

Herausgegeben im Selbstverlag
des Institutes für Hydrologie und Wasserwirtschaft
Gottfried Wilhelm Leibniz Universität Hannover

Appelstraße 9a; D-30167 Hannover
Tel.: 0511/762-2237
Fax: 0511/762-3731
E-Mail: info@iww.uni-hannover.de

2017

Alle Rechte beim Autor

Stochastische Niederschlagsmodellierung unter Berücksichtigung von Großwetterlagen

Von der Fakultät für Bauingenieurwesen und Geodäsie
der Gottfried Wilhelm Leibniz Universität Hannover

zur Erlangung des akademischen Grades

Doktor-Ingenieur

- Dr.-Ing. -

genehmigte Dissertation

von

Dipl.-Ing. Aslan Belli

geboren am 15.01.1980 in München

2017

Referent: Prof. Dr.-Ing. Uwe Haberlandt

Korreferent: Prof. Dr. rer.nat. Dr.-Ing. habil. András Bárdossy

Tag der Promotion: 15.09.2016

Erklärung

Hiermit erkläre ich, Aslan Belli, geboren am 15.01.1980 in München, dass ich:

- die Regeln der geltenden Promotionsordnung kenne und eingehalten habe und mit einer Prüfung nach den Bestimmungen der Promotionsordnung einverstanden bin,
- die Dissertation selbst verfasst habe, keine Textabschnitte von Dritten oder eigener Prüfungsarbeiten ohne Kennzeichnung übernommen und alle von mir benutzten Hilfsmittel und Quellen in meiner Arbeit angegeben habe,
- Dritten weder unmittelbar noch mittelbar geldwerte Leistungen für Vermittlungstätigkeiten oder für die inhaltliche Ausarbeitung der Dissertation erbracht habe,
- die vorliegende Dissertation noch nicht als Prüfungsarbeit für eine staatliche oder andere wissenschaftliche Prüfung eingereicht habe,
- die gleiche oder eine in wesentlichen Teilen ähnliche Arbeit nicht bei einer anderen Hochschule als Dissertation eingereicht habe und
- damit einverstanden bin, dass die Dissertation auch zum Zwecke der Überprüfung der Einhaltung allgemein geltender wissenschaftlicher Standards genutzt wird, insbesondere auch unter Verwendung elektronischer Datenverarbeitungsprogramme.

Aslan Belli, Hannover, den 20. März 2016

Inhaltsverzeichnis

| | |
|--|----|
| Abbildungsverzeichnis | 4 |
| Tabellenverzeichnis | 9 |
| Abkürzungsverzeichnis | 12 |
| Symbolverzeichnis | 13 |
| Kurzfassung..... | 14 |
| Abstract | 16 |
| 1 Einleitung | 18 |
| 1.1 Motivation | 18 |
| 1.2 Zielsetzung | 18 |
| 1.3 Umsetzung..... | 19 |
| 2 Relevante Arbeiten..... | 20 |
| 2.1 Stochastische Niederschlagsmodellierung | 20 |
| 2.1.1 Alternating-Renewal-Modelle..... | 20 |
| 2.1.2 Disaggregation..... | 22 |
| 2.1.3 Punktprozessmodelle..... | 23 |
| 2.1.4 Zeitreihenmodelle..... | 24 |
| 2.1.5 Sonstige Modelle..... | 26 |
| 2.2 Großwetterlagen | 26 |
| 2.3 Methoden zum Niederschlags-Downscaling | 29 |
| 3 Untersuchungsgebiet und Datenbasis..... | 33 |
| 3.1 Das Gebiet und seine Geographie | 33 |
| 3.2 Niederschlagsstationen..... | 34 |
| 3.3 Der Niederschlag in Niedersachsen..... | 34 |
| 3.4 Plausibilitätsuntersuchungen | 39 |
| 3.5 Voruntersuchungen – notwendige Zeitreihenlänge..... | 41 |
| 3.6 Klimadaten für die Großwetterlagenklassifikation und das Downscaling | 42 |
| 4 Großwetterlagenklassifikation..... | 43 |
| 4.1 Allgemeines zur Methodik | 43 |
| 4.2 Verwendete GWL-Klassifikation..... | 45 |
| 5 Univariate Niederschlagsmodellierung | 48 |
| 5.1 ARP-Niederschlagsmodell – Modell ohne GWL..... | 48 |
| 5.1.1 Externe Struktur..... | 48 |
| 5.1.2 Interne Struktur..... | 49 |
| 5.2 Modellkomponenten und -varianten – Implementierung der GWL..... | 50 |

| | | |
|---------|---|-----|
| 5.2.1 | Validierung der Modellübertragung auf das Gebiet | 50 |
| 5.2.1.1 | Ursprünglicher Modellaufbau | 50 |
| 5.2.1.2 | Niederschlagsgenerierung und -validierung | 54 |
| 5.2.2 | Implementierung der GWL | 59 |
| 5.2.2.1 | Analyse des Zusammenhangs von GWL und Niederschlagsereignissen | 61 |
| 5.2.2.2 | Modellkonfiguration | 65 |
| 5.2.2.3 | Parameterschätzung | 70 |
| 5.2.2.4 | Niederschlagsgenerierung des aktualisierten Modells ohne GWL | 71 |
| 5.2.2.5 | Niederschlagsgenerierung mit GWL | 74 |
| 6 | Räumliche Übertragbarkeit der Modellparameter | 78 |
| 6.1 | Methodendiskussion und -auswahl | 78 |
| 6.2 | Transfer der Modellparameter im Raum | 81 |
| 6.2.1 | Variogrammschätzung | 81 |
| 6.2.2 | Ergebnisauswertung | 83 |
| 6.3 | Implementierung der Großwetterlagen | 85 |
| 7 | Optimierung der räumlichen Konsistenz und GWL-Struktur | 88 |
| 7.1 | Simulated Annealing Algorithmus | 88 |
| 7.2 | Optimierung univariater Daten hinsichtlich der räumlichen Niederschlagsstrukturen | 90 |
| 7.2.1 | Methodik | 90 |
| 7.2.2 | Ergebnisse | 93 |
| 7.3 | Implementierung der GWL | 100 |
| 7.3.1 | Methodik | 100 |
| 7.3.2 | Ergebnisse | 101 |
| 8 | Einfluss der GWL auf weitere Modellierungskennwerte | 105 |
| 8.1 | Klimavariablen | 105 |
| 8.2 | Saisonalität | 108 |
| 8.3 | Zeitliche Persistenz (Autokorrelation) | 110 |
| 8.3.1 | Gesamte Zeitreihe | 110 |
| 8.3.2 | Ereignisse | 110 |
| 8.4 | Räumliche Persistenz | 111 |
| 9 | Downscaling | 113 |
| 9.1 | Modellaufbauten | 113 |
| 9.1.1 | Transformation der GWL-Häufigkeiten | 114 |
| 9.1.2 | Transformation der L-Momente | 116 |
| 9.1.3 | Transformation der Ereigniszeitreihen | 117 |

| | | |
|--------|-----------------------------------|-----|
| 10 | Zusammenfassung und Ausblick..... | 126 |
| 11 | Literatur..... | 129 |
| Anhang | | 138 |

Abbildungsverzeichnis

| | |
|---|----|
| Abbildung 2-1 Punktprozessmodelle (nach Onof et al. (2000))..... | 23 |
| Abbildung 2-2 Niederschlags-Downscaling – schematische Darstellung der verschiedenen Methoden | 30 |
| Abbildung 3-1 Übersichtskarte von Niedersachsen; die Dreiecke markieren die höchsten Erhebungen | 33 |
| Abbildung 3-2 Verwendete hoch aufgelöste Niederschlagsstationen | 34 |
| Abbildung 3-3 Thiessen-Polygone der Saisonsummen des Niederschlages [mm]; links: Sommer, rechts: Winter | 35 |
| Abbildung 3-4 Thiessen-Polygone der saisonalen Ereignisanzahl [-]; links: Sommer, rechts: Winter | 35 |
| Abbildung 3-5 Thiessen-Polygone der Mittelwerte der wsi [mm/h]; links: Sommer, rechts: Winter... | 36 |
| Abbildung 3-6 Thiessen-Polygone der Varianz der wsi [mm ² /h ²]; links: Sommer, rechts: Winter | 36 |
| Abbildung 3-7 Thiessen-Polygone der Schiefe der wsi [-]; links: Sommer, rechts: Winter | 36 |
| Abbildung 3-8 Thiessen-Polygone des Mittelwertes der wsa [mm]; links: Sommer, rechts: Winter ... | 37 |
| Abbildung 3-9 Thiessen-Polygone der Mittelwerte der wsd [min]; links: Sommer, rechts: Winter | 37 |
| Abbildung 3-10 Thiessen-Polygone der Varianz der wsd [min ²]; links: Sommer, rechts: Winter..... | 37 |
| Abbildung 3-11 Thiessen-Polygone der Schiefe der wsd [-]; links: Sommer, rechts: Winter..... | 38 |
| Abbildung 3-12 Thiessen-Polygone der Mittelwerte der dsw [min]; links: Sommer, rechts: Winter.... | 38 |
| Abbildung 3-13 Thiessen-Polygone der Varianz der dsw [min ²]; links: Sommer, rechts: Winter | 38 |
| Abbildung 3-14 Thiessen-Polygone der Schiefe der dsw [-]; links: Sommer, rechts: Winter | 39 |
| Abbildung 3-15 Autokorrelation der Ereignisse als Mittel über alle Stationen (die X-Achse zeigt den lag)..... | 40 |
| Abbildung 3-16 Anteil [%] nachgewiesener Signifikanz der Autokorrelation in den Ereignissen (die x-Achse zeigt den lag) | 40 |
| Abbildung 3-17 Anteil [%] der Stationen, welche bei x Jahren Vergleichszeitreihenlänge aus statistischer Sicht parametrisch gleichwertig zur 15-jährigen Reihe sind; dargestellt sind die Anteile der Summen der Tests auf alle Ereigniselemente (Nassereignisintensität, Nassdauer und Trockendauer) | 41 |
| Abbildung 3-18 Übersicht über die für die GWL-Klassifikation verwendeten Daten, entnommen aus Haberlandt et al. (2011)..... | 42 |
| Abbildung 4-1 Beispiele der räumlichen Verteilung der 500 hPa geopotentiellen Höhe der Luftdruckverteilung zweier GWL (entnommen aus Haberlandt et al. (2011)) | 44 |
| Abbildung 4-2 Feuchteindex der mit Beobachtungsdaten definierten GWL; Version mit 8 GWL..... | 45 |
| Abbildung 4-3 Mittlerer jährlicher maximaler Tageswert der Cluster; Version mit 8 GWL..... | 45 |
| Abbildung 4-4 Anteil [-] der mit Beobachtungsdaten (Tageswerte) definierten GWL; links: Winter, rechts: Sommer; x-Achse: GWL; Version mit 8 GWL | 46 |
| Abbildung 4-5 Feuchteindex der mit Beobachtungsdaten definierten GWL; Version mit 4 GWL..... | 46 |
| Abbildung 4-6 Anteil [-] der mit Beobachtungsdaten (Tageswerte) definierten GWL; links: Winter, rechts: Sommer; x-Achse: GWL; Version mit 4 GWL | 47 |

| | |
|--|----|
| Abbildung 4-7 Feuchteindex der mit Beobachtungsdaten definierten GWL; Version mit 2 GWL | 47 |
| Abbildung 4-8 Anteil [-] der mit Beobachtungsdaten (Tageswerte) definierten GWL; links: Winter, rechts: Sommer; x-Achse: GWL; Version mit 2 GWL | 47 |
| Abbildung 5-1 Schematische Darstellung des univariaten Niederschlagsmodells | 48 |
| Abbildung 5-2 Sommerextremwerte, dt=1h | 58 |
| Abbildung 5-3 Winterextremwerte, dt=1h | 58 |
| Abbildung 5-4 GWL-Implementierung in der univariaten Niederschlagsgenerierung | 61 |
| Abbildung 5-5 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse, sortiert nach GWL im Sommer; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe | 62 |
| Abbildung 5-6 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse, sortiert nach GWL im Winter; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe | 62 |
| Abbildung 5-7 Ungewichtete Häufigkeit [%] der acht GWL in den Ereignissen im Mittel über alle Stationen; 9 – keine GWL kann zugewiesen werden | 63 |
| Abbildung 5-8 Über die Dauer gewichtete Häufigkeit [%] der acht GWL in den Ereignissen im Mittel über alle Stationen; 9 – keine GWL kann zugewiesen werden | 63 |
| Abbildung 5-9 Ungewichtete Häufigkeit [%] der zwei GWL in den Ereignissen im Mittel über alle Stationen | 64 |
| Abbildung 5-10 Über die Dauer gewichtete Häufigkeit [%] der zwei GWL in den Ereignissen im Mittel über alle Stationen | 64 |
| Abbildung 5-11 Ungewichtete Häufigkeit [%] der vier GWL in den Ereignissen im Mittel über alle Stationen | 64 |
| Abbildung 5-12 Über die Dauer gewichtete Häufigkeit [%] der vier GWL in den Ereignissen im Mittel über alle Stationen | 65 |
| Abbildung 5-13 Gegenüberstellung der theoretischen (gepunktete Linie) und der empirischen (durchgezogene Linie) Verteilungsfunktionen, beispielhaft für eine Station im Winter mit den in Tabelle 5-10 angegebenen theoretischen Verteilungen (GWL-5) | 67 |
| Abbildung 5-14 Gegenüberstellung der Quantile der theoretischen (y-Achse) und der empirischen (x-Achse) Verteilungsfunktionen, beispielhaft für drei Stationen im Sommer mit den in Tabelle 5-10 angegebenen theoretischen Verteilungen (feuchte GWL 5) | 68 |
| Abbildung 5-15 Gegenüberstellung der Quantile der theoretischen (y-Achse) und der empirischen (x-Achse) Verteilungsfunktionen, beispielhaft für drei Stationen im Sommer mit den in Tabelle 5-10 angegebenen theoretischen Verteilungen (trockene GWL 2) | 69 |
| Abbildung 6-1 Zusatzvariablen für die Parameterregionalisierung – Validierungsdatensatz | 79 |
| Abbildung 6-2 Tageswertstationen – Messnetz in Niedersachsen | 80 |
| Abbildung 6-3 Stundenwert-Beobachtungsstationen der Variogrammschätzung | 82 |
| Abbildung 6-4 Variogrammschätzung; links: Mittelwert der <i>dsd</i> , rechts: Mittelwert der <i>wsi</i> ; x-Achse: Entfernung in km; y-Achse: Varianz, für <i>dsd</i> durch 1000 dividiert, für <i>wsi</i> mit 1000 multiplizierte Werte. | 82 |
| Abbildung 6-5 Vergleich der Kreuzvalidierung der Interpolation mit und ohne GWL; Version mit acht GWL, Mittel über alle GWL | 85 |
| Abbildung 7-1 Fließschema des Simulating-Annealing-Algorithmus | 89 |

| | |
|---|-----|
| Abbildung 7-2 Tausch von Ereignissen bei Simulated Annealing | 90 |
| Abbildung 7-3 Regression der Zielfunktion; durchgezogene Linie: lineare Regression; unterbrochene Linie: Potenz-Regression; gestrichelte Linie: logarithmische Regression; die y-Achse gibt den einheitenlosen Wert der Eigenschaft an; die x-Achse ist der euklidische Abstand der verglichenen Stationen in km..... | 92 |
| Abbildung 7-4 Sets für die räumliche Konsistenz..... | 94 |
| Abbildung 7-5 Zielfunktion der Optimierung ohne GWL (2 Stationen); die x-Achse gibt den Wert der Zielfunktion an und die y-Achse die Anzahl an Iterationsschritten in 100.000 | 95 |
| Abbildung 7-6 Zielfunktion der Optimierung ohne GWL (Set 5, alle Stationen); die y-Achse gibt den Wert der Zielfunktion an und die x-Achse die Anzahl an Iterationsschritten in 100.000 | 96 |
| Abbildung 7-7 Funktion der Korrelation zwischen jeweils zwei Stationen für alle Stationen des Sets 5 der Optimierung ohne GWL; die y-Achse gibt den Pearson'schen Korrelationskoeffizienten an, die x-Achse die Entfernung in km; links: Stundenwertintervall, rechts: Tageswertintervall | 98 |
| Abbildung 7-8 Lag-Kreuzkorrelationen der Stundenwerte der Beobachtung und der Synthese nach der Optimierung ohne GWL; links: Beobachtung, rechts: Simulation; die x-Achse gibt die Lags an und die y-Achse die Korrelationskoeffizienten..... | 99 |
| Abbildung 7-9 Zeitreihen der Stundenwerte des Sets 1 für drei Monate, links: direkte Ausgabedaten des univariaten N-Modells, rechts: Ausgabedaten der Optimierung; die x-Achse gibt die Zeit an, die y-Achse die Werte des Niederschlags in mm/h; die oberen Werte sind die der Station 03180, die unteren die der Station 03984..... | 99 |
| Abbildung 7-10 Zielfunktion der Optimierung mit und ohne GWL; es werden die Summen der Zielfunktionselemente aus (7-6) einander gegenübergestellt; die y-Achse gibt den Wert der Zielfunktion an und die x-Achse die Anzahl an Iterationsschritten in 100.000 | 102 |
| Abbildung 7-11 Korrelation zwischen jeweils zwei Stationen für alle Stationen des Sets 5 der Optimierung mit und ohne GWL; die y-Achse gibt den Pearson'schen Korrelationskoeffizienten an, die x-Achse die Entfernung in km; links: Stundenwertintervall, rechts: Tageswertintervall..... | 102 |
| Abbildung 7-12 Univariate Zielfunktion von fünf Stationen im Untersuchungsgebiet; links: Version mit acht GWL, rechts: Version mit zwei GWL; die y-Achse gibt den Wert der Zielfunktion an und die x-Achse die Anzahl an Iterationsschritten in 100.000..... | 103 |
| Abbildung 8-1 Abweichung [%] der Temperaturen der GWL von der mittleren Temperatur aller GWL mit zwei (oben), vier (Mitte) und acht GWL (unten; GWL 9: keine GWL kann zugewiesen werden), links: Beobachtung, rechts: Synthese nach dem Simulated Annealing..... | 107 |
| Abbildung 8-2 Abweichung [%] der Temperaturen der GWL von der mittleren Temperatur aller GWL mit zwei (oben) und acht (unten) GWL, links: Beobachtung, rechts: REMO C20 (1971-2000)..... | 108 |
| Abbildung 8-3 Abweichung [%] der Temperaturen der GWL von der mittleren Temperatur aller GWL mit zwei GWL, links: REMO C20 (1971-2000), rechts: REMO A1b (2071-2100) | 108 |
| Abbildung 8-4 Monatliche Saisonalität der Niederschläge; y-Achse: Anteil [%] der Monatssummen am Jahresniederschlag, x-Achse: Monate; links: Niedersachsen, rechts: Harz-Hochland; dargestellt wurde die Version mit 8 GWL | 109 |
| Abbildung 8-5 Monatliche Saisonalität der REMO-Niederschläge im Vergleich zur Beobachtung in Niedersachsen; y-Achse: Anteil [%] der Monatssummen am Jahresniederschlag, x-Achse: Monate | 109 |

| | |
|---|-----|
| Abbildung 8-6 Monatliche Saisonalität der Synthese-Daten im Vergleich zu den REMO-Niederschlägen in Niedersachsen; y-Achse: Anteil [%] der Monatssummen am Jahresniederschlag, x-Achse: Monate, links: Vergangenheit (C20: 1971-2000), rechts: Zukunft (A1B: 2071-2100)..... | 110 |
| Abbildung 8-7 Mittlere Autokorrelation der Stundenwerte (links) und Tageswerte (rechts); Beobachtung gegen Modell; x-Achse: Lags; y-Achse: Wert der Korrelation..... | 110 |
| Abbildung 8-8 Autokorrelation der Ereigniselemente, Beobachtung und Modell; links: lag 1; rechts: lag 2..... | 111 |
| Abbildung 8-9 Pearson'sche Korrelationskoeffizienten der univariat generierten Daten in Abhängigkeit vom Raum; Darstellung für die Synthese ohne GWL und die Synthese mit zwei GWL, x-Achse: Entfernung [km], y-Achse: Korrelationskoeffizient; links: Stundenwerte, rechts: Tageswerte | 112 |
| Abbildung 8-10 Pearson'sche Korrelationskoeffizienten der Beobachtung in Abhängigkeit vom Raum; dargestellt sind die Paare aller Stationen im Untersuchungsgebiet mit einem Abstand > 10 km; Darstellung, x-Achse: Entfernung [km], y-Achse: Korrelationskoeffizient..... | 112 |
| Abbildung 9-1 Änderungen im Niederschlag der Großwetterlagen (nach Haberlandt et al. (2015)) . | 113 |
| Abbildung 9-2 GWL-Frequenzen [%] in den Ereignissen von Beobachtung und REMO, beispielhaft für die Station Diepholz im Winter | 114 |
| Abbildung 9-3 Quantil-Quantil-Transformation | 118 |
| Abbildung A-1 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Winter, sortiert nach GWL mit 2 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe..... | 144 |
| Abbildung A-2 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Sommer, sortiert nach GWL mit 2 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe..... | 144 |
| Abbildung A-3 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Winter, sortiert nach GWL mit 4 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe..... | 145 |
| Abbildung A-4 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Sommer, sortiert nach GWL mit 4 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe..... | 145 |
| Abbildung A-5 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Winter, sortiert nach GWL mit 8 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe; GWL 9 sind, Ereignisse denen keine GWL zugewiesen werden konnte..... | 146 |
| Abbildung A-6 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Sommer, sortiert nach GWL mit 8 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe; GWL 9 sind, Ereignisse denen keine GWL zugewiesen werden konnte..... | 146 |
| Abbildung A-7 L-Moment 2. Ordnung der Ereignisse im Winter, sortiert nach GWL mit 2 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe..... | 147 |
| Abbildung A-8 L-Moment 2. Ordnung der Ereignisse im Sommer, sortiert nach GWL mit 2 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe..... | 147 |
| Abbildung A-9 L-Moment 2. Ordnung der Ereignisse im Winter, sortiert nach GWL mit 4 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe..... | 148 |
| Abbildung A-10 L-Moment 2. Ordnung der Ereignisse im Sommer, sortiert nach GWL mit 4 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe..... | 148 |

| | |
|--|-----|
| Abbildung A-11 L-Moment 2. Ordnung der Ereignisse im Winter, sortiert nach GWL mit 8 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe; GWL 9 sind Ereignisse, denen keine GWL zugewiesen werden konnte..... | 149 |
| Abbildung A-12 L-Moment 2. Ordnung der Ereignisse im Sommer, sortiert nach GWL mit 8 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe; GWL 9 sind Ereignisse, denen keine GWL zugewiesen werden konnte..... | 149 |
| Abbildung A-13 Variogrammschätzung; oben links: Mittelwert der dsd , oben rechts: Mittelwert der wsi , unten rechts: Mittelwert der wsd ; x-Achse: Entfernung in km; y-Achse: Varianz, für dsd durch 1000 dividiert, für wsi mit 1000 multiplizierte Werte. | 150 |
| Abbildung A-14 Variogrammschätzung; oben links: 2. L-Moment der dsd , oben rechts: 2. L-Moment der wsi , unten rechts: 2. L-Moment der wsd ; x-Achse: Entfernung in km; y-Achse: Varianz..... | 150 |
| Abbildung A-15 Variogrammschätzung; oben links: Tau-3 der dsd , oben rechts: Tau-3 der wsi , unten rechts: Tau-3 der wsd ; x-Achse: Entfernung in km; y-Achse: Varianz..... | 151 |

Tabellenverzeichnis

| | |
|---|----|
| Tabelle 5-1 Modellaufbau des Ausgangszustandes..... | 50 |
| Tabelle 5-2 Stationsliste der Auswertungen..... | 54 |
| Tabelle 5-3 Modellübertragung auf das Gebiet – Mittelwerte der Ereignisse – Winter..... | 55 |
| Tabelle 5-4 Modellübertragung auf das Gebiet – Mittelwerte der Ereignisse – Sommer | 55 |
| Tabelle 5-5 Modellübertragung auf das Gebiet – Abgeleitete Werte..... | 55 |
| Tabelle 5-6 Indizes der Extremwerte im Mittel über alle Stationen, Sommer; p-value (Test) gibt die Anzahl synthetischer Zeitreihen an, deren Extremwerte dieselbe Verteilung haben wie die Beobachtung..... | 58 |
| Tabelle 5-7 Indizes der Extremwerte im Mittel über alle Stationen, Winter; p-value (Test) gibt die Anzahl synthetischer Zeitreihen an, deren Extremwerte dieselbe Verteilung haben wie die Beobachtung..... | 58 |
| Tabelle 5-8 GWL-Zuweisung der Ereignisse; blau: Nassereignis, grau: Trockenereignis | 60 |
| Tabelle 5-9 In den Untersuchungen berücksichtigte Verteilungsfunktionen | 65 |
| Tabelle 5-10 Modellkonfiguration nach der Anpassung an GWL und Untersuchungsgebiet..... | 66 |
| Tabelle 5-11 Anteil [%] an Tests, die bei einem Signifikanzniveau von 0,05 eine Eignung der gewählten Verteilungsfunktion (siehe Tabelle 5-10) ergeben..... | 70 |
| Tabelle 5-12 Abweichung [%] der abgeleiteten Größen (Ereignisanzahl und Niederschlagssummen) der synthetischen Daten (ARP0 und ARP1) zur Beobachtung | 72 |
| Tabelle 5-13 Abweichung [%] der statistischen Momente der synthetischen Daten (ARP0 und ARP1) zur Beobachtung..... | 72 |
| Tabelle 5-14 Vergleich der Indizes der Extremwerte der Modellvarianten ARP0 und ARP1 im Mittel über alle Stationen, Sommer | 73 |
| Tabelle 5-15 Vergleich der Indizes der Extremwerte der Modellvarianten ARP0 und ARP1 im Mittel über alle Stationen, Winter..... | 73 |
| Tabelle 5-16 Abweichung [%] der statistischen Momente der synthetischen Daten zur Beobachtung | 74 |
| Tabelle 5-17 Vergleich der Indizes der Extremwerte der synthetischen Daten im Mittel über alle Stationen, Sommer | 75 |
| Tabelle 5-18 Vergleich der Indizes der Extremwerte der synthetischen Daten im Mittel über alle Stationen, Winter..... | 76 |
| Tabelle 5-19 Abweichung [%] der abgeleiteten Größen der synthetischen Daten zur Beobachtung.... | 77 |
| Tabelle 6-1 Kreuzvalidierung der Interpolation der L-Momente (ein grüner Hintergrund kennzeichnet das Verfahren mit den besten Ergebnissen) | 84 |
| Tabelle 6-2 Optimale Zusatzvariablen – Kombination bei der Interpolation der L-Momente..... | 84 |
| Tabelle 6-3 Einfluss weiterer Zusatzvariablen auf die multiple Regression des 2. L-Moments der <i>dsd</i> | 84 |
| Tabelle 6-4 Kreuzvalidierung der Interpolation der Feinstrukturparameter..... | 85 |
| Tabelle 6-5 Abweichung [%] der statistischen Momente der Beobachtung zu der der Modellergebnisse mit den Modellparametern aus Beobachtung und Regionalisierung (Kreuzvalidierung) Mean: Mittelwert, Var: Varianz, Skew: Schiefe | 86 |

| | |
|---|-----|
| Tabelle 6-6 Kennwerte zum Vergleich der Extrema der Modellergebnisse mit den Modellparametern der Beobachtung und der Kreuzvalidierung (oben: 1-Stunden-Werte, unten 3-Stunden-Werte)..... | 87 |
| Tabelle 7-1 Güte der verschiedenen Regressionsverfahren der Zielfunktion des Simulated Annealings | 93 |
| Tabelle 7-2 Zusammensetzung der Sets für das Simulated Annealing | 94 |
| Tabelle 7-3 Gewichtungen der Zielfunktionselemente ohne GWL..... | 95 |
| Tabelle 7-4 Zielfunktionselemente nach der der Optimierung ohne GWL (Set 1 bis 4)..... | 97 |
| Tabelle 7-5 Auszug der Zielfunktionselemente nach der Optimierung ohne GWL (Set 5, Nummerierung der Stationen entsprechend Tabelle 7-2)..... | 97 |
| Tabelle 7-6 Auszug der Korrelationen der Tageswertreihen nach der Optimierung ohne GWL (Set 1 bis 4)..... | 98 |
| Tabelle 7-7 Korrelationen der Tageswertreihen nach der Optimierung ohne GWL (Set 5) | 98 |
| Tabelle 7-8 Zielfunktionselemente nach der Optimierung mit und ohne GWL (Set 2 und 3)..... | 101 |
| Tabelle 7-9 Mittlere GWL-Gleichzeitigkeit [%] in den Ereignissen der Stationen des Sets GWL-Gleichzeitigkeit | 103 |
| Tabelle 7-10 Mittelwert der RMSD der GWL-Frequenz nach der univariaten Optimierung der Stationen des Sets GWL-Gleichzeitigkeit..... | 104 |
| Tabelle 8-1 Korrelation zwischen Niederschlags- und Klimadaten..... | 106 |
| Tabelle 8-2 Arithmetisches Mittel über alle Stationen der Pearson'schen Korrelation der univariat generierten Daten | 111 |
| Tabelle 9-1 Anteile [%] der GWL an den zu Ereignissen verbundenen Stundenwert-Intervallen; Version mit zwei GWL | 115 |
| Tabelle 9-2 Auszug 1 der Anteile [%] der GWL an den zu Ereignissen verbundenen Stundenwert-Intervallen; Version mit acht GWL, GWL 9 besteht aus Ereignissen mit nicht zuweisbaren GWL .. | 115 |
| Tabelle 9-3 Auszug 2 der Anteile [%] der GWL an den zu Ereignissen verbundenen Stundenwert-Intervallen; Version mit acht GWL, GWL 9 besteht aus Ereignissen mit nicht zuweisbaren GWL .. | 115 |
| Tabelle 9-4 Mittlere Änderungen [%] über alle Stationen der abgeleiteten Niederschlagscharakteristika | 116 |
| Tabelle 9-5 Veränderung [%] der statistischen Momente im Mittel über alle Stationen bei den verschiedenen Downscaling-Verfahren (<i>wsd</i> im Winter), entsprechend den Veränderungen des Mittelwertes des zugehörigen REMO-Rasterpunktes zwischen den Zeiträumen 1971-2000 und 2071-2100, ohne GWL-Berücksichtigung..... | 119 |
| Tabelle 9-6 Veränderung [%] der L-Momente im Mittel über alle Stationen bei den verschiedenen Downscaling-Verfahren (<i>wsd</i> im Winter), entsprechend den Veränderungen des Mittelwertes des zugehörigen REMO-Rasterpunktes zwischen den Zeiträumen 1971-2000 und 2071-2100, ohne GWL-Berücksichtigung..... | 119 |
| Tabelle 9-7 Mittlere Änderungen [%] über alle Stationen der saisonalen Niederschlagssummen für drei Verfahren, Version mit acht GWL | 120 |
| Tabelle 9-8 Mittlere Änderungen [%] über alle Stationen der Anzahl an Ereignissen pro Saison für drei Verfahren, Version mit acht GWL..... | 120 |

| | |
|---|-----|
| Tabelle 9-9 Mittlere Änderungen [%] über alle Stationen der mittleren Ereignisvolumen für drei Verfahren, Version mit acht GWL..... | 121 |
| Tabelle 9-10 Mittlere Änderungen [%] über alle Stationen der gewichteten 1-stündlichen Extremwerte für drei Verfahren, Version mit acht GWL..... | 121 |
| Tabelle 9-11 Mittlere Änderungen [%] über alle Stationen der gewichteten 24-stündlichen Extremwerte für drei Verfahren, Version mit acht GWL..... | 122 |
| Tabelle 9-12 Mittlere Änderungen [%] über alle Stationen der gewichteten und ungewichteten 24-stündlichen Extremwerte für die Quantil-Quantil-Transformation, Version mit acht GWL; Transformationszeitraum: Beobachtungszeitraum zu 2021-2050..... | 122 |
| Tabelle 9-13 Mittlere Änderungen [%] über alle Stationen der saisonalen Niederschlagssummen, Version mit acht GWL..... | 123 |
| Tabelle 9-14 Mittlere Änderungen [%] über alle Stationen der Anzahl an Ereignissen pro Jahr, Version mit acht GWL..... | 123 |
| Tabelle 9-15 Mittlere Änderungen [%] über alle Stationen der gewichteten 1- und 24-stündlichen Extremwerte, Version mit acht GWL, Transformationszeitraum: Beobachtungszeitraum zu 2071-2100..... | 124 |
| Tabelle 9-16 Mittlere Änderungen [%] über alle Stationen der Niederschlagssummen für die Quantil-Quantil-Transformation, Version ohne GWL, mit zwei, vier und acht GWL..... | 124 |
| Tabelle 9-17 Mittlere Änderungen [%] über alle Stationen der Anzahl an Ereignissen pro Saison für die Quantil-Quantil-Transformation, Version ohne GWL, mit zwei, vier und acht GWL..... | 125 |
| Tabelle 9-18 Mittlere Änderungen [%] über alle Stationen der gewichteten stündlichen, 6-stündlichen und 24-stündlichen Extremwerte für die Quantil-Quantil-Transformation, Version ohne GWL, mit zwei, vier und acht GWL, Transformationszeitraum: Beobachtungszeitraum zu 2021-2050..... | 125 |
| Tabelle A-1 Liste der hoch aufgelösten Niederschlagsstationen..... | 138 |
| Tabelle A-2 Fehlwertanteile der Beobachtungsjahre in den hoch aufgelösten Niederschlagsstationen; in den Untersuchungen verwendet wurde der Bereich im dicken Rahmen; die Zahlen markieren den Fehlwertanteil in Prozent; NA kennzeichnet Jahre, in denen keine Beobachtungen vorliegen; der Wert „Mittel“ gibt den durchschnittlichen Fehlwertanteil der verwendeten Zeiträume an..... | 139 |
| Tabelle A-3 Mittel der statistischen Momente der Ereignisse – Beobachtung gegen Modellierung; für die Beobachtung werden die tatsächlichen Werte angegeben, für die Modellierung die prozentualen Abweichungen zur Beobachtung..... | 140 |
| Tabelle A-4 Mittel der L- Momente der Ereignisse – Beobachtung gegen Modellierung; für die Beobachtung werden die tatsächlichen Werte angegeben, für die Modellierung die prozentualen Abweichungen zur Beobachtung..... | 141 |
| Tabelle A-5 Mittel der abgeleiteten Größen – Beobachtung gegen Modellierung; für die Beobachtung werden die tatsächlichen Werte angegeben, für die Modellierung die prozentualen Abweichungen zur Beobachtung..... | 141 |
| Tabelle A-6 Indizes der Niederschlagsextrema der Modellierung im Winter..... | 142 |
| Tabelle A-7 Indizes der Niederschlagsextrema der Modellierung im Sommer..... | 143 |

Abkürzungsverzeichnis

| | |
|-------------------|---|
| A1b | Klimamodelldurchlauf Zukunft (Annahme: ausgewogene Nutzung aller Quellen) |
| ARP | Alternating Renewal Processes (ein Typ Niederschlagsmodell) |
| ARP1-4 | Modelldurchläufe (siehe Abschnitt 5.2.2) |
| AR | Autoregressive Niederschlagsmodelle |
| ARMA | Autoregressive Moving Averages (ein Typ Niederschlagsmodell) |
| C20 | Klimamodelldurchlauf Vergangenheit (Referenzszenario) |
| CP | Circulation Pattern (englisch für Großwetterlagen) |
| DWD | Deutscher Wetterdienst |
| ECHAM | Globales Klimamodell des Max-Planck-Instituts für Meteorologie |
| EDK | External Drift Kriging |
| EV | Niederschlagsereignis |
| GCM | General Circulation Model (englisch für Globales Klimamodell) |
| GEV | Generalized Extreme Value Distribution |
| GPA | Generalized Pareto Distribution |
| GWL | Großwetterlagen |
| KNN | Künstliche Neuronale Netze |
| KS-Test | Kolmogoroff-Smirnoff-Test |
| M1 bis M3b | Methoden zur GWL-Implementierung (siehe Abschnitt 5.2.2) |
| MA | Moving Averages (ein Typ Niederschlagsmodell) |
| MR | Lineare Multiple Regression |
| NCAR | Reanalyse-Projekt des National Center for Atmospheric Research (USA) |
| NN | Nächster Nachbar |
| $n\omega^2$ -Test | Cramér von Mises Tests |
| OK | Ordinary Kriging |
| Q-Q-Plots | Quantil-Quantil-Plots |
| RCM | Regionales Klimamodell |
| REMO | Regionales Klimamodell des Max-Planck-Instituts für Meteorologie |
| RMSD | Root Mean Square Deviation |
| RMSE | Root Mean Square Error |
| SA | Simulated Annealing |
| STARMA | Space Time Autoregressive Moving Averages (ein Typ Niederschlagsmodell) |
| WGM | Wahrscheinlichkeitsgewichtete Momente |

Symbolverzeichnis

| | |
|-------------------------------------|--|
| bb | Parameter der Feinstruktur |
| χ_i | Testgröße des Chi-Quadrat-Tests |
| C_{kl} | Kontinuität nach Wilks |
| $D_{abs,n/w}$ | Abstandskriterium für die Extremwertanalyse (n-ungewichtet, w-gewichtet) |
| d_m | Mittlerer Niederschlag pro Jahr an Tagen mit Niederschlagssumme $> 0,1\text{mm}$ |
| $D_{n,n'}$ | Testgröße des Kolmogoroff-Smirnoff-Tests |
| $D_{sign,n/w}$ | Biaskriterium für die Extremwertanalyse (n-ungewichtet, w-gewichtet) |
| dsd | Dry Spell Duration (Trockendauer) |
| $\gamma_{dsd/wsd/wsi}$ | Schiefe der Ereignisse |
| H | Geländehöhe über Normalnull |
| L1, L2, Tau3 | L-Momente 1. und 2. Ordnung; Quotient des L-Moments 3. Ordnung der mit Stundenwerten definierte Ereignisse |
| λ_i oder L_i | L-Moment i-ter Ordnung |
| LM_d | L-Momente der mit Tageswerten definierten Ereignisse |
| lna | Parameter der Feinstruktur |
| N_{dd} | Durchschnittliche Anzahl trockener Tage |
| N_{wd} | Durchschnittliche Anzahl nasser Tage |
| $n\omega^2$ | Testgröße des Cramér-von-Mises-Tests |
| O_i | Zielfunktionselemente |
| P_{00} | Wahrscheinlichkeit der Gleichzeitigkeit von Trockenheit an 2 Stationen |
| P_{11} | Wahrscheinlichkeit der Gleichzeitigkeit von Niederschlägen an 2 Stationen |
| p-value ($n\omega^2/K$ -S-Test) | Summe der erfolgreichen Stichprobentests |
| P_Y | Durchschnittliche Jahresniederschlagshöhe |
| R_A | Abdeckungsgrad |
| $\sigma^2_{dsd/wsd/wsi}$ | Varianz der Ereignisse |
| $\mu_{dsd/wsd/wsi}$ | Mittelwert der Ereignisse |
| w_i | Feuchteindex |
| wsd | Wet Spell Duration (Nassereignisdauer) |
| wsi | Wet Spell Intensity (Nassereignisintensität) |
| wsp | Wet Spell Peak (Nassereignis-Spitzenwert) |
| wspt | Wet Spell Peak Time (Zeitpunkt des Nassereignis-Spitzenwerts) |

Kurzfassung

Für die Bemessung und den Betrieb vieler Ingenieurbauwerke werden Abflussdaten (z. B. eines Flusses oder Kanals) benötigt. Da diese oft nicht vorhanden sind, werden die Daten häufig modelltechnisch generiert. Als Eingangsdaten der Modelle werden in der Regel zeitlich hoch aufgelöste Niederschlagsdaten verwendet. Idealerweise werden Beobachtungsdaten verwendet, allerdings sind diese oftmals nicht verfügbar. Aufgrund der hohen Komplexität des klimatischen Geschehens ist eine präzise physikalische Modellierung von zeitlich hoch aufgelösten Niederschlagsdaten in der Regel nicht möglich. In Fällen in denen keine geeigneten beobachteten Niederschlagsdaten vorhanden sind, kommen daher Daten aus stochastischen Niederschlagsmodellen zum Einsatz.

In der Stochastik wird häufig versucht, vorhandene Daten zu clustern. Dies bedeutet, dass man die Daten nach bestimmten Kriterien in Gruppen unterteilt. Seit Jahrzehnten wird das regionale Klima Europas in Großwetterlagen (GWL) klassifiziert. Die GWL definieren einen Zeitraum, in dem in einem Großraum, z. B. Europa, bestimmte Verhältnisse in der Luftdruckverteilung vorherrschen. Durch diese Strukturen im Luftdruck wird das lokale Klimageschehen bestimmt. Es liegt daher nahe, diese Daten für eine Clusterbildung zu verwenden.

In der vorliegenden Arbeit wurden Niederschlagsdaten mit Fokus auf große Niederschlagsereignisse in einer Stundenwertauflösung generiert. Hierfür wurde ein auf der Reproduktion von Niederschlagsereignissen basierendes Modell (ein sogenanntes Alternating-Renewal-Model) weiterentwickelt. Dieses bestehende, erprobte Modell wurde für die Nutzung von GWL angepasst und deren Einfluss auf die Modellierungsqualität des Niederschlags wurde analysiert. Durch die Unterscheidung des Niederschlages in natürliche Cluster wurde zum einen eine Verbesserung der Modellgüte erwartet. Zum anderen sollte mit der Anpassung des Modells an GWL und Klimamodelldaten die Modellierung zukünftiger Zustände ermöglicht werden. Da aufgrund des Klimawandels Veränderungen im Niederschlagsgeschehen erwartet werden, ist dieser Schritt notwendig, um die modellierten Daten für die Bemessung langjährig bestehender Bauwerke sinnvoll anzuwenden.

Der Einfluss der GWL auf andere Aspekte der Modellierung wurde ebenfalls untersucht, zum Beispiel auf die Regionalisierung des Modells oder auf die Reproduktionsgüte des räumlichen Zusammenhanges der generierten Punktdaten. Eine weitere, wichtige Untersuchung betraf den Einfluss der Verwendung von GWL auf die Reproduktion des Zusammenhanges von Niederschlagsdaten und Klimadaten, z. B. von Temperatur und Sonnenscheindauer. Dies ist von Bedeutung, da diese Daten oft gemeinsam mit dem Niederschlag die Grundlage von hydrologischen Modellen bilden.

Durch die Berücksichtigung der GWL konnten folgende Kennwerte in der Synthese besser reproduziert werden:

- die statistischen Momente der Ereignischarakteristika (leichte Verbesserungen),
- die synthetischen Niederschlagsjahreswerte und
- die Niederschlagsextrema in allen Zeitschritten, mit Ausnahme der Stundenwert-Extrema

Die Analyse des Zusammenhanges von Niederschlag und anderen Klimavariablen war aufgrund mangelnder nachweisbarer quantifizierbarer Korrelationen in der Beobachtung schwierig. Daher wurden weitere Untersuchungen vorgenommen, z. B. der Vergleich der Durchschnittstemperaturen, die während der einzelnen GWL vorherrschten.

Auf diese Weise konnte ein deutlicher Zusammenhang zwischen den GWL und den Temperaturen nachgewiesen werden, der in der Synthese durch die Verwendung von GWL größtenteils reproduziert werden konnte.

Insgesamt ergab sich als Ergebnis, dass die Verwendung von GWL in der Niederschlagsmodellierung mit dem verwendeten Modell zu nachweisbaren Verbesserungen führt. Der Aufwand der Implementierung der GWL in das Modell ist allerdings sehr hoch und die Anzahl der benötigten Modellparameter deutlich höher als bei einem Modell ohne Verwendung von GWL.

Einen weiteren wichtigen Gegenstand der Arbeit bildete die räumliche Übertragbarkeit der Modellparameter. Diese wird benötigt, um das Modell in Gebieten anzuwenden, in denen keine beobachteten Niederschlagsdaten vorhanden sind. Es wurde untersucht, ob das erprobte Vorgehen mit dem die Modellparameter ohne GWL transformiert wurden, auch mit dem an GWL angepassten Modell nutzbar ist. Es ergab sich, dass das Vorgehen mittels einiger Anpassungen gut einsetzbar ist.

Für die Modellierung zukünftiger Zustände wurde ursprünglich davon ausgegangen, dass die Transformation der GWL-Häufigkeit ausreichen würde um mit dem Modell zukünftige Zustände des Niederschlags abzubilden. Untersuchungen ergaben jedoch, dass dies nicht genügt. Dies liegt daran, dass sich nicht nur die Häufigkeiten der GWL mit der Zeit verändern, sondern auch die Eigenschaften der GWL. Eine Transformation der GWL-Häufigkeiten erklärte somit nur einen Teil der Veränderungen im Niederschlagsgeschehen. Daher wurden Ansätze zur Transformation der Modellparameter entwickelt. Der erfolgreichste Ansatz war eine Quantil-Quantil-Transformation der beobachteten Ereigniszeitreihe als Vorstufe für die Modellparameterbestimmung. Mit der Kombination von GWL-Auftretenshäufigkeits- und Ereigniszeitreihen-Transformation konnten somit zukünftige Zustände mit guten Ergebnissen modelliert werden. Als zusätzliche Eingangsdaten wurden unter anderem Daten aus Klimamodellen verwendet.

Schlagwörter: Niederschlag, Niederschlagsmodellierung, Hochwasserschutz

Abstract

The design and operation of many engineering purposes require outlet runoff data (e.g. of a river or channel). Due to the commonness of the absence of runoff observations, synthetic data is often generated via models. Input to these models is generally hourly and sub-hourly rainfall data. Ideally observed rainfall values are used. In many cases observed rainfall data is also unavailable and is thus replaced by synthetic data. As a rule, due to the high complexity of climatic processes, it is often impossible to run precise, physically-based, hourly precipitation models in cases where no observed data is available. The common way to solve this problem is the use of stochastic rainfall models.

It is common practice in many fields of stochastic modeling to attempt to cluster the input data. This means the data is divided into partial data sets that share common criteria. For decades, the regional climate in Europe has been recorded in the form of circulation patterns (CP). These CPs define a period in which a wide area (e.g. Europe) is dominated by certain specific patterns in the atmospheric pressure. These patterns determine the local climate. Given this it is a logical step to use CPs to cluster data used in precipitation modeling.

This work focuses on the generation of hourly precipitation data with a special focus on large events. This was accomplished by further developing a rainfall model based on the reproduction of precipitation events (an alternating-renewal-processes-model). This established model was adapted to use CPs and the influence of the CPs on the quality of the modeling of precipitation was assessed. Using the natural clustering capabilities of the CPs was expected to improve result quality. The plan was also that, by adapting the model to CPs and using climate model data as input, it would be possible to model future conditions. This is necessary since climate change is expected to influence precipitation patterns and thus needs to be addressed, e.g. in the meaningful application of model data (i.e. the synthetic rainfall data) in the design of buildings meant to stand a long time.

The impact of using CPs on other aspects of the modeling procedure was also analyzed. This analysis included, e.g., the regionalisation of model-parameters or the quality of the reproduction of the spatial correlations of the synthetic point value precipitation data. Another important aspect of the research was the influence of the CPs on the reproduction of the correlation of precipitation data and other climatic data (temperature and sunshine hours). This is of great significance since this data, combined with precipitation data, is often the basis of hydrological models.

Including CPs in the model improved the following aspects of the model:

- Reproduction quality of event characteristics (small improvement)
- Synthesis of yearly values
- Reproduction of extreme values in all interval lengths with the exception of hourly values

The correlations between precipitation and other climate variables were difficult to analyze since it wasn't possible to verify it in form of correlation coefficients. Therefore, other means of measurement were used, e.g., the mean temperature of the times dominated by each CP was taken as a measure. In this manner, it was possible to establish a more clear correlation between the temperature and the CP. This correlation was reproducible in the synthesis using CPs.

Considering CPs in the precipitation model led to significant advantages. Nevertheless the effort is high and the resulting model has a much higher number of parameters than the model not using CPs.

The transfer of the model parameters in space is another important aspect of this study. This step is necessary to use the model in places where no observed rainfall data is available. It was investigated whether the method that was successfully used to transfer the parameters of the model not using CP is also applicable in the model using CPs. The results showed that, after some changes, the method was well suited for this use.

In the initial approach it was assumed that considering the changes of the CPs frequencies in time (using the data of the climate-change model) would be sufficient for the modeling of future precipitation conditions. The assumption was that the changes in the precipitation are directly correlated to the occurrence frequencies of the CPs. But further analysis showed that not only the frequency of the occurrence of the CPs will change but also the characteristics of each CP. Thus a transformation of the occurrence of the CPs can only partially explain the changes in the precipitation. Because of this, methods of transforming the model parameters were developed. Most successful was a quantile-quantile transformation of the observed time-series of the rainfall events prior to the determination of the model parameters. Thus, a successful synthesis of precipitation data of future conditions was achieved through the combination of event-data transformation and CP-occurrence-frequency transformation.

Keywords: Precipitation, Rainfall Modeling, Flood Protection

1 Einleitung

1.1 Motivation

Der Niederschlag ist der wichtigste Bestandteil des Wasserhaushaltes. Erst der Niederschlag ermöglicht die Nutzbarmachung des Binnenlandes, indem er Grundwasser und Flüsse speist. Der Niederschlag entsteht aufgrund komplexer Abläufe und ist daher schwer vorhersehbar. Er kann auch extreme Ausprägungen annehmen, z. B. lange Trockenperioden oder auch große Niederschlagsmengen in einem kurzen Zeitraum. Daher sind Prognosen und Vorhersagen, die relevante Extremsituationen betreffen und damit präventive Maßnahmen ermöglichen, von großer Bedeutung. In den letzten Jahren hat sich der Bedarf an solchen Methoden aufgrund des akuten Klimawandels erheblich erhöht.

Durch Hochwasser, Überflutung oder Trockenheit gefährdete Bauwerke sind idealerweise anhand von Niederschlägen zu bemessen oder auszulegen, die über längere Zeit beobachtet wurden. Leider sind solche Messwerte für die meisten Gebiete nur in (für viele Anwendungszwecke) zu niedriger Auflösung oder zu kurzer Beobachtungsdauer verfügbar; für viele Gebiete sind sie gar nicht vorhanden. Daher wurden und werden zur Gewinnung synthetischer Niederschlagsdaten mannigfaltige Methoden entwickelt und angewendet. Mit diesen Daten können Bemessungen auch in Gebieten durchgeführt werden, deren Datenlage bzw. -auflösung beobachteter Niederschläge unzureichend ist.

Der Niederschlag ist ein Teil des Klimas. Seit Jahrzehnten wird das regionale Klima Europas in Großwetterlagen (GWL) klassifiziert. Diese geben einen Zeitraum an, in dem in einem Großraum (z. B. Europa) bestimmte Verhältnisse in der Luftdruckverteilung vorherrschen. Da auf diese Weise das Klima in bestimmte wiederkehrende klimatische Bedingungen unterteilt wird, liegt es nahe, die GWL für die Niederschlagsmodellierung zu verwenden.

Die vorliegende Arbeit beschäftigt sich mit der Generierung von Niederschlagsdaten mit Fokus auf großen Niederschlagsereignissen in einer Stundenwertauflösung. Diese sind für die Hochwasservorsorge von besonderer Bedeutung und können somit insbesondere für die Auslegung von Bauwerken verwendet werden. Dafür soll ein auf der Reproduktion von Niederschlagsereignissen basierendes Modell im Hinblick auf seine Eignung geprüft und weiterentwickelt werden.

Die durchzuführenden Untersuchungen sollen zum einem ein bestehendes, erprobtes Modell an GWL anpassen und deren Einfluss auf die Modellierungsqualität des Niederschlages analysieren. Durch die Unterscheidung des Niederschlages in natürliche Cluster soll eine Verbesserung der Modellgüte erzielt werden. Zum anderen soll mit der Anpassung des Modells an GWL und Klimamodelldaten die Modellierung zukünftiger Zustände ermöglicht werden. Letzteres ist in einem zeitgemäßen Niederschlagsmodell nötig, da aufgrund des Klimawandels Veränderungen im Niederschlagsgeschehen erwartet werden. Dies muss in der Auslegung von Bauwerken berücksichtigt werden.

1.2 Zielsetzung

Bei dem verwendeten Modell werden Zeitreihen von Niederschlagsereignissen generiert. Das Ziel dieser Arbeit ist es daher, die GWL für die Einteilung dieser Zeitreihen zu benutzen. Anhand der Clusterung der Niederschlagsereignisse durch die GWL soll eine differenziertere Analyse und Generierung der Niederschlagsdaten ermöglicht werden. Mit den GWL sollen gezielt Zeiträume mit einer hohen Niederschlagswahrscheinlichkeit getrennt von den Zeiträumen mit einer niedrigen Niederschlagswahrscheinlichkeit modelliert werden.

Somit kann es ermöglicht werden, mit den GWL realistischere und der Beobachtung stärker entsprechende Niederschlagsdaten zu gewinnen. Dieser Effekt soll untersucht, qualitativ festgestellt und, wenn möglich, quantifiziert werden.

Neben diesem Hauptziel soll der Einfluss der differenzierenden Wirkung der GWL auf andere Kenngrößen der Modellierung ermittelt werden, zum Beispiel auf die Regionalisierung des Modells oder die Verwendbarkeit des Modells für zukünftige Zustände. Ein weiterer wichtiger Aspekt hat sich erst während der laufenden Arbeiten als Ziel herausgestellt: die Untersuchung des Einflusses der Verwendung von GWL auf die Reproduktion des Zusammenhanges von Niederschlags- und Klimadaten (Temperatur und Sonnenscheindauer) in Beobachtung und Synthese. Dies ist relevant, da meist diese drei Datentypen Eingangsdaten von hydrologischen Modellen sind.

1.3 Umsetzung

Das verwendete Modell ist zweistufig. Im ersten Schritt werden unabhängige Punktdaten (im Weiteren „univariate Daten“ genannt) generiert. Im zweiten Schritt wird mittels eines Optimierungsalgorithmus den generierten Niederschlagsdaten der räumliche Zusammenhang der Beobachtung aufgeprägt.

Der univariate Teil des Niederschlagsmodells hat die Aufgabe, den intermittierenden Charakter des Niederschlags aus trockenen und nassen Zuständen zu reproduzieren. Mittels Verteilungsfunktionen werden die relevanten Ereignischarakteristika (*Nassdauer*, *Ereignisintensität* und *Trockendauer*) erfasst und reproduziert. Für das Modell wird jedem Ereignis eine GWL zugewiesen und für jede GWL werden separat die Verteilungsfunktionen angepasst. Bei der Generierung werden im ersten Schritt die Häufigkeiten der GWL in der univariaten Generierung reproduziert. Im zweiten Schritt werden die Daten mittels eines Optimierungsalgorithmus hinsichtlich Abfolge-Frequenz und Gleichzeitigkeit der GWL umstrukturiert. Falls mehrere Stationen generiert werden, optimiert derselbe Algorithmus die Daten gleichzeitig sowohl hinsichtlich des räumlichen Zusammenhanges als auch hinsichtlich der genannten GWL-Kriterien.

Die Validierung der Ergebnisse erfolgt primär anhand der Analyse der Parameter: *Extremwerte*, *Niederschlagsereigniskenngrößen*, *Jahressummen* und *Jahresereignisanzahlen*. Weiterhin werden weitere Kriterien wie räumlicher Zusammenhang, Abhängigkeiten von Klimavariablen, Autokorrelation und Saisonalität betrachtet.

Die Modellparameter werden mittels beobachteter Niederschlagsdaten bestimmt. Die Regionalisierung ist ein weiterer wichtiger Aspekt des Modells und ermöglicht seinen Einsatz in Gebieten ohne Niederschlagsbeobachtung. Der Fokus der Untersuchungen liegt auf dem Einfluss, den die GWL auf die Regionalisierung ausübt.

Im Rahmen der vorliegenden Dissertation wird ein Niederschlagsmodell vorgestellt und zu einem Niederschlags-Downscaling weiterentwickelt. Dies bedeutet, dass der Klimawandel mittels einer Transformation der Modellparameter berücksichtigt wird. Hierbei werden Daten aus einem globalen oder regionalen Klimamodell verwendet und das Klimasignal durch Koppelung des Niederschlagsmodells an das Klimamodell berücksichtigt. Hierbei soll auch der Einfluss der Änderungen der GWL-Häufigkeiten über die Zeit auf das Downscaling analysiert werden.

2 Relevante Arbeiten

Der erste Teil dieses Abschnittes behandelt die wichtigsten stochastischen Niederschlagsmodell-Typen. Anschließend wird auf Methoden der Großwetterlagendefinition und ihre Historie eingegangen. Eine Diskussion über unterschiedliche Downscaling-Modelle schließt den Abschnitt ab.

2.1 Stochastische Niederschlagsmodellierung

Mittels stochastischer Niederschlagsmodelle können Niederschlagsdaten generiert werden. Die aus der Literatur einschlägig bekannten Methoden haben unterschiedliche Zielsetzungen und methodische Herangehensweisen. So gibt es Modelle, die für kleinräumige Analysen univariate Punktdaten erzeugen, oder Modelle, die Flächendaten generieren, mit denen auch Modellierungen in großen Einzugsgebieten möglich sind. Es gibt Modelle, die nur an Punkten mit Beobachtungen neue Daten generieren können, und solche, die auch in Gebieten ohne Beobachtungen angewendet werden können. Die zeitliche Auflösung der generierten Niederschlagsdaten bildet ein weiteres wichtiges Modellmerkmal; die Variabilität ist hierbei wieder groß – von minutengenaue Auflösung (relevant z. B. für die Stadtentwässerung) bis hin zu Saison- und Jahressummen (relevant z. B. für die Landwirtschaft).

Dieser Abschnitt fokussiert sich auf Modelle, welche räumlich konsistente Punktdaten der Niederschlagsdaten in Stundenwertauflösung erzeugen. In diesem Zusammenhang wird von räumlicher Konsistenz gesprochen, wenn die synthetischen Punktniederschläge eine realitätsnahe Abhängigkeit zueinander aufweisen. Jedoch werden auch Modelle diskutiert, die andere Zielsetzungen haben. In der Regel sind dies Anfangs- und Zwischenstadien, die mittlerweile zu Modellen mit der gewünschten Zielsetzung geführt haben.

2.1.1 Alternating-Renewal-Modelle

Zur kontinuierlichen Generierung von Niederschlagszeitreihen werden *Alternating-Renewal-Processes*-Modelle (ARP-Modelle) erfolgreich eingesetzt und genießen hierbei große Beachtung.

Der ARP-Ansatz basiert auf der Synthese relevanter Ereignischarakteristika. Die Ereignisse bestehen aus *Nass-* und *Trockenperioden*. Diese Perioden werden, entsprechend der Bezeichnung der Modelle, alternierend generiert, aufgereiht und analysiert.

In den meisten Fällen werden die Trockenperioden durch ihre Dauer, die Nassperioden durch ihre Dauer und ihr Volumen definiert. Die Modelle generieren die Ereignisse mit stochastischen Ansätzen und enthalten meist auch ein Feinstrukturmodell zur Disaggregation, d. h. Zerlegung, der Nassereignisse in eine Darstellung mit kontinuierlichem Zeitschritt. In der Regel ist eine solche notwendig, da beobachtete Niederschlagsdaten in ebensolcher Form erfasst werden.

Erste Versuche zur Erstellung eines ARP-Modells gehen auf Green (1964) zurück, der sich auf das Erscheinen des Niederschlags konzentrierte und die Dauern der Perioden auf einer Exponentialverteilung basierend generierte. Eine Generierung der Ereignisvolumen erfolgte hier noch nicht. Auch eine weitere frühe Arbeit, Tsakiris (1988), generierte die Dauern der Nass- und Trockenperioden unter Vernachlässigung der Volumen und verwies auf Eagleson (1978), der grundlegende Untersuchungen von Niederschlagsereignissen vorgenommen hatte. Ziel der letztgenannten Arbeit war es, Häufigkeitsverteilungen von Jahresniederschlägen zu generieren, um die Varianz der Jahresniederschlagswerte genauer zu bestimmen. Restrepo-Posada & Eagleson (1982) ergänzten die Untersuchungen von Eagleson (1978) dadurch, dass sie ein Modell zur Separation der Niederschlagsereignisse entwickelten.

Unabhängig von diesen Arbeiten entwickelte Buishand (1978) ein ARP-Modell zur Generierung von Nass- und Trockendauern in Tageswertauflösung mit einer beschränkten negativen Binomialverteilung. Er verglich die Ergebnisse des Niederschlagsauftretens des ARP-Modells mit den Ergebnissen eines Markov-Ketten-Modells (siehe Abschnitt 2.1.4). Bei diesen recht simplen Modellen konnten allerdings nur geringe Unterschiede in der Güte der Ergebnisse festgestellt werden.

Croley et al. (1978) entwickelten ein ARP-Stundenwertmodell, bei dem die Trockendauern mit einer Exponentialverteilung, die Nassdauern und -volumen mit einer Lognormalverteilung generiert werden. Der Peak-Zeitpunkt wird mit einer an die Nassdauern bedingten logarithmischen Normalverteilung bestimmt; die weitere Struktur des Ereignisses wird über Niederschlagsprofile bestimmt. Auch Acreman (1990) betrachtete neben den Dauern der Ereignisse das Volumen und den zeitlichen Verlauf der Nassperioden. Hierfür verwendete er für die Ereignisdauern die Exponential- und die verallgemeinerte Pareto-Verteilung; die Nassvolumen generierte er mit einer an die Nassdauern bedingten Gammaverteilung. Mit einer Beta-Verteilung bestimmt das Modell mittlere Formen aller Regenereignisse für die Feinstruktur. Acreman (1990) diskutierte bereits den Einfluss unterschiedlicher Ereignis-Separierungsdauern, bezeichnete diesen Aspekt allerdings als unbedeutend. Er untersuchte ebenfalls die Autokorrelation der Ereignisse und die Korrelationen zwischen Nassdauern und -volumen. Er konnte allerdings eine Autokorrelation der Ereignisse nicht nachweisen, während die Korrelationen zwischen Nassdauern und -volumen eine sehr starke Signifikanz aufwiesen. Dieser Aspekt wurde durch spätere Untersuchungen bestätigt. So konnte De Michele (2003) den Zusammenhang von Nassdauern und -intensitäten mit einer 2D-Copula nachbilden.

Weitere Beiträge zu univariaten ARP-Modellen lieferten Marien & Vandewiele (1986) und Bernardara et al. (2007). Marien & Vandewiele (1986) entwickelten ein ARP-Modell, das mit Hilfe verschiedener Verteilungsfunktionen 10-minütliche Punktniederschläge generiert. Das von Bernardara et al. (2007) entwickelte Verfahren generiert das Niederschlagsauftreten mit einem ARP-Modell und die Niederschlagsintensitäten mit fraktionalem Gauß'schen Rauschen. Hiermit konnte der Einfluss der zeitlichen Skaleninvarianz berücksichtigt werden.

Franz (1970) entwickelte eines der ersten ARP-Modelle, welches auch die räumliche Konsistenz des Niederschlags betrachtet. Das relativ komplizierte Modell generiert die stündlichen Niederschlagswerte mit Hilfe einer multivariaten Normalverteilung. Die räumliche Konsistenz wird mit Hilfe eines Markov-Modells berücksichtigt. Die Trockendauern werden mit Hilfe von empirischen Verteilungen generiert.

Die Fortsetzung der Arbeiten zur räumlichen Analyse mit Hilfe von ARP-Modellen wurde deutlich später aufgenommen. Hutchinson (1995) diskutierte verschiedene Methoden zur räumlichen Interpolation von ARP-Modellparametern und zur konsistenten räumlich-zeitlichen Modellierung in verschiedenen Zeitschritten. Haberlandt (1998) entwickelte später ein Stundenwert-ARP-Modell, das mittels geostatistischer Methoden eine Übertragung der Modellparameter im Raum ermöglicht. Damit wird die Generierung von Niederschlägen an Orten möglich, an denen keine Beobachtungsdaten erfasst werden. Als Fortsetzung dieser Arbeiten entwickelten Haberlandt et al. (2008) ein Hybridmodell zur Erzeugung räumlich konsistenter Niederschläge. Dieses Modell besteht aus dem ursprünglichen ARP-Modell und einem nachgeschalteten Simulated Annealing-Algorithmus, welcher die Reihenfolge der synthetischen Niederschlagsereignisse entsprechend der räumlichen Konsistenz optimiert (siehe hierzu auch Abschnitt 7). Da die Zielfunktion der Optimierung in Abhängigkeit von der Entfernung der Stationen definiert wird, ist auch die Optimierung von modellierten Daten an Stellen ohne Beobachtungsdaten möglich.

Pegram & Clothier (2001) gingen einen etwas anderen Weg und verwendeten ein ARP-Modell, um eine „Perlschnur“ (string of beads) zu simulieren. Eine „Perle“ ist hierbei ein Zeitraum, in dem mehr als 1 % des Untersuchungsgebietes (64 km Radius einer Radarstation in Südafrika) einen Niederschlag größer 1 mm/h aufweist. Eingangsdaten sind hierbei die räumlichen Niederschlagsdaten der erwähnten Radarstation.

Jennings et al. (2010) entwickelten ein ARP-Modell, das in Kombination mit Scaling-Techniken an Stellen mit beobachteten Tageswertdaten die Generierung von hoch aufgelösten Daten (bis zu einer Auflösung von 6 Minuten) ermöglicht.

Eine weitere Anwendung eines ARP-Modelles stellten Ng & Panu (2010) vor. In dieser Arbeit verglichen sie mehrere Tageswert-Niederschlagsmodelle miteinander. Sie bezeichneten das ARP-Modell, gemeinsam mit einem Markovkettenmodell, als das Modell mit den besten Ergebnissen.

Abschnitt 5 enthält weitere Details, Modellvoraussetzungen und eine Darstellung der Grundstruktur des Modelltyps ARM anhand des in dieser Arbeit verwendeten Modells.

2.1.2 Disaggregation

Der Begriff *Disaggregation* bezeichnet das Aufteilen einer Gesamtgröße in Teilgrößen. In einem Untersuchungsgebiet sind im Normalfall signifikant mehr langjährig beobachtete Niederschlagsstationen in täglicher Auflösung verfügbar als in stündlicher oder minütlicher. Um diese Daten für eine Hochwassermodellierung nutzen zu können, ist eine Disaggregation auf Stundenwerte oder gar 5-Minuten-Werte wünschenswert. Das bedeutet, dass Niederschlagsdaten von einer niedrigen zu einer höheren Auflösung zu transformieren sind. Die ebenfalls vorhandenen Modelle zur räumlichen Disaggregation von Niederschlagsfeldern werden hier nicht diskutiert.

Unter den vorhandenen Disaggregations-Methoden finden die multiplikativen Kaskadenmodelle wohl die größte Beachtung. Bei diesen Modellen wird der Niederschlag schrittweise aufgespalten (siehe Schertzer & Lovejoy (1987) oder Gupta & Waymire (1993)). Bei einer zeitlichen Disaggregation erfolgt normalerweise eine mehrfache Halbierung. So wird der 24h lang gemessene Niederschlag in 12h-Teile aufgeteilt, anschließend in 6h-Teile usw. Es wird hierbei zwischen „canonical-“ und „micro-canonical-cascade“-Modellen unterschieden. Bei der ersteren Modellgruppe erfolgt lediglich ein Massenerhalt im Mittel über die Zeitreihe und bei der zweitgenannten ein exakter Massenerhalt. Als relevante „canonical“-Modelle sind Gaume et al. (2007) (unter Verwendung eines log-Poisson-Zufallsgenerators) oder Molnar & Burlando (2005) (mit einem intermittierenden Lognormal-Modell) zu nennen. Beide Modelle vergleichen „canonical“ und „micro-canonical“-Modelle und erzeugen hierbei 4- (bzw. 10-) Minuten-Daten für die urbane Hydrologie. Die „micro-canonical“-Modelle werden etwas häufiger verwendet. Neben den oben angeführten beiden Arbeiten sind hierbei besonders Olsson (1998), Güntner et al. (2001) (beide arbeiten mit Aufteilungs-Wahrscheinlichkeiten) und Cârsteanu et al. (1999) (arbeitet mit einer Wavelet-Transform-Methode) zu erwähnen. Menabde & Sivapalan (2000) verwendeten ein „micro-canonical“-Kaskadenmodell, um synthetische Niederschlagsereignisse zu disaggregieren.

Von ebenfalls großer Bedeutung sind Modelle, die ein bestehendes Niederschlagsmodell zur Synthese von hochaufgelösten Niederschlägen nehmen und dessen Ergebnisse mit beobachteten niedrig aufgelösten Niederschlägen abgleichen. Dies bedeutet, dass z. B. Stundenwertdaten so generiert werden, dass sie der Beobachtung entsprechende Tageswerte aufweisen.

Zu diesem Bereich gehören die Arbeiten Koutsoyiannis & Onof (2001) (mit der Zielgröße Stundenwerte), Cowpertwait et al. (2004) (mit der Zielgröße 5-Minutenwerte) und Connolly et al. (1998) (dieses Modell fokussiert sich auf eine korrekte Wiedergabe der Ereignisparameter). Alle drei genannten Modelle nutzen als Niederschlagsmodell ein auf der Poisson-Verteilung basierendes Modell.

Außer den erwähnten Modellen gibt es weitere einschlägige Modelle; einige der wichtigsten werden hier kurz angesprochen. Sivakumar (2001) entwickelte ein Disaggregationsmodell, welches sich der Chaostheorie bedient und prinzipiell den Scaling-Kaskadenmodellen entspricht. Somit steht es in direkter Konkurrenz zu diesen. Ein weiterer Ansatz, der einige Beachtung fand, ist die Verwendung von künstlichen neuronalen Netzen von Burian et al. (2000) zur Niederschlags-Disaggregation von Stunden- zu 15-Minuten-Werten. Guenni & Bárdossy (2002) entwickelten ein zweistufiges Modell zur Disaggregation von Monats- zu Tageswerten. Bei diesem werden zuerst mit einem auf einer beschränkten Normalverteilung basierenden Modell an Monatswerte bedingte Tageswerte generiert und die Werte anschließend mit einem Simulated-Annealing-Optimierungsverfahren entsprechend der beobachteten Autokorrelation, Scalingstruktur und Saisonalität restrukturiert. Ormsbee (1989) stellte eine der Pionierarbeiten der Niederschlags-Disaggregation vor, die mittels vier Verteilungsfunktionen Stunden- zu Minutenwertzeitreihen disaggregiert. Da in dem Modell nur der Zeitpunkt der höchsten bzw. niedrigsten Intensität innerhalb des Stundenwertes bestimmt wird, ist die Ausgabeauflösung hierbei variabel.

2.1.3 Punktprozessmodelle

Die Rechteckimpuls-Punktprozessmodelle bilden eine weitere Gruppe der Niederschlagsmodelle, bei denen der Zeitpunkt des Auftretens eines Niederschlagsereignisses mit Hilfe eines Poisson-Prozesses bestimmt wird. Jedem dieser Ereignisse wird eine Anzahl von Niederschlagszellen zugewiesen, welche die Form von Rechteckimpulsen mit Dauer und Intensität aufweisen. Die Werte der Dauer und Intensität werden im einfachsten Fall durch theoretische Verteilungsfunktionen bestimmt (siehe Rodriguez-Iturbe et al. 1987)). Hierbei können Überlagerungen der Niederschlagszellen entstehen. In diesem Fall werden die Intensitäten der sich überlastenden Ereignisse für den Zeitraum der Überlastung aufsummiert und bilden so ein Niederschlagsereignis.

Rodriguez-Iturbe et al. (1987) führten zwei unterschiedliche Methoden ein, welche die weitere Entwicklung der Punktprozessmodelle nachträglich prägten. Bei der ersten Methode, dem Neyman-Scott-Prozess, wird die Position des Auftretens der Niederschlagszelle mit Zufallszahlen bestimmt; bei der zweiten, dem Bartlett-Lewis-Prozess, dagegen das Intervall zwischen den Niederschlagszellen. Die Anzahl der Zellen wird ebenfalls mit Hilfe von Zufallsverteilungen bestimmt. Das Gesamtmodell kann gut anhand Abbildung 2-1 nachvollzogen werden.

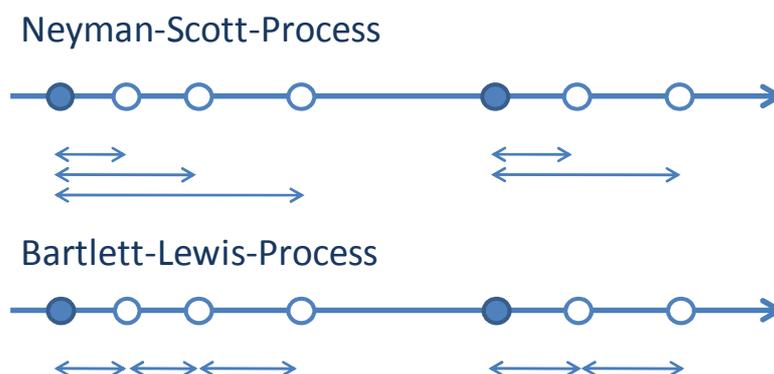


Abbildung 2-1 Punktprozessmodelle (nach Onof et al. (2000))

Dieser einfache Modellansatz wurde kontinuierlich weiterentwickelt. Bereits Rodriguez-Iturbe et al. (1988) führten eine Änderung des Modells ein, bei der mittels einer Zufallsvariablen Korrelationen zwischen den Dauern der Zellen eines Ereignisses erzeugt werden. In eine ähnliche Richtung zielte auch Entekhabi et al. (1989).

Cowpertwait (1994) verallgemeinerte die Form der Punktprozess-Methodik, indem er Zelltypen einführte. Die Intensitäten in dem Modell sind abhängig von den Zelltypen, und es besteht eine Korrelation zwischen Intensitäten und Dauern der Zellen. Weiterhin beschrieb Cowpertwait (1994) Methoden zur multivariaten Niederschlagsgenerierung mit Punktprozessmodellen.

In eine etwas andere Richtung stieß Cowpertwait (1998), indem ein Modell mit Fokus auf die Momente höherer Ordnung gezeigt wurde. Cowpertwait et al. (2004) und Cowpertwait (2006) entwickelten ein auf Punktprozessen basierendes Downscaling. Dies wird mittels einer „Versuch und Irrtum“-Akkumulation der generierten Zellen durchgeführt. Das Verfahren ist in den erwähnten Arbeiten anhand guter Grafiken anschaulich dargestellt.

Olsson & Burlando (2002) untersuchten die Reproduktion des Scaling-Verhaltens des Niederschlags in den Ausgabedaten des Modells.

Im Allgemeinen wurden bei den frühen Analysen zu den Punktprozess-Modellen Dauer und Intensität der Ereignisse als unabhängig voneinander angesehen. Da aber in verschiedenen Studien eine Abhängigkeit dieser Parameter festgestellt wurde (siehe auch Abschnitt 2.1.1), führten Evin & Favre (2008) eine Methode ein, bei der die Abhängigkeiten mittels Copula-Funktionen berücksichtigt werden.

Guenni & Hutchinson (1998) präsentierten eine Methode zur räumlichen Interpolation von Modellparametern der Punktprozessmodelle. Onof et al. (2000) und später Cowpertwait (2006) und Burton et al. (2008) entwickelten mehrere multivariate Punktprozessmodelle.

2.1.4 Zeitreihenmodelle

Zur Generierung von Niederschlagsdaten verwendet eine Gruppe von Modellen Methoden der Zeitreihenanalyse. Hier werden die wichtigsten dieser Methoden vorgestellt.

Markov-Ketten stellen eine einfache Form der Zeitreihenmodelle dar. Bei diesen Modellen wird mit Übergangswahrscheinlichkeiten aus einem Zeitschritt der nächste gebildet. Je nach Ordnung der Markov-Kette werden hierbei vorangegangene Zeitschritte berücksichtigt.

Die Vorgehensweise wird nachfolgend kurz mit der Terminologie von Haan et al. (1976) vorgestellt.

Eine Markov-Kette mit $c+1$ Zuständen ist gegeben durch die Eigenschaft, dass der Modellzustand sich aus den vorangegangenen Zuständen ergibt:

$$P(E_{n,j}|E_{n-1,j_{n-1}}, \dots, E_{1,j_1}) = P(E_{n,j}|E_{n-1,j_{n-1}}) \quad (2-1)$$

Mit: $E_{i,j}$ - Zustandsvariablen, z. B. Tagesniederschläge

$i=1, 2, \dots$, und $j = 0, 1, \dots, c$

$P(x|y)$ - Wahrscheinlichkeit von x in Abhängigkeit von y

Für den Fall, dass die Kette nicht von n abhängt, entsteht eine *stationäre* Markov-Kette. Die sich bildenden Wahrscheinlichkeiten p_{ij} , können in einer $(c+1)*(c+1)$ -Matrix zusammengefasst werden.

Für ein Modell des Niederschlagsauftretens ergibt sich mit einer $2*2$ -Matrix:

$$(p_{11}, p_{01}, p_{10}, p_{00}) \quad (2-2)$$

mit p_{xy} : Wahrscheinlichkeit, dass auf Zustand x Zustand y folgt (1-nass, 0-trocken)

Die Übergangswahrscheinlichkeiten werden anhand einer beobachteten Niederschlagsreihe ermittelt. In unserem Beispiel:

$$\begin{aligned} p_{11} &= n_{11}/(n_{10}+n_{11}) & p_{10} &= n_{10}/(n_{10}+n_{11}) \\ p_{01} &= n_{01}/(n_{01}+n_{00}) & p_{00} &= n_{00}/(n_{01}+n_{00}) \end{aligned} \quad (2-3)$$

Die Summe aller Wahrscheinlichkeiten eines Zustandswechsels müssen 1 ergeben. In unserem Beispiel also müssen z. B. die Wahrscheinlichkeiten, dass auf einen nassen Tag ein trockener Tag oder ein nasser Tag folgt, in Summe 1 sein.

Gabriel & Neumann (1962) verwendeten eine Markov-Kette zur Modellierung des täglichen Niederschlagsauftretens. Hierbei gelang es, das Auftreten und den Zyklus des Wetters wiederzugeben. Die Monate wurden separat voneinander modelliert, um die Saisonalität zu erfassen. Chin (1977) verwendete ebenfalls eine Markov-Kette zur Simulierung des täglichen Niederschlagsauftretens an verschiedenen Orten der USA. Hosseini et al. (2011) entwickelte ein Markov-Ketten-Modell zur Bestimmung des Niederschlagsauftretens mit Fokus auf Trockenzeiten. Es wurden Modellvarianten entwickelt, welche die Temperaturdaten, die Saisonalität und das Niederschlagsauftreten mehrerer vorangegangener Tage als zusätzliche Eingangsgröße verwenden.

Ein Markov-Modell *n-ter Ordnung* berücksichtigt *n* vorangegangene Zeitschritte in den Wahrscheinlichkeiten. Pattison (1965) entwickelte ein Markov-Modell 6. Ordnung zur Modellierung von stündlichen Niederschlagswerten, wobei der Niederschlag hierfür in 20 Klassen eingeteilt wurde.

Haan et al. (1976) entwickelten ein Modell zur Generierung von Tagesniederschlägen für jeden Monat durch eine Markov-Kette mit einer Transformationsmatrix von 7*7 Feldern. Die generierten Tageswerte können neben trockenen Tagen 6 verschiedene Volumengrößen aufweisen.

Raudkivi & Lawgun (1970) entwickelten ein Modell für Niederschlagswerte in 10-minütiger Auflösung, bei dem das Niederschlagsaufkommen mit einer Markov-Kette und die Volumen durch Sampling mittels einer Weibull-Verteilung bestimmt werden. Lennartsson et al. (2008) entwickelten ein Modell, das ebenfalls eine Markov-Kette für die Bestimmung des Auftretens verwendet. Zur Bestimmung der Volumen wird für kleine Mengen die empirische Verteilung verwendet und für große Mengen eine verallgemeinerte Pareto-Verteilung. Um die zeitlichen Abhängigkeiten berücksichtigen zu können, kommt hierbei auch eine Copula-Funktion zum Einsatz.

Ein weiterer relevanter Typ der Zeitreihenmodelle sind die „Autoregressive Moving Averages“-Modelle (ARMA). Die Terminologie der folgenden Formeln wurde angelehnt an Box et al. (2008). ARMA-Prozesse bestehen aus zwei Teilen. Zum einen aus einem „Moving Average“ (MA) und zum anderen aus dem autoregressiven (AR) Modellteil.

Ein stationärer MA-Prozess q-ter Ordnung wird mit einem weißen Rauschen ε_t und den Parametern $\theta_1, \dots, \theta_q$ gebildet, wobei für alle $t \in \mathbb{Z}$ gilt:

$$y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}, \text{ mit } \mu - \text{Mittelwert} \quad (2-4)$$

Den zweiten Teil des Modells bildet der AR-Teil, der die nähere Vergangenheit in die Modellierung einfließen lässt. Ein AR-Modell p-ter Ordnung wird mit den Parametern ϕ_1, \dots, ϕ_p und der Konstante δ gebildet:

$$y_t = \delta + \phi_1 \cdot y_{t-1} + \phi_2 \cdot y_{t-2} + \dots + \phi_p \cdot y_{t-p} + \varepsilon_t \quad (2-5)$$

In Kombination bilden diese beiden Prozesse ein ARMA(p,q)-Modell:

$$y_t = \delta + \sum_{i=1}^p (\phi_{t-i} \cdot y_{t-i}) + \varepsilon_t - \sum_{i=1}^q (\theta_i \cdot \varepsilon_{t-i}) \quad (2-6)$$

Burlando et al. (1993) führten ein ARMA-Modell zur Kurzzeit-Vorhersage von stündlichen Niederschlagsdaten ein. Sie entwickelten hierzu eine kontinuierliche und eine ereignisbasierte Methode zur Parameterschätzung. Die kontinuierliche Methode beinhaltet alle Werte, inklusive der Nullwerte, während die ereignisbasierte ausschließlich positive Niederschlagswerte berücksichtigt. Es ergab sich, dass der kontinuierliche Ansatz deutlich schlechtere Ergebnisse lieferte als der ereignisbasierte.

Chang et al. (1984) wendeten ein binäres diskretes ARMA-Modell (B-DARMA) an. Das Modell basiert auf den von Jacobs & Lewis (1978a) und Jacobs & Lewis (1978b) entwickelten Modellen. DARMA-Modelle stellen eine Verallgemeinerung des ARMA-Modells dar, bei dem eine lineare Transferfunktion verwendet wird. Hierdurch wird es möglich, Nass-Trocken-Sequenzen zu generieren.

Dalezios & Adamowski (1995) verwendeten ein Space Time Autoregressive Moving Average-Modell (STARMA), bei dem mit einem räumlichen Verzögerungsfaktor (lag) eine räumlich-zeitliche Niederschlagsgenerierung in einem 15-tägigen Zeitschritt ermöglicht wird.

Zu den neueren Arbeiten gehören zwei Fallstudien: Momani (2009), der die Anwendung eines ARIMA-Modelles in Jordanien präsentierte, und Abdul-Aziz et al. (2013), die ein saisonales ARIMA-Modell in Ghana anwendeten, um Niederschlagsmuster vorherzusagen.

2.1.5 Sonstige Modelle

Neben den in den vorangegangenen Abschnitten besprochenen sind noch einige andere Modelle der Niederschlagssynthese für diese Arbeit relevant.

Bárdossy (1998) verwendete einen Simulated Annealing Optimierungs-Algorithmus zur Synthese von Stunden- und 5-Minuten-Niederschlagsreihen. Das Modell arbeitet in zwei Schritten. Im ersten Schritt wird mit einem einfachen Modell, z. B. über eine Verteilungsfunktion, eine Niederschlags-Grundgesamtheit erzeugt. Im zweiten Schritt wird diese den gewünschten Zielkriterien entsprechend (z. B. Autokorrelation, Scaling-Faktoren, Ereignisdauern etc.) anhand eines Resamplings optimiert. So kann eine Zeitreihe erzeugt werden, welche die gewünschten Eigenschaften hat. Unter anderem hat dieses Modell in Deutschland zur Entwicklung des Modells NIEDSIM (siehe Bárdossy & Brommundt (2008)) geführt, welches vom Bundesland Baden-Württemberg zur Bereitstellung repräsentativer Niederschlagsreihen für die Wasserwirtschaft genutzt wird.

Teegavarapu et al. (2009) stellten eine auf genetischen Algorithmen basierende Methode zur Generierung von Tageswert-Niederschlagsdaten vor, wobei Daten benachbarter Stationen verwendet wurden. In vielerlei Hinsicht ähnelt dieses Vorgehen einer Interpolation.

2.2 Großwetterlagen

Baur (1963) definierte Großwetterlagen (GWL) als „die mittlere Luftdruckverteilung eines Großraumes, mindestens von der Größe Europas während eines mehrtägigen Zeitraumes, in welchem gewisse Züge aufeinander folgender Wetterlagen gleich bleiben, eben jene Züge, welche die Witterung in den einzelnen Teilgebieten des Großraums bedingen.“

Einzug in die deutsche Meteorologie nahmen GWL bereits in den vierziger Jahren in Form von GWL-Katalogen (siehe Baur et al. (1944)). Diese Klassifizierungen überarbeiteten und führten Hess & Brezowsky 1952, 1969 und 1977) fort, welche stets aktualisiert und gepflegt werden (Werner & Gerstengarbe 1999 und 2010)). Diese Arbeiten enthalten detaillierte Erläuterungen der verwendeten, zum Teil subjektiven Klassifizierungskriterien, eine Diskussion aller ermittelten GWL-Klassen und einen taggenauen GWL-Katalog, beginnend im Jahr 1881.

Die Definition der GWL erfolgt anhand der geographischen Lage der Steuerungszentren und der Zirkulationsform, was in der Regel auch die Namen dieser Klassen bestimmt, z. B. Westlage (zyklonal) oder Hoch Nordmeer-Inland (antizyklonal). Die zyklonale Rotation wird jedoch nur angegeben, wenn die entsprechende GWL sowohl zyklonalen als auch antizyklonalen Witterungscharakter aufweisen kann.

Neben dieser klassischen Klassifikation gibt es noch verschiedene weitere subjektive Einteilungen. Erwähnenswert ist zum Beispiel die Arbeit von Lamb (1950), der die GWL für die britischen Inseln katalogisierte und publizierte. Auch dieser Katalog wird weiterhin aktualisiert, zuletzt durch Jones et al. (2013). Eine umfangreiche Übersicht der subjektiv klassifizierten GWL ist zum Beispiel Key & Crane (1986) zu entnehmen. Eine etwas neuere Übersicht über bedeutende subjektive Klassifikationsmethoden findet sich in Huth et al. (2008).

Deutlich später kam der Ansatz hinzu, die bisherigen Klassifizierungsmethoden zu automatisieren. Jones et al. (1993) führten hierfür ein Punktesystem ein, um die Lamb-GWL nachzubilden. Dafür werden Gitterpunkten über Europa entsprechend dem Luftdruck bestimmte Punktwerte zugewiesen. Über das Verhältnis der Punkte zueinander wird dann die vorherrschende GWL bestimmt. Anwendungsfälle dieses Verfahrens finden sich z. B. in Buishand & Brandsma (1997) oder Linderson (2001). Diese Methode wurde kürzlich von Jones et al. (2013) angewendet. Einen ähnlichen Ansatz, gekoppelt mit einer Korrelationsanalyse (auch *Musterkorrelationsanalyse* genannt), verwendete James (2007), um die GWL nach Hess und Brezowsky automatisch nachzubilden.

Bárdossy et al. (1995) stellten ein vielbeachtetes, auf Fuzzy-Regeln basierendes objektives Verfahren zur Definition von GWL vor. Das Verfahren kann, unabhängig von subjektiven Katalogen, die GWL entsprechend frei wählbarer Zielkriterien optimiert klassifizieren. Dieses Verfahren kann unter anderem für die Niederschlagssimulation benutzt werden, um zum Beispiel besonders regenreiche GWL von besonders trockenen zu unterscheiden. Bárdossy et al. (2002) und Bárdossy (2010) führten verbesserte Zielfunktions- und Validierungselemente ein. Bárdossy & Filiz (2005) erweiterten die Zielfunktionen des Fuzzy-Regelsystems um Parameter des Abflusses. So können die GWL, die potentiell Hochwasser hervorrufen, direkt identifiziert werden. Die GWL werden jeweils für Europa (Druckdaten) mit Fokus auf Deutschland (Niederschlagsdaten) bzw. Südwesteuropa (Abflussdaten) erstellt. Für Weiteres zur Methodik der Klassifikation wird auf Abschnitt 4 verwiesen. Dort wird das Modell detailliert diskutiert. Einen Anwendungsfall in den USA stellten Özelkan et al. (1998) vor.

Ein neuerer Ansatz zur objektiven Klassifizierung der GWL in Frankreich für großräumige Regenfelder wurde von Garavaglia et al. (2010) vorgestellt, und zwar basierend auf einem Gradienten-Vergleich der Druckfelder. Dieses Modell verwendet ebenfalls ein Punktesystem und ist somit ähnlich wie das Modell nach Jones et al. (1993) strukturiert.

Buishand & Brandsma (1997) verglichen die nach Jones et al. (1993) bestimmten GWL mit den subjektiven Lamb-GWL und mit GWL, die mit einem Eigenvektorverfahren objektiv erstellt wurden. Ziel der Arbeit war, neben dem Vergleich, die Bestimmung des Einflusses der GWL auf die Vorhersagbarkeit von Niederschlag und Temperatur. In der Arbeit wurde festgestellt, dass für den Tageswert-Niederschlag 15 bis 30 % der Varianz durch die GWL erklärt werden. Das Verfahren nach Jones et al. (1993) erzielte hierbei etwas bessere Ergebnisse. Andere Studien, z. B. Bárdossy et al. (1995), Wilby et al. (1995) oder Garavaglia et al. (2010), wiesen ebenfalls nach, dass ein signifikanter Anteil des Niederschlagsverhaltens durch GWL erklärt werden kann. Wilby et al. (1995) merkten an, dass dieses Verhalten sowohl auf der mesoskalen Ebene als auch, wenn auch schwächer, auf der Stationsebene zu beobachten ist.

Aus diesem Grund war die Verwendung der GWL für die Niederschlagsmodellierung ein natürlicher Schritt, was von Bárdossy & Plate (1991) frühzeitig erkannt wurde. In dieser Arbeit wurde ein Markovketten-Modell vorgestellt, welches das Niederschlagsvorkommen generiert, gekoppelt mit Großwetterlagen. Die Arbeit wird in Bárdossy & Plate (1992) fortgeführt, wobei ein räumlich-zeitliches multivariates autoregressives Tageswert-Niederschlagsmodell verwendet wurde. Eingangsdaten für die Parametrisierung waren die GWL nach Hess und Brezowsky. Hierbei wurde auch die räumliche Gleichzeitigkeit des Niederschlages analysiert und ein deutlicher Einfluss der GWL festgestellt. Bogardi et al. (1993) verwendeten das Modell in abgewandelter Form in den USA. Hierbei kamen GWL zum Einsatz, die mit einem k-Means-Algorithmus objektiv klassifiziert wurden. Dadurch konnten Erkenntnisse bestätigt werden, die bei in Deutschland durchgeführten, vorangegangenen Arbeiten gewonnen wurden. Stehlík & Bárdossy (2002) setzten die Arbeiten von Bárdossy & Plate (1992) mit einem angepassten Modell fort. In dieser Arbeit kamen nicht die GWL nach Hess und Brezowsky zum Einsatz, sondern die objektiv nach Bárdossy et al. (2002) klassifizierten. Dies ermöglicht den Einsatz von GWL, die mit Daten aus globalen Klimamodellen (GCM, General Circulation Model, siehe Abschnitt 2.3) generiert werden. Es wurden jedoch ausschließlich mit Beobachtungsdaten klassifizierte GWL verwendet; eine Extrapolation in die Zukunft erfolgte hier also noch nicht.

In Bárdossy & Brommundt (2008) und Brommundt (2008) dienten GWL als wertvolle Zusatzinformation zur Feststellung der wahrscheinlichsten Zugrichtung von Niederschlagsfeldern. Beersma & Buishand (2003) gingen einen direkteren Weg und verwendeten Indizes der Zirkulation (gebildet aus Stärke und Zugrichtung der Strömungen und Wirbel) erfolgreich als Information zu einem Nearest-Neighbour-Sampling des Tageswert-Niederschlags. An weiteren Arbeiten ist noch Schubert (1994) zu erwähnen, der ein Markovketten-Niederschlagsmodell an nach Hess und Brezowsky klassifizierte GWL gekoppelt hat.

Bereits 1990 haben Bárdossy & Caspary (1990) anhand der Arbeiten von Hess und Brezowsky GWL-Analysen vorgenommen, um zu sehen, inwieweit der Klimawandel durch GWL abgebildet werden kann. Hierbei konnte ein Wandel in den Häufigkeiten der GWL sowie ein deutlicher Zusammenhang zwischen GWL und Niederschlagsvorkommen nachgewiesen werden. In Kombination ist dies ein erster deutlicher Hinweis darauf, dass GWL-Untersuchungen für das Niederschlags-Downscaling besonders hilfreich sein können. Matyasovszky et al. (1993) wendeten die unter Bogardi et al. (1993) beschriebene Klassifikations-Methode auf Daten eines GCM an. Bei der Analyse fanden sie einen Wandel in den GWL-Häufigkeiten, verknüpften diesen mit der Tageswert-Niederschlagsmodellierung und generierten so veränderte Niederschlagsdaten. Die Arbeiten wurden unter Hinzunahme eines weiteren GCM in Matyasovszky et al. (1994) fortgeführt.

Ein Downscaling macht die Ausgabedaten der GCM nutzbar für verschiedene praktische Anwendungszwecke auf lokaler Skala. Abschnitt 2.3 enthält eine Diskussion darüber, wie ein Downscaling mit Hilfe von GWL durchgeführt werden kann. Dort werden auch die Ergebnisse der Untersuchungen bzgl. des Einflusses der GWL auf das Downscaling vorgestellt.

Corte-Real et al. (1999) erstellten ein an GWL gekoppeltes Markov-Ketten-Tageswert-Niederschlagsmodell. Sie verwendeten zur Definition der GWL ein k-mean-Clusteringverfahren (siehe Corte-Real et al. (1998)) und Luftdruckdaten des Kontrolllaufs eines GCM (HADCM2). Die Untersuchungen ergaben, dass für die Vergangenheit GCM-Daten durchaus für die GWL-Klassifikation verwendet werden können. Weiterhin stellten die Autoren fest, dass ein Downscaling von GCM-Prognosedaten möglich ist, wenn der Zusammenhang zwischen GWL und Niederschlag in der Zukunft gleichbleibt.

Wetterhall et al. (2009) führten ein Downscaling von Niederschlags-Tageswerten mit einem autoregressiven Niederschlagsmodell durch, das an nach Bárdossy et al. (2002) mit GCM-Daten klassifizierte GWL und den Feuchtefluss (ein aus der Kombination aus Windgeschwindigkeit und Luftfeuchtigkeit gebildeter Parameter) gekoppelt wurde. Die festgestellten Veränderungen für die Zukunft wurden in der Arbeit eher auf die Veränderungen in der spezifischen Feuchte zurückgeführt als auf die sich verändernden GWL-Häufigkeiten. Yang et al. (2010) verwendeten ebenfalls GWL und Feuchtefluss für das Niederschlags-Downscaling. Hierbei stellten sie fest, dass der Feuchtefluss hinsichtlich des Niederschlagsauftretens einen großen Einfluss auf die GWL hat.

Bárdossy & Pegram (2011) verwendeten GWL, um Quantile-Quantile-Transformationen (eine kurze Erläuterung erfolgt in Abschnitt 2.3) zwischen beobachteten Niederschlagsdaten und solchen aus Klimamodellen zu definieren. Hierbei stellten die Autoren fest, dass die Verwendung der GWL einen merklich positiven Einfluss auf die Wiedergabe der räumlichen Muster des Niederschlags in den synthetischen Daten hat. Auch für Gebietsmittel des Niederschlages konnte durch Verwendung von GWL eine leichte Verbesserung gegenüber der Verwendung einer Quantile-Quantile-Transformation ohne GWL erzielt werden.

Goodess & Jones (2002) untersuchten den Zusammenhang von GWL und Änderungen der Niederschlagscharakteristika in den Jahren 1958 bis 1997. Sie verwendeten hierbei die Klassifizierungsmethode nach Jones et al. (1993). Auch in dieser Studie konnte ein deutlicher Zusammenhang zwischen Niederschlagscharakteristika und GWL festgestellt werden. In der Trenduntersuchung stellten sie fest, dass Änderungen im Niederschlagsvorkommen und -volumen nicht speziellen GWL zugeordnet werden konnten, sondern quer über alle GWL hinweg vorkommen. Die Autoren stellten weiterhin fest, dass die Veränderungen nicht allein durch die GWL erklärt werden können. Schließlich erläuterten sie, dass die gleichen GWL in verschiedenen Jahreszeiten unterschiedlichen Einfluss auf den Niederschlag haben.

Haberlandt et al. (2011) führten ähnliche Untersuchungen an den nach Bárdossy (2010) klassifizierten GWL durch. Auch in dieser Studie konnte ein eindeutiger Zusammenhang zwischen der GWL und Niederschlagscharakteristiken nachgewiesen werden. Die Autoren betrachteten die Gebietsniederschläge und den Feuchteindex (siehe Abschnitt 4). Sie stellten hierbei fest, dass die Veränderungen im Wesentlichen über alle GWL hinweg einheitlich sind. Daraus folgerten sie, dass die GWL alleine die Änderungen im Niederschlag nicht erklären können. Dies bedeutet, dass die Wiedergabe der Änderungen der GWL-Häufigkeiten alleine nicht für ein Niederschlags-Downscaling genügt.

2.3 Methoden zum Niederschlags-Downscaling

Es gilt als gesichertes Wissen, dass sich das Klima im Laufe der Zeit wandelt (siehe IPCC (2007)). Um diesen Prozess zu erfassen, wurden verschiedene Klimamodelle entwickelt (ECHAM, COSMO Climate Local Model, LAM Aladin und weitere). Die Daten aus diesen globalen Klimamodellen (GCM) sind für viele Anwendungszwecke allerdings nicht direkt verwendbar. Insbesondere bei hydrologischen Fragestellungen eignen sich die Daten der Klimamodelle nicht als Eingangsgrößen der Niederschlag-Abfluss-Modelle, da sie nur in sehr groben räumlichen und teilweise auch zeitlichen Auflösungen vorliegen. Aus diesem Grund wurden in den letzten Jahren verschiedene Downscaling-Modelle entwickelt.

Dabei kristallisierten sich zwei Ansätze als Hauptrichtungen heraus. Bei den *dynamischen Modellen* werden Klimadaten in höherer Auflösung mittels numerisch abgebildeter physikalischer Prozesse und der Daten der Klimamodelle erzeugt. Diese Modelle werden oft als *regionale Klimamodelle* (RCM) bezeichnet.

Die *statistischen Modelle* nutzen für die Gewinnung der notwendig hoch aufgelösten Eingabedaten der hydrologischen Modelle einen statistischen Bezug zwischen Variablen der globalen Modelle, z. B. Niederschlag in großen Gebieten, und den gesuchten lokalen Variablen, z. B. Punktniederschlag auf der Oberfläche. Oft werden hierfür existierende Niederschlagsmodelle angepasst, sodass diese das Klimaänderungssignal mittels Bedingung an die Klimamodelle berücksichtigen. Ein dritter Ansatz ist gegeben durch die Kombination beider Modelltypen, wobei hier der Übergang zur Bias-Korrektur der RCM fließend ist. Eine Übersicht ist in Abbildung 2-2 zu finden. In der Grafik wird gezeigt, wie aus den Klimamodell- und den beobachteten Klimadaten mit verschiedenen Methoden ein Downscaling durchgeführt werden kann, sodass hieraus herunterskalierte Klimamodell- und Beobachtungsdaten gewonnen werden können.

Aufgrund der hohen Dynamik und der großen Anzahl an Veröffentlichungen wird sich darauf beschränkt, ohne Anspruch auf Vollständigkeit, einen Ausschnitt der für diese Arbeit wichtigsten statistischen Downscaling-Modelle zu geben.

Statistische Downscaling-Modelle können explizit auf den gewünschten Zielparameter optimiert werden, was ein großer Vorteil ist. So ist es möglich, das in GCM häufig vorhandene Problem eines systematischen Fehlers (Bias) zu eliminieren. Außerdem ist bei statistischen Modellen in der Regel der Rechenaufwand wesentlich geringer als bei dynamischen Modellen. Somit erlauben diese Modelle viele Durchgänge und auch eine Unsicherheitsanalyse mit gängigen Methoden, was bei dynamischen Downscaling-Modellen in der Regel deutlich aufwendiger zu realisieren ist. So existieren für das in Deutschland weit verbreitete REMO-Modell (siehe Jacob et al. (2008)) aktuell nur drei Modelldurchläufe, während statistische Modelle in der Regel problemlos dutzende oder gar hunderte Modelldurchläufe ermöglichen.

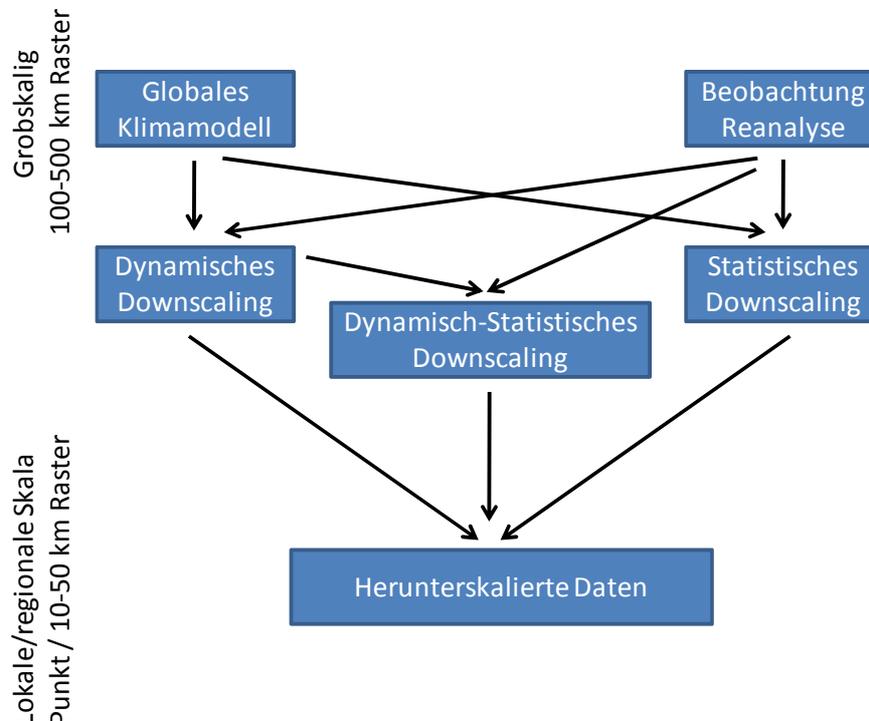


Abbildung 2-2 Niederschlags-Downscaling – schematische Darstellung der verschiedenen Methoden

Wilby et al. (1998) und Wilby et al. (2004) gaben gute Übersichten zu den zum jeweiligen Zeitpunkt vorliegenden Ansätzen. Wilby et al. (2004) unterteilten die statistischen Downscaling-Modelle in drei Klassen: Wettertypmodelle, Wettergeneratoren und Regressionsmodelle.

Als Beispiele für Wassertypmodelle sind Fuzzy-Modelle oder Monte-Carlo-Methoden zu nennen. Wettergeneratoren sind beispielsweise Markov-Ketten, stochastische oder Ereignisdauermodelle. Regressionsmodelle können mittels einer linearen Regression, aber auch mit künstlichen neuronalen Netzen oder Kriging-Methoden konstruiert und analysiert werden.

Die Wassertypmodelle haben einen indirekten physischen Bezug und sind auf verschiedene Wettervariablen anwendbar. Damit können sie unter Umständen den Zusammenhang der verschiedenen Klimatypen erfassen. Allerdings sind sie unempfindlich für zukünftige Klimaänderungen. Die Wettergeneratoren hingegen können Ensembles für die Unsicherheitsanalyse generieren und räumliche Strukturen berücksichtigen. Allerdings erfordern sie eine willkürliche Anpassung der Parameter zur Erfassung von zukünftigen Klimaänderungen, und diese könnten sich daher auf unerwartete Weise auf weitere Niederschlagscharakteristika auswirken. Die Regressionsmethoden hingegen können alle Prognosevariablen berücksichtigen, aber sind schlecht in der Wiedergabe der Varianz und Extremwerte. Weitere Details hierzu sind Wilby et al. (2004) zu entnehmen.

Bei der Verwendung der Daten der globalen, aber auch der regionalen Klimamodelle hat sich herausgestellt, dass diese oft einen systematischen Fehler (Bias) aufweisen. Aus diesem Grund ist die Korrektur dieses Fehlers (*Bias-Korrektur*) mittlerweile ein wichtiger Aspekt der Downscaling-Modelle. Hierzu wird auf die Literatur verwiesen, z. B. Piani et al. (2010).

Chen et al. (2012b) wiesen auf einen weiteren wichtigen Aspekt hin: In der hydrologischen Modellierung bei Verwendung von Daten verschiedener GCMs und verschiedener Downscaling-Modelle entstehen signifikante Unterschiede. Nach heutigem Stand des Wissens sollten daher, bevor eine Aussage zu zukünftigen hydrologischen Systemzuständen getroffen wird, neben der Verwendung mehrerer Klimaszenarien auch weitreichende Unsicherheitsanalysen durchgeführt werden (unter Verwendung mehrerer GCM und verschiedener Downscaling-Modelle, idealerweise mit mehreren Modellläufen).

An dieser Stelle werden noch einige der neueren Studien kurz vorgestellt. Einen guten Einstieg ins Thema bieten Jacob et al. (2001), welche sieben statistische Modelle zum Downscaling von GCM-Daten verwendeten, und zwar Regressionsmodelle, Resamplingmodelle, skalierende Modelle und eine Quantile-Quantile-Transformation (eine kurze Erläuterung erfolgt weiter unten noch in diesem Abschnitt). Chen et al. (2012a) verglichen verschiedene Modelle mit Fokus auf Unsicherheitsanalyse. Zum Einsatz kamen unterschiedliche Modelle, z. B. basierend auf Änderungsfaktoren, Markov-Ketten und Regressionmethoden. Chen et al. (2011) führten außerdem eine Methode ein, bei der mit zwei Regressionsmodellen dynamisch-statistische Modelle gebildet werden, wobei das Klimaänderungssignal aus einem dynamischen Downscaling-Modell gewonnen wird.

Gudmundsson et al. (2012) stellten mehrere dynamisch-statistische Downscaling-Modelle vor: eine Quantile-Quantile-Transformation, weiterhin regressionsbasierte Methoden und zuletzt zwei nicht-parametrische Methoden (eine auf empirischen Verteilungen basierende und eine nicht-parametrische Regression). Es wurden die nicht-parametrischen Methoden und die Quantile-Quantile-Transformation favorisiert, allerdings konnte in der Arbeit auch mit den anderen vorgestellten Methoden ein erfolgreiches Downscaling ermöglicht werden.

Bárdossy & Pegram (2011) verwendeten eine Quantile-Quantile-Transformation für ein dynamisch-statistisches Downscaling. Dieses auch Quantile-Mapping oder Quantile-Transformation genannte Verfahren kann zur Korrektur eines Bias in einer Grundgesamtheit verwendet werden. Es werden hierbei systematische Abweichungen zwischen zwei Verteilungsfunktionen erfasst und auf eine dritte Verteilungsfunktion übertragen.

So kann zum Beispiel Folgendes erreicht werden: Aus einer mit einem Bias belasteten synthetischen Zeitreihe, die vergangene und zukünftige Zeiträume umfasst, und einer beobachteten Zeitreihe der Vergangenheit kann eine vom Bias korrigierte Verteilungsfunktion für zukünftige Zeiträume erstellt werden. Die Methodik ähnelt stark der Downscaling-Vorgehensweise, die im Abschnitt 9 beschrieben wird, da diese an der Arbeit von Bárdossy & Pegram (2011) orientiert entwickelt wurde. Benestad (2010) erstellte eine Methode zum Downscaling von extremen Tageswertniederschlägen. Er verwendete hierbei eine Quantile-Quantile-Transformation, um ein auf empirischen Orthogonalfunktionen basierendes Downscaling-Modell zu kalibrieren. Auch Quintana Seguí et al. (2010) verwendeten eine Quantile-Quantile-Transformation für das Downscaling von Tageswertniederschlägen.

Wetterhall et al. (2009) verwendeten GWL im Downscaling von Niederschlagsdaten. Erläuterungen zu den verwendeten Großwetterlagen sind Bárdossy et al. (2002) und Abschnitt 4 der vorliegenden Arbeit zu entnehmen. Bei der Generierung des Niederschlags wird ein an GWL und den Feuchtefluss bedingtes autoregressives Modell verwendet. So kann das Klimasignal über die Reproduktion der Änderungen der GWL-Häufigkeiten und im Feuchtefluss auf die Daten übertragen werden. Der erwähnte Feuchtefluss wird aus der Kombination von Windgeschwindigkeit und Luftfeuchtigkeit gebildet. Yang et al. (2010) führten ein Downscaling durch, das ebenfalls an GWL und Feuchtefluss bedingt wurde. Das Modell besteht aus einer Regression für das Auftreten und aus Verteilungsfunktionen für das Volumen. Die Methodik wurde im Detail in Yang (2008) erläutert. Alam (2011) führte ein dynamisch-statistisches Downscaling mit verschiedenen Methoden durch; zum einen mit einem regressionsbasierten Ansatz (siehe Yang et al. (2010)) und zum anderen mit einer Quantile-Quantile-Transformation. Auch hier kamen als Randbedingungen GWL und der Feuchtefluss zum Einsatz.

Eine der neuesten Studien über GWL im Downscaling stammt von Pegram & Bárdossy (2013), welche Kreuzkorrelationskoeffizienten und eine GWL-basierte Quantile-Quantile-Transformation zum Downscaling von Daten eines RCM verwendeten. Der Ansatz mit Kreuzkorrelations-Koeffizienten dient hierbei zur räumlichen Rekorrelierung der Niederschlagsdaten, da die Daten der regionalen Klimamodelle eine geringere räumliche Korrelation haben als die der Beobachtung. Details hierzu sind auch Bárdossy & Pegram (2012) zu entnehmen.

Carreau & Vrac (2011) verwendeten ein Modell, das auf einer Kombination aus Verteilungsfunktionen und künstlichen neuronalen Netzen (KNN) basiert. Einen ähnlichen Weg beschritten bereits Coulibaly et al. (2005), die ein auf künstlichen neuronalen Netzen basierendes Modell zum Downscaling täglicher Niederschläge konstruierten. Auch Haylock et al. (2006) verwendeten unter anderem Downscaling-Verfahren auf Basis von KNN.

Eine weitere Untersuchung stellten Flaounas et al. (2013) vor, die dynamische Verfahren mit einem dem Quantile-Quantile-Transformations-Verfahren ähnelnden Downscaling verglichen. In dieser Arbeit wurden allerdings keine Punktdaten, sondern Gebiete mit einer Auflösung von 20 bis 50 km transformiert.

3 Untersuchungsgebiet und Datenbasis

Nachdem im letzten Abschnitt der Stand der Wissenschaft anhand vorhandener Ansätze diskutiert wurde, werden in dem vorliegenden Abschnitt zunächst das Untersuchungsgebiet und die Datenbasis vorgestellt. Zuerst werden grundlegende Fakten des Gebietes dargelegt und im Anschluss werden die spezifischen Niederschlagscharakteristika diskutiert.

3.1 Das Gebiet und seine Geographie

Das Untersuchungsgebiet dieser Studie ist das Bundesland Niedersachsen. Das Gebiet liegt im Norden Deutschlands und somit in einer gemäßigten Klimazone. Das Klima im Norden Niedersachsens wird durch den Einfluss der Nordsee bestimmt, während der Süden stark durch die Hochlagen mehrerer Mittelgebirge definiert wird.

Eine Relief-Karte von Niedersachsen, seiner wichtigsten Städte, Flüsse und Erhebungen ist in Abbildung 3-1 dargestellt.

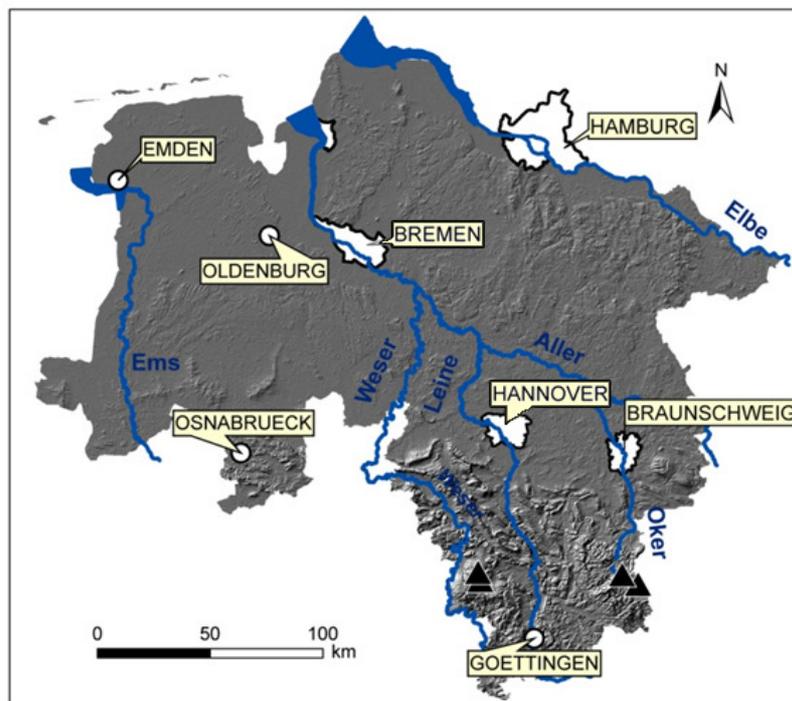


Abbildung 3-1 Übersichtskarte von Niedersachsen; die Dreiecke markieren die höchsten Erhebungen

Laut Niedersachsen.de (2014) umfasst Niedersachsen eine Fläche von 47613 km² und hat 7,9 Millionen Einwohner. Die wichtigsten Flüsse des Landes sind Weser, Leine, Ems, Elbe, Aller und Oker (siehe Abbildung 3-1). Kanäle werden in der Abbildung nicht dargestellt.

Wichtige Mittelgebirge sind der südöstlich gelegene Harz und das südwestlich gelegene Weserbergland. Die wichtigsten Erhebungen sind im Harz der Brocken (1141 m NN), die Heinrichshöhe (1045 m NN) und der Königberg (1033 m NN). Diese Erhebungen liegen leicht außerhalb Niedersachsens in Sachsen-Anhalt. Die höchsten Erhebungen in Niedersachsen selbst sind der Wurmberg (971 m NN) und der Bruchberg (927 m NN). Im Weserbergland liegen die Erhebungen Große Blöße (528 m NN), der Großer Ahrensberg (525 m NN) und der Ebersnacken (460 m NN).

3.2 Niederschlagsstationen

Abbildung 3-2 zeigt die Lage der verwendeten Niederschlagsstationen. Daten wurden von 20 Stationen mit einer Beobachtungsdauer von 10 bis 15 Jahren und neun Stationen mit einer Beobachtungsdauer von 7 bis 9 Jahren erhalten. Die Untersuchungsdaten entstammen dem Zeitraum 1996 bis 2010. Die Stationen haben zueinander stets mindestens sieben Jahre Überschneidungsdauer (dies entspricht der minimalen Beobachtungslänge der Stationen). Die Verwendung der kürzeren Stationen war nötig, um die Datenbasis zu vergrößern, damit der Einfluss der GWL auf die Regionalisierung des Modells geprüft werden kann. Diese braucht eine dichte räumliche Datenbasis. Es wurden zwei Stationspaare verwendet, bei denen die Stationen sehr nahe beieinanderliegen. Die Daten wurden vom Deutschen Wetterdienst (DWD) und der Meteomedia AG (bzw. MeteoGroup Schweiz AG) bezogen. Eine Auflistung der Niederschlagsstationen gibt Tabelle A-1 im Anhang.

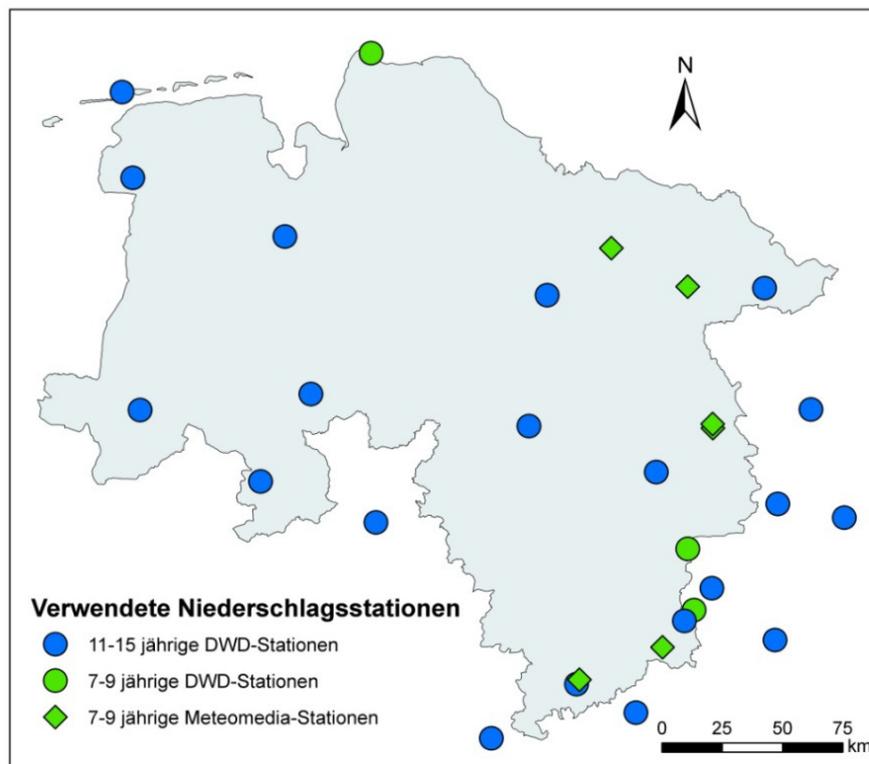


Abbildung 3-2 Verwendete hoch aufgelöste Niederschlagsstationen

3.3 Der Niederschlag in Niedersachsen

Aus dem Blickwinkel der Niederschlagsanalyse unterteilt sich Niedersachsen in drei Regionen mit unterschiedlichem Niederschlagsverhalten: zunächst die küstennahen Gebiete mit vergleichsweise hohen, dann das Binnenland mit eher niedrigen und als Drittes und Letztes die süd-östlichen Mittelgebirgsregionen des Harzes mit sehr hohen Niederschlagsaufkommen. Die genannten Regionen sind bereits in deren Niederschlagssummen (siehe Abbildung 3-3) und der jeweiligen Anzahl der Niederschlagsereignisse (siehe Abbildung 3-4) der verwendeten Niederschlagsstationen zu erkennen. Besonders im Sommer ist die Trennung in die genannten drei Regionen klar zu sehen. Die Feststellung dieser drei Regionen ist konsistent mit den Ergebnissen von Haberlandt et al. (2010).

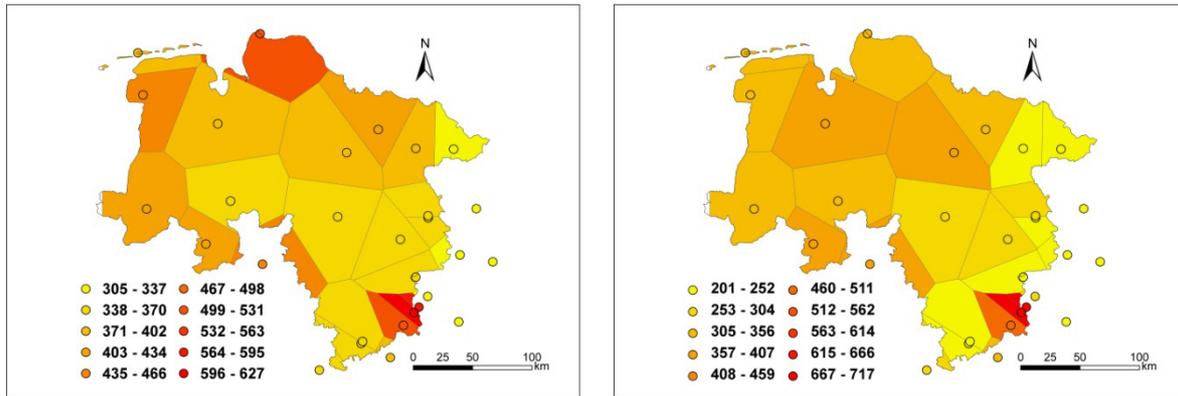


Abbildung 3-3 Thiessen-Polygone der Saisonsummen des Niederschlages [mm]; links: Sommer, rechts: Winter

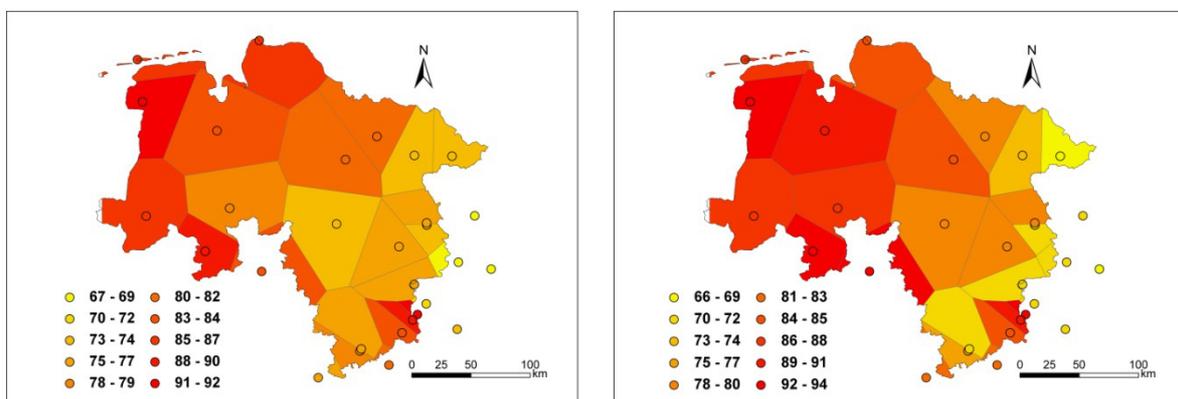


Abbildung 3-4 Thiessen-Polygone der saisonalen Ereignisanzahl [-]; links: Sommer, rechts: Winter

Dieser Abschnitt ermittelt und analysiert die für die Modellierung als Eingangsdaten relevanten Kennwerte des Niederschlages anhand der Werte der verwendeten Niederschlagszeitreihen.

Die hier dargestellten Parameter des Niederschlages richten sich nach dem verwendeten Niederschlagsmodell (siehe Abschnitt 5.1.1). Es sind die Nassdauer wsd [min], die Ereignisintensität wsi [mm/h], die Trockendauer dsd [min] und das Ereignisvolumen wsa [mm].

Im Vergleich zu anders gestalteten Daten, zum Beispiel den saisonalen Summen, zeigen die mittleren Ereignisintensitäten beider Jahreszeiten eine deutlich schwächere regionale Ausprägung (siehe Abbildung 3-5). Bei Varianz und Schiefe der Ereignisintensitäten ist eine regionale Ausprägung kaum vorhanden (siehe Abbildung 3-6 und Abbildung 3-7). Lediglich die in den bisher betrachteten Parametern unauffällige Mittelgebirgsregion des Deisters und im Sommer zwei einzelne Stationen im Westen und Osten zeigen ein ausgeprägt abweichendes Verhalten zum restlichen Niedersachsen. Insgesamt entsteht der Eindruck einer räumlichen Zufälligkeit der wsi .

Eine interessante Erkenntnis ist, dass die wsi für den Winter eine sehr niedrige und im Sommer eine recht hohe Varianz aufweist. Dies ist leicht dadurch zu erklären, dass im Sommer sowohl kurze heftige konvektive als auch advective Ereignisse auftreten, während im Winter die langanhaltenden advectiven Ereignisse deutlich dominieren. Dies schlägt sich auch in den deutlich niedrigeren mittleren wsi im Winter nieder. Ebenfalls erwähnenswert ist die stets positive Schiefe, die durch die zu erwartende Dominanz der niedrigen Niederschlagsintensitäten zu erklären ist.

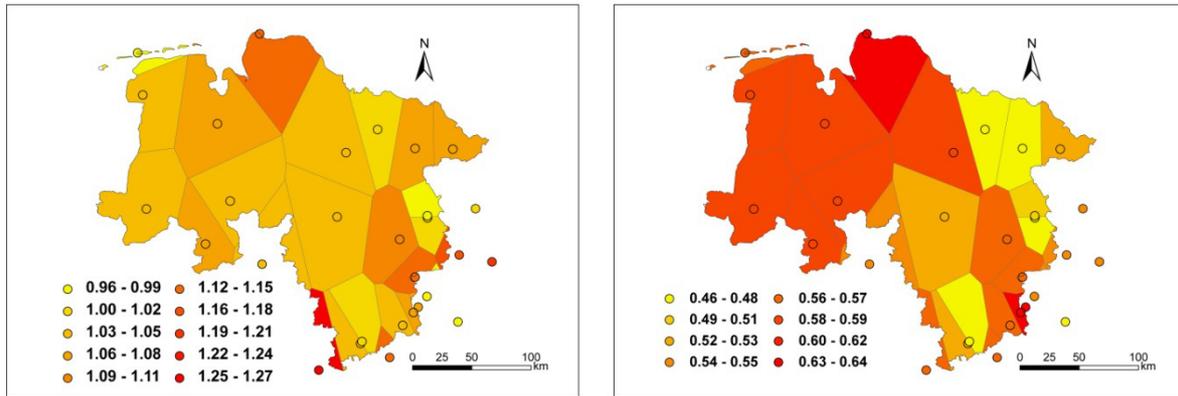


Abbildung 3-5 Thiessen-Polygone der Mittelwerte der w_{si} [mm/h]; links: Sommer, rechts: Winter

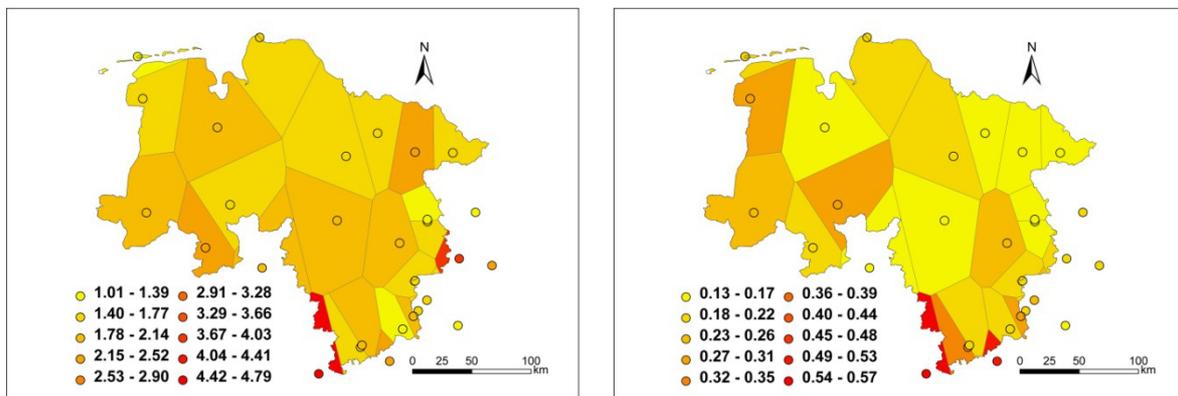


Abbildung 3-6 Thiessen-Polygone der Varianz der w_{si} [mm²/h²]; links: Sommer, rechts: Winter

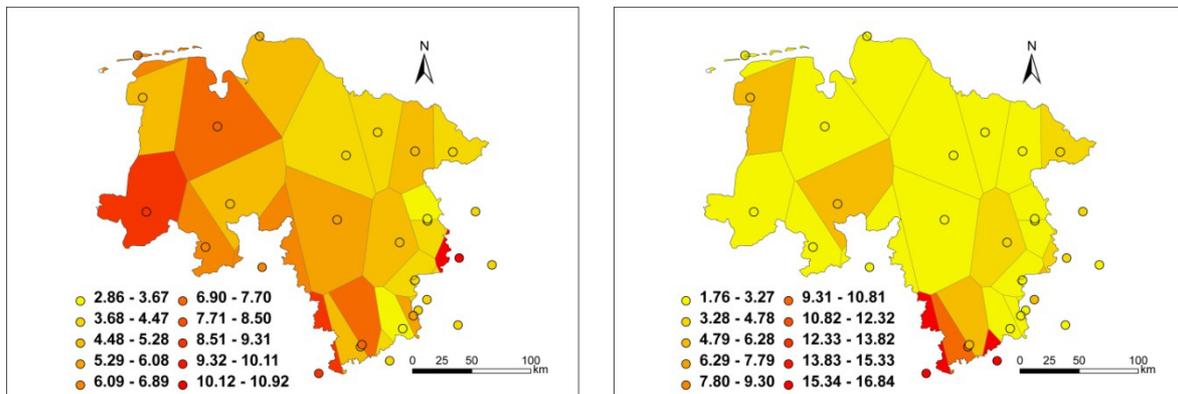


Abbildung 3-7 Thiessen-Polygone der Schiefe der w_{si} [-]; links: Sommer, rechts: Winter

Auch bei den mittleren Ereignisvolumen (siehe Abbildung 3-8) sind die Regionen nicht so deutlich zu sehen wie z. B. bei den Summen. Allerdings ist hier im Gegensatz zu den Intensitäten der Harz klar auszumachen und die Küstenregion, wenn auch etwas abgeschwächt, zeichnet sich in den Werten ab.

Auch Varianz und Schiefe der w_{sa} bestätigten die Ergebnisse aus den Mittelwerten. Sie werden hier nicht dargestellt, da sie keine neuen Erkenntnisse bringen und auch nicht zu den Eingangsdaten des Modells gehören.

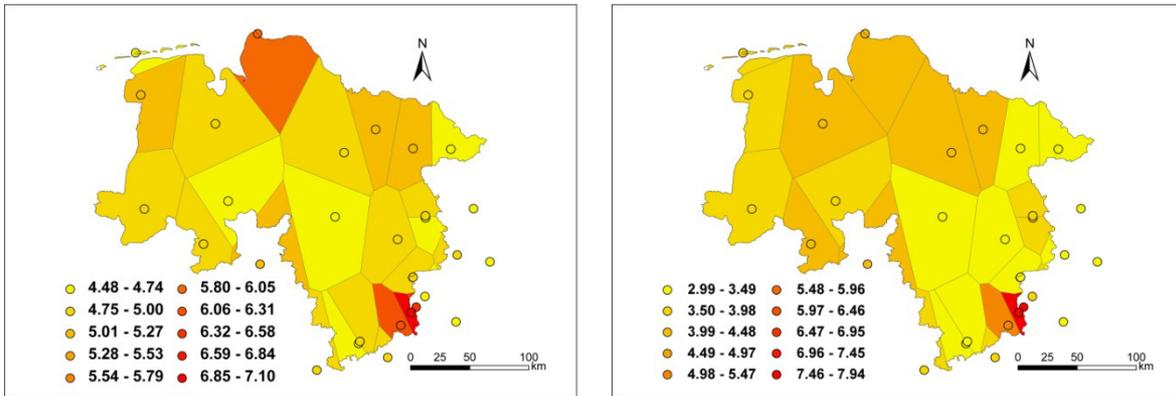


Abbildung 3-8 Thiessen-Polygone des Mittelwertes der *wsa* [mm]; links: Sommer, rechts: Winter

In den Ereignisdauern sind die bekannten Regionen wieder etwas ausgeprägter zu erkennen. Besonders der Harz erweist sich in den Mittelwerten als sehr ausgeprägt (siehe Abbildung 3-9). Für die Varianz ist zumindest der Harz stets klar zu erkennen (siehe Abbildung 3-10). Bei der Schiefe hingegen ist dies nur noch im Winter möglich (siehe Abbildung 3-11).

Ansonsten sind im Sommer in Übereinstimmung mit den erhöhten *wsi* niedrigere Dauern festzustellen, was ebenfalls auf die häufigen konvektiven Niederschläge im Sommer zurückzuführen sein dürfte. Interessant sind auch die im Winter erhöhten Varianzen.

Auch der Effekt der stets positiven Schiefe ist wieder zu beobachten. Dies ist ebenfalls durch die eher seltenen langen und häufigen kurzen Ereignisdauern zu erklären.

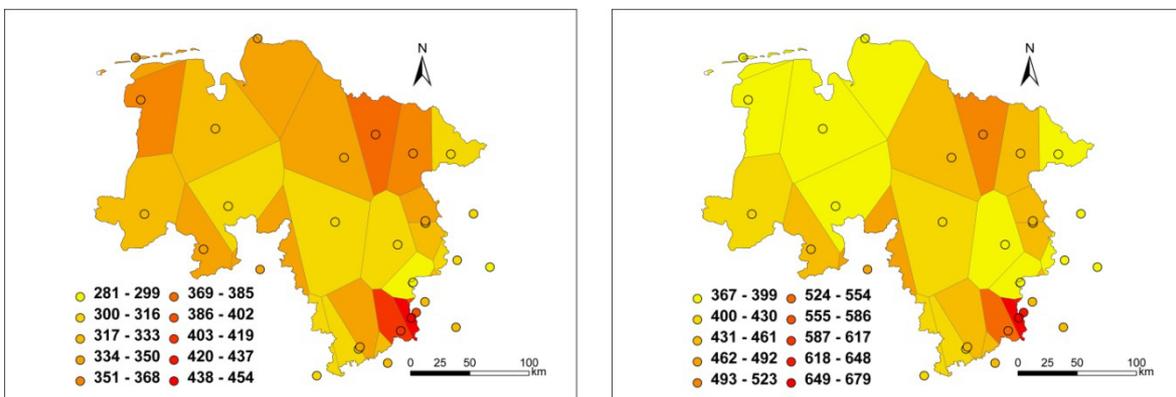


Abbildung 3-9 Thiessen-Polygone der Mittelwerte der *wsd* [min]; links: Sommer, rechts: Winter

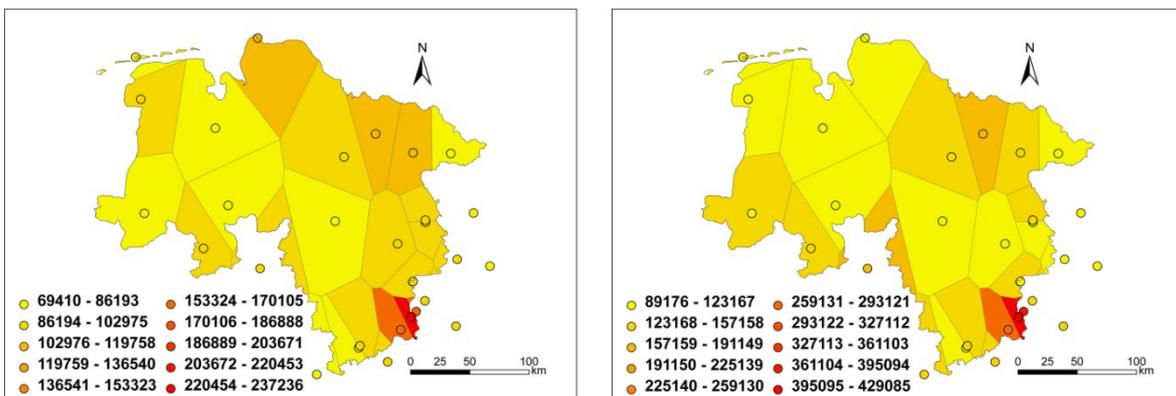


Abbildung 3-10 Thiessen-Polygone der Varianz der *wsd* [min²]; links: Sommer, rechts: Winter

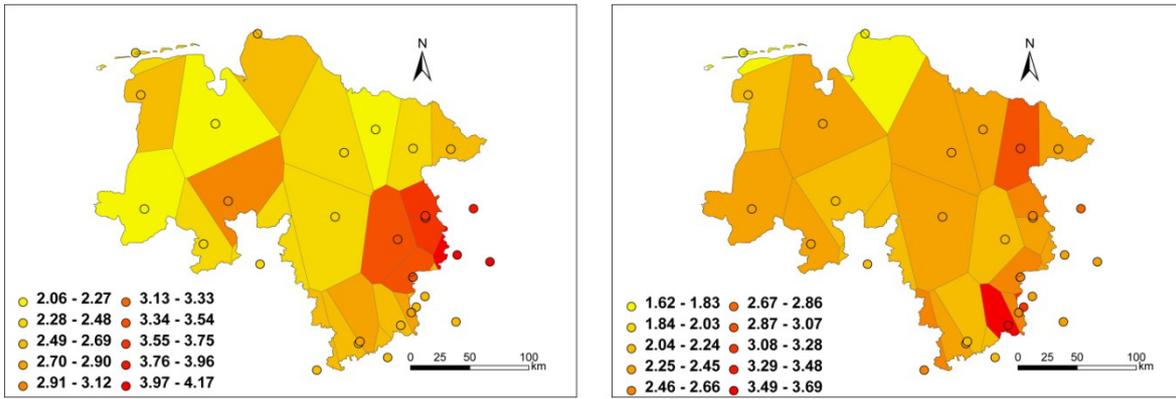


Abbildung 3-11 Thiessen-Polygone der Schiefe der wsd [-]; links: Sommer, rechts: Winter

Der letzte Kennwert, der betrachtet wird, sind die Trockendauern. Bei diesem Kennwert sind für die Mittelwerte die bekannten Regionen wieder klar zu erkennen (siehe Abbildung 3-12). Die durchschnittlichen Trockendauern sind für den Winter etwas kürzer. Dies passt zu der etwas höheren Ereignisanzahl im Winter. In den Varianzen und den Schiefen zeigen sich die Regionen ebenfalls, wenn auch etwas schwächer (siehe Abbildung 3-13 und Abbildung 3-14). Ausnahme ist der Sommer für die Schiefe, welcher praktisch keine räumliche Variabilität aufweist. Interessant hierbei ist, dass die Werte der bereits für die wsi auffälligen Deister-Station bei der sommerlichen Varianz und Schiefe von denen der restlichen Stationen abweichen. Eine sich wiederholende Erkenntnis ist die wieder stets positive Schiefe.

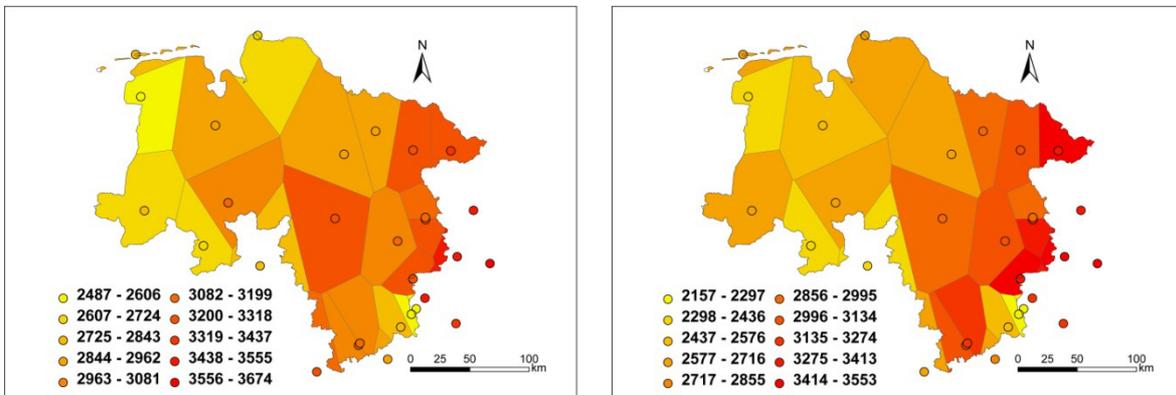


Abbildung 3-12 Thiessen-Polygone der Mittelwerte der dsd [min]; links: Sommer, rechts: Winter

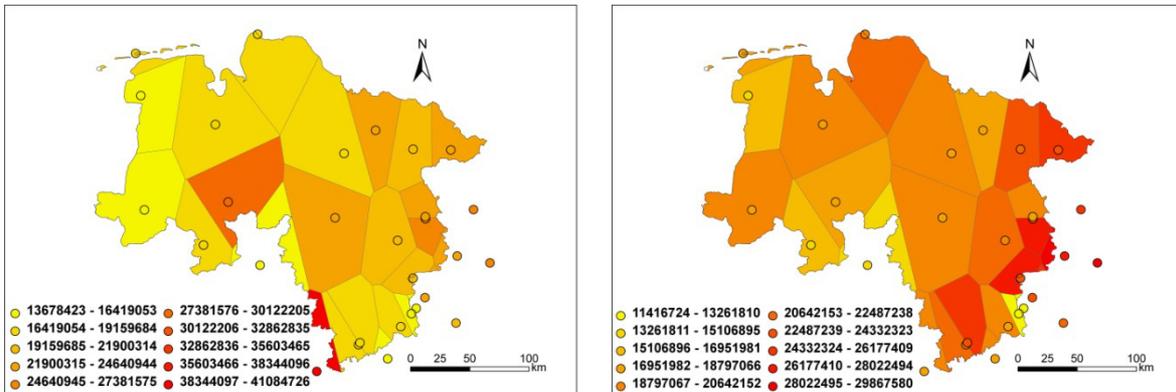


Abbildung 3-13 Thiessen-Polygone der Varianz der dsd [min²]; links: Sommer, rechts: Winter

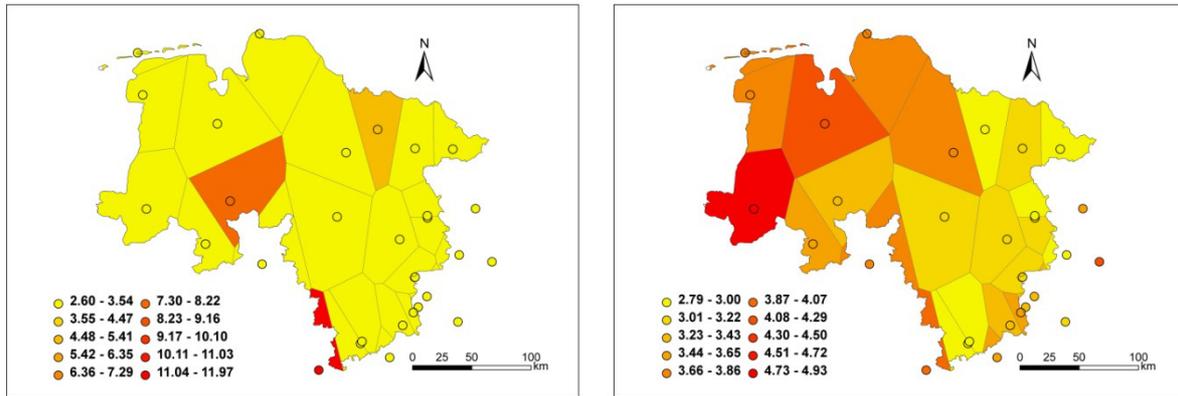


Abbildung 3-14 Thiessen-Polygone der Schiefe der dsd [-]; links: Sommer, rechts: Winter

3.4 Plausibilitätsuntersuchungen

In den Untersuchungen sollten nur kontinuierliche Zeitreihen mit einem niedrigen Fehlwertanteil verwendet werden. Hieraus folgte die Auswahl der verwendeten Stationen und des betrachteten Verwendungszeitraumes. Bei einigen Stationen konnte daher nicht der vollständige Beobachtungszeitraum genutzt werden. Um Verfälschungen der Saisonalität zu verhindern, wurde als Kriterium angesetzt, dass die verwendeten Jahre einen Fehlwertanteil von unter 5 % aufweisen müssen; nur in Ausnahmefällen wurden Jahre in die Untersuchungen eingeschlossen, die diesen Grenzwert leicht überschreiten (siehe Tabelle A-2).

Anschließend wurden die Zeitreihen mit Boxplots auf Ausreißer und mit ihren statistischen Kennwerten und der Doppelsummenanalyse auf Inhomogenitäten und Inkonsistenzen geprüft. Auffällige Extremwerte wurden dabei per Hand mit Daten benachbarter Stunden- und Tageswertstationen verglichen. Als Folge mussten einige wenige Werte als Ausreißer verworfen werden. Zur Prüfung der Plausibilität wurden auch die Jahressummen der verwendeten Stundenwertzeitreihen mit benachbarten Tageswertstationen verglichen.

Ein weiterer wichtiger Punkt der Plausibilitätsanalyse ist die Überprüfung einer eventuellen Autokorrelation. Dies ist von großer Bedeutung, da das Alternating-Renewal-Modell grundsätzlich die Unabhängigkeit der Ereignisse zueinander voraussetzt (siehe Haberlandt et al. (2008)). Die Ergebnisse der Untersuchungen sind als Mittel über alle Stationen in Abbildung 3-15 zu sehen. Dargestellt werden hierbei die Autokorrelation der Elemente selbst (wsd , wsi und dsd) sowie die Korrelation der Elemente untereinander.

Die Nomenklatur der letztgenannten ergibt sich wie nachfolgend beschrieben: wsd bezeichnet die pearsonsche Korrelation der dsd , die auf ein wsd folgen. Analog zur Autokorrelation wird die Korrelation von dsd von den zehn nachfolgenden Ereignissen mit den wsd verglichen. Analog ergeben sich $dsdwsd$, $wsdwsi$ und $wsiwsd$.

Wie in der Abbildung 3-15 zu erkennen, kann nicht vollständig bestätigt werden, dass die Ereignisse unabhängig voneinander sind. Allerdings sind die dsd die einzige Kenngröße, bei der zwischen der ersten und den weiteren Schrittweiten in den Autokorrelationen ein großer Unterschied vorliegt. Die übrigen Parameter erscheinen eher unauffällig. Obwohl die wsi , wsd , $wsdwsi$ und $wsiwsd$ vergleichsweise ausgeprägt Autokorrelationen aufweisen, nehmen diese mit der Schrittweite nur wenig ab und stellen vermutlich keine wirkliche Autokorrelation dar.

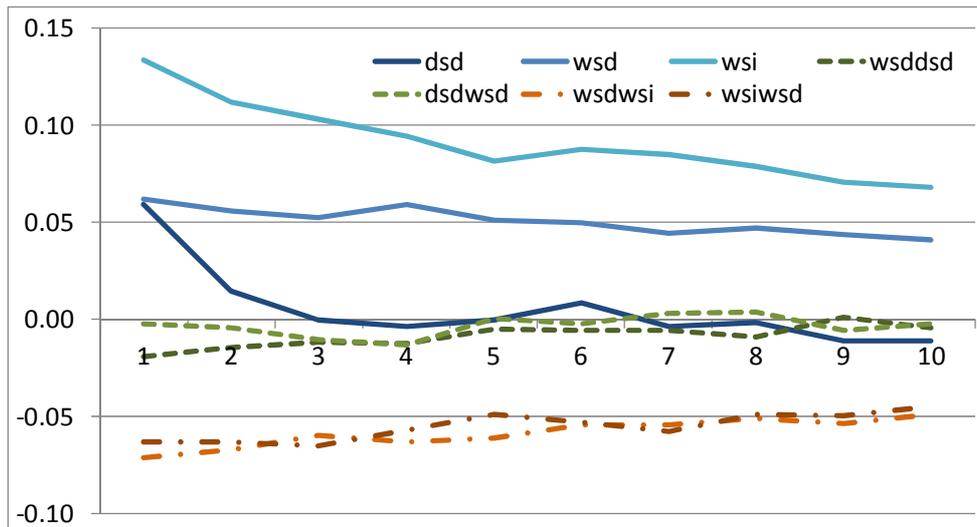


Abbildung 3-15 Autokorrelation der Ereignisse als Mittel über alle Stationen (die X-Achse zeigt den lag)

Zur Verifikation der Ergebnisse wurden auch die Signifikanzen der Autokorrelationen betrachtet (siehe Abbildung 3-16). Hier wird exemplarisch die Signifikanz der Autokorrelationen mit einem Signifikanzniveau von 0,05 näher betrachtet. Es wurden auch die Signifikanzniveaus 0,1 und 0,01 betrachtet, diese lieferten aber sehr ähnliche Ergebnisse. Die Erkenntnisse der Betrachtung der Werte der Autokorrelation selbst wiederholen sich. Einziger Unterschied ist, dass die Signifikanz der Autokorrelationen der *wsdwsi* und *wsiwsd* mit der Schrittweite stärker abnehmen.

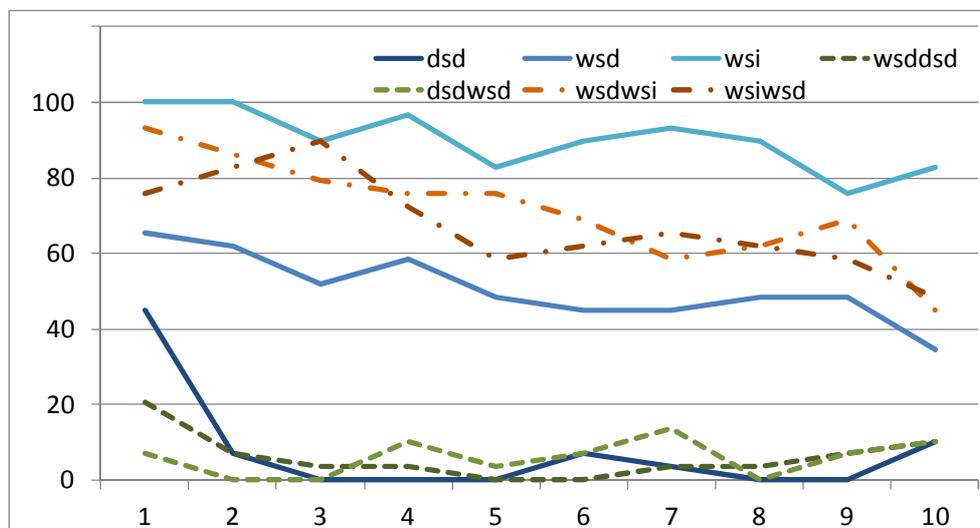


Abbildung 3-16 Anteil [%] nachgewiesener Signifikanz der Autokorrelation in den Ereignissen (die x-Achse zeigt den lag)

Insgesamt kann zusammengefasst werden, dass die Autokorrelationen der Ereignisse kaum ausgeprägt sind. In dieser Untersuchung werden zwei Nassereignisse durch eine mindestens 3 Stunden dauernde Trockenheit getrennt (siehe auch Abschnitt 5.1.1). Eine Variation dieses Parameters würde die hier dargestellten Ergebnisse beeinflussen. Die leichte Autokorrelation in den *dsd* wurde akzeptiert, da die dreistündige Ereignistrennung zu besseren Modellergebnissen führte als eine längere Ereignistrennung.

3.5 Voruntersuchungen – notwendige Zeitreihenlänge

Die Untersuchung der minimalen Zeitreihenlänge war aufgrund der eingeschränkten Datenlage von großer Bedeutung. Hierfür werden Stichprobenparameter getestet. Mittels des Doppel-T-Tests werden die Mittelwerte und mittels des F-Tests die Varianzen der Ereigniselemente der Stationen unterschiedlicher Stichprobenlängen darauf getestet, ob sie signifikant voneinander abweichen. Für die Details dieser Testverfahren wird auf einschlägige Literatur verwiesen, zum Beispiel Sachs & Hedderich (2006).

Bei den Untersuchungen kommen nur die Stationen zum Einsatz, für die ununterbrochene Beobachtungsdaten von 1996 bis 2010 vorliegen. Mit diesen werden die Parameter aller Ereigniselemente (Trockendauern, Nassdauern und Nassereignisintensität, siehe Abschnitt 5.1.1) auf Homogenität getestet, wobei alle relevanten Teilmengen berücksichtigt werden. So wird bei den Analysen der Vergleichszeitreihenlänge von 13 Jahren die Stichprobe 1996-2010 (15 Jahre) mit den Stichproben 1996-2008, 1997-2009 und 1998-2010 verglichen. Abbildung 3-17 zeigt die Zusammenfassung dieser Untersuchungen. Getestet werden die Mittelwerte und Varianzen der Ereigniselemente.

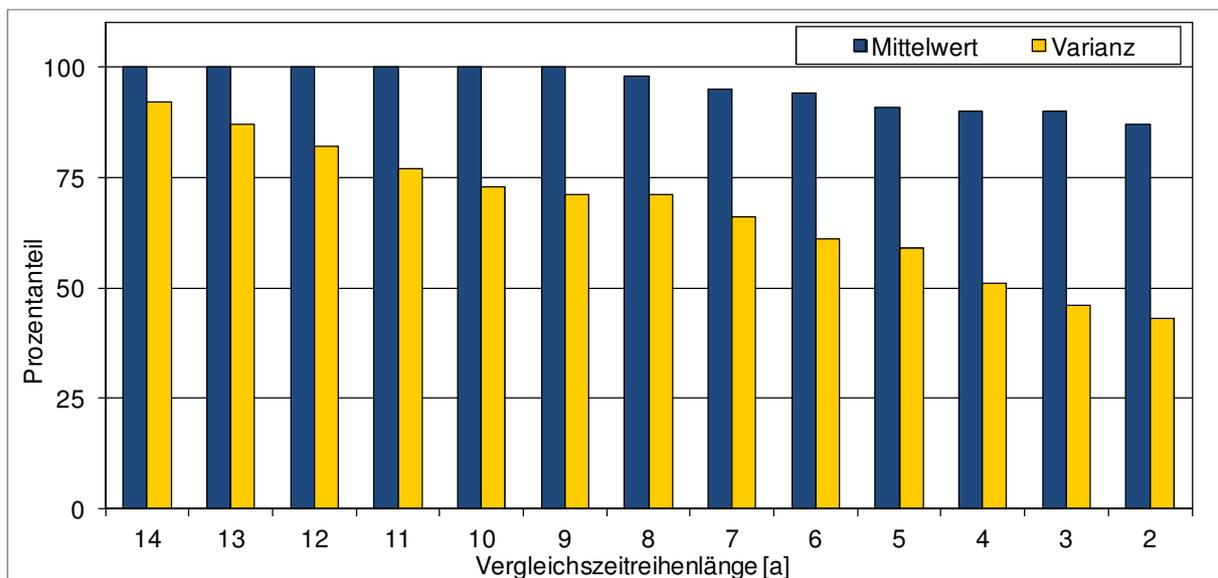


Abbildung 3-17 Anteil [%] der Stationen, welche bei x Jahren Vergleichszeitreihenlänge aus statistischer Sicht parametrisch gleichwertig zur 15-jährigen Reihe sind; dargestellt sind die Anteile der Summen der Tests auf alle Ereigniselemente (Nassereignisintensität, Nassdauer und Trockendauer)

Es ist zu erkennen, dass die Mittelwerte der Ereigniselemente fast aller Stationen für Zeitreihenlängen von 9 bis 14 Jahren statistisch gleichwertig mit denen der 15-jährigen Zeitreihen sind. Selbst bei 7-jährigen Zeitreihen beträgt der Anteil der gleichwertigen Mittelwerte noch 95 %. Etwas schlechter sieht es bei den Varianzen aus. Bei diesen sinkt der Anteil der gleichwertigen Werte kontinuierlich mit der Zeitreihenlänge der Vergleichsreihe. Für 14-jährige Zeitreihen liegt der Wert bei 92 %; für 10-jährige bei 73 % und für 7-jährige noch bei 66 %.

Aus den in Abschnitt 3.2 genannten Gründen wurden einige sieben Jahre lang beobachtete Stationen verwendet. Es wurden während der Untersuchungen stets die Ergebnisse der langen Zeitreihen mit denen der kurzen Zeitreihen verglichen, um signifikante Abweichungen zu erkennen. Es konnten bei keiner der Untersuchungen signifikante Unterschiede zwischen den beiden Stationsgruppen festgestellt werden. Es kann daher davon ausgegangen werden, dass die Verwendung der Stationen mit kurzen Zeitreihen für das Niederschlagsmodell akzeptabel ist.

3.6 Klimadaten für die Großwetterlagenklassifikation und das Downscaling

Zur Bestimmung der GWL werden Luftdruck- und Niederschlagsdaten benötigt (siehe Abschnitte 2.2 und 4). Weitere Details sind auch Haberlandt et al. (2015) und Haberlandt et al. (2011) zu entnehmen.

Für vergangene Zeiträume werden Druckdaten auf Meereshöhe der NCAR-Reanalyse (Kalnay et al. 1996) und tägliche Niederschlagsdaten des DWD (Zeitraum 1951-2000) verwendet. Optimierung und Validierung werden anhand von zwei Clustern durchgeführt. Weiterhin wurden Daten von 115 Klimastationen zur Validierung der NCAR-Druckdaten verwendet.

Zur Bestimmung von GWL in zukünftigen Zeiträumen wurden Druckdaten des globalen Klimamodells ECHAM5/MPI-OM (siehe Jungclaus et al. (2006)) und tägliche Niederschlagsdaten des auf ECHAM5 basierenden regionalen Klimamodells REMO (siehe Jacob et al. (2008)) verwendet. Um die zukünftigen Daten für ein Downscaling verwenden zu können (mit dem Ziel, Änderungen zu erfassen), wurden mit diesen Modelldaten Zeitreihen der GWL für einen vergangenen Zeitraum (1951-2000) und einen zukünftigen Zeitraum (2001-2100) erzeugt. Dieselben REMO-Niederschlagsdaten wurden für das Downscaling verwendet (siehe Abschnitt 9).

Für das ECHAM-Modell wurden die ECHAM-Modellläufe 20C_R1 (1951-2000) und A1B (2001-2100) verwendet. Bei dem REMO-Modell wurden Daten des gleichnamigen und auf dem genannten ECHAM-Durchlauf basierenden ersten REMO- Modelllaufs verwendet. Dieser wird in der Literatur oft nach dem an diesem Modelllauf beteiligten Projektpartner UBA (Umweltbundesamt) benannt.

Eine Übersicht der verwendeten Stationen, Cluster und Raster ist der Abbildung 3-18 zu entnehmen.

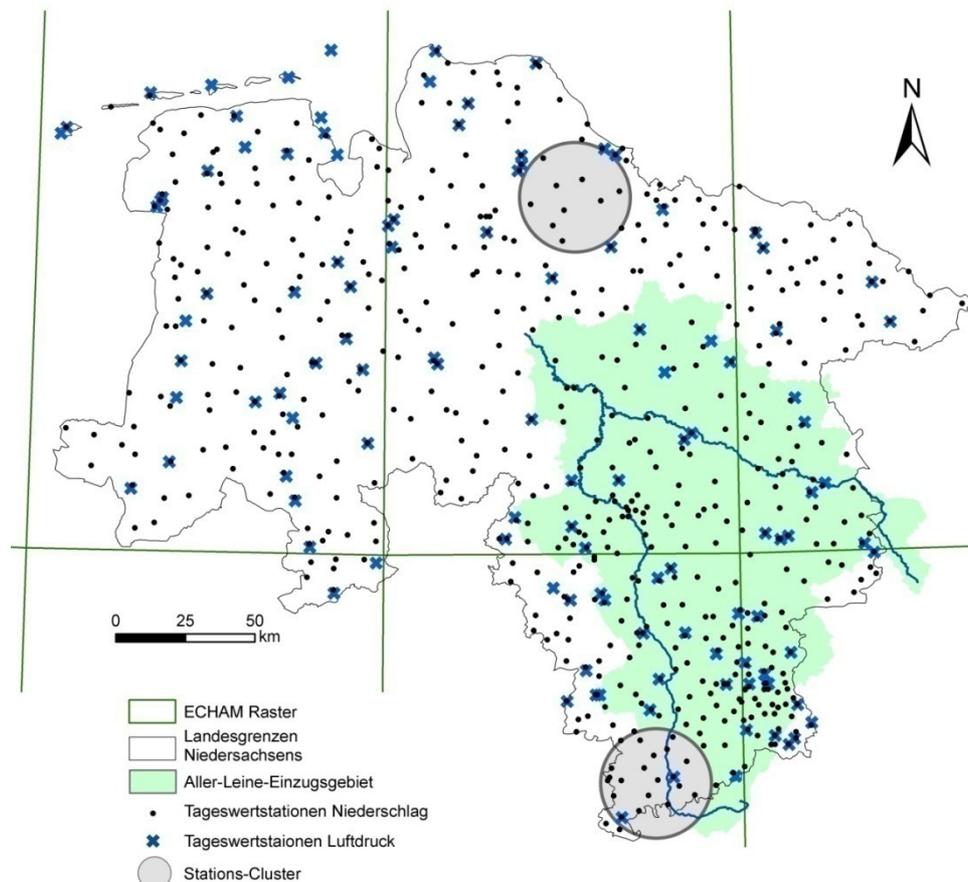


Abbildung 3-18 Übersicht über die für die GWL-Klassifikation verwendeten Daten, entnommen aus Haberlandt et al. (2011)

4 Großwetterlagenklassifikation

Dieser Abschnitt erläutert die in dieser Arbeit eingesetzte Methode nach Bárdossy (2010) und beschreibt die verwendeten Modelle, Daten und Randbedingungen. Für die Klassifizierung der Großwetterlagen (GWL) wurde die Struktur nach Haberlandt et al. (2015) bzw. Haberlandt et al. (2011) benutzt. Eine allgemeine Beschreibung der GWL ist im Abschnitt 2.2 zu finden.

4.1 Allgemeines zur Methodik

In der computergestützten Modellierung wird meist mit der dualen Logik nach Georg Boole gearbeitet, welche Entscheidungen eindeutig mit Ja oder Nein abschließt. Nach dieser Herangehensweise ist ein Element in einer Grundmenge enthalten oder nicht.

Die Klassifikationsmethode dieser Arbeit benutzt dagegen Fuzzy-Logik, welche unscharfe (englisch: „fuzzy“) Beschreibungen zulässt. Dieses Konzept wurde unter dem Begriff „Fuzzy-Sets“ erstmals durch Zadeh (1965) beschrieben und wurde in den nachfolgenden Jahrzehnten stetig weiterentwickelt.

Das Grundkonzept der Fuzzy-Logik beruht darauf, dass ein Element auch teilweise in einer Grundmenge enthalten sein kann. In der booleschen Logik kann etwas entweder sein oder nicht sein. Bei einer Fuzzy-Herangehensweise ergeben sich mehr Möglichkeiten. So kann ein Anfahrtsweg gleichzeitig zum Teil nah und normal oder normal und weit sein. Naturgemäß kann er aber nicht nah und weit gleichzeitig sein. In der booleschen Herangehensweise wäre der Anfahrtsweg nah, normal oder weit. Eine detaillierte Beschreibung der Grundlagen der Fuzzy-Logik und seiner Regeln ist beispielsweise in Kasabov (1996) zu finden.

Fuzzy-Regeln sind Beziehungen, die auf Grundlage der Fuzzy-Logik gebildet werden. Für das auf Fuzzy-Regeln basierende Klassifikationssystem nach Bárdossy (2010) werden Klassen aus einem Set von Fuzzy-Regeln gebildet. Anschließend wird für jede Klasse der Erfüllungsgrad ermittelt, den das Element bei den Fuzzy-Regeln der Klassen hat. Die Klasse, die die Regel mit dem größten Erfüllungsgrad hat, wird dem Objekt zugewiesen.

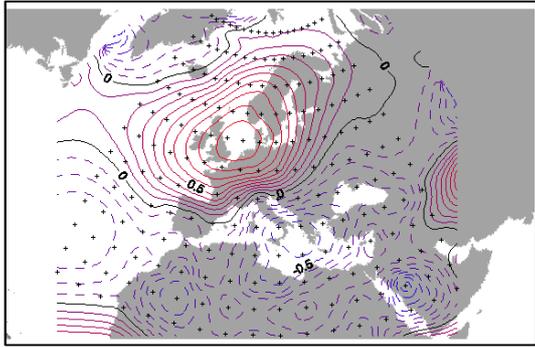
In der GWL-Klassifikation werden die Regeln entsprechend den GWL-typischen Anomalien im Luftdruck auf Meeresspiegelhöhe (*normalized sea level pressure*) über Europa und dem Atlantik gebildet (siehe Abbildung 4-1). Diese Daten werden täglich für ein regelmäßiges $5^{\circ} \times 5^{\circ}$ Raster ermittelt und dienen als Eingangsdaten der Klassifikation.

Die GWL werden durch Fuzzyregeln mit 1 bis N Argumenten für N Gitterpunkte definiert. Jeder Gitterpunkt hat eine Zugehörigkeitsfunktion zu den Anomalien. Diese unterscheiden sich in die fünf Klassen sehr positiv, mittel positiv, mittel negativ, sehr negativ und zufällig.

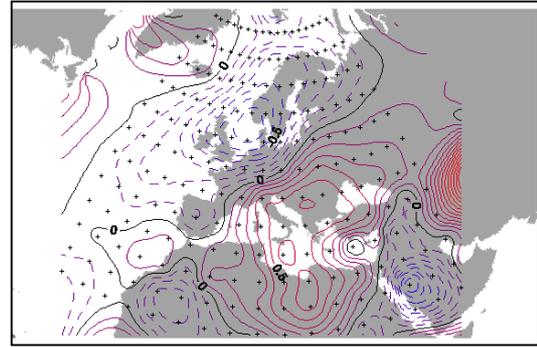
Unter Berücksichtigung der GWL-Anzahl M ergibt sich eine $N \times M$ -Matrix der Fuzzynummern A_{ij} :

$$F = \begin{pmatrix} A_{1,1} & \dots & A_{1,N} \\ \dots & \dots & \dots \\ A_{M,1} & \dots & A_{M,N} \end{pmatrix} \quad (4-1)$$

Der Zugehörigkeitsgrad wird ermittelt, und entsprechend diesem wird die dem Tag zugehörige GWL festgelegt. Das hierfür benötigte Regelsystem wird mittels einer Optimierung mit Simulated Annealing Techniken (siehe Reeves, 1993) realisiert. In der Zielfunktion des Optimierungsalgorithmus muss die Zielstellung der GWL-Klassifikation berücksichtigt werden. In diesem Anwendungsfall ist dies die Niederschlagsmodellierung.



Trockene GWL (GWL 1)



Nasse GWL (GWL 6)

Abbildung 4-1 Beispiele der räumlichen Verteilung der 500 hPa geopotentiellen Höhe der Luftdruckverteilung zweier GWL (entnommen aus Haberlandt et al. (2011))

Die hier verwendete Nomenklatur der Zielfunktion richtet sich nach Haberlandt et al. (2015). Der erste Teil der Zielfunktion behandelt den Schwellwert ϑ der Niederschlagstagesummen. Hierbei kommt der Abdeckungsgrad R_A zum Einsatz:

$$R_A(t) = \frac{m_{wet}(t)}{n_{tot}(t)} \quad (4-2)$$

$m_{wet}(t)$ - Anzahl Niederschlagsstationen mit Regen

$n_{tot}(t)$ - Gesamtanzahl Niederschlagsstationen

t - Zeitschritt (in Tagen)

$$o_{1,2}(\vartheta_{1,2}) = \sum_{i=1}^S \sqrt{\frac{1}{T} \sum_{t=1}^T \left[p_i(R_A(t) > \vartheta_{1,2}) - \bar{p}(R_A(t) > \vartheta_{1,2}) \right]^2} \quad (4-3)$$

$\vartheta_{1,2}$ - Grenzwert 1 und 2

T - Anzahl Tage

p_i - Relative Häufigkeit, dass Niederschlagstageswerte $\vartheta_{1,2}$ überschreiten an einem Tag, an dem die GWL i auftritt

\bar{p} - mittlere Überschreitungswahrscheinlichkeit ohne GWL

Mit Formel (4-3) werden über unterschiedliche Grenzwerte 2 Elemente der Zielfunktion definiert. Die verwendeten Grenzwerte sind $\vartheta_1=0,01$ (für trockene Zeiträume) und $\vartheta_2=0,90$ (für nasse Zeiträume).

Das dritte Element der Zielfunktion betrifft das Verhältnis der Niederschlagsabdeckung mit und ohne GWL:

$$o_3 = \frac{1}{T} \sum_{t=1}^T \left| \log \frac{\bar{R}_{A,i}(t)}{\bar{R}_A} \right| \quad (4-4)$$

$\bar{R}_{A,i}$ - mittlerer Abdeckungsgrad einer spezifischen GWL i

\bar{R}_A - mittlerer Abdeckungsgrad im Gebiet

Diese drei Elemente bilden zusammengesetzt die Zielfunktion:

$$o_{tot} = \sum_{k=1}^3 \omega_k o_k \rightarrow \max \quad (4-5)$$

Weiteres zu den Zielfunktionen ist Haberlandt et al. (2015), Bárdossy et al. (2002) und Bárdossy (2010) zu entnehmen.

Zur Einschätzung und Beurteilung der GWL wird der sogenannte Feuchteindex herangezogen, bei dem die relative Feuchtigkeit jeder GWL ermittelt wird (siehe (4-6)).

$$w_i(x) = \frac{\bar{z}_i(x)}{\bar{z}(x)} \quad (4-6)$$

$\bar{z}_i(x)$ – Mittlerer Tagesniederschlag an Ort x mit GWL i

$\bar{z}(x)$ – Mittlerer Tagesniederschlag an Ort x ohne Verwendung von GWL

Je weiter der Feuchteindex von 1 abweicht, desto signifikanter ist die durch die GWL gewonnene zusätzliche Information. Eine trockene GWL hat einen Feuchteindex kleiner 1 und eine nasse einen größer 1. Ein weiteres Maß zur Einschätzung der Qualität der GWL-Klassifikation sind die mittleren Niederschlagtagessummen der GWL. Weiteres kann Bárdossy (2010) entnommen werden.

4.2 Verwendete GWL-Klassifikation

Für die Untersuchungen wurden zunächst acht GWL verwendet. Zudem gibt es eine GWL-Klasse 9, die die Intervalle markiert, denen keine GWL zugewiesen werden konnten. Die verwendeten Eingangsdaten sind Abschnitt 3.6 zu entnehmen.

Ein sehr wichtiges Kriterium der GWL-Validierung ist der Feuchteindex (siehe Formel (4-6)). Dieser ist der Abbildung 4-2 zu entnehmen. Man kann deutlich unterschiedliche Werte der GWL erkennen. In dieser und den nachfolgenden Grafiken ist Cluster 1 das nördliche und Cluster 2 das südliche Cluster (vergleiche mit Abbildung 3-18). Es zeigt sich, dass es für den Winter (November bis April) trockene, nasse und mittlere GWL und für den Sommer (Mai bis Oktober) nur nasse und trockene GWL gibt.

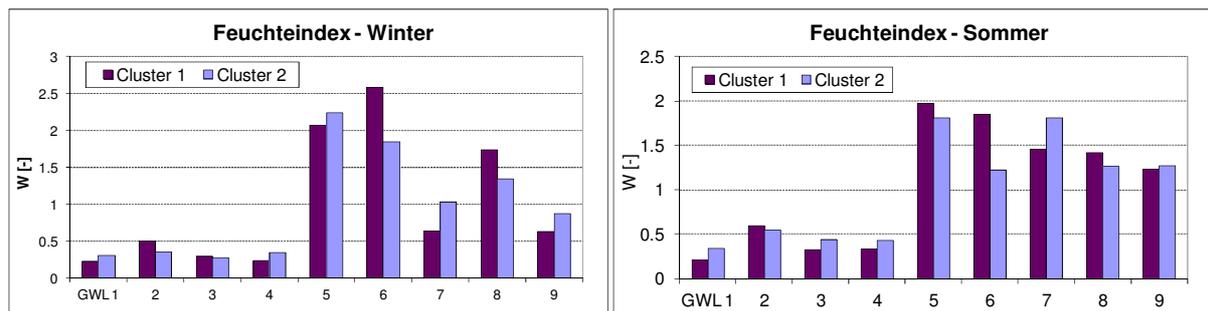


Abbildung 4-2 Feuchteindex der mit Beobachtungsdaten definierten GWL; Version mit 8 GWL

Da der Fokus dieser Arbeit unter anderem auf Extremwerten liegt, wurden auch große Tageswerte bei der Validierung verwendet. Abbildung 4-3 zeigt die mittleren jährlichen maximalen Tageswerte. Es ist zu sehen, dass die nassen GWL 5-9 in der Regel die höheren großen Niederschläge aufweisen, auch wenn dies nicht für alle nassen GWL gleichermaßen gilt. Die saisonalen Unterschiede sind größtenteils erwartungsgemäß so, dass die Werte im Sommer größer sind. Interessante Ausnahme ist die GWL 5, deren Extremwerte im Winter nahezu gleich hoch sind wie im Sommer.

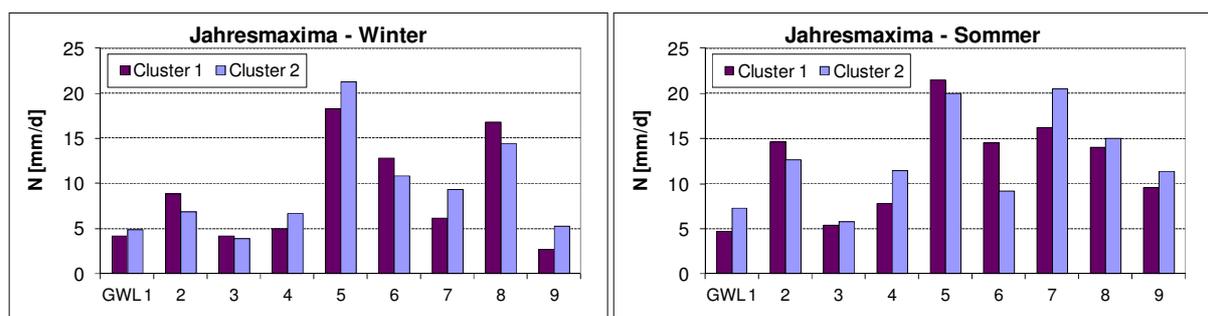


Abbildung 4-3 Mittlerer jährlicher maximaler Tageswert der Cluster; Version mit 8 GWL

Abbildung 4-4 zeigt den Anteil der GWL an der gesamten Zeitreihe. Interessant ist die Dominanz der feuchten GWL 5 für die nassen GWL und der geringe Anteil der GWL 3, 6 und 9. Die Unterschiede zwischen Sommer und Winter sind gering.

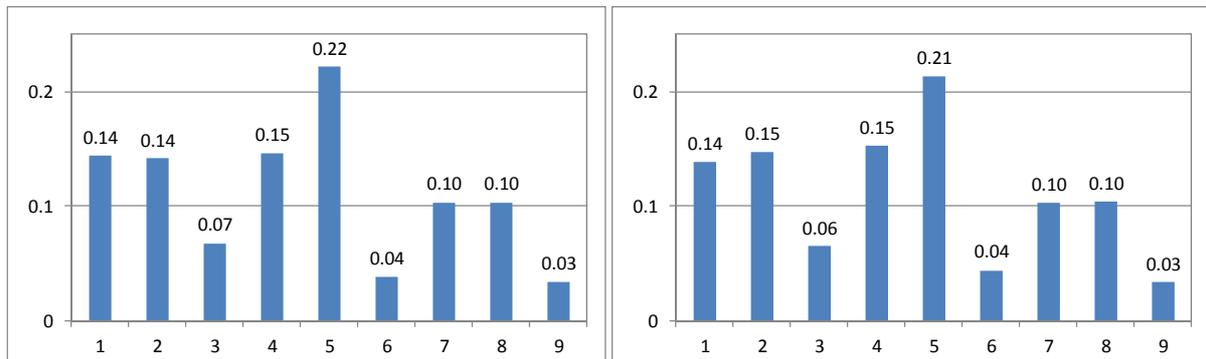


Abbildung 4-4 Anteil [-] der mit Beobachtungsdaten (Tageswerte) definierten GWL; links: Winter, rechts: Sommer; x-Achse: GWL; Version mit 8 GWL

Weitere Informationen zu den GWL, insbesondere auch zur Validierung, sind Haberlandt et al. (2011) zu entnehmen.

Eine Aufteilung der Zeitreihe in GWL hat den Vorteil, dass die Daten entsprechend ihren Eigenschaften in Cluster eingeteilt werden. Dies sollte zu einer erhöhten Qualität der Modellergebnisse führen. Allerdings wird bei getrennter Ermittlung der Modell-Parameter für jede GWL auch die für die Parametrisierung verfügbare Datenmenge verringert. Dies ist insbesondere für die GWL mit geringer Häufigkeit problematisch. So kann zum Beispiel in unserem Fall bei einer Gesamtzeitreihenlänge von 15 Jahren für die GWL 3 nur noch ein Datenumfang von weniger als einem Jahr angesetzt werden. Aufgrund dieser Überlegungen wurden noch zwei weitere GWL-Versionen definiert, zum einen eine mit zwei GWL (*nass* und *trocken*) und zum anderen eine mit vier GWL (zwei *nasse* und zwei *trockene*).

Für die Version mit vier GWL wurden nasse (GWL-Set 1 aus GWL 1&4 und GWL-Set 2 aus GWL 2&3) und trockene GWL (GWL-Set 3 aus GWL 5&6 und GWL-Set 4 aus GWL 7-9) zusammengefügt. Der Feuchteindex der Version ist Abbildung 4-5 und die Häufigkeiten Abbildung 4-6 zu entnehmen. Die Häufigkeiten sind ziemlich ausgeglichen und der Feuchteindex der einzelnen GWL auch innerhalb der Gruppen „nass“ und „trocken“ erkennbar unterschiedlich.

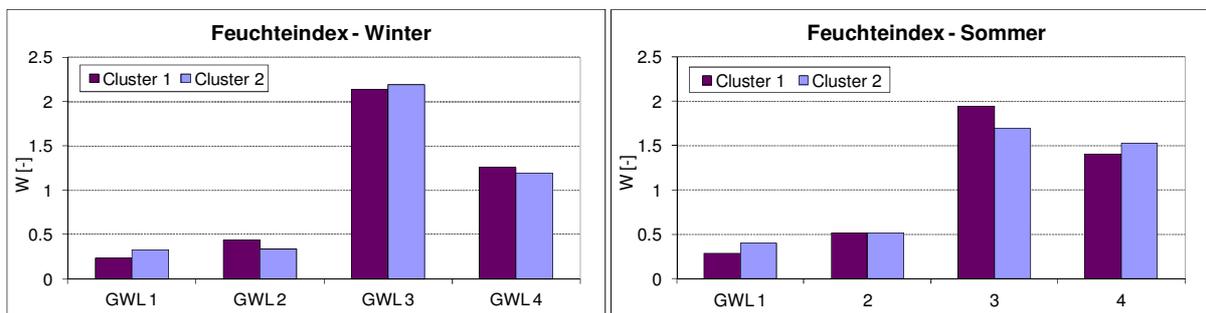


Abbildung 4-5 Feuchteindex der mit Beobachtungsdaten definierten GWL; Version mit 4 GWL

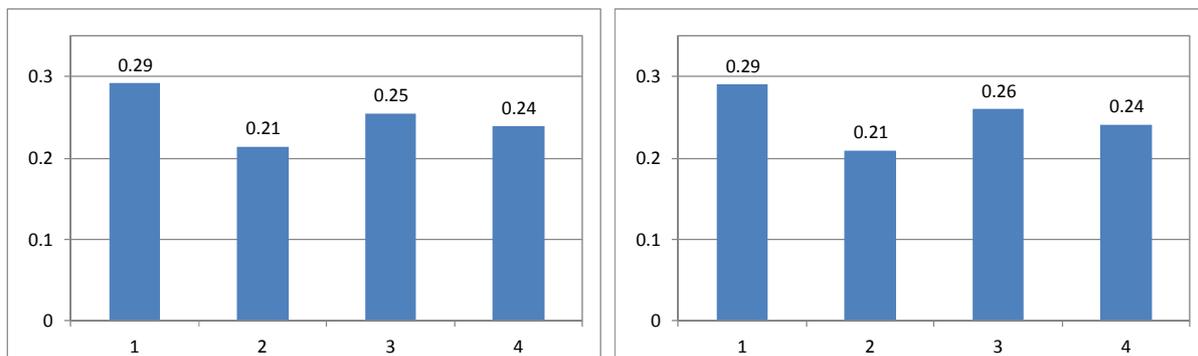


Abbildung 4-6 Anteil [-] der mit Beobachtungsdaten (Tageswerte) definierten GWL; links: Winter, rechts: Sommer; x-Achse: GWL; Version mit 4 GWL

Grund für die Erstellung dieser Version war das Ziel, ein Optimum zwischen den gewünschten diskriminativen und den ungewünschten zeitreihenverkürzenden Effekten zu erreichen. Diese Aspekte werden im Abschnitt 5, insbesondere 5.2.2.1, weiter diskutiert. Es sollten wenige GWL verwendet werden, um sehr seltene GWL zu vermeiden, und dennoch sollten je zwei trockene und nasse GWL verwendet werden. Hierdurch sollte eine sehr nasse, eine nasse, eine trockene und eine sehr trockene GWL definiert werden, die alle eine in etwa gleich große Auftretenswahrscheinlichkeit haben. Dies ist mit Einschränkungen gelungen.

Für die Version mit zwei GWL wurden die GWL 1-4 (GWL-Set 1) und 5-9 (GWL-Set 2) zusammengefasst. Der Feuchteindex der Version ist Abbildung 4-7 und die Häufigkeiten der Abbildung 4-8 zu entnehmen. Die Häufigkeiten der GWL sind nahezu identisch.

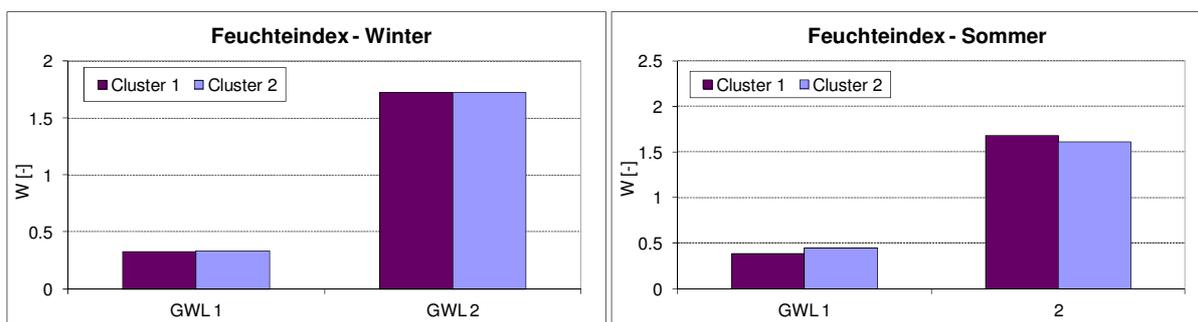


Abbildung 4-7 Feuchteindex der mit Beobachtungsdaten definierten GWL; Version mit 2 GWL

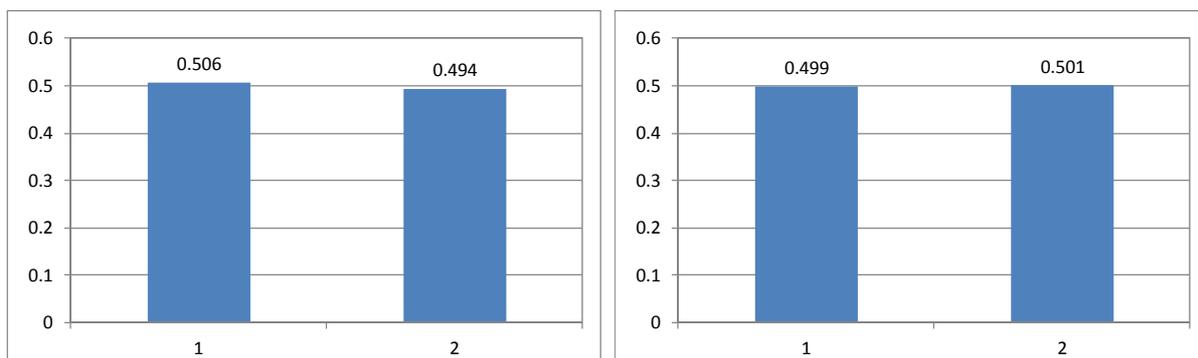


Abbildung 4-8 Anteil [-] der mit Beobachtungsdaten (Tageswerte) definierten GWL; links: Winter, rechts: Sommer; x-Achse: GWL; Version mit 2 GWL

5 Univariate Niederschlagsmodellierung

Das univariate Niederschlagsmodell erzeugt räumlich unabhängige Punktniederschlagsdaten, d. h., die Niederschläge, die an mehreren Punkten generiert werden, haben keinen zeitlichen Bezug zueinander. Wie eingangs in der Einleitung erwähnt, ist dies der erste Teil des zweiteiligen hybriden Niederschlagsmodells. In Abschnitt 7 wird die Umwandlung der Ausgabedaten der univariaten Modellierung zu räumlich konsistenten Niederschlägen erläutert.

Dieser Abschnitt diskutiert den Einfluss der Großwetterlagen auf das univariate Modell, das eine Weiterentwicklung des Modells nach Haberlandt et al. (2008) ist.

5.1 ARP-Niederschlagsmodell – Modell ohne GWL

In der univariaten Modellierung wird der Niederschlagsprozess mittels eines Alternating-Renewal-Prozesses abgebildet. Bei einem solchen Prozess werden abwechselnd An-Aus-Zustände generiert (An=Regen, Aus=kein Regen). Es wird eine Zufälligkeit des Prozesses angenommen und die Modellparameter werden als Zufallsvariablen betrachtet. Es wird hierbei angenommen, dass die Zustände unabhängig von vorangegangenen Zuständen sind.

Das Niederschlagsmodell wird in eine Stufe für die externe und eine für die interne Struktur gesplittet. Die externe Struktur definiert die äußeren Ereigniselemente, also Dauern und Volumen. Die interne Struktur hingegen bestimmt den zeitlichen Verlauf der Nassereignisse. Eine genauere Beschreibung erfolgt in den nächsten beiden Unterabschnitten.

5.1.1 Externe Struktur

In der externen Struktur des Modells werden die Nassereignisse durch ihre Dauer (*wet spell duration, wsd*) und ihre durchschnittliche Niederschlagsintensität (*wet spell intensity, wsi*) charakterisiert, während die Trockenereignisse ausschließlich durch ihre Dauer (*dry spell duration, dsd*) definiert werden. Es werden abwechselnd unabhängig voneinander Nass- und Trockenereignisse generiert.

Die Elemente der externen Struktur können der Abbildung 5-1 entnommen werden. In der Grafik sind die Nassereignisse durch rote Kästchen angedeutet, die über *wsi* und *wsd* definiert werden. Die Trockenereignisse dagegen werden als leere Elemente dargestellt. Der einzige Parameter der Trockenereignisse, die *dsd*, wird durch Ende bzw. Anfang der sie umgebenden Nassereignisse definiert.

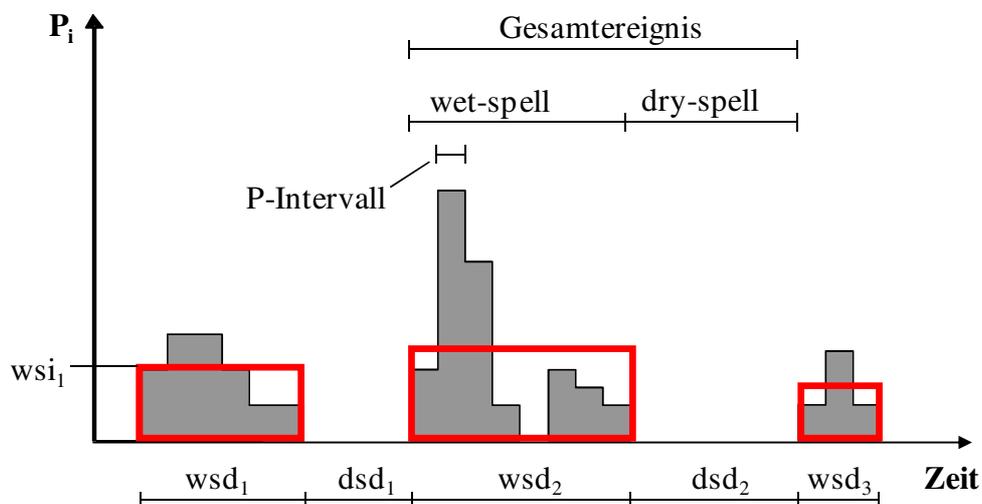


Abbildung 5-1 Schematische Darstellung des univariaten Niederschlagsmodells

Die Modellierung der externen Struktur erfolgt anhand von Verteilungsfunktionen für die jeweiligen Elemente. Da die *wsd* und *wsi* voneinander abhängig sind (siehe Abschnitt 5.2.1.1), wird dieser Zusammenhang durch die Verwendung einer Copula berücksichtigt (für ihre Funktionsweise siehe Abschnitt 5.2.1.1). Die Saisonalität der Niederschlagscharakteristika wird über eine Unterscheidung in Winter und Sommer berücksichtigt. Hierzu werden die Ereignisse der jeweiligen Saisons mit 2 getrennten Parametersätzen bestimmt.

Da die zeitlich aufeinanderfolgenden Ereignisse als vollkommen autonom voneinander betrachtet und später auch generiert werden, wird eine Unabhängigkeit der Ereignisse vorausgesetzt.

Der erste Schritt bei der Bearbeitung ist das Zusammenfassen der beobachteten 5-Minuten-Niederschlagszeitreihen zu Ereignissen. Hierbei ist das minimale *Intervall zur Trennung der Ereignisse* (*dt*) von großer Bedeutung. In einer Kalibrierung wurde festgestellt, dass ein Wert von 3 Stunden die besten Modellergebnisse lieferte. Hierfür wurde das Modell mehrfach mit verschiedenen *dt* betrieben. Es wurde das *dt* ausgewählt, welches die beste Wiedergabe der beobachteten Daten mit dem Modell ermöglichte. Zur Beurteilung der Modellgüte wurden die in Abschnitt 5.2.1.2 vorgestellten Kriterien verwendet. Eine weitere wichtige Kenngröße ist die *minimal berücksichtigte Niederschlagsintensität*. Hierbei wurde für die hochaufgelösten Beobachtungswerte der Minimalwert der Aufzeichnung (0,01 mm) gewählt. Da kein Änderungsbedarf zu erkennen war, wurde das minimale Ereignisvolumen von den Vorgängerarbeiten übernommen und auf 0,5 mm gesetzt (siehe Haberlandt et al. (2008)). Die Ereignisse mit einem Volumen unterhalb dieses Minimalwertes fanden keinen Eingang in die Modellierung; daher geht ein kleiner Teil des Jahresniederschlags verloren (ca. 5-9 %). Diese kleinen Ereignisse haben allerdings eine sehr geringe Auswirkung auf den Effektivniederschlag von Hochwasser produzierenden Abflussereignissen. Daher ist dies ein hinnehmbarer Verlust; durch diesen Kompromiss wird die Anpassung der Verteilungsfunktionen wesentlich erleichtert. Die maximal mögliche Nassereignisdauer wurde als 6000 Minuten (ca. 4 Tage) gewählt und spielte somit keine Rolle. Fehlwerte in den Beobachtungswerten wurden auf 0 gesetzt. Da nur Zeiträume mit einem sehr geringen Fehlwertanteil verwendet wurden, führte dies nicht zu relevanten Verfälschungen der Zeitreihen der Ereignisse.

Der zweite Schritt der Modellierung der externen Struktur ist die Anpassung von Verteilungsfunktionen an die *wsd*, *wsi* und *dsd*. Einhergehend mit der Anpassung der Verteilungsfunktionen wird auch die erwähnte Copula-Funktion angepasst. Eine genauere Beschreibung erfolgt im weiteren Verlauf dieses Abschnittes. Aufgrund von neuen Datenlieferungen erfolgte die Modellanpassung mehrfach mit abweichenden Zeiträumen und teilweise unterschiedlichen Stationen. Das Modell zeigte sich hierbei sehr sensitiv und unterschiedliche Verteilungsfunktionen erwiesen sich als ideal für unterschiedliche Datenzeiträume.

Mit den Verteilungsfunktionen, der Copula und Zufallszahlen können jetzt abwechselnd unabhängige Nass- und Trockenereignisse generiert werden.

5.1.2 Interne Struktur

Die interne Struktur definiert den zeitlichen Verlauf der Nassereignisse. Dies wird mit Hilfe von Modellprofilen realisiert. Hierbei wird eine symmetrische eingipflige Doppelsexponentialfunktion zur Bildung eines Profils der Disaggregation der *wet spells* eingesetzt, mit dem Ziel, eine befriedigende Wiedergabe des Intensitätsmaximums zu erzeugen. Eine realitätsnahe Abbildung der anderen Ereignisseigenschaften, z. B. Niederschlagsverlauf oder Autokorrelation, nahm eine zweitrangige Rolle ein, wobei allerdings ein Abklingen des Ereignisses gewährleistet werden soll. Naturgemäß müssen alle Intervalle des Ereignisses einen positiven Wert haben.

Laut Haberlandt (1996) erfolgte die Wahl der verwendeten Doppelsexponentialfunktion subjektiv unter Berücksichtigung der erwähnten Vorgaben.

Eingangsgroßen sind die Nassereignis-Kenngrößen Dauer und Intensität. Im ersten Schritt wird aus diesen Kenngrößen das Ereignisvolumen wsa bestimmt. Anschließend wird über eine Gleichverteilung der Peakzeitpunkt $wspt$ bestimmt. Der Peakwert wsp wird mit Hilfe einer einfachen Regression bestimmt (siehe (5-1)).

$$\ln(wsp) = \ln(\alpha) + \beta \cdot \ln(wsi), \text{ bzw. } wsp = \alpha \cdot wsi^\beta \quad (5-1)$$

Die Modellparameter α und β werden mit der Methode der kleinsten Quadrate bestimmt.

Die Funktionen zur Berechnung des auf- und absteigenden Astes sind symmetrisch und lauten für den aufsteigenden Ast:

$$P_i = wsp \cdot e^{\lambda \cdot (t - wspt)}, \text{ mit } P_i - \text{Niederschlagsvolumen des Intervalls } i \quad (5-2)$$

und für den absteigenden Ast:

$$P_i = wsp \cdot e^{-\lambda \cdot (t - wspt)} \quad (5-3)$$

Der Modellparameter λ wird für jedes Ereignis neu über die Lösung der folgenden Gleichung bestimmt:

$$f(\lambda) = \frac{1}{\lambda} \cdot wsp \cdot [2 - e^{-\lambda \cdot wspt} - e^{\lambda \cdot (wspt - wsd)}] - wsa = 0 \quad (5-4)$$

Weitere Details hierzu sind Haberlandt (1996) zu entnehmen.

5.2 Modellkomponenten und -varianten – Implementierung der GWL

In den folgenden Unterabschnitten werden die verschiedenen Modellaufbauten, mit und ohne GWL, vorgestellt und diskutiert.

Zu Beginn der Diskussion der Modellvarianten wird der Modellaufbau von Haberlandt et al. (2008) ohne GWL und ohne Veränderung des Modellaufbaus mit den Daten des Untersuchungsgebiets angewendet. Anschließend wird der Modellaufbau mit und ohne GWL auf die Daten abgestimmt.

5.2.1 Validierung der Modellübertragung auf das Gebiet

In diesem Abschnitt erfolgt wie erwähnt die Anwendung des Ursprungszustands des Modells auf das Untersuchungsgebiet. Zu Beginn wird der Modellaufbau vorgestellt und anschließend werden die Ergebnisdaten diskutiert.

5.2.1.1 Ursprünglicher Modellaufbau

Der ursprüngliche Modellaufbau entsprechend Haberlandt et al. (2008) ist der Tabelle 5-1 zu entnehmen.

Tabelle 5-1 Modellaufbau des Ausgangszustandes

| Element | Kürzel | Methodik | Parameteranzahl |
|---|--------|---------------------------------------|-----------------|
| Nassereignisdauern | wsd | Verallgemeinerte Extremwertverteilung | 3 |
| Trockenereignisdauern | dsd | Weibull-3-Verteilung | 3 |
| Nassereignisintensitäten | wsi | Kappa-Verteilung | 4 |
| Zusammenhang wsd - wsi | - | Frank-Copula | 1 |
| Interne Struktur | - | Doppelsexponentialfunktion | 2 |
| Die Parameterschätzung erfolgt mittels L-Momente. | | | |

Für die *wsd* wird die verallgemeinerte Extremwertverteilung (abgekürzt *GEV* für *Generalized Extreme Value Distribution*) verwendet, die sich zur Erfassung und Synthese der seltenen (extremere) Werte besonders gut eignet. Diese Verteilungsfunktion wird, wie in (5-5) und (5-6), gezeigt definiert.

$$F(x) = \exp \left\{ - \left[1 - \frac{\kappa \cdot (x - \xi)}{\alpha} \right]^{1/\kappa} \right\}, \text{ für } \kappa \neq 0 \quad (5-5)$$

$$F(x) = e^{- \left[1 - \frac{\kappa \cdot (x/\xi)}{\alpha} \right]^{1/\kappa}}, \text{ für } \kappa \neq 0 \quad (5-6)$$

Der Wertebereich liegt bei:

$$x < (\xi + \alpha/\kappa), \text{ wenn } \kappa > 0$$

$$-\infty < x < \infty, \text{ wenn } \kappa = 0$$

$$x > (\xi + \alpha/\kappa), \text{ wenn } \kappa < 0$$

Die GEV besitzt die 3 Parameter $\xi \in \mathbb{R}$ (Lage), $\alpha > 0$ (Streuung) und $\kappa \in \mathbb{R}$ (Form). Für die Sonderfälle $\kappa = 0$ entspricht die GEV einer Gumbelverteilung und für $\kappa = 1$ einer umgekehrten Exponentialverteilung. Mehr zu der Verteilungsfunktion ist zum Beispiel Prescott & Walden (1983) zu entnehmen.

Für die *dsd* wurde eine andere gängige Extremwertverteilung, die Weibull-3-Verteilung, gewählt. Ihre Verteilungsfunktion lautet:

$$F(x) = 1 - e^{- \left[\frac{x - \mu}{\beta} \right]^\alpha} \quad (5-7)$$

Der Wertebereich liegt bei $x > \mu$. Die Verteilung hat die Parameter $\alpha > 0$ (Lage), $\beta > 0$ (Streuung) und $\mu \in \mathbb{R}$ (Form). Mehr dazu kann beispielsweise Teimouri & Gupta (2013) entnommen werden.

Die *wsi* wurden mit der 4-parametrischen Kappa-Verteilung modelliert. Die Verteilungsfunktion lautet:

$$F(x) = \left\{ 1 - h \cdot \left[1 - \frac{h \cdot (x - \zeta)}{\alpha} \right]^{1/k} \right\}^{1/h} \quad (5-8)$$

Der Wertebereich ist beschränkt auf:

$$x < \zeta + \alpha, \text{ wenn } \kappa > 0$$

$$x < \infty, \text{ wenn } \kappa < 0$$

und:

$$\xi + \frac{\alpha \cdot (1 - h^{-\kappa})}{\kappa} < x, \text{ wenn } h > 0$$

$$\xi + \frac{\alpha}{\kappa} < x, \text{ wenn } h \leq 0 \text{ und } \kappa < 0$$

$$-\infty < x, \text{ wenn } h \leq 0 \text{ und } \kappa \geq 0$$

Die Sonderfälle $\kappa=0$ und $h=0$ sind implizit als kontinuierliche Beschränkungen in den Formeln enthalten; siehe Hosking & Wallis (1997). Für den Sonderfall $h=-1$ wird die Kappa-Verteilung zur verallgemeinerten logistischen Verteilung, für $h=0$ zur GEV und für $h=1$ zur verallgemeinerten Pareto-Verteilung. Die Parameter der Kappa-Verteilung sind $\xi \in \mathbb{R}$ (Lage), $\alpha > 0$ (Streuung) und die beiden Formparameter $h \in \mathbb{R}$ und $k \in \mathbb{R}$. Weiteres zur Kappa-Verteilung kann Shabri & Jemain (2010) entnommen werden. Näheres zur GEV kann Hosking & Wallis (1997) entnommen werden.

Zur Schätzung der Parameter der Verteilungsfunktionen wurde die Methode der **L-Momente** verwendet. L-Momente stellen bei der Parameterschätzung eine Alternative zur Verwendung der statistischen Momente (Mittelwert, Varianz, Schiefe und Wölbung) dar. Sie basieren auf den wahrscheinlichkeitsgewichteten Momenten (WGM).

WGM sind wie folgt definiert (siehe Greenwood et al. (1979)):

$$M_{p,r,s} = E[X^p \{F(x)\}^r \cdot \{1 - F(x)\}^s] \quad (5-9)$$

$F(x)$ ist die Verteilungsfunktion. Es werden besonders die beiden Sonderfälle $\alpha_r = M_{1,0,r}$ und $\beta_r = M_{1,r,0}$ betrachtet. Hiermit ergibt sich mit der Quantilfunktion $x(u)$:

$$\alpha_r = \int_0^1 x(u)(1-u)^r du, \quad \beta_r = \int_0^1 x(u)u^r du, \quad u = F(x) \quad (5-10)$$

Anders als bei den statistischen Momenten steht der Exponent der WGM an der Wahrscheinlichkeit u und nicht am Quantil $x(u)$. Hierdurch ergibt sich ein Schätzverfahren, das für Fehler durch Ausreißer weniger anfällig ist.

Eine vertiefte Darstellung der wahrscheinlichkeitsgewichteten Momente ist Hosking & Wallis (1997) zu entnehmen. Allerdings sind die WGM für eine direkte Parameterschätzung schwer zu interpretieren. Daher wurden Linearkombinationen der WGM entwickelt, mit denen Streuung und Form abgebildet werden können (siehe Hosking & Wallis (1997)). Diese Linearkombinationen der WGM werden als L-Momente λ bezeichnet. Die Linearkombinationen der 1. bis 4. Ordnung lauten:

$$\begin{aligned} \lambda_1 &= \alpha_0 & \lambda_1 &= \beta_0 & (5-11) \\ \lambda_2 &= \alpha_0 - 2\alpha_1 & \lambda_2 &= 2\beta_1 - \beta_0 \\ \lambda_3 &= \alpha_0 - 6\alpha_1 + 6\alpha_2 & \lambda_3 &= 6\beta_2 - 6\beta_1 + \beta_0 \\ \lambda_4 &= \alpha_0 - 12\alpha_1 + 30\alpha_2 - 20\alpha_3 & \lambda_4 &= 20\beta_3 - 30\beta_2 + 12\beta_1 - \beta_0 \end{aligned}$$

λ_1 entspricht hierbei dem Mittelwert. Für eine Erläuterung der L-Momente höherer Ordnung wird erneut auf Hosking & Wallis (1997) verwiesen.

Für die Parameterschätzung werden im Allgemeinen λ_1 und λ_2 direkt verwendet. Statt λ_3 und λ_4 werden allerdings meist die dimensionslosen Quotienten mit λ_2 verwendet:

$$\tau_r = \lambda_r / \lambda_2, \quad r = 3, 4, \dots \quad (5-12)$$

Für die Parameterschätzung wurde die Programmiersprache R (siehe R Development Core Team (2008) und das Paket $lmomco$ (siehe Asquith (2011)) verwendet. Für die detaillierte Diskussion der Formeln der Parameterschätzung der einzelnen Verteilungsfunktionen wird auf Asquith (2011), Hosking & Wallis (1997), Stedinger et al. (1993) oder Kluge (1996) verwiesen.

Copulas werden verwendet, um die Abhängigkeiten von Zufallsvariablen zu reproduzieren. Es muss das Problem gelöst werden, dass Randverteilungen und Korrelation alleine die Abhängigkeit zweier Zufallsvariablen nicht ausreichend beschreiben. Im Extremfall kann eine Abhängigkeit vorliegen, welche durch keine Korrelation erfasst werden kann (siehe z. B. Embrechts et al. (2003)).

Bei Copulas wird dieses Problem durch Zerlegung in eine multivariate Verteilungsfunktion der Abhängigkeit (die Copulafunktion C) und die Verteilung der Zufallsvariablen (die Randverteilungen $F_i(x_i)$) gelöst. Als Randverteilungen werden Wahrscheinlichkeitsverteilungen der einzelnen Zufallsvariablen bezeichnet, wenn mehrere abhängige Zufallsvariablen im Zusammenhang betrachtet werden.

Im Modell wird der 2-dimensionale Fall angewendet; daher wird dieser Fall diskutiert. Verwendet werden die bivariaten Beobachtungsdaten (wsd und wsi) in der Form $(X_1, Y_1), \dots, (X_n, Y_n)$. Die Copula ergibt sich somit zu:

$$F(x_1, x_2) = C(F_1(x_1), F_2(x_2)) \quad (5-13)$$

Die Copulafunktionen $C:[0,1]$ sind multivariate Funktionen mit gleichverteilten Randverteilungen. Die Randverteilungen lauten $F_1(x_1)$ und $F_2(x_2)$.

Es gilt nach Sklar (siehe Sklar (1996)), dass für jede n-dimensionale Verteilungsfunktion F mit den Randverteilungen F_1, \dots, F_n eine n-Copula existiert. Es gilt für alle $x \in [-\infty, +\infty]$:

$$F(x_1, \dots, x_n) = C(F_1(x_1), \dots, F_n(x_n)) \quad (5-14)$$

Wenn alle Randverteilungen F_i stetig sind, ist C immer eindeutig. Da für unsere Betrachtungen nur stetige Verteilungsfunktionen verwendet werden, ist eine eindeutige Lösung des Problems möglich.

Eine gängige Einteilung der Copulas unterscheidet in *archimedische* und *elliptische* Copulas. Elliptische Copulas sind radial symmetrische Copulas, die aus elliptischen Verteilungsfunktionen abgeleitet werden. Gängige elliptische Copulas sind die Normal- und T-Copula.

Im Gegensatz zu den elliptischen erlauben die archimedischen Copulas, das Abhängigkeitsproblem auf eine univariate explizit formulierbare Funktion zu vereinfachen. Für archimedische Copulas muss gelten:

$$C(u, v) = \phi^{-1}\{\phi(u) + \phi(v)\} \quad (5-15)$$

Hierbei wird ϕ als *Generator* der Copula bezeichnet, der folgendes Kriterium erfüllen muss (siehe z. B. Salvadori (2007) oder Genest & Mackay (1986)):

$$\phi: (0,1] \rightarrow [0, \infty), \text{ so dass } \phi(1) = 0 \quad (5-16)$$

Weiterhin muss für die pseudoinverse Funktion gelten:

$$\phi^{-1}(t) = 0, \text{ für alle } t > \phi(0) \quad (5-17)$$

Beispiele für gängige archimedische Copulas sind *Clayton*-, *Frank*- oder *Gumbel*-Copula. Weitere Informationen zum Thema Copulas und multivariate Modellierung können Salvadori (2007), Embrechts et al. (2003), Joe (1997) oder Nelsen (2006) entnommen werden.

Zur Wiedergabe des Zusammenhanges zwischen *wsd* und *wsi* wurde die symmetrische, archimedische **Frank-Copula** gewählt. Dies geschah aus praktischen Gründen wie der passenden Abhängigkeitsspannweite, der einfachen Parameterschätzmethode und der Simulationsmerkmale, (siehe Haberlandt et al. (2008)). Eine Frank-Copula wurde bereits von De Michele & Salvadori (2003) erfolgreich zur Berücksichtigung der Abhängigkeiten zwischen Nassereignisdauern und Intensitäten eingesetzt.

Eine Copula der Frank-Familie kann wie folgt formuliert werden:

$$C_\delta(u, v) = \ln \left(1 + \frac{(e^{-\delta u} - 1) \cdot (e^{-\delta v} - 1)}{e^{-\delta} - 1} \right), \text{ mit } u, v \in I \text{ und } \delta \in \mathbb{R} \quad (5-18)$$

Hierbei stehen u und v für die Verteilungsfunktionen $F(x)$ von *wsi* und *wsd*. Diese Funktion hat nur einen Parameter δ . Für den Fall, dass δ größer null ist ($\delta > 0$), liegt eine positive Abhängigkeit vor, bei δ ($\delta < 0$) eine negative; $\delta = 0$ zeigt an, dass die Variablen u und v voneinander unabhängig sind.

In den Untersuchungen ergaben sich stets δ -Werte von -0,5 bis -1,5. Dies gilt für die Betrachtung mit und ohne GWL. Die erwartete, starke negative Abhängigkeit zwischen *wsi* und *wsd* ist somit bestätigt. Ausnahme ist die Winter-Saison der hoch gelegenen Harz-Station Braunlage, für welche δ -Werte von circa +1 auftreten. In dieser Station, die aufgrund ihrer hohen Lage eine Ausnahme in dieser Untersuchung darstellt, scheinen im Winter große Ereignisdauern mit großen Intensitäten einherzugehen.

Der Parameter δ kann mit Hilfe des Kendall's Tau Rangkorrelationskoeffizienten über eine Annäherung bestimmt werden:

$$\tau(\delta) = \frac{1}{9} \delta - \frac{1}{900} \delta^3 + \frac{1}{52920} \delta^5 + \frac{1}{2721600} \delta^7 + \dots \quad (5-19)$$

Diese Annäherung erzielt für $\delta < 5$ gute Ergebnisse. Für die praktische Anwendung kann im Bereich $\delta < 5$ auch vereinfacht mit $\tau(\delta) = \delta / 9$ gerechnet werden (siehe De Michele & Salvadori (2003)). Hierbei gilt $\tau(-\delta) = -\tau(\delta)$. Weitere Details zur Parameterschätzung können De Michele & Salvadori (2003) oder (unter Verwendung einer anderen Schreibweise der Copula) Salvadori (2007) entnommen werden. Andere Parameterschätzverfahren sind verfügbar (z. B. unter Verwendung von Spearman's Rho). Da die beschriebene Methode sehr erprobt ist, wird auf diese zurückgegriffen.

Für die Parameterschätzung der Copula wurden die Programmiersprache *R* und das Paket *copula* (siehe Kojadinovic & Yan (2010)) verwendet.

Bei Verwendung der Copula ergab sich eine Schwierigkeit. In der Beobachtung kommen kurze *wsd* vergleichsweise häufig in Kombination mit großen *wsi* vor. Ebenfalls kommen niedrige *wsi* oft gemeinsam mit hohen *wsd* vor. Dies führt dazu, dass archimedische Copula (wie die verwendete Frank-Copula) schwierig an diese Bedingungen angepasst werden können. Für die Zukunft wäre daher zu überlegen, eine elliptische Copula, beispielsweise die T-Copula, für die Modellierung zu verwenden.

5.2.1.2 Niederschlagsgenerierung und -validierung

Eine ausführliche Diskussion der Niederschlagsgenerierung und -validierung für alle 29 Stationen einzeln würde unnötig viel Platz einnehmen. Stattdessen erläutert dieser Abschnitt die gewählte Methode der Niederschlagsgenerierung und -validierung anhand einiger ausgewählter Stationen, welche die relevanten Regionen (Küste, Binnenland, Mittelgebirge) des Untersuchungsgebietes abdecken (siehe Tabelle 5-2).

Für die Region Binnenland wurden zwei Stationen in verschiedenen Teilen von Niedersachsen gewählt. Bei der Darstellung wird auf das Gesamtjahr verzichtet und nur die Saisons (Sommer und Winter) dargestellt, da diese alle für die Diskussion relevanten Informationen enthalten. Es wurde darauf geachtet, dass die dargestellten Informationen repräsentativ für die Ergebnisse aller Stationen sind.

Tabelle 5-2 Stationsliste der Auswertungen

| Stations-ID | Stations-Name | Region |
|-------------|---------------|--------------------|
| 01055 | Norderney | Küste/Inseln |
| 01519 | Diepholz | Binnenland - West |
| 01529 | Soltau | Binnenland - Heide |
| 03984 | Braunlage | Hochland - Harz |

Die statistischen Momente der Ereignisse werden in allen Regionen recht gut wiedergegeben (siehe Tabelle 5-3 und Tabelle 5-4). Aus Platzgründen werden im Fließtext nur die Mittelwerte dargestellt, (während die höheren Momente im Anhang dargestellt werden). Diese sind mit Ausnahme des Ereignisvolumens die direkt in die Modellierung als Eingangsdaten eingehenden Werte. Die synthetischen Daten wurden mittels einer 1000-jährigen synthetischen Zeitreihe ermittelt, die den 10 bis 15-jährigen Beobachtungszeitreihen gegenübergestellt werden. Die Zeitreihe für 1000 Jahre wurde in Form von zehn 100-jährigen Zeitreihen generiert. Dieses Vorgehen wurde gewählt, um eine Unsicherheitsanalyse in den Extremwerten zu ermöglichen. Hierauf wird an etwas späterer Stelle in diesem Abschnitt eingegangen.

Da in das Modell L-Momente und nicht die statistischen Momente selbst eingehen (siehe Abschnitt 5.2.1.1 und Tabelle A-4), können die höheren statistischen Momente der Ereignisse (siehe Tabelle A-3) daher bereits als Indiz für die Leistungsfähigkeit des Modells betrachtet werden. Die höheren Momente werden i. d. R. ebenfalls zufriedenstellend wiedergegeben. Allerdings gibt es teilweise Probleme; insbesondere die höheren Momente der *wsa* und *wsi* zeigen relativ hohe Abweichungen von der Beobachtung.

Tabelle 5-3 Modellübertragung auf das Gebiet – Mittelwerte der Ereignisse – Winter

| Stations-ID | Mittelwert dsd | | Mittelwert wsd | | Mittelwert wsi | | Mittelwert wsa | |
|-------------|----------------|------|----------------|-----|----------------|------|----------------|------|
| | obs | syn | obs | syn | obs | syn | obs | syn |
| 01055 | 2607 | 2606 | 388 | 388 | 0,57 | 0,57 | 3,49 | 3,47 |
| 01519 | 2654 | 2642 | 388 | 388 | 0,59 | 0,60 | 3,57 | 3,63 |
| 01529 | 2644 | 2636 | 458 | 458 | 0,58 | 0,59 | 4,30 | 4,27 |
| 03984 | 2190 | 2171 | 679 | 659 | 0,63 | 0,64 | 7,94 | 7,56 |

Tabelle 5-4 Modellübertragung auf das Gebiet – Mittelwerte der Ereignisse – Sommer

| Stations-ID | Mittelwert dsd | | Mittelwert wsd | | Mittelwert wsi | | Mittelwert wsa | |
|-------------|----------------|------|----------------|-----|----------------|------|----------------|------|
| | obs | syn | obs | syn | obs | syn | obs | syn |
| 01055 | 2760 | 2747 | 335 | 336 | 0,96 | 0,96 | 4,68 | 4,79 |
| 01519 | 3082 | 3035 | 313 | 313 | 1,04 | 1,05 | 4,68 | 4,77 |
| 01529 | 2868 | 2825 | 339 | 340 | 1,05 | 1,06 | 4,92 | 5,06 |
| 03984 | 2545 | 2525 | 454 | 442 | 1,07 | 1,07 | 7,10 | 7,29 |

Bei den abgeleiteten Kennwerten Ereignisanzahl und Niederschlagssumme (siehe Tabelle 5-5) zeigen sich auch gute Resultate. Jedoch zeigt sich besonders für den Sommer, dass die Ergebnisse noch ausbaubar sind.

Tabelle 5-5 Modellübertragung auf das Gebiet – Abgeleitete Werte

| Stations-ID | Sommer | | | | Winter | | | |
|-------------|----------------|------|---------------------|-----|----------------|------|---------------------|-----|
| | Ereignisanzahl | | Niederschlags-summe | | Ereignisanzahl | | Niederschlags-summe | |
| | obs | syn | obs | syn | obs | syn | obs | syn |
| 01055 | 85,1 | 86,0 | 398 | 412 | 87,5 | 87,1 | 305 | 302 |
| 01519 | 77,5 | 79,3 | 363 | 379 | 85,7 | 86,0 | 306 | 312 |
| 01529 | 81,2 | 83,7 | 400 | 423 | 84,8 | 84,4 | 364 | 361 |
| 03984 | 88,3 | 89,4 | 627 | 651 | 90,3 | 92,1 | 717 | 696 |

Ein weiteres wichtiges Kriterium zur Beurteilung der Modellgüte sind die Extremwerte. Aufgrund der Aufgabenstellung des Modells, nämlich die Datengenerierung für die Hochwassermmodellierung, wurde den Extremwerten ein hoher Stellenwert beigemessen. Es wurden mehrere Dauerstufen verwendet und sowohl grafische als auch statistische Auswertungen vorgenommen.

Die verwendeten Dauerstufen sind 1, 3, 6, 12 und 24 Stunden und wurden als gleitendes Fenster aus der Stundenwertzeitreihe ermittelt. Die verwendeten statistischen Kriterien sind zwei einfache Abstandsmaße und zwei Stichprobentests.

Das erste Abstandskriterium behandelt den absoluten Abstand der synthetischen und beobachteten Extremwerte desselben Wiederkehrintervalls:

$$D_{abs} = \frac{1}{n} \sum_{i=1}^n \left(w \left| \frac{X_{syn}(T_i) - X_{obs}(T_i)}{X_{obs}(T_i)} \right| \right) \quad (5-20)$$

w – Gewichtungsfaktoren

$X_{obs}(T_i)$ – Wert der Beobachtung des Wiederkehrintervalls i

$X_{syn}(T_i)$ – Wert der Synthese des Wiederkehrintervalls i

n – Anzahl der verwendeten Quantile

Die Anzahl der betrachteten Quantile richtet sich nach der Länge der Beobachtung. Es wurden zwei Versionen des Kriteriums betrachtet. Die erste ($D_{abs,n}$) hat eine Gewichtung von $1/n$ für alle Wiederkehrintervalle, die zweite ($D_{abs,w}$) hat eine ansteigende Gewichtung von $w = i / \sum_{j=1}^n j$, so dass die selteneren Extremwerte stärker berücksichtigt werden.

Das zweite Abstandskriterium soll einen eventuellen Bias erfassen:

$$D_{sign} = \frac{1}{n} \sum_{i=1}^n \left(w \frac{X_{syn}(T_i) - X_{obs}(T_i)}{X_{obs}(T_i)} \right) \quad (5-21)$$

Ein positiver Wert für D_{sign} deutet also auf eine Überschätzung der Extremwerte durch die Synthese hin, während ein negativer Wert eine Unterschätzung anzeigt. Es wurden ebenfalls zwei Versionen des Kriteriums betrachtet. Die erste ($D_{sign,n}$) hat eine Gewichtung von $1/n$ für alle Wiederkehrintervalle, die zweite ($D_{sign,w}$) hat eine ansteigende Gewichtung von $w = i / \sum_{j=1}^n j$ (i entspricht dem i aus (5.21) und j ist eine weitere Laufvariable), sodass auch hier die selteneren Extremwerte wieder stärker berücksichtigt werden.

Weiterhin wurden noch zwei statistische Testverfahren verwendet, um zu prüfen, ob die Stichproben der beobachteten und synthetischen Extremwerte derselben Verteilung entstammen. Der erste dieser Tests ist der Kolmogoroff-Smirnoff-Anpassungstest (K-S-Test). Dieser Test beruht auf der Analyse des maximalen Abstands der beiden empirischen Verteilungen zueinander. Der Wert der K-S-Statistik wird wie folgt bestimmt:

$$D_{n,n'} = \sup_x \left| F_{1,n}(x) - F_{2,n}(x) \right| \quad (5-22)$$

\sup_x – Supremum (obere Grenze) der Abweichungen

$F_{1,n}$ und $F_{2,n}$ – empirische Verteilungsfunktion der beiden Teststichproben

Weiteres zum K-S-Test kann beispielsweise Sachs (2004) entnommen werden.

Der zweite Anpassungstest ist der Cramér-von-Mises (auch $n\omega^2$ genannt)-Test. Das Prinzip des Tests basiert auf dem Vergleich der empirischen Verteilungen der beiden Stichproben. Die Teststatistik des $n\omega^2$ -Stichprobentests wird, wie in (5-23) gezeigt, berechnet.

$$n\omega^2 = \frac{U}{NM(N+M)} - \frac{4MN-1}{6(M+N)} \quad (5-23)$$

$$\text{Mit: } U = N \sum_{i=1}^N (r_i - i)^2 + M \sum_{j=1}^N (s_j - j)^2$$

Hierbei stehen r_i und s_j für den Rang der gemeinsam sortierten Werte der Stichproben X und Y mit den Stichprobenmengen N und M . Weiteres kann der einschlägigen Literatur, z. B. Anderson (1962), entnommen werden.

Da das Verwenden der Teststatistiken allein als Indiz gelten kann, aber keine eindeutige Aussagekraft hat, werden die p -values hinzugezogen. Ein p -value gibt das größte Signifikanzniveau an, für das eine Nullhypothese verworfen werden kann. Wenn z. B. ein Signifikanzniveau von 0,05 angesetzt werden soll, wird die Nullhypothese beibehalten, sofern der ermittelte p -value größer 0,05 ist. Hier wird also geprüft, wie häufig ein p -value größer 0,05 erzielt wird und anschließend die Gesamthäufigkeit der erfolgreichen Tests verglichen. Bei 29 Stationen und zehn synthetischen Datensätzen pro Station können theoretisch 290 erfolgreiche Tests erzielt werden. Die Nullhypothese beider Tests ist, dass die beiden Stichproben (beobachtete und modellierte Extremwerte) statistisch gleichwertig sind.

Auch für die Extremwerte wird wieder nur die jeweilige Saison (Sommer und Winter) gezeigt. Dies ist auch völlig ausreichend, da bei kleinen Dauerstufen für alle Stationen die Sommerextremwerte fast vollständig mit den Jahresextremwerten übereinstimmen und selbst für die höchste analysierte Dauerstufe von 24 Stunden die Unterschiede zwischen Sommer und Gesamtjahr vernachlässigbar gering sind.

In Abbildung 5-2 und Abbildung 5-3 werden die Extremwertverteilungen der synthetischen und beobachteten Extremwerte einander gegenübergestellt. Es wird bewusst entgegen der oben getroffenen Vereinbarung zu den darzustellenden Stationen (siehe Tabelle 5-2) für den Sommer die Station 03400 (Leinefelde) und für den Winter 03193 (Harzgerode) gezeigt. Die Auswahl wurde so getroffen, dass sowohl ein Beispiel einer guten Wiedergabe der Sommerextremwerte (Station 01529) als auch einer schlechten gezeigt werden kann (Station 03400/03193).

Man sieht in den Grafiken die Quantile der Beobachtung und der zehn Modelldurchläufe der Synthese. Im Idealfall sind die Quantile der Beobachtungswerte genau in der Mitte der Quantile der Synthese. Hierbei ist optimalerweise die Streuung der synthetischen Werte möglichst gering. In der Mehrheit der Fälle gelingt dies recht gut (siehe Station 01529), in anderen Fällen nicht so gut (Station 03400/03193). Die grafisch dargestellte Station 03400 ist etwas untypisch, da für $dt=1h$ die synthetischen Extrema deutlich überschätzt werden, während diese bei den meisten Stationen eher die Beobachtung unterschätzen. Es liegen keine systeminhärenten, für alle Stationen geltenden Unterschätzungen bzw. Überschätzungen vor.

Die grafische Darstellung eignet sich aber nur für die Analyse einzelner Stationen. Wenn man, wie wir in den späteren Abschnitten dieser Arbeit, verschiedene Modellaufbauten vergleichen will, muss man Werte verwenden, die alle Stationen und Modelldurchläufe erfassen, also die vorgestellten Indizes.

Tabelle 5-6 und Tabelle 5-7 zeigen die Indizes der Extremwerte. Dargestellt werden Mittelwerte (gekennzeichnet mit Strichen über den Kenngrößen) und die Summen der Signifikanz kennzeichnenden p -Values für alle Stationen und Durchläufe. Zur Analyse der Tabelle wird daran erinnert, dass 29 Stationen mit jeweils 10 Modelldurchläufen verwendet wurden. Daher können maximal 290 der statistischen Tests anzeigen, dass die synthetischen Daten derselben Verteilung entspringen wie die beobachteten. Auch hier ist zu erkennen, dass die Extremwerte recht gut wiedergegeben werden. Festzustellen ist jedoch, dass mit Zunahme der Dauerstufe eine Verschlechterung der Reproduktion zu erkennen ist. Ausnahme ist der Sprung von $dt=12h$ auf $dt=24h$, bei dem eine Verbesserung in den Indizes vorhanden ist. An $D_{sign,n}$ ist zu erkennen, dass für beide Jahreszeiten bei $dt=1h$ die Extremwerte eher leicht unterschätzt, für alle anderen Dauerstufen allerdings leicht überschätzt werden. Im Vergleich Sommer zu Winter sind klare Unterschiede erkennbar. Allgemein werden die Winterextrema etwas besser reproduziert.

Insbesondere sind die Verschlechterungen mit zunehmender Dauerstufe geringer als im Sommer. Hier ist eher zu sehen, dass $dt=1h$ und $dt=24h$ in etwa gleich gut reproduziert werden, während die Extrema der Dauerstufen zwischen diesen etwas schlechter wiedergegeben werden, mit einem negativen Peak bei $dt=3h$.

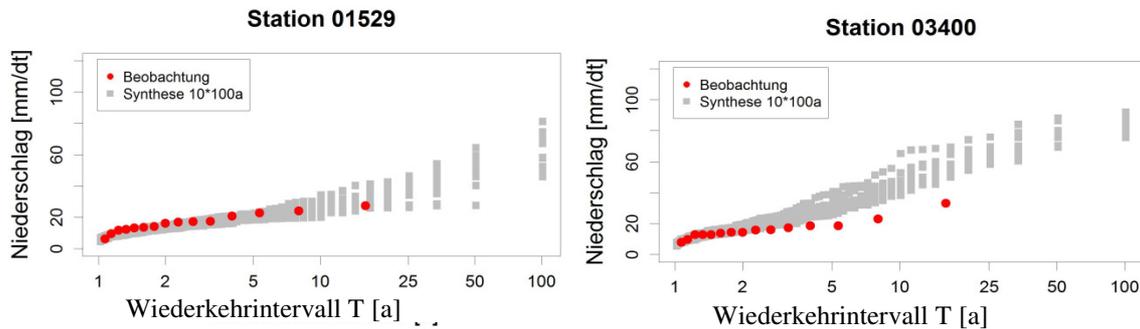


Abbildung 5-2 Sommerextremwerte, $dt=1h$

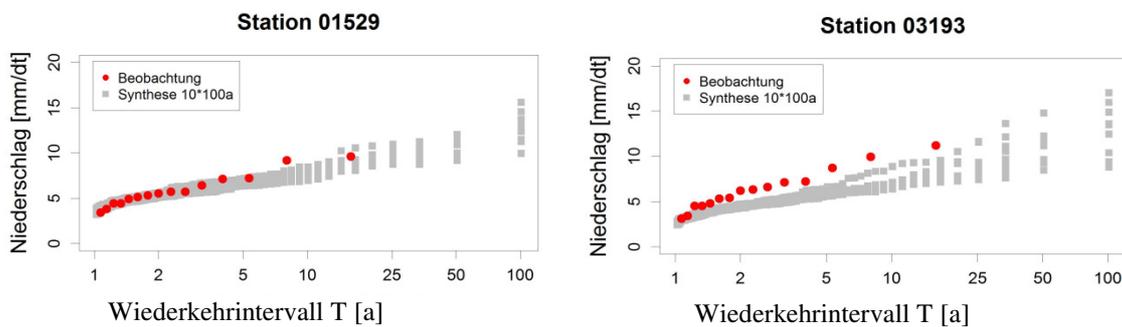


Abbildung 5-3 Winterextremwerte, $dt=1h$

Tabelle 5-6 Indizes der Extremwerte im Mittel über alle Stationen, Sommer; p-value (Test) gibt die Anzahl synthetischer Zeitreihen an, deren Extremwerte dieselbe Verteilung haben wie die Beobachtung

| dt [h] | $\overline{D_{abs,n}}$ [mm/h] | $\overline{D_{abs,w}}$ [mm/h] | $\overline{D_{sign,n}}$ [mm/h] | $\overline{D_{sign,w}}$ [mm/h] | $\overline{n\omega^2}$ | p-value ($\overline{n\omega^2}$) | $\overline{D_{n,n'}}$ | p-value (K-S-Test) |
|--------|----------------------------------|----------------------------------|-----------------------------------|-----------------------------------|------------------------|---------------------------------------|-----------------------|-----------------------|
| 1 | 0,17 | 0,16 | -0,06 | -0,11 | 0,023 | 264 | 0,029 | 260 |
| 3 | 0,29 | 0,20 | 0,24 | 0,15 | 0,034 | 240 | 0,033 | 254 |
| 6 | 0,36 | 0,27 | 0,34 | 0,24 | 0,050 | 176 | 0,038 | 186 |
| 12 | 0,36 | 0,27 | 0,35 | 0,25 | 0,048 | 172 | 0,038 | 200 |
| 24 | 0,29 | 0,22 | 0,27 | 0,20 | 0,037 | 205 | 0,033 | 225 |

Tabelle 5-7 Indizes der Extremwerte im Mittel über alle Stationen, Winter; p-value (Test) gibt die Anzahl synthetischer Zeitreihen an, deren Extremwerte dieselbe Verteilung haben wie die Beobachtung

| dt [h] | $\overline{D_{abs,n}}$ [mm/h] | $\overline{D_{abs,w}}$ [mm/h] | $\overline{D_{sign,n}}$ [mm/h] | $\overline{D_{sign,w}}$ [mm/h] | $\overline{n\omega^2}$ | p-value ($\overline{n\omega^2}$) | $\overline{D_{n,n'}}$ | p-value (K-S-Test) |
|--------|----------------------------------|----------------------------------|-----------------------------------|-----------------------------------|------------------------|---------------------------------------|-----------------------|-----------------------|
| 1 | 0,13 | 0,10 | -0,05 | -0,04 | 0,021 | 253 | 0,027 | 265 |
| 3 | 0,16 | 0,14 | 0,12 | 0,11 | 0,029 | 229 | 0,030 | 236 |
| 6 | 0,16 | 0,13 | 0,12 | 0,09 | 0,030 | 238 | 0,031 | 241 |
| 12 | 0,16 | 0,13 | 0,11 | 0,07 | 0,027 | 237 | 0,029 | 240 |
| 24 | 0,14 | 0,11 | 0,06 | 0,02 | 0,020 | 268 | 0,026 | 267 |

5.2.2 Implementierung der GWL

Bei der Einführung der GWL in das univariate Modell wurden verschiedene Methoden ausprobiert.

Als Erstes wurde den beobachteten Ereignissen die jeweils ideale GWL zugewiesen, was kein triviales Problem darstellt. Die erste getestete Methode (M1) war es, dem Ereignis die GWL aufzuprägen, die zu Beginn des Nass- bzw. Trockenereignisses vorherrschte. Dies ist für die kurzen *wsd* im Normalfall ausreichend, aber nicht für die langen *dsd*, die durchaus über viele Tage gehen und daher mehrere GWL aufweisen können. Der zweite Ansatz (M2) war daher, die GWL zu verwenden, die zum Ende des Ereignisses vorherrscht. Der Gedanke war, dass die Länge der Trockendauer von dem Zeitpunkt bestimmt wird, an dem es wieder anfängt zu regnen, also auch durch die GWL, die an diesem Zeitpunkt vorherrscht. Beim dritten Ansatz (M3a) wird den Ereignissen die GWL zugewiesen, die während der Dauer der Ereignisse am häufigsten auftritt.

Ansatz (M3a) lieferte die besten Ergebnisse. Daher konzentriert sich die Untersuchung dieser Arbeit auf diesen Ansatz. Bei der Generierung ist neben den getrennten Parametersätzen auch die Frequenz der GWL von Bedeutung. Bei der Generierung muss die für die Synthese verwendete GWL vorab festgelegt werden. Dies ist nötig, da im Vorfeld nicht bekannt sein kann, wie lange die generierte Ereignisdauer sein wird, und daher kann die GWL nicht im direkten Bezug auf die GWL-Beobachtungsdaten ermittelt werden. Es müssen also die GWL über die Häufigkeit oder die Frequenz der GWL in den beobachteten Ereignissen bestimmt werden.

Im ersten Ansatz (M3a) wurde hierfür die einfache Häufigkeit der GWL in den Ereignissen verwendet. Als Alternativansatz (M3b) wurde die Häufigkeit über die Ereignisdauern gewichtet erfasst. Dies erfolgt, indem statt der einfachen Häufigkeit der GWL in den Ereignissen die Gesamtdauer der Ereignisse mit jeweils zugewiesener GWL erfasst und aufsummiert wird. Aufgrund besserer Ergebnisse des Ansatzes M3b und der Erkenntnisse in Abschnitt 5.2.2.1 wurde M3b für die Untersuchungen ausgewählt.

Hierbei wird innerhalb eines Ereignisses jedem Intervall die GWL zugewiesen, die das Ereignis dominiert. Hierdurch entsteht eine neue GWL-Zeitreihe. Dies führt zu einem gewissen Informationsverlust, da während eines Ereignisses öfters mehrere GWL vorkommen (siehe hierzu auch Abschnitt 7.3). Es ist allerdings nötig, da in der Synthese keine intervallgenaue GWL-Zuweisung erfolgen kann (es kann jedem Ereignis nur eine GWL zugewiesen werden). Das Phänomen ist in Tabelle 5-8 grafisch dargestellt. Zu sehen ist hier, dass das Trockenereignis (symbolisiert durch den grau unterlegten Zeitraum) aus 4 Stunden mit der GWL 1 und 19 Stunden mit der GWL 2 besteht. Erfasst wird es aber als 23-stündiges Ereignis mit der GWL 2. In der Generierung wird diese leicht fehlerhafte Datenaufnahme reproduziert (siehe Tabelle 7-9).

Beim Ansatz (M3b) wird also die GWL-Häufigkeit reproduziert, die in der GWL-Zeitreihe vorhanden ist, die aus den mit GWL versehenen Ereignissen folgt (Spalte *GWL – Ereignisse* in Tabelle 5-8). Im Vergleich zum Ansatz (M3a) erfolgt über diesen Umweg eine Gewichtung in der Erfassung der GWL-Häufigkeiten.

Tabelle 5-8 GWL-Zuweisung der Ereignisse; blau: Nassereignis, grau: Trockenereignis

| Zeit | GWL – Zeitreihe | GWL – Ereignisse | Zeit | GWL – Zeitreihe | GWL – Ereignisse |
|------------------|--------------------|---------------------|------------------|--------------------|---------------------|
| 01.01.2005 00:00 | 1 | 1 | 02.01.2005 00:00 | 2 | 2 |
| 01.01.2005 01:00 | 1 | 1 | 02.01.2005 01:00 | 2 | 2 |
| 01.01.2005 02:00 | 1 | 1 | 02.01.2005 02:00 | 2 | 2 |
| 01.01.2005 03:00 | 1 | 1 | 02.01.2005 03:00 | 2 | 2 |
| 01.01.2005 04:00 | 1 | 1 | 02.01.2005 04:00 | 2 | 2 |
| 01.01.2005 05:00 | 1 | 1 | 02.01.2005 05:00 | 2 | 2 |
| 01.01.2005 06:00 | 1 | 1 | 02.01.2005 06:00 | 2 | 2 |
| 01.01.2005 07:00 | 1 | 1 | 02.01.2005 07:00 | 2 | 2 |
| 01.01.2005 08:00 | 1 | 1 | 02.01.2005 08:00 | 2 | 2 |
| 01.01.2005 09:00 | 1 | 1 | 02.01.2005 09:00 | 2 | 2 |
| 01.01.2005 10:00 | 1 | 1 | 02.01.2005 10:00 | 2 | 2 |
| 01.01.2005 11:00 | 1 | 1 | 02.01.2005 11:00 | 2 | 2 |
| 01.01.2005 12:00 | 1 | 1 | 02.01.2005 12:00 | 2 | 2 |
| 01.01.2005 13:00 | 1 | 1 | 02.01.2005 13:00 | 2 | 2 |
| 01.01.2005 14:00 | 1 | 1 | 02.01.2005 14:00 | 2 | 2 |
| 01.01.2005 15:00 | 1 | 1 | 02.01.2005 15:00 | 2 | 2 |
| 01.01.2005 16:00 | 1 | 1 | 02.01.2005 16:00 | 2 | 2 |
| 01.01.2005 17:00 | 1 | 1 | 02.01.2005 17:00 | 2 | 2 |
| 01.01.2005 18:00 | 1 | 1 | 02.01.2005 18:00 | 2 | 2 |
| 01.01.2005 19:00 | 1 | 1 | 02.01.2005 19:00 | 2 | 2 |
| 01.01.2005 20:00 | 1 | 2 | 02.01.2005 20:00 | 2 | 2 |
| 01.01.2005 21:00 | 1 | 2 | 02.01.2005 21:00 | 2 | 2 |
| 01.01.2005 22:00 | 1 | 2 | 02.01.2005 22:00 | 2 | 2 |
| 01.01.2005 23:00 | 1 | 2 | 02.01.2005 23:00 | 2 | 2 |

Der nächste Schritt ist die praktische Umsetzung in der Synthese des Niederschlages. Hierbei wird die gewichtete Häufigkeit der GWL nachgebildet. Dies funktioniert in mehreren Schritten, die in Abbildung 5-4 dargestellt sind. Vereinfacht wird in der Abbildung nur auf „Ereignisse“ eingegangen. In der praktischen Generierung werden jeweils abwechselnd Nass- und Trockenereignisse generiert. Bei der Generierung werden für jede GWL separate Parametersätze für Verteilungsfunktionen und Copulas verwendet. Ebenso erfolgt eine Unterscheidung in Saisons (Sommer und Winter), für die separate Parametersätze für jede GWL und die GWL-Häufigkeiten erfasst werden. Auch dies wird in der Abbildung vereinfachend nicht dargestellt.

Sofern die synthetische Zeitreihe eine ausreichende Länge aufweist, kann diese Methode die GWL-Häufigkeiten gut reproduzieren. Es muss aber bedacht werden, dass auch der erwähnte Informationsverlust der M3b reproduziert wird.

Mit dem geschilderten Vorgehen wird die Häufigkeit der GWL in den Ereignissen gut nachgebildet, aber die Abfolge-Frequenz völlig durcheinandergebracht. Dies wird im zweiten Schritt mittels einer Optimierung korrigiert (siehe Abschnitt 7.3).

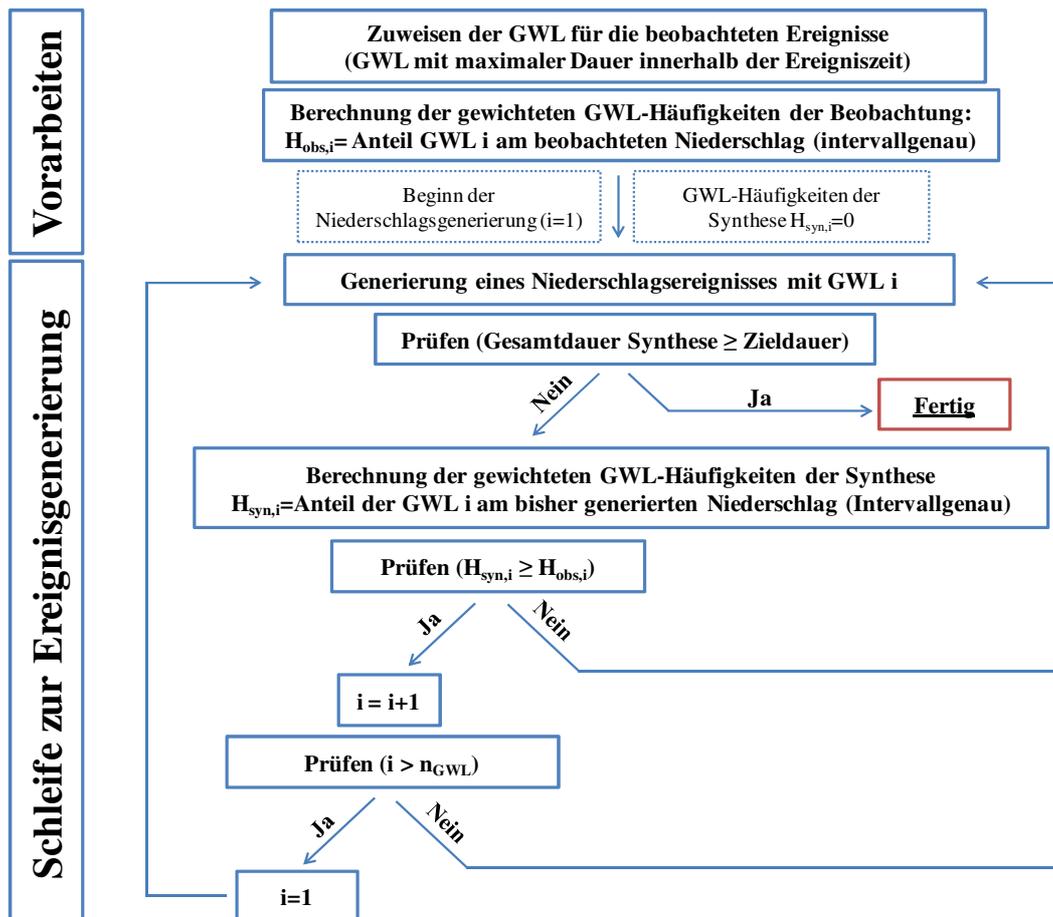


Abbildung 5-4 GWL-Implementierung in der univariaten Niederschlagsgenerierung

5.2.2.1 Analyse des Zusammenhangs von GWL und Niederschlagsereignissen

Zu Beginn der Untersuchungen lautete die Frage, inwiefern sich das Niederschlagsverhalten in den einzelnen GWL voneinander unterscheidet. Interessant war natürlich der Zusammenhang, der als Folge der beschriebenen Klassifizierungsmethode der Ereignisse entsteht.

Die zielführendste Methode, dies zu analysieren, war es, die Eingangsdaten des Modells, also die L-Momente der Niederschlagsereignisse der einzelnen GWL, miteinander zu vergleichen. Zusätzlich wurden die statistischen Momente in die Untersuchungen aufgenommen.

In Abbildung 5-5 sind die Mittelwerte der Ereignisse entsprechend den GWL für den Sommer zu erkennen. Es wurde hierbei nicht die Variante mit allen 8 GWL dargestellt, sondern die der zu zwei GWL zusammengeführten Version. Diese Vorgehensweise wurde vorgezogen, weil die Unterschiede in dieser Version klarer zu erkennen sind. Auch in den anderen Varianten sind die Unterschiede vorhanden (siehe Abschnitt 4.2 und Abbildung A-1 bis Abbildung A-6), welche allerdings teilweise etwas weniger eindeutig zu erkennen sind. In den Abbildungen werden die Werte der mit GWL differenzierten Zeitreihe denen der gesamten Zeitreihe gegenübergestellt. Zu sehen ist, dass die Mittelwerte der trockenen GWL 1 signifikant von denen der feuchten GWL 2 abweichen. Ähnliches zeigt sich für den Winter (siehe Abbildung 5-6). Allerdings sind die Unterschiede in den *wsd* im Winter nicht sehr ausgeprägt.

Die hier für die Mittelwerte gezeigten Ergebnisse zeigen sich in ähnlich starker Form für die L-Momente zweiter Ordnung (siehe Abbildung A-7 bis Abbildung A-12). Für die Tau-Werte der L-Momente dritter Ordnung sind nennenswerte Unterschiede zwischen den GWL nur noch für die *dsd* nachzuweisen. Ähnlich sah es bei den statistischen Momenten 2. und 3. Ordnung aus.

Sowohl bei den Varianz, als auch bei der Schiefe waren Unterschiede zwischen den GWL zu erkennen, obwohl sie schwächer sind als bei den Mittelwerten.

An den Abbildungen ist ebenfalls die unterschiedliche Niederschlagsstruktur der Saisons gut zu erkennen. Langen Ereignissen mit niedrigen Intensitäten im Winter stehen kurze Ereignisse mit hohen Intensitäten im Sommer gegenüber. Dies gilt für beide GWL.

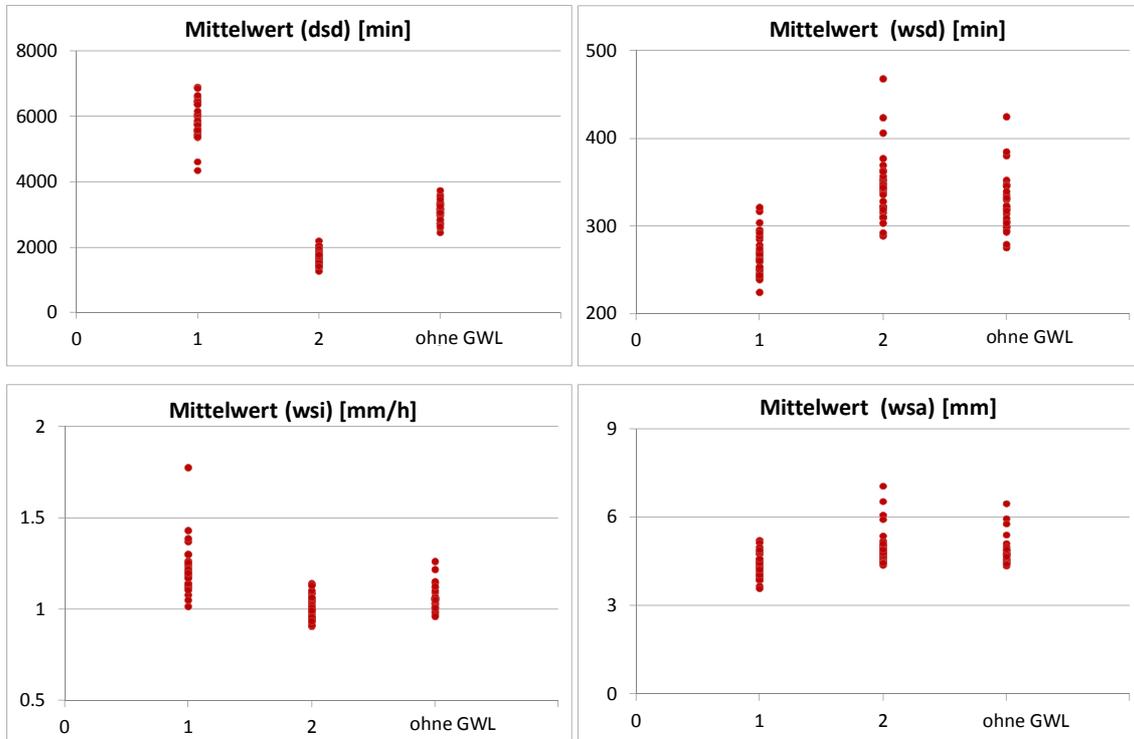


Abbildung 5-5 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse, sortiert nach GWL im Sommer; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

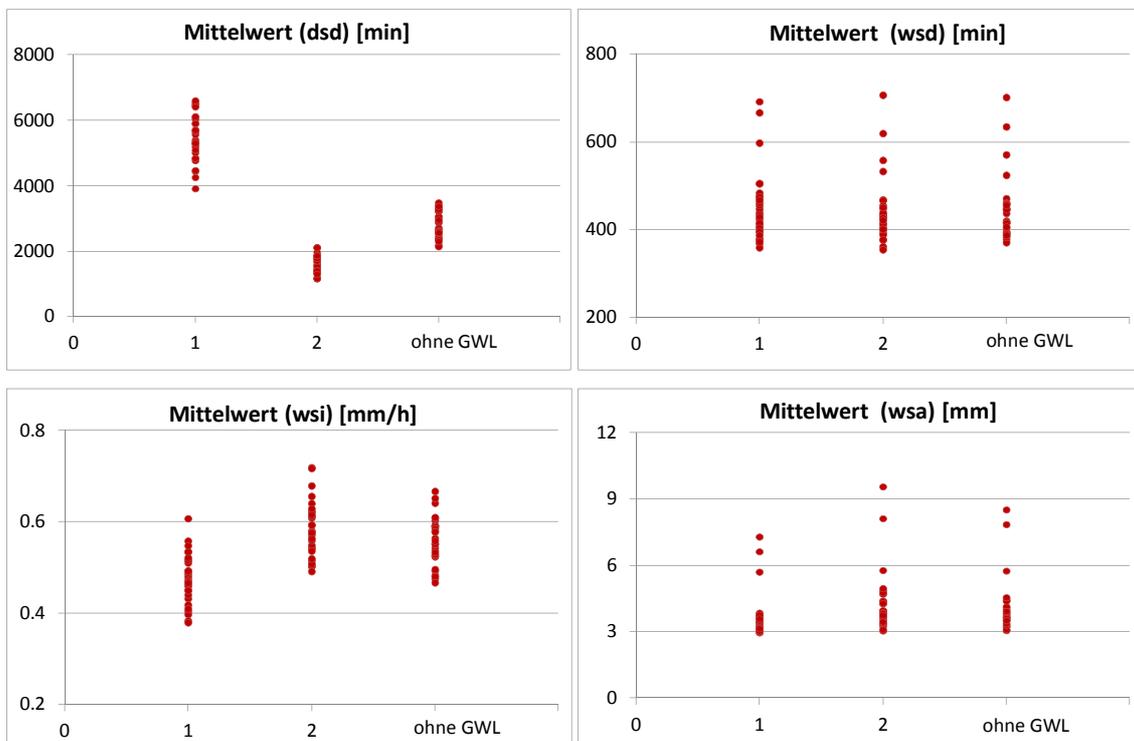


Abbildung 5-6 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse, sortiert nach GWL im Winter; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

Weiterhin wurden die Häufigkeiten der GWL in den Ereignissen und in den Intervallen der Ereignisse untersucht. Hierfür wurde in einem ersten Schritt jedem Ereignis eine GWL zugewiesen (wie in Abschnitt 5.2.2 beschrieben) und anschließend wurden die Häufigkeiten ermittelt. In Abbildung 5-7 und Abbildung 5-8 sind die Ergebnisse zu sehen.

Es ergaben sich zwei Erkenntnisse von Bedeutung. Erstens gibt es GWL, welche eine sehr große Häufigkeit aufweisen (insbesondere GWL 5), und GWL, welche sehr selten auftreten (z. B. GWL 3).

Die zweite, noch wichtigere Erkenntnis aber betrifft das Wechselspiel von Häufigkeiten der Ereignisse einer bestimmten GWL und deren durchschnittlicher Länge. So ergibt sich, dass die Verwendung der mit der Dauer der Ereignisse gewichteten GWL-Häufigkeit (siehe Abschnitt 5.2.2, Ansatz (M3b)) zu ganz anderen Ergebnissen führt als die Häufigkeit der ungewichteten GWL in den Ereignissen. So tritt bei reiner Betrachtung der Ereignisanzahlen die GWL 5 für Trocken- und Nassereignisse in etwa gleich häufig auf. Betrachtet man jedoch auch die Dauern der Ereignisse, die hierbei eine bestimmte GWL zugewiesen bekommen, revidiert sich das völlig, und die GWL 5 ist nur noch für die Nassereignisse eine besonders bedeutende GWL. Dies erklärt sich dadurch, dass die GWL 5 eine sehr nasse GWL ist (siehe Abschnitt 4.2) und daher eher kurze Trockendauern und lange Nassdauern aufweist. Wenn in einem Zeitraum, in dem die GWL 5 vorherrscht beispielsweise drei schnell aufeinander folgende Regenereignisse auftreten, ergeben sich hieraus auch drei kurze Trockenereignisse. Demgegenüber wird ein trockener Zeitraum mit der GWL 1 oft komplett von einem einzelnen Trockenereignis abgedeckt. Ein ähnlicher Effekt ist bei allen GWL zu beobachten.

Diese Erkenntnis war maßgeblich dafür verantwortlich, dass der Ansatz M3b ausgewählt wurde (siehe Abschnitt 5.2.2).

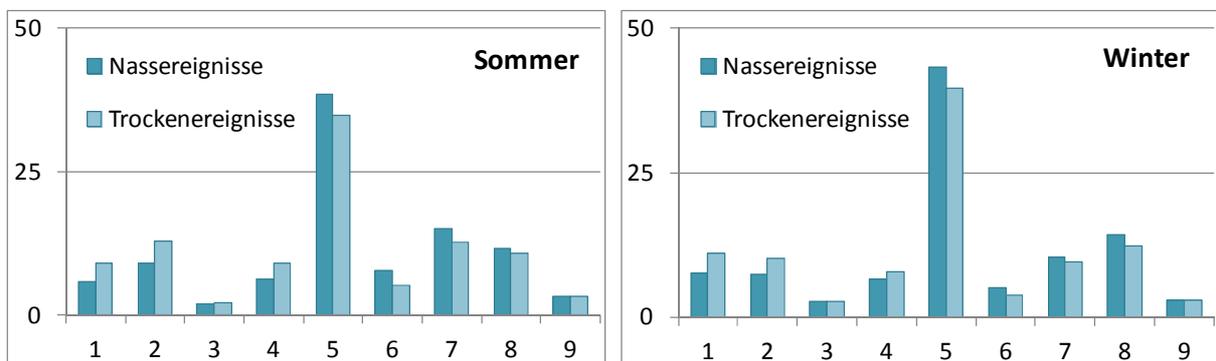


Abbildung 5-7 Ungewichtete Häufigkeit [%] der acht GWL in den Ereignissen im Mittel über alle Stationen; 9 – keine GWL kann zugewiesen werden

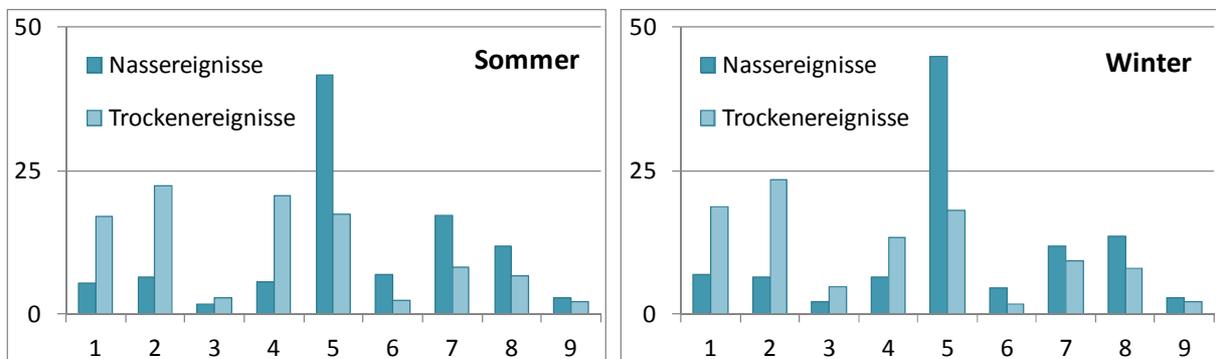


Abbildung 5-8 Über die Dauer gewichtete Häufigkeit [%] der acht GWL in den Ereignissen im Mittel über alle Stationen; 9 – keine GWL kann zugewiesen werden

Bei der Version mit zwei GWL wiederholt sich diese Erkenntnis. Wieder ist zu erkennen, dass bei Betrachtung der Ereignisanzahl (siehe Abbildung 5-9 und Abbildung 5-10) die GWL für Nass- und Trockenereignisse in etwa gleich häufig sind. Für die Betrachtung der gewichteten Häufigkeiten der GWL ist hier noch klarer zu erkennen, wie die trockene GWL 1 für die überwältigende Mehrheit der trockenen Intervalle und die feuchte GWL 2 für die der nassen Intervalle verantwortlich ist.

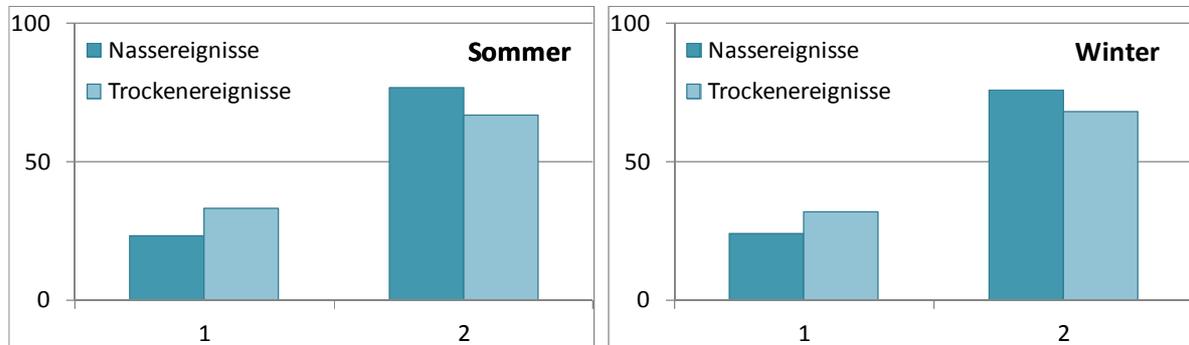


Abbildung 5-9 Ungewichtete Häufigkeit [%] der zwei GWL in den Ereignissen im Mittel über alle Stationen

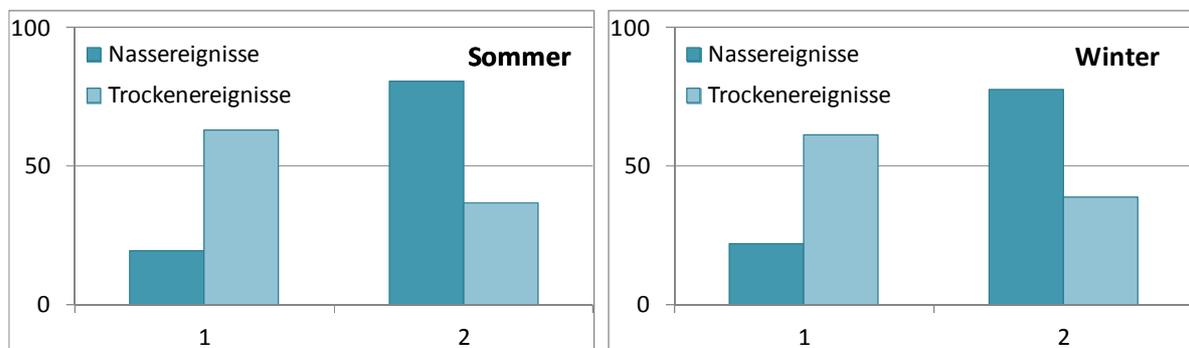


Abbildung 5-10 Über die Dauer gewichtete Häufigkeit [%] der zwei GWL in den Ereignissen im Mittel über alle Stationen

Ebenfalls zu sehen ist dies bei der Version mit vier GWL (siehe Abbildung 5-11 und Abbildung 5-12). Diese Version wurde erstellt, um eine möglichst hohe Anzahl an GWL zu haben, ohne aber GWL zu haben, die eine sehr geringe Stichprobengröße aufweisen (siehe auch Abschnitt 4.2). Abbildung 5-12 zeigt, dass die relative Häufigkeit aller GWL hoch ist wodurch eine ausreichende Stichprobengröße sichergestellt wird. Passend zu den bisherigen Ergebnissen ist die Anzahl der Ereignisse, die einer feuchten GWL zugewiesen wurden, hierbei wieder deutlich höher.

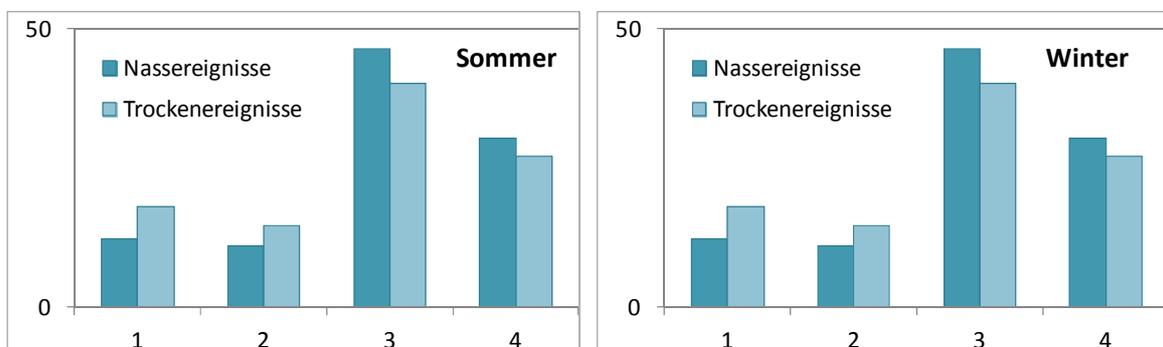


Abbildung 5-11 Ungewichtete Häufigkeit [%] der vier GWL in den Ereignissen im Mittel über alle Stationen

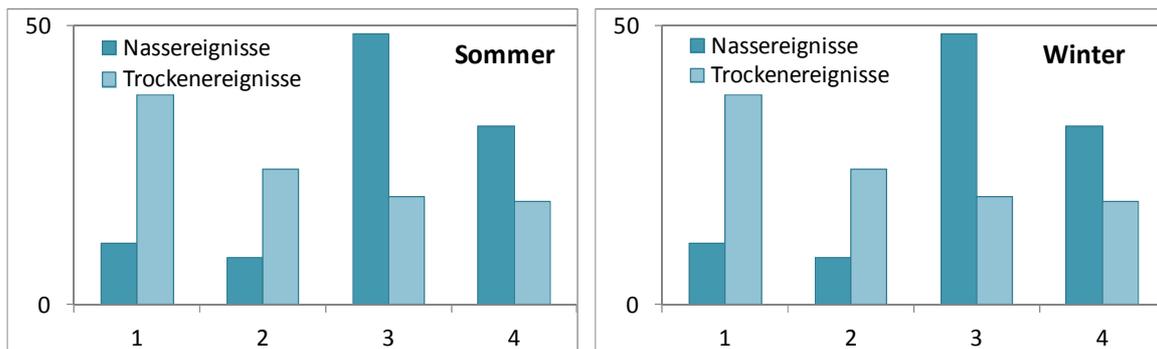


Abbildung 5-12 Über die Dauer gewichtete Häufigkeit [%] der vier GWL in den Ereignissen im Mittel über alle Stationen

5.2.2.2 Modellkonfiguration

Um das Modell optimal auf die Nutzung von GWL abzustimmen, mussten Verteilungsfunktionen ausgewählt werden, die optimale Ergebnisse ergeben für die entsprechend den GWL geclusterten Ereignis-Zeitreihen. Da die Ergebnisse des Modells mit und ohne Bindung an GWL verglichen werden sollen, wurden Verteilungsfunktionen gesucht, die eine möglichst optimale Anpassungsgüte für beide Modellversionen aufweisen.

Tabelle 5-9 In den Untersuchungen berücksichtigte Verteilungsfunktionen

| | | |
|------------------------------------|--|------------------------------------|
| Exponential-Verteilung | Gamma-Verteilung | Allgemeine Extremwert-Verteilung |
| Verallgemeinerte Lambda-Verteilung | Verallgemeinerte logistische Normal-Verteilung | Verallgemeinerte Normal-Verteilung |
| Verallgemeinerte Pareto-Verteilung | Gumbel-Verteilung | Kappav-Verteilung |
| Normal-Verteilung | Pearson-3-Verteilung | Rayleigh-Verteilung |
| Umgekehrte Gumbel-Verteilung | Wakeby-Verteilung | Weibull-Verteilung |

Aufgrund der vielen untersuchten Verteilungsfunktionen (insgesamt 17 für jede Kenngröße, siehe Tabelle 5-9), der hohen Anzahl an Stationen, der zu berücksichtigenden GWL und der drei zu modellierenden Kenngrößen (*wsi*, *wsd*, *dsd*) war insbesondere die Sichtung der Evaluierungsdaten kompliziert. Zur Analyse der Anpassungsgüte wurden verschiedene grafische und statistische Verfahren eingesetzt. Für eine grafische Sichtung wurden die Plots der theoretischen und empirischen Verteilungsfunktion und die Quantil-Quantil-Plots betrachtet. An Testverfahren wurden der Kolmogoroff-Smirnoff-Test (K-S-Test), der Chi-Quadrat- (χ^2) -Test und der Cramér-von-Mises-Test ($(n\omega^2)$ -Test) verwendet, was im Folgenden erläutert wird.

Der K-S-Anpassungstest beruht auf der Analyse des maximalen Abstands der empirischen zur theoretischen Verteilung. Die Teststatistik ermittelt sich mit folgender Formel:

$$D = \sup_x \left| \tilde{F}(x) - F(x) \right| \quad (5-24)$$

\sup_x – Supremum (obere Grenze) der Abweichungen

$\tilde{F}(x)$ – empirische Verteilungsfunktion

$F(x)$ – theoretische Verteilungsfunktion

Weiteres zum K-S-Anpassungstest kann der Standardliteratur, z. B. Sachs (2004), entnommen werden.

Beim Chi-Quadrat-Test wird die Verteilung in Klassen eingeteilt. Anschließend wird geprüft, ob die empirisch vorhandene Anzahl an Klasselementen der theoretisch notwendigen entspricht. Näheres kann z. B. wieder Sachs (2004) entnommen werden. Die Testgröße wird wie folgt bestimmt:

$$\chi^2 = \sum_{j=1}^k \frac{(b_j - e_j)^2}{b_j} \quad (5-25)$$

b_j – tatsächliche Anzahl an Werten pro Klasse

e_j – theoretisch nötige Anzahl an Werten pro Klasse

k – Anzahl an Klassen

Der Cramér-von-Mises-Anpassungstest vergleicht den Abstand der empirischen Verteilung von der theoretischen Verteilungsfunktion. Die Test-Statistik setzt sich wie folgt zusammen:

$$n\omega^2 = \frac{1}{12N} + \sum_{i=1}^N \left(F(x_i) - \frac{2m(x_i) - 1}{2N} \right)^2 \quad (5-26)$$

$$\tilde{F}(x_i) = \frac{2m(x_i) - 1}{2N} - \text{empirische Verteilungsfunktion}$$

N – Stichprobengröße

$m(x_i)$ – Rang des Stichprobenelements x_i

Weiteres zum $n\omega^2$ -Test kann z. B. Stephens (1970) entnommen werden.

Nach Abschluss der Analysen der Anpassungsgüte der Verteilungsfunktionen wurden zusätzlich die Ergebnisse verschiedener Modellvarianten verglichen.

Am Ende setzte sich die bereits bei der Verteilungsfunktionsvalidierung favorisierte Konfiguration durch. Daher wird an dieser Stelle auch nur diese vorgestellt. Die endgültige Modellkonfiguration ist Tabelle 5-10 zu entnehmen. Die Konfiguration wird im Weiteren für die Modellierung mit und ohne GWL verwendet. Die zu erkennende Modellkonfiguration enthält für die Nassereignisdauern und -intensitäten eine Kombination aus verallgemeinerter Pareto-Verteilung als Randverteilungen mit einer Frank-Copula. Dies entspricht der Modellkonfiguration von De Michele & Salvadori (2003). Dies ist allerdings ausdrücklich als Ergebnis der Untersuchungen zu sehen, d. h. es wurde in keiner Weise intendiert.

Tabelle 5-10 Modellkonfiguration nach der Anpassung an GWL und Untersuchungsgebiet

| Element | Kürzel | Methodik | Parameteranzahl |
|--|--------|------------------------------------|-----------------|
| Nassereignisdauern | wsd | Verallgemeinerte Pareto-Verteilung | 3 |
| Trockenereignisdauern | dsd | Weibull-3-Verteilung | 3 |
| Nassereignisintensitäten | wsi | Verallgemeinerte Pareto-Verteilung | 3 |
| Zusammenhänge wsd-wsi | - | Frank-Copula | 1 |
| Interne Struktur | - | Doppelexponentialfunktion | 2 |
| Die Parameterschätzung erfolgt mittels L-Momenten. | | | |

Die **verallgemeinerte Pareto-Verteilung** (abgekürzt GPA für *generalized pareto distribution*) ist eine Funktion mit drei Parametern. Diese sind $c \in \mathbb{R}$ (Lage), $b \geq 0$ (Streuung) und $a \in \mathbb{R}$ (Schiefe). Die hier verwendete Nomenklatur wurde Singh & Guo (1995) entnommen.

Die Verteilungsfunktion lautet

$$F(x) = 1 - \left(1 - \frac{a \cdot (x - c)}{b} \right)^{1/a}, \text{ wenn } a \neq 0 \quad (5-27)$$

$$F(x) = 1 - \exp\left(-\frac{x - c}{b}\right) \text{ wenn } a = 0$$

Der Wertebereich liegt bei

$$x \geq 0, \text{ wenn } a \geq 0 \quad (5-28)$$

$$c \leq x \leq c - \frac{b}{a}, \text{ wenn } a < 0$$

Für die Erläuterung der Weibull-Verteilung, der Frank-Copula und der Doppelexponentialfunktion wird auf Abschnitt 5.2.1.1 verwiesen.

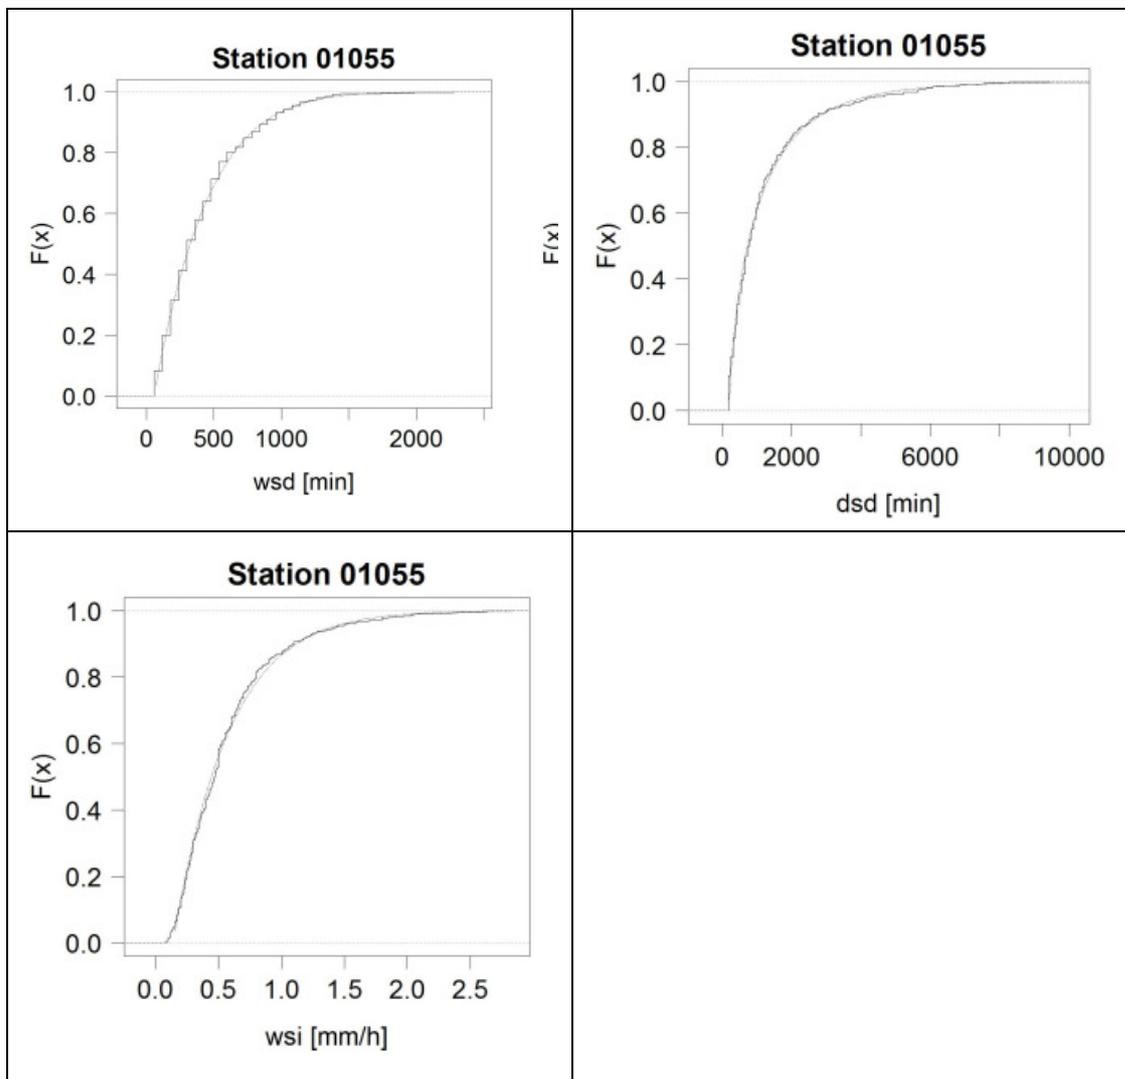


Abbildung 5-13 Gegenüberstellung der theoretischen (gepunktete Linie) und der empirischen (durchgezogene Linie) Verteilungsfunktionen, beispielhaft für eine Station im Winter mit den in Tabelle 5-10 angegebenen theoretischen Verteilungen (GWL-5)

Für jede der neun GWL müssen Ausführungen aller Plots und Testergebnisse für drei Kennwerte (*wsd*, *dsc* und *wsi*) bei zwei Saisons, 29 Stationen und 15 theoretischen Verteilungen erstellt werden. Die hierdurch entstehende Menge an Daten kann in ihrer Gesamtheit hier nicht dargestellt werden. Daher werden hier die Ergebnisse der Verteilungsfunktionsanalysen nur für einzelne Beispielergebnisse der ausgewählten Verteilungen diskutiert.

In Abbildung 5-13 sind Beispiele der Verteilungsfunktionen von einer der aus Tabelle 5-2 bekannten Beispielstationen der besonders häufigen trockenen GWL-5 zu erkennen. In Abbildung 5-14 (feuchte GWL 5) und Abbildung 5-15 (trockene GWL 2) sind Quantil-Quantil-Plots (Q-Q-Plots) von drei Stationen zu sehen. Man erkennt eine insgesamt gute Anpassungsgüte. Am schwierigsten gestaltete sich die Anpassung einer Verteilung an die *dsc*. Bei den Q-Q-Plots ist eine allgemeine Schwäche in der Anpassungsgüte der extremen Trockendauern zu erkennen. Diese Schwäche ist in leichterer Form auch bei den Intensitäten und Nassdauern vorhanden. Ein weiterer Schwachpunkt der Anpassung sind die *wsi* in den trockenen GWL.

An den Grafiken ist auch sehr gut zu erkennen, wie extrem stark der Wertebereich der Stationen in den verschiedenen Gebieten variiert.

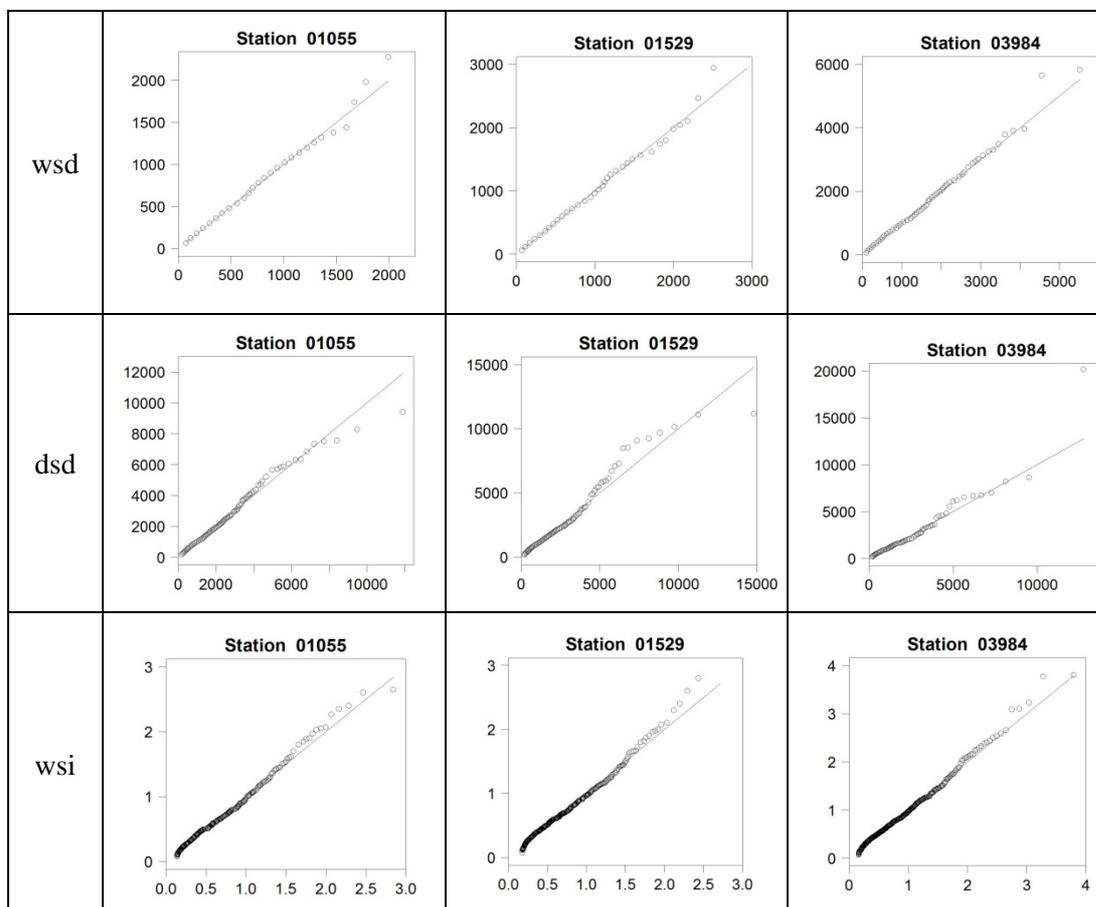


Abbildung 5-14 Gegenüberstellung der Quantile der theoretischen (y-Achse) und der empirischen (x-Achse) Verteilungsfunktionen, beispielhaft für drei Stationen im Sommer mit den in Tabelle 5-10 angegebenen theoretischen Verteilungen (feuchte GWL 5)

Es ist auf eine Besonderheit der Dauern hinzuweisen. Bei Betrachtung der Q-Q-Plots scheinen die *wsd* weniger Punkte zu haben als die *wsi* (siehe Abbildung 5-14 und Abbildung 5-15). Dies ist darauf zurückzuführen, dass die *wsd* gehäuft auftreten. So ist zum Beispiel die *wsd* von 180 Minuten extrem häufig. In der Grafik erscheinen dann unter Umständen hunderte Punkte als ein einzelner Punkt.

Aus demselben Grund weisen die *wsd* in den Verteilungsfunktionen eine leichte Stufenform auf (siehe Abbildung 5-13). Dieser Effekt ist auch in den *dsd* zu beobachten; allerdings in deutlich schwächerer Form, da die *dsd* eine deutlich größere Spannweite und Variabilität haben.

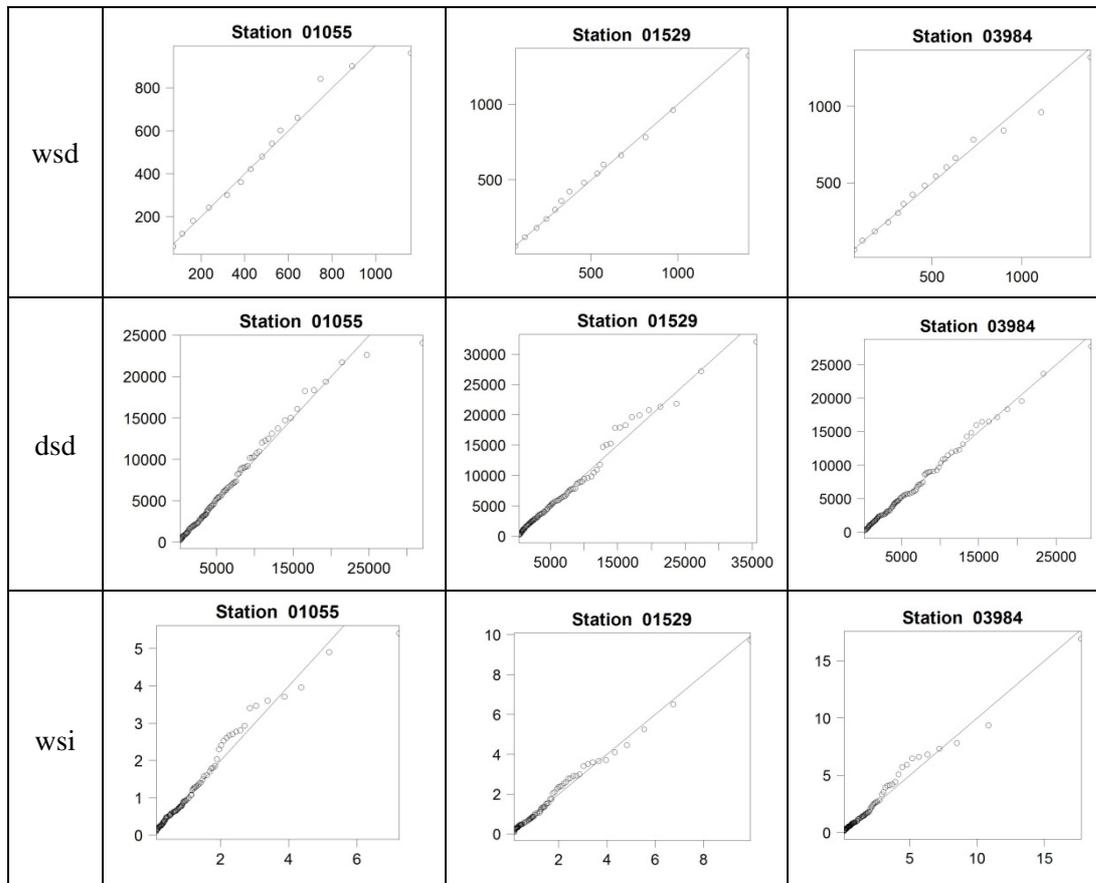


Abbildung 5-15 Gegenüberstellung der Quantile der theoretischen (y-Achse) und der empirischen (x-Achse) Verteilungsfunktionen, beispielhaft für drei Stationen im Sommer mit den in Tabelle 5-10 angegebenen theoretischen Verteilungen (trockene GWL 2)

Die Beurteilung der Testverfahren ist problematisch, weil die Stichprobengröße hierbei eine große Bedeutung hat. Bei GWL mit einer geringen Stichprobengröße können auch Verteilungsfunktionen sehr gute Ergebnisse in den Tests erzielen, wenn sie optisch als völlig unpassend bewertet wurden. Andererseits ergeben sich für das Gesamtjahr teilweise sehr schlechte Ergebnisse, auch dann, wenn die Verteilungsfunktionen optisch eine sehr gute Anpassung zeigen. Ebenfalls zeigen die verschiedenen Testverfahren teilweise stark unterschiedliche Ergebnisse. Praktisch wurden die Testverfahren daher eher zur Überprüfung der optischen Bewertungen verwendet.

Dargestellt werden hier nur die Ergebnisse als Prozentanteil der Anpassungstests über beide Saisons einmal ohne GWL, ein zweites Mal mit der häufigsten GWL: der GWL 5 (siehe Tabelle 5-11). Auf die Darstellung der Ergebnisse der Anpassungstests der mit den übrigen GWL klassifizierten Stichproben wird hier verzichtet, da diese selbst für die häufigen GWL für optisch geeignet erscheinende Verteilungsfunktionen beinahe durchweg eine Eignung bestätigen. Zu erkennen ist, dass die Ergebnisse mit und ohne GWL unterschiedlich ausfallen. In der Regel zeigen die Anpassungen nach GWL klassifizierten Stichproben eine bessere Anpassungsgüte. Insbesondere bei den *wsd* ist die Anpassungsgüte ohne GWL eher schlecht, mit GWL dagegen recht gut. Eine Ausnahme bilden die *dsd*, bei denen die Anpassungsgüte ohne GWL besser ist.

Tabelle 5-11 Anteil [%] an Tests, die bei einem Signifikanzniveau von 0,05 eine Eignung der gewählten Verteilungsfunktion (siehe Tabelle 5-10) ergeben

| Kenngröße | GLW | K-S-Test | | χ^2 -Test | | n ω^2 -Test | |
|-----------|--------|----------|-----|----------------|----|--------------------|-----|
| | | ohne | 5 | ohne | 5 | ohne | 5 |
| wsd | Winter | 7 | 72 | 3 | 21 | 10 | 23 |
| | Sommer | 0 | 66 | 3 | 24 | 0 | 55 |
| dsd | Winter | 38 | 29 | 39 | 28 | 86 | 66 |
| | Sommer | 38 | 59 | 25 | 14 | 83 | 62 |
| wsi | Winter | 100 | 100 | 7 | 24 | 90 | 100 |
| | Sommer | 97 | 100 | 41 | 41 | 86 | 100 |

In die Untersuchungen wurden folgende Verteilungsfunktionen einbezogen: Exponentialverteilung, Gammaverteilung, verallgemeinerte Extremwertverteilung, verallgemeinerte Lambda-Verteilung, verallgemeinerte Logistische Verteilung, verallgemeinerte Normalverteilung, verallgemeinerte Pareto-Verteilung, Gumbel-Verteilung, Kappa-Verteilung, Normalverteilung, Pearson-3-Verteilung, Rayleigh-Verteilung, umgekehrte Gumbel-Verteilung, Wakeby-Verteilung und Weibull-3-Verteilung.

Auf eine detaillierte Diskussion der Anpassung der Copula (siehe Abschnitt 5.2.1.1) und der Doppalexponentialfunktion (siehe Abschnitt 5.1.2) wird hier verzichtet, da die Wahl selbiger unverändert entsprechend Haberlandt et al. (2008) vorgenommen wurde.

5.2.2.3 Parameterschätzung

Die Parameterschätzung verlief größtenteils unproblematisch. Die Parameter der Frank-Copula bei einer Generierung ohne GWL liegen meist im negativen Bereich (-0,5 bis -1,5) liegt. Die wenigen Ausnahmen von dieser Regel treten bei drei benachbarten Stationen im Luv-Bereich des Harz-Mittelgebirges (Bad Lauterberg, Schierke und Braunlage; Höhenlage 300-600 m NN) auf. Zwei dieser Stationen sind die mit Abstand höchstgelegenen Stationen der Untersuchung (Schierke und Braunlage, beide ca. 600 m NN). Diese weisen für den Sommer ebenfalls negative Parameter für die Copula auf, aber im Winter positive Parameter zwischen 0,5 und 1,3. Eine Ausnahme ist die Station Oldenburg (11 m NN), die für den Winter einen Parameter nahe 0 aufweist.

Die hohe Anzahl negativer Frank-Copula-Parameter zeigt, dass zwischen den *wsd* und *wsi* im Allgemeinen eine negative Abhängigkeit vorliegt. Dies liegt darin begründet, dass mit zunehmender Ereignisdauer eine sinkende durchschnittliche Niederschlagsintensität zu erwarten ist.

Die positiven Abhängigkeiten der drei West-Harz-Stationen zeigen, dass anscheinend im Winter für die Stationen im Luv-Bereich des Harzes die Intensität des Niederschlags mit der Dauer steigt. Diese Erkenntnis mag in diesem Fall keinen direkten Einfluss auf die Modellauslegung haben, aber muss für weitere Modellierungen im Gebiet festgehalten werden.

Dieser Effekt im Winter zeigte sich auch bei der Generierung mit GWL. Dies gilt sowohl für feuchte als auch trockene GWL, allerdings ist der angezeigte positive Zusammenhang bei den nassen GWL deutlich stärker. Einzelne GWL weichen von der Regel ab und weisen auch im Winter negative Parameter auf.

Im Sommer ist bei den West-Harz-Stationen nur auffällig, dass im Gegensatz zu allen anderen Stationen die Parameter der nassen GWL im Bereich -0,1 bis -0,5 liegen, während die Werte hier bei anderen Stationen meist deutlich niedriger liegen. Bei allen Stationen kann festgestellt werden, dass die Parameter in den trockenen GWL meist niedriger sind als diejenigen in den nassen.

Sehr interessant ist bei der Betrachtung mit GWL die Station Oldenburg. Diese weist, wie bereits erwähnt, bei der Betrachtung ohne GWL die Besonderheit auf, im Winter einen Copula-Parameterwert nahe 0 zu haben. Mit GWL zeigt sich hier, dass die Copula-Parameter in den trockenen GWL stets negativ und in den nassen GWL positiv sind. Warum dieser Effekt ausschließlich in der Station Oldenburg zu beobachten ist, konnte nicht geklärt werden. Im Sommer hingegen sind alle Copula-Parameter negativ.

Die Parameterschätzung mit GWL war für die Parameter der Verteilungsfunktionen teilweise etwas problematisch. Die Parameterschätzung für die seltenen GWL erzielte teilweise keine plausiblen Werte. Für die GWL 3 und 6 war teilweise eine Parameterschätzung nicht möglich. In solchen Fällen war es notwendig, die Parameter mit den Parametern des Modells ohne GWL-Berücksichtigung zu ersetzen. Dieses Problem bestärkte in der Entscheidung eine Variante mit zu vier Klassen zusammengefassten GWL (siehe Abschnitt 4.2). Das Problem trat nicht für diese Variante und für die Version mit den zu zwei Klassen zusammengefassten GWL auf.

Die Betrachtung der übrigen Modellparameter zeigte keine weiteren Auffälligkeiten.

5.2.2.4 Niederschlagsgenerierung des aktualisierten Modells ohne GWL

Für die Beurteilung der Modellierung wurden die Ergebnisse des angepassten Modells (ARP1, siehe Tabelle 5-10) mit denen des Modells vor der Neukonfiguration entsprechend Haberlandt et al. (2008) (ARP0) verglichen. Die Ergebnisse sind Tabelle 5-12 bis Tabelle 5-15 zu entnehmen. Die Grundlage der hier vorgestellten Ergebnis-Kennwerte sind 10 Modelldurchläufe mit je 100 Jahren aller 29 Stationen. Es werden wieder die Mittelwerte (gekennzeichnet durch Striche über den Kenngrößen) und die Summen der Signifikanz kennzeichnenden p-Values für alle Stationen und Durchläufe dargestellt.

In der Nomenklatur der Tabelle 5-13 steht μ für den Mittelwert, σ^2 für die Varianz und γ für die Schiefe. Zur leichteren Übersicht wird ein Farbmuster verwendet. Grün deutet eine bessere Performance von ARP1 gegen ARP0 an, rot eine schlechtere und gelb steht für einen Kennwert, der sich unverändert gut reproduzieren lässt. Zusätzlich zu den im Modell verwendeten Ereignisparametern wurde als abgeleitete Kenngröße das Ereignisvolumen wsa [mm] betrachtet. Man kann in der Tabelle erkennen, dass für mehr als die Hälfte der betrachteten Kennwerte eine Verbesserung erzielt wurde, während nur wenige Parameter schlechtere Ergebnisse zeigten.

Die Tabelle 5-12 zeigt die beiden abgeleiteten Kenngrößen mittlere Jahresereignisanzahl und mittlere Jahresniederschlagssumme. Es wurde eine leichte Verbesserung mit dem angepassten Modell erzielt.

In Tabelle 5-14 und Tabelle 5-15 werden die Extremwerte der beiden Modellaufbauten verglichen. Es werden die im Abschnitt 5.2.1.2 vorgestellten Gütemaße verwendet. Der Wert $p\text{-value}(\dots)$ gibt wieder die Anzahl erfolgreicher Tests an. Hierbei ist die Gesamtanzahl der durchgeführten Tests 290 (29 Stationen mit je 10 Modelldurchläufen). Die Farbgebung entspricht der von Tabelle 5-13. Für die Sommer-Extremwerte (diese sind in der Regel extremer) wurde eine nahezu durchgehende leichte Verschlechterung durch die Modellanpassung erzielt und für die Winter-Extremwerte größtenteils eine leichte Verbesserung. Insgesamt sind die Veränderungen meist eher gering. Auf eine grafische Darstellung der Extremwerte wurde hier und in den folgenden Abschnitten verzichtet, da mit diesen aufgrund der hohen Anzahl an Stationen und Modelldurchläufen nahezu unmöglich Vergleiche angestellt werden können.

Insgesamt erreichen die Versionen ARP0 und ARP1 vergleichbar gute Ergebnisse. Die Arbeit fokussiert sich auf die Ermittlung des Einflusses der GWL auf die Modellierung; daher ist dies ein akzeptables Ergebnis, und ARP1 ist somit für die weiteren Untersuchungen unser Referenzmodell aufbau.

Tabelle 5-12 Abweichung [%] der abgeleiteten Größen (Ereignisanzahl und Niederschlagssummen) der synthetischen Daten (ARP0 und ARP1) zur Beobachtung

| Saison | Version | Mittlere Ereignisanzahl | Mittlere Niederschlagssummen |
|--------|---------|-------------------------|------------------------------|
| Winter | ARP0 | 1,12 | 2,27 |
| | ARP1 | 1,01 | 1,82 |
| Sommer | ARP0 | 1,51 | 4,56 |
| | ARP1 | 1,45 | 4,46 |
| Jahr | ARP0 | 1,17 | 2,56 |
| | ARP1 | 1,08 | 2,44 |

Tabelle 5-13 Abweichung [%] der statistischen Momente der synthetischen Daten (ARP0 und ARP1) zur Beobachtung

| Saison | Version | μ_{dsd} | σ_{dsd}^2 | γ_{dsd} | μ_{wsd} | σ_{wsd}^2 | γ_{wsd} |
|--------|---------|-------------|------------------|----------------|-------------|------------------|----------------|
| Winter | ARP0 | 0,85 | 4,17 | 8,99 | 0,58 | 5,20 | 21,09 |
| | ARP1 | 0,91 | 4,13 | 8,99 | 0,32 | 6,11 | 16,86 |
| Sommer | ARP0 | 0,83 | 4,96 | 15,29 | 0,52 | 5,24 | 24,70 |
| | ARP1 | 0,77 | 5,30 | 15,18 | 0,47 | 4,77 | 12,83 |
| Jahr | ARP0 | 0,82 | 4,03 | 11,79 | 0,53 | 4,64 | 18,57 |
| | ARP1 | 0,78 | 4,20 | 11,55 | 0,35 | 5,44 | 15,91 |
| Saison | Version | μ_{wsi} | σ_{wsi}^2 | γ_{wsi} | μ_{wsa} | σ_{wsa}^2 | γ_{wsa} |
| Winter | ARP0 | 1,70 | 8,64 | 19,81 | 1,96 | 19,70 | 80,98 |
| | ARP1 | 1,02 | 15,86 | 35,94 | 1,74 | 13,51 | 34,99 |
| Sommer | ARP0 | 0,62 | 10,52 | 40,34 | 3,29 | 70,35 | 122,14 |
| | ARP1 | 0,62 | 8,40 | 28,07 | 3,31 | 65,51 | 104,24 |
| Jahr | ARP0 | 0,87 | 8,50 | 36,61 | 1,75 | 46,45 | 126,04 |
| | ARP1 | 0,81 | 7,52 | 25,04 | 1,67 | 40,00 | 106,54 |

Tabelle 5-14 Vergleich der Indizes der Extremwerte der Modellvarianten ARP0 und ARP1 im Mittel über alle Stationen, Sommer

| dt [h] | $\overline{D_{abs,n}}$ [mm/h] | | $\overline{D_{abs,w}}$ [mm/h] | | $\overline{D_{sign,n}}$ [mm/h] | | $\overline{D_{sign,w}}$ [mm/h] | |
|--------|-------------------------------|-------|---------------------------------|------|--------------------------------|-------|--------------------------------|-------|
| | ARP0 | ARP1 | ARP0 | ARP1 | ARP0 | ARP1 | ARP0 | ARP1 |
| 1 | 0,17 | 0,16 | 0,16 | 0,16 | -0,06 | -0,10 | -0,11 | -0,12 |
| 3 | 0,29 | 0,25 | 0,20 | 0,19 | 0,24 | 0,22 | 0,15 | 0,15 |
| 6 | 0,36 | 0,36 | 0,27 | 0,28 | 0,34 | 0,35 | 0,24 | 0,26 |
| 12 | 0,36 | 0,38 | 0,27 | 0,30 | 0,35 | 0,37 | 0,25 | 0,28 |
| 24 | 0,29 | 0,30 | 0,22 | 0,24 | 0,27 | 0,28 | 0,20 | 0,22 |
| dt [h] | $\overline{n\omega^2}$ | | p-value ($n\omega^2$ -Test) | | $D_{n,n'}$ | | p-value (K-S-Test) | |
| | ARP0 | ARP1 | ARP0 | ARP1 | ARP0 | ARP1 | ARP0 | ARP1 |
| 1 | 0,023 | 0,027 | 264 | 249 | 0,029 | 0,030 | 260 | 251 |
| 3 | 0,034 | 0,034 | 240 | 233 | 0,033 | 0,033 | 254 | 247 |
| 6 | 0,050 | 0,054 | 176 | 165 | 0,038 | 0,039 | 186 | 182 |
| 12 | 0,048 | 0,054 | 172 | 154 | 0,038 | 0,040 | 200 | 173 |
| 24 | 0,037 | 0,041 | 205 | 191 | 0,033 | 0,035 | 225 | 209 |

Tabelle 5-15 Vergleich der Indizes der Extremwerte der Modellvarianten ARP0 und ARP1 im Mittel über alle Stationen, Winter

| dt [h] | $\overline{D_{abs,n}}$ [mm/h] | | $\overline{D_{abs,w}}$ [mm/h] | | $\overline{D_{sign,n}}$ [mm/h] | | $\overline{D_{sign,w}}$ [mm/h] | |
|--------|-------------------------------|-------|---------------------------------|------|--------------------------------|-------|--------------------------------|-------|
| | ARP0 | ARP1 | ARP0 | ARP1 | ARP0 | ARP1 | ARP0 | ARP1 |
| 1 | 0,13 | 0,20 | 0,10 | 0,16 | -0,05 | -0,19 | -0,04 | -0,15 |
| 3 | 0,16 | 0,37 | 0,14 | 0,33 | 0,12 | 0,27 | 0,11 | 0,27 |
| 6 | 0,16 | 0,13 | 0,13 | 0,11 | 0,12 | 0,08 | 0,09 | 0,08 |
| 12 | 0,16 | 0,14 | 0,13 | 0,12 | 0,11 | 0,10 | 0,07 | 0,08 |
| 24 | 0,14 | 0,11 | 0,11 | 0,10 | 0,06 | 0,04 | 0,02 | 0,02 |
| dt [h] | $\overline{n\omega^2}$ | | p-value ($n\omega^2$ -Test) | | $D_{n,n'}$ | | p-value (K-S-Test) | |
| | ARP0 | ARP1 | ARP0 | ARP1 | ARP0 | ARP1 | ARP0 | ARP1 |
| 1 | 0,021 | 0,062 | 253 | 125 | 0,027 | 0,041 | 265 | 171 |
| 3 | 0,029 | 0,023 | 229 | 268 | 0,030 | 0,026 | 236 | 273 |
| 6 | 0,030 | 0,028 | 238 | 240 | 0,031 | 0,030 | 241 | 246 |
| 12 | 0,027 | 0,027 | 237 | 230 | 0,029 | 0,029 | 240 | 237 |
| 24 | 0,020 | 0,017 | 268 | 275 | 0,026 | 0,025 | 267 | 281 |

5.2.2.5 Niederschlagsgenerierung mit GWL

In der Auswertung der Ergebnisse der Modellierung mit GWL werden im ersten Schritt die im Abschnitt 5.2.1.1 vorgestellten Kennwerte der Modellversionen ohne GWL (ARP1), die Version mit acht GWL (ARP2), die Version mit vier GWL (ARP3) und die Version mit zwei GWL (ARP4) verglichen. Die Farbgebung entspricht der von Tabelle 5-13. Zusätzlich wird die beste Modellversion mit GWL-Bindung durch Fettdruck gekennzeichnet. Für Informationen zu den verwendeten unterschiedlichen GWL-Versionen wird auf die Abschnitte 4.2 und 5.2.2.1 verwiesen.

Tabelle 5-16 Abweichung [%] der statistischen Momente der synthetischen Daten zur Beobachtung

| Saison | Version | μ_{dsd} | σ_{dsd}^2 | γ_{dsd} | μ_{wsd} | σ_{wsd}^2 | γ_{wsd} |
|--------|---------|-------------|------------------|----------------|-------------|------------------|----------------|
| Winter | ARP1 | 0,91 | 4,13 | 8,99 | 0,32 | 6,11 | 16,86 |
| | ARP2 | 0,83 | 3,55 | 7,88 | 0,45 | 4,26 | 12,15 |
| | ARP3 | 0,43 | 3,35 | 7,8 | 0,37 | 5,28 | 14,13 |
| | ARP4 | 0,30 | 3,20 | 7,62 | 0,31 | 5,74 | 15,29 |
| Sommer | ARP1 | 0,77 | 5,30 | 15,18 | 0,47 | 4,77 | 12,83 |
| | ARP2 | 0,53 | 4,84 | 11,3 | 0,55 | 3,35 | 10,82 |
| | ARP3 | 0,32 | 4,38 | 10,24 | 0,44 | 3,83 | 11,06 |
| | ARP4 | 0,40 | 5,03 | 10,23 | 0,34 | 4,40 | 13,08 |
| Jahr | ARP1 | 0,78 | 4,20 | 11,55 | 0,35 | 5,44 | 15,91 |
| | ARP2 | 0,47 | 4,09 | 10,05 | 0,45 | 3,46 | 11,12 |
| | ARP3 | 0,23 | 3,82 | 9,73 | 0,34 | 4,45 | 13,43 |
| | ARP4 | 0,28 | 4,13 | 9,77 | 0,32 | 4,98 | 15,18 |
| Saison | Version | μ_{wsi} | σ_{wsi}^2 | γ_{wsi} | μ_{wsa} | σ_{wsa}^2 | γ_{wsa} |
| Winter | ARP1 | 1,02 | 15,86 | 35,94 | 1,74 | 13,51 | 34,99 |
| | ARP2 | 1,27 | 9,66 | 32,75 | 1,47 | 13,69 | 50,85 |
| | ARP3 | 1,05 | 10,94 | 26,4 | 1,76 | 13,42 | 50,57 |
| | ARP4 | 1,07 | 13,68 | 28,78 | 1,64 | 13,73 | 44,64 |
| Sommer | ARP1 | 0,62 | 8,40 | 28,07 | 3,31 | 65,51 | 104,24 |
| | ARP2 | 1,07 | 9,93 | 44,01 | 2,23 | 58,37 | 110,96 |
| | ARP3 | 0,54 | 9,80 | 38,70 | 2,73 | 63,48 | 105,34 |
| | ARP4 | 0,55 | 9,31 | 30,18 | 2,94 | 57,8 | 97,03 |
| Jahr | ARP1 | 0,81 | 7,52 | 25,04 | 1,67 | 40,00 | 106,54 |
| | ARP2 | 0,69 | 8,32 | 40,29 | 1,25 | 38,43 | 110,38 |
| | ARP3 | 0,76 | 8,10 | 34,94 | 1,37 | 40,84 | 107,54 |
| | ARP4 | 0,79 | 7,86 | 27,02 | 1,56 | 36,57 | 98,00 |

Die Ergebnisse zeigen ein gemischtes Bild. Durch die Bindung des Modells an die GWL verbessern sich einige der statistischen Momente leicht, andere verschlechtern sich leicht (siehe Tabelle 5-16). Insgesamt dominieren hierbei die Verbesserungen etwas. Für die Reproduktion der L-Momente ergibt sich ein ähnliches Bild (siehe Tabelle A-4). Die Unterschiede der Modellvarianten mit unterschiedlicher Anzahl an GWL sind gering.

Tabelle 5-17 Vergleich der Indizes der Extremwerte der synthetischen Daten im Mittel über alle Stationen, Sommer

| dt [h] | $\overline{D_{abs,n}}$ [mm/h] | | | | $\overline{D_{abs,w}}$ [mm/h] | | | |
|--------|--------------------------------|--------------|--------------|--------------|------------------------------------|-------------|--------------|--------------|
| | ARP1 | ARP2 | ARP3 | ARP4 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,16 | 0,18 | 0,17 | 0,17 | 0,16 | 0,19 | 0,17 | 0,17 |
| 3 | 0,25 | 0,21 | 0,23 | 0,22 | 0,19 | 0,16 | 0,17 | 0,17 |
| 6 | 0,36 | 0,31 | 0,34 | 0,30 | 0,28 | 0,24 | 0,26 | 0,23 |
| 12 | 0,38 | 0,34 | 0,36 | 0,33 | 0,30 | 0,26 | 0,28 | 0,26 |
| 24 | 0,30 | 0,27 | 0,28 | 0,27 | 0,24 | 0,22 | 0,23 | 0,22 |
| dt [h] | $\overline{D_{sign,n}}$ [mm/h] | | | | $\overline{D_{sign,w}}$ [mm/h] | | | |
| | ARP1 | ARP2 | ARP3 | ARP4 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | -0,10 | -0,13 | -0,11 | -0,12 | -0,12 | -0,16 | -0,14 | -0,14 |
| 3 | 0,22 | 0,17 | 0,20 | 0,19 | 0,15 | 0,10 | 0,12 | 0,12 |
| 6 | 0,35 | 0,29 | 0,33 | 0,28 | 0,26 | 0,22 | 0,24 | 0,20 |
| 12 | 0,37 | 0,33 | 0,35 | 0,32 | 0,28 | 0,25 | 0,27 | 0,25 |
| 24 | 0,28 | 0,25 | 0,27 | 0,25 | 0,22 | 0,20 | 0,21 | 0,20 |
| dt [h] | $\overline{n\omega^2}$ | | | | p-value ($\overline{n\omega^2}$) | | | |
| | ARP1 | ARP2 | ARP3 | ARP4 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,027 | 0,032 | 0,028 | 0,029 | 249 | 232 | 243 | 240 |
| 3 | 0,034 | 0,025 | 0,030 | 0,029 | 233 | 252 | 239 | 247 |
| 6 | 0,054 | 0,045 | 0,050 | 0,043 | 165 | 194 | 180 | 206 |
| 12 | 0,054 | 0,048 | 0,051 | 0,046 | 154 | 181 | 161 | 185 |
| 24 | 0,041 | 0,035 | 0,038 | 0,036 | 191 | 216 | 201 | 209 |
| dt [h] | $\overline{D_{n,n'}}$ | | | | p-value(K-S-Test) | | | |
| | ARP1 | ARP2 | ARP3 | ARP4 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,030 | 0,033 | 0,031 | 0,031 | 251 | 240 | 251 | 251 |
| 3 | 0,033 | 0,030 | 0,031 | 0,031 | 247 | 269 | 259 | 258 |
| 6 | 0,039 | 0,037 | 0,038 | 0,036 | 182 | 198 | 184 | 216 |
| 12 | 0,040 | 0,038 | 0,039 | 0,038 | 173 | 202 | 183 | 202 |
| 24 | 0,035 | 0,033 | 0,034 | 0,033 | 209 | 229 | 221 | 231 |

Tabelle 5-18 Vergleich der Indizes der Extremwerte der synthetischen Daten im Mittel über alle Stationen, Winter

| dt [h] | $\overline{D_{abs,n}}$ [mm/h] | | | | $\overline{D_{abs,w}}$ [mm/h] | | | |
|--------|--------------------------------|--------------|--------------|-------------|------------------------------------|--------------|-------------|--------------|
| | ARP1 | ARP2 | ARP3 | ARP4 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,20 | 0,20 | 0,20 | 0,20 | 0,16 | 0,16 | 0,17 | 0,16 |
| 3 | 0,37 | 0,37 | 0,037 | 0,37 | 0,33 | 0,35 | 0,34 | 0,34 |
| 6 | 0,13 | 0,14 | 0,14 | 0,14 | 0,11 | 0,12 | 0,12 | 0,12 |
| 12 | 0,14 | 0,15 | 0,15 | 0,15 | 0,12 | 0,14 | 0,13 | 0,14 |
| 24 | 0,11 | 0,12 | 0,12 | 0,12 | 0,10 | 0,11 | 0,11 | 0,11 |
| dt [h] | $\overline{D_{sign,n}}$ [mm/h] | | | | $\overline{D_{sign,w}}$ [mm/h] | | | |
| | ARP1 | ARP2 | ARP3 | ARP4 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | -0,19 | -0,19 | -0,19 | -0,19 | -0,15 | -0,15 | -0,16 | -0,15 |
| 3 | 0,27 | 0,29 | 0,27 | 0,28 | 0,27 | 0,28 | 0,27 | 0,28 |
| 6 | 0,08 | 0,097 | 0,09 | 0,10 | 0,08 | 0,09 | 0,08 | 0,09 |
| 12 | 0,10 | 0,12 | 0,11 | 0,11 | 0,08 | 0,09 | 0,09 | 0,09 |
| 24 | 0,04 | 0,06 | 0,05 | 0,05 | 0,02 | 0,02 | 0,03 | 0,03 |
| dt [h] | $\overline{n\omega^2}$ | | | | p-value ($\overline{n\omega^2}$) | | | |
| | ARP1 | ARP2 | ARP3 | ARP4 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,062 | 0,054 | 0,060 | 0,06 | 125 | 149 | 134 | 137 |
| 3 | 0,023 | 0,023 | 0,023 | 0,024 | 268 | 268 | 260 | 262 |
| 6 | 0,028 | 0,029 | 0,030 | 0,031 | 240 | 247 | 242 | 243 |
| 12 | 0,027 | 0,030 | 0,030 | 0,031 | 230 | 234 | 236 | 227 |
| 24 | 0,017 | 0,019 | 0,019 | 0,020 | 275 | 266 | 265 | 260 |
| dt [h] | $\overline{D_{n,n'}}$ | | | | p-value(K-S-Test) | | | |
| | ARP1 | ARP2 | ARP3 | ARP4 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,041 | 0,038 | 0,040 | 0,04 | 171 | 185 | 175 | 167 |
| 3 | 0,026 | 0,026 | 0,026 | 0,027 | 273 | 274 | 271 | 271 |
| 6 | 0,030 | 0,030 | 0,031 | 0,031 | 246 | 248 | 247 | 249 |
| 12 | 0,029 | 0,030 | 0,030 | 0,030 | 237 | 239 | 243 | 234 |
| 24 | 0,025 | 0,026 | 0,026 | 0,026 | 281 | 275 | 269 | 264 |

Auch die Extremwerte (siehe Tabelle 5-17 und Tabelle 5-18) zeigen ein gemischtes Bild. Für die wichtigeren Sommer-Extrema (die i. d. R. identisch mit den Jahres-Extrema sind) zeigt sich eine nahezu durchgehende Verbesserung der Reproduktion durch die Hinzunahme der GWL (Ausnahme sind die einstündigen Extremwerte). Die Reproduktion der kleineren Winter-Extrema hingegen zeigt interessante Ergebnisse.

Während die gemittelten Kenngrößen größtenteils eine leichte Verschlechterung anzeigen, ist die Anzahl an Tests, die eine gute Wiedergabe der Extremwerte markieren (erkennbar an den p-values) größtenteils höher. Die Unterschiede zwischen den Versionen mit unterschiedlicher GWL-Anzahl sind gering, wobei die Version mit zwei GWL im Sommer für die meisten Dauerstufen die beste ist. In Tabelle A-6 und Tabelle A-7 finden sich die Extremwerte aller Modellvarianten zusammengefasst.

Bei den abgeleiteten Größen (siehe Tabelle 5-19) zeigen sich mit Verwendung der GWL größtenteils Verbesserungen der Modellierungsergebnisse. Es ist hierbei nicht möglich, eine bestimmte Anzahl an GWL zu favorisieren.

Eine Gegenüberstellung der Momente und der abgeleiteten Charakteristika aller Modellvarianten findet sich in Tabelle A-3 bis Tabelle A-5.

Tabelle 5-19 Abweichung [%] der abgeleiteten Größen der synthetischen Daten zur Beobachtung

| Saison | Version | Mittlere Jahresereignisanzahl | Mittlere Niederschlagssummen |
|--------|---------|-------------------------------|------------------------------|
| Winter | ARP1 | 1,01 | 1,82 |
| | ARP2 | 1,00 | 1,60 |
| | ARP3 | 0,77 | 1,95 |
| | ARP4 | 0,76 | 1,92 |
| Sommer | ARP1 | 1,45 | 4,46 |
| | ARP2 | 0,96 | 2,94 |
| | ARP3 | 0,81 | 3,35 |
| | ARP4 | 1,06 | 3,73 |
| Jahr | ARP1 | 1,08 | 2,44 |
| | ARP2 | 0,76 | 1,79 |
| | ARP3 | 0,55 | 1,81 |
| | ARP4 | 0,62 | 2,03 |

Zusammengefasst lässt sich feststellen, dass die GWL einen nachweisbaren Einfluss auf die Ergebnisse der Modellierung haben, auch wenn dieser geringer war, als erwartet.

Die Reproduktion der statistischen Momente verbessert sich durch Berücksichtigung der GWL insgesamt sehr leicht. Allerdings verschlechtern sich hierbei auch einige der Momente.

Wenn man die Priorität auf die großen Sommer-Extrema setzt, kann eine geringe Verbesserung der Modellergebnisse festgestellt werden. Als zu favorisierende Methode kann die Version mit zwei GWL genannt werden, da diese bei den wichtigen Sommer-Extremwerten die besten Ergebnisse liefert.

Auch für die abgeleiteten Kennwerte (Ereignisanzahl und saisonale Summen) lassen sich mit den GWL Verbesserungen erzielen. Hierbei sind die Versionen mit 4 und 8 GWL der Version mit 2 GWL leicht überlegen.

6 Räumliche Übertragbarkeit der Modellparameter

Da die Daten der Niederschlagsbeobachtung an den meisten Orten der Welt, aber auch in Deutschland, oftmals sehr spärlich sind, ist es wünschenswert, die Modellparameter auf Orte zu übertragen, an denen keine Beobachtungsdaten vorliegen. Somit können auch für diese Orte Niederschläge modelliert werden. In diesem Abschnitt werden einige Methoden dafür diskutiert und miteinander verglichen. Als Resultat der Diskussion wird eine Methode als optimale ausgewählt werden. Für die Voruntersuchungen zur räumlichen Niederschlagsvariabilität wird auf Abschnitt 3.3 verwiesen.

6.1 Methodendiskussion und -auswahl

In diesem Kapitel wird zuerst eine Übersicht der infrage kommenden Methoden zur räumlichen Übertragung der Parameter und der hierzu gehörenden Zusatzvariablen gegeben. Im Anschluss hieran werden diese Methoden detailliert erläutert.

Um das Modell auf Gebiete ohne Niederschlagsbeobachtung anwenden zu können, ist eine Übertragung der Modelleigenschaften notwendig. Es wurde als sinnvoller und leichter erachtet, die in der Parametergenerierung verwendeten L-Momente und nicht die Modellparameter oder Zeitreihen selbst zu übertragen. Der Grund hierfür ist einerseits, dass eine Interpolation in Stundenwertauflösung aufgrund des Datenumfanges aufwendig und die entstehende Zeitreihe oft stark geglättet ist, während andererseits nicht-lineare Modellparameter meist schwer zu übertragen sind.

An dieser Stelle soll untersucht werden, ob für das GWL verwendende Modell eine Interpolation durchführbar ist. Aufgrund der hohen Parameteranzahl und der verringerten Stichprobengröße ist dies nicht trivial.

Erster Schritt der Untersuchungen war, für die Ereignisse der gesamten Jahre, also ohne GWL und ohne Saisonberücksichtigung, eine Vorauswahl von Interpolationsverfahren zu treffen. Diese wurden anschließend auf das Modell mit GWL und Saisonalitätsbezug übertragen und an diesem validiert. Diese Vorgehensweise ist sinnvoll, da sonst für die Anzahl an Interpolationsverfahren, Modellparameter und Zusatzvariablen eine strukturierte Analyse der Interpolationsverfahren unter Berücksichtigung der GWL und Saisons unmöglich wäre.

Es wurden in den Analysen verschiedene Methoden getestet. Diese waren das Nächster-Nachbar-Verfahren (NN), das Ordinary Kriging (OK), das External Drift Kriging (EDK), Multiple Regression (MR) und ein einfaches Disaggregationsverfahren.

Haberlandt (1998) hatte bereits vergleichbare Untersuchungen mit OK, EDK und MR vorgenommen. In der Arbeit zeigte sich für Mittelwerte und Standardabweichungen der *wsd* und *d_{sd}* das EDK als günstigstes Verfahren. In dieser Arbeit wird allerdings ein anderes Untersuchungsgebiet verwendet. Weiterhin kommen L-Momente und *w_{si}* zum Einsatz, während Haberlandt (1998) statistische Momente und *w_{sa}* verwendete. Daher können diese Ergebnisse nicht einfach übertragen werden.

In der Regionalisierung wurden folgende Zusatzvariablen (bzw. Einflussgrößen) für das EDK und die MR verwendet:

- Geländehöhe über Normalnull (H)
- Durchschnittlicher Jahresniederschlag (P_y)
- Durchschnittliche Anzahl nasser Tage (N_{wd}) und trockener Tage (N_{dd}) pro Jahr
- Mittlerer Niederschlag pro Jahr an Tagen mit $P > 0,1\text{mm}$ (d_m)
- L-Momente (L_1 , L_2 , Tau_3) des der interpolierten Kenngröße entsprechenden Ereignisparameters bei Ereignisdefinition mit Tageswerten (LM_d)

Abbildung 6-1 zeigt 4 Beispiele für verwendete Zusatzvariablen für die Niederschlagsstationen der Validierung. Da insgesamt 86 Zusatzvariablen in den Untersuchungen betrachtet wurden, wird hier ein qualitativer Auszug der Ergebnisse gezeigt. In den Parametern ist in der Regel ein deutlicher räumlicher Bezug vorhanden. Insbesondere die Harzregion ist meist klar erkennbar.

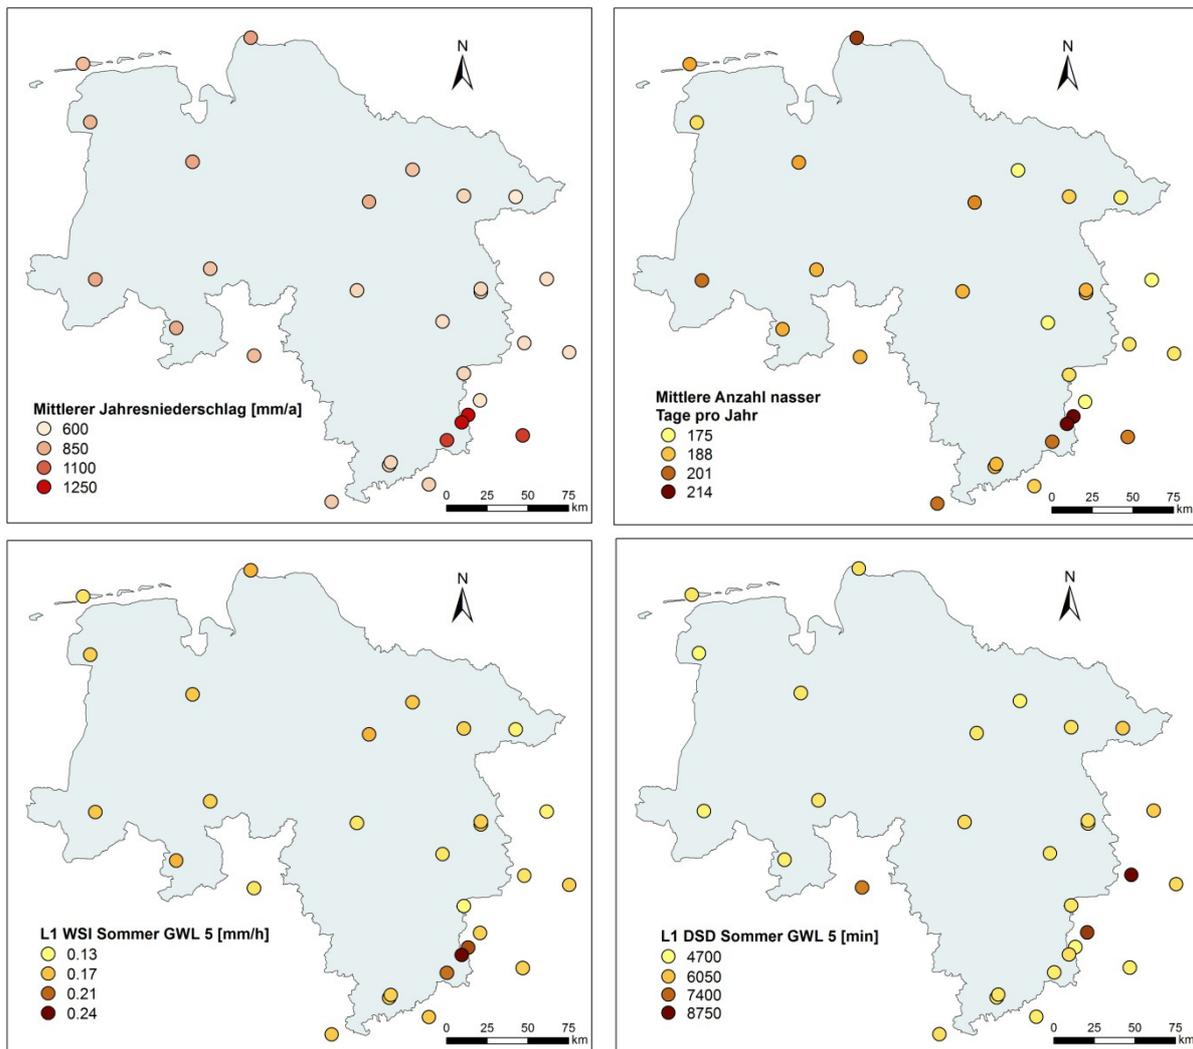


Abbildung 6-1 Zusatzvariablen für die Parameterregionalisierung – Validierungsdatensatz

Aufgrund der Zusatzvariablen kann das Modell also im einfachen Fall nur für Orte mit vorhandener Tageswertzeitreihe regionalisiert werden. Natürlich könnten aber auch interpolierte Tageswerte verwendet werden. Hier müsste darauf geachtet werden, dass die interpolierten Tageswerte sowohl zur Kalibrierung des Modells als auch zum operativen operativen Einsatz verwendet werden müssen. Abbildung 6-2 zeigt eine Übersicht der Tageswertstationen, die im Untersuchungszeitraum verwendbare Beobachtungsdaten aufweisen.

Zuerst werden die Kriging-Verfahren besprochen. Diese sind eine Gruppe gut bekannter und häufig verwendeter Verfahren. Das Verfahren wurde nach der Pionierarbeit von Krige (1951) benannt. Kriging gehört zur Gruppe der Regressionsanalysen, welche mit der Methode der kleinsten Quadrate arbeiten.

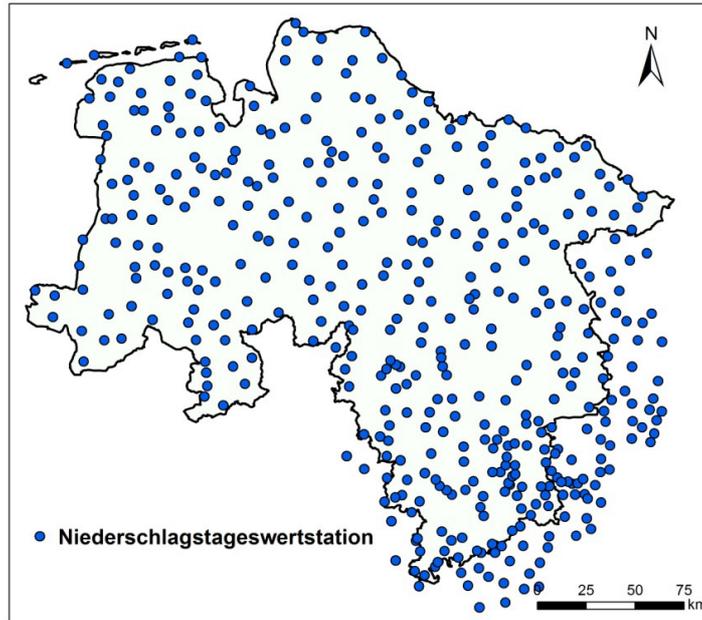


Abbildung 6-2 Tageswertstationen – Messnetz in Niedersachsen

Verwendet wurde das **Ordinary Kriging (OK)**, welches der am häufigsten anzutreffende Fall des Kriging ist. Für das OK gilt, dass die Summe aller Gewichtungsfaktoren 1 sein muss (siehe (6-1)). Hiermit ergibt sich folgender Krige-Schätzer (siehe (6-2)).

$$\sum_{\alpha=1}^{n(u)} \lambda_{\alpha} = 1 \quad (6-1)$$

$$Z^*(u_0) = \sum_{\alpha=1}^{n(u)} \lambda_{\alpha} Z(u_{\alpha}) \quad (6-2)$$

$Z^*(u_0)$ ist der Schätzwert des unbekanntes zu bestimmenden Punktes u_0 . $\lambda_{\alpha}(u)$ ist der Gewichtungsfaktor, der dem bekannten Messpunkt $Z(u_{\alpha})$ zugewiesen wird.

Für das OK muss die intrinsische Hypothese erfüllt sein. Das bedeutet zum einem, dass der Erwartungswert m der Zielfunktion für alle Punkte im Gebiet gleich ist. Zum anderen beinhaltet die intrinsische Hypothese, dass der Erwartungswert der Differenzen zwischen zwei Punkten im Gebiet gleich null ist und die Varianz des Inkrements zweier Punkte im Gebiet nur abhängig vom Abstandsvektor und nicht vom Ort ist.

Formuliert wird das OK durch Semi-Variogramme, bei denen die (Semi-)Varianz des Inkrements zwischen zwei Punkten ($Z(u+h)$ und $Z(u)$) nur vom Abstandsvektor h abhängig ist. Für alle u im Gebiet gilt:

$$\gamma(h) = \frac{1}{2} E \left\{ \left[Z(u') - Z(u'+h) \right]^2 \right\} = \frac{1}{2} Var \left[\left[Z(u') - Z(u'+h) \right] \right] \quad (6-3)$$

Die Fehlervarianz lautet:

$$\sigma^2(u) = \sum_{\alpha=1}^n \sum_{\beta=1}^n \lambda_{\alpha} \lambda_{\beta} \gamma(u_{\alpha} - u_{\beta}) - 2 \sum_{\alpha=1}^n \lambda_{\alpha} \gamma(u_{\alpha} - u) \quad (6-4)$$

Mit Hilfe der Lagrange-Funktion wird die Fehlervarianz minimiert (siehe (6-5)).

$$L(\lambda_{\alpha}, \mu) = \sigma^2 - 2\mu \left(\sum_{\alpha=1}^n \lambda_{\alpha} - 1 \right) \rightarrow Min \quad (6-5)$$

μ - Lagrange Parameter

Wenn mittels $\delta L/\delta \lambda_i$ und $\delta L/\delta \mu$ die Ableitungen zu null gesetzt werden, wird das Kriging-Gleichungssystem gebildet:

$$\sum_{\beta=1}^{n(u)} \lambda_{\beta} \gamma(u_{\alpha} - u_{\beta}) + \mu = \gamma(u_{\alpha} - u), \quad \alpha = 1, \dots, n \quad (6-6)$$

$$\sum_{\beta=1}^{n(u)} \lambda_{\beta} = 1 \quad (6-7)$$

Somit können die Gewichtungsfaktoren λ_{α} ermittelt und anschließend mit (6-2) die Interpolation durchgeführt werden. Weiteres zum OK kann zum Beispiel Goovaerts (1997) entnommen werden. Für die Variogrammschätzung wird auf Isaaks & Srivastava (1989) verwiesen.

Das **External Drift Kriging (EDK)**-Verfahren ermöglicht die Berücksichtigung von Zusatzvariablen in der Interpolation. Grundgedanke des Verfahrens ist, dass der Erwartungswert (der dem Trend $m(u)$ entspricht) von den Zusatzvariablen Y_i abhängt.

$$E[Z(u)|Y_i] = m(u) = a_0 + \sum_{i=1}^N a_i Y_i(u) \quad (6-8)$$

Mit dem EDK können nur Werte für Punkte interpoliert werden, an denen die verwendeten Zusatzvariablen vorhanden sind. Weiteres ist Deutsch & Journel (1997) zu entnehmen.

Die **lineare multiple Regression (MR)** ist ein einfaches Verfahren, bei dem eine Abhängigkeit zwischen dem gesuchten Schätzwert des unbekanntes Punktes und bekannten Werten anderer Kenngrößen am selben Punkt hergestellt wird. Bei dem hier verwendeten linearen Fall der Regression wird dies über die folgende Beziehung vorgenommen:

$$X = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (6-9)$$

mit: X - Schätzwert des unbekanntes Punktes

α, β_n - Parameter der Regression

x_n - Einflussgröße (entspricht den Zusatzvariablen des EDK)

Zur Lösung der sich mit den Beobachtungspunkten aus (6-9) entstehenden Gleichungen wurde die Methode der kleinsten Quadrate verwendet. Für Details zu diesem Vorgehen siehe die einschlägige Literatur, z. B. Herrmann (2007) oder Bronstein & Semendjajew (2000).

Bei dem Verfahren des **nächsten Nachbarn (NN)** wird für den unbekanntes Punkt der Wert des geographisch nächstliegenden Beobachtungspunktes (euklidischer Abstand) verwendet.

Bei Verwendung der Großwetterlagen müssen die oben beschriebenen Verfahren auf jede GWL einzeln angewendet werden.

Bei den Untersuchungen kam das Softwarepaket „GSLIB (siehe Deutsch & Journel“ (1997)) und das R-Paket „Stats“ (siehe R Development Core Team (2008)) zum Einsatz.

6.2 Transfer der Modellparameter im Raum

Im ersten Schritt wurde untersucht, welches Interpolationsverfahren am besten geeignet für die Interpolation ohne GWL ist.

6.2.1 Variogrammschätzung

Für die Kriging-Verfahren musste die Datenbasis für die Variogrammschätzung erhöht werden, da diese ansonsten für ein so großes Gebiet mit nur 29 Stationen nicht realisierbar wäre. Daher wurden alle Stationen verwendet, die im Zeitraum 2005 bis 2008 vollständige Daten enthielten.

Der Zeitraum wurde so ausgewählt, da er eine Kombination von möglichst vielen Beobachtungsstationen (78) und einer möglichst langen Zeitreihenlänge darstellt. Ein kürzerer Zeitraum hätte nicht nennenswert mehr Beobachtungsstationen enthalten und ein längerer Zeitraum hätte die Stationsanzahl nahezu halbiert. Die verwendeten Stationen sind in Abbildung 6-3 dargestellt. Die Datenbasis ist leider recht stark südost-lastig. Dies ist keineswegs beabsichtigt, sondern hat sich daraus ergeben, dass insgesamt recht wenig hochauflösende Niederschlagsdaten aus dem Nordwesten Niedersachsens vorhanden sind.

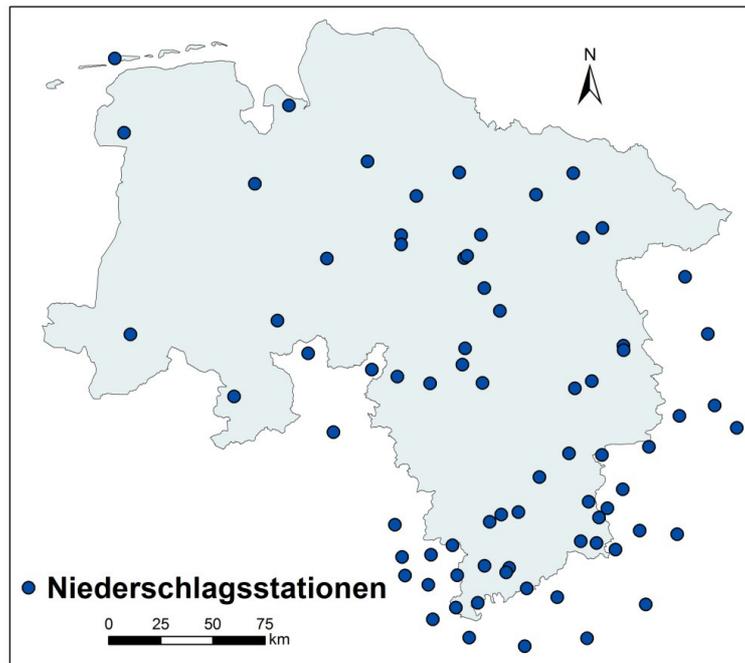


Abbildung 6-3 Stundenwert-Beobachtungsstationen der Variogrammschätzung

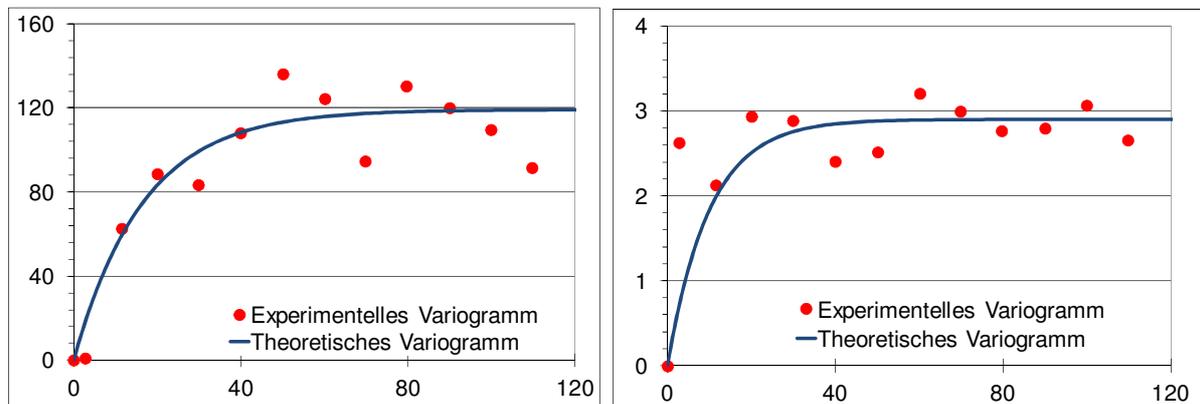


Abbildung 6-4 Variogrammschätzung; links: Mittelwert der dsd , rechts: Mittelwert der wsi ; x-Achse: Entfernung in km; y-Achse: Varianz, für dsd durch 1000 dividiert, für wsi mit 1000 multiplizierte Werte.

In der Variogrammschätzung konnten für die wsd und dsd recht gute Ergebnisse erzielt werden, allerdings war die Anpassung für die wsi sehr schwierig. Die experimentellen Variogramme zeigen praktisch einen reinen Nugget-Effekt (siehe Abbildung 6-4 und Abbildung A-13 bis Abbildung A-15). Die stets vorhandenen Werte nahe 0 liegen an 2 Stationspaaren, die jeweils sehr nahe beieinanderliegen. Ein relevanter räumlicher Einfluss ist also für die wsi anscheinend nicht erkennbar. Dies bestätigt die Ergebnisse der Analysen zum räumlichen Niederschlagsverhalten aus Abschnitt 3.3. Dies ist ein Hinweis dafür, dass es zu prüfen wäre, in späteren Modellversionen zu einer Modellierung der wsa zurückzugehen. Dies war in früheren Modellen noch üblich (siehe Haberlandt (1998)).

Es ist zumindest anzunehmen, dass die Regionalisierung des Modells mit *wsa* leichter möglich sein sollte, da diese zumindest die üblichen regionalen Unterschiede des Gebietes aufweisen (siehe Abschnitt 3.3). Allerdings erfolgt an dieser Stelle keine ausführliche Analyse, welche Kenngröße vorzuziehen ist, da die auf GWL fokussierte Zielsetzung dieser Arbeit den hierfür notwendigen hohen Zeitaufwand nicht rechtfertigen würde.

6.2.2 Ergebnisauswertung

Die Auswertung der Ergebnisse erfolgt in zwei Schritten. Zuerst wurde eine Kreuzvalidierung der interpolierten Werte durchgeführt. Im zweiten Schritt wurde das Niederschlagsmodell mit den interpolierten Werten aus der Kreuzvalidierung angetrieben und die Modellergebnisse mit den Ergebnissen des nicht interpolierten Modells verglichen. Als Kriterien zur Beurteilung der Kreuzvalidierung werden der Bias

$$Bias = \frac{\sum_{i=1}^N (X_{int} - X_{beo}) / N}{\sum_{i=1}^N X_{beo} / N} \quad (6-10)$$

mit X_{int} : interpolierte Größe, X_{beo} : Beobachtungsgröße, N -Anzahl Elemente,

der mittlere quadratische Fehler (root mean square error, RMSE)

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_{int} - X_{beo})^2}{N}} \quad (6-11)$$

und der pearsonsche Korrelationskoeffizient (siehe Sachs (2004), in den nachfolgenden Tabellen als *Korrel* abgekürzt) herangezogen.

Die Kreuzvalidierung der Interpolation der L-Momente ist der Tabelle 6-1 zu entnehmen. Bei allen Variablen ist der Favorit entweder EDK oder MR. Für *dsd* und *wsi* ist die MR stets ein wenig besser, für *wsd* das EDK. In Tabelle 6-2 sind die optimalen Kombinationen der Zusatzvariablen dargestellt. Diese sind auch Grundlage der Tabelle 6-1. Bei der multiplen Regression bringt eine höhere Anzahl an Zusatzvariablen Vorteile in den Modellergebnissen. Multikolarität wurde nicht explizit untersucht, ist aber aufgrund der verwendeten Eingangsgrößen ein zu erwartendes Phänomen. Es konnten in den Untersuchungen allerdings keine Probleme festgestellt werden.

Sogar die gleichzeitige Berücksichtigung von N_{wd} und N_{dd} bringt teilweise leichte Vorteile (siehe Tabelle 6-3). Dies ist ein eindeutiger Vorteil für das EDK, das mit deutlich weniger Zusatzvariablen auskommt. Bei der Auswahl der optimalen Kombination der Zusatzvariablen wurde versucht, die Anzahl der Zusatzvariablen gering zu halten. So wurden Kombinationen mit mehr Zusatzvariablen nur vorgezogen, wenn diese zu signifikanten Verbesserungen führten. In dem Beispiel in Tabelle 6-3 wird somit die Version mit drei Zusatzvariablen der mit vier vorgezogen, da der Vorteil der letztgenannten Version sehr gering ist. Interessant ist, dass in zwei Fällen das für das EDK optimale Kriterium nicht Element der optimalen Kriterien der multiplen Regression ist (siehe in Tabelle 6-2 bei L2(*dsd*) und L2(*wsi*)).

Alle Momente der *dsd* und der *wsd* konnten gut bis zufriedenstellend interpoliert werden. Leider trifft dies nicht auf die *wsi* zu. Diese konnten mit keiner der vorgestellten Methoden wirklich gut reproduziert werden.

Lediglich mit der MR konnten für alle Momente der *wsi* zumindest Korrelationen von immerhin ungefähr 0,5 erreicht werden. Dies passt gut zu dem in der Voruntersuchung festgestellten Anschein einer räumlichen Zufälligkeit der *wsi* (siehe Abschnitte 3.3 und 6.2.1).

Auf eine detaillierte Diskussion des Einflusses aller einzelnen Zusatzvariablen auf die MR wird hier wegen der hohen Anzahl der Variablen und Nebensächlichkeit des Themas bezüglich des Hauptpunkts der Untersuchungen, den Einfluss der GWL auf die Niederschlagsmodellierung, verzichtet.

Tabelle 6-1 Kreuzvalidierung der Interpolation der L-Momente (ein grüner Hintergrund kennzeichnet das Verfahren mit den besten Ergebnissen)

| Methode | | L1 (dsd) | L1 (wsd) | L1 (wsi) | L2 (dsd) | L2 (wsd) | L2 (wsi) | Tau3 (dsd) | Tau3 (wsd) | Tau3 (wsd) |
|---------|--------|----------|----------|----------|----------|----------|----------|------------|------------|------------|
| OK | Bias | 0,00 | -0,01 | 0,00 | 0,00 | -0,01 | 0,00 | 0,00 | 0,00 | 0,00 |
| | RMSE | 0,08 | 0,09 | 0,06 | 0,09 | 0,09 | 0,08 | 0,03 | 0,03 | 0,07 |
| | Korrel | 0,73 | 0,88 | 0,35 | 0,57 | 0,88 | 0,01 | 0,66 | 0,86 | 0,13 |
| EDK | Bias | 0,00 | -0,01 | 0,01 | 0,00 | -0,01 | 0,01 | 0,00 | 0,00 | 0,00 |
| | RMSE | 0,08 | 0,08 | 0,05 | 0,08 | 0,08 | 0,08 | 0,03 | 0,03 | 0,06 |
| | Korrel | 0,77 | 0,88 | 0,47 | 0,66 | 0,88 | 0,32 | 0,72 | 0,86 | 0,46 |
| MR | Bias | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 | 0,00 |
| | RMSE | 0,07 | 0,07 | 0,05 | 0,07 | 0,08 | 0,06 | 0,02 | 0,04 | 0,05 |
| | Korrel | 0,79 | 0,84 | 0,47 | 0,79 | 0,88 | 0,54 | 0,76 | 0,79 | 0,67 |
| NN | Bias | 0,02 | -0,03 | 0,01 | 0,01 | -0,04 | 0,01 | -0,01 | 0,00 | 0,01 |
| | RMSE | 0,10 | 0,11 | 0,07 | 0,10 | 0,13 | 0,08 | 0,03 | 0,04 | 0,07 |
| | Korrel | 0,71 | 0,73 | 0,26 | 0,68 | 0,78 | 0,32 | 0,68 | 0,82 | 0,36 |

Tabelle 6-2 Optimale Zusatzvariablen – Kombination bei der Interpolation der L-Momente

| Methode | L1 (dsd) | L1 (wsd) | L1 (wsi) | L2 (dsd) | L2 (wsd) | L2 (wsi) | Tau3 (dsd) | Tau3 (wsd) | Tau3 (wsd) |
|---------|--------------------------|--------------------------|-------------------------|-----------------------|--------------------------|--------------------------|--------------------------|--------------------------|--------------------------|
| EDK | P_y | H | LM_d | P_y | H | $H+d_m+$ LM_d | $H+N_{dd}$ | d_m | P_y |
| MR | $H+P_y+$ $N_{dd}+d_m$ | $H+P_y+$ $N_{wd}+d_m$ | P_y+N_{wd} $+LM_d$ | $H+N_{dd}$ $+LM_d$ | $H+P_y+$ $N_{wd}+d_m$ | $H+P_y+$ $N_{wd}+d_m$ | $H+P_y+$ $N_{dd}+d_m$ | $H+P_y+$ $N_{wd}+d_m$ | $H+P_y+$ $N_{wd}+d_m$ |

Tabelle 6-3 Einfluss weiterer Zusatzvariablen auf die multiple Regression des 2. L-Moments der *dsd*

| Zusatzvariablen | Korrelationskoeffizient |
|-----------------------------------|-------------------------|
| P_y | 0,410 |
| H | 0,430 |
| $H+N_{dd}$ | 0,751 |
| $H+N_{dd}+LM_d$ | 0,786 |
| $H+N_{dd}+N_{wd}+LM_d$ | 0,787 |
| $P_y+H+N_{dd}+N_{wd}+LM_d$ | 0,781 |

Ein interessantes, wenngleich schwieriges Problem stellt die Interpolation der Parameter der Feinstruktur (*lna*, *bb*) und der Copula dar. Hierfür ließen sich mit allen Verfahren nur recht unbefriedigende Ergebnisse erzielen (siehe Tabelle 6-4). Lediglich das multiple Regressions- und das Nächster-Nachbar-Verfahren erzielten zumindest für die Feinstrukturparameter halbwegs zufriedenstellende Ergebnisse, nicht jedoch für den Copula-Parameter. Da die Interpolation der Feinstrukturparameter teilweise zu Werten führte, die nicht verwendbar waren, ist das Nächster-Nachbar-Verfahren für die genannten drei Kenngrößen das zu empfehlende Verfahren.

Tabelle 6-4 Kreuzvalidierung der Interpolation der Feinstrukturparameter

| Methode | | lna | bb | Franks Copula |
|---------|--------|------|-------|---------------|
| OK | Bias | 0,00 | 0,00 | -0,07 |
| | RMSE | 0,02 | 0,02 | 0,52 |
| | Korrel | 0,29 | 0,18 | -0,18 |
| EDK | Bias | 0,00 | 0,00 | -0,02 |
| | RMSE | 0,02 | 0,02 | 0,41 |
| | Korrel | 0,14 | -0,03 | -0,03 |
| MR | Bias | 0,00 | 0,00 | 0,02 |
| | RMSE | 0,01 | 0,01 | 0,42 |
| | Korrel | 0,30 | 0,39 | -0,06 |
| NN | Bias | 0,00 | 0,00 | 0,00 |
| | RMSE | 0,01 | 0,01 | 0,37 |
| | Korrel | 0,47 | 0,58 | 0,11 |

6.3 Implementierung der Großwetterlagen

Um die im Abschnitt 6.2 favorisierten Interpolationsverfahren (EDK und multiple Regression) für das Modell mit GWL und Saisonalität zu validieren, wurden im ersten Schritt die Parameter desselben mit diesen Methoden interpoliert und Kreuzvalidiert. Abbildung 6-5 vergleicht die Ergebnisse der Kreuzvalidierung beider Varianten. Man kann sehen, dass die Ergebnisse der Interpolation der Modellparameter des Modells mit GWL etwas schlechter sind als die des Modells ohne GWL. Dies ist nicht überraschend. Um optimale Ergebnisse für das Modell mit GWL zu bekommen, hätten für jede GWL die optimalen Zusatzvariablen ermittelt werden müssen. Dies ist jedoch besonders bei Verwendung von neun GWL und zwei Saisons praktisch nicht zu realisieren. In den Grafiken ist gut zu erkennen, dass das Problem bei der Interpolation mit EDK deutlich stärker auftritt.

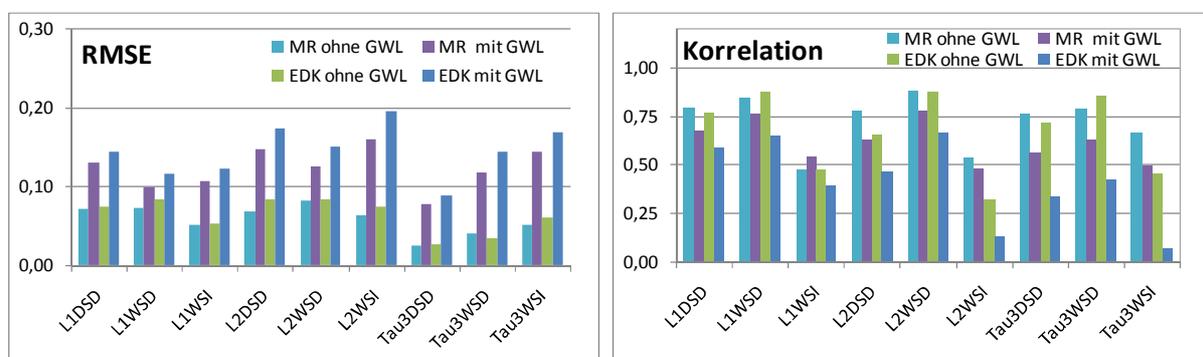


Abbildung 6-5 Vergleich der Kreuzvalidierung der Interpolation mit und ohne GWL; Version mit acht GWL, Mittel über alle GWL

Tabelle 6-5 Abweichung [%] der statistischen Momente der Beobachtung zu der der Modellergebnisse mit den Modellparametern aus Beobachtung und Regionalisierung (Kreuzvalidierung)
Mean: Mittelwert, Var: Varianz, Skew: Schiefe

| Saison | Version | Mean(dsd) | Var(dsd) | Skew(dsd) | Mean(wsd) | Var(wsd) | Skew(wsd) |
|--------|----------|-----------|----------|-----------|-----------|----------|-----------|
| Winter | ARP2 | 2 | 5 | 9 | 0 | 5 | 13 |
| | ARP2 EDK | 8 | 14 | 12 | 7 | 14 | 18 |
| | ARP2 MR | 8 | 14 | 10 | 6 | 16 | 19 |
| Sommer | ARP2 | 1 | 5 | 15 | 1 | 4 | 11 |
| | ARP2 EDK | 6 | 16 | 15 | 6 | 14 | 11 |
| | ARP2 MR | 6 | 15 | 15 | 5 | 12 | 13 |
| Saison | Version | Mean(wsi) | Var(wsi) | Skew(wsi) | Mean(wsa) | Var(wsa) | Skew(wsa) |
| Winter | ARP2 | 1 | 10 | 31 | 2 | 14 | 51 |
| | ARP2 EDK | 6 | 20 | 34 | 6 | 17 | 34 |
| | ARP2 MR | 6 | 21 | 33 | 6 | 18 | 37 |
| Sommer | ARP2 | 1 | 9 | 44 | 2 | 61 | 112 |
| | ARP2 EDK | 5 | 22 | 35 | 5 | 56 | 109 |
| | ARP2 MR | 4 | 19 | 36 | 5 | 54 | 103 |

Auch wenn festgestellt wurde, dass die Interpolation mit GWL ohne eine sehr aufwendig detaillierte Kalibrierung etwas schlechter funktioniert als ohne GWL, sind die Ergebnisse der Kreuzvalidierung immer noch zufriedenstellend.

In Tabelle 6-5 sind die statistischen Momente der Ergebnisse des Modells mit den Parametern aus dem betrachteten Interpolationsverfahren denen der originalen Modellergebnisse gegenübergestellt. Es wird hierbei die Version mit acht GWL verwendet. Es werden die beiden Versionen EDK (alle Parameter sind mit EDK interpoliert) und MR (alle Parameter sind mit MR interpoliert) dargestellt. Wie schon in der Kreuzvalidierung zeigt die MR die leicht besseren Ergebnisse.

Auf dieselbe Weise werden die Extremwerte betrachtet (siehe Tabelle 6-6). Dies wird beispielhaft an zwei repräsentativen Dauerstufen gezeigt. Hierbei werden die Kriterien aus Abschnitt 5.2.1.2 verwendet. Beim Vergleich der Extremwerte kann keine Methode klar präferiert werden.

Als Schlussfolgerung kann festgehalten werden, dass die Methode verwendet werden sollte, die mit dem geringsten Aufwand umsetzbar ist. Bei guter Datenlage der Zusatzvariablen ist dies vermutlich MR, ansonsten EDK. Beide Verfahren liefern gute Ergebnisse.

Tabelle 6-6 Kennwerte zum Vergleich der Extrema der Modellergebnisse mit den Modellparametern der Beobachtung und der Kreuzvalidierung (oben: 1-Stunden-Werte, unten 3-Stunden-Werte)

| Saison | Version | $\overline{D_{abs,n}}$ [mm/h] | $\overline{D_{sign,n}}$ [mm/h] | p-value ($n\omega^2$) | p-value (K-S-Test) |
|--------|----------|----------------------------------|-----------------------------------|----------------------------|-----------------------|
| Winter | ARP2 | 0,16 | -0,13 | 221 | 231 |
| | ARP2 EDK | 0,18 | -0,16 | 176 | 201 |
| | ARP2 MR | 0,16 | -0,14 | 203 | 225 |
| Sommer | ARP2 | 0,18 | -0,13 | 232 | 240 |
| | ARP2 EDK | 0,19 | -0,14 | 198 | 217 |
| | ARP2 MR | 0,19 | -0,14 | 202 | 207 |
| Saison | Version | $\overline{D_{abs,n}}$ [mm/h] | $\overline{D_{sign,n}}$ [mm/h] | p-value ($n\omega^2$) | p-value (K-S-Test) |
| Winter | ARP2 | 0,37 | 0,29 | 268 | 274 |
| | ARP2 EDK | 0,40 | 0,33 | 249 | 260 |
| | ARP2 MR | 0,39 | 0,32 | 236 | 243 |
| Sommer | ARP2 | 0,21 | 0,17 | 252 | 269 |
| | ARP2 EDK | 0,20 | 0,16 | 244 | 262 |
| | ARP2 MR | 0,21 | 0,17 | 246 | 253 |

7 Optimierung der räumlichen Konsistenz und GWL-Struktur

Die univariate Niederschlagsgenerierung erzeugt Daten unabhängig von anderen Stationen. Dies führt dazu, dass das zeitliche Verhalten der synthetischen Daten benachbarter Stationen völlig unterschiedlich ist. Beispielsweise kann an einer Station eine extrem feuchte Woche auftreten, während dieselbe Woche an einer wenige Kilometer entfernt liegenden Station komplett niederschlagsfrei generiert wird. Auch der Bezug zum zeitlichem Verlauf der GWL wird in der univariaten Generierung nicht korrekt erfasst, weil diese nur die relativen Häufigkeiten der GWL nachbildet. Das heißt, dass die Abfolge der GWL in den univariat generierten synthetischen Zeitreihen eine höchst unrealistische Struktur aufweist (siehe Abschnitt 7.3.1).

Diese beiden Kriterien (räumliche Konsistenz und zeitlicher GWL-Bezug) sind also in dieser Phase der Modellierung noch nicht korrekt wiedergegeben. Daher wird im zweiten Schritt der Modellierung ein stochastisches Optimierungsverfahren vorgestellt, das die generierten Zeitreihen entsprechend diesen Kriterien umstrukturiert.

7.1 Simulated Annealing Algorithmus

Das Prinzip des *Simulated Annealing* (SA) Algorithmus bildet den Abkühlungsprozess eines metallischen Körpers nach und wurde erstmalig von Metropolis et al. (1953) veröffentlicht. Während der langsamen Abkühlung eines Metalls ordnen sich die Moleküle und bilden stabile Kristalle. Hierbei wird ein energieärmer Zustand erreicht, in dem die Moleküle in einer Form hinsichtlich der Stabilität nahezu optimal angeordnet sind. Der SA-Algorithmus versucht für beliebige zu optimierende Strukturen (zum Beispiel das Problem des Handlungsreisenden), den Abkühlungsprozess nachahmend, das globale Optimum zu finden.

Der SA-Algorithmus wird anhand einer Zeitreihe erläutert, deren Zielfunktion durch Tauschen seiner Elemente optimiert wird (Abbildung 7-1).

Der Optimierungsprozess beginnt mit einer Startlösung, aus der durch das Tauschen zweier Elemente eine zufällige Nachbarlösung erzeugt wird. Wird hierdurch eine Verbesserung verursacht, wird der neue Zustand angenommen. Aber auch wenn die neue Lösung eine schlechtere darstellt, kann sie mit einer sich verändernden Wahrscheinlichkeit angenommen werden, welche mit der Anzahl der Wiederholungen abnimmt. Geregelt wird dies über die sogenannte Temperatur T :

$$P = \exp\left(\frac{Ob_{old} - Ob_{new}}{T}\right) \quad (7-1)$$

Ob_{old} - Zielfunktion vor Elemententausch

Ob_{new} - Zielfunktion nach Elemententausch

Dadurch, dass zu einem gewissen Grad Verschlechterungen zugelassen werden, und über die zu Beginn festgelegte Temperatur wird verhindert, dass der Optimierungsalgorithmus frühzeitig in einem lokalen Optimum steckenbleibt. Die Temperatur wird während des Optimierungsprozesses in regelmäßigen (ebenfalls vorab festzulegenden) Abständen gesenkt; sie darf jedoch nicht kleiner null werden. Die Form der Temperatursenkung ist variabel und, genau wie die Wahl der Anfangstemperatur, meist Teil der Kalibrierung. Mit abnehmenden Temperaturwerten sinkt auch die Wahrscheinlichkeit, dass eine Verschlechterung auftritt. So wird am Anfang versucht, in die Nähe des globalen Optimums zu gelangen und gegen Ende sich diesem weiter anzunähern.

Die Zielfunktion wird entsprechend dem Anwendungszweck definiert. Für unseren Fall wird dies später detailliert erläutert. Grundsätzlich bedeutet (bei der hier dargestellten Notation) eine Verringerung der Zielfunktion eine Verbesserung.

Die Optimierung wird in der Regel nach einer vorgeschriebenen Anzahl an Iterationen abgebrochen. Im Normalfall wird jedem Temperaturwechsel eine gleiche Anzahl an Iterationen zugewiesen, und die Anzahl der Temperaturwechsel wird beschränkt. Oft wird noch ein zusätzliches Kriterium für den Abbruch definiert; dies kann beispielsweise ein minimaler Zielfunktionswert sein. Wird dieser Wert unterschritten, wird der erreichte Zustand als optimierter Zustand betrachtet und der Optimierungsprozess abgebrochen. Ein Abbruch kommt auch dann infrage, falls sich der Systemzustand über viele Iterationsschritte nicht ändert.

Weiteres zum SA-Algorithmus, einschließlich seiner Herleitung und Randbedingungen für seine Anwendung, ist z. B. Reeves (1993) zu entnehmen.

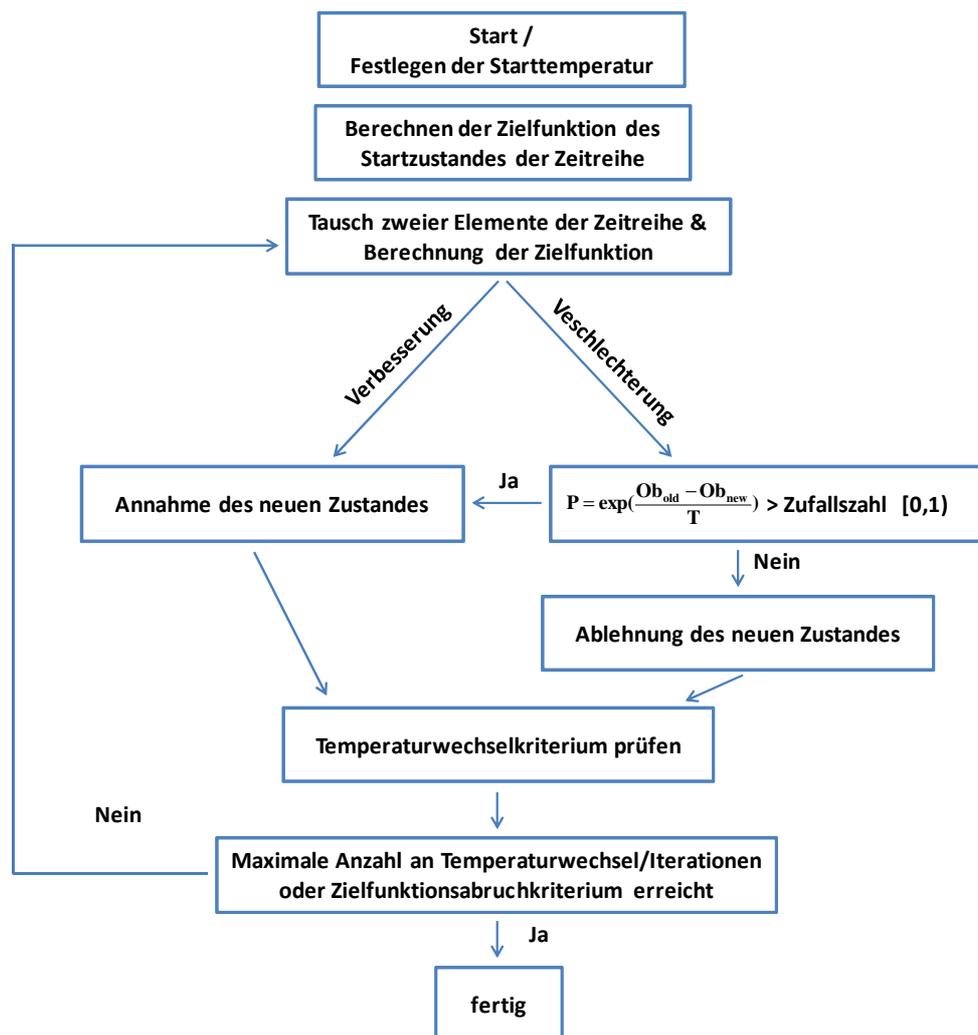


Abbildung 7-1 Fließschema des Simulating-Annealing-Algorithmus

7.2 Optimierung univariater Daten hinsichtlich der räumlichen Niederschlagsstrukturen

Dieser Abschnitt beschäftigt sich mit der Aufprägung der räumlichen Konsistenz in den synthetischen Niederschlagsdaten.

7.2.1 Methodik

Bei der Anwendung des SA wird der neue Systemzustand durch Tauschen zweier Ereignisse erstellt. Hierbei wird nicht das gesamte Ereignis getauscht, sondern nur Nassereignisse oder nur Trockenereignisse. Hierdurch soll eine höhere Variabilität erzielt werden. Da eine Unabhängigkeit der Nass- und Trockenereignisse vorausgesetzt wird (siehe Abschnitte 5.1.1 und 3.4) und selbige im Modell zufällig zu Gesamtereignissen zusammengeführt werden, ist dies unproblematisch. Abbildung 7-2 (links) zeigt den Tausch eines Nassereignisses und Abbildung 7-2 (rechts) den eines Trockenereignisses.

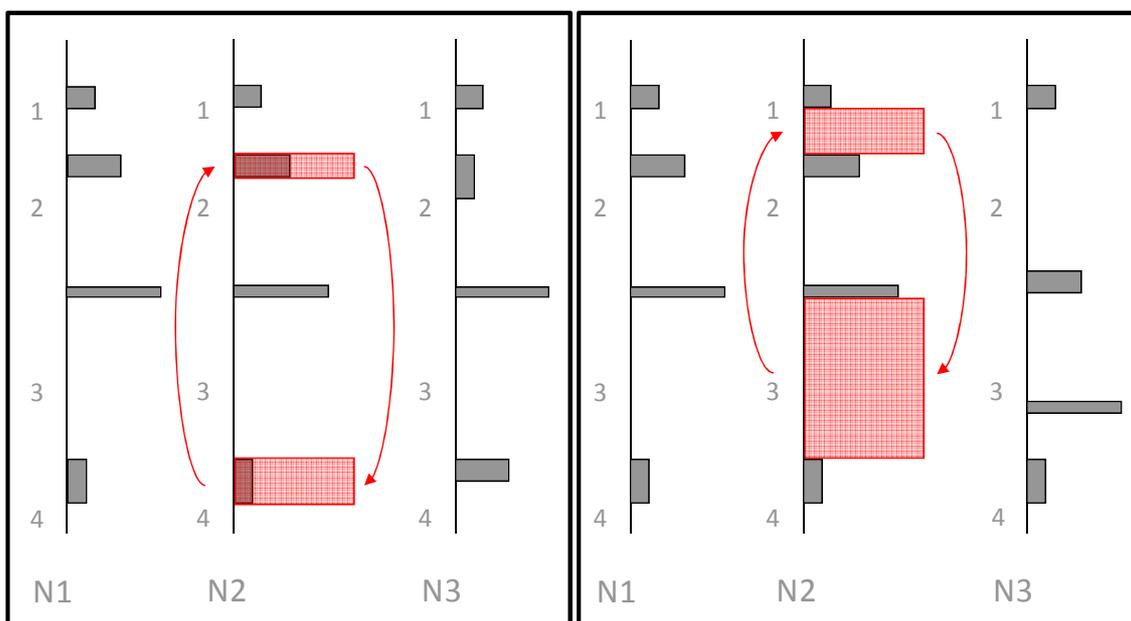


Abbildung 7-2 Tausch von Ereignissen bei Simulated Annealing

Die Zielfunktion (siehe unten) wird über den Vergleich von Zeitreihen gebildet. Bei der Optimierung nach Haberlandt et al. (2008) bleibt eine Zeitreihe unverändert. Bei insgesamt n zu optimierenden Stationen wird zuerst die zweite Station optimiert. Es werden also nur Ereignisse in der zweiten Station getauscht und die Zielfunktion aus der ersten und zweiten Station berechnet. Im nächsten Schritt wird die dritte Station optimiert und dabei mit der ersten und zweiten Station verglichen. Dies wird fortgeführt, bis zum Schluss die n -te Station optimiert und dabei mit der ersten bis $(n-1)$ -ten Station verglichen wird.

Hierbei wird darauf geachtet, dass nur innerhalb der Saisons getauscht wird, also nur Sommerereignisse mit Sommerereignissen und Winterereignisse mit Winterereignissen. Es muss darauf geachtet werden, dass, falls Ereignisse verschiedener Jahre getauscht werden, keine Verschiebung der Jahreszeiten auftritt. Das Problem entsteht, wenn (beispielsweise) ein Sommerereignis aus dem Jahr 1995 mit 3000 Minuten Dauer gegen ein Ereignis aus dem Jahr 1996 mit 60 Minuten Dauer getauscht wird. Als Resultat wäre der Sommer 1995 um 2940 Minuten zu kurz und bei einer Disaggregation der Ereigniszeitreihe würden 2940 Minuten des Winters in den Sommer übergehen. Dies kann sich akkumulieren, so dass als Resultat der saisonale Bezug der synthetischen Daten vollständig aufgelöst wird.

Zur Verhinderung dieser Saisonalitäts-Verschiebung wurden, für den Fall, dass die zu tauschenden Ereignisse nicht im selben Jahr liegen, folgende Bedingungen festgelegt:

1. Maximale Differenz zweier Trockenereignisse:
 - 120 bei $d_{sd} < 15000$ min
 - 360 bei $15000 \text{ min} < d_{sd} < 25000$ min
 - 720 bei $25000 \text{ min} < d_{sd}$
2. Maximale Differenz zweier Nassereignisse:
 - 60 bei $w_{sd} < 1500$ min
 - 120 bei $1500 \text{ min} < w_{sd} < 2500$ min
 - 180 bei $2500 \text{ min} < w_{sd}$
3. Insgesamt entstehende Abweichung über alle Jahre: 10800 min (ca. 1 Woche)

Falls eine der drei Bedingungen nicht erfüllt wird, wird ein neues Ereignis zum Tausch gezogen. Das andere Ereignis wird beibehalten. Dieses Vorgehen wird gewählt, um sicherzustellen, dass nicht ausschließlich kurze Ereignisse für den Tausch gewählt werden.

Mit den beschriebenen Bedingungen wurde die Rechenzeit nur geringfügig ($> 10\%$ der bisherigen) verlängert und die Güte des festgestellten Optimums sogar leicht erhöht.

Die Zielfunktion für die räumliche Konsistenz des ursprünglichen Modells (siehe Haberlandt et al. (2008)) wird aus mehreren Elementen gebildet. Das erste beschreibt die Gleichzeitigkeit des Niederschlagsvorkommens bei Stationen k und l zwischen ihren Niederschlagszeitreihen z :

$$P_{11} = P_{kl}(z_k > 0 | z_l > 0) \approx \frac{n_{11}}{n} \quad (7-2)$$

n_{11} - Anzahl an Intervallen mit gleichzeitigem Niederschlag

n - Anzahl aller Intervalle

Obwohl dieser Parameter wenig sensitiv reagiert (siehe Abbildung 7-3) hat es einen positiven Einfluss auf die Ergebnisse des SA, einen weiteren Parameter zur Gleichzeitigkeit zu verwenden, der sich auf die Trockenheit bezieht:

$$P_{00} = P_{kl}(z_k = 0 | z_l = 0) \approx \frac{n_{00}}{n} \quad (7-3)$$

n_{00} - Anzahl an Intervallen mit gleichzeitiger Trockenheit ($N = 0 \text{ mm}$)

n - Anzahl aller Intervalle

Ein weiterer Teil der Zielfunktion ist ein Maß für die *Kontinuität* nach Wilks (1998). Bei diesem Kennwert wird der Erwartungswert des Niederschlages an der Station k verglichen für den Fall von vorhandenem und nicht vorhandenem Niederschlag an Station l :

$$C_{kl} = \frac{E(z_k | z_k > 0, z_l = 0)}{E(z_k | z_k > 0, z_l > 0)} \quad (7-4)$$

Der Pearson'sche Korrelationskoeffizient der Stundenwertintervalle bildet das letzte Element der Zielfunktion zur räumlichen Konsistenz:

$$\rho_{kl} = \frac{\text{cov}(z_k, z_l)}{\sqrt{\text{var}(z_k) \cdot \text{var}(z_l)}}, \quad z_k > 0, z_l > 0 \quad (7-5)$$

Die verschiedenen Elemente der Zielfunktion werden mit Gewichtungsfaktoren ω_x miteinander kombiniert:

$$o_{fs} = \omega_1 (P_{11} - P_{11}^*)^2 + \omega_2 (P_{00} - P_{00}^*)^2 + \omega_3 (C_{kl} - C_{kl}^*)^2 + \omega_4 (\rho_{kl} - \rho_{kl}^*)^2 \quad (7-6)$$

Markierte Kennwerte (*) sind die Zielwerte der Zielfunktion, solche ohne die aktuellen Werte der zu optimierenden Zeitreihen

Die optimalen Gewichtungsfaktoren müssen mit einer Kalibrierung ermittelt werden, wobei idealerweise nicht nur das Resultat der Optimierung, sondern auch das Verhältnis der gewichteten Elemente zueinander über die Iteration berücksichtigt werden sollte. Dies ist deswegen notwendig, weil die verschiedenen Elemente unterschiedlich schnell konvergieren.

Die Zielwerte der Elemente der Zielfunktion y wurden mittels einer Regression der Entfernung (x) zwischen den in der Modellierung verwendeten hochaufgelösten Stationen festgelegt. Es wurden hierfür drei verschiedene Verfahren geprüft:

1. $y = a * x + b$ (linear) (7-7)
2. $y = a * x^b$ (Potenz)
3. $y = a * \ln x + b$ (logarithmisch)

Die Bestimmung erfolgte mittels des Bestimmtheitsmaßes und einer optischen Überprüfung (siehe Abbildung 7-3 und Tabelle 7-1). Zuzüglich wurden zur Bestätigung der Ergebnisse weitere Kriterien verwendet, z. B. maximale Abweichung zwischen Regression und Beobachtung, sodass nicht stets die Funktion mit dem besten Bestimmtheitsmaß favorisiert wurde. Die Residuen wurden nicht separat betrachtet, da diese in Abbildung 7-3 ausreichend gut erkennbar sind. Die sich als ideal ergebenden Regressionsverfahren sind in der Tabelle 7-1 fett gedruckt dargestellt.

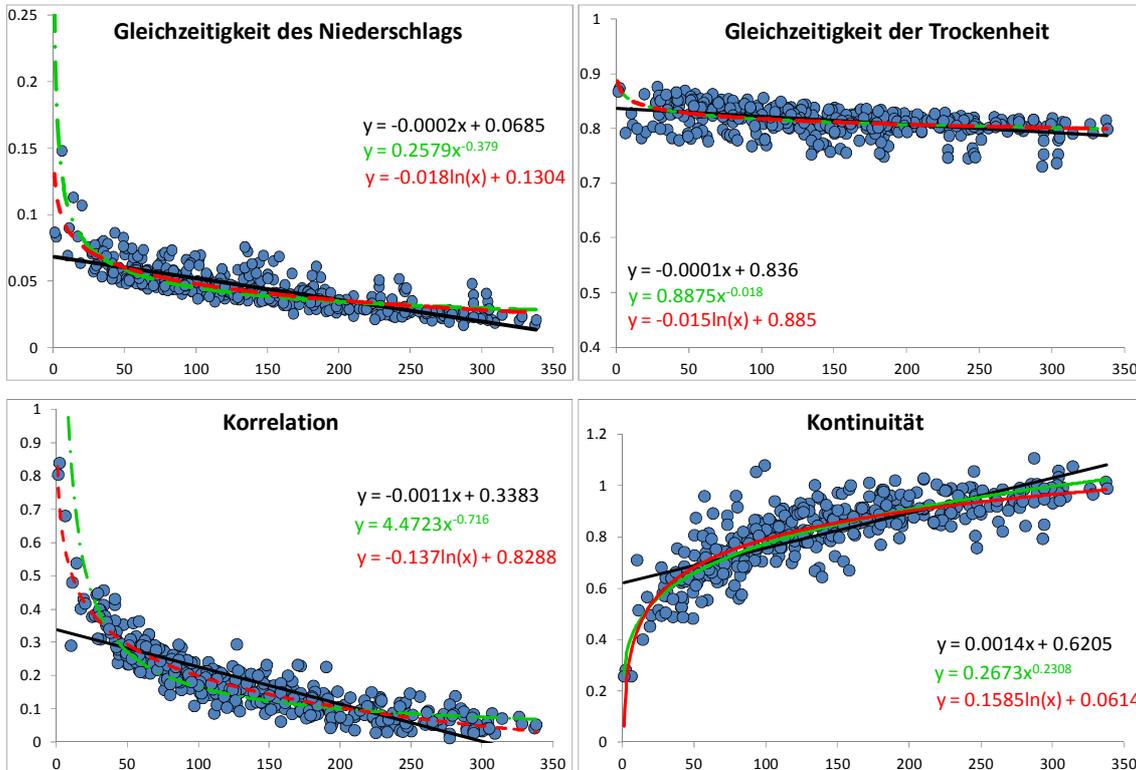


Abbildung 7-3 Regression der Zielfunktion; durchgezogene Linie: lineare Regression; unterbrochene Linie: Potenz-Regression; gestrichelte Linie: logarithmische Regression; die y-Achse gibt den einheitenlosen Wert der Eigenschaft an; die x-Achse ist der euklidische Abstand der verglichenen Stationen in km

Tabelle 7-1 Güte der verschiedenen Regressionsverfahren der Zielfunktion des Simulated Annealings

| Gleichzeitigkeit des Niederschlags | | Gleichzeitigkeit der Trockenheit | |
|---|------------------|---|------------------|
| Verfahren | Bestimmtheitsmaß | Verfahren | Bestimmtheitsmaß |
| linear | 0,6187 | linear | 0,2232 |
| Potenz | 0,6361 | Potenz | 0,1946 |
| logarithmisch | 0,6652 | logarithmisch | 0,2009 |
| Korrelation (Stundenwerte) | | Kontinuität | |
| Verfahren | Bestimmtheitsmaß | Verfahren | Bestimmtheitsmaß |
| linear | 0,6612 | linear | 0,6006 |
| Potenz | 0,6927 | Potenz | 0,7509 |
| logarithmisch | 0,8702 | logarithmisch | 0,7156 |

Anzumerken ist, dass bei der Gleichzeitigkeit der Trockenheit keines der Verfahren einen guten Wert für das Bestimmtheitsmaß liefern konnte. Aus der grafischen Darstellung ist allerdings zu erkennen, dass die Streuung für diesen Index sehr gering ist. Es stellt sich daher die Frage, ob der Anteil der durch die Regression erklärten Varianz (diese bildet das Bestimmtheitsmaß) hier ein sinnvoller Faktor zur Beurteilung ist. Der Index weist ein geringes Gefälle auf. Diese beiden Faktoren (geringe Streuung und leichtes Gefälle) lassen zwar die lineare Darstellung als ideal erscheinen; das Gefälle ist jedoch sehr gering, sodass bereits ein konstanter Wert zur Darstellung des Indexes genügen könnte. Der Parameter ist dennoch nicht überflüssig für die Optimierung, da diese an der synthetischen Zeitreihe vorgenommen wird.

Das dargestellte Modell hat allerdings eine Schwachstelle, die an dieser Stelle diskutiert wird. Das SA ist in der vorliegenden Implementierung recht rechenaufwendig. Die Ereignisse werden in der Ereigniszeitreihe getauscht, bevor sie zu Stundenwertzeitreihen disaggregiert werden, um die Kenngrößen zu berechnen. Das erhöht den Rechenaufwand unnötig. Sinnvoller wäre es, das SA-Verfahren an den Stundenwertzeitreihen durchzuführen; hierbei dürfen allerdings die Ereignisse nicht zerstört werden. Da daher weiterhin Ereignisse und nicht Stundenwerte getauscht werden sollen, wäre es eine Möglichkeit, programmiertechnisch mit *Objekten* und *Zeigern* zu arbeiten. Hierbei könnten einem Objekt die Ereignischarakteristika (Saisonalität, *GWL*, *wsd* und *wsi*, respektive *dsd*) und die zugehörige Stundenwertzeitreihe zugewiesen werden. Bei der Anwendung des SA müssten dann nur noch die Zeiger umgestellt werden, womit sich die Umwandlung der ganzen Zeitreihe erübrigt und damit viel Rechenaufwand eingespart wird. Speicherprobleme könnten gegebenenfalls durch eine Aufteilung und schrittweise Bearbeitung der Zeitreihe umgangen werden. Diese Aspekte sollten bei einer nächsten Revision des Programms berücksichtigt werden.

7.2.2 Ergebnisse

Die räumliche Konsistenz wird für Sets mit einer begrenzten Anzahl von Stationen erstellt. Dies ist zielführender als die Optimierung für alle Stationen im Einzugsgebiet, da die Laufzeit des Optimierungsprogramms mit der Anzahl der Stationen stark ansteigt. So benötigt die räumliche Optimierung von zehn Stationen fast zwanzigmal länger als die von zwei Stationen. Dies liegt vor allem an dem erhöhten Rechenaufwand der einzelnen Iterationsschritte (die aktuell bearbeitete Station wird mit jeder bereits bearbeiteten Station verglichen) und weniger an einer steigenden Anzahl an Iterationsschritten.

Bei steigender Anzahl von Stationen würden damit erheblich längere Wartezeiten entstehen. In unserer Analyse wurde das SA an 5 Sets durchgeführt (siehe Abbildung 7-4). Hierbei wurden für alle relevanten Regionen des Untersuchungsgebiets (1*Küste, 2*Binnenland, 1*Mittelgebirge) Sets aus 2 Stationen und ein Set aus 10 Stationen im Binnenland und Mittelgebirge verwendet. Eine Auflistung der Sets ist Tabelle 7-2 zu entnehmen. Der Grund für die Auswahl war, dass alle relevanten Regionen des Einzugsgebietes (siehe Abschnitt 3.3) untersucht werden sollten. Somit sollte sichergestellt werden, dass die Methode in allen Regionen funktioniert. Set 5 wurde verwendet, damit auch der Einfluss einer erhöhten Anzahl an Stationen untersucht werden konnte.

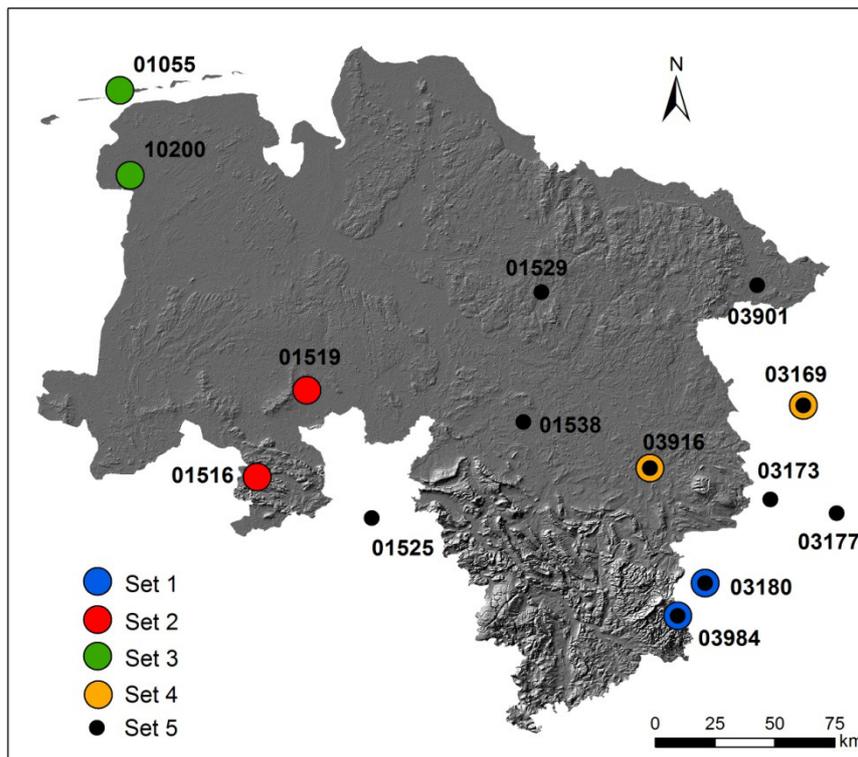


Abbildung 7-4 Sets für die räumliche Konsistenz

Tabelle 7-2 Zusammensetzung der Sets für das Simulated Annealing

| | Stationen in der Reihenfolge der Optimierung | | |
|-------|--|------------------------|----------------------|
| Set 1 | 1. Wernigerode (03180) | 2. Braunlage (03984) | |
| Set 2 | 1. Osnabrück (01516) | 2. Diepholz (01519) | |
| Set 3 | 1. Norderney (01055) | 2. Emden (10200) | |
| Set 4 | 1. Braunschweig (03916) | 2. Gardelegen (03169) | |
| Set 5 | 1. Braunschweig (03916) | 2. Gardelegen (03169) | 3. Ummendorf (03173) |
| | 4. Magdeburg (03177) | 5. Wernigerode (03180) | 6. Hannover (01538) |
| | 7. Soltau (01529) | 8. Luechow (03901) | 9. Braunlage (03984) |
| | 10. Bad Salzuflen (01525) | | |

In Tabelle 7-3 finden sich die Gewichtungen der Zielfunktionselemente. Es ist anzumerken, dass die Gewichtungen nicht direkt vergleichbar sind, da die Wertebereiche der Zielfunktionselemente stark voneinander abweichen.

Tabelle 7-3 Gewichtungen der Zielfunktionselemente ohne GWL

| | | | |
|------------------------------------|------|-------------|----|
| Gleichzeitigkeit des Niederschlags | 200 | Korrelation | 15 |
| Gleichzeitigkeit der Trockenheit | 2100 | Kontinuität | 20 |

Abbildung 7-5 zeigt den Verlauf der Zielfunktion und ihrer Elemente für die Optimierung der jeweils zweiten Station aller fünf Sets. Die Sets vier und fünf können hierbei zusammengefasst werden. Dies ist möglich, da Set 4 aus den beiden ersten Stationen des Sets 5 besteht. Die Optimierung des Sets 4 entspricht daher bis hin zu den verwendeten Zufallszahlen zu 100 % der Optimierung der ersten beiden Stationen des Sets 5.

In der Grafik ist deutlich zu erkennen, wie der Algorithmus zu Beginn der Optimierung teilweise deutliche Verschlechterungen der Zielfunktion zulässt, um nicht in einem lokalen Optimum hängen zu bleiben. Aus der Grafik ist ebenfalls erkennbar, wie sich der Verlauf für jede Optimierung etwas anders darstellt; zum Beispiel hat die Gleichzeitigkeit des Niederschlags bei den Sets 4 und 5 einen weit höheren Anteil an der Zielfunktion als beim Set 1, obwohl für beide dieselben Gewichtungen verwendet wurden. Der große Rechenaufwand erlaubt es nicht, die Gewichtungen für jede mögliche Kombination der 29 Stationen separat zu kalibrieren.

Einige allen Stationen gemeinsame Faktoren waren jedoch recht schnell feststellbar. Beispielsweise konvergieren die Korrelationen am schnellsten und benötigen daher keine so große Gewichtung. Demgegenüber konvergiert die Gleichzeitigkeit des Niederschlags am langsamsten und bekam daher die höchste Gewichtung, da sie ansonsten teilweise gar nicht konvergierte. Obwohl die Gleichzeitigkeit des Niederschlags somit das mit Abstand größte Element der Zielfunktion ist, konvergiert sie immer noch extrem langsam. In Abbildung 7-5 ist beim Set 3 zu erkennen, dass es teilweise größere Probleme bei der Konvergenz der Gleichzeitigkeit des Niederschlags gibt. Etwas besser sieht es bei der Gleichzeitigkeit der Trockenheit aus, die allerdings naturgemäß aufgrund der großen Anzahl an trockenen Intervallen im Laufe der Optimierung die geringste Veränderung erfährt. Obwohl die Kontinuität relativ schnell konvergiert, benötigte sie für eine vollständige Konvergenz eine relativ große Gewichtung.

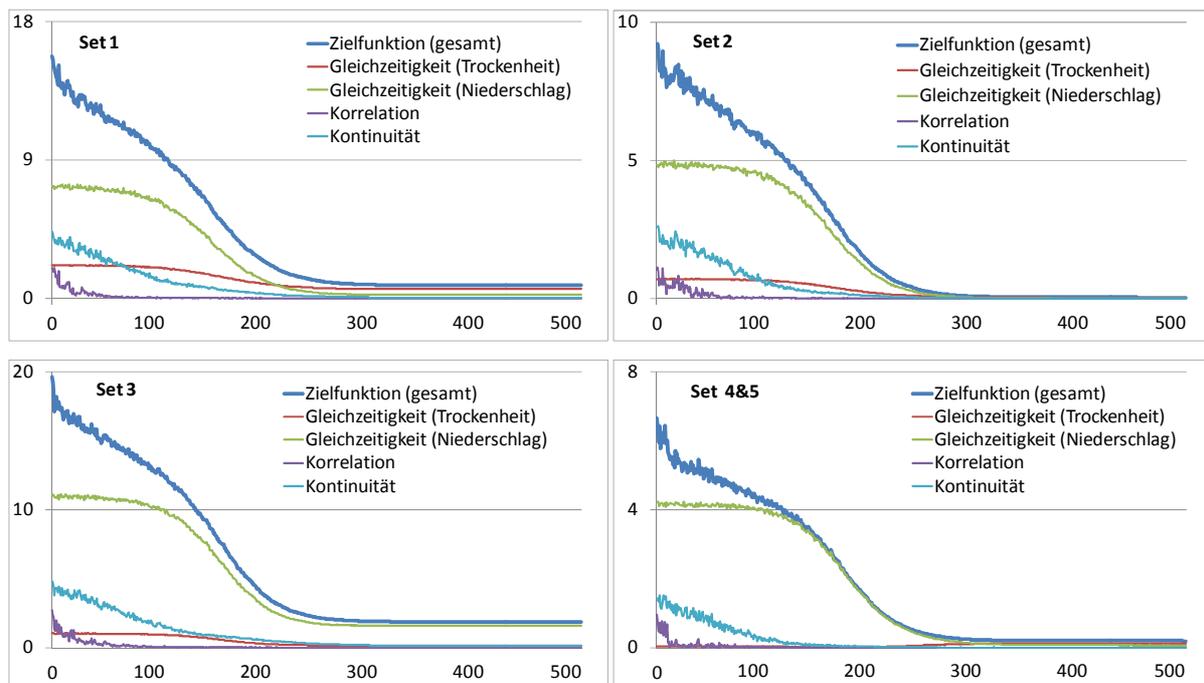


Abbildung 7-5 Zielfunktion der Optimierung ohne GWL (2 Stationen); die x-Achse gibt den Wert der Zielfunktion an und die y-Achse die Anzahl an Iterationsschritten in 100.000

Die Grafik zeigt, dass die gewählte Iterationsanzahl völlig ausreicht bzw. sogar deutlich höher ist als notwendig, da die Zielfunktion in der Regel bereits bei ca. 25 bis 30 Millionen Iterationsschritten konvergiert. Im Normalfall wird das SA abgebrochen, wenn sich über viele Iterationsschritte keine Änderungen ergeben. Dies wurde für diese Untersuchungen außer Kraft gesetzt.

Abbildung 7-6 zeigt die Werte der Zielfunktion für alle optimierten Stationen des Sets 5. Zu erkennen ist, dass alle Stationen nach ähnlich vielen Iterationsschritten konvergieren. Die unterschiedlichen Endwerte der Zielfunktion scheinen nicht von der Reihenfolge der Optimierung abzuhängen. So konvergieren die Stationen 3, 4, 5 und 9 eher schlecht, während die Stationen 8 und 10 einen sehr niedrigen Endwert aufweisen. Die schlechten Ergebnisse der Zielfunktionsendwerte scheinen von der Lage der Stationen abzuhängen. Die Stationen 5 und 9 sind die im Harz hoch gelegenen Stationen Wernigerode und Braunlage; die Stationen 3 und 4 sind die im Leebereich des Harzes gelegenen Stationen Ummendorf und Magdeburg. Die im niedersächsischen Binnenland gelegenen restlichen Stationen konvergieren unabhängig von der Reihenfolge der Optimierung deutlich besser.

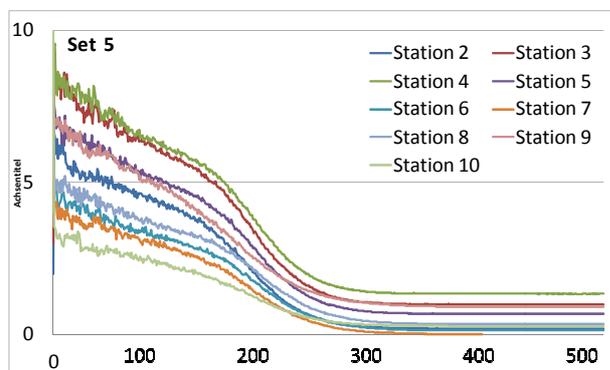


Abbildung 7-6 Zielfunktion der Optimierung ohne GWL (Set 5, alle Stationen); die y-Achse gibt den Wert der Zielfunktion an und die x-Achse die Anzahl an Iterationsschritten in 100.000

In Tabelle 7-4 und Tabelle 7-5 sind die ungewichteten Endwerte der Elemente der Zielfunktion dargestellt. Tabelle 7-4 zeigt die Ergebnisse der Sets 1-4 und Tabelle 7-5 einen Auszug des Sets 5. Der Auszug wurde so zusammengestellt, dass ein eventueller Zusammenhang zwischen der Anzahl der optimierten Stationen und der Optimierungsgüte erkannt werden kann. Hierbei muss man berücksichtigen, dass die n-te Station mit allen Stationen 1 bis (n-1) abgeglichen wird (hier n=10). Eine Verschlechterung der Gütekriterien zwischen der Station n zu den einzelnen Stationen ist daher das zu erwartende Resultat. Wenn man sich jedoch die Tabelle 7-5 ansieht, scheint dieser Effekt vernachlässigbar zu sein. Der Zusammenhang zwischen der Station 10 und den anderen Stationen scheint in ähnlich guter Form erstellt worden zu sein wie für die vorherigen Stationen.

Es muss aber auf die Station 9 (Braunlage, im Set 1 Station 2) hingewiesen werden, bei der die Gleichzeitigkeit des Niederschlages und der Trockenheit vermutlich aufgrund der überdurchschnittlich hohen Niederschlagswerte nur schwierig mit den anderen Stationen in Abhängigkeit zu bringen war. Die anderen Stationen, die beim Endwert der Zielfunktion unterdurchschnittliche Werte erzielten (3, 4 und 5), zeigen leicht schlechtere Ergebnisse als die übrigen; diese sind aber besser als bei der Station Braunlage.

Ähnliches ist auch bei den anderen Sets zu erkennen (Tabelle 7-4). Auch hier funktioniert die Optimierung der Binnenland-Sets 2 und 4 fast optimal, während das Harz-Set 1 und das Küsten-Set 3 leicht schlechtere Ergebnisse zeigen.

Tabelle 7-4 Zielfunktionselemente nach der der Optimierung ohne GWL (Set 1 bis 4)

| | Entfernung [km] | Gleichzeitigkeit (Niederschlag) | | Gleichzeitigkeit (Trockenheit) | | Korrelation (Stundenwerte) | | Kontinuität | |
|-------|--------------------|------------------------------------|------|-----------------------------------|------|-------------------------------|------|-------------|------|
| | | Beo | Sim | Beo | Sim | Beo | Sim | Beo | Sim |
| Set 1 | 18 | 0,08 | 0,07 | 0,83 | 0,78 | 0,39 | 0,36 | 0,52 | 0,56 |
| Set 2 | 42 | 0,06 | 0,06 | 0,83 | 0,82 | 0,32 | 0,28 | 0,63 | 0,63 |
| Set 3 | 10 | 0,09 | 0,06 | 0,84 | 0,81 | 0,41 | 0,39 | 0,46 | 0,55 |
| Set 4 | 69 | 0,05 | 0,05 | 0,83 | 0,86 | 0,27 | 0,27 | 0,71 | 0,71 |

Die grafische Darstellung der Korrelationskoeffizienten der Stundenwertzeitreihen des Sets 5 in Abhängigkeit von der Entfernung (siehe Abbildung 7-7, links) zeigt, dass auch der räumliche Aspekt der Korrelationen auf Stundenwertebene sehr gut wiedergegeben wird. Bei einander nahen Stationen tritt eine leichte Unterschätzung der Korrelation der Stundenwerte auf. Der Effekt ist vermutlich in der Regressionsfunktion der Zielfunktion begründet (siehe Abbildung 7-3). Eine ähnliche räumliche Abhängigkeit der Reproduktionsgüte wurde für die anderen Kennwerte nicht festgestellt.

Tabelle 7-5 Auszug der Zielfunktionselemente nach der Optimierung ohne GWL (Set 5, Nummerierung der Stationen entsprechend Tabelle 7-2)

| Miteinander verglichene Stationen | | Entfernung [km] | Gleichzeitigkeit (Niederschlag) | | Gleichzeitigkeit (Trockenheit) | | Korrelation (Stundenwerte) | | Kontinuität | |
|---|----|--------------------|------------------------------------|------|-----------------------------------|------|-------------------------------|------|-------------|------|
| | | | Beo | Sim | Beo | Sim | Beo | Sim | Beo | Sim |
| 1 | 2 | 69 | 0,05 | 0,05 | 0,83 | 0,86 | 0,27 | 0,27 | 0,71 | 0,71 |
| 1 | 6 | 56 | 0,06 | 0,05 | 0,83 | 0,84 | 0,29 | 0,26 | 0,68 | 0,67 |
| 1 | 10 | 118 | 0,05 | 0,05 | 0,82 | 0,81 | 0,16 | 0,18 | 0,80 | 0,80 |
| 2 | 3 | 42 | 0,06 | 0,04 | 0,83 | 0,86 | 0,32 | 0,28 | 0,63 | 0,63 |
| 2 | 4 | 28 | 0,06 | 0,04 | 0,83 | 0,86 | 0,39 | 0,33 | 0,65 | 0,65 |
| 3 | 6 | 108 | 0,05 | 0,04 | 0,83 | 0,84 | 0,17 | 0,19 | 0,79 | 0,79 |
| 5 | 6 | 102 | 0,05 | 0,04 | 0,83 | 0,84 | 0,17 | 0,19 | 0,78 | 0,79 |
| 5 | 9 | 18 | 0,08 | 0,07 | 0,83 | 0,78 | 0,40 | 0,36 | 0,52 | 0,57 |
| 6 | 10 | 75 | 0,05 | 0,05 | 0,83 | 0,81 | 0,25 | 0,23 | 0,72 | 0,71 |
| 8 | 9 | 143 | 0,04 | 0,05 | 0,82 | 0,76 | 0,19 | 0,15 | 0,84 | 0,84 |
| 9 | 10 | 134 | 0,04 | 0,05 | 0,82 | 0,73 | 0,20 | 0,10 | 0,83 | 0,83 |

Tabelle 7-6 und Tabelle 7-7 stellen die Korrelationen der Tageswertzeitreihen in der Beobachtung und den simulierten Daten einander gegenüber. Obwohl dieser Wert nicht in der Zielfunktion berücksichtigt wurde, wird er insgesamt gut wiedergegeben. Allerdings wird er meist leicht und in einigen Fällen sogar recht stark unterschätzt.

Die Korrelationen werden bei den sehr nahe zusammenliegenden Stationen der Sets 1 und 3 nahezu perfekt und bei den weit entfernt liegenden Stationen im Set 5 eher schlecht reproduziert. Dieser Eindruck eines räumlichen Zusammenhanges konnte jedoch durch die grafische Auswertung der Korrelationskoeffizienten des Sets 5 nicht bestätigt werden (siehe Abbildung 7-7, rechts). Hier ist zu sehen, dass die Korrelation der Tageswerte bei der Optimierung über alle Entfernungen hinweg systematisch etwas unterschätzt wird.

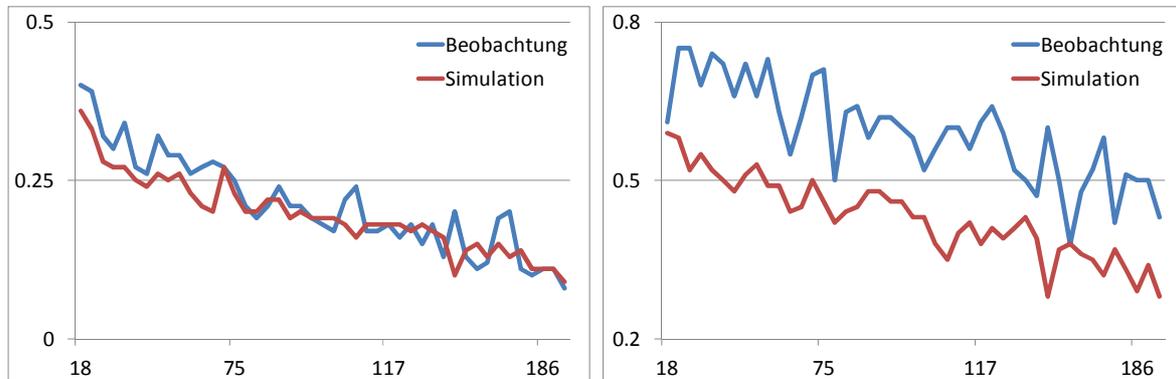


Abbildung 7-7 Funktion der Korrelation zwischen jeweils zwei Stationen für alle Stationen des Sets 5 der Optimierung ohne GWL; die y-Achse gibt den Pearson'schen Korrelationskoeffizienten an, die x-Achse die Entfernung in km; links: Stundenwertintervall, rechts: Tageswertintervall

Tabelle 7-6 Auszug der Korrelationen der Tageswertreihen nach der Optimierung ohne GWL (Set 1 bis 4)

| | Entfernung [km] | Korrelation (Tageswerte) | |
|-------|--------------------|--------------------------|------|
| | | Beo | Sim |
| Set 1 | 18 | 0,61 | 0,60 |
| Set 2 | 42 | 0,71 | 0,57 |
| Set 3 | 10 | 0,65 | 0,66 |
| Set 4 | 69 | 0,70 | 0,50 |

Tabelle 7-7 Korrelationen der Tageswertreihen nach der Optimierung ohne GWL (Set 5)

| Stationen entsprechend Optimierungsposition | | Entfernung [km] | Korrelation (Tageswerte) | |
|--|----|--------------------|--------------------------|------|
| | | | Beo | Sim |
| 1 | 2 | 69 | 0,70 | 0,50 |
| 1 | 6 | 56 | 0,73 | 0,49 |
| 3 | 6 | 108 | 0,60 | 0,40 |
| 5 | 6 | 102 | 0,52 | 0,43 |
| 1 | 10 | 118 | 0,64 | 0,41 |
| 3 | 10 | 166 | 0,51 | 0,33 |
| 6 | 10 | 75 | 0,71 | 0,47 |
| 9 | 10 | 134 | 0,61 | 0,28 |

In der Niederschlags-Abfluss-Modellierung ist oftmals neben der Gleichzeitigkeit und der Korrelation auch die Zugrichtung eines Niederschlagsereignisses von hoher Bedeutung. Um dies ansatzweise zu erfassen, wird in dieser Arbeit eine Kenngröße verwendet, die hier als *Lag-Kreuzkorrelation* bezeichnet wird. Hierbei wird die Korrelation zweier Stationen verglichen, wenn diesen ein zeitlicher Versatz (Lag) zueinander aufgeprägt wird. Das bedeutet, dass eine der beiden Stationen um x Stunden verschoben und anschließend die Korrelation der unverschobenen Zeitreihe zur verschobenen Zeitreihe ermittelt wird. In den Untersuchungen werden Lags von 1 bis 15 Stunden verglichen. Es wird ein Zeitreihenversatz in beide Richtungen betrachtet.

In Abbildung 7-8 sind beispielhaft die Lag-Kreuzkorrelationen der Stundenwerte von Simulation und Beobachtung für die Stationen des Sets 2 dargestellt. Es ist zu erkennen, dass auch die Lag-Kreuzkorrelationen mit den bekannten leichten Unterschätzungen der Korrelation wiedergegeben werden. Auffällig ist, dass bei den Stundenwertzeitreihen die Korrelation in den synthetischen Zeitreihen mit den Lags etwas weicher abfällt als in den beobachteten Daten. Die Zeitschritte x der Beobachtungszeitreihe der Station P01516 haben einen stärkeren Bezug zu den Zeitschritten $x-1$ der Station P01519 als zu den Zeitschritten $x+1$. Dies wird in der Synthese nicht korrekt reproduziert. Ähnliches ist auch bei den anderen Stationen zu beobachten. Um die Zugrichtung des Niederschlages zu erfassen, wäre also eine Anpassung der Zielfunktion notwendig.

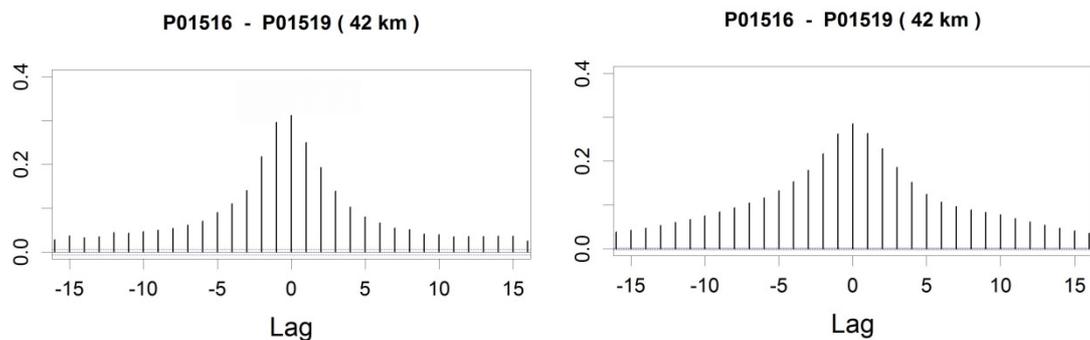


Abbildung 7-8 Lag-Kreuzkorrelationen der Stundenwerte der Beobachtung und der Synthese nach der Optimierung ohne GWL; links: Beobachtung, rechts: Simulation; die x-Achse gibt die Lags an und die y-Achse die Korrelationskoeffizienten

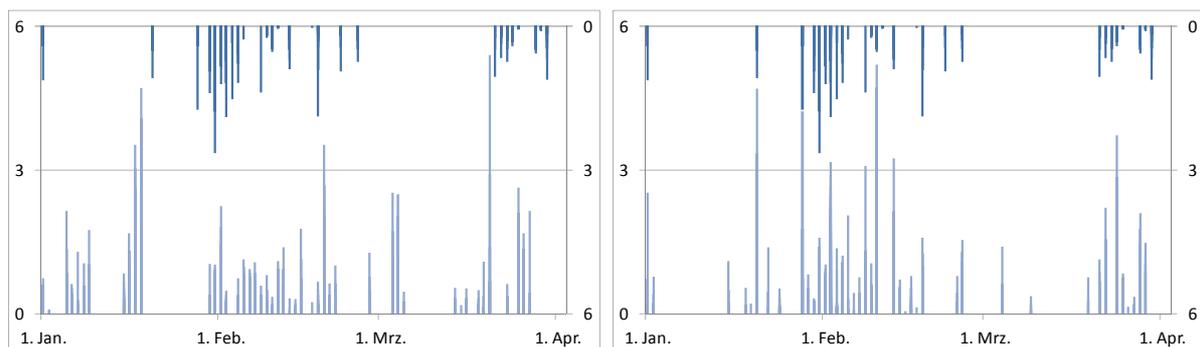


Abbildung 7-9 Zeitreihen der Stundenwerte des Sets 1 für drei Monate, links: direkte Ausgabedaten des univariaten N-Modells, rechts: Ausgabedaten der Optimierung; die x-Achse gibt die Zeit an, die y-Achse die Werte des Niederschlages in mm/h; die oberen Werte sind die der Station 03180, die unteren die der Station 03984

Im letzten Schritt der Auswertung wird der Effekt der Optimierung an den Stundenwert-Zeitreihen betrachtet. Dies wird hier mit einem Beispiel des Sets 1 diskutiert (siehe Abbildung 7-9). Es ist zu erkennen, dass die Station 1 (03180) bei der Optimierung nicht verändert wird. Aus der Gegenüberstellung der Zeitreihen vor der Optimierung wird erkennbar, dass die beiden Zeitreihen keinen direkten Zusammenhang haben.

Während an einer Station eine Trockenphase auftritt, finden an der anderen Station große Nassereignisse statt, und die großen Nassereignisse beider Stationen beginnen unabhängig voneinander. In der optimierten Zeitreihe kann hingegen erkannt werden, dass die Trockenphasen an beiden Stationen gleichzeitig auftreten und die Nassereignisse klare Gemeinsamkeiten aufweisen. Hierbei sollte berücksichtigt werden, dass die Station 03984 (Braunlage) deutlich nasser ist als die Station 03180 (Wernigerode).

7.3 Implementierung der GWL

Die Großwetterlagen wurden über Zielfunktionen implementiert. Da in der univariaten Generierung kein direkter Bezug zu der Zeitreihe der GWL berücksichtigt und die GWL-Abfolge in den Ereignissen nicht reproduziert wird (siehe auch Abschnitt 5.2.2), muss, anders als in früheren Modellversionen, eine univariate Optimierung der ersten Station durchgeführt werden.

7.3.1 Methodik

Die GWL werden also in zwei Schritten des SA berücksichtigt. Der erste Schritt ist die univariate Optimierung der Ausgangsstation. Das Vorgehen ist im Grunde dasselbe wie bei der multivariaten Optimierung. Ereignisse werden wie üblich getauscht und die Zielfunktion berechnet. Nur wird Letztgenannte im Falle der univariaten Optimierung nur anhand einer Station ermittelt.

Die Zielfunktion der univariaten Optimierung der ersten Station besteht aus zwei Elementen. Erstes Element ist die Konsistenz der GWL in den synthetischen Daten und der Zeitreihe der GWL:

$$o_{fs1} = 1 - \frac{n_{11}}{n_{tot}} \quad (7-8)$$

n_{11} – Anzahl an Intervallen (Stundenwerte), an denen bei den synthetischen und den beobachteten Niederschlagszeitreihen dieselbe GWL vorherrscht
 n_{tot} – Anzahl aller Intervalle

Das zweite Element der Zielfunktion ist die Abfolge-Frequenz der GWL in den Ereignissen. Hierbei mussten aufgrund der unterschiedlichen Ereignisanzahlen von Beobachtung und Synthese relative Häufigkeiten verwendet werden.

$$o_{fs2} = \frac{o_{freq}(Sommer) + o_{freq}(Winter)}{2} \quad (7-9)$$

$$o_{freq} = \frac{rs(ws) + rs(ds)}{2} \quad (7-10)$$

$$rs = \sqrt{\frac{1}{n_{GWL} * (n_{GWL} - 1)} \sum_{i=1}^{n_{GWL}} \sum_{j=1}^{n_{GWL}} \left(Freq_{rel, syn}(GWL_i, GWL_j) - Freq_{rel, obs}(GWL_i, GWL_j) \right)^2} \quad (7-11)$$

$$Freq_{rel}(GWL_i, GWL_j) = \frac{n_{ij}}{n} \quad (7-12)$$

mit x – Ereignistyp

ws – Nassereignis und ds – Trockenereignis

$Freq_{rel}(GWL_i, GWL_j)$ – relative Abfolgehäufigkeit der GWL i auf die GWL j

n_{ij} – Anzahl Ereignisse, bei denen GWL i auf GWL j folgt

n – Gesamtanzahl der Ereignisse

n_{GWL} – Anzahl an GWL

Trotz der kompliziert erscheinenden Formel-Darstellung, verursacht durch die Fülle der zu berücksichtigenden Randbedingungen, ist das Prinzip sehr einfach. Es wird untersucht, mit welchen Häufigkeiten auf eine bestimmte GWL eine andere bestimmte GWL folgt.

Auch für die erste Station wird die gesamte Zielfunktion mittels einer Gewichtung bestimmt:

$$o_{fs} = \omega_1 o_{fs1} + \omega_2 o_{fs2} \quad (7-13)$$

Die Gewichtungsfaktoren ω_x wurden mit Hilfe einer Kalibrierung bestimmt.

Für die zweite bis n-te Station wird ein weiteres Element zur bisherigen Zielfunktion (siehe Formel (7-6)) hinzugefügt. Dieses Element ist die Gleichzeitigkeit der GWL in den Ereignissen der verglichenen Stationen.

$$o_{GWL}(k,l) = 1 - \frac{n_1(k,l)}{n_{tot}(k,l)} \quad (7-14)$$

$n_1(k,l)$ – Anzahl der Intervalle mit gleicher GWL in Station k und l

$n_{tot}(k,l)$ – Anzahl aller Intervalle

Es ergibt sich eine neue gesamte Zielfunktion:

$$o_{fs} = \omega_1 (P_{11} - P_{11}^*)^2 + \omega_2 (P_{00} - P_{00}^*)^2 + \omega_3 (C_{kl} - C_{kl}^*)^2 + \omega_4 (\rho_{kl} - \rho_{kl}^*)^2 + \omega_5 \sum_{k=1}^{l-1} o_{GWL}(k,l) \quad (7-15)$$

Kennwerte mit Sternchen () sind die Zielwerte der Zielfunktion, solche ohne die aktuellen Werte der zu optimierenden Zeitreihen*

7.3.2 Ergebnisse

Im ersten Schritt der Untersuchung wurde geprüft, ob die Implementierung der GWL die Optimierungsergebnisse der räumlichen Konsistenz beeinflusst hat. Zu erwarten war ein geringer Einfluss, weil die Optimierungsergebnisse als sehr gut eingestuft wurden. In der Tabelle 7-8 sind die Ergebnisse der Sets 2 und 3 dargestellt. Die Auswahl wurde so getroffen, dass ein ohne GWL sehr gut (Set 2) und ein weniger gut (Set 3) optimiertes Set diskutiert werden können. Zu sehen ist, dass die Implementierung der GWL kaum Einfluss auf die räumliche Konsistenz hatte.

Tabelle 7-8 Zielfunktionselemente nach der Optimierung mit und ohne GWL (Set 2 und 3)

| | | Gleichzeitigkeit (Niederschlag) | | Gleichzeitigkeit (Trockenheit) | | Korrelation (Stundenwerte) | | Kontinuität | |
|-------|-------|---------------------------------|---------|--------------------------------|-------------|----------------------------|---------|-------------|-------------|
| | | Ohne GWL | Mit GWL | Ohne GWL | Mit GWL | Ohne GWL | Mit GWL | Ohne GWL | Mit GWL |
| Set 2 | 0 GWL | 0,06 | | 0,82 | | 0,30 | | 0,63 | |
| | 8 GWL | 0,06 | 0,06 | 0,81 | 0,81 | 0,30 | 0,30 | 0,63 | 0,64 |
| | 4 GWL | 0,06 | 0,06 | 0,82 | 0,81 | 0,30 | 0,30 | 0,64 | 0,63 |
| | 2 GWL | 0,06 | 0,06 | 0,81 | 0,82 | 0,30 | 0,30 | 0,63 | 0,63 |
| Set 3 | 0 GWL | 0,06 | | 0,81 | | 0,40 | | 0,55 | |
| | 8 GWL | 0,06 | 0,06 | 0,81 | 0,81 | 0,40 | 0,40 | 0,55 | 0,57 |
| | 4 GWL | 0,06 | 0,06 | 0,81 | 0,81 | 0,40 | 0,40 | 0,55 | 0,56 |
| | 2 GWL | 0,06 | 0,06 | 0,81 | 0,81 | 0,40 | 0,40 | 0,55 | 0,55 |

Im zweiten Schritt wurde untersucht, inwiefern die Berücksichtigung der GWL einen Einfluss auf die Konvergenz der Optimierung hat. Abbildung 7-10 zeigt hier, dass die Konvergenzzeit und das Endresultat der Zielfunktion praktisch nicht beeinflusst werden.

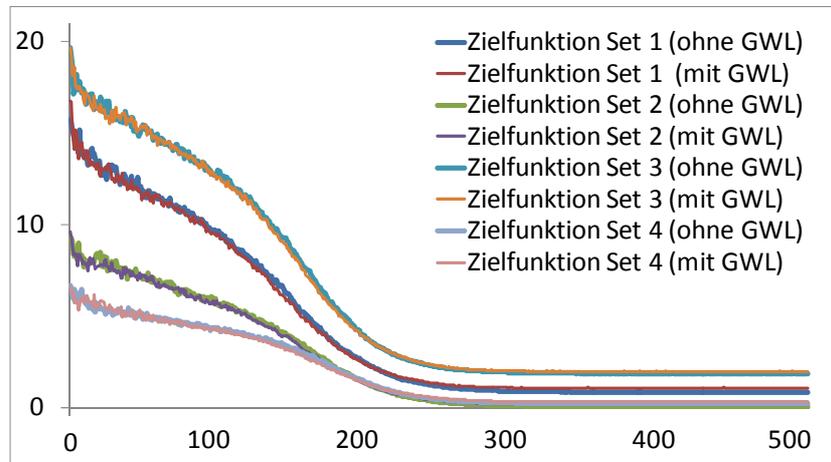


Abbildung 7-10 Zielfunktion der Optimierung mit und ohne GWL; es werden die Summen der Zielfunktionselemente aus (7-6) einander gegenübergestellt; die y-Achse gibt den Wert der Zielfunktion an und die x-Achse die Anzahl an Iterationsschritte in 100.000

Weiterhin von Relevanz ist der Einfluss der GWL auf die Korrelation in Abhängigkeit von der Entfernung. Hierzu wurden wieder die Korrelationen der Stundenwert- und Tageswertzeitreihen des Sets 5 betrachtet. Abbildung 7-11 zeigt die Korrelationen aller Stationen des Sets zueinander in Abhängigkeit von der Distanz der Stationen voneinander. Es ist leicht erkennbar, dass die Berücksichtigung der GWL hier kaum Einfluss auf die Korrelation hat. Lediglich die Version mit vier GWL zeigt merkbar niedrigere Korrelationen für die Tageswerte. Ein Einfluss der GWL auf die Lag-Kreuzkorrelationen konnte beim direkten Vergleich nicht festgestellt werden; siehe hierzu auch Abschnitt 7.2.2.

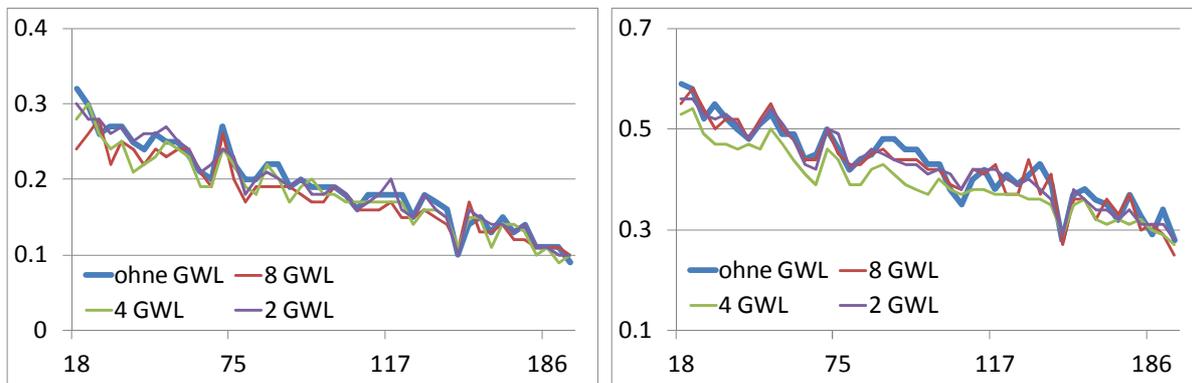


Abbildung 7-11 Korrelation zwischen jeweils zwei Stationen für alle Stationen des Sets 5 der Optimierung mit und ohne GWL; die y-Achse gibt den Pearson'schen Korrelationskoeffizienten an, die x-Achse die Entfernung in km; links: Stundenwertintervall, rechts: Tageswertintervall

Nachdem festgestellt wurde, dass GWL keinen negativen Einfluss auf die Wiedergabe der räumlichen Konsistenz haben, kann nun die Relevanz der GWL in der Optimierung untersucht werden. Das Ergebnis ist nicht überraschend. Obwohl die Berücksichtigung der GWL einen positiven Effekt auf die räumliche Konsistenz in den univariat generierten Daten aufweist (siehe Abschnitt 8.4), verkompliziert sie auch die Zielfunktion. Hierdurch ist wiederum eine Verschlechterung der Optimierungsleistung zu erwarten. Anscheinend heben die beiden Effekte einander auf.

Hierbei ist zu beachten, dass erstmalig eine univariate Optimierung der ersten Station vorgenommen wird. Da univariat kein Zeitreihenbezug erstellt wird und ebenfalls die Abfolgen der GWL nicht mehr stimmen, ist eine Optimierung auch dann nötig, wenn nur eine Station verwendet werden soll. Abbildung 7-12 zeigt das Verhalten der Zielfunktion von fünf zufällig ausgewählten Stationen (*Set GWL-Gleichzeitigkeit*) im Untersuchungsgebiet (01055, 01134, 01516, 03400 und 03984) für die Versionen mit acht und zwei GWL. Die Version mit vier GWL wurde nicht gezeigt, da sie das gleiche Verhalten wie die Version mit acht GWL aufweist.

Zu erkennen ist, dass für die Versionen mit acht GWL bei allen Stationen ein nahezu identischer Verlauf der Zielfunktionen zu beobachten ist. Bei der Version mit zwei GWL hingegen konnte für die Station Braunlage (03984) beobachtet werden, dass die GWL-Frequenz eine deutlich höhere Abweichung von der Beobachtung aufweist, als dies bei den anderen Stationen der Fall ist. Ansonsten verhalten sich die Zielfunktionen der anderen Stationen auch in etwa gleichartig.

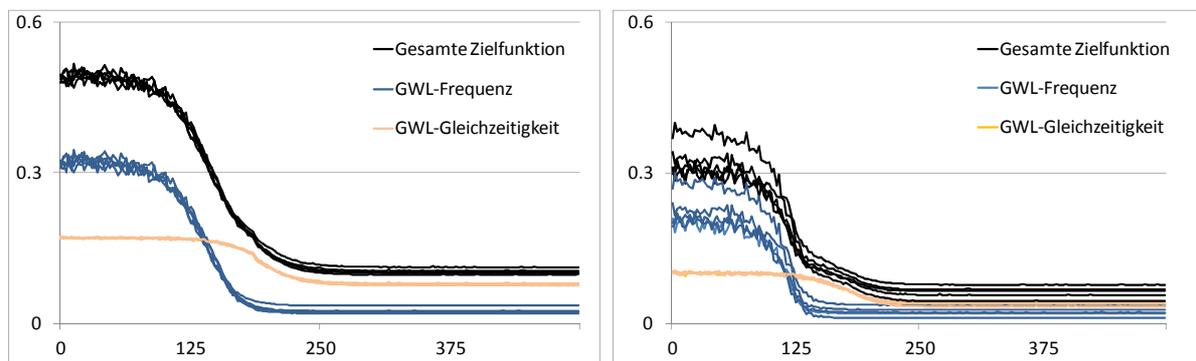


Abbildung 7-12 Univariate Zielfunktion von fünf Stationen im Untersuchungsgebiet; links: Version mit acht GWL, rechts: Version mit zwei GWL; die y-Achse gibt den Wert der Zielfunktion an und die x-Achse die Anzahl an Iterationsschritten in 100.000

Bei der Betrachtung von Abbildung 7-12 fällt auf, dass die Zielfunktion der GWL-Gleichzeitigkeit für die Version mit acht GWL gegen einen etwas erhöhten Wert konvergiert. Dies kann mit Tabelle 7-9 erläutert werden. In dieser Tabelle sind die beobachteten Werte der GWL-Gleichzeitigkeit aufgelistet. Es ist klar zu erkennen, dass die GWL-Gleichzeitigkeit in den Ereignissen mit zunehmender GWL-Anzahl abnimmt. Dies ist dadurch zu erklären, dass das Zusammenfassen mehrerer GWL während der Dauer eines Ereignisses zu einem teilweise recht hohen Informationsverlust führen kann. Besonders während einer langen Trockendauer kann eine ganze Bandbreite aus trockenen, aber auch feuchten, GWL auftreten. Kategorisiert wird das Trockenereignis allerdings nur über die während der Trockendauer am häufigsten vorherrschenden GWL. Wenn anschließend die Gleichzeitigkeit der GWL in den Ereignisreihen und den Tageswerten ermittelt wird, ergeben sich dann die hier dargestellten Werte. Das Phänomen ist detailliert in Abschnitt 5.2.2 diskutiert.

Tabelle 7-9 Mittlere GWL-Gleichzeitigkeit [%] in den Ereignissen der Stationen des Sets GWL-Gleichzeitigkeit

| Version | 8 GWL | 4 GWL | 2 GWL |
|---------------------|-------|-------|-------|
| Beobachtung | 62 | 69 | 83 |
| Univariat optimiert | 61 | 75 | 91 |
| Abhängig optimiert | 52 | 70 | 81 |

Der Tabelle 7-9 sind mehrere interessante Fakten zu entnehmen. Erstens der bereits erwähnte Informationsverlust. Dieser variiert je nach Version zwischen 40 und 10 Prozent. Weiter ist zu sehen, dass für die Ereignisse nach der univariaten Optimierung die GWL-Gleichzeitigkeit teilweise höher ist als für die Beobachtung. Dies gilt allerdings nicht für die Version mit acht GWL. Es wäre also zu überlegen, Grenzwerte einzuführen. Bisher wurde auf Grenzwerte verzichtet, da kein Nachteil in einer überhöhten GWL-Gleichzeitigkeit festgestellt wurde. Der dritte interessante Punkt in der Tabelle ist, dass die Gleichzeitigkeit bei den abhängig optimierten Reihen niedriger ist als bei den univariat optimierten. „Abhängig optimiert“ bezeichnet hierbei die Stationen 2 bis n der Optimierung, bei denen als einziges GWL-bezogenes Kriterium die Gleichzeitigkeit der GWL zwischen den synthetisch generierten Stundenwerten berücksichtigt wird.

Eine weitere Erkenntnis der Untersuchung war, dass die GWL-Gleichzeitigkeit nur eine sehr geringe Variation aufweist. Dies gilt sowohl für die Beobachtung als auch für die Synthese. Weiterhin wurde festgestellt, dass die GWL-Gleichzeitigkeit bei regenreichen Stationen tendenziell etwas höher war. Dies liegt vermutlich daran, dass bei diesen die Trockenereignisse im Allgemeinen kürzer sind. Bei kürzeren Ereignissen werden meist weniger GWL zusammengefasst, daher ist der Informationsverlust geringer.

Das zweite Element der Validierung betrifft die Abweichung der Frequenzen der GWL in den Ereignissen (RMSD, siehe Formel (7-16)). Die in Tabelle 7-10 dargestellten Ergebnisse zeigen, dass diese bei den univariat optimierten Reihen mit der Anzahl der berücksichtigten GWL zunehmen. Allerdings liegen auch für die Version mit acht GWL die festgestellten Werte noch in einem sehr niedrigen Wertebereich. Die gezeigten Werte sind das Mittel der Sommer- und Winterwerte.

$$RMSD = \sqrt{\frac{\sum_{i=1}^{n_{GWL}} \sum_{j=1}^{n_{GWL}} \left(\frac{H_{syn}(i,j) - H_{obs}(i,j)}{H_{obs}(i,j)} \right)^2}{n_{GWL}^2}} \quad (7-16)$$

n_{GWL} -Anzahl an GWL

$H_{syn/obs}(i,j)$ -relative Häufigkeit, dass auf GWL i GWL j folgt (Synthese und Beobachtung)

Die Abweichungen sind bei den abhängig optimierten Stationen, wie erwartet, deutlich höher. Allerdings sind die Werte in einem tolerablen Rahmen. Zur weiteren Verbesserung wäre es möglich, die Fehlerquadrate als Element der Zielfunktion für die Stationen 2 bis n zu übernehmen. Allerdings ist dies momentan rechentechnisch nicht sinnvoll, da die Rechenzeit bereits sehr hoch ist. Dies ist aber erneut zu prüfen, falls das Programmsystem, wie in Abschnitt 7.2.1 beschrieben, umstrukturiert wird. Auch bei dieser Kenngröße variieren die Werte bei unterschiedlichen Stationen wenig.

Tabelle 7-10 Mittelwert der RMSD der GWL-Frequenz nach der univariaten Optimierung der Stationen des Sets GWL-Gleichzeitigkeit

| | | 2 GWL | 4 GWL | 8 GWL |
|-------------------|---------------------|-------|-------|-------|
| Nassereignisse | Univariat optimiert | 0,002 | 0,004 | 0,008 |
| | Abhängig optimiert | 0,047 | 0,074 | 0,051 |
| Trockenereignisse | Univariat optimiert | 0,003 | 0,007 | 0,013 |
| | Abhängig optimiert | 0,048 | 0,066 | 0,045 |

8 Einfluss der GWL auf weitere Modellierungskennwerte

In diesem Abschnitt werden die Niederschlagsdaten der Beobachtung (bzw. der REMO-Daten) mit den Niederschlagsdaten der Synthese in den folgenden drei Konstellationen verglichen:

- Modellierung ohne GWL
- Modellierung mit GWL aus NCAR (Beobachtung) im Zeitraum 1996 bis 2008
- Modellierung mit GWL aus REMO (als Vorbereitung des Downscalings) im Zeitraum 1971 bis 2000 sowie 2071 bis 2100 (dies entspricht dem Zeitraum des Downscalings)

Bei allen drei Untersuchungen dieses Abschnittes wurden ausschließlich univariat generierte Daten verwendet. Das bedeutet, dass Niederschlagsdaten univariat generiert werden und anschließend nur die Optimierung der ersten Station vorgenommen wird, bei der nur die Gleichzeitigkeit der GWL von Beobachtung und Synthese und die GWL-Frequenz in den Ereignissen berücksichtigt werden (siehe Abschnitt 7.3.1).

8.1 Klimavariablen

Zur Ermittlung des Zusammenhanges von Niederschlag und weiteren Klimavariablen wurde zuerst die Korrelation von Klimadaten und Niederschlagsdaten analysiert. Verwendet wurden Daten der Temperatur und der Sonnenscheindauer, welche für REMO durch Daten der Globalstrahlung ersetzt wurden. Bei den Analysen wurden für die Temperatur auch die Differenzen der Temperaturintervalle, also die Erwärmung bzw. Abkühlung, herangezogen. Die verwendeten Intervalllängen sind Stunden- und Tageswerte. Weiterhin wurden diverse Schwellenwerte verwendet.

Ziel der Untersuchung ist es herauszufinden, welchen Zusammenhang beobachtete Niederschlagsdaten zu anderen beobachteten Klimadaten haben und ob GWL dazu dienen können, diesen Zusammenhang zwischen synthetischen Niederschlagsdaten und den beobachteten Klimadaten zu reproduzieren.

Die Beobachtungsdaten weisen kaum nachweisbare Korrelationen zwischen Niederschlag und weiteren Klimavariablen auf. Lediglich die Kenngrößen „Niederschläge größer 1 mm/h mit stündlichen Temperaturmitteln“ und „tägliche Sonnenscheindauern mit Niederschlägen“ zeigen eine deutlich nachweisbare Korrelation. Die Tabelle 8-1 zeigt dies anhand der Version mit zwei GWL im Mittel über alle Stationen. Die Unterschiede der Modellierung mit unterschiedlicher GWL-Anzahl sind vernachlässigbar.

Tabelle 8-1 kann man entnehmen, dass für die Temperaturdaten die GWL keinen nennenswerten Vorteil bringen. Die beobachteten Korrelationen in der Synthese sind anscheinend zufällig, da auch die Daten der Modellierung ohne Verwendung von GWL eine recht hohe Korrelation aufweisen. Vermutlich liegt dies an der zu stark verkleinerten Stichprobengröße.

Anders sieht es für die Sonnenscheindauer aus. Für diese Kenngröße gibt es deutlich nachweisbare negative Korrelationen zu den Niederschlagsdaten. In der Modellierung ohne GWL gibt es keinerlei nachweisbare Korrelation. In der Synthese mit Bedingung an GWL sind die Korrelationen hingegen deutlich erkennbar, auch wenn sie die Korrelation der Beobachtung unterschätzen.

Mithilfe der Tabelle 8-1 kann weiterhin die Korrelation, die in der Beobachtung vorherrscht, mit der Korrelation der REMO-Daten verglichen werden. Allerdings sind die deutlichen Korrelationen zwischen Sonnenscheindauer und Niederschlag der Beobachtung in den REMO-Daten kaum nachweisbar. Zur Erinnerung: Dies ist die einzige Kenngröße, die für die Beobachtung relevante Korrelationen zeigt, welche sicher nicht auf einer zu geringen Stichprobengröße beruhen.

Es muss aber erneut darauf hingewiesen werden, dass bei REMO nicht die Sonnenscheindauer, sondern die Globalstrahlung verwendet wurde. Die nicht vorhandene Korrelation kann eventuell hierauf zurückzuführen sein.

Tabelle 8-1 Korrelation zwischen Niederschlags- und Klimadaten

| Stündliche Temperaturmittel [°C] zu stündlichen Niederschlagssummen [mm] größer 1 mm | | |
|--|------------------------------------|-------------------------------------|
| | Pearson Korrelationskoeffizient | Spearman Korrelationskoeffizient |
| Beobachtung | 0,28 | 0,26 |
| Synthese ohne GWL | 0,15 | 0,15 |
| Synthese mit 2 GWL | 0,15 | 0,15 |
| REMO C20 | 0,17 | 0,19 |
| REMO A1b | 0,17 | 0,19 |
| Tägliche Sonnenscheinstunden [h] zu täglichen Niederschlagssummen [mm] | | |
| | Pearson Korrelationskoeffizient | Spearman Korrelationskoeffizient |
| Beobachtung | -0,26 | -0,43 |
| Synthese ohne GWL | 0,02 | -0,01 |
| Synthese mit 2 GWL | -0,06 | -0,12 |
| REMO C20 | 0,00 | -0,05 |
| REMO A1b | -0,02 | -0,07 |

Eine weitere betrachtete Kenngröße ist das Temperaturmittel der GWL. Verwendet wurden hierbei die GWL-Zeitreihen, die aus der Zusammenfassung der GWL aus der Ereignisdefinition entstanden sind (siehe Abschnitt 4.2). Bei der Betrachtung erfolgte eine Unterscheidung zwischen Sommer- und Winterhalbjahren. In der Darstellung werden die Abweichungen der mittleren Temperaturen der GWL zur mittleren Temperatur der gesamten Saison gezeigt. Abbildung 8-1 zeigt dies für die Versionen mit zwei, vier und acht GWL. Besonders in der Version mit zwei GWL ist ein klarer Zusammenhang zwischen GWL und Temperaturmittel am deutlichsten zu erkennen. Aber auch für die Versionen mit vier und acht GWL ist dies noch stark erkennbar. Dieser Effekt wird durch die Synthese mit GWL gut reproduziert, wobei es einige Schwächen bei der Version mit acht GWL gibt.

Über diesen Weg konnte also ein deutlicher Zusammenhang zwischen den im Abschnitt 4.2 und 5.2.2.1 festgestellten unterschiedlichen Niederschlagscharakteristika der GWL und der Temperatur nachgewiesen werden. Ebenfalls konnte gezeigt werden, dass die Synthese diesen Zusammenhang sehr gut reproduziert. Da in der Niederschlags-Abfluss-Modellierung sowohl Niederschlags- als auch Klimadaten von Bedeutung sind, ist dies eine wichtige Erkenntnis.

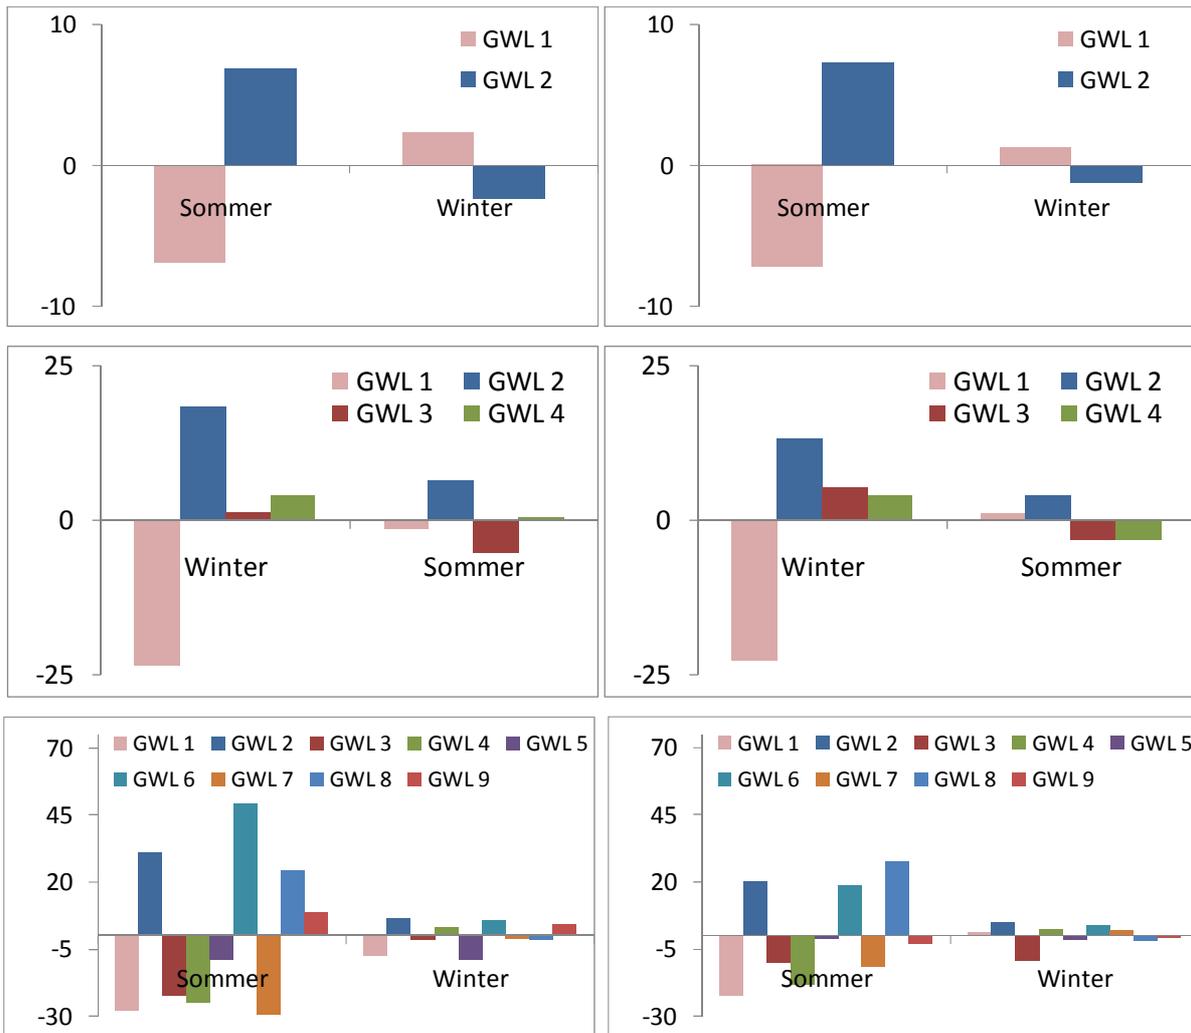


Abbildung 8-1 Abweichung [%] der Temperaturen der GWL von der mittleren Temperatur aller GWL mit zwei (oben), vier (Mitte) und acht GWL (unten; GWL 9: keine GWL kann zugewiesen werden), links: Beobachtung, rechts: Synthese nach dem Simulated Annealing

Selbstverständlich ist es ebenfalls von Interesse, ob dieser Effekt auch in den Daten der Klimamodelle vorhanden ist. In Abbildung 8-2 werden für die Version mit zwei und acht GWL die mittleren Temperaturdifferenzen der Beobachtung denen von REMO gegenübergestellt. Man kann erkennen, dass der Effekt gut zu beobachten ist. Für die Versionen mit vier GWL (hier nicht dargestellt) ist er vergleichbar vorhanden. In der Version mit acht GWL gab es allerdings erkennbare Unterschiede der Temperaturdifferenzen der sehr seltenen GWL 3.

Beim Vergleich der Situation der Vergangenheit (1971-2000) mit der zukünftigen Situation (2071-2100) ergab sich, dass sich der Effekt etwas abschwächt, aber weiter bestehen bleibt (siehe Abbildung 8-3). Die Version mit vier und acht GWL zeigen vergleichbare Ergebnisse.

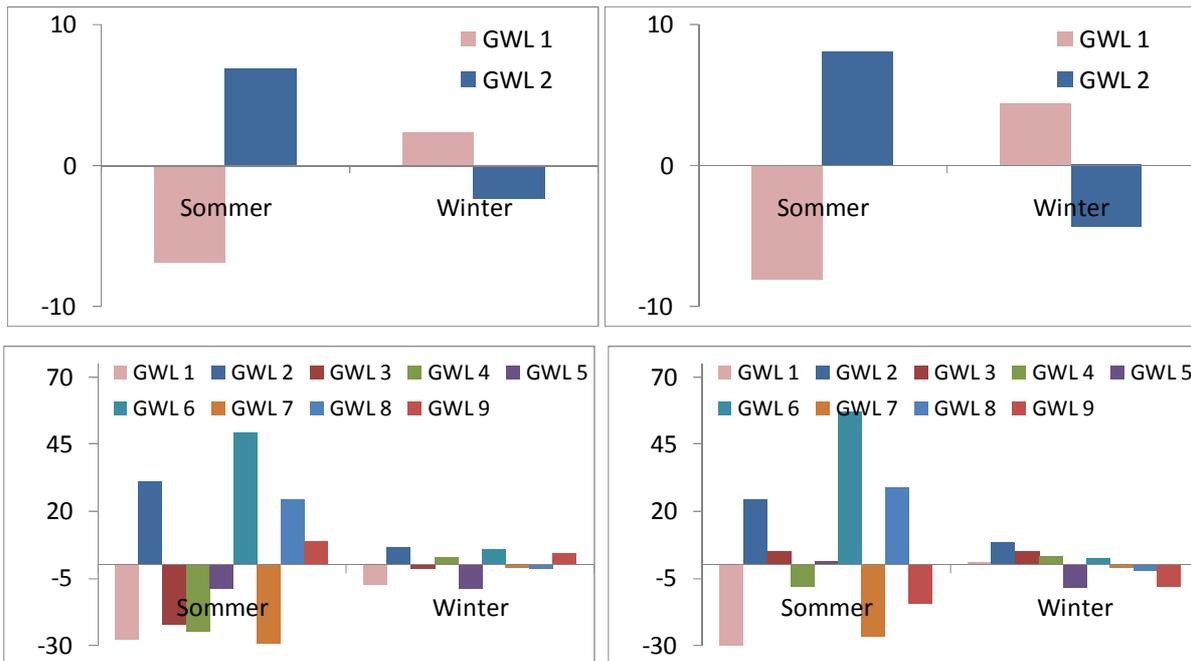


Abbildung 8-2 Abweichung [%] der Temperaturen der GWL von der mittleren Temperatur aller GWL mit zwei (oben) und acht (unten) GWL, links: Beobachtung, rechts: REMO C20 (1971-2000)

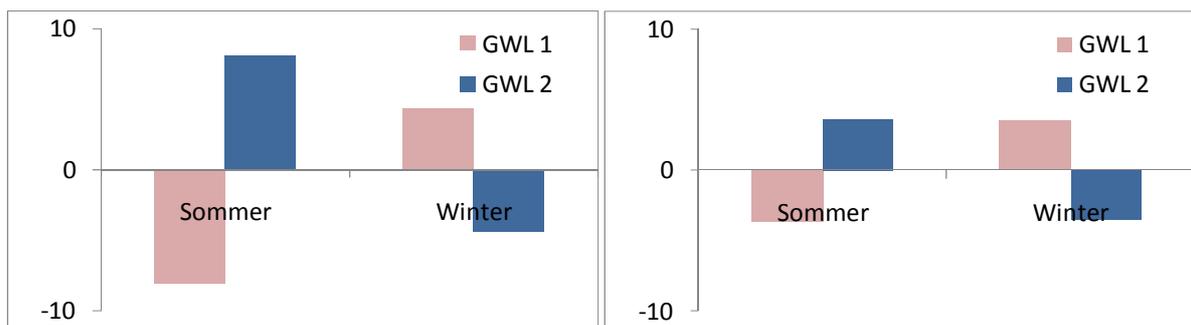


Abbildung 8-3 Abweichung [%] der Temperaturen der GWL von der mittleren Temperatur aller GWL mit zwei GWL, links: REMO C20 (1971-2000), rechts: REMO A1b (2071-2100)

8.2 Saisonalität

Es wurde vermutet, dass die GWL einen Vorteil bei der Nachbildung der Saisonalität bringt.

Zur Erinnerung: Es wurde bei der Generierung und Optimierung nur zwischen Winter und Sommer unterschieden; der Jahresgang wurde nicht berücksichtigt. Es wird die Version mit acht GWL dargestellt. Die Ergebnisse der Versionen mit vier und zwei GWL sind qualitativ gleichwertig.

Abbildung 8-4 zeigt den Anteil der Monatssummen am Jahresniederschlag in Prozent im Mittel über alle Stationen des Gebietes. Unterschiedliche Monatsdauern werden hierbei ignoriert. Da dies bei Beobachtung und Synthese getan wird, ist der hierdurch entstehende Fehler marginal.

Betrachtet wurden folgende Gebiete: ganz Niedersachsen, Harz-Hochland (>600 m NN), Nordwest-Niedersachsen und Südost-Niedersachsen (ohne Harz-Hochland). Aber die Unterschiede waren gering (beispielhaft am Hochharz als extremsten Teilgebiet gezeigt).

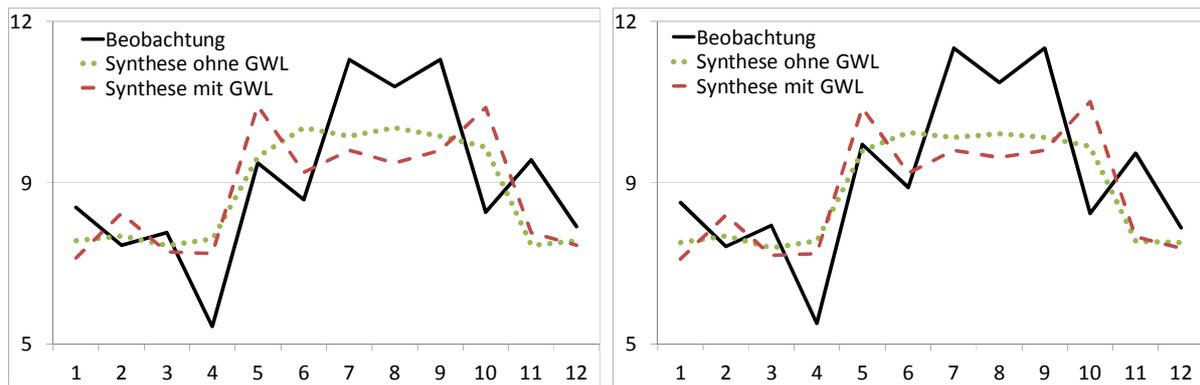


Abbildung 8-4 Monatliche Saisonalität der Niederschläge; y-Achse: Anteil [%] der Monatssummen am Jahresniederschlag, x-Achse: Monate; links: Niedersachsen, rechts: Harz-Hochland; dargestellt wurde die Version mit 8 GWL

Zu sehen ist, dass die monatliche Saisonalität nicht optimal wiedergegeben wird. Die GWL haben einen nachweisbaren Einfluss. Zum Beispiel wird die Spitze im Mai gegenüber Juni erfasst oder das kleine Tief im August gegenüber Juli und September. Allerdings wird nicht erfasst, dass die Niederschlagssumme im Oktober gegenüber den Vormonaten deutlich abfällt. Insgesamt kann also eine sehr leichte Verbesserung festgestellt werden. Falls eine strikte Saisonalität benötigt wird, ist es allerdings immer noch nötig, andere Schritte vorzunehmen, z. B. die Saisonalität in der Optimierung als ein zusätzliches Kriterium zu erfassen.

Es ist natürlich im Hinblick auf die anstehende Untersuchung zum Downscaling interessant, ob die Saisonalität in den REMO-Daten gut wiedergegeben wird. Daher wird hier zuerst ein kurzer Überblick über die Saisonalität in selbigen gegeben. In Abbildung 8-5 werden die Beobachtungsdaten den REMO-Daten der Vergangenheit (C20: 1971-2000) und der Zukunft (A1B: 2071-2100) gegenübergestellt. Hierbei werden die beobachteten Daten der Stationen den Werten des nächstgelegenen REMO-Rasterpunktes gegenübergestellt. Man sieht, dass die Saisonalität aus Beobachtung und REMO-Vergangenheit recht gut übereinstimmt. Allerdings werden einige Monatswerte über- oder unterschätzt (beispielsweise Juni oder März). Was aber besonders auffällt, ist, dass in den zukünftigen REMO-Werten die Saisonalität weniger stark und anders ausgeprägt ist.

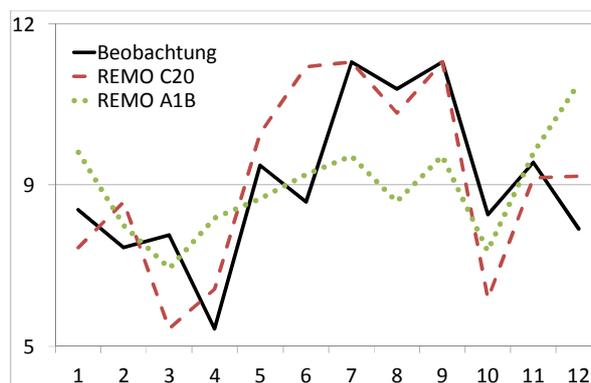


Abbildung 8-5 Monatliche Saisonalität der REMO-Niederschläge im Vergleich zur Beobachtung in Niedersachsen; y-Achse: Anteil [%] der Monatssummen am Jahresniederschlag, x-Achse: Monate

Abbildung 8-6 stellt die mit REMO-GWL und -Niederschlägen als Eingangsdaten modellierten synthetischen Werte den REMO-Niederschlagswerten gegenüber. Es soll hiermit erkannt werden, ob durch die Verwendung von GWL eine Veränderung der Reproduktion der Saisonalität in den Downscalingdaten zu erwarten ist. Während für die Werte der Vergangenheit noch eine leichte Verbesserung der Saisonalität erkannt werden kann (z. B. für März oder August), ist dies für die Zukunft nicht mehr möglich.

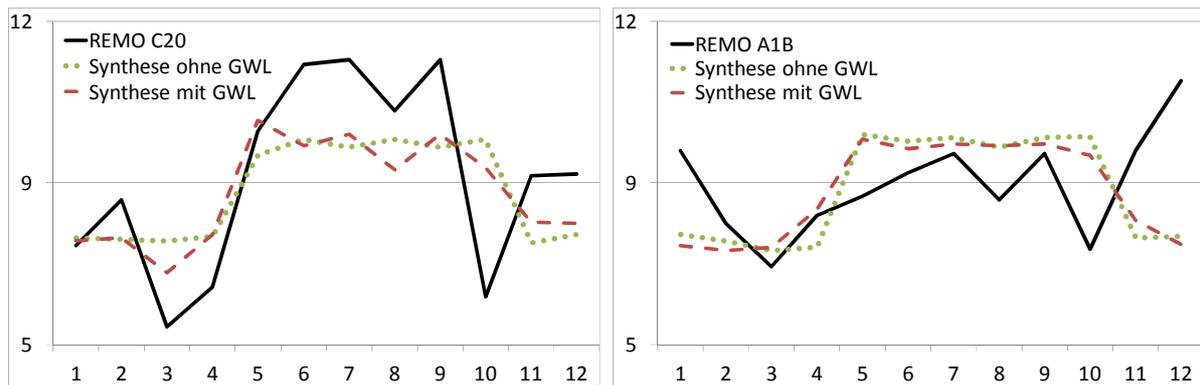


Abbildung 8-6 Monatliche Saisonalität der Synthese-Daten im Vergleich zu den REMO-Niederschlägen in Niedersachsen; y-Achse: Anteil [%] der Monatssummen am Jahresniederschlag, x-Achse: Monate, links: Vergangenheit (C20: 1971-2000), rechts: Zukunft (A1B: 2071-2100)

8.3 Zeitliche Persistenz (Autokorrelation)

8.3.1 Gesamte Zeitreihe

Ein weiterer Aspekt im Zusammenhang mit GWL ist die Autokorrelation in den Stundenwertzeitreihen. Bei der Untersuchung ergab sich jedoch kein nennenswerter Einfluss der GWL (siehe Abbildung 8-7). Dies ist nicht überraschend, da in der Optimierung bezüglich GWL nur ganze Ereignisse getauscht werden und somit der Einfluss auf die Autokorrelation der Stundenwerte naturgemäß gering ist. Dargestellt wurde die Version mit zwei GWL. Die Versionen mit vier und acht GWL zeigen vergleichbare Werte.

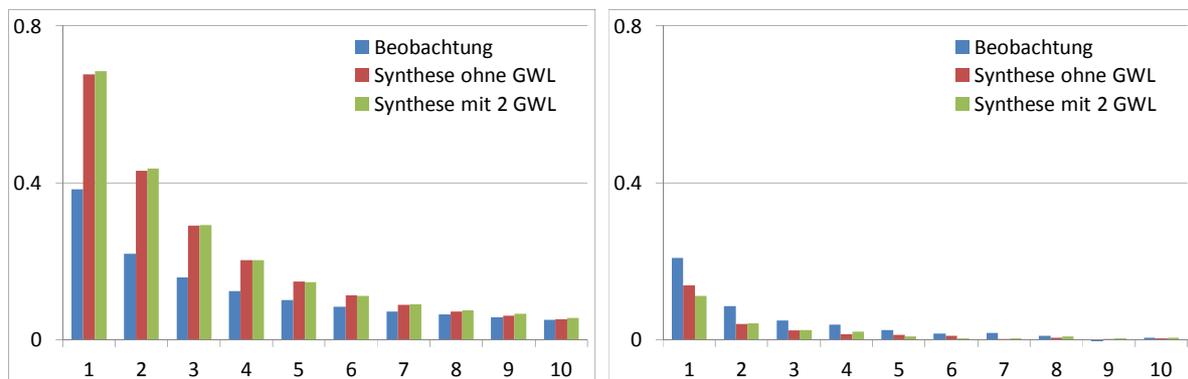


Abbildung 8-7 Mittlere Autokorrelation der Stundenwerte (links) und Tageswerte (rechts); Beobachtung gegen Modell; x-Achse: Lags; y-Achse: Wert der Korrelation

Trotzdem sind die Erkenntnisse, die der Abbildung 8-7 entnommen werden können, von Bedeutung, denn die Autokorrelationen der Stundenwerte werden durch das Modell überschätzt, während die Autokorrelationen der Tageswerte unterschätzt werden. Dies ist größtenteils auf das einfache Feinstrukturmodell zurückzuführen, das anscheinend unzureichend ist. Die Ergebnisse der Analyse des Einflusses der GWL auf die Autokorrelation müssen daher als schwer auswertbar betrachtet werden. Festgehalten werden muss jedoch, dass hier Verbesserungsbedarf besteht.

8.3.2 Ereignisse

Die Analysen im Abschnitt 3.4 machten deutlich, dass bei den verwendeten Modellkenngrößen (für dieses Untersuchungsgebiet) eine geringe Lag 1-Autokorrelation in den Niederschlagsereignissen vorhanden ist. Das Fehlen einer Autokorrelation in den Ereignissen ist jedoch klassischerweise eine Modellvoraussetzung der ARP-Modelle. Daher ist eine Untersuchung des Einflusses der GWL auf die Wiedergabe der beobachteten Autokorrelation sinnvoll.

Abbildung 8-8 stellt die Lag 1- und Lag 2-Autokorrelation der Ereigniselemente nach Eliminierung der Saisonalität grafisch dar und macht den Einfluss der GWL deutlich und klar sichtbar. Besonders bei einem Lag (Abstand) von 1 ist für die *dsd* und *wsd* zu erkennen, dass durch die Verwendung der GWL die geringe Autokorrelation der Ereignisse mit dem Modell gut wiedergegeben wird, während das Modell ohne GWL diese nicht erfassen kann. Auf die Autokorrelation der *wsi* haben die GWL allerdings keinen Einfluss. Für den Lag 2-Fall ist der Einfluss der GWL deutlich geringer. Für die (hier nicht dargestellten) weiter entfernten Autokorrelationsschrittweiten ist der Einfluss der GWL praktisch nicht mehr erkennbar.

Auch wenn die Autokorrelation der Ereignisse nicht vollständig wiedergegeben werden kann, hat die Berücksichtigung der GWL in diesem Punkt zu einer Verbesserung des Modells geführt. In Fällen, in denen eine Autokorrelation nicht völlig vermieden werden kann, ist es möglich, diese mit den GWL größtenteils zu reproduzieren.

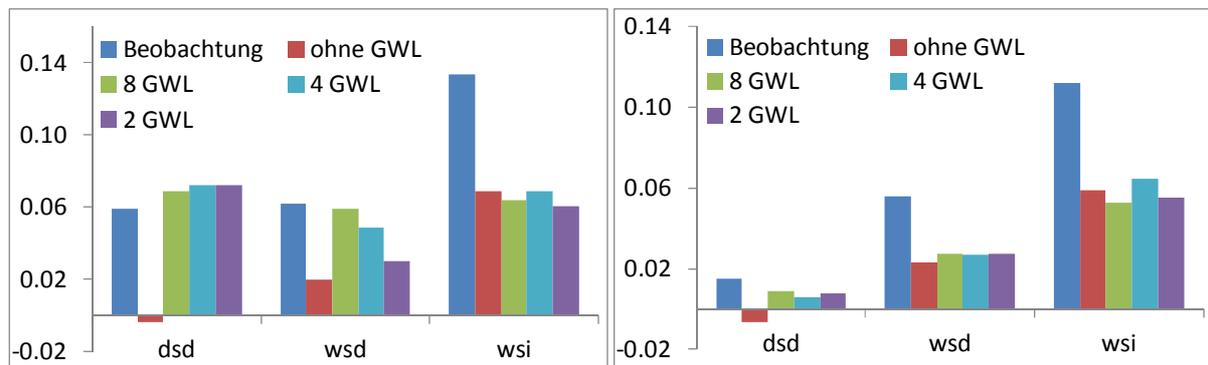


Abbildung 8-8 Autokorrelation der Ereigniselemente, Beobachtung und Modell; links: lag 1; rechts: lag 2

8.4 Räumliche Persistenz

Auf den Einfluss der GWL auf die räumliche Persistenz wurde bereits in Abschnitt 7.3 eingegangen. Allerdings wurde dort nur auf den Fall eingegangen, dass eine räumliche Optimierung vorgenommen wird. An dieser Stelle soll jedoch diskutiert werden, was mit der räumlichen Persistenz passiert, wenn die GWL rein univariat in die Modellierung einfließen.

Tabelle 8-2 listet die durchschnittliche bivariate Korrelation aller Stationen auf. Man kann erkennen, dass die mit GWL generierten Werte im Gegensatz zu den ohne GWL generierten Werten durchwegs Korrelationen aufweisen. Allerdings sind diese insbesondere für die Stundenwerte im Vergleich zur Beobachtung sehr gering.

Tabelle 8-2 Arithmetisches Mittel über alle Stationen der Pearson'schen Korrelation der univariat generierten Daten

| Version | Stundenwertzeitreihen | Tageswertzeitreihen |
|-------------------|-----------------------|---------------------|
| Beobachtung | 0,14 | 0,49 |
| Synthese ohne GWL | 0,00 | 0,00 |
| 8 GWL | 0,01 | 0,05 |
| 4 GWL | 0,02 | 0,07 |
| 2 GWL | 0,02 | 0,09 |

Interessant ist daher die Betrachtung der Korrelationen aller Stationen zueinander. In Abbildung 8-9 sind diese in Abhängigkeit von ihrer Entfernung zueinander dargestellt. Auf den ersten Blick ist zu erkennen, dass es keinen direkten räumlichen Bezug mehr gibt. Die Korrelationen zweier sehr naher Stationen unterscheiden sich nicht von der Korrelation zweier hunderte Kilometer voneinander entfernten Stationen. Allerdings kann ebenso klar erkannt werden, dass die Korrelationen für die Synthese mit GWL fast ausnahmslos klar erkennbar höher sind als für die Synthese ohne GWL.

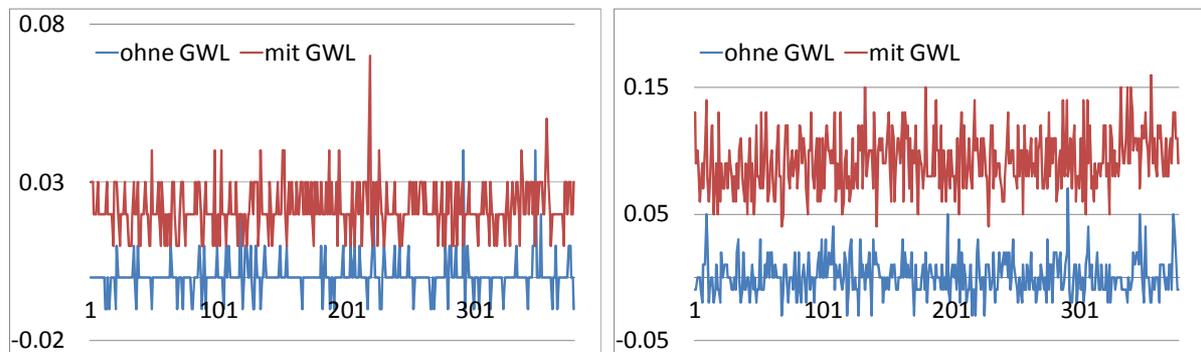


Abbildung 8-9 Pearson'sche Korrelationskoeffizienten der univariat generierten Daten in Abhängigkeit vom Raum; Darstellung für die Synthese ohne GWL und die Synthese mit zwei GWL, x-Achse: Entfernung [km], y-Achse: Korrelationskoeffizient; links: Stundenwerte, rechts: Tageswerte

Die ermittelten Korrelationen lassen sich leichter erklären, wenn man sie mit den Korrelationen der Beobachtung in Abbildung 8-10 vergleicht. Die Korrelationen der mit GWL univariat generierten Zeitreihen haben in etwa die Größe der 350 km voneinander entfernten Stationen. Demnach kann mittels der univariat berücksichtigten GWL zwischen den Zeitreihen die Korrelation erstellt werden, die vorhanden ist, wenn zwei Stationen nicht nah benachbart sind, aber in derselben Region liegen.

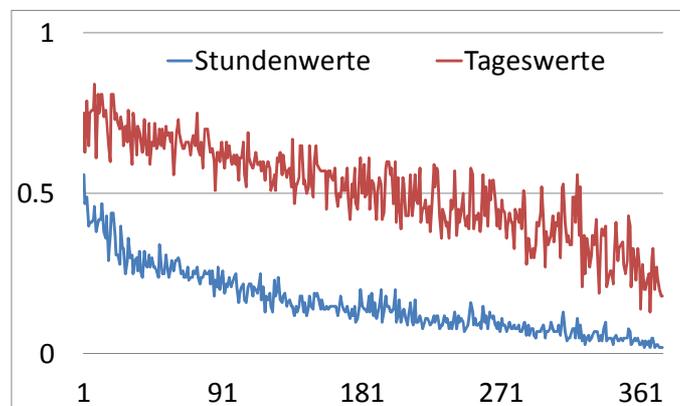


Abbildung 8-10 Pearson'sche Korrelationskoeffizienten der Beobachtung in Abhängigkeit vom Raum; dargestellt sind die Paare aller Stationen im Untersuchungsgebiet mit einem Abstand > 10 km; Darstellung, x-Achse: Entfernung [km], y-Achse: Korrelationskoeffizient

9 Downscaling

Nach dem heutigen Stand der Wissenschaft besteht ein Wandel des Klimas aufgrund anthropogener Einwirkungen und natürlicher Prozesse (siehe IPCC (2007)). Ein modernes Niederschlagsmodell, das Daten (zum Beispiel für die Auslegung von Bauwerken) generiert, sollte daher in der Lage sein, diese Prozesse abzubilden. Wie in Abschnitt 2.3 erläutert, geschieht dies in der Regel mittels eines Downscaling. In diesem Abschnitt wird analysiert und diskutiert, inwiefern das vorgestellte Modell als ein Downscaling-Modell einsetzbar ist und welchen Einfluss hierbei die Großwetterlagen haben.

9.1 Modellaufbauten

Bei den Untersuchungen wurden unterschiedliche Modellaufbauten eingesetzt. Der erste Ansatz versuchte ein Downscaling ausschließlich mittels einer Transformation der GWL-Häufigkeiten zu bewerkstelligen. Bei den Untersuchungen von Haberlandt et al. (2015) zeigte sich jedoch, dass sich nicht nur die GWL-Häufigkeiten über die Zeit ändern, sondern auch die Niederschlagsverhältnisse in den GWL (siehe Abbildung 9-1). Somit kann eine reine Transformation der GWL-Häufigkeiten nicht genügen, um den Klimawandel mit dem Modell abzubilden. Es müssen also neben den GWL-Häufigkeiten auch die Modellparameter transformiert werden.

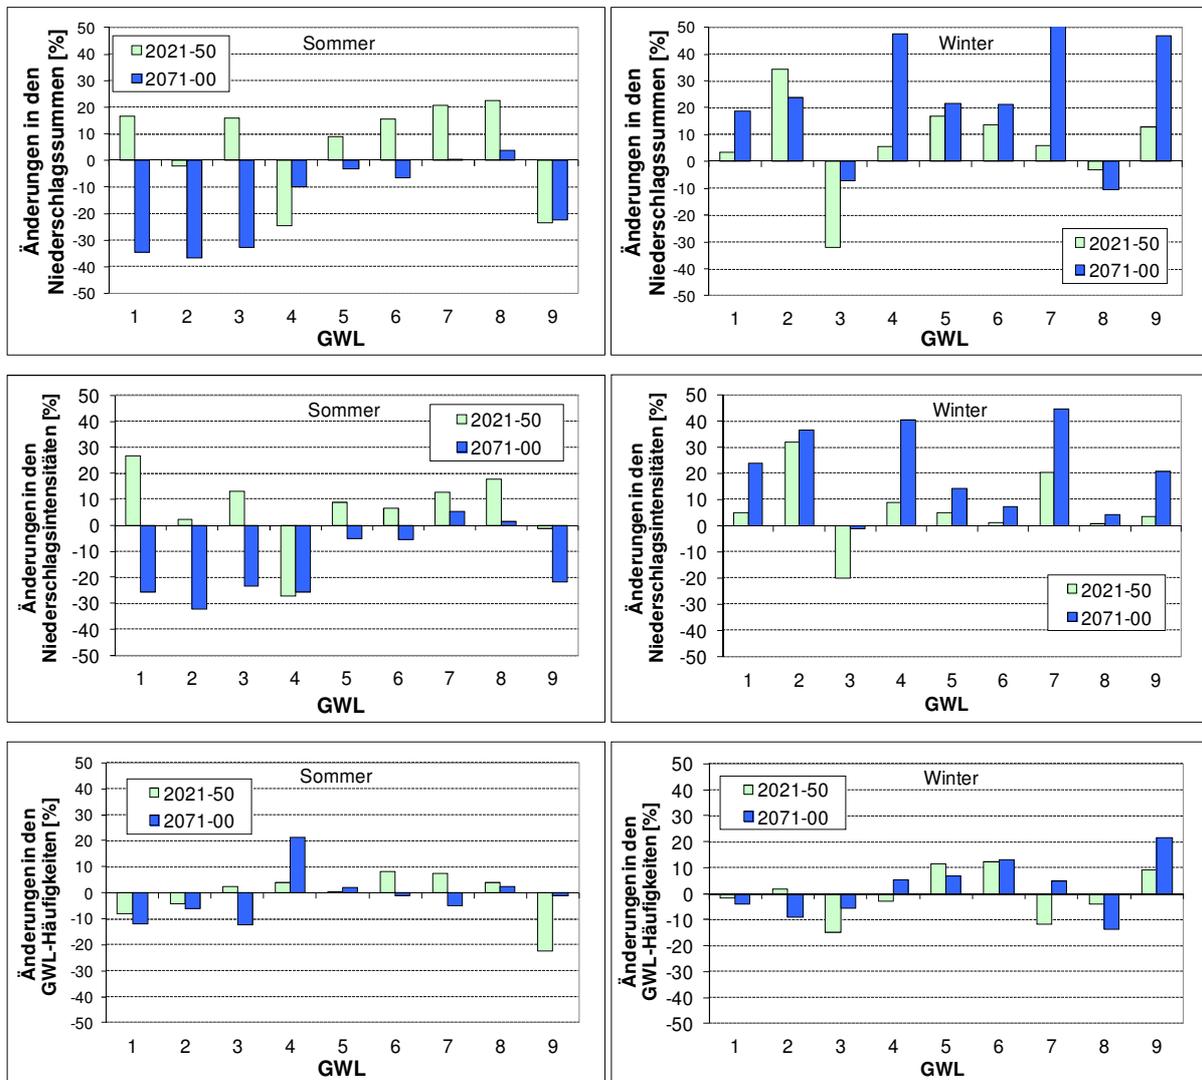


Abbildung 9-1 Änderungen im Niederschlag der Großwetterlagen (nach Haberlandt et al. (2015))

Der erste Ansatz zur Transformation der Modellparameter hatte das Ziel, mit einem einfachen Verfahren direkt die L-Momente zu transferieren. Nach verschiedenen Untersuchungen (siehe Abschnitt 9.1.2) wurde hierzu ein erfolgreicher Quantil-Quantil-Transformationsansatz ausgearbeitet.

In diesem Kapitel wird auf die Funktionalität des Modells und der verwendeten Methoden eingegangen. Da als Eingangsgröße nur ein einziger Durchlauf eines einzigen globalen bzw. regionalen Klimamodells verwendet wird, haben die mit dem Modell ermittelten Veränderungen für die Zukunft nur eine geringe Aussagekraft. Um belastbare Resultate zu erzielen, müssten verschiedene Klimamodelle, mehrere Klimaszenarien und mehrere Durchläufe derselben verwendet werden.

Im Falle einer Regionalisierung werden die zusätzlich anfallenden Kenngrößen für das Downscaling mit dem Nächster-Nachbar-Verfahren übertragen.

9.1.1 Transformation der GWL-Häufigkeiten

Die mit den REMO-Daten ermittelten GWL-Häufigkeiten konnten nicht direkt verwendet werden, da es im Verwendungszeitraum Abweichungen zwischen Beobachtung und REMO gibt (siehe Abbildung 9-2). Daher wurde als erster Schritt der Untersuchung die Transformation der beobachteten GWL-Häufigkeiten nötig.

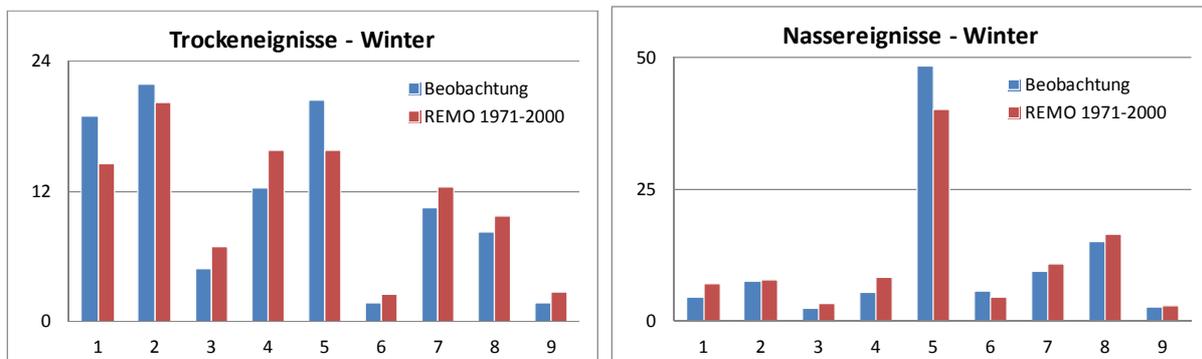


Abbildung 9-2 GWL-Frequenzen [%] in den Ereignissen von Beobachtung und REMO, beispielhaft für die Station Diepholz im Winter

Es wurde hierfür die Häufigkeitsänderung der GWL-Häufigkeiten der Klimamodell-Daten auf die GWL der Beobachtungsdaten übertragen. Die Bestimmung der GWL-Häufigkeiten der Klimamodell-Daten erfolgt, wie in Abschnitt 3.6, beschrieben mit ECHAM- und REMO-Daten. Der gewählte Ansatz ist ein einfacher Delta-Change-Approach (siehe z. B. Teutschbein & Seibert (2012)):

$$CP_{beo,z} = CP_{beo,h} \frac{CP_{Echam,z}}{CP_{Echam,h}} \quad (9-1)$$

$CP_{x,y}$ - Relative Häufigkeit der GWL in den Intervallsummen der Ereignisse der Stichprobe x (Beobachtung oder ECHAM) des Zeitraums y (h – historisch oder z – zukünftig)

Hierbei werden die Kennwerte der Saisons unabhängig voneinander transformiert.

Tabelle 9-1 zeigt die GWL-Anteile der Version mit zwei GWL. Man kann sehen, dass bei der Transformation von Beobachtung zu 2021-2050 nicht viel passiert, auch wenn einige Veränderungen vorhanden sind (z. B. im Winter bei den Nassereignissen). Anders sieht es für die Transformation von Beobachtung zu 2071-2100 aus. Hier gibt es signifikante Änderungen für die Nassereignisse und teilweise auch für die Trockenereignisse. Bei den Versionen mit vier und acht GWL sieht es ähnlich aus. Allerdings sind hier die Änderungen für die Trockenereignisse etwas ausgeprägter, wenn auch immer noch recht gering.

Um dies zu illustrieren, werden in Tabelle 9-2 und Tabelle 9-3 die GWL der Trockenereignisse im Winter und Nassereignisse im Sommer dargestellt, um somit die Bereiche zu zeigen, bei denen für die Version mit zwei GWL die größte und geringste Veränderung zu beobachten war.

Tabelle 9-1 Anteile [%] der GWL an den zu Ereignissen verbundenen Stundenwert-Intervallen; Version mit zwei GWL

| Transformation von | Nassereignisse | | | | Trockenereignisse | | | |
|--------------------------|----------------|----|--------|----|-------------------|----|--------|----|
| | Sommer | | Winter | | Sommer | | Winter | |
| Beobachtung zu 2021-2050 | 1 | 2 | 1 | 2 | 1 | 2 | 1 | 2 |
| GWL | 1 | 2 | 1 | 2 | 1 | 2 | 1 | 2 |
| Vor Transformation | 19 | 81 | 22 | 78 | 63 | 37 | 61 | 39 |
| Nach Transformation | 18 | 82 | 20 | 80 | 64 | 36 | 61 | 39 |
| Beobachtung zu 2071-2100 | | | | | | | | |
| Vor Transformation | 19 | 81 | 22 | 78 | 63 | 37 | 61 | 39 |
| Nach Transformation | 15 | 85 | 21 | 79 | 62 | 38 | 61 | 39 |

Tabelle 9-2 Auszug 1 der Anteile [%] der GWL an den zu Ereignissen verbundenen Stundenwert-Intervallen; Version mit acht GWL, GWL 9 besteht aus Ereignissen mit nicht zuweisbaren GWL

| Transformation von | | | | | | | | | |
|--------------------------|-----------------------------|----|---|----|----|---|----|---|---|
| | Trockenereignisse im Winter | | | | | | | | |
| Beobachtung zu 2021-2050 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
| GWL | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
| Vor Transformation | 19 | 24 | 4 | 13 | 18 | 2 | 10 | 8 | 2 |
| Nach Transformation | 18 | 25 | 3 | 13 | 20 | 2 | 8 | 8 | 2 |
| 1971-2000 zu 2071-2100 | Trockenereignisse im Winter | | | | | | | | |
| Vor Transformation | 19 | 24 | 4 | 13 | 18 | 2 | 10 | 8 | 2 |
| Nach Transformation | 19 | 21 | 4 | 15 | 20 | 2 | 9 | 7 | 2 |

Tabelle 9-3 Auszug 2 der Anteile [%] der GWL an den zu Ereignissen verbundenen Stundenwert-Intervallen; Version mit acht GWL, GWL 9 besteht aus Ereignissen mit nicht zuweisbaren GWL

| Transformation von | | | | | | | | | |
|--------------------------|--------------------------|---|---|---|----|---|----|----|---|
| | Nassereignisse im Sommer | | | | | | | | |
| Beobachtung zu 2021-2050 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
| GWL | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
| Vor Transformation | 6 | 7 | 1 | 6 | 43 | 7 | 17 | 12 | 2 |
| Nach Transformation | 6 | 6 | 1 | 4 | 43 | 7 | 19 | 12 | 2 |
| 1971-2000 zu 2071-2100 | Nassereignisse im Sommer | | | | | | | | |
| Vor Transformation | 6 | 7 | 1 | 6 | 43 | 7 | 17 | 12 | 2 |
| Nach Transformation | 4 | 5 | 0 | 5 | 46 | 6 | 19 | 12 | 3 |

Insgesamt kann festgestellt werden, dass es zwischen den GWL durchaus Verschiebungen gibt. Es konnte auch festgestellt werden, dass es Verschiebungen von den trockenen GWL zu den nassen GWL gab. Gut zu sehen ist dies für die Nassereignisse in der Version mit zwei GWL im Sommer bei der Transformation von Beobachtung zu 2071-2100.

Hier erhöhte sich der Anteil der nassen GWL von 81 % auf 85 %. Die Veränderungen blieben allerdings hinter den Erwartungen zurück. Insbesondere muss festgestellt werden, dass für Trockenereignisse nur geringe Veränderungen auftraten.

Die hier getroffenen Erkenntnisse passen gut zu den erwähnten Ergebnissen von Haberlandt et al. (2011), die bereits 2011 die Prognose aufstellten, dass eine Transformation der GWL anscheinend nicht für ein Downscaling genügen würde (siehe auch Abschnitt 2.2).

9.1.2 Transformation der L-Momente

Der gewählte Ansatz verwendet die Informationen des regionalen Downscaling-Modells REMO. Es ist allerdings nicht möglich, die Parameter an den REMO-Zeitreihen direkt zu schätzen, da diese mit einem Bias belastet sind. Das Thema Bias und Bias-Korrektur wird in der einschlägigen Literatur intensiv diskutiert, zum Beispiel von Terink et al. (2010) anhand eines REMO-Downscaling eines Reanalyse-Modells (ERA15). Daher war eine Transformation der Beobachtungsdaten nötig. Zuerst wurde versucht, die L-Momente, welche die direkten Eingangsdaten der Parameterschätzung sind, zu transformieren. Dieser Ansatz entspricht der Formel (9-1):

$$L_{beo,z} = L_{beo,h} \frac{L_{Remo,z}}{L_{Remo,h}} \quad (9-2)$$

$L_{x,y}$ - L- Moment der Zeitreihe der Stichprobe x (Beobachtung oder REMO) des Zeitraumes y (h - historisch oder z - zukünftig)

Es wurden verschiedene Versionen getestet. Im ersten Schritt wurden alle relevanten L-Momente (1. bis 3. Ordnung) und die Parameter der Feinstruktur transformiert. Aufgrund der nicht-linearen Struktur der Parameter der Feinstruktur wurden im zweiten Schritt nur die L-Momente transformiert. Als auch dies nicht die gewünschten Ergebnisse lieferte, wurde versucht, ausschließlich die L-Momente 1. Ordnung zu transformieren.

Nachdem die L-Momente transformiert wurden, erfolgte mit diesen die Parameterschätzung der Verteilungsfunktionen des Niederschlagsmodells.

Tabelle 9-4 Mittlere Änderungen [%] über alle Stationen der abgeleiteten Niederschlagscharakteristika

| Transformations- zeitraum | Niederschlagssummen | | Anzahl an Ereignissen pro Jahr | |
|--------------------------------------|---------------------|--|--------------------------------|--|
| | REMO | ARP 2 mit transformierten L-Momenten | REMO | ARP 2 mit transformierten L-Momenten |
| Beobachtungszeitraum zu 2021-2050 | | | | |
| Sommer | 5 | -1 | -2 | -2 |
| Winter | 9 | 17 | 2 | 3 |
| Beobachtungszeitraum zu 2071-2100 | | | | |
| Sommer | -9 | -15 | -12 | -13 |
| Winter | 20 | 26 | 1 | 3 |

Leider war das Modell mit diesen Downscaling-Methoden nicht in der Lage, die mit REMO ermittelten Änderungen in den Mitteln der Niederschlagssummen und den mittleren Anzahlen von

Niederschlagsereignissen pro Saison zu reproduzieren. Da dies als eine Minimalqualität des Downscaling angesehen wurde, wurde das Modell in dieser Form verworfen.

Tabelle 9-4 zeigt beispielhaft die Ergebnisse des Modells mit acht GWL und der Transformation der L-Momente. Die Resultate sind durchaus typisch für diese Transformationsvariante und auch bei anderer Anzahl GWL zu sehen. Die Änderung der Anzahl der Ereignisse wird sehr gut reproduziert, aber die Änderungen der mittleren Niederschlagssummen werden relativ schlecht reproduziert.

Bei ausschließlicher Transformation der L-Momente sind die Ergebnisse ähnlich; allerdings werden die Änderungen der mittleren Anzahl an Ereignissen pro Jahr schlechter wiedergegeben.

9.1.3 Transformation der Ereigniszeitreihen

Die Ergebnisse der Transformation der L-Momente zeigten nicht die erhofften Erfolge. Daher wurden im Rahmen dieser Dissertation verschiedene andere Ansätze entwickelt und validiert.

Die Ereignisse werden durch die bekannten Elemente Trockendauer, Nassereignisdauer und -intensität bestimmt. Hierdurch verändert sich die Dynamik der Transformation im Vergleich zu Ansätzen, die die Ereignisintervalle selbst transformieren. Dies liegt insbesondere an der Abwesenheit von Nullwerten. Diese sind ein zentrales Problem vieler Bias-Korrektur-Ansätze. Diese nehmen meist eine Korrektur der Niederschlagsintervalle vor und können somit die Häufigkeit der trockenen Intervalle nicht direkt beeinflussen. Das Problem wird mit speziellen Methoden angegangen (siehe beispielsweise Bárdossy & Pegram (2012) oder Teutschbein & Seibert (2012)). Da die trockenen Perioden in dem hier verwendeten Ansatz durch die Dauern der Trockenereignisse erfasst werden, können sie direkt transformiert werden. Somit entsteht kein Problem mit den Nullwerten. Allerdings würde eine reine Bias-Korrektur der Ereignisse die Dauern von Saisons und Jahren verändern und somit eine anschließende Korrektur erfordern. Daher ergab sich als Ansatz, dass auf eine Bias-Korrektur der Ereignisse eine Modellierung folgt. Die Parameter dieser Modellierung werden mit den korrigierten Daten bestimmt. Diese beiden Schritte ergeben zusammen mit der GWL-Transformation das Downscaling.

Das zuerst getestete Verfahren transformiert die Ereignisse zur Erfassung der Änderungen des Mittelwertes (der dem L-Moment erster Ordnung entspricht). Im Folgenden wird der Ansatz *Transformierung des Mittelwertes* dargelegt, der sich wie folgt beschreiben lässt:

$$EV_{beo,z} = EV_{beo,h} \frac{Mean(EV_{Remo,z})}{Mean(EV_{Remo,h})} \quad (9-3)$$

EV_{x,y}-Ereigniselement wsd, wsi oder dsd mit der Stichprobe x (Beobachtung oder REMO) und dem Zeitraum y (h – historisch oder z – zukünftig)

Da, wie im Laufe des Kapitels beschrieben, die Ergebnisse dieses Ansatzes nicht zufriedenstellend waren, wurde dieser einfache Ansatz zu zwei verschiedenen Verfahren entwickelt, die die weiter unten beschriebenen Probleme beheben sollen.

Das erste Verfahren (Quotienten-Verfahren) ist wieder ein auf Division basierendes Verfahren. Bei dem Verfahren wird das Verhältnis der zukünftigen und vergangenen Werte der Ereigniselemente aus REMO auf die der Beobachtung übertragen:

$$EV_{beo,z} = EV_{beo,h} \frac{F_{Remo,z}^{-1} \left(F_{beo,h} \left(EV_{beo,h} \right) \right)}{F_{Remo,h}^{-1} \left(F_{beo,h} \left(EV_{beo,h} \right) \right)} = EV_{beo,h} \frac{EV_{Remo,z}}{EV_{Remo,h}} \quad (9-4)$$

F_x – Verteilungsfunktion F_x⁻¹ – Inverse Verteilungsfunktion

Der Ansatz basiert auf den klassischen Delta-Change-Ansätzen für Niederschlagsdaten (siehe zum Beispiel Teutschbein & Seibert (2012)). Im Zähler erfolgt eine Transformation des Beobachtungswertes in die REMO-Zukunft und im Nenner in die REMO-Vergangenheit. Der Quotient wird mit dem Beobachtungswert multipliziert. Die Transformationen erfolgen, indem die entsprechend ihrer Verteilungsfunktion ermittelten Wahrscheinlichkeiten der beobachteten Ereignisse als Eingangsgröße der inversen Verteilungsfunktion der REMO-Datensets verwendet werden.

Der zweite Ansatz ist eine Quantil-Quantil-Transformation, die für den Wert der Beobachtung die Wahrscheinlichkeit in der Verteilungsfunktion der REMO-Daten der Vergangenheit ermittelt. Anschließend wird mit dieser Wahrscheinlichkeit und der inversen Verteilungsfunktion der REMO-Daten des zukünftigen Zeitraumes der „Beobachtungswert“ der Zukunft ermittelt:

$$EV_{beo,z} = F_{Remo,z}^{-1} \left(F_{Remo,h} (EV_{beo,h}) \right) \quad (9-5)$$

Das Vorgehen kann in Anlehnung an Bárdossy & Pegram (2011), die eine ähnliche Prozedur zur Bias-Korrektur verwendeten, erläutert werden. Im Unterschied zu Bárdossy & Pegram (2011) erfolgt hier aber, wie eingangs erläutert, keine reine Bias-Korrektur. Die Bias-Korrektur in den Ereigniszeitreihen ist nur der erste Schritt des Downscalings, auf den zuerst die Parameterbestimmung mit den korrigierten Zeitreihen und anschließend die Modellierung mit den korrigierten Parametern folgen. In Abbildung 9-3 sind zwei theoretische Verteilungen und eine empirische Verteilung dargestellt. Die als Kreise dargestellten Elemente der empirischen Verteilung der Nassereignisdauern sind die zu transformierenden Werte der Beobachtung. Diese Werte werden mit der Formel (9-5) transformiert. Es werden somit die Veränderungen der REMO-Werte der Vergangenheit (rot durchgezogene Linie) zu denen der REMO-Werte der Zukunft (grün gestrichelte Linie) in Beziehung gesetzt und auf die beobachteten Werte der Vergangenheit übertragen.

In dem Beispiel ist auch das in Abschnitt 5.2.2.2 diskutierte Symptom der Häufung der Werte der Dauern gut zu erkennen. Dies hat jedoch keinen Einfluss auf die Methode.

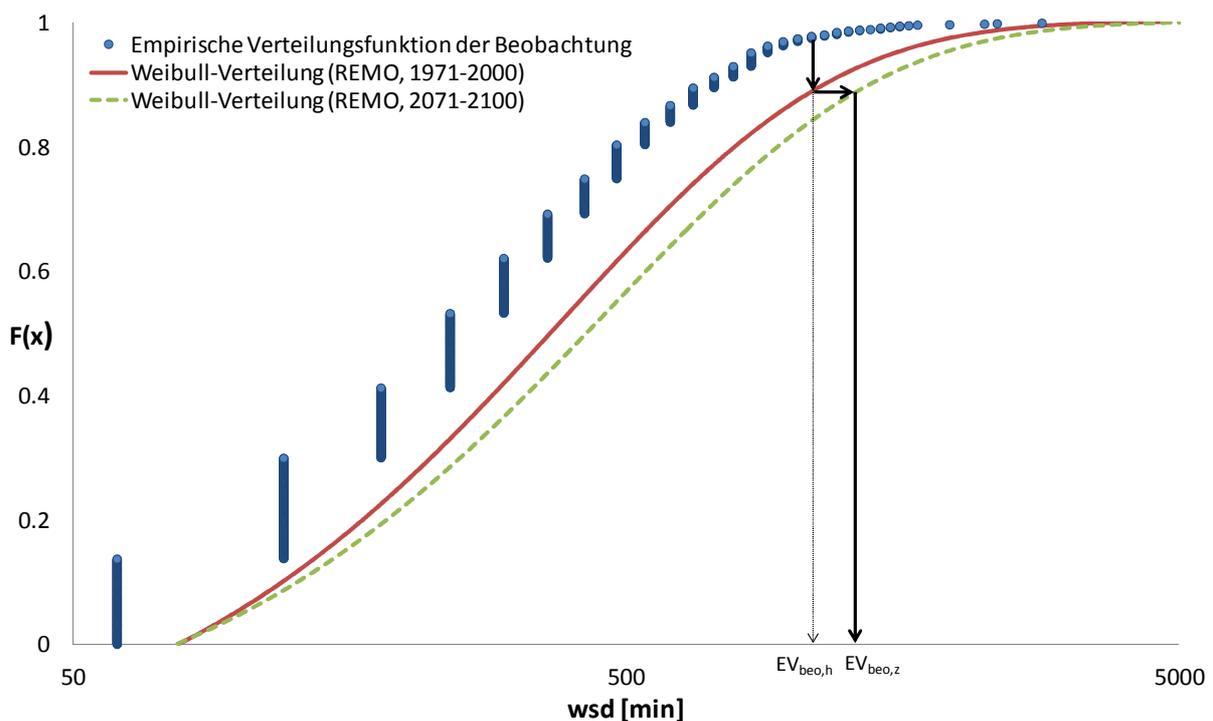


Abbildung 9-3 Quantil-Quantil-Transformation

Bei der Anwendung beider Transformationsverfahren wurde allen Ereignissen zuerst eine GWL zugewiesen. Anschließend wurden an die Ereignisse der Remo-Daten Verteilungsfunktionen für alle GWL angepasst. Mit diesen GWL erfolgte anschließend die Transformation der Ereignisse der Beobachtung, differenziert gemäß der jeweiligen GWL.

In Tabelle 9-5 und Tabelle 9-6 wird beispielhaft an den *wsd* der Wintermonate die Transformation der Momente und L-Momente mit den verschiedenen Verfahren diskutiert. Die anderen Kenngrößen und Saisons ergaben vergleichbare Ergebnisse. Bereits der einfache Mittelwert-Ansatz (siehe Formel (9-3)) reichte aus, um die Veränderungen des Mittelwertes korrekt zu erfassen. Allerdings werden hier Varianz und Schiefe nicht entsprechend den Veränderungen des RCM transformiert, sondern zufällig verändert (Standardabweichung, 2. L-Moment) oder sie bleiben völlig unverändert (Schiefe, Tau des 3. L-Moments). Es ist allerdings zu erwähnen, dass die Veränderungen von Standardabweichung und 2. L-Moment stets die richtigen Tendenzen aufweisen.

Man erkennt, dass die statistischen Momente und die L-Momente durch das Quotienten-Verfahren und das Quantil-Quantil-Verfahren in etwa gleich gut reproduziert werden. Es konnte hierbei festgestellt werden, dass die Schiefe meist die größten Abweichungen zeigt. Die Änderungen der L-Momente aller Ereigniselemente (*wsd*, *wsi* und *dsd*) werden hingegen sowohl durch das Quotienten-Verfahren als auch durch das Quantil-Quantil-Verfahren gut reproduziert.

Tabelle 9-5 Veränderung [%] der statistischen Momente im Mittel über alle Stationen bei den verschiedenen Downscaling-Verfahren (*wsd* im Winter), entsprechend den Veränderungen des Mittelwertes des zugehörigen REMO-Rasterpunktes zwischen den Zeiträumen 1971-2000 und 2071-2100, ohne GWL-Berücksichtigung

| | Mittelwert | Standardabweichung | Schiefe |
|----------------------------------|------------|--------------------|---------|
| REMO | 3 | 11 | 1 |
| Transformierung des Mittelwertes | 3 | 5 | 0 |
| Quotienten-Verfahren | 3 | 12 | 4 |
| Quantil-Quantil-Transformation | 3 | 10 | 3 |

Tabelle 9-6 Veränderung [%] der L-Momente im Mittel über alle Stationen bei den verschiedenen Downscaling-Verfahren (*wsd* im Winter), entsprechend den Veränderungen des Mittelwertes des zugehörigen REMO-Rasterpunktes zwischen den Zeiträumen 1971-2000 und 2071-2100, ohne GWL-Berücksichtigung

| | 1. L-Moment | 2. L-Moment | Tau des 3. L-Moments |
|----------------------------------|-------------|-------------|----------------------|
| REMO | 3 | 5 | 1 |
| Transformierung des Mittelwertes | 3 | 2 | 0 |
| Quotienten-Verfahren | 3 | 4 | 1 |
| Quantil-Quantil-Transformation | 3 | 5 | 1 |

Die drei Verfahren wurden im nächsten Schritt mittels der abgeleiteten Niederschlagscharakteristika verglichen. Hierfür wurde das Niederschlagsmodell mit den transformierten Ereignis-Zeitreihen als Eingangsdaten betrieben und für jedes Verfahren 1000 Jahre generiert. Die Generierung erfolgte rein univariat mit den ermittelten Häufigkeiten der transformierten GWL (siehe Abschnitt 5.2.2) ohne direkten Bezug zur Zeitreihe der GWL. Anschließend wurden die Ergebnisse mit den in den REMO-Daten beobachteten Veränderungen verglichen.

Die Ergebnisse hiervon wurden in Tabelle 9-7 und Tabelle 9-8 zusammengefasst. Diese Tabellen zeigen die Version mit acht GWL und den Fall, der die GWL-Transformation berücksichtigt (siehe Abschnitt 9.1.1). Die Ergebnisse der anderen Varianten sind ähnlich. Bei der Verwendung der Daten muss berücksichtigt werden, dass zwar 1000 Jahre generiert werden, diese aber stets nur den Zustand des Zeitraumes abbilden, für den die Modellparameter generiert wurden.

In den Tabellen ist zu erkennen, dass bereits das einfache Verfahren zur Transformierung des Mittelwertes gute Ergebnisse für Niederschlagssummen und Ereignisanzahl erzielt. Das Quotienten-Verfahren weist ebenfalls recht passable Ergebnisse auf, zeigt allerdings eine leichte Schwäche für die Kennwerte des Sommers. Als drittes Modell überzeugt die Quantil-Quantil-Transformation. Der einzige Kennwert, der hier etwas größere Abweichungen zeigt, ist die Anzahl an Ereignissen im Sommer bei der Transformation zu 2071-2100. Diese Schwäche haben jedoch auch die anderen Methoden.

Tabelle 9-7 Mittlere Änderungen [%] über alle Stationen der saisonalen Niederschlagssummen für drei Verfahren, Version mit acht GWL

| Transformationszeitraum | Saisonale Niederschlagssummen | | | |
|-----------------------------------|-------------------------------|----------------------------------|----------------------|--------------------------------|
| Beobachtungszeitraum zu 2021-2050 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | 5 | 7 | 7 | 6 |
| Winter | 9 | 10 | 10 | 9 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | -9 | -9 | -15 | -7 |
| Winter | 20 | 23 | 18 | 21 |

Tabelle 9-8 Mittlere Änderungen [%] über alle Stationen der Anzahl an Ereignissen pro Saison für drei Verfahren, Version mit acht GWL

| Transformationszeitraum | Anzahl an Ereignissen pro Saison | | | |
|-----------------------------------|----------------------------------|----------------------------------|----------------------|--------------------------------|
| Beobachtungszeitraum zu 2021-2050 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | -2 | -3 | -2 | -3 |
| Winter | 2 | 3 | 2 | 3 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | -12 | -14 | -15 | -15 |
| Winter | 1 | 2 | 1 | 2 |

Es konnte also festgestellt werden, dass alle drei Verfahren die Ereignisanzahlen und Niederschlagssummen gut wiedergeben. Im Anschluss wurden die Mittelwerte der Ereignisvolumen *wsa* betrachtet. Diese Kenngröße geht nicht direkt in die Transferfunktionen ein, sondern leitet sich aus den *wsd* und *wsi* ab. In Tabelle 9-9 ist zu erkennen, dass auch diese Kenngröße durch alle drei Verfahren gut reproduziert wird.

Allerdings zeigen die Transformierung des Mittelwertes im Winter des ersten Zeitraumes sowie das Quotienten-Verfahren und die Quantil-Quantil-Transformation im Sommer des zweiten Zeitraumes leichte Abweichungen.

Tabelle 9-9 Mittlere Änderungen [%] über alle Stationen der mittleren Ereignisvolumen für drei Verfahren, Version mit acht GWL

| Transformations-zeitraum | Mittlere Ereignisvolumen | | | |
|-----------------------------------|--------------------------|----------------------------------|----------------------|--------------------------------|
| Beobachtungszeitraum zu 2021-2050 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | 8 | 8 | 7 | 9 |
| Winter | 6 | 9 | 6 | 6 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | 6 | 5 | 1 | 9 |
| Winter | 20 | 20 | 17 | 19 |

Da die generierten Niederschlagsdaten als Eingangsgrößen für die hydrologische Modellierung vorgesehen wurden, haben die Extremwerte eine besondere Bedeutung. Tabelle 9-10 und Tabelle 9-11 zeigen beispielhaft die Veränderungen der gemäß Abschnitt 5.2.1.2 gewichteten stündlichen und 24-stündlichen Extremwerte ($D_{\text{sign,w}}$). Es wurden zusätzlich zu den gezeigten auch die 3-, 6- und 12-Stundenwert-Extrema betrachtet. Da diese aber vergleichbare Ergebnisse zeigen, werden sie hier nicht dargestellt. Der erste Punkt, der auffällt, hat nichts mit den zu vergleichenden Methoden zu tun. Interessanterweise sind die Änderungen der 24-stündlichen Extremwerte in den Sommermonaten für den nahen Zeitraum größer als für den fernen. Zur Erinnerung: Die Sommer-Extrema sind deutlich größer. Diese Erkenntnis zeigt sich auch für die ungewichteten Extremwerte. Die Ergebnisse beinhalten allerdings große Unsicherheiten, da nur ein REMO-Durchlauf betrachtet wurde.

Tabelle 9-10 Mittlere Änderungen [%] über alle Stationen der gewichteten 1-stündlichen Extremwerte für drei Verfahren, Version mit acht GWL

| Transformations-zeitraum | Stündliche Extremwerte | | | |
|-----------------------------------|------------------------|----------------------------------|----------------------|--------------------------------|
| Beobachtungszeitraum zu 2021-2050 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | 7 | 8 | 2 | 9 |
| Winter | 2 | 10 | 3 | 5 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | 14 | 1 | 2 | 18 |
| Winter | 17 | 18 | 11 | 14 |

Die Ergebnisse zeigen, dass die Quantil-Quantil-Transformation eindeutig das beste Ergebnis liefert. Nachdem die Methode mit Transformierung des Mittelwertes bereits für die statistischen Momente höherer Ordnung schlechte Ergebnisse gezeigt hatte, war es wenig überraschend, dass sich dies für die Extremwerte wiederholte. Anders sieht es mit dem Quotienten-Verfahren aus, das trotz der sehr guten Erfassung der Änderung in den statistischen Momenten die Extremwerte deutlich schlechter reproduziert als die Quantil-Quantil-Transformation.

Tabelle 9-11 Mittlere Änderungen [%] über alle Stationen der gewichteten 24-stündlichen Extremwerte für drei Verfahren, Version mit acht GWL

| Transformationszeitraum | 24-stündliche Extremwerte | | | |
|-----------------------------------|---------------------------|----------------------------------|----------------------|--------------------------------|
| Beobachtungszeitraum zu 2021-2050 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | 12 | 9 | 8 | 15 |
| Winter | 9 | 12 | 7 | 8 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Transformierung des Mittelwertes | Quotienten-Verfahren | Quantil-Quantil-Transformation |
| Sommer | 8 | -2 | -2 | 15 |
| Winter | 26 | 21 | 20 | 21 |

Für den Vergleich der drei Verfahren wurden bewusst die gewichteten Extremwerte betrachtet, da in diese die für viele hydrologische Anwendungen besonders relevanten seltenen Extremwerte stärker eingehen. Tabelle 9-12 macht deutlich, dass die bereits in der gewichteten Betrachtung festgestellten Überschätzungen der Veränderungen in den ungewichteten sommerlichen Extremwerten wesentlich stärker auftreten. Allerdings sind die Werte immer noch in einem akzeptablen Rahmen. Das bedeutet, dass die Änderungen in den kleinen Extremwerten stärker überschätzt werden als die seltenen Extremwerte.

Tabelle 9-12 Mittlere Änderungen [%] über alle Stationen der gewichteten und ungewichteten 24-stündlichen Extremwerte für die Quantil-Quantil-Transformation, Version mit acht GWL; Transformationszeitraum: Beobachtungszeitraum zu 2021-2050

| | gewichtet | | ungewichtet | |
|---------------------------|-----------|-------------|-------------|-------------|
| 1-stündliche Extremwerte | REMO | Downscaling | REMO | Downscaling |
| Sommer | 7 | 9 | 9 | 12 |
| Winter | 2 | 5 | 1 | 5 |
| 24-stündliche Extremwerte | REMO | Downscaling | REMO | Downscaling |
| Sommer | 12 | 15 | 15 | 20 |
| Winter | 9 | 8 | 7 | 10 |

Tabelle 9-13 und Tabelle 9-14 vergleichen die Ergebnisse des Downscaling unter ausschließlicher Verwendung der GWL-Transformation, unter ausschließlicher Verwendung der Quantil-Quantil-Transformation und unter Verwendung beider Transformationen in Kombination. Man erkennt hier sehr deutlich, dass die GWL-Transformation einen eher geringen Einfluss hat. Aber erwartungsgemäß zeigt die Kombination aus beiden Transformationen das beste Resultat. Bei Betrachtung der Werte muss beachtet werden, dass die einzelnen Werte der Transformationen aufsummiert, wegen vorhandener Wechselwirkungen, nicht exakt das Ergebnis der Kombination ergeben. Das Ergebnis wird durch die Analyse der Extremwerte bestätigt (siehe Tabelle 9-15).

Tabelle 9-13 Mittlere Änderungen [%] über alle Stationen der saisonalen Niederschlagssummen, Version mit acht GWL

| Transformations- zeitraum | Saisonale Niederschlagssummen | | | |
|--------------------------------------|-------------------------------|----------------------------|--|--|
| Beobachtungszeitraum zu 2021-2050 | REMO | Nur GWL- Transformation | Nur Quantil- Quantil- Transformation | Quantil-Quantil- Transformation + GWL-Transformation |
| Sommer | 5 | -2 | 7 | 6 |
| Winter | 9 | 2 | 6 | 9 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Nur GWL- Transformation | Nur Quantil- Quantil- Transformation | Quantil-Quantil- Transformation + GWL-Transformation |
| Sommer | -9 | -2 | -4 | -7 |
| Winter | 20 | 1 | 18 | 21 |

Tabelle 9-14 Mittlere Änderungen [%] über alle Stationen der Anzahl an Ereignissen pro Jahr, Version mit acht GWL

| Transformations- zeitraum | Anzahl Ereignisse pro Jahr | | | |
|--------------------------------------|----------------------------|----------------------------|--|--|
| Beobachtungszeitraum zu 2021-2050 | REMO | Nur GWL- Transformation | Nur Quantil- Quantil- Transformation | Quantil-Quantil- Transformation + GWL-Transformation |
| Sommer | -2 | -2 | -1 | -3 |
| Winter | 2 | 1 | 2 | 3 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Nur GWL- Transformation | Nur Quantil- Quantil- Transformation | Quantil-Quantil- Transformation + GWL-Transformation |
| Sommer | -12 | -1 | -11 | -15 |
| Winter | 1 | 0 | 1 | 2 |

Tabelle 9-15 Mittlere Änderungen [%] über alle Stationen der gewichteten 1- und 24-stündlichen Extremwerte, Version mit acht GWL, Transformationszeitraum: Beobachtungszeitraum zu 2071-2100

| Transformationszeitraum | Extremwerte | | | |
|-------------------------|-------------|------------------------|------------------------------------|---|
| Stündliche Werte | REMO | Nur GWL-Transformation | Nur Quantil-Quantil-Transformation | Quantil-Quantil-Transformation + GWL-Transformation |
| Sommer | 14 | -3 | 21 | 18 |
| Winter | 17 | 1 | 13 | 14 |
| 24-stündliche Werte | REMO | Nur GWL-Transformation | Nur Quantil-Quantil-Transformation | Quantil-Quantil-Transformation + GWL-Transformation |
| Sommer | 8 | -2 | 17 | 15 |
| Winter | 26 | 1 | 19 | 21 |

Auch die Unterschiede zwischen den Modellvarianten ohne GWL, mit zwei GWL, vier GWL und acht GWL sind von Interesse. Für diesen Vergleich wird jeweils die Modellvariante Quantil-Quantil-Transformation mit GWL-Transformation verwendet, mit Ausnahme des Modells ohne GWL.

Tabelle 9-16, Tabelle 9-17 und Tabelle 9-18 fassen die Ergebnisse der Vergleiche zusammen, wobei verschiedene Modellaufbauten offensichtlich zu geringen Unterschieden führen. In manchen Bereichen zeigen die Versionen mit GWL bessere Ergebnisse, in anderen die Versionen ohne GWL. Bei den Extremwerten (Tabelle 9-18) werden die Änderungen der stündlichen Extremwerte besser ohne GWL wiedergegeben; die der höheren Dauerstufen dagegen besser mit GWL. Dieses Ergebnis passt zu der Erkenntnis, dass die Verwendung von GWL in der Niederschlagsmodellierung zu einer besseren Reproduktion der Extremwerte in Dauerstufen größer als eine Stunde und einer schlechteren der stündlichen Extremwerte führte (siehe Abschnitt 5.2.2.5). Eine spezielle Version der GWL-Anzahl kann anhand der Ergebnisse nicht favorisiert werden.

Tabelle 9-16 Mittlere Änderungen [%] über alle Stationen der Niederschlagssummen für die Quantil-Quantil-Transformation, Version ohne GWL, mit zwei, vier und acht GWL

| Transformationszeitraum | Niederschlagssummen | | | | |
|-----------------------------------|---------------------|----------|-----------|-----------|-----------|
| Beobachtungszeitraum zu 2021-2050 | REMO | Ohne GWL | Mit 2 GWL | Mit 4 GWL | Mit 8 GWL |
| Sommer | 5 | 4 | 6 | 6 | 6 |
| Winter | 9 | 7 | 8 | 7 | 9 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Ohne GWL | Mit 2 GWL | Mit 4 GWL | Mit 8 GWL |
| Sommer | -9 | -8 | -5 | -6 | -7 |
| Winter | 20 | 19 | 19 | 18 | 21 |

Tabelle 9-17 Mittlere Änderungen [%] über alle Stationen der Anzahl an Ereignissen pro Saison für die Quantil-Quantil-Transformation, Version ohne GWL, mit zwei, vier und acht GWL

| Transformationszeitraum | Anzahl an Ereignissen pro Saison | | | | |
|-----------------------------------|----------------------------------|----------|-----------|-----------|-----------|
| Beobachtungszeitraum zu 2021-2050 | REMO | Ohne GWL | Mit 2 GWL | Mit 4 GWL | Mit 8 GWL |
| Sommer | -2 | -3 | -3 | -2 | -3 |
| Winter | 2 | 2 | 2 | 3 | 3 |
| Beobachtungszeitraum zu 2071-2100 | REMO | Ohne GWL | Mit 2 GWL | Mit 4 GWL | Mit 8 GWL |
| Sommer | -12 | -14 | -13 | -14 | -15 |
| Winter | 1 | 2 | 2 | 2 | 2 |

Tabelle 9-18 Mittlere Änderungen [%] über alle Stationen der gewichteten stündlichen, 6-stündlichen und 24-stündlichen Extremwerte für die Quantil-Quantil-Transformation, Version ohne GWL, mit zwei, vier und acht GWL, Transformationszeitraum: Beobachtungszeitraum zu 2021-2050

| Transformationszeitraum | Extremwerte | | | | |
|-------------------------|-------------|----------|-----------|-----------|-----------|
| 1-stündliche Werte | REMO | Ohne GWL | Mit 2 GWL | Mit 4 GWL | Mit 8 GWL |
| Sommer | 7 | 8 | 10 | 11 | 9 |
| Winter | 2 | 1 | 1 | 2 | 5 |
| 6-stündliche Werte | REMO | Ohne GWL | Mit 2 GWL | Mit 4 GWL | Mit 8 GWL |
| Sommer | 10 | 14 | 15 | 15 | 14 |
| Winter | 6 | 2 | 3 | 3 | 7 |
| 24-stündliche Werte | REMO | Ohne GWL | Mit 2 GWL | Mit 4 GWL | Mit 8 GWL |
| Sommer | 12 | 11 | 13 | 15 | 15 |
| Winter | 9 | 3 | 4 | 4 | 8 |

10 Zusammenfassung und Ausblick

In dieser Arbeit wurde der Einfluss der Verwendung von Großwetterlagen auf die Ergebnisse eines Alternating-Renewal-Niederschlagsmodells untersucht. Dabei wurden objektiv klassifizierte GWL benutzt sowie das zweistufige Stundenwert-Niederschlagsmodell nach Haberlandt et al. (2008) angepasst und weiterentwickelt. Die GWL wurden für Niedersachsen mittels eines auf Fuzzy-Methoden basierenden Modells nach Bárdossy (2010) bestimmt (siehe Haberlandt et al. (2011)). Es wurden acht GWL definiert und klassifiziert. Diese wurden zu Versionen mit je vier bzw. zwei GWL-Klassen zusammengefasst.

Die Parameter des Niederschlagsmodells wurden anhand von beobachteten hochaufgelösten Niederschlagsdaten des DWD und Meteomedias bestimmt. Für die Bestimmung der GWL wurden Luftdruckdaten aus der NCAR- Reanalyse sowie tägliche Niederschlagsdaten des DWD und für das Downscaling zusätzlich Luftdruckdaten des ECHAM5/MPI-OM-Klimamodells und Niederschlagsdaten des regionalen Klimamodells REMO verwendet.

Zuerst wurde das ARP-Modell an das neue Untersuchungsgebiet angepasst, indem die für das Gebiet optimalen Verteilungsfunktionen ausgewählt wurden. In der Auswahl der optimalen Verteilungsfunktionen wurden die GWL bereits berücksichtigt. Anschließend wurden die Modellparameter der GWL für den univariaten Teil des Modells angepasst, indem jeder GWL ein eigener Parametersatz zugewiesen wurde. Bei der Generierung wurde die GWL-Häufigkeit in den Ereignissen nachgebildet. Durch die Berücksichtigung der GWL konnten folgende Kennwerte in der Synthese besser reproduziert werden:

- die statistischen Momente der Ereignischarakteristika (leichte Verbesserungen),
- die synthetischen Niederschlagsjahreswerte und
- die Niederschlagsextrema in allen Zeitschritten, mit Ausnahme der Stundenwertextrema

Hierauf folgte die Optimierung hinsichtlich räumlicher Konsistenz mittels eines Simulated Annealing-Verfahrens, das um GWL-Frequenz, -Gleichzeitigkeit und -Abfolge erweitert wurde. Die Optimierung hinsichtlich der GWL konnte sehr zufriedenstellend realisiert werden, ohne dass die zusätzlichen Elemente der Zielfunktion des Simulated Annealing die Reproduktion der räumlichen Konsistenz verschlechterten.

Anschließend wurde der Einfluss der GWL auf weitere Niederschlagscharakteristika untersucht. Den ersten Schritt bildeten Analysen des Einflusses auf den Zusammenhang von Niederschlag und weiteren Klimavariablen. Die Untersuchungen wurden mittels Betrachtung der Korrelationen vorgenommen. Die einzige Kenngröße, bei der eine nennenswerte Korrelation zum Niederschlag festgestellt wurde, war die Sonnenscheindauer. Diese Korrelation konnte zu einem geringen Anteil durch Verwendung von GWL reproduziert werden.

Die Betrachtung des Zusammenhanges von Niederschlag und Klima war also aufgrund der fehlenden nachweisbaren quantifizierbaren Korrelationen schwer analysierbar. Daher wurden weitere Untersuchungen vorgenommen, z. B. der Vergleich der Durchschnittstemperaturen, die während der einzelnen GWL vorherrschten. Es konnte auf diese Weise ein deutlicher Zusammenhang zwischen den GWL und den Temperaturen nachgewiesen werden, der auch in der Synthese mit GWL reproduziert werden konnte. Dieser für die Niederschlags-Abfluss-Modellierung höchst relevante Effekt könnte vermutlich verstärkt werden, wenn neben den Niederschlagsdaten auch Temperatur- und weitere Klimadaten bereits in der Zielfunktion der GWL-Klassifikation berücksichtigt würden. Dies wurde von Bárdossy et al. (2002) bereits mit Temperaturdaten durchgeführt. Es wäre daher von Interesse, die hier vorgestellten Arbeiten mit dieser Form von GWL fortzuführen.

Ein interessanter Aspekt war, dass die sehr leichte Autokorrelation in den Niederschlagsereignissen der Beobachtung in der Modellierung durch Berücksichtigung der GWL größtenteils reproduziert werden konnte. Ein anderer, einfacherer, Ansatz zur Lösung dieses Problems wäre, es eine längere Trockendauer zur Ereignistrennung anzusetzen; dies führt allerdings nicht immer zu gleich guten Ergebnissen. Mit den GWL kann dieses Problem umgangen werden.

Es konnte nachgewiesen werden, dass univariat generierte Niederschlagsdaten alleine durch die Berücksichtigung von GWL eine geringe räumliche Persistenz aufweisen.

Auf den Jahresgang der Niederschlagsdaten haben die GWL kaum nachweisbaren Einfluss.

Einen weiteren wichtigen Gegenstand der Arbeit bildete die räumliche Übertragbarkeit der Modellparameter mit dem Ziel, das Modell auf Gebiete anzuwenden, an denen keine beobachteten Niederschlagsdaten vorhanden sind. Es sollte geklärt werden, ob das Vorgehen nach Haberlandt et al. (2008) auch mit dem an GWL angepassten Modell anwendbar ist. Als Ergebnis ist festzuhalten, dass das Modell mittels einiger Anpassungen gut einsetzbar ist. Eine weitere Erkenntnis war, dass die *wsi* eine sehr geringe räumliche Variabilität aufweisen. Ob dies für eine räumliche Übertragbarkeit ein Vorteil oder ein Nachteil ist, müsste in weiteren Arbeiten untersucht werden.

Den Abschluss der Arbeit bildete die Anwendung des weiterentwickelten Niederschlagsmodells für ein Downscaling. Es wurde ursprünglich davon ausgegangen, dass die Transformation der GWL-Häufigkeiten ausreichen würde, um mit dem Modell zukünftige Zustände des Niederschlags abzubilden. Dieser Ansatz wurde jedoch in Untersuchungen negiert (siehe Haberlandt et al. (2015)), da sich nicht nur die Häufigkeiten der GWL mit der Zeit verändern, sondern auch die Eigenschaften der GWL. Auch die Untersuchungen der vorliegenden Arbeit bestätigten dies. Die Transformation der GWL-Häufigkeiten erklärt nur einen Teil der Veränderungen im Niederschlagsgeschehen. Daher wurden verschiedene Ansätze zur Transformation der Modellparameter entwickelt. Als erfolgreichster Ansatz zeigte sich eine Quantil-Quantil-Transformation der Ereigniszeitreihe als Vorstufe für die Modellparameterbestimmung. Mit der Kombination von GWL- und Ereignis-Transformation konnte somit ein erfolgreiches Downscaling durchgeführt werden. Die Ergebnisse der Transformation entsprechen qualitativ allerdings in etwa den Ergebnissen des Downscalings ohne jedwede Betrachtung von GWL. Die übrigen hier genannten Vorteile der Berücksichtigung von GWL in der Modellierung gelten allerdings auch für das Downscaling. Wenn das Modell bereits an GWL angepasst wurde, ist der zusätzliche Aufwand der Berücksichtigung der GWL im Downscaling gering. Es muss lediglich zusätzlich eine sehr einfache Transformation der GWL-Häufigkeiten erfolgen.

Bei den Untersuchungen wurde mit verschiedenen Anzahlen von GWL experimentiert. Dadurch sollte herausgefunden werden, ob und wie sich das Zeitreihen-diskriminierende Verhalten der GWL gegenüber der Verkürzung der Beobachtungszeitreihen auswirkt. Dies führte allerdings zu keinem klaren Ergebnis. Zum Teil ergaben sich die besseren Ergebnisse durch Verwendung von vielen GWL, zum Teil aber durch die Nutzung von zu einigen wenigen Klassen zusammengefassten GWL.

Insgesamt kann festgestellt werden, dass die Verwendung von GWL in der Niederschlagsmodellierung mit einem ARP-Modell zu nachweisbaren Verbesserungen geführt hat. Allerdings ist der Aufwand der Implementierung der GWL in das Modell sehr hoch und die Anzahl der benötigten Modellparameter deutlich höher als bei einem Modell ohne Verwendung von GWL. In den meisten Anwendungsfällen dürften die festgestellten Verbesserungen diesen hohen Aufwand nicht rechtfertigen.

Für das verwendete ARP-Modell wurde eine sehr bedeutende Verbesserung eingeführt. In der bisherigen Form führte die räumliche Optimierung mittels Simulated Annealings zu Verschiebungen und Vermischungen in der Saisonalität. Zu Ende der Optimierung war eine Saisonalität in den Daten kaum noch vorhanden. Dieses Problem wurde behoben (siehe Abschnitt 7.2.1).

Weitere Arbeiten sollten mit folgenden Zielrichtungen durchgeführt werden: Es wäre von höchstem Interesse, das zusammenhängende Modellieren von Niederschlag und Klimadaten weiter zu untersuchen. Die Ergebnisse der vorliegenden Arbeit zeigen, dass die GWL hierfür ein großes Potential bieten. Es wäre auch interessant zu analysieren, wie sich die Berücksichtigung von GWL auf die Modellierungsergebnisse mit anderen Dauerstufen auswirkt. Das hier vorgestellte Modell könnte für längere oder kürzere Zeitschritte ausgelegt werden.

Schließlich sollten zwei weitere mögliche Arbeiten erwähnt werden, die nicht in direktem Zusammenhang mit den GWL stehen und die hier durchgeführten Arbeiten somit nur bedingt betreffen. Zum einen ergab sich eine nicht zufriedenstellende Reproduktion der Feinstruktur des Niederschlags durch das Modell. Die Autokorrelation der Stundenwerte wird durch das Modell deutlich überschätzt und die der Tageswerte unterschätzt. Der Grund hierfür dürfte der zu einfache Prozess zur Generierung der Feinstruktur sein. Hier besteht Verbesserungsbedarf. Zum anderen wurde ein Ansatz entwickelt, um das Simulated Annealing auf objektorientierte und Zeiger-basierte Programmierung umzustellen (siehe Abschnitt 7.2.1). Eine zielgerichtete Implementierung dieses Ansatzes könnte den Rechenaufwand erheblich reduzieren.

11 Literatur

- Abdul-Aziz, A.R., Anokye, M., Kwame, A., Munyakazi, L., Nsowah-Nuamah, N. (2013): Modeling and Forecasting Rainfall Pattern in Ghana as a Seasonal Arima Process: The Case of Ashanti Region. *International Journal of Humanities and Social Science* 3 (3), 224–233
- Acreman, M.C. (1990): A simple stochastic model of hourly rainfall for Farnborough, England. *Hydrological Sciences Journal* 35 (2), 119–148
- Alam, M.M. (2011): Statistical downscaling of extremes of precipitation in mesoscale catchments from different RCMs and their effects on local hydrology: Dissertation, Universität Stuttgart
- Anderson, T.W. (1962): On the Distribution of the Two-Sample Cramer-von Mises Criterion. *Annals of Mathematical Statistics* 33 (3), 1148–1159
- Asquith, W.H. (2011): Distributional analysis with L-moment statistics using the R environment for statistical computing; CreateSpace Independent Publishing Platform
- Bárdossy, A. (1998): Generating precipitation time series using simulated annealing. *Water Resources Research* 34 (7), 1737–1744
- Bárdossy, A. (2010): Atmospheric circulation pattern classification for South-West Germany using hydrological variables. *Physics and Chemistry of the Earth, Parts A/B/C* 35 (9-12), 498–506
- Bárdossy, A., Brommundt, J. (2008): Erzeugung simultan-synthetischer Niederschlagsreihen hoher zeitlicher und räumlicher Auflösung für Baden-Württemberg. Institut für Wasserbau, Lehrstuhl für Hydrologie und Geohydrologie, Stuttgart
- Bárdossy, A., Caspary, H.J. (1990): Detection of climate change in Europe by analyzing European atmospheric circulation patterns from 1881 to 1989. *Theor Appl Climatol* 42 (3), 155–167
- Bárdossy, A., Duckstein, L., Bogardi, I. (1995): Fuzzy rule-based classification of atmospheric circulation patterns. *Int. J. Climatol.* 15 (10), 1087–1097
- Bárdossy, A., Filiz, F. (2005): Identification of flood producing atmospheric circulation patterns. *Journal of Hydrology* 313 (1-2), 48–57
- Bárdossy, A., Pegram, G. (2011): Downscaling precipitation using regional climate models and circulation patterns toward hydrology. *Water Resour. Res.* 47 (4), 18 S.
- Bárdossy, A., Pegram, G. (2012): Multiscale spatial recorrelation of RCM precipitation to produce unbiased climate change scenarios over large areas and small. *Water Resour. Res.* 48 (9), 1–13
- Bárdossy, A., Plate, E.J. (1991): Modeling daily rainfall using a semi-Markov representation of circulation pattern occurrence. *Journal of Hydrology* 122 (1-4), 33–47
- Bárdossy, A., Plate, E.J. (1992): Space-time model for daily rainfall using atmospheric circulation patterns. *Water Resour. Res.* 28 (5), 1247–1259
- Bárdossy, A., Stehlík, J., Caspary, H.J. (2002): Automated objective classification of daily circulation patterns for precipitation and temperature downscaling based on optimized fuzzy rules. *Clim. Res.* 23, 11–22
- Baur, F. (Hrsg.) (1963): Großwetterkunde und langfristige Witterungsvorhersage, Bad Homburg v. d. Höhe, 26. - 28. 10.1961; Akad. Verl.-Ges., Frankfurt
- Baur, F., Hess, P., Nagel, H. (1944): Kalender der Großwetterlagen Europas 1881-1939, Bad Homburg v. d. Höhe

- Beersma, J.J., Buishand, T.A. (2003): Multi-site simulation of daily precipitation and temperature conditional on the atmospheric circulation. *Clim. Res.* 25, 121–133
- Benestad, R.E. (2010): Downscaling precipitation extremes. *Theor Appl Climatol* 100 (1-2), 1–21
- Bernardara, P., Michele, C. de, Rosso, R. (2007): A simple model of rain in time: An alternating renewal process of wet and dry states with a fractional (non-Gaussian) rain intensity. *Atmospheric Research* 84 (4), 291–301
- Bogardi, I., Matyasovszky, I., Bardossy, A., Duckstein, L. (1993): Application of a space-time stochastic model for daily precipitation using atmospheric circulation patterns. *Journal of Geophysical Research: Atmospheres* 98 (D9), 16653–16667
- Box, G., Jenkins, G.M., Reinsel, G.C. (2008): *Time series analysis: Forecasting and control*, 4th Edition, 4. Aufl. Wiley series in probability and statistics; John Wiley, Hoboken (NJ, USA)
- Brommundt, J. (2008): *Stochastische Generierung räumlich zusammenhängender Niederschlagszeitreihen*. Mitteilungen / Institut für Wasserbau, Universität Stuttgart, H. 170; Inst. für Wasserbau, Stuttgart
- Bronstein, I.N., Semendjajew, K.A. (2000): *Taschenbuch der Mathematik*, 5. Aufl.; Harri Deutsch, Thun [u.a.]
- Buishand, T.A. (1978): Some remarks on the use of daily rainfall models. *Journal of Hydrology* 36 (3-4), 295–308
- Buishand, T.A., Brandsma, T. (1997): Comparison of circulation classification schemes for predicting temperature and precipitation in the Netherlands. *International Journal of Climatology* 17 (8), 875–889
- Burian, S.J., Durrans, S.R., Tomić, S., Pimmel, R.L., Wai, C.N. (2000): Rainfall disaggregation using artificial neural networks. *J. Hydrol. Eng.* 5 (3), 299–307
- Burlando, P., Rosso, R., Cadavid, L.G., Salas, J.D. (1993): Forecasting of short-term rainfall using ARMA models. *Journal of Hydrology* 144 (1-4), 193–211
- Burton, A., Kilsby, C.G., Fowler, H.J., Cowpertwait, P., O'Connell, P.E. (2008): RainSim: A spatial-temporal stochastic rainfall modelling system. *Environmental Modelling & Software* 23 (12), 1356–1369
- Carreau, J., Vrac, M. (2011): Stochastic downscaling of precipitation with neural network conditional mixture models. *Water Resources Research* 47 (10)
- Cârsteanu, A., Venugopal, V., Foufoula-Georgiou, E. (1999): Event-specific multiplicative cascade models and an application to rainfall. *J. Geophys. Res.* 104 (D24), 31611–31622
- Chang, T.J., Kavvas, M.L., Delleur, J.W. (1984): Modeling of Sequences of Wet and Dry Days by Binary Discrete Autoregressive Moving Average Processes. *Journal of Climate and Applied Meteorology* 23 (9), 1367–1378
- Chen, H., Xu, C.-Y., Guo, S. (2012a): Comparison and evaluation of multiple GCMs, statistical downscaling and hydrological models in the study of climate change impacts on runoff. *Journal of Hydrology* 434-435, 36–45
- Chen, J., Brissette, F.P., Leconte, R. (2011): Uncertainty of downscaling method in quantifying the impact of climate change on hydrology. *Journal of Hydrology* 401 (3-4), 190–202
- Chen, J., Brissette, F.P., Leconte, R. (2012b): Coupling statistical and dynamical methods for spatial downscaling of precipitation. *Climatic Change* 114 (3-4), 509–526

- Chin, E.H. (1977): Modeling daily precipitation occurrence process with Markov Chain. *Water Resources Research* 13 (6), 949–956
- Connolly, R.D., Schirmer, J., Dunn, P.K. (1998): A daily rainfall disaggregation model. *Agricultural and Forest Meteorology* 92 (2), 105–117
- Corte-Real, J., Qian, B., Xu, H. (1998): Regional climate change in Portugal: precipitation variability associated with large-scale atmospheric circulation. *International Journal of Climatology* 18 (6), 619–635
- Corte-Real, J., Xu, H., Qian, B. (1999): A weather generator for obtaining daily precipitation scenarios based on circulation patterns. *Clim. Res.* 13, 61–75
- Coulibaly, P., Dibike, Y.B., Anctil, F. (2005): Downscaling Precipitation and Temperature with Temporal Neural Networks. *Journal of Hydrometeorology* 6 (4), 483–496
- Cowpertwait, P. (1994): A Generalized Point Process Model for Rainfall. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 447 (1929), 23–37
- Cowpertwait, P. (1998): A Poisson-cluster model of rainfall: some high-order moments and extreme values. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 454 (1971), 885–898
- Cowpertwait, P., Lockie, T., Davis, M.D. (2004): A stochastic spatial-temporal disaggregation model for rainfall. *Research Letters in the Information and Mathematical Sciences* 6, 109–122
- Cowpertwait, P.S. (2006): A spatial–temporal point process model of rainfall for the Thames catchment, UK. *Journal of Hydrology* 330 (3–4), 586–595
- Croley, T.E., Eli, R.N., Cryer, J.D. (1978): Ralston Creek hourly precipitation model. *Water Resour. Res.* 14 (3), 485–490
- Dalezios, N.R., Adamowski, K. (1995): Spatio-temporal precipitation modelling in rural watersheds. *Hydrological Sciences Journal* 40 (5), 553–568
- De Michele, C. (2003): A Generalized Pareto intensity-duration model of storm rainfall exploiting 2-Copulas. *J. Geophys. Res.* 108 (D2)
- De Michele, C., Salvadori, G. (2003): A Generalized Pareto intensity-duration model of storm rainfall exploiting 2-Copulas. *Journal of Geophysical Research: Atmospheres* 108 (D2)
- Deutsch, C.V., Journel, A.G. (1997): *GSLIB: Geostatistical software library and user's guide*, 2. Aufl.; Oxford University Press, New York (NY, USA)
- Eagleson, P.S. (1978): Climate, soil, and vegetation: 2. The distribution of annual precipitation derived from observed storm sequences. *Water Resour. Res.* 14 (5), 713–721
- Embrechts, P., Lindskog, F., McNeil, A. (2003): Chapter 8 - Modelling Dependence with Copulas and Applications to Risk Management. Svetlozar T. R. (Hg.), *Handbook of Heavy Tailed Distributions in Finance*, 329–384
- Entekhabi, D., Rodriguez-Iturbe, I., Eagleson, P.S. (1989): Probabilistic representation of the temporal rainfall process by a modified Neyman-Scott Rectangular Pulses Model: Parameter estimation and validation. *Water Resources Research* 25 (2), 295–302
- Evin, G., Favre, A.-C. (2008): A new rainfall model based on the Neyman-Scott process using cubic copulas. *Water Resources Research* 44 (3)
- Flaounas, E., Drobinski, P., Vrac, M., Bastin, S., Lebeaupin-Brossier, C., Stéfanon, M., Borga, M., Calvet, J.-C. (2013): Precipitation and temperature space–time variability and extremes in the

- Mediterranean region: evaluation of dynamical and statistical downscaling methods. *Climate Dynamics* 40 (11-12), 2687–2705
- Franz, D.D. (1970): Hourly Rainfall Synthesis for a Network of Stations; Stanford University, Stanford (Kalifornien, USA)
- Gabriel, K.R., Neumann, J. (1962): A Markov chain model for daily rainfall occurrence at Tel Aviv. *Quarterly Journal of the Royal Meteorological Society* 88 (375), 90–95
- Garavaglia, F., Gailhard, J., Paquet, E., Lang, M., Garçon, R., Bernardara, P. (2010): Introducing a rainfall compound distribution model based on weather patterns sub-sampling. *Hydrol. Earth Syst. Sci.* 14 (6), 951–964
- Gaume, E., Mouhous, N., Andrieu, H. (2007): Rainfall stochastic disaggregation models: Calibration and validation of a multiplicative cascade model. *Advances in Water Resources* 30 (5), 1301–1319
- Genest, C., Mackay, J. (1986): The Joy of Copulas: Bivariate Distributions with Uniform Marginals. *The American Statistician* 40 (4), 280–283
- Goodess, C.M., Jones, P.D. (2002): Links between circulation and changes in the characteristics of Iberian rainfall. *Int. J. Climatol.* 22 (13), 1593–1615
- Goovaerts, P. (1997): Geostatistics for natural resources evaluation. Applied geostatistics series; Oxford University Press, New York
- Green, J.R. (1964): A Model for Rainfall Occurrence. *Journal of the Royal Statistical Society. Series B (Methodological)* 26 (2), 343–353
- Greenwood, J.A., Landwehr, J.M., Matalas, N.C., Wallis, J.R. (1979): Probability weighted moments: definition and relation to parameters of several distributions expressible in inverse form. *Water Resources Research* 15 (5), 1049–1054
- Gudmundsson, L., Bremnes, J.B., Haugen, J.E., Engen-Skaugen, T. (2012): Technical Note: Downscaling RCM precipitation to the station scale using statistical transformations – a comparison of methods. *Hydrology and Earth System Sciences* 16 (9), 3383–3390
- Guenni, L., Bárdossy, A. (2002): A two steps disaggregation method for highly seasonal monthly rainfall. *Stochastic Environmental Research and Risk Assessment (SERRA)* 16 (3), 188–206
- Guenni, L., Hutchinson, M.F. (1998): Spatial interpolation of the parameters of a rainfall model from ground-based data. *Journal of Hydrology* 212-213, 335–347
- Güntner, A., Olsson, J., Calver, A., Gannon, B. (2001): Cascade-based disaggregation of continuous rainfall time series: the influence of climate. *Hydrology and Earth System Sciences* 5 (2), 145–164
- Gupta, V.K., Waymire, E.C. (1993): A statistical analysis of mesoscale rainfall as a random cascade. *Journal of Climate and Applied Meteorology* 32, 251–267
- Haan, C.T., Allen, D.M., Street, J.O. (1976): A Markov Chain Model of daily rainfall. *Water Resources Research* 12 (3), 443–449
- Haberlandt, U. (1996): Stochastische Synthese und Regionalisierung des Niederschlages für Schmutzfrachtberechnungen: Dissertation. Universität Stuttgart, Stuttgart (Deutschland)
- Haberlandt, U. (1998): Stochastic rainfall synthesis using regionalized model parameters. *J. Hydrol. Eng.* 3 (3), 160–168
- Haberlandt, U., Belli, A., Bárdossy, A. (2011): Eignung von Großwetterlagen als Prämisse für das statistische Niederschlagsdownscaling. *Forum für Hydrologie und Wasserbewirtschaftung, Tag der Hydrologie* 30 (11), 136–143

- Haberlandt, U., Belli, A., Bárdossy, A. (2015): Statistical downscaling of precipitation using a stochastic rainfall model conditioned on circulation patterns - an evaluation of assumptions. *Int. J. Climatol.* 35 (3), 417–432
- Haberlandt, U., Belli, A., Hölscher, J. (2010): Trends in beobachteten Zeitreihen von Temperatur und Niederschlag in Niedersachsen. *Hydrologie & Wasserbewirtschaftung* 54 (1), 28–36
- Haberlandt, U., Ebner von Eschenbach, A.-D., Buchwald, I. (2008): A space-time hybrid hourly rainfall model for derived flood frequency analysis. *Hydrol. Earth Syst. Sci.* 12 (6), 1353–1367
- Haylock, M.R., Cawley, G.C., Harpham, C., Wilby, R.L., Goodess, C.M. (2006): Downscaling heavy precipitation over the United Kingdom: a comparison of dynamical and statistical methods and their future scenarios. *International Journal of Climatology* 26 (10), 1397–1415
- Herrmann, N. (2007): Höhere Mathematik für Ingenieure, Physiker und Mathematiker. Höhere Mathematik
- Hess, P., Brezowsky, H. (1952): Katalog der Grosswetterlagen Europas. Berichte des Deutschen Wetterdienstes in der US-Zone 33
- Hess, P., Brezowsky, H. (1969): Katalog der Grosswetterlagen Europas, 2. neu bearbeitete und ergänzte Aufl. Berichte des Deutschen Wetterdienstes
- Hess, P., Brezowsky, H. (1977): Katalog der Großwetterlagen Europas 1881-1976, 3. verbesserte und ergänzte Auflage. Berichte des Deutschen Wetterdienstes
- Hosking, J., Wallis, J.R. (1997): Regional frequency analysis: An approach based on L-moments; Cambridge University Press, Cambridge (UK)
- Hosseini, R., Le, N., Zidek, J. (2011): Selecting a binary Markov model for a precipitation process. *Environmental and Ecological Statistics* 18 (4), 795–820
- Hutchinson, M.F. (1995): Stochastic space-time weather models from ground-based data. *Agricultural and Forest Meteorology* 73 (3-4), 237–264
- Huth, R., Beck, C., Philipp, A., Demuzere, M., Ustrnul, Z., Cahynová, M., Kyselý, J., Tveito, O.E. (2008): Classifications of Atmospheric Circulation Patterns. *Annals of the New York Academy of Sciences* 1146 (1), 105–152
- IPCC (2007): Climate Change 2007: Synthesis Report: Contribution of Working Groups I, II and III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change.; Intergovernmental Panel on Climate Change (IPCC), Genf (Schweiz)
- Isaaks, E.H., Srivastava, R.M. (1989): Applied geostatistics; Oxford University Press, New York (NY, USA)
- Jacob, D., Göttel, H., Kotlarski, S., Lorenz, P., Sieck, K. (2008): Klimaauswirkungen und Anpassung in Deutschland: Phase 1: Erstellung regionaler Klimaszenarien für Deutschland. *Climate Change*. Max-Planck-Institut für Meteorologie (MPI-M), Hamburg
- Jacob, D., Van den Hurk, B. J. J. M., Andrae, U., Elgered, G., Fortelius, C., Graham, L.P., Jackson, S.D., Karstens, U., Köpken, C., Lindau, R., Podzun, R., Rockel, B., Rubel, F., Sass, B.H., Smith, R. N. B., Yang, X. (2001): A comprehensive model inter-comparison study investigating the water budget during the BALTEX-PIDCAP period. *Meteorology and Atmospheric Physics* 77 (1-4), 19–43
- Jacobs, P.A., Lewis, P. (1978a): Discrete Time Series Generated by Mixtures II: Asymptotic Properties. *Journal of the Royal Statistical Society. Series B (Methodological)* 40 (2), 222–228

- Jacobs, P.A., Lewis, P. (1978b): Discrete Time Series Generated by Mixtures. I: Correlational and Runs Properties. *Journal of the Royal Statistical Society. Series B (Methodological)* 40 (1), 94–105
- James, P.M. (2007): An objective classification method for Hess and Brezowsky Grosswetterlagen over Europe. *Theor. Appl. Climatol.* 88 (1-2), 17–42
- Jennings, S.A., Lambert, M.F., Kuczera, G. (2010): Generating synthetic high resolution rainfall time series at sites with only daily rainfall using a master–target scaling approach. *Journal of Hydrology* 393 (3–4), 163–173
- Joe, H. (1997): Multivariate models and dependence concepts. *Monographs on statistics and applied probability*, Bd. 73; Chapman & Hall, London (UK), New York (NY, USA)
- Jones, P.D., Harpham, C., Briffa, K.R. (2013): Lamb weather types derived from reanalysis products. *Int. J. Climatol.* 33 (5), 1129–1139
- Jones, P.D., Hulme, M., Briffa, K.R. (1993): A comparison of Lamb circulation types with an objective classification scheme. *Int. J. Climatol.* 13 (6), 655–663
- Jungclaus, J.H., Keenlyside, N., Botzet, M., Haak, H., Luo, J.-J., Latif, M., Marotzke, J., Mikolajewicz, U., Roeckner, E. (2006): Ocean Circulation and Tropical Variability in the Coupled Model ECHAM5/MPI-OM. *Journal of Climate* 19 (16), 3952–3972
- Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K.C., Ropelewski, C., Wang, J., Leetmaa, A., Reynolds, R., Jenne, R., Joseph, D. (1996): The NCEP / NCAR 40-year reanalysis project. *Bulletin of the American Meteorological Society* (77), 437–471
- Kasabov, N.K. (1996): Foundations of neural networks, fuzzy systems, and knowledge engineering. A Bradford book; MIT Press, Cambridge (Mass., USA)
- Key, J., Crane, R.G. (1986): A comparison of synoptic classification schemes based on ‘objective’ procedures. *J. Climatol.* 6 (4), 375–388
- Kluge, C. (1996): Wahrscheinlichkeitsanalyse von Hochwasserdurchflüssen: statistische Verfahren zur Anpassung ausgewählter Verteilungsfunktionen. *Dresdner Berichte; Institut für Siedlungs- und Industrierwasserwirtschaft der Technische Universität Dresden, Dresden (Deutschland)*
- Kojadinovic, I., Yan, J. (2010): Modeling multivariate distributions with continuous margins using the copula R package. *Journal of Statistical Software* 34 (9), 1–20
- Koutsoyiannis, D., Onof, C. (2001): Rainfall disaggregation using adjusting procedures on a Poisson cluster model. *Journal of Hydrology* 246 (1-4), 109–122
- Krige, D.G. (1951): A statistical approach to some basic mine valuation problems on the Witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society* 52, 119–139
- Lamb, H.H. (1950): Types and spells of weather around the year in the British Isles: Annual trends, seasonal structure of the year, singularities. *Q.J Royal Met. Soc.* 76 (330), 393–429
- Lennartsson, J., Baxevani, A., Chen, D. (2008): Modelling precipitation in Sweden using multiple step markov chains and a composite model. *Journal of Hydrology* 363 (1-4), 42–59
- Linderson, M.-L. (2001): Objective classification of atmospheric circulation over southern Scandinavia. *Int. J. Climatol.* 21 (2), 155–169
- Marien, J.L., Vandewiele, G.L. (1986): A Point rainfall generator with internal storm structure. *Water Resour. Res.* 22 (4), 475–482

- Matyasovszky, I., Bogardi, I., Bardossy, A., Duckstein, L. (1993): Space-time precipitation reflecting climate change. *Hydrological Sciences Journal* 38 (6), 539–558
- Matyasovszky, I., Bogardi, I., Duckstein, L. (1994): Comparison of two general circulation models to downscale temperature and precipitation under climate change. *Water Resour. Res.* 30 (12), 3437–3448
- Menabde, M., Sivapalan, M. (2000): Modeling of rainfall time series and extremes using bounded random cascades and levy-stable distributions. *Water Resour. Res.* 36 (11), 3293–3300
- Metropolis, N., Rosenbluth, A.W., Rosenbluth, M.N., Teller, A.H., Teller, E. (1953): Equation of State Calculations by Fast Computing Machines. *The Journal of Chemical Physics* 21 (6), 1087
- Molnar, P., Burlando, P. (2005): Preservation of rainfall properties in stochastic disaggregation by a simple random cascade model. *Atmospheric Research* 77 (1-4), 137–151
- Momani, P. (2009): Time Series Analysis Model for Rainfall Data in Jordan: Case Study for Using Time Series Analysis. *American Journal of Environmental Sciences* 5 (5), 599–604
- Nelsen, R.B. (2006): *An introduction to Copulas*, 2. Aufl. Springer series in statistics; Springer Science+Business Media, New York (NY, USA)
- Ng, W.W., Panu, U.S. (2010): Comparisons of traditional and novel stochastic models for the generation of daily precipitation occurrences. *Journal of Hydrology* 380 (1–2), 222–236
- Niedersachsen.de (2014) Niedersachsen in Zahlen. Internet-Portal der Niedersächsischen Landesregierung. Niedersächsische Staatskanzlei - Presse- und Informationsstelle der Landesregierung. http://www.niedersachsen.de/land_leute/land/zahlen_fakten/niedersachsen-in-zahlen-20094.html. Letzte Aktualisierung: 25.02.2014
- Olsson, J. (1998): Evaluation of a scaling cascade model for temporal rain- fall disaggregation. *Hydrol. Earth Syst. Sci.* 2 (1), 19–30
- Olsson, J., Burlando, P. (2002): Reproduction of temporal scaling by a rectangular pulses rainfall model. *Hydrological Processes* 16 (3), 611–630
- Onof, C., Chandler, R.E., Kakou, A., Northrop, P., Wheater, H.S., Isham, V. (2000): Rainfall modelling using Poisson-cluster processes: a review of developments. *Stochastic Environmental Research and Risk Assessment* 14 (6), 384–411
- Ormsbee, L.E. (1989): Rainfall disaggregation model for continuous hydrologic modeling. *J. Hydraul. Eng.* 115 (4), 507–525
- Özelkan, E.C., Galambosi, Á., Duckstein, L., Bárdossy, A. (1998): A multi-objective fuzzy classification of large scale atmospheric circulation patterns for precipitation modeling. *Applied Mathematics and Computation* 91 (2-3), 127–142
- Pattison, A. (1965): Synthesis of hourly rainfall data. *Water Resources Research* 1 (4), 489–498
- Pegram, G., Bárdossy, A. (2013): Downscaling Regional Circulation Model rainfall to gauge sites using recorrelation and circulation pattern dependent quantile–quantile transforms for quantifying climate change. *Journal of Hydrology* 504, 142–159
- Pegram, G., Clothier, A.N. (2001): High resolution space–time modelling of rainfall: the “String of Beads” model. *Journal of Hydrology* 241 (1-2), 26–41
- Piani, C., Weedon, G.P., Best, M., Gomes, S.M., Viterbo, P., Hagemann, S., Haerter, J.O. (2010): Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models. *Journal of Hydrology* 395 (3-4), 199–215

- Prescott, P., Walden, A.T. (1983): Maximum likelihood estimation of the parameters of the three-parameter generalized extreme-value distribution from censored samples. *Journal of Statistical Computation and Simulation* 16 (3-4), 241–250
- Quintana Seguí, P., Ribes, A., Martin, E., Habets, F., Boé, J. (2010): Comparison of three downscaling methods in simulating the impact of climate change on the hydrology of Mediterranean basins. *Journal of Hydrology* 383 (1-2), 111–124
- R Development Core Team (2008): R: A language and environment for statistical computing.; R Foundation for Statistical Computing, Wien (Österreich)
- Raudkivi, A.J., Lawgun, N. (1970): Synthesis of Urban Rainfall. *Water Resources Research* 6 (2), 455–464
- Reeves, C.R. (1993): *Modern heuristic techniques for combinatorial problems*; Halsted Press, New York
- Restrepo-Posada, P.J., Eagleson, P.S. (1982): Identification of independent rainstorms. *Journal of Hydrology* 55 (1-4), 303–319
- Rodriguez-Iturbe, I., Cox, D.R., Isham, V. (1987): Some Models for Rainfall Based on Stochastic Point Processes. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 410 (1839), 269–288
- Rodriguez-Iturbe, I., Cox, D.R., Isham, V. (1988): A Point Process Model for Rainfall: Further Developments. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences* 417 (1853), 283–298
- Sachs, L. (2004): *Angewandte Statistik: Anwendung statistischer Methoden*; mit 317 Tabellen und 99 Übersichten, 11. Aufl.; Springer, Berlin (Deutschland)
- Sachs, L., Hedderich, J. (2006): *Angewandte Statistik: Methodensammlung mit R* : mit 180 Tabellen, 12. Aufl.; Springer, Berlin (Deutschland)
- Salvadori, G. (2007): *Extremes in Nature*. Water Science and Technology Library, Bd. 56; Springer, New York (NY, USA)
- Schertzer, D., Lovejoy, S. (1987): Physical modeling and analysis of rain and clouds by anisotropic scaling multiplicative processes. *Journal of Geophysical Research: Atmospheres* 92 (D8), 9693–9714
- Schubert, S. (1994): A weather generator based on the European 'Grosswetterlagen'. *Clim. Res.* 4, 191–202
- Shabri, A., Jemain, A.A. (2010): LQ-moments: Parameter Estimation for Kappa Distribution. *Sains Malaysiana* 39 (5), 845–850
- Singh, V.P., Guo, H. (1995): Parameter estimation for 3-parameter generalized pareto distribution by the principle of maximum entropy (POME). *Hydrological Sciences Journal* 40 (2), 165–181
- Sivakumar, B. (2001): Is a chaotic multi-fractal approach for rainfall possible? *Hydrol. Process.* 15 (6), 943–955
- Sklar, A. (1996): *Random variables, distribution functions, and copulas: a personal look backward and forward*. Lecture notes-monograph series, 1–14
- Stedinger, J.R., Vogel, R.M., Foufoula-Georgiou, E. (1993): Chapter 18. Frequency analysis of extreme events. Maidment, D.R. (Hg.), *Handbook of Hydrology*, 18.1-18.66

- Stehlik, J., Bárdossy, A. (2002): Multivariate stochastic downscaling model for generating daily precipitation series based on atmospheric circulation. *Journal of Hydrology* 256 (1-2), 120–141
- Stephens, M.A. (1970): Use of the Kolmogorov-Smirnov, Cramer-Von Mises and Related Statistics Without Extensive Tables. *Journal of the Royal Statistical Society. Series B (Methodological)* 32 (1), 115–122
- Teegavarapu, R.S., Tufail, M., Ormsbee, L. (2009): Optimal functional forms for estimation of missing precipitation data. *Journal of Hydrology* 374 (1-2), 106–115
- Teimouri, M., Gupta, A.K. (2013): On the three-parameter weibull distribution shape parameter estimation. *Journal of Data Science* 11, 403–414
- Terink, W., Hurkmans, R. T. W. L., Torfs, P. J. J. F., Uijlenhoet, R. (2010): Evaluation of a bias correction method applied to downscaled precipitation and temperature reanalysis data for the Rhine basin. *Hydrol. Earth Syst. Sci.* 14 (4), 687–703
- Teutschbein, C., Seibert, J. (2012): Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *Journal of Hydrology* 456–457, 12–29
- Tsakiris, G. (1988): Stochastic modelling of rainfall occurrences in continuous time. *Hydrological Sciences Journal* 33 (5), 437–447
- Werner, P.C., Gerstengarbe, F.-W. (1999): *Katalog der Großwetterlagen Europas (1881-1998): Nach Paul Hess und Helmuth Brezowsky 5., verbesserte und ergänzte Auflage*, Potsdam, Offenbach a. M.
- Werner, P.C., Gerstengarbe, F.-W. (2010): *Katalog der Großwetterlagen Europas (1881-2009): Nach Paul Hess und Helmuth Brezowsky 7., verbesserte und ergänzte Auflage*, Potsdam, Offenbach a. M.
- Wetterhall, F., Bárdossy, A., Chen, D., Halldin, S., Xu, C.-Y. (2009): Statistical downscaling of daily precipitation over Sweden using GCM output. *Theor Appl Climatol* 96 (1-2), 95–103
- Wilby, R.L., Barnsley, N., O'Hare, G. (1995): Rainfall variability associated with Lamb weather types: The case for incorporating weather fronts. *Int. J. Climatol.* 15 (11), 1241–1252
- Wilby, R.L., Charles, S.P., Zorita, E., Timbal, B., Whetton, P., Mearns, L.O. (2004): *Guidelines for use of climate scenarios developed from statistical downscaling methods: Supporting material of the Intergovernmental Panel on Climate Change; IPCC Data Distribution Centre*
- Wilby, R.L., Wigley, T., Conway, D., Jones, P.D., Hewitson, B.C., Main, J., Wilks, D.S. (1998): Statistical downscaling of general circulation model output: A comparison of methods. *Water Resources Research* 34 (11), 2995–3008
- Wilks, D.S. (1998): Multisite generalization of a daily stochastic precipitation generation model. *Journal of Hydrology* 210 (1-4), 178–191
- Yang, W. (2008): *Discrete-continuous downscaling model for generating daily precipitation time series. Mitteilungen / Institut für Wasserbau, Universität Stuttgart, H. 168; Institut für Wasserbau, Universität Stuttgart, Stuttgart (Deutschland)*
- Yang, W., Bárdossy, A., Caspary, H.-J. (2010): Downscaling daily precipitation time series using a combined circulation- and regression-based approach. *Theor Appl Climatol* 102 (3-4), 439–454
- Zadeh, L.A. (1965): Fuzzy sets. *Information and Control* 8 (3), 338–353

Anhang

Tabelle A-1 Liste der hoch aufgelösten Niederschlagsstationen

| ID | Name | Bundesland | Höhe | Beobachtungsbeginn | Beobachtungsende | Beobachtungslänge | Betreiber |
|--------|---------------------|----------------|-------|--------------------|------------------|-------------------|-----------|
| | | | [mNN] | | | [a] | |
| 01055 | Norderney | Niedersachsen | 11,0 | 1996 | 2010 | 15 | DWD |
| 01132 | Lingen | Niedersachsen | 22,0 | 1996 | 2010 | 15 | DWD |
| 01497 | Oldenburg | Niedersachsen | 11,0 | 1999 | 2010 | 12 | DWD |
| 01516 | Osnabrück | Niedersachsen | 95,4 | 1996 | 2010 | 15 | DWD |
| 01519 | Diepholz | Niedersachsen | 39,0 | 1997 | 2010 | 14 | DWD |
| 01525 | Bad Salzflufen | NRW | 134,6 | 1996 | 2010 | 15 | DWD |
| 01529 | Soltau | Niedersachsen | 75,6 | 1996 | 2010 | 15 | DWD |
| 01538 | Hannover Flughafen | Niedersachsen | 55,0 | 1996 | 2010 | 15 | DWD |
| 01564 | Göttingen | Niedersachsen | 167,0 | 1996 | 2010 | 15 | DWD |
| 01576 | Kassel | Hessen | 231,0 | 2000 | 2010 | 11 | DWD |
| 03169 | Gardelegen | Sachsen-Anhalt | 47,0 | 1996 | 2010 | 15 | DWD |
| 03173 | Ummendorf | Sachsen-Anhalt | 162,0 | 1999 | 2010 | 12 | DWD |
| 03177 | Magdeburg | Sachsen-Anhalt | 76,0 | 1996 | 2010 | 15 | DWD |
| 03180 | Wernigerode | Sachsen-Anhalt | 234,0 | 1998 | 2010 | 13 | DWD |
| 03189 | Schierke | Sachsen-Anhalt | 609,0 | 2004 | 2010 | 7 | DWD |
| 03193 | Harzgerode | Sachsen-Anhalt | 404,0 | 1996 | 2010 | 15 | DWD |
| 03400 | Leinefeld | Thüringen | 356,0 | 1996 | 2010 | 15 | DWD |
| 03901 | Lüchow | Niedersachsen | 17,0 | 1996 | 2010 | 15 | DWD |
| 03916 | Braunschweig | Niedersachsen | 81,2 | 1998 | 2010 | 13 | DWD |
| 03984 | Braunlage | Niedersachsen | 607,0 | 1996 | 2010 | 15 | DWD |
| 10131 | Cuxhaven | Niedersachsen | 5,0 | 2002 | 2010 | 9 | DWD |
| 10200 | Emden | Niedersachsen | 0,0 | 1998 | 2010 | 13 | DWD |
| N500 | Bühne-Rimbeck | Sachsen-Anhalt | 100,0 | 2003 | 2010 | 8 | DWD |
| 102470 | Amelinghausen | Niedersachsen | 85,0 | 2004 | 2010 | 7 | Meteoedia |
| 102480 | Uelzen | Niedersachsen | 9,1 | 2004 | 2010 | 7 | Meteoedia |
| 103520 | Wolfsburg | Niedersachsen | 81,0 | 2004 | 2010 | 7 | Meteoedia |
| 103510 | Wolfsburg-Autostadt | Niedersachsen | 61,0 | 2003 | 2010 | 8 | Meteoedia |
| 104450 | Göttingen | Niedersachsen | 191,0 | 2002 | 2010 | 9 | Meteoedia |
| 104480 | Bad Lauterberg | Niedersachsen | 308,0 | 2003 | 2009 | 7 | Meteoedia |

Tabelle A-2 Fehlwertanteile der Beobachtungsjahre in den hoch aufgelösten Niederschlagsstationen; in den Untersuchungen verwendet wurde der Bereich im dicken Rahmen; die Zahlen markieren den Fehlwertanteil in Prozent; NA kennzeichnet Jahre, in denen keine Beobachtungen vorliegen; der Wert „Mittel“ gibt den durchschnittlichen Fehlwertanteil der verwendeten Zeiträume an

| | 01055 | 01132 | 01497 | 01516 | 01519 | 01525 | 01529 | 01538 | 01564 | 01576 | 03169 | 03173 | 03177 | 03180 | 03189 |
|--------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 1991 | NA | 83,5 | 86,8 | 84,0 | 84,7 | 95,1 |
| 1992 | NA | 14,1 | NA | NA | NA | 56,6 | 90,7 | 51,6 | NA | NA | 19,5 | 22,0 | 18,8 | 35,8 | 98,2 |
| 1993 | NA | 1,0 | NA | 6,0 | NA | 2,4 | 0,4 | 2,5 | 88,5 | NA | 5,7 | 3,1 | 6,2 | 18,1 | 100,0 |
| 1994 | 12,9 | 7,9 | NA | 12,3 | NA | 5,2 | 8,0 | 4,8 | 13,2 | NA | 9,4 | 10,8 | 13,6 | 14,2 | 100,0 |
| 1995 | 18,4 | 20,4 | NA | 19,3 | NA | 41,3 | 39,2 | 44,9 | 41,1 | NA | 47,4 | 47,2 | 41,0 | 47,4 | 100,0 |
| 1996 | 8,8 | 3,1 | NA | 4,8 | NA | 1,0 | 0,7 | 6,9 | 3,3 | NA | 0,9 | 18,3 | 2,0 | 70,6 | 100,0 |
| 1997 | 2,2 | 0,9 | NA | 0,1 | 0,8 | 2,3 | 0,5 | 1,2 | 1,0 | NA | 0,9 | 11,9 | 0,7 | 15,0 | 100,0 |
| 1998 | 3,6 | 0,6 | NA | 0,5 | 0,3 | 1,0 | 0,7 | 5,0 | 0,7 | NA | 3,5 | 11,9 | 9,0 | 9,4 | 100,0 |
| 1999 | 1,0 | 0,7 | 4,8 | 0,2 | 2,3 | 0,5 | 0,6 | 4,6 | 1,5 | 66,7 | 0,3 | 0,7 | 0,6 | 0,8 | 100,0 |
| 2000 | 2,0 | 1,1 | 6,5 | 0,1 | 20,4 | 0,4 | 1,1 | 2,2 | 0,6 | 3,7 | 0,2 | 0,1 | 4,6 | 1,4 | 100,0 |
| 2001 | 1,9 | 0,1 | 0,7 | 0,2 | 1,4 | 2,0 | 1,7 | 4,6 | 5,1 | 1,9 | 4,8 | 4,8 | 4,9 | 8,6 | 100,0 |
| 2002 | 2,9 | 0,2 | 0,4 | 0,1 | 1,0 | 1,0 | 0,4 | 3,8 | 0,8 | 0,3 | 0,6 | 9,4 | 3,1 | 3,7 | 100,0 |
| 2003 | 3,0 | 1,3 | 0,6 | 0,1 | 0,2 | 0,2 | 0,2 | 9,7 | 0,3 | 0,3 | 0,2 | 4,3 | 0,3 | 5,9 | 42,7 |
| 2004 | 1,5 | 0,3 | 0,2 | 0,7 | 0,7 | 2,0 | 0,1 | 2,7 | 2,1 | 1,3 | 0,4 | 3,7 | 0,1 | 0,0 | 0,0 |
| 2005 | 1,2 | 0,6 | 0,4 | 1,7 | 0,9 | 0,2 | 0,2 | 1,0 | 1,8 | 0,3 | 0,3 | 1,7 | 1,9 | 2,7 | 0,0 |
| 2006 | 5,3 | 2,7 | 3,4 | 0,1 | 1,3 | 0,8 | 0,2 | 5,6 | 1,2 | 0,7 | 3,0 | 1,3 | 0,7 | 4,9 | 0,0 |
| 2007 | 1,5 | 1,1 | 2,4 | 0,2 | 0,6 | 2,3 | 0,1 | 1,1 | 1,3 | 0,0 | 0,1 | 0,1 | 0,0 | 0,0 | 0,0 |
| 2008 | 0,0 | 1,2 | 0,0 | 0,9 | 0,0 | 0,2 | 0,0 | 1,0 | 0,0 | 1,0 | 0,3 | 0,0 | 0,0 | 0,0 | 0,0 |
| 2009 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 |
| 2010 | 0,0 | 0,0 | 0,0 | 8,8 | 0,0 | 0,0 | 0,5 | 0,0 | 0,0 | 0,0 | 0,0 | 1,7 | 0,0 | 0,0 | 0,0 |
| Mittel | 2,3 | 0,9 | 1,6 | 1,2 | 2,1 | 0,9 | 0,5 | 3,3 | 1,3 | 0,9 | 1,0 | 2,3 | 1,9 | 2,9 | 0,0 |

| | 03193 | 03400 | 03901 | 03916 | 03984 | 10131 | 10200 | N500h | 102470 | 102480 | 103510 | 103520 | 104450 | 104480 |
|--------|-------|-------|-------|-------|-------|-------|-------|-------|--------|--------|--------|--------|--------|--------|
| 1991 | 84,3 | 85,5 | NA | NA | 66,3 | NA | NA | NA | NA | NA | NA | NA | NA | NA |
| 1992 | 19,7 | 20,5 | NA | NA | 18,2 | NA | NA | NA | NA | NA | NA | NA | NA | NA |
| 1993 | 10,2 | 3,9 | 74,7 | NA | 3,1 | NA | NA | NA | NA | NA | NA | NA | NA | NA |
| 1994 | 10,7 | 25,2 | 24,0 | NA | 29,6 | NA | NA | NA | NA | NA | NA | NA | NA | NA |
| 1995 | 42,1 | 44,1 | 43,1 | NA | 41,2 | NA | NA | NA | NA | NA | NA | NA | NA | NA |
| 1996 | 5,9 | 1,3 | 4,7 | NA | 3,5 | NA | NA | NA | NA | NA | NA | NA | NA | NA |
| 1997 | 3,5 | 7,0 | 0,7 | 86,4 | 3,5 | NA | NA | NA | NA | NA | NA | NA | NA | NA |
| 1998 | 0,3 | 1,6 | 1,1 | 0,8 | 0,8 | NA | 0,1 | NA | NA | NA | NA | NA | NA | NA |
| 1999 | 0,9 | 1,3 | 0,7 | 1,5 | 1,2 | NA | 0,0 | NA | NA | NA | NA | NA | NA | NA |
| 2000 | 0,2 | 0,0 | 0,8 | 1,2 | 11,9 | 40,5 | 0,0 | NA | NA | NA | NA | NA | NA | NA |
| 2001 | 4,9 | 0,3 | 0,6 | 1,3 | 2,0 | 30,8 | 0,0 | NA | NA | NA | NA | NA | 85,7 | NA |
| 2002 | 1,0 | 1,2 | 0,7 | 1,3 | 0,6 | 6,9 | 1,4 | 92,1 | NA | NA | 81,3 | NA | 1,1 | 90,8 |
| 2003 | 0,4 | 0,2 | 0,2 | 0,4 | 0,1 | 5,4 | 0,3 | 3,6 | 56,6 | 41,4 | 0,3 | 65,9 | 0,4 | 0,5 |
| 2004 | 0,9 | 2,7 | 0,2 | 1,2 | 0,0 | 0,9 | 1,6 | 0,0 | 0,8 | 0,2 | 0,7 | 1,3 | 0,3 | 0,2 |
| 2005 | 0,4 | 1,4 | 0,4 | 1,0 | 0,3 | 2,0 | 0,1 | 0,0 | 0,3 | 0,3 | 0,3 | 0,3 | 0,4 | 0,3 |
| 2006 | 4,3 | 1,9 | 0,2 | 0,8 | 0,2 | 2,9 | 2,9 | 0,0 | 3,8 | 0,1 | 0,1 | 0,1 | 0,1 | 0,1 |
| 2007 | 0,0 | 0,6 | 0,5 | 0,0 | 5,0 | 0,0 | 1,2 | 0,0 | 7,7 | 0,1 | 0,1 | 2,3 | 5,7 | 0,1 |
| 2008 | 0,0 | 0,0 | 0,0 | 1,2 | 2,6 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,2 | 0,1 | 0,1 | 0,3 |
| 2009 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,1 | 0,0 | 0,0 | 0,0 | 0,0 |
| 2010 | 0,0 | 1,7 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,0 | 0,5 | 0,1 | 51,9 |
| Mittel | 1,5 | 1,4 | 0,7 | 0,8 | 2,1 | 2,0 | 0,6 | 0,5 | 1,8 | 0,1 | 0,2 | 0,7 | 0,9 | 0,2 |

Tabelle A-3 Mittel der statistischen Momente der Ereignisse – Beobachtung gegen Modellierung; für die Beobachtung werden die tatsächlichen Werte angegeben, für die Modellierung die prozentualen Abweichungen zur Beobachtung

| | Saison | Beobachtung | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
|---|--------|-------------|--------|--------|--------|--------|--------|
| Mittelwert dsd [min] | Winter | 2867 | 0,85 | 0,91 | 0,83 | 0,43 | 0,30 |
| | Sommer | 3047 | 0,83 | 0,77 | 0,53 | 0,32 | 0,40 |
| Varianz dsd [min ²] | Winter | 19513556 | 4,17 | 4,13 | 3,55 | 3,35 | 3,20 |
| | Sommer | 20829091 | 5,30 | 4,84 | 5,03 | 3,53 | 4,38 |
| Schiefe dsd [-] | Winter | 3,44 | 8,99 | 8,99 | 7,88 | 7,80 | 7,62 |
| | Sommer | 3,53 | 15,29 | 15,18 | 11,30 | 10,24 | 10,23 |
| Wölbung dsd [-] | Winter | 16,71 | 24,74 | 24,59 | 21,57 | 21,11 | 20,32 |
| | Sommer | 23,63 | 38,08 | 37,59 | 26,41 | 23,96 | 24,47 |
| Mittelwert wsd [min] | Winter | 439,13 | 0,58 | 0,32 | 0,45 | 0,37 | 0,31 |
| | Sommer | 334,00 | 0,52 | 0,47 | 0,55 | 0,44 | 0,34 |
| Varianz wsd [min ²] | Winter | 147874 | 5,20 | 6,11 | 4,26 | 5,28 | 5,74 |
| | Sommer | 99790 | 5,24 | 4,77 | 3,35 | 3,83 | 4,40 |
| Schiefe wsd [-] | Winter | 2,37 | 21,09 | 16,86 | 12,15 | 14,13 | 15,29 |
| | Sommer | 2,80 | 24,70 | 12,83 | 10,82 | 11,06 | 13,08 |
| Wölbung wsd [-] | Winter | 9,14 | 57,45 | 35,59 | 26,80 | 30,82 | 31,94 |
| | Sommer | 13,77 | 67,72 | 29,37 | 29,67 | 25,93 | 29,15 |
| Mittelwert wsi [mm/h] | Winter | 0,55 | 1,70 | 1,02 | 1,27 | 1,05 | 1,07 |
| | Sommer | 1,06 | 0,62 | 0,62 | 1,07 | 0,54 | 0,55 |
| Varianz wsi [mm ² /h ²] | Winter | 0,22 | 8,64 | 15,86 | 9,66 | 10,94 | 13,68 |
| | Sommer | 1,91 | 10,52 | 8,40 | 9,93 | 9,80 | 9,31 |
| Schiefe wsi [-] | Winter | 4,20 | 19,81 | 35,94 | 32,75 | 26,40 | 28,78 |
| | Sommer | 5,29 | 40,34 | 28,07 | 44,01 | 38,70 | 30,18 |
| Wölbung wsi [-] | Winter | 50,83 | 46,53 | 62,32 | 188,33 | 85,91 | 52,99 |
| | Sommer | 49,81 | 147,68 | 104,14 | 169,56 | 148,03 | 113,06 |
| Mittelwert wsa [mm] | Winter | 3,96 | 1,96 | 1,74 | 1,47 | 1,76 | 1,64 |
| | Sommer | 5,01 | 3,29 | 3,31 | 2,23 | 2,73 | 2,94 |
| Varianz wsa [mm ²] | Winter | 30,75 | 19,70 | 13,51 | 13,69 | 13,42 | 13,73 |
| | Sommer | 50,34 | 70,35 | 65,51 | 58,37 | 63,48 | 57,80 |
| Schiefe wsa [-] | Winter | 3,53 | 80,98 | 34,99 | 50,85 | 50,57 | 44,64 |
| | Sommer | 4,28 | 122,14 | 104,24 | 110,96 | 105,34 | 97,03 |
| Wölbung wsa [-] | Winter | 19,48 | 461,23 | 146,75 | 279,49 | 287,75 | 230,27 |
| | Sommer | 31,38 | 529,10 | 443,43 | 490,43 | 451,29 | 412,19 |

Tabelle A-4 Mittel der L- Momente der Ereignisse – Beobachtung gegen Modellierung; für die Beobachtung werden die tatsächlichen Werte angegeben, für die Modellierung die prozentualen Abweichungen zur Beobachtung

| | Saison | Beobachtung | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
|------------------|--------|-------------|--------|--------|--------|--------|--------|
| L1 dsd [min] | Winter | 2867 | 0,85 | 0,91 | 0,83 | 0,43 | 0,30 |
| | Sommer | 3047 | 0,83 | 0,77 | 0,53 | 0,32 | 0,40 |
| L2 dsd [min] | Winter | 19513556 | 4,17 | 4,13 | 3,55 | 3,35 | 3,20 |
| | Sommer | 20829091 | 5,30 | 4,84 | 5,03 | 3,53 | 4,38 |
| Tau3 dsd [-] | Winter | 3,44 | 8,99 | 8,99 | 7,88 | 7,80 | 7,62 |
| | Sommer | 3,53 | 15,29 | 15,18 | 11,30 | 10,24 | 10,23 |
| Tau4 dsd [-] | Winter | 16,71 | 24,74 | 24,59 | 21,57 | 21,11 | 20,32 |
| | Sommer | 23,63 | 38,08 | 37,59 | 26,41 | 23,96 | 24,47 |
| L1 wsd [min] | Winter | 439,13 | 0,58 | 0,32 | 0,45 | 0,37 | 0,31 |
| | Sommer | 334,00 | 0,52 | 0,47 | 0,55 | 0,44 | 0,34 |
| L2 wsd [min] | Winter | 147874 | 5,20 | 6,11 | 4,26 | 5,28 | 5,74 |
| | Sommer | 99790 | 5,24 | 4,77 | 3,35 | 3,83 | 4,40 |
| Tau3 wsd [-] | Winter | 2,37 | 21,09 | 16,86 | 12,15 | 14,13 | 15,29 |
| | Sommer | 2,80 | 24,70 | 12,83 | 10,82 | 11,06 | 13,08 |
| Tau4 wsd [-] | Winter | 9,14 | 57,45 | 35,59 | 26,80 | 30,82 | 31,94 |
| | Sommer | 13,77 | 67,72 | 29,37 | 29,67 | 25,93 | 29,15 |
| L1 wsi [mm/h] | Winter | 0,55 | 1,70 | 1,02 | 1,27 | 1,05 | 1,07 |
| | Sommer | 1,06 | 0,62 | 0,62 | 1,07 | 0,54 | 0,55 |
| L2 wsi [mm/h] | Winter | 0,22 | 8,64 | 15,86 | 9,66 | 10,94 | 13,68 |
| | Sommer | 1,91 | 10,52 | 8,40 | 9,93 | 9,80 | 9,31 |
| Tau3 wsi [-] | Winter | 4,20 | 19,81 | 35,94 | 32,75 | 26,40 | 28,78 |
| | Sommer | 5,29 | 40,34 | 28,07 | 44,01 | 38,70 | 30,18 |
| Tau4 wsi [-] | Winter | 50,83 | 46,53 | 62,32 | 188,33 | 85,91 | 52,99 |
| | Sommer | 49,81 | 147,68 | 104,14 | 169,56 | 148,03 | 113,06 |
| L1 wsa [mm] | Winter | 3,96 | 1,96 | 1,74 | 1,47 | 1,76 | 1,64 |
| | Sommer | 5,01 | 3,29 | 3,31 | 2,23 | 2,73 | 2,94 |
| L2 wsa [mm] | Winter | 30,75 | 19,70 | 13,51 | 13,69 | 13,42 | 13,73 |
| | Sommer | 50,34 | 70,35 | 65,51 | 58,37 | 63,48 | 57,80 |
| Tau3 wsa [-] | Winter | 3,53 | 80,98 | 34,99 | 50,85 | 50,57 | 44,64 |
| | Sommer | 4,28 | 122,14 | 104,24 | 110,96 | 105,34 | 97,03 |
| Tau4 wsa [-] | Winter | 19,48 | 461,23 | 146,75 | 279,49 | 287,75 | 230,27 |
| | Sommer | 31,38 | 529,10 | 443,43 | 490,43 | 451,29 | 412,19 |

Tabelle A-5 Mittel der abgeleiteten Größen – Beobachtung gegen Modellierung; für die Beobachtung werden die tatsächlichen Werte angegeben, für die Modellierung die prozentualen Abweichungen zur Beobachtung

| | Saison | Beobachtung | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
|------------------------------|--------|-------------|------|------|------|------|------|
| Mittlere Ereignisanzahl | Winter | 79,84 | 1,12 | 1,01 | 1,00 | 0,77 | 0,76 |
| | Sommer | 78,45 | 1,51 | 1,45 | 0,96 | 0,81 | 1,06 |
| Mittlere Niederschlagssummen | Winter | 321,46 | 2,27 | 1,82 | 1,60 | 1,95 | 1,92 |
| | Sommer | 395,56 | 4,56 | 4,46 | 2,94 | 3,35 | 3,73 |

Tabelle A-6 Indizes der Niederschlagsextrema der Modellierung im Winter

| dt [h] | $\overline{D_{abs,n}}$ [mm/h] | | | | | $\overline{D_{abs,w}}$ [mm/h] | | | | |
|--------|-----------------------------------|-------|-------|-------|-------|---|-------|-------|-------|-------|
| | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,13 | 0,20 | 0,20 | 0,20 | 0,20 | 0,10 | 0,16 | 0,16 | 0,17 | 0,16 |
| 3 | 0,16 | 0,37 | 0,37 | 0,037 | 0,37 | 0,14 | 0,33 | 0,35 | 0,34 | 0,34 |
| 6 | 0,16 | 0,13 | 0,14 | 0,14 | 0,14 | 0,13 | 0,11 | 0,12 | 0,12 | 0,12 |
| 12 | 0,16 | 0,14 | 0,15 | 0,15 | 0,15 | 0,13 | 0,12 | 0,14 | 0,13 | 0,14 |
| 24 | 0,14 | 0,11 | 0,12 | 0,12 | 0,12 | 0,11 | 0,10 | 0,11 | 0,11 | 0,11 |
| dt [h] | $\overline{D_{sign,n}}$ [mm/h] | | | | | $\overline{D_{sign,w}}$ [mm/h] | | | | |
| | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | -0,05 | -0,19 | -0,19 | -0,19 | -0,19 | -0,04 | -0,15 | -0,15 | -0,16 | -0,15 |
| 3 | 0,12 | 0,27 | 0,29 | 0,27 | 0,28 | 0,11 | 0,27 | 0,28 | 0,27 | 0,28 |
| 6 | 0,12 | 0,08 | 0,097 | 0,09 | 0,10 | 0,01 | 0,08 | 0,09 | 0,08 | 0,09 |
| 12 | 0,11 | 0,10 | 0,12 | 0,11 | 0,11 | 0,07 | 0,08 | 0,09 | 0,09 | 0,09 |
| 24 | 0,06 | 0,041 | 0,06 | 0,05 | 0,05 | 0,02 | 0,02 | 0,02 | 0,03 | 0,03 |
| dt [h] | $\overline{n\overline{\omega^2}}$ | | | | | p-value ($\overline{n\overline{\omega^2}}$) | | | | |
| | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,02 | 0,062 | 0,054 | 0,060 | 0,06 | 253 | 125 | 149 | 134 | 137 |
| 3 | 0,029 | 0,023 | 0,023 | 0,023 | 0,024 | 229 | 268 | 268 | 260 | 262 |
| 6 | 0,030 | 0,028 | 0,029 | 0,030 | 0,031 | 238 | 240 | 247 | 242 | 243 |
| 12 | 0,027 | 0,027 | 0,030 | 0,030 | 0,031 | 237 | 230 | 234 | 236 | 227 |
| 24 | 0,017 | 0,017 | 0,019 | 0,019 | 0,020 | 268 | 275 | 266 | 265 | 260 |
| dt [h] | $\overline{D_{n,n^i}}$ | | | | | p-value (K-S-Test) | | | | |
| | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,027 | 0,041 | 0,038 | 0,040 | 0,04 | 265 | 171 | 185 | 175 | 167 |
| 3 | 0,030 | 0,026 | 0,026 | 0,026 | 0,027 | 236 | 273 | 274 | 271 | 271 |
| 6 | 0,031 | 0,030 | 0,030 | 0,031 | 0,031 | 241 | 246 | 248 | 247 | 249 |
| 12 | 0,029 | 0,029 | 0,030 | 0,030 | 0,030 | 240 | 237 | 239 | 243 | 234 |
| 24 | 0,026 | 0,025 | 0,026 | 0,026 | 0,026 | 267 | 281 | 275 | 269 | 264 |

Tabelle A-7 Indizes der Niederschlagsextrema der Modellierung im Sommer

| dt [h] | $\overline{D_{abs,n}}$ [mm/h] | | | | | $\overline{D_{abs,w}}$ [mm/h] | | | | |
|--------|-----------------------------------|-------|-------|-------|-------|---|-------|-------|-------|-------|
| | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,17 | 0,16 | 0,18 | 0,17 | 0,17 | 0,16 | 0,16 | 0,19 | 0,17 | 0,17 |
| 3 | 0,29 | 0,25 | 0,21 | 0,023 | 0,22 | 0,20 | 0,19 | 0,16 | 0,17 | 0,17 |
| 6 | 0,36 | 0,36 | 0,31 | 0,34 | 0,30 | 0,27 | 0,28 | 0,24 | 0,26 | 0,23 |
| 12 | 0,36 | 0,38 | 0,34 | 0,36 | 0,33 | 0,27 | 0,30 | 0,26 | 0,28 | 0,26 |
| 24 | 0,29 | 0,30 | 0,27 | 0,28 | 0,27 | 0,22 | 0,24 | 0,22 | 0,23 | 0,22 |
| dt [h] | $\overline{D_{sign,n}}$ [mm/h] | | | | | $\overline{D_{sign,w}}$ [mm/h] | | | | |
| | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | -0,06 | -0,10 | -0,13 | -0,11 | -0,12 | -0,11 | -0,12 | -0,16 | -0,14 | -0,14 |
| 3 | 0,24 | 0,22 | 0,17 | 0,20 | 0,19 | 0,15 | 0,15 | 0,10 | 0,12 | 0,12 |
| 6 | 0,34 | 0,35 | 0,29 | 0,33 | 0,28 | 0,24 | 0,26 | 0,22 | 0,24 | 0,20 |
| 12 | 0,35 | 0,37 | 0,33 | 0,35 | 0,32 | 0,25 | 0,28 | 0,25 | 0,27 | 0,25 |
| 24 | 0,27 | 0,28 | 0,25 | 0,27 | 0,25 | 0,20 | 0,22 | 0,20 | 0,21 | 0,20 |
| dt [h] | $\overline{n\overline{\omega}^2}$ | | | | | p-value ($\overline{n\overline{\omega}^2}$) | | | | |
| | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,023 | 0,027 | 0,032 | 0,028 | 0,029 | 264 | 249 | 232 | 243 | 240 |
| 3 | 0,034 | 0,034 | 0,025 | 0,030 | 0,029 | 240 | 233 | 252 | 239 | 247 |
| 6 | 0,050 | 0,054 | 0,045 | 0,050 | 0,043 | 176 | 165 | 194 | 180 | 206 |
| 12 | 0,048 | 0,054 | 0,048 | 0,051 | 0,046 | 172 | 154 | 181 | 161 | 185 |
| 24 | 0,037 | 0,041 | 0,035 | 0,038 | 0,036 | 205 | 191 | 216 | 201 | 209 |
| dt [h] | $\overline{D_{n,n'}}$ | | | | | p-value (K-S-Test) | | | | |
| | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 | ARP0 | ARP1 | ARP2 | ARP3 | ARP4 |
| 1 | 0,029 | 0,030 | 0,033 | 0,031 | 0,031 | 260 | 251 | 240 | 251 | 251 |
| 3 | 0,033 | 0,033 | 0,030 | 0,031 | 0,031 | 254 | 247 | 269 | 259 | 258 |
| 6 | 0,038 | 0,039 | 0,037 | 0,038 | 0,036 | 186 | 182 | 198 | 184 | 216 |
| 12 | 0,038 | 0,040 | 0,038 | 0,039 | 0,038 | 200 | 173 | 202 | 183 | 202 |
| 24 | 0,033 | 0,035 | 0,033 | 0,034 | 0,033 | 225 | 209 | 229 | 221 | 231 |

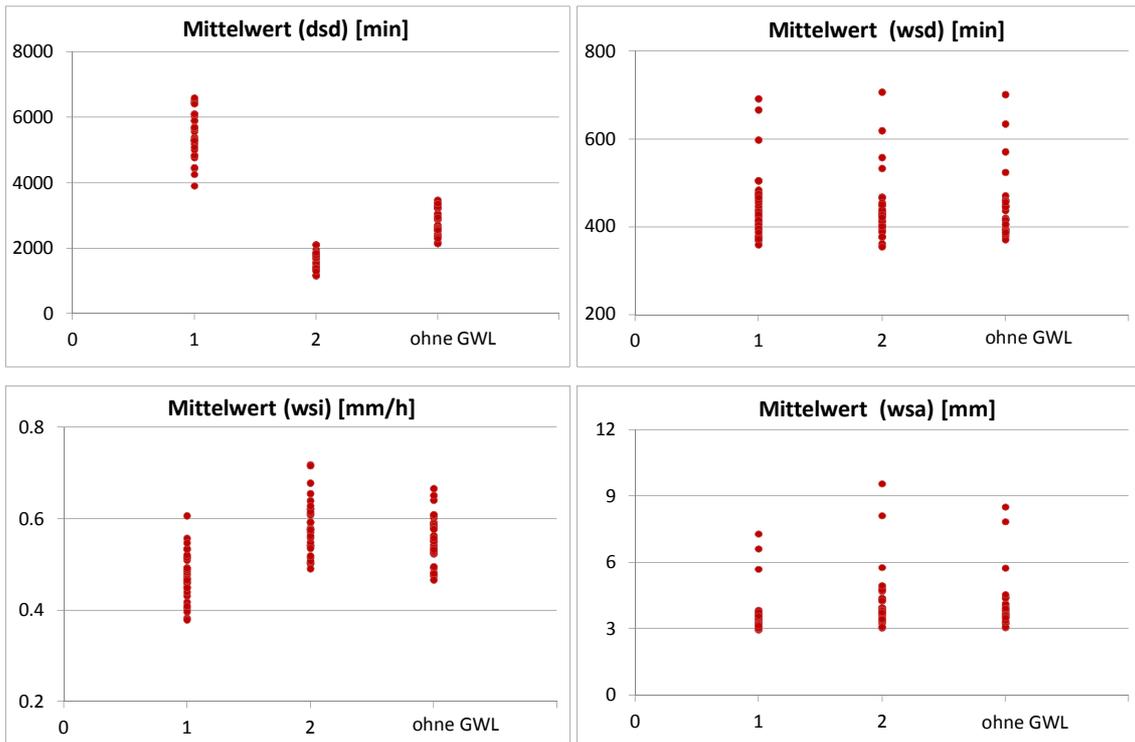


Abbildung A-1 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Winter, sortiert nach GWL mit 2 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

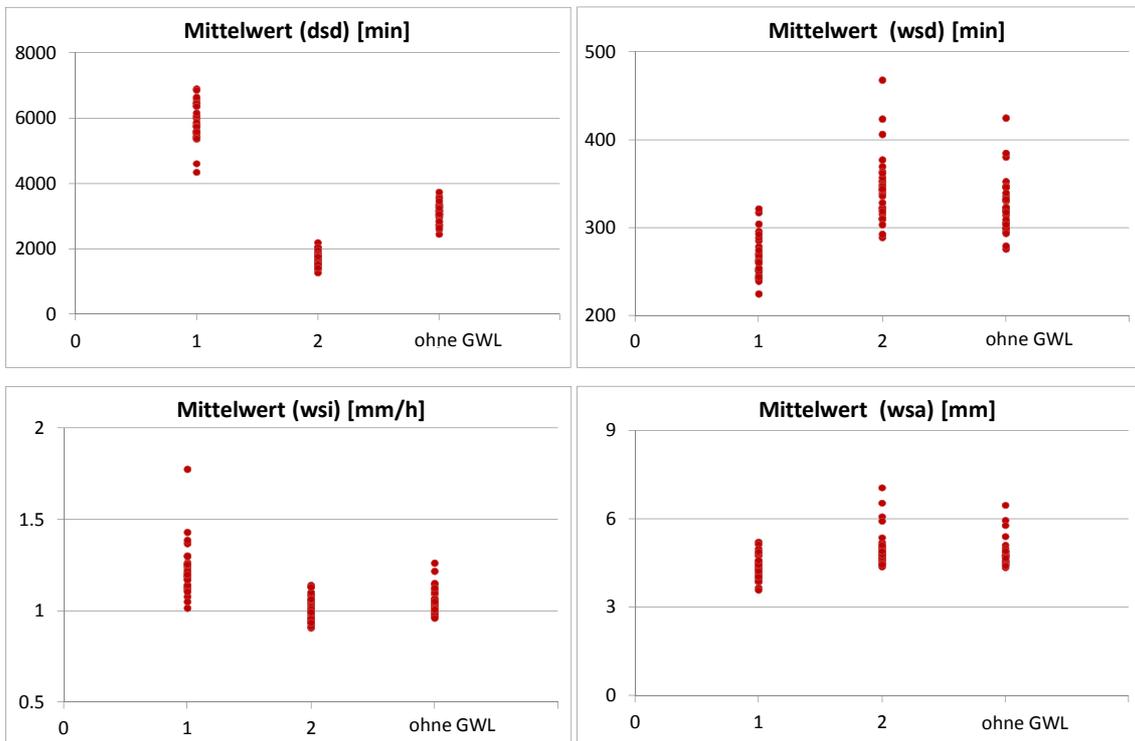


Abbildung A-2 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Sommer, sortiert nach GWL mit 2 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

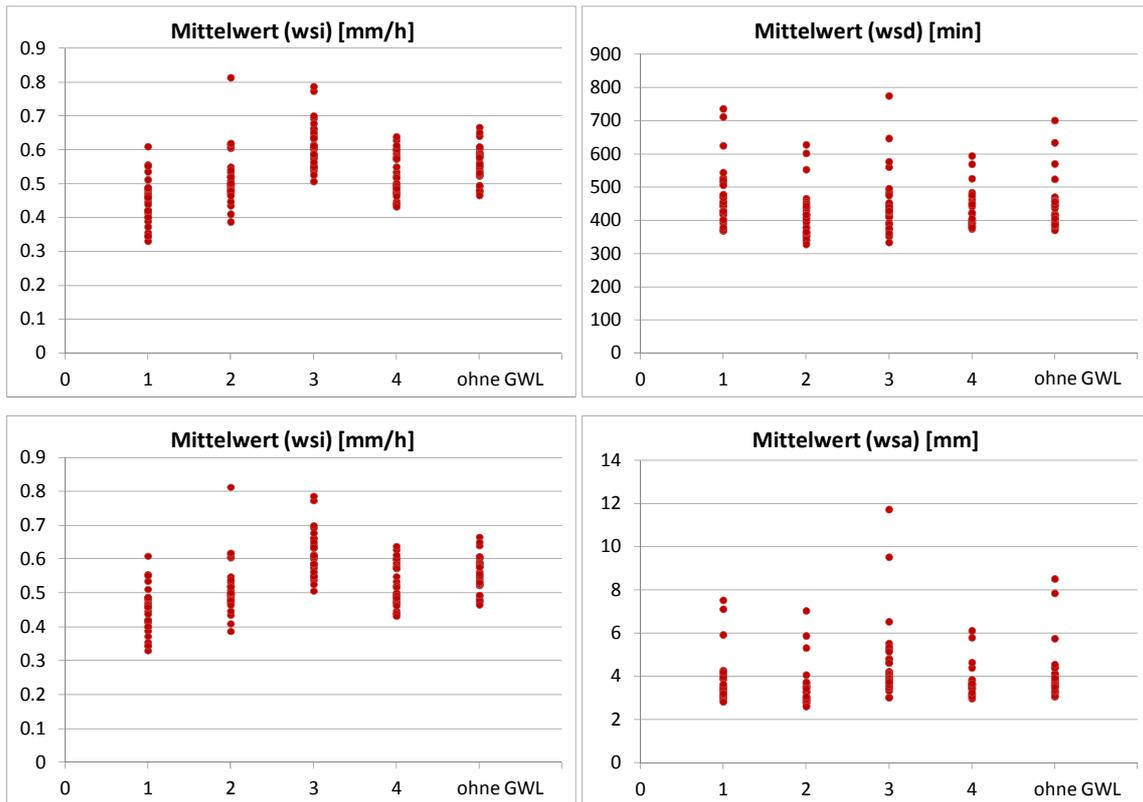


Abbildung A-3 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Winter, sortiert nach GWL mit 4 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

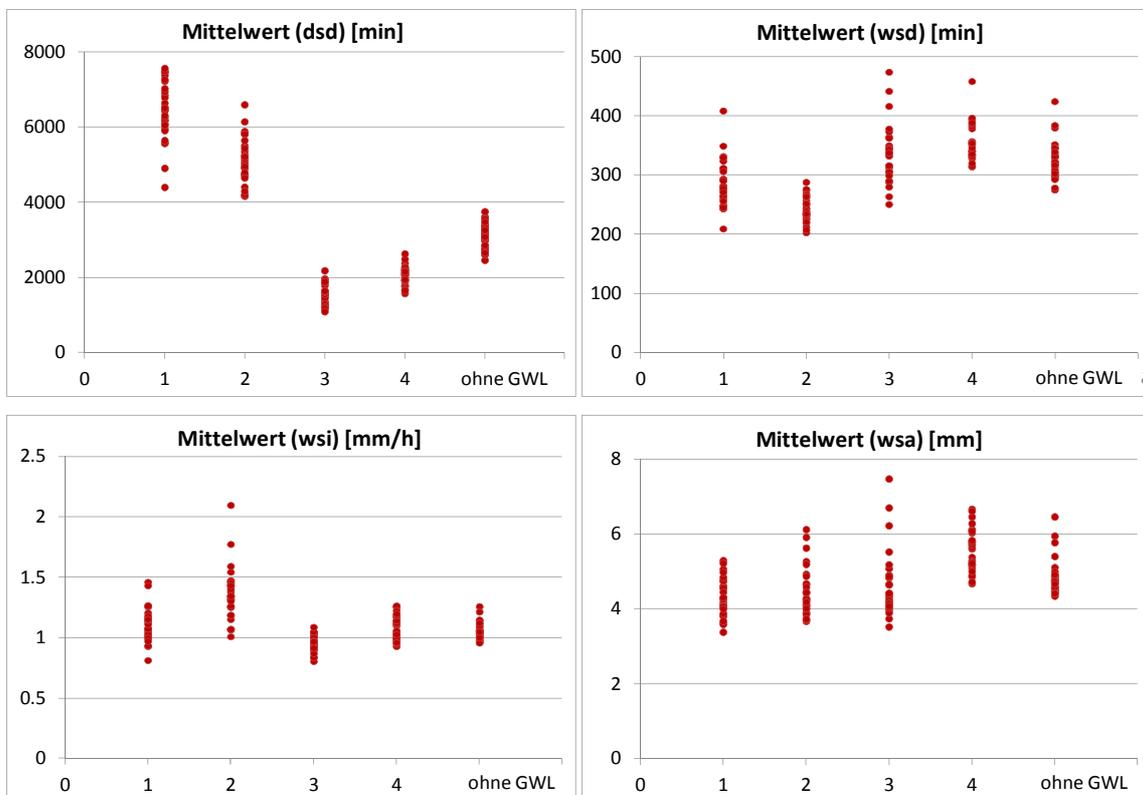


Abbildung A-4 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Sommer, sortiert nach GWL mit 4 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

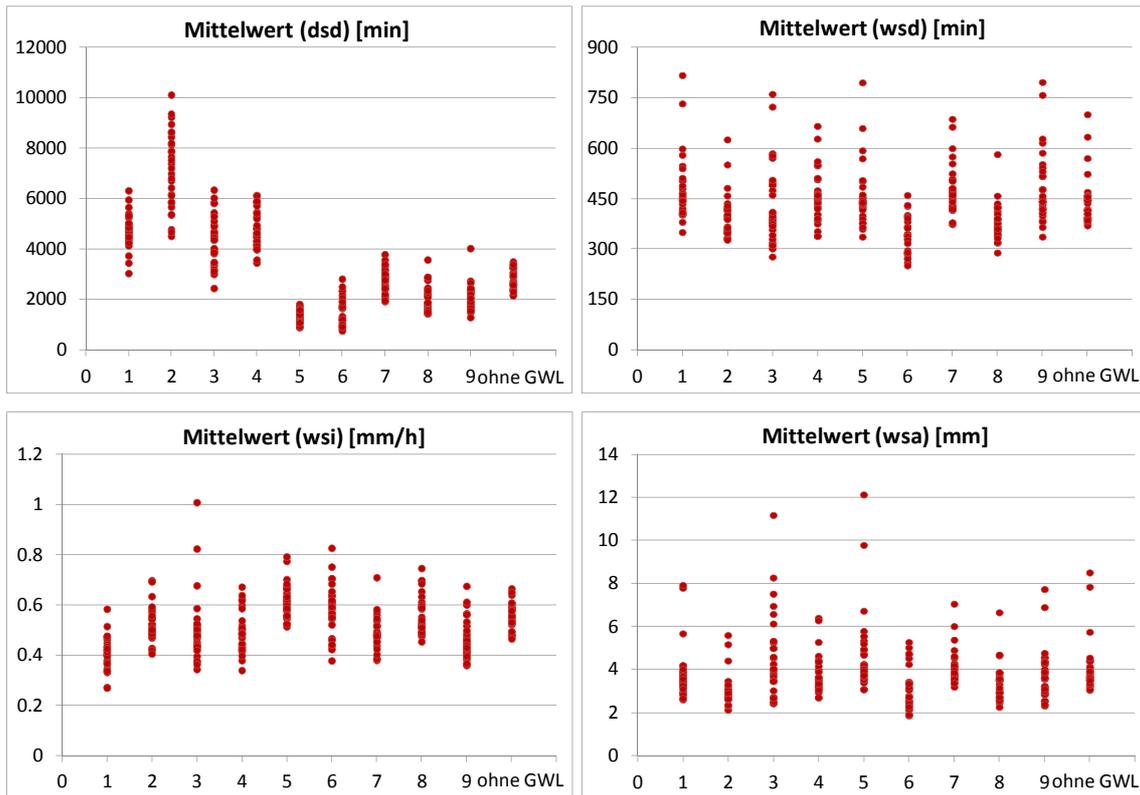


Abbildung A-5 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Winter, sortiert nach GWL mit 8 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe; GWL 9 sind, Ereignisse denen keine GWL zugewiesen werden konnte

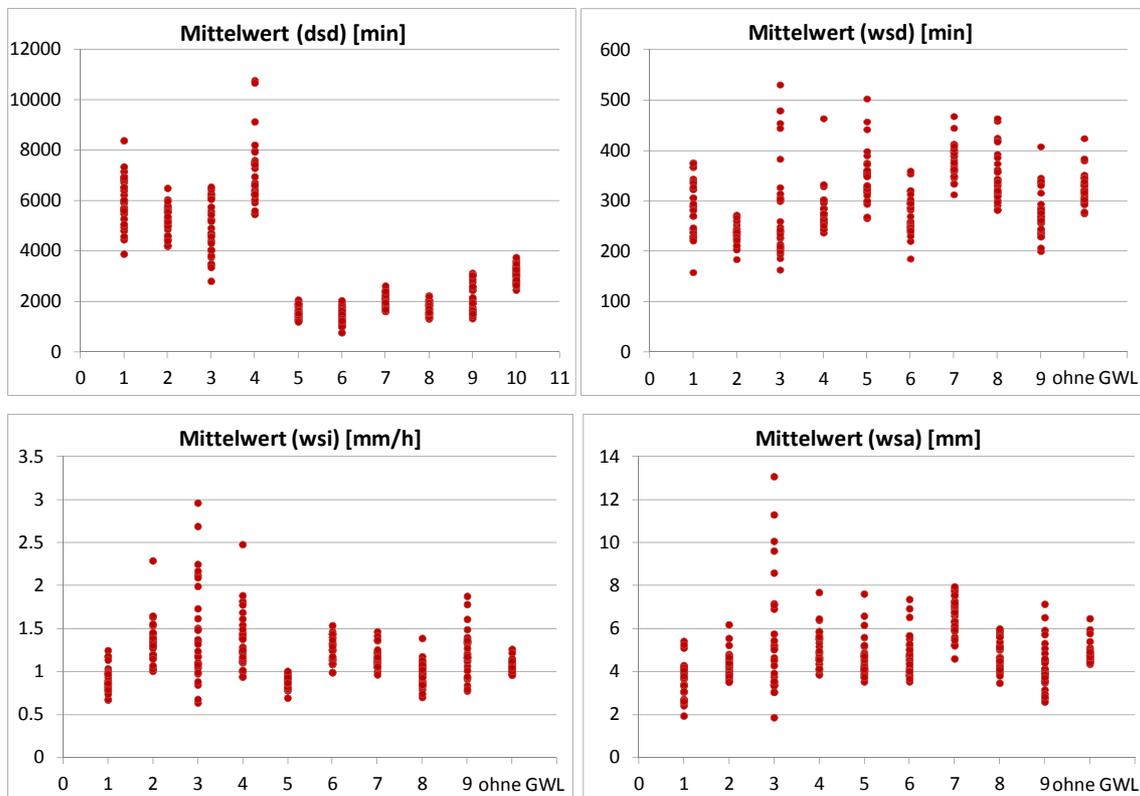


Abbildung A-6 Mittelwert (entspricht L-Moment 1. Ordnung) der Ereignisse im Sommer, sortiert nach GWL mit 8 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe; GWL 9 sind, Ereignisse denen keine GWL zugewiesen werden konnte

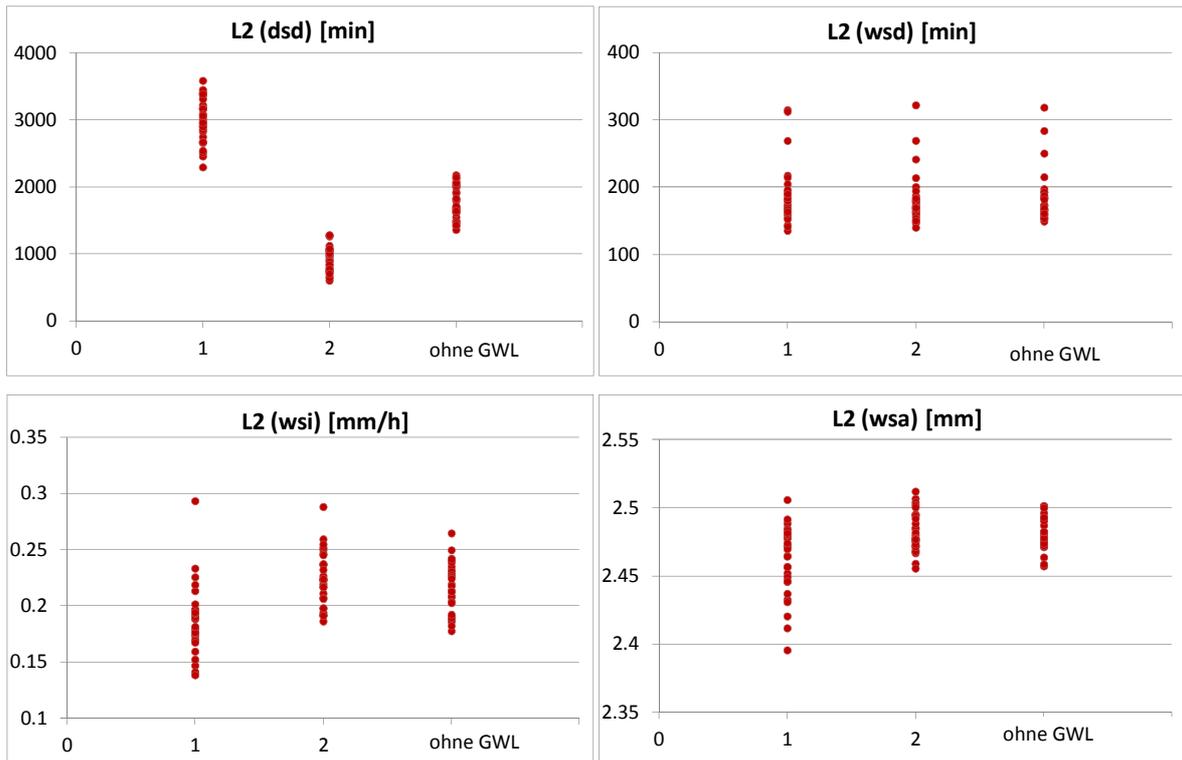


Abbildung A-7 L-Moment 2. Ordnung der Ereignisse im Winter, sortiert nach GWL mit 2 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

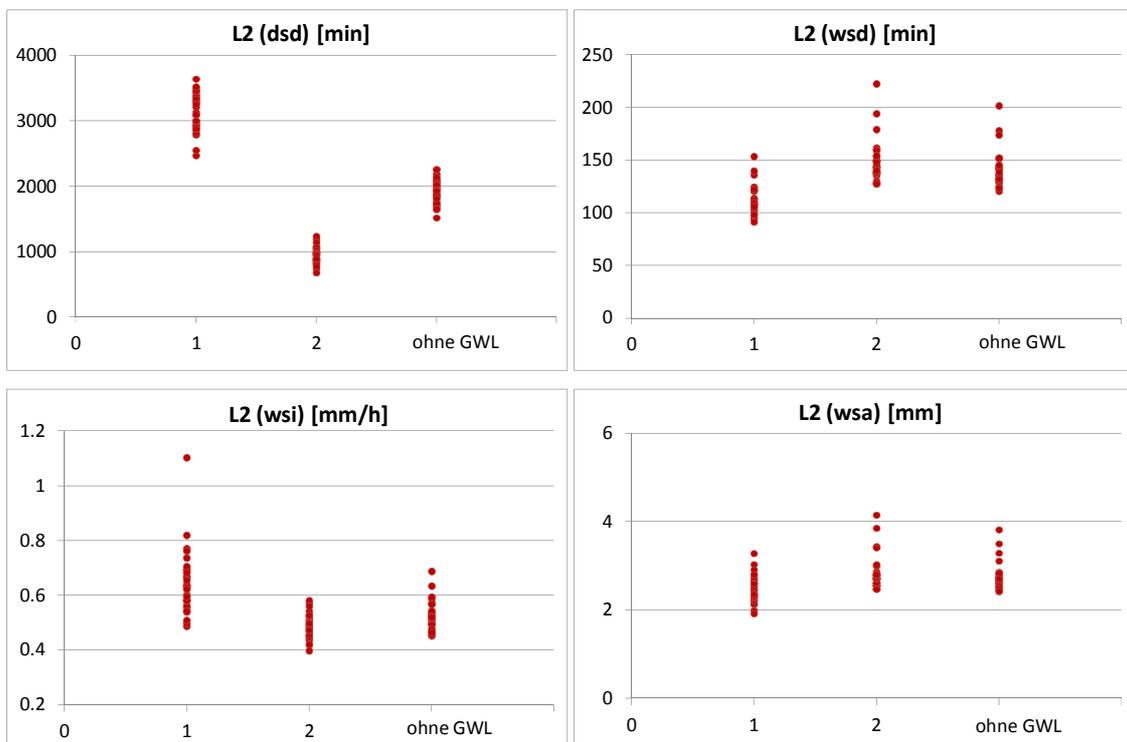


Abbildung A-8 L-Moment 2. Ordnung der Ereignisse im Sommer, sortiert nach GWL mit 2 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

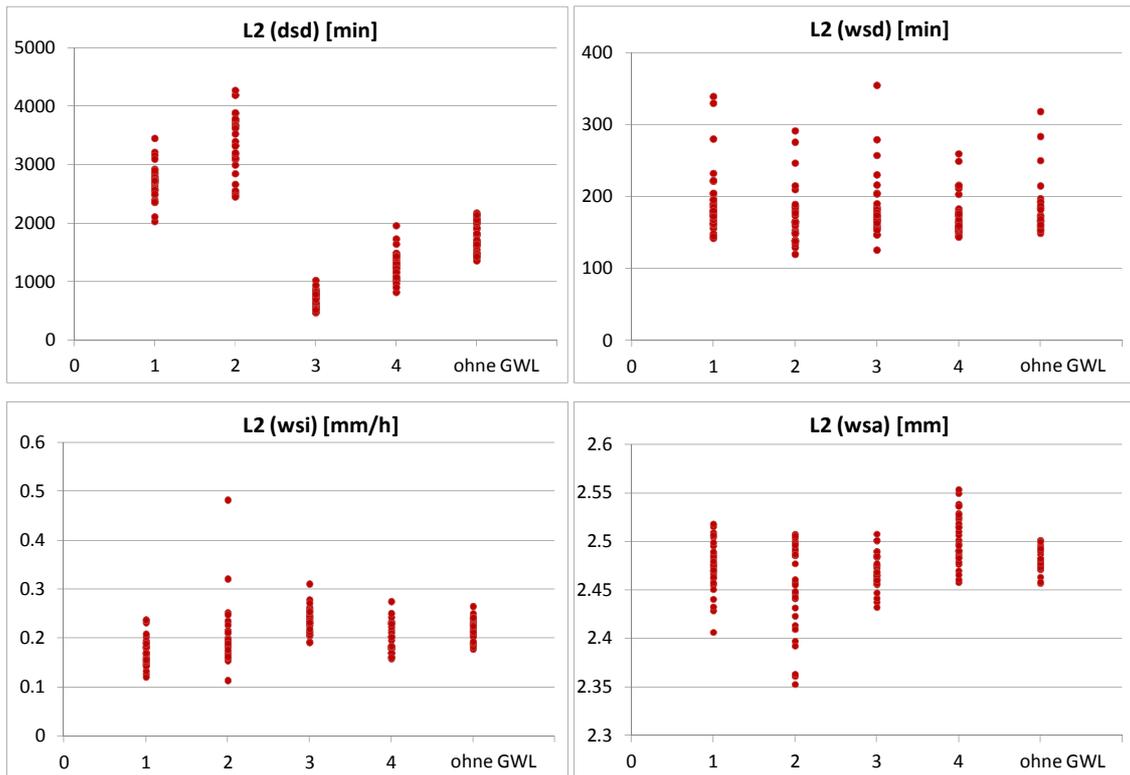


Abbildung A-9 L-Moment 2. Ordnung der Ereignisse im Winter, sortiert nach GWL mit 4 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

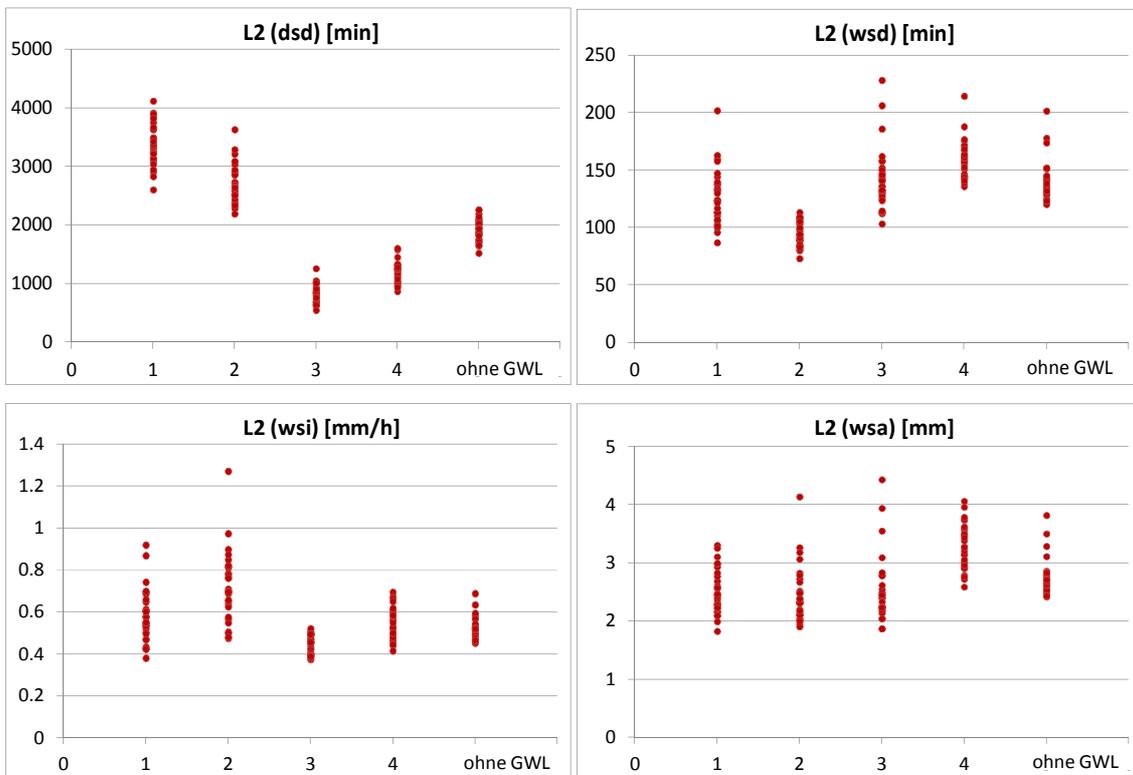


Abbildung A-10 L-Moment 2. Ordnung der Ereignisse im Sommer, sortiert nach GWL mit 4 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe

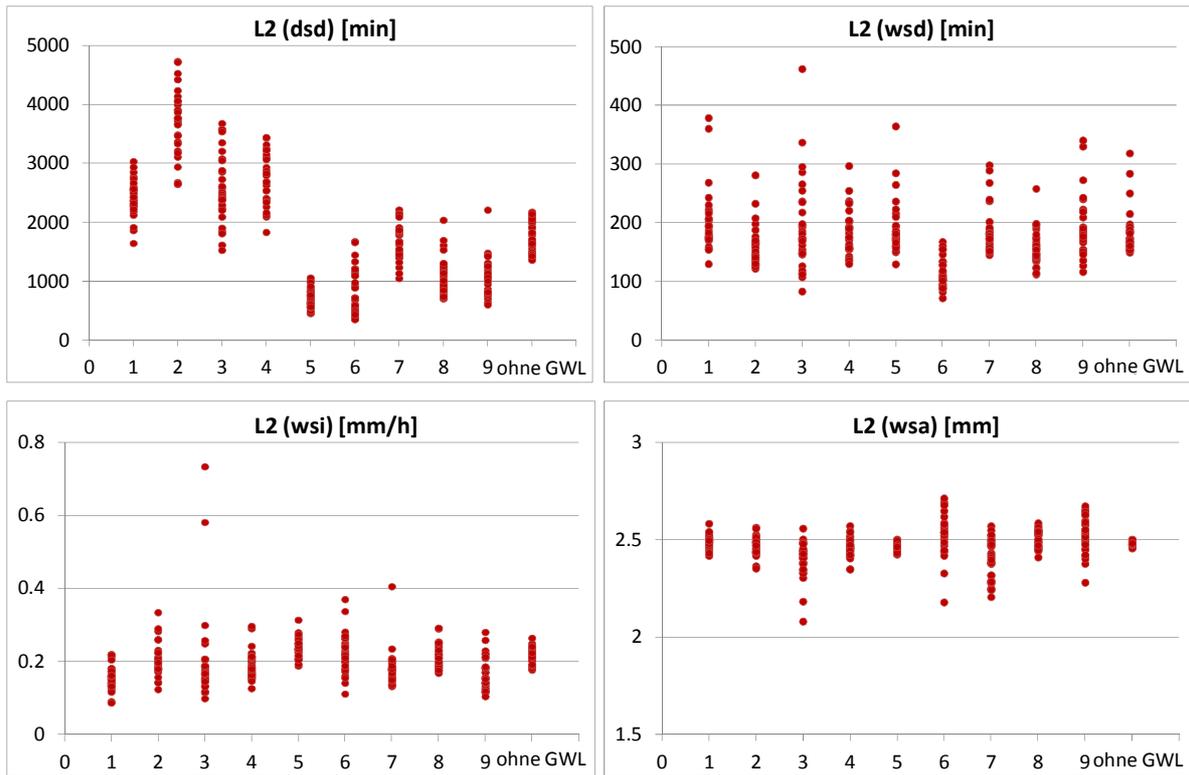


Abbildung A-11 L-Moment 2. Ordnung der Ereignisse im Winter, sortiert nach GWL mit 8 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe; GWL 9 sind Ereignisse, denen keine GWL zugewiesen werden konnte

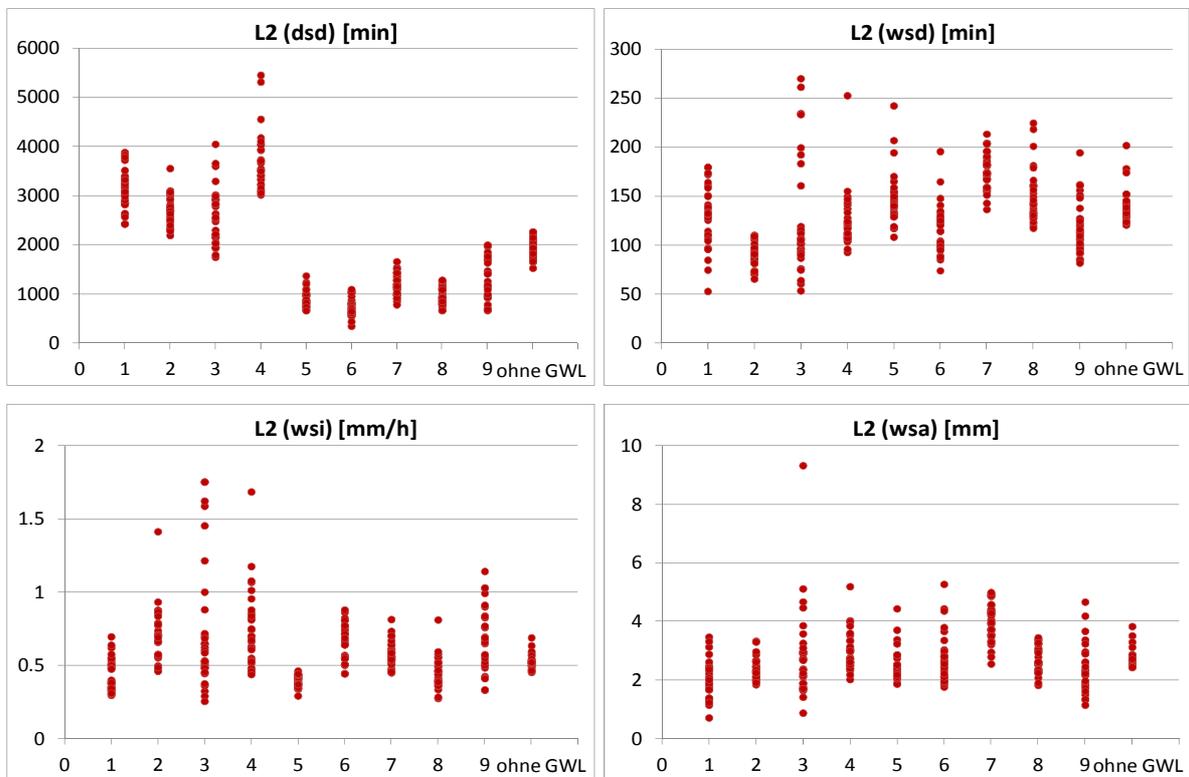


Abbildung A-12 L-Moment 2. Ordnung der Ereignisse im Sommer, sortiert nach GWL mit 8 GWL; „ohne GWL“ zeigt den Wert der gesamten Zeitreihe; GWL 9 sind Ereignisse, denen keine GWL zugewiesen werden konnte

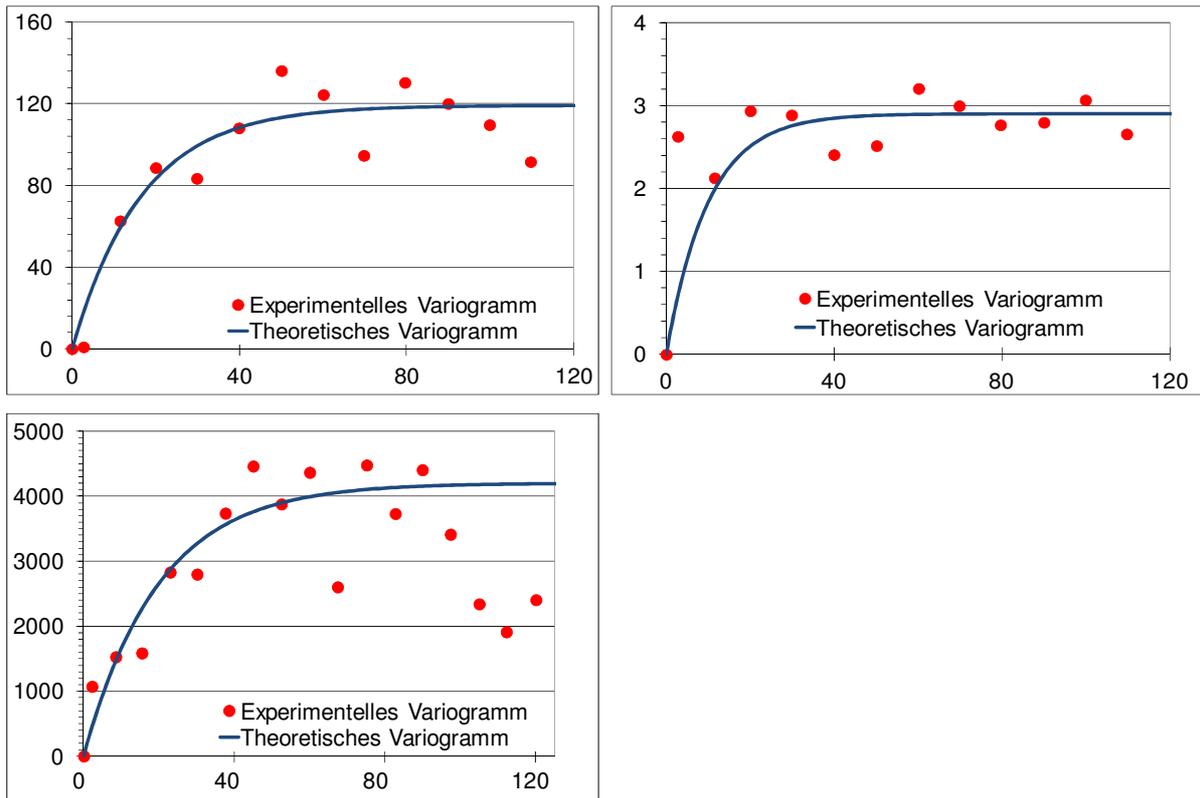


Abbildung A-13 Variogrammschätzung; oben links: Mittelwert der dsd , oben rechts: Mittelwert der wsi , unten rechts: Mittelwert der wsd ; x-Achse: Entfernung in km; y-Achse: Varianz, für dsd durch 1000 dividiert, für wsi mit 1000 multiplizierte Werte.

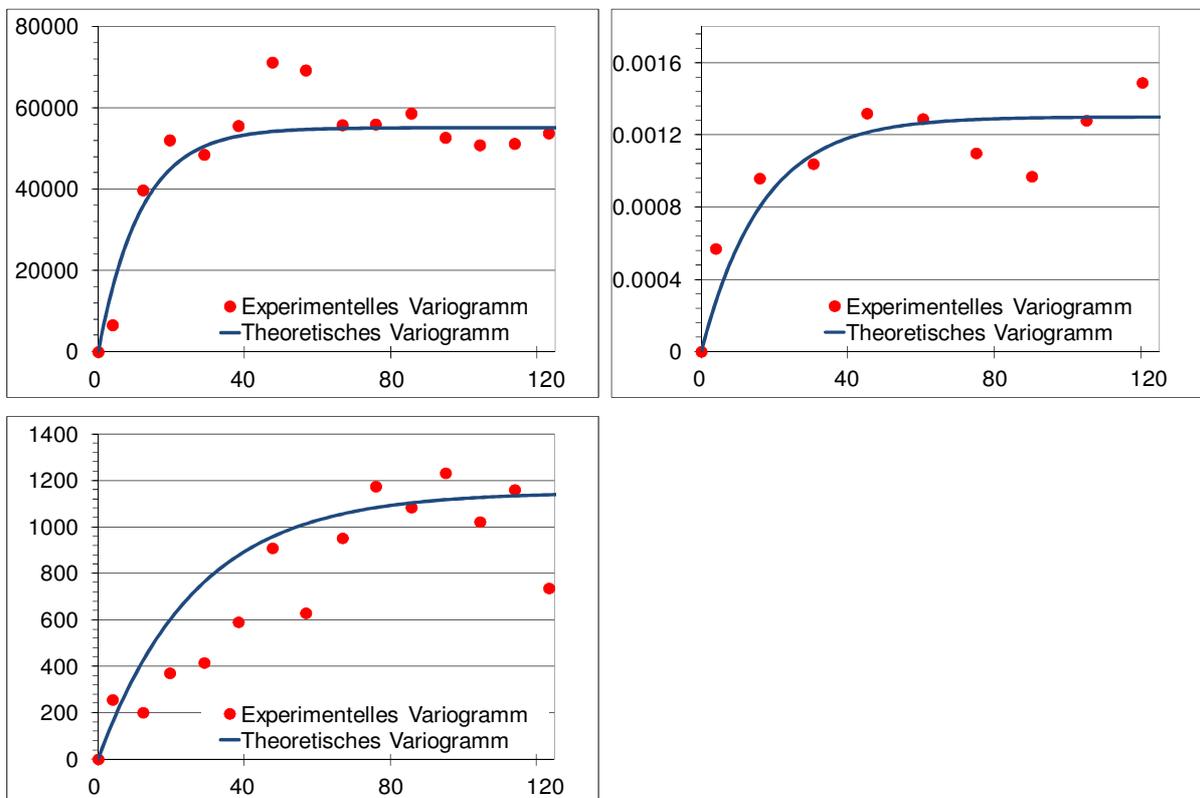


Abbildung A-14 Variogrammschätzung; oben links: 2. L-Moment der dsd , oben rechts: 2. L-Moment der wsi , unten rechts: 2. L-Moment der wsd ; x-Achse: Entfernung in km; y-Achse: Varianz.

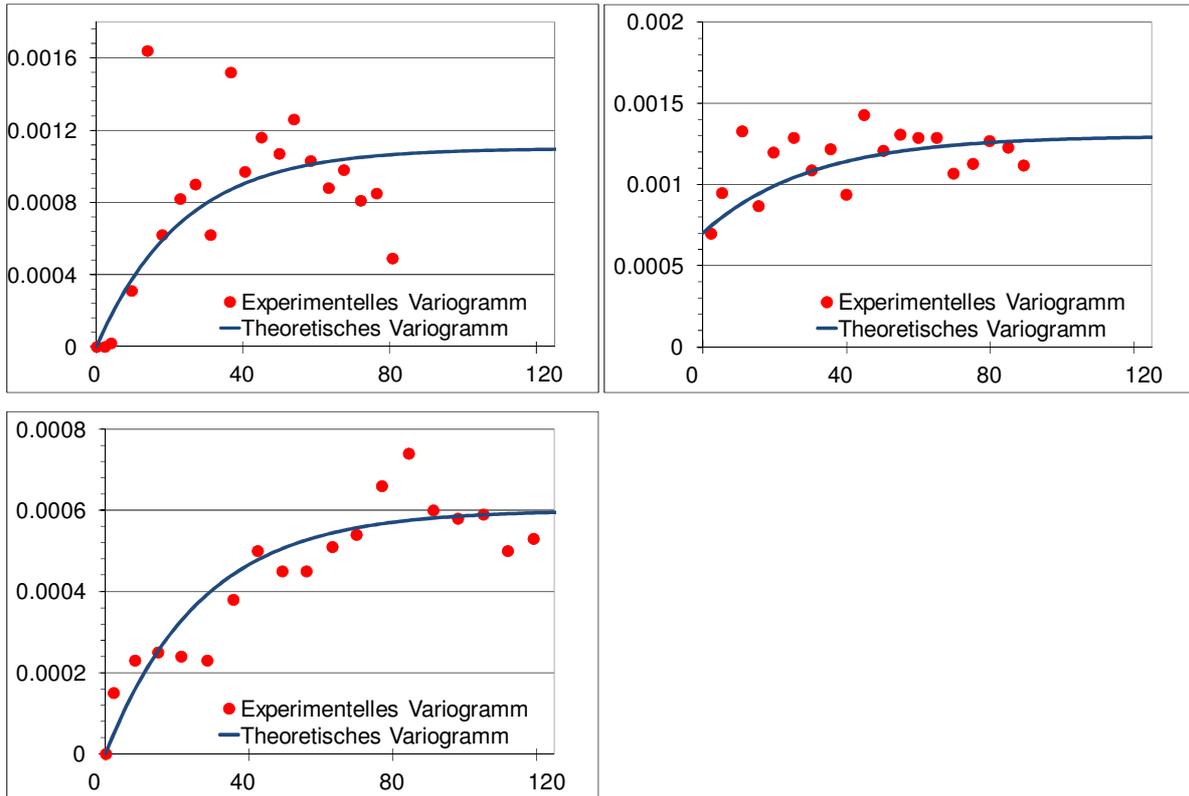


Abbildung A-15 Variogrammschätzung; oben links: Tau-3 der dsd , oben rechts: Tau-3 der wsi , unten rechts: Tau-3 der wsd ; x-Achse: Entfernung in km; y-Achse: Varianz.