-16.93	21.43	0.28

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

Anhand der hohen Abweichungen ist bereits zu erkennen, daß die Vorhersage sehr schlecht ist. Die Korrelation der beiden Ganglinien geht gegen Null. Die Abflußspitzen werden vom Termin her zumindest teilweise noch richtig getroffen, ihre Höhe sowie der Basisabfluß werden aber nicht richtig wiedergegeben. Diese sehr schlechten Ergebnisse decken sich mit den Resultaten des trivialen Ansatzes, wenngleich sie hier geringfügig besser sind.

Aufgrund der schlechten Ergebnisse wurde in einem zweiten Schritt die selektive, lagebedingte Verbindung des Input Layers (Niederschlagsstationen) mit dem ersten Hidden Layer (Pegel) untereinander aufgehoben und diese vollständig miteinander verbunden. Dies entspricht einer räumlichen Aufteilung der Niederschläge im KNN (Tabelle 20).

Es kann zwar auch hier durch ein großes Zeitfenster über den Eingangsdaten eine Verbesserung der Vorhersagequalität erreicht werden, die Ergebnisse sind aber nach wie vor völlig unzureichend (Abbildung 27).

Tab. 20: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, Variante 10, Niederschlag als Eingangsdaten, vollständig verbundene IL und HL

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]
Aktuelle Eingangsdaten					
Bayreuth	0.95	-59.77	-4.18	6.29	0.17
Theisau	2.47	-74.47	-7.21	8.39	0.10
Schwüribitz	6.87	-71.09	-16.89	22.37	0.00
Eingangsdaten der 12 vorherigen Tage					
Bayreuth	0.77	-67.26	-4.55	6.29	0.23
Theisau	3.22	-66.72	-6.27	10.08	0.15
Schwüribitz	6.89	-70.97	-16.37	23.37	0.18

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient




Abb. 27: Berechneter und gemessener Abfluß am Pegel Schwüribitz, 1.11.1976 - 31.10.1977, Variante 10, Zeitfenster 12 Tage, Niederschlag als Eingangsdaten, vollständig verbundene IL und HL

Dem KNN gelingt es in keinsten Weise, die Abflußganglinie als ganzes, einzelne Abflußspitzen oder den Basisabfluß vorherzusagen. Es scheint, als ob die berechneten Abflußspitzen eher zufällig entstehen, sich aber in keinsten Weise an der gemessenen Kurve orientieren. Die Abweichungen erreichen hier fast den Maximalwert von 1 bei diesen normierten Daten.

Aufgrund dieser völlig unzureichenden Ergebnisse wurden in einem weiteren Schritt alle verfügbaren meteorologischen Daten für das jeweilige Einzugsgebiet verwendet. Bei den Vorarbeiten zeigte sich hier eine Verbesserung, da so v.a. auch die Schneeschmelze mit berücksichtigt werden kann. Auch hier wird ein zwischen dem Input und Hidden Layer vollständig verbundenes Netz verwendet.

Tabelle 21 und Abbildung 28 zeigen gegenüber der alleinigen Verwendung des Niederschlags lediglich eine geringfügige Verbesserung der Ergebnisse. Es werden jetzt zwar mehr Abflußspitzen erkannt und abgebildet, die Höhe der Abflüsse sowie der Basisabfluß weisen allerdings noch große Abweichungen auf.

Tab. 21: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, Variante 11, meteorologische Eingangsdaten

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten					
Bayreuth	0.82	-65.04	-4.54	6.13	0.29
Theisau	2.30	-76.29	-7.39	8.32	0.17
Schwüribitz	6.36	-73.24	-17.40	21.97	0.19
Eingangsdaten der 12 vorherigen Tage					
Bayreuth	0.84	-64.46	-4.58	5.20	0.69
Theisau	2.90	-70.07	-6.59	8.66	0.33
Schwüribitz	8.98	-62.20	-15.03	18.14	0.62

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

Trotz der geringen Verbesserung im Vergleich zur alleinigen Verwendung des Niederschlags bleibt dennoch eine hohe Unterschätzung der Abflüsse um über 60 %. Dies gilt sowohl für die Spitzen wie auch den Basisabfluß. Auch mit der einfachen Netztopologie zeigt sich, daß eine Kontinuumsvorhersage, basierend ausschließlich auf meteorologischen Eingangsdaten, zumindest für diese Einzugsgebiete nicht möglich ist.




Abb. 28: Berechneter und gemessener Abfluß am Pegel Schwüribitz, 1.11.1976 - 31.10.1977, Variante 11, Zeitfenster 12 Tage, Niederschlag, Temperatur, Sonnenscheindauer, Schneehöhe als Eingangsdaten

Als weiterer Schritt wurde das Potential der Kontinuumsbetrachtung mittels KNN durch die Hinzunahme eines Oberliegerpegels zu den meteorologischen Eingangsdaten untersucht. Dies ist eine häufig in der Literatur zu findende Methode, die als eine Art des Routings beschrieben wird (Minns et al., 1996).

c) Meteorologische und hydrologische Eingangsdaten, Variante 12 - 13

In einem ersten Versuch wurde neben allen meteorologischen Daten die Informationen eines Oberliegerpegels verwendet. Bei dieser Netzanwendung zeichnet sich erwartungsgemäß eine sehr deutliche Verbesserung gegenüber der Verwendung meteorologischer Daten ab (Tabelle 22 und Abbildung 29).

Im Vergleich zu der Anwendung ausschließlich mit hydrologischen Daten zeigt sich, daß die Ergebnisse mit meteorologischen und hydrologischen Eingangsdaten mit Ausnahme von Bayreuth (aktuelle Eingangsdaten) etwas schlechter sind. Die Höhe der Abflußspitzen sowie der Basisabfluß werden mit der einfachen Netztopologie schlechter bestimmt. Die sehr hohe prozentuale Abweichung am Pegel Bayreuth ist auf eine starke Überschätzung der Abflußspitzen zurückzuführen. Ein Grund hierfür ist nicht zu erkennen.

Tab. 22: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, Variante 12, meteorologische und hydrologische Eingangsdaten

Pegel	MQ_b $\left[\frac{m^3}{s}\right]$	ΔMQ [%]	MQ_{diff} $\left[\frac{m^3}{s}\right]$	$S_{MQ_{diff}}$ $\left[\frac{m^3}{s}\right]$	r_{MQ_b, MQ_g} [—]
Aktuelle Eingangsdaten					
Bayreuth	4.70	100.09	2.36	2.11	0.83
Theisau	4.85	-49.97	-4.84	2.45	0.96
Schwürbitz	18.23	-23.25	-5.52	9.23	0.94
Eingangsdaten der zwei vorherigen Tage					
Bayreuth	2.95	25.44	0.60	1.54	0.77
Theisau	2.25	-76.81	-7.40	5.94	0.90
Schwürbitz	16.96	-28.59	-6.75	14.17	0.90

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient




Abb. 29: Berechneter und gemessener Abfluß am Pegel Schwürbitz, 1.11.1976 - 31.10.1977, Variante 12, Zeitfenster zwei Tage, Niederschlag und Abfluß als Eingangsdaten

Gegenüber der alleinigen Verwendung der meteorologischen Daten ist erwartungsgemäß eine deutliche Verbesserung sowohl der Abflußspitzen im Termin wie auch in der Höhe sowie des Basisabflusses zu erkennen. Beim Trainieren des KNN hat sich aber wieder deutlich die Bevorzugung der hydrologischen Informationen gezeigt. Verbindungen, die mit dem Abfluß als Input in Verbindung stehen, wurden am stärksten gewichtet.

Untersuchungen mit einem beliebigen Pegel als Input für das KNN zeigen für alle drei Pegel sehr ähnliche Ergebnisse wie mit dem „richtigen“ Oberliegerpegel selbst. Dies belegt die absolute Dominanz der hydrologischen Eingangsdaten gegenüber den meteorologischen. Dies zeigt, daß KNN sehr tolerant gegenüber den Eingangsdaten sind. Dies hat zum einen den Vorteil, eine Kontinuumssimulation auch bei schlechter Datenbasis durchführen zu können, zum anderen liegt allerdings der Verdacht nahe, nahezu alles als Input verwenden zu können, solange annähernd die Charakteristik des zu untersuchenden Prozesses darin wiedergegeben wird. Das KNN würde immer in etwa gleich gute Ergebnisse liefern.

Ein weiterer Schritt in der Betrachtung der Kontinuumssimulation war die Verbindung der beiden Ansätze

- nur hydrologische Eingangsdaten
- nur meteorologische Eingangsdaten

in einem gemeinsamen Netz. Hier sollten alle Vorteile der jeweiligen Methode zusammen genutzt werden. Zum einen läßt sich so noch besser die Gewässerstruktur im Netz berücksichtigen, zum anderen werden alle Informationen über die Lagebeziehungen der Niederschlagsmeßstellen mit berücksichtigt.

Durch die Verwendung aller vorhandenen meteorologischen und hydrologischen Eingangsinformationen in einem KNN werden für den Pegel Theisau die besten Ergebnisse erreicht. Hier zeigt sich über alle statistischen Parameter hinweg eine deutliche Verbesserung der Ergebnisse (Tabelle 23). Im Vergleich zum trivialen Ansatz werden hier alle Charakteristika der Abflußganglinie besser vorhergesagt und beschrieben.

Für den Pegel Bayreuth bestehen weiterhin Probleme in der exakten Vorhersage der Höhe der Abflußspitzen. Hier scheinen andere, lokale Gegebenheiten die Kontinuumsberechnung zu beeinflussen, die nicht vom KNN gelernt und wiedergegeben werden können.

Dieser größere Fehler zeigt sich auch bei allen anderen vorangegangenen Anwendungen in diesem Einzugsgebiet. Mit der einfachen Netztopologie ist er allerdings deutlich geringer als mit der trivialen Methode.

Am Pegel Schwüribitz ist eine geringe Verschlechterung der Ergebnisse im Bezug zur trivialen Anwendung zu erkennen. Wenngleich die Abflußspitzen im Termin und der Basisabfluß sehr gut vorhergesagt werden bleiben doch erhebliche Abweichungen in der Abflußhöhe. Diese wurden mit der trivialen Methode besser vorhergesagt (Abbildung 30).

Tab. 23: Differenz und Korrelation zwischen berechnetem und gemessenem Abfluß für den Zeitraum 1.11.1976 - 31.10.1977, Variante 13, meteorologische und hydrologische Eingangsdaten

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten					
Bayreuth	3.26	38.57	2.69	5.14	0.90
Theisau	9.41	-2.92	-0.28	1.70	0.99
Schwürlitz	19.96	-15.94	-3.79	4.66	0.98
Eingangsdaten der zwei vorherigen Tage					
Bayreuth	2.49	5.85	0.41	4.37	0.81
Theisau	9.34	-3.60	-0.35	2.68	0.95
Schwürlitz	18.73	-21.16	-5.00	8.56	0.95

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient




Abb. 30: Berechnete und gemessene Abflußganglinie des Pegels Schwürlitz, 1.11.1976 - 31.10.1977, Variante 13, Zeitfenster zwei Tage, meteorologische und hydrologische Eingangsdaten

6.3.3 Bewertung der Ergebnisse der Kontinuumssimulation

- Gegenüber dem trivialen Ansatz verbessern sich die Ergebnisse für die Vorhersage des Abflußkontinuums bei alleiniger Verwendung von hydrologischen Daten für alle Pegel geringfügig. Das größte Einzugsgebiet mit dem Pegel Schwürlitz zeigt geringfügig schlechtere Ergebnisse, wobei auch hier die Vorhersage trotz allem sehr gut ist.
- Die ohnehin schlechten Ergebnisse bei Verwendung lediglich des Niederschlags können durch die einfache Netztopologie nur zum Teil geringfügig verbessert werden. Die Vorhersage bleibt generell auf schlechtem Niveau.
- Bei der Verwendung weiterer meteorologischer Daten wie Temperatur, Sonnenscheindauer und Schneehöhe kann keine Verbesserung der Vorhersagequalität erreicht werden. Die Höhe der Abflußspitzen wie auch der Basisabfluß können in keinem der beiden Fälle korrekt vorhergesagt werden.
- Die Verbindung aller meteorologischer Eingangsdaten mit deren Lagebeziehungen sowie die Integration der Gewässerstruktur in die Netztopologie zeigt gegenüber des trivialen Ansatzes mit Abstand die größte Verbesserung in den Vorhersageergebnissen.
- Eine Kontinuumsvorhersage ist ohne Verwendung hydrologischer Daten mit diesen Ansätzen nicht möglich.

6.3.4 Hochwasserereignisse

Entsprechend der Kontinuumsbetrachtung wurden diese Untersuchungen auch für die Hochwasservorhersage mit der gleichen Aufteilung der Eingangsdaten durchgeführt. Diese Arbeiten mußten aufgrund der Datenbasis im Einzugsgebiet der Vils durchgeführt werden. Hier liegen stündliche Niederschlags- und Abflußmessungen vor.

Alle im weiteren aufgeführten Ergebnisse beziehen sich der Übersichtlichkeit wegen wieder auf den Pegel Amberg/Vils. Diese Untersuchungen wurden auch an den Pegeln Vilseck/Vils und Schmidmühlen/Vils durchgeführt, wobei die Ergebnisse die gleiche Charakteristik aufweisen. Die KNN wurden mit einem Ereignis des Zeitraums 10.12.1991 - 12.1.1992 angelert und danach auf drei andere Hochwasserereignisse angewendet (Tabelle 13).

Bei diesen Untersuchungen ist ebenfalls die Gewässerstruktur wie auch die Lageinformationen der Meßstellen im KNN über die Anzahl der Layer, die Anzahl der Neuronen in den einzelnen Schichten und über die Verbindungen der Neuronen untereinander integriert worden.

a) Hydrologische Eingangsdaten, Variante 14

Hier stellt sich wider Erwarten ein differenziertes Bild in der Vorhersage ein (Tabelle 24). Während in der trivialen Anwendung mit aktuellen Eingangsdaten der Oberliegerpegel noch gute Ergebnisse erzielt worden sind, sind die Ergebnisse hier eher schlecht, die Abflußganglinie wird teilweise nicht mehr wiedergegeben. Bei Verwendung der 12 vorherigen Stundenwerte werden hingegen wieder sehr gute Ergebnisse erreicht. Diese sind hier deutlich besser als mit der trivialen Methode.

Ausnahme hierbei ist das Ereignis 25.12.1990 - 20.1.1991. Hier gelingt es dem Netz mit keinem Zeitfenster, die Höhe der Abflüsse oder die Form der Abflußkurve vorherzusagen. Lediglich der Hochwasserscheitel wird am Termin seines Eintreffens richtig nachgebildet, alle anderen Werte liegen deutlich neben der Messung.

Tab. 24: Differenz und Korrelation zwischen berechneten und gemessenen stündlichen Abflüssen am Pegel Amberg, Variante 14, hydrologische Eingangsdaten

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten						
25.12.-20.1.91	2.92	2.66	-47.06	-2.40	1.72	-0.36
8.5.-25.5.91	6.04	2.19	-31.34	-1.01	1.33	0.59
15.6.-5.7.91	9.11	4.22	-1.26	-0.06	2.32	0.47
Eingangsdaten der 12 vorherigen Stunden						
25.12.-20.1.91	9.23	7.62	51.43	2.60	1.08	0.81
8.5.-25.5.91	9.55	3.58	12.32	0.40	0.69	0.90
15.6.-5.7.91	10.75	3.78	-11.41	-0.49	0.83	0.93

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

Demgegenüber können die beiden anderen Ereignisse ab der Verwendung von sechs (besser 12) vorherigen Meßwerten exakt in Höhe wie Eintrittstermin vorhergesagt werden. Mit diesen Zeitfenstern wird eine Vorhersage gegenüber der trivialen Methode erst ermöglicht. Abbildung 31 zeigt wiederum die Berechnungsergebnisse als Ganglinie.




Abb. 31: Berechnete und gemessene Abflußganglinie Pegel Amberg, 15.6. - 5.7.1991 mit dem Trainingsmuster 10.12.1991 - 10.1.1992, Variante 14, Zeitfenster 12 Stunden, hydrologische Eingangsdaten

b) Meteorologische Eingangsdaten, Variante 15

Bei dieser Untersuchung mußte aufgrund fehlender Daten auf die Betrachtung des Ereignisses vom 25.12.1990 - 20.1.1991 verzichtet werden.

Trotz geringer mittlerer Abweichung zeigt der Korrelationskoeffizient nahe Null in Tabelle 25, daß ganz gleich welches Zeitfenster man verwendet, in keinem Fall eine auch nur annähernd genaue Vorhersage gemacht werden konnte. Die Ergebnisse sind über alle betrachteten Fälle hinweg sehr schlecht. Wenngleich Abflußscheitel in Höhe der Gemessenen berechnet werden, so liegen diese meist vom Zeitpunkt her deutlich falsch (Abbildung 32). Ein Grund hierfür ist nicht zu erkennen, das KNN ist aber offensichtlich nicht in der Lage, die Summe des Antriebs (Niederschläge aller Stationen) richtig zu verarbeiten. Auch längere Zeitfenster wie z. B. 24 vorherige Stunden erbringen keine besseren Ergebnisse, im Gegenteil, sie verschlechtern sie noch. Trotz der ungenügenden Ergebnisse zeigt die einfache Netztopologie zumindest geringere Fehler als die triviale Methode.

Hier zeigt sich wieder die Tendenz der KNN, das Mittel von Eingangs- und Zielfunktion anzupassen, dies aber teilweise ohne Rücksicht auf die Form der abzubildenden Funktion.

Tab. 25: Differenz und Korrelation zwischen berechneten und gemessenen stündlichen Abflüssen am Pegel Amberg, Variante 15, Niederschlag als Eingangsdaten

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten						
8.5.-25.5.91	3.66	2.90	-9.25	-0.30	1.75	-0.06
15.6.-5.7.91	5.43	3.31	-22.60	-0.99	2.09	-0.01
Eingangsdaten der 12 vorherigen Stunden						
8.5.-25.5.91	8.97	3.18	-0.18	-0.01	1.92	0.03
15.6.-5.7.91	5.77	3.75	-12.28	-0.55	2.36	0.10

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient




Abb. 32: Berechnete und gemessene Abflußganglinie Pegel Amberg, 15.6. - 5.7.1991, Variante 15, Zeitfenster 12 Stunden, Niederschlag als Eingangsdaten

Nach diesen absolut unzureichenden Ergebnissen (Abbildung 32) wurde auch hier in einem ersten Schritt versucht, durch eine Verbindung der Informationen aus hydrologischen und meteorologischen Eingangsdaten eine Verbesserung der Vorhersage zu erreichen. Diese wurde wieder durch Verknüpfung der meteorologischen Eingangsdaten zunächst nur mit einem Oberliegerpegel, dann mit Integration der Gewässerstruktur ins Netz versucht.

c) Hydrologische und meteorologische Eingangsdaten, Variante 16-17

Tabelle 26 zeigt, daß ab einem Zeitfenster von 12 vorherigen Daten die Vorhersagequalität bei der Verwendung meteorologischer Eingangsdaten in Verbindung mit einem Oberliegerpegel gut ist. Die Abflußspitzen werden im Eintreffen und in der Höhe sehr gut vorhergesagt, lediglich in der Rückgangphase treten noch große Abweichungen zwischen berechneten und gemessenen Werten auf. Mit aktuellen Eingangsdaten ist keine sinnvolle Vorhersage möglich.

Tab. 26: Differenz und Korrelation zwischen berechneten und gemessenen stündlichen Abflüssen am Pegel Amberg, *Variante 16*, meteorologische und hydrologische Eingangsdaten

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten						
8.5.-25.5.91	7.70	3.81	19.42	1.14	3.63	0.16
15.6.-5.7.91	9.62	4.52	5.84	0.46	3.89	0.51
Eingangsdaten der 12 vorherigen Stunden						
8.5.-25.5.91	9.65	4.11	28.83	1.67	1.24	0.90
15.6.-5.7.91	11.21	5.89	37.86	2.95	2.17	0.83

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

Abbildung 33 zeigt die noch immer deutliche Überschätzung der Abflußmenge. Die Spitzen werden zwar in Termin und Höhe recht gut vorhergesagt, v. a. aber in der Rückgangphase zeigen sich deutliche Abweichungen von der Messung. Die Berechnungen liegen durchweg über den gemessenen Werten.




Abb. 33: Berechnete und gemessene Abflußganglinie am Pegel Amberg, 15.6. - 5.7.1991, Variante 16, Zeitfenster 12 Stunden, hydrologische und meteorologische Eingangsdaten


Dies verbessert sich bei vollständiger Integration der Gewässerstruktur in die Netztopologie. Hier zeigt sich wiederum eine deutliche Verbesserung der Vorhersageergebnisse gegenüber dem vorherigen Ansatz oder trivialer Anwendung (Tabelle 27).

Es ist zu erkennen, daß bei Verwendung der aktuellen Eingangsdaten wiederum keine gute Vorhersage getroffen werden kann. Erst ab der Verwendung eines Zeitfensters der Größe 12 Stunden ist die Simulation sehr gut (Abbildung 34). Hier ist die Qualität der Vorhersage auch deutlich besser als mit der trivialen Methode.

Tab. 27: Differenz und Korrelation zwischen berechneten und gemessenen stündlichen Abflüssen am Pegel Amberg, Variante 17, meteorologische und hydrologische Eingangsdaten

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]
Aktuelle Eingangsdaten						
8.5.-25.5.91	2.97	2.31	-27.64	-0.90	1.79	0.00
15.6.-5.7.91	4.47	7.61	78.29	3.43	2.10	0.51
Eingangsdaten der 12 vorherigen Stunden						
8.5.-25.5.91	8.77	2.87	-10.00	-0.32	1.11	0.73
15.6.-5.7.91	10.25	3.86	-9.68	-0.42	1.50	0.71

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient

**Abb. 34:** Berechnete und gemessene Abflußganglinie am Pegel Amberg, 15.6. - 5.7.1991, Variante 17, Zeitfenster 12 Stunden, hydrologische und meteorologische Eingangsdaten

Abgesehen von den Ausreißern im absteigenden Ast der Hochwasserwelle wird nun im Gegensatz zur Verbindung meteorologischer Daten mit einem Oberliegerpegel auch die Rückgangsphase gut beschrieben. Der Grund für diese Ausreißer in den Rückgangphasen, die sich in gleichem Maße beim Ereignis vom 8.5.1991 einstellen, könnte auf ein Überspringen des Netzes aufgrund des rapiden Abfalls der Ganglinie beruhen. Im Trainingsmuster ist ein ähnlich steiler Abfall nach dem ersten Scheitel zu erkennen.

Untersuchungen mit weniger Trainingszyklen (10 % der obigen Ansatzes) haben gezeigt, daß sich hier dieser Abfall nicht so stark ausprägt wie oben dargestellt. Dies läßt auf ein Übertrainieren (Overfitting) des KNN schließen. Allerdings werden hier die Scheitelabflüsse nicht so gut vorhergesagt. Dies zeigt, daß keine generelle Aussage über Güte und Qualität eines bestimmten Ansatzes mit bestimmter Topologie und Trainingsphase im Vorfeld der Anwendung getroffen werden kann. Dies entscheidet sich immer erst mit der Anwendung am speziellen Einzugsgebiet.

6.3.5 Bewertung der Ergebnisse der Hochwasservorhersage

- Bei alleiniger Verwendung hydrologischer Eingangsdaten konnte mit der einfachen Netztopologie eine z. T. sehr deutliche Verbesserung gegenüber den trivialen Ansätzen erreicht werden.
- Eine Hochwasservorhersage konnte bei alleiniger Verwendung meteorologischer Eingangsdaten nicht erreicht werden.
- Durch die Verbindung meteorologischer und hydrologischer Eingangsdaten können hier deutliche Verbesserungen erzielt werden.
- Auch bei diesem Ansatz mit der einfachen Netztopologie zeigt sich, daß die Hochwasservorhersage für die bisherigen, recht einfachen Ansätze ohne Verwendung hydrologischer Eingangsdaten nicht zu realisieren ist.
- Die deutlichen Verbesserungen gegenüber der trivialen Methode im Bereich der Hochwasservorhersage zeigen aber, daß bereits eine einfache Berücksichtigung der Lage- und Rauminformationen von Stationen im Untersuchungsgebiet erhebliche Vorteile aufweist.

Diese Ergebnisse der bisher untersuchten Varianten erlauben die Hypothese, eine Abflußmodellierung auf der Basis meteorologischer Eingangsdaten ist durch eine intensive Verwendung weiterer räumlicher Informationen in einem flächenbezogenen Ansatz zu realisieren. Diese Möglichkeiten werden im nächsten Kapitel näher untersucht.

6.4 Komplexe Netztopologie

6.4.1 Allgemeines

Wie die Ergebnisse der Kapitel 6.2 und 6.3 gezeigt haben, ist die Vorhersage des Abflusses mit dem alleinigen Systemantrieb Niederschlag mittels KNN nicht realisierbar. Die hohe Nichtlinearität des N-A-Prozesses, die aufgrund zahlreicher Modifikationen durch Verdunstung, Landnutzung, Boden, Vorfeuchte usw. existiert, kann nicht durch solch einfache Ansätze abgebildet werden. In diesem Kapitel werden daher diese Größen bei der N-A-Modellierung berücksichtigt, sie fließen als flächenhafte Eingangsdaten mit in die Berechnung ein. Da auch hier verlässliche Aussagen über Qualität und Güte der Berechnung nur mit gesicherten Daten erfolgen kann beruhen auch diese Untersuchungen auf der Verwendung gemessener Zeitreihen meteorologischer Merkmale und Abflußanglinien.

Die Modellierung erfolgt mittels der komplexen Netztopologie rasterpunktbezogen. Form und Größe des Einzugsgebietes geben die Größe des KNN vor, die Fließwege im Einzugsgebiet definieren die Verbindungen der Neuronen untereinander. Zeitlich veränderliche Informationen werden für die Berechnung dem KNN als Eingangsdaten mit angelegt. Tabelle 28 gibt eine Übersicht über die untersuchten Kombinationen der verschiedenen Daten und der zeitlichen Auflösung der Berechnungen.

Tab. 28: Untersuchte Varianten der komplexen Netztopologie

Eingangsdaten	Zeitliche Auflösung	Varianten
DHM, N	Tage	Variante 18
	Stunden	Variante 30
DHM, N, $VN_{m,i}$	Tage	Variante 19
	Stunden	Variante 31
DHM, N, LL_m	Tage	Variante 20
	Stunden	Variante 32
DHM, N, $VN_{m,i}$, LL_m	Tage	Variante 21
DHM, N, T	Tage	Variante 22
	Stunden	Variante 33
DHM, N, T, $VN_{m,i}$, LL_m	Tage	Variante 23
DHM, N, LN	Tage	Variante 24, Differenz der LN
	Stunden	Variante 34, Differenz der LN
DHM, N, $VN_{m,i}$, LL_m , LN	Tage	Variante 25
DHM, N, LN	Tage	Variante 26, reale LN
		Variante 27, invertierte LN
		Variante 28, binarisierte LN
	Stunden	Variante 35, reale LN
		Variante 36, invertierte LN
		Variante 37, binarisierte LN
DHM, N, T, LN	Tage	Variante 29
	Stunden	Variante 38
Varianten 30-38 mit Boden	Stunden	Varianten 39-46

6.4.2 Kontinuumssimulation

Training

Im Einzugsgebiet des Oberen Mains werden für diesen Ansatz wieder die drei Pegel Bayreuth (B), Theisau (T) und Schwüribitz (S) verwendet. Aufgrund der Komplexität der KNN und der daraus resultierenden Menge an Eingangsdaten kann hier nicht mehr mit den langen Trainingszeiträumen der vorherigen Ansätze gerechnet werden. Eine Datei für den Pegel Schwüribitz mit den Eingangsdaten Niederschlag, Temperatur und NDVI hat für 10 Jahre die Größe von knapp 158 MB. Damit sind KNN nicht mehr zu trainieren. Aufgrund dessen wurden auch für die Kontinuumssimulation charakteristische Zeiträume für das Training ausgewählt. Tabelle 29 zeigt das Abflußverhalten der drei Pegel für diese Zeiträume.

Tab. 29: Statistik der gemessenen Abflüsse für die Trainings- und Validierungszeiträume der Pegel Bayreuth, Theisau und Schwüribitz

Pegel	Gemessener mittlerer Abfluß MQ_g $\left[\frac{m^3}{s}\right]$	Standardabweichung SMQ_g $\left[\frac{m^3}{s}\right]$	Gemessener Scheitel- abfluß HQ_{max} $\left[\frac{m^3}{s}\right]$
Trainingszeiträume			
B, 1.11.85 - 31.10.87	2.95	4.04	34.60
T, 1.10.74 - 1.3.75	29.15	25.91	164.00
S, 10.12.86 - 31.1.87	90.53	112.47	503.00
Validierungszeiträume			
B, 1.11.88 - 1.11.91	2.53	3.06	32.90
T, 31.10.80 - 30.10.83	16.64	20.02	205.00
S, 6.11.80 - 5.11.83	36.28	44.51	557.00

Aufgrund der Komplexität der KNN (z. B. für Schwüribitz 10057 Neuronen bei 7289 Verbindungen) fanden hier zunächst nur die Niederschlagsdaten des Vortages Anwendung. Jeder weitere vorherige Tag hätte den Input Layer um die Anzahl der Pixel im Untersuchungsgebiet vergrößert. Beim Pegel Schwüribitz wären dies 2424 Neuronen mit der entsprechenden Anzahl von Verbindungen. Die Verwendung vorheriger Zustände im Einzugsgebiet wird über den regionalisierten Vorregenindex bewerkstelligt, der als weitere Informationsebene neben dem Niederschlag verwendet wird.

Validierung

Zur Validierung der trainierten Netze wurden jeweils drei Jahre aus der Kontinuumsmessung verwendet. Tabelle 29 gibt die Statistik der gemessenen Abflüsse in diesem Zeitraum wieder.

Ergebnistabellen und Abbildungen der Abflußganglinien sind für alle untersuchten Varianten gesammelt in Anhang A wiedergegeben, hier seinen nur die Wichtigsten exemplarisch dargestellt.

1) Niederschlag als Eingangsdatensatz, *Variante 18*

Im Vergleich zum trivialen Ansatz wie zur einfachen Netztopologie zeigt sich, daß sich für die Trainingsphase des KNN eine deutliche Verbesserung der Ergebnisse einstellt, die Validierungsphase ist aber auch hier sehr schlecht. Das KNN kann zwar das Trainingsmuster sehr gut erlernen, es gelingt aber nicht, die funktionalen Zusammenhänge zwischen dem Niederschlag und dem Abfluß im Einzugsgebiet abzubilden (Tabelle 30 und Seite 2, Anhang A).

Tab. 30: Differenz und Korrelation zwischen berechneten und gemessenen täglichen Abflüssen, *Variante 18*, Niederschlag als Eingangsdaten und komplexe Netztopologie

Pegel	MQ_b $\left[\frac{m^3}{s}\right]$	ΔMQ [%]	MQ_{diff} $\left[\frac{m^3}{s}\right]$	$S_{MQ_{diff}}$ $\left[\frac{m^3}{s}\right]$	r_{MQ_b, MQ_g} [–]	E_{log} [–]
Training						
B, 1.11.85	3.17	7.67	0.23	2.69	0.75	0.102
T, 1.10.74	29.66	1.32	0.39	19.06	0.68	0.264
SW, 10.12.86	80.67	0.96	0.76	91.09	0.48	-0.370
Validierung						
B, 1.11.88	2.43	-3.78	-0.10	2.96	0.35	0.001
T, 31.10.80	33.13	105.29	16.99	19.06	0.25	-1.413
SW, 6.11.80	167.93	367.95	132.04	148.43	0.09	-3.875

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log. Effizienz

Während in der Trainingsphase die Abweichungen bei allen drei Pegeln deutlich unter 10 % liegen und auch die Korrelationen zwischen berechneter und gemessener Ganglinie noch recht hoch sind, kommt es in der Validierungsphase zu Überschätzungen von weit über 300 %. Korrelation und Effizienz gehen gegen Null oder werden gar negativ. Dieser Fehler zeigt sich auch deutlich in Abbildung 35 und der Abbildung auf Seite 2, Anhang A, in der gemessene gegen berechnete Ganglinien für Training und Validierung aufgetragen sind.




Abb. 35: Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988-1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, *Variante 18*, Zeitfenster ein Tag, Niederschlag als Eingangsdatensatz und komplexe Netztopologie

Deutlich ist die Fehlberechnung in der Validierungsphase zu erkennen, es treten maximale Abweichungen von über 80 % auf, viele Abflußspitzen werden gar nicht erkannt oder nur andeutungsweise nachgebildet. Die Validierung mit einem anderen Zeitraum der Eingangsdaten und somit anderen Randbedingungen (Bodenfeuchte, Landnutzung, etc.) sind vom KNN mit diesen Daten nicht nachzubilden.

2) Niederschlag und Vorregenindex als Eingangsdatensatz, Variante 19

Um vorherige Zustände im Einzugsgebiet zu erfassen wird zusätzlich der regionalisierte Vorregenindex als Eingangsdatensatz verwendet. Hierdurch soll dem Netz die Information über die klimatologische Geschichte des Einzugsgebiets für einen bestimmten Zeitraum mit angeboten werden. Auch hier stellt sich wieder der Umstand ein, daß das KNN zwar sehr gut das Trainingsmuster erlernen kann, diese gute Nachbildung aber nicht in der Validierung umsetzen kann (Seite 3, Anhang A). Hier liegen die Abweichungen vom gemessenen Ist-Wert in der Lernphase unter 1 %, Korrelation und Effizienzwert sind relativ hoch. In der Überprüfungsphase zeigen sich aber auch hier wieder große Abweichungen vom gemessenen Wert. Während für Bayreuth noch eine Unterschätzung von knapp 13 % festzustellen ist, werden die beiden anderen Pegel wieder deutlich überschätzt. Die mittleren täglichen Abweichungen liegen mit über 25 % sehr hoch. Es treten auch hier sehr hohe punktuelle Differenzen auf (Seite 3, Anhang A), wobei selbst der Basisabfluß nicht richtig nachgebildet werden kann. Auch hier muß festgestellt werden, daß der Abfluß an den drei untersuchten Pegeln nicht vorhergesagt werden kann.

3) Niederschlag und Lauflänge im Einzugsgebiet als Eingangsdatensatz, Variante 20

Um den Einfluß der Laufzeiten im Einzugsgebiet zu untersuchen, ist hier dem KNN als weitere Informationsquelle der Abstand der einzelnen Flächenelemente vom Untersuchungspegel mit als Eingangsdatensatz angeboten worden. Es zeigt sich auch hier wieder die gleiche Tendenz des sehr guten Erlernens und schlechten Vorhersagens der Abflußmuster (Seite 4, Anhang A). Größenordnung und Tendenz sind annähernd so wie bei Verwendung des Vorregenindex. Die Trainingsphase ist ausgezeichnet mit sehr geringen Abweichungen vom gemessenen Wert, in der Validierungsphase kommt es zu teilweise sehr deutlichen Überschätzungen (> 100 %) der Pegel Theisau und Schwürbitz, die Abflüsse am Pegel Bayreuth werden leicht unterschätzt. Die Charakteristik und Höhe der Ganglinien wird an keinem der drei Pegel wiedergegeben (Seite 4, Anhang A).

Die Kombination der zwei Eingangsparameter Vorregenindex und Lauflänge (*Variante 21*) im Einzugsgebiet liefert sehr ähnliche Ergebnisse. Die Trainingsphasen sind wieder ausgewiesen durch gute Adaption an die Lernmuster (Korrelationskoeffizient 0.74, log Effizienz 0.167), wohingegen in der Validierungsphase wieder eine deutliche Unterschätzung der Abflüsse um fast 10 % auftritt.

4) Niederschlag und Temperatur als Eingangsdatensatz, Variante 22

Bei dieser Anwendung ist als weitere wichtige Größe die räumlich verteilte Temperatur mit zum Trainingsmuster hinzugenommen worden. Es zeigt sich aber auch hier wie bereits bei den vorherigen Anwendungen (trivialer Ansatz, einfache Netztopologie), daß die Verwendung der Temperatur zu teilweise chaotischem Verhalten des KNN führt. Es treten zufällige extreme Abweichungen auf, die aus dem Netz oder den Daten nicht zu erklären sind (Abbildung 36 und Seite 5, Anhang A, Sommer 1990).




Abb. 36: Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Variante 22, Zeitfenster ein Tag, Niederschlag und Temperatur als Eingangsdatensatz und komplexe Netztopologie

Bei den Pegeln Bayreuth und Theisau treten wieder Überschätzungen von über 100 % auf, der Pegel Schwübitz kann trotz mehrmaliger Versuche überhaupt nicht erlernt oder gar vorhergesagt werden (Tabelle 31 und Seite 5, Anhang A). Die mittleren täglichen Abweichungen betragen über 50 %, Korrelation und Effizienz sind mit fast durchgängig negativen Werten sehr schlecht. Von einer Vorhersage der Abflüsse kann mit diesen Eingangsdaten ebenfalls nicht die Rede sein.

Eine gemeinsame Nutzung der Daten Niederschlag, Temperatur, Vorregenindex sowie Lauf-längen im Einzugsgebiet (Variante 23) liefert trotz wiederum sehr guten Trainingsergebnissen in der Vorhersage mit Überschätzungen von knapp 800 % und einem log Effizienzwert von -21.32 vollkommen abweichende Ergebnisse von der Realität. Der Faktor Temperatur scheint hier für eine Vorhersage mit KNN gänzlich ungeeignet zu sein.

Tab. 31: Differenz und Korrelation zwischen berechneten und gemessenen täglichen Abflüssen, *Variante 22*, Niederschlag und Temperatur als Eingangsdaten und komplexe Netztopologie

Pegel	MQ_b $\left[\frac{m^3}{s}\right]$	ΔMQ [%]	MQ_{diff} $\left[\frac{m^3}{s}\right]$	SMQ_{diff} $\left[\frac{m^3}{s}\right]$	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.84	-3.59	-0.11	2.02	0.87	0.313
T, 1.10.74	29.43	0.55	0.16	16.68	0.76	0.389
SW, 10.12.86	60.40	-24.41	-19.51	30.74	0.96	-34.974
Validierung						
B, 1.11.88	5.60	122.09	3.08	10.49	-0.11	-2.184
T, 31.10.80	33.13	105.29	16.99	25.75	0.25	-1.413
SW, 6.11.80	402.17	1020.72	366.29	247.20	-0.39	-15.958

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log. Effizienz

5) Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz, *Variante 24*

Wenngleich bei der Verwendung der NDVI-Monatsmittel als Zeitreihe der Differenzen jeweils aufeinanderfolgender Monate zur Repräsentation der Landnutzung und ihrer Veränderung im Jahresgang die Trainingsphase noch etwas besser ist als bei den vorherigen Anwendungen, so ist doch in der Validierungsphase auch hier wieder die selbe Problematik der Überschätzung der Abflüsse zu erkennen (Tabelle 32 und Seite 6, Anhang A).

Tab. 32: Differenz und Korrelation zwischen berechneten und gemessenen täglichen Abflüssen, *Variante 24*, Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdaten und komplexe Netztopologie

Pegel	MQ_b $\left[\frac{m^3}{s}\right]$	ΔMQ [%]	MQ_{diff} $\left[\frac{m^3}{s}\right]$	SMQ_{diff} $\left[\frac{m^3}{s}\right]$	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.92	-0.96	-0.03	1.48	0.93	0.682
T, 1.10.74	28.50	-2.63	-0.77	16.12	0.78	-0.474
SW, 10.12.86	70.48	-6.58	-4.97	33.74	0.94	-4.606
Validierung						
B, 1.11.88	2.17	-14.12	-0.36	2.77	0.43	0.234
T, 31.10.80	25.97	60.86	9.83	35.93	-0.14	-8.822
SW, 6.11.80	127.10	252.79	91.07	201.57	-0.022	-16.33

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log. Effizienz

Ist zwar der Effizienzwert in der Lernphase bei Theisau und Schwürbitz relativ schlecht, so zeigen doch die geringen Abweichungen sowie die hohe Korrelation eine sehr gute Übereinstimmung mit den gemessenen Abflüssen. Dieses gute Ergebnis kann allerdings nicht in der Validierungsphase wiederholt werden. Der Basisabfluß wird hier zwar etwas besser in seiner Gesamtcharakteristik nachgebildet, die Abflußspitzen und deren Höhe können aber in keinsten Weise vorhergesagt werden (Abbildung 37 und Seite 6, Anhang A). Die maximalen täglichen Abweichungen liegen hier zwar unter 75 %, doch ist dies natürlich in keinsten Weise eine akzeptable Vorhersage. Eine Überschätzung der Abflüsse von über 250 % am Pegel Schwürbitz zeigt das Unvermögen der KNN, diese Vorhersage mit diesen Eingangsdaten durchzuführen.




Abb. 37: Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Variante 24, Zeitfenster ein Tag, Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz und komplexe Netztopologie

Auch eine Verknüpfung der NDVI-Datensätze mit Niederschlag, Lauflängenindex und Vorregenindex erreicht keine besseren Ergebnisse. Sie sind zwar mit Abweichungen von ca. -26 % deutlich geringer als bei alleiniger Verwendung der Landnutzungsdaten, von einer präzisen Vorhersage kann aber auch hier nicht die Rede sein. Der Korrelationskoeffizient beträgt hier 0.43 bei einem log Effizienzwert von 0.226.

6) Niederschlag und reale NDVI-Monatsmittel als Eingangsdatensatz, Variante 26

Um zu testen, ob der Fehler der Vorhersage an der Verwendung der Differenzen der NDVI-Monatsmittel liegt, ist bei dieser Anwendung direkt mit den realen NDVI-Werten der einzelnen Monate gerechnet worden. Seite 7, Anhang A zeigt aber auch für diese Eingangsdaten eine ähnliche Charakteristik wie unter 5). Die Trainingsphase kann wieder als sehr gut beschrieben werden (Abweichungen unter 5 %), die Validierungsphase hingegen liegt mit Differenzen von über 200 % wieder deutlich neben der Messung. Auch die Charakteristik in den Abweichungen der Tageswerte (Seite 7, Anhang A) ist sehr ähnlich in Höhe und Anzahl der Differenzen. Eine Abfluvvorhersage ist auch mit den realen Monatsmitteln des NDVI nicht möglich.

7) Niederschlag und invertierte reale NDVI-Monatsmittel als Eingangsdatensatz

Variante 27

Da in den realen NDVI-Daten viel Vegetation über hohe Grauwerte abgebildet werden, dies aber vom KNN als abfluvfördernd und nicht abfluvhemmend interpretiert werden könnte, sind die realen Monatsmittel invertiert und dann dem KNN als Datensatz angeboten worden. Dies soll zeigen, ob grundsätzliche Fehler bei der Verwendung der NDVI-Daten vorliegen oder ob das schlechte Ergebnis auf das KNN selbst zurückzuführen ist. Da aber die Tabelle auf Seite 8, Anhang A annähernd das gleiche Ergebnis aufzeigt wie bei der direkten Verwendung der realen unveränderten NDVI-Werte, kann ein prinzipieller Fehler in der Anwendung dieser Daten mit KNN ausgeschlossen werden. In der Abbildung Seite 8, Anhang A sind teilweise noch höhere tägliche Abweichungen festzustellen, auch hier ist die Vorhersage über den gesamten Bearbeitungszeitraum durchwegs schlecht.

8) Niederschlag und binarisierte NDVI-Monatsmittel als Eingangsdatensatz Variante 28

Um die Stärke des Einflusses des NDVI auf die Berechnungsergebnisse näher zu untersuchen, ist in dieser Anwendung das Extremmaß für abfluvhemmend bzw. -fördernd gewählt worden. Die NDVI-Daten werden nach dem Schwellwert 0.5 binarisiert, alle Pixel mit geringerem NDVI als 0.5 erhalten den Wert 0, alle Pixel mit höherem NDVI den Wert 1. Da aber die Tabelle Seite 9, Anhang A wiederum sehr ähnliche Werte wie unter 6) aufweist und v. a. die Trainingsphase in Abbildung Seite 9, Anhang A nahezu identisch ist mit der Abbildung auf Seite 7, Anhang A kann davon ausgegangen werden, daß der tatsächliche NDVI-Wert weniger Einfluß auf das Ergebnis hat. Die Problematik der schlechten Vorhersage ist eher ursächlich bei den KNN zu suchen.

9) Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdatensatz Variante 29

In dieser Kombination werden dem KNN alle zur Verfügung stehenden Daten als räumlich verteilte Datensätze angeboten. Die Ergebnisse dieser Anwendung unterscheiden sich aber prinzipiell nicht von den Vorherigen. Die Trainingsphase zeigt wieder sehr gute Ergebnisse bis hin zur fast exakten Nachbildung des Bearbeitungsjahres (Tabelle 33 und Seite 10, Anhang A), die Validierung erscheint als eine Mischung aus den Anwendungen mit alleiniger Verwendung der einzelnen Datensätze (Abbildung 38 und Seite 10, Anhang A).

Tab. 33: Differenz und Korrelation zwischen berechneten und gemessenen täglichen Abflüssen, Variante 29, Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdaten und komplexe Netztopologie

Pegel	MQ_b [$\frac{m^3}{s}$]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.95	0.13	0.00	1.16	0.96	0.774
T, 1.10.74	28.92	-1.19	-0.35	11.43	0.90	0.626
SW, 10.12.86	64.30	-19.53	-15.61	30.67	0.96	-37.966
Validierung						
B, 1.11.88	3.45	36.81	0.93	4.27	-0.04	-1.422
T, 31.10.80	25.15	55.88	9.02	39.62	-0.03	-5.913
SW, 6.11.80	374.25	942.91	338.36	232.95	-0.40	-14.400

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log. Effizienz

Auch hier tritt wieder die starke Abweichung im Sommer 1990 auf, wohingegen der Verlauf der restlichen Ganglinie wieder die Abweichungen vergleichbar den vorherigen Anwendungen aufweist. Die Kombination der drei Datensätze erreicht in keinsten Weise eine annehmbare Vorhersagequalität. Eine Vorhersage allein auf meteorologischen Daten beruhend ist mit dieser Art von KNN nicht zu realisieren.

Eine Erweiterung der Eingangsdaten um Vorregenindex und Lauflängenindex erzielt hier zwar die besten Trainingsergebnisse (Korrelation 0.95, log Effizienz 0.78), liegt aber dann in der Vorhersage ebenfalls deutlich neben den gemessenen Abflüssen (Überschätzung von über 100 %). Es konnte mit keiner der getesteten Eingangsdaten alleine oder in Kombination mit anderen eine sinnvolle Vorhersage der mittleren täglichen Abflüsse erreicht werden.




Abb. 38: Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, *Variante 29*, Zeitfenster ein Tag, Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdatensatz und komplexe Netztopologie

6.4.3 Bewertung der Ergebnisse der Kontinuumsimulation

Untersuchungen mit einem Gebietsniederschlag = 1 haben gezeigt, daß sich während der Trainingsphase im KNN sehr schnell ein statischer Zustand einstellt. Die meisten internen Verknüpfungen im Hidden Layer, die die Fließwege im Einzugsgebiet widerspiegeln, werden auf Null gesetzt. Dies bedeutet, daß diese Verbindungen für die weiteren Berechnungen nicht mehr berücksichtigt werden. Dieser Zustand trat unabhängig vom gewählten Trainingsverfahren immer ein. Wichtig sind hier für das KNN offensichtlich nur die Verbindungen, die direkt zur Berechnung der Ausgabe beitragen.

Diejenigen, die zur Bildung einer Zwischensumme dienen, spielen keine Rolle. Das KNN benötigt sie nicht, um in der Trainingsphase eine Abbildung der funktionalen Zusammenhänge zwischen Ein- und Ausgabe zu erreichen. Die sehr guten Trainingsergebnisse bestätigen dies.

Bewertet nun aber das KNN diese internen Verbindungen selbst als unwichtig und unterdrückt sie, so zeigt dies, daß dieser flächenhafte Ansatz mit Integration räumlicher Informationen in die Struktur eines KNN nicht funktioniert. Das KNN versucht, mit möglichst wenig relevanten Neuronen, die in möglichst kurzer Verbindung zur Ausgabe stehen, die Abbildung des Zusammenhanges herzustellen. Hierfür sind diese internen Verknüpfungen nicht von Nöten.

Die guten Trainingsresultate deuten zudem darauf hin, daß durch die Vielzahl der Neuronen eine deutliche Überbestimmung der Transferfunktion zwischen Input und Output stattfindet. Das KNN hat zuviele freie und somit adaptierbare Parameter. Das KNN verliert dadurch nahezu jede Generalisierungsfähigkeit, eine Übertragung der erlernten Struktur auf andere Ereignisse ist nicht möglich. Zudem zeigen Untersuchungen der Niederschlagsereignisse, daß sich allein die Charakteristik der Niederschläge stark von Anderen unterscheidet, hierbei sind die variablen Randbedingungen der Abflußbildung und -konzentration noch nicht einmal berücksichtigt. Dies kann durch ein überbestimmtes KNN nicht verallgemeinert und abgebildet werden.

Es muß festgestellt werden, daß KNN in der Form der komplexen Netztopologie nicht in der Lage sind, das Abflußkontinuum aufgrund meteorologischer Daten und der Landnutzung vorherzusagen. Diese Einschränkung zeigt sich schon bei den vorher getesteten Ansätzen (trivialer Ansatz, einfache Netztopologie), sie wird hier wieder bestätigt.

Der Ansatz der flächenbezogenen Abflußmodellierung mittels KNN (komplexe Netztopologie) muß als gescheitert angesehen werden. Es gelingt in keiner der untersuchten Anwendungen weder auf Stunden- noch auf Tagesbasis, eine vernünftige Abflußvorhersage auf der Basis meteorologischer Eingangsdaten, Landnutzungsinformationen, Boden und/oder weiteren flächenhaften Eingangsdaten zu erhalten.

6.4.4 Hochwasserereignisse

Aufgrund der Komplexität der Daten und der daraus resultierenden Ähnlichkeit der Ansätze sind hier in der ereignisbezogenen Hochwasservorhersage keine nennenswert anderen Ergebnisse zu erwarten. Lediglich die zeitliche Auflösung unterscheidet sich von den Arbeiten zur Kontinuumsbetrachtung, der grundsätzliche Versuch, das KNN über repräsentative Ereignisse anzulernen ist der gleiche. Die Statistik der gemessenen Abflüsse für die Verifikation ist wiederum in Tabelle 13 aufgeführt. Da hier nun v.a. die Güte der Abflussspitzenvorhersage von Belang ist, wird nun nicht mehr der logarithmische Effizienzparameter wie bei der Kontinuumsbetrachtung als Gütekriterium verwendet. Hier ist besser der eigentliche Effizienzwert zu verwenden, da dieser gerade auch die hohen Werte mit berücksichtigt (Gleichung 4).

Graphiken und Tabellen der Untersuchungsergebnisse sind in Anhang B dargestellt.

1) Niederschlag als Eingangsdatensatz, Variante 30

Im Vergleich zu den Anwendungen zum Kontinuum gelingt es hier dem KNN nicht mehr, das Trainingsmuster zu erlernen. Die Abweichungen liegen bereits hier bei fast 30 % (Tabelle 34 und Seite 2, Anhang B), Korrelation und Effizienz zeigen überhaupt keine Übereinstimmung mehr zwischen Messung und Berechnung.

Tab. 34: Differenz und Korrelation zwischen berechneten und gemessenen täglichen Abflüssen, Variante 30, Niederschlag als Eingangsdaten und komplexe Netztopologie

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]	E [—]
Training							
10.12.1991	8.71	5.81	28.69	1.30	2.54	0.16	-0.226
Validierung							
25.12.1990	4.90	3.88	-21.79	-1.01	1.64	-0.02	-0.467
08.05.1991	5.36	4.05	28.57	0.90	1.58	0.01	-0.402
15.06.1991	4.87	4.63	10.29	0.43	2.01	-0.04	-0.077

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E : Effizienz

Wenngleich die Differenzen in den Validierungszeiträumen nicht größer werden, so zeigen doch hier die noch geringeren Korrelationen und Effizienzwerte die größeren Fehler in der Vorhersage. Es ist überhaupt kein Zusammenhang zwischen den Meßwerten und denen der Berechnung zu erkennen. Dies zeigt auch Abbildung 39 und Seite 2, Anhang B. Es kann hier in keiner Weise von einer Vorhersage gesprochen werden.




Abb. 39: Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, *Variante 30*, Zeitfenster ein Tag, Niederschlag als Eingangsdatensatz und komplexe Netztopologie

2) Niederschlag und Vorregenindex als Eingangsdatensatz, Variante 31

Wenngleich hier in der Trainingsphase sehr geringe mittlere Abweichungen erreicht werden (Seite 3, Anhang B), so zeigt doch die hohe Standardabweichung von fast 50 % und die geringe Korrelation und Effizienz, daß auch hier das Ereignis nicht einmal erlernt, geschweige denn eine Vorhersage anderer Ereignisse gemacht werden konnte. Die geringen mittleren Abweichungen beruhen wieder auf der Tendenz der KNN auf eine globale Mittelung, die einzelnen Werte können dabei aber stark differieren. Dies zeigt sich so auch auf Seite 3, Anhang B, wo doch sehr starke Abweichungen zwischen Messung und Berechnung zu verzeichnen sind. Weder Charakteristik noch Höhe der Hochwasserereignisse werden richtig vorhergesagt.

3) Niederschlag und Lauflänge im Einzugsgebiet als Eingangssatz, Variante 32

Eine annähernd gleiche Charakteristik wie b) zeigt die Arbeit mit der Lauflänge der einzelnen Teilflächen im Untersuchungsgebiet (Seite 4, Anhang B). Auch hier gelingt dem KNN in der Trainingsphase lediglich eine globale Minimierung der Abweichung zwischen gemessenem und berechnetem Wert, eine Nachbildung der Abflußganglinie gelingt aber nicht. Dieses KNN ist dann natürlich auch nicht in der Lage, entsprechend richtige Vorhersagen für andere Zeiträume zu treffen.

4-9) Meteorologische Eingangsdaten und/oder NDVI-Monatsmittel als Eingangssatz, Variante 33-38

Alle Anwendungen mit meteorologischen Eingangsdaten sowie dieser in Kombination mit den NDVI-Daten in verschiedener Aufbereitung zeigen sehr ähnliche Ergebnisse. Tabelle 35 und Abbildung 40 zeigen am Beispiel der Differenz der NDVI-Monatsmittel den Fehler in den Berechnungen.

Tab. 35: Differenz und Korrelation zwischen berechneten und gemessenen täglichen Abflüssen, Variante 34, Niederschlag und Differenz aufeinanderfolgender NDVI-Monatsmittelwerte als Eingangsdaten und komplexe Netztopologie

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E [-]
Training							
10.12.1991	8.71	4.51	0.04	0.00	2.39	0.38	0.143
Validierung							
25.12.1990	5.37	2.85	-42.57	-2.11	1.70	-0.06	-1.787
08.05.1991	1.46	2.07	-34.38	-1.08	1.57	-0.07	-0.543
15.06.1991	7.70	4.14	-1.27	-0.05	1.91	0.45	0.068

HQ_{max_b} : Berechneter Scheitelabfluß; MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E : Effizienz




Abb. 40: Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, Variante 34, Zeitfenster ein Tag, Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz und komplexe Netztopologie

Die Seiten 5-10, Anhang B (Varianten 33-38) zeigen für alle untersuchten Kombinationen von Eingangsdaten vergleichbar schlechte Ergebnisse. In keinem der Fälle gelingt es dem KNN in irgendeiner Weise, das angelegte Trainingsmuster zu erlernen oder eines der Ereignisse aus den Verifikationszeiträumen vorherzusagen. Die Korrelationen zwischen berechneten und gemessenen Ganglinien liegen fast alle um 0. Die teilweise recht hohen negativen Effizienzwerte zeigen, daß keine der Vorhersagen ein ausreichendes Gütemaß erreicht hat. Alle Anwendungen mit diesen Daten müssen für die Hochwasservorhersage als sehr fehlerhaft und unbrauchbar beschrieben werden.

Arbeiten mit dem Trainingsmuster 8.5. - 25.5.1991 zeigen, daß sich auch hier sehr schlechte Ergebnisse einstellen. Die Güte der Ergebnisse ist unabhängig vom Zeitraum des Trainings wie der Validierung gleich schlecht. Ganz gleich, mit welchem Trainingsmuster das KNN trainiert worden ist, es gelingt in keinem der Fälle, ein Hochwasserereignis, sei es im Winter oder im Sommer, richtig zu erlernen oder gar vorherzusagen.

10) Boden als zusätzlicher Eingangsdatensatz, Varianten 39-46

Digitale Bodendaten liegen nur für das Einzugsgebiet der Oberpfälzer Vils vor. Die Ergebnisse der dort untersuchten Varianten dürften sich aber nicht von denen des Oberen Mains unterscheiden.

Alle bearbeiteten Kombinationen von Eingangsdaten (siehe 1 bis 9) in zusätzlicher Kombination mit den Bodenarten ergaben keinerlei sinnvolle Ergebnisse. Das Netz ist weder in der Lage, beim Training noch in der Validierung diese Daten in irgendeiner Weise richtig zu berücksichtigen. Alle Netzausgaben ergaben einen kontinuierlichen Wert von 1. Es ist nicht nachzuvollziehen, ob ein Fehler in der Datenrepräsentation oder in der Netzberechnung vorliegt. Da aber auch andere Zahlenbewertungen für die Abflußbereitschaft der unterschiedlichen Bodenarten mit dem gleichen Ergebnis getestet wurden liegt der Verdacht nahe, daß der Fehler im KNN auftreten muß. Dieses muß diese zusätzlichen Eingangsdaten in einer Weise werten, daß sich solche falsche Ergebnisse ergeben. Der Grund dafür konnte nicht festgestellt werden.

6.4.5 Bewertung der Ergebnisse der Hochwasservorhersage

Die KNN zeigen hier wie bei der Kontinuumsbetrachtung das gleiche, sehr bald sich einstellende, statische Verhalten. Die internen Verbindungen als Repräsentanten der Fließwege im Einzugsgebiet werden in der Trainingsphase auf Null gesetzt, sie verlieren dadurch jede Bedeutung für weitere Betrachtungen.

Gelang es den KNN beim Abflußkontinuum noch, das Lernmuster nachzubilden, so ist dies bei den stündlichen Daten nicht mehr möglich. Solche KNN, die selbst in der Lernphase große Fehler machen, können natürlich keine vernünftige Vorhersage treffen.

Warum sich dieses Unvermögen des KNN so einstellt, konnte nicht zweifelsfrei geklärt werden. Es läßt sich eigentlich nur dadurch erklären, daß:

- die höhere zeitliche Auflösung der meteorologischen Eingangsdaten und
- die repräsentativen NDVI-Monatsmittel

in keinem so deutlichen funktionalen Zusammenhang mit dem Abfluß stehen. Daß das KNN nicht einmal in der Lage ist, die Trainingsmuster zu erlernen weist darauf hin, daß zwischen Niederschlag und Abfluß in dieser zeitlichen Auflösung ein so geringer Zusammenhang besteht, daß er vom KNN nicht abgebildet werden kann.

6.5 Bewertung alternativer Netztopologien und Ansätze

Es wurden im Laufe des Projektes eine Vielzahl verschiedener Lernverfahren und Aktivierungsfunktionen getestet. Es hat sich gezeigt, daß ein einfaches Feed-Forward-Netz mit Backpropagation-Lernverfahren die besten Ergebnisse mit hinreichend kurzen Trainingszeiten liefert. Zusammenfassend läßt sich festhalten:

- Die Verwendung der logistischen Aktivierungsfunktion $f_{log}(x) = \frac{1}{1+e^{-x}}$ für den Wertebereich von 0 bis 1 liefert für die vorliegenden Arbeiten die besten Anpassungsergebnisse. Untersuchungen mit anderen Aktivierungsfunktionen ($\tanh(x)$, linear) ergaben bei keinem der getesteten Netze eine Verbesserung der Ergebnisse.
- Die Verwendung von Time-Delay-Netzen bringt im Vergleich zu einem Zeitfenster über den Eingangsdaten (1, 2 oder mehr Eingangsdaten vorheriger Messungen) bei Feed-Forward-Netzen keine Verbesserung der Ergebnisse. Die Anwendung wird hingegen umständlicher und das Training langwieriger. Der Unterschied der beiden Anwendungen liegt nur in der unterschiedlichen Gewichtung zurückliegender Daten. Bei Feed-Forward-Netzen überläßt man es dem Netz, diese zu gewichten, bei Time-Delay-Netzen ist dies über deren Verknüpfungen vorbestimmt.
- Der Test von Partiell-Rekurrenten Netzen, bei denen durch spezielle Kontextzellen die Zeitinformation im Netz berücksichtigt wird, lieferte ebenfalls keine besseren Ergebnisse wie mit den Standardnetzen. Die Eintrittszeitpunkte der Abflußspitzen werden zwar etwas besser, deren Höhe aber hingegen generell zu niedrig vorhergesagt. Somit weisen sie keine nennenswerten Vorteile gegenüber den Feed-Forward-Netzen auf.
- Der Einsatz von Radiale-Basisfunktionen-Netze (RBF-Netze) ergab auch nach längerer Untersuchung keine sinnvollen Ergebnisse. Da ein Programmfehler nicht ausgeschlossen werden kann, wird auf diese Anwendung nicht weiter eingegangen.
- Bei den bisher verwendeten größten Netzen in der komplexen Netztopologie (10057 Neuronen bei 7289 Verbindungen) stößt man selbst auf leistungsfähigen Workstations an die Handhabbarkeit dieser Netze. Die Trainingszeiten liegen für 1000 Zyklen bei ca. 330 Minuten, an einen sinnvollen Einsatz ist in der Praxis mit diesen Netzen auf seriellen Rechnern nicht mehr zu denken. Spätestens hier muß man Parallelcomputer einsetzen.

7 Einsatz von Künstlichen Neuronalen Netzen zur Abflußprognose

7.1 Allgemeines

Im Bereich der Hydrologie ist eine zuverlässige Abflußvorhersage und langfristige Prognose der Abflüsse eine der fundamentalen Aufgaben. Hierfür existieren für eine Vielzahl unterschiedlicher Anwendungen ganz unterschiedliche Modelltypen mit unterschiedlichen Modellansätzen.

In der wasserwirtschaftlichen Praxis werden N-A-Modelle zur Beschreibung der Abflußentstehung im Einzugsgebiet, Oberflächenwasserbewirtschaftungsmodelle für die Bewirtschaftung ganzer Einzugsgebiete sowie Zeitreihenmodelle für die Beschreibung des statistischen Zusammenhangs von zwei und mehr Variablen eingesetzt. KNN werden hierbei als Zeitreihen- und N-A-Modell eingesetzt.

Gegenüber einer Hochwasservorhersage, die auf einer kurzfristigen Vorhersage von Abflüssen auf der Basis aktuell gemessener Daten beruht, kann die Prognose von Abflüssen als stochastische Vorhersage bezeichnet werden. Hier stehen nicht möglichst exakte Kurzzeitsvorhersagen sondern langfristige Aussagen über ein generelles Abflußverhalten im Vordergrund. Basis einer Prognose sind nicht aktuell gemessene Daten, sie beruht meist auf geschätzten oder wiederum prognostizierten Eingangsdaten. Den Definitionen von [Blaschke et al., 1987] und [Plate, 1978] folgend ist eine begriffliche Abgrenzung von Vorhersage und Prognose wie folgt möglich (Tabelle 36).

Tab. 36: Vergleich von Vorhersage und Prognose

Vorhersage	Prognose
Angabe eines Wertes eines Merkmals <u>mit</u> Bezug zur aktuellen Situation	Angabe eines Wertes eines Merkmals <u>ohne</u> Bezug zur aktuellen Situation
Möglichst exakte Angabe des Wertes	Statistische Aussage über mögliche Werte
Angabe des Wertes zu einem exakt anzugebenden Zeitpunkt	Angabe zu beliebigen Zeitpunkten innerhalb einer Zeitspanne
Hohe Zuverlässigkeit der Vorhersage zu einem bestimmten Zeitpunkt	Beliebig kleine Zuverlässigkeit für einen exakten Zeitpunkt innerhalb des Zeitintervalls
Zufallsanteil $\varepsilon(t)$ der Systemfunktion im Vergleich zur Vorhersage $y(t)$ klein	$\varepsilon(t)$ kann beliebig groß oder klein sein, muß aber den gesamten Bereich der Merkmalsausprägung abdecken

Der Vorteil von KNN ist, daß kein umfangreiches Expertenwissen bekannt sein, keine komplexen Differentialgleichungen gelöst oder aufwendige Akquisition, Aufbereitung und Formalisierung des Problemwissens betrieben werden müssen. Diesem datenbasierten Ansatz für die Prozeßmodellierung steht der Nachteil gegenüber, daß KNN keine Erklärung der Lösung liefern können, da sie lediglich ein implizites Modell des untersuchten Problems ableiten, dieses aber kaum weiter analysiert werden kann. Diese Vor- und Nachteile sollen im Hinblick auf die Anwendbarkeit von KNN im Bereich der Prognose des Abflußkontinuums hier näher untersucht werden.

7.2 Vorgehensweise

Die Untersuchungen der Kontinuums- und Hochwasserberechnung haben gezeigt, daß alleine auf der Basis meteorologischer Eingangsdaten keine sinnvollen Ergebnisse zu erzielen sind. Das KNN war in keiner der untersuchten Varianten in der Lage, die Niederschlag-Abfluß-Beziehung zu erlernen und abzubilden. Es macht daher keinen Sinn, eine Abflußprognose mit diesen Daten durchzuführen. Aufgrund dessen ist diese prinzipielle Untersuchung ausschließlich auf der Basis von hydrologischen Eingangsdaten gemacht worden. Diese erlauben noch am ehesten, eine grundsätzliche Aussage über die Möglichkeiten einer Prognose von Abflüssen mittels KNN treffen zu können. Da das grundsätzliche Verhalten der KNN bei unterschiedlichen Eingangsdaten unabhängig von der Netztopologie ist, sind hier alle Arbeiten aufgrund der Einfachheit mittels des trivialen Ansatzes durchgeführt worden.

Prognostizierte Abflußganglinien sind schwer zu erstellen. Ein mögliches zukünftiges Abflußverhalten ist unter geänderten Rahmenbedingungen (andere Landnutzung, Klimaänderung, geänderte Niederschlagscharakteristik) nicht bekannt. Daher werden für diese Untersuchung unterschiedliche Ausschnitte aus langen gemessenen Abflußganglinien an den drei Pegeln (Bayreuth, Theisau, Schwüritz) im Einzugsgebiet des Oberen Mains auf unterschiedliche Dynamikbereiche (10 %, 20 %, 40 %, ... der gemessenen Reihen) normiert und dem KNN zum Training angelegt (Abbildung 41).




Abb. 41: Schematische Darstellung der unterschiedlichen Dynamik der Trainings- und Validierungsdaten

Die Länge dieser Ausschnitte variiert zwischen einem Jahr extremer Niedrig- und Hochwasserabflüsse und 18 Jahren mit der ganzen Dynamik bisher aufgetretener Abflüsse. Dies setzt die Annahme voraus, daß sich die Abflußcharakteristik für die prognostizierte Zukunft nicht ändert, allein die Abflußhöhe wird als variabel angenommen.

Hierdurch sind eine ganze Reihe von trainierten Netzen verfügbar, die gänzlich unterschiedlicher Abflußcharakteristik folgen. Die trainierten Netze werden wiederum mit unterschiedlich langen und unterschiedlich ausgeprägten Validierungszeiträumen getestet, um die berechnete Abflußganglinie im Vergleich zur gemessenen hinsichtlich Qualität und Quantität der Abflüsse hin zu interpretieren und zu bewerten. Die qualitative Bewertung und Beschreibung der beiden Abflußganglinien wird rein visuell durchgeführt. So sind theoretische Aussagen über Anwendbarkeit und Güte der Prognose für ganz unterschiedliche Teilaspekte des Abflußgeschehens möglich.

Für die Untersuchung werden eine ganze Reihe verschiedener Zeitausschnitte aus den gemessenen Abflußganglinien der Pegel verwendet. In Tabelle 37 sind die untersuchten Ausschnitte mit ihrer Abflußcharakteristik aufgeführt. Ausgewählt werden Zeiträume mit möglichst extremen Abflußverhaltens, die das ganze Spektrum möglicher Abflüsse in den vorliegenden Zeitreihen repräsentieren. Hervorgehoben sind zwei Zeitausschnitte am Pegel Bayreuth, deren Ergebnisse im folgenden näher dargestellt sind.

Tab. 37: Statistik der gemessenen Abflüsse für die verschiedenen, verwendeten Zeiträume der Pegel Bayreuth, Theisau und Schwürbitz

Pegel	Gemessener mittlerer Abfluß MQ_g $\left[\frac{m^3}{s}\right]$	Standard- abweichung SMQ_g $\left[\frac{m^3}{s}\right]$	Gemessener Scheitelabfluß HQ_{max} $\left[\frac{m^3}{s}\right]$
Verwendete Zeiträume für Training und Prognose			
Bayreuth, 1.11.1963-31.10.1973	3.15	4.44	105.94
Bayreuth, 1.11.1967-31.10.1972	3.04	4.73	105.94
Bayreuth, 1.11.1969-31.10.1970	4.30	7.34	105.94
Bayreuth, 1.11.1972-31.10.1973	1.98	1.37	10.20
Bayreuth, 1.11.1974-31.10.1992	3.24	4.30	55.50
Theisau, 1.12.1970-30.11.1975	10.38	11.35	164.00
Theisau, 1.11.1971-30.11.1972	6.95	3.25	26.70
Theisau, 1.11.1975-31.10.1988	15.37	19.59	211.00
Theisau, 1.11.1986-31.10.1988	23.38	31.35	211.00
Schwürbitz, 1.12.1970-30.11.1975	23.74	26.33	295.00
Schwürbitz, 1.11.1971-30.11.1972	16.22	11.97	86.00
Schwürbitz, 1.11.1975-31.10.1988	33.26	39.88	557.00
Schwürbitz, 1.11.1986-31.10.1988	45.24	56.31	503.00

7.3 Ergebnisse

Bei allen Anwendungen an allen Pegeln hat sich ein sehr ähnliches Verhalten eingestellt. Im folgenden sollen exemplarisch die Ergebnisse des Pegels Bayreuth (hervorgehoben in Tabelle 37) aufgezeigt werden, die Ergebnisse sind so auch an den anderen untersuchten Pegel im Einzugsgebiet aufgetreten.

Es zeigt sich, daß in Abhängigkeit des gewählten Trainingszeitraums mit der entsprechenden Abflußcharakteristik sich folgendes Prognoseverhalten der KNN einstellt:

- Die KNN, die mit Abflußganglinien trainiert worden sind, deren Abflußmaxima geringer sind als im Prognosezeitraum aufgetreten, überschätzen generell die Abflüsse (Abbildung 42). Die Netze stellen sich auf ein niedriges Niveau der Abflüsse ein und sind nach dem Training nicht mehr in der Lage, dieses statische Verhalten ohne neuerliches Antrainieren zu korrigieren. Bei einer Prognose für die Zukunft ist ein Nachtrainieren aber zumindest für das überwachte Lernen mit Hilfe von bekannten Trainingsmustern nicht möglich, da sie zu dem Zeitpunkt nicht bekannt sind.




Abb. 42: Prognose möglicher hoher Abflüsse mit einem zu gering trainiertem KNN; Trainingsphase 1.11.1972 - 31.10.1973, Validierungsphase 1.11.1969 - 31.10.1970

- Umgekehrt verhält es sich mit KNN, die mit Abflußganglinien trainiert worden sind, deren Abflußmaxima höher sind als im Prognosezeitraum aufgetreten. Diese unterschätzen fast ausnahmslos den Abfluß (Abbildung 43).




Abb. 43: Prognose möglicher niedriger Abflüsse mit einem zu hoch trainiertem KNN; Trainingsphase 1.11.1969 - 31.10.1970, Validierungsphase 1.11.1972 - 31.10.1973

- In beiden Fällen werden die Abflußspitzen in der Regel unterschätzt. Selbst bei einer prinzipiellen Überschätzung der Abflüsse durch das KNN ist es auch hier nicht in der Lage, die Spitzenwerte des Abflusses richtig in ihrer Höhe zu prognostizieren.

- Die Abweichung der prognostizierten von der gemessenen Abflußhöhe ist abhängig vom Verhältnis der Abflußspitzenhöhe im Trainingsmuster und im Prognosezeitraum. Je größer diese Differenz und je höher die zu prognostizierende Abflußspitze, desto größer ist auch der Fehler in der Prognose. Die prognostizierten Abflüsse erscheinen gestaucht oder gestreckt gegenüber den Vergleichswerten. Das Stauchungs- oder Streckungsverhältnis ist abhängig von dem Verhältnis der maximalen Abflußspitzen der Muster zueinander.
- Die Form und Charakteristik der Abflußganglinie wird in ihrer Qualität andeutungsweise prognostiziert, jedoch variiert die Quantität der Abflüsse unter o. a. Bedingungen (Abbildung 44). Dies ist dadurch zu erklären, daß hohe Eingabewerte eine hohe Ausgabe, niedrige Eingabewerte eine niedrige Ausgabe bewirken. KNN beschränken sich in dieser Anwendung mit hydrologischen Eingangsdaten auf ein lineares Regressionsmodell, daß diese einfache Beziehung impliziert.




Abb. 44: Ausschnitt einer Abflußberechnung des Pegels Bayreuth, 1.2.1970 - 31.8.1970

- Eine Verringerung des Dynamikumfangs der Eingangsdaten mittels Herabsetzen der Intervallgrenzen auf 80 % oder 60 % der Originalwerte führt nicht dazu, daß die KNN höhere als in den Trainingsdaten aufgetretene Abflüsse richtig prognostizieren können (Abbildung 45). Es führt lediglich dazu, daß die berechneten Abflüsse sich in einem engeren Band (dem der Intervallgrenzen) bewegen, die prinzipielle Über- oder Unterschätzung der Abflüsse in Abhängigkeit der verwendeten Eingangs- und Ausgangsdaten bleibt weiterhin bestehen.




Abb. 45: Um 20 % verringerte Intervallgrenzen für das Training des KNN, Pegel Bayreuth, 1.11.1969 - 31.10.1970

- Die Länge der gewählten Trainingszeiträume ist für die Güte einer Prognose nicht ausschlaggebend, bereits kurze Zeiträume der Trainingsmuster ergeben nahezu gleiche Ergebnisse wie mehrjährige Reihen, wenn sie die relevanten Trainingsmuster beinhalten.

7.4 Bewertung der Abflußprognose mit KNN

In der vorliegenden Arbeit wird die Möglichkeit flächenhafter Abflußmodellierung mittels KNN unter Verwendung flächenhafter Eingangsdaten untersucht. Hierfür kommen eine Reihe von Eingangsdaten einzeln und in verschiedenen Kombinationen miteinander zum Einsatz (Tabelle 38).

Tab. 38: Untersuchte Varianten

Meteorologische Eingangsdaten	
Niederschlag	Variante 2-4, 6-7, 9-13, 15-46
Temperatur	Variante 3, 4, 11-13, 22,23,29,38,46
Sonnenscheindauer	Variante 3, 4, 11-13
Schneehöhe	Variante 3, 4, 11-13
Hydrologische Eingangsdaten	
Abfluß der flußaufwärts gelegenen Oberliegerpegel in einer zeitlichen Auflösung von Stunden und Tagen	Variante 1, 4, 5, 7, 8, 12-14, 16, 17
Topographische Eingangsdaten	
Digitales Höhenmodell	Variante 18-46
Landnutzung	Variante 24-29, 34-38, 42-46
Bodenarten	Variante 39-46
Abgeleitete Eingangsdaten	
Laufängenindex (Maß für die Entfernung zum Untersuchungspegel)	Variante 20, 21, 23, 25
Vorregenindex (Maß für die Vorfeuchte im Einzugsgebiet)	Variante 19, 21, 23 25

Neben dem Multi-Layer-Perceptron mit Standard Backpropagation Lernverfahren und logistischer Aktivierungsfunktion werden eine Reihe anderer Netze, Aktivierungsfunktionen und Lernverfahren getestet. Da sich aber mit keinem alternativen Ansatz eine Verbesserung der Ergebnisse erzielen läßt wird auf eine detaillierte Darstellung verzichtet.

Die KNN werden durch überwachtes Lernen trainiert. Hierbei werden dem Netz in der Trainingsphase die zu berechnenden Ausgangsdaten mit angelegt. Durch Gewichtsänderungen wird die Differenz zwischen tatsächlichem und gewünschtem Output iterativ minimiert, das KNN erlernt den Systemoperator der abzubildenden Funktion.

Generell hat sich gezeigt, daß es mit KNN nicht möglich ist, ohne Verwendung von Abflußdaten der Oberliegerpegel sinnvolle Ergebnisse zu erzielen. Allein auf der Basis der in Tabelle 38 aufgeführten Eingangsdaten ist es in keinem Fall gelungen, die Abflüsse korrekt zu berechnen oder vorherzusagen.

Unter dieser Einschränkung liefert die **einfache Netztopologie** die besten Ergebnisse. Neben den punktuellen stationsbezogenen Meßreihen kommt hier als weitere Informationsebene die Lagebeziehung der Meßstellen im Untersuchungsgebiet untereinander und deren Entfernung zum Untersuchungspegel zum tragen (Abbildung 19). Durch die Integration dieser Informationen in das Netzdesign können ohne großen Mehraufwand zum Teil sehr gute Vorhersagen getroffen werden.

Bei der flächenhaften Abflußmodellierung mittels KNN kommen räumlich verteilte Eingangsdaten zum Einsatz (**komplexe Netztopologie**). Hier ist der Einsatz punktueller Abflußdaten der Oberliegerpegel nicht möglich. Das KNN ist dergestalt, daß es das Untersuchungsgebiet rasterpunktbezogen abbildet und die Fließwege im Einzugsgebiet über die Verknüpfungen der Neuronen untereinander detailliert nachzeichnet (Abbildung 21).

Dem KNN gelingt es mit der komplexen Netztopologie mit keiner Kombination an Eingangsdaten, den Abfluß korrekt zu berechnen. Wenngleich die Trainingsergebnisse sehr gut sind, zeigt sich in der stark fehlerhaften Abflußvorhersage, daß das Netz jegliche Generalisierungsleistung verloren hat. Die große Anzahl an freien adaptierbaren Verbindungen im Hidden Layer führt dazu, daß das Netz übertrainiert ist. Da sich diese Überanpassung spontan von nicht trainiert zu sofort übertrainiert einstellt, läßt sich dies auch nicht durch verkürzte Lernphasen verhindern. Der intensive Dateneinsatz verhindert hier die Abflußberechnung mittels KNN.

In Anlehnung an die bisher häufigste Verwendung von KNN im Bereich der Hydrologie werden auch Berechnungen ohne Berücksichtigung von Raum- oder anderweitiger Informationen (**triviale Methode**) durchgeführt. Alle meteorologischen wie hydrologischen Eingangsdaten fließen gleich gewichtet ins Netz, weitere Informationen werden nicht berücksichtigt. Dem Netz wird gänzlich selbst überlassen, eine Beziehung zwischen diesen Eingangs- und den gewünschten Ausgangsdaten zu finden und die Relevanz einzelner Stationen zu gewichten (Abbildung 18).

Wie bei der einfachen Netztopologie auch zeigt sich hier, daß eine Abflußmodellierung allein auf der Basis meteorologischer Daten nicht möglich ist. Erst unter ausschließlicher oder zusätzlicher Verwendung von Abflußdaten der Oberliegerpegel ist dies hinreichend genau möglich. Dem KNN gelingt es nicht, die komplexe, hoch nichtlineare Beziehung zwischen Niederschlag und Abfluß mit all seinen Modifikationen durch andere meteorologische Einflußgrößen abzubilden.

All dies zeigt sich in Tabelle 39, in der anhand des Merkmals prozentuale Abweichung $\Delta MQ[\%]$ der berechneten von den gemessenen Abflüssen diese Ergebnisse auszugsweise dargestellt sind.

Tab. 39: Vergleichende Gegenüberstellung der mittleren prozentualen Abweichung $\Delta MQ[\%]$ der berechneten von den gemessenen Abflüssen der unterschiedlichen Ansätze

Abfluß von Oberliegerpegeln als Eingangsdaten					
Kontinuum			Hochwasser		
trivial	einfach	komplex	trivial	einfach	komplex
17.31	14.41	—	-72.22	51.43	—
1.09	5.63	—	-92.96	12.32	—
-9.71	-11.25	—	-95.75	-11.41	—
Niederschlag als Eingangsdaten					
Kontinuum			Hochwasser		
trivial	einfach	komplex	trivial	einfach	komplex
-68.19	-72.83	-3.78	24.24	-0.18	28.57
-66.18	-76.47	105.29	4.36	-12.28	10.29
-67.48	-73.40	367.95	—	—	—
Niederschlag und Abfluß von Oberliegerpegeln als Eingangsdaten					
Kontinuum			Hochwasser		
trivial	einfach	komplex	trivial	einfach	komplex
21.47	0.41	—	-18.88	-10.00	—
-25.77	-0.35	—	-16.21	-9.68	—
-13.30	-5.00	—	—	—	—

Eine flächenhafte Abflußmodellierung auf der Basis raumbezogener Eingangsdaten, wie dies mit den klassischen N-A-Modellen in der Hydrologie seit langem durchgeführt wird, ist mit KNN nicht möglich. Hauptgrund für das Scheitern ist die Größe der Netze und der damit verbundenen Anzahl an freien, vom Netz adaptierbaren Gewichte. Die große Zahl an Gewichten verhindert selbst in kleinen Einzugsgebieten und grober räumlicher Auflösung jegliche Generalisierung der erlernten Prozeßfunktion. Damit verliert aber das KNN sein Potential, komplexe nichtlineare Systemoperatoren in einfacher Weise abzubilden. Dieses Hauptmerkmal und der große Vorteil der KNN gegenüber komplizierten, aufwendigen physikalischen Beschreibungen des Abflußprozesses kommt so nicht mehr zum Tragen.

Daneben gilt, daß KNN vollständig bestimmt sind durch die Charakteristik der angelegten Trainingsmuster. Sie können nur den Dynamikumfang prognostizieren, der ihnen auch in der Lernphase bekannt gemacht worden ist. Ihre Generalisierungsleistung beschränkt sich auf die abzubildende Funktion selbst, nicht aber auf mögliche Extremwerte oder unbekannte Größen einer unbekannten Zukunft, die nicht im Lernmuster enthalten sind. Sie sind „Papeienmodelle“, die aufgrund ihrer Abhängigkeit von den Eingangsdaten Vorhersagen nur für unveränderte Randbedingungen erlauben. Verändern sich die Rahmenbedingungen, die in den Eingangsdaten der Trainingsphase impliziert sind, gelten die erlernten Strukturen im KNN nicht mehr.

Läßt man den Versuch einer flächenhaften Abflußmodellierung außer Acht, so lassen sich trotz allem im Bereich der kurzfristigen Vorhersage mit der einfachen Netztopologie gegenüber der bisher häufig verwendeten trivialen Methode zum Teil deutliche Ergebnisverbesserung erzielen. Allein die Berücksichtigung der Lage- und Raumbeziehungen der Meßstellen im Einzugsgebiet führt ohne großen Mehraufwand an Datenbereitstellung oder Rechendauer zu diesem Erfolg.

Dieses Einbringen von a priori Wissen vom Anwender birgt so viele Vorteile, daß es dem trivialen Ansatz immer vorzuziehen ist. Die notwendigen Informationen hierfür können leicht aus Kartenmaterial bestimmt werden. Der geringe Mehraufwand steht in keinem Verhältnis zu den deutlichen Verbesserungen der Berechnungsergebnisse, die man damit erzielen kann. Die einfache Netztopologie ist somit gerade auch für einen praktischen Einsatz geeignet, bei dem es nicht auf die Analyse der zugrundeliegenden Prozesse ankommt sondern schnelle, robuste und hinreichend genaue Verfahren ohne aufwendige Datenerhebung gefragt sind.

Literatur

Blaschke, H. et al. [1987]: Operationelle Wasserstands- und Abflußvorhersagen. Besondere Mitteilungen zum Deutschen Gewässerkundlichen Jahrbuch, Nr. 51, Koblenz

Büttner, U. [1997]: Operationelle Hochwasservorhersagen im Konflikt mit der Datenverfügbarkeit in der Praxis - Kann mit neuronalen Netzen im Sinne einer künstlichen Intelligenz eine Konfliktlösung herbeigeführt werden?. Tagungsband zur Modellierung in der Hydrologie, Symp. zum 30-jährigen Bestehen der Dresdener Schule der Hydrologie, 22.-24.9.1997, S. 39-49

Cheng, B.; Titterton, D.M. [1994]: Neural Networks: A Review from a Statistical Perspective. Statistical Science, Vol. 9, No. 1, S. 2-54

Clair, T.A.; Ehrmann, J.M. [1998]: Using neural networks to assess the influence of changing seasonal climates in modifying discharge, dissolved organic carbon, and nitrogen export in eastern Canadian rivers. Water Resources Research, Vol. 34, No. 3., S. 447-455

Crespo, J.L.; Mora, E. [1994]: Drought estimation with neural networks. Advances in Engineering Software, Vol. 18, S. 167-170

Dartus, D.; Courivaud, J.M.; Dedeker, L. [1993]: Use of neural net for the study of a flood wave propagation in an open channel. Jour. of Hydraulic Research, Vol. 31, No. 2, pp. 161-169

Dyck, S.; Peschke, G. [1995]: Grundlagen der Hydrologie. Verlag für Bauwesen, Berlin

Hsu, K.; Ghupta, H.V.; Sorooshian, S. [1995]: Artificial neural network modeling of the rainfall-runoff process. Water Resources Research, Vol. 31, No. 10, S. 2517-2530

Ichiyonagi, K.; Goto, Y.; Mizuno, K.; Yokomizu, Y.; Matsumura, T. [1995]: An Artificial Neural Network to Predict River Flow Rate into a Dam for a Hydro- Power Plant. IEEE International Conference on Neural Networks Proceedings, S. 2679-2682, Perth

Kanal, L. [1993]: On patterns, categories and alternate realities. Pattern Recognition Letters, Vol. 14, S. 241-255

Karunanithi, N.; Grenney, W.J.; Whitley, D.; Bovee, K. [1994]: Neural Networks for River Flow Prediction. Journal of Computing in Civil Engineering, Vol. 8, No. 2, S. 201-219

Madhok, V. [1994]: A Survey of Artificial Neural Network Applications in Flow Analysis of Energy Networks. Bericht des Los Alamos National Laboratory, New Mexico

Maniak, U. [1992]: Hydrologie und Wasserwirtschaft. Springer Verlag, Berlin

McCulloch, W.S.; Pitts, W.H. [1943]: A logical calculus of the ideas immanent in neural nets. Bulletin Math. Biophys., Vol. 5, S. 115-133

- Minns, A.W.; Hall, M.J. [1996]: Artificial neural networks as rainfall-runoff models. *Hydrological Sciences*, Vol. 41, S. 399-417
- Müller, B.; Reinhardt, J. [1990]: *Neural Networks*. Springer Verlag, Berlin
- Peschke, G.; Kaufmann, K.; Sambale, C.; Töpfer, J.; Zimmermann, S. [1997]: Liefern Verfahren der künstlichen Intelligenz nützliche Ergänzungen zur traditionellen hydrologischen Modellierung? Tagungsband zum Symposium "Modellierung in der Hydrologie" der Dresdner Schule für Hydrologie, S. 28-38
- Plate, E. [1978]: Modelle für Speicherzuflüsse - Einführungsreferat. Senatskommission für Wasserforschung der Deutschen Forschungsgemeinschaft - Rundgespräch "Bemessung und Bewirtschaftung von Speichern", Murnau 1978
- Rogers, L.L.; Dowla, F.U. [1994]: Optimization of Groundwater Remediation using artificial neural Networks with parallel solute Transport Modeling. *Water Resources Research*, Vol. 30, Februar 1994, Nr. 2
- Rumelhart, D.E.; McClelland, J.L. [1986]: *Parallel Distributed Processing*. MIT Bradford Press, Vol. 1
- Sarle, W.S. [1994]: *Neural Networks and Statistical Models*. Proceedings of the 19. Annual SAS Users Group International Conference, Cary, NC, USA
- Schmitz, G.H.; Schütze, N. [1997]: Pro und Contra zur Verwendung künstlicher neuronaler Netze in der Hydrologie. tagungsband zum Symposium Modellierung in der Hydrologie, Dresden, S. 50-65
- Schöneburg, E.; Hansen, N.; Gawelczyk A. [1990]: *Neuronale Netzwerke*. Markt & Technik-Verlag, München
- Smith, J.; Eli, R.N. [1995]: Neural-Network Models of Rainfall-Runoff Process. *Jour. of Water Resources Planning and Management*, Vol. 121, No. 6, S. 499-508
- Tarboton, D.G. [1997]: A new method for the determination of flow directions and upslope areas in grid digital elevation models. *Water Resources Research*, Vol. 33, No. 2, S. 309-319
- Veldkamp, A.H.G.; Torfs, P.M.M.; Warmerdam & Jellema [1994]: Flood Forecasting by Neural Networks. Paper No. 2.20, XVII. Conference of the Danube Countries on Hydrological Forecasting and Hydrological Bases of Water Management, S. 291-297
- Zell, A. [1994]: *Simulation Neuronaler Netze*. Addison-Wesley, Bonn

Allgemeine Literatur ohne Bezug im Text

Becher, Th. [1997]: Anwendung von Neuronalen Netzen zur Prognose und Simulation im Umweltschutz. 42. Internationales Wissenschaftliches Kolloquium der Fakultät für Informatik und Automation, TU Ilmenau, S. 427-432

Berns, K. [1992]: Neuronale Netze für technische Anwendungen. Nature, Vol. 355, S. 161-163

Ludwig, K. [1978]: Systematische Berechnung von Hochwasser-Abflußvorgängen mit Flußgebietsmodellen. Mitteilungen des Inst. für Wasserwirtschaft, Hydrologie und landwirtschaftlichen Wasserbau der Uni Hannover

Wendisch, W. [1997]: Anwendung Neuronaler Netze für die Prognose. 42. Internationales Wissenschaftliches Kolloquium der Fakultät für Informatik und Automation, TU Ilmenau, S. 418-422

Anhang A

Flächenhafte Berechnung des Abflußkontinuums auf Tagesbasis im Einzugsgebiet des **Oberen Mains**

Anhang A:

Tabellen und Abbildungen zur flächenhaften Berechnung des Abflußkontinuums auf Tagesbasis im Einzugsgebiet des **Oberen Mains**.

Die Tabelle gibt die Differenz und Korrelation zwischen berechneten und gemessenen Abflüssen für die Pegel Bayreuth, Theisau und Schwürbitz wieder. Zeitfenster der Berechnungen ist ein Tag. Die Abbildung zeigt die berechnete Abflußganglinie am Pegel Bayreuth für den Zeitraum 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986.

Verzeichnis

Seite 2: Niederschlag als Eingangsdatensatz,
Variante 18

Seite 3: Niederschlag und Vorregenindex über 30 Tage als Eingangsdatensatz,
Variante 19

Seite 4: Niederschlag und Lauflängenindex im Einzugsgebiet Eingangsdatensatz,
Variante 20

Seite 5: Niederschlag und Temperatur als Eingangsdatensatz,
Variante 22

Seite 6: Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz,
Variante 24

Seite 7: Niederschlag und reale NDVI-Monatsmittel als Eingangsdatensatz,
Variante 26

Seite 8: Niederschlag und invertierte reale NDVI-Monatsmittel als Eingangsdatensatz,
Variante 27


Seite 9: Niederschlag und binarisierte NDVI-Monatsmittel als Eingangsdatensatz,
Variante 28

Seite 10: Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdatensatz,
Variante 29

1) Niederschlag als Eingangsdatensatz, Variante 18

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	3.17	7.67	0.23	2.69	0.75	0.102
T, 1.10.74	29.66	1.32	0.39	19.06	0.68	0.264
SW, 10.12.86	80.67	0.96	0.76	91.09	0.48	-0.370
Validierung						
B, 1.11.88	2.43	-3.78	-0.10	2.96	0.35	0.001
T, 31.10.80	33.13	105.29	16.99	19.06	0.25	-1.413
SW, 6.11.80	167.93	367.95	132.04	148.43	0.09	-3.875

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag als Eingangsdatensatz

2) Niederschlag und Vorregenindex über 30 Tage als Eingangsdatensatz, Variante 19

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.95	-0.04	-0.01	2.66	0.75	0,179
T, 1.10.74	29.12	-0.52	-0.15	19.02	0.68	0.284
SW, 10.12.86	75.11	-0.45	-0.34	40.92	0.92	0.714
Validierung						
B, 1.11.88	2.20	-12.69	-0.32	2.91	0.37	0.104
T, 31.10.80	30.70	90.18	14.56	27.11	0.20	-1.200
SW, 6.11.80	48.28	34.00	12.25	63.99	0.01	-0.775

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag und Vorregenindex über 30 Tage als Eingangsdatensatz

3) Niederschlag und Lauflängenindex im Einzugsgebiet Eingangsdatensatz, Variante 20

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} $\left[\frac{m^3}{s}\right]$	SMQ_{diff} $\left[\frac{m^3}{s}\right]$	r_{MQ_b, MQ_g} [—]	E_{log} [—]
Training						
B, 1.11.85	2.94	-0.08	-0.00	2.67	0.75	0.181
T, 1.10.74	29.11	-0.56	-0.17	19.06	0.68	0.283
SW, 10.12.86	74.01	-1.91	-1.44	42.83	0.91	0.701
Validierung						
B, 1.11.88	2.23	-11.54	-0.29	2.94	0.36	0.105
T, 31.10.80	32.46	101.04	16.31	26.62	0.20	-1.361
SW, 6.11.80	38.26	6.20	2.24	62.01	0.04	-0.433

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag und Lauflängenindex im Einzugsgebiet als Eingangsdatensatz

4) Niederschlag und Temperatur als Eingangsdatensatz, Variante 22

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.84	-3.59	-0.11	2.02	0.87	0.313
T, 1.10.74	29.43	0.55	0.16	16.68	0.76	0.389
SW, 10.12.86	60.40	-24.41	-19.51	30.74	0.96	-34.974
Validierung						
B, 1.11.88	5.60	122.09	3.08	10.49	-0.11	-2.184
T, 31.10.80	33.13	105.29	16.99	25.75	0.25	-1.413
SW, 6.11.80	402.17	1020.72	366.29	247.20	-0.39	-15.958

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag und Temperatur als Eingangsdatensatz

5) Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz, Variante 24

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.92	-0.96	-0.03	1.48	0.93	0.682
T, 1.10.74	28.50	-2.63	-0.77	16.12	0.78	-0.474
SW, 10.12.86	70.48	-6.58	-4.97	33.74	0.94	-4.606
Validierung						
B, 1.11.88	2.17	-14.12	-0.36	2.77	0.43	0.234
T, 31.10.80	25.97	60.86	9.83	35.93	-0.14	-8.822
SW, 6.11.80	127.10	252.79	91.07	201.57	-0.022	-16.33

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz

6) Niederschlag und reale NDVI-Monatsmittel als Eingangsdatensatz, Variante 26

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.84	-3.63	-0.11	2.92	0.69	-7.310
T, 1.10.74	28.88	-1.33	-0.39	15.86	0.79	-0.390
SW, 10.12.86	73.31	-2.84	-2.14	37.84	0.93	-2.924
Validierung						
B, 1.11.88	2.82	11.66	0.29	3.71	0.12	-12.162
T, 31.10.80	51.14	216.74	34.99	46.89	-0.25	-4.371
SW, 6.11.80	27.22	-24.16	-8.67	76.11	0.07	-5.137

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag und reale NDVI-Monatsmittel als Eingangsdatensatz

7) Niederschlag und invertierte reale NDVI-Monatsmittel als Eingangsdatensatz, Variante 27

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.87	-2.73	-0.08	3.03	0.66	-0.006
T, 1.10.74	28.85	-1.43	-0.42	15.49	0.80	-0.074
SW, 10.12.86	70.93	-6.00	-4.52	37.35	0.93	-2.002
Validierung						
B, 1.11.88	2.83	12.17	0.31	3.64	0.09	-0.676
T, 31.10.80	51.40	218.37	35.26	50.75	-0.26	-5.700
SW, 6.11.80	53.15	47.53	17.12	109.71	0.09	-4.48

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag und invertierte reale NDVI-Monatsmittel als Eingangsdatensatz

8) Niederschlag und binarisierte NDVI-Monatsmittel als Eingangsdatensatz, Variante 28

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.92	-1.04	-0.03	1.54	0.93	-0.152
T, 1.10.74	29.67	1.38	0.40	19.04	0.68	0.264
SW, 10.12.86	74.31	-7.01	-5.60	69.56	0.74	-0.504
Validierung						
B, 1.11.88	10.14	302.08	7.62	5.85	-0.13	-11.730
T, 31.10.80	33.19	105.68	17.05	25.79	0.25	-1.424
SW, 6.11.80	39.26	8.98	3.23	95.02	0.14	-1.215

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag und binarisierte NDVI-Monatsmittel als Eingangsdatensatz

9) Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdatensatz, Variante 29

Pegel	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E_{log} [-]
Training						
B, 1.11.85	2.95	0.13	0.00	1.16	0.96	0.774
T, 1.10.74	28.92	-1.19	-0.35	11.43	0.90	0.626
SW, 10.12.86	64.30	-19.53	-15.61	30.67	0.96	-37.966
Validierung						
B, 1.11.88	3.45	36.81	0.93	4.27	-0.04	-1.422
T, 31.10.80	25.15	55.88	9.02	39.62	-0.03	-5.913
SW, 6.11.80	374.25	942.91	338.36	232.95	-0.40	-14.400

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz



Berechnete und gemessene Abflußganglinie des Pegels Bayreuth, 1.11.1988 - 1.11.1991 mit dem Trainingsmuster 1.11.1985 - 1.11.1986, Zeitfenster ein Tag, Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdatensatz

Anhang B

Flächenhafte Berechnung von Hochwasserereignissen auf Stundenbasis im Einzugsgebiet der **Oberpfälzer Vils**.

Anhang B:

Tabellen und Abbildungen zur flächenhaften Berechnung von Hochwasserereignissen auf Stundenbasis im Einzugsgebiet der **Oberpfälzer Vils**.

Die Tabellen geben die Differenz und Korrelation zwischen berechneten und gemessenen Abflüssen für die Pegel Vilseck, Amberg und Schmidmühlen wieder. Zeitfenster der Berechnungen ist ein Tag. Die Abbildungen zeigen die berechnete Abflußganglinie am Pegel Amberg für den Zeitraum 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 25.12.1991 - 12.1.1992.

Verzeichnis

Seite 2: Niederschlag als Eingangsdatensatz,
Variante 30

Seite 3: Niederschlag und Vorregenindex über 30 Tage als Eingangsdatensatz,
Variante 31

Seite 4: Niederschlag und Lauflängenindex im Einzugsgebiet Eingangsdatensatz,
Variante 32

Seite 5: Niederschlag und Temperatur als Eingangsdatensatz,
Variante 33

Seite 6: Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz,
Variante 34

Seite 7: Niederschlag und reale NDVI-Monatsmittel als Eingangsdatensatz,
Variante 35

Seite 8: Niederschlag und invertierte reale NDVI-Monatsmittel als Eingangsdatensatz,
Variante 36


Seite 9: Niederschlag und binarisierte NDVI-Monatsmittel als Eingangsdatensatz,
Variante 37

Seite 10: Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdatensatz,
Variante 38

1. Niederschlag als Eingangsdatensatz, Variante 30

Ereignis	HQ_{max_b} $\left[\frac{m^3}{s}\right]$	MQ_b [%]	ΔMQ [%]	MQ_{diff} $\left[\frac{m^3}{s}\right]$	$S_{MQ_{diff}}$ $\left[\frac{m^3}{s}\right]$	r_{MQ_b, MQ_g} [-]	E [-]
Training							
10.12.1991	8.71	5.81	28.69	1.30	2.54	0.16	-0.226
Validierung							
25.12.1990	4.90	3.88	-21.79	-1.01	1.64	-0.02	-0.467
8.5.1991	5.36	4.05	28.57	0.90	1.58	0.01	-0.402
15.6.1991	4.87	4.63	10.29	0.43	2.01	-0.04	-0.077

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 25.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag als Eingangsdatensatz

2. Niederschlag und Vorregenindex über 30 Tage als Eingangsdatensatz, Variante 31

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E [-]
Training							
10.12.1991	8.36	4.52	0.05	0.00	2.44	0.33	0.108
Validierung							
25.12.1990	4.71	0.27	-94.61	-4.69	1.97	0.04	-8.824
8.5.1991	5.41	3.89	23.39	0.74	1.59	-0.02	-0.306
15.6.1991	5.21	3.34	-20.45	-0.86	1.97	0.15	-0.179

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 25.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag und Vorregenindex über 30 Tage als Eingangsdatensatz

3. Niederschlag und Lauflängenindex im Einzugsgebiet Eingangsdatensatz, Variante 32

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]	E [—]
Training							
10.12.1991	8.57	4.51	0.04	0.00	2.43	0.33	0.109
Validierung							
25.12.1990	4.99	2.97	-40.03	-1.99	1.62	0.14	-1.495
8.5.1991	4.39	3.03	-3.84	-0.12	1.64	-0.01	-0.147
15.6.1991	5.32	3.55	-15.47	-0.65	1.97	0.16	-0.094

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag und Lauflängenindex im Einzugsgebiet als Eingangsdatensatz

4. Niederschlag und Temperatur als Eingangsdatensatz, Variante 33

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E [-]
Training							
10.12.1991	9.41	5.79	28.28	1.28	2.54	0.18	-0.215
Validierung							
25.12.1990	5.18	3.87	-22.04	-1.09	1.64	-0.01	-0.474
8.5.1991	5.26	4.04	28.17	0.89	1.58	0.01	-0.396
15.6.1991	4.87	4.61	9.95	0.42	2.01	-0.03	-0.071

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag und Temperatur als Eingangsdatensatz

5. Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz, Variante 34

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [-]	E [-]
Training							
10.12.1991	8.71	4.51	0.04	0.00	2.39	0.38	0.143
Validierung							
25.12.1990	5.37	2.85	-42.57	-2.11	1.70	-0.06	-1.787
8.5.1991	1.46	2.07	-34.38	-1.08	1.57	-0.07	-0.543
15.6.1991	7.70	4.14	-1.27	-0.05	1.91	0.45	0.068

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag und Differenz aufeinander folgender NDVI-Monatsmittel als Eingangsdatensatz

6. Niederschlag und reale NDVI-Monatsmittel als Eingangsdatensatz, Variante 35

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]	E [—]
Training							
10.12.1991	8.29	4.52	0.07	0.00	2.39	0.38	0.141
Validierung							
25.12.1990	5.32	2.84	-42.73	-2.12	1.69	-0.07	-1.784
8.5.1991	4.63	4.34	38.15	1.20	1.59	-0.10	-0.690
15.6.1991	5.66	4.47	6.43	0.27	1.89	0.30	0.071

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag und reale NDVI-Monatsmittel als Eingangsdatensatz

7. Niederschlag und invertierte reale NDVI-Monatsmittel als Eingangsdatensatz, Variante 36

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]	E [—]
Training							
10.12.1991	9.27	5.56	23.14	10.4	2.65	0.17	-0.218
Validierung							
25.12.1990	5.18	3.12	-37.17	-1.84	1.86	-0.19	-1.599
8.5.1991	4.48	3.30	4.68	0.15	1.56	-0.01	-0.041
15.6.1991	5.09	4.61	9.87	0.41	1.95	0.20	-0.010

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag und invertierte reale NDVI-Monatsmittel als Eingangsdatensatz

8. Niederschlag und binarisierte NDVI-Monatsmittel als Eingangsdatensatz, Variante 37

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	$S_{MQ_{diff}}$ [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]	E [—]
Training							
10.12.1991	8.29	4.52	0.07	0.00	2.39	0.38	0.141
Validierung							
25.12.1990	5.32	3.36	-32.21	-1.60	1.69	-0.02	-1.054
8.5.1991	4.78	3.29	4.45	0.14	1.55	0.08	-0.023
15.6.1991	3.96	3.81	-9.17	-0.39	2.05	-0.11	-0.116

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; $S_{MQ_{diff}}$: Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz




Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag und binarisierte NDVI-Monatsmittel als Eingangsdatensatz

9. Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdatensatz, Variante 38

Ereignis	HQ_{max_b} [$\frac{m^3}{s}$]	MQ_b [%]	ΔMQ [%]	MQ_{diff} [$\frac{m^3}{s}$]	SMQ_{diff} [$\frac{m^3}{s}$]	r_{MQ_b, MQ_g} [—]	E [—]
Training							
10.12.1991	9.13	4.52	0.09	0.00	2.37	0.40	0.157
Validierung							
25.12.1990	5.47	2.84	-42.81	-2.12	1.68	-0.02	-1.780
8.5.1991	2.14	2.25	-28.07	-0.91	1.61	-0.05	-0.441
15.6.1991	4.08	2.54	-39.42	-1.65	2.03	-0.02	-0.748

MQ_b : Berechneter mittlerer Abfluß; ΔMQ : Prozentuale Abweichung; MQ_{diff} : Mittlere tägliche Abweichung; SMQ_{diff} : Standardabweichung; r_{MQ_b, MQ_g} : Korrelationskoeffizient; E_{log} : log Effizienz



Berechnete und gemessene Abflußganglinie des Pegels Amberg, 25.12.1990 - 20.1.1991 mit dem Trainingsmuster 10.12.1991 - 12.1.1992, Zeitfenster ein Tag, Niederschlag, Temperatur und NDVI-Monatsmittel als Eingangsdatensatz

- | | | |
|----------------|---|--------------|
| Heft 1
1978 | Darstellung des Instituts für Wasserwesen an der Hochschule der Bundeswehr München | (vergriffen) |
| Heft 2
1979 | Ansprachen und Vorträge anlässlich der Inbetriebnahme der Laboratorien des Instituts für Wasserwesen an der Hochschule der Bundeswehr München
Prof. Dr.-Ing. W. Bechteler
Zur Ermittlung der Schwebstoffverteilung in offenen Gerinnen
Dr.-Ing. E. Billmeier
Sedimentationsvorgänge bei Absetzanlagen
Prof. Dr.-Ing. H.-B. Kleeberg
Bewertung wasserwirtschaftlicher Maßnahmen
Prof. Dr.-Ing. H. Teichmann
Messung von Geruchsemissionen auf Kläranlagen
Dipl.-Ing. G. Vogel
Druckstoßfortpflanzungsgeschwindigkeit in Wasser-Feststoff-Gemischen
Prof. Dr.-Ing. H.-J. Vollmers
Einige Bemerkungen zu Modellversuchen mit beweglicher Sohle | (vergriffen) |
| Heft 3
1980 | Vorträge aus dem Wasserwirtschaftlichen Kolloquium
Präsident Dipl.-Ing. L. Strobel
Langfristige wasserwirtschaftliche Aufgaben in Bayern
MinDir Dr.-Ing. E.h. B. Rümelin
Bauzustand und Planung der Rhein-Main-Donau-Wasserstraße
Dr.-Ing. E.h. K.R. Imhoff
Maßnahmen des Gewässerschutzes im Vorfluter | |
| Heft 4
1980 | Vorträge aus dem Wasserwirtschaftlichen Kolloquium
BD Dipl.-Ing. H. Mayr
Projekt Oberau - Probleme bei Planung und Bauausführung im ersten Bauabschnitt
Dr.-Ing. G. Naber
Betriebserfahrung für die sichere Gestaltung von Trinkwasser-Fernleitungen
Dipl.-Ing. P.P. Schmitt
Konstruktive Wasserbaumaßnahmen im Zusammenhang mit dem Ausbau des Lechs
Ltd. MinRat L. Büttner
Flußbauliche Sanierung am Rio Piray/Bolivien | |
| Heft 5
1981 | Prof. Dr.-Ing. W. Bechteler
Dipl.-Phys. K. Färber
Stochastische Modelle zur Beschreibung des Rückhalte- und Transportvorganges von suspendierten Sedimentpartikeln in turbulenten Gerinneströmungen
Dipl.-Ing. H. Hoffmann
Dipl.-Ing. B. Heller
Optimierung der Eindickung anaerob zu stabilisierender Schlämme in Bezug auf wirtschaftliche Abmessungen der dafür erforderlichen Bauwerke
Prof. Dr.-Ing. H.-B. Kleeberg
Dipl.-Ing. R. Knoop
Dipl.-Ing. G. Keser
Die Schwebstoffführung des Rio Piray/Bolivien
Dipl.-Ing. W. Schrimpf
Experimentelle Bestimmungen der Sinkgeschwindigkeit von Feststoffen in ruhender Flüssigkeit und turbulenter Strömung | |

- Heft 6 Vorträge aus dem Wasserwirtschaftlichen Kolloquium (vergriffen)
 1982 BD Dipl.-Ing. F. Defregger
 Chemisch-physikalische und thermische Verfahren zur Behandlung und Beseitigung von Sonderabfällen
 Dipl.-Ing. Dr.techn. P.G. Harhammer
 Optimale Verbundwirtschaft mit Speicherkraftwerken
 Dipl.-Ing. G. Schiechl
 Flußsanierung durch Wasserkraftausbau an Lech und Wertach - eine volkswirtschaftlich sinnvolle Lösung
- Heft 7 Vorträge aus dem Wasserwirtschaftlichen Kolloquium (vergriffen)
 1982 Dr.-Ing. G. Lottes
 Technik und Nutzung der Wasserkraft heute
 Ltd. BD Dipl.-Ing. F. Wieselsberger
 Die internationale Gewässerschutzkommission für den Bodensee
 Dipl.-Ing. Dr.techn. H. Drobir
 Die wasserbaulichen Konstruktionen der Kraftwerksgruppe Sellrain-Silz
- Heft 8 Dipl.-Ing. H. Hoffmann (vergriffen)
 1983 Anaerobe Stabilisierung von nitrifizierenden und denitrifizierenden Schlämmen
 Dipl.-Ing. G. Keser
 Modelle zur Simulation von Abflußdaten
 Dipl.-Ing. G. Koplitz-Weißgerber
 Probleme von Wasserversorgungsanlagen in tropischen Ländern - aufgezeigt am Beispiel Thailands
 Dipl.-Ing. M. Vetter
 Vergleich von Modellen des Schwebstofftransports in offenen Gerinnen mit Meßergebnissen
 Prof. Dr.-Ing. H.-J. Vollmers
 Ing. G. Palenque Espada
 Sedimenttransportmessungen im Rio Pilcomayo in Bolivien
- Heft 9 Dr.-Ing. K. Koch (vergriffen)
 1983 Physikalisch-chemische Messung von Geruchsemissionen auf kommunalen Kläranlagen
- Heft 10 Dr.-Ing. G. Vogel
 1983 Stationäre Strömung von Wasser-Feststoff-Gemischen in Druckrohrleitungen
- Heft 11 Tätigkeitsbericht des Instituts für Wasserwesen
 1983 1978 - 1983
- Heft 12 Dipl.-Ing. W. Schrimpf (vergriffen)
 1984 Dipl.-Ing. E. Steinle
 Untersuchung an horizontal durchströmten Sandfängen zur Verbesserung der Sandabscheidung und Vorreinigung kommunaler Abwässer
- Heft 13 Vorträge aus dem Wasserwirtschaftlichen Kolloquium (vergriffen)
 1984 Prof.Dr.-Ing. W. Bischofsberger
 Die Anwendung der Sauerstoffbegasung beim Belebungsverfahren
 Prof. Dr. Th. Dracos
 Rasche Reaktion von Grundwasserleitern auf Infiltrationsvorgänge
 Dipl.-Ing. O. Niekamp
 Probleme bei der Betriebssimulation von Speichersystemen auf der Basis synthetischen Datenmaterials
 Dipl.-Ing. H. Øverland
 Modelle zur Simulation von Bodenabtrag und -transport durch Wasser
 Direktor Ing. K. Rienößl
 Der Bau des Zillerkraftwerkes
 Ltd. BD Dipl.-Ing. L. Seethaler

Die Trinkwassertalsperre Frauenau - Vorstellung des Gesamtkonzeptes und Erläuterung von baulich besonders interessanten Maßnahmen

Dipl.-Ing. M. Vetter

Die Anwendung der Gravitationstheorie zur Ermittlung der vertikalen Verteilung der Schwebstoffkonzentration

Heft 14 Vorträge aus dem Wasserwirtschaftlichen Kolloquium (vergriffen)

1985 Dr.-Ing. D. Briechele

Die Grundwasserabsenkung im Rheinischen Braunkohlenrevier

Dipl.-Phys. K. Färber

Bestimmung von Turbulenzparametern in einer Gerinneströmung mit einem Laser-Doppler-Anemometer und einem Pitot-Rohr

Ltd. BD Dipl.-Ing. B. Fürmaier

Möglichkeiten der Verwertung von Hausmüll und hausmüllähnlichen Abfällen

Dr.-Ing. H.-P. Hack

Das Pfeilerkraftwerk Nußdorf am Inn

Ltd. BD Prof. Dr.-Ing. K. Scheurmann

Gestaltungsprobleme der unteren Isar

Heft 15 Dr.-Ing. G. Koplitz-Weißgerber

1985 Bewirtschaftung von Bewässerungssystemen in semiariden Regionen

Heft 16 Vorträge aus dem Wasserwirtschaftlichen Kolloquium

1986 Dr. R. Biedermann

Sicherheit der schweizerischen Talsperren

Dr. W. Nohl

Die landschaftsästhetische Beurteilung einer Teilrückleitung der oberen Isar

Dr.-Ing. K. Breitenbücher

Die exotherme, aerob-thermophile Stabilisierung

Dr.-Ing. N. Dichtl

Die zweistufige anaerobe thermophil/mesophile Schlammstabilisierung

Ing.(grad.) O. Jungbauer

Zweistufen-Schlammbehandlung System UTB

(Grundlagen - Entwicklung - Verfahrenstechnik - Betriebsergebnisse)

Dipl.-Ing. M. Rödiger

Die thermische Vorpasteurisierung und Faulung von Klärschlamm im technischen und wirtschaftlichen Vergleich

Dr.rer.nat. A. Steiner

Schlammstabilisierung unter dem Aspekt der Klärschlammverordnung-Hygiene

BD Dipl.-Ing. B. Torge

Schlammstabilisierung unter dem Aspekt der Klärschlammverordnung

- Verfahrenstechnik - Betrieb - Hygiene

Heft 17 Dr.-Ing. G. Keser

1986 Der Einfluß der hydrologischen Unsicherheit auf die Versorgung durch Wasserkraftspeicher

Heft 18 Dipl.-Phys. K. Färber

1987 Stochastische Modelle zur Simulation des Transportes nicht kohäsiver Sedimente in offenen Gerinnen

Heft 19 Dipl.-Ing. M. Vetter

1987 Der Transport suspendierter Feststoffe in offenen Gerinnen

(vergriffen)

Heft 20 Dr.-Ing. W. Schrimpf

1987 Ein Beitrag zur Berechnung der Sedimentation von Feststoffen in horizontal durchströmten Sandfängen

Heft 21 Dr.-Ing. Dipl.-Phys. K. Färber

1987 Stochastische Modelle der Bewegung suspendierter Partikel in turbulenter Strömung

- Heft 22 Dr.-Ing. E. Steinle
1987 Untersuchungen zur Energiebilanz konventioneller beheizter Faulbehälter - Konsequenzen für die Bemessung von Faulgasspeichern sowie Faulraumheizungen
- Heft 23 Dr.-Ing. H. Hoffmann
1987 Die Leistungsfähigkeit von Belebungsverfahren in Kaskadenschaltung
- Heft 24 Dr.rer.nat. K. Kaiser (vergriffen)
1987 Prof. Dr.-Ing. H. Teichmann
Vergleichende Geruchsmessungen auf Abwasserreinigungsanlagen
- Heft 25 Vorträge aus dem Wasserwirtschaftlichen Kolloquium
1987 Prof. Dr.-Ing.habil. H. Doedens
Konzepte zur stofflichen Verwertung auch im Verbund mit der thermischen Abfallverwertung
Dr.-Ing. R. Tuminski
Realisierung der stofflichen und thermischen Abfallverwertung
Dipl.-Ing.(FH) G. Berger
Das Gesamtkonzept der Abfallverwertung des Zweckverbandes für Abfallbeseitigung in Nord-west-Oberfranken und Erfahrungen aus einem Jahr Betrieb der Müllsortieranlage
BD Dipl.-Ing. F.-H. Weiß
Flußbetteintiefungen unterhalb von Stauanlagen; Untersuchungsmethoden und Möglichkeiten der Sanierung
- Heft 26 Dipl.-Ing. M. Vetter
1988 Gesamttransport von Sedimenten in offenen Gerinnen
- Heft 27 Tätigkeitsbericht des Instituts für Wasserwesen
1988 1984 - 1988
- Heft 28 Grußadressen und Vorträge anlässlich der 10-Jahres-Feier des Instituts für Wasserwesen (1978 - 1988)
1989
- Heft 29 Vorträge aus dem Wasserwirtschaftlichen Kolloquium
1989 Dipl.-Phys. H.-P. Streibelt
Abwässer und Schlämme aus Fahrzeug-Waschanlagen
GeoDir Dr. D. Gessner
Abwässer und Schlämme aus militärischen Fahrzeugwaschanlagen
Dipl.-Ing., Dipl.-Wirtsch.-Ing., Dipl.-Oec. J. Bever
Mineralogische Untersuchungen an Klärschlamm-Kalk- und Klärschlamm-Kalk-Ton-Mischungen
Dipl.-Ing. A. Stein
Aspekte zur Nutzung eines belüfteten Sandfanges als Höchstlaststufe
- Heft 30 Vorträge aus dem Wasserwirtschaftlichen Kolloquium
1989 PD Dr. W. Gujer
Simulation von Belebungsanlagen
Univ.-Prof. Dr.-Ing. P. Wolf
Modellberechnungen zum Einfluß der Nachklärung auf die Nitrifikation in Belebungsanlagen
BD Dipl.-Ing. H. Hofstetter
Siedlungswasserwirtschaftliche Fragen von zivilen Flughäfen - dargestellt am Planungskonzept für den Flughafen München II
MinRat Dipl.-Ing. G. Heiwolt
Entsorgung von Militärflugplätzen
- Heft 31 Montaña Vargas J. L.
1989 Prognose von Niederschlagsfeldern

- Heft 32 Vollmers H.-J.
 1989 Physikalische Modellierung des Feststofftransports
 Kleeberg H.-B., Øverland H.
 Zur Berechnung des effektiven oder abflußwirksamen Niederschlags
 Bechteler W., Kulisch H.
 Software zur Berechnung stationärer Abflußzustände in Gerinnen
 Bechteler W., Maurer M.
 Gütebeurteilung theoretisch-empirischer Modellansätze der Hydromechanik mit Hilfe der Zuverlässigkeitsmethode erster Ordnung
 Bechteler W., Tasdemir A.
 Experimentelle Ermittlung des Wellenwiderstandes eines Kreiszylinders mittels Stereophotogrammetrie
 Zottmann W.L.M., Vollmers H.-J.
 Beginn des Feststofftransports bei Strömung und Welle
- Heft 33 Bever J.G.
 1989 Die Monodeponie als eine Möglichkeit zur Entsorgung von kommunalem Klärschlamm
- Heft 34 Niekamp O.
 1989 Der Betrieb von Speichersystemen mit Überleitung unter Berücksichtigung von Nutzungsänderungen
- Heft 35 Øverland H.
 1990 Einfluß der Landnutzung auf Hochwasserabfluß und Schwebstofftransport
- Heft 36 Patt H. (vergriffen)
 1990 Hydromechanische Untersuchungen an einem belüfteten Sandfang
- Heft 37 Stein A.
 1990 Ein Beitrag zur Bemessung belüfteter Sandfänge kommunaler Kläranlagen
- Hefte Beiträge der 5. Wissenschaftlichen Tagung "Hydrologie und Wasserwirtschaft":
 38a/38b Folgen anthropogener Einflüsse auf den Wasserhaushalt und die Wasserbewirtschaftung
 1990
- Heft 39 Zottmann W.L.M. (vergriffen)
 1991 Zur Entstehung von Riffeln und Dünen
- Heft 40 Application of Hot-Film Probes for Measurement of Wall Shear Stress in Water
 1992 Gust G.
 Rugged, High-Resolution Velocity Probes Based on Skin-Friction Elements
 Zottmann W.L.M.
 The Flow Around a Cylinder
 Mayer O.
 Mathematical Theory for Shear Stress Measurement with Hot-Film Probes
 Zängerl H.-P.
 Development of an Electronic Module Running a Hot-Film Probe with the Constant Temperature Method (CTM)
 Michl R.
 Setup of a Shear Stress Multichannel Measuring System
 Sattel H., Noack J.
 Application of Hot-Film Probes Calibrated by Means of Laser Doppler Velocimetry
- Heft 41 Norgauer U.
 1992 Untersuchung der Abhängigkeit des Wirkungsgrades der Schlammfäulung von der Durchmischung im Faulbehälter
- Heft 42 Vetter M.
 1992 Ein Beitrag zur Berechnung des Feststofftransports in offenen Gerinnen

- Heft 43 Niekamp O., Kleeberg H.-B.
1992 Echtzeitsteuerung von Hochwasserrückhaltebecken unter Verwendung eines Betriebsmodells
Geitz M., Kleeberg H.-B.
Prognose von Niederschlagsfeldern mit einem stochastischen Modell
Carstensen A., Øverland H.
Bestimmung von Fließrichtungen und Gewässernetz aus digitalen Höhenmodellen (DHM)
Urbaniak S.
Phosphorelimination in einem Weichwassergebiet durch Vor-, Simultan- und Nachfällung mit Kalk
Rath K.
Erste Betriebsergebnisse zur Phosphorelimination durch Simultanfällung mit Kalk
Baier V.
Die Fouriertransformation in der Bildverarbeitung - Anwendungen in der Hydromechanik
Sattel H., Tasdemir A.
Messung der Wandschubspannung an Bootskörpern mittels Heißfilmanemometrie
Otto A.J.
Eindimensionale numerische Lösung des Dammbuchproblems in Kanälen mit variablen Querschnitten
- Heft 44 Hagen N.
1992 Steuerung von Speichern unter dem Aspekt der Wassergüte
- Heft 45 Kleeberg H.-B., Øverland H.
1993 Möglichkeiten der Abflußmodellierung unter Nutzung von Geoinformationssystemen
- Heft 46 Urbaniak S.
1993 Phosphorelimination durch Vor-, Simultan- und Nachfällung mit Kalk bei Abwasser mit geringer Säurekapazität
- Heft 47 Hagen N., Kleeberg H.-B. (vergriffen)
1993 Möglichkeiten der Modellierung des großräumigen Stofftransportes auf Landflächen Güte-Simulationsmodelle für stehende Gewässer - Eine Literaturanalyse
- Heft 48 Bechteler W., Broich K., Hartmann S., Kulisch H., Nuji M., Otto A.J.
1993 Simulationsmodelle zur Berechnung von Dammbüchen und 1- bzw. 2-dimensionaler Ausbreitung der Flutwelle im Gelände
- Heft 49 Tätigkeitsbericht des Instituts für Wasserwesen 1988 - 1993
1993
- Heft 50 Sattel H. (vergriffen)
1994 Wandschubspannung an umströmten Körpern
- Heft 51 Geitz M.
1994 Einfluß der räumlichen Niederschlagsvariabilität auf Ergebnisse von Niederschlag-Abfluß-Berechnungen
- Heft 52 Patt H.
1995 Der naturnahe Gewässerausbau - Grundlagen und Anwendungen
- Heft 53 Mayer O. (vergriffen)
1995 Auslegung und Simulation photovoltaischer Wechselstrompumpensysteme
- Heft 54 Schemmer J.
1995 Meßgeräte zur Bestimmung des Schwebstoffgehalts
Hrissanthou V., Vollmers H.-J., Hartmann S.
Beginn des Feststofftransportes - Eine zusammenfassende Betrachtung
- Heft 55 Kleeberg H.-B., Niekamp O.
1995 Vorstudie zur Formulierung von Forschungen zur Verfügbarkeit von Wasser

- Hefte Klimaänderung und Wasserwirtschaft
56a/56b Internationales Symposium am 27./28. November 1995 im Europäischen Patentamt
1996 in München, Tagungsband Teile a und b

Das Heft 55 und die Hefte 56a/56b wurden nicht im Schriftenaustausch versandt.

- Heft 57 Baier V.
1996 Bestimmung und Beschreibung der Form von Schwebstoffpartikeln mittels Unterwasservideomikroskop und digitaler Bildverarbeitung
- Heft 58 Bechteler W., Vollmers H.-J., Wieprecht S.
1996 DFG - Rundgespräch Geschiebe am 7./8. 12. 1995 in Würzburg
- Heft 59 Tasdemir A.
1997 Experimentelle und numerische Ermittlung der freien Wasseroberfläche
- Heft 60 Hartmann S.
1997 Entwicklung einer Strategie zur in situ-Ermittlung der kritischen Erosionsgeschwindigkeit
- Heft 61 Broich K.
1998 Computergestützte Analyse des Dammerosionsbruchs
- Heft 62 Nuji M.
1998 Praktischer Einsatz eines hochgenauen Verfahrens für die Berechnung von tiefengemittelten Strömungen
- Heft 63 Shen Z.
1998 Veränderung des Geschiebetransports durch naturnahe Sohleneinbauten
- Heft 64 Urbaniak S.
1998 Belastungsschwankungen und ihre Auswirkungen auf die Leistung von Abwasserreinigungsanlagen
- Heft 65 Tätigkeitsbericht des Instituts für Wasserwesen 1993 -1998
1998
- Heft 66 Festveranstaltung
1999 20 Jahre Institut für Wasserwesen
 Ehrendoktorwürde Prof. Dr.-Ing. Habil. J. Giesecke
- Heft 67 Willems W., Kleeberg H.-B.
1999 Analyse von Niedrigwasserabflüssen am Rhein
 Sedlmeir G., Hügel T., Papavassiliu T.
 Informationssystem ISSchnee für Gis-gestützte Schneekarten der bayerischen Mittelgebirge unter Berücksichtigung von Klimaänderungen
- Heft 68 Molnár T., Kasper G., Kleeberg H.-B.
1999 Parametermodelle und effektive Parameter zur Simulation von Wasserflüssen
 Carstensen A.
 Bestimmung von Parametern eines stochastischen Modells zur Generierung von Niederschlagsfeldern
- Heft 69 Günther F. W., Osswald M.
1999 Minimierung des Schlammanfalls auf Kläranlagen durch Desintegration – Bestandsaufnahme auf großtechnischen Anlagen
- Heft 70 Kleeberg H.-B., Mayer U.
1999 Hydrologische Extreme – Gefährdungspotentiale in Fließgewässern durch Trockenperioden

Heft 71 Hülgel T.
2000 Abflussberechnung mit Hilfe Neuronaler Netze