

# **Eine neue Strategie zur multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen**

Dissertation zur Erlangung des akademischen Grades  
Doctor rerum naturalium (Dr. rer. nat.)

vorgelegt von

**Dipl.-Hydrol. Ruben Müller**

geboren am 12.07.1982 in Heilbronn

## **Gutachter:**

Prof. Dr. Niels Schütze

Technische Universität Dresden

Prof. Dr. Markus Disse

Technische Universität München

Prof. Dr. Jürgen Stamm

Technische Universität Dresden

Dresden, den 19. September 2014



## Kurzfassung

Wasserwirtschaftliche Speichersysteme sind unverzichtbar, um weltweit die Trinkwasserversorgung, Nahrungsmittelproduktion und Energieversorgung sicherzustellen.

Die multikriterielle simulationsbasierte Optimierung (MK-SBO) ist eine leistungsfähige Methodik, um für Mehrzweck-Talsperrenverbundsysteme (MZ-TVS) eine Pareto-optimale Menge an Kompromisslösungen zwischen konträren Zielen bereitzustellen. Der rechen-technische Aufwand steigt jedoch linear mit der Länge des Simulationszeitraums der Talsperrenbewirtschaftung an. Folglich begrenzen sich MK-SBO-Studien bisher auf Simulationszeiträume von wenigen Jahrzehnten. Diese Zeiträume sind i.d.R. unzureichend, um Unsicherheiten, die aus der stochastischen Natur der Zuflüsse resultieren, adäquat zu beschreiben. Bewirtschaftungsoptimierungen von MZ-TVS hinsichtlich ihrer Zuverlässigkeit, z.B. durch die Maximierung von Versorgungssicherheiten, können sich als wenig belastbar und ermittelte Steuerungsstrategien als wenig robust erweisen.

Um diesen Herausforderungen zu begegnen, wird ein neues modulares Framework zur multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von MZ-TVS (Frams-BoT) entwickelt. Eine Informationserweiterung zu stochastischen Zuflussprozessen erfolgt über ein weiterentwickeltes Zeitreihenmodell mittels generierter Zeitreihen von mehreren Tausend Jahren Länge. Eine neue Methode zur Monte-Carlo-Rekombination von Zeitreihen ermöglicht dann die Nutzung dieser Informationen in der MK-SBO in wesentlich kürzeren Simulationszeiträumen. Weitere Rechenzeit wird durch Parallelisierung und eine fortgeschrittene Kodierung von Entscheidungsvariablen eingespart. Die Simulation von Zuflussdargeboten für multikriterielle Klimafolgenanalysen erfolgt durch ein prozessorientiertes Wasserhaushaltsmodell. Level-Diagramme (Blasco et al., 2008) unterstützten den komplexen Prozess der Entscheidungsfindung.

Die Wirksamkeit und Flexibilität des Frameworks wurden in zwei Fallstudien gezeigt. In einer ersten Fallstudie konnten in einer Klimafolgenanalyse Versorgungssicherheiten von über 99% als ein Ziel eines multikriteriellen Optimierungsproblems maximiert werden, um die Verlässlichkeit der Bewirtschaftung eines MZ-TVS in Sachsen (Deutschland) zu steigern. Eine zweite Fallstudie befasste sich mit der Maximierung der Leistungsfähigkeit eines MZ-TVS in Äthiopien unter verschiedenen Problemformulierungen. In beiden Fallstudien erwiesen sich die erzielten Pareto-Fronten und Steuerungsstrategien gegenüber 10 000-jährigen Zeiträumen als robust. Die benötigten Rechenzeiten der MK-SBO ließen sich durch das Framework massiv senken.

## Abstract

Water resources systems are worldwide essential for a secure supply of potable water, food and energy production.

Simulation-based multi-objective optimization (SB-MOO) is a powerful method to provide a set of Pareto-optimal compromise solutions between various contrary goals of multi-purpose multi-reservoir systems (MP-MRS). However, the computational costs increases with the length of the time period in which the reservoir management is simulated. Consequently, MK-SBO studies are currently restricted to simulation periods of several decades. These time periods are normally insufficient to describe the stochastic nature of the inflows and the consequent hydrological uncertainties. Therefore, an optimization of the reliability of management of MP-MRS, e.g. through the maximization of the security of supply, may not be resilient. Obtained management strategies may not prove robust.

To address these challenges, a new modular framework for simulation-based multi-objective optimization of the reservoir management of multi-purpose multi-reservoir systems (Frams-BoT) is developed. A refined time series model provides time series of several thousand years to extend the available information about the stochastic inflow processes. Then, a new Monte-Carlo recombination method allows for the exploitation of the extended information in the SB-MOO on significantly shorter time periods. Further computational time is saved by parallelization and an advanced coding of decision variables. A process-oriented water balance model is used to simulate inflows for multi-objective climate impact analysis. Level-Diagrams [Blasco et al., 2008] are used to support the complex process of decision-making.

The effectiveness and flexibility of the framework is presented in two case studies. In the first case study about a MP-MRS in Germany, high securities of supply over 99% were maximized as part of a multi-objective optimization problem in order to improve the reliability of the reservoir management. A second case study addressed the maximization of the performance of a MP-MRS in Ethiopia under different formulations of the optimization problem. In both case studies, the obtained Pareto-Fronts and management strategies proved robust compared to 10 000 year time periods. The required computational times of the SB-MOO could be reduced considerably.

# Inhaltsverzeichnis

<b>Inhaltsverzeichnis</b>	<b>1</b>
<b>1 Einleitung</b>	<b>1</b>
1.1 Hintergrund . . . . .	1
1.2 Forschungsziele . . . . .	3
1.3 Aufbau der Arbeit . . . . .	4
<b>I Methoden und Literaturübersicht</b>	<b>7</b>
<b>2 Optimierung der Talsperrensteuerung</b>	<b>9</b>
2.1 Steuerungsstrategien als Werkzeuge zur Bewirtschaftung . . . . .	9
2.2 Einkriterielle und multikriterielle Optimierung . . . . .	10
2.2.1 Lösungsstrategien für multikriterielle Optimierungsprobleme mit evolutionären Algorithmen . . . . .	11
2.2.2 Das Konzept der Pareto-Optimalität in der multikriteriellen Opti- mierung . . . . .	13
2.2.3 Entscheidungshilfetechniken für multikriterielle Probleme . . . . .	15
2.3 Optimierungstechniken für Steuerungsstrategien wasserwirtschaftlicher Spei- chersysteme . . . . .	16
2.3.1 Klassische Optimierungstechniken . . . . .	17
2.3.2 Neuere Optimierungstechniken . . . . .	19
2.4 Versorgungssicherheit und Zeitreihenlänge . . . . .	24
2.5 Überblick zum Stand der Technik . . . . .	25
2.6 Zusammenfassung . . . . .	29
<b>3 Besondere Aspekte der Langfristbewirtschaftung</b>	<b>31</b>
3.1 Talsperrenbewirtschaftung unter klimatisch veränderten Rahmenbedingun- gen . . . . .	31
3.2 Zeitreihengenerierung in der Wasserbewirtschaftung . . . . .	35
<b>4 Zusammenfassung und offene Forschungsfragen</b>	<b>39</b>

<b>II</b>	<b>Framework zur multikriteriellen simulationsbasierten Bewirtschaftungs- optimierung von Mehrzweck-Talsperrenverbundsystemen</b>	<b>41</b>
<b>5</b>	<b>Vorstellung des Gesamtkonzepts</b>	<b>43</b>
<b>6</b>	<b>Beschreibung der Module</b>	<b>47</b>
6.1	Modul A: Talsperrenzuflüsse unter projizierten klimatische Bedingungen . . .	47
6.1.1	Das Wasserhaushaltsmodell WaSiM-ETH . . . . .	47
6.1.2	Modellkalibrierung . . . . .	51
6.2	Modul B: Stochastische Zeitreihengenerierung . . . . .	52
6.2.1	Der SMA-Filter . . . . .	52
6.2.2	Das multivariate HKNN-SMA-Zeitreihenmodell . . . . .	54
6.3	Modul C: Monte-Carlo-Rekombination . . . . .	57
6.3.1	Folgescheitelalgorithmus . . . . .	58
6.3.2	Ablauf der Monte-Carlo-Rekombination . . . . .	59
6.4	Modul D: Multikriterielle Optimierung . . . . .	61
6.4.1	Das MO-CMA-ES-Verfahren . . . . .	61
6.4.2	Parallelisierung der MO-CMA-ES . . . . .	65
6.4.3	Initialisierung der MO-CMA-ES . . . . .	66
6.4.4	Behandlung von Randbedingungen . . . . .	67
6.4.5	Simulation der Talsperrenbewirtschaftung . . . . .	71
6.5	Modul E: Validierung der approximierten Pareto-Menge . . . . .	72
6.5.1	Auswahl zu validierender Lösungen . . . . .	72
6.5.2	Validierung . . . . .	73
6.6	Modul F: Visualisierung und Entscheidungshilfe . . . . .	74
6.6.1	Wertung der Kompromisslösungen . . . . .	74
6.6.2	Bildung von Kompromissklassen und Wahl repräsentativer Lösungen	75
6.6.3	Visualisierung durch Level-Diagramme . . . . .	76
<b>7</b>	<b>Fazit zum Teil II</b>	<b>79</b>
<b>III</b>	<b>Fallstudien</b>	<b>81</b>
<b>8</b>	<b>Fallstudie 1: Mehrzweck-Talsperrenverbundsystem im Erzgebirge</b>	<b>83</b>
8.1	Beschreibung des Talsperrenverbundsystems . . . . .	84
8.1.1	Die Einzugsgebiete der Talsperren . . . . .	84
8.1.2	Das Mehrzweck-Talsperrenverbundsystem . . . . .	85
8.2	Projektion zukünftiger Talsperrenzuflüsse (Modul A) . . . . .	89
8.2.1	Datengrundlagen und Methoden . . . . .	89

8.2.2	Modellaufbau . . . . .	92
8.2.3	Formulierung des Kalibrierungsproblems . . . . .	92
8.2.4	Ergebnisse . . . . .	95
8.2.5	Zusammenfassung . . . . .	98
8.3	Stochastische Zeitreihengenerierung (Modul B) . . . . .	99
8.3.1	Vorgehen . . . . .	99
8.3.2	Ergebnisse . . . . .	103
8.4	Monte-Carlo-Rekombination (Modul C) . . . . .	109
8.4.1	Vorgehen . . . . .	109
8.4.2	Ergebnisse . . . . .	109
8.5	Multikriterielle Optimierung der Talsperrenbewirtschaftung (Module D bis F) . . . . .	113
8.5.1	Implementierung des Talsperrenverbundsystems in OASIS . . . . .	113
8.5.2	Validierung des Talsperrenbewirtschaftungsmodells . . . . .	114
8.5.3	Beschreibung der durchgeführten Szenarienrechnungen . . . . .	114
8.5.4	Mathematische Modellbeschreibung . . . . .	116
8.5.5	Ergebnisse für den rezenten klimatischen Zustand . . . . .	121
8.5.6	Ergebnisse der Klimafolgenanalyse für das Talsperrenverbundsystem	132
8.5.7	Leistungsfähigkeit des Frams-BoT . . . . .	139
8.6	Zusammenfassung . . . . .	141
<b>9</b>	<b>Fallstudie 2: Mehrzweck-Talsperrenverbundsystem in Äthiopien</b>	<b>143</b>
9.1	Beschreibung des Talsperrenverbundsystems . . . . .	143
9.2	Datengrundlagen . . . . .	144
9.3	Stochastische Zeitreihengenerierung (Modul B) . . . . .	145
9.4	Monte-Carlo-Rekombination (Modul C) . . . . .	147
9.5	Multikriterielle Optimierung der Talsperrenbewirtschaftung (Module D bis F) . . . . .	148
9.5.1	Aufbau des Talsperrenbewirtschaftungsmodells . . . . .	148
9.5.2	Beschreibung der durchgeführten Szenarienrechnungen . . . . .	149
9.5.3	Mathematische Modellbeschreibung . . . . .	150
9.5.4	Ergebnisse . . . . .	152
9.6	Zusammenfassung . . . . .	157
<b>10</b>	<b>Zusammenfassung und Ausblick</b>	<b>161</b>
	<b>Literaturverzeichnis</b>	<b>166</b>
	<b>Abbildungsverzeichnis</b>	<b>189</b>

*Inhaltsverzeichnis*

<b>Tabellenverzeichnis</b>	<b>193</b>
<b>Algorithmenverzeichnis</b>	<b>196</b>
<b>Abkürzungsverzeichnis</b>	<b>197</b>
<b>IV Anhang</b>	<b>206</b>
<b>A Methoden</b>	<b>207</b>
<b>B Anwendungsbezogene Benchmarks</b>	<b>211</b>
<b>C Fallstudie 1</b>	<b>216</b>
<b>D Fallstudie 2</b>	<b>235</b>



# 1 Einleitung

## 1.1 Hintergrund

Talsperren sind wasserwirtschaftliche Speicheranlagen, die mithilfe eines Absperrbauwerks ein Fließgewässer in einem Tal zu einem künstlichen See aufstauen. Talsperrenverbundsysteme umfassen mehrere Talsperren, die gemeinsam bewirtschaftet werden. Das so gespeicherte Wasser kann dann in Trockenperioden zur Deckung unterschiedlicher Bedürfnisse abgegeben werden. Die Statistik der International Commission On Large Dams (WCD) zählt weltweit 37641 Talsperren.<sup>1</sup> Diese stellen jährlich rund 1 400 000 GWh Energie zur Verfügung, versorgen die Bewässerungswirtschaft auf einer Fläche von 335 000 km<sup>2</sup>, bieten 292 km<sup>3</sup> Hochwasserschutzraum und versorgen Millionen von Menschen mit Trink- und Brauchwasser (ICOLD, 2003).

Trotz dieser imposanten Zahlen haben gleichzeitig weltweit 783 Millionen Menschen keinen sicheren Zugang zu sauberem Wasser (WHO/UNICEF, 2012) und 925 Millionen Menschen leiden an Unterernährung (FAO, 2010). Zukünftige Herausforderungen können zu einer Verschärfung der Missstände führen (Rosegrant, 2001; Rosegrant et al., 2002). Hierzu zählen der projizierte klimatische Wandel (IPCC, 2007), die wachsende Weltbevölkerung (Vörösmarty et al., 2000) und die fortschreitende Sedimentation (White, 2010).

Studien weisen darauf hin, dass die Bewirtschaftung von Talsperren oftmals auf Steuerungsstrategien beruht, die den potenziellen gesellschaftlichen Nutzen nicht erzielen (unter anderem Oliveira and Loucks, 1997; Labadie, 2004; New et al., 2007; Malekmohammadi et al., 2011; Castelletti et al., 2013). Wasserressourcen werden somit verschwendet. Bei einer zusätzlichen Veränderung der Rahmenbedingungen ohne entsprechende Anpassung der Bewirtschaftung ist von einer weiteren Diskrepanz zwischen erwirtschaftetem und potenziellem gesellschaftlichen Nutzen auszugehen. Daher empfiehlt die WCD, dass aufgrund der zukünftigen Entwicklungen der Rahmenbedingungen der Betrieb von Talsperren regelmäßig anzupassen und zu optimieren sei (WCD, 2000). Bereits seit den 70er Jahren werden hierzu mathematische Optimierungstechniken eingesetzt (Yeh, 1985). Wobei sich die *simulationsbasierte Optimierung* (SBO) als besonders vorteilhaft erweist (Koutsoyiannis and Economou, 2003).

Während 72% der Talsperren weltweit einen einzigen Nutzungszweck erfüllen, dienen

---

<sup>1</sup>Hierzu zählen Talsperren mit einer Mindesthöhe des Absperrbauwerks von 15 Metern.

## 1 Einleitung

24,8 % als Mehrzweck-Talsperren multiplen wasserwirtschaftlichen Nutzungen (ICOLD, 2003). Aufgrund der unvereinbaren Naturen verschiedener Nutzungsformen von Mehrzweck-Talsperren entstehen jedoch oftmals Konflikte zwischen den Bewirtschaftungszielen. Daher erfordert die Bewirtschaftung von Mehrzweck-Talsperren einen Kompromiss bezüglich der Befriedigung der betrachteten Nutzungen. Der Einsatz von *a-posteriori multikriterieller simulationsbasierter Optimierung* ermöglicht es, eine (Pareto-optimale) Menge bestmöglicher Kompromisslösungen bereitzustellen, die das Spannungsfeld zwischen den Bewirtschaftungszielen abdeckt und beschreibt. Jede Kompromisslösung ist mit einer dazugehörigen optimalen Steuerungsstrategie hinterlegt. Entscheidungsträger sind somit in der vorteilhaftesten Position, eine bevorzugte bestmögliche Kompromisslösung aus vielen Möglichkeiten auswählen zu können. Diese Auswahl kann jedoch kompliziert und mühsam sein, weshalb Entscheidungshilfetechniken entwickelt wurden, um den Entscheidungsprozess zu vereinfachen (Lotov and Miettinen, 2008).

Labadie (2004) stellt fest, dass die Entscheidungsträger in der Praxis wissenschaftliche Studien zur Optimierung der Talsperrenbewirtschaftung oft mit großer Skepsis aufnehmen. Die Bewirtschaftung der wasserwirtschaftlichen Speichersysteme erfolgt zumeist, um mögliche Versagensfälle zu vermeiden. Oftmals sind einzuhaltende Versorgungssicherheiten vertraglich geregelt und Abgabemengen vorgeschrieben. Im Gegensatz dazu setzen viele wissenschaftliche Studien auf eine Maximierung der Abgabeleistung oder eine Minimierung von Defiziten. Diese Ziele werden als Summe bzw. Erwartungswert oder als Minimierung eines quadratischen Fehlers zwischen Zielvorgabe und erreichtem Ziel formuliert (Soltani et al., 2008). Die Folge ist, dass die Implementierung der optimierten Steuerungsstrategien oftmals unterbleibt (Labadie, 2004). Die Aufnahme von Versorgungssicherheiten in die Formulierung der Optimierung könnte die Akzeptanz wissenschaftlicher Studien in der Praxis steigern. Jedoch berücksichtigen bisher nur wenige Studien Versorgungssicherheiten als wichtige Leistungsmerkmale wasserwirtschaftlicher Speichersysteme.

Kjeldsen and Rosbjerg (2004) verweisen darauf, dass Datengrundlagen von 1 000 bis 10 000 Jahren notwendig sind, um Zuflüsse als stochastischen Prozess und die damit verbundenen Unsicherheiten ausreichend zu beschreiben. Erst dann seien statistisch verlässliche Aussagen über Versorgungssicherheiten gewährleistet. Da diese als Beobachtungsdaten nicht verfügbar sind, müssen diese langjährigen Zeiträume durch stochastische Zeitreihenmodelle zur Verfügung gestellt werden. Auch die DIN-Norm 19700-11 (Deutsches Institut für Normung, 2004) empfiehlt für „verlässliche Angaben“ zu Sicherheiten „Optimierungsrechnungen zur Speicherbewirtschaftung“ auf Basis von „Langzeitsimulationen mit stochastischen Modellen über 1 000 oder mehr Jahre“. Koutsoyiannis et al. (2002) berichten jedoch bereits bei Optimierungszeiträumen von 2 000 Jahren von extremen Rechenzeiten. Unter den genannten Anforderungen ist eine multikriterielle Optimierung, die dem Entscheidungsträger Pareto-

optimale Lösungen bereitstellt, rechentechnisch wesentlich aufwendiger und daher bis jetzt nicht in der Literatur zu finden.

Für wasserwirtschaftliche Speichersysteme wäre in der Klimafolgenforschung ebenfalls eine Umsetzung der genannten Anforderungen sinnvoll. Hier zeigt sich jedoch, dass die Abschätzungen der zukünftigen Leistungsfähigkeiten der Speichersysteme und die Bereitstellung angepasster Steuerungsstrategien für wasserwirtschaftliche Speichersysteme derzeit auf einkriterielle Optimierungen beschränkt sind (Brass, 2006; Raje and Mujumdar, 2010; Eum and Simonovic, 2010; Eum et al., 2012). Da jedoch für Mehrzweckspeicher nicht davon ausgegangen werden kann, dass die bisher eingegangenen Kompromisse auch unter veränderten Rahmenbedingungen die beste Wahl darstellen, kommt hier der multikriteriellen Optimierung eine besondere Bedeutung zu.

## 1.2 Forschungsziele

Um den genannten Herausforderungen zu begegnen, wird in dieser Arbeit eine neue Strategie zur effizienten multikriteriellen simulationsbasierten Optimierung entwickelt. Die folgenden Ziele stehen dabei im Mittelpunkt dieser Arbeit:

- Die multikriterielle simulationsbasierte Optimierung von Steuerungsstrategien von Mehrzweck-Talsperrenverbundsystemen unter expliziter Berücksichtigung von Versorgungssicherheiten, auf Basis der hierfür notwendigen Zeiträume in der Langfristsimulation ist zu ermöglichen. Die Formulierung von Versorgungssicherheiten als Zielfunktion erlaubt die Maximierung der Zuverlässigkeit der Bewirtschaftung als ein Ziel einer multikriteriellen Optimierung.
- Die Strategie soll möglichst effizient arbeiten, um auch mehrere Optimierungsrechnungen, trotz der effektiven Ausnutzung von Zuflusszeitreihen mit einer Länge von mehreren Tausend Jahren, in vertretbarem Zeiteinsatz zu ermöglichen.
- Dies erlaubt sowohl die Analyse mehrerer Optimierungen für Szenarien unter realen Rahmenbedingungen mit planerischen Eingriffen ins wasserwirtschaftliche System als auch für Szenariensembles für klimatisch veränderte Rahmenbedingungen (Klimafolgenforschung).
- Der Einsatz von Entscheidungshilfetechniken soll die Ergebnisse einfach vermittelbar machen und dem Entscheidungsträger bei der Wahl der bevorzugten Lösung unterstützen.

Die Umsetzung der Ziele führt zu einem neuartigen *Framework zur a posteriori multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen* (Frams-BoT). Die durchzuführenden Arbeitsschritte sind nach dem Ablauf methodisch in Module zusammengefasst. Den Kern des Frameworks bildet eine multikriterielle

simulationsbasierte Optimierung. Diese basiert auf der Kombination einer leistungsfähigen *evolutionären Strategie* (ES) und einem *adaptiven Talsperrenbewirtschaftungsmodell* (ATM). Diese Kombination ist in der Lage, nahezu beliebige Talsperrensysteme unter komplexen Bewirtschaftungsstrategien zu simulieren und bietet somit eine hohe Flexibilität. Ein neues, einfach zu handhabendes multivariates Zeitreihenmodell ermöglicht die stochastische Generierung von korrelierten Zeitreihen, die als Grundlage der Langfristsimulationen mit einem ATM benötigt werden.

Um Klimafolgenanalysen durchführen zu können, sind zunächst zukünftige Zuflussdargebote abzuschätzen. Diese können hier durch ein physikalisch begründetes und flächendifferenziertes Wasserhaushaltsmodell simuliert werden. Eine robuste Kalibrierung des Modells erfolgt multikriteriell mit der evolutionären Strategie des Frameworks.

Der Umstand, dass die optimierten Steuerungsstrategien nur von den (impliziten) Eigenschaften des stochastischen Prozesses, jedoch nicht von der Realisierung abhängen (Koutsoyiannis and Economou, 2003), erlaubt die extremen Rechenzeiten bei Simulationen über mehrere Tausend Jahre beherrschbar zu machen. Eine neu entwickelte Methodik dient hierbei zur Verkürzung der langjährigen synthetischen Zeitreihen unter Erhaltung relevanter hydrologischer Informationen. Der Simulationszeitraum, in dem die Talsperrenbewirtschaftung in der Optimierung evaluiert wird, lässt sich drastisch reduzieren, ohne das signifikante Unterschiede zu einer simulationsbasierten Optimierung über den gesamten langjährigen Zeitraum auftreten. Die Zulässigkeit des Ansatzes wird in einer nachfolgenden Validierung der Pareto-Menge überprüft. Die Parallelisierung der verwendeten ES und eine erweiterte effiziente Kodierung von Entscheidungsvariablen spart weitere Rechenzeit ein.

Die ausgewählte Entscheidungshilfetechnik ermöglicht die verständliche Visualisierung hochdimensionaler Ergebnisse und bewertet gleichzeitig die Pareto-optimalen Lösungen hinsichtlich ihrer Kompromissfähigkeit. Die Auswahl weniger repräsentativer Kompromisslösungen reduzieren die umfangreichen Ergebnismengen auf wesentliche Kompromisslösungen und entlasten somit den Entscheidungsträger in der Auswahl.

### 1.3 Aufbau der Arbeit

Die weitere Arbeit ist in vier Teile gegliedert. In Teil I werden Grundlagen und Methoden zur Bewirtschaftungsoptimierung von Talsperren zur Verfügung gestellt und diskutiert. Außerdem wird der Stand der Forschung auf diesem Gebiet und weiteren relevanten Forschungsgebieten, wie der Klimafolgenforschung und der stochastischen Zeitreihenmodellierung, vorgestellt. Abschließend wird zum ersten Teil eine Zusammenfassung gegeben und Forschungsfragen diskutiert.

Teil II führt das neu entwickelte modulare Framework zur multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen (Frams-BoT) ein. In Teil III erfolgt die Anwendung des Frameworks in zwei Fallstudien.

Die erste Fallstudie konzentriert sich auf: (1) die Maximierung von hohen Versorgungssicherheiten eines Mehrzweck-Talsperrenverbundsystems in Rahmen einer multikriteriellen Optimierung für den Ist-Zustand und unter planerischen Eingriffen und (2) eine multikriterielle Klimafolgenanalyse. In der Fallstudie wird hierzu eine Formulierung vorgeschlagen, mit der mehrere zu maximierende Versorgungssicherheiten in einer Zielfunktion kombiniert werden können. Das hierbei betrachtete wasserwirtschaftliche Speichersystem liegt im sächsischen Osterzgebirge (Deutschland) und umfasst die Talsperren Klingenberg, Lehmühle und Rauschenbach.

Die zweite Fallstudie zeigt mögliche Vorteile der Strategie, anhand einer multikriteriellen Optimierung eines weiteren Mehrzweck-Talsperrenverbundsystems im Einzugsgebiet des Tanasees (Äthiopien), auch für klassisch formulierte Zielfunktionen auf. Das betrachtete Speicherverbundsystem umfasst den für Äthiopien wichtigen und wasserwirtschaftlich bewirtschaftbaren Tanasee und vier neu errichtete Talsperren, die dessen Hauptzuflüsse für die Bedarfsdeckung von Bewässerungsprojekten aufstauen.

Das letzte Kapitel beschließt mit der Zusammenfassung und dem Ausblick die vorliegende Arbeit.



# **Teil I**

## **Methoden und Literaturübersicht**





## 2 Optimierung der Talsperrensteuerung

### 2.1 Steuerungsstrategien als Werkzeuge zur Bewirtschaftung

Nach Abbildung 2.1 sieht die gängige Aufteilung des Stauraums einer Mehrzweck-Talsperre einen *Reserveraum*, einen *Bewirtschaftungsraum* und den *gewöhnlichen Hochwasserschutzraum* vor (Maniak, 2005). Der Reserveraum wird aus Gründen der Wasserqualität vorgesehen oder er reserviert Wasser für kritische Abgaben während Trockenperioden. Er stellt das Absenkziel der Talsperre dar, wenn Wasser aus dem Bewirtschaftungsraum zur Bedarfsdeckung abgegeben wird. Ist das Zuflussdargebot ausreichend, ist der Bewirtschaftungsraum gefüllt zu halten und stellt somit das Stauziel dar. Der gewöhnliche Hochwasserschutzraum liegt oberhalb des Bewirtschaftungsraums und wird nur im Hochwasserfall gefüllt (außergewöhnliches Stauziel), um im Unterstrom ein Überschreiten des Maximaldurchflusses zu verhindern.




Abbildung 2.1: Gängige Einteilung des Stauraums bei Mehrzweck-Talsperren (entnommen aus Maniak, 2005)

Als Leitfaden für die Bewirtschaftung der Talsperre stehen dem Staumeister in der Regel festgelegte Steuerungsstrategien, also Betriebsregeln, zur Verfügung.<sup>1</sup> Sie sind oftmals heuristischer Natur und definieren geforderte Stauziele oder Abgaben in Abhängigkeit von der Saison oder von Zustandsgrößen, wie z.B. Zuflüssen oder Speicherinhalten. Zumeist liegen diese Betriebsregeln in grafischer oder tabellarischer Form vor. *Regelkurven* geben für definierte Zeitschritte (oftmals 10-tägig, oder monatlich) Speicherkontrollvolumina vor, um den Stauinhalt einer Talsperre in *Staulamellen* zu unterteilen. Mehrere Staulamellen sind in einem *Lamellenplan* zusammengefasst. *Dispatcherpläne* unterteilen den Bewirtschaftungsraum durch Regelkurven in untergeordnete Staulamellen, die mit abnehmendem Speicherinhalt jeweils geringere Regelabgaben vorschreiben. Lund and Ferreira (1996) und Lund and Guzman (1999) geben einen Überblick über gängige Steuerungsstrategien für Talsperren und Talsperrenverbundsysteme. Neuere Steuerungskonzepte schlagen unter anderem Nalbantis and Koutsoyiannis (1997), Oliveira and Loucks (1997) und Dittmann et al. (2009) vor.

## 2.2 Einkriterielle und multikriterielle Optimierung

Im Folgenden sollen in Kürze die notwendigen mathematischen Formulierungen für die ein- und multikriterielle Optimierung eingeführt werden.

Es sei  $\mathbf{x} = (x_{i=1}, \dots, x_{i=n}) \in \mathbb{R}^n$  der Entscheidungsvektor bestehend aus  $i = 1, \dots, n$  Entscheidungsvariablen  $x_i$  aus dem Entscheidungsraum  $\mathbb{R}^n$ . Das Vorhandensein von Ungleichheits-Randbedingungen,

$$g(\mathbf{x}) \geq 0, \quad (2.1)$$

oder Gleichheits-Randbedingungen

$$h(\mathbf{x}) = 0 \quad (2.2)$$

beschränkt  $\mathbf{x}$  auf einen zulässigen Entscheidungsraum  $\mathcal{X} \subset \mathbb{R}^n$ , der ein Unterraum von  $\mathbb{R}^n$  ist. In der **einkriteriellen Optimierung** (EKO) wird  $\mathbf{x}$  durch Einsatz eines deterministischen oder stochastischen Optimierungsverfahrens angepasst, um eine einzelne Zielfunktion  $f(\mathbf{x})$ ,  $f: \mathcal{X} \rightarrow \mathbb{R}$  zu minimieren

$$\min_{\mathbf{x} \in \mathcal{X}} f(\mathbf{x}). \quad (2.3)$$

Eine entsprechende Maximierung wird durch die Multiplikation der Zielfunktionswerte mit einem Faktor von  $-1$  erreicht:  $\max_{\mathbf{x} \in \mathcal{X}} = -1 (\min_{\mathbf{x} \in \mathcal{X}} -1 \times f(\mathbf{x}))$ . Die **multikriterielle Optimierung** (MKO) ist eine Erweiterung der einkriteriellen Optimierung, um simultan  $m$

---

<sup>1</sup>Die kurzfristige Talsperrensteuerung (z.B. Steuerung im Hochwasserfall) nicht inbegriffen.

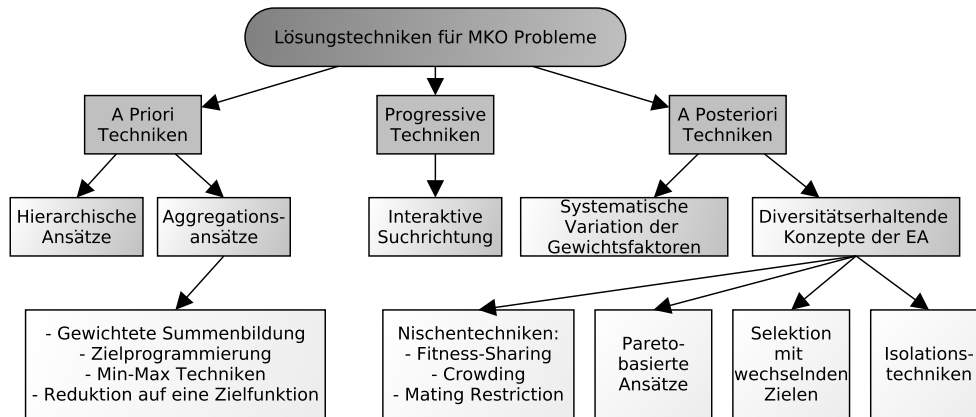


Abbildung 2.2: Klassifikation der Lösungsstrategien für multikriterielle Optimierungsprobleme (nach Meyer, 2004).

Zielfunktionen eines Zielfunktionsvektors  $\mathbf{f}(\mathbf{x}) = (f_{j=1}(\mathbf{x}), \dots, f_{j=m}(\mathbf{x}))$ ,  $\mathbf{f}(\mathbf{x}) : \mathcal{X} \rightarrow \mathbb{R}$  zu minimieren,

$$\min_{\mathbf{x} \in X} \mathbf{f}(\mathbf{x}). \quad (2.4)$$

Mit Zielfunktionen werden Ziele des Entscheidungsträgers formuliert. Die MKO wird bei Optimierungsproblemen eingesetzt, bei denen mehrere abhängige und konträre Ziele von Interesse sind. Liegen Zielkonflikte vor, dann bedingt die Verbesserung eines Ziels zumeist gleichzeitig eine Verschlechterung anderer Ziele. In diesem Fall existiert keine Lösung, die für alle Ziele optimal ist (Zhou et al., 2011) und es sind Kompromisse zwischen den konträren Zielen zu finden.

### 2.2.1 Lösungsstrategien für multikriterielle Optimierungsprobleme mit evolutionären Algorithmen

Die vielfältigen bekannten Ansätze zum Lösen multikriterieller Optimierungsprobleme lassen sich aus der Sicht eines Entscheidungsträgers auf das Optimierungsproblem klassifizieren (Van Veldhuizen and Lamont, 2000). Die von Van Veldhuizen and Lamont (2000) und Hwang and Masud (1979) klassifizierten Lösungsstrategien für MKO Probleme lassen sich nach Meyer (2004) vereinen (siehe Abbildung 2.2). Demnach existieren drei Hauptklassen mit jeweils zugehörigen Ansätzen.

**A priori Entscheidungsfindung** setzt voraus, dass der Entscheidungsträger bereits vor der Optimierung die Wichtigkeit der einzelnen konträren Ziele in Relation setzen kann. Die Entscheidungsfindung und Präferenzierung findet somit *vor* der eigentlichen Optimierung statt, da bereits eine Vorstellung über die Art des gewünschten Kompromisses besteht.

*Hierarchische Ansätze* minimieren die Ziele in einer festgelegten Reihenfolge. Als Nebenbedingungen gilt jeweils, dass die zuvor minimierten Ziele sich nur um einen festgelegten Betrag verschlechtern dürfen. Durch *Aggregationsansätze* lassen sich mehrere Ziele in eine skalare Zielfunktion überführen. Bei der *gewichteten Summenbildung* erfolgt eine Multiplikation oder Summierung der zuvor normierten Zielfunktionen mit Wichtungsfaktoren, die die Präferenzen des Entscheidungsträgers widerspiegeln. *Zielprogrammierung* und *Min-Max-Techniken* setzen jeweils einen Satz gewünschter Zielfunktionswerte voraus. Die Minimierung eines gewichteten Abstandsmaßes bzw. der gewichteten Abweichung führt dann zu den gewünschten Zielfunktionswerten. Grundsätzlich wird in der a priori Entscheidungsfindung also das multikriterielle Optimierungsproblem in eine Form überführt, die mit einem einkriteriellen Optimierungsalgorithmus gelöst werden kann.

**Progressive Entscheidungsfindung** verschmilzt den Entscheidungsprozess und den Optimierungsvorgang, indem der Entscheidungsträger die “Suchrichtung” der Optimierung interaktiv lenkt, um bestimmte Ziele stärker zu priorisieren.

**A posteriori Entscheidungsfindung** setzt den Entscheidungsprozess an den Ende Optimierungsprozesses. Es ist daher kein Vorwissen für die Durchführung der Optimierung nötig. Dem Entscheidungsträger wird als Ergebnis eine Menge an Kompromisslösungen präsentiert. Diese Kompromisslösungen decken idealerweise das gesamte *Spannungsfeld* des Konfliktes zwischen den Zielfunktionen ab. Anhand seiner Präferenz kann der Entscheidungsträger dann die Kompromisslösungen aus der Ergebnis-Menge auswählen.

Die *systematische Variation der Gewichtsfaktoren* basiert auf den Aggregierungsansatz und basiert auf vielfachen Optimierungsläufen mit jeweils variierenden Wichtungsfaktoren durch. *Diversitätserhaltende Konzepte* nutzen direkt die populationsbasierte Arbeitsweise der evolutionärer Algorithmen aus. Durch eine der in Abbildung 2.2 genannten Mechanismen werden die Individuen der Population gezielt „gesteuert“, um in einem Optimierungslauf Lösungen über das gesamte Spannungsfeld des Konflikts und den konträren Zielen zu verteilen.

Freitas (2004) weist darauf hin, dass Aggregationstechniken im Grunde ad-hoc-Herangehensweisen sind. Der Autor weist ausführlich auf Vor- und Nachteile der aufgeführten Techniken und Ansätze hin und führt mehrere Gründe an, warum hierarchische Ansätze und vor allem Pareto-basierte Ansätze vorzuziehen sind. Jüngere Übersichtsartikel zur multikriteriellen Optimierung mit evolutionären Algorithmen (Abschnitt 2.3.2) sind von einer Reihe von Autoren zu finden (Deb, 2007; Ishibuchi et al., 2008; Zhou et al., 2011). Entscheidungshilfekonzepte für die a posteriori Entscheidungsfindung werden in Abschnitt 2.2.3 diskutiert.

### 2.2.2 Das Konzept der Pareto-Optimalität in der multikriteriellen Optimierung

Abbildung 2.3 veranschaulicht das vorgestellte Konzept der Pareto-Optimalität als ein zentrales Konzept in der (a posteriori) multikriteriellen Optimierung. Durch das Konzept der Dominanz können Lösungen im Optimierungsprozess hinsichtlich mehrerer Ziele verglichen und strikt partiell geordnet werden. Eine Lösung  $\mathbf{x} \in \mathbb{R}^n$  dominiert demnach eine Lösung  $\check{\mathbf{x}} \in \mathbb{R}^n$  (formuliert als  $\mathbf{x} \prec \check{\mathbf{x}}$ ), wenn exakt  $\forall j \in \{1, \dots, m\} : f_j(\mathbf{x}) \leq f_j(\check{\mathbf{x}})$  und  $\exists j \in \{1, \dots, m\} : f_j(\mathbf{x}) < f_j(\check{\mathbf{x}})$  zutrifft.

Das Ergebnis einer a posteriori MKO stellt eine Menge  $\Theta \subset \mathcal{X}$  an Lösungen dar. Diese Lösungen werden durch keine weiteren Lösungen dominiert. Die Menge ist also selbst nicht-dominiert und es gilt  $\Theta = \{\mathbf{x} \mid \mathbf{x} \in \mathcal{X} \wedge \nexists \check{\mathbf{x}} \in \mathcal{X} : \check{\mathbf{x}} \prec \mathbf{x}\}$ . Diese Lösungsmenge  $\Theta$  wird als Pareto-Menge bezeichnet. Sie enthält im Sinne der Pareto-Optimalität die bestmöglichen Kompromisslösungen zwischen den konträren Zielen (Zielfunktionen). Es gilt somit für alle Lösungen der Pareto-Menge, dass sich für das gestellte Optimierungsproblem keine weiteren Lösungen finden lassen, bei denen alle Ziele simultan verbessert werden können. Die Verbesserung eines Ziels führt gleichzeitig zu einer Verschlechterung eines anderen Ziels. Die Projektion der Pareto-Menge im Zielfunktionsraum ist durch  $\mathbf{f}(\Theta) = \{\mathbf{f}(\mathbf{x}) \mid \mathbf{x} \in \mathcal{X} \wedge \nexists \check{\mathbf{x}} \in \mathcal{X} : \check{\mathbf{x}} \prec \mathbf{x}\} \subset \mathbb{R}^m$  gegeben und wird Pareto-Front genannt.

Im Allgemeinen ist  $\Theta$  einzigartig und enthält eine unendlich große Menge Lösungen. Durch den Einsatz von multikriteriellen Optimierungsstrategien kann eine nicht einzigartige und endliche Menge Lösungen  $\Theta^a$  gefunden werden, die eine diskrete Approximation von  $\Theta$  darstellt. Die diskrete Approximation  $\Theta^a \in \mathcal{X}$  der wahren, aber unbekanntenen Pareto-Menge  $\Theta$ , zusammen mit der zugehörigen diskreten Approximation  $\mathbf{f}(\Theta^a) \in \mathcal{X}$  der wahren Pareto-Front  $\mathbf{f}(\times) \in \mathcal{X}$  stellt die Grundlage für den Prozess der Entscheidungsfindung dar.

Für weiterführende Informationen soll auf das Buch von Ehrgott (2005) verwiesen werden, das sich ausführlich mit der Theorie der multikriteriellen Optimierung beschäftigt.




Abbildung 2.3: Schema zur multikriteriellen Optimierung: Die Punkte stellen Lösungen zwischen den beiden konträren Talsperrennutzungen Wasserversorgung und Hochwasserschutz dar. Die in schwarz dargestellte Lösung wird von den dunkelgrauen Lösungen im Kegel der Lösung dominiert, da diese Lösungen in Bezug auf die schwarze Lösung beide Ziele verbessern können. Die hellgrauen Lösungen werden durch die schwarze Lösung dominiert. Die weißen Lösungen können nicht direkt mit der schwarzen Lösung verglichen werden. Alle Lösungen mit dicker Umrandung sind nicht-dominiert, da sich in ihren Kegeln keine Lösungen befinden. Sie sind die Pareto-optimalen Kompromisslösungen und bilden die approximierten Pareto-Front. Der Utopia-Punkt ist die ideale Lösung, die nicht erreicht werden kann, da die Talsperre gleichzeitig möglichst voll (geringste Defizite in der Wasserversorgung) und leer (geringste Hochwasserschäden) sein müsste. Die ausgewogene Kompromisslösung besitzt den geringsten Abstand zum Utopia-Punkt. Der Nadir-Punkt ist die Lösung, bei der beide Ziele gleichzeitig am schlechtesten erfüllt werden.

### 2.2.3 Entscheidungshilfetechniken für multikriterielle Probleme

Die drei Hauptprobleme im Prozess der a posteriori Entscheidungsfindung unter multiplen Zielen sind nach Larichev (1992):

- a) die Wertung der Kompromisslösungen nach ihrer Präferenz<sup>2</sup>,
- b) das Zusammenfassen von Kompromisslösungen zu Kompromissklassen<sup>3</sup> und
- c) die Wahl der bevorzugten Kompromisslösung.<sup>4</sup>

Larichev stellt weiterhin fest, dass die Komplexität einer Entscheidungsfindung auf Grundlage einer Tabelle mit mehr als einem Dutzend Lösungen und mehr als zwei Zielen im Allgemeinen zu fordernd für den menschlichen Verstand ist. Bei der mathematischen Formulierung multikriterieller Optimierungsprobleme sind jedoch mehr als zwei Zielfunktionen keine Seltenheit (siehe Tabelle A.1). Um den Prozess der Entscheidungsfindung zu erleichtern, wurde daher eine Vielzahl von Methoden entwickelt. Klassische Methoden die eine Wertung der Kompromisslösungen (Outranking) vornehmen und somit bei der Wahl der letztlich bevorzugten Kompromisslösung helfen, entstammen den ELECTRE-, oder PROMETHEE-Entscheidungshilfetechniken (Figueira et al., 2005). Deb (2001) beschreibt einen Ansatz auf Basis von Pseudo-Gewichten, der jede Lösung anhand eines Ranking-Vektors bezüglich jeder Zielfunktion klassifiziert wird. Der Entscheidungsträger kann die Lösungen anhand seines bevorzugten Ranking-Vektors auswählen.

Vor allem die grafische Darstellung der Pareto-Front ist eine Möglichkeit dem Entscheidungsträger Informationen effizient und einfach zugänglich zu machen, da ein Bild mehr sagt als Tausend Worte (Lotov and Miettinen, 2008). Mit GAIA wurde z.B. eine deskriptive grafische Erweiterung der PROMETHEE-Technik entwickelt (Brans and Mareschal, 2005). Eine visuelle räumliche Darstellung von Datensätzen (Kompromissdarstellung im kartesischen Raum) mit mehr als zwei Dimensionen ist jedoch nur mit Einschränkungen möglich und oft unverständlich. Ein aktives Feld der Forschung ist daher die Entwicklung von fortgeschrittenen Visualisierungstechniken, die sich um eine einfache Darstellung von hochdimensionalen Datensätzen ohne Informationsverlust bemühen.

So führt Lotov (1975) die *Interactive Decision Maps* ein, um die Pareto-Menge im hochdimensionalen Zielfunktionsraum anhand von mehreren zweidimensionalen Schnitten abzubilden. Tušar and Filipic (2011) projizieren dreidimensionale Abschnitte einer vierdimensionalen Pareto-Front auf *Scatter-Plots*. Pryke et al. (2007) wenden *Heatmaps* zur Visualisierung hochdimensionaler Datensätze an. Sowohl die Pareto-Front als auch der Entscheidungsraum lassen sich dabei durch die Farbwahl synchronisiert darstellen.

<sup>2</sup>Welche Zielfunktionen werden bei einer Lösung in Relation zu den anderen wie bevorzugt um zu einem Kompromiss zu gelangen?

<sup>3</sup>Welche Lösungen verhalten sich in Bezug auf 1. ähnlich?

<sup>4</sup>Welche Lösung aus allen vorgestellten Lösungen wird in der Praxis umgesetzt?

Agrawal et al. (2005) beschreiben die *Hyper-Space Diagonal Counting*-Methode zur vereinfachten Visualisierung. Ein komplexes Präferenzschema sortiert dabei die Lösungen, um die Wahl der bevorzugten Kompromisslösung zu erleichtern. Obayashi and Sasaki (2003) nutzen *selbstorganisierende Merkmalskarten* sowohl für die Visualisierung der Pareto-Menge im Entscheidungs- und Zielfunktionsraum als auch zum Data-Mining. Die *Hyper-Radial-Visualization*-Methode (Chiu and Bloebaum, 2008) projiziert hochdimensionale Pareto-Fronten anhand geometrischer Informationen in den zweidimensionalen Raum und hebt die zu bevorzugende Kompromisslösung hervor. Blasco et al. (2008) nutzen *Level-Diagramme*, um hochdimensionale Pareto-Fronten und Entscheidungsvektoren nach Zielfunktionen und Entscheidungsvariablen in einzelnen Tafeln einer Abbildung darzustellen. Eine Wertung der Kompromisslösungen wird genutzt, um die Pareto-optimale Lösungen in den einzelnen Tafeln anhand der Ordinatenwerte zu synchronisieren. Wenn gewünscht, kann auch die Präferenz des Entscheidungsträgers bei der Wertung der Lösungen berücksichtigt werden.

Die Partitionierung der Pareto-Menge zur Erstellung von Kompromissklassen und zur Reduktion des Ergebnisumfangs auf ausgesuchte Kompromisslösungen wurde bereits durch mehrere Autoren angewandt (Deb, 2001; Obayashi and Sasaki, 2003; Reddy and Kumar, 2006; Taboada and Coit, 2006, 2007; Reddy and Kumar, 2007b; Zio and Bazzo, 2010; Chaudhari et al., 2010; Veerappa and Letier, 2011). Zio and Bazzo (2011) erweitern Level-Diagramme, um eine Zuordnung von Kompromisslösungen zu Kompromissklassen. Aus den ermittelten Kompromissklassen lässt sich jeweils eine repräsentative Lösung wählen. Die Anzahl von Lösungen wird somit bei geringem Informationsverlust über die Ausdehnung und Form der Pareto-Front deutlich verringert.

### 2.3 Optimierungstechniken für Steuerungsstrategien wasserwirtschaftlicher Speichersysteme

An mathematischen Optimierungstechniken zur Betriebsoptimierung von Talsperren und Talsperrenverbundsystemen wird seit den 70er Jahren aktiv geforscht (Yeh, 1985; Labadie, 2004; Rani et al., 2010; Adeyemo, 2011; Wurbs, 1993). Doch bisher konnte keine mathematische Optimierungstechnik entwickelt werden, die sich allgemein bewährt und durchgesetzt hätte (Husain, 2012). Der Grund hierfür ist, dass sich das Problem durch die stochastische Natur der Zuflüsse<sup>5</sup>, die hohe Anzahl an Entscheidungsvariablen, die nichtlineare Systemdynamik und den bei Mehrzweck-Speichern auftretenden Konflikten zwischen Bewirtschaftungszielen als äußerst komplex und schwer lösbar erweist (Oliveira and Loucks, 1997).

Der weitere Aufbau des Abschnitts sieht in Unterabschnitt 2.3.1 zunächst die Einführung der, im Bereich der Wasserwirtschaft eingesetzten, klassischen Optimierungstechniken

---

<sup>5</sup>Natürlich können auch andere Größen wie z.B. Abgaben stochastischer Natur sein.



vor. Diese lassen sich anhand der Beschreibung der stochastischen Natur der Zuflüsse in zwei grundlegend unterschiedliche Verfahrensklassen, *implizite stochastische Optimierung* und *explizite stochastische Optimierung*, unterteilen (Labadie, 2004). Klassische Optimierungstechniken operieren direkt mit den Variablen von Gleichungssystemen, mit denen die wasserwirtschaftlichen Speichersysteme mathematisch beschrieben werden. Diese Variablen sind zumeist die Abgaben der wasserwirtschaftlichen Speicher für jeden Zeitschritt. Auch beschränken sich klassische Optimierungstechniken in der Regel auf einkriterielle Problemstellungen oder verlangen die Überführung mehrerer Ziele in eine Zielfunktion zur a priori multikriteriellen Optimierung. Zum Lösen der Probleme kommen lokale Optimierungsalgorithmen zum Einsatz, in neuerer Zeit jedoch auch globale Problemlöser (Labadie, 2004).

Weiterhin finden *Simulationsmodelle* eine verbreitete Anwendung, obwohl diese eine händische Optimierung der Steuerungsstrategien unter der Expertise eines Anwenders erfordern. Neuere Optimierungstechniken nutzen die Entwicklungen auf dem Gebiet der *Computational Intelligence*, um Teilprobleme der Problemstellung zu abstrahieren. Die *simulationsbasierte Optimierung* kombiniert die Vorteile der Simulationsmodelle mit den Vorteilen der globalen Optimierungsalgorithmen, wie evolutionären Algorithmen. Der Optimierungsgegenstand stellt direkt die Steuerungsstrategie dar, unter der ein Talsperrenbewirtschaftungsmodell die Bewirtschaftung simuliert. Unterabschnitt 2.3.2 stellt die Simulationsmodelle, die simulationsbasierte Optimierung und evolutionäre Algorithmen als leistungsfähige globale Optimierungsalgorithmen vor.

### 2.3.1 Klassische Optimierungstechniken

Die **implizite stochastische Optimierung** (ISO) nutzt beobachtete oder mittels stochastischer Zeitreihenmodelle generierte, kontinuierliche Zeitreihen zur Beschreibung des hydrologischen Zuflussregimes. Zuflüsse als stochastische Prozesse werden implizit, das heißt durch die Ausprägung einer Realisierung (einer Zeitreihe), beschrieben. Daher müssen die Zeitreihen den hydrologischen Prozess in seinen möglichen Ausprägungen genau und umfassend wiedergeben.

ISO-Studien zur Optimierung von Steuerungsstrategien umfassen drei Schritte (Labadie, 2004). Der erste Schritt umfasst die Aufbereitung beobachteter Zuflüsse und, falls vorgesehen, die Generierung synthetischer Zuflüsse mittels stochastischer Zeitreihenmodelle. In der zweiten Stufe wird die eigentliche Optimierung des Betriebs *für den gesamten Zeitraum*, simultan durchgeführt. Da der Optimierungsalgorithmus die Information der kompletten Zuflusszeitreihe ausbeutet, wird auch von Optimierung unter *perfekter Vorhersage* (perfect foresight) gesprochen (Rani et al., 2010). In der dritten Stufe erfolgt aus dem Satz optimierter Abgaben und den dabei vorherrschenden Zustandsvariablen die Ableitung gültiger Steuerungsstrategien. Nach Momtahan and Dariane (2007) umfassen die hierzu

angewandten Techniken lineare und nichtlineare Polynome, Regressionen mit künstlichen neuronalen Netzen und Fuzzy-Regeln.

Die *lineare Programmierung (LP)* ist ein klassischer und weitverbreiteter ISO-Ansatz. Techniken der *nichtlinearen Programmierung* beherrschen im Gegensatz zur LP nichtlineare Funktionen. Ansätze wie die *sequenzielle lineare Programmierung*, die *quadratische Programmierung* und die *sequenzielle quadratische Programmierung* setzen voraus, dass die nichtlinearen Funktionen differenzierbar sind (Labadie, 2004). Mit der *dynamischen Programmierung (DP)*; Bellman, 1961) lassen sich nicht-konvexe, nichtlineare und diskontinuierliche Probleme lösen (Yakowitz, 1982). Randbedingungen sind hier für Entscheidungsvariablen und Zustandsvariablen möglich. Aus diesen Gründen zählt die DP in der Bewirtschaftung von Wasserressourcen zu den meist eingesetzten Optimierungsmethoden (Husain, 2012). Der größte Nachteil der DP liegt in dem, von Bellman (1961) beschriebenen, „*Fluch der Dimensionalität*“. Unter diesem wird die zunehmende Komplexität des Optimierungsproblems, das durch eine rasante Zunahme der Entscheidungsvariablen und Nebenbedingungen durch die Diskretisierung des Zustandsraums (u.a. der Zuflüsse und Speicherinhalte), der Länge des Optimierungszeitraums und der zunehmenden Anzahl von Speichern entsteht, verstanden. Rani et al. (2010) führen mehrere Weiterentwicklungen der DDP auf, die den Fluch der Dimensionalität verringern, die bekannteste ist die von Jacobson and Mayne (1970) vorgestellte *diskrete differenzielle dynamische Programmierung (DDDP)*.

Die **explizite stochastische Optimierung (ESO)** basiert auf der direkten, also expliziten, wahrscheinlichkeitstheoretischen Formulierung der stochastischen hydrologischen Prozesse. Zumeist sind dies Wahrscheinlichkeitsverteilungen oder bedingte Wahrscheinlichkeiten (Übergangswahrscheinlichkeiten) der Zuflüsse (Schmidt and Plate, 1983). Durch das Fehlen von deterministisch gegebenen Zuflüssen ist bei ESO-Ansätzen eine Optimierung unter perfekter Vorhersage nicht möglich. Dies ist jedoch gegenüber den ISO-Ansätzen die realistischere Annahme (Labadie, 2004).

Die Hauptvertreter der ESO-Methoden sind *Chance-Constrained Programmierung* sowie die stochastischen Abwandlungen der LP und DP als *stochastisch lineare Programmierung* und die am häufigsten angewandte *stochastisch dynamische Programmierung (SDP)*. Wie auch bei ISO-Ansätzen werden Steuerungsstrategien nach dem Optimierungslauf anhand der Zustandsvariablen und den optimalen Abgaben rekursiv ermittelt (Labadie, 2004). Mit ESO-Ansätzen ermittelte Steuerungsstrategien ermöglichen es, die hydrologischen Unsicherheiten mit in die Talsperrenbewirtschaftung einzubeziehen.

Eine geläufige Bezeichnung für die SDP ist Markov-Entscheidungsprozess, da die wahrscheinlichkeitstheoretische Formulierung der Zuflüsse zumeist auf einer Markov-Kette erster Ordnung basiert. Nachteile der SDP betreffen sowohl die hohen rechentechnischen Anforderungen, die sich durch die hohe Anzahl der zukünftig möglichen Zuflüsse und die notwendige Diskretisierung des Zustandsraums in Klassen ergeben, als auch Einschränkungen bezüglich

wahrscheinlichkeitstheoretischer Formulierungen (Loucks et al., 1981; Rani et al., 2010). Somit unterliegt auch die SDP dem Fluch der Dimensionalität.

Nach Dembo (1991) sind bei einer gängigen Diskretisierung der Zuflüsse und Speicherinhalte in 100 Klassen für die Optimierung der Abgaben einer Talsperre bereits zu jedem Zeitschritt  $10^4$  mögliche Kombinationen aus Zuflüssen und Speicherständen zu untersuchen. Bei einem Talsperrenverbundsystem mit  $x$  Talsperren steigt die Kombinationsanzahl um  $10^{4x}$ . Daher werden Systemdekompositionsmethoden (Brass, 2006) oder die Verknüpfung der SDP mit evolutionären Algorithmen (Huang et al., 2002) angewandt, um den Fluch der Dimensionalität zu mindern.

**Hybride Verfahren** nutzen nach Yeh (1985) unterschiedliche Methoden der ESO- und ISO-Klassen, um möglichst effizient einzelne Phasen oder Unterprobleme des Optimierungsproblems zu lösen.

### 2.3.2 Neuere Optimierungstechniken

In neuerer Zeit werden nach Rani et al. (2010) zunehmend Konzepte aus dem Bereich der **Computational Intelligence** eingesetzt. Hierzu zählen Ansätze wie *künstliche neuronale Netze* (KNN; Fogel, 1962), die die grundlegende Arbeitsweise des menschlichen Gehirns imitieren (Haykin, 1994). KNN können als Proxymodelle Teilaspekte des Optimierungsproblems vereinfachen (z.B. Castelletti et al., 2012). *Fuzzy Logic* (Zadeh, 1965) imitiert die menschliche Entscheidungsfindung. Rani et al. (2010) bietet einen Überblick über die unterschiedlichen Einsatzfelder der Fuzzy Logic in der Wasserwirtschaft.

Auch die *evolutionären Algorithmen* (EA) werden dem Bereich der Computational Intelligence zugeordnet. EAs können als Optimierungsalgorithmen für ISO- und ESO-Ansätze dienen. Insbesondere eignen sich EA jedoch für den Einsatz im Rahmen der *simulationsbasierten Optimierung* (SBO). In diesem Abschnitt sollen zunächst die *Simulationsmodelle* (SM) und die EA als die beiden Hauptbestandteile der SBO, die im Anschluss diskutiert wird, eingeführt werden.

**Simulationsmodelle** sind auch weiterhin das primäre Werkzeug zur Planung neuer wasserwirtschaftlicher Speicher und der Speicherbewirtschaftung bereits existierender Speicher (Maniak, 2005). Durch SM ist der Betrieb von einzelnen Talsperren oder komplexen Talsperrenverbundsystemen bis hin zur integrierten Flussgebietsbewirtschaftung unter vielfältigen Rahmenbedingungen ohne große Vereinfachungen modellierbar (Wurbs, 1994).

SM nutzen, wie ISO-Ansätze, beobachtete oder synthetische Zuflusszeitreihen als Grundlage zur Beschreibung des hydrologischen Regimes. Die Beschreibung der stochastischen Prozesse erfolgt somit implizit. Vom Benutzer spezifizierte Betriebsregeln ermöglichen eine

realitätsnahe Simulation des Talsperrenbetriebs. Für eine realistische Bewertung vorgegebener Steuerungsstrategien sind daher ebenso möglichst lange Zeitreihen wünschenswert. SM unterscheiden sich jedoch gegenüber ISO-Ansätzen in zwei wesentlichen Punkten:

- SM verfügen über keine Optimierungsroutinen, um die Steuerungsstrategien selbst zu optimieren. Diese sind iterativ durch den Nutzer von Hand anzupassen. Anhand von Gütekriterien ist die Bewirtschaftung des wasserwirtschaftlichen Systems für die jeweils vorgeschlagene Steuerungsstrategie zu bewerten (Yeh, 1985). Hashimoto et al. (1982) geben hierzu einen Überblick über gängige Gütekriterien.
- SM selbst lassen sich in zwei Klassen unterteilen. Zur ersten Klasse gehören verordnende Modelle. Die Verteilung des Wassers im System geschieht unter Beachtung der Steuerungsstrategien anhand eines Algorithmus. Wasser wird nach Wasserrechten oder von Oberstrom nach Unterstrom für jeden Zeitschritt verteilt, bis das zu Verfügung stehende Wasser verbraucht ist. Die zweite Klasse arbeitet intern auf Basis von linearer oder nichtlinearer Optimierung. Hierbei wird das Wasser im System unter Beachtung der gültigen Steuerungsvorschriften so verteilt, dass eine interne Zielfunktion maximiert wird, indem Wasser bevorzugt an Ziele mit hohen Bonuspunkten bereitgestellt wird (Rani et al., 2010). Die jeweils optimale Verteilung wird für *jeden Zeitschritt* bestimmt.<sup>6</sup> Die Anzahl der Entscheidungsvariablen ist somit von der Länge des Simulationszeitraums unabhängig.

Die meisten SM werden für ein bestimmtes wasserwirtschaftliches System entwickelt und sind nicht auf andere Systeme übertragbar (Rani et al., 2010). Es existiert jedoch auch eine Anzahl von *adaptiven Talsperrenbewirtschaftungsmodellen* (ATM), die grundlegende Strukturen wie Talsperren und Fließwege zur Verfügung stellen. Mit diesem Bausatz können viele unterschiedliche Talsperrenverbundsysteme implementiert und dann simuliert werden. Bekannte Modelle, die heute Verwendung finden, sind unter anderem WEAP (Stockholm Environment Institute, 1999), HEC-3 (Hydrologic Engineering Center, 1981), HEC-5 (Hydrologic Engineering Center, 1998), HEC-ResPRM (Hydrologic Engineering Center, 2013), MIKE BASIN (DHI WASY, 2013), OASIS (Hydrologics Inc., 2009), RIBASIM (Hydraulics, 1991), AQUATOOL (Andreu et al., 1996), MODSIM (Labadie, 1995), CALSIM (Draper et al., 2004), TALSIM (SYDRO, 2013), HydroPlatform (Harou et al., 2010) und WRAP (Wurbs, 2005).

Zu den Vorteilen der SM zählen nach Loucks and Sigvaldas (1982) eine gegenüber ISO- und ESO-Ansätzen detailliertere und realitätsgetreuere Abbildung des Systemverhaltens. SM simulieren die Talsperrenbewirtschaftung anhand praxisnaher Steuerungsstrategien. Loucks et al. (1981) heben zudem die einfache Verwendung von synthetisch generierten

---

<sup>6</sup>Simulationsmodelle wie z.B. HEC-5 oder OASIS sind auch in der Lage die Bewirtschaftung unter einer Voraussicht von wenigen Zeitschritten zu simulieren.

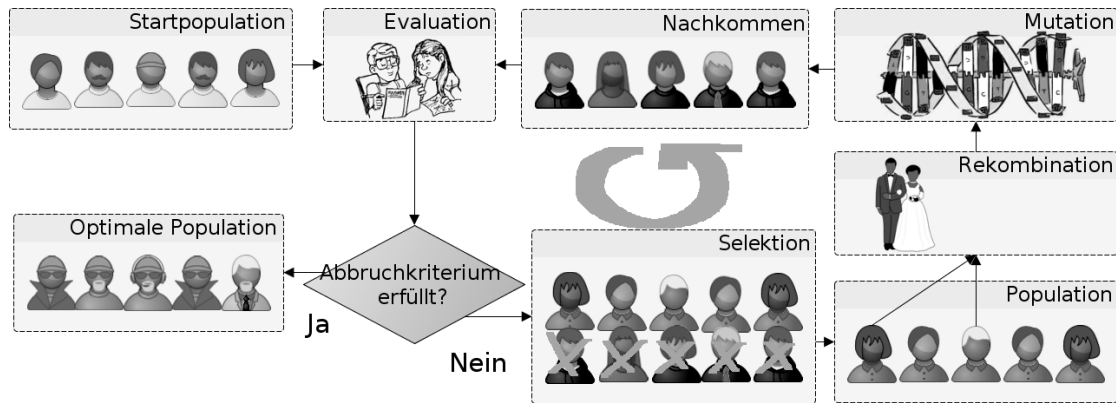


Abbildung 2.4: Prinzipieller Ablauf eines evolutionären Algorithmus.

Zeitreihen in SM hervor.

**Evolutionäre Algorithmen** sind stochastische Optimierungsstrategien und gehören zur Klasse der heuristischen Verfahren. EA imitieren die Darwin'sche Evolution. Sie basieren auf Populationen von Problemlösern (Individuen), die in einem iterativen Zyklus, der sich über Generationen erstreckt, Geburt, Tod, Veränderung und natürlicher Selektion unterliegen. Wie in der Natur erzeugt der Selektionsdruck durch kollektive Phänomene fortschreitend veränderte Problemlöser, die hinsichtlich des Optimierungsproblems, jeweils verbesserte Lösungen enthalten (Beyer and Schwefel, 2002).

Seit den Anfängen der EA in den 1970er Jahren haben sich vor allem drei Hauptzweige etabliert:

- *Evolutionäre Strategien* (ES; Rechenberg, 1965; Schwefel, 1975)
- *Evolutionäre Programmierung* (EP; Fogel, 1962; Fogel et al., 1966)
- *Genetische Algorithmen* (GA; Holland, 1975; De Jong, 1975; Goldberg and Holland, 1988).

Allen Hauptzweigen sind Grundprinzipien gemein, welche Abbildung 2.4 illustriert.

Der EA beginnt mit einer *Startpopulation* mit zufällig initialisierten Elternteilen ( $\mu + \lambda$  bei EP und ES, oder  $\mu$  bei GA).<sup>7</sup> Hierbei sei  $\mu$  die Anzahl der Eltern und  $\lambda$  die Anzahl der Nachkommen. Jedes Elternteil trägt einen eigenen Vektor mit den Entscheidungsvariablen in sich. Anhand einer Zielfunktion wird der Entscheidungsvektor hinsichtlich seiner Güte für das Optimierungsproblem bewertet (Evaluation). Der Zielfunktionswert spiegelt die Fortpflanzungsfähigkeit des Individuums wieder. In der *Selektion* werden Individuen mit

<sup>7</sup>Darunter wird die Belegung der Entscheidungsvariablen mit zufälligen Werten verstanden.

schlechter Fortpflanzungsfähigkeit aus der Population entfernt. In der *Reproduktion* erzeugen Eltern neue Nachkommen. Durch Verfahren der *Rekombination* kommt es zu einem Austausch von zielführenden Informationen und durch *Mutation* zu einer Aufrechterhaltung der Diversität. Die Nachkommen bilden dann die Elternteile in der nächsten Iteration. Durch die Weitergabe von zunehmend zielführender Information über Generationen nähert sich die EA der optimalen Lösung.

Der Hauptunterschied der GA zu ES und EP besteht in der Repräsentation des Entscheidungsvektors. In der GA ist der Entscheidungsvektor „genetisch“ kodiert, zum Beispiel im Binärformat. ES nutzen oftmals eine als Selbstadaption bezeichnete Technik, die die Lernrate an den Optimierungsfortschritt anpasst. Hierbei spielt die Rekombination eine wichtige Rolle. Die Selektion basiert bei GA auf einem wahrscheinlichkeitstheoretischen Ansatz, während ES und EP deterministisch Individuen anhand der Fortpflanzungsfähigkeit verwerfen (Bäck and Schwefel, 1993; Fogel, 1994).

Meyer (2004) fasst die Vorteile und Nachteile der evolutionären Algorithmen gegenüber den klassischen Optimierungstechniken zusammen. So lassen sich EA

- Auf ein sehr breites Spektrum von Problemklassen anwenden.
- Als stochastische Optimierungsstrategie benötigen EA keine Hilfsgrößen wie Gradienten und eignen sich somit für mathematisch nicht formulierbare Zielfunktionen mit äußerst komplexen Zielfunktionsoberflächen. Hierzu zählen un stetige, nicht-differenzierbare, nichtlineare, multimodale und stark zerklüftete Zielfunktionen (Igel et al., 2007).
- EA sind auf Ebene der Population leicht parallelisierbar und leicht für die multikriterielle Optimierung erweiterbar.
- Es ist kein spezielles Vorwissen über das zu lösende Problem notwendig, aber es kann durch sorgfältige Wahl der Evolutionsoperatoren und der Kodierung der Entscheidungsvariablen in den Suchprozess eingebracht werden.
- EA lassen sich leicht mit Simulationsmodellen kombinieren.

Die Nachteile der EA umfassen

- Vor allem den hohen Rechenaufwand, der dem Populationskonzept geschuldet ist. Dieser Nachteil relativiert sich mit dem Fortschritt der Rechentechnik sowie durch die gute Parallelisierbarkeit der EA.
- Insbesondere GA besitzen vielfältige Parameter, die die Mutation, Selektion und Rekombination steuern. Diese Parameter müssen an das Optimierungsproblem angepasst werden (Eiben et al., 1999; Suiadee and Tingsanchali, 2007).

Aufgrund der heuristischen und stochastischen Arbeitsweise gibt es für EA keine Garantie das theoretisch mögliche Optimum zu erreichen. Diese Nachteile sind jedoch im Vergleich zu den Vorteilen gering, sodass evolutionäre Algorithmen heute in vielfältigen Bereichen eingesetzt werden (Nissen, 1997; Zhou et al., 2011).

Die **simulationsbasierte Optimierung** vereinigt die Vorteile von Simulationsmodellen mit den Vorteilen von leistungsstarken lokalen oder globalen Optimierungsstrategien. Die simulationsbasierte Optimierung kann je nach Anzahl der Ziele einkriteriell (EK-SBO) oder multikriteriell (MK-SBO) sein. Ammeri et al. (2010) geben einen umfassenden Überblick über Optimierungstechniken, die zur EK-SBO eingesetzt werden, und schlagen eine Klassifizierung der Optimierungstechniken vor.

In der SBO übernimmt ein mit dem SM gekoppelter globaler Optimierungsalgorithmus die Aufgabe des Anwenders, nach Steuerungsstrategien zu suchen. Die Aufgaben des Anwenders beschränken sich nunmehr auf die Formulierung einer oder mehrerer Zielfunktionen, um das Optimierungsproblem zu beschreiben. Abbildung 2.5 illustriert den prinzipiellen Ablauf einer SBO. Ein Optimierungsalgorithmus schlägt demnach zunächst eine Steuerungsstrategie (Entscheidungsvektor) vor. Über eine *Schnittstelle* wird das SM mit den Steuerungsstrategien konfiguriert. Das SM wird zur Evaluation des Entscheidungsvektors gestartet und die Bewirtschaftung des Talsperrenmodells simuliert. Aus den Ausgaben (z.B. Zeitreihen von Abgaben) des Simulationsmodells werden die erforderlichen Zielfunktionen berechnet und an den Optimierungsalgorithmus zurückgegeben. An dieser Stelle ist eine Evaluation des Entscheidungsvektors abgeschlossen. Der Optimierungsalgorithmus bewertet den Entscheidungsvektor anhand der entsprechenden Zielfunktionswerte und schlägt eine neue Steuerungsstrategie vor. In der nachfolgenden Iteration wiederholt sich die Prozedur solange, bis ein definiertes Abbruchkriterium erfüllt wird.

Eine ausführliche Analyse zu den Vor- und Nachteilen des EK-SBO-Ansatzes, die prinzipiell auch für den MK-SBO-Ansatz gilt, geben Koutsoyiannis and Economou (2003). Demnach zählt vor allem die geringe Dimensionalität des Optimierungsproblems, besonders bei Optimierungen über längere Zeitabschnitte, zu den größten Vorteilen. Die Anzahl der Entscheidungsvariablen ist auf die Beschreibung der Steuerungsstrategien beschränkt und die Rechenzeit nimmt nur linear mit der Länge des Simulationszeitraums zu, wogegen die Rechenzeit bei ISO-Ansätzen exponentiell ansteigt. Während die mit ISO-Ansätzen ermittelten Steuerungsstrategien lediglich Gültigkeit für die spezifische Sequenz der Zuflüsse besitzen, sind die mit SBO-Ansätzen ermittelten Steuerungsstrategien unabhängig von der spezifischen Sequenz der Zuflüsse.<sup>8</sup> Die optimalen Steuerungsstrategien sind von den

---

<sup>8</sup>Koutsoyiannis and Economou (2003) beziehen sich auf die optimale Abfolge der Abgaben unter der perfekten Vorhersage der Zuflüsse vor der regressiven Schätzung der Steuerungsstrategien im nächsten Schritt der ISO. Schlussendlich beruht jedoch auch die Verallgemeinerung der Steuerung durch die Regression auf einer perfekten Vorhersage.

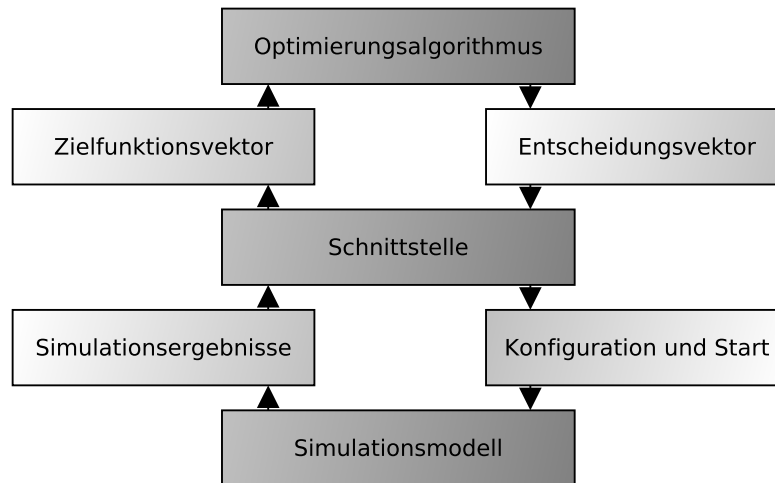


Abbildung 2.5: Prinzipieller Ablauf der simulationsbasierten Optimierung.

implizit gegebenen stochastischen Eigenschaften der Zuflüsse abhängig (Koutsoyiannis et al., 2002).

Koutsoyiannis and Economou (2003) erreichen mit dem EK-SBO-Ansatz nur geringfügig schlechtere Ergebnisse als mit dem ISO-Ansatz unter perfekter Vorhersage. Celeste and Billib (2009) vergleichen einkriterielle ISO-Ansätze mit einem SDP und einem EK-SBO-Ansatz und kommen zu dem Schluss, dass alle ISO-Modelle und der EK-SBO-Ansatz bessere Ergebnisse als der SDP-Ansatz liefern. SBO ist den klassischen Optimierungstechniken somit zumindest ebenbürtig.

## 2.4 Versorgungssicherheit und Zeitreihenlänge

Die häufigsten Nutzungsarten von Talsperren sind die Bereitstellung von Brauch- und Trinkwasser sowie von Bewässerungswasser (ICOLD, 2013). Die gängige geforderte Versorgungssicherheit für die Bereitstellung von Trinkwasser liegt bei 99 %, während für Bewässerungsspeicher in ariden Gebieten zumeist 70 % veranschlagt werden (White, 2010). Sowohl um die Versorgungssicherheit eines bestehenden wasserwirtschaftlichen Speichers über die Auswertung einer Simulation des Betriebs des Speichers zu überprüfen, als auch um die erforderliche Speichergröße bei einer geforderten Versorgungssicherheit zu bemessen, werden Zuflusszeitreihen benötigt (Maniak, 2005). Da beobachtete Zeitreihen im Allgemeinen zu kurz für diese Aufgaben sind, werden beliebig lange Zeitreihen mit Zeitreihenmodellen künstlich hergestellt.

Nach Koutsoyiannis (2005) lässt sich die Zeitreihenlänge  $n_Z$ , die benötigt wird, um die (ereignisbezogene) Versagenswahrscheinlichkeit  $R'$  mit einem Fehler von  $\pm \varepsilon R'$  und einer Konfidenz  $\gamma'$  zu ermitteln, nach Gleichung 2.5 berechnen.



$$n_Z = k \left( \frac{z_{p=(1+\gamma')/2}}{\varepsilon} \right)^2 \left( \frac{1}{R'} - 1 \right) \quad (2.5)$$

Hierbei sei  $R$  die zugehörige (ereignisbezogene) Versorgungssicherheit. Die Definition und der Zusammenhang zwischen beiden Größen ist durch

$R := P[A(t) \geq B(t); t \in 1, \dots, T] = 1 - R'$  gegeben, weiterhin sei  $k$  die Anzahl an Saisons je Jahr und  $z_p$  das  $p$ -Quantil der Standardnormalverteilung.

Beispielhaft ergibt sich für eine gesuchte Versorgungssicherheit von  $R = 99\%$  ( $R' = 0,01$ ), bei  $k = 12$ ,  $\gamma' = 95\%$  ( $z_{(1+\gamma')/2} = 1,96$ ) und  $\varepsilon = 10\%$ , eine Zeitreihenlänge von 38 000 Jahren (456 000 Monate). Diese Zeitreihenlänge wäre für die hier veranschlagten Kennwerte auch für eine verlässliche Langfristsimulation zu veranschlagen (Koutsoyiannis and Economou, 2003). Im Vergleich zu den „1 000 oder mehr Jahre(n)“, wie in der DIN 19700-11 gefordert, liegen die hier vorgeschlagenen Zeiträume für Langfristsimulationen sogar deutlich höher. Die Zeitreihenlänge von 38 000 Jahren soll als Grundlage dienen, um die mögliche Anwendbarkeit einer Optimierungstechnik zu diskutieren, wenn das Erreichen einer geforderten Versorgungssicherheit einen Teil der Optimierungsaufgabe darstellt.

Für ISO-Ansätze resultiert das einfachste Optimierungsproblem, bei dem ausschließlich die Abgabe eines Reservoirs über einen Zeitraum zu optimieren ist, in einem Problem mit 456 000 Entscheidungsvariablen. ESO-Ansätze stützen sich für die Beschreibung des stochastischen Prozesses auf die explizite Angabe von statistischen Kennwerten, die Länge der Zeitreihe ist daher kein direktes Problem. Jedoch basieren ESO-Ansätze zumeist auf einer Beschreibung der stochastischen Prozesse mittels Markov-Ketten erster Ordnung, wodurch deren korrekte Abbildung erschwert wird (Labadie, 2004). Simulationen mit Talsperrenbewirtschaftungsmodellen über diese Zeiträume sind durchführbar, jedoch mit extremen Rechenzeiten verbunden. Ebenso sind EK-SBO und MK-SBO prinzipiell möglich, die Gesamtrechenzeit wäre jedoch ein Vielfaches der bereits langen Rechenzeiten eines Simulationsmodells und somit mit heutiger Rechentechnik nicht vertretbar.

## 2.5 Überblick zum Stand der Technik

Dieser Abschnitt diskutiert den Stand der Technik hinsichtlich der Optimierung von Steuerungsstrategien für Talsperrenverbundsysteme. Begleitend geben Tabellen A.1 und A.2 einen Überblick hinsichtlich unterschiedlicher Merkmale aktuellerer Arbeiten. Der Fokus soll dabei auf Arbeiten liegen, die auf evolutionäre Algorithmen als Optimierungstechnik setzen.

Es zeigt sich, dass ungeachtet der angesprochenen Nachteile der **ISO-Ansatz** noch häufig angewandt wird. Forscher nutzen leistungsfähige EA, um die Abgaben von wasserwirtschaft-

lichen Speichern als hochdimensionales Problem zu optimieren. Hochdimensionale Probleme umfassen dabei eine Anzahl von bis zu 720 Entscheidungsvariablen. Die Zeiträume belaufen sich auf bis zu 36 Jahre für die Optimierung der Abgaben einzelner Talsperren (Reddy and Kumar, 2007c) und nehmen für komplexere Optimierungen ab (Kim et al., 2004; Kai et al., 2010; Schardong et al., 2013). Oftmals wird jedoch auch das mittlere Jahresverhalten der Zuflüsse zur Optimierung herangezogen (Reddy and Kumar, 2006, 2007a, 2008; Regulwar and Raj, 2009; Kumar et al., 2001).

Typische **Simulationszeiträume** belaufen sich bei EK-SBO-Studien auf 19 (Celeste and Billib, 2009) bis 50 Jahre (Eum et al., 2012). Abweichend hiervon optimieren Koutsoyiannis et al. (2002) die Talsperrenverbundsysteme Acheloos-Thessalia und das Greater Athens Water Supply Talsperrenverbundsystem in Griechenland mit einem hierfür entwickelten Entscheidungshilfesystem auf Basis von EK-SBO über 2000 Jahre. Die wasserwirtschaftlichen Systeme sind im hierfür entwickelten ATM Hydronomeas aufgebaut. Die Regelkurven nach Nalbantis and Koutsoyiannis (1997) werden mit dem SCE-Algorithmus (Duan et al., 1992) optimiert. Der Zeitraum der Langfristsimulationen erstreckt sich jeweils über 2000 Jahre synthetisch generierter Zuflüsse. Die Autoren empfehlen eine Parallelisierung des SCE-Algorithmus, um die hierbei auftretenden enormen Rechenzeiten der Optimierung zu reduzieren. Bei MK-SBO-Studien liegen die typischen Zeitraumlängen zwischen einem Jahr (Scola et al., 2010) und 50 Jahren (Liu et al., 2012). Hier sind Kim et al. (2008) hervorzuheben. Als Grundlage für die Optimierung der Bewirtschaftungsregeln des Speichers Soyangang (Korea) generieren die Autoren zunächst 100 Jahre monatlicher Zuflüsse mit einem periodischen autoregressiven Zeitreihenmodell erster Ordnung. Die Bewirtschaftungsregeln sehen eine Steuerung auf Basis eines monatlichen funktionalen Zusammenhangs zwischen der zu tätigen Abgabe und der Summe aus Speicherinhalt und Zuflüssen vor. Eine Validierung von Kompromisslösungen wird gegen 6 Jahre historischer Zuflüsse durchgeführt. Insgesamt sehen neben Kim et al. (2008) elf weitere Studien (siehe Tabellen A.1 und A.2) eine Validierung der angepassten Steuerungsstrategien anhand beobachteter Zuflüsse vor.

**Expertenwissen** bringen Scola et al. (2010) und Scola et al. (2011) in die Formulierung des Entscheidungsvektors für die Optimierung der Wasserkraftproduktion einer Talsperre ein. Um das Optimierungsproblem in ein randbedingungsfreies Problem zu überführen, schlagen die Autoren eine spezielle Kodierung der Entscheidungsvariablen vor. Somit entfallen die oberen und unteren Randbedingungen der Kontrollspeichervolumina für die Regelkurven in der Formulierung des Problems. In einem Vergleich mit dem äquivalenten Optimierungsproblem unter Randbedingungen erweist sich der neu entwickelte Ansatz als effizienter. Scola et al. (2011) testen den Ansatz aus Scola et al. (2010) an einem Talsper-

renverbundsystem mit fünf Speichern. Die Autoren erzielen im Vergleich zu Optimierungen unter Randbedingungen ebenso deutlich bessere Ergebnisse.

Castelletti et al. (2012) prüfen die Speicherleistung der Hoah Binh Talsperre (Vietnam). Die maximale Speicherleistung wird zunächst mit DDP abgeschätzt. Hiermit lässt sich eine mögliche Leistungssteigerung gegenüber der historischen Steuerungsstrategie aufzeigen. Die Autoren nutzen weiterhin MK-SBO, um die Betriebsregeln des Speichers zu optimieren. Die täglichen Speicherkontrollvolumina der Regelkurven erfordern 365 Entscheidungsvariablen. Um die hohe Dimensionalität des Optimierungsproblems zu reduzieren, wird ein Ersatz-Simulationsmodell auf Basis künstlicher neuronaler Netze entwickelt, welches die täglich definierten Regelkurven mit lediglich fünf Parametern beschreibt. Auch mit diesem Ansatz ist eine Leistungssteigerung hinsichtlich der Ziele Hochwasserschutz, Wasserbereitstellung und Energieproduktion im Validierungszeitraum der Jahre 1995-2004 gegenüber der historischen Bewirtschaftung möglich. Die Leistung ist dabei nur geringfügig schlechter als unter der DDP.

Kangrang and Chavalit (2007) erzwingen einen glatten Verlauf der Regelkurven der Talsperren Bhumibol und Sirikit (Thailand) durch die Berechnung eines gleitenden Mittels zwischen jeweils drei aufeinanderfolgenden monatlichen Speicherkontrollvolumina. Die Autoren nutzen ebenfalls einen MK-SBO-Ansatz.

Der NSGA-II-Algorithmus (Deb et al., 2002) wird mit dem adaptiven Talsperrenbewirtschaftungsmodell HEC-3 gekoppelt. Als beste Zielfunktion zeigt sich in einem Vergleich zwischen sechs unterschiedlichen Zielfunktionen das mittlere Defizit.

Eine **Entscheidungshilfe** in Form einer Visualisierungstechnik oder einer Auswahl repräsentativer Lösungen stellen insgesamt 11 der 38 betrachteten Studien bereit. Zumeist beschränkt sich die Entscheidungshilfe jedoch auf eine Auswertung von Kompromisslösungen, die subjektiv von den Autoren ausgewählt wurden. Hervorzuhebende Studien mit umfassenden Entscheidungshilfetechniken stammen von Malekmohammadi et al. (2011), Karagiannidis and Moussiopoulos (1997) und Reddy and Kumar (2007b).

So optimieren Malekmohammadi et al. (2011) die kurz- und langfristige Talsperrenverbundbewirtschaftung der Talsperren Bakhtiari und Dez (Iran) hinsichtlich der beiden Hauptnutzungen Hochwasserschutz und Brauchwasserbereitstellung. Die Pareto-optimalen Lösungen bewerten Malekmohammadi u.a. mit dem ELECTRE-TRI-Ansatz (Karagiannidis and Moussiopoulos, 1997), um den Entscheidungsträger bei der Entscheidungsfindung zu unterstützen.

Reddy and Kumar (2007b) stellen den EM-MOPSO-Algorithmus anhand einer ISO-basierten MKO des Bhadra Talsperrenverbundsystems (Indien) vor. In einer Fallstudie mit drei Zielfunktionen nutzen die Autoren ein Clusterungsverfahren, um die dreidimensional approximierten Pareto-Front zu klassifizieren. Aus jedem der bestimmten Cluster wird eine repräsentative Lösung gewählt, um somit den Umfang der Lösungsmenge zu reduzieren.

Jede repräsentative Lösung erhält dann ein Pseudo-Gewicht, mit dem ihre Kompromissfähigkeit zwischen den Zielfunktionen eingeschätzt werden kann. In einer weiteren Studie nutzen Reddy and Kumar (2008) das *Compromise Programming* nach Deb (2001), um eine bevorzugte Kompromisslösung zu ermitteln.

Die in der Literatur verwendeten **Formulierungen von Zielfunktionen** lassen sich hauptsächlich zwei Kategorien zuordnen. Diese sind (1) die Minimierung (Maximierung) einer Summe oder eines Erwartungswerts und (2) die Minimierung eines quadrierten Fehlers zwischen Zielvorgabe und erreichtem Ziel (siehe Tabellen A.1 und A.2). Hierbei dominiert die erste Kategorie, die wiederum hauptsächlich verwendet wird, um die Ziele Energieproduktion und Wasserbereitstellung zu maximieren (bzw. deren Defizite zu minimieren). Komplexere Zielfunktionen beschreiben Wasserqualitätsindikatoren, Erträge aus der Bewässerungslandwirtschaft, Hochwasserschäden oder ökonomische Interessen. Die Minimierung eines quadrierten Fehlers zielt vor allem auf die Minimierung von extremen Fehlbeträgen in der Bereitstellung.

Soltani et al. (2008) nutzen einen *tracking model* Ansatz zur Optimierung der Bewirtschaftung einer Talsperre im Iran mittels GA. Der *tracking model* Ansatz entstammt dem Feld der szenarienbasierten Optimierung, dessen Ursprung im Finanzwesen liegt (Dembo, 1991). Hierbei wird in jeder Iteration ein Entscheidungsvariablenvektor anhand mehrerer Szenarienrechnungen evaluiert. Die Zielfunktion des Optimierungsproblems ist als Quotient aus der Spannweite der Versorgungssicherheiten aller Szenarien und der zugehörigen mittleren Versorgungssicherheit definiert. Koutsoyiannis et al. (2002) fordern innerhalb einer MK-SBO eine einzuhaltende Versorgungssicherheit durch die Formulierung einer Randbedingung. EK-SBO- oder MK-SBO-Studien mit Formulierungen von Zielfunktionen zur Maximierung von Versorgungssicherheiten sind dem Autor dieser Arbeit zu diesem Zeitpunkt nicht bekannt.

Genetische Algorithmen dominieren die eingesetzten **Optimierungsalgorithmen** der betrachteten Arbeiten. Voran der weitverbreitete NSGA-II-Algorithmus, der als bekannter Algorithmus häufig als Benchmark verwendet wird (Reddy and Kumar, 2007b; Schardong et al., 2013). Neuere Studien, deren primäres Ziel die Einführung oder Bewertung eines multikriteriellen EA ist, sind unter anderem bei Chen et al. (2007), Gu and Wu (2010), Castelletti et al. (2013), Lerma et al. (2013) und Schardong et al. (2013) zu finden. Erwähnenswert sind sowohl die Arbeiten von Hakimi-Asiabar et al. (2009), die selbstorganisierende Merkmalskarten in Verbindung mit einer variablen Nachbarschaftssuche zur multikriteriellen Optimierung eines Talsperrenverbundsystems mit dem ISO-Ansatz kombinieren, als auch von Kumar et al. (2001) und Regulwar and Raj (2009), die jeweils Fuzzy-Ansätze zur MKO von wasserwirtschaftlichen Stauanlagen vorschlagen. Saliha (2012) nutzt als multikriteriellen Optimierungsalgorithmus der MK-SBO die evolutionäre Strategie

MO-CMA-ES (Hansen, 2006), die mit einer besonders geringen Populationsgröße arbeitet.

Nach den Tabellen A.1 und A.2 sehen insgesamt 14 Studien den Einsatz von **adaptiven Talsperrenbewirtschaftungsmodellen** vor, wobei neben TALSIM, MIKE 11, MODSIM, Hydronomeas und AQUATOOL die verschiedenen Modelle des Hydrologic Engineering Center (HEC-5, HEC-3 und HEC-HMS) am häufigsten Anwendung finden.

## 2.6 Zusammenfassung

Mit der fortschreitenden Leistungsfähigkeit der Rechentechnik bietet vor allem die Synergie einer Kombination von EA und SM in der simulationsbasierten Optimierung die zunehmend attraktivere Wahl, um komplexe wasserwirtschaftliche Optimierungsprobleme zu bewältigen. Viele Nachteile der klassischen ISO- und ESO-Optimierungstechniken lassen sich mit SBO-Ansätzen umgehen. Durch den Einsatz von Expertenwissen lassen sich die Optimierungsprobleme deutlich effizienter gestalten.

Oftmals existieren für Mehrzweck-Talsperren und Mehrzweck-Talsperrenverbundsysteme aufgrund der unterschiedlichen Nutzungen konträre Bewirtschaftungsziele. Einen Überblick über das Spannungsfeld der konträren Ziele ermöglicht der Einsatz der MKO. Doch nicht nur bei Mehrzweck-Speichern ist der Einsatz von MKO-Ansätzen sinnvoll. So lassen sich auch negative Auswirkungen von Einzweck-Speichern, z.B. auf die Ökologie, bewerten.

Ein Entscheidungsträger muss sich, je nach MKO Technik, vor (a priori) oder nach (a posteriori) der Optimierung für eine bestmögliche Kompromisslösung entscheiden. Um die Auswahl einer bevorzugten Lösung aus der Pareto-Menge zu vereinfachen und Lösungsmenge im Entscheidungs- und Zielfunktionsraum zu charakterisieren, wurden Entscheidungshilfetechniken entwickelt. Als besonders vorteilhaft erscheinen dabei Techniken, die eine übersichtliche Visualisierung von hochdimensionalen Daten und eine Wertung der Kompromisslösung vereinen.

Eine umfassende Literaturstudie zum Stand der Technik zeigt, dass Optimierungen über langjährige Zeiträume bisher nur für a priori MK-SBO-Ansätze möglich sind. Die verwendeten Zeiträume in a posteriori MK-SBO-Ansätzen reichen bis 100 Jahre. Erfahrungen zur Optimierung von Versorgungssicherheiten als Teil von multikriteriellen Optimierungsproblemen liegen noch nicht vor.



## 3 Besondere Aspekte der Langfristbewirtschaftung

Němec and Schaake (1982) ziehen ein historisches Resumé und weisen auf den bedeutenden Hydrologen Ray K. Linsley hin, der bereits 1960 die Anpassung an sich verändernde klimatische Bedingungen als das schwierigste Problem für die Talsperrenbewirtschaftung prognostizierte. Die Autoren bewerteten Arbeiten bis in die frühen 80 Jahre und schließen, dass weitere Forschungsarbeiten auf diesem Gebiet notwendig sind und viele Fragen nicht abschließend geklärt seien. Nach weiteren 30 Jahren aktiver Forschung kommen auch heute Autoren wie Fowler et al. (2003) und New et al. (2007) überein, dass sich dieser Umstand noch nicht geändert hat. In Abschnitt 3.1 soll daher auf den aktuellen Stand der Klimafolgenanalyse für die Talsperrenbewirtschaftung eingegangen und aktuelle Studien sollen vorgestellt werden.

Weiter gibt Abschnitt 3.2 einen Überblick über Zeitreihenmodelle, die zur stochastischen Generierung von Durchflusszeitreihen in der Wasserwirtschaft eingesetzt werden. Diese Modelle sind notwendig, um langjährige Zeitreihen mit gleichen stochastischen und statistischen Eigenschaften wie die beobachteten stochastischen Prozesse zu generieren. Treten in den synthetisch generierten Zeitreihen bisher unbeobachtete Zustände, wie z.B. Extremereignisse auf, erhöht sich der implizite Informationsgehalt der Zeitreihen, der dann in ISO-, SM- und SBO-Ansätzen ausgewertet werden kann (Maniak, 2005).

### 3.1 Talsperrenbewirtschaftung unter klimatisch veränderten Rahmenbedingungen

Nach dem gegenwärtigen Stand der Klimaforschung besitzt der anthropogene Treibhausgasausstoß einen signifikanten Einfluss auf den Gleichgewichtszustand des Klimas. Eine Erhöhung der CO<sub>2</sub>-Konzentration in der Erdatmosphäre hat demnach eine Erhöhung der durchschnittlichen globalen Oberflächentemperaturen zur Folge. Dies wiederum kann regional zu unterschiedlichen klimatischen Änderungssignalen führen, die unterschiedliche Auswirkungen auf die verfügbaren Wasserressourcen zur Folge haben können (IPCC, 2007).

Das IPCC stellt mit den *SRES-Szenarien* (Nakicenovic and Swart, 2000) zukünftige Entwicklungen der CO<sub>2</sub>-Konzentration in der Atmosphäre bereit. Diese Szenarien basieren auf Projektionen von ökonomischen, technologischen und demografischen Entwicklungen. Die Eintretenswahrscheinlichkeit der Szenarien ist dabei jeweils gleich (IPCC, 2007). Ausgesuchte SRES-Szenarien, die in Fallstudie 1 (Kapitel 8) aufgegriffen werden, sind:

**Szenario A1B** Das Szenario beschreibt eine mittlere Entwicklung des Emissionsgasausstoßes. Zwar findet ein starkes ökonomisches Wachstum statt, jedoch kann der wachsende Ausstoß durch eine schnelle Einführung von effizienten Technologien gemindert werden. Die maximale Weltbevölkerung wird Mitte des 21. Jahrhunderts erreicht und geht anschließend wieder zurück. In diesem Szenario findet ein starker sozialer und kultureller Austausch statt, regionale Einkommensunterschiede verringern sich.

**Szenario A2** Unter dem Szenario A2 wird von einer hohen Emissionsentwicklung ausgegangen. Gründe hierfür liegen in einer heterogenen Welt. Die Bevölkerung wächst konstant, während nur regional vom wirtschaftlichen Wachstum profitiert wird.

**Szenario B1** Das Szenario B1 ermöglicht einen niedrigen Emissionsgasausstoß durch regional nachhaltiges Wirtschaften. Bei einem gemäßigten Wachstum von Wirtschaft und Weltbevölkerung werden soziale Unterschiede abgebaut und die „Welt rückt näher zusammen“ (Nakicenovic and Swart, 2000).

Um den Einfluss des weltweit steigenden Kohlendioxidausstoßes auf das Klimasystem und somit auf die verfügbaren Wasserressourcen abzuschätzen, werden Modellketten zur Modellierung des globalen und regionalen Klimas genutzt (Storch, 1993). Dabei wird das globale Klimasystem in einem ersten Schritt durch numerische *großräumige Zirkulationsmodelle* (General circulation models, GCM) unter bestimmten Annahmen zur zukünftigen Entwicklung der Treibhausgasemission modelliert. GCMs sind in der Lage, vielfältige klimarelevante Erdsystemkomponenten wie die Atmosphäre, Ozeane, Landoberfläche und See-Eis und deren Interaktion auf globaler und kontinentaler Ebene zu modellieren (Grotch, 1991; Storch, 1993; Wilby, 2005).

Die räumliche Auflösung der GCMs ist aufgrund des enormen Rechenaufwands mit 150 bis mehreren 100 Kilometern sehr gering. Dies verhindert eine direkte Nutzung der Modellergebnisse in mesoskaligen hydrologischen Modellen. Es entsteht daher die Notwendigkeit, durch weitere Methoden die räumliche Auflösung der GCM-Modellergebnisse unter Berücksichtigung von wichtigen Merkmalen auf regionaler und lokaler Skala in einer Modellkaskade zu verfeinern (Grotch, 1991; Fowler et al., 2007). Dieses Vorgehen wird als *Downscaling* bezeichnet. Nach Fowler et al. (2007) werden dynamische und statistische *Downscalingverfahren* unterschieden. Während dynamische Downscalingverfahren auf *regionalen Klimamodellen* (RCM) basieren, die den Modelloutput der GCM als obere Randbedingungen verwenden, basieren statistische Downscalingverfahren auf Regressionsmodellen, Wettergeneratoren, Delta Ansätzen, Fuzzy-Regel-basierten Ansätzen oder auf Verfahren der Wetterlagenklassifikation. Unter Zuhilfenahme von verschiedenen komplexen Niederschlags-Abflussmodellen können die projizierten klimatischen Verhältnisse zu Abflüssen aus Einzugsgebieten transformiert werden. Diese Niederschlags-Abfluss-Modelle sind entweder stochastischer (z.B. Augustin et al., 2008) oder deterministischer Natur.



### 3.1 Talsperrenbewirtschaftung unter klimatisch veränderten Rahmenbedingungen

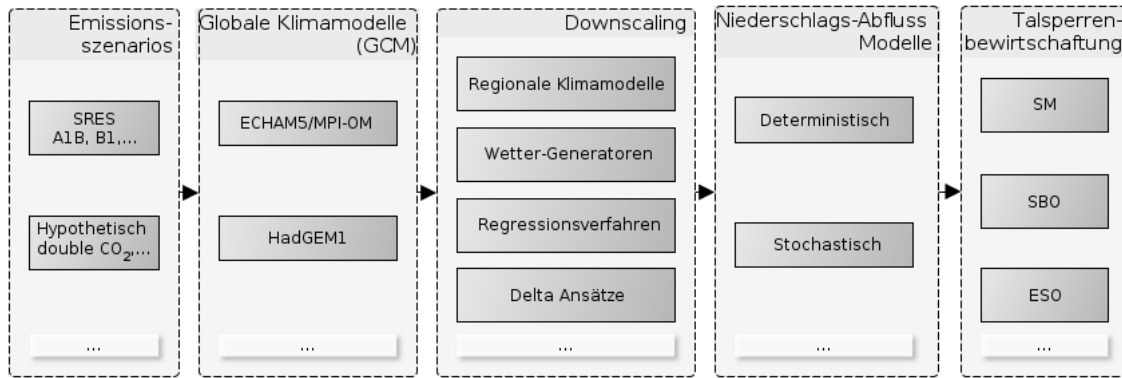


Abbildung 3.1: Modellkaskade zur Bewertung von Klimaveränderungen auf die Wasserverfügbarkeit in der Mesoskala.

Leavesley (1994), Xu and Singh (2004) und Fowler et al. (2007) geben einen Überblick über Arbeiten und Ansätze, die den Einfluss eines veränderten Klimas auf den Wasserhaushalt und weiterhin auf wasserwirtschaftliche Systeme überprüfen. Abbildung 3.1 illustriert den Ablauf möglicher Modellkaskaden.

Simulationsläufe von GCM und RCM stellen jeweils nur eine Realisierung eines stochastisch geprägten, meteorologischen Prozesses dar. Sichere Prognosen sind daher nur mit einem hohen Stichprobenumfang an Realisierungen möglich. Diese stehen jedoch oftmals nicht zur Verfügung, oder können wegen des hohen Arbeitsaufwands nicht berechnet werden. Nicht unerhebliche Unsicherheiten hinsichtlich der zukünftig mittleren Verhältnisse sind die Folge. Auch führen unterschiedliche GCM, RCM und hydrologische Modelle zu jeweils abweichenden Ergebnissen. Daher werden Ensemble-Rechnungen mit unterschiedlichen Modellkaskaden von GCM, RCM und hydrologischen Modellen empfohlen (IPCC, 2007; Fowler et al., 2007). Wissenschaftler versuchen, diese Unsicherheiten mit innovativen Ansätzen zu quantifizieren (Wilby and Harris, 2006; Steinschneider et al., 2012; Nazemi et al., 2012, in press).

Reagiert ein wasserwirtschaftliches System sensitiv auf den klimatischen Wandel, da z.B. die verfügbaren Wasserressourcen als Wasserdargebot unter den neuen klimatischen Bedingungen zurückgehen, dann ist zumeist eine Abnahme der Leistungsfähigkeit des Systems die Folge und Versagensfälle treten vermehrt auf (Klemes, 1985). Eine Fülle von Autoren untersuchen die Auswirkungen von veränderten Klimazuständen auf wasserwirtschaftliche Systeme (Klimafolgenanalyse), indem die Bewirtschaftung unter den projizierten Rahmenbedingungen anhand von Simulationsmodellen analysiert wird (unter anderem Klemes, 1985; Lettenmaier and Sheer, 1991; Nawaz et al., 1999; Fowler et al., 2003; Christensen et al., 2004; Morgenschweis et al., 2007; Minville et al., 2010). Die zukünftige Leistungsfähigkeit wasserwirtschaftlicher Anlagen wird in diesen Studien am Status quo,

also mit den historischen Steuerungsstrategien, abgeschätzt. Unter veränderten Rahmenbedingungen können die aktuellen Steuerungsstrategien jedoch gegebenenfalls nicht länger die optimale Leistungsfähigkeit garantieren, sodass die zukünftig mögliche Leistungsfähigkeit (Grenzleistungsfähigkeit) deutlich unterschätzt werden kann. Daher sind zunächst an die veränderten Rahmenbedingungen adaptierte Steuerungsstrategien zu ermitteln.

Die Klimafolgenforschung für wasserwirtschaftliche Speichersysteme mittels bestmöglicher Steuerungsstrategien ist ein relativ junges Forschungsfeld. Eum and Simonovic (2010) koppeln einen GA und ein Simulationsmodell in einem EK-SBO-Ansatz, um jeweils optimal angepasste Steuerungsstrategien für ein Talsperrenverbundsystem im Nakdong Einzugsgebiet (Korea) unter veränderten klimatischen Zuständen zu ermitteln. Die projizierten Zuflüsse entstammen einer Modellkaskade aus einem Wettergenerator zum Downscaling der GCM-Daten und ein Niederschlags-Abfluss-Modell zur Modellierung der Zuflüsse zu den Klimaszenarien. Die Autoren stützen sechs Szenarienrechnungen auf jeweils 60 Jahre generierter Zuflüsse. In einer vergleichbaren Studie analysieren Eum et al. (2012) die Einflüsse der projizierten Klimaveränderungen auf ein Talsperrenverbundsystem am Oberen Thames Fluss (Kanada). Hier nutzen die Autoren einen Wettergenerator zum Downscaling von zwei Klimaszenarien. Jeweils 100 Jahre synthetischen Wetters treiben das Niederschlags-Abflussmodell HEC-HMS an, um tägliche Zuflüsse zu den Talsperren zu generieren. Um Hochwasserschäden zu minimieren, wird das Talsperrenverbundsystem jeweils anhand von 50-jährigen Zuflüssen optimiert. Eine Validierung der optimierten Regelkurven erfolgt dann anhand der verbleibenden 50-jährigen Zuflüsse.

Raje and Mujumdar (2010) nutzen SDP zur Adaption des Talsperrenbetriebs der Talsperre Hirakud (Indien) für Klimaprojektionen des SRES A2-Szenarios und einem zunehmendem Bewässerungsbedarf bis zum Jahr 2100. Die Simulationsergebnisse des CGCM2-Klimamodells dienen zum Antrieb des räumlich verteilten hydrologischen DHM-Modells, um so Zuflüsse für jeweils 20-jährige Zeitscheiben zur Verfügung zu stellen. Die Klimafolgenabschätzung erfolgt in den Zeitscheiben anhand der adaptierten Talsperrenverbundsysteme und vergleichend mit den aktuellen Steuerungsstrategien. Ebenfalls mit SDP schätzt Brass (2006) die mögliche Leistungsfähigkeit eines Talsperrenverbundsystems in Deutschland unter sechs Klimaprojektionen ab.

Alle drei Studien kommen zu dem Schluss, dass die angepassten wasserwirtschaftlichen Systeme weniger sensitiv gegenüber den Klimaszenarien reagieren. Die ermittelten Steuerungsstrategien sollten sich nach Raje and Mujumdar (2010) als effektive Optionen erweisen, um die negativen Auswirkungen der veränderten klimatischen Rahmenbedingungen zu reduzieren.

## 3.2 Zeitreihengenerierung in der Wasserbewirtschaftung

In der Planung und Bewirtschaftung wasserwirtschaftlicher Anlagen werden stochastische Zeitreihenmodelle in vielen Bereichen eingesetzt. So können mittels geeigneter Zeitreihenmodelle auf der operationellen Zeitskala Vorhersagen über Zuflüsse oder Abgabeanforderungen für begrenzte zukünftige Zeitschritte geschätzt werden (Echtzeitprognosen). Diese Vorhersagen können dann einen effizienten operationellen Betrieb ermöglichen. Des Weiteren findet die Generierung langjähriger synthetischer Zeitreihen in der Bemessung der benötigten Speichergröße von Versorgungs- und Rückhaltespeichern Verwendung (Langzeitprognosen). Auch für die Evaluation der mittel- und langfristigen Talsperrenbewirtschaftung, z.B. mittels Simulationsprogrammen, bilden synthetische Zeitreihen zumeist die Grundlage. Da Zeitreihenmodelle zur Echtzeitprognose in dieser Arbeit keine Anwendung finden, soll im Folgenden eine kurze Übersicht über Zeitreihenmodelle für Langzeitprognosen gegeben werden.

Mit den Arbeiten von Barnes (1954) und Fiering (1964) finden **lineare parametrische Modelle** Einzug in die Planung und Bewirtschaftung wasserwirtschaftlicher Anlagen (Box and Jenkins, 1976; Salas et al., 1980; Vecchia, 1985; Rasmussen et al., 1996) und stellen somit die älteste Modellklasse dar, die bis heute auf wissenschaftliches Interesse stößt (Langousis and Koutsoyiannis, 2006; Anderson et al., 2007; Shamir et al., 2007).

**Nichtlineare parametrische Modelle** können die, in stochastischen Prozessen inhärenten, nichtlinearen Merkmale berücksichtigen (Kantz and Schreiber, 2004). Sie sind jedoch sehr komplex und finden daher in der Wasserwirtschaft kaum Anwendung (Montanari et al., 1999; Ooms and Franses, 2001; Elek and Márkus, 2004).

**Disaggregationsmodelle** (DM) sind parametrische Modelle und arbeiten mit mehreren Zeitreihenmodellen auf unterschiedlichen Zeit- und Raumskalen. DM sind daher in der Lage statistische Eigenschaften auf mehreren Zeit- oder Raumskalen zu erhalten. So sind DM, neben wenigen parametrischen Modellen (wie z.B. FARIMA Modelle; Hamilton, 1994), in der Lage Langzeitpersistenz (Hurst, 1951) zu modellieren. Unter *Langzeitpersistenz* wird ein längeres „Gedächtnis“ eines stochastischen Prozesses verstanden. Sie ist zumeist an einem langsamen exponentiellen Abklang des Autokorrelogramms erkennbar. Wie Koutsoyiannis (2005), Langousis and Koutsoyiannis (2006) und Hoshi et al. (1978) feststellen, ist eine adäquate Modellierung der Langzeitpersistenz notwendig, um die Leistungsfähigkeit wasserwirtschaftlicher Speichersysteme nicht zu überschätzen bzw. zu projektierende Speichergrößen zu unterschätzen.

**Nichtparametrische Zeitreihenmodelle** (NP) sind erst seit neuerer Zeit im Fokus der Forschung. Verschiedene Arten des Bootstrapping, wie Moving-Block-Bootstrapping, Kerndichteschätzer oder K-Nearest-Neighbor-Bootstrapping wurden erfolgreich zur Zeitreihenmodellierung eingesetzt (Lall and Sharma, 1996; Vogel and Shallcross, 1996; Sharma and O'Neill, 2002; Kim et al., 2004; Kim and Valdés, 2005; Prairie et al., 2006; Srinivas

and Srinivasan, 2006; Lee et al., 2010; Ndiritu, 2011). Dies gilt auch für nichtparametrische Zeitreihenmodelle auf Basis künstlicher neuronaler Netze (KNN), die anfangs alleine (Raman and Sunilkumar, 1995; Awchi and Srivastava, 2009) und in neueren Studien in Verbindung mit anderen Methoden als hybride-KNN (HKNN) angewandt werden (Ochoa-Rivera et al., 2002; Prairie et al., 2006; Ahmed and Sarma, 2007; Sudheer et al., 2008; Ashrafzadeh and Rizi, 2009). NP erfordern keine Annahmen über die zugrunde liegenden Wahrscheinlichkeitsverteilungen der Zeitreihen (oder entsprechende Transformationen zu einer Normalverteilung). Wenige hybride KNN-Modelle können darüber hinaus nichtlineare Zusammenhänge in der Struktur der Zeitreihe wiedergeben und unbeobachtete Durchflüsse generieren.

Das NP-Zeitreihenmodell von Ilich and Despotovic (2008), weiterentwickelt in Ilich (2013), beschreibt einen gänzlich neuen Weg, der mit den bisherigen Vorgehensweisen bricht. Hierbei werden zunächst wöchentliche oder monatliche Zuflüsse aus einer angepassten Wahrscheinlichkeitsverteilung gezogen. Es erfolgt dann eine iterative Anordnung der Zuflüsse, um für alle Jahre die innerjährliche Autokorrelationsstruktur abzubilden. In einem abschließenden Schritt werden dann ganze Jahre iterativ angeordnet, um die überjährliche Autokorrelationsstruktur abzubilden.

Bezüglich der Defizite vieler parametrischen und nichtparametrischen Modelle stellen Rajagopalan et al. (2009) fest, dass:

- a) kein Erhalt der Korrelation über Modellgrenzen hinweg erfolgt (z.B. die Korrelation des ersten Monats eines Jahres mit dem letzten Monat des vorherigen Jahres).
- b) mitunter negative Durchflüsse simuliert werden, die dann als Zeitschritte ohne Durchflüsse zu korrigieren sind.
- c) keine Generierung neuartiger Innovationen erfolgt, wodurch die Simulation unbeobachteter Durchflüsse unterbleibt und sich wenige Durchflussmuster oft wiederholen.
- d) die Langzeitpersistenz stochastischer Prozesse nicht, oder nur unzureichend modelliert wird.

Srinivas and Srinivasan (2006) führen weiterhin an, dass keine der bisher vorgestellten Modelle eine generelle Akzeptanz unter Anwendern und somit weitreichende Verbreitung gefunden hat. Die Autoren stellen die Frage, ob mögliche Gründe dafür ein fehlendes Vertrauen in die Modelle oder ein Unvermögen der Anwender sind, da die Modelle in ihrer Theorie, Implementierung oder Anwendung zu komplex sind. Anwender von Zeitreihenmodellen aus nicht mathematischen Disziplinen neigen demnach eher zu einfachen

### *3.2 Zeitreihengenerierung in der Wasserbewirtschaftung*

Modellen. Ilich and Despotovic (2008) nennen als Beispiel das einfache ISM-Modell, das trotz seiner bekannten Defizite von den zuständigen Behörden für die Simulation des Colorado River genutzt wird. Diesen Kritikpunkt nennt auch Ilich (2008) als einen der Gründe für ihre Modellentwicklung und verweist darauf, dass zunehmend Zeitreihenmodelle der NP-Modellklasse entwickelt werden.



## 4 Zusammenfassung und offene Forschungsfragen

Folgende offene Forschungsfragen ergeben sich aus der Recherche zum Stand der Technik in Hinblick auf die gestellten Ziele dieser Arbeit:

- Frage a) In der Literatur sind vor allem zwei Formulierungen von Zielfunktionen vorzufinden. Diese sind (1) die Minimierung einer Summe bzw. eines Erwartungswerts oder (2) die Minimierung eines quadrierten Fehlers (SE) zwischen einer Zielvorgabe und erreichtem Ziel (siehe Tabellen A.1 und A.2). Mit der Arbeit von Soltani et al. (2008) ist lediglich eine Studie bekannt, die eine Zielfunktion auf Basis einer Versorgungssicherheit (Reliability) nutzt. Erfahrungen mit EK-SBO- oder MK-SBO-Studien in Verbindung mit einer expliziten Formulierung von Zielfunktionen auf Basis von Versorgungssicherheiten liegen nicht vor. Als Hauptgrund hierfür ist wahrscheinlich Frage b) anzuführen.
- Frage b) Verlässliche Aussagen über hohe Versorgungssicherheiten (wie in Kapitel 8) erfordern langjährige Zeitreihen (siehe Abschnitt 2.4). Auch die Optimierung von wasserwirtschaftlichen Systemen unter „klassischen“ Zielfunktionen (Frage a) kann unter langjährigen Zeitreihen verlässlichere Ergebnisse erzielen. Mit der Arbeit von Koutsoyiannis et al. (2002) liegt eine Studie vor, die einen a priori MK-SBO-Ansatz mit einer Zeitreihenlänge von 2000 Jahren anwendet. Die Zuflusszeitreihen, die in Studien mit a posteriori MK-SBO-Ansätzen Verwendung finden, umfassen maximal 100 Jahre. Hier ist die Verwendung von längeren Zeitreihen wünschenswert, jedoch steigt der Rechenaufwand linear mit der Zeitreihenlänge. Koutsoyiannis et al. (2002) empfehlen den Einsatz von Parallelisierungstechniken, um Rechenzeit einzusparen. Auf handelsüblicher Hardware ist der Umfang einer möglichen Parallelisierung jedoch stark begrenzt. Neben der Parallelisierung der MK-SBO müssen somit weitere Einsparungspotenziale gefunden und ausgenutzt werden.
- Frage c) Die Grenzleistungsfähigkeit von wasserwirtschaftlichen System im Rahmen einer Klimafolgenabschätzung wird bisher durch Anwendung von klassischen ISO- und ESO-, sowie EK-SBO-Ansätzen abgeschätzt. Mit diesen Ansätzen lassen sich jedoch nicht Veränderungen auf das Spannungsfeld von konträren Bewirtschaftungszielen untersuchen. A priori MK-SBO-Ansätze erfordern die Wichtung der konträren Bewirtschaftungsziele von Mehrzweckspeichern. Unter veränderten

klimatischen Bedingungen kann jedoch erwartet werden, dass die historische Wichtung in den Szenarien nicht mehr die bevorzugte Kompromisslösung darstellt. A posteriori MKO-Ansätze ermöglichen durch die Approximation der Pareto-Front einerseits die Bewertung der zukünftigen Spannungsfelder, andererseits ermöglicht die Pareto-Menge eine Auswahl der Kompromisslösung anhand der Prioritäten des Entscheidungsträgers. Im Bereich der wasserwirtschaftlichen Klimafolgenanalyse scheint bisher jedoch keine Erfahrung in der Anwendung von MKO-Ansätzen zu existieren.

- Frage d) Stochastische Zeitreihenmodelle dienen als Werkzeuge, um langjährige Zeitreihen mit bisher unbeobachteten hydrologischen Zuständen zu generieren. Um das zu entwickelnde Framework möglichst anwenderfreundlich zu gestalten, soll das angewandte stochastisches Zeitreihenmodell einfach zu implementieren und zu handhaben sein. Die Leistungsfähigkeit des Modells, muss dabei ausreichen, um die wichtigsten Eigenschaften der stochastischen Prozesse adäquat zu beschreiben.
- Frage e) Die vielversprechende Methode der Level-Diagramme (Blasco et al., 2008) soll zur Vermittlung der Ergebnisse im Rahmen einer multikriteriellen Entscheidungshilfe für wasserwirtschaftliche Speichersysteme eingeführt werden. Die Ergebnisdarstellung ist an die Erfordernisse anzupassen.



## **Teil II**

# **Framework zur multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen**



## 5 Vorstellung des Gesamtkonzepts

Um auf die in Kapitel 4 angesprochenen offenen Forschungsfragen a) bis e) einzugehen und dem Stand der Forschung zu entsprechen, wird in Teil II dieser Arbeit ein Framework zur multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen (Frams-BoT) entwickelt. Der prinzipielle Aufbau von Frams-BoT ist in Abbildung 5.1 dargestellt. Das Framework ist modular aufgebaut und integriert für die durchzuführenden Arbeitsschritte aufeinander abgestimmte Methoden:

- In Modul A, Abschnitt 6.1, werden Talsperrenzuflüsse (Zuflussdargebote) unter verschiedenen projizierten Klimaszenarien als Grundlage zur Klimafolgenanalyse modelliert. In dieser Arbeit wird das physikalisch begründete und flächendifferenzierte Modell WaSiM-ETH (Schulla, 2012) genutzt, um tägliche Zuflüsse aus den meteorologischen Daten ausgewählter Klimaprojektionen zu generieren. Eine multikriterielle Kalibrierung von WaSiM-ETH erfolgt mit der in Frams-BoT implementierten Version der multikriteriellen Optimierungsstrategie MO-CMA-ES.
- In Modul B, Abschnitt 6.2, findet die stochastische Zeitreihengenerierung von langjährigen Zuflusszeitreihen statt. Um den in Abschnitt 4 unter Frage d) aufgeführten Anforderungen gerecht zu werden, wird ein Zeitreihenmodell (HKNN-SMA) als Abwandlung des MPAR-SMAF-Ansatzes von Langousis and Koutsoyiannis (2006) entwickelt. Hierbei wird das lineare multivariate und parametrische autoregressive Regressions-Untermittel (MPAR) des Ansatzes durch das nichtparametrische Zeitreihenmodell HKNN nach Ashrafzadeh and Rizi (2009) ersetzt. Die Nachteile der linearen parametrischen Modelle lassen sich gegen die Vorteile der hybriden KNN-Modelle austauschen. Neben der Langzeitpersistenz ist das Modell in der Lage wichtige statistische und stochastische Eigenschaften robust abzubilden. Weiterhin ist das Zeitreihenmodell einfach zu implementieren und anzuwenden.
- In Modul C, Abschnitt 6.3, findet anhand einer neu entwickelten Monte-Carlo-Rekombinationsmethode eine signifikante Verkürzung der langjährigen Zuflusszeitreihen statt. Als wichtige wasserwirtschaftliche Kenngröße des hydrologischen Zuflussregimes bleibt dabei die Verteilung der Trockenperioden (beschrieben durch die zugehörigen Defizitvolumina) erhalten. Zusammen mit den Methoden im Modul D dient Modul C der Reduktion der Rechenzeiten (Frage b).

- In Modul D, Abschnitt 6.4, geschieht die eigentliche Optimierung der Steuerungsstrategien der Talsperrenverbundsysteme anhand einer multikriteriellen simulationsbasierten Optimierung. Die leistungsfähige multikriterielle evolutionäre Strategie MO-CMA-ES (Igel et al., 2007) wird in dieser Arbeit mit dem Talsperrenoptimierungsmodell OASIS (Hydrologics Inc., 2009) gekoppelt. Eine Parallelisierung der MO-CMA-ES erlaubt den simultanen Aufruf von bis zu 64 Simulationsmodellen. Das Zusammenspiel eines Box-Constraint-Handlers (Igel et al., 2007) mit dem hier generalisierten Ansatz von Scola et al. (2010) ermöglicht eine effiziente und robuste, da randbedingungslose, Optimierung von mehreren Regelkurven eines wasserwirtschaftlichen Speichers. Die Initialisierung der Startpopulation des Optimierungsalgorithmus kann die Konvergenz der Optimierung weiterhin beschleunigen (Frage b).
- In Modul E, Abschnitt 6.5, erfolgt eine Bewertung der optimierten Steuerungsstrategien durch die Validierung der Zielfunktionswerte mit den unveränderten langjährigen Zeitreihen aus Modul B. Somit lässt sich prüfen, inwieweit die multikriterielle Optimierung mit den in Modul C gekürzten Zeitreihen hinsichtlich der unveränderten langjährigen Zeitreihen repräsentativ und übertragbar sind. Um den Rechenaufwand auch für diesen Schritt zu reduzieren, kann durch eine Clusterung der Pareto-Menge eine Auswahl an zu validierenden Lösungen vorgenommen werden.
- In Modul F, Abschnitt 6.6, werden Level-Diagramme genutzt, um eine Entscheidungshilfe für multikriterielle Probleme zu geben und hochdimensionale Datensätze verständlich zu visualisieren. Mittels der Wertungen der Lösungen lassen sich die Spannungsfelder (Pareto-Fronten) der konträren Ziele vergleichen und analysieren (Frage e). In Klimafolgenanalysen lassen sich Level-Diagramme weiterhin nutzen, um die Pareto-Fronten unter verschiedenen Klimaszenarien zu vergleichen. Die Reduktion des Umfangs der Lösungsmenge auf repräsentative Lösungen mit selbstorganisierenden Merkmalskarten vereinfacht den Entscheidungsprozess zusätzlich.

Das Zusammenspiel der genannten Methoden in den Modulen C und D, zusammen mit einer möglichen Initialisierung der MO-CMA-ES, sowie der Auswahl an zu validierenden Lösungen, soll die benötigten Rechenzeiten erheblich reduzieren. Dies ermöglicht die multikriterielle Optimierung des Talsperrenbetriebs unter Berücksichtigung von Versorgungssicherheiten auf Grundlage langjähriger Simulationsrechnungen (Frage a und Frage b). Ebenso erlaubt dieses Vorgehen die Durchführung von mehreren Optimierungsrechnungen für eine Klimafolgenanalyse (Frage c) in annehmbarer Zeit. Der überwiegende Teil der Methoden in Frams-BoT ist in der Entwicklungsumgebung MATLAB<sup>TM</sup> implementiert. Der Quellcode von MO-CMA-ES ist in C<sup>++</sup> verfügbar. Die Schnittstelle zwischen der MO-CMA-ES und OASIS ist in der Programmiersprache Perl implementiert.




Abbildung 5.1: Framework zur multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen. Pfeile mit durchgezogenen Strichen skizzieren das methodische Ablaufschema, strichpunktierte Pfeile zeigen den Datenfluss.



## 6 Beschreibung der Module

Dem Ablaufschema in Abbildung 5.1 folgend, sollen in diesem Kapitel die einzelnen Module der Frams-BoT-Strategie und der darin verwendeten Methoden im Detail vorgestellt werden.

### 6.1 Modul A: Talsperrenzuflüsse unter projizierten klimatische Bedingungen

Für Klimafolgenanalysen sind in Modul A zunächst die Zuflussdargebote für einzelne Klimaszenarien abzuschätzen. Die generellen Arbeitsschritte in Modul A umfassen die Aufarbeitung der beobachteten oder projizierten meteorologischen Daten und der beobachteten Abflussspenden, den Modellaufbau des verwendeten Niederschlags-Abfluss-Modells, das Bereitstellen einer Schnittstelle zwischen Optimierungsalgorithmus und dem Simulationsmodell, die Kalibrierung und Validierung des Modells anhand von Beobachtungsdaten sowie die Simulation von Abflussspenden oder Zuflüssen für die jeweiligen Realisierungen der Klimaszenarien. Je nach Anforderungen, Datengrundlage und Lage der Untersuchungsgebiete kann die Modellkette in Modul A vom Anwender angepasst werden.

Im Folgenden sollen zunächst die Grundzüge des Wasserhaushaltsmodells WaSiM-ETH erläutert werden. Anschließend wird auf die Kalibrierung von prozessorientierten hydrologischen Modellen wie WaSiM-ETH eingegangen.

#### 6.1.1 Das Wasserhaushaltsmodell WaSiM-ETH

WaSiM-ETH besitzt einen modularen Aufbau. Je nach Problemstellung können Module zur Simulation bestimmter Prozesse zu- oder abgeschaltet bzw. aus einem Pool von verfügbaren Modellansätzen ausgewählt werden. Die generelle Modellstruktur von WaSiM-ETH illustriert Abbildung 6.1. Im Folgenden werden ausgewählte Module beschrieben, deren Parameter zu kalibrieren sind oder die gesondert für die Wasserhaushaltsmodellierung ausgewählt wurden. Für genauere Informationen über WaSiM-ETH wird auf die umfassende Modelldokumentation (Schulla, 2012) verwiesen.

Übersteigt die Niederschlagsintensität die Infiltrationskapazität des Bodens, entsteht Oberflächenabfluss als Infiltrationsüberschuss. Ist die oberste Schicht des Bodens gesättigt, entsteht in dieser Zelle zusätzlicher Oberflächenabfluss als Sättigungsflächenabfluss. Beide Komponenten des Oberflächenabflusses bilden in der schneefreien Jahreszeit in WaSiM-ETH den Direktabfluss. Der Anteil des infiltrierenden Wassers wird anhand des Richards-Modells

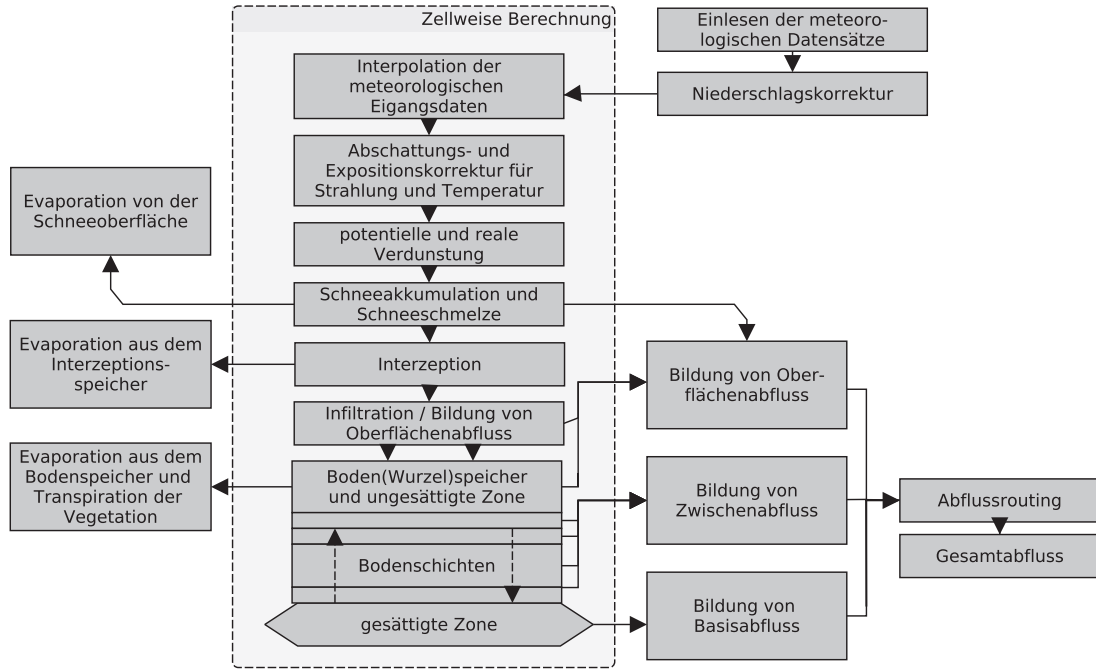


Abbildung 6.1: Modellkonzept von WaSiM-ETH (nach Schulla, 2012).

berechnet, wobei die maximale Infiltrationsmenge, als obere Randbedingung, nach dem, von Peschke (1977) erweiterten, Ansatz nach Green and Ampt (1911) abgeschätzt wird. Die Konzentration des Direktabflusses im Einzugsgebiet erfolgt über eine Flächen-Laufzeit-Funktion nach Dyck (1980). Nach der Translation wird in der untersten Fließzeitzone am Gebietsauslass die Retention berechnet. Dieser Gebietsrückhalt wird in Form eines Einzellinearspeichers berücksichtigt

$$Q_{D,t} = Q_{D,t-1} \times e^{-\frac{\Delta t}{K_1}} + \hat{Q}_D \times \left(1 - e^{-\frac{\Delta t}{K_1}}\right). \quad (6.1)$$

Hierbei ist  $Q_{D,t}$  der Direktabfluss im Zeitschritt  $t$ ,  $Q_{D,t-1}$  der Direktabfluss im vorherigen Zeitschritt,  $\hat{Q}_D$  die in der untersten Fließzeitzone zur Verfügung stehende Direktabflussmenge bezogen auf das gesamte Gebiet und  $K_1$  die Speicherkonstante des Direktabflussspeichers. Das infiltrierte Wasser wird dann entweder über präferentielle Fließwege dem Grundwasser oder bei entsprechend vorhandenen Stauhorizonten im Boden dem Zwischenabflussspeicher zugeführt. Der Zwischenabfluss  $q_{I,t}$  für eine bestimmte Zelle wird zunächst flächendifferenziert nach Gleichung 6.2 bestimmt.

$$q_{I,t} = K(\Theta_t) \Delta z \times d_r \times \tan \beta \quad (6.2)$$



## 6.1 Modul A: Talsperrenzuflüsse unter projizierten klimatische Bedingungen

Hierbei ist  $K(\Theta_t)$  die hydraulische Leitfähigkeit in Abhängigkeit des Bodenwassergehalts  $\Theta_t$ ,  $\Delta z$  die Mächtigkeit der jeweiligen Bodenschicht und  $\beta$  das Gefälle der lokalen Rasterzelle. Der Faktor  $d_r$  bewirkt eine Skalierung des Zwischenabflusses je Rasterzelle. Analog zum Direktabfluss in Gleichung 6.1 wird der resultierende Zwischenabfluss  $Q_{I,t}$  für das Gesamtgebiet durch einen Einzellinearspeicher am Gebietsauslass berechnet. Analog zu  $K_1$  findet hierbei die Speicherrückgangskonstante  $K_2$  des Zwischenabflusses zur zeitlichen Verteilung der schnellen Abflusskomponenten Verwendung. Die Berechnung von Basisabfluss geschieht konzeptionell mittels

$$Q_{B,t} = Q_0 \times K_S \times e^{\frac{(h_{GW,t} - h_{GEO,0})}{K_B}} \quad (6.3)$$

mit dem Basisabfluss  $Q_{B,t}$ , dem Skalierungsfaktor des Basisabflusses  $Q_0$ , der gesättigten hydraulischen Leitfähigkeit  $K_S$ , dem Grundwasserspiegel  $h_{GW,t}$ , der Geländeoberkante der ersten Bodenschicht  $h_{GEO,0}$  sowie der Auslaufkonstante des Basisabflusses  $K_B$ . Die eindimensionale vertikale Bodenwasserbewegung durch die Bodenschichten einer Rasterzelle

$$\frac{\Delta\theta}{\Delta t} = \frac{\Delta q}{\Delta z} = q_{in} - q_{ab}. \quad (6.4)$$

wird durch den physikalisch begründeten Ansatz der Richards-Differentialgleichung in der diskretisierten Form beschrieben. Hierbei ist  $\Delta\theta$  die Änderung des Bodenwassergehalts während der Länge des Zeitschritts  $\Delta t$ . Die Änderung des spezifischen Flusses über die Mächtigkeit einer Bodenschicht  $\Delta z$  ist  $\Delta q$ .  $q_{in}$  und  $q_{ab}$  sind die Zu- bzw. Abflüsse aus der jeweiligen Bodenschicht. Anhand von Pedo-Transferfunktionen (Schapp et al., 2001; Acutis and Donatelli, 2003; Wösten and Nemes, 2004) oder Tabellenwerten (Ad-hoc-Arbeitsgruppe Boden, 2005) lassen sich die Mualem-van-Genuchten Parameter abschätzen, die zur Beschreibung der Richards-Differentialgleichung notwendig sind. Die hydraulischen Leitfähigkeiten werden zusätzlich über den empirischen Parameter  $k_{rec}$ , welcher die Abnahme der Leitfähigkeit mit der Tiefe beeinflusst, angepasst (Schulla, 2012).

In WaSiM-ETH wird zwischen flüssigem und festem Niederschlag unterschieden. Dabei existiert ein Übergangsbereich, in dem sowohl Schnee- als auch Regenniederschlag vorkommen. Die Grenzen der Übergangsbereiche werden anhand der interpolierten Lufttemperatur festgelegt und die Unterscheidung des Niederschlages für jede einzelne Rasterzelle vorgenommen. Der Schneeanteil  $p_{Schnee}$  am Niederschlag berechnet sich mittels

$$p_{Schnee} = \frac{T_{OR} + T_{TOR} - T_L}{2 \times T_{TOR}} \quad (6.5)$$

im Temperaturbereich

$$(T_{OR} - T_{TOR} < T_L < T_{OR} + T_{TOR}) \quad (6.6)$$

mit der aktuellen Lufttemperatur  $T_L$ , der Lufttemperatur  $T_{OR}$ , bei der 50 % des Niederschlags als Schnee fallen und  $T_{TOR}$ , der als die Hälfte des Temperatur-Übergangsbereichs von Schnee zu Regen definiert ist.

Der angewandte Ansatz zur Modellierung der Schneeschmelze entstammt der Arbeit von Anderson (1973). Eine Schneeschmelze findet bei diesem Ansatz bei Temperaturen oberhalb der Schmelz-Grenztemperatur  $T_0$  statt. Dabei wird anhand der gefallenen Niederschlagsmenge zwischen Zeitintervallen mit Niederschlag ( $P \geq 2$  mm) und ohne Niederschlag ( $P \leq 2$  mm) unterschieden. Fällt Niederschlag, errechnet sich die Schmelzwassermenge  $M$  durch

$$M = (M_R + M_S + M_E + M_P) \times \frac{\Delta t}{24} \quad (6.7)$$

mit der Strahlungsschmelze  $M_R$ , der Schmelze infolge fühlbarer Wärme  $M_S$ , der Schmelze durch latente Wärme  $M_E$  sowie der Schmelze durch den Energieeintrag des Niederschlags  $M_P$ . Die einzelnen Anteile der Schmelze sind durch

$$M_R = 1,2 \times T_L \quad (6.8)$$

$$M_S = (c_1 + c_2 \times u) \times (T_L - T_0) \quad (6.9)$$

$$M_E = (c_1 + c_2 \times u) \times \left( \frac{E - 6,11}{\gamma_P} \right) \quad (6.10)$$

$$M_P = 0,0125 \times P \times T_L \quad (6.11)$$

gegeben. Hierbei ist  $c_1$  ein temperaturabhängiger Schmelzfaktor,  $c_2$  ein windabhängiger Schmelzfaktor,  $u$  die Windgeschwindigkeit,  $\gamma_P$  die Psychrometerkonstante,  $E$  der Sättigungsdampfdruck bei gegebener Lufttemperatur,  $P$  die Niederschlagsmenge und  $T_0$  die Grenztemperatur für den Schmelzbeginn. Für niederschlagsfreie Zeitintervalle wird die Schneeschmelze mit dem Schmelzfaktor der Strahlung RF wie folgt berechnet

$$M = \text{RF} \times (T_L - T_0) \times \frac{\Delta t}{24}.$$

Das Wasseräquivalent der Schneedecke wird nach flüssiger und fester Phase unterschieden. Der Anteil der flüssigen Phase am Gesamtspeicher beträgt in WaSiM-ETH maximal 10% des Wasseräquivalents. Erst wenn der Speicher der flüssigen Phase vollständig gefüllt wurde, findet eine Abgabe von Wasser aus der Schneedecke statt. Bei Temperaturen unterhalb  $T_0$  kann ein Wiedergefrieren des Wasser in der Schneedecke  $M_{\text{neg}}$  erfolgen

$$M_{\text{neg}} = c_{\text{rfr}} \times \text{RF} \times (T_L - T_0) \times \frac{\Delta t}{24},$$

hierbei ist  $c_{\text{rfr}}$  der Koeffizient für das Wiedergefrieren der flüssigen Phase. Weitere Details zum Schneemodul von WaSiM-ETH sind der Modelldokumentation von Schulla (2012) zu entnehmen.

Aufgrund projizierter Temperaturzunahmen ist zukünftig ein früherer jährlicher Beginn der Vegetationsperiode nicht auszuschließen (Bernhofer et al., 2011). Diese Verschiebung und gegebenenfalls auch eine Verlängerung der gesamten Vegetationsperiode könnten den Wasserhaushalt durch eine zunehmende Verdunstung beeinflussen. Daher ist es wichtig, den Beginn der Pflanzenwachstumsphase dynamisch abzubilden. Ansätze zur Beschreibung der dynamischen Pflanzenphänologie eines Waldes stammen von Sarvas (1974) und für Acker- und Grünlandflächen von Chmielewski et al. (2005). Bei beiden Ansätzen handelt es sich jeweils um Temperatursummenansätze, bei denen der Beginn phänologischer Phasen variabel anhand von Schwellenwerten und Temperatursummen ermittelt wird.

### 6.1.2 Modellkalibrierung

Die klassische Kalibrierung von prozessorientierten hydrologischen Modellen geschieht durch den Anwender von Hand. Hierbei werden die Modellparameter so verändert, dass das simulierte dynamische Modellverhalten mit der Beobachtung (z.B. Abflussspenden) möglichst übereinstimmt (Shafii and De Smedt, 2009). Dieser Vorgang ist subjektiv, arbeitsintensiv und führt nicht immer zu den bestmöglichen Ergebnissen (Gupta et al., 1998).

Die rechnergestützte Kalibrierung wird als Optimierungsproblem formuliert. Während die Modellparameter gezielt variiert werden, wird die Anpassung des simulierten dynamischen Modellverhaltens an die Beobachtung mit einem Gütekriterium beschrieben. In der Literatur sind mehrere Studien zu finden, die sich mit der Wahl und dem Einfluss von Gütekriterien befassen (unter anderem Gupta et al., 1999; Moriasi et al., 2002; Krause et al., 2005; Reusser et al., 2009; Wöhling et al., 2013). Yapo et al. (1998) und Gupta et al. (1998) zeigen, dass die Güte der Abbildung wichtiger hydrologischer Charakteristiken zwischen Beobachtungsdaten und Simulationsergebnissen nicht durch ein einzelnes Gütekriterium beschreibbar und bewertbar ist.

Durch Unsicherheiten, die durch die Beobachtungsdaten, das Modellkonzept und die Parameterschätzung entstehen, ist es im Allgemeinen nicht möglich, einen einzigartigen und optimalen Parametersatz zu finden, mit dem sich alle hydrologischen Charakteristiken abbilden lassen (Efstratiadis and Koutsoyiannis, 2010). Die in der Kalibrierung erreichten Gütekriterien sind daher oftmals zueinander konträr (Gupta et al., 1998). Mit dem Einsatz der multikriteriellen Optimierung (MKO) als Kalibrierungsstrategie können simultan mehrere Gütekriterien berücksichtigt werden.

Gupta et al. (1999) schlussfolgern, dass die Kalibrierung von prozessorientierten hydrologischen Modellen mittels MKO-Ansätzen eine Leistungsfähigkeit erreicht hat, die der von erfahrenen Modellierern mindestens ebenbürtig ist. Die multikriterielle Kalibrierung sei daher den händischen und einkriteriellen Kalibrierungsverfahren vorzuziehen (Gupta et al., 1999). Eine Reihe von Autoren hat seitdem die Vorteile der multikriteriellen Kalibrierung

von Niederschlags-Abflussmodellen studiert und weiterentwickelt (Madsen, 2000; Bekele and Nicklow, 2007; Liu, 2009; Liu and Sun, 2010).

In dieser Arbeit wird der im Abschnitt 6.4 vorgestellte psMO-CMA-ES Algorithmus zur Kalibrierung von WaSiM-ETH vorgeschlagen. Die Kopplung des Simulationsmodells mit dem Optimierungsalgorithmus gestaltet sich über eine Schnittstelle in Perl einfach.

### 6.2 Modul B: Stochastische Zeitreihengenerierung

Zeitreihen als Grundlage der Optimierung von Steuerungsstrategien müssen Ergodizität und Stationarität aufweisen, damit die geschätzten Zielfunktionswerte mit zunehmender Zeitreihenlänge gegen die wahren Zielfunktionswerte konvergieren (Winston, 1994 zitiert durch Koutsoyiannis and Economou, 2003). Dies bedeutet in Hinblick auf die Optimierung der Talsperrensteuerung unter sich verändernden klimatischen Rahmenbedingungen, dass deterministisch aufgeprägte Trends in den Zeitreihen zu entfernen sind (beispielsweise in Abschnitt 8.3<sup>1</sup>). Die Ergebnisse aus dem Modul A sind für die jeweiligen Rechnungen daher nach Bedarf zunächst einer Trendbereinigung zu unterziehen. Dies gilt auch für Beobachtungswerte, wenn die Ergodizität und Stationarität der Zeitreihen aufgrund von anthropogenen Einflüssen nicht gegeben ist.

Die Arbeitsschritte in Modul B umfassen die Aufarbeitung der Zuflusszeitreihen, die (automatische) Parametrisierung und Validierung des Zeitreihenmodells als auch die Generierung der synthetischen Zeitreihen. Die generierten langjährigen Zeitreihen des Moduls B sind Grundlage für Modul C und finden weiterhin in der Validierung der Pareto-Mengen in Modul E Verwendung. In diesem Abschnitt soll zunächst der SMA-Filter als Postprocessing-Werkzeug des danach diskutierten HKNN-SMA-Modells vorgestellt werden.

#### 6.2.1 Der SMA-Filter

Eine weiterführende Diskussion des *Symmetric Moving Average Filters* (SMA-Filter) liefern Koutsoyiannis (2000) und Langousis and Koutsoyiannis (2006). Es sei  $\mathbf{X}_t = [X_t^{l=1}, X_t^{l=2}, \dots, X_t^{l=v}]^T$ ,  $t = 1, \dots, T$  ein multivariater zyklisch-stationärer stochastischer Prozess mit  $l = 1, \dots, v$  Zeitreihen (hier  $v$  benachbarter Standorte, wie Pegel). Für eine Saison  $s = 1, \dots, k$  und den Standort  $l$  sei  $X_{(t-1)k+s}^l$  stationär. Der Einfachheit halber seien zunächst die Erwartungswerte  $E[X_t^l] = 0$  und die Varianzen  $\text{Var}[X_t^l] = 1$ , sowie die

---

<sup>1</sup>Als deterministisch aufgeprägter Trend kann z.B. der CO<sub>2</sub>-Anstieg in den SRES-Emissionsszenarien und die daraus resultierende Abnahme der Zuflüsse angesehen werden.

Periode  $k$  des Prozesses 12 Saisons (Monate). Durch die Aggregation des Prozesses  $\mathbf{X}_t$  auf einer jährlicher Zeitskala entsteht der jährliche stochastische Prozess

$$Z_t^l = \sum_{j=(t-1)k+1}^{ik} X_j^l = \sum_{s=1}^k X_{(i-1)k+s}^l, \quad \forall l, t. \quad (6.12)$$

Lässt sich die Autokorrelationsfunktion  $\rho_j^l = \text{Corr} [Z_t^l, Z_{t-j}^l]$  mit den Lags (Zeitverschiebungen)  $j = 0, 1, 2 \dots$  durch

$$\rho_j^l = \frac{1}{2} \left( |j+1|^{2H^l} + |j-1|^{2H^l} - |j|^{2H^l} \right), \quad l = 0, 1, \dots, v; \quad j = 0, \pm 1, \pm 2 \dots \quad (6.13)$$

annähern, dann besitzt  $Z_t^l$  die Eigenschaften eines fraktionellen Gauß-Prozesses zweiter Ordnung (Koutsoyiannis, 2000). Der stochastische Prozess ist auf höheren Lags und somit auf höheren Zeitskalen signifikant korreliert und es wird von Langzeitpersistenz gesprochen. Höhere Zuflüsse weisen somit eine erhöhte Tendenz auf, auf bereits höhere Zuflüsse zu folgen und niedrigere Zuflüsse eine entsprechende Tendenz, auf niedrigere Zuflüsse zu folgen (Koutsoyiannis et al., 2002). Der Parameter  $H^l$  ist hierbei der Hurst-Koeffizient (Hurst, 1951). Für stochastische Prozesse mit Langzeitpersistenz ist dieser größer als 0,5.

Aus der Summe mehrerer stationärer und stochastischer Prozesse mit gleich großem Hurst-Koeffizienten entsteht ein neuer stationärer stochastischer Prozess mit dem gleichen Hurst-Koeffizienten (Langousis and Koutsoyiannis, 2003). Daher kann  $Z_t^l$  durch einen Prozess mit den Sequenzen  $X_{(t-1)+s}^l$  beschrieben werden, dessen  $H^l$  dem des Prozesses  $Z_t^l$  entspricht. Um  $X_t^l$  zu modellieren, nutzen Langousis and Koutsoyiannis (2006) als zyklisch-stationären Hilfsprozess  $\mathbf{W}_t = [W_t^{l=1}, W_t^{l=2}, \dots, W_t^{l=v}]^T$  ein multivariates periodisches autoregressives Modell der Ordnung eins (MPAR(1); Bras and Rodriguez-Iturbe, 1985).  $\mathbf{W}_t$  besitzt die Periode  $k$ , sowie die Erwartungswerte  $E[W_t^l] = 0$  und Varianzen  $\text{Var}[W_t^l] = 1$ .

Als Modell ohne Langzeitpersistenz und  $H^l = 0,5$  ist ein MPAR(1) nicht in der Lage  $\rho_j^l$  (Gleichung 6.13) korrekt abzubilden. Durch Filterung des stochastischen Prozesses  $\mathbf{W}_t$  mit dem linearen SMA-Filter

$$X_{j,s}^l = \sigma_s^l \sum_{j=-q}^q \alpha_{|j|}^l W_j^l \quad (6.14)$$

kann  $\mathbf{W}_t$  jede gewünschte Autokorrelationsfunktion im Sinne von Gleichung 6.13 für  $q+1$  Terme annähern (Koutsoyiannis, 2000). Hierbei ist  $\sigma_s^l$  die Varianz im Monat  $s$  und  $\alpha_j^l$  sind die SMA-Koeffizienten, die sich nach Koutsoyiannis (2000) aus der Autokorrelationsstruktur

des stochastischen Prozesses  $X_t^l$  mittels der inversen finiten Fourier-Transformation  $s_\alpha^l(\omega)$  von  $\rho_j^l$  ableiten lassen

$$\alpha_j^l = \int_0^{1/2} s_\alpha^l(\omega) \cos(2\pi j\omega) d\omega, \quad j = \{0, 1, \dots, q\}. \quad (6.15)$$

Wird  $H^l$  z.B. über das Verfahren nach Koutsoyiannis (2002) geschätzt, dann lassen sich die Koeffizienten  $\alpha_j^l$  wie folgt bestimmen:

$$\alpha_j^l = \frac{\sqrt{(2-2H_l)\gamma_o}}{3-2H_l} \left[ (j+1)^{H^l+0,5} + (j-1)^{H^l+0,5} - 2j^{H^l+0,5} \right], \quad j > 0, \quad (6.16)$$

hierbei ist  $\gamma_o$  die Varianz des aggregierten Prozesses  $Z_t^l$ .

### 6.2.2 Das multivariate HKNN-SMA-Zeitreihenmodell

Die beiden Methoden im Kern des nichtparametrische HKNN-Zeitreihenmodells nach Ashrafzadeh and Rizi (2009) sind künstliche neuronale Netze und k-Nearest-Neighbor-Sampling (Cover and Hart, 1967). Langousis and Koutsoyiannis (2006) nutzen ein parametrisches multivariates periodisches autoregressives Modell erster Ordnung, MPAR(1), um den stochastischen Prozess  $\mathbf{W}_t$  zu beschreiben und den SMA-Filter, um  $\mathbf{W}_t$  in den Prozess  $\mathbf{X}_t$  mit Langzeitpersistenz zu überführen. In dieser Arbeit soll das MPAR(1)-Modell durch das nichtparametrische HKNN-Zeitreihenmodell nach Ashrafzadeh and Rizi (2009) ersetzt werden. Zur Modellierung multivariater Zeitreihen ist das univariate HKNN-Modell daher multivariat zu erweitern.

Nach Ashrafzadeh and Rizi (2009) findet das HKNN-Modell seinen Ursprung in einem Ansatz nach Prairie et al. (2006), ersetzt jedoch die lokal gewichtete nichtlineare Regression im Kern des Ansatzes durch eine nichtlineare Regression auf Basis künstlicher neuronaler Netze (KNN). Als KNN selbst kommt ein Feed-Forward Multi-Layer-Perceptron (MLP) zum Einsatz. Ohne eine Einschränkung der Allgemeingültigkeit sei die Periode  $k$  des Prozesses 12 Saisons,  $s = 1, \dots, k$ . Der Prozess lasse sich zunächst ausreichend genau mit Lag-1 (einem zurückliegenden Monat) beschreiben.

Um den zyklisch-stationären Prozess  $\mathbf{X}_t$  abzubilden, kann für jeden Monat einer einzelnen Zeitreihe ein MLP aufgebaut und trainiert werden. Das Ziel ist es dabei, die Durchflüsse des aktuellen Monats aus den Durchflüssen des zurückliegenden Monats zu schätzen. Die Kreuzkorrelationen zwischen den Zeitreihen wird durch das k-Nearest-Neighbor-Sampling aufrecht erhalten. Es sind  $k \times v$  einzelne MLP aufzubauen und zu trainieren. Um jedoch ein möglichst einfaches Zeitreihenmodell zu implementieren, ist es ratsam, mehrere Standorte mit ähnlichen stochastischen Prozessen mit einem MLP zu simulieren. Die Anzahl an MLP kann dann entsprechend verringert werden.

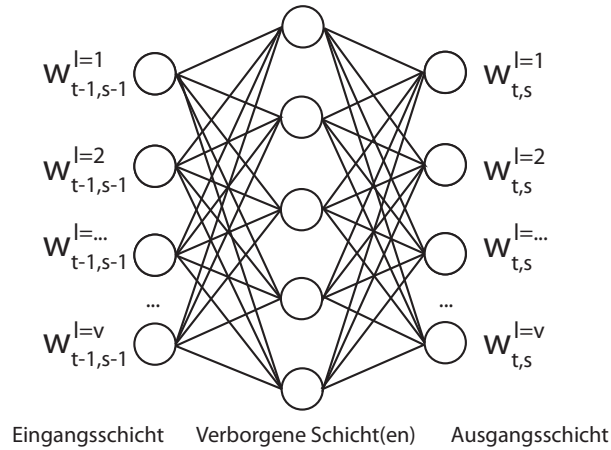


Abbildung 6.2: Schema eines künstlichen neuronalen Netzwerks. Das Netzwerk aus drei Schichten setzt sich aus der Eingangsschicht, einer oder mehreren verborgenen Schichten und einer Ausgangsschicht zusammen.

Im weiteren Verlauf soll der Einfachheit halber davon ausgegangen werden, dass alle  $v$  Zeitreihen mit einem Satz MLP simuliert werden können. Die Anzahl der Neuronen in der Eingangsschicht eines MLP gleicht der Anzahl  $v$  an Durchflusszeitreihen des stochastischen Prozesses  $\mathbf{W}_t$  (Abbildung 6.2).<sup>2</sup> Um eine Überanpassung des MLP während der Trainingsphase zu verhindern, wird der Bayesian Regulation Backpropagation Trainingsalgorithmus (Mackay, 1992) zum Anlernen verwendet. Die Anzahl der verborgenen Schicht(en) und die sich darin befindlichen Neuronen sind problemspezifisch und hängen vom zu modellierenden stochastischen Prozess ab.

Die einzelnen Schritte zur Simulation des stochastischen Prozesses  $\mathbf{W}_t$  ohne Langzeitpersistenz mit dem HKNN-Modell sind für  $t = 1, \dots, T$  Zeitschritte im Folgenden beschrieben. Zu beachten ist, dass neben der grundsätzlichen Vorlaufphase eines Zeitreihenmodells für den Vor- und Nachlauf des SMA-Filters zusätzliche  $q \times 3$  Zeitschritte zu simulieren sind. Diese Zeitschritte sind nach der Anwendung des SMA-Filters zu verwerfen. Der grundsätzliche Ablauf ist demnach für jeden Zeitschritt:

1. Der aktuelle Zeitschritt sei  $t$  mit der zugehörigen Saison  $s$ . Anhand der nichtlinearen Regression  $\text{KNN}_s$  auf Basis des künstlichen neuronalen Netzwerks

$$\tilde{\mathbf{w}}_t^l = \text{KNN}_s(\mathbf{w}_{t-1}^l) + \mathbf{e}_{t,s}, \forall l$$

<sup>2</sup>Ist für die Beschreibung eines stochastischen Prozesses für eine Saison mehr als der zurückliegende Monat erforderlich, müssen für diese ebenso Eingangsneuronen zur Verfügung stehen.

lässt sich ein mittlerer Merkmalsvektor  $\tilde{\mathbf{w}}_t^l = [\tilde{w}_t^{l=1}, \tilde{w}_t^{l=2}, \dots, \tilde{w}_t^{l=v}]$  aus dem Merkmalsvektor des zugehörigen vorherigen Zeitschritts  $\mathbf{w}_{t-1}^l = [w_{t-1}^{l=1}, w_{t-1}^{l=2}, \dots, w_{t-1}^{l=v}]$  für alle  $l = 1, \dots, v$  Zeitreihen berechnen.

2. Durch k-Nearest-Neighbor-Sampling ist aus den Beobachtungsdaten aller  $l \in \{1, \dots, L\}$  Zeitreihen ein zu  $\tilde{\mathbf{w}}_{t-1}^l$  ähnlicher Merkmalsvektor  $\tilde{\mathbf{x}}_{t-1}^l$  zu ermitteln. Der Ablauf dieses Schritts ist:

- a) Für den Zeitpunkt  $t - 1$  und die Saison  $s - 1$  ist eine Menge  $\mathbf{S}$  aus  $i = 1, \dots, n$  möglichen beobachteten Merkmalsvektoren  $\tilde{\mathbf{x}}_{t-1}^l, l = 1, \dots, v$  zu erstellen, deren zugehörige Saison  $s - 1$  ist.
- b) Für alle  $i = 1, \dots, n$  Merkmalsvektoren der Menge  $\mathbf{S}$  sind die euklidische Distanzen  $d_i$  in der zugehörigen Menge  $\mathbf{D}$  zu berechnen  $\mathbf{D} = \|\tilde{\mathbf{x}}_{t-1}^l - \tilde{\mathbf{w}}_{t-1}^l\|_2$ . Als nächstes sind die Merkmalsvektoren  $\tilde{\mathbf{x}}_{t-1}^l$  aus  $\mathbf{S}$  nach der jeweiligen euklidischen Distanz  $d_i$  zu ordnen, um somit einen zugehörigen Rang  $r$  zu erhalten.
- c) Auf Basis der diskreten Wahrscheinlichkeitsfunktion

$$c_r = \frac{1}{r} \left( \sum_{r=1}^m \frac{1}{r} \right)^{-1}, \quad m = n^{0,5}$$

wird die kumulative Wahrscheinlichkeitsfunktion  $p_r = \sum_{r=1}^m c_r$  ermittelt. Für eine, aus einer Gleichverteilung gezogene, Zufallszahl  $z \in \{0, \dots, 1\}$  kann dann ein Merkmalsvektor  $\tilde{\mathbf{x}}_{t-1}^l$  aus  $\mathbf{S}$  gezogen werden, für den  $z$  am nächsten bei  $p_r$  liegt.

3. Mittels des entsprechenden KNN und des Merkmalsvektors  $\tilde{\mathbf{x}}_{t-1}^l$  des vergangenen Monats wird nun der mittlere Merkmalsvektor  $\tilde{\mathbf{x}}_t^l$  für alle  $v$  multivariaten Zeitreihen geschätzt

$$\tilde{\mathbf{x}}_t^l = \text{KNN}_s(\tilde{\mathbf{x}}_{t-1}^l) + e_t, \quad \forall l.$$

Anschließend wird das Residuum  $\hat{e}_t$  aus der Differenz von  $\tilde{\mathbf{w}}_t^l$  (aus Schritt eins) und  $\tilde{\mathbf{x}}_t^l$  ermittelt. Das endgültige simulierte Zuflussmerkmal  $\mathbf{w}_t^l$  mit den Zuflüssen aller  $v$  Zeitreihen für den Zeitschritt  $t$  ergibt sich abschließend zu

$$\mathbf{w}_t^l = \tilde{\mathbf{w}}_t^l + \hat{e}_t, \quad \forall l.$$

Damit ist die Simulation für den Zeitschritt  $t$  abgeschlossen. Das Schema wird beginnend bei Schritt eins solange wiederholt, bis die gewünschte Zeitreihenlänge erreicht ist.

Um den SMA-Filter auf die mit dem HKNN-Modell simulierten Zeitreihen des stochastischen Prozess  $\mathbf{W}_t$  anzuwenden, wird zunächst jede Zeitreihe  $W_t^l$  auf monatlicher Basis



zentriert,  $\tilde{W}_{t,s}^l = W_{t,s=\hat{s}}^l - E[W_{t,s=\hat{s}}]$ ,  $\hat{s} = 1, \dots, 12$ . Die Notation  $W_{t,s=\hat{s}}$  soll hier bedeuten, dass nur Zuflüsse eines Zeitschritts  $t$  zählen, bei dem die gehörige Saison  $s$  einer bestimmten Saison  $\hat{s}$  entspricht. Auf die saisonbereinigte Zeitreihe kann mittels Gleichung 6.14 der SMA-Filter angewandt werden. Um  $\mathbf{X}_t$  mit Langzeitpersistenz zu erhalten, sind die Zuflüsse nach der Filterung wiederum mit  $X_{t,s}^l = \tilde{W}_{t,s}^l + E[W_{t,s=\hat{s}}]$ ,  $\hat{s} = 1, \dots, 12$  zu transformieren.

Vor allem nach der Filterung der Zeitreihen mit dem SMA-Filter entstehen vereinzelt negative Durchflüsse. Diese müssen in einem Nachbearbeitungsschritt korrigiert werden. Das einfachste Verfahren ist dabei, negative Zuflüsse mit einem Zuflusswert von null gleichzusetzen. Alternativ hierzu soll ein einfaches Verfahren vorgeschlagen werden, mit dem die negativen Zuflüsse anhand des  $p$ -Quantils der beobachteten Zuflüsse  $Q_p^l$  neu skaliert werden.

Zunächst wird geprüft, ob negative Zuflüsse in einer Zeitreihe vorliegen. Ist dies der Fall, werden die negativen Durchflüsse nach Gleichung 6.17 korrigiert.

$$\forall \{x_t^l < 0\} \in X^l, l : \frac{x_t^l - \min(X^l)}{0 - \min(X_t^l)} \times Q_p^l, \forall l = \{1, \dots, v\}, \forall t = \{1, \dots, T\} \quad (6.17)$$

Hierbei ist  $\min(X_t^l)$  das Minimum der simulierten Zeitreihe  $X_t^l$ . Als  $p$ -Quantil empfiehlt sich je nach Zeitreihe das 2,5 %- oder 5 %-Quantil.

### 6.3 Modul C: Verkürzen der Zeitreihen durch Monte-Carlo-Rekombination

Die mit SBO-Ansätzen optimierten Steuerungsstrategien sind nach Koutsoyiannis et al. (2002) unabhängig von der spezifischen Sequenz der Zuflüsse. Die Steuerungsstrategien hängen, wie bei ESO-Ansätzen, nur von den (hier impliziten) stochastischen Eigenschaften der Zuflüsse ab (Koutsoyiannis et al., 2002; Efstratiadis and Koutsoyiannis, 2010). Der entwickelte Ansatz der *Monte-Carlo-Rekombination* (MCR) nutzt diesen Umstand aus, um langjährige Zeitreihen signifikant zu verkürzen. Es werden *Proxyzeitreihen* generiert, die die impliziten stochastischen Eigenschaften der langjährigen Zeitreihen bewahren. Da die Rechenzeit von Talsperrenbewirtschaftungsmodellen linear mit der Länge des Simulationszeitraums ansteigt, ist der Zeitgewinn in der MKO durch die Reduktion der Zeitreihenlänge leicht abzuschätzen.

Der Ansatz der MCR geht prinzipiell von vier Grundannahmen aus. Die erste Annahme ist, dass der Folgescheitelalgorithmus (FSA) geeignet ist, um Trockenperioden in einer gegenüber der Problemstellung sinnvollen Weise zu identifizieren und zu separieren. Zweitens, das Defizitvolumen, dass jeder Trockenperiode über den FSA zugewiesen wird, ist

eine aussagekräftige Kenngröße, um die Trockenperiode zu charakterisieren. Drittens wird davon ausgegangen, dass die Verteilung der Defizitvolumina genutzt werden kann, um das hydrologische Regime in einer für die Speicherwirtschaft relevanten Art zu beschreiben wobei die impliziten stochastischen Eigenschaften der langjährigen Zeitreihe erhalten bleiben.

Eine Einschränkung der hier vorgestellten MCR ist, dass diese nur auf eine Zeitreihe angewandt werden kann. Aus mehreren (korrelierten) relevanten Zuflusszeitreihen ist daher eine einzige repräsentative Zeitreihe zu erstellen. Existieren mehrere zu berücksichtigende Abgaben, sind diese ebenso zusammenzufassen. Die vierte Annahme geht daher davon aus, dass mit diesen Vereinfachungen das wasserwirtschaftliche und hydrologische System in einer integrierten Weise beschrieben werden kann. Die MCR lässt sich somit auf eine einzelne repräsentative Zeitreihe anwenden und die so ermittelten Ergebnisse lassen sich anschließend auf die ursprünglichen Zuflusszeitreihen übertragen.

Datengrundlage für den MCR-Ansatz sind die langjährigen (multivariaten) Zeitreihen aus Modul B. Im Folgenden soll zunächst kurz der Folgescheitelalgorithmus erläutert werden, bevor der MCR-Ansatz vorgestellt wird.

### 6.3.1 Folgescheitelalgorithmus

Der Folgescheitelalgorithmus (FSA) ist ein Verfahren zur Abschätzung des benötigten kleinsten Speicherinhaltes  $\hat{V}_{\text{FSA}}$  eines Versorgungsspeichers gegenüber einer geforderten Abgabe (Sollabgabe). Der mit dem FSA ermittelte Speicher garantiert die vollständige Sollabgabe im betrachteten Zeitraum, jedoch wird der Speicher in der maximalen Trockenperiode einmal komplett entleert. Das errechnete Speichervolumen ist für die zugrundeliegende Zeitreihe gültig (Maniak, 2005). Abbildung 6.3 illustriert das Konzept des Folgescheitelalgorithmus. Die Sollabgabe sei mit  $c_{\text{crit}}$  gegeben und der Zufluss zur Zeit  $t = 1, \dots, T$  sei  $Q_t^{\text{in}}$ . Das Verfahren beruht auf der Analyse der sequentiell wechselnden lokalen Maxima und Minima der aufsummierten Nettozuflusslinie (Zuflusszeitreihe minus Sollabgabezeitreihe  $N_t = \sum_1^t (Q_t^{\text{in}} - c_{\text{crit}}), \forall t = 1, \dots, T$ ). Ein Differenzvolumen  $V_{\text{FSA}}$  errechnet sich jeweils aus der Differenz eines lokalen Maximums und des lokalen Minimums, das bis zum nächsthöheren Maximum zu finden ist. Das Defizitvolumen  $V_{\text{FSA}}$  stellt das benötigte Speichervolumen innerhalb des Zeitraums zwischen dem ersten Maximum und dem Minimum dar, der Zeitraum zweier aufeinander folgender Maxima stellt selbst eine Trockenperiode dar. Die Anzahl der so separierten Trockenperioden ist dann  $n_{\text{ha}}$ . Das erforderliche Speichervolumen  $\hat{V}_{\text{FSA}}$  für einen Versorgungsspeicher ist das Maximum aller ermittelten Speichervolumen  $V_{\text{FSA}}$ .




Abbildung 6.3: Schema des Folgescheitelalgorithmus.

### 6.3.2 Ablauf der Monte-Carlo-Rekombination

Im Folgenden soll der Ablauf der MCR-Methode beschrieben werden. Ein Ablaufschema ist zusätzlich in Abbildung 6.4 auf Seite 62 gegeben.

1. Sind mehrere lokale Zuflüsse für die Simulation der Talsperrenbewirtschaftung in Modul D relevant, kann es erforderlich sein, aus deren Zeitreihen eine Dummy-Zeitreihe zu erstellen. Dies ist der einfachen Form des FSA geschuldet, der nur eine Zeitreihe verarbeiten kann. Ein einfacher Ansatz stellt die Summation der monatlichen Zuflusswerte aller Zeitreihen vor. Liegen mehrere, jedoch konstante Abgaben vor, können diese zu einer Gesamtsollabgabe  $c_{\text{crit}}$  aufsummiert werden. Nicht konstante Abgaben lassen sich durch eine entsprechende monatliche Summation in eine Gesamtsollabgabe überführen (siehe z.B. Kapitel 8.4 und 9.4).
2. Zunächst erfolgt die Anwendung des Folgescheitelalgorithmus auf die langjährige (Dummy-) Zeitreihe mit einer festgelegten Sollabgabe  $c_{\text{crit}}$ . Das Ergebnis des FSA ist die Separation von Trockenperioden in einem Satz aus  $i = 1, \dots, n_{\text{ha}}$  zeitlich abfolgenden Defizitperioden mit den jeweils zugehörigen Defizitvolumina  $V_{\text{FSA},i}$ . Weiterhin besitzt jede Defizitperiode einen definierten Startzeitpunkt  $t$  und eine Periodenlänge  $L$ .
3. Die empirische kumulative Verteilungsfunktion (ECDF) der separierten  $V_{\text{FSA},i}$  ist gegeben durch

$$\hat{F}_{n_{\text{ha}}}(V_{\text{FSA}}) = \frac{1}{n_{\text{ha}}} \sum_{i=1}^{n_{\text{ha}}} 1 \{V_{\text{FSA},i} \leq V_{\text{FSA}}\}. \quad (6.18)$$

Aus dem Satz mit  $n_{\text{ha}}$  unterschiedlichen  $V_{\text{FSA},i}$  werden mittels einer Anzahl  $n_r < n_{\text{ha}}$  gleichverteilter Zufallszahlen  $z \subset [0, 1]$  zufällige Defizitvolumina  $V_{\text{FSA},i}$  gezogen, indem jeweils die  $V_{\text{FSA},i}$  ausgewählt wird, deren zugehörige Unterschreitungswahrscheinlichkeit  $\hat{F}_{n_{\text{ha}}}(V_{\text{FSA},i})$  am nächsten an dem jeweiligen  $z$  liegt. Die resultierende

Zeitreihenlänge steigt mit den Verhältnissen  $\frac{c_{\text{crit}}}{Q}$  und  $\frac{n_r}{n_{\text{ha}}}$  an und kann somit beeinflusst werden.

4. Es wird überprüft ob das größte Defizitvolumen  $\max(V_{\text{FSA},i})$  der Dummy-Zeitreihe im zufällig gezogenen Satz der Defizitvolumen enthalten ist. Ist dies nicht der Fall, wird diese gegen das kleinste Defizitvolumen ausgetauscht.
5. In diesem Schritt des Verfahrens wird aus den zufällig gezogenen Defizitvolumina  $V_{\text{FSA},j}$ , mit ihren zugehörigen definierten Startzeitpunkten  $t$  und den Periodenlängen  $L$ , eine gültige verkürzte (Dummy-) Zeitreihe aufgebaut. Dabei werden, beginnend mit einer zufällig ausgewählten Defizitperiode, jeweils neue Defizitperioden gezogen und an diese angefügt. Die anzufügende Defizitperiode muss dabei einen Startzeitpunkt  $t$  besitzen, dessen zugehöriger Monat auf den letzten Monat der aufzubauenden Zeitreihe folgt. Dieser Schritt wird solange wiederholt, bis keine zeitlich aufeinanderfolgenden Defizitperioden mehr vorhanden sind.

Anschließend ist die bisher aufgebaute (Dummy-) Zeitreihe bis zum letzten Monat des Wasserhaushaltsjahres zu verlängern. Alle restlichen, noch nicht angefügten Defizitperioden werden jeweils bis zum Anfang und Ende eines vollen Wasserhaushaltsjahres verlängert. Nach diesem Schritt lassen sich sukzessiv alle verbleibenden Defizitperioden ziehen und an das Ende der aufzubauenden Zeitreihe anhängen. Wird mit einer Dummy-Zeitreihe gearbeitet, ist die Abfolge der Defizitperioden mit deren zugehörigen Startzeitpunkten  $t$  und den Periodenlängen  $L$  für den späteren Aufbau der Proxyzeitreihen zu speichern.

6. Anhand der Abfolge der Defizitperioden, kann nun die verkürzte monatliche (Dummy-) Zeitreihe aus den monatlichen Zuflüssen der langjährigen (Dummy-) Zeitreihe, entsprechend der Startzeitpunkte  $t$  und den Periodenlängen  $L$ , aufgebaut werden.
7. Auf die im letzten Schritt aufgebaute Zeitreihe wird erneut der FSA angewandt und  $n_r$  unterschiedliche  $V_{\text{FSA},r}$  separiert. Für diesen Satz Defizitvolumina ist die ECDF zu konstruieren

$$\hat{F}_{n_r}(V_{\text{FSA}}) = \frac{1}{n_r} \sum_{r=1}^{n_r} 1 \{V_{\text{FSA},r} \leq V_{\text{FSA}}\}. \quad (6.19)$$

8. Im nächsten Schritt ist die Güte der durchgeführten Monte-Carlo-Rekombination zu bewerten. Wichtig ist es dabei vor allem, die Verteilung aller größeren  $V_{\text{FSA},i}$  mit hinreichender Güte abbilden zu können. Dies bedeutet, dass der Vergleich der beiden ECDF auf einen Bereich größer als ein festzulegender Schwellenwert der Unterschreitungswahrscheinlichkeit  $P_T$  beschränkt wird. Als Gütekriterium zur Beschreibung der Übereinstimmung wird der Pearson'sche Korrelationskoeffizient  $\rho$  gewählt, der zwischen  $\hat{F}_{n_{\text{ha}}}(V_{\text{FSA}})$  und  $\hat{F}_{n_r}(V_{\text{FSA}})$  oberhalb  $P_T$  berechnet wird. Eine hinreichend

lineare Korrelation der beiden beschnittenen ECDF liegt vor, wenn  $\rho$  größer oder gleich der geforderten Korrelationsgüte  $\rho_{\min}$  ist. Anderenfalls sind die Schritte 3 bis 4 solange zu wiederholen, bis  $\rho \geq \rho_{\min}$ .

Wurde eine Dummy-Zeitreihe generiert, wird mit Hilfe der, in Schritt 5 gespeicherten, Abfolge der Defizitperioden die Rekombination auf den Satz multivariater Zeitreihen übertragen, um äquivalente Proxyzeitreihen zu generieren.<sup>3</sup> Die korrekte zeitliche Abfolge der Zuflüsse sowie die Einhaltung der Kreuzkorrelationen ist somit für die Proxyzeitreihen gegeben.

In der abschließenden Kontrolle werden die wichtigsten monatlichen und jährlichen statistischen Kennwerte (Mittelwert, Varianz, Schiefe, Autokorrelation) überprüft. Weiterhin sollten die maßgebenden extremen Defizitperioden in den verkürzten Zeitreihen in Bezug auf das Defizitvolumen und die Periodendauer erhalten bleiben. Weiteren Aufschluss über einen ausreichenden Erhalt der impliziten Information in den Proxyzeitreihen und somit über die Güte der Rekombination gibt die Validierung der Pareto-Menge in Modul E.

## 6.4 Modul D: Simulationsbasierte multikriterielle Optimierung

In Modul D geschieht mit der Optimierung der Steuerungsstrategien von Mehrzweck-Talsperrenverbundsystemen die Hauptaufgabe des Frameworks. Die Arbeitsschritte dieses Moduls umfassen den Aufbau des Talsperrenbewirtschaftungsmodells unter Verwendung der Proxyzeitreihe, eine Implementierung der Schnittstelle zwischen dem Talsperrenbewirtschaftungsmodell und dem Optimierungsalgorithmus sowie die eigentlichen Optimierungsläufe. Wird in der MKO mit Archiv gearbeitet, ist nach der Optimierung die approximierte Pareto-Front zu ermitteln.<sup>4</sup>

Im weiteren Verlauf dieses Abschnitts erfolgt zunächst die Beschreibung der MO-CMA-ES als Erweiterung der einkriteriellen CMA-ES. Weiterhin wird auf die Parallelisierung und die Initialisierung der MO-CMA-ES eingegangen. Die Beschreibung einer Methode zur randbedingungs-freien Formulierung von Optimierungsproblemen, sowie die Einführung des ATM OASIS erfolgen im Anschluss.

### 6.4.1 Das MO-CMA-ES-Verfahren

Die einkriterielle *Covariance Matrix Adaption Evolutionary Strategy* (CMA-ES; Hansen 2006) ist nach Igel et al. (2007) eine der leistungsfähigsten evolutionären Algorithmen für reellwertige Optimierungen. Da die in dieser Arbeit angewandte *Multiobjective Covariance*

<sup>3</sup>Ohne Dummy-Zeitreihe entspricht natürlich die verkürzte Zeitreihe der Proxyzeitreihe.

<sup>4</sup>Wird mit Archiv gearbeitet, werden alle evaluierten Lösungen geloggt und nach der Optimierung ausgewertet. Ohne Archiv besteht die Pareto-Front aus den letzten ausgegebenen Nachfahren des multikriteriellen Optimierungsalgorithmus.




Abbildung 6.4: Ablaufschema der Monte-Carlo-Rekombinationsmethode. Durchgezogene Pfeile kennzeichnen die schrittweise Abfolge, gestrichelte Pfeile Datenflüsse.

*Matrix Adaption Evolutionary Strategy* (MO-CMA-ES; Igel et al. 2007) als multikriterielle Erweiterung der  $(\mu, \lambda)$ -CMA-ES<sup>5</sup> hervorgeht, soll zunächst ein Überblick über diese gegeben werden.

Als evolutionäre Strategie arbeitet die nicht-elitäre<sup>6</sup>  $(\mu, \lambda)$ -CMA-ES mit einer Population aus  $\mu$  Elternteile und  $\lambda$  Nachkommen. Alle  $k = 1, \dots, \lambda$  Nachfahren der Generation  $\cdot^{(g+1)}$  werden durch eine multivariate Normalverteilung  $\mathcal{N}$  mit einem Mittelwert von  $\mathbf{m}^{(g)}$ , einer Kovarianzmatrix  $\mathbf{C}^{(g)}$  und einer Standardabweichung  $\sigma^{(g)}$  (auch Schrittweite genannt) auf Basis von Informationen der Generation  $\cdot^{(g)}$  generiert

$$\mathbf{x}_k^{(g+1)} \sim \mathcal{N} \left( \mathbf{m}^{(g)}, (\sigma^{(g)})^2 \mathbf{C}^{(g)} \right), \forall k. \quad (6.20)$$

Die in den evolutionären Algorithmen gebräuchlichen Konzepte der Rekombination und Selektion finden in der CMA-ES Anwendung durch die Bildung eines gewichteten Mittelwerts der Normalverteilung aus  $\mu$  ausgesuchten Individuen

$$\mathbf{m}^{(g+1)} = \sum_{i=1}^{\mu} w_i \mathbf{x}_{i:\lambda}^{(g+1)}, \quad (6.21)$$

wobei gilt, dass

$$\sum_{i=1}^{\mu} w_i = 1, \quad w_i \geq 0 \forall i = 1, \dots, \mu \quad (6.22)$$

und  $\mu \leq \lambda$ .  $\mathbf{x}_{i:\lambda}^{(g+1)} \in \mathbb{R}^n$  ist das  $i$ -beste Individuum aus  $\{\mathbf{x}_1^{(g+1)}, \dots, \mathbf{x}_\lambda^{(g+1)}\}$  aus Gleichung 6.20 und  $f(\mathbf{x}_{i:\lambda}^{(g+1)}) \leq f(\mathbf{x}_{2:\lambda}^{(g+1)}) \leq \dots \leq f(\mathbf{x}_{\lambda:\lambda}^{(g+1)})$ . Der Kennwert  $\mu_{\text{eff}} = (\sum_{i=1}^{\mu} w_i^2)^{-1}$  gibt dabei an, wie die Gewichte  $w_i$  verteilt sind. Die gewichtete Kovarianzmatrix  $\mathbf{C}_\mu^{(g+1)}$  ist ein Schätzer der wahren, jedoch unbekanntenen Kovarianzmatrix  $\mathbf{C}^{(g)}$  wird mit

$$\mathbf{C}_\mu^{(g+1)} = \sum_{i=1}^{\mu} w_i (\mathbf{x}_{i:\lambda}^{(g)} - \mathbf{m}^{(g)}) (\mathbf{x}_{i:\lambda}^{(g)} - \mathbf{m}^{(g)})^T \quad (6.23)$$

auf Grundlage der zurückliegenden besten Individuen geschätzt. Um zu garantieren, dass  $\mathbf{C}_\mu^{(g+1)}$  für die neue Generation ein guter Schätzer der wahren Kovarianzmatrix ist, muss  $\mu_{\text{eff}}$  ausreichend groß sein. Eine geringe Populationsgröße, die eine geringe Rechenzeit

---

<sup>5</sup>Die Notation  $(\mu, \lambda)$  weist auf eine ES hin, bei der die Selektion ausschließlich auf den  $\lambda$  Nachkommen beruht. Die Elternteile werden grundsätzlich verworfen, auch wenn diese besser sind als die Nachkommen. Im Gegensatz hierzu weist die Notation  $(\mu + \lambda)$  darauf hin, dass die Elternteile nicht verworfen werden, wenn diese besser sind als die Nachkommen. Insgesamt erfolgt also eine Selektion aus dem Pool  $\mu + \lambda$  und die insgesamt  $\lambda$  schlechtesten Individuen entfallen (Beyer and Schwefel, 2002).

<sup>6</sup>Jedes Individuum wird in jeder neuen Population ersetzt.

ermöglicht, führt jedoch zu kleinen  $\mu_{\text{eff}}$  und somit zu Problemen bei der Aktualisierung der Kovarianzmatrix. Hansen (2006) nutzt daher die Konzepte des  $\mu$ -Rank Updates

$$f_{R,\mu} = c_{\text{cov}} \left(1 - \frac{1}{\mu_{\text{cov}}}\right) \times \sum_{i=1}^{\mu} w_i \left(\frac{\mathbf{x}_{i:\lambda}^{(g)} - \mathbf{m}^{(g)}}{\sigma^{(g)}}\right) \left(\frac{\mathbf{x}_{i:\lambda}^{(g)} - \mathbf{m}^{(g)}}{\sigma^{(g)}}\right)^{\text{T}} \quad (6.24)$$

mit dem Wichtungparameter des Rank-One-Updates  $\mu_{\text{cov}} \geq 1$ , und der Lernrate des Kovarianzmatrix-Updates  $c_{\text{cov}} \approx \min(\mu_{\text{cov}}, \mu_{\text{eff}}, n^2) / n^2$  als auch des Rank-One-Updates

$$f_{R,1} = \frac{c_{\text{cov}}}{\mu_{\text{cov}}} \mathbf{p}_c^{(g+1)} \mathbf{p}_c^{(g+1)\text{T}}, \quad (6.25)$$

um zusätzlich Informationen aus vergangenen Generationen bei der Aktualisierung der Kovarianzmatrix

$$\mathbf{C}_{\mu}^{(g+1)} = (1 - c_{\text{cov}}) \mathbf{C}^{(g)} + f_{R,1} + f_{R,\mu} \quad (6.26)$$

verwenden zu können.  $\mathbf{p}_c^{(g+1)}$  (Gleichung 6.25) bezeichnet dabei den evolutionären Pfad zur Generation  $\cdot^{(g+1)}$ . Dieser lässt sich aus dem evolutionären Pfad zur Generation  $\cdot^{(g)}$

$$\mathbf{p}_c^{(g+1)} = (1 - c_c) \mathbf{p}_c^{(g)} + \sqrt{c_c (2 - c_c) \mu_{\text{eff}}} \frac{\mathbf{m}^{(g+1)} - \mathbf{m}^{(g)}}{\sigma^{(g)}} \quad (6.27)$$

mit der Lernrate des Rank-One-Updates  $c_c \leq 1$  berechnen.<sup>7</sup> Zusätzlich wird die Schrittweitenkontrolle

$$\sigma^{(g+1)} = \sigma^{(g)} \exp \left( \frac{c_{\sigma}}{d_{\sigma}} \left( \frac{\|\mathbf{p}_{\sigma}^{(g+1)}\|}{\mathbb{E} \|\mathcal{N}(\mathbf{0}, \mathbf{I})\|} \right) \right) \quad (6.28)$$

benötigt, um negative Effekte von zu kleinen oder großen  $\mu_{\text{eff}}$  auf das Update des Algorithmus zu vermeiden, wobei  $c_{\sigma}$  die Lernrate der Schrittweitenkontrolle,  $d_{\sigma}$  ein Dämpfungsfaktor und  $\mathcal{N}(\mathbf{0}, \mathbf{I})$  eine multivariate Standardnormalverteilung (mit Einheits-Kovarianzmatrix und Mittelwert von null) ist. Hierbei berechnet sich  $\mathbf{p}_{\sigma}^{(g+1)}$  anhand des konjungierten Evolutionspfads  $\mathbf{p}_{\sigma}^{(g)}$  der vorherigen Population<sup>8</sup>

$$\mathbf{p}_{\sigma}^{(g+1)} = (1 - c_{\sigma}) \mathbf{p}_{\sigma}^{(g)} + \sqrt{c_{\sigma} (2 - c_{\sigma}) \mu_{\text{eff}}} \frac{\mathbf{m}^{(g+1)} - \mathbf{m}^{(g)}}{\sigma^{(g)}}.$$

Die  $(\mu, \lambda)$ -CMA-ES findet in dieser Arbeit zur Überprüfung der Pareto-Front durch einkriteriell berechnete Kontrolllösungen in Fallstudie 1 Verwendung.

Auf Grundlage der  $(\mu, \lambda)$ -CMA-ES entwickeln Igel et al. (2007) als Abwandlung der  $(\mu, \lambda)$ -CMA-ES die elitäre  $(1 + \lambda)$ -CMA-ES, bei der  $\lambda$  Nachfahren der Population  $\cdot^{(g+1)}$  aus dem besten Individuum  $\mathbf{x}_{\text{parent}}^{(g)}$  der Population  $\cdot^{(g)}$  erzeugt werden. Die Schrittweitenkontrolle

<sup>7</sup>Zum Beispiel ist der evolutionäre Pfad  $\mathbf{p}_c^{(g)}$  über zwei Generationen  $\frac{\mathbf{m}^{(g+1)} - \mathbf{m}^{(g)}}{\sigma^{(g)}} + \frac{\mathbf{m}^{(g)} - \mathbf{m}^{(g-1)}}{\sigma^{(g-1)}}$ .

<sup>8</sup>In der ersten Generation wird  $\mathbf{p}_{\sigma}^{(0)} = \mathbf{0}$  gesetzt.



der  $(\mu, \lambda)$ -CMA-ES wird mit der  $1/5$ -Erfolgsregel nach Rechenberg (1973) ersetzt. Als neues Elten-Individuum wird jeweils das Individuum mit der höchsten Fitness gewählt

$$\forall i \in \{1, \dots, \lambda\} : f(\mathbf{x}_{\text{parent}}^{(g+1)}) \leftarrow f(\mathbf{x}_i^{(g+1)}) \leq f(\mathbf{x}_{\text{parent}}^{(g)}).$$

Die MO-CMA-ES basiert auf einer Population aus  $\lambda_{\text{MO}}$  unabhängigen Individuen der  $(1 + \lambda)$ -CMA-ES.<sup>9</sup> Diese unterliegen durch nicht-dominierendes Sortieren<sup>10</sup> (Deb et al., 2002) multikriterieller Selektion. Der Hypervolumen-Indikator (Emmerich et al., 2005) als ein zweites Sortierkriterium erhält die Diversität im Zielfunktionsraum aufrecht.<sup>11</sup> Daher kann die MO-CMA-ES auch mit geringer Populationsgröße operieren, was für geringe Gesamtrechenzeiten spricht. Durch Selbstadaption der MO-CMA-ES, die diese von der  $(\mu, \lambda)$ -CMA-ES erbt, sind keine Parameter vom Anwender selbst für ein jeweiliges Optimierungsproblem anzupassen.

In der Literatur sind Studien, die die MO-CMA-ES einsetzen, bisher rar, jedoch über ein breites Anwendungsspektrum verteilt. Langouët et al. (2011) nutzen die MO-CMA-ES, um einen Verbrennungsmotor zu kalibrieren. Saliha (2012) nutzt diesen zur multikriterielle Optimierung der Steuerung eines Talsperrenverbundsystems in Äthiopien. Prada (2012) verwendet die MO-CMA-ES sowie zwei weiterentwickelte Versionen (Voß et al., 2009, 2010) des Algorithmus zur automatischen Parameterextraktion von Leistungselektronik. Shir et al. (2012) nutzen den MO-CMA-ES zur experimentellen multikriteriellen Quantenkontrolle.

#### 6.4.2 Parallelisierung der MO-CMA-ES

Der MO-CMA-ES Algorithmus ist in der frei verfügbaren Shark-Bibliothek<sup>12</sup> (Igel et al. 2008) enthalten. Die in dieser Arbeit entwickelte parallelisierte und simulationsbasierte MO-CMA-ES (psMO-CMA-ES) baut auf der Version 2.4.3 der Shark-Bibliothek auf.

Die Parallelisierung der Simulationsmodellaufrufe mittels openMP (OpenMP Architecture Review Board, 2002) bietet ein großes und einfach auszuschöpfendes Potenzial, um Rechenzeit einzusparen. Auf geeigneter handelsüblicher Hardware können mit dem psMO-CMA-ES bis zu 64 Simulationsmodellaufrufe gleichzeitig gestartet und berechnet werden. Somit kann die Rechenzeit einer MKO bis auf den Faktor 64 beschleunigt werden. Abbildung 6.5 gibt einen Überblick über den parallelisierten Simulationsmodellaufruf. Durch die Vervielfältigung des Simulationsmodells werden Zugriffskonflikte vermieden. Stehen der MKO  $i = 0, \dots, n_T$  Threads zur Verfügung, dann werden alle unter einem Thread zu evaluierenden Nachfahren  $\mathbf{x}_i^{(g+1)}$  nach dem Schema

<sup>9</sup>Igel et al. (2007) folgend wird in dieser Arbeit  $\lambda = 1$  gesetzt.

<sup>10</sup>Das nicht-dominierte Sortieren ist eine hierarchische Partitionierung (Ranking) einer Lösungsmenge in jeweils nicht-dominierte Mengen (Deb et al., 2002).

<sup>11</sup>Mit dem Hypervolumen-Indikator wird eine hohe Diversität im Sinne einer möglichst weit gefächerten und gleichmäßig verteilten Approximation der Pareto-Front sichergestellt.

<sup>12</sup>Homepage (Dez 2013): <http://sourceforge.net/projects/shark-project/>

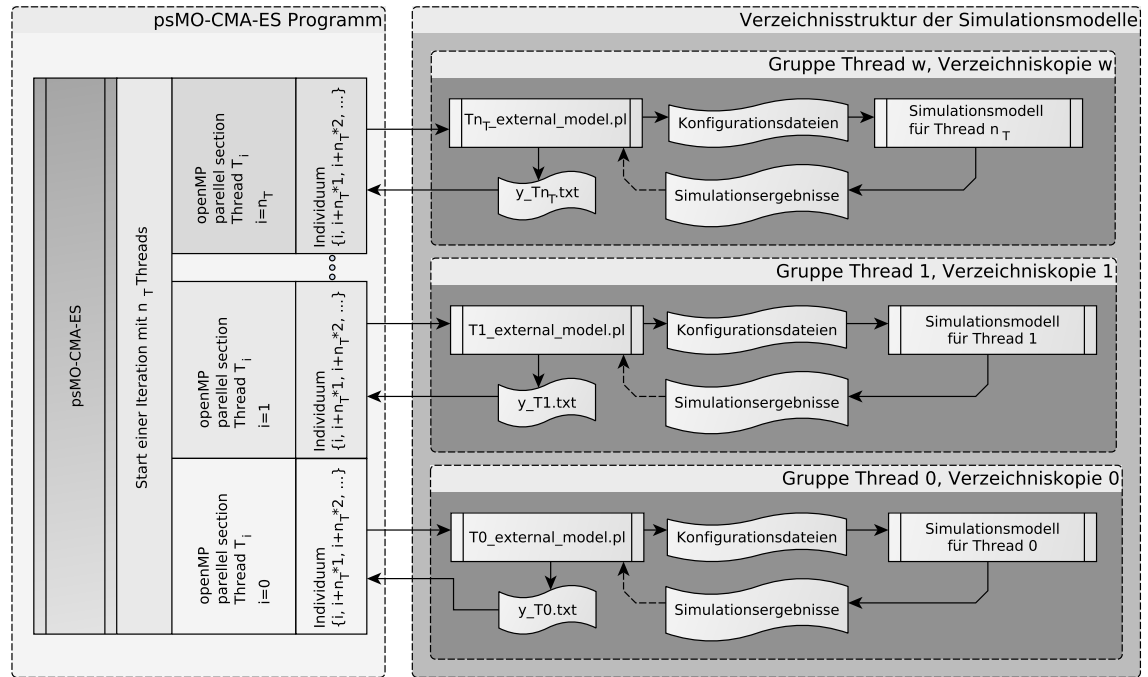


Abbildung 6.5: Simulationsmodellaufrufe durch die psMO-CMA-ES unter Verwendung mehrerer Threads.

$$T_i \leftarrow \mathbf{f}(\mathbf{x}_i^{(g+1)}), \forall i : \mathbf{i} = \{i, i + n_T \times 1, i + n_T \times 2, \dots, i + n_T \times n_E < \lambda\} \quad (6.29)$$

bestimmt, wobei jeder Thread  $n_E$  Modellevaluationen durchführt. Ist  $\lambda$  kein  $n_E$ -faches von  $n_T$ , können nach Gleichung 6.29 nicht alle Individuen verteilt werden. Die nicht erfassten  $(\lambda \bmod n_T)$  Individuen werden nachträglich sequenziell auf einem Thread evaluiert. Daher ist es ratsam, die Populationsgröße als ein Vielfaches der Thread-Anzahl zu wählen.

Die Kommunikation der psMO-CMA-ES mit dem Simulationsmodell findet über eine beliebige Schnittstelle, z.B. Perl (Wall et al., 2000), statt. Diese Schnittstelle konfiguriert das Simulationsmodell und wertet nach einem Simulationslauf die Ausgabedateien aus, um daraus die Zielfunktionen zu berechnen. Die Konfiguration der psMO-CMA-ES über eine Steuerdatei sowie vielfältige Einstellungsmöglichkeiten erleichtern die Handhabung.

### 6.4.3 Initialisierung der MO-CMA-ES

Mit einer guten Initialisierung der Startpopulation der EA kann diese in der Nähe der Pareto-optimalen Lösungen mit der Suche im Entscheidungsraum starten. In diesem Fall kann der Algorithmus schneller die wahre Pareto-Front approximieren. Lösungsmengen aus

bereits durchgeführten MKO lassen sich zur Initialisierung des Optimierungsalgorithmus für ähnliche Bewirtschaftungsoptimierungen verwenden.

Wurden in bereits durchgeführten MK-SBO die evaluierten Lösungen archiviert, besitzt die zur Verfügung stehenden Pareto-Mengen zumeist mehr Lösungen als die Startpopulation der neuen MKO Individuen aufweist. Daher wird zunächst der in Abschnitt 6.5 beschriebene Ansatz zur Auswahl von  $n_C = \mu$  Lösungen aus dieser Menge angewandt. Die mögliche Effizienzsteigerung in der MKO durch Initialisierung wird anhand von Benchmarks im Anhang B auf Seite 213 nachgewiesen.

#### 6.4.4 Randbedingungsfreie Optimierung von Staulamellenplänen

##### Box-Constraint-Handler

Ungleichheits-Randbedingungen  $g(\mathbf{x}) \geq 0$ , Gleichheits-Randbedingungen  $h(\mathbf{x}) = 0$  sowie die Sonderform der Box-Constraints

$$\mathbf{x}^{\min} \leq \mathbf{x} \leq \mathbf{x}^{\max}, \quad (6.30)$$

grenzen den möglichen Wertebereich des Entscheidungsraums mit Vektoren oberer und unterer Randbedingungen,  $\mathbf{x}^{\min}$  und  $\mathbf{x}^{\max}$ , ein.

Optimierungsalgorithmen besitzen oftmals keine expliziten Mechanismen, um zu erkennen, ob ein Entscheidungsvektor  $\mathbf{x} \in \mathbb{R}^n$  im zulässigen Raum  $\mathcal{X}$  liegt. Daher kann es im Verlauf der Optimierung zu Verletzungen der vorgegebenen Randbedingungen kommen. Um diese Fälle handhaben zu können und die Effektivität von Optimierungsalgorithmen unter Randbedingungen zu steigern, wird aktiv an sogenannten Constraint-Handling-Techniken (CHT) geforscht (Coello, 2002; Mezura-Montes and Coello Coello, 2008; Coello Coello, 2010; Kramer, 2010). Michalewicz (1995) gibt einen Überblick über unterschiedliche Funktionsklassen von CHT. Igel et al. (2007) schlagen in ihrer Arbeit eine CHT für Box-Constraints (BCHT) vor, der den ungültigen Entscheidungsvektor eines Individuums des MO-CMA-ES wie folgt repariert:

$$\text{gültig}(\mathbf{x}) \in \mathcal{X} : \min(\max(x_1, x_1^{\min}), x_1^{\max}), \dots, \min(\max(x_n, x_n^{\min}), x_n^{\max}). \quad (6.31)$$

Der nun gültige Entscheidungsvektor kann evaluiert werden. Um dem Optimierungsalgorithmus die Schwere des Verstoßes gegen den Box-Constraint mitzuteilen, werden alle Zielfunktionen mit einem Straffunktionsterm  $\nu_B(\mathbf{x})$  erweitert. Die erweiterte Zielfunktion

$$\mathbf{f}_{\text{pen}}(\mathbf{x}) = \mathbf{f}(\mathbf{x}) + \nu_B(\mathbf{x}) \quad (6.32)$$

gibt dem Optimierungsalgorithmus die Chance, den Box-Constraint „zu erlernen“, indem die Distanz der ungültigen Lösung zu  $\mathcal{X}$  in  $\nu_B(\mathbf{x})$  kodiert wird

$$\nu_B(\mathbf{x}) = \alpha_B \|\mathbf{x} - \text{gültig}(\mathbf{x})\|_2^2. \quad (6.33)$$

$\alpha_B$  ist dabei ein Straffaktor, der garantiert, dass  $\nu_B(\mathbf{x})$  zumindest eine Potenz kleiner ist als  $\mathbf{f}(\mathbf{x})$ . Der Standardwert von  $\alpha_B$  ist  $10^{-5}$ . Da die Straffunktion lediglich für das Lernverhalten des Optimierungsalgorithmus interessant ist, wird  $\nu_B(\mathbf{x})$  zwar in der Formulierung der Zielfunktionen mit genannt, in der Präsentation der Zielfunktionswerte wiederum *herausgerechnet*. Anderenfalls wären die Zielfunktionen bei Strafzuschlägen in einer Größenordnung der Zielfunktionswerte nicht mehr interpretierbar.

### Rule-Curve-Stacking

Die zu optimierenden Steuerungsstrategien beschränken sich in dieser Arbeit auf Staulamellenpläne (oder Dispatcherpläne) von wasserwirtschaftlichen Speichern. Die Schichtung der  $u = 1, \dots, w$  monatlich ( $s = 1, \dots, 12$ ) aufgelösten Staulamellen im Staukörper, beschrieben durch die Speicherkontrollvolumina der zugehörigen Regelkurven  $Z_s^{L,u}$ , zusammen mit den Beschränkungen durch das minimale und maximale Stauvolumen eines Speichers,  $Z_s^{L,\min}$  bzw.  $Z_s^{L,\max}$ , bedingen eine Ungleichheits-Randbedingung in der Form

$$Z_s^{L,\min} \leq Z_s^{L,1} \leq Z_s^{L,2} \leq \dots \leq Z_s^{L,u} \leq Z_s^{L,\max} \quad \forall s \in \{1, \dots, 12\}. \quad (6.34)$$

Hierbei sei  $L$  eine Talsperre von insgesamt  $G$  Talsperren eines Talsperrenverbundsystems. Die Schwierigkeit des Optimierungsproblems steigt mit der Anzahl  $w$  der zu optimierenden Lamellen in einer Talsperre durch die Komplexität der Randbedingung nach Gleichung 6.34.

Scola et al. (2010) schlagen eine Methode vor, die mittels einer Codierung der Entscheidungsvariablen die Verletzung der Ungleichheits-Randbedingung 6.34 ausschließt. Diese ist jedoch auf eine Regelkurve ( $w = 1$ ) begrenzt. Demnach ist  $Z_s^{L,u}$  nach

$$Z_s^{L,u} = Z_s^{L,\min} + x_s^{L,u} (Z_s^{L,\max} - Z_s^{L,\min}), \quad x_s \in \{0, \dots, 1\}, \quad \forall s \in \{1, \dots, 12\} \quad (6.35)$$

jeweils als Anteil  $x_s$  des zur Verfügung stehenden Stauinhalts zu berechnen. Das Optimierungsproblem reduziert sich dadurch auf ein Problem ohne Randbedingungen<sup>13</sup>. Anhand von Fallstudien zeigen die Autoren, dass durch den Einsatz dieser Methodik statistisch signifikant bessere Ergebnisse erreicht werden (Scola et al., 2010, 2011).

Um die Anwendung der Methode für beliebig viele Regelkurven zu ermöglichen, soll hier eine Verallgemeinerung der Methode, das Rule-Curve-Stacking (RCS), vorgeschlagen werden.

---

<sup>13</sup>Gemeint sind hier Randbedingungen, die explizit den Entscheidungsvektor betreffen.

**Algorithmus 6.1** Rule-Curve-Stacking

---

```

1: for  $L = 1 : G$  do                                ▷ Schleife über Talsperren
2:   for  $u = 1 : w$  do                                ▷ Schleife über Staulamellenobergrenzen
3:     if  $u == n$  then                                ▷  $n$ -te  $Z^{L,u}$  mit konstanten Werten
4:        $D_R = \min_{s \in \{1, \dots, 12\}} (Z_s^{L,u-1})$       ▷ Dummy Wert
5:       for  $s = 1 : 12$  do                            ▷ Schleife über Monate
6:          $Z_s^{L,u=0} = Z_s^{L,\max}$                     ▷ Dummy Werte
7:          $Z_s^{L,u} = Z_s^{L,\min} + x_s^{L,u} (D - Z_s^{L,\min})$ ,  $x \in \{0, \dots, 1\}$     ▷ Einordnen
8:       end for
9:     else
10:      for  $s = 1 : 12$  do                            ▷ Schleife über Monate
11:         $Z_s^{L,u=0} = Z_s^{L,\max}$                     ▷ Dummy Werte
12:         $Z_s^{L,u} = Z_s^{L,\min} + x_s^u (Z_s^{L,u-1} - Z_s^{L,\min})$ ,  $x \in \{0, \dots, 1\}$     ▷ Einordnen
13:      end for
14:    end if
15:  end for
16: end for

```

---

Die Einhaltung der Nebenbedingung  $\mathbf{x} \in \{0, \dots, 1\}$  wird zunächst durch die BCHT in der MO-CMA-ES erzwungen. Der Pseudo-Algorithmus 6.1 beschreibt den Ablauf des Rule-Curve-Stackings. Demnach werden, wie bei Scola et al. (2010), die Staulamellen als Unterraum eines jeweils größeren Stauvolumens betrachtet.<sup>14</sup> Der Entscheidungsraum  $\mathcal{X} \in \{0, \dots, 1\}$ , in dem der Optimierungsalgorithmus operiert, garantiert die allgemeine Gültigkeit des Ansatzes.

Sind mehr als drei Staulamellen Gegenstand der Optimierung, beginnt der Algorithmus mit der jeweils höchsten Staulamellenobergrenze, die zwischen der oberen Randbedingung und der unteren Randbedingung liegt. Danach werden sukzessiv die jeweils niedrigeren Staulamellenobergrenzen als Teilräume der höheren Staulamellen monatlich eingeordnet.

Weiterhin sei eine  $n$ -te Staulamellenobergrenze zu berücksichtigen, die in jedem Monat des Jahres das gleiche Stauvolumen aufweist. In diesem Fall wird zunächst das minimale Speicherkontrollvolumen der nächsthöheren Staulamellenobergrenze  $D_R = \min_{i \in \{1, \dots, 12\}} (Z_i^{L,u-1})$  bestimmt. Diese gilt dann als obere Randbedingung für die Berechnung der innerjährlich konstanten Staulamelle (Zeile 6). Auf die erhöhte Effektivität der MKO durch das RCS wird im Anhang B auf Seite 211 eingegangen.

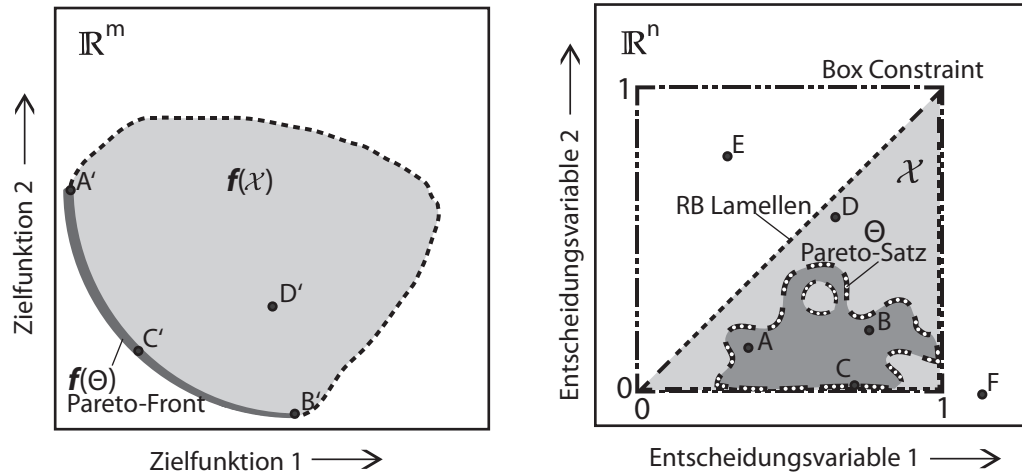
Abbildung 6.6 illustriert den Entscheidungsraum von zwei Entscheidungsvariablen und deren zugehörige Abbildung im Zielfunktionsraum. In Darstellung a) ist ein MKO-Problem mit Ungleichheits-Randbedingung (Gleichung 6.34) schematisiert. In Darstellung b) ist ein ähnliches MKO Problem schematisiert, bei dem durch das Rule-Curve-Stacking die

---

<sup>14</sup>Für Stauhöhen ist das Verfahren natürlich ebenso gültig.

Ungleichheits-Randbedingung entfällt. Der Entscheidungsraum wird in beiden Fällen zunächst durch einen Box-Constraint begrenzt. Im Fall einer Optimierung mit Ungleichheits-Randbedingung sind die Entscheidungsvektoren der Lösungen F und E ungültig. F verstößt gegen den Box-Constraint und E verstößt gegen die Ungleichheits-Randbedingung. Beide Lösungen können nicht evaluiert werden.

- a) Entscheidungsraum und Zielfunktionsraum für die MKO von Staulamellen mit Randbedingungen



- b) Entscheidungsraum und Zielfunktionsraum für die MKO von Staulamellen ohne Randbedingungen

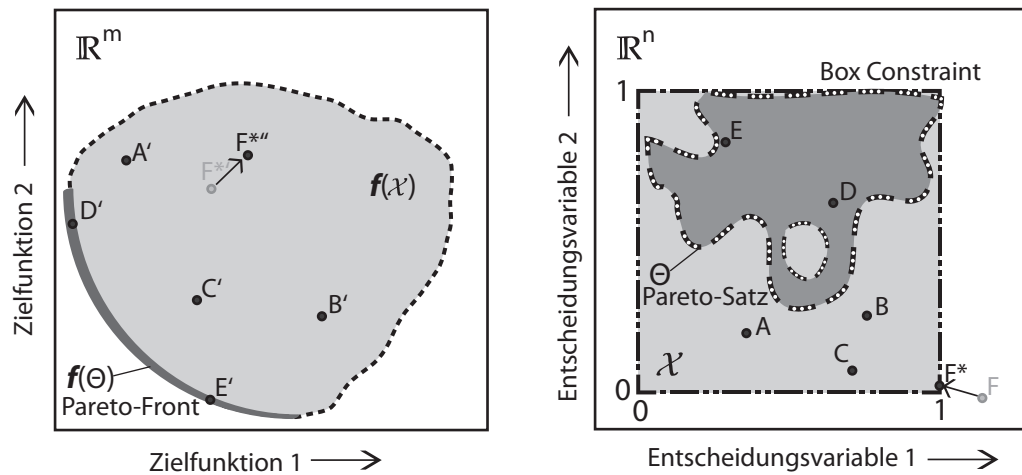


Abbildung 6.6: Schema eines Entscheidungsraums und Zielfunktionsraums mit Randbedingungen und ohne Randbedingungen.

Mit einer BCHT erfolgt eine Überführung des Entscheidungsvektors der Lösung F in  $\mathcal{X}$  zu  $F^*$ . Durch eine Straffunktion verschlechtert sich die Abbildung  $F^*$  im Zielfunktionsraum, es entsteht  $F^{*''}$ . Da die Ungleichheits-Randbedingung (Gleichung 6.34) durch das Rule-Curve-Stacking entfällt, besitzt jede Lösung innerhalb des Box-Constraints begrenzten Raums

grundsätzlich eine gültige Abbildung im Zielfunktionsraum. Das Optimierungsproblem zeichnet sich durch eine wesentlich geringere Komplexität aus.

### 6.4.5 Simulation der Talsperrenbewirtschaftung

Das von der Firma Hydrologics Inc. kommerziell vertriebene und weitverbreitete<sup>15</sup> adaptive Flussgebietsmanagements- und Talsperrenbewirtschaftungsmodell OASIS (Operational Analysis and Simulation of Integrated Systems; Hydrologics Inc., 2009) wird zur Simulation des Talsperrenbetriebs verwendet. Das zu untersuchende wasserwirtschaftliche System kann in OASIS einfach in einer GUI durch Knotenpunkte und Fließwege modelliert und mittels der eigenen Programmiersprache OCL beliebig erweitert werden. OASIS benötigt außerdem nur sehr geringe Rechenzeiten.<sup>16</sup>

Das Modell übersetzt das wasserwirtschaftliche System zur Simulation zunächst in ein Gleichungssystem. Ein gemischt-ganzzahliger linearer Programmierungs-Algorithmus löst das Gleichungssystem, indem eine Zielfunktion

$$\max \sum_{t=1}^T \sum_{(i,j) \in \mathbf{A}} c_{(i,j),t} \times x_{(i,j),t} \quad (6.36)$$

mit

$$\sum_{(i,j) \in \mathbf{A}} x_{(i,j),t} - \sum_{(i,j) \in \mathbf{A}} x_{(j,i),t} = b_{j,t}, \quad \forall j \in \mathbf{N} \quad (6.37)$$

$$x_{(i,j),t}^{\min} \leq x_{(i,j),t} \leq x_{(i,j),t}^{\max}, \quad \forall (i,j) \in \mathbf{A}. \quad (6.38)$$

maximiert wird, welche die optimale Verteilung des Wassers im System beschreibt (Tu et al., 2003).  $x_{(i,j),t}^{\min}$  und  $x_{(i,j),t}^{\max}$  sind dabei jeweils die unteren und oberen Randbedingungen der Flüsse  $x_{(i,j),t}$ ;  $\mathbf{N}$  ist die Menge Knoten,  $\mathbf{A}$  ist die Menge aller Fließwege im System und  $b_{j,t}$  ist ein Quellen- bzw. Senkenterm. Dabei wird das zur Verfügung stehende Wasser  $x_{(i,j),t}$  entlang der Fließwege mit den Indizes  $(i,j) \in \mathbf{A}$  an die Ziele bestimmter Knoten (mit den Indizes  $i$  und  $j$ ) verteilt. Ziele wie Wasserentnahmen, Mindestdurchflüsse oder Speicherziele werden entsprechend vorgegebener Bonuspunkte  $c_{(i,j),t}$  für jeden Zeitschritt  $t$  unter Einhaltung der Bedingungen in den Gleichungen 6.37 und 6.38 beliefert, um die gesammelten Bonuspunkte zu maximieren. Der Zustand des Systems am Ende eines Zeitschritts stellt jeweils die Initialisierung des Systems für den neuen Zeitschritt dar.

<sup>15</sup>Organisationen die OASIS nutzen, sind u.a. (Sheer, 2013): State of North Carolina, State of Tennessee, State of Kansas, Delaware River Basin Commission, Susquehanna River Basin Commission, Interstate Commission on the Potomac River Basin, New York City, South Florida Water Management District, City of Rocky Mount NC, Excelon Power, Dominion Power.

<sup>16</sup>In einem direkten Vergleich anhand der Fallstudie 1 zeigte sich z.B. eine um den Faktor 7 schnellere Simulation als mit MODSIM 8.1.

Die Verteilung des Wassers wird somit für den kurzfristigen Bewirtschaftungszeitraum (ein Zeitschritt) optimiert. Auf dieser Basis kann die mittel- und langfristige multikriterielle Optimierung der Talsperrenbewirtschaftung durch Steuerungsregeln mittels der MO-CMA-ES durchgeführt werden.

### 6.5 Modul E: Validierung der approximierten Pareto-Menge

Im Modul E werden zunächst Langfristsimulationen mit dem Talsperrenbewirtschaftungsmodell und den ungekürzten, langjährigen synthetischen Zeitreihen für die Kompromisslösungen der Pareto-Menge durchgeführt. Die Annahme, dass die Proxyzeitreihe aus Modul C (Abschnitt 6.3) die langjährigen synthetischen Zeitreihen adäquat beschreibt, kann somit überprüft werden. Ist dies der Fall, dann müssen die in der MKO ermittelten Lösungen in einer Langfristsimulation mit den langjährigen synthetischen Zeitreihen vergleichbare Zielfunktionswerte erbringen (sie sind dann übertragbar). Ein linearer Zusammenhang zwischen den Zielfunktionswerten der jeweiligen Zielfunktionen muss gegeben sein. Ist dies der Fall, werden für die Kompromisslösungen für alle weiteren Arbeitsschritte des Frameworks die Zielfunktionswerte aus der Validierung übernommen.

Bei schlechten Validierungsergebnissen ist davon auszugehen, dass die in der MKO approximierte Pareto-Front nicht die wirkliche Pareto-Front annähert, wie sie sich unter der langjährigen synthetischen Zeitreihe ergeben würde. In diesem Fall wären die Arbeitsschritte in diesem Framework noch einmal ab Modul C mit geänderten Annahmen zu wiederholen.

Eine Validierung sehr großer Pareto-Mengen  $\Theta^a$  einer Langfristsimulation, über die Länge der ungekürzten synthetischen Zeitreihe, kann wiederum sehr rechen- und zeitintensiv sein. Es empfiehlt sich daher, eine Reduktion der Anzahl der zu validierenden Lösungen.<sup>17</sup>

#### 6.5.1 Auswahl zu validierender Lösungen

Zur Auswahl weniger zu validierender Lösungen wird die Pareto-Front zunächst durch einen Clusterungsalgorithmus in wenige Cluster partitioniert. Hierfür werden in dieser Arbeit selbstorganisierende Merkmalskarten (SOM, Kohonen, 2001)<sup>18</sup> verwendet. Die Anzahl der Neuronen in der SOM ist dabei für die resultierende Anzahl der Cluster entscheidend und mindestens der Größe der gewünschten Clusteranzahl entsprechen, da aufgrund der Funktionsweise der SOM weniger Cluster als Neuronen erzielt werden können.

Die so gewonnenen  $c = 1, \dots, C$  Cluster unterteilen die Pareto-Menge anhand ihrer Projektion im Zielfunktionsraum in separate Lösungsmengen  $\Theta^c, \forall c \in \{1, \dots, C\} : \Theta^c \subset \Theta^a$ . Als Vorverarbeitungsschritt zur Clusterung wird  $\mathbf{f}^{\text{MKO}}(\Theta^a)$  mittels Gleichung 6.39

---

<sup>17</sup>Existiert ein sehr hoher linearer Zusammenhang zwischen  $f_j^{\text{MKO}}(\Theta^a)$  und  $f_j^{\text{Val}}(\Theta^a)$ , dann lassen sich die Zielfunktionswerte der nicht validierten Lösungen aus den Regressionsgleichungen 6.40 schätzen. In diesem Fall könnte dann die gesamte Pareto-Menge weiter übernommen werden.

<sup>18</sup>SOM Toolbox for MATLAB 5, Vesanto et al. (2000)



$$\bar{f}_j(\mathbf{x}) = \frac{f_j^{\text{MKO}}(\mathbf{x}) - \min_{\mathbf{x} \in \Theta^a} (f_j^{\text{MKO}}(\mathbf{x}))}{\max_{\mathbf{x} \in \Theta^a} (f_j^{\text{MKO}}(\mathbf{x})) - \min_{\mathbf{x} \in \Theta^a} (f_j^{\text{MKO}}(\mathbf{x}))}, \quad j = \{1, \dots, m\}. \quad (6.39)$$

normiert, so dass gilt  $\bar{\mathbf{f}}^{\text{MKO}}(\Theta^a) \in \{0, \dots, 1\}$ .

Für jedes der ermittelten  $c = 1, \dots, C$  Cluster wird anschließend eine repräsentative Lösung gewählt, bei der die euklidische Distanz des Zielfunktionsvektors zu allen anderen Zielfunktionsvektoren im Cluster  $c$  minimal ist (Reddy and Kumar, 2007b).

### 6.5.2 Validierung

Sind Lösungen übertragbar, dann existiert ein funktionaler Zusammenhang zwischen den in der Validierung ermittelten Zielfunktionswerten  $\mathbf{f}^{\text{VAL}}(\Theta^a)$  und den in der MKO ermittelten Zielfunktionswerten  $\mathbf{f}^{\text{MKO}}(\Theta^a)$ .<sup>19</sup> Der funktionale Zusammenhang lässt sich durch  $m$  lineare Regressionsfunktionen

$$f_j^{\text{VAL}}(\Theta^a) = \beta_j + \alpha_j \times f_j^{\text{MKO}}(\Theta^a) + e, \quad j = \{1, \dots, m\} \quad (6.40)$$

schätzen. Bei einer exakten Beschreibung des hydrologischen Regimes durch die Proxyzeitreihen ist die Steigung von  $\alpha_j$  idealerweise eins und der Offset  $\beta_j$  null. Eine Steigung  $\alpha_j \neq 1$  und ein Offset  $\beta_j \neq 0$  sind jedoch akzeptabel, solange eine ausreichende Güte des linearen Zusammenhangs gegeben ist. In diesem Fall ist eine Über- oder Unterschätzung der Zielfunktionswerte systematischer Natur und hat keinen Einfluss auf die Ordnung der Lösungen. Die Güte des linearen Zusammenhangs lässt sich durch die Pearson'schen Korrelationskoeffizienten

$$\rho_j = \frac{\text{Cov}(f_j^{\text{MKO}}(\Theta^a), f_j^{\text{VAL}}(\Theta^a))}{\sigma(f_j^{\text{MKO}}(\Theta^a)) \sigma(f_j^{\text{VAL}}(\Theta^a))}, \quad j = \{1, \dots, m\} \quad (6.41)$$

beschreiben. Als weiteres Kriterium zur Beurteilung der Validierung wird die Varianz  $\sigma_j^2$ , bzw. die Standardabweichung der Residuen  $e$  aus der linearen Regression zur Schätzung der linearen Funktionen (Gleichung 6.40) herangezogen. Die Varianz sollte möglichst gering sein. Bei Versorgungssicherheiten sollte die Standardabweichung idealerweise eine Potenz geringer sein, als die letzte maßgebende Stelle.

Sind die Validierungsergebnisse zufriedenstellend, werden für die validierten Kompromisslösungen die Zielfunktionswerte  $f_j^{\text{MKO}}(\Theta^a)$  aus der MKO durch die Zielfunktionswerte  $f_j^{\text{VAL}}(\Theta^a)$  aus der Validierung ersetzt. Als letzter Schritt in Modul E lassen sich, durch ein anschließendes nichtdominiertes Sortieren, Lösungen mit schlechter Übertragbarkeit entfernen. Zielkonflikte sind in der weiteren Auswertung der Pareto-Menge dann leichter

<sup>19</sup>Grundsätzlich ist auch ein Einbezug weiterer relevanter Kenngrößen möglich.

erkennbar. In den weiteren Schritten ersetzt die im Modul E veränderte Pareto-Menge (Verkleinerung der Pareto-Menge sowie der Übernahme der Werte  $\mathbf{f}^{\text{VAL}}(\Theta^a)$  als Projektion in den Zielfunktionsraum) die Pareto-Menge aus der MKO.

## 6.6 Modul F: Visualisierung und Entscheidungshilfe

In Modul F ermöglichen Level-Diagramme (Blasco et al., 2008) die Darstellung hochdimensionaler Datensätze. Die Wertung der Kompromisslösungen gibt dem Entscheidungsträger gleichzeitig Information über den Kompromiss, den jede Lösung bezüglich der konträren Ziele anbietet. Die Zusammenfassung der Kompromisslösungen in Kompromissklassen und die Bereitstellung von repräsentativen Lösungen, in Anlehnung an Zio and Bazzo (2011), reduziert den Umfang der Lösungsmenge und vereinfacht somit die Entscheidungsfindung.

Die Vorarbeiten zur Visualisierung der Ergebnisse aus Modul E mittels Level-Diagrammen erfordern zunächst eine Wertung der Kompromisslösungen (Abschnitt 6.6.1) sowie die Zusammenfassung von Kompromisslösungen in Kompromissklassen (Abschnitt 6.6.2). Für diese Kompromissklassen lassen sich wiederum repräsentative Kompromisslösungen bestimmen und schließlich zur Entscheidungshilfe, wie in Abschnitt 6.6.3 beschrieben, visualisieren.

### 6.6.1 Wertung der Kompromisslösungen

Die Wertung der Kompromisslösungen vermittelt dem Entscheidungsträger, inwieweit eine Kompromisslösung jedes einzelne Ziel favorisiert. Gleichzeitig nutzen Level-Diagramme die Wertung der einzelnen Kompromisslösung zur Darstellung von (hochdimensionalen) Datensätzen, wie Pareto-Fronten oder Entscheidungsvektoren.

Zunächst werden sowohl die  $j = 1, \dots, m$  einzelnen Zielfunktionen  $f_j(\mathbf{x}) \in \mathcal{X}$  als auch  $\Theta^a$  nach Gleichung 6.39 normiert, so dass  $\forall j : 0 \leq f_j(\mathbf{x}) \leq 1$  und  $0 \leq \Theta^a \leq 1$  gilt. Die Wertung einer Kompromisslösung basiert weiterhin auf einer Distanz  $D_p$  der Abbildungen  $\bar{\mathbf{f}}(\mathbf{x}) \in \mathcal{X}$  zum Utopia-Punkt  $y_j^a := \min_{\mathbf{x} \in \Theta^a} (\bar{f}_j(\mathbf{x}))$ ,  $\forall j \in \{1, \dots, m\}$ . Hierbei sind verschiedene p-Normen  $\|\bar{\mathbf{f}}(\mathbf{x})\|_p$  zur Beschreibung der Distanz  $D_p$  denkbar. Nach Blasco et al. (2008) eignen sich besonders folgende p-Normen, die jeweils eine Wertung der Kompromisslösung nach anderen Aspekten zulassen:

- die Manhattan-Norm, oder 1-Norm,  $D_1 = \|\mathbf{f}(\mathbf{x})\|_1 = \sum_{j=1}^m |\bar{f}_j(\mathbf{x})|$ ,  $D_1 \subseteq (0, m)$ . Diese Norm berücksichtigt alle Zielfunktionen gleichberechtigt. Dies ermöglicht die Ausgewogenheit des Kompromisses einer Lösung hinsichtlich aller Ziele zu analysieren.
- die euklidische Distanz, oder 2-Norm,  $D_2 = \|\mathbf{f}(\mathbf{x})\|_2 = \sqrt{\sum_{j=1}^m \bar{f}_j(\mathbf{x})^2}$ ,  $D_2 \subseteq (0, \sqrt{m})$ . Diese Norm liefert durch die gewohnte geometrische Distanz einen besseren Eindruck über die Form der Pareto-Front im kartesischen Raum.

- die Maximum-Norm, oder Inf-Norm,  $D_\infty = \|\mathbf{f}(\mathbf{x})\|_\infty = \max(\bar{f}_j(\mathbf{x}))$ ,  $D_\infty \subseteq (0, 1)$ . Diese Norm fokussiert den jeweils schlechtesten Zielfunktionswert einer Lösung. Eine Verschlechterung der Norm ist direkter Hinweis auf die Verschlechterung einer Lösung bezüglich einer Zielfunktion.

### 6.6.2 Bildung von Kompromissklassen und Wahl repräsentativer Lösungen

Kompromissklassen fassen Kompromisslösungen zusammen, die Ziele ähnlich favorisieren (Wertung) und sich darüber hinaus in weiteren festgelegten Kenngrößen ähnlich sein können. Wie auch in Kapitel 6.5 werden im Modul F selbstorganisierende Merkmalskarten zur Partitionierung der Pareto-Menge verwendet. Die Partitionierung bezieht sich jedoch nunmehr nicht alleine auf die mittels Gleichung 6.39 normierte Pareto-Front  $\bar{\mathbf{f}}(\Theta^a)$ , sondern auf einen Merkmalsvektor

$$\mathbf{r} = \left[ \Theta^a, \alpha_1 \left( \left[ \bar{\mathbf{f}}(\Theta^a), \bar{\mathbf{D}}_p \right] \right) \right]. \quad (6.42)$$

Dieser enthält, neben der normierten Pareto-Front  $\bar{\mathbf{f}}(\Theta^a)$ , die Menge der normierten Entscheidungsvariablen  $\Theta^a$  sowie den Satz  $\bar{\mathbf{D}}_p$  mit den Distanzen der Zielfunktionsvektoren  $\bar{\mathbf{f}}(\mathbf{x})$  für eine  $p$ -Norm

$$\bar{\mathbf{D}}_p = \frac{\mathbf{D}_p - \min(\mathbf{D}_p)}{\max(\mathbf{D}_p) - \min(\mathbf{D}_p)} \quad (6.43)$$

mit

$$\mathbf{D}_p = \left\| \bar{\mathbf{f}}(\mathbf{x}) \right\|_p, \quad \mathbf{x} \in \Theta^a \quad (6.44)$$

zum Utopia-Punkt  $y_j^a := \bar{f}_j(\mathbf{x}) = 0$ . Mit dem Parameter  $\alpha_1$  kann der Einfluss der Zielfunktionswerte und der Entscheidungsvariablen in der Partitionierung gegenüber  $\Theta^a$  gewichtet werden. Durch die entsprechende Wahl von  $\alpha_1$  kann eine hohe Ähnlichkeit der Steuerungsstrategien in den Kompromissklassen erzwungen werden. Als möglicher Standardwert wird hier  $\alpha_1 = \frac{n}{m+1}$  vorgeschlagen.

Lotov and Miettinen (2008) verweisen auf Miller (1956), der empfiehlt die Anzahl der Auswahlmöglichkeiten auf  $n_C = 7 \pm 2$  zu beschränken. Die richtige Balance, zwischen der Reduktion der Kompromisslösungen und einer ausreichenden gleichmäßigen Abdeckung der Diversität der Pareto-Menge mit repräsentativen Lösungen, ist jedoch problemabhängig. Durch die Partitionierung des Merkmalsvektors  $\mathbf{r}$  durch die SOM werden zunächst  $c = 1, \dots, n_C$  Cluster gesucht. Die Cluster stellen die Kompromissklassen dar. Aus den Kompromissklassen erfolgt im nächsten Schritt die Auswahl repräsentativer Lösungen. Für die Auswahl der repräsentativen Lösungen Cl- $c$  aus den Kompromissklassen  $c$  sind prinzipiell folgende Methoden anwendbar:

**Methode RLA** Die repräsentative Lösung Cl-c wird jeweils nach der geringsten Distanz  $D_p$  gewählt, Cl-c :  $\min \left( \left\| \bar{\mathbf{f}}(\mathbf{x}) \right\|_p \right)$ . Die repräsentativen Lösungen sind innerhalb jeder Kompromissklasse die nächsten am Utopia-Punkt. Besitzen die Kompromissklassen ähnliche minimale  $D_p$ , werden jedoch nur sehr ähnliche repräsentative Lösungen mit sehr ähnlichen Kompromissen ermittelt. Abhilfe kann je nach Problem ein hohes  $\alpha_1$  in Gleichung 6.42 bringen.

**Methode RLB** Die repräsentative Lösung Cl-c wird so gewählt, dass diese den mittleren euklidischen Abstand zu allen anderen Lösungen bezüglich der Pareto-Front erhält, Cl-c :  $\min_{\mathbf{x} \in \Theta^c} \left( \left\| \bar{\mathbf{f}}(\Theta_i^a \in c) - \bar{\mathbf{f}}(\Theta_j^a \in c) \right\|_p \right)$ ,  $\forall \{i = 1, \dots, p; j = 1, \dots, p\} : i \neq j$ . Die gewählten repräsentativen Lösungen verteilen sich dann in Abhängigkeit der räumlichen Lage der Kompromissklassen weiträumig über die approximierte Pareto-Front.

**Methode RLC** Als repräsentative Lösung Cl-c wird die Kompromisslösung mit dem geringsten mittleren euklidischen Abstand zu allen anderen Kompromisslösungen im Entscheidungsraum  $\Theta^c$  gewählt, Cl-c :  $\min_{\mathbf{x} \in \Theta^c} \left( \left\| \mathbf{x}_i - \mathbf{x}_j \right\|_p \right)$ ,  $\forall \{i = 1, \dots, p; j = 1, \dots, p\} : i \neq j$ . Methode RLC sollte in Verbindung mit einem geringen  $\alpha_1$  in Gleichung 6.42 durchgeführt werden.

Für eine weiterführende Methode zur Wertung der Kompromisslösungen unter Präferenz des Entscheidungsträgers soll auf Blasco et al. (2008) und Zio and Bazzo (2010) verwiesen werden.

### 6.6.3 Visualisierung durch Level-Diagramme

Abbildung 6.7 gibt ein einfaches Beispiel für die Anwendung eines Level-Diagramms. Die Visualisierung erfolgt hierbei getrennt für jede Zielfunktion

$f_j(\mathbf{x})$ ,  $j = \{1, \dots, m\}$ ,  $\mathbf{x} \in \Theta^a$  und Entscheidungsvariable  $x_i$ ,  $i = \{1, \dots, n\}$  in einer eigenen Tafel der Abbildung. Die Wertung einer Kompromisslösung durch  $D_p$  wird auf der Ordinate jeder Tafel abgetragen. Die Abszisse jeder Tafel entspricht für jede Lösung je nach Darstellung  $f_j(\mathbf{x})$  oder  $x_i$ . Nach dieser Methode befindet sich die grafische Repräsentation einer Kompromisslösung in allen Tafeln auf der gleichen Ordinatenhöhe. Somit ist für eine Lösung die gesamte Information über  $\mathbf{f}(\mathbf{x})$  und  $\mathbf{x}$  abrufbar, wenn für eine Lösung in allen Tafeln über die Ordinatenhöhe nivelliert wird. Da die Anzahl an Tafeln nicht beschränkt ist, können somit auch (beliebig) hochdimensionale Daten visualisiert werden. Ein offensichtlicher Nachteil der Level-Diagramme, ist der Verlust der Eineindeutigkeit der Visualisierung anhand der Wertung, wenn mehrere Lösungen durch ähnliche  $D_p$  auf fast gleicher Ordinatenhöhe liegen. Dies tritt vor allem bei der Darstellung großer Pareto-Mengen auf.

Die einzelnen Kompromissklassen nach Abschnitt 6.6 erhalten in Level-Diagrammen eine farbliche Kodierung. Zusätzlich wird in dieser Arbeit eine konkave Hülle um die Lösungen eines Clusters gezeichnet und das hieraus entstehende Polygon transparent farblich hinterlegt. Diese ermöglicht eine schnelle Differenzierung der Kompromissklassen und erhöht somit die Übersichtlichkeit. Die konkave Hülle wird mit dem *Alpha-Shape-Algorithmus* nach Edelsbrunner et al. (1983) ermittelt.

In beiden Fallstudien wird gezeigt, dass Level-Diagramme genutzt werden können, um zusätzliche Kenngrößen darzustellen, die nicht aus Zielfunktionen abgeleitet werden und nicht Bestandteil der Wertung sind. Weiterhin wird gezeigt, wie sich mit Hilfe von Level-Diagrammen leicht ein visueller Eindruck von Klimafolgen auf ein wasserwirtschaftliches System mit mehr als zwei konträren Zielen vermitteln lässt.

Die Entscheidungsvariablen in dieser Arbeit stellen ausschließlich zeitlich abhängige Speicherkontrollvolumina von Regelkurven dar. Eine äquivalente Darstellung der Entscheidungsvariablen über die jeweilige  $p$ -Norm (ähnlich Abbildung 6.7, b) bringt hier, auch wegen der hohen Dimensionalität und der innerjährlichen Abfolge der Entscheidungsvariablen, keine wesentlichen Vorteile. Daher wird von einer Darstellung der Entscheidungsvariablen in einem Level-Diagramm abgesehen. Stattdessen werden für eine Kompromissklasse die Regelkurven zur repräsentativen Lösung dargestellt. Um Informationen zu den Ausprägungen der Regelkurven aller weiteren Lösungen in der Kompromissklasse zu geben, wird die Spannbreite der monatlichen Kontrollspeichervolumina je Regelkurve als transparente Fläche hinterlegt.

Abbildung a) links: Plot der Pareto-Front des MKO-Problems, rechts: Plot der normierten Pareto-Front des MKO-Problems mit Iso-Linien der 1-Norm




Abbildung b) Level-Diagramm des MKO-Problems unter der 1-Norm, Tafeln 1-2 zeigen die Pareto-Front, Tafel 3 die Entscheidungsvariablen.




Abbildung 6.7: Darstellung eines MKO-Problems als 2D-Plot und als Level-Diagramm (entnommen aus Blasco et al., 2008). Die approximierte Pareto-Front eines MKO-Problems zeigt Abbildung a), links. Abbildung a), rechts, beinhaltet die Isolinien der 1-Norm. Punkt A ist der ausgeglichene Kompromiss. Anhand der Isolinien ist die Wertung im Level-Diagramm, Abbildung b), nachvollziehbar, die als Ordinatenwert abgetragen ist.

## 7 Fazit zum Teil II

Die vorgestellte Strategie Frams-BoT ermöglicht eine effiziente simulationsbasierte multikriterielle Optimierung von Steuerungsstrategien für Mehrzweck-Talsperrenverbundsysteme. Das Framework stellt dem Anwender für die einzelnen durchzuführenden Arbeitsschritte Methoden auf dem Stand der Technik zur Verfügung und führt für die unterschiedlichen Arbeitsschritte teilweise neue oder weiterentwickelte Methoden ein.

Eine Reduktion der Rechenzeiten unter Langfristsimulationen wird in Frams-BoT durch mehrere Ansätze erreicht: (1) Die *Parallelisierung* der eingesetzten evolutionären Strategie MO-CMA-ES (Igel et al., 2007) schöpft die Leistung heutiger handelsüblicher Hardware aus. (2) Die Verkürzung der Laufzeit der Langfristsimulationen zur Talsperrenbewirtschaftung reduziert die Rechenzeit proportional. Die neuentwickelte *Monte-Carlo-Rekombination* ermöglicht die MK-SBO anhand erheblich kürzerer Proxyzeitreihen, die einen vergleichbaren Gehalt an relevanter Information über den stochastischen Prozess wie die zuvor synthetisch erzeugten Zeitreihen über mehrere Tausend Jahre aufweisen. (3) Eine erweiterte *Kodierung der Entscheidungsvariablen* nach Scola et al. (2010) überführt die Optimierung von Regelkurven in ein randbedingungsfreies Optimierungsproblem. (4) Eine *Initialisierung der Startpopulation* der MO-CMA-ES kann schneller zu besseren Ergebnissen führen. Für die Punkte (3) und (4) konnten die Verbesserungen in der MK-SBO anhand von Benchmarks als signifikant eingestuft werden.

Zuflussdargebote unter veränderten klimatischen Rahmenbedingungen sind durch das Wasserhaushaltsmodell *WaSiM-ETH* modellierbar. Die multikriterielle Optimierung wird für eine objektive und robuste Kalibrierung des Modells verwendet (Vrugt et al., 2003). Als multikriterieller Optimierungsalgorithmus kann die in Frams-BoT implementierte MO-CMA-ES angewandt werden.

Ein *nichtparametrisches multivariates Zeitreihenmodell* wurde vorgestellt, um synthetische monatliche Zeitreihen mit Längen von mehreren Tausend Jahre einfach zu generieren. Insbesondere lassen sich hiermit Autokorrelationen auf einer jährlichen Zeitskala auch auf höheren Lags modellieren.

*Level-Diagramme* bieten Entscheidungshilfen auf mehreren Ebenen. Neben der reinen Wertung der Kompromisslösungen lassen sich diese in Kompromissklassen zusammenfassen. Die Auswahl von repräsentativen Lösungen reduziert den Umfang der Kompromisslösungen und vereinfacht das Entscheidungsproblem. Weiterhin bieten Level-Diagramme die Möglichkeit, hochdimensionale Datensätze darzustellen.





## **Teil III**

### **Fallstudien**



## 8 Fallstudie 1: Mehrzweck-Talsperrenverbundsystem im Erzgebirge

Die Arbeiten in der Fallstudie 1 entstanden im Rahmen des vom Bundesministerium für Bildung und Forschung (BMBF) finanzierten Verbundvorhabens „Regionale Klimaanpassung in der Modellregion Dresden“ (REGKLAM). REGKLAM selbst ist eines der sieben Fördermaßnahmen des BMBF-Großprojekts „KLIMZUG – Klimawandel in Regionen zukunftsfähig gestalten“. KLIMZUG unterstützt Regionen in Deutschland dabei, regionalspezifische Maßnahmen zur Anpassung an den Klimawandel zu entwickeln und umzusetzen.

Gegenstand der Studien ist das Mehrzweck-Talsperrenverbundsystem mit den Talsperren Klingenberg (KL), Lehmühle (LM) und Rauschenbach (RB) im sächsischen Osterzgebirge (Abbildung 8.1). Insgesamt werden zwei Themenkomplexe bearbeitet. Der erste Themenkomplex befasst sich mit der multikriteriellen Bewertung der Speicherleistung unter rezenten Bedingungen und für planungstechnische Änderungen am Talsperrenverbundsystem. Der zweite Themenkomplex sieht die multikriterielle Bewertung der Speicherleistung unter projizierten klimatischen Rahmenbedingungen vor (Klimafolgenanalyse). Gleichzeitig erfolgt eine Bereitstellung von praxisnahen Adaptionsstrategien für die jeweiligen klimatischen Rahmenbedingungen. Hierzu werden zunächst die Zuflussdargebote für die betrachteten Klimaszenarien durch Simulationen mit einem Wasserhaushaltsmodell ermittelt. Aus Gründen der schlechten Datenverfügbarkeit geschieht dies ausschließlich für die Einzugsgebiete der Talsperren KL und LM.<sup>1</sup> Die Ermittlung der Zuflussdargebote der Talsperre Rauschenbach erfolgt anschließend durch Regressionsrechnungen.

In beiden Themenkomplexen erfolgt die multikriterielle simulationsbasierte Optimierung mit Langfristsimulationen in monatlichen Zeitschritten, über 10 000 Jahre. Die Ziele der MKO sehen eine Maximierung von drei Versorgungssicherheiten, eines Wassergüteindikators sowie die Minimierung der Stützleistung durch die Talsperre RB vor. Die Implementierung aller relevanten und komplexen Bewirtschaftungsstrategien des Systems ins Talsperrenbewirtschaftungsmodell ermöglicht praxisnahe Ergebnisse.

Die Gliederung des Kapitels 8 sieht zunächst die Beschreibung des Mehrzweck-Talsperrenverbundsystems und der zugehörigen Talsperreneinzugsgebiete vor. Danach werden das

---

<sup>1</sup>Die oberstromig gelegene Talsperre Flaje (Tschechien) beeinflusst 43 km<sup>2</sup> des rund 70 km<sup>2</sup> großen Einzugsgebietes der Talsperre Rauschenbach. Für die tschechischen Gebiete und die Talsperre Flaje lagen jedoch kaum Daten vor.




Abbildung 8.1: Topografische Übersichtskarte zum Talsperrenverbundsystem der Talsperren Klingenberg, Lehnmühle und Rauschenbach im Osterzgebirge. Die Überleitungsstrecke von der Talsperre Rauschenbach, die zum Teil die Revierwasserlaufanstalt (RWA) nutzt, ist als doppelt gestrichelte Linie dargestellt.

Vorgehen und die Ergebnisse zur Klimafolgenanalyse aus Modul A vorgestellt. Ebenso sollen für die beiden Themenkomplexe die Ergebnisse der Module B und C für alle durchgeführten Optimierungsläufe gemeinsam diskutiert werden. Die Ergebnisdarstellung in Modul B bezieht sich, aus Gründen des Umfangs, auf den Reanalysezeitraum (Jahre 1961-1990) des regionalen Klimamodells WETTREG 2010. Die Vorstellung der Vorgehensweisen und Ergebnisse der Optimierungsläufe für die Themenkomplexe erfolgt abschließend getrennt anhand der Module E bis F.

## 8.1 Beschreibung des Talsperrenverbundsystems

### 8.1.1 Die Einzugsgebiete der Talsperren

Das Einzugsgebiet der Wilden Weißeritz liegt südwestlich der Stadt Dresden, in Sachsen, Deutschland. Es erstreckt sich von 191 m.ü.NN am Pegel Hainsberg 3 im nördlichen Teil bis in die oberen Kammlagen des tschechischen Osterzgebirges im südlichen Teil auf ca. 909 m.ü.NN (Abbildung C.1, links). Die Gesamtfläche beträgt in etwa 162 km<sup>2</sup>, davon be-

finden sich ca. 12 km<sup>2</sup> auf tschechischem Staatsgebiet. Die durchgeführten Untersuchungen beschränken sich auf das Einzugsgebiet der Wilden Weißeritz bis zum Auslasspegel der Talsperre KL (Pegel Klingenberg) auf 366 m.ü.NN, welches nunmehr eine Fläche von ca. 90 km<sup>2</sup> umfasst.

Die Hauptlandnutzungsformen, die in der Summe etwa 90 % der Gebietsbedeckung zu etwa gleichen Teilen beanspruchen, sind Acker-, Grünland- und Waldflächen. Die Verteilung der Landnutzung im Gebiet ist relief- und klimabedingt. Flächen oberhalb 700 m.ü.NN sind überwiegend bewaldet, landwirtschaftlich genutzte Flächen nehmen in den unteren Lagen des Einzugsgebietes zu (Abbildung C.1, rechts).

Charakteristisch für die Geologie des Untersuchungsgebiets sind vor allem Metamorphite, dabei überwiegend Gneise (60 %), aber auch Phyllite und Glimmerschiefer (Abbildung C.2, links). Die Böden sind deutlich differenziert, so treten Podsole vermehrt in den Hoch- und Kammlagen auf, während Braunerden in den mittleren und unteren Lagen vermehrt anzutreffen sind (Abbildung C.2, rechts).

Das südwestlicher gelegene Einzugsgebiet der Talsperre Rauschenbach erstreckt sich zwischen 700 m.ü.NN und 800 m.ü.NN. Die Hauptlandnutzungsformen sind Nadelwald (75 %) und Grünland (24 %). Es dominieren die Bodenarten Braunerde, Podsol sowie Torfmoor.

Das Klima der beiden Einzugsgebiete entspricht der gemäßigten Klimazone und ist kontinental beeinflusst. Oberhalb von 650 m.ü.NN herrscht kühles Gebirgsklima bei einer Jahresdurchschnittstemperatur von 4,0 bis 5,5 °C und 950 bis 1 050 mm Jahresniederschlag vor. In tieferen Lagen ist ein gemäßigtes Gebirgsklima bei einer Jahresdurchschnittstemperatur von 6,1 bis 7,7 °C und 730 bis 1 000 mm Jahresniederschlag anzutreffen.

### 8.1.2 Das Mehrzweck-Talsperrenverbundsystem

#### Allgemeine Beschreibung

Die Talsperren Klingenberg, Lehmühle und Rauschenbach werden vom Talsperrenbetreiber, der Landestalsperrenverwaltung des Freistaates Sachsen (LTV), als Mehrzweck-Talsperrenverbundsystem bewirtschaftet. Die Talsperren KL und LM stauen das Fließgewässer der Wilden Weißeritz im Vorland des Osterzgebirges auf. Die Wilde Weißeritz entspringt auf der tschechischen Seite des Osterzgebirgskamms auf 823 m.ü.NN. Die Vereinigung mit der Roten Weißeritz zur Vereinigten Weißeritz erfolgt unterhalb der Talsperren KL und LM in Freital-Hainsberg. Der aufgestaute Hauptzufluss der Talsperre RB ist die Flöha, welche nur ca. 800 m von der Quelle der Wilden Weißeritz entfernt entspringt. Auf tschechischer Seite staut zunächst die Talsperre Flaje die Flöha auf.

Die wasserwirtschaftlichen Hauptnutzungen des Mehrzweck-Talsperrenverbundsystems umfassen, neben einer geringfügigen Wasserkraftproduktion und Naherholungszwecken, den Hochwasserschutz und die Bereitstellung von Rohwasser zur Trinkwasserversorgung.

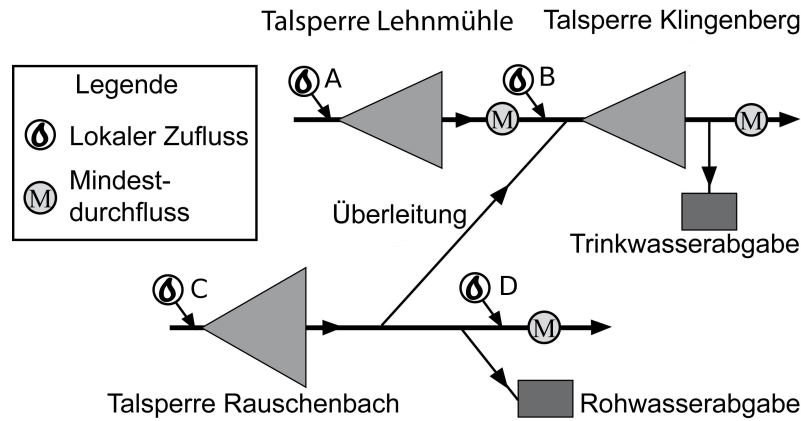


Abbildung 8.2: Schematischer Überblick über die Topographie des Talsperrenverbundsystems, allen lokalen Zuflüssen und wichtiger Bewirtschaftungsziele.

Hochwasserschutzziele der Talsperren Klingenberg und Lehmühle sind unter anderem die Städte Tharandt, Freital und Dresden. Die Talsperre Rauschenbach schützt nach Winkler (2009) den Erholungsort Neuhausen und die Stadt Olbernhau. Rohwasser zur Trinkwasserversorgung wird durch die Talsperre KL bereitgestellt und dient zur Versorgung der Städte Freital, Dresden und von Teilen des Landkreises Sächsische Schweiz-Osterzgebirge.

In der Verbundbewirtschaftung erfolgt eine Stützung der Talsperre Klingenberg durch die oberstromig gelegene Talsperre LM und die abseits gelegene Talsperre RB. Das Rohwasser der Talsperre RB gelangt durch eine Überleitung mit der Streckenführung über die historische Revierwasserlaufanstalt (RWA), den Oberen Großhartmannsdorfer Teich, die Talsperre Lichtenberg und den Lattenbach zur Talsperre KL. (Abbildung 8.1) Dabei muss das Wasser ab der Talsperre Lichtenberg wegen der Höhenunterschiede im Streckenverlauf gepumpt werden, wobei nicht unerhebliche Kosten für den Betrieb der Überleitung entstehen (Winkler, 2009).

Auskunft über wichtige Kennwerte der Talsperren gibt Tabelle C.1. Für weitergehende Informationen über die Talsperren wird der interessierte Leser auf das Werk von Sieber (1992) verwiesen.

### Zuflüsse im Talsperrenbewirtschaftungsmodell

Die in Modul A modellierten Abflussspenden (Abbildung 8.5) werden für die Umsetzung des Talsperrenverbundsystems im ATM in vier lokale Zuflüsse A, B, C und D umgerechnet. Die Lage der lokalen Zuflüsse im Modell ist in Abbildung 8.2 einzusehen. Hiernach werden die Abflussspenden der Modellgebiete A und B für den lokalen Zufluss A aufsummiert. Der lokale Zufluss B umfasst die Abflussspenden des Modellgebietes C. Der lokale Zufluss C als Gesamtzufluss der Talsperre Rauschenbach, sowie der lokale Zufluss D werden jeweils durch Regressionsrechnungen ermittelt (Abschnitt 8.3.1).

Tabelle 8.1: Geforderte Abgaberaten  $Q^{\text{BSS}\{1,\dots,3\}}$  und zugehörige Versorgungssicherheiten  $R(\text{BSS})$ .

Bereitstellungsstufe	Abgaberate $Q^{\text{BSS}\{1,\dots,3\}}$ ( $\text{m}^3\text{s}^{-1}$ )	geforderte Versorgungssicherheit $R(\text{BSS})$ (%)
BSS3	1,000	99,00
BSS2	0,925	99,50
BSS1	0,850	99,95

### Die Bewirtschaftung des Talsperrenverbundsystems

Die Implementierung aller relevanten Bewirtschaftungsregeln ist eine Voraussetzung, um eine praxisnahe Simulation der Bewirtschaftung unter den gegebenen Steuerungsstrategien zu ermöglichen. Als primäre Steuerungsstrategien des Talsperrenverbundsystems sind jene definiert, die der Optimierung unterliegen. Diese regeln zum einen die Bereitstellung des Trinkwassers aus der Talsperre Klingenberg und zum anderen die Überleitung von Wasser aus der Talsperre Rauschenbach. Sekundäre Steuerungsstrategien sind wichtige Bewirtschaftungsregeln, die lediglich im Simulationsmodell implementiert sind.

**Primäre Steuerungsstrategien** Die Abgabe von Rohwasser zur Trinkwassergewinnung erfolgt gestaffelt anhand eines Dispatcherplans mit drei Bereitstellungsstufen, BSS1, BSS2 und BSS3, in festgelegten Abgaberaten  $Q^{\text{BSS}}$ . Jede Abgaberate ist nach Tabelle 8.1 mit einer *geforderten Versorgungssicherheit*  $R(\text{BSS1})$ ,  $R(\text{BSS2})$  und  $R(\text{BSS3})$ , definiert als

$$R(\text{BSS}\{1, \dots, 3\}) = \Pr \left[ S^{\text{KL}+\text{LM}} \geq Z^{\text{KL},\{1,\dots,3\}} \right] = \Pr \left[ Q^{\text{del}} \geq Q^{\text{BSS}\{1,\dots,3\}} \right], \quad (8.1)$$

zu garantieren. Die zugehörigen, während der Bewirtschaftung über einen Zeitraum *erreichten Versorgungssicherheiten*  $P(\text{BSS1})$ ,  $P(\text{BSS2})$  und  $P(\text{BSS3})$  sind entsprechend Gleichung 8.1 analog definiert. Anhand von zwei monatlich definierten Kontrollspeichervolumina  $Z_s^{\text{KL},1}$  und  $Z_s^{\text{KL},2}$  werden über zwei Regelkurven  $Z^{\text{KL},1}$  und  $Z^{\text{KL},2}$  die Bereitstellungsstufen innerhalb des *Gesambewirtschaftungsraums*  $Z^{\text{KL}+\text{LM},\text{Bew}}$  festgelegt.  $Z^{\text{KL}+\text{LM},\text{Bew}}$  bezieht sich dabei auf die Summe der Bewirtschaftungsräume der beiden Talsperren Klingenberg  $Z^{\text{KL},\text{Bew}}$  und Lehmühle  $Z^{\text{LM},\text{Bew}}$ . Die zu realisierende Abgaberate an Brauch- und Trinkwasser  $Q^{\text{BSS}}$  kann dann zu jedem Zeitpunkt  $t$ , unter Kenntnis der aktuellen Inhaltssumme  $S_t^{\text{KL}+\text{LM}}$  der beiden Talsperren KL und LM ( $S_t^{\text{KL}}$  und  $S_t^{\text{LM}}$ ), aus dem Dispatcherplan abgelesen werden. Die verwirklichte Abgabe  $Q_t^{\text{del}}$  entspricht der festgelegten Abgaberate der aktuellen Bereitstellungsstufe  $Q^{\text{BSS}}$ , es sei denn, der Bedarf kann nicht gedeckt werden.

Der Talsperrenbetreiber geht bei der Simulation von der genauen Kenntnis über alle Zuflüsse bis zum Ende des aktuellen Monats aus. Um somit unter OASIS vergleichbare Ergebnisse erzielen zu können, ist eine zusätzliche in OCL-implementierte Iterationsstufe

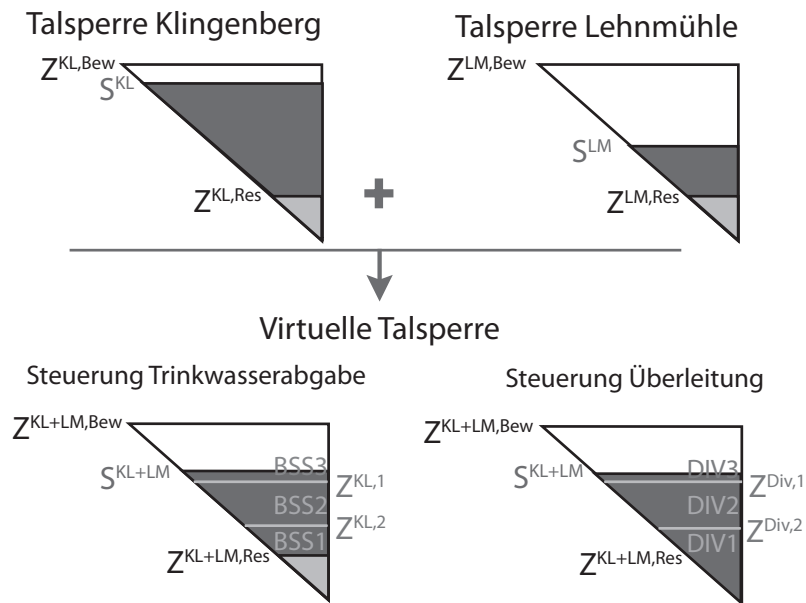


Abbildung 8.3: Schema der Bereitstellungsstufen innerhalb der virtuellen Talsperre

Tabelle 8.2: Überleitungsraten  $Q^{\text{DIV}\{1,\dots,3\}}$  nach Überleitungsstufe zur Stützung der Talsperre Klingenberg durch die Talsperre Rauschenbach.

Überleitungsstufe	Überleitungsleistung	
	$Q^{\text{DIV}\{1,\dots,3\}}$ (hm <sup>3</sup> je Monat)	
DIV3		0,00
DIV2		0,40
DIV1		0,60

erforderlich. Diese ermöglicht es, die Überleitungsmenge nach dem akkumulierten Füllstand  $S_t^{\text{KL+LM}}$  am Ende des jeweiligen Zeitschritts  $t$  nach der Verrechnung aller Zuflüsse und Abgaben zu steuern.

Analog zu den Steuerungsregeln der Trinkwasserabgabe ist die Bewirtschaftung der Stützung durch die Talsperre RB vorgesehen. Nach Abbildung 8.3 sind DIV1, DIV2 und DIV3 als Teilräume des akkumulierten Bewirtschaftungsraums  $Z^{\text{KL+LM,Bew}}$  festgelegt. Anhand derer kann zu jedem Zeitpunkt  $t$  die zu erbringende Überleitungsmenge in Abhängigkeit von  $S_t^{\text{KL+LM}}$  ermittelt werden. Die zu den Überleitungsstufen zugehörigen monatlichen Überleitungsmengen  $Q^{\text{DIV}\{1,\dots,3\}}$  sind in Tabelle 8.2 vermerkt.

**Sekundäre Steuerungsstrategien** umfassen die folgenden Punkte:

1. Da an die Talsperre KL als Trinkwassertalsperre hohe Anforderungen an die Wassergüte gestellt werden, wird in dieser jederzeit ein möglichst hoher Wasserstand angestrebt. Die Verbundsteuerung der Talsperren Klingenberg und Lehmühle geschieht aus diesem Grund wie folgt: Von zwei vollen Talsperren KL und LM ausgehend, wird



## 8.2 Projektion zukünftiger Talsperrenzuflüsse (Modul A)




Abbildung 8.4: Modellkaskade in Modul A zur Klimafolgenanalyse für die Fallstudie 1.

zunächst die Talsperre KL um  $1,0 \text{ hm}^3$  auf  $13,27 \text{ hm}^3$  abgesenkt. Nach Erreichen dieses Werts wird die Talsperre LM bis zum Reserveraum auf  $2,5 \text{ hm}^3$  entleert. Erst dann beginnt die weitere Entleerung der Talsperre KL, bis zum Reserveraum bei  $2,0 \text{ hm}^3$ . Bei der Wiederbefüllung der Talsperren geschieht der Prozess in umgekehrter Reihenfolge.

- Die im Unterstrom maximal zulässigen Abgaben werden zum Zwecke des Hochwasserschutzes, wenn möglich, eingehalten. Ebenso wird der Hochwasserschutzraum im Normalbetrieb frei gehalten und nach einem Einstau im Hochwasserfall schnellstmöglich wieder geleert. Die Steuerung des Talsperrensystems im Hochwasserfall ist für Simulationsrechnungen auf einer monatlichen Zeitskala jedoch wegen der geringen zeitlichen Auflösung kaum relevant.
- Ökologische Mindestabgaben sind von den Talsperren KL und LM mit konstanten  $0,05 \text{ m}^3\text{s}^{-1}$  bzw.  $0,03 \text{ m}^3\text{s}^{-1}$  aufrechtzuerhalten. Die Talsperre RB realisiert sowohl eine Abgabe über die Revierwasserlaufanstalt als auch die Mindestwasserführung am Pegel Rauschenbach 3, diese belaufen sich jeweils auf  $0,15 \text{ m}^3\text{s}^{-1}$ . Diese Bedarfsziele besitzen im Modell die höchste Priorität und werden daher zuerst beliefert.

## 8.2 Projektion zukünftiger Talsperrenzuflüsse (Modul A)

### 8.2.1 Datengrundlagen und Methoden

In Modul A werden die Zuflussdargebote für Klimaszenarien modelliert. Die Szenarien basieren auf den SRES-Emissionsszenarien A1B, B1 und A2. Abbildung 8.4 zeigt die hierbei verwendete Modellkette. Meteorologische Daten in geeigneter Auflösung entstammen Bernhofer et al. (2011). Das Wasserhaushaltsmodell WaSiM-ETH wird zunächst zur Modellierung von Abflussspenden, unter Verwendung der meteorologischen Daten genutzt. Die Abflussspenden sind, nach weiterer Bearbeitung in den Modulen B und C, Grundlage für die Optimierung der Talsperrenbewirtschaftung in Modul D.

### **Rezente meteorologische Daten**

Im Rahmen der Regionalisierung werden 94 DWD-Stationen (18 Klima- und 76 Niederschlagsstationen) und 3 Stationen des Tschechischen Hydrologisch-Meteorologischen Dienstes (CHMI) ausgewählt (Abbildung C.3, links). Im Anschluss an eine Regionalisierung der stationsbasierten Klimadaten auf einen gemeinsamen Zeitraum von 1961-1990 erfolgt die Übertragung auf die Fläche durch ordinary-Kriging (Krige, 1951; Stein, 1999).

### **Meteorologische Daten der projizierten klimatischen Verhältnisse**

Die in dieser Arbeit verwendeten Klimadaten basieren sämtlich auf dem Lauf 1 des allgemeinen großräumigen Zirkulationsmodells ECHAM5/MPI-OM T63 (Enke, 2001). Aus diesen wurde ein Ensemble meteorologischer Daten durch Downscaling mit zwei unterschiedlichen regionalen Klimamodellen bereitgestellt (Bernhofer et al., 2011). Diese umfassen das dynamische WETTREG 2010 (Kreienkam et al., 2010; Spekat et al., 2007) und das statistische CLM (Hollweg et al. 2008).

Der Datensatz von WETTREG 2010 enthält für jeweils 10 Realisierungen tägliche Werte der Klimaelemente für die SRES-Emissionsszenarien A1B, A2 und B1 für ausgewählte Stationen des Deutschen Wetterdienstes über den Zeitraum 1961-2100. Die abgedeckte Stationsdichte ist im Vergleich zum DWD-Messnetz wesentlich geringer, (Abbildung C.3, links). Die täglichen Klimaelemente aus CLM liegen für den Zeitraum von 1961 bis 2100 in Form eines Rasters mit einer räumlichen Auflösung von  $0,165^\circ$  vor. Für CLM stehen lediglich 2 Realisierungen für die SRES Emissionsszenarien A1B und B1 zur Verfügung. Auf das Untersuchungsgebiet entfalten drei Rasterzellen. (Abbildung C.3, rechts). Wie auch bei den rezenten Klimaelementen, erfolgt eine Regionalisierung der meteorologischen Daten mittels ordinary-Krigings.

### **Hydrologische Daten**

Die Kalibrierung und Validierung des Wasserhaushaltsmodells WaSiM-ETH basieren auf beobachteten Durchflussdaten. Es standen für den Pegel Ammeldorf lückengefüllte und geprüfte Durchflussdaten im Zeitraum vom 01.11.1945 bis 31.10.2011 zur Verfügung. Aufgrund der ungenügenden Datenlage wurde für den Pegel Klingenberg (Auslasspegel der Talsperre Klingenberg, Datenlücken vom 01.11.1977 bis zum 31.10.1978 und vom 01.11.1979 bis zum 18.09.2008) aus Bewirtschaftungsdaten der Talsperren Lehmühle und Klingenberg (Zuflüsse, Abgaben, Speicheränderung) eine durchgängige Zeitreihe generiert.




Abbildung 8.5: Aufteilung des Einzugsgebiet der Talsperren Klingenberg und Lehmühle in die Modellgebiete A, B und C. Modellgebiet A entwässert in Modellgebiet B, Modellgebiet B entwässert in Modellgebiet C.

### Kalibrierung des Wasserhaushaltsmodells mittels multikriterieller Optimierung

Die MKO des Wasserhaushaltsmodells WaSiM-ETH wird mit dem psMO-CMA-ES (Abschnitt 6.4) durchgeführt.<sup>2</sup> Aufgrund der unzureichenden Datenqualität der Pegel Lehmühle, Beerwalde und Klingenberg wird das Untersuchungsgebiet nach Abbildung 8.5 in drei Teileinzugsgebiete untergliedert. Während die Modellgebiete A und C kalibriert werden, erhält Modellgebiet B die Parameter des Modellgebiets C. Die automatische Kalibrierung von WaSiM-ETH erfolgt im Zeitraum 01.11.1999 bis 31.10.2005. Die Modellvorlaufzeit beträgt ab dem 01.11.1997 zwei Jahre.

### Validierung

Die Modellvalidierung erfolgt über den Zeitraum von fünf hydrologischen Jahren (01.11.2005 bis 31.10.2010) mit zwei Jahren Modellvorlaufzeit (ab 01.11.2003) anhand beobachteter Durchflussdaten für die Modellgebiete A und C.

<sup>2</sup>Es wird WaSiM-ETH der Version 9.08 für Linux verwendet, die psMO-CMA-ES kann auf 64 Threads zugreifen.

## Simulation und Parameterunsicherheit

Zur multikriteriellen Kalibrierung von WaSiM-ETH wird die psMO-CMA-ES verwendet. Verschiedene Gütekriterien dienen als Zielfunktionen, um während der Optimierung simultan unterschiedliche Aspekte des Hydrografen zu verbessern.

Nach Vrugt et al. (2003) stellt die approximierete Pareto-Menge  $\Theta^a$  die minimale Parameterunsicherheit dar, die erreicht werden kann, ohne dass eine subjektive Präferenz bezüglich einzelner konträrer Zielfunktionen und somit von Aspekten des Hydrografen gemacht wird.

Die Analyse der Parameterunsicherheit erfolgt hier nach der Kalibrierung, durch die Auswahl von 60 Pareto-optimalen Lösungen. Diese können dann im Validierungszeitraum evaluiert werden, um die Unsicherheit abzubilden, die sich durch die Präferenz bezüglich einzelner konträrer Zielfunktionen (Gütekriterien) ergibt.

Die Auswahl sieht die 30 besten Lösungen der Zielfunktion  $F_1$  (Gleichung 8.2) über  $F_1 > 0,3$  und die 30 besten Lösungen bezüglich der Zielfunktion  $F_2$  (Gleichung 8.3) unter  $F_2 < 27\%$  vor. Zielfunktion  $F_3$  (Gleichung 8.4) ist unbeschränkt. Mit dem Fokus auf die beiden Gütekriterien  $F_1$  und  $F_2$  lassen sich anhand  $F_3$  weitere Lösungen gewinnen, die in Anlehnung an Efstratiadis and Koutsoyiannis (2010) als „behavioural solutions“ angesehen werden können.

Für die Simulationen des Wasserhaushalts unter den projizierten Klimaszenarien wird eine Referenzlösung als Kompromisslösung mit geringer euklidischer Distanz zum Utopia-Punkt aus der Pareto-Menge gezogen.

### 8.2.2 Modellaufbau

Die Modellimplementierung des Untersuchungsgebiets in WaSiM-ETH wird auf Basis einer räumlichen Auflösung von 500 m mal 500 m erstellt. Die vorherrschenden Landnutzungsarten lassen sich in 12 Klassen zusammenfassen. Die Parametrisierung der generalisierten Leitböden mit Mualem-van-Genuchten-Parametern (van Genuchten, 1980) erfolgt für die einzelnen Bodenhorizonte anhand von Tabellenwerten der Bodenarten über die bodenkundliche Kartieranleitung (Ad-hoc-Arbeitsgruppe Boden, 2005). Fehlende Daten zur Lagerungsdichte werden über den Ansatz nach Müller and Waldeck (2011) ermittelt.

### 8.2.3 Formulierung des Kalibrierungsproblems

#### Zielfunktionen

Entsprechend den Empfehlungen von Moriasi et al. (2002) erfolgt die Wahl von zwei klassischen Gütekriterien als Zielfunktionen. Zielfunktion  $F_1$ , Gleichung (8.2), und Zielfunktion  $F_2$ , Gleichung (8.3), beschreiben die Güte der Dynamik und die Fülle der Abflussspende. Zielfunktion  $F_3$ , Gleichung (8.4), hingegen beschreibt das 25 %-Quantil ( $Q_{0,25}$ ) des Grundwasserflurabstands  $Z_{GW}$ , als Angabe in Metern unterhalb der Geländeoberkante.  $F_3$  stellt

im eigentlichen Sinne kein Gütekriterium dar und wurde für Untersuchungen innerhalb des REGKLAM-Projekts gewählt.  $F_3$  ist für diese Arbeit jedoch nicht weiter relevant.  $\nu_B(\mathbf{x})$  ist der Strafterm des Box-Constraint-Handlers (Gleichung 6.33).

$$\mathbf{max} F_1 = -1 \times \mathbf{min} (-\text{NSE} + \nu_B(\mathbf{x})) \quad (8.2)$$

$$\mathbf{min} F_2 = \mathbf{min} (|\text{PBIAS}_{\text{H1}}| + |\text{PBIAS}_{\text{H2}}| + \nu_B(\mathbf{x})) \quad (8.3)$$

$$\mathbf{min} F_3 = \mathbf{min} (Q_{0,25}(Z_{\text{GW}}) + \nu_B(\mathbf{x})) \quad (8.4)$$

Die dimensionslose Nash-Sutcliff-Effizienz (NSE; Nash and Sutcliffe 1970)

$$\text{NSE} = \sum_{t=1}^T (O_t - S_t)^2 / \sum_{t=1}^T (O_t - \bar{O}_t)^2, \text{NSE} \in [-\infty, 1] \quad (8.5)$$

ist ein in der Hydrologie weit verbreitetes Gütekriterium. In der Gleichung ist  $O_t$  ein Beobachtungswert zum Zeitpunkt  $t$ ,  $S_t$  der zugehörige simulierte Wert und  $\bar{O}_t$  der Mittelwert aller Beobachtungswerte aus dem Zeitraum  $T$ . Die Zielfunktion  $F_1$  kennzeichnet bei einem Wert von 1,0 eine perfekte Modellanpassung, kleiner 0,0 ist der Mittelwert des zu modellierenden Prozesses eine bessere Schätzung als die Simulation des Modells (Nash and Sutcliffe, 1970).

Zielfunktion  $F_2$  setzt sich aus zwei Absolutwerten des Prozent-Bias (PBIAS; Gupta et al., 1999) zusammen, dem  $\text{PBIAS}_{\text{H1}}$  der Monate November bis April und dem  $\text{PBIAS}_{\text{H2}}$  der Monate Mai bis Oktober (H1 steht für das erste Halbjahr des hydrologischen Jahres, H2 für das zweite Halbjahr). Der PBIAS, hier als Formel 8.6 für ein Halbjahr,

$$\text{PBIAS}_{\text{H}} = \sum_{t=1}^T (O_t - S_t) / \sum_{t=1}^T (O_t) \quad (8.6)$$

ermöglicht eine Bewertung der Modellanpassung anhand des Abflussvolumens. Wird der PBIAS über das gesamte Jahr berechnet, können sich eine überschätzte Abflussbildung im ersten Halbjahr und eine unterschätzte Abflussbildung im zweiten Halbjahr, oder umgekehrt, ausgleichen. Um diesen Effekt zu vermeiden, werden die beiden Halbjahre getrennt bewertet und als Absolutwerte aufsummiert. Der theoretische Wertebereich von  $F_2$  ist  $(0, \dots, \infty)$ .

Obwohl  $\nu_B(\mathbf{x})$  hier in der mathematischen Formulierung des Optimierungsproblems einfließt, wird der Strafterm in der Präsentation der Ergebnisse in Abschnitt 8.2.4 herausgerechnet und ist somit nicht Bestandteil der Zielfunktionswerte.

### Entscheidungsvariablen

Für das Schneemodul wird der Ansatz nach Anderson genutzt (Abschnitt 6.1.1). Darin sind neun Parameter zu kalibrieren. Die Parameter  $T_{\text{TOR}}$  und  $T_{\text{OR}}$  teilen den Niederschlag in flüssige und feste Anteile auf;  $T_0$  ist die Grenztemperatur der Schneeschmelze. Die Schneeakkumulation und die Schneeschmelze werden über den Tagesgradfaktor  $C_1$  ohne Windeinfluss, den Tagesgradfaktor  $C_2$  mit Windeinfluss, die Speicherkapazität von Schnee für Wasser CHW, den Koeffizienten für das Wiedergefrieren CRFR sowie den minimalen und den maximalen Schmelzfaktor durch Strahlung  $\text{RF}_{\text{Min}}$  und  $\text{RF}_{\text{Max}}$  beschrieben. Tabelle C.3 listet die oberen und unteren Randbedingungen der Parameter.

Zu kalibrierende Parameter des Bodenmoduls (Abschnitt 6.1.1) sind die Speicherrückgangskonstanten des Direktabflusses  $K_1$ , des Zwischenabflusses  $K_2$ , sowie des Basisabflusses  $K_B$ , der Korrekturfaktor der Transmissivität  $Q_D$ , die Entwässerungsdichte  $D_R$ , der Anteil des Direktabflusses am Schmelzwasser  $S_{\text{DF}}$  und  $k_{\text{rec},H}$ , die Abnahme der gesättigten hydraulischen Leitfähigkeit mit der Tiefe. Letzterer ist für jeden der bis zu 7 Horizonte ( $H$ ) des geschichteten Bodens zu bestimmen. Der Parameter muss monoton mit der Tiefe abnehmen. Eine Dimensionsreduktion auf eine Entscheidungsvariable wird über die Exponentialfunktion

$$k_{\text{rec},H} = \exp(h_H \times P_{\text{prox}}), P_{\text{prox}} \in \{-0,2682, \dots, -0,001\} \quad (8.7)$$

$$k_{\text{rec},H} \in \{0,253, \dots, 1,0\}$$

erreicht. Hierbei ist  $P_{\text{prox}}$  eine Proxygröße der Entscheidungsvariable. Der Parameter  $h_H$  ist, je nach Anzahl der Horizonte  $H$ , wie folgt definiert:

$$h_H = \begin{cases} [1, 2, 6] & \text{für } H = 4 \\ [1, 2, 4, 6] & \text{für } H = 5 \\ [1, 2, 4, 5, 6] & \text{für } H = 6 \\ [1, 2, 3, 4, 5, 6] & \text{für } H = 7 \end{cases}$$

Für den letzten Horizont wird  $k_{\text{rec},H}$  jeweils mit 0,25 angesetzt. Tabelle C.2 gibt die unteren und oberen Randbedingungen der einzelnen Parameter im Bodenmodell für die Modellgebiete A und C an. Ein jeweils eigener Satz Bodenparameter wird für die Teileinzugsgebiete Ammeldorf und Rehefeld kalibriert. Für das Modellgebiet A umfasst die Anzahl an Entscheidungsvariablen somit 22 Modellparameter<sup>3</sup>, für das Modellgebiet C beschränkt sich die Anzahl auf 16.

---

<sup>3</sup>Der Parameter  $k_{\text{rec},H}$  gilt global und wird daher nur einmal kalibriert.




Abbildung 8.6: Pareto-Fronten des Modellgebiets A (a) und des Modellgebiets C (b). Die Zielfunktion  $F_3$  ist durch die farbliche Kodierung der einzelnen Lösungen dargestellt. Punkte mit dickem schwarzem Rand stellen die repräsentativen Lösungen dar. Die Referenzlösung ist durch einen größeren Punkt markiert.

## 8.2.4 Ergebnisse

### Kalibrierung mittels multikriterieller Optimierung

Für das Modellgebiet A (Einzugsgebiet des Pegels Ammeldorf) ergibt sich nach etwa 40 000 Modellevaluationen eine Pareto-Menge aus 116 Lösungen (Abbildung 8.6, a). Der Wertebereich der Zielfunktionen  $F_1$  reicht von -1,85 bis 0,78. Zielfunktion  $F_2$  erstreckt sich von 7,3% bis 31,6% und Zielfunktion  $F_3$  von 0,6 m bis 4,0 m. Erkennbar ist, dass höhere Nash-Sutcliffe-Effizienzen ( $F_1$ ) jeweils höhere Grundwasserflurabstände ( $F_3$ ) und höhere PBIAS ( $F_2$ ) voraussetzen. Für das Modellgebiet C umfasst die Pareto-Menge nach etwa 20 000 Modellevaluationen 358 Kompromisslösungen (Abbildung 8.6, b). Der Wertebereich der Zielfunktion  $F_1$  erstreckt sich von einem NSE von -2,76 bis 0,69. Die Zielfunktion  $F_2$  erstreckt sich von 0,7% bis 44,5%, die Grundwasserflurabstände in  $F_3$  liegen zwischen 0,8 m und 4,0 m. Wie auch im Modellgebiet A verhalten sich die Zielfunktionen  $F_1$  und  $F_2$  konträr, höhere Grundwasserflurabstände begünstigen die Zielfunktion  $F_1$ .

Bei beiden Optimierungen gilt, dass der klassisch verwendete PBIAS, ohne Aufteilung in Halbjahre, etwa halb so groß ist. Bezüglich der Gütekriterien PBIAS und NSE können die Ergebnisse nach Moriasi et al. (2002) als gut eingestuft werden.

Beide Optimierungsläufe resultieren in Entscheidungsvariablen mit vielen Parameterwerten im Bereich der oberen und unteren Randbedingungen (Abbildung C.4). Für das Modellgebiet A bedingen hohe NSE jeweils geringe Werte der Parameter  $T_O$ ,  $K_B$  und  $Q_O$ . Dagegen lassen sich im Modellgebiet C hohe NSE nur bei hohen  $C_1$ ,  $C_2$  und geringen

$S_{DF}$  erreichen. Bei Lösungen mit vergleichbar hohen NSE-Werten lassen sich bei beiden Modellgebieten zumeist ähnliche Entscheidungsvektoren feststellen.

Abbildung 8.7 zeigt die Vergleiche der simulierten und beobachteten täglichen Abflussspenden. Bei beiden Modellgebieten stimmen sowohl die Größenordnungen als auch die Dynamik der simulierten Abflussspenden gut überein. Die Bandbreite an Abflussspenden aus den 60 Pareto-optimalen Lösungen deckt die beobachtete Abflussganglinie im Niedrigwasser- und Hochwasserbereich weitestgehend ab. Auch auf monatlicher und jährlicher Zeitskala können die Größenordnung, der generelle Verlauf und die Dynamik der Abflussspende abgebildet werden (Abbildung C.5).

### Auswertung der Validierung

Nach Abbildung 8.8 können die kalibrierten Modelle der Modellgebiete A und C auch im Validierungszeitraum die beobachteten Abflussspenden mit hoher Übereinstimmung abbilden.

Die extrem ansteigenden Abflussspenden ab dem Jahr 2008 am Pegel Klingenberg sind der unzureichenden Qualität der Durchflussdaten zuzuschreiben. Auf monatlicher und jährlicher Zeitskala ist der stark ansteigende Trend der Abflussspenden (Abbildung C.7) deutlich zu erkennen.




Abbildung 8.7: Abflussspenden des Modellgebietes A (a) und des Modellgebiets C (b) im Kalibrierungszeitraum auf täglicher Zeitskala. Dargestellt sind jeweils das Medium (schwarze Linie) und die Spannweite (graue Fläche) der Abflussmodellierungen der Pareto-optimalen Lösungen und die Beobachtungswerte (rote Linie).






Abbildung 8.8: Abflussspenden des Modellgebietes A (a) und des Modellgebiets C (b) im Validierungszeitraum auf täglicher Zeitskala. Dargestellt sind jeweils das Medium (schwarze Linie) und die Spannweite (graue Fläche) der Abflussmodellierungen der Pareto-optimalen Lösungen und die Beobachtungswerte (rote Linie).

Zusammenfassend kann aufgrund der erzielten hohen Übereinstimmung der simulierten und beobachteten Abflussspenden die Kalibrierung beider Modelle als erfolgreich angesehen werden. Die geringen Spannweiten der Abflussspenden durch die Simulation des Wasserhaushalts mit 60 Pareto-optimalen Lösungen deuten sowohl in der Kalibrierung als auch in der Validierung auf niedrige Parameterunsicherheiten hin.

### Projizierter Wasserhaushalt

In Abbildung 8.6 ist die ausgewählte Referenzlösung für die Simulation des Wasserhaushalts gekennzeichnet. Anhand der ihr zugehörigen Modellparametrisierung erfolgt die Simulation des Wasserhaushalts zur Abschätzung der Klimafolgen in den Jahren 2000 bis 2100.

Nach Tabelle 8.3 nimmt der Median der mittleren jährlichen Abflussspenden aus den 10 Realisierungen aus WETTREG 2010 (med A) in der Zeitscheibe 2021-2050 im Vergleich zu den Beobachtungen (DWD) zwischen 12 % und 26 % und in der Zeitscheibe 2071-2100 zwischen 43 % und 53 % ab. Dies liegt hauptsächlich am abnehmenden Niederschlag. Die zunehmende potentielle und reale Evapotranspiration hat dabei nur einen geringen Einfluss. Die Unsicherheiten durch die Realisierungen betragen bis zum Jahr 2050 rund 80 mm und in Zeitscheibe 2071-2100 rund 40 mm. Damit beträgt die Bandbreite durchgängig etwa 15 % bis 20 % des Medians. Unter CLM bleiben die Mediane der mittleren jährlichen Abflussspenden in etwa konstant, die Bandbreite der Abflussspenden beträgt weniger als 10 %

Tabelle 8.3: Vergleich der Mediane (med A) und Spannweiten (angegeben über das Minimum min A und das Maximum max A) der projizierten Abflussspenden aus allen Realisierungen der regionalen Klimamodelle WETTREG 2010 und CLM in den vier Zeitscheiben.

A (mm)	DWD		ECHAM5/MPI-OM T63 (Lauf 1)								
	1961-1990		1991-2020			2021-2050			2071-2100		
	Beo.	C20	A1B	B1	A2	A1B	B1	A2	A1B	B1	A2
			WETTREG 2010								
min A		415	407	430	437	319	339	416	211	211	264
med A	492	<i>463</i>	<i>462</i>	<i>460</i>	<i>459</i>	<i>355</i>	<i>380</i>	<i>429</i>	<i>233</i>	<i>239</i>	<i>282</i>
max A		491	492	507	515	383	410	443	255	255	295
			CLM								
min A <sub>1</sub>		446	450	425		457	423		430	437	
med A <sub>1</sub>	492	<i>476</i>	<i>453</i>	<i>438</i>		<i>466</i>	<i>459</i>		<i>441</i>	<i>450</i>	
max A <sub>1</sub>		507	456	451		475	495		452	464	

des Medians und ist somit geringer als bei Simulationen mit WETTREG 2010. Es stehen jedoch auch weniger Realisierungen zur Verfügung. Beide Klimamodelle unterschätzen die Abflussspenden im Reanalysezeitraum um knapp 30 mm. Einen Eindruck vom Verlauf der mittleren Jahreswerte sowohl der potentiellen und realen Evapotranspiration als auch der Abflussspenden gibt Abbildung C.8.

Boxplots der Verteilungen der mittleren monatlichen Abflussspenden für das Modellgebiet A unter Parameterunsicherheit sind für alle Zeitscheiben unter dem SRES-Szenario A1B in Abbildung C.6 darstellt. Erkennbar ist die Abflussspendenspitze im März unter Verwendung der WETTREG 2010 Daten, die von der beobachteten, schneeschnmelzbedingten Abflussspendenspitze im April abweicht. Die Abflussspenden der Monate Januar bis März sind bis 2100 am geringsten von Rückgängen betroffen. Für die Emissionsszenarien B1 und A2 ergeben sich mit A1B vergleichbare innerjährliche Verteilungen. Als Ausnahme hiervon sind unter B1 in der Zeitscheibe 2021-2050 weiterhin Abflussspenden wie in der Zeitscheibe 1961-1990 vorzufinden.

### 8.2.5 Zusammenfassung

Der MO-CMA-ES konnte erstmals und erfolgreich für die automatische multikriterielle Kalibrierung eines flächendifferenzierten und deterministischen Wasserhaushaltsmodells angewandt werden. Eine einfache Analyse zur Parameterunsicherheit im Kalibrierungs- und Validierungszeitraum deutet auf eine geringe Parameterunsicherheit hin. Simulationen des Wasserhaushalts unter WETTREG 2010 lassen zukünftig deutlich abnehmende Ab-

flussspenden und damit auch abnehmende Zuflussdargebote für die Talsperren erwarten. Diese Abnahmen können mit CLM nicht bestätigt werden.

## 8.3 Stochastische Zeitreihengenerierung (Modul B)

### 8.3.1 Vorgehen

Die im Modul A für die Klimaszenarien generierten als auch die beobachteten Zeitreihen werden mit dem HKNN-SMA-Zeitreihenmodell stochastisch verlängert. Die angestrebte Zeitreihenlänge ist, in Anlehnung an die Bemessungszeitreihe des Talsperrenbetreibers, 10 000 Jahre.

#### Trendbereinigung

Die stochastisch verlängerten multivariaten Zuflusszeitreihen sind Grundlage für die Optimierung der Talsperrensteuerung mittels Regelkurven in Abschnitt 8.5. Um dort praxisrelevante Regelkurven zu erlangen, müssen für die Zeitreihen stationäre Rahmenbedingungen gelten (Winston, 1994). Jedoch prägen die SRES-Emissionsszenarien den projizierten Talsperrenzuflüssen durch die steigende atmosphärische Treibhausgaskonzentration und rückläufige Niederschläge oftmals einen rückläufigen deterministischen Trend auf (Abbildung C.8).

Für die Zeitscheiben der Klimaszenarien müssen daher zunächst mittlere hydrologische Verhältnisse geschaffen werden, die quasi-stationäre Zuflusszeitreihen erlauben. Zunächst werden die Zuflüsse der einzelnen Zeitreihen gegen einen linearen Trend getestet. Existiert ein signifikanter Trend ( $\alpha = 0,05$ ), wird die Zeitreihe mit dem natürlichen Logarithmus  $\hat{X} = \log(X)$  transformiert. Der Trend wird bereinigt und die Zeitreihe anschließend mit  $X = \exp(\hat{X})$  zurücktransformiert. Dieses Vorgehen vermindert eine Verfälschung der wichtigen Niedrigwasserperioden im Sommer, da der Trend primär durch die höheren Durchflüsse bereinigt wird (Abbildung 8.9, links).

Nach Tabelle 8.4 sind alle Realisierungen in der Zeitscheibe 1991-2020 frei von signifikanten Trends. Für das Emissionsszenario A1B treten signifikante Trends in den Realisierungen erst ab der Zeitscheibe 2071-2100 auf. Für die Emissionsszenarien A2 und B1 treten diese für den lokalen Zufluss B bereits 2021-2050 auf. Auffällig ist die geringe Anzahl von signifikanten Trends des lokalen Zuflusses A in allen Zeitscheiben. Für das regionale Klimamodell CLM können keine signifikanten Trends festgestellt werden.

#### Modellierung der lokalen Zuflüsse im Gebiet Rauschenbach

Der Gesamtzufluss der Talsperre Rauschenbach (lokaler Zufluss C) sowie der Durchfluss am Pegel Rauschenbach (lokaler Zufluss D) werden durch eine nichtlineare Regression auf




Abbildung 8.9: Vergleich der Trendbereinigung anhand logarithmierter Zuflüsse (links) und untransformierter Zuflüsse (rechts). Die trendbereinigte Zuflussganglinie ist jeweils in grau gegeben, in schwarz die trendbehaftete Zeitreihe des Emissionsszenarios A2 unter WETTREG 2010 in der Zeitscheibe 2021-2050, Realisierung 00.

Tabelle 8.4: Anzahl der Realisierungen mit signifikanten Trends für die lokalen Zuflüsse A und B für WETTREG 2010.

Emissionsszenario		A1B		A2		B1	
lokaler Zufluss		A	B	A	B	A	B
Zeitscheibe	1991-2020	0	0	0	0	0	0
	2021-2050	0	0	0	9	0	3
	2071-2100	1	4	0	10	0	8

Basis von künstlichen neuronalen Netzen für jeden Monat  $s$  geschätzt (nach Kişi, 2007). Die Regressionen  $C_s = \text{KNN}_s(\text{GES}_s)$ ,  $\forall s \in \{1, \dots, 12\}$  für den lokalen Zufluss C basieren auf den beobachteten monatlichen Gesamtzuflüsse der Talsperre Klingenberg  $\text{GES}_s$  für den jeweiligen Monat, die Regressionen  $D_s = \text{KNN}_s(\text{GES}_s, \text{RB}_s)$   $\forall s \in \{1, \dots, 12\}$  des lokalen Zuflusses D beziehen sich zusätzlich auf den beobachteten Gesamtzufluss der Talsperre Rauschenbach  $\text{RB}_s$ .

Die beobachteten Zuflussdaten für das Training der KNN entstammt jeweils dem Zeitraum November 1921 bis Oktober 2007 und wurden von der LTV zur Verfügung gestellt. Für die Schätzung der Zuflüsse in den Klimaszenarien ist  $\text{GES}_s$  als Summe der lokalen Zuflüsse A und B definiert und  $\text{RB}_s$  durch den geschätzten lokalen Zufluss C. Die  $R^2$ -Statistiken für die Schätzung aller Zuflüsse im Trainingszeitraum betragen für den lokalen Zufluss C 0,78 und für den lokalen Zufluss D 0,87. Abbildung 8.10 zeigt die zugehörige Streudiagramme der beobachteten und geschätzten Zuflusswerte.




Abbildung 8.10: Streudiagramm zwischen den beobachteten und den mittels KNN-Regression geschätzten lokalen Zuflüssen C und D.

### Erstellen von Trainingsdatensätzen

Die Realisierungen eines regionalen Klimamodells sind für ein Klimaszenario jeweils zufällige Ausprägungen eines stochastischen Prozesses. Da die Realisierungen derselben Grundgesamtheit entstammen, können diese nach der Trendbereinigung in einen Trainingsdatensatz übernommen werden. Dieser umfasst alle Realisierungen eines regionalen Klimamodells für eine Zeitscheibe und ein Emissionsszenario. Für WETTREG 2010 stehen 10 Realisierungen zur Verfügung, für CLM zwei.

Die Realisierungen werden dazu nach ihrer Realisierungsnummer (00-99 für WETTREG 2010 bzw. 1-2 für CLM) zu jeweils 300-jährigen bzw. 60-jährigen Gesamtdatensätzen aneinandergereiht. Durch die willkürliche Anordnung der Realisierungen im Trainingsdatensatz ergibt sich vor allem für höhere Lags eine Unsicherheit bezüglich der Autokorrelationsstruktur. Zur Abschätzung der Unsicherheit werden 10 000 zufällige Anordnungen der einzelnen Realisierungen gezogen und jeweils ein Autokorrelogramm auf jährlicher Zeitskala berechnet. Dadurch zeigt sich, dass die Unsicherheit im allgemeinen für Lag-1 bis Lag-4 vernachlässigbar ist und mit höheren Lags nur leicht zunimmt (Abbildung C.9).

### Stochastische Zeitreihengenerierung

Der Vergleich der Autokorrelogramme der beobachteten Zuflüsse der Jahre 1961-1990 und der Zuflüsse aus der Reanalyse für WETTREG 2010 zeigt eine deutliche Unterschätzung der Autokorrelationsstruktur letzterer (Abbildung 8.11). Der Autokorrelationskoeffizient bei Lag-1 ist für die beobachteten Zuflüsse 0,38, unter WETTREG 2010 lediglich 0,12.

In den Zeitscheiben 1991-2020 und 2071-2100 bricht das Autokorrelogramm der Zuflüsse bei allen Emissionsszenarien mit dem ersten Lag ab. Lediglich in der Zeitscheibe 2021-2050 sind die Lag-1 Autokorrelationskoeffizienten mit 0,14 und 0,21 für die Emissionsszenarien A1B und A2 signifikant von 0 verschieden (Abbildung 8.16). Unter der




Abbildung 8.11: Autokorrelogramme der Zuflüsse des lokalen Zuflusses A aus der Beobachtung (1921-2007), der Reanalyse (1961-1990) des regionalen Klimamodells WETTREG 2010, sowie der synthetisch erzeugten Zuflusszeitreihen der HKNN und HKNN-SMA Modelle.

Tabelle 8.5: Vergleich der geschätzten Hurst-Koeffizienten für die beobachteten (1921-2007) und simulierten Zuflusszeitreihen (HKNN-SMA-Modell) der lokalen Zuflüsse A, B, C und D.

Lokaler Zufluss	Hurst Koeffizient $H$			
	A	B	C	D
Beobachtet	0,63	0,61	0,57	0,54
Simuliert	0,66	0,63	0,60	0,58

hierauf begründeten Annahme, dass die Autokorrelationsstruktur der Zuflüsse auf jährlicher Zeitskala systematisch für die Zuflüsse der Projektionen unterschätzt wird, soll diese für die Zeitreihengenerierung der projizierten Zuflüsse mit dem SMA-Filter nach Vorbild der beobachteten Zuflusszeitreihen modelliert werden. Daher werden für den SMA-Filter als Parameter die geschätzten Hurst-Koeffizienten der Beobachtungsdaten verwendet. Diese sind in Tabelle 8.5 gelistet.

Für die Zeitreihengenerierung wird für jeden lokalen Zufluss ein Satz mit zwölf künstlichen neuronalen Netzen trainiert (Abschnitt 6.2). Für bestimmte Auswertungen der Modellperformance im folgenden Abschnitt wird auch auf die Ergebnisse der Zeitreihengenerierung ohne den SMA-Filter, als HKNN-Modell, eingegangen. Mit Vor- und Nachlauf für den SMA-Filter ( $q = 150$ ) beträgt die insgesamt zu generierende Zeitreihenlänge für das HKNN-SMA-Modelle jeweils 123 600 Monate.

### 8.3.2 Ergebnisse

#### Modellgüte

Einen Überblick über die Modellgüte soll im Folgenden anhand der Zeitreihenmodellierung für den Reanalysezeitraum (Jahre 1961-1990) des regionalen Klimamodells WETTREG 2010 vorgestellt werden.

Die Evaluierung der Modellgüte umfasst den Vergleich wichtiger statistischer Kennwerte für die beobachteten (Zeitraum 1921-2000) und die synthetischen Zeitreihen. Der Vergleich umfasst die ersten drei statistischen Momente, geschätzt durch den Mittelwert  $\mu$ , die Varianz – hier als Standardabweichung  $\sigma$  angegeben – und die Schiefe  $\xi$ , sowie die Lag-1 Autokorrelationen, die Kreuzkorrelationen und die marginale Verteilung der Zuflüsse in bestimmten Monaten. Weiterhin erfolgt der Vergleich von Kennwerten zur Beschreibung der simulierten Trockenperioden (Salas et al., 1980).

Für eine bessere Vergleichbarkeit wird die 10 000-jährige Zeitreihe in 125 Zeitreihen mit gleicher Länge wie die Beobachtungsdaten (80 Jahre) unterteilt. Aus Gründen des Umfangs beschränkt sich die Diskussion im Wesentlichen auf den lokalen Zufluss A.

In Abbildung 8.12 sind die grundlegenden statistischen Kennwerte der zehn Realisierungen in Hellgrau dargestellt. Vor allem für die monatlichen Autokorrelationskoeffizienten können erhebliche Unterschiede zwischen den Realisierungen festgestellt werden. Die Kennwerte des Trainingsdatensatzes (schwarz) entsprechen, mit Ausnahme der Schiefe in den Sommermonaten, dem jeweils mittleren Verhalten der Kennwerte aus den 10 Realisierungen. Insgesamt erfolgt eine gute Abbildung der grundlegenden statistischen Kennwerte des Trainingsdatensatzes ohne erkennbaren Bias. Das Interquantil der Kennwerte aus den 125 unterteilten Zeitreihen überlagert die beobachteten Kennwerte zumeist. Die Spannweite der Kennwerte der 80-jährigen Zeitreihen ist mit der Variabilität der Kennwerte über die Realisierungen vergleichbar. Die 10 000-jährige Zeitreihe deckt somit die Variabilität der stochastischen Eigenschaften in den Realisierungen, in vergleichbar langen Zeiträumen ab. Die Abbildungsgüte der monatlichen und jährlichen statistischen Kennwerte ist für die 10 000-jährige Zeitreihe über den gesamten Zeitraum erwartungsgemäß ebenso gut (Tabelle C.4).

Abbildung 8.13 zeigt die Kreuzkorrelationen für die gleichen Zeitschritte zwischen ausgewählten lokalen Zuflüssen. Die Kreuzkorrelationen auf der jährlichen Zeitskala werden leicht unterschätzt. Weiterhin zeigen die Diagramme, dass die Korrelationskoeffizienten der einzelnen Realisierungen teilweise sehr unterschiedliche innerjährliche Verläufe besitzen.

Die marginale Dichtefunktion  $J_K$  der Zuflüsse in einzelnen Monaten ist für die Modellierung von Zeitreihen für wasserwirtschaftliche Zwecke ebenso von Bedeutung (Lall and Sharma, 1996). Die mit einem Kernel-Density-Estimator (Scott, 2008) geschätzten marginalen




Abbildung 8.12: Vergleich monatlicher und jährlicher statistischer Kennwerte (Mittelwert, Standardabweichung, Schiefe, Autokorrelationskoeffizient  $r_1$ ) für den lokalen Zufluss A. Die Statistiken der beobachteten Zuflüsse sind als schwarze Linie dargestellt. Die Statistiken der, in 125 einzelne Zeitreihen zu 80 Jahren unterteilten, synthetischen Zeitreihen sind als Boxplots gegeben. Die Kennwerte der 10 Realisierungen aus WETTREG 2010 sind in Hellgrau dargestellt.




Abbildung 8.13: Vergleich monatlicher und jährlicher Kreuzkorrelationen zwischen ausgewählten lokalen Zuflüssen (Datengrundlage 1921-2007). Die Statistiken der beobachteten Zuflüsse sind als schwarze Linie dargestellt. Die Statistiken der, in 125 einzelne Zeitreihen zu 80 Jahren unterteilten, synthetischen Zeitreihen sind als Boxplots gegeben.



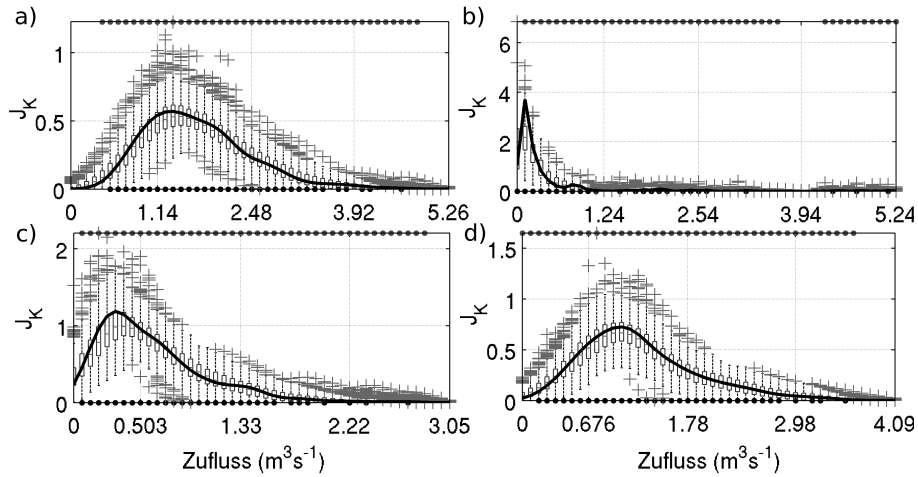


Abbildung 8.14: Marginale Dichtefunktionen der Zuflüsse des lokalen Zuflusses A für die Monate April (a), Juli (b), Oktober (c) und Januar (d). Die Dichte des beobachteten Zuflusses ist als schwarze Linie dargestellt, die der 125 synthetischen Zeitreihen sind als Boxplots gegeben.

Dichtefunktionen der Monate Januar, April, Juli und Oktober sind in Abbildung 8.14 dargestellt. Mit dem HKNN-SMA-Modell können demnach beliebige Verteilungen für die einzelnen Monate erfolgreich modelliert werden. Weiterhin sind in Abbildung 8.14 beobachtete Zuflüsse an den 50 Stützstellen (Punkte unten) markiert. Ein Vergleich zeigt, dass in der synthetischen Zeitreihe Zuflüsse in Stützstellen (Punkte oben) auftreten, die für die Beobachtung unbesetzt sind. Mit dem Modell ist es somit möglich, unbeobachtete Zuflüsse zu simulieren.

Das Autokorrelogramm des lokalen Zuflusses A für Jahreswerte (Abbildung 8.11) weist für den Trainingsdatensatz des Reanalysezeitraums gegenüber dem der Beobachtung (1921-2007) eine deutlich schwächere Autokorrelationsstruktur auf. Die Autokorrelogramme der einzelnen Realisierungen zeigen, auch aufgrund der geringen Zeitreihenlänge von 30 Jahren, kein einheitliches Verhalten. Das HKNN-Modell, ohne SMA-Filter, zeigt bereits bei Lag-1 einen kaum signifikanten Autokorrelationskoeffizienten. Durch die Nachbearbeitung mit dem SMA-Filter nähert sich das Autokorrelogramm des HKNN-SMA-Modells den Beobachtungsdaten an und klingt langsamer exponentiell ab.

Abbildung 8.15 gibt einen Überblick über die Verteilung wichtiger Kennwerte über die simulierten Defizit- und Überschussperioden. Diese sind die Länge einer Defizit- oder Überschussperiode ( $L_{\text{DEF}}$  bzw.  $L_{\text{SUR}}$ ), das Defizit- oder Überschussvolumen ( $V_{\text{DEF}}$  bzw.  $V_{\text{SUR}}$ ), sowie das Defizitvolumen  $V_{\text{FSA}}$  der nach dem Folgescheitelalgorithmus separierten Perioden. Die Kennwerte werden jeweils für eine Sollabgabe  $c_{\text{crit}}$  von  $1,05 \text{ m}^3\text{s}^{-1}$  bestimmt.

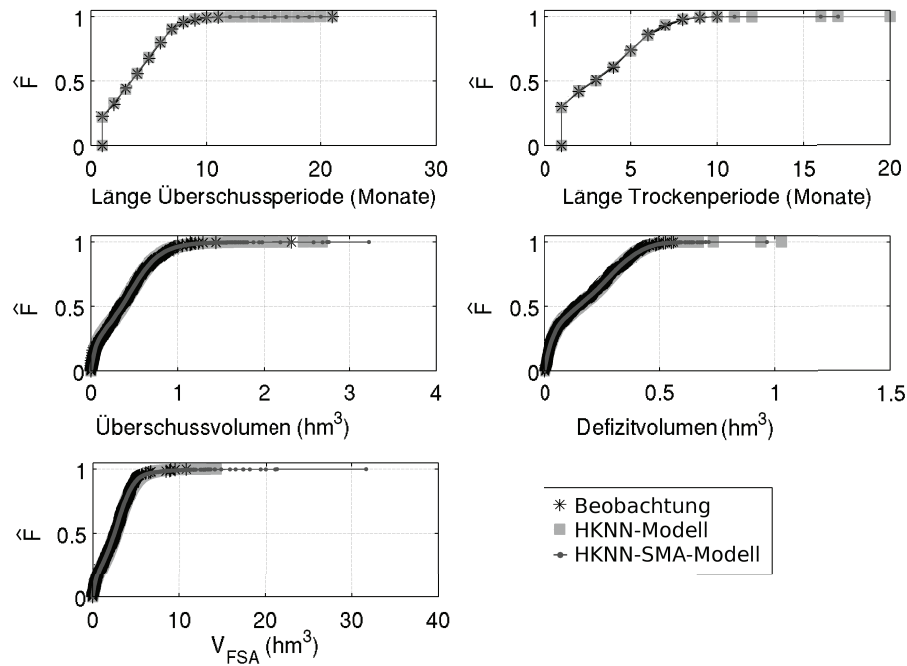


Abbildung 8.15: Empirisch kumulative Verteilungsfunktionen verschiedener Kennwerte für Trocken- und Überschussperioden (Reanalysezeitraum, WETTREG 2010). Als Schwellenwert  $c_{\text{crit}}$  ist  $1,05 \text{ m}^3 \text{ s}^{-1}$  angesetzt, der betrachtete Zufluss ist die Summe der Zuflüsse A und B.

Die langjährige Zeitreihe für diesen Vergleich wird aus der monatlichen Summe der lokalen Zuflüsse A und B berechnet.

Grundsätzlich kann dabei festgestellt werden, dass die Verteilungen der Kennwerte der synthetischen Zeitreihe denen der beobachteten Zeitreihe folgen. Mit dem HKNN- und dem HKNN-SMA-Modell können noch nicht beobachtete  $V_{\text{DEF}}$  bzw.  $V_{\text{SUR}}$  sowie  $L_{\text{DEF}}$  simuliert werden. Während das Maximum von  $V_{\text{SUR}}$  für das HKNN-SMA-Modell nur geringfügig größer als das beobachtete Maximum ist, erhöhen sich die Maxima der Kennwerte der Trockenperioden  $L_{\text{DEF}}$ ,  $V_{\text{DEF}}$  in etwa um das Doppelte bzw. für  $V_{\text{FSA}}$  um das Dreifache.

### Zeitreihengenerierung für projizierte klimatische Verhältnisse

Für die Klimamodelle WETTREG 2010 und CLM werden in allen Zeitscheiben (1961-1990, 1991-2020, 2021-2050 und 2071-2100) für die Emissionsszenarien A1B, B1 und A2 mit dem HKNN-Modell und dem HKNN-SMA-Modell synthetische Zeitreihen über 10 000 Jahre erzeugt. Nach Abbildung 8.16 weisen alle synthetischen Zeitreihen des HKNN-SMA-Modells durch die Verwendung der Hurst-Koeffizienten des Beobachtungszeitraums mit den Beobachtungswerten ähnliche jährliche Autokorrelogramme auf (Tabelle 8.5). Die Trainingsdatensätze zeigen, ebenso wie die Zeitreihen der HKNN-Modelle bereits nach dem ersten Lag deutlich geringere Autokorrelationskoeffizienten.

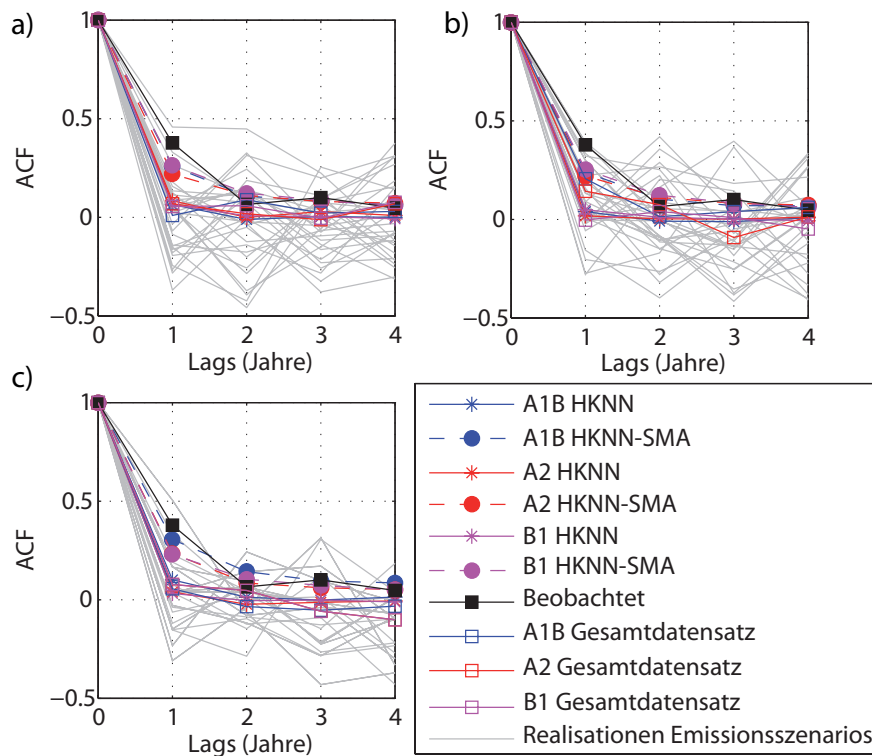


Abbildung 8.16: Autokorrelogramme des lokalen Zuflusses A im Beobachtungszeitraum (1921-2007), der Gesamtdatensätze der Klimaszenarien sowie der synthetischen Zuflusszeitreihen der HKNN und HKNN-SMA Modelle (Emissionsszenarien A1B, B1 und A2 für das regionale Klimamodell WETTREG 2010). Die Zeitscheibe 1991-2020 ist in a), 2021-2050 in b) und 2071-2100 in c) dargestellt.

Die Simulation der für die Speicherwirtschaft wichtigen maßgebenden Trockenperioden soll im Folgenden anhand der benötigten Speichergröße  $\hat{V}_{\text{FSA}}$  des Folgescheitelalgorithmus verglichen werden. Nach Tabelle 8.6 zeigt sich der Effekt der Langzeitpersistenz auf  $\hat{V}_{\text{FSA}}$ . Das HKNN-Modell, das diese nicht simuliert, erreicht durchweg geringere  $\hat{V}_{\text{FSA}}$  als das HKNN-SMA-Modell. Daher würden die Anforderungen an die Größe eines wasserwirtschaftlichen Speichers mit dem HKNN-Modell unterschätzt (Langousis and Koutsoyiannis, 2006).

Für den rezenten Zeitraum ergeben sich somit nur geringe Unterschiede für die maximalen Defizitvolumina. Nach Tabelle 8.6 sind die  $\hat{V}_{\text{FSA}}$  in der Zeitscheibe 1991-2020 unter WETTREG 2010 für alle SRES-Emissionsszenarien vergleichbar. Dies ist auch plausibel, denn in diesem Zeitraum unterscheiden sich die Emissionsszenarien nur geringfügig (IPCC, 2007).

Tabelle 8.6: Maximales Defizitvolumen nach dem Folgescheitelalgorithmus  $\hat{V}_{\text{FSA}}$  für die generierten Zeitreihen.

Szenario	Zeitscheibe	CO <sub>2</sub>	Datenbasis	$\hat{V}_{\text{FSA}}$ (hm <sup>3</sup> )		
				HKNN	HKNN-SMA	
Beobachtung	1921-2007		13,9	21	35,2	
	1961-1990		13,9	23,1	40,4	
	1961-1990		10,7	14,2	30,3	
	1991-2020	A1B		8,7	12,3	20,2
		A2		9,0	16,0	24,2
		B1		8,6	14,5	19,4
WETTREG 2010		A1B	67,4	165,0	374,0	
	2021-2050	A2	38,1	49,2	108,7	
		B1	11,5	18,3	27,2	
	2071-2100*	A1B		16,9	30,2	60,8
		A2		14,1	24,7	65,9
		B1		14,1	23,6	51,2

\* wegen reduziertem  $c_{\text{crit}}$  (0,75 m<sup>3</sup>s<sup>-1</sup>) nicht direkt vergleichbar

Für die Zeitscheibe 2021-2050 zeigen sich dann deutlichere Unterschiede zwischen den Emissionsszenarien. Während unter B1 noch keine extremen Trockenperioden auftreten, werden vor allem in A1B extrem hohe  $\hat{V}_{\text{FSA}}$  simuliert. Dabei ist  $\hat{V}_{\text{FSA}}$  gegenüber  $c_{\text{crit}}$  aufgrund des exponentiellen Zusammenhangs sehr sensitiv. Beispielfhaft verringert sich  $\hat{V}_{\text{FSA}}$  in der Zeitscheibe 2021-2050 (A1B) bei einer Reduktion von  $c_{\text{crit}}$  um 0,05 m<sup>3</sup>s<sup>-1</sup> von 104 hm<sup>3</sup> auf knapp ein Drittel des Wertes (Abbildung C.10).

Aufgrund der Abnahme der Zuflüsse in der Zeitscheibe 2071-2100 um rund 50 % (Tabelle C.5) kann zur Ermittlung von  $\hat{V}_{\text{FSA}}$  nicht mehr mit einer konstanten Abgabe  $c_{\text{crit}}$  von 1,05 m<sup>3</sup>s<sup>-1</sup> gerechnet werden. Für die letzte Zeitscheibe wird  $c_{\text{crit}}$  auf 0,65 m<sup>3</sup>s<sup>-1</sup> reduziert. Trotzdem ergeben sich nach Tabelle 8.6, unter Verwendung des HKNN-SMA-Modells, hohe  $\hat{V}_{\text{FSA}}$  um 50 bis 60 hm<sup>3</sup>.

Die generierten 10 000-jährigen Zeitreihen der Szenarien des regionalen Klimamodells CLM weisen bis zum Jahr 2100 keine relevanten Zunahmen von  $\hat{V}_{\text{FSA}}$  auf. Die maximalen Defizitvolumina nach dem Folgescheitelalgorithmus schwanken durch die stochastische Natur der Zeitreihengenerierung zwischen 23,5 hm<sup>3</sup> (1991-2020, A1B) und 40,1 hm<sup>3</sup> (1991-2020, B1), ein Zusammenhang zwischen den mittleren projizierten Zuflüssen und den maximalen Defizitvolumina nach dem Folgescheitelalgorithmus existiert nicht. Nach Tabelle C.6 bleiben die mittleren lokalen Zuflüsse in etwa auf einem Niveau.

## 8.4 Monte-Carlo-Rekombination (Modul C)

### 8.4.1 Vorgehen

Das Talsperrenmodell des Talsperrenverbundsystems besitzt vier miteinander korrelierte lokale Zuflüsse (Abbildung 8.19). Daher wird für die Monte-Carlo-Rekombination nach Abschnitt 6.3 eine Dummy-Zeitreihe benötigt. Tabelle 8.7 gibt eine Übersicht über die verwendeten Parameterwerte der Monte-Carlo-Rekombination.

Die Dummy-Zeitreihe für das Talsperrenverbundsystem wird aus den lokalen Zuflüssen A und B gebildet, da diese ausreichen das System adäquat zu beschreiben. Die beiden Zeitreihen werden monatlich durch Addition zusammengeführt. Die Sollabgabe  $c_{\text{crit}}$  für den Folgescheitelalgorithmus wird spezifisch für die zu rekombinierenden Zeitreihen gewählt. Für die synthetischen Zeitreihen der Beobachtung (1921-1990), der Zeitreihe der LTV und der Zeitreihe für das Emissionsszenario B1 in der Zeitscheibe 2021-2050 ergibt sich diese aus der Summe der höchsten Abgaberate von  $1,00 \text{ m}^3\text{s}^{-1}$  (BSS3) und der Wildbettabgabe der Talsperre Klingenberg von  $0,05 \text{ m}^3\text{s}^{-1}$ .

Für die Zeitreihen der Emissionsszenarien A1B und A2 in der Zeitscheibe 2021-2050 wird auf die Wildbettabgabe der Talsperre Klingenberg verzichtet, trotzdem ergeben sich sehr lange Defizitperioden, so dass im Vergleich zu dem Szenario B1 bis zum Jahr 2050 eine geringe Anzahl an Defizitperioden (Tabelle 8.7) separiert werden kann. Die Sollabgabe  $c_{\text{crit}}$  für die Zeitreihen der Zeitscheibe 2071-2100 wird auf die geringste Abgabestufe der reduzierten Abgaberate (Abschnitt 8.5.3) gesetzt.

### 8.4.2 Ergebnisse

Die Rekombination der synthetischen Zeitreihe für die rezenten Verhältnisse im Zeitraum 1921-2007 soll zunächst als Beispiel für die Ergebnisse im Modul C dienen. Durch den Folgescheitelalgorithmus lassen sich bei einer Sollabgabe von  $c_{\text{crit}} = 1,05 \text{ m}^3\text{s}^{-1}$  zunächst  $n_{\text{ha}} = 11\,287$  Trockenperioden identifizieren. Hieraus werden  $n_{\text{T}} = 800$  Trockenperioden gezogen.

Abbildung 8.17 (a) stellt die ECDF der Defizitvolumina  $V_{\text{FSA}}$  der Beobachtungsdaten und der rekombinierten Zeitreihe gegenüber. Eine gute Übereinstimmung der ECDF ist gegeben. Der Pearson'sche Korrelationskoeffizient  $\rho$ , der über einem Schwellenwert  $P_{\text{T}}$  von 0,4 berechnet wurde, beträgt  $\rho = 99,51$  und bestätigt die Güte der Rekombination. Zur Illustration der Arbeitsschritte ist in Abbildung 8.17 (b) zunächst die Abfolge der angeordneten Trockenperioden, angegeben durch die zugehörigen Defizitvolumina dargestellt. Abbildung 8.17 (c) zeigt einen Ausschnitt der schlussendlich rekombinierten monatlichen Dummy-Zeitreihe, der die extremste Trockenperiode umfasst.

Die Überprüfungen der wichtigsten statistischen Kennwerte der Dummy-Zeitreihe (Abbildung 8.18) sowie der lokalen Zuflüsse A (Abbildung C.11) bis D (Abbildung C.14) lassen ebenfalls auf eine erfolgreiche Rekombination der langjährigen Zeitreihe schließen.

Tabelle 8.7 fasst die Ergebnisse der Monte-Carlo-Rekombinationen für alle weiteren Zeitreihen zusammen. Die Zeitreihenlängen der verkürzten Zeitreihen liegen demnach zwischen 561 bis 1148 Jahren.

Die Simulationsdauer eines Talsperrenbewirtschaftungsmodells ist in etwa proportional zum Simulationszeitraum. Somit ist, durch die hier durchgeführten Rekombinationen, in den jeweiligen MK-SBO eine Verkürzung der Rechenzeit um den Faktor 9 bis 18 zu erwarten.




Abbildung 8.17: MCR der synthetischen Zuflusszeitreihen des Zeitraums 1921-2007. (a) Darstellung der empirischen kumulativen Verteilungsfunktion der langjährigen Zeitreihe und der rekombinierten Dummy-Zeitreihe. (b) Darstellung der Zeitreihe der rioden, gegeben durch die zugehörigen Defizitvolumina. (c) Ausschnitt der Dummy-Zeitreihe über die größte Defizitperiode  $\max(V_{FSA})$ .




Abbildung 8.18: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Dummy-Zeitreihe für den Datensatz 1921-2007.

Tabelle 8.7: Übersicht über gewählte Werte der Parameter und Ergebnisse der Monte-Carlo-Rekombination für verschiedene Zeitreihen.

Datenbasis	Zeitraum	CO <sub>2</sub>	$n_{ha}$	$\bar{Q}$ (m <sup>3</sup> s <sup>-1</sup> )	$c_{crit}$ (m <sup>3</sup> s <sup>-1</sup> )	$n_r$ (-)	$P_T$ (-)	$\rho_{min}$ (-)	$n_{he}$	$\rho$ (-)	$L_R$ (Jahre)
Beobachtet	1921-2007	-	11287	1,45	1,05	800	0,4	99,5	994	99,51	882
		A1B	3126	1,06	1,00	250	0,6	99,0	276	99,39	1148
2021-2050		A2	3520	1,13	1,00	300	0,8	95,5	288	97,50	993
		B1	7824	1,28	1,05	400	0,9	92,5	396	93,53	561
WETTREG 2010	2071-2100	A1B	5795	0,71	0,65	300	0,7	98,5	370	98,24	691
		A2	5567	0,71	0,65	400	0,7	96,0	495	96,16	819
	B1	5482	0,71	0,65	300	0,75	95,0	293	95,4	878	

Es ist  $n_{ha}$  die Anzahl der Defizitperioden der langjährigen Zeitreihe,  $\bar{Q}$  ist der mittlere akkumulierte Zufluss der lokalen Zuflüsse A und B,  $c_{crit}$  die für den FSA verwendete Sollabgabe,  $n_r$  die gewählte Anzahl an zu rekombinierenden Defizitvolumina,  $P_T$  der Schwellenwert der Unterschreitungswahrscheinlichkeit,  $\rho_{min}$  der Schwellenwert des erforderlichen Korrelationskoeffizienten  $\rho$ ,  $n_{he}$  die Anzahl der Defizitperioden in der rekombinierten Zeitreihe,  $\rho$  der Pearson'sche Korrelationskoeffizient und  $L_R$  die Zeitreihenlänge der rekombinierten Zeitreihe. Die Spalte CO<sub>2</sub> weist die SRES-Emissionsszenarien des regionalen Klimamodells WETTREG 2010 aus.






Abbildung 8.19: Schema der Modellimplementierung des Talsperrenverbundsystems in OASIS.

## 8.5 Multikriterielle Optimierung der Talsperrenbewirtschaftung (Module D bis F)

### 8.5.1 Implementierung des Talsperrenverbundsystems in OASIS

Das Mehrzweck-Talsperrenverbundsystem der Talsperren Klingenberg, Lehmühle und Rauschenbach wird unter Beachtung der in Abschnitt 8.1.2 genannten Bewirtschaftungsstrategien im adaptiven Talsperrenbewirtschaftungsmodell OASIS implementiert. Abbildung 8.19 zeigt die Implementierung des Knotenschemas des Talsperrenverbundsystems im Simulationsmodell OASIS.

### 8.5.2 Validierung des Talsperrenbewirtschaftungsmodells

Eine Validierung anhand von beobachteten Talsperreninhalten und Abgaben ist nicht möglich, da sich die Bewirtschaftung in den letzten Jahren veränderte und somit keine ausreichend konsistente Datenbasis zur Verfügung steht.<sup>4</sup>

Die Validierung des Modellaufbaus des Talsperrenverbundsystems in OASIS erfolgt daher unter dem Aspekt, dass die aktuellen Bewirtschaftungsregeln der LTV einen Betrieb des Talsperrenverbundsystems mit den geforderten Versorgungssicherheiten ermöglichen. Das aufgebaute Talsperrenmodell sollte daher mit den Dispatcherplänen des Talsperrenbetreibers ähnliche Leistungsdaten ausgeben. Als Datengrundlage hierfür dienen weiterhin die von der LTV bereitgestellten 10 000-jährigen Bemessungszeitreihen des Talsperrenverbundsystems Klingenberg und Lehmühle sowie der Talsperre Rauschenbach. Sowohl der in der Modellimplementation unter OASIS benötigte Zwischengebietszufluss zwischen den Talsperren Klingenberg und Lehmühle als auch der Durchfluss am Pegel Rauschenbach 3 werden mittels einer multiplen linearen Regression geschätzt.

Ziel ist es somit, die geforderten Versorgungssicherheiten (Tabelle 8.1) mit dem aufgestellten Modell zu erreichen. Die in der Validierung ermittelten Versorgungssicherheiten liegen mit 98,6 % für die P(BSS3), 99,5 % für die P(BSS2) und 100 % für die P(BSS1) nahe bei den geforderten Versorgungssicherheiten, stimmen jedoch nicht genau mit diesen überein. Die geforderte Versorgungssicherheit der Abgabestufe von  $1,00 \text{ m}^3\text{s}^{-1}$  (99 %) wird mit 0,4 % unterschritten, während die Versorgungssicherheit der Abgabestufe von  $0,85 \text{ m}^3\text{s}^{-1}$  (99,95 %) mit 0,05 % überschritten wird.

Mögliche Ursachen der Abweichungen können in einer leicht abweichenden Arbeitsweise des Modells sowie in den hier geschätzten Zuflusszeitreihen begründet liegen. Die mittlere monatliche Überleitungsmenge beträgt  $0,078 \text{ hm}^3$  je Monat, die Wahrscheinlichkeit einer vollen Talsperre Klingenberg im April beläuft sich auf 77,7 %. Diese Ergebnisse sind laut der LTV stimmig.<sup>5</sup> Demnach kann eine praxisnahe Implementierung des Talsperrenverbundsystems KL-LM-RB als erfolgreich angesehen werden.

### 8.5.3 Beschreibung der durchgeführten Szenarienrechnungen

Insgesamt umfassen die betrachteten Szenarienrechnungen zwei Themenkomplexe. Der erste Themenkomplex umfasst die multikriterielle Optimierungen der Talsperrensteuerung für rezente klimatische Verhältnisse. Neben der Optimierung des Talsperrensystems für den Ist-Zustand liegt der Fokus auf einer planungstechnischen Veränderung am System. Mit diesem

---

<sup>4</sup>Unter anderem durch die mehrmaligen Erweiterungen des Hochwasserschutzraums (Sieber, 2003) und die Restaurierung der Talsperre Klingenberg (Haufe et al., 2012)

<sup>5</sup>Mündliche Absprache mit Herrn Ulf Winkler, Referatsleiter Wassermengenwirtschaft, LTV am 01.03.2013

Szenario soll die Flexibilität des Frameworks demonstriert werden. Die Szenarienrechnungen des Themenkomplexes eins sind:

**S-AKT** Unter Szenario S-AKT werden die Steuerungsstrategien des Talsperrenverbundsystems unter aktuellen (AKT) Rahmenbedingungen anhand der generierten langjährigen stochastischen Zeitreihe (Abschnitt 8.3) auf Basis der beobachteten Zuflüsse im Zeitraum 1921-2007 optimiert. Mit der hier durchgeführten SBO könnte der multikriterielle Nachweis der Speicherleistung unter gegenwärtigen Rahmenbedingungen (DIN19700-11) erfolgen.

**S-BEO** Szenario S-BEO optimiert die Betriebsweise des Talsperrenverbundsystems unter Verwendung der Beobachtungsdaten (BEO) im Zeitraum 1921-2007 für rezente Rahmenbedingungen. Im Gegensatz zu Szenario S-AKT stehen jedoch nur Zuflüsse in einem Zeitraum von 86 Jahren zur Verfügung. Das Szenario S-BEO stellt somit die Vergleichsgrundlage zur Bewertung der Rechnungen unter S-AKT und der Frams-BoT-Strategie dar.

**S-5RK** In diesem Szenario wird eine zusätzliche vierte Bereitstellungsstufe BSS4 oberhalb der BSS3 eingeführt. Die Abgaberate beträgt  $1,20 \text{ m}^3 \text{ s}^{-1}$  bei einer freigestellten Versorgungssicherheit, die jedoch mehr als 30 % betragen muss. Mit der neu eingeführten Regelkurve  $Z^{\text{KL},0}$  sind insgesamt 5 Regelkurven zu optimieren (5RK). Mit dem Szenario S-5RK wird demonstriert, dass mit dem Framework auch unkompliziert strukturelle Veränderungen bewertet werden können.

Der zweite Themenkomplex umfasst Szenarien, die die projizierten klimatischen Verhältnisse in den Zeitscheiben der Emissionsszenarien unter dem regionalen Klimamodell WETTREG 2010 behandeln. Die Datengrundlage der Szenarien umfasst die in Abschnitt 8.2 modellierten und im Abschnitt 8.3 verlängerten Zeitreihen der lokalen Zuflüsse. Für das regionale Klimamodell CLM wird an dieser Stelle auf multikriterielle Optimierungen zur Abschätzung der Grenzleistungsfähigkeit verzichtet, da das nahezu unveränderte projizierte hydrologische Zuflussregime dies nicht zwingend erforderlich erscheinen lässt (Tabelle C.6). Im Folgenden sollen die Szenarien vorgestellt werden, für die eine multikriterielle Optimierung der Talsperrenbewirtschaftung durchgeführt wird:

**S-2021-CO<sub>2</sub>** Zu diesen Szenarien zählen alle MKO der Talsperrenbewirtschaftung für die Zeitscheibe 2021-2050 und die mit den SRES-Emissionsszenarien (CO<sub>2</sub>) A1B, A2 und B1 des regionalen Klimamodells WETTREG 2010 projizierten klimatischen Entwicklungen.

**S-2071-CO<sub>2</sub>** Zu diesen Szenarien zählen alle MKO der Talsperrenbewirtschaftung für die Zeitscheibe 2071-2100 und die mit den SRES-Emissionsszenarien (CO<sub>2</sub>) A1B, A2 und B1 des regionalen Klimamodells WETTREG 2010 projizierten klimatischen

Entwicklungen. Die Abgaben der Bereitstellungsstufen werden wegen der stark abgenommenen mittleren Zuflüsse (Tabelle C.5) reduziert und betragen für die BSS1  $0,75 \text{ m}^3\text{s}^{-1}$ , für die BSS2  $0,675 \text{ m}^3\text{s}^{-1}$  und für die BSS3  $0,6 \text{ m}^3\text{s}^{-1}$  bei gleichbleibenden Versorgungssicherheiten.

### 8.5.4 Mathematische Modellbeschreibung

Die Herausforderung bei der mathematischen Formulierung der MKO liegt in der Beschreibung der Versorgungssicherheiten nach Abschnitt 8.1.2. Die Versorgungssicherheiten der drei Bereitstellungsstufen sind differenziert zu betrachten. Die separate Formulierung von drei Zielfunktionen für die Versorgungssicherheiten würde zu einem unnötig hochdimensionalen Optimierungsproblem führen. Aus diesem Grund wird eine Formulierung vorgeschlagen, die alle drei Versorgungssicherheiten in einer Zielfunktion zusammenfasst.

Die in dieser Fallstudie geforderten Versorgungssicherheiten (Tabelle 8.1) sind sehr hoch. Dies bedeutet, dass vom möglichen Wertebereich (0,0 % bis 100,0 %) in den rezenten Szenarienrechnungen nur ein sehr kleiner Bereich größer 99,0 % von Interesse ist. Die Pareto-Front mit geringen Versorgungssicherheiten ist für den Entscheidungsträger je nach Auslastung des Talsperrensystems uninteressant. Aus diesem Grund wird der Zielfunktionsraum durch die Zielfunktionen eingeschränkt, wodurch Rechenzeit eingespart wird.<sup>6</sup> Die Restriktionen führen jedoch zu Unstetigkeitsbereichen im Zielfunktionsraum mit nur schwacher Kausalität und somit zu einer komplexeren Optimierungsaufgabe.

#### Modellbeschreibung für die Szenarien S-AKT, S-BEO, S-2021-CO<sub>2</sub> und S-2071-CO<sub>2</sub>

Zielfunktion  $FF1$  (Gleichung 8.8) maximiert die generelle Versorgungssicherheit, indem die drei erreichten Versorgungssicherheiten  $P(\text{BSS1})$ ,  $P(\text{BSS2})$ ,  $P(\text{BSS3})$  der Bereitstellungsstufen eins bis drei in einer Zielfunktion zusammengefasst werden. Dies wird durch eine Summe aus drei Hilfsfunktionen  $\nu_1$ ,  $\nu_2$  und  $\nu_3$  (Gleichungen 8.8a bis 8.8c), sowie einer Strafbetragsfunktion  $\nu_s$  (Gleichung 8.9) erreicht. Die Strafbetragsfunktion der BCHT  $\nu_B(\mathbf{x})$  (Gleichung 6.33) ist lediglich für das Lernverhalten der MO-CMA-ES von Bedeutung. Der Strafterm wird daher in der Präsentation der Ergebnisse in den nachfolgenden Abschnitten aus den Zielfunktionswerten der Zielfunktionen  $FF1$ ,  $FF2$  und  $FF3$  herausgerechnet.

$$\mathbf{max}(FF1) = -1 \times \mathbf{min}(\nu_1 + \nu_2 + \nu_3 + \nu_s + \nu_B(\mathbf{x})) \quad (8.8)$$

---

<sup>6</sup>Eine kleinere Population kann die Pareto-Front im kleineren Zielfunktionsraum ausreichend abdecken. Dies spart Rechenzeit, da diese mit der Populationsgröße ansteigt.




Abbildung 8.20: Funktionsverlauf der Hilfsfunktion  $\nu_1$  bei einem Schwellenwert  $\lambda_1$  gegenüber der erreichten Versorgungssicherheit  $P(\text{BSS1})$ .

$$\nu_1 = \begin{cases} -1 \times \left( \frac{P(\text{BSS1}) - \lambda_1}{1 - \lambda_1} \right) & \text{für } P(\text{BSS1}) \geq \lambda_1 \\ 1 - \frac{P(\text{BSS1})}{\lambda_1} & \text{sonst} \end{cases} \quad (8.8a)$$

$$\nu_2 = \begin{cases} -1 \times \left( \frac{P(\text{BSS2}) - \lambda_2}{1 - \lambda_2} \right) & \text{für } P(\text{BSS2}) \geq \lambda_2 \\ 1 - \frac{P(\text{BSS2})}{\lambda_2} & \text{sonst} \end{cases} \quad (8.8b)$$

$$\nu_3 = \begin{cases} -1 \times \left( \frac{P(\text{BSS3}) - \lambda_3}{1 - \lambda_3} \right) & \text{für } P(\text{BSS3}) \geq \lambda_3 \\ 1 - \frac{P(\text{BSS3})}{\lambda_3} & \text{sonst} \end{cases} \quad (8.8c)$$

Die Hilfsfunktionen  $\nu_{1,\dots,3}$  unterteilen den Zielfunktionsraum in Abhängigkeit des Schwellenwertes der geforderten Versorgungssicherheit  $\lambda_{1,\dots,3} \in \{0, \dots, R(\text{BSS}\{1, \dots, 3\})\}$  in zwei jeweils linear skalierte Bereiche. Abbildung 8.20 illustriert den Funktionsverlauf der Hilfsfunktion  $\nu_1$ . Unterschreitet eine Versorgungssicherheit aus  $P(\text{BSS}\{1, \dots, 3\})$  den zugehörigen Schwellenwert  $\lambda_{1,\dots,3}$ , erfolgt durch die Strafbetragsfunktion

$$\nu_s = \begin{cases} 10^5 & \text{für } \exists \{P(\text{BSS1}) < \lambda_1, P(\text{BSS2}) < \lambda_2, P(\text{BSS3}) < \lambda_3\} \\ 0 & \text{sonst} \end{cases} \quad (8.9)$$

eine Beaufschlagung der Zielfunktionen  $FF1$  bis  $FF3$  mit einem hohen Strafterm. Existieren  $P(\text{BSS}\{1, \dots, 3\}) < \lambda_{1,\dots,3}$  dann ist der Wertebereich der Zielfunktion  $FF1$  begrenzt durch  $FF1 \in \{(3 + \nu_s), \dots, \nu_s\}$ ; bei durchweg ausreichenden  $P(\text{BSS}\{1, \dots, 3\})$  ist  $FF1 \in \{-3, \dots, 0\}$ . Die Zielfunktion  $FF1$  wird in der Fallstudie 1 auch als alleinige Zielfunktion für einkriterielle Kontrollrechnungen mit der CMA-ES verwendet.

Für die Ausbildung des Hypolimnions in der Talsperre Klingenberg ist eine vollständig gefüllte Bewirtschaftungszone im Frühjahr wünschenswert. In Absprache mit dem Betreiber des Talsperrenverbundsystems wird ein Indikator für die Wassergüte im Staukör-

per als Zielfunktion  $FF2$  (Gleichung 8.10) definiert.  $FF2$  maximiert die Wahrscheinlichkeit einer gefüllten Talsperre Klingenberg im Monat April,

$$\mathbf{max}(FF2) = -1 \times \mathbf{min} \left( -1 \times \Pr \left( S_{t'}^{\text{KL}} = S^{\text{KL,Bew}} \right) + \nu_S + \nu_B(\mathbf{x}) \right), t' \in \{1, \dots, T'\}, \quad (8.10)$$

um die Ausbildung des Hypolimnions zu unterstützen. Hierbei ist  $S_{t'}^{\text{KL}}$  der Talsperreninhalt der Talsperre Klingenberg zum Zeitschritt  $t' \in \{1, \dots, T'\}$  von insgesamt  $T'$  vorkommenden April und  $S^{\text{KL,Bew}}$  der maximale Stauinhalt der Bewirtschaftungszone (Tabelle C.1). Der Wertebereich der Zielfunktion  $FF2$  ist  $FF2 \in \{0 + \nu_S, \dots, 1\}$ .

Zielfunktion  $FF3$  (Gleichung 8.11) minimiert die mittleren monatlichen Überleitungsmengen von der Talsperre Rauschenbach zur Talsperre Klingenberg. Da das Wasser ab der Talsperre Lichtenberg zum Überwinden der Höhendifferenzen gepumpt werden muss, werden mit einer geringeren Überleitungsmenge Betriebskosten reduziert.

$$\mathbf{min}(FF3) = \mathbf{min} \left( \frac{1}{T} \sum_{t=1}^T Q_t^{\text{div}} + \nu_S + \nu_B(\mathbf{x}) \right) \quad (8.11)$$

Der Wertebereich der Zielfunktion  $FF3$  ist  $FF3 \in \{0 + \nu_S, \dots, 0,6\}$ . Entscheidungsvariablen sind einerseits die Speicherkontrollvolumina  $Z_s^{\text{KL},1}$  und  $Z_s^{\text{KL},2}$  der Regelkurven zur Trinkwasserbereitstellung (Abschnitt 8.1.2),

$$\left( Z_s^{\text{KL},1}, Z_s^{\text{KL},2}, Z_s^{\text{Div},1}, Z_s^{\text{Div},2} \right)_{\forall s}^* = \mathbf{arg} \left( \mathbf{max}(FF1), \mathbf{max}(FF2), \mathbf{min}(FF3) \right) \quad (8.12)$$

andererseits die Speicherkontrollvolumina  $Z_s^{\text{Div},1}$  und  $Z_s^{\text{Div},2}$  der Regelkurven zur Überleitung von Rohwasser von der Talsperre Rauschenbach in den Monaten  $s = 1, \dots, 12$ . Somit umfasst das Optimierungsproblem insgesamt 48 Entscheidungsvariablen. Das Talsperrenbewirtschaftungsmodell OASIS simuliert die Talsperrenbewirtschaftung unter den gegebenen Steuerungsstrategien,

$$\left( Q_t^{\text{div}}, Q_t^{\text{del}}, S_t^{\text{KL}}, S_t^{\text{LM}}, Q_t^{\text{in}}, Q_t^{\text{ab}} \right) = \text{OASIS} \left( Z_s^{\text{KL},1}, Z_s^{\text{KL},2}, Z_s^{\text{Div},1}, Z_s^{\text{Div},2} \right), \forall s, t \quad (8.13)$$

um die Zustandsvariablen und Abgaben zur Evaluation des Entscheidungsvektors zu generieren. Durch die Kodierung der Entscheidungsvariablen nach dem Rule-Curve-Stacking (Abschnitt 6.4.4) entfallen die Randbedingungen

$$Z_s^{\text{Res,KL}} + Z_s^{\text{Res,LM}} \leq Z_s^{\text{KL,2}} \leq Z_s^{\text{KL,1}} \leq Z_s^{\text{Bew,KL}} + Z_s^{\text{Bew,LM}}, \forall s \quad (8.14)$$

$$0 \leq Z_s^{\text{Div,2}} \leq Z_s^{\text{Div,1}} \leq Z_s^{\text{Bew,KL}} + Z_s^{\text{Bew,LM}}, \forall s. \quad (8.15)$$

in der Optimierung. Die Regelkurven sind grundsätzlich größer als die Summe aus den Volumina der Reserveräume der Talsperren Klingenberg und Lehmühle  $Z_s^{\text{Res,KL}} + Z_s^{\text{Res,LM}}$  und kleiner als die Summe der Bewirtschaftungszonen  $Z_s^{\text{Bew,KL}} + Z_s^{\text{Bew,LM}}$ . Die erzielte Abgabe zur Trinkwasserbereitstellung  $Q_t^{\text{del}}$  ist wie folgt formuliert:

$$Q_t^{\text{del}} = \begin{cases} Q^{\text{BSS3}} & \text{für } S_t^{\text{KL+LM}} \geq Z_s^{\text{KL,1}} \\ Q^{\text{BSS2}} & \text{für } Z_s^{\text{KL,1}} > S_t^{\text{KL+LM}} \geq Z_s^{\text{KL,2}} \\ Q^{\text{BSS1}} & \text{für } S_t^{\text{KL+LM}} < Z_s^{\text{KL,2}} \wedge Q_t^{\text{in,KL}} + Q_t^{\text{ab,KL}} + S_t^{\text{KL}} \geq Q^{\text{BSS1}} \\ Q_t^{\text{KL,m}} & \text{sonst} \end{cases} \quad (8.16)$$

$\forall s, t.$

Hierbei ist

$$Q_t^{\text{KL,m}} = \max \left( Q_t^{\text{in,KL}} - Q_t^{\text{ab,KL}} + S_t^{\text{KL}}, 0 \right), \forall t$$

mit dem Gesamtzufluss und der geforderten Gesamtabgabe der Talsperre Klingenberg,  $Q_t^{\text{in,KL}}$  und  $Q_t^{\text{ab,KL}}$ . Die erzielte Überleitungsrate  $Q_t^{\text{div}}$  wird beschrieben durch

$$Q_t^{\text{div}} = \begin{cases} Q^{\text{DIV,3}} & \text{für } S_t^{\text{KL+LM}} \geq Z_s^{\text{Div,1}} \wedge Q_t^{\text{in,RB}} - Q_t^{\text{ab,RB}} + S_t^{\text{RB}} \geq Q^{\text{DIV,2}} \\ Q^{\text{DIV,2}} & \text{für } Z_s^{\text{Div,1}} > S_t^{\text{KL+LM}} \geq Z_s^{\text{Div,2}} \wedge Q_t^{\text{in,RB}} - Q_t^{\text{ab,RB}} + S_t^{\text{RB}} \geq Q^{\text{DIV,2}} \\ Q^{\text{DIV,1}} & \text{für } S_t^{\text{KL+LM}} < Z_s^{\text{Div,2}} \wedge Q_t^{\text{in,RB}} - Q_t^{\text{ab,RB}} + S_t^{\text{RB}} > Q^{\text{DIV,1}} \\ Q_t^{\text{RB,m}} & \text{sonst} \end{cases} \quad (8.17)$$

$\forall s, t$

mit

$$Q_t^{\text{RB,m}} = \max \left( Q_t^{\text{in,RB}} - Q_t^{\text{ab,RB}} + S_t^{\text{RB}}, 0 \right), \forall t$$

und dem Gesamtzufluss und der geforderten Gesamtabgabe der Talsperre Rauschenbach,  $Q_t^{\text{in,RB}}$  und  $Q_t^{\text{ab,RB}}$ . Die Einhaltung der Kontinuität (Gleichung 6.37), der oberen und unteren Randbedingungen der Mindest- und Maximaldurchflüsse und der Mindest- und Maximalspeicherinhalte (Randbedingung 6.38) fordert jeweils OASIS.

### Erweiterung der Formulierung für das Szenario S-5RK

Im Allgemeinen gelten die Formulierungen des Abschnitts 8.5.4. Abweichende Formulierungen für das Szenario S-5RK werden im Folgenden vorgestellt. Die in diesem Szenario verwendete Zielfunktion  $FF1$  (Gleichung 8.18) erweitert Gleichung 8.8 um eine weitere Hilfsfunktionen  $\nu_4$  (Gleichung 8.19), welche die erreichte Versorgungssicherheit aus P (BSS4) der neu eingeführten Bereitstellungsstufe BSS4 beschreibt.

$$\mathbf{max}(FF1) = -1 \times \mathbf{min} (\nu_1 + \nu_2 + \nu_3 + w_4 \times \nu_4 + \nu_S + \nu_B (\mathbf{x})) \quad (8.18)$$

Durch den Wichtungsfaktor  $w_4 \in \{0, \dots, 1\}$  wird der Anteil der Hilfsfunktion  $\nu_4$  am Gesamtergebnis von  $FF1$  eingestellt. Die Hilfsfunktionen  $\nu_1, \nu_2$  und  $\nu_3$  (Gleichungen 8.8a bis 8.8c) sowie  $\nu_B (\mathbf{x})$  (Gleichung 6.33) gelten unverändert.

$$\nu_4 = \begin{cases} -1 \times \left( \frac{P(\text{BSS4}) - \lambda_4}{1 - \lambda_4} \right) & \text{für } P(\text{BSS4}) \geq \lambda_4 \\ 1 - \frac{P(\text{BSS4})}{\lambda_4} & \text{sonst} \end{cases} \quad (8.19)$$

Die Strafbetragsfunktion  $\nu_s$  (Gleichung 8.9) erweitert sich um dem Schwellenwert  $\lambda_4$  zu

$$\nu_s = \begin{cases} 10^5 & \text{für } \exists \{P(\text{BSS1}) < \lambda_1, P(\text{BSS2}) < \lambda_2, P(\text{BSS3}) < \lambda_3, P(\text{BSS4}) < \lambda_4\}. \\ 0 & \text{sonst} \end{cases} \quad (8.20)$$

Es gilt dann durch die Erweiterung des Optimierungsproblems

$$\begin{aligned} (Z_s^{\text{KL},0}, Z_s^{\text{KL},1}, Z_s^{\text{KL},2}, Z_s^{\text{Div},1}, Z_s^{\text{Div},2})_{\forall s} &= \mathbf{arg} (\mathbf{max}(FF1), \mathbf{max}(FF2), \mathbf{min}(FF3)) \\ (Q_t^{\text{div}}, Q_t^{\text{del}}, S_t^{\text{KL}}, S_t^{\text{LM}}, Q_t^{\text{in}}, Q_t^{\text{ab}}) &= \text{OASIS} (Z_s^{\text{KL},0}, Z_s^{\text{KL},1}, Z_s^{\text{KL},2}, Z_s^{\text{Div},1}, Z_s^{\text{Div},2}), \forall s, t, \end{aligned}$$

wobei der Entscheidungsvektor 60 Variablen umfasst. Die Randbedingung der Staulamellenordnung in der virtuellen Talsperre wird wie folgt erweitert:

$$Z_s^{\text{Res,KL}} + Z_s^{\text{Res,LM}} \leq Z_s^{\text{KL},2} \leq Z_s^{\text{KL},1} \leq Z_s^{\text{KL},0} \leq Z_s^{\text{Bew,KL}} + Z_s^{\text{Bew,LM}}, \forall s. \quad (8.21)$$

Durch das Rule-Curve-Stacking wird diese jedoch weiterhin jederzeit eingehalten. Die Formulierung der Abgabe von Trinkwasser erweitert sich nach






Abbildung 8.21: Gegenüberstellung der in der MKO und der Validierung (VAL) erzielten Versorgungssicherheiten und Zielfunktionswerte für das Szenario S-AKT. Die rote Linie markiert den linearen Zusammenhang der Parameter.

$$Q_t^{\text{del}} = \begin{cases} Q^{BSS4} & \text{für } S_t^{\text{KL+LM}} \geq Z_s^{\text{KL},0} \\ Q^{BSS3} & \text{für } Z_s^{\text{KL},0} > S_t^{\text{KL+LM}} \geq Z_s^{\text{KL},1} \\ Q^{BSS2} & \text{für } Z_s^{\text{KL},1} > S_t^{\text{KL+LM}} \geq Z_s^{\text{KL},2} \\ Q^{BSS1} & \text{für } S_t^{\text{KL+LM}} < Z_s^{\text{KL},1} \wedge Q_t^{\text{in,KL}} + Q_t^{\text{ab,KL}} + S_t^{\text{KL}} > Q^{BSS1} \\ Q_t^{\text{KL},m} & \text{sonst} \end{cases} \quad (8.22)$$

$\forall s, t$

mit

$$Q_t^{\text{KL},m} = \mathbf{max} \left( Q_t^{\text{in,KL}} - Q_t^{\text{ab,KL}} + S_t^{\text{KL}}, 0 \right), \forall t$$

um eine weitere Fallunterscheidung für die zusätzliche Bereitstellungsstufe.

### 8.5.5 Ergebnisse für den rezenten klimatischen Zustand

Die Gliederung dieses Abschnitts sieht zunächst die Vorstellung der Ergebnisse des Themenkomplexes eins mit den Szenarien S-AKT, S-BEO und S-5RK vor. Parameter und Kennwerte für die einzelnen Module, auf die im Text nicht eingegangen wird, sind für den Themenkomplex eins in Tabelle C.7 gegeben.

### Ergebnisse des Szenarios S-AKT

**Modul D** Die multikriterielle Optimierung für dieses Szenario wird in zwei aufeinanderfolgenden Läufen durchgeführt. Die zunächst gewählten Schwellenwerte  $\lambda_{1,\dots,3}$  von 0,6, 0,8 und 0,98 erlauben zunächst eine schnelle Konvergenz des Optimierungsalgorithmus in den gewünschten Zielfunktionsraum mit relativ hohen Versorgungssicherheiten. Der zweite Lauf nutzt dann ausgewählte Kompromisslösungen aus dem ersten Lauf als Initialisierung mit Schwellenwerten  $\lambda_{1,\dots,3}$  ähnlich den geforderten Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$ . Eine Population umfasst in beiden Läufen jeweils 48 Individuen.<sup>7</sup> Die Pareto-Menge am Ende des zweiten Laufs umfasst 915 Kompromisslösungen.




Abbildung 8.22: Level-Diagramm des Szenarios S-AKT. Dargestellt sind die erreichten Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  und die Zielfunktionen  $FF1$  bis  $FF3$ . Die Lösungen sind in vier Kompromissklassen CI-1 (Rot), CI-2 (Grün), CI-3 (Blau) und CI-4 (Lila) unterteilt. Die repräsentativen Lösungen der Kompromissklassen sind hervorgehoben und entsprechend nummeriert.

<sup>7</sup>Die unkonventionelle Anzahl von 48 Individuen kann auf einer AMD FX CPU mit 8 Kernen in sechs Zyklen je Iteration abgearbeitet werden. Die rechentechnischen Ressourcen lassen sich so durch die psMO-CMA-ES optimal ausnutzen (siehe Abschnitt 6.4.2).




Abbildung 8.23: Darstellung der optimalen Regelkurven zur Steuerung der Trinkwasserabgabe (links) und der Überleitung (rechts) nach Kompromissklassen. Farbige Flächen kennzeichnen die Spannweite der jeweiligen Regelkurve. Die Kompromissklassen sind a) C1-1, b) C1-2, c) C1-3 und d) C1-4.

**Modul E** Durch die SOM-Clustering können 317 Kompromisslösungen mit ausreichenden Versorgungssicherheiten zur Validierung bestimmt und anhand der 10 000-jährigen synthetischen Zeitreihe validiert werden. Alle Kompromisslösungen besitzen auch nach der Validierung ausreichende Versorgungseinheiten. Nach der Bereinigung der Lösungsmenge mittels nicht-dominierendes Sortieren verbleiben weiterhin 99 dominante Kompromisslösungen in der Pareto-Menge. Die Scatterplots der zugehörigen Versorgungssicherheiten  $P(BSS\{1, \dots, 3\})$  und der Zielfunktionswerte  $FF1$ ,  $FF2$  und  $FF3$  der MKO und der Validierung sind in Abbildung 8.21 dargestellt. Auf Grund der Verbindung des kürzeren Zeitraums und der äußerst hohen geforderten Versorgungssicherheit sind in der MKO nur wenige diskret verteilte  $P(BSS1)$  Werte möglich. Dies ist aus den jeweiligen Streudiagramme deutlich ersichtlich. Die hieraus in der Validierung resultierenden  $P(BSS1)$  Werte streuen jedoch nur geringfügig um den ursprünglichen Wert. Ein hoher linearer Zusammenhang ist daher für alle Versorgungssicherheiten und Zielfunktionswerte gegeben.

**Modul F** Die Ergebnisse für das Szenario S-AKT sind in einem Level-Diagramm in Abbildung 8.22 dargestellt. Zusätzlich zu den Zielfunktionen (Tafeln 4 - 6) sind die erreichten Versorgungssicherheiten (Tafeln 1 - 3) gegeben. Die Kompromisslösungen werden jedoch ausschließlich mit der 1-Norm auf Basis der Zielfunktionswerte  $FF1$  bis  $FF3$  gewertet. Die repräsentativen Lösungen werden jeweils mit Methode RLB (Abschnitt 6.6.2) ermittelt. Durch die Clustering mit der ESO-Methoden ergeben sich vier Kompromissklassen C1-1

Tabelle 8.8: Erreichte Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  und Zielfunktionswerte für das Szenario S-AKT.

Lösung	P(BSS1) (%)	P(BSS2) (%)	P(BSS3) (%)	$FF1$ (-)	$FF2$ (%)	$FF3$ ( $\text{hm}^3$ je Monat)	1-Norm (-)
Cl-1	99,970	99,89	99,82	2,997	88,16	0,183	0,77
Cl-2	99,942	99,89	99,82	2,997	82,68	0,099	0,81
Cl-3	99,971	99,83	99,67	2,995	84,83	0,120	0,98
Cl-4	99,957	99,73	99,09	2,988	81,87	0,085	1,46
$\min(FF3)$	99,957	99,73	99,13	2,988	77,44	0,056	1,58
$\max(FF2)$	99,995	99,89	99,71	2,996	91,35	0,280	0,96
$\min(D_1)$	99,978	99,92	99,87	2,998	85,39	0,130	0,69
$L_{\text{Hist}}$	99,985	99,426	99,01	2,984	81,04	0,161	

bis Cl-4 mit ihren repräsentativen Lösungen. Im Level-Diagramm sind die Kompromissklassen am deutlichsten in den Tafeln der Zielfunktionen  $FF2$  und  $FF3$  zu unterscheiden. Kompromissklasse Cl-1 umfasst Lösungen mit den höchsten monatlichen Überleitungsraten  $FF3$ , der besten Wassergüte  $FF2$  sowie sehr guten bis mittleren Versorgungssicherheiten  $FF1$ . Die Kompromissklasse Cl-3 erreicht mit höheren  $FF3$  Werten höhere  $FF2$  Werte als Cl-2, jedoch geringere  $FF1$  Werte. Generell gilt, dass mit sinkenden mittleren monatlichen Überleitungsmengen  $FF3$  sowohl die Versorgungssicherheit  $FF1$  als auch der Wassergüteindikator  $FF2$  abnehmen. Zwischen der Wassergüte und der Versorgungssicherheit ist ebenfalls ein Zielkonflikt auszumachen. Es muss jeweils entschieden werden, wie die beiden Ziele  $FF1$  und  $FF2$  mit dem zur Verfügung stehenden Wasser bedient werden.

Wie auch direkt im Level-Diagramm ersichtlich, weisen die repräsentativen Lösungen der Kompromissklassen nach Tabelle 8.8 Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  auf, die mitunter weit über den geforderten Versorgungssicherheiten  $R(\text{BSS} \{1, \dots, 3\})$  (Tabelle 8.1) liegen. Die hierzu benötigten Überleitungsraten reichen von 0,085 bis 0,183  $\text{hm}^3$  je Monat.

Der Zielkonflikt zwischen  $FF1$  und  $FF2$  ist an den repräsentativen Lösungen Cl-2 und Cl-3 erkennbar. Obwohl der repräsentativen Lösung Cl-3 eine höhere mittlere monatliche Überleitungsmenge zur Verfügung steht, liegen die erreichten Versorgungssicherheiten unter denen von Cl-2. Mit den höheren mittleren Überleitungsmengen kann lediglich der Wasserqualitätsindex gesteigert werden.

Durch die Partitionierung nach Methode RLB verteilen sich die repräsentativen Lösungen über ein breites Spektrum unterschiedlicher Kompromissarten. Mit geringen 1-Normen stellen die repräsentativen Lösungen Cl-1 und Cl-2 einen ausgewogenen Kompromiss zwischen allen Zielfunktionen dar. Cl-4 minimiert vor allem die Überleitungsrate und nimmt dabei schlechtere Versorgungssicherheiten und Wasserqualitäten in Kauf, was in höheren 1-Normen resultiert. Kompromisslösung Cl-3 legt die Wichtung vor allem auf  $FF3$ , ohne

jedoch  $FF1$  und  $FF2$  zu schlechte Zielfunktionswerte erreichen zu lassen. Die geringste 1-Norm ist 0,69 und wird von Lösung  $\min(D_1)$  repräsentiert. Lösung  $\min(D_1)$  besitzt hinsichtlich aller Zielfunktionswerte die in etwa mittleren Werte, was einem ausgeglichenen Kompromiss entspricht.

Die Lösung  $\min(FF3)$  weist gegenüber Cl-2 nochmals eine um 26 % geringere Überleitungsrate auf. Die daraus resultierenden geringeren Betriebskosten bedingen neben geringeren Versorgungssicherheiten einen um knapp 4 % geringeren Wassergüteindikator ( $FF2$ ). Die beste Wassergüte mit 91,35 % wird mit Lösung  $\max(FF2)$  erzielt, die dafür jedoch die mit Abstand höchsten Überleitungsraten benötigt.

Die Bewirtschaftung des Talsperrenverbundsystems mit den aktuell verwendeten Regelkurven für die Bereitstellungs- und Überleitungsstufen verfehlt nach Tabelle 8.8 für die synthetische Zeitreihe (1921-2007) knapp die geforderte Versorgungssicherheit  $R(BSS2)$ . Im Vergleich mit  $L_{Hist}$  erreicht Lösung Cl-2 mit deutlich geringerer  $FF3$  jeweils höhere  $FF1$  und  $FF2$  Werte.

Die zugehörigen Dispatcherpläne sind in Abbildung 8.23 getrennt nach den Kompromissklassen dargestellt. Die Spannweiten der monatlichen Speicherkontrollvolumina der Regelkurven sind als transparente farbige Fläche dargestellt. Die geringen Spannweiten der Regelkurven zeugen von jeweils sehr ähnlichen Steuerungsstrategien in den einzelnen Kompromissklassen.

Allen Dispatcherplänen der repräsentativen Lösungen ist gemein, dass sich BSS2 und DIV2 in allen Monaten nur über sehr geringe Stauinhalte erstrecken. Gemeinsame Ausnahmen für DIV2 sind bei allen Lösungen im Dezember zu finden. Cl-1 und Cl-2 besitzen größere DIV2 im Juni und Juli. Cl-3 und Cl-4 nutzten DIV2 von Januar bis Juli mit Unterbrechungen im März und Mai. DIV2 ist für die Steuerung des Talsperrenverbundsystems nur in den Monaten Juli, August (Cl-1 und Cl-3) und in der Periode Januar-April (Cl-3) von Bedeutung. Mit dem Maximum der Zuflüsse zur Schneeschmelze sollen die Talsperren möglichst gefüllt sein, ansonsten wird schon bei minimalen Fehlinhalten übergeleitet. Ab Mai (Cl-2) oder Juni (Cl-1, Cl-4) wird die Abgabe bei höheren Stauinhalten reduziert, Cl-3 beginnt hiermit schon im Januar. Im Mai wird durchweg voll übergeleitet, im Ausgleich wird schon früh mit  $0,6 \text{ hm}^3$  je Monat gestützt. Im Allgemeinen besitzen die Regelkurven einen relativ glatten und definierten Verlauf sowie eine nachvollziehbare Steuerungslogik.

**Validierung anhand der beobachteten Zuflüsse** In einem zusätzlichen Validierungsschritt wird die Bewirtschaftung des Talsperrenverbundsystems mit den 99 Dispatcherplänen anhand der beobachteten Zuflusszeitreihen (1921-2007) simuliert. Es erfolgt ein Vergleich mit der aktuellen Bewirtschaftungsstrategie des Talsperrenbetreibers.

Das Level-Diagramm in Abbildung 8.24 zeigt, dass Kompromisslösungen bei vergleichbaren mittleren monatlichen Überleitungsmengen bessere Versorgungssicherheiten, bei




Abbildung 8.24: Vergleich der erreichten Versorgungssicherheiten und Zielfunktionswerte der Lösungen aus S-AKT (Grau) mit der aktuellen Steuerungsstrategie (Schwarz) im Zeitraum 1921-2007 anhand der Beobachtungsdaten.

gleichzeitig unwesentlich geringeren Wassergüteindikatoren erreichen. Die besseren Ergebnisse sind jedoch zu relativieren, da sich bereits in der Validierung gezeigt hat, dass die Versorgungssicherheiten mit den Steuerungsstrategien des Talsperrenbetreibers leicht unterschätzt werden. Die Zielfunktionen  $FF1$  und  $FF2$  verbessern sich wiederum mit der Zunahme der monatlichen Überleitungsmengen. Die Validierung kann somit hinsichtlich des Beobachtungszeitraums als erfolgreich betrachtet werden.

### Ergebnisse des Szenarios S-BEO

**Modul D** Die MKO der Talsperrensteuerung für das Szenario S-BEO greift auf eine Initialisierung der psMO-CMA-ES auf Basis von 48 Pareto-optimalen Lösungen des Szenarios S-AKT zurück. Die Pareto-Menge nach der MKO umfasst 284 Kompromisslösungen.

**Modul E** Streudiagramme zwischen den Ergebnissen der MKO und der Validierung von  $\Theta^a$  sind in Abbildung 8.25 dargestellt. Eine schlechte Übertragbarkeit wird vor allem für die Versorgungssicherheiten der BSS3 ersichtlich. Nur Kompromisslösungen mit einer P(BSS3) von 100 % erreichen auch in der Validierung ausreichende Versorgungssicherheiten. Insgesamt verbleiben somit lediglich 26 gültige Kompromisslösungen in der Lösungsmenge. Die restlichen 258 Lösungen verfehlen die geforderten Versorgungssicherheiten  $R(BSS\{1, \dots, 3\})$  und werden somit verworfen. Daher lässt sich der Pareto-optimale Zielfunktionsraum nach

## 8.5 Multikriterielle Optimierung der Talsperrenbewirtschaftung (Module D bis F)




Abbildung 8.25: Gegenüberstellung der in der MKO und der Validierung (VAL) erzielten Versorgungssicherheiten und Zielfunktionswerte für das Szenario S-BEO. Die rote Linie markiert den linearen Zusammenhang der Parameter.

der Validierung nicht vollständig mit Kompromisslösungen abdecken. Die wahre Pareto-Front wird ungenügend approximiert.

**Modul F** Abbildung 8.26 zeigt das Level-Diagramm des Szenarios S-BEO. Die verbleibenden Kompromisslösungen sind drei Kompromissklassen zugeordnet. Diese grenzen sich deutlich voneinander ab. Wegen der schlechten Übertragbarkeit werden die Kompromissklassen nach Methode RLA (Abschnitt 6.6.2) gewählt. Im Szenario S-BEO fehlen Kompromisslösungen, die bei geringen Überleitungsraten  $FF3$  geringe  $FF2$  und geringe, aber ausreichende  $FF1$  erreichen (Tabelle 8.9). Die mit den repräsentativen Lösungen erreichten  $P(BSS3)$  und  $P(BSS2)$  von über 99,8% bzw. über 99,94% liegen weit über den geforderten Werten der  $R(BSS3)$  und  $R(BSS2)$  von 99,0% und 99,5%. Die erreichten  $P(BSS1)$  wiederum liegen jeweils nur geringfügig oberhalb der geforderten Sicherheit  $R(BSS1)$  von 99,95%. Die geringste Überleitungsrate,  $\min(FF3)$ , ist mit  $0,147 \text{ hm}^3$  je Monat um  $0,91 \text{ hm}^3$  je Monat höher als im Szenario S-AKT. Eine generelle Abnahme der Versorgungssicherheit und des Wassergüteindikators ist auch unter S-BEO mit abnehmenden mittleren monatlichen Überleitungsmenge zu verzeichnen.

Vergleichbare Merkmale lassen sich bei den optimierten Dispatcherpläne zwischen den Szenarien S-BEO und S-AKT finden. Nach Abbildung 8.27 werden die Talsperren Klingenberg und Lehmühle schon bei geringen Fehlinhalten durch die Talsperre Rauschenbach mit  $0,6 \text{ hm}^3$  je Monat (Überleitungsstufe DIV1) gestützt. Die Überleitungsstufe DIV2 und die

Tabelle 8.9: Erreichte Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  und Zielfunktionswerte für das Szenario S-BEO.

Lösung	P(BSS1) (%)	P(BSS2) (%)	P(BSS3) (%)	FF1 (-)	FF2 (%)	FF3 ( $\text{hm}^3$ je Monat)	1-Norm (-)
Cl-1	99,953	99,94	99,85	2,997	87,38	0,166	0,67
Cl-2	99,960	99,94	99,86	2,998	88,69	0,197	1,11
Cl-3	99,968	99,92	99,82	2,997	89,95	0,246	1,78
$\min(\text{FF3})$	99,954	99,82	99,52	2,993	85,38	0,147	1,00
$\max(\text{FF2})$	99,968	99,93	99,81	2,997	90,22	0,255	1,89




Abbildung 8.26: Level-Diagramm für das Szenario S-BEO. Dargestellt sind die erreichten Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  und die Zielfunktionen  $FF1$  bis  $FF3$ . Die Lösungen sind in drei Kompromissklassen Cl-1 (Rot), Cl-2 (Grün) und Cl-3 (Blau) unterteilt. Die zu den Kompromissklassen zugehörigen repräsentativen Lösungen sind hervorgehoben und nach Kompromissklasse nummeriert.

Bereitstellungsstufe BSS2 erstrecken sich über einen nur sehr geringen Anteil des Stauvolumens  $S^{\text{KL}+\text{LM}}$ . Größere Ausprägungen der beiden Lamellen sind nur in vereinzelt Monaten zu finden. Gegenüber S-AKT verschiebt sich bei allen repräsentativen Lösungen die ausgeprägte Staulamelle DIV2 aus dem Monat Dezember in den April.

### Ergebnisse des Szenarios S-5RK

**Modul D** Szenario S-5RK führt eine zusätzliche Abgabestufe (BSS4) ein. In dieser wird eine Rohwasserabgabe von  $1,2 \text{ m}^3 \text{ s}^{-1}$  realisiert. Die psMO-CMA-ES wird wiederum mit



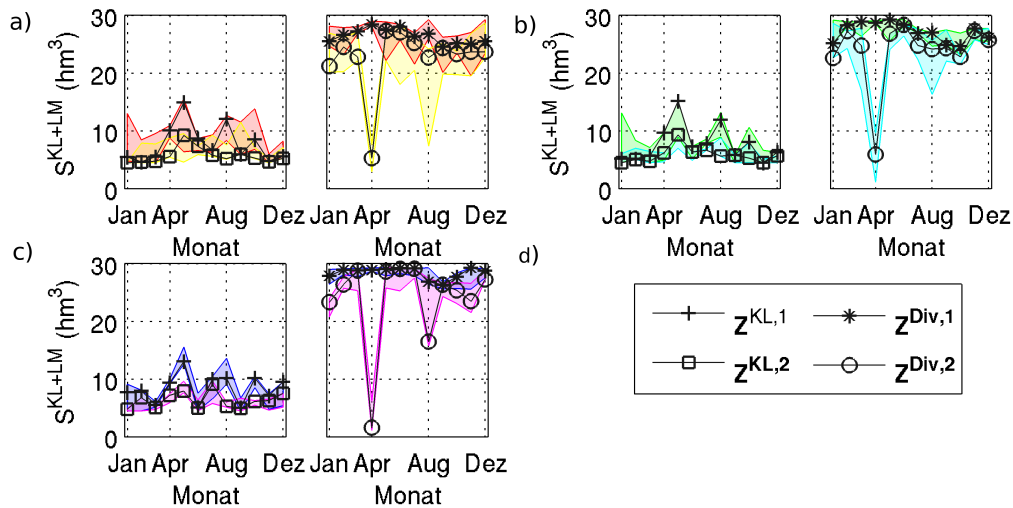


Abbildung 8.27: Darstellung der optimalen Regelkurven zur Steuerung der Trinkwasserabgabe (links) und der Überleitung (rechts) nach Kompromissklassen. Farbige Flächen kennzeichnen die Spannweite der jeweiligen Regelkurve. Die Kompromissklassen sind Cl-1 in a), Cl-2 in b) und Cl-3 in c).

48 Pareto-optimalen Lösungen aus dem Szenario S-AKT initialisiert. Das Gewicht  $w_4$  ist auf 0,33 gesetzt. Die monatlichen Startwerte der neuen Regelkurve  $Z_s^{KL,0}$  werden mit der oberen Randbedingung  $Z^{\text{Bew,KL}} + Z^{\text{Bew,LM}}$  belegt.<sup>8</sup> Die resultierende Pareto-Menge aus der MKO umfasst 597 Kompromisslösungen.

**Modul E** Die Scatterplots (Abbildung C.16) zur Validierung der Lösungen aus der MKO zeigen eine mit S-AKT vergleichbar gute Übertragbarkeit der Kompromisslösungen. Auch für die zusätzliche Bereitstellungsstufe kann ein hoher linearer Zusammenhang zwischen den Ergebnissen in der MKO und der Validierung nachgewiesen werden. Die mittleren monatlichen Überleitungsraten der FF3 sind jedoch in der MKO deutlich überschätzt. Da die Stützung in der MKO voll ausgereizt wird, fehlen nach der Validierung Kompromisslösungen mit hohen mittleren monatlichen Überleitungsmengen in der Lösungsmenge. Von den 315 validierten Kompromisslösungen erweisen sich 165 Lösungen als weiterhin dominant.

**Modul F** Unter Verwendung der Methode RLA zur Wahl der repräsentativen Lösungen ergibt sich das Level-Diagramm nach Abbildung 8.28. Die drei gefundenen Kompromissklassen lassen sich drei Kategorien zuordnen. Die Separation der Kompromissklassen richtet sich primär nach dem Verlauf der Werte der Zielfunktion FF1, wobei die Kompromissklasse Cl-1 die geringsten 1-Normen enthält.

<sup>8</sup>Mit Rule-Curve-Stacking entspricht dies einem Wert von 1,0.

Nach Tabelle 8.10 liegen selbst die niedrigsten ermittelten Versorgungssicherheiten  $P(BSS\{1, \dots, 4\})$  weit über den geforderten Versorgungssicherheiten. So ist bereits  $P(BSS3)$  bei allen Lösungen mindestens auf dem Niveau der geforderten Versorgungssicherheit  $R(BSS2)$ . Die Sicherheiten der Bereitstellungsstufe BSS4 liegen im Bereich von 33,4% und 38,5%, wobei die niedrigsten und höchsten Versorgungssicherheiten der Kompromissklasse Cl-3 angehören. Die Lösung mit der niedrigsten Überleitungsmenge ( $\min(FF3)$ ) erfordert im Vergleich zur Lösung  $\min(FF3)$  im Szenario S-AKT eine knapp doppelte so hohe Überleitungsrate. Der mit Lösung  $\max(FF2)$  maximal erreichte Wasserqualitätsindikator beträgt 89,5% und ist 1,85% geringer als bei  $\max(FF2)$  in S-AKT.

Die optimierten Dispatcherpläne weisen nach Abbildung 8.29 Regelkurven mit bereits aus den Szenarien S-AKT und S-BEO bekannten Merkmalen auf. So existieren ausgeprägte Lamellen der Überleitungsstufe DIV2 über mehrere  $\text{hm}^3$  Stauinhalt nur in bestimmten Monaten (April und August). Die Lamellen der Bereitstellungsstufen zeigen einen ausgeprägteren innerjährlichen Verlauf. So erstreckt sich die Lamelle der BSS2 im Schnitt über einen Stauinhalt des Staukörpers von  $5 \text{ hm}^3$  und ist somit deutlich ausgeprägter als in den Szenarien S-AKT und S-BEO. Die zusätzliche Regelkurve  $Z^{\text{KL},0}$  weist hingegen, bis auf vereinzelt Lösungen in der Kompromissklasse Cl-3, kaum eine innerjährliche Dynamik auf. Die maximale Ausdehnung der Lamelle von BSS4 erstreckt sich von  $25,2 \text{ hm}^3$  bis auf  $29,29 \text{ hm}^3$ .




Abbildung 8.28: Level-Diagramm für das Szenario S-5RK. Dargestellt sind die erreichten Versorgungssicherheiten und Zielfunktionen. Die Lösungen sind in drei Kompromissklassen CI-1 (Rot), CI-2 (Grün) und CI-3 (Blau) unterteilt. Die zu den Kompromissklassen zugehörigen repräsentativen Lösungen sind hervorgehoben.




Abbildung 8.29: Darstellung der optimalen Regelkurven zur Steuerung der Trinkwasserabgabe (links) und der Überleitung (rechts) nach Kompromissklassen. Farbige Flächen kennzeichnen die Spannweite der jeweiligen Regelkurve. Die Kompromissklassen sind CI-1 in a), CI-2 in b) und CI-3 in c).

Tabelle 8.10: Erreichte Versorgungssicherheiten  $P(BSS \{1, \dots, 4\})$  und Zielfunktionswerte für das Szenario S-5RK.

Lösung	P(BSS1) (%)	P(BSS2) (%)	P(BSS3) (%)	P(BSS4) (%)	$FF1$ (-)	$FF2$ (%)	$FF3$ ( $\text{hm}^3$ je Monat)	1-Norm (-)
Cl-1	99,961	99,89	99,70	37,10	2,995	87,53	0,179	0,94
Cl-2	99,967	99,88	99,66	36,86	2,995	88,62	0,208	1,07
Cl-3	99,958	99,87	99,62	36,91	2,995	85,43	0,136	1,21
$\min(FF3)$	99,956	99,81	99,70	33,43	2,995	81,86	0,094	1,33
$\max(FF2)$	99,967	99,88	99,67	38,07	2,995	89,50	0,235	1,10
$\min(\text{Norm})$	99,955	99,81	99,70	33,58	2,995	82,85	0,097	0,83

### 8.5.6 Ergebnisse der Klimafolgenanalyse für das Talsperrenverbundsystem

Die Gliederung dieses Abschnitts sieht zunächst die Vorstellung der Ergebnisse der Zeitscheibe 2021-2050 vor. Die Optimierungen des Talsperrenverbundsystems KL-LM-RB für die Zeitscheibe 2071-2100 erfolgt im Anschluss. Weitere Parameter und Kennwerte zu den einzelnen Modulen sind in Tabelle C.8 zu finden.

#### Ergebnisse der Zeitscheibe 2021-2050

Die drei Szenarien S-2021-A1B, S-2021-A2 und S-2021-B1 geben einen Ausblick auf veränderte hydrologische Rahmenbedingungen, unter denen das Talsperrenverbundsystem KL-LM-RB bis zur Mitte des Jahrhunderts bewirtschaftet werden könnte. Nach Tabelle C.5 nehmen in WETTREG 2010 die mittleren Talsperrenzuflüsse für die Emissionsszenarien A1B und A2 um bis zu 25 % ab, während die mittleren Zuflüsse unter dem Emissionsszenario B1 so gut wie unverändert bleiben.

**Modul D** Pareto-optimale Kompromisslösungen des Szenarios S-AKT werden verwendet, um die psMO-CMA-ES für die multikriteriellen Optimierungen des Szenarios S-2021-A2 zu initialisieren. Die Initialisierung der evolutionären Strategie der Szenarien S-2021-A1B und S-2021-B1 basiert auf Kompromisslösungen des Szenarios S-2021-A2, da zu erwarten ist, dass dieses bereits besser an die Problemstellungen angepasst ist. Die aus den Optimierungen resultierenden Pareto-Mengen umfassen 2673 (S-2021-A1B), 3549 (S-2021-A2) und 799 (S-2021-B1) Kompromisslösungen.

**Modul E** Nach der Validierung verbleiben weiterhin 314 Pareto-optimale Lösungen für S-2021-A1B. Lediglich 57 bzw. 91 dominierende Lösungen verbleiben für S-2021-A2 und S-2021-B1. Dies liegt nach den Streudiagrammen (Abbildungen C.17) an den wenigen Lösungen, die für S-2021-A2 in  $FF2$  und für S-2021-B1 in  $FF1$  überdurchschnittliche Verbesserungen bringen. Die Lösungen sind jedoch über den gesamten Wertebereich verteilt,

was diese Unzulänglichkeiten etwas relativieren. Die Güte der Validierungsergebnisse des Szenarios S-2021-A1B lässt sich mit den Szenarien S-AKT und S-5RK vergleichen. Da die Stützleistung wie auch in S-5RK in der MKO voll ausgereizt wird, fehlen durch die Unterschätzung nach der Validierung Kompromisslösungen mit hohen mittleren monatlichen Überleitungsmengen in der Lösungsmenge.

**Modul F** Die Pareto-Mengen der Szenarien S-2021-A1B und S-2021-A2 lassen sich in jeweils fünf Kompromissklassen, Cl-1 bis Cl-5, unterteilen, S-2021-B1 erhält drei Kompromissklassen. Die repräsentativen Lösungen sind in S-2021-B1 mit Methode RLA ausgewählt. Um eine bessere Verteilung der repräsentativen Lösungen für die Szenarien S-2021-A1B und S-2021-A2 zu erreichen, wird für diese beiden Szenarien Methode RLB eingesetzt. Die Level-Diagramme für die separate Auswertung der Szenarien sind in Abbildung C.18 gegeben. Lösungen mit hohen mittleren monatlichen Überleitungsmengen um  $0,35 \text{ hm}^3$  je Monat bieten in S-2021-A1B und S-2021-A2 den besten Ausgleich zwischen allen Zielen.

Durch die geringe Anzahl der verbleibenden Lösungen und den somit gut separierten Kompromissklassen ist der Konflikt zwischen den Zielfunktionen im Level-Diagramm des Szenarios S-2021-A2 besonders einfach abzulesen. Vergleichbare mittlere monatliche Überleitungsmengen ( $FF3$ ) führen in der Kompromissklasse Cl-5 zu besseren Wassergüteindikatoren ( $FF2$ ), jedoch schlechteren Versorgungssicherheiten  $FF1$  als in Kompromissklasse Cl-2.

Tabelle 8.11 stellt die erreichten Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  und Zielfunktionswerte  $FF1$  bis  $FF3$  der repräsentativen Lösungen zusammen. Es existieren in den Szenarien S-2021-A1B und S-2021-A2 keine Kompromisslösungen, die allen geforderten Mindestversorgungssicherheiten  $R(\text{BSS} \{1, \dots, 3\})$  simultan entsprechen. Die ermittelten Lösungen scheitern an der geforderten Versorgungssicherheit der Bereitstellungsstufe  $P(\text{BSS}1)$  mit 99,95 %. In S-2021-A1B verfehlt die repräsentative Lösung Cl-1 die geforderte  $R(\text{BSS}1)$  um 0,062 %, in S-2021-B1 verfehlt Cl-3 diese um 0,032 %. Auch die Lösung sko ( $FF1$ ) der, zusätzlich mittels der CMA-ES durchgeführten, einkriteriellen Optimierung<sup>9</sup> führt zu keinen ausreichenden  $P(\text{BSS}1)$ . Mit  $L_{\text{Bal}}$  sind in Tabelle 8.11 zusätzliche Kompromisslösungen ausgewählt, die möglichst nahe an den geforderten  $R(\text{BSS} \{1, \dots, 3\})$  Werten liegen.

Einen Vergleich der drei Szenarien der Zeitscheibe 2021-2050, zusammen mit dem Szenario S-AKT gibt Abbildung 8.30. Die Lösungen der vier Szenarien bilden den gemeinsamen Pool zur Wertung der Kompromisslösungen mit der 1-Norm. Auf Kompromissklassen wird verzichtet, die Szenarien selber werden als ein Cluster betrachtet. Die Lösungen des Szenarios S-2021-A2 sind aus Gründen der Übersichtlichkeit auf den Bereich  $FF1 > 2,937$  beschränkt. Somit können in einem Level-Diagramm die Szenarien mithilfe der 1-Norm, der

<sup>9</sup>Als Zielfunktion wird ausschließlich  $FF1$  maximiert.

Tabelle 8.11: Erreichte Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  und Zielfunktionswerte für die Szenarien der Zeitscheibe 2021-2050 für ausgewählte Lösungen.

Lösung	P(BSS1) (%)	P(BSS2) (%)	P(BSS3) (%)	FF1 (-)	FF2 (%)	FF3 (hm <sup>3</sup> je Monat)	1-Norm (-)
Szenario S-2021-A1B							
Cl-1	99,888	99,76	99,43	2,991	63,79	0,317	0,83
Cl-2	99,539	99,34	98,63	2,975	32,90	0,159	1,33
Cl-3	99,570	99,32	96,44	2,953	32,41	0,152	1,71
Cl-4	99,768	99,62	99,19	2,986	42,37	0,209	1,08
Cl-5	99,624	99,50	98,97	2,981	35,20	0,173	1,21
L <sub>Bal</sub>	99,771	99,58	99,09	2,985	44,87	0,212	1,02
max(FF1)							
max(FF2)	99,909	99,83	99,53	2,993	74,38	0,468	1,00
sko(FF1)	99,911	99,90	99,85	2,997	71,55	0,416	
Szenario S-2021-A2							
Cl-1	99,628	99,37	98,87	2,979	55,53	0,103	0,86
Cl-2	97,100	96,73	96,12	2,900	39,23	0,036	1,31
Cl-3	99,918	99,85	99,52	2,993	76,55	0,410	1,03
Cl-4	99,882	97,53	73,74	2,711	71,89	0,205	1,35
Cl-5	97,774	89,69	81,82	2,693	50,33	0,009	1,47
L <sub>Bal</sub>	99,580	99,49	99,19	2,983	49,70	0,126	1,16
max(FF2)	99,921	99,90	99,82	2,996	72,55	0,232	0,69
sko(FF1)	99,915	99,90	99,88	2,997	75,88	0,372	
Szenario S-2021-B1							
Cl-1	99,997	99,98	99,96	2,999	84,14	0,102	0,64
Cl-2	99,986	99,98	99,89	2,998	76,03	0,044	0,90
Cl-3	99,993	99,93	99,85	2,998	74,63	0,037	1,00
max(FF1)							
max(FF2)	99,998	99,995	99,97	3,000	92,91	0,290	0,75
min(FF3)	99,964	99,63	99,09	2,987	69,93	0,015	1,20

Zielfunktionswerte und der Form der Hüllen um die Kompromisslösungen gegeneinander verglichen und bewertet werden.

Dem geringsten Stress untersteht das Talsperrenverbundsystem demnach unter dem Szenario S-2021-B1. Hier lassen sich die geringsten 1-Normen erreichen. Hierauf folgt das Szenario S-AKT. Sowohl die Wertebereiche als auch die Formen der Pareto-Fronten beider Szenarien sind im Level-Diagramm vergleichbar. Mit angepassten Steuerungsstrategien kann somit auch unter den Verhältnissen in S-2021-B1 eine leicht verbesserte Speicherleistung erreicht werden.

Unter S-2021-A2 und S-2021-A1B gerät das Talsperrenverbundsystem unter verstärkten Leistungsdruck, da die Zuflussdargebote bei gleichbleibenden Abgabeanforderungen geringer sind. Dementsprechend sind die zu realisierenden Überleitungsmengen höher.




Abbildung 8.30: Level-Diagramm für die Szenarien der Zeitscheibe 2021-2050. Dargestellt sind die erreichten Versorgungssicherheiten und Zielfunktionen der jeweiligen Szenarien. Die Wertung der Kompromisslösungen basiert auf allen vier Pareto-Mengen. Die strich-punktierten Linien kennzeichnen jeweils  $R(\text{BSS} \{1, \dots, 3\})$ .

Nach dem Wassergüteindikator  $FF2$  ist mit einer zukünftigen Abnahme der Wasserqualität zu rechnen. Diesbezüglich schneidet S-2021-A1B am schlechtesten ab. Trotz der von S-2021-A2 nach S-2021-A1B zunehmenden mittleren monatlichen Überleitungsmengen sinken die erreichbare Wasserqualität und die Versorgungssicherheiten zusehens ab.

Tabelle 8.12 vergleicht die Leistungsfähigkeit des Talsperrenverbundsystems unter den rezenten Steuerungsstrategien ( $L_{\text{Hist}}$ ) mit Kompromisslösungen  $L_{\text{Opt}}^*$  aus den Pareto-Mengen. Die Kompromisslösungen  $L_{\text{Opt}}^*$  wurden so gewählt, dass diese möglichst vergleichbare Überleitungsmengen besitzen.

Der Vergleich der Lösungen  $L_{\text{Hist}}$  und  $L_{\text{Opt}}^*$  bestätigt die deutliche Unterschätzung der zukünftig möglichen Leistungsfähigkeit bei einer einfachen Simulationsstudie ohne Adaption der Steuerungsstrategien. Die Versorgungssicherheiten und der Wasserqualitätsindikator sind unter  $L_{\text{Hist}}$  deutlich geringer.

Die zu den Kompromissklassen der jeweiligen Level-Diagramme zugehörigen Regelkurven als zugehörige „No-regrets“-Anpassungsmaßnahmen sind in den Abbildungen C.19 zu finden. Die geringe Variabilität der Regelkurven einer Kompromissklasse lässt sich an den geringen Spannweiten der farbigen Flächen erkennen. Ersichtlich ist der, im Vergleich zu

Tabelle 8.12: Vergleich der Simulationsergebnisse unter der aktuellen Steuerungsstrategie  $L_{\text{Hist}}$  und Ergebnissen von Lösungen  $L_{\text{Opt}}^*$  aus der MK-SBO mit ähnlichen  $FF3$ .

Lösung	P(BSS1) (%)	P(BSS2) (%)	P(BSS3) (%)	$FF1$ (-)	$FF2$ (%)	$FF3$ ( $\text{hm}^3$ je Monat)
S-2021-A1B						
$L_{\text{Hist}}$	99,901	93,839	88,706	2,824	40,46	0,240
$L_{\text{Opt}}^*$	99,755	99,624	99,50	2,989	49,48	0,234
S-2021-A2						
$L_{\text{Hist}}$	99,848	94,45	90,48	2,848	58,78	0,184
$L_{\text{Opt}}^*$	99,863	99,81	99,74	2,994	65,67	0,168
S-2021-B1						
$L_{\text{Hist}}$	100,00	99,665	98,918	2,986	80,13	0,086
$L_{\text{Opt}}^*$	99,953	99,87	99,67	2,995	81,79	0,084

S-AKT, deutlich unruhigere innerjährliche Verlauf der Staulamellen in den Clustern unter S-2021-A2 und S-2021-A1B.

### Szenarien der Zeitscheibe 2071-2100

Nach Tabelle C.5 nehmen mit WETTREG 2010 die mittleren Talsperrenzuflüsse in allen Emissionsszenarien der Zeitscheibe um bis zu 50 % ab. Als vorgezogene Anpassungsmaßnahme werden in den Szenarien daher die Abgaben des Talsperrenverbundsystems bei gleichbleibenden geforderten Versorgungssicherheiten nach Abschnitt 8.5.3 reduziert. Die maximale Abgabe beträgt nunmehr  $0,75 \text{ m}^3 \text{ s}^{-1}$  wobei die Staffelung der Abgaberraten in Schritten zu  $0,075 \text{ m}^3 \text{ s}^{-1}$  beibehalten wird.

**Modul D** Ähnlich zum Vorgehen in der Zeitscheibe 2021-2050 wird zunächst die Optimierung S-2071-A1B durchgeführt. Die Initialisierung des Optimierungslaufs basiert auf den Ergebnissen des Szenarios S-2021-A1B. Die MKO der Szenarien S-2071-A2 und S-2071-B1 bauen dann, durch die Verwendung von Pareto-optimalen Lösungen aus der Lösungsmenge S-2071-A1B, auf diesem Szenario auf. Nach Tabelle C.8 umfassen die Pareto-Mengen der drei MKO zwischen 4344 und 6187 Kompromisslösungen.

**Modul E** Das anschließende nicht-dominierende Sortieren der 355 bis 359 validierten Kompromisslösungen verringert die Lösungsmengen auf 257 bis 283 weiterhin dominierende Lösungen. Die Streudiagramme der Szenarien S-2071-A1B, S-2071-A2 und S-2071-B1 (Abbildung C.22) weisen für P(BSS1) und P(BSS2) Heteroskedastizität auf, da die Varianzen bei geringen Versorgungssicherheiten deutlich höher sind als für höhere. Dies wird auf die Zielfunktion  $FF1$  übertragen. Trotzdem herrscht in allen Szenarien ein hoher linearer Zusammenhang zwischen MKO und Validierung.






Abbildung 8.31: Level-Diagramm für das Szenario der Zeitscheibe 2071-2100. Dargestellt sind die erreichten Versorgungssicherheiten und Zielfunktionen nach Szenarien. Die Wertung der Kompromisslösungen umfasst simultan alle vier Pareto-Mengen. Die strich-punktierten Linien kennzeichnen jeweils  $R(\text{BSS} \{1, \dots, 3\})$ .

**Modul F** Die zum Erstellen der Level-Diagramme (Abbildung C.20) angewandte SOM-Clustering erzielt sechs Kompromissklassen für S-2071-A1B und jeweils fünf für die Szenarien S-2071-A2 und S-2071-B1. Die repräsentativen Lösungen werden jeweils mit Methode RLA bestimmt. Die zu den Kompromissklassen der jeweiligen Level-Diagramme zugehörigen Regelkurven sind in den Abbildungen C.21 zu finden. Der durch den Rückgang der Zuflussdargebote gestiegene Leistungsdruck führt zu einer nunmehr hohen Variabilität an unterschiedlich ausgeprägten Regelkurven je Kompromissklasse. Der innerjährliche Verlauf der Staulamellen ist deutlich unruhiger. Mit zunehmendem Leistungsdruck sind daher mehr Kompromissklassen nötig, damit eine Kompromissklasse eine definierbare Art an zugehörigen Steuerungsstrategien aufweisen kann.

Die Abbildung der Ergebnisse durch die Level-Diagramme unter Verwendung der 1-Norm zeigt, dass in dieser Zeitscheibe die höchsten Überleitungsmengen den ausgeglichensten Kompromiss darstellen. Der bisher zumeist vorhandene Wiederanstieg der 1-Normen nach Überschreiten eines bestimmten  $FF3$  Wertes (die „U-Form“) kann hier nicht ausgemacht werden. Mit zunehmender Stützleistung  $FF3$  können sowohl das Ziel einer hohen Wasserqualität  $FF2$  als auch einer hohen Versorgungssicherheit  $FF1$  zunehmend besser erreicht werden. Die Leistung des Talsperrenverbundsystems ist daher in höchstem Maße von der Stützleistung der Talsperre Rauschenbach abhängig.

Tabelle 8.13: Erreichte Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  und Zielfunktionswerte für die Szenarien der Zeitscheibe 2071-2100 für ausgewählte Lösungen.

Lösung	P(BSS1) (%)	P(BSS2) (%)	P(BSS3) (%)	$FF1$ (-)	$FF2$ (%)	$FF3$ ( $\text{hm}^3$ je Monat)	1-Norm (-)
S-2071-A1B							
Cl-1	98,975	98,59	96,47	2,940	19,99	0,289	1,41
Cl-2	98,547	97,16	89,25	2,850	13,44	0,247	1,57
Cl-3	95,216	93,90	91,50	2,806	12,57	0,197	1,53
Cl-4	99,523	99,37	98,00	2,969	60,20	0,421	0,97
Cl-5	98,929	94,90	75,49	2,693	31,64	0,276	1,58
Cl-6	96,649	95,24	81,03	2,729	17,16	0,225	1,65
sko( $FF1$ )	99,652	98,92	97,36	2,959	60,84	0,467	
S-2071-A2							
Cl-1	99,790	99,75	99,02	2,986	62,72	0,462	1,00
Cl-2	98,580	97,03	92,72	2,883	17,09	0,277	1,51
Cl-3	98,100	96,84	88,10	2,830	12,24	0,251	1,61
Cl-4	93,789	92,97	86,27	2,730	8,07	0,187	1,67
Cl-5	93,912	90,68	71,14	2,557	12,39	0,164	1,78
sko( $FF1$ )	99,871	99,62	98,53	2,980	64,43	0,509	
S-2071-B1							
Cl-1	99,332	98,89	97,57	2,958	18,52	0,296	1,40
Cl-2	98,979	98,03	88,08	2,851	10,76	0,249	1,58
Cl-3	99,806	99,76	99,03	2,986	65,25	0,469	1,00
Cl-4	98,949	97,60	75,02	2,716	25,93	0,266	1,59
Cl-5	96,937	93,92	75,13	2,660	18,09	0,220	1,69
sko( $FF1$ )	99,745	99,66	99,50	2,989	47,72	0,432	

Tabelle 8.13 listet die Ergebnisse der repräsentativen Lösungen auf. Die repräsentative Lösung mit der geringsten 1-Norm ist jeweils die Lösung mit der höchsten mittleren monatlichen Überleitungsmenge. Es ist ersichtlich, dass hohe Überleitungsmengen über  $0,4 \text{ hm}^3$  je Monat bereitzustellen sind, um einen Wasserqualitätsindikator von etwa 60 % und hohe, wenn auch ungenügende, Versorgungssicherheiten zu ermöglichen. Vor allem bei geringeren Überleitungsmengen erfordert der Zielkonflikt zwischen  $FF1$  und  $FF2$  die Entscheidung zwischen bedenklichen Wassergüteindikatoren  $FF2$  unter 30 % oder einer unsichereren Trinkwasserbereitstellung. Die validierten Lösungsmengen für alle drei Szenarien enthalten keine Kompromisslösungen mit durchweg ausreichenden Versorgungssicherheiten. Auch durch die einkriteriellen Optimierungen können keine Lösungen mit gültigen Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  gefunden werden.

Wie bereits im Abschnitt 8.5.6 soll mit Abbildung 8.31 eine Übersicht der Ergebnisse in der Zeitscheibe 2071-2100 anhand eines Level-Diagramms gegeben werden. Anhand der deckungsgleichen Lage der Hüllen um die Kompromisslösungen im Level-Diagramm kann

Tabelle 8.14: Vergleich der Simulationsergebnisse unter der aktuellen Steuerungsstrategie  $L_{\text{Hist}}$  und Ergebnissen von Lösungen  $L_{\text{Opt}}^*$  aus der MK-SBO mit ähnlichen  $FF3$ .

Lösung	P(BSS1) (%)	P(BSS2) (%)	P(BSS3) (%)	$FF1$ (-)	$FF2$ (%)	$FF3$ ( $\text{hm}^3$ je Monat)
S-2071-A1B						
$L_{\text{Hist}}$	99,874	89,29	81,84	2,720	22,78	0,308
$L_{\text{Opt}}^*$	99,330	98,25	93,71	2,913	29,85	0,307
S-2071-A2						
$L_{\text{Hist}}$	99,973	90,20	82,11	2,723	21,16	0,314
$L_{\text{Opt}}^*$	99,257	98,170	96,88	2,901	29,56	0,314
S-2071-B1						
$L_{\text{Hist}}$	99,943	90,37	82,11	2,903	20,96	0,314
$L_{\text{Opt}}^*$	99,258	98,17	96,89	2,909	29,56	0,315

auf eine einheitliche Speicherleistung des Talsperrenverbundsystems in den Szenarien der Zeitscheibe 2071-2100 geschlossen werden. Die Lösungen mit der jeweils geringsten 1-Norm liegen im Diagramm nahe beieinander und teilen sich ähnliche Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  und Zielfunktionswerte. Weiterhin besitzen die repräsentativen Lösungen des Level-Diagramms in Abbildung 8.31 zugehörige Regelkurven mit gleichartigen Merkmalen bezüglich der innerjährigen Staulamellenverläufe (Abbildung C.15). Dies unterstreicht die Ähnlichkeit der Rahmenbedingungen und des Verhaltens des Talsperrensystems in den Szenarien zusätzlich.

Wie auch in der Zeitscheibe 2021-2050 stellt Tabelle 8.14 den Vergleich der Leistungsfähigkeit anhand der rezenten Steuerungsstrategien ( $L_{\text{Hist}}$ ) und optimaler Kompromisslösungen  $L_{\text{Opt}}^*$  mit ähnlichen Überleitungsmengen dar. Die zukünftig mögliche Leistungsfähigkeit würde in einer Klimafolgenanalyse unter einfacher Simulation mit historischen Steuerungsstrategien bezüglich der Versorgungssicherheiten und des Wasserqualitätsindikators in der letzten Zeitscheibe deutlicher unterschätzt werden als in der Zeitscheibe 2021-2050.

### 8.5.7 Leistungsfähigkeit des Frams-BoT

Die Streudiagramme im zurückliegenden Abschnitt zeigen für die Szenarien gute bis ausreichende lineare Zusammenhänge zwischen der MKO und der Validierung. Mit Tabelle 8.15 und Tabelle 8.16 sollen die linearen Regressionen als Werkzeug der Validierung durch die Angaben der  $R^2$  Statistiken, sowie der Standardabweichung der Residuen  $\sigma$  ergänzt werden.

Die  $R^2$ -Statistiken sind demnach vor allem für  $P(\text{BSS} \{1, \dots, 3\})$  in den Szenarien mit geringerer Auslastung des Talsperrensystems, S-BEO, S-AKT, S-5RK und S-2021-B1 kleiner als in den übrigen Szenarien der Klimaprojektionen. Vor allem für  $P(\text{BSS3})$  sind die  $R^2$  geringer als 0,7. Die Residuenanalyse (Tabelle 8.16) zeigt jedoch, dass die Standard-

Tabelle 8.15: Bestimmtheitsmaße  $R^2$  zwischen den in der MKO und Validierung erzielten Versorgungssicherheiten und Zielfunktionswerten.

Szenario	$R^2$ (-) nach Zielfunktionen und Versorgungssicherheiten						
	P(BSS1)	P(BSS2)	P(BSS3)	P(BSS4)	FF1	FF2	FF3
S-BEO	0,77	0,597	-		0,762	0,969	0,998
S-AKT	0,969	0,889	0,464		0,956	0,982	1,00
S-5RK	0,676	0,887	0,455	0,99	0,725	0,984	1,00
S-2021-A1B	0,997	0,994	0,996		0,998	0,999	1,00
S-2021-A2	0,992	0,982	0,989		0,988	0,957	0,993
S-2021-B1	0,968	0,922	0,657		0,970	0,988	0,997
S-2071-A1B	0,997	0,993	0,992		0,995	0,991	0,998
S-2071-A2	0,990	0,994	0,999		0,992	0,986	0,988
S-2071-B1	0,998	0,997	0,998		0,999	0,997	0,999

abweichungen der Residuen  $\sigma$  für S-AKT, S-5RK und S-2021-B1 eine Potenz geringer ist als die letzte signifikante Stelle der Versorgungssicherheit. S-BEO schneidet hier im Vergleich zu S-AKT schlechter ab. Der kurze Simulationszeitraum verhindert in S-BEO eine verlässliche Optimierung der Versorgungssicherheiten und Zielfunktionen. Neben den höheren Standardabweichungen der Residuen konnte auch ein großer Anteil der Pareto-Front mit niedrigen, aber ausreichenden  $P(\text{BSS} \{1, \dots, 3\})$  nicht abgedeckt werden. Die schlechteste Übertragbarkeit der Lösungen aus der MKO wird unter Szenario 2021-A1B erreicht. Trotz des längsten Zeitraums in der MKO von 1138 Jahren erweisen sich die rekombinierten 250 Trockenperioden als zu wenig, um das hydrologische Regime ausreichend abzubilden. Die hohen Standardabweichungen der Residuen der Szenarien in der Zeitscheibe 2071-2100 waren zum großen Teil auf die hohe Varianz der Residuen bei geringen Versorgungssicherheiten zurückzuführen. Geringe Standardabweichungen der Residuen und hohe  $R^2$ -Statistiken belegen für die Zielfunktionen  $FF3$  und  $FF2$  jeweils eine gute Übertragbarkeit, von systematischen Über- und Unterschätzungen und von den Problemen im Szenario S-2021-A1B abgesehen.

Abschließend soll die Einsparung an Rechenzeit für das Szenario S-AKT mit Frams-BoT betrachtet werden. Die mit der Monte-Carlo-Rekombination erzeugte Proxyzeitreihe besitzt eine Länge von 882 Jahren. Die Rechenzeit<sup>10</sup> eines einzelnen Simulationslaufs der Talsperrenbewirtschaftung mit dem in OASIS implementierten Talsperrenverbundsystem beträgt 30 Sekunden. Die Gesamtlaufzeit ist bei einer Verwendung von 8 Kernen  $T_R = 30 \text{ s} * \frac{96\,000 \text{ Evaluationen}}{8 \text{ Threads}} = 365\,360 \text{ s} = 4,2 \text{ Tage}$ . Eine entsprechende Simulation mit OASIS über den Zeitraum von 10 000 Jahren erfordert 335 Sekunden. Somit ergibt sich für eine MK-SBO, ohne Parallelisierung und unter einer Langfristsimulation über die kompletten 10 000 Jahre, eine Gesamtlaufzeit von  $T_R = 335 \text{ s} * \frac{96\,000 \text{ Evaluationen}}{1 \text{ Thread}} = 32,1\text{E}6 \text{ s} = 372 \text{ Tage}$ .

<sup>10</sup>AMD FX 8150, 3,6 GHz

Tabelle 8.16: Standardabweichung der Residuen  $\sigma$  der linearen Regression zwischen den in der MKO und Validierung erzielten Versorgungssicherheiten und Zielfunktionswerten.

Szenario	$\sigma$ nach Zielfunktionen und Versorgungssicherheiten						
	P(BSS1) (%)	P(BSS2) (%)	P(BSS3) (%)	P(BSS4) (%)	FF1 (-)	FF2 (%)	FF3 (hm <sup>3</sup> je Monat)
S-BEO	0,089	0,055	0,047		0,002	0,791	0,003
S-AKT	0,045	0,020	0,006		0,001	0,474	0,001
S-5RK	0,032	0,007	0,003	0,122	0,000	0,292	0,001
S-2021-A1B	0,055	0,032	0,014		0,001	0,490	0,001
S-2021-A2	0,677	0,454	0,114		0,010	1,892	0,006
S-2021-B1	0,032	0,017	0,005		0,000	0,466	0,002
S-2071-A1B	0,600	0,332	0,243		0,010	0,884	0,003
S-2071-A2	1,196	0,345	0,100		0,014	1,158	0,008
S-2071-B1	0,495	0,261	0,126		0,006	0,623	0,002

Dies bedeutet eine Reduktion der Rechenzeit um den Faktor 89 unter Verwendung von Frams-BoT. Der Faktor 89 ergibt sich dabei als Anzahl der Threads mal dem Verhältnis aus der Länge der ursprünglichen Zeitreihe und der Proxyzeitreihe zusammen.

## 8.6 Zusammenfassung

In dieser Fallstudie wurden multikriterielle simulationsbasierte Optimierungen für das Mehrzweck-Talsperrenverbundsystem Klingenberg, Lehmühle und Rauschenbach mit der Strategie Frams-BoT durchgeführt. Eine besondere Herausforderung lag dabei in der verlässlichen Maximierung von drei Versorgungssicherheiten  $P(\text{BSS} \{1, \dots, 3\})$  der gestaffelten Rohwasserabgabe der Talsperre Klingenberg in einer Zielfunktion der multikriteriellen Optimierung. Je nach Abgabestufe sind unterschiedlich hohe Versorgungssicherheiten von mindestens 99 % zu gewährleisten. Weitere Ziele der Optimierung sahen darüber hinaus die Maximierung eines Wassergüteindikators und die Minimierung der kostenintensiven Stützung mit Rohwasser durch die Talsperre Rauschenbach vor.

In einem ersten Themenkomplex wurde Frams-BoT mit rezenten Rahmenbedingungen angewendet. Es erfolgte der Vergleich der Strategie mit einer einfachen multikriteriellen Optimierung anhand von 86 Jahren beobachteter Zuflüsse. Zusätzlich wurde die Strategie für die Auswertung einer planungstechnischen Änderung am Talsperrenverbundsystem angewandt. Im zweiten Themenkomplex wurden innerhalb einer Klimafolgenanalyse die zukünftig möglichen Spannungsfelder (Pareto-Fronten) der konträren Bewirtschaftungsziele ermittelt.

In beiden Themenkomplexen wurden die beobachteten oder projizierten Zuflüsse zunächst multivariat auf 10 000 Jahre verlängert, um die Datengrundlage signifikant zu

erweitern. Das neu entwickelte HKNN-SMA-Zeitreihenmodell, mit dem die langjährigen Zeitreihen generiert wurden, erwies sich dabei als effizient und leistungsfähig. Wichtige statistische Kennwerte blieben in den synthetischen Zeitreihen der vier lokalen Zuflüsse des Talsperrenverbundsystems inklusive der Autokorrelationsstruktur auf der jährlichen Zeitskala erhalten.

Mit der Monte-Carlo-Rekombinationsmethode konnten dann aus den langjährigen Zeitreihen um den Faktor 10 verkürzte Proxyzeitreihen generiert werden. Die wichtigsten statistischen Kennwerte und die Verteilung der Defizitvolumina der Trockenperioden, blieben dabei erhalten.

In den beiden Themenkomplexen konnte anhand der durchgeführten Optimierungen gezeigt werden, dass es mit Frams-BoT möglich ist, (1) Versorgungssicherheiten verlässlich als Teil eines multikriteriellen Optimierungsproblems zu maximieren, um somit die Leistungsfähigkeit eines wasserwirtschaftlichen Systems zu steigern. (2) Durch die Kombination verschiedener Methoden konnte eine Reduktion der Rechenzeit erreicht werden, um so in der MK-SBO effektiv eine Datengrundlage von mehreren Tausend Jahren nutzen zu können. Die Anwendung der Strategie zeigte deutliche Vorteile gegenüber der MK-SBO mit beobachteten Zeitreihen. (3) Das Framework konnte durch die geringen Rechenzeiten für eine Klimafolgenanalyse unter mehreren Szenarien eingesetzt werden. Pareto-Fronten mit einer Fülle zukünftig möglicher Kompromisslösungen konnten ermittelt und die zukünftig möglichen Konfliktfelder aufgezeigt werden.

Durch den Einsatz einer multikriteriellen Entscheidungshilfe wurden die umfangreichen Ergebnisse zugleich visualisiert, gewertet und auf wenige repräsentative Lösungen reduziert. Hier konnte weiterhin demonstriert werden, dass es mit Level-Diagrammen möglich ist, (1) Kennwerte darzustellen, die nicht in die Wertung einfließen, aber für die Entscheidungsfindung mit relevant sein können und (2) diese genutzt werden können, um unabhängige Pareto-Mengen aus mehreren MKO miteinander zu vergleichen.

## 9 Fallstudie 2: Mehrzweck-Talsperrenverbundsystem in Äthiopien

Im Fokus der Fallstudie 2 steht ein Mehrzweck-Speicherverbundsystem im Einzugsgebiet des Tanasees, Äthiopien. Die Anwendbarkeit der Frams-BoT-Strategie soll anhand von verschiedenen Szenarien überprüft werden. Diese unterscheiden sich in der Anzahl der Entscheidungsvariablen, der Anzahl der Zielfunktionen und der Länge des Simulationszeitraums in der multikriteriellen simulationsbasierten Optimierung. Eine ausreichend hohe Wasserspiegellage des Tanasees ist ein wichtiges Bewirtschaftungsziel. Daher sollte die minimal auftretende Wasserspiegellage  $\min(h^{\text{Tana}})$  möglichst hoch sein. Die Formulierung einer Maximierung der minimalen Wasserspiegellage zeigte sich jedoch in Voruntersuchungen als problematisch. Als Extremwert einer Verteilung erwies sich  $\min(h^{\text{Tana}})$  als zu restriktiv in der MK-SBO und nur wenige Kompromisslösungen mit geringer Diversität wurden erreicht. Daher wurde die Maximierung des mittleren Wasserstands als Zielfunktion gewählt.

### 9.1 Beschreibung des Talsperrenverbundsystems

Der Tanasee ist Äthiopiens größter und höchstgelegener Süßwassersee und liegt zwischen den 10.95°N und 12.78°N Höhengraden und zwischen den 36.89°E und 38.25°E Breitengraden. Der See füllt eine Senke im Hochland von Abessinien, 1 786 m.ü.NN (Saliha, 2012). Die Seeoberfläche beträgt, je nach Füllvolumen, zwischen 2 950 km<sup>2</sup> und 3 260 km<sup>2</sup>. Die maximale Ausdehnung des Sees wird im Oktober und die minimale Ausdehnung zwischen Mai und Juni erreicht (Kebede et al., 2006). Die Einzugsgebietsfläche umfasst 15 321 km<sup>2</sup> (Alemayehu et al., 2009).

Das vorherrschende Klima im Einzugsgebiet ist kalt-semiarid. Die Hauptregenzeit, die den Großteil der mittleren jährlichen Niederschlagssumme von 1 326 mm liefert, beginnt im Juni und endet im September (Saliha, 2012). Mehr als 40 Flüsse speisen den Tanasee. Jedoch verteilen sich 93 % des Zustroms auf lediglich vier Flüsse, Gilgel-Abay (Blauer Nil), Ribb, Gumera und Koga (siehe Abbildung 9.6). Die Evaporation von der Seeoberfläche stellt das ganze Jahr hindurch eine nicht unerhebliche Größe im Wasserhaushalt des Sees dar und liegt in der Summe in der Größenordnung der Einträge durch Niederschläge (Kebede et al., 2006). Die innerjährliche Verteilung der Wasserhaushaltsgrößen des Tanasees illustriert Abbildung 9.1.




Abbildung 9.1: Wasserhaushalt des Tanasees (nach Kebede et al., 2006).

Der Tanasee ist von großer Bedeutung für Äthiopien und besonders für die umliegende Region. Die Nahrungsmittelproduktion stützt sich auf die Landwirtschaft im Einzugsgebiet und die Fischerei im See. Wichtige Transportwege führen über den See und werden durch die Schifffahrt aufrecht erhalten. Lokale Kultur- und Naturschätze sind wichtig für die nationale Identität und bringen Einnahmen durch den Tourismus (Saliha, 2012).

Um die großen, ungenutzten wirtschaftlichen und landwirtschaftlichen Potenziale des Einzugsgebiets zu erschließen, wurden seit dem Ende des 20. Jahrhunderts große Anstrengungen unternommen. Mit dem Bau des Chara-Chara Stauwehrs am einzigen Ausfluss des Tanasees im Jahr 1996 kann der Stauinhalt bewirtschaftet werden. Die Wasserkraftwerke Tis-Abay I und II (Betrachtung entfällt hier) können so kontrolliert mit Wasser aus dem See versorgt werden. Ein weiteres Kraftwerk im angrenzenden Belles-Einzugsgebiet turbinert das Wasser aus dem Tanasee unter Ausnutzung der 311 Meter Höhendifferenz. Das Tana-Belles genannte Kraftwerk hat eine Ausbauleistung von 460 MWh und wird mit 48 % ausgelastet. Oberstromig des Tanasees wurden vier Talsperren errichtet, die primär Wasser für die Bewässerungslandwirtschaft auf neu projektierten landwirtschaftlichen Flächen zur Verfügung stellen. Diese sind die Talsperren Megech, Koga, Ribb und Gumera (Abbildung 9.6).

Aus den vielfältigen Nutzungen des Systems resultieren Konflikte zwischen den Bewirtschaftungszielen Bewässerungswasserbereitstellung, Stauhöhe des Tanasees, ökologische Mindestdurchflüsse, Einhaltung der Mindestdurchflüsse für touristische Zwecke (vor allem Mindestdurchflüsse für den Wasserfall Tis-Issat) und Energieerzeugung.

## 9.2 Datengrundlagen

Die Datengrundlage umfasst zehn Zuflusszeitreihen in monatlicher Auflösung im Zeitraum 1985-2005 und entstammt der Arbeit von Saliha et al. (2011). Die lokalen Zuflüsse werden in






Abbildung 9.2: Autokorrelogramme aller lokalen Zuflüsse nach Knoten (Abbildung 9.6) auf jährlicher Zeitskala.

den weiteren Abschnitten anhand der zugehörigen Konten im Talsperrenbewirtschaftungsmodell benannt (Abbildung 9.6). Die mittleren monatlichen Zuflüsse sind in Tabelle D.3 zusammengefasst. Innerjährliche Bedarfvorgaben für die Bewässerungsprojekte und die ökologischen Mindestdurchflüsse sind aus Saliha (2012) entnommen und in Tabelle D.4 einzusehen, für genauere Angaben zu den Evaporationsverlusten und Niederschlagseinträgen der Speicher soll ebenfalls auf diese Arbeit verwiesen werden.

### 9.3 Stochastische Zeitreihengenerierung (Modul B)

Abbildung 9.2 zeigt die Kreuzkorrelationsmatrix zwischen den monatlichen Lag-1 Autokorrelationskoeffizienten der einzelnen lokalen Zuflüsse. Es lassen sich vier Cluster mit hohen Korrelationskoeffizienten zwischen den einzelnen lokalen Zuflüssen ausmachen. Der erste Cluster umfasst die lokalen Zuflüsse der Knoten 80, 81 und 402, der zweite Cluster 82, 83, 84 und 401, der dritte Cluster 403 und 404, während der lokale Zufluss am Knoten 86 keinem Cluster zugehört.

Anhand dieser Cluster wird das HKNN-SMA-Modell mit vier Sätzen zu je 12 KNN aufgebaut (Abschnitt 6.2). Jeder Satz KNN ist für die Simulation der monatlichen Durchflüsse der lokalen Zuflüsse entsprechend eines Clusters zuständig.

Die KNN werden mit den 20-jährigen Zuflusszeitreihen trainiert, um jeweils die Zuflüsse des nächsten Monats zu schätzen. Mit Vor- und Nachlauf für den SMA-Filter beträgt die zu generierende Zeitreihenlänge 123 600 Monate (bei  $q = 150$ ), wovon je 300 Monate am Anfang und Ende der Zeitreihe verworfen werden.

Die Tabellen D.5, D.6, D.7 und D.8 erlauben den Vergleich von Statistiken zwischen den einzelnen synthetischen Zuflusszeitreihen und der Datengrundlage. Zusammenfassend

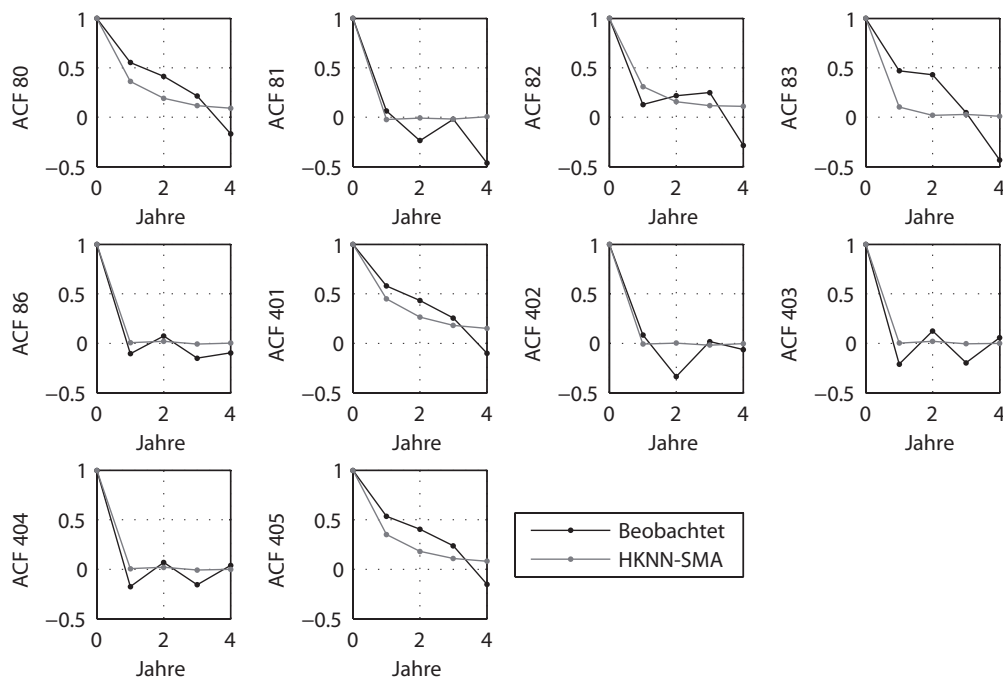


Abbildung 9.3: Autokorrelogramme aller lokalen Zuflüsse nach Knoten (Abbildung 9.6) auf jährlicher Zeitskala.

können die Mittelwerte  $\mu$  der originalen Zeitreihen mit sehr geringen Abweichungen und ohne systematischen Bias für alle lokalen Zuflüsse an den Knoten des Modells wiedergegeben werden. Ebenso bleiben die Standardabweichung  $\sigma$  und die Schiefe  $\xi$  auf monatlicher und jährlicher Zeitskala erhalten. Größere Abweichungen sind auf jährlicher Zeitskala für die Lag-1 Autokorrelationskoeffizienten  $r_1$  erkennbar, die für einzelne Zeitreihen unterschätzt werden. Dies ist ebenso in den Autokorrelogrammen der Zuflüsse in Abbildung 9.3 ersichtlich. Trotz der nachträglichen Filterung der Zeitreihen mit dem SMA-Filter können die Autokorrelationsstrukturen auf jährlicher Zeitskala nicht immer zufriedenstellend abgebildet werden. Die geschätzten Hurst-Koeffizienten ( $H_{\text{Knoten}}$ ), mit denen die SMA-Filter für die einzelnen Zeitreihen parametrisiert wurden, sind  $H_{80} = 0,67$ ,  $H_{81} = 0,52$ ,  $H_{82} = 0,54$ ,  $H_{83} = 0,51$ ,  $H_{86} = 0,50$ ,  $H_{401} = 0,69$ ,  $H_{402} = 0,50$ ,  $H_{403} = 0,50$ ,  $H_{404} = 0,50$  und  $H_{405} = 0,70$ . Für den lokalen Zufluss 83 resultiert die geringe Autokorrelationsstruktur, mit den unterschätzten Autokorrelationskoeffizienten  $r_1$  und  $r_2$ , aus dem geschätzten Hurst-Koeffizienten von  $H_{83} = 0,51$ .

Mit Abbildung 9.4 soll abschließend der erfolgreiche Erhalt der Kreuzkorrelationen anhand der lokalen Zuflüsse in den Einzugsgebieten der Flüsse Gumera (404-83, 86-83) und Megech (401-80) sowie zwischen dem Zufluss des Speichers Megech und des Tanasees (401-405) demonstriert werden.




Abbildung 9.4: Monatliche und jährliche Kreuzkorrelationen lokaler Zuflüsse nach ausgewählten Knoten des Talsperrenbewirtschaftungsmodells (Abbildung 9.6). Die Boxplots zeigen die Verteilungen der Korrelationskoeffizienten der in 20 Jahre unterteilten synthetischen Zeitreihe, die schwarze Linie die der beobachteten Zuflüsse.

## 9.4 Monte-Carlo-Rekombination (Modul C)

Die Dummy-Zeitreihe zur Monte-Carlo-Rekombination (MCR) der synthetischen langjährigen Zeitreihe wird aus den monatlichen Summen aller zehn Zuflüsse gebildet. Der konstante Schwellenwert  $c_{\text{crit}}$  für den FSA wird als die mittlere monatliche Summe aus allen Bewässerungsanforderungen (Knoten 580, 571, 572 und 573), Trinkwasserabgaben (Knoten 577) und Mindestdurchflüssen (Knoten 575) angesetzt und beträgt  $3\,167\text{ hm}^3$  je Monat. Über einem Schwellenwert  $P_T$  von 0,8 besitzt die ECDF der Defizitvolumina der rekombinierten Dummy-Zeitreihe mit der beobachteten ECDF einen Korrelationskoeffizienten von 0,91. Die Gesamtlänge der Dummy-Zeitreihe und somit aller Proxyzeitreihen ist 679 Jahre. Aus der Abfolge der Trockenperioden für die Dummy-Zeitreihe können weiterhin 10 Proxyzeitreihen für die 10 lokalen Zuflüsse generiert werden. Weitere Parameterwerte und Kenngrößen zur MCR listet Tabelle D.9 auf.

Abbildung 9.5 (a) zeigt eine gute Übereinstimmung der ECDF zwischen der rekombinierten und der synthetischen Dummy-Zeitreihe auch unterhalb des Schwellenwerts  $P_T$ . Nur leichte Abweichungen sind in Abbildung 9.5 (b) für die statistischen Kennwerte der Schiefe und den innerjährlichen Autokorrelationskoeffizienten der Dummy-Zeitreihe festzustellen. Den Erhalt der statistischen Kennwerte in den Proxyzeitreihen zeigen die Abbildungen D.1, D.2, D.3 und D.4 auf Seite 242 beispielhaft für die lokalen Zuflüsse 401, 402, 404 und 86. Anhand der hier vorgestellten Beispiele, deren Güte auch für die anderen lokalen Zuflüsse




Abbildung 9.5: Vergleich der ECDF der Defizitvolumina nach dem FSA für die rekombinierte Dummy-Zeitreihe und die langjährige Zeitreihe a) und Vergleich der Kennwerte Mittelwert  $\mu$ , Standardabweichung  $\sigma$ , Schiefe  $\xi$  und Lag-1 Autokorrelationskoeffizient  $r_1$  b).

repräsentativ ist, kann die MCR somit in Bezug auf den Erhalt von wichtigen statistischen Kennwerten als erfolgreich angesehen werden.

## 9.5 Multikriterielle Optimierung der Talsperrenbewirtschaftung (Module D bis F)

### 9.5.1 Aufbau des Talsperrenbewirtschaftungsmodells

Den Aufbau des Speicherverbundsystems im Einzugsgebiet des Tanasees zeigt Abbildung 9.6. Von den Knoten, die den Bedarf der Bewässerungswirtschaft einfordern (580, 571, 572 und 573), werden jeweils 10 % des zugestellten Wassers über Dummy-Fließwege an im Unterstrom gelegene Knoten zurückgeführt. Die Größen der Toträume, der gewöhnlichen Hochwasserschutzräume und der Gesamtstauräume der Speicher sind in Tabelle D.2 zusammengefasst.

Der Zusammenhang zwischen Stauinhalt, Wasseroberfläche und Stauhöhe ist für den Tanasee erst ab einem Absenkziel über 1 784 m.ü.NN gegeben. OASIS kann daher bei einem Absinken des Stauinhalts unter 23 153  $hm^3$  keine geringeren zugehörigen Stauhöhen als 1 784 m.ü.NN ausgeben.

Die Bewirtschaftungsregeln sehen allgemein vor, dass die ökologischen Mindestabflüsse und die Trinkwasserbereitstellung sowohl aus dem Bewirtschaftungsraum als auch dem Reserveraum beliefert werden. Durch die Wahl der Netzgewichte der Speicher oberstromig des Tanasees wird sichergestellt, dass diese den Tis-Issat Wasserfall mit Wasser aus dem




Abbildung 9.6: Schema des Einzugsgebietes des Tanasee mit Superposition der Modelimplementierung des Mehrzweck-Talsperrenverbundsystems in OASIS (nach Alemayehu et al., 2009).

Bewirtschaftungsraum stützen, jedoch nicht die Wasserkraftproduktion (Tabelle D.1). Die Wasserkraftproduktion am Tana-Belles Kraftwerk wird nur durch das Wasser im Bewirtschaftungsraum des Tanasees gestützt. Wasser aus den Toträumen der Speicher wird wegen der hohen Netzgewichte nicht entnommen, es kann jedoch verdunsten.

### 9.5.2 Beschreibung der durchgeführten Szenarienrechnungen

In Fallstudie 2 werden acht Szenarien betrachtet, die sich anhand der Länge des Simulationszeitraums sowie der Anzahl der Zielfunktionen und Entscheidungsvariablen (siehe hierzu Abschnitt 9.5.3) unterscheiden. Die hier betrachteten Szenarien orientieren sich nur lose an einem Szenario aus der Arbeit von Saliha (2012) und sind nicht direkt mit den dortigen Ergebnissen vergleichbar. Die acht Szenarien sind wie folgt festgelegt:

**S-2D-65-20y und S-2D-65-679y** Das Optimierungsproblem der beiden Szenarien umfasst die Zielfunktionen  $FF1$  und  $FF2$  und insgesamt 65 Entscheidungsvariablen. Die Regelkurven aller Bewirtschaftungszonen sind monatlich variabel und die Regelkurven

Tabelle 9.1: Zuordnung der Laufvariablen  $r$  zu den einzelnen Speichern und den zugehörigen Abnehmern (Bewässerungswasser, Mindestwasserabgaben) im Einzugsgebiet des Tanasees.

Laufvariable $r$	Speicher				
	Megech	Koga	Ribb	Gumera	Tanasee
	1	2	3	4	5

der Reserveräume sind jeweils innerjährlich konstant. Die Szenarien unterscheiden sich anhand des Simulationszeitraums, der entweder die 20-jährige Beobachtungsreihe oder die 679-jährige Proxyzeitreihe umfasst.

**S-3D-65-20y und S-3D-65-679y** Diese beiden Szenarien unterscheiden sich von den Szenarien S-2D-65-20y und S-2D-65-679y durch die Anzahl der Zielfunktionen. Beide Szenarien berücksichtigen zusätzlich zu den Zielfunktionen  $FF1$  und  $FF2$  die Zielfunktion  $FF3$ .

**S-2D-120-20y und S-2D-120-679y** Auf Basis der 20-jährige Beobachtungsreihe oder der 679-jährigen Proxyzeitreihe wird das Speicherverbundsystem in den beiden Szenarien hinsichtlich der Zielfunktionen  $FF1$  und  $FF2$  optimiert. Neben den Regelkurven aller Bewirtschaftungszonen sind auch die Regelkurven der Reserveräume monatlich variabel. Insgesamt sind somit 120 Entscheidungsvariablen Gegenstand der Optimierung.

**S-3D-120-20y und S-3D-120-679y** Diese beiden Szenarien unterscheiden sich von den Szenarien S-2D-120-20y und S-2D-120-679y durch die Anzahl der Zielfunktionen. Beide Szenarien berücksichtigen zusätzlich zu den Zielfunktionen  $FF1$  und  $FF2$  die Zielfunktion  $FF3$ .

Um die Aufzählung ähnlicher Szenarien im Text zu vereinfachen, werden die Szenarien anhand der jeweiligen Unterscheidungsmerkmale mit  $(x)$  zusammengefasst. Zum Beispiel kennzeichnet S-2D-120- $x$  die beiden Szenarien S-2D-120-*20y* und S-2D-120-*679y* und S- $x$ -120- $x$  kennzeichnet *alle* Szenarien mit 120 Entscheidungsvariablen.

### 9.5.3 Mathematische Modellbeschreibung

Zielfunktion  $FF1$  (Gleichung 9.1) minimiert die Summe der Defizite aus der Bereitstellung von Trinkwasser, Bewässerungswasser, ökologischen Mindestdurchflüssen und den Mindestdurchflüssen des Wasserfalls Tis-Issat.

$$\min (FF1) = \min \left( \frac{12}{T} \sum_{t=1}^T \left( \sum_{r=1}^4 (D_t^{r,\text{Bew}} + D_t^{r,\text{Oek}}) + D_t^{\text{Meg}} + D_t^{\text{Tis}} \right) + \nu_B(\mathbf{x}) \right) \quad (9.1)$$

## 9.5 Multikriterielle Optimierung der Talsperrenbewirtschaftung (Module D bis F)

Hierbei ist das Defizit der Trinkwasserabgabe  $D_t^{\text{Meg}}$  aus der Talsperre Megech zum Zeitschritt  $t$  durch den Bedarf an Brauchwasser für die Stadt Gondar  $B_t^{\text{Meg}}$  und die Abgabe  $Q_t^{\text{Meg}}$  definiert,  $D_t^{\text{Meg}} = B_t^{\text{Meg}} - Q_t^{\text{Meg}}$ . Das Defizit der Zuflüsse zum Tis-Issat Wasserfall aus dem Tanasee  $D_t^{\text{Tis}} = B_t^{\text{Tis}} - Q_t^{\text{Tis}}$  berechnet sich aus dem Bedarf  $B_t^{\text{Tis}}$  und dem bereitgestellten Zufluss  $Q_t^{\text{Tis}}$ . Tabelle 9.1 listet die Laufvariable  $r$ , nach der im Folgendem die einzelnen Speicher und Abnehmer angesprochen werden. Das Gesamtdefizit aller Bewässerungswasserabgaben zum Zeitschritt  $t$  ist demnach  $D_t^{r,\text{Bew}} = \sum_{r=1}^4 (B_t^{r,\text{Bew}} - Q_t^{r,\text{Bew}})$ , mit den jeweiligen geforderten Bewässerungswasserabgaben  $B_t^{r,\text{Bew}}$  und den bereitgestellten Zuflüssen  $Q_t^{r,\text{Bew}}$ . Das Gesamtdefizit an ökologischen Mindestwasserabgaben ist  $D_t^{\text{Oek}} = \sum_{r=1}^4 (B_t^{r,\text{Oek}} - Q_t^{r,\text{Oek}})$ , mit den jeweiligen geforderten Mindestwasserabgaben  $B_t^{r,\text{Oek}}$  und den bereitgestellten Zuflüssen  $Q_t^{r,\text{Oek}}$ .

Zielfunktion  $FF2$  maximiert die mittlere Jahres-Energieproduktion des Wasserkraftwerks Tana-Belles

$$\mathbf{max}(FF2) = -1 \times \mathbf{min} \left( -\frac{12}{T} \times \left( \sum_{t=1}^T (E_t^{\text{Tana}}) \right) + \nu_B(\mathbf{x}) \right) \quad (9.2)$$

mit der Energie  $E_t^{\text{Tana}} = Q_t^{\text{Tana}} \times \left( \frac{h_{t-1}^{\text{Tana}} + h_t^{\text{Tana}}}{2} - 1452 \text{ m} - 35 \text{ m} \right) \times 8,83 \text{ kN/m}^3$  unter Berücksichtigung der Stauhöhe des Tanasees zum Beginn  $h_{t-1}^{\text{Tana}}$  und am Ende  $h_t^{\text{Tana}}$  des Zeitschritts  $t$ , sowie der oberen Randbedingung der Energieproduktion  $E_t^{\text{Tana}} \leq 460 \text{ MWh} \times 0,48 \times 24 \text{ h} \times 30,425$ .

Zielfunktion  $FF3$  wird nur bei bestimmten Szenarien verwendet (Abschnitt 9.5.2) und maximiert die mittlere Stauhöhe des Tanasees

$$\mathbf{max}(FF3) = \mathbf{min} \left( -1 \times \left( \frac{1}{T} \left( \sum_{t=1}^T h_t^{\text{Tana}} \right) \right) + \nu_B(\mathbf{x}) \right) \quad (9.3)$$

mit der Stauhöhe des Tanasees  $h_t^{\text{Tana}}$  zum Zeitpunkt  $t$ . Die Strafbetragsfunktion  $\nu_B(\mathbf{x})$  der BCHT (Gleichung 6.33) ist lediglich für das Lernverhalten der MO-CMA-ES von Bedeutung. Der Strafterm wird daher in der Präsentation der Ergebnisse in den nachfolgenden Abschnitten aus den Zielfunktionswerten der Zielfunktionen  $FF1$ ,  $FF2$  und  $FF3$  herausgerechnet. Sowohl die Anzahl der Entscheidungsvariablen,

$$\left( Z_s^{r,\text{Res}}, Z_s^{r,\text{Bew}} \right)_{\forall r,s}^* = \mathbf{arg} \left( \mathbf{min}(FF1), \mathbf{max}(FF2) \right) \quad (9.4)$$

$$\left( Z_s^{r,\text{Res}}, Z_s^{r,\text{Bew}} \right)_{\forall r,s}^* = \mathbf{arg} \left( \mathbf{min}(FF1), \mathbf{max}(FF2), \mathbf{max}(FF3) \right) \quad (9.5)$$

als auch die Anzahl der Zielfunktionen sind vom jeweiligen Szenario abhängig. Das Talsperrenbewirtschaftungsmodell OASIS wird zur Evaluation des Entscheidungsvektors genutzt.

$$\left( Q_t^{\text{Bew}}, Q_t^{r,\text{Oek}}, Q_t^{\text{Tana}}, Q_t^{\text{Meg}}, Q_t^{\text{Tis}}, h_t^{\text{Tana}} \right) = \text{OASIS} \left( Z_s^{r,\text{Res}}, Z_s^{r,\text{Bew}} \right), \forall s, t$$

Die Randbedingung der Abfolge der Regelkurven im Staukörper ist für alle Szenarien gleich. Die Einhaltung der hieraus resultierende Randbedingung

$$Z^{r,\text{Tot}} \leq Z_s^{r,\text{Res}} \leq Z_s^{r,\text{Bew}} \leq Z^{r,\text{HQ}}, \forall r, s \quad (9.6)$$

wird durch das Rule-Curve-Stacking erzwungen. Für die Szenarien S-x-65-x gilt weiterhin, dass alle monatlichen Regelkurven einem einzigen Wert  $Z_s^{r,\text{Res}}$  entsprechen  $Z_s^{r,\text{Res}} = Z^{r,\text{Res}}, \forall s$ . Die Einhaltung der Kontinuität (Gleichung 6.37) sowie der oberen und unteren Randbedingungen der Mindestdurchflüsse, Maximaldurchflüsse und Mindest- und Maximalspeicherinhalte (Randbedingung 6.38) werden von OASIS gehandhabt.

### 9.5.4 Ergebnisse

**Modul D** Die MKO des Speicherverbundsystems erfolgt jeweils über 120 000 Evaluationen des Talsperrenbewirtschaftungsmodells. Die Populationsgröße umfasst jeweils 48 Elternteile und Nachkommen. Die Größen der jeweils erhaltenen Pareto-Mengen sind in Tabelle D.10 zusammengefasst.

**Modul E** Nach der multikriteriellen Optimierung des Talsperrenverbundsystems erfolgt die Validierung der Pareto-optimalen Lösungsmenge  $\Theta^a$  nach Abschnitt 6.5. Hierzu werden zunächst repräsentative Lösungen aus den Pareto-Mengen der acht MKO gezogen. Die Anzahl der zu validierenden Lösungen liegt zwischen 52 und 80. Die Anzahl der nach der Validierung weiterhin dominanten Lösungen reduziert sich zum Teil erheblich. Es verbleiben für S-2D-120-20y lediglich sechs Kompromisslösungen und für S-2D-120-679y zehn Kompromisslösungen in der Pareto-Menge (Tabelle D.10).

Tabelle 9.2 umfasst die  $R^2$ -Statistiken und Standardabweichungen der Residuen  $\sigma$  aus der linearen Regression zwischen den Ergebnissen der MKO und der Validierung. Der Vergleich von Szenarien mit der jeweils gleichen Anzahl an Entscheidungsvariablen und Zielfunktionen zeigt, dass S-2D-65-679y und S-3D-120-679y wesentlich höhere  $R^2$ -Statistiken und geringere Standardabweichungen der Residuen  $\sigma$  aufweisen, als die respektiven Szenarien mit 20 Jahren Simulationszeitraum. Das  $R^2$  ist für S-3D-65-20y mit S-3D-65-679y vergleichbar. Letzteres besitzt jedoch eine deutlich geringere Standardabweichung der Residuen  $\sigma$ . S-2D-120-679y und S-2D-120-20y unterscheiden sich nur geringfügig hinsichtlich der



$\sigma$ - und  $R^2$ -Statistiken. Somit zeigt die MK-SBO anhand der 679-jährigen Proxyzeitreihen eine bessere Übertragbarkeit der Ergebnisse.

Tabelle 9.3 fasst die Offsets  $\beta$  und Steigungen  $\alpha$  der linearen Regressionen zusammen. Die Szenarien S-x-x-679y weisen gegenüber den Szenarien S-x-x-20y deutlich vorteilhaftere Parameter  $\beta$  und  $\alpha$  auf. Daher sind bereits in der MKO unter Verwendung der Proxyzeitreihen zur MK-SBO verlässlichere Aussagen über das Verhalten der Kompromisslösungen im Gesamtzeitraum möglich.

Ein signifikanter linearer Zusammenhang zwischen der mittleren Wasserspiegellage des Tanasees und dessen geringster Wasserspiegellage ( $\min(h^{\text{Tana}})$ ) im Zeitraum der Validierung lässt sich nach den Streudiagrammen (Abbildungen D.7, a und b) für die Szenarien S-3D-65-20y, S-3D-65-679y und S-3D-120-679y (Abbildungen D.8, b) feststellen. Die Zielfunktion  $FF3$  muss dabei mindestens einen Wert von 1785,9 m.ü.NN erreichen, bevor in der Validierung  $\min(h^{\text{Tana}})$  oberhalb der Wasserspiegellage von 1784 m.ü.NN erreichbar sind. Dies ist der fehlenden Implementierung des Zusammenhangs zwischen Stauinhalt und Stauhöhe unter 1784 m.ü.NN geschuldet. Oberhalb einer mittleren Wasserspiegellage von 1785,9 m.ü.NN lassen sich damit in der MKO zuverlässige Aussagen über die geringste Wasserspiegellage des Tanasees innerhalb des Gesamtzeitraums machen.

Nach den Streudiagrammen der Szenarien S-2D-x-x (Abbildung D.5 und D.6) kann im Szenario S-2D-65-679y lediglich eine Kompromisslösung  $\min(h^{\text{Tana}})$  von über 1784 m.ü.NN garantieren, in S-2D-120-20y sind dies zwei Kompromisslösungen. Diese treten bereits unter einer mittleren Wasserspiegellage des Tanasees von 1785,5 m.ü.NN auf und somit unter dem oben genannten Schwellenwert von 1785,9 m.ü.NN. Damit ist ausgeschlossen, dass generell zu niedrige mittlere Wasserspiegellagen für die fehlenden  $\min(h^{\text{Tana}})$  über 1784 m.ü.NN verantwortlich sind. Somit ist für die Szenarien mit lediglich zwei Zielfunktionen ( $FF1$  und  $FF2$ ) durch die fehlende explizite Auswertung von Informationen über die mittlere Wasserspiegellage ( $FF3$ ) in der MKO keine gesicherte generelle Aussage über  $\min(h^{\text{Tana}})$  möglich.

**Modul F** Die nach der Validierung weiterhin dominierenden Kompromisslösungen der vier Szenarien S-2D-x-x sind in der Abbildung 9.7 zusammengefasst. In Abbildung a) sind die Ergebnisse aus der MKO und in Abbildung b) die Ergebnisse der Validierung anhand der dominierenden Kompromisslösungen dargestellt. Ergänzend hierzu listet Tabelle D.11 die Spannweiten der Kenn- und Zielfunktionswerte in der Validierung für die Szenarien S-2D-x-x anhand der Pareto-Extreme auf.

In der MKO und der Validierung erzielen die Szenarien S-2D-120-x mit jährlich 8,5 hm<sup>3</sup> und 15,1 hm<sup>3</sup> die geringsten Defizite für die Wasserbereitstellung ( $FF1$ ). Dies wird durch die variablen Regelkurven des Reserveraums ermöglicht, die gegenüber dem innerjährlich konstanten Reserveraum der Szenarien S-2D-65-x mehr Freiheitsgrade zur Anpassung




Abbildung 9.7: Level-Diagramm für die vier Szenarien (S-2D-x-x) mit zwei Zielfunktionen unter Verwendung der 1-Norm. Abbildung a) zeigt die Ergebnisse der MKO, Abbildung b) die (weiterhin Pareto-optimalen) Ergebnisse der Validierung. Die repräsentativen Lösungen eines Szenarios sind jeweils hervorgehoben. \*  $FF3$  ist keine Zielfunktion der MKO.

erlauben. Im Gegensatz hierzu ist die mittlere Jahres-Energieproduktion ( $FF2$ ) in den beiden Szenarien S-2D-65-x mit innerjährlich konstantem Reserveraum mit über 1 891 GWh deutlich höher als die 1 659 GWh bis 1 779 GWh der Szenarien S-2D-120-x. Hohe mittlere Seespiegellagen ( $FF3^*$ ) sind in der MKO auf die Szenarien S-2D-65-20y und S-2D-65-679y beschränkt, in der Validierung entfallen jedoch die Wertebereiche der mittleren Wasserspiegellagen auf einen gemeinsam abgedeckten Bereich zwischen 1 785,0 m.ü.NN und 1 785,8 m.ü.NN.

Für die vier Szenarien S-3D-x-x sind in Abbildung 9.8 die beiden Level-Diagramme der MKO und der Validierung gegeben. Tabelle D.12 listet hierzu die Pareto-Extreme in der Validierung auf. Wie schon zuvor, erzielen innerjährlich variable Regelkurven des Reserveraums (Szenarien S-3D-120-x) mit jährlich  $9,1 \text{ hm}^3$  bis  $9,2 \text{ hm}^3$  deutlich geringere Defizite ( $FF1$ ) als die Szenarien S-3D-65-x mit jeweils  $31 \text{ hm}^3$ . Jedoch sind, im Gegensatz zu den Szenarien S-2D-x-x, in der Validierung keine Unterschiede hinsichtlich der hohen Jahres-Energieproduktionswerte in  $FF2$  erkennbar. Durch den Zielkonflikt sind für maximale Jahres-Energieproduktionen sehr hohe Defizite in der Wasserbereitstellung

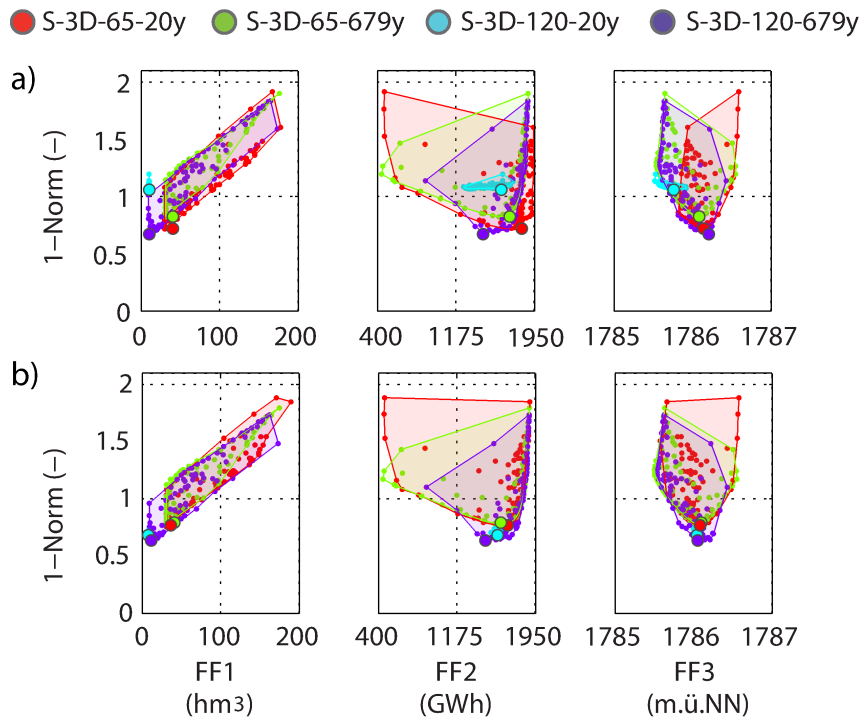


Abbildung 9.8: Level-Diagramm mit den vier Szenarien (S-3D-x-x) mit drei Zielfunktionen unter Verwendung der 1-Norm. Abbildung a) zeigt die Ergebnisse der MKO, Abbildung b) die (weiterhin Pareto-optimalen) Ergebnisse der Validierung. Die repräsentativen Lösungen eines Szenarios sind jeweils hervorgehoben.

(und umgekehrt) zu erwarten. Auffällig ist weiterhin, dass die Szenarien S-3D-65-x eine deutliche geringere Energieproduktion bereitstellen können, wenn hohe Wasserspiegellagen des Tanasees erwünscht sind.

Aus den Statistiken der linearen Regression und dem Level-Diagramm kann entnommen werden, dass das Szenario S-3D-120-20y keine ausreichende Übertragbarkeit der Ergebnisse erlaubt. Wie bereits beschrieben ist es der Pareto-Front in der MKO zwar möglich größere Wertebereiche der Zielfunktionen  $FF2$  und  $FF3$  abzudecken, in der Validierung sinkt dieser aber auf einen geringen Bereich zusammen (siehe Tabelle D.12 und Abbildung 9.8). Anhand der zugrunde liegenden Regelkurven kann dieser Umstand erklärt werden.

Die Diversität der Regelkurven aus S-3D-120-20y (Abbildung 9.9) ist deutlich geringer als die der Regelkurven aus S-3D-120-679y (Abbildung 9.10). Durch die geringe Information über die Bandbreite hydrologischer Zustände in der 20-jährigen Zeitreihe in der MKO sind wenige Veränderungen der Regelkurven ausreichend, um größere Wertebereiche der  $FF2$  und  $FF3$  abzudecken. Aufgrund der hohen Bandbreite hydrologischer Zustände in der Validierung entspricht die geringe Diversität der Regelkurven jedoch nur sehr spezifischen Zuständen, mit einem beschränkten Umfang an Kompromissen zwischen den Zielen. In




Abbildung 9.9: Optimale Regelkurven der fünf Speicher für das Szenario S-3D-120-20y. Die repräsentativen Lösungen sind als markierte schwarze Linien dargestellt, die Spannweite aller sonstigen Regelkurven sind entsprechend als farbig transparente Flächen dargestellt.

S-3D-120-679y trägt die Proxyzeitreihe ausreichend Information, um eine hohe Diversität an Regelkurven in der MKO zu erzwingen. Die Proxyzeitreihe ist repräsentativ für den Gesamtzeitraum und die Regelkurven führen auch in der Validierung zu einem ähnlichen Verhalten des wasserwirtschaftlichen Speichersystems.

**Rechenzeit** Die mit der Monte-Carlo-Rekombination erzeugte Proxyzeitreihe besitzt in Fallstudie 2 eine Länge von 679 Jahren. Die Rechenzeit<sup>1</sup> eines einzelnen Simulationslaufs der Talsperrenbewirtschaftung mit dem OASIS implementierten Talsperrenverbundsystem beträgt 9 Sekunden. Die Gesamtrechenzeit ergibt sich bei Verwendung von 8 Kernen  $T_R = 9 \text{ s} * \frac{120\,000 \text{ Evaluationen}}{8 \text{ Threads}} = 135\,000 \text{ s} = 1,6 \text{ Tage}$ . Eine entsprechende Simulation mit OASIS über den Zeitraum von 10 000 Jahren erfordert 122 Sekunden. Somit ergibt sich für den einfachsten Ansatz zur MK-SBO, ohne Parallelisierung und unter einer Langfristsimulation über die kompletten 10 000 Jahre, eine Gesamtlauzeit von  $T_R = 122 \text{ s} * \frac{120\,000 \text{ Evaluationen}}{1 \text{ Thread}} = 1,8E6 \text{ s} = 169,4 \text{ Tage}$ . Für die hier durchgeführten MK-SBO konnte somit eine Einsparung von Rechenzeit um den Faktor 100 erzielt werden.

<sup>1</sup>AMD FX 8150, 3,6 GHz

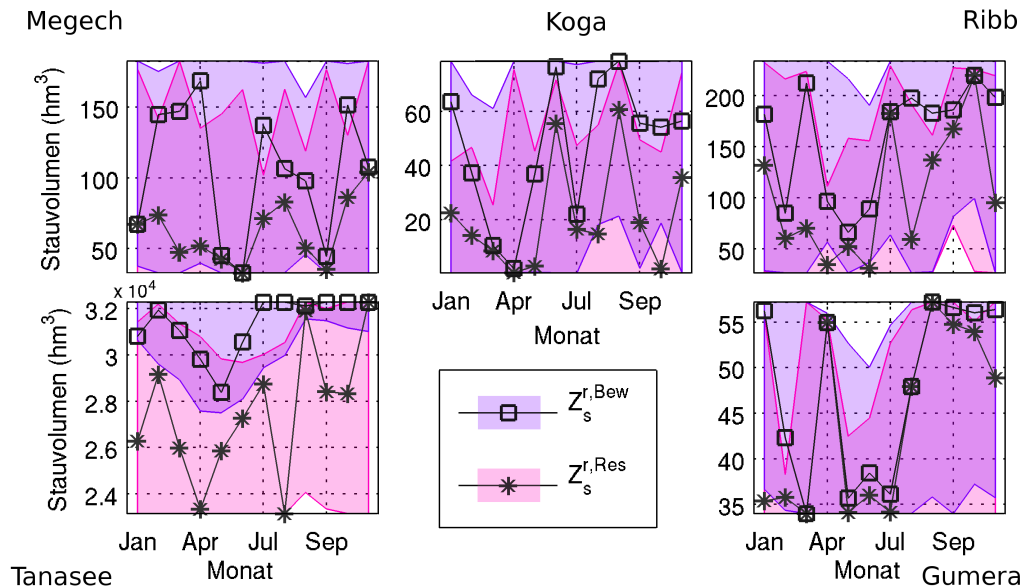


Abbildung 9.10: Optimale Regelkurven der fünf Speicher für das Szenario S-3D-120-679y. Die repräsentativen Lösungen sind als markierte schwarze Linien dargestellt, die Spannweite aller sonstigen Regelkurven sind entsprechend als farbig transparente Flächen dargestellt.

## 9.6 Zusammenfassung

In der Fallstudie 2 wurde die Frams-BoT-Strategie für multikriterielle Optimierungen an einem Mehrzweck-Speichersystem im Einzugsgebiet des Tanasees, Äthiopien, angewandt. Die acht durchgeführten Optimierungsläufe unterschieden sich dabei jeweils durch die Anzahl der Zielfunktionen, die Anzahl der Entscheidungsvariablen sowie den Zeitraum der Bewirtschaftungssimulation. Die Zeiträume umfassten die beobachteten Zuflüsse über 20 Jahre und einen Zeitraum über 679 Jahre, der durch die Monte-Carlo-Rekombination aus einem Satz 10 000-jähriger Zeitreihen ermittelt wurde.

Es gilt die Annahme, dass die stochastisch generierte 10 000-jährige Zeitreihe (Gesamtzeitraum) eine gültige Approximation des wahren stochastischen Prozesses darstellt. Die Anzahl der Realisierungen (über den Zeitraum) beschreibt den stochastischen Zufallsprozess der Zuflüsse in seiner Gesamtheit ausreichend. Die durchgeführten Optimierungsläufe zeigen:

- Informationen über die mittlere Wasserspiegellage des Tanasees sind über eine Zielfunktion ( $FF3$ ) in die MKO einzubringen, wenn die geringste aufgetretene Wasserspiegellage ( $\min(h^{\text{Tana}})$ ) in den Entscheidungsprozess einfließen soll. Die kritische Wasserspiegellage von 1 874 m.ü.NN wird in der Validierung der Szenarien mit zwei Zielfunktionen zumeist unterschritten, obwohl in der MKO deutlich höhere  $\min(h^{\text{Tana}})$  erreicht werden können. Dies deutet an, dass Systemzustände, über die

nicht implizit Informationen in der MKO verarbeitet werden, weniger robust gegen hydrologische Unsicherheiten sind und keine verlässlichen Aussagen auf die wirkliche Speicherleistung zulassen. Unter diesen Gesichtspunkten wäre eine weiterführende Untersuchung zu Formulierungen von  $\min(h^{\text{Tana}})$  als Randbedingung einer MK-SBO wünschenswert.

- Ausreichende Informationen über den stochastischen Zuflussprozess sind unerlässlich, um ein Talsperrenbewirtschaftungsmodell mit vielen Entscheidungsvariablen zu parametrisieren. Hier zeigt das Szenario S-3D-120-20y mit 120 Entscheidungsvariablen und drei Zielfunktionen deutliche Probleme in der Übertragbarkeit. Somit wären auch die zu erwartenden Ergebnisse in der realen Bewirtschaftung mit einer dieser Steuerungsstrategien nicht abschätzbar. Mit der Proxyzeitreihe als Datengrundlage der MK-SBO ist die Validierung anhand der 10 000-jährigen Zeitreihe sowohl für die Szenarien mit 65 als auch für 120 Entscheidungsvariablen als gut zu bewerten. Dies erhöht das Vertrauen in die Speicherleistung, die in der Realwelt zu erwarten wäre.
- Allgemein lässt sich mit innerjährlich konstanten Reserveräumen (65 Entscheidungsvariablen) mehr Energie produzieren, jedoch sind die zu erwartenden Defizite in der Wasserversorgung höher und die Wasserspiegellagen des Tanasees niedriger. Die insgesamt vorzuziehende ausgeglichene Kompromisslösung entstammt dem Szenario S-3D-120-679y. Bei einem mittleren Defizit von  $10,8 \text{ hm}^3$  je Monat über alle Sektoren beträgt die jährliche Energieproduktion durchschnittlich  $1\,561 \text{ GWh}$ . Der mittlere Wasserspiegel des Tanasees liegt dabei auf  $1\,786,1 \text{ m.ü.NN}$  und die geringste Wasserspiegellage ist bei  $1\,784,4 \text{ m.ü.NN}$  zu erwarten.

Alle diese Ergebnisse beruhen auf Simulationen der Speicherbewirtschaftung mit dem Talsperrenbewirtschaftungsmodell OASIS. OASIS nutzt einen internen Optimierungsalgorithmus, um das verfügbare Wasser unter Beachtung der Steuerungsstrategien im System für jeden Zeitschritt zu verteilen. Eine offene Forschungsfrage ist, ob die in dieser Fallstudie aufgezeigten Ergebnisse unter Einsatz eines verordneten Talsperrenbewirtschaftungsmodells abweichen. Verordnende Talsperrenbewirtschaftungsmodelle, wie zum Beispiel HEC-5, handhaben die Wasserverteilung im System restriktiver. Damit könnte geklärt werden, wie sich die zusätzlichen Freiheitsgrade, die OASIS durch die modellseitige Optimierung der Wasserverteilung im System ermöglicht, auswirkt.

Die minimale Wasserspiegellage  $\min(h^{\text{Tana}})$  wurde hier nicht zur Formulierung einer Zielfunktion in der MKO herangezogen, da sich diese Kenngröße als Extremwert in Voruntersuchungen als problematisch erwies. Vorteile könnten hier Kriterien wie das 95 %-Quantil des Wasserstands (eventuell ausschließlich in der Trockenzeit) bringen.

Tabelle 9.2: Bestimmtheitsmaße  $R^2$  und Standardabweichung der Residuen  $\sigma$  zwischen der MKO und der Validierung.

Szenario	$R^2$				$\sigma$			
	$FF1$	$FF2$	$FF3$	$\min(h^{\text{Tana}})$	$FF1$	$FF2$	$FF3$	$\min(h^{\text{Tana}})$
	(-)	(-)	(-)	(-)	( $\text{hm}^3$ je Monat)	(GWh)	(m.ü.NN)	(m.ü.NN)
S-2D-65-20y*	0,997	0,783	0,691	-	2,757	6,314	0,032	-
S-2D-65-679y*	1,000	0,999	0,994	-	0,359	2,131	0,004	-
S-2D-120-20y*	0,957	0,948	0,957	-	5,136	24,386	0,032	-
S-2D-120-679y*	0,998	0,912	0,994	-	1,732	28,633	0,02	-
S-3D-65-20y	0,998	0,998	0,956	0,940	2,129	14,730	0,045	0,122
S-3D-65-679y	1,000	1,000	0,999	0,850	0,576	3,201	0,007	0,210
S-3D-120-20y	0,674	0,007	0,005	-	0,395	20,838	0,032	-
S-3D-120-679y	1,000	0,999	0,999	0,635	0,588	4,310	0,006	0,138

Tabelle 9.3: Parameter  $\alpha$  und  $\beta$  der linearen Regression zwischen der MKO und der Validierung.

Szenario	Offset $\beta$				Steigung $\alpha$			
	$FF1$	$FF2$	$FF3$	$\min(h^{\text{Tana}})$	$FF1$	$FF2$	$FF3$	$\min(h^{\text{Tana}})$
	( $\text{hm}^3$ je Monat)	(GWh)	(m.ü.NN)	(m.ü.NN)	(-)	(-)	(-)	(-)
S-2D-65-20y*	8,61	-72023	12,3	-	1,05	38,08	0,99	-
S-2D-65-679y*	-0,44	11,3	-189	0,02 <sup>+</sup>	0,99	1,00	1,11	1,71 <sup>+</sup>
S-2D-120-20y*	-0,07	557,7	-62,2	0,08 <sup>+</sup>	1,41	0,57	1,04	6,19 <sup>+</sup>
S-2D-120-679y*	5,91	-2614	449	-	0,95	2,33	0,75	-
S-3D-65-20y	0,46	27,4	-294	-2933	1,04	0,95	1,16	2,66
S-3D-65-679y	-0,18	0,8	-56,1	-1356	0,99	1,01	1,03	1,76
S-3D-120-20y	-0,99	1555 <sup>+</sup>	1755 <sup>+</sup>	-	1,05	0,01 <sup>+</sup>	0,02 <sup>+</sup>	-
S-3D-120-679y	-0,05	14,4	-89,2	0,64	0,99	1,00	1,05	135,92

\* FF3 ist keine Zielfunktion der MKO, <sup>+</sup>nicht signifikant ( $\alpha = 0,05$ ), - keine Regression wegen fehlendem Zusammenhang durchgeführt





## 10 Zusammenfassung und Ausblick

Wasserwirtschaftliche Speichersysteme schaffen durch ihre Speicherfunktion einen Ausgleich zwischen dem schwankenden natürlichen Wasserdargebot und dem Bedarf an Trinkwasser, Bewässerungswasser und der Energieerzeugung durch Wasserkraft. Um durch eine möglichst zuverlässige Bedarfsdeckung den potenziellen gesellschaftlichen Nutzen erbringen zu können, ist es unerlässlich Talsperren, Talsperrenverbundsysteme und Mehrzweck-Talsperrenverbundsysteme optimal zu bewirtschaften. Als Richtlinien zur Bewirtschaftung dienen dem Talsperrenbetreiber in der Praxis Steuerungsstrategien. Diese sind für jedes wasserwirtschaftliche System, unter den vorherrschenden hydrologischen Rahmenbedingungen und den durch die Nutzungen bedingten Bewirtschaftungszielen, optimal anzupassen.

Hierfür werden seit den 1970er Jahren aktiv unterschiedlichste mathematische Optimierungstechniken entwickelt. Die simulationsbasierte Optimierung (SBO) bietet gegenüber klassischen Optimierungstechniken dabei wesentliche Vorteile. Jedoch gestaltet sich die Simulation mit Talsperrenbewirtschaftungsmodellen als rechenintensiv, vor allem bei langjährigen Simulationszeiträumen. Innerhalb einer SBO sind mehrere Zehntausend Evaluationen eines Talsperrenbewirtschaftungsmodells durchzuführen, sodass schnell unbeherrschbare Gesamtrechnenzeiten erreicht werden. Bisherige Studien beschränken sich daher zumeist auf Simulationszeiträume von wenigen Jahrzehnten.

Da Simulationszeiträume von wenigen Jahrzehnten den stochastischen Prozess der Zuflüsse in der Regel nur ungenügend beschreiben können, sind erstens wenig robuste Steuerungsstrategien das Resultat der SBO und zweitens gestalten sich Aussagen über erreichbare Versorgungssicherheiten in der SBO als äußerst unsicher. Bisher sind daher keine SBO-Studien bekannt, die die Wasserversorgung durch die Maximierung der zugehörigen Versorgungssicherheiten optimieren, obwohl dies, angesichts der hydrologischen Unsicherheiten mit denen die Talsperrenbewirtschaftung konfrontiert ist, naheliegend erscheint. Weiterhin beschränkt sich die Abschätzung der zukünftig möglichen Leistungsfähigkeit von Mehrzweck-Talsperrenverbundsystemen in der Klimafolgenforschung bisher auf a priori multikriterielle Optimierungen. Wegen der multikriteriellen Natur der Ziele von Mehrzweckspeichern wäre der Einsatz von a posteriori multikriterieller SBO wünschenswert. Die zukünftig mögliche Leistungsfähigkeit könnte dann anhand vieler möglicher Kompromisslösungen evaluiert werden.

Um den aufgezeigten offenen Problemstellungen zu begegnen, wurde in dieser Arbeit eine neue Strategie zur a posteriori multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen vorgestellt. Um die Strategie möglichst

nahe an eine Anwendung in der Praxis zu führen, wurde ein umfangreiches, modulares Framework (Frams-BoT) bereitgestellt. Dem Anwender werden sowohl für die Arbeitsschritte von MK-SBO-Studien unter Langfristsimulationen als auch zur Klimafolgenanalyse teilweise neu entwickelte Methoden zur Verfügung stellt.

Die zum Erreichen der Ziele notwendige, drastische Einsparung an Rechenzeit wird hauptsächlich durch drei Punkte erreicht: (1) Die Parallelisierung der evolutionären Strategie MO-CMA-ES erlaubt die simultanen Evaluationen mehrerer Steuerungsstrategien durch Simulationsmodelle. (2) Die in der MK-SBO ermittelten Steuerungsstrategien sind nur von den Eigenschaften des stochastischen Prozesses und dem bereitgestellten Informationsumfang abhängig und nicht von dessen zugrunde liegenden Ausprägung (Zeitreihe). Mit einem multivariaten Zeitreihenmodell werden zunächst die Grundgesamtheiten der stochastischen Prozesse durch mehrere Tausend Jahre lange Zeitreihen approximiert. Die Monte-Carlo-Rekombination erzeugt hieraus erheblich verkürzte Proxyzeitreihen. Diese bewahren wichtige statistische und stochastische Eigenschaften der langjährigen synthetischen Zeitreihen sowie die, für die Speicherwirtschaft wichtigen, Informationen über die Verteilung der Defizitvolumina der Trockenperioden. Daher kann davon ausgegangen werden, dass sich die anhand der Proxyzeitreihen ermittelten Steuerungsstrategien nicht von solchen unterscheiden, die anhand einer äquivalenten MK-SBO auf Grundlage der langjährigen synthetischen Zeitreihen ergeben würden. Die Robustheit der Ergebnisse wird nach der MK-SBO durch die Validierung der Kompromisslösungen anhand der ursprünglichen langjährigen Zeitreihen überprüft und geringfügige Abweichungen korrigiert. (3) Weiterhin können, durch die hier verallgemeinerte Kodierung der Entscheidungsvariablen nach Scola et al. (2010) sowie durch die Initialisierung der Startpopulation der MO-CMA-ES, signifikant bessere Ergebnisse erzielt werden.

Die Datengrundlagen zur Langfristsimulation mit dem Talsperrenbewirtschaftungsmodell OASIS lassen sich durch ein in dieser Arbeit weiterentwickeltes nichtparametrisches multivariates Zeitreihenmodell (HKNN-SMA) generieren. Als Datengrundlagen dienen entweder beobachtete Zuflüsse oder Zuflussdargebote, die für Klimaprojektionen zunächst durch das Wasserhaushaltsmodell WaSiM-ETH modelliert werden. Für die Kalibrierung des Wasserhaushaltsmodells wird eine multikriterielle Optimierung mit der evolutionären Strategie des Frameworks vorgeschlagen.

Um die komplexen und umfassenden Ergebnisse dem Entscheidungsträger verständlich zu präsentieren, wird ein multikriterielles Entscheidungshilfesystem bereitgestellt. Level-Diagramme (Blasco et al., 2008) verbinden die Wertung der Kompromisslösungen mit einer Auswahl von wenigen repräsentativen Lösungen aus Kompromissklassen. Diese können auch als hochdimensionale Datensätze verständlich visualisiert werden.

In zwei Fallstudien wurden die Anwendbarkeit und Leistungsfähigkeit der Strategie demonstriert. Die erste Fallstudie über ein Mehrzweck-Talsperrenverbundsystem (Sachsen,

Deutschland) fokussierte insbesondere die Maximierung der Versorgungssicherheit der Trinkwasserversorgung. Die Versorgungssicherheiten von drei Abgabestufen konnten hierbei in einer Zielfunktion aggregiert werden. Zwei weitere Zielfunktionen des MKO-Problems dienten der Reduktion möglicher Kosten bei einer simultanen Maximierung eines Wassergüteindikators.

Umfangreiche Anwendungen, die auch eine Klimafolgenanalyse für drei Klimaszenarien umschloss, demonstrierten eine hohe Robustheit der Strategie. Die Ergebnisse der MK-SBO-Rechnungen unter Anwendung des Frameworks zeigten eine hohe Übereinstimmung mit Vergleichssimulationen mit den synthetischen Datengrundlagen über 10 000 Jahre. Die approximierten Pareto-Fronten stellten sich als repräsentativ für die langfristigen Zeiträume heraus. Effektiv ließen sich somit verlässliche MK-SBO realisieren, deren Ergebnisse sich auch gegenüber MK-SBO unter Langfristsimulationen über mehrere Tausend Jahre als vergleichbar zeigten.

Gegenüber den historischen Steuerungsstrategien konnte mit vergleichbaren Kompromisslösungen mit geringen mittleren Überleitungsmengen, die Leistungsfähigkeit des Talsperrenverbundsystems nur geringfügig gesteigert werden. Die Pareto-Menge zeigt daher hier dem Talsperrenbetreiber vor allem weitere bestmögliche gültige Optionen auf um die Bewirtschaftung auf alternative Kompromisse umzustellen. Das Verständnis über das Verhalten des Talsperrenverbundsystems hinsichtlich der Konflikte wird erweitert.

In den betrachteten Klimaszenarien nimmt die Leistungsfähigkeit des Speichersystems durch rückläufige projizierte Zuflussdargebote auch mit optimalen Steuerungsstrategien ab. Durch die approximierten Pareto-Mengen konnte dem Entscheidungsträger hier eine Bandbreite an zukünftig möglichen Kompromissen zwischen den konträren Bewirtschaftungszielen bereitgestellt werden. Bieten die bereitgestellten Kompromisslösungen keine zufriedenstellende Adaption an die veränderten Rahmenbedingungen, müssen bautechnische Anpassungsmaßnahmen in Betracht gezogen werden. Das vertiefte Verständnis über die zukünftigen Möglichkeiten kann die Entscheidungsfindung hinsichtlich der Notwendigkeit und der Art der zusätzlichen Maßnahmen unterstützen.

Durch die hohe Flexibilität der Strategie konnte Frams-BoT in einer zweiten Fallstudie für ein Mehrzweck-Speicherverbundsystem im Einzugsgebiet des Tanasees (Äthiopien) angewandt werden. Mehrere MK-SBO Läufe wurden durchgeführt, die sich durch eine Variation der Anzahl der Entscheidungsvariablen und Zielfunktionen sowie der Datengrundlage unterschieden. Eine hohe Leistungsfähigkeit des Frameworks konnte auch hier bestätigt werden. Es zeigte sich, dass für komplexe Optimierungsprobleme ausreichend Informationen über den stochastischen Prozess der Zuflüsse in der MK-SBO zur Verfügung stehen müssen, um eine Überparametrisierung (der Steuerungsstrategien) zu verhindern.

Weiterhin gestalteten sich Aussagen über Systemzustände des Speicherverbundsystems hinsichtlich der langjährigen Repräsentation der stochastischen Prozesse nur als verlässlich, wenn diese Informationen über die Zielfunktionen in die MKO einfließen. Frams-BoT

bietet sich somit auch als Werkzeug zur Bewertung unterschiedlicher mathematischer Formulierungen von wasserwirtschaftlichen Optimierungsproblemen an.

In beiden Fallstudien zeigte sich anhand umfangreicher Zeitreihengenerierungen das hier weiterentwickelte HKNN-SMA-Modell als zuverlässiges und leistungsfähiges Modell. Wichtige statistische Kennwerte konnten in den stochastisch generierten Zeitreihen erhalten werden. Als multivariates Modell eignet sich HKNN-SMA zur simultanen Modellierung mehrerer Zuflusszeitreihen unter Erhalt der Kreuzkorrelationen. Trotz der Generierung auf der monatlichen Zeitskala ließen sich ebenso höhere Autokorrelationskoeffizienten auf der jährlichen Zeitskala zuverlässig modellieren. Das HKNN-SMA-Modell bietet somit eine unkomplizierte und verlässliche Methodik zur Informationserweiterung über die stochastischen Prozesse durch Zeitreihenmodellierung.

Level-Diagramme zeigten sich als vielseitig einsetzbare Entscheidungshilfetechnik. Die Wertung der Kompromisslösungen hilft dem Entscheidungsträger diese hinsichtlich der Art der Kompromisse einzuordnen. Die Bildung von Kompromissklassen und die nachfolgende Wahl repräsentativer Lösungen reduziert den Ergebnisumfang objektiv und erleichtert den Entscheidungsprozess. Somit stellen Level-Diagramme nicht nur durch die verständliche Visualisierung der hochdimensionalen Daten ein vielseitiges Werkzeug zur Entscheidungsfindung dar. Mit Level-Diagrammen konnten außerdem die Ergebnisse unterschiedlicher SB-MKO-Läufe oder Szenarien in beiden Fallstudien direkt verglichen werden. In der Fallstudie 1 ließen sich neben den Zielfunktionswerten zur integrierten Visualisierung weitere wichtige Kennwerte darstellen, die nicht direkt in die Wertung einfließen.

Die Gesamtrechnenzeiten für eine MK-SBO mit Langfristsimulationen mit Frams-BoT betrug in beiden Fallstudien zwischen 1,5 und 4,5 Tagen und konnten auf handelsüblicher Hardware gegenüber einem äquivalenten, trivialen Ansatz um den Faktor 100 beschleunigt werden. Dies zeigt, dass verlässliche MK-SBO unter Langfristsimulationen ohne die angewandten Methodiken zu bewerkstelligen sind.

Mit der modular aufgebauten Strategie Frams-BoT wurde ein flexibles und umfassendes Werkzeug zur multikriteriellen simulationsbasierten Optimierung von robusten Steuerungsstrategien wasserwirtschaftlicher Mehrzweck-Speicherverbundsysteme geschaffen. Die in dieser Arbeit vorgeschlagenen Methoden bieten weiterhin einige Ansatzpunkte zur Weiterentwicklung:

### 1) Ausbau der Monte-Carlo-Rekombination

- Erweiterung des hier verwendeten und sehr einfachen Ansatzes, alle relevanten Speicher und lokalen Zuflüsse zu aggregieren (Dummy-Zeitreihe), um eine stärkere räumliche und zeitliche Differenzierung unter Einhaltung der räumlich-zeitlichen Kreuzkorrelationen zu ermöglichen.

- Überprüfung der Eignung anderer Verfahren zur Separation von Trockenperioden (unter anderem von Zelenhasić and Salvai, 1987; Tallaksen et al., 1997; Van Huijgevoort et al., 2012) als informationserhaltende Merkmale.
- Ersatz der zufälligen Auswahl und Rekombination von Trockenperioden durch eine direkte Optimierung der Ähnlichkeit der informationserhaltenden Merkmale unter Einsatz von genetischen Algorithmen.

## 2) Erweiterung der Validierung

- Erweiterung der Validierung der Ergebnisse aus der MK-SBO anhand unabhängiger synthetischer Zeitreihen aus demselben Zeitreihenmodell. Denkbar wäre auch eine Validierung an synthetischen Zeitreihen aus ähnlichen Zeitreihenmodellen. Die Notwendigkeit dieses Schrittes wäre jedoch gegenüber den bisher unbeachteten Unsicherheiten aus der verwendeten Modellkaskade und den Eingangsdaten abzuwägen.

## 3) Präferenzierung der Kompromisse in Level-Diagramme

- Berücksichtigung der Präferenzierung durch den Entscheidungsträger bei der Wertung der Kompromisslösungen (z.B. Zio und Bazzo, 2010) und bestimmter Merkmale von Steuerungsstrategien oder Systemzuständen.

Folgende weitere Einsatzmöglichkeiten für Frams-BoT sind denkbar:

### 1) Benchmark für Steuerungsstrategien.

- Neben den in dieser Arbeit verwendeten Regelkurven und Dispatcherplänen sind vielfältige weitere Arten von Steuerungsstrategien bekannt. Ein Benchmark unterschiedlicher Steuerungsstrategien könnte neue Erkenntnisse über die Leistungsfähigkeit dieser liefern und somit zu einer effizienteren Bewirtschaftung beitragen.

### 2) Ökonomische Bewertung der Talsperrenbewirtschaftung

- Einsatz der Strategie zur Optimierung des Betriebs wasserwirtschaftlicher Speicheranlagen unter ökonomischen Gesichtspunkten. Die Formulierung der ökonomischen Ziele sollte unter der besonderen Beachtung von Unsicherheiten über die zu erwartenden Kosten und Gewinne geschehen.

## Literaturverzeichnis

- M. Acutis and M. Donatelli. Soilpar 2.00: software to estimate soil hydrological parameters and functions. *European Journal of Agronomy*, 18 (3–4):373–377, 2003.
- Ad-hoc-Arbeitsgruppe Boden. *Bodenkundliche Kartieranleitung*. Bundesanstalt für Geowissenschaften und Rohstoffe in Zusammenarbeit mit den Staatlichen Geologischen Diensten, Aufl.5, 2005.
- JA Adeyemo. Reservoir operation using multi-objective evolutionary algorithms-a review. *Asian Journal of Scientific Research*, 4(1):16–27, 2011.
- G Agrawal, CL Bloebaum, and K Lewis. Intuitive design selection using visualized n-dimensional pareto frontier. In *1st AIAA Multidisciplinary Design Optimization Specialist Conference*, 2005.
- Juran Ahmed and Arup Sarma. Artificial neural network model for synthetic streamflow generation. *Water Resources Management*, 21:1015–1029, 2007. ISSN 0920-4741. doi: 10.1007/s11269-006-9070-y.
- Tadesse Alemayehu, Matthew McCartney, and Seifu Kebede. Simulation of water resource development and environmental flows in the lake tana subbasin. In *SSimulation of Water Resource Development and Environmental Flows in the Lake Tana Subbasin, "presented at the Intermediate Results Dissemination Workshop, for the project Improved Water and Land Management in the Ethiopian Highlands: Its Impact on Downstream Stakeholders Dependent on the Blue Nile, organized by the IWMI Subregional Office for East Africa and Nile Basin.*, 2009.
- Ahmed Ammeri, Habib Chabchoub, Wafik Hachicha, and Faouzi Masmoudi. A comprehensive literature classification of simulation–optimization methods. In *The 9th International Conference on Multi Objective Programming and Goal Programming (MOPGP)–May*, pages 24–26, 2010.
- EA Anderson. National weather service river forecast system-snow accumulation and ablation model. national oceanographic and atmospheric administration, silver springs. Technical report, Md., Tech. Memo NWS\_HYDRO-17, 1973.
- P. Anderson, Y. Tesfaye, and M. Meerschaert. Fourier-parma models and their application to river flows. *Journal of Hydrologic Engineering*, 12(5):462–472, 2007.

- J. Andreu, J. Capilla, and E. Sanchís. Aquatool. *Journal of Hydrology*, 177(3-4):269 – 291, 1996. ISSN 0022-1694. doi: 10.1016/0022-1694(95)02963-X.
- Afshin Ashrafzadeh and Atefeh Parvaresh Rizi. A hybrid neural network based model for synthetic time series generation. In *Interational Symposium on Water Management and Hydraulic Engineering*, 2009.
- Nicole H Augustin, Lindsay Beevers, and William T Sloan. Predicting river flows for future climates using an autoregressive multinomial logit model. *Water Resources Research*, 44(7):W07403, 2008.
- T.A. Awchi and D. K. Srivastava. Analysis of drought and storage for mula project using ann and stochastic generation models. *Hydrology Research*, 40(1):79–91, 2009.
- Thomas Bäck and Hans-Paul Schwefel. An overview of evolutionary algorithms for parameter optimization. *Evolutionary computation*, 1(1):1–23, 1993.
- F. B. Barnes. Storage required for a city water supply. *Journal of the Institute of Engineers Australia*, 26(9):198–203, 1954.
- Elias G. Bekele and John W. Nicklow. Multi-objective automatic calibration of swat using nsga-ii. *Journal of Hydrology*, 341(3–4):165 – 176, 2007. ISSN 0022-1694. doi: 10.1016/j.jhydrol.2007.05.014.
- Richard Bellman. On the approximation of curves by line segments using dynamic programming. *Communications of the ACM*, 4(6):284, 1961.
- Christian Bernhofer, Jörg Matschullat, and Achim Bobeth. Klimaprojektionen für die regklam-modellregion dresden. *REGKLAM Publikationsreihe*, 2, 2011.
- Hans-Georg Beyer and Hans-Paul Schwefel. Evolution strategies – a comprehensive introduction. *Natural Computing*, 1(1):3–52, 2002. ISSN 1567-7818. doi: 10.1023/A:1015059928466.
- X. Blasco, J.M. Herrero, J. Sanchis, and M. Martinez. A new graphical visualization of n-dimensional pareto front for decision-making in multiobjective optimization. *Information Sciences*, 178(20):3908 – 3924, 2008. ISSN 0020-0255. doi: 10.1016/j.ins.2008.06.010.
- G.E.P. Box and G.M. Jenkins. *Time Series Analysis: Forecasting and Control*. Holden-Day, 1976.
- Jean-Pierre Brans and Bertrand Mareschal. Promethee methods. In *Multiple criteria decision analysis: state of the art surveys*, pages 163–186. Springer, 2005.

- RL Bras and I Rodriguez-Iturbe. *Random functions and hydrology*. Addison-Wesley, Reading MA., 1985.
- Carsten Brass. *Betriebsoptimierung von Talsperrensystemen mittels Stochastisch Dynamischer Programmierung (SDP) unter Berücksichtigung veränderlicher Ziele und Randbedingungen*. PhD thesis, Fakultät für Bauingenieurwesen, Lehrstuhl für Hydrologie Wasserwirtschaft und Umwelttechnik , Ruhr-Universität Bochum, 2006.
- A. Castelletti, F. Pianosi, X. Quach, and R. Soncini-Sessa. Assessing water reservoirs management and development in northern vietnam. *Hydrology and Earth System Sciences*, 16(1):189–199, 2012. doi: 10.5194/hess-16-189-2012.
- A. Castelletti, F. Pianosi, and M. Restelli. A multiobjective reinforcement learning approach to water resources systems operation: Pareto frontier approximation in a single run. *Water Resources Research*, pages n/a–n/a, 2013. ISSN 1944-7973. doi: 10.1002/wrcr.20295.
- Alcigeimes B. Celeste and Max Billib. Evaluation of stochastic reservoir operation optimization models. *Advances in Water Resources*, 32:1429–1443, 2009.
- Alcigeimes B. Celeste, Wilson F. Curi, and Rosires C. Curi. Implizit stochastic optimization for deriving reservoir operating rules in semiarid brazil. *Pesquisa Operacional*, 29: 223–234, 2009.
- Fi-John Chang, Li Chen, and Li-Chiu Chang. Optimizing the reservoir operating rule curves by genetic algorithms. *Hydrol. Process.*, 19:2277–2289, 2005.
- L. C. Chang and C. C. Yang. Optimizing the rule curves for multi-reservoir operations using a genetic algorithm and hec-5. *Journal of Hydroscience and Hydraulic Engineering*, 20: 59–75, 2002.
- Li-Chiu Chang and Fi-John Chang. Multi-objective evolutionary algorithm for operating parallel reservoir system. *Journal of Hydrology*, 377:12–20, 2009.
- Mrs PM Chaudhari, R VDharaskar, and VM Thakare. Computing the most significant solution from pareto front obtained in multi-objective evolutionary. *IJACSA*, 1:63–68, 2010.
- Li Chen. Real coded genetic algorithm optimization of long term reservoir operation. *JAWRA Journal of the American Water Resources Association*, 39(5):1157–1165, 2003. ISSN 1752-1688. doi: 10.1111/j.1752-1688.2003.tb03699.x.
- Li Chen, James Mcphee, and William W. Yeh. A diversified multiobjective ga for optimizing reservoir rule curves. *Advances in Water Resources*, 30(5):1082–1093, May 2007. doi: 10.1016/j.advwatres.2006.10.001.



- Po-Wen Chiu and CL Bloebaum. Hyper-radial visualization (hrv) with weighted preferences for multi-objective decision making. In *Proceedings of the 12th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference*, pages 10–12, 2008.
- FrankM. Chmielewski, Antje Müller, and Wilfried Kuchler. Possible impacts of climate change on natural vegetation in saxony (germany). *International Journal of Biometeorology*, 50(2):96–104, 2005. ISSN 0020-7128. doi: 10.1007/s00484-005-0275-1.
- Niklas S Christensen, Andrew W Wood, Nathalie Voisin, Dennis P Lettenmaier, and Richard N Palmer. The effects of climate change on the hydrology and water resources of the colorado river basin. *Climatic Change*, 62(1-3):337–363, 2004.
- Carlos A Coello Coello. Theoretical and numerical constraint-handling techniques used with evolutionary algorithms: a survey of the state of the art. *Computer Methods in Applied Mechanics and Engineering*, 191(11-12):1245 – 1287, 2002. ISSN 0045-7825. doi: 10.1016/S0045-7825(01)00323-1.
- Carlos A. Coello Coello. Constraint-handling techniques used with evolutionary algorithms. In *Proceedings of the 12th annual conference companion on Genetic and evolutionary computation, GECCO '10*, pages 2603–2624, New York, NY, USA, 2010. ACM. ISBN 978-1-4503-0073-5. doi: 10.1145/1830761.1830910. URL <http://doi.acm.org/10.1145/1830761.1830910>.
- Thomas Cover and Peter Hart. Nearest neighbor pattern classification. *Information Theory, IEEE Transactions on*, 13(1):21–27, 1967.
- K.A. De Jong. *An Analysis of the Behavior of a Class of Genetic Adaptive Systems*. PhD thesis, University of Michigan,, 1975.
- K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *Evolutionary Computation, IEEE Transactions on*, 6(2):182–197, 2002. ISSN 1089-778X. doi: 10.1109/4235.996017.
- Kalyanmoy Deb. Multi-objective optimization. *Multi-objective optimization using evolutionary algorithms*, pages 13–46, 2001.
- Kalyanmoy Deb. Current trends in evolutionary multi-objective optimization. *International Journal for Simulation and Multidisciplinary Design Optimization*, 1(1):1–8, 2007. doi: 10.1051/ijsmdo:2007001.
- RonS. Dembo. Scenario optimization. *Annals of Operations Research*, 30(1):63–80, 1991. ISSN 0254-5330. doi: 10.1007/BF02204809.

- Deutsches Institut für Normung. *Norm-Entwurf DIN 19700-11 Stauanlagen - Teil 11 Talsperren*. Berlin: Beuth Verlag, 2004.
- DHI WASY. Mike basin, 2013. URL <http://mikebydhi.com/Products/WaterResources/MIKEBASIN.aspx>. Zugriff: 14.09.2013.
- R. Dittmann, F. Froehlich, R. Pohl, and M. Ostrowski. Optimum multi-objective reservoir operation with emphasis on flood control and ecology. *Nat. Hazards Earth Syst. Sci.*, 9:1973–1980, 2009.
- Andrew J Draper, Armin Munevar, Sushil K Arora, Erik Reyes, Nancy L Parker, Francis I Chung, and Lloyd E Peterson. Calsim: Generalized model for reservoir system analysis. *Journal of Water Resources Planning and Management*, 130(6):480–489, 2004.
- Qingyun Duan, Soroosh Sorooshian, and Vijai Gupta. Effective and efficient global optimization for conceptual rainfall-runoff models. *Water resources research*, 28(4): 1015–1031, 1992.
- S. Dyck. *Angewandte Hydrologie – Teil 2: Der Wasserhaushalt der Flussgebiete, 2. Auflage*. Berlin, München, Wilhelm Ernst & Sohn, 1980.
- H. Edelsbrunner, D. G. Kirkpatrick, and R. Seidel. On the shape of a set of points in the plane. *IEEE Transactions on Information Theory*, 29(4):551–559, 1983.
- Andreas Efstratiadis and Demetris Koutsoyiannis. One decade of multi-objective calibration approaches in hydrological modelling: a review. *Hydrological Sciences Journal*, 55:1: 58–78, 2010.
- Matthias Ehrgott. *Multicriteria optimization*. Springer, 2005.
- A.E. Eiben, R. Hinterding, and Z. Michalewicz. Parameter control in evolutionary algorithms. *Evolutionary Computation, IEEE Transactions on*, 3(2):124–141, 1999. ISSN 1089-778X. doi: 10.1109/4235.771166.
- P. Elek and L. Márkus. A long range dependent model with nonlinear innovations for simulating daily river flows. *Natural Hazards and Earth System Science*, 4(2):277–283, 2004. doi: 10.5194/nhess-4-277-2004.
- Michael Emmerich, Nicola Beume, and Boris Naujoks. An emo algorithm using the hypervolume measure as selection criterion. In *Evolutionary Multi-Criterion Optimization*, pages 62–76. Springer, 2005.
- W. Enke. Regionalisierung von klimamodell-ergebnissen des statistischen verfahrens der wetterlagenklassifikation und nachgeordneter multipler regressionsanalyse für sach- sen - abschlussbericht. Technical report, (SMUL), Dresden, 2001.

- Hyung-II Eum and Slobodan P. Simonovic. Integrated reservoir management system for adaptation to climate change: The nakdong river basin in korea. *Water Resources Management*, 24:3397–3417, 2010. ISSN 0920-4741. doi: 10.1007/s11269-010-9612-1.
- Hyung-II Eum, A. Vasan, and P. Simonovic, Slobodan. Integrated reservoir management system for flood risk assessment under climate change. *Water Resources Management*, 26:3785–3802, 2012. ISSN 0920-4741. doi: 10.1007/s11269-012-0103-4.
- FAO. Global hunger declining, but still unacceptably high. Technical report, Food and Agriculture Organization of the United Nations, 2010. URL <http://www.fao.org/docrep/012/a1390e/a1390e00.pdf>.
- M.B. Fiering. Multivariate technique for synthetic hydrology. *Journal of the Hydraulic Division ASCE*, 90:43–60, 1964.
- Jos e Figueira, Salvatore Greco, and Matthias Ehrgott. *Multiple criteria decision analysis: state of the art surveys*, volume 78. Springer, 2005.
- David B Fogel. An introduction to simulated evolutionary optimization. *Neural Networks, IEEE Transactions on*, 5(1):3–14, 1994.
- LJ Fogel. Autonomous automata. *Industrial Research*, 4:14—19, 1962.
- LJ Fogel, AJ Owens, and MJ Walsh. *Artificial Intelligence through Simulated Evolution*. Wiley, New York, 1966.
- Carlos M Fonseca and Peter J Fleming. An overview of evolutionary algorithms in multiobjective optimization. *Evolutionary computation*, 3(1):1–16, 1995.
- H. J. Fowler, C. G. Kilsby, and P. E. O’Connell. Modeling the impacts of climatic change and variability on the reliability, resilience, and vulnerability of a water resource system. *Water Resources Research*, 39:1222, 2003.
- H. J. Fowler, S. Blenkinsop, and C. Tebaldi. Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *International Journal of Climatology*, 27(12):1547–1578, 2007. ISSN 1097-0088. doi: 10.1002/joc.1556.
- Alex A. Freitas. A critical review of multi-objective optimization in data mining: a position paper. *SIGKDD Explor. Newsl.*, 6(2):77–86, December 2004. ISSN 1931-0145. doi: 10.1145/1046456.1046467.
- David E Goldberg and John H Holland. Genetic algorithms and machine learning. *Machine learning*, 3(2):95–99, 1988.

- W.H. Green and G.A. Ampt. Studies of soil physics. part 1. the flow of air and water through soils. *Journal of Agricultural Sciences*, 4:1–24, 1911.
- Stanley L. & Michael C. MacCracken Grotch. The use of general circulation models to predict regional climatic change. *Journal of Chlimate*, 4:286–303, 1991.
- Wei Gu and Yonggang Wu. Application of multi-objective cultural algorithm in water resources optimization. In *Power and Energy Engineering Conference (APPEEC), 2010 Asia-Pacific*, pages 1–4, 2010. doi: 10.1109/APPEEC.2010.5448982.
- Hoshin Vijai Gupta, Soroosh Sorooshian, and Patrice Ogou Yapo. Toward improved calibration of hydrologic models: Multiple and noncommensurable measures of information. *Water Resources Research*, 34(4):751–763, 1998.
- H.V. Gupta, S. Sorooshian, and P.O. Yapo. Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. *Journal of Hydrologic Engineering*, 4:135–143, 1999.
- Mehrdad Hakimi-Asiabar, Seyyed Hassan Ghodsypour, and Reza Kerachian. Multi-objective genetic local search algorithm using kohonen’s neural map. *Computers & Industrial Engineering*, 56(4):1566 – 1576, 2009. ISSN 0360-8352. doi: 10.1016/j.cie.2008.10.010.
- James Douglas Hamilton. *Time series analysis*, volume 2. Cambridge Univ Press, 1994.
- N. Hansen. *Towards a new evolutionary computation. Advances in estimation of distribution algorithms*, chapter The CMA Evolution Strategy: A Comparing Review, pages 75–102. Springer, 2006.
- Julien J. Harou, Didrik Pinte, Amaury Tilmant, David E. Rosenberg, Davidn E. Rheinheimer, and Kristiana Hansen. An open-source model platform for water management that links models to a generic user-interface and data-manager. In *International Environmental Modelling and Software Society (iEMSs) 2010 International Congress on Environmental Modelling and Software Modelling for Environment’s Sake, Fifth Biennial Meeting, Ottawa, Canada*, 2010.
- T Hashimoto, J. R. Stedinger, and D. P. Loucks. Reliability, resiliency, and vulnerability criteria for water resource system performance evaluation. *Water Resour Res*, 1:14–20, 1982. doi: 10.1029/WR018i001p00014.
- Holger Haufe, Thomas Wollenhaupt, Uwe Beetz, Helmut Beyer, Dominik Fiedler, Helfried Hertting, and Olaf Kornmann. Die instandsetzung der talsperre klingenberg-ingenieurtechnische lösungen zur staumauer. In *35. Dresdner Wasserbaukolloquium 2012 „Staubauwerke - Planen, Bauen, Betreiben“*, 2012.

- Simon Haykin. *Neural networks: a comprehensive foundation*. Prentice Hall PTR, 1994.
- John H Holland. *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. U Michigan Press, 1975.
- HD. Hollweg, U. Böhm, I. Fast, B. Hennemuth, K. Keuler, E. Keup-Thiel, M. Lautenschlager, S. Legutke, K. Radtke, B. Rockel, M. Schubert, A. Will, M. Woldt, and C. Wunram. Ensemble simulations over europe with the regional climate model clm forced with ipcc ar4 global scenarios. Technical report, M & D Technical Report, 2008.
- K. Hoshi, S.J. Burges, and I. Yamoka. Reservoir design capacities for various seasonal operational hydrologic models. In *Proc. Jpn. Soc. Civ. Eng.*, volume 35, pages 273–295, 1978.
- Wen-Cheng Huang, Lun-Chin Yuan, and Chi-Ming Lee. Linking genetic algorithms with stochastic dynamic programming to the long-term operation of a multireservoir system. *Water Resources Research*, 38(12):40–1–40–9, 2002. ISSN 1944-7973. doi: 10.1029/2001WR001122.
- H.E. Hurst. Long term storage capacities of reservoirs. *Transactions of ASCE*, 116:776–808, 1951.
- Azhar Husain. An overview of reservoir systems operation techniques. *International Journal of Engineering Research and Development*, 4(10):30–27, 2012.
- C.-L. Hwang and A. S. M. Masud. *Multiple Objective Decision Making - Methods and Applications*. Springer Verlag, Berlin, Germany, 1979.
- Delft Hydraulics. Ribasim: River basin simulation. project completion report to water resources commission. Technical report, Taipei, Taiwan, R.O.C., 1991.
- Hydrologic Engineering Center. *HEC-3 Reservoir System Analysis for Conservation, User Manual*, 1981. URL [www.dtic.mil/cgi-bin/GetTRDoc?AD=ADA235645](http://www.dtic.mil/cgi-bin/GetTRDoc?AD=ADA235645).
- Hydrologic Engineering Center. *HEC-5 Simulation of Flood Control and Conservation Systems, User Manual*. US Army Corps of Engineers, Hydrologic Engineering Center, 1998. URL [www.dtic.mil/dtic/tr/fulltext/u2/a217037.pdf](http://www.dtic.mil/dtic/tr/fulltext/u2/a217037.pdf).
- Hydrologic Engineering Center. Prescriptive reservoir model program (hec-resprm), 2013. URL <http://www.hec.usace.army.mil/software/hec-resprm/>. Zugriff: 14.09.2013.
- Hydrologics Inc. *User manual for OASIS with OCL*, 2009. URL [http://www.hydrologics.net/documents/OASIS\\_Manual14-2010.pdf](http://www.hydrologics.net/documents/OASIS_Manual14-2010.pdf).

- ICOLD. World register of dams. Technical report, International Commission on Large Dams. Paris., 2003.
- ICOLD. International commission on large dams: General synthesis, 2013. URL [http://www.icold-cigb.org/GB/World\\_register/general\\_synthesis.asp](http://www.icold-cigb.org/GB/World_register/general_synthesis.asp). Zugriff 21.011.2013.
- Christian Igel, Nikolaus Hansen, and Stefan Roth. Covariance matrix adaptation for multi-objective optimization. *Massachusetts Institute of Technology, Evolutionary Computation*, 15(1):1–28, 2007.
- Christian Igel, Verena Heidrich-Meisner, and Tobias Glasmachers. Shark. *Journal of Machine Learning Research*, 9:993–996, 2008.
- Nesa Ilich. Shortcomings of linear programming in optimizing river basin allocation. *Water Resources Research*, 44(2), 2008.
- Nesa Ilich. An effective three-step algorithm for multi-site generation of stochastic weekly hydrologic time series. *Hydrological Sciences Journal*, 0(ja):in press, 2013. doi: 10.1080/02626667.2013.822643.
- Nesa Ilich and Jovan Despotovic. A simple method for effective multi-site generation of stochastic hydrologic time series. *Stochastic Environmental Research and Risk Assessment*, 22:265–279, 2008. ISSN 1436-3240. doi: 10.1007/s00477-007-0113-6. 10.1007/s00477-007-0113-6.
- IPCC. 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. Technical report, Geneva (CH), 2007.
- H. Ishibuchi, N. Tsukamoto, and Y. Nojima. Evolutionary many-objective optimization: A short review. In *Evolutionary Computation, 2008. CEC 2008. (IEEE World Congress on Computational Intelligence)*. *IEEE Congress on*, pages 2419–2426, 2008. doi: 10.1109/CEC.2008.4631121.
- H. Jacobson and Q. Mayne. *Differential dynamic programming*. Elsevier, New York, 1970.
- Ma Kai, Lu ShiBao, and Huang Qiang. Application of multi-objective evolutionary algorithm to cascade reservoirs operation. In *Computer Application and System Modeling (ICCA SM), 2010 International Conference on*, volume 8, pages V8–484–V8–487, 2010. doi: 10.1109/ICCA SM.2010.5620276.
- A Kangrang and C Chavalit. Genetic algorithms connected simulation with smoothing function for searching rule curves. *American Journal of Applied Sciences*, 4:73–79, 2007. doi: 10.3844/ajassp.2007.73.79.

- Anongrit Kangrang, Anujit Phumpha, and Witsanukorn Chaiyapoom. Stochastic inflow simulation for searching rule curves. *American Journal of Applied Sciences*, 5:221–226, 2008.
- Holger Kantz and Thomas Schreiber. *Nonlinear time series analysis*, volume 7. Cambridge university press, 2004.
- Avraam Karagiannidis and Nicolas Moussiopoulos. Application of electre iii for the integrated management of municipal solid wastes in the greater athens area. *European Journal of Operational Research*, 97(3):439–449, 1997.
- S Kebede, Y Travi, T Alemayehu, and V Marc. Water balance of lake tana and its sensitivity to fluctuations in rainfall, blue Nile basin, ethiopia. *Journal of hydrology*, 316(1):233–247, 2006.
- Byung Sik Kim, Hung Soo Kim, and Byung Ha Seoh. Streamflow simulation and skewness preservation based on the bootstrapped stochastic models. *Stochastic Environmental Research and Risk Assessment*, 18:386–400, 2004. ISSN 1436-3240. doi: 10.1007/s00477-004-0212-6. 10.1007/s00477-004-0212-6.
- T. Kim and J. Valdés. Synthetic generation of hydrologic time series based on nonparametric random generation. *Journal of Hydrologic Engineering*, 10 (5):395–404, 2005.
- Taesoon Kim and Jun-Haeng Heo. Application of multi-objective genetic algorithms to multireservoir system optimization in the han river basin. *KSCIE Journal of Civil Engineering*, 10(5):371–380, 2006. ISSN 1226-7988. doi: 10.1007/BF02830091.
- Taesoon Kim, Jun-Haeng Heo, Deg-Hyo Bae, and Jin-Hoon Kim. Single-reservoir operating rules for a year using multiobjective genetic algorithm. *Journal of Hydroinformatics*, 10.1:163–179, 2008.
- Özgür Kişi. Streamflow forecasting using different artificial neural network algorithms. *Journal of Hydrologic Engineering*, 12(5):532–539, 2007.
- Thomas Rodding Kjeldsen and Dan Rosbjerg. Choice of reliability, resilience and vulnerability estimators for risk assessments of water resources systems/choix d’estimateurs de fiabilité, de résilience et de vulnérabilité pour les analyses de risque de systèmes de ressources en eau. *Hydrological sciences journal*, 49(5), 2004.
- V. Klemes. Sensitivity of water resource systems to climate variations. Technical report, World Climate Application Programme WCP-988, World Meteorological Organization, 1985.
- T. Kohonen. *Self-organizing maps*, volume 30. Springer Verlag, 2001.

- D. Koutsoyiannis. A generalized mathematical framework for stochastic simulation and forecast of hydrologic time series. *Water Resources Research*, 36(6):1519–1534, 2000.
- D. Koutsoyiannis. The hurst phenomenon and fractional gaussian noise made easy. *Hydrological Sciences Journal*, 47(4):573–595, 2002.
- D Koutsoyiannis, A Efstratiadis, and G Karavokiros. A decision support tool for the management of multi-reservoir systems. *JAWRA Journal of the American Water Resources Association*, 38(4):945–958, 2002.
- Demetris Koutsoyiannis. *Reliability Concepts in Reservoir Design*. John Wiley & Sons, Inc., 2005. ISBN 9780471478447. doi: 10.1002/047147844X.sw776.
- Demetris Koutsoyiannis and Athanasia Economou. Evaluation of the parameterization-simulation-optimization approach for the control of reservoir systems. *Water Resources Research*, 39(6):1170–1187, 2003. ISSN 1944-7973. doi: 10.1029/2003WR002148.
- Oliver Kramer. A review of constraint-handling techniques for evolution strategies. *Applied Computational Intelligence and Soft Computing*, 2010:11 pages, 2010. doi: 10.1155/2010/185063.
- P. Krause, D. P. Boyle, and F. Bäse. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*, 5:89–97, 2005.
- p F. Kreienkam, A. Spekat, and W . Enke. Ergebnisse eines regionalen szenarienlaufs für deutschland mit dem statistischen modell wettreg 2010. Technical report, Climate & Environment Consulting Potsdam GmbH. Bericht an Umweltbundesamt, 2010.
- Daniel Krige. A statistical approach to some basic mine valuation problems on the witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society of South Africa*, 52:199–139, 1951.
- D. Nagesh Kumar and M. Janga Reddy. Ant colony optimization for multi-purpose reservoir operation. *Water Resources Management*, 20:879–898, 2006.
- D. Nagesh Kumar, D.S.V. Prasad, and K. Srinivasa Raju. Optimal reservoir operation using fuzzy approach. In *Proce. of Int. Conf. on Civil Engrg., Bangalore, India, Interline Publishing*, pages 377–384, 2001.
- John W. Labadie. Modsim: River basin network flow model for conjunctive stream-aquifer management program. user manual and documentation. Technical report, Colorado State University, 1995.
- John W. Labadie. Optimal operation of multireservoir systems: State-of-the-art review. *Journal of Water Resources Planning and Management*, 130:93–111, 2004.



- U. Lall and A. Sharma. A nearest neighbor bootstrap for resampling hydrologic time series. *Water Resources Research*, 32(3):679–693, 1996.
- Andreas Langousis and Demetris Koutsoyiannis. Mathematical derivations for seasonal models reproducing overyear scaling behaviour. Technical report, Internal report, Department of Water Resources, Hydraulic and Maritime Engineering-National Technical University of Athens (<http://www.itia.ntua.gr/getfile/599/2/2003StochMethodsSeasonalScaleApp.pdf>), 2003.
- Andreas Langousis and Demetris Koutsoyiannis. A stochastic methodology for generation of seasonal time series reproducing overyear scaling behaviour. *Journal of Hydrology*, 322:138–154, 2006.
- Hoël Langouët, Ludovic Métivier, Delphine Sinoquet, and Quang-Huy Tran. Engine calibration: multi-objective constrained optimization of engine maps. *Optimization and Engineering*, 12:407–424, 2011. ISSN 1389-4420. doi: 10.1007/s11081-011-9140-8. 10.1007/s11081-011-9140-8.
- O. I. Larichev. Cognitive validity in design of decision-aiding techniques. *Journal of Multi-Criteria Decision Analysis*, 1(3):127–138, 1992. ISSN 1099-1360. doi: 10.1002/mcda.4020010303.
- GeorgeH. Leavesley. Modeling the effects of climate change on water resources - a review. *Climatic Change*, 28(1-2):159–177, 1994. ISSN 0165-0009. doi: 10.1007/BF01094105.
- T. Lee, D. Salas, and J. Prairie. An enhanced nonparametric streamflow disaggregation model with genetic algorithm. *Water Resources Research*, 46:W08545, 2010.
- N. Lerma, J. Paredes-Arquiola, J. Andreu, and A. Solera. Development of operating rules for a complex multi-reservoir system by coupling genetic algorithms and network optimization. *Hydrological Sciences Journal*, 58(4):797–812, 2013. doi: 10.1080/02626667.2013.779777.
- Dennis P Lettenmaier and Daniel P Sheer. Climatic sensitivity of california water resources. *Journal of Water Resources Planning and Management*, 117(1):108–125, 1991.
- Dedi Liu, Shenglian Guo, Xiaohong Chen, Quanxi Shao, Qihua Ran, Xingyuan Song, and Zhaoli Wang. A macro-evolutionary multi-objective immune algorithm with application to optimal allocation of water resources in dongjiang river basins, south china. *Stochastic Environmental Research and Risk Assessment*, 26(4):491–507, 2012. ISSN 1436-3240. doi: 10.1007/s00477-011-0505-5.

- Yang Liu. Automatic calibration of a rainfall–runoff model using a fast and elitist multi-objective particle swarm algorithm. *Expert Systems with Applications*, 36(5):9533 – 9538, 2009. ISSN 0957-4174. doi: 10.1016/j.eswa.2008.10.086.
- Yang Liu and Fan Sun. Sensitivity analysis and automatic calibration of a rainfall–runoff model using multi-objectives. *Ecological Informatics*, 5(4):304 – 310, 2010. ISSN 1574-9541. doi: 10.1016/j.ecoinf.2010.04.006.
- Alexander V Lotov and Kaisa Miettinen. Visualizing the pareto frontier. In *Multiobjective optimization*, pages 213–243. Springer, 2008.
- A.V Lotov. Exploration of economic systems with the help of reachable sets. In *Proceedings of the International Conference on Modeling of Economic Processes*, pages 132–137. Computer Center of the USSR Academy of Sciences, Moscow, RUS, 1975.
- D. P Loucks and O.T. Sigvaldas. *Multiple reservoir operation in North America*. International Institute for Applied Systems Analysis, Polish Academy of Sciences, 1982.
- Daniel P Loucks, Jery R Stedinger, Douglas A Haith, et al. *Water Resource Systems Planning and Analysis*. Prentice-Hall., 1981.
- J. Lund and J. Guzman. Derived operating rules for reservoirs in series or in parallel. *Journal of Water Resources Planning and Management*, 125(3):143–153, 1999. doi: 10.1061/(ASCE)0733-9496(1999)125:3(143). URL 29.
- Jay R Lund and Inês Ferreira. Operating rule optimization for missouri river reservoir system. *Journal of Water Resources Planning and Management*, 122(4):287–295, 1996.
- David J. C. Mackay. A practical bayesian framework for backpropagation networks. *Neural Computation*, 4:448–472, 1992. doi: 10.1162/neco.1992.4.3.448.
- H Madsen. Automatic calibration of a conceptual rainfall–runoff model using multiple objectives. *Journal of Hydrology*, 235(3–4):276 – 288, 2000. ISSN 0022-1694. doi: 10.1016/S0022-1694(00)00279-1.
- Bahram Malekmohammadi, Banafsheh Zahraie, and Reza Kerachian. Ranking solutions of multi-objective reservoir operation optimization models using multi-criteria decision analysis. *Expert Systems with Applications*, 38(6):7851 – 7863, 2011. ISSN 0957-4174. doi: 10.1016/j.eswa.2010.12.119.
- Ulrich Maniak. *Hydrologie und Wasserwirtschaft, Eine Einführung für Ingenieure*. Springer-Verlag Berlin Heidelberg New York, 2005.

- Michael D McKay, Richard J Beckman, and William J Conover. Comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 21(2):239–245, 1979.
- Dany Meyer. *Modellbasierte Mehrzieloptimierung mit Neuronalen Netzen und Evolutionstrategien*. PhD thesis, Technische Universität Ilmenau, 2004.
- Efrén Mezura-Montes and Carlos A. Coello Coello. A survey of constraint-handling techniques based on evolutionary multiobjective optimization. *PPSN*, 2008. doi: 10.1.1.103.4087.
- Zbigniew Michalewicz. A survey of constraint handling techniques in evolutionary computation methods. In *Proceedings of the 4th Annual Conference on Evolutionary Programming*, pages 135–155. MIT Press, 1995.
- George A Miller. The magical number seven, plus or minus two: some limits on our capacity for processing information. *Psychological review*, 63(2):81, 1956.
- Marie Minville, Francois Brissette, and Robert Leconte. Impacts and uncertainty of climate change on water resource management of the peribonka river system (canada). *Journal of Water Resources Planning and Management*, 136(3):376–385, 2010. doi: 10.1061/(ASCE)WR.1943-5452.0000041.
- Sh Momtahan and AB Dariane. Direct search approaches using genetic algorithms for optimization of water reservoir operating policies. *Journal of water resources planning and management*, 133(3):202–209, 2007.
- A. Montanari, M. Longoni, and R. Rosso. A seasonal long-memory stochastic model for the simulation of daily river flows. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 24(4):319 – 324, 1999. ISSN 1464-1909. doi: 10.1016/S1464-1909(99)00007-6.
- Gerd Morgenschweis, Georg zur Strassen, Simone Patzke, and Dirk Schwanenberg. Abschätzung der auswirkung von möglichen klimaänderungen auf die bewirtschaftung der talsperren im einzugsgebiet der ruhr. *Sonderdruck aus Jahresbericht Ruhrwassermenge 2006*, pages S.32–50, 2007.
- D. N. Moriasi, J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, and T. L. Veith. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3):885–900, 2002.
- U. Müller and A. Waldeck. Auswertungsmethoden im bodenschutz – dokumentation zur methodenbank des niedersächsischen bodeninformationssystems (nibis). Technical

- report, GeoBerichte 19, Landesamt für Bergbau, Energie und Geologie Niedersachsen, Hannover., 2011.
- N. Nakivenovic and R. Swart. *Special Report on Emissions Scenarios. A special report of working group III of the Intergovernmental Panel on Climate Change*. S. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2000.
- I. Nalbantis and D. Koutsoyiannis. A parametric rule for planning and management of multiple-reservoir systems. *Water Resources Research*, 33(9):2165–2177, 1997. ISSN 1944-7973. doi: 10.1029/97WR01034.
- J. E. Nash and J. V. Sutcliffe. River flow forecasting through conceptual models: Part 1. a discussion of principles. *Journal of Hydrology*, 10(3):282–290, 1970.
- N. R. Nawaz, A. J. Adeloye, and M. Montaseri. The impact of climate change on storage-yield curves for multi-reservoir systems. *Nordic Hydrology*, 30:126–146, 1999.
- A. Nazemi, H. S. Wheater, K. P. Chun, and A. Elshorbagy. A stochastic reconstruction framework for analysis of water resource system vulnerability to climate-induced changes in river flow regime. *Water Resources Research*, 2012, in press.
- John Ndiritu. A variable-length block bootstrap method for multi-site synthetic streamflow generation. *Hydrological Sciences Journal*, 56(3):362–379, 2011. doi: 10.1080/02626667.2011.562471.
- J Němec and John Schaake. Sensitivity of water resource systems to climate variation. *Hydrological Sciences Journal*, 27(3):327–343, 1982.
- Mark New, Ana Lopez, Suraje Dessai, and Rob Wilby. Challenges in using probabilistic climate change information for impact assessments: an example from the water sector. *Phil. Trans. R. Soc. A*, 1857, no. 365:2117–2131, 2007.
- Long Le Ngo, Hendrik Madsen, and Dan Rosbjerg. Simulation and optimisation modelling approach for operation of the hoa binh reservoir, vietnam. *Journal of Hydrology*, 336: 269–281, 2007.
- Volker Nissen. *Einführung in Evolutionäre Algorithmen: Optimierung nach dem Vorbild der Natur*. Verlag Vieweg, 1997.
- Shigeru Obayashi and Daisuke Sasaki. Visualization and data mining of pareto solutions using self-organizing map. In *Proceedings of the 2nd international conference on Evolutionary multi-criterion optimization*, EMO’03, pages 796–809, Berlin, Heidelberg, 2003. Springer-Verlag. ISBN 3-540-01869-7. URL <http://dl.acm.org/citation.cfm?id=1760102.1760166>.

- J. C. Ochoa-Rivera, R. García-Bartual, and J. Andreu. Multivariate synthetic streamflow generation using a hybrid model based on artificial neural networks. *Hydrology and Earth System Sciences*, 6 (4):641–654, 2002.
- R. Oliveira and D. P. Loucks. Operating rules for multireservoir systems. *Water Resour. Res.*, 33(4):839–852, 1997. doi: 10.1029/96WR03745.
- Marius Ooms and Philip Hans Franses. A seasonal periodic long memory model for monthly river flows. *Environmental Modelling & Software*, 16(6):559 – 569, 2001. ISSN 1364-8152. doi: 10.1016/S1364-8152(01)00025-1. <ce:title>Economics and Environmental Modelling</ce:title>.
- OpenMP Architecture Review Board. Openmp application program interface, version 2.0, 04 2002.
- G. Peschke. Ein zweistufiges modell der infiltration von regen in geschichteten böden. *Acta Hydrophysica*, 22 (1):39–48, 1977.
- Daniele Prada. *Multiobjective optimization for parameter extraction of power electronics devices*. PhD thesis, politecnico di milano, 2012.
- J. R. Prairie, B. Rajagopalan, T. J. Fulp, and E. A. Zagona. Modified k-nn model for stochastic streamflow simulation. *Journal of Hydrologic Engineering*, 11:371–378, 2006. vorgänger zu ashr. hknn.
- Andy Pryke, Sanaz Mostaghim, and Alireza Nazemi. Heatmap visualization of population based multi objective algorithms. In *Proceedings of the 4th international conference on Evolutionary multi-criterion optimization*, EMO'07, pages 361–375, Berlin, Heidelberg, 2007. Springer-Verlag. ISBN 978-3-540-70927-5.
- B. Rajagopalan, J. Salas, and U. Lall. *Advances in Data-Based Approaches for Hydrologic Modeling and Forecasting*, chapter Stochastic methods for modeling precipitation and streamflow. World Scientific, 2009.
- Deepashree Raje and P.P. Mujumdar. Reservoir performance under uncertainty in hydrologic impacts of climate change. *Advances in Water Resources*, 33(3):312 – 326, 2010. ISSN 0309-1708. doi: 10.1016/j.advwatres.2009.12.008.
- H. Raman and N. Sunilkumar. Multivariate modelling of water resources time series using artificial neural networks. *Hydrological Sciences Journal*, 40(2):145–163, 1995. doi: 10.1080/02626669509491401.
- Deepti Rani, Moreira, and Maria Madalena. Simulation–optimization modeling: A survey and potential application in reservoir systems operation. *Water Resour Manage*, 24: 1107–1138, 2010.

- P. F Rasmussen, J. D. Salas, L. Fagherazzi, J.-C. Rassam, and B. Bobée. Estimation and validation of contemporaneous parma models for streamflow simulation. *Water Resources Research*, 32(10):3151–3160, 1996.
- Ingo Rechenberg. *Cybernetic solution path of an experimental problem*. Royal Aircraft Establishment, Farnborough p. Library Translation 1122, 1965.
- Ingo Rechenberg. *Optimierung technischer Systeme nach Prinzipien der biologischen Evolution*. Stuttgart, Fommann-Holzboog, 1973.
- Janga M. Reddy and Nagesh D. Kumar. Multiobjective differential evolution with application to reservoir system optimization. *Journal of Computing in Civil Engineering*, 21(2):136–146, 2007a.
- M. J. Reddy and Nagesh D Kumar. Optimal reservoir operation using multi-objective evolutionary algorithm. *Water Resources Management*, 20:861–878, 2006.
- M. Janga Reddy and D. Nagesh Kumar. Multi-objective particle swarm optimization for generating optimal trade-offs in reservoir operation. *Hydrological Processes*, 21(21):2897–2909, 2007b. ISSN 1099-1085. doi: 10.1002/hyp.6507.
- M. Janga Reddy and Nagesh D. Kumar. Optimal reservoir operation for irrigation of multiple crops using elitist-mutated particle swarm optimization. *Hydrological Sciences Journal*, 52(4):686–701, 2007c. doi: 10.1623/hysj.52.4.686.
- M.Janga Reddy and Nagesh D. Kumar. Evolving strategies for crop planning and operation of irrigation reservoir system using multi-objective differential evolution. *Irrigation Science*, 26:177–190, 2008. ISSN 0342-7188. doi: 10.1007/s00271-007-0084-x.
- D. Regulwar and P. Raj. Multi objective multireservoir optimization in fuzzy environment for river sub basin development and management. *Journal of Water Resource and Protection*, 1 (4):271–280, 2009.
- D. E. Reusser, T. Blume, B. Schaepli, and E. Zehe. Analysing the temporal dynamics of model performance for hydrological models. *Hydrology and Earth System Sciences*, 13(7):999–1018, 2009. doi: 10.5194/hess-13-999-2009.
- Mark W Rosegrant. *Two Thousand Twenty Global Food Outlook: Trends, Alternatives, and Choices*. Intl Food Policy Res Inst, 2001.
- Mark W Rosegrant, Ximing Cai, and Sarah A Cline. *World water and food to 2025: dealing with scarcity*. Intl Food Policy Res Inst, 2002.
- J.D. Salas, Delleur, V. J.W.and Yevjevich, and W.L. Lane. *Applied Modeling of Hydrologic Time Series*. 1980.

- A. H. Saliha, S. B. Awulachew, J. Cullmann, and Horlacher H.-B. Estimation of flow in ungauged catchments by coupling a hydrological model and neural networks: case study. *Hydrology Research*, 42.5, 2011. doi: 10.2166/nh.2011.157.
- Alemayehu Habte Saliha. *Decision Support Tool to Optimize the Operation of Multi-Purpose Reservoirs: A Case Study in the Lake Tana Catchment, Ethiopia*. PhD thesis, Technische Universität Dresden, 2012.
- R. Sarvas. *Investigations on the annual cycle of development of forest trees II. Autumn dormancy and winter dormancy*, volume 84 (1), pages 1–101. Communicationes Instituti Forestalis Fenniae, 1974.
- M.G. Schapp, F.J. Leij, and M.Th. van Genuchten. rosetta: A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *Journal of Hydrology*, 251 (3):163–176, 2001.
- A. Schardong, S. Simonovic, and A. Vasan. Multiobjective evolutionary approach to optimal reservoir operation. *Journal of Computing in Civil Engineering*, 27(2):139–147, 2013. doi: 10.1061/(ASCE)CP.1943-5487.0000213.
- O. Schmidt and E. Plate. Optimaler wasserwirtschaftlicher speicherbetrieb. *Zeitschrift für Operations Research*, 27:1–19, 1983.
- J. Schulla. Model description wasim (water balance simulation model). Technical report, Hydrology Software Consulting J. Schulla, 2012.
- H-P Schwefel. *Evolutionsstrategie und numerische Optimierung*. PhD thesis, TU Berlin, Germany, 1975.
- L.A. Scola, O.M. Neto, R. H C Takahashi, and S.A.A.G. Cerqueira. Multi-objective optimal reservoir operation. In *Evolutionary Computation (CEC), 2010 IEEE Congress on*, pages 1–5, 2010. doi: 10.1109/CEC.2010.5586361.
- L.A. Scola, O.M. Neto, R.H.C. Takahashi, and S.A.A.G. Cerqueira. Multi-objective optimal multiple reservoir operation. In *Evolutionary Computation (CEC), 2011 IEEE Congress on*, pages 1927–1933, 2011. doi: 10.1109/CEC.2011.5949851.
- David W Scott. Kernel density estimators. *Multivariate Density Estimation: Theory, Practice, and Visualization*, pages 125–193, 2008.
- M. Shafii and F. De Smedt. Multi-objective calibration of a distributed hydrological model (wetspa) using a genetic algorithm. *Hydrology and Earth System Sciences*, 13(11): 2137–2149, 2009. doi: 10.5194/hess-13-2137-2009.

- Eylon Shamir, Jianzhong Wang, and Konstantine P. Georgakakos. Probabilistic streamflow generation model for data sparse arid watersheds1. *JAWRA Journal of the American Water Resources Association*, 43(5):1142–1154, 2007. ISSN 1752-1688. doi: 10.1111/j.1752-1688.2007.00094.x.
- A. Sharma and R. O’Neill. A nonparametric approach for representing interannual dependence in monthly streamflow sequences. *Water Resources Research*, 38(7):1–10, 2002.
- Daniel P. Sheer. Schriftliche mitteilung 23.08.2013, 27.08 2013.
- OferM. Shir, Jonathan Roslund, Zaki Leghtas, and Herschel Rabitz. Quantum control experiments as a testbed for evolutionary multi-objective algorithms. *Genetic Programming and Evolvable Machines*, 13(4):445–491, 2012. ISSN 1389-2576. doi: 10.1007/s10710-012-9164-7.
- M. Shourian, S.J. Mousavi, and A. Tahershamsi. Basin-wide water resources planning by integrating pso algorithm and modsim. *Water Resour Manage*, 22:1347–1366, 2008.
- H-U Sieber. Talsperren als multifunktionale anlagen. *Wasserwirtschaft Wassertechnik*, pages 17–21, 2003.
- Hans-Ulrich Sieber. *Talsperren in Sachsen*. Landestalsperrenverwaltung des Freistaates Sachsen, 1992.
- M. A. Soltani, A. Karimi, M. R. Bazargan-Lari, and Shirangi. E. Stochastic multi-purpose reservoir operation planning by scenario optimization and differential evolutionary algorithm. *Journal of applied Sciences*, 10.3923/jas.2008.4186.4191(22):4186–4191, 2008. doi: 10.3923/jas.2008.4186.4191.
- A. Spekat, W. Enke, and F. Kreienkamp. Neuentwicklung von regional hoch aufgelösten wetterlagen für deutschland und bereitstellung regionaler klimaszenarios auf der basis von globalen klimasimulationen mit dem regionalisierungsmodell wettreg auf der basis von globalen klimasimulationen mit echam5/mpicom t63 l31 2010 bis 2100 für die sres-szenarios b1, a1b und a2. endbericht,. Technical report, Umweltbundesamt, 2007.
- V.V. Srinivas and K. Srinivasan. Hybrid matched-block bootstrap for stochastic simulation of multiseason streamflows. *Journal of Hydrology*, 329(1-2):1 – 15, 2006. ISSN 0022-1694. doi: 10.1016/j.jhydrol.2006.01.023. excellent overview in intro.
- Michael L. Stein. *Interpolation of Spatial Data: Some Theory for Kriging*. Springer Series in Statistics, 1999.



- Scott Steinschneider, Austin Polebitski, Casey Brown, and Benjamin H. Letcher. Toward a statistical framework to quantify the uncertainties of hydrologic response under climate change. *Water Resources Research*, 48(11):n/a–n/a, 2012. ISSN 1944-7973. doi: 10.1029/2011WR011318.
- Stockholm Environment Institute. Weap: Water evaluation and planning. Technical report, Tellus Institute, Boston, 1999.
- & Eduardo Zorita & Ulrich Cubasch Storch, Hans. Downscaling of global climate change estimates to regional scales: An application to iberian rainfall in wintertime. *Journal of Climate*, 6:1161–1171, 1993.
- K P Sudheer, K. Srinivasan, T R Neelakanthan, and V V Srinivas. A nonlinear data-driven model for synthetic generation of annual streamflows. *Hydrological Processes*, 22(12): Art. No. W04004, January 2008.
- Watchara Suiadee and Tawatchai Tingsanchali. A combined simulation–genetic algorithm optimization model for optimal rule curves of a reservoir: a case study of the namoon irrigation project, thailand. *Hydrological Processes*, 21(23):3211–3225, 2007. ISSN 1099-1085. doi: 10.1002/hyp.6528.
- SYDRO. Talsim 2.2, 09 2013. URL [http://www.sydro.de/de/soft\\_detail.asp?id=9&menu=3&content=17](http://www.sydro.de/de/soft_detail.asp?id=9&menu=3&content=17). Zugriff: 14.09.2013.
- H Taboada and David W Coit. Data clustering of solutions for multiple objective system reliability optimization problems. *Quality Technology & Quantitative Management Journal*, 4(2):35–54, 2007.
- Heidi A Taboada and David W Coit. Data mining techniques to facilitate the analysis of the pareto-optimal set for multiple objective problems. In *Proceedings of the industrial engineering research conference, IERC*, 2006.
- Lena M Tallaksen, Henrik Madsen, and Bente Clausen. On the definition and modelling of streamflow drought duration and deficit volume. *Hydrological Sciences Journal*, 42(1): 15–33, 1997.
- Ming-Yen Tu, Nien-Sheng Hsu, and William W-G Yeh. Optimization of reservoir management and operation with hedging rules. *Journal of Water Resources Planning and Management*, 129(2):86–97, 2003.
- Ching P. Tung, Shao Y. Hsu, Chia M. Liu, and Jr S. Li. Application of the genetic algorithm for optimizing operation rules of the liyutan reservoir in taiwan. *Journal of the American Water Resources Association*, 39(3):649–657, 2003. doi: 10.1111/j.1752-1688.2003.tb03682.x.

- Tea Tušar and Bogdan Filipic. Visualizing 4d approximation sets of multiobjective optimizers with projections. In *2011 Genetic and Evolutionary Computation Conference (GECCO'2011)*, pages 737–744, 2011.
- M. TH. van Genuchten. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. *Soil Sciences Society of American Journal*, 44(5):892–898, 1980.
- MHJ Van Huijgevoort, P Hazenberg, HAJ Van Lanen, and R Uijlenhoet. A generic method for hydrological drought identification across different climate regions. *Hydrology & Earth System Sciences*, 16(8), 2012.
- David A. Van Veldhuizen and Gary B. Lamont. Multiobjective evolutionary algorithms: Analyzing the state-of-the-art. *Evol. Comput.*, 8(2):125–147, 2000. ISSN 1063-6560. doi: 10.1162/106365600568158.
- A. V. Vecchia. Periodic autoregressive-moving average (parma) modeling with applications to water resources. *Journal of the American Water Resources Association*, 21:721–730, 1985.
- Varsha Veerappa and Emmanuel Letier. Understanding clusters of optimal solutions in multi-objective decision problems. In *Requirements Engineering Conference (RE), 2011 19th IEEE International*, pages 89–98. IEEE, 2011.
- Juha Vesanto, Johan Himberg, Esa Alhoniemi, and Juha Parhankagas. Som toolbox for matlab 5, report a57. Technical report, Helsinki University of Technology, 2000.
- Richard M. Vogel and Amy L. Shallcross. The moving blocks bootstrap versus parametric time series models. *Water Resources Research*, 32 (6):1875–1882, 1996.
- Thomas Voß, Nikolaus Hansen, and Christian Igel. Recombination for learning strategy parameters in the mo-cma-es. In *Evolutionary Multi-Criterion Optimization*, pages 155–168. Springer, 2009.
- Thomas Voß, Nikolaus Hansen, and Christian Igel. Improved step size adaptation for the mo-cma-es. In *Proceedings of the 12th annual conference on Genetic and evolutionary computation, GECCO '10*, pages 487–494, New York, NY, USA, 2010. ACM. ISBN 978-1-4503-0072-8. doi: 10.1145/1830483.1830573.
- Jasper A. Vrugt, Hoshin V. Gupta, Luis A. Bastidas, Willem Bouten, and Soroosh Sorooshian. Effective and efficient algorithm for multiobjective optimization of hydrologic models. *Water Resources Research*, 39(8):n/a–n/a, 2003. ISSN 1944-7973. doi: 10.1029/2002WR001746.

- Charles J. Vörösmarty, Pamela Green, Joseph Salisbury, and Richard B. Lammers. Global water resources: Vulnerability from climate change and population growth. *Science*, 289(5477):284–288, 2000. doi: 10.1126/science.289.5477.284.
- Larry Wall, Tom Christiansen, and Jon Orwant. *Programming Perl, 3rd Edition*. O’Reilly Media, 2000.
- WCD. *Dams and Development: A New Framework for Decision-making: the Report of the World Commission on Dams, November 2000*. Earthscan, 2000.
- W. R. White. *World water: resources, usage and the role of man-made reservoirs*. Foundation for Water Research, 2010. URL [www.fwr.org](http://www.fwr.org).
- WHO/UNICEF. *Progress on Drinking Water and Sanitation: 2012 Update*. WHO/UNICEF, 2012.
- R. L. Wilby and I. Harris. A framework for assessing uncertainties in climate change impacts: Low-flow scenarios for the river thames, uk. *Water Resources Research*, 42(2): 1–10, 2006. ISSN 1944-7973. doi: 10.1029/2005WR004065.
- Robert L. Wilby. Uncertainty in water resource model parameters used for climate change impact assessment. *Hydrological Processes*, 19(16):3201–3219, 2005. ISSN 1099-1085. doi: 10.1002/hyp.5819.
- Ulf Winkler. Die talsperrenbewirtschaftung im spannungsfeld von trockenperioden und hochwasserereignissen, <http://www.umwelt.sachsen.de/umwelt/klima/1304.htm>, (juni 2013). 2009.
- W. L. Winston. *Operations Research, Applications and Algorithms*. Duxbury, Boston, Mass, 3rd ed edition, 1994.
- Douglas A Wolfe and Myles Hollander. Nonparametric statistical methods. *Nonparametric statistical methods*, 1973.
- R. A. Wurbs. Computer models for water resources planning and management. Technical report, U.S. Army Corps of Engineers, Institute for Water Resources, 1994.
- Ralph A Wurbs. Reservoir-system simulation and optimization models. *Journal of water resources planning and management*, 119(4):455–472, 1993.
- Ralph A. Wurbs. Modeling river/reservoir system management, water allocation, and supply reliability. *Journal of Hydrology*, 300:100–113, 2005.
- Thomas Wöhling, Luis Samaniego, and Rohini Kumar. Evaluating multiple performance criteria to calibrate the distributed hydrological model of the upper neckar catchment.

- Environmental Earth Sciences*, 69(2):453–468, 2013. ISSN 1866-6280. doi: 10.1007/s12665-013-2306-2.
- J.H.M. Wösten and A. Nemes. Pedotransfer functions for europe. In Y. Pachepsky and W.J. Rawls, editors, *Development of Pedotransfer Functions in Soil Hydrology*, volume 30 of *Developments in Soil Science*, pages 431 – 435. Elsevier, 2004. doi: 10.1016/S0166-2481(04)30022-X.
- C.-Y. Xu and V. P. Singh. Review on regional water resources assessment models under stationary and changing climate. *Water Resources Management*, 18(6):591–612, 2004. ISSN 0920-4741. doi: 10.1007/s11269-004-9130-0.
- Sidney Yakowitz. Dynamic programming applications in water resources. *Water Resources Research*, 18(4):673–696, 1982.
- Patrice Ogou Yapo, Hoshin Vijai Gupta, and Soroosh Sorooshian. Multi-objective global optimization for hydrologic models. *Journal of Hydrology*, 204(1–4):83 – 97, 1998. ISSN 0022-1694. doi: [http://dx.doi.org/10.1016/S0022-1694\(97\)00107-8](http://dx.doi.org/10.1016/S0022-1694(97)00107-8).
- William W-G. Yeh. Reservoir management and operations models: A state-of-the-art review. *Water Resources Research*, 21(12):1797–1818, 1985. ISSN 1944-7973. doi: 10.1029/WR021i012p01797.
- Lotfi A Zadeh. Fuzzy sets. *Information and control*, 8(3):338–353, 1965.
- Emir Zelenhasić and Atila Salvai. A method of streamflow drought analysis. *Water Resources Research*, 23(1):156–168, 1987.
- Aimin Zhou, Bo-Yang Qu, Hui Li, Shi-Zheng Zhao, Ponnuthurai Nagarathnam Suganthan, and Qingfu Zhang. Multiobjective evolutionary algorithms: A survey of the state of the art. *Swarm and Evolutionary Computation*, 1(1):32 – 49, 2011. ISSN 2210-6502. doi: 10.1016/j.swevo.2011.03.001.
- E. Zio and R. Bazzo. Optimization of the test intervals of a nuclear safety system by genetic algorithms, solutions clustering and fuzzy preferenz assigment. *Nuclear Engineering and Technology*, 42:414–425, 2010.
- E. Zio and R. Bazzo. A clustering procedure for reducing the number of representative solutions in the pareto front of multiobjective optimization problems. *European Journal of Operational Research*, 210(3):624 – 634, 2011. ISSN 0377-2217. doi: 10.1016/j.ejor.2010.10.021.

# Abbildungsverzeichnis

2.1	Gängige Einteilung des Stauraums bei Mehrzweck-Talsperren. . . . .	9
2.2	Klassifikation der Lösungsstrategien für multikriterielle Optimierungsprobleme	11
2.3	Schema zur multikriteriellen Optimierung. . . . .	14
2.4	Prinzipieller Ablauf eines evolutionären Algorithmus. . . . .	21
2.5	Prinzipieller Ablauf der simulationsbasierten Optimierung. . . . .	24
3.1	Modellkaskade zur Bewertung von Klimaveränderungen auf die Wasserverfügbarkeit in der Mesoskala. . . . .	33
5.1	Framework zur multikriteriellen simulationsbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen. . . . .	45
6.1	Modellkonzept von WaSiM-ETH (nach Schulla, 2012). . . . .	48
6.2	Schema eines künstlichen neuronalen Netzwerks. . . . .	55
6.3	Schema des Folgescheitelalgorithmus. . . . .	59
6.4	Ablaufschema der Monte-Carlo-Rekombinationsmethode. . . . .	62
6.5	Simulationsmodellaufrufe durch die psMO-CMA-ES . . . . .	66
6.6	Entscheidungsraum und Zielfunktionsraum . . . . .	70
6.7	Vergleichende Darstellung eines MKO-Problems als 3D-Plot und als Level-Diagramm. . . . .	78
8.1	Übersichtskarte zum Talsperrenverbundsystem der Talsperren Klingenberg, Lehmühle und Rauschenbach. . . . .	84
8.2	Schematischer Überblick über die Topographie des Talsperrenverbundsystems, allen lokalen Zuflüssen und wichtiger Bewirtschaftungsziele. . . . .	86
8.3	Schema der Bereitstellungsstufen innerhalb der virtuellen Talsperre . . . . .	88
8.4	Modellkaskade in Modul A zur Klimafolgenanalyse für die Fallstudie 1. . . . .	89
8.5	Aufteilung des Einzugsgebiet in die Modellgebiete A, B und C. . . . .	91
8.6	Pareto-Fronten des Modellgebiets A und des Modellgebiets C. . . . .	95
8.7	Abflussspenden der Modellgebiete A und C im Kalibrierungszeitraum auf täglicher Zeitskala. . . . .	96
8.8	Abflussspenden der Modellgebiete A und C im Validierungszeitraum auf täglicher Zeitskala. . . . .	97

8.9	Vergleich der Trendbereinigung mittels untransformierter Zuflüsse und logarithmierter Zuflüsse. . . . .	100
8.10	Streudiagramm zwischen den beobachteten und den mittels KNN-Regression geschätzten lokalen Zuflüssen C und D. . . . .	101
8.11	Autokorrelogramme der Zuflüsse des lokalen Zuflusses A. . . . .	102
8.12	Vergleich monatlicher und jährlicher statistischer Kennwerte für den lokalen Zufluss A (Reanalysezeitraum WETTREG 2010). . . . .	104
8.13	Vergleich monatlicher und jährlicher Kreuzkorrelationen. . . . .	104
8.14	Marginale Dichtefunktionen der Zuflüsse der Monate April, Juli, Oktober und Januar für den lokalen Zufluss A . . . . .	105
8.15	Empirisch kumulative Verteilungsfunktionen verschiedener Kennwerte für Trockenperioden und Überschussperioden. . . . .	106
8.16	Autokorrelogramme des lokalen Zuflusses A in der Beobachtung (1921-2007), der Gesamtdatensätze, sowie der synthetisch erzeugten Zuflusszeitreihen. . . . .	107
8.17	Darstellung der empirischen kumulativen Verteilungsfunktion der langjährigen Zeitreihe und der rekombinierten Zeitreihe, sowie Zeitreihe die zufällig angeordneten Defizitvolumen. . . . .	111
8.18	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Dummy-Zeitreihe für den Datensatz 1921-2007. . . . .	111
8.19	Schema der Modellimplementation des Talsperrenverbundsystems in OASIS. . . . .	113
8.20	Funktionsverlauf der Hilfsfunktion $\nu_1$ bei einem Schwellenwert $\lambda_1$ gegenüber der erreichten Versorgungssicherheit $P(BSS1)$ . . . . .	117
8.21	Scatterplots zwischen den, in der MKO und der Validierung erzielten, Versorgungssicherheiten und Zielfunktionswerten für das Szenario S-AKT. . . . .	121
8.22	Level-Diagramm für das Szenario S-AKT. . . . .	122
8.23	Regelkurven des Szenarios S-AKT . . . . .	123
8.24	Vergleich der erreichten Versorgungssicherheiten und Zielfunktionswerte der Lösungen aus S-AKT mit der aktuellen Steuerungsstrategie. . . . .	126
8.25	Scatterplots zwischen den, in der MKO und der Validierung erzielten, Versorgungssicherheiten und Zielfunktionswerten für das Szenario S-BEO. . . . .	127
8.26	Level-Diagramm für das Szenario S-BEO. . . . .	128
8.27	Regelkurven des Szenarios S-BEO . . . . .	129
8.28	Level-Diagramm für das Szenario S-5RK. . . . .	131
8.29	Regelkurven des Szenarios S-5RK . . . . .	131
8.30	Level-Diagramm als Übersicht für die Zeitscheibe 2021-2050. . . . .	135
8.31	Level-Diagramm für die Zeitscheibe 2071-2100. . . . .	137
9.1	Wasserhaushalt des Tanasees (nach Kebede et al., 2006). . . . .	144

9.2	Autokorrelogramme aller lokalen Zuflüsse nach Knoten (Abbildung 9.6) auf jährlicher Zeitskala. . . . .	145
9.3	Autokorrelogramme aller lokalen Zuflüsse nach Knoten (Abbildung 9.6) auf jährlicher Zeitskala. . . . .	146
9.4	Monatliche und jährliche Kreuzkorrelationen lokaler Zuflüsse nach ausgewählten Knoten des Talsperrenbewirtschaftungsmodells. . . . .	147
9.5	Vergleich der Statistiken von rekombinierter Dummy-Zeitreihe und langjähriger Zeitreihe, Fallstudie 2 . . . . .	148
9.6	Schema des Einzugsgebietes des Tanasee mit Superposition der Modelimplementierung des Mehrzweck-Talsperrenverbundsystems in OASIS (nach Alemayehu et al., 2009). . . . .	149
9.7	Level-Diagramm mit den vier Szenarien (S-2D-x-x) mit zwei Zielfunktionen unter Verwendung der 1-Norm. . . . .	154
9.8	Level-Diagramm mit den vier Szenarien (S-3D-x-x) mit drei Zielfunktionen unter Verwendung der 1-Norm. . . . .	155
9.9	Optimale Regelkurven der fünf Speicher für das Szenario S-3D-120-20y. . . . .	156
9.10	Optimale Regelkurven der fünf Speicher für das Szenario S-3D-120-679y. . . . .	157
B.1	Verlauf des $H_c$ -Kriteriums für die Benchmarks A und B. . . . .	213
B.2	Verlauf des $H_c$ -Kriteriums für die Benchmarks C und D. . . . .	214
C.1	Morphologie und Landnutzung des Untersuchungsgebiets. . . . .	217
C.2	Geologie und Bodentypen des Untersuchungsgebiets. . . . .	217
C.3	Lage der verwendeten Niederschlags- und Klimastationen des DWD und CHMI, sowie der virtuellen Niederschlags- und Klimastationen von WETTREG 2010 und CLM. . . . .	218
C.4	Normalisierte Entscheidungsvektoren der Modellgebiete A und C. . . . .	218
C.5	Abflussspende der Modellgebiete A und C im Kalibrierungszeitraum auf monatlicher und jährlicher Zeitskala. . . . .	219
C.6	Veränderungen im Jahresgang der rezenten und projizierten mittleren Abflussspenden unter WETTREG 2010. . . . .	219
C.7	Abflussspende der Modellgebiete A und C im Validierungszeitraum auf monatlicher und jährlicher Zeitskala. . . . .	220
C.8	Entwicklung der Jahreswerte der korrigierten Niederschlagssumme, der Summe der Abflussspenden und der realen und potentiellen Evapotranspiration im Einzugsgebiet der Talsperren KL und LM. . . . .	220
C.9	Autokorrelogramm auf jährlicher Zeitskala für den Reanalysezeitraum des regionalen Klimamodells WETTREG 2010. . . . .	223

C.10	Exponentielle Zunahme des Defizitvolumens $V_{\text{FSA}}$ mit den Abgabeanforderungen $c_{\text{crit}}$ für den Gesamttalsperrenzufluss der Talsperren KL und LM (Zeitscheibe 2021-2050 unter WETTREG 2010, A1B). . . . .	223
C.11	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe für den lokalen Zufluss A (1921-2007). . . . .	224
C.12	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe für den lokalen Zufluss B (1921-2007). . . . .	224
C.13	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe für den lokalen Zufluss C (1921-2007). . . . .	224
C.14	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe für den lokalen Zufluss D (1921-2007). . . . .	225
C.15	Regelkurven der Lösungen mit den geringsten 1-Normen in der Zeitscheibe 2071-2100. . . . .	227
C.16	Scatterplots für das Szenario S-5RK. . . . .	228
C.17	Scatterplots für die Szenarien S-2021-A1B, S-2021-A2 und S-2021-B1. . . . .	229
C.18	Level-Diagramme der Szenarien S-2021-A1B, S-2021-A2 und S-2021-B1. . . . .	230
C.19	Optimale Regelkurven aller Szenarios der Zeitscheibe 2021-2050. . . . .	231
C.20	Level-Diagramme der Szenarien S-2071-A1B, S-2071-A2 und S-2071-B1. . . . .	232
C.21	Regelkurven des Szenarios S-2071-A2. . . . .	233
C.22	Scatterplots für die Szenarien S-2071-A1B, S-2071-A2 und S-2071-B1. . . . .	234
D.1	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe des Knotens 401. . . . .	241
D.2	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe des Knotens 402. . . . .	242
D.3	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe des Knotens 404. . . . .	242
D.4	Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe des Knotens 86. . . . .	242
D.5	Streudiagramme der Szenarien S-2D-65-20y und S-2D-65-679y. . . . .	243
D.6	Streudiagramme der Szenarien S-2D-120-20y und S-2D-120-679y. . . . .	244
D.7	Streudiagramme der Szenarien S-3D-65-20y und S-3D-65-679y. . . . .	245
D.8	Streudiagramme der Szenarien S-3D-120-20y und S-3D-120-679y. . . . .	246



## Tabellenverzeichnis

8.1	Geforderte Abgaberaten $Q^{\text{BSS}\{1,\dots,3\}}$ und zugehörige Versorgungssicherheiten $R(\text{BSS})$ . . . . .	87
8.2	Überleitungsraten $Q^{\text{DIV}\{1,\dots,3\}}$ nach Überleitungsstufe zur Stützung der Talsperre Klingenberg durch die Talsperre Rauschenbach. . . . .	88
8.3	Vergleich der Mediane und Spannweiten der projizierten Abflussspenden unter WETTREG 2010 und CLM. . . . .	98
8.4	Anzahl der Realisierungen mit signifikanten Trends für die lokalen Zuflüsse A und B für WETTREG 2010. . . . .	100
8.5	Vergleich der geschätzten Hurst-Koeffizienten für die beobachteten (1921-2007) und simulierten Zuflusszeitreihen (HKNN-SMA-Modell) der lokalen Zuflüsse A, B, C und D. . . . .	102
8.6	Maximales Defizitvolumen nach dem Folgescheitelalgorithmus $\hat{V}_{\text{FSA}}$ für die generierten Zeitreihen. . . . .	108
8.7	Übersicht über gewählte Werte der Parameter und Ergebnisse der Monte-Carlo-Rekombination für verschiedene Zeitreihen. . . . .	112
8.8	Erreichte Versorgungssicherheiten $P(\text{BSS}\{1,\dots,3\})$ und Zielfunktionswerte für das Szenario S-AKT. . . . .	124
8.9	Erreichte Versorgungssicherheiten $P(\text{BSS}\{1,\dots,3\})$ und Zielfunktionswerte für das Szenario S-BEO. . . . .	128
8.10	Erreichte Versorgungssicherheiten $P(\text{BSS}\{1,\dots,4\})$ und Zielfunktionswerte für das Szenario S-5RK. . . . .	132
8.11	Erreichte Versorgungssicherheiten $P(\text{BSS}\{1,\dots,3\})$ und Zielfunktionswerte für die Szenarien der Zeitscheibe 2021-2050 für ausgewählte Lösungen. . . . .	134
8.12	Vergleich der Simulationsergebnisse unter der aktuellen Steuerungsstrategie $L_{\text{Hist}}$ und Ergebnissen von Lösungen $L_{\text{Opt}}^*$ aus der MK-SBO mit ähnlichen <i>FF3</i> . . . . .	136
8.13	Erreichte Versorgungssicherheiten $P(\text{BSS}\{1,\dots,3\})$ und Zielfunktionswerte für die Szenarien der Zeitscheibe 2071-2100 für ausgewählte Lösungen. . . . .	138
8.14	Vergleich der Simulationsergebnisse unter der aktuellen Steuerungsstrategie $L_{\text{Hist}}$ und Ergebnissen von Lösungen $L_{\text{Opt}}^*$ aus der MK-SBO mit ähnlichen <i>FF3</i> . . . . .	139
8.15	Bestimmtheitsmaße $R^2$ zwischen den in der MKO und Validierung erzielten Versorgungssicherheiten und Zielfunktionswerten. . . . .	140

8.16	Standardabweichung der Residuen $\sigma$ der linearen Regression zwischen den in der MKO und Validierung erzielten Versorgungssicherheiten und Zielfunktionswerten. . . . .	141
9.1	Zuordnung der Laufvariablen $r$ zu den einzelnen Speichern und den zugehörigen Abnehmern im Einzugsgebiet des Tanasees. . . . .	150
9.2	Bestimmtheitsmaße $R^2$ und Parameter der linearen Regression, Fallstudie 2 . .	159
9.3	Parameter $\alpha$ und $\beta$ der linearen Regression, Fallstudie 2 . . . . .	159
A.1	Literaturübersicht zur globalen multikriteriellen Optimierung von Talsperren. .	208
A.2	Literaturübersicht zur globalen einkriteriellen Optimierung von Talsperren. . .	210
C.1	Relevante Kenndaten der Talsperren Klingenberg, Lehmühle und Rauschenbach.	216
C.2	Untere und obere Randbedingungen der Entscheidungsvariablen des Bodenmodells der Modellgebiete A und C. . . . .	216
C.3	Untere und obere Randbedingungen der Entscheidungsvariablen des Schneemodells der Modellgebiete A und C. . . . .	217
C.4	Statistische Kennwerte der beobachteten und synthetischen Zeitreihen der lokalen Zuflüsse (1921-2007) . . . . .	221
C.5	Übersicht über die mittleren lokalen Zuflüsse des regionalen Klimamodells WETTREG 2010. . . . .	225
C.6	Übersicht über die mittleren lokalen Zuflüsse des regionalen Klimamodells CLM.	226
C.7	Einstellungen und Ergebnisse der Module D bis F im rezenten Zeitraum (1921-2007). . . . .	226
C.8	Einstellungen und Ergebnisse der Module D bis F in den Zeitscheiben 2021-2050 und 2071-2100. . . . .	227
D.1	Netzgewichte der Modellimplementierung in OASIS (Fallstudie 2). . . . .	235
D.2	Vorgegebene Staulamellengrößen (akkumuliert als obere und untere Randbedingungen) und Gesamtstauinhalte der einzelnen Speicher $r$ . . . . .	235
D.3	Mittlere monatliche Zuflusssummen nach den Knoten in OASIS. . . . .	236
D.4	Mittlere monatliche Bedarfssummen nach den Knoten und Fließwegen in OASIS.	236
D.5	Mittelwerte der beobachteten und synthetischen Zeitreihen der lokalen Zuflüsse.	237
D.6	Standardabweichungen der beobachteten und synthetischen Zeitreihen der lokalen Zuflüsse. . . . .	238
D.7	Schiefe der beobachteten und synthetischen Zeitreihen der lokalen Zuflüsse. . .	239
D.8	Autokorrelationskoeffizienten der beobachteten und synthetischen Zeitreihen der lokalen Zuflüsse (1985-2005). . . . .	240
D.9	Übersicht über gewählte Parameterwerte und Ergebnisse der Monte-Carlo-Rekombination in Fallstudie 2. . . . .	241

D.10 Kennwerte der MKO der Talsperrenbewirtschaftung in Fallstudie 2. . . . . 241

D.11 Extreme der Zielfunktionswerte  $FF1$  und  $FF2$  Pareto-optimaler Lösungen der  
Szenarien S-2D-x-x in der Validierung. . . . . 247

D.12 Zielfunktionswerte  $FF1$ ,  $FF2$  und  $FF3$  Pareto-optimaler Lösungen in der  
Validierung der Szenarien S-3D-x-x. . . . . 247

# Algorithmenverzeichnis

6.1 Rule-Curve-Stacking . . . . .	69
-----------------------------------	----

## Abkürzungsverzeichnis

ATM	Adaptives Talsperrenbewirtschaftungsmodell
BCHT	Box-Constraint-Handling-Technik
Cl-c	Repräsentative Lösung des Clusters $c$
CHMI	Tschechischer Hydrologisch-Meteorologischer Dienst
CHT	Constraint-Handling-Technik
CLM	Climate Local Model
CMA-ES	Covariance Matrix Adaption Evolutionary-Strategy
DM	Disaggregationsmodell
DDDP	Diskrete differenziale dynamische Programmierung
DP	Dynamische Programmierung
DWD	Deutscher Wetterdienst
EA	Evolutionärer Algorithmus
ECDF	Empirisch kumulative Verteilungsfunktion
EKO	Einkriterielle Optimierung
EK-SBO	Einkriterielle simulationsbasierte Optimierung
EP	Evolutionäre Programmierung
Frams-BOT	Framework zur a posteriori simulationbasierten Bewirtschaftungsoptimierung von Mehrzweck-Talsperrenverbundsystemen
ES	Evolutionäre Strategie
ESO	Explizite stochastische Optimierung
FSA	Folgescheitelalgorithmus
GA	Genetischer Algorithmus
GCM	General circulation model
GUI	Graphical User Interface
HKNN	Hybrides künstliches neuronales Netzwerk
ISO	Implizite stochastische Optimierung
LTV	Landestalsperrenverwaltung des Landes Sachsen
LM	Lehnmühle (Talsperre)
m.ü.NN	Meter über Meereshöhe
MCR	Monte-Carlo-Rekombination

MKO	Multikriterielle Optimierung
MK-SBO	Multikriterielle simulationsbasierte Optimierung
MLP	Multi-Layer Perceptron
MO-CMA-ES	Multiobjective Covariance Matrix Adaption Evolutionary-Strategy
NP	Nichtparametrisches Zeitreihenmodell
<i>NSE</i>	Nash Sutcliff Effizienz
<i>PBIAS</i>	Prozentualer BIAS
<i>PBIAS<sub>H1</sub></i>	Prozentualer BIAS der Monate November bis April
<i>PBIAS<sub>H2</sub></i>	Prozentualer BIAS der Monate Mai bis Oktober
RB	Rauschenbach (Talsperre)
RCM	Regionales Klimamodell
RCS	Rule-Curve-Stacking
SBO	simulationsbasierte Optimierung
SDP	stochastisch dynamische Programmierung
SM	Simulationsmodell
SMA	Symmetric moving average
SOM	Selbstorganisierende Merkmalskarte
SRES	Special Report on Emissions Scenarios
VAL	Validierung
WETTREG	Wetterlagenbasierte Regionalisierungsmethode Deutschland

## Symbolverzeichnis

$A_t$	Abflussspende, (mm)
$A$	Menge aller Fließwege, (–)
$B_t^{r,*}$	zu deckender Bedarf der Art (*) für den Speicher $r$ , ( $\text{hm}^3 \text{Monat}^{-1}$ )
$C$	Anzahl Cluster, (–)
$C_1$	Tagesgradfaktor ohne Windeinfluss, ( $\text{mm}^\circ\text{C}^{-1}\text{d}^{-1}$ )
$C_2$	Tagesgradfaktor mit Windeinfluss, ( $\text{mm}^\circ\text{C}^{-1}\text{d}^{-1}$ )
$C_\mu^{(g)}$	gewichtete Covarianzmatrix der Generation $g$ , (–)
$CHW$	Speicherkapazität von Schnee für Wasser, (–)
$CRFR$	Koeffizienten des Wiedergefrierens, (–)
$D_p$	Distanz in einer p-Norm, (–)
$D_p$	Menge der Distanzen, (–)
$\bar{D}_p$	Menge der normierten Distanzen, (–)
$D_R$	Entwässerungsdichte, ( $\text{m}^{-1}$ )
$D_t^{r,\text{Bew}}$	Defizit Bewässerungswasser des Speicher $r$ , ( $\text{hm}^3$ )

$D_t^{r, \text{Oek}}$	Defizit ökol. Mindestdurchfluss, Speicher $r$ , ( $\text{hm}^3$ )
$D_t^{\text{Meg}}$	Defizit Trinkwasserabgabe Speicher Megech
$E$	Sättigungsdampfdruck, (hPa)
$E_t^{\text{Tana}}$	Erzeugte Energie des Tana-Belles Kraftwerks, (GWh)
$F$	gültiger Entscheidungsraum, (-)
$F_j$	Zielfunktionen in Abschnitt 8.2, (-)
$FF_j$	Zielfunktionen in Abschnitt 8.5, 9.5, (-)
$H$	Anzahl Bodenhorizonte, (-)
$H_c$	Indikator des abgedeckten Hypervolumens, (-)
$H^l, H_l$	Hurstkoeffizient am Standort/Knoten $l$ , (-)
$J_K$	marginale Dichtefunktion, (-)
$K$	hydraulische Leitfähigkeit, ( $\text{ms}^{-1}$ )
$K_S$	gesättigte hydraulische Leitfähigkeit, ( $\text{ms}^{-1}$ )
$K_1$	Speicherrückgangskonstante des Direktabfluss, (h)
$K_2$	Speicherrückgangskonstante des Zwischenabfluss, (h)
$K_B$	Speicherrückgangskonstante des Basisabfluss, (m)
$L_{\text{DEF}}$	Länge einer Defizitperiode, (-)
$L_{\text{Hist}}$	Lösung unter rezenten Steuerungsstrategien, (-)
$L_R$	Länge der Proxyzeitreihen
$L_{\text{Opt}}^*$	Mit $L_{\text{Hist}}$ vergleichbare Lösung aus $\Theta^a$ , (-)
$M_E$	Schmelze infolge latenter Wärme, (mm)
$M_P$	Niederschlagsschmelze, (mm)
$M_R$	Strahlungsschmelze, (mm)
$M_S$	Schmelze infolge fühlbarer Wärme, (mm)
$M_{\text{neg}}$	wiedergefrierendes Schmelzwasser der Schneedecke, (mm)
$N_t$	Nettozuflusslinie, (-)
$N$	Menge aller Knoten, (-)
$O_t$	Beobachtungswert, (mm)
$P$	Niederschlag, (mm)
$P_{\text{prox}}$	Proxygröße für $k_{\text{rec}, H}$ , (-)
$P_T$	Schwellwert, MCR, (-)
$\bar{Q}$	mittlerer Zufluss, ( $\text{m}^3\text{s}^{-1}$ )
$Q_D$	Korrekturfaktor der Transmissivität, (-)
$Q_{D,t}$	Direktabfluss, (mm)
$\hat{Q}_D$	Fluss der untersten Fließzeitzone, (mm)

## Symbolverzeichnis

$Q_t^{\text{in},*}$	Zufluss zum Speicher (*); (*)=KL, LM, RB, ( $\text{hm}^3$ )
$Q_0$	Skalierungsfaktor Basisabfluss, (–)
$Q_{I,t}$	resultierender Zwischenabfluss, (mm)
$Q_{B,t}$	Basisabfluss, (mm)
$Q_t^{\text{ab},*}$	Abgaberate des Speichers (*); (*)=KL, LM, RB, ( $\text{hm}^3$ )
$Q_t^*$	Bedarf der Art (*); (*)= Bew, Oek, Meg, Tis, ( $\text{hm}^3$ )
$Q^{\text{BSS}1,\dots,4}$	geforderte Abgaberraten der BSS, ( $\text{m}^3\text{s}^{-1}$ )
$Q_t^{\text{KL},\text{m}}$	unzureichende Abgaberrate des Speichers KL, ( $\text{m}^3\text{s}^{-1}$ )
$Q^{\text{DIV}1,\dots,3}$	geforderte Überleitungsraten, ( $\text{m}^3\text{s}^{-1}$ )
$Q_t^{\text{RB},\text{m}}$	unzureichende Überleitungsrate des Speichers RB, ( $\text{m}^3\text{s}^{-1}$ )
$Q_p^l$	p-Quantil der beobachteten Zuflüsse, (–)
$Q_t^{\text{del}}$	erzielte Abgaberrate der Trinkwasserbereitstellung, ( $\text{m}^3\text{s}^{-1}$ )
$Q_t^{\text{in},\text{KL}}$	Nettozuflüsse des Speichers KL, ( $\text{m}^3\text{s}^{-1}$ )
$R^2$	Bestimmtheitsmaß, (–)
$RF_{\text{Min}}$	minimaler Schmelzfaktor, ( $\text{mm}(\text{°Cd})^{-1}$ )
$RF_{\text{Max}}$	maximaler Schmelzfaktor, ( $\text{mm}(\text{°Cd})^{-1}$ )
$RF$	Schmelzfaktor durch Strahlung, ( $\text{mm}(\text{°Cd})^{-1}$ )
$S_{\text{DF}}$	Anteil des Direktabflusses am Schmelzwasser, (–)
$\mathbf{S}$	Menge der Merkmalsvektoren, (–)
$S_t$	Simulationswert, (mm)
$S_t^*$	Speicherinhalt des Speichers (*), ( $\text{hm}^3$ )
$S_t^{\text{KL}+\text{LM}}$	Gesamtstauinhalt der Speicher KL und LM, ( $\text{hm}^3$ )
$T$	Anzahl der Zeitschritte, (–)
$T_i$	Thread $i$ , (–)
$T_L$	Lufttemperatur, ( $\text{°C}$ )
$T_{\text{OR}}$	Lufttemperatur bei 50% Schneeanteil, ( $\text{°C}$ )
$T_0$	Schmelz-Grenztemperatur, ( $\text{°C}$ )
$T_R$	Gesamtlaufzeit einer MKO, (s)
$T_{\text{TOR}}$	Temperatur- Übergangsbereich,
$V_{\text{DEF}}$	Defizitvolumen, ( $\text{hm}^3$ )
$V_{\text{FSA}}$	Defizitvolumen nach dem FSA, ( $\text{hm}^3$ )



$\hat{V}_{\text{FSA}}$	maximales Defizitvolumen nach dem FSA, ( $\text{hm}^3$ )
$V_{\text{SUR}}$	Überschussvolumen, ( $\text{hm}^3$ )
$\mathbf{W}_t$	zyklisch-stationärer multivariater Hilfsprozess, $(-)$
$W_t^l$	zyklisch-stationärer Hilfsprozess, Standort $l$ , $(-)$
$\mathcal{X}$	zulässiger Entscheidungsraum, $(-)$
$\mathbf{X}_t$	multivariater stochastischer Prozess, $(-)$
$X_t^l$	stochastischer Prozess, Standort $l$ , $(-)$
$Z^{\text{KL},0,\dots,2}$	Regelkurve für die Lamelleneinteilung der BSS, ( $\text{hm}^3$ )
$Z^{\text{DIV},1,\dots,2}$	Regelkurve für die Lamelleneinteilung der
$Z_s^{*,\text{Bew}}$	Speicherkontrollvolumen des Bewirtschaftungsraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{*,\text{HQ}}$	Speicherkontrollvolumen des gewöhnlichen Hochwasserrückhalteraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{\text{Div},1,\dots,2}$	Speicherkontrollvolumen einer Regelkurve der Überleitungssteuerung, ( $\text{hm}^3$ )
$Z_s^{\text{KL},0,\dots,2}$	Speicherkontrollvolumen einer Regelkurve, Bereitstellungsstufen, ( $\text{hm}^3$ )
$Z_s^{\text{min}}$	Untere Randbedingung Speicherkontrollvolumina, ( $\text{hm}^3$ )
$Z_s^{\text{max}}$	Obere Randbedingung Speicherkontrollvolumina, ( $\text{hm}^3$ )
$Z_s^{*,\text{Res}}$	Speicherkontrollvolumen des Reserveraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{*,\text{Tot}}$	Speicherkontrollvolumen des Totraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{*,u}$	Speicherkontrollvolumina der $u$ -ten Regelkurve eines Speichers (*), ( $\text{hm}^3$ )
$Z_{\text{GW}}$	Grundwasserflurabstand, (m.u.GoK)
$Z_t^l$	stochastischer Prozess, jährliche Zeitskala, Standort $l$ , $(-)$
$P(\text{BSS } \{1, \dots, 4\})$	erreichte Versorgungssicherheiten aller BSS, (%)
$R(\text{BSS } \{1, \dots, 4\})$	geforderte Versorgungssicherheiten aller BSS, (%)
$Z^{\text{KL+LM},\text{Bew}}$	Gesamtbewirtschaftungsraum der Speicher KL und LM, ( $\text{hm}^3$ )
$Z^{\text{KL+LM},\text{Res}}$	Gesamtreserveraum der Speicher KL und LM, ( $\text{hm}^3$ )
$Z_s^{*,\text{Tot}}$	Speicherkontrollvolumen des Totraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{*,u}$	Speicherkontrollvolumina der $u$ -ten Regelkurve eines Speichers (*), ( $\text{hm}^3$ )
$Z_{\text{GW}}$	Grundwasserflurabstand, (m.u.GoK)
$Z_t^l$	stochastischer Prozess, jährliche Zeitskala, Standort $l$ , $(-)$

## Symbolverzeichnis

$\hat{V}_{\text{FSA}}$	maximales Defizitvolumen nach dem FSA, ( $\text{hm}^3$ )
$V_{\text{SUR}}$	Überschussvolumen, ( $\text{hm}^3$ )
$\mathbf{W}_t$	zyklisch-stationärer multivariater Hilfsprozess, (-)
$W_t^l$	zyklisch-stationärer Hilfsprozess, Standort $l$ , (-)
$\mathcal{X}$	zulässiger Entscheidungsraum, (-)
$\mathbf{X}_t$	multivariater stochastischer Prozess, (-)
$X_t^l$	stochastischer Prozess, Standort $l$ , (-)
$Z^{\text{KL},0,\dots,2}$	Regelkurve für die Lamelleneinteilung der BSS, ( $\text{hm}^3$ )
$Z^{\text{DIV},1,\dots,2}$	Regelkurve für die Lamelleneinteilung der Überleitungssteuerung, ( $\text{hm}^3$ )
$Z_s^{*,\text{Bew}}$	Speicherkontrollvolumen des Bewirtschaftungsraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{*,\text{HQ}}$	Speicherkontrollvolumen des gewöhnlichen Hochwasserrückhalteraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{\text{Div},1,\dots,2}$	Speicherkontrollvolumen einer Regelkurve der Überleitungssteuerung, ( $\text{hm}^3$ )
$Z_s^{\text{KL},0,\dots,2}$	Speicherkontrollvolumen einer Regelkurve, Bereitstellungsstufen, ( $\text{hm}^3$ )
$Z_s^{\text{min}}$	Untere Randbedingung Speicherkontrollvolumina, ( $\text{hm}^3$ )
$Z_s^{\text{max}}$	Obere Randbedingung Speicherkontrollvolumina, ( $\text{hm}^3$ )
$Z_s^{*,\text{Res}}$	Speicherkontrollvolumen des Reserveraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{*,\text{Tot}}$	Speicherkontrollvolumen des Totraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{*,u}$	Speicherkontrollvolumina der $u$ -ten Regelkurve eines Speichers (*), ( $\text{hm}^3$ )
$Z_{\text{GW}}$	Grundwasserflurabstand, (m.u.GoK)
$Z_t^l$	stochastischer Prozess, jährliche Zeitskala, Standort $l$ , (-)
$P(\text{BSS}\{1, \dots, 4\})$	erreichte Versorgungssicherheiten aller BSS, (%)
$R(\text{BSS}\{1, \dots, 4\})$	geforderte Versorgungssicherheiten aller BSS, (%)
$Z^{\text{KL+LM},\text{Bew}}$	Gesamtbewirtschaftungsraum der Speicher KL und LM, ( $\text{hm}^3$ )
$Z^{\text{KL+LM},\text{Res}}$	Gesamtreserveraum der Speicher KL und LM, ( $\text{hm}^3$ )
$Z_s^{*,\text{Tot}}$	Speicherkontrollvolumen des Totraums eines Speichers (*), ( $\text{hm}^3$ )
$Z_s^{*,u}$	Speicherkontrollvolumina der $u$ -ten Regelkurve eines Speichers (*), ( $\text{hm}^3$ )
$Z_{\text{GW}}$	Grundwasserflurabstand, (m.u.GoK)
$Z_t^l$	stochastischer Prozess, jährliche Zeitskala, Standort $l$ , (-)

## Lateinische Kleinbuchstaben

$c$	Clusternummer, (–)
$c_{(i,j),t}$	Bonuspunkte, (–)
$c_{\text{crit}}$	Sollabgabe, ( $\text{m}^3\text{s}^{-1}$ )
$c_r$	diskrete Wahrscheinlichkeitsfunktion, (–)
$c_{\text{rfr}}$	Koeffizient des Wiedergefrierens, (–)
$c_1$	temperaturabhängiger Schmelzfaktor, ( $\text{mm}(\text{°Cd})^{-1}$ )
$c_2$	windabhängiger Schmelzfaktor, ( $\text{mm}(\text{°C}(\text{ms}^{-1})\text{d})^{-1}$ )
$d_r$	Skalierungsfaktor Zwischenabfluss, ( $\text{m}^{-1}$ )
$e$	Residuum, (–)
$\bar{\mathbf{f}}$	normierter Vektor $\bar{\mathbf{f}} \in \{0, \dots, 1\}$ , (–)
$\mathbf{f}(\mathbf{x})$	Zielfunktionsvektor, (–)
$\mathbf{f}(\Theta)$	Pareto-Front, (–)
$\mathbf{f}(\Theta^a)$	approximierte Pareto-Front
$\mathbf{f}^{\text{MKO}}(\Theta^a)$	approximierte Pareto-Front der MKO, (–)
$\mathbf{f}^{\text{VAL}}(\Theta^a)$	approximierte Pareto-Front der Validierung, (–)
$\mathbf{f}_{\text{pen}}(\mathbf{x})$	Zielfunktionsvektor mit Straffunktion des BCH, (–)
$f_j(\mathbf{x})$	Zielfunktion $j$ , (–)
$g(\mathbf{x})$	Ungleichheits-Randbedingung, (–)
$.^g$	Generation, (–)
$h_{\text{GEO},0}$	Geländeoberkante der ersten Bodenschicht, (m.ü.NN)
$h_{\text{GW},t}$	Grundwasserspiegel, (m.ü.NN)
$h_H$	Parameter der Horizontttiefen, (–)
$h_t^{\text{Tana}}$	Wasserspiegellage Tanasee, (m.ü.NN)
$h(\mathbf{x})$	Gleichheits-Randbedingung, (–)
$i$	Zähler, (–)
$j$	Zähler, Lag, (–)
$k$	Anzahl Saisons, (–)
$k_{\text{rec},H}$	Abnahmefaktor der gesättigten hydraulischen Leitfähigkeit, (–)
$l$	Standort, multivariate Prozesse, (–)
$m$	Anzahl der Zielfunktionen, (–)
$\mathbf{m}^{(g)}$	Mittelwert zur Generation $g$ , (–)
$n$	Anzahl der Entscheidungsvariablen, (–)
$n_C$	Anzahl der Kompromissklassen, (–)
$n_E$	Anzahl der validierten Lösungen, (–)

## Symbolverzeichnis

$n_{\text{ha}}$	Anzahl der separierten Trockenperioden
$n_{\text{M}}$	die Anzahl der durchgeführten Evaluationen, (–)
$n_{\text{N}}$	Anzahl der Neuronen einer SOM, (–)
$n_{\text{P}}$	Anzahl der dominierenden Lösungen (VAL), (–)
$n_{\text{PM}}$	Anzahl der Pareto-optimalen Lösungen (MKO), (–)
$n_{\text{r}}$	Anzahl der gezogener Trockenperioden, (–)
$n_{\text{T}}$	Anzahl der Threads, (–)
$n_{\text{E}}$	Anzahl der Evaluationen pro Zyklus, (–)
$p_{\text{Schnee}}$	Schneeanteil am Niederschlag, (–)
$p_r$	kumulative Wahrscheinlichkeitsfunktion, (–)
$\mathbf{p}_{\text{c}}^{(g)}$	evolutionärer Pfad zur Generation $g$ , (–)
$q$	Anzahl Terme des SMA-Filters, (–)
$q_{\text{ab}}$	Abfluss aus Bodenschicht, ( $\text{ms}^{-1}$ )
$q_{\text{in}}$	Zufluss in Bodenschicht, ( $\text{ms}^{-1}$ )
$q_{I,t}$	Zwischenabfluss, ( $\text{ms}^{-1}$ )
$r$	Laufvariable der Speichertzuoordnung, (–)
$\mathbf{r}$	Merkmalsvektor, (–)
$r_j$	Autokorrelationskoeffizient Lag- $j$ , (–)
$s$	Saison oder Monat, (–)
$\hat{s}$	ausgewählte/r Saison/Monat, (–)
$s_{\alpha}^l(\omega)$	Fourier-Transformation, (–)
$t$	Zeitschritt, (s)
$u$	Windgeschwindigkeit, ( $\text{ms}^{-1}$ )
$v$	Anzahl Standorte, multivariater Prozess, (–)
$w$	Anzahl der Speicher im Verbundsystem, (–)
$w_i$	Gewicht, (–)
$\mathbf{w}$	Merkmalsvektor, (–)
$x_i$	$i$ -te Entscheidungsvariable, (–)
$x_{(i,j),t}$	Fluss entlang eines Fließwegs, ( $\text{m}^3\text{s}^{-1}$ )
$x_{(i,j),t}^{\min}$	Untere Randbedingung eines Flusses, ( $\text{m}^3\text{s}^{-1}$ )
$x_{(i,j),t}^{\max}$	Obere Randbedingung eines Flusses, ( $\text{m}^3\text{s}^{-1}$ )
$\mathbf{x}$	Vektor, Entscheidungsvektor, (–)
$\mathbf{x}^{\min}$	Vektor der unteren Randbedingungen, (–)
$\mathbf{x}^{\max}$	Vektor der oberen Randbedingungen, (–)
$y_j^{\text{a}}$	approximierter UtopiaPunkt, (–)

$z$	gleichverteilte Zufallszahl, (–)
$\Delta z$	Mächtigkeit einer Bodenschicht, (m)
<b>Griechische Großbuchstaben</b>	
$\Delta\theta$	Änderung des Bodenwassergehalts, (–)
$\Theta$	Pareto-Menge, (–)
$\Theta^a$	approximierte Pareto-Menge, (–)
$\Theta_s$	Bodenwassergehalt, (%)
<b>Griechische Kleinbuchstaben</b>	
$\alpha$	Konfidenz, (–)
$\alpha_j$	Steigung, lineare Regression, (–)
$\alpha_j^l$	SMA Koeffizient, (–)
$\alpha_w$	Wichtungsfaktor, (–)
$\beta$	Gefälle einer Rasterzelle, (°)
$\beta_j$	Offset, lineare Regression, (–)
$\gamma_P$	Psychrometerkonstante, (hPaK <sup>-1</sup> )
$\gamma_o$	Varianz des stochastischen Prozesses $Z_t^l$ , (–)
$\lambda$	Anzahl der Nachkommen, (–)
$\lambda_{1,\dots,4}$	Schwellenwert der Versorgungssicherheiten, (–)
$\mu$	Anzahl der Elternteile, (–)
$\nu_B(\mathbf{x})$	Strafbetragsfunktion des BCH, (–)
$\nu_S$	Strafbetragsfunktion, (–)
$\nu_{1,\dots,4}$	Hilfsfunktionen 1 bis 4, (–)
$\rho$	Pearson'scher Korrelationskoeffizient, (–)
$\rho_j^l$	Autokorrelationsfunktion mit den Lags $j$ , (–)
$\rho_{\min}$	Schwellenwert des Pearson'schen Korrelationskoeffizienten, (–)
$\sigma$	Standardabweichung, (–)
$\xi$	Schiefte, (–)

**Teil IV**

**Anhang**

## **A Methoden**

Tabelle A.1: Literaturübersicht zur globalen multikriteriellen Optimierung von Talsperren. Es sind: RES... Anzahl der Speicher, OPT... Optimierungsalgorithmus, BR... Bewirtschaftungsregel, ISO... implizite stochastische Optimierung, ZF... Zielfunktionen, ZFT... Zielfunktionsstyp°, EV... Anzahl der Entscheidungsvariablen, ATM... adaptives Talsperrenbewirtschaftungsmodell, EW... Expertenwissen (Optimierung), ZRL... Zeitreihenlänge (Jahre), VAL... Validierung der Steuerungsstrategien, ZRM... Zeitreihenmodell, EH... Entscheidungshilfe

Studie	RES	OPT	ATM	BR	ISO	ZF	ZFT	EV	EW	ZRL	VAL	ZRM	EH
Kumar et al. (2001)	1	MOFLP			x	2	a, b	12		1**			
Kim and Heo (2006)	3	NSGA-II			x	3	c, d, e	180		4			x
Reddy and Kumar (2006)	1	MOGA			x	2	b, e	36		1**			x
Ngo et al. (2007)	1	SCE		x		1	b, d	10		4*			
	1	SCE	MIKE 11	x		1	b, d, h	7		5*		x	
Reddy and Kumar (2007b)	1	EM-MOPSO			x	3	e, b, h	36		1**			x
Reddy and Kumar (2007a)	1	MODE			x	2	f, g	720		36			x
	1	NSGA-II			x	2	f, g	720		36			
Chen et al. (2007)	1	MNMG		x		2	a, b	27		41			
Reddy and Kumar (2008)	1	MODE			x	2	f, g	333		1**			
Kim et al. (2008)	1	NSGA-II		x		2	i, b	120		100		x	x
Hakimi-Asiabar et al. (2009)	2	SBMOGA			x	2	a, b	720		30			
Ditmann et al. (2009)	3	MOES	TALSIM	x		3	e, a, j	6		39			x
	3	MOES	TALSIM	x		5	k, e, d	9		140*		x	x
Chang and Chang (2009)	2	NSGA-II			x	2	i	12		49			
Regulwar and Raj (2009)	4	MOGAPU			x	2	a, b	96		1**			
Scola et al. (2010)	1	NSGA-II		x		2	a, 1	12	x	1			
Scola et al. (2011)	5	NSGA-II		x		2	a, 1	60	x	1			
Eum and Simonovic (2010)	2	DE	HEC-HMS	x		1	a, b, d	48		30		x	x



Studie	RES	OPT	ATM	BR	ISO	ZF	ZFT	EV	EW	ZRL	VAL	ZRM	EH
Kai et al. (2010)	4	NSGA-II			x	2	b	480		10			
	4	SADP			x	2	b	480		10			
	4	DDDP			x	2	b	480		10			
Gu and Wu (2010)	3	MOCA			x	2	b	12		1			
Malekmohammadi et al. (2011)	2	NSGA-II			x	2	k, b	628		28	x		x
Saliha (2012)	5	MO-CMA-ES	HEC-5	x		2	a, b	65		20			
		CMA-ES	HEC-5	x		1	a, b	65		20			
Liu et al. (2012)	3	MEMOIA		x		3	b	36		50			
Castelletti et al. (2012)	1	MOGA		x		3	m	5	x	31	x		
		DDP			x	1	m			31			
Castelletti et al. (2013)	1	MOFQI		x			b, d	5		31	x		
		MOPSO		x			b, d	5		31	x		
Lerma et al. (2013)	4	PIKAIA	AQUATOOL	x		1	a, c	12		28			
Schardong et al. (2013)	5	MODE			x	3	a, h, m	180		6			x
		NSGA-II			x	3	a, h, m	180		6			

\* Einzelereignisse bzw. Trocken- oder Flutperioden, \*\* auf Basis des mittleren innerjährlichen Verlaufs, ° Schlüssel zu den Zielfunktionstypen, es wird nicht zwischen der Maximierung der Bereitstellung und der Minimierung von Defiziten unterschieden: a=Max. Summe Bereitstellung von Wasser, b=Max. Summe Energieproduktion, c=Min. Summe Stauinhalt, d= Min. Summe Abgabe aus Speicher, e=Min. SE oder MSE aus Abgabe und Zufluss oder Bereitstellung und Bedarf, etc. f=Max. Ertrag aus Feldfruchtanbau, g=Max. Profit aus Feldfruchtanbau, h=Max. Wasserqualitätsindikator, i=Min. Shortage Index [USACE1997], j=Min. ökologische Beeinflussung, k=Min. Schaden durch Hochwasser, l=Max. minimale Energieproduktion, m=Max. unterschiedliche ökonomische Interessen, n=Max. Versorgungssicherheit

Tabelle A.2: Literaturübersicht zur globalen einkriteriellen Optimierung von Talsperren. Es sind: RES...Anzahl der Speicher, OPT... Optimierungsalgorithmus, ISO... implizite stochastische Optimierung, ATM... adaptives Talsperrenbewirtschaftungsmodell, BR... Bewirtschaftungsregel, ZFT... Zielfunktionsstyp°, EV... Entscheidungsvariablen, EW... Expertenwissen (Optimierung), ZRL... Zeitreihenlänge, ZRM... Zeitreihenmodell, VAL... Validierung der Steuerungsstrategien

Studie	RES	OPT	ISO	ATM	BR	ZFT	EV	EW	ZRL	ZRM	VAL
Koutsoyiannis et al. (2002)	4	SCA		Hydronomeas	x	b	8		2000	x	x
Chang and Yang (2002)	3	GA		HEC-5	x	i	48		38		
Chen (2003)	1	ME				i	12		41		
Tung et al. (2003)	1	GA			x	i	72		20		
Chang et al. (2005)	1	GA			x	i	36		36		
Kumar and Reddy (2006)	1	ACO	x			e	462		36		
Suiadee and Tingsanchali (2007)	1	GA		HEC-3	x	g	24		23		
Kangrang and Chavalit (2007)	2	GA		HEC-3	x	a	48	x	21		
Soltani et al. (2008)	1	SDEA	x			n	240		20		x
Kangrang et al. (2008)	2	GA		HEC-3	x	a	48		41	x	x
Shourian et al. (2008)	10	PSO		MODSIM		m	5		40		
Celeste et al. (2009)	1	ISO-QP	x			e			19		
Eunn et al. (2012)	3	DE		HEC-HMS	x	k	72		50	x	x

\* Einzelereignisse bzw. Trocken- oder Flutperioden, \*\* auf Basis des mittleren innerjährlichen Verlaufs, ° Schlüssel zu den Zielfunktionstypen, es wird nicht zwischen der Maximierung der Bereitstellung und der Minimierung von Defiziten unterschieden: a=Max. Summe Bereitstellung von Wasser, b=Max. Summe Energieproduktion, c=Min. Summe Stauinhalt, d= Min. Summe Abgabe aus Speicher, e=Min. SE oder MSE aus Abgabe und Zufluss oder Bereitstellung und Bedarf, etc. f=Max. Ertrag aus Feldfruchtanbau, g=Max. Profit aus Feldfruchtanbau, h=Max. Wasserqualitätsindikator, i=Min. Shortage Index [USACE1997], j=Min. ökologische Beeinflussung, k=Min. Schaden durch Hochwasser, l=Max. minimale Energieproduktion, m=Max. unterschiedliche ökonomische Interessen, n=Max. Versorgungssicherheit

## B Anwendungsbezogene Benchmarks

### Rule-Curve-Stacking

Das Rule-Curve-Stacking (Abschnitt 6.4.4) soll bei der simultanen Optimierung von mehreren abfolgenden Regelkurven die Verletzung der Randbedingungen der Art

$$Z_i^{\min} \leq Z_i^{L,1} \leq Z_i^{L,2} \leq \dots Z_i^{L,u} \leq Z_i^{\max} \quad \forall u, i \quad (\text{B.1})$$

verhindern. Scola et al. (2010) und Scola et al. (2011) demonstrieren die Effektivität des Verfahrens bei der Optimierung von jeweils einer Regelkurve je Speicher.

### Methodik

Die Erweiterung für beliebig viele Regelkurven je Speicher wird für das Talsperrenverbundsystem KL-LM-RB für das Szenario S-BEO (Abschnitt 8.5.3) getestet. Dies erfolgt durch 25 SBO mit gleichen Initialisierungen der Startpopulation und jeweils mit und ohne RCS. Als Vergleichskriterium wird das bedeckte Hypervolumen  $H_c$  herangezogen.

Zur Berechnung von  $H_c$  werden zunächst der Nadir-Punkt und Utopia-Punkt aus dem Stichprobenumfang der approximierten Pareto-Fronten bestimmt. Latin Hypercube Sampling (McKay et al., 1979) wird genutzt, um fünf Millionen zufällig verteilte Punkte  $P$  in den Raum zwischen Nadir-Punkt und Utopia-Punkt zu generieren. Dieser Satz Punkte ist für alle fünfzig MK-SBO identisch. Das bedeckte Hypervolumen-Kriterium  $H_c$  berechnet sich dann als der Anteil der Punkte  $P$ , die durch die jeweils approximierten Lösungen in  $\mathbf{f}(\Theta^a)$  dominiert werden (Fonseca and Fleming, 1995). Die Null-Hypothese, dass sich die Stichproben  $H_c$  mit und ohne RCS unterscheiden wird durch den Mann-Whitney-Test (Wolfe and Hollander, 1973) bei einer Signifikanz von  $\alpha = 0,05$  überprüft.

Unter Einsatz von RCS ist die MKO frei von Randbedingungen. Ohne RCS werden Lösungen, die gegen die Randbedingung (Gleichung B.1) verstoßen, nicht durch das Simulationsmodell evaluiert. Stattdessen sind die Zielfunktionen  $FF1$ ,  $FF2$  und  $FF3$  im Fall eines Verstoßes durch

$$\exists x_i \notin \mathcal{X} : FF^P \{1, \dots, 3\} = (1e6 + \text{ung}(\mathbf{x})) \times 100. \quad (\text{B.2})$$

zu ersetzen.  $\text{ung}(\mathbf{x})$  bewertet hierbei die Distanz der ungültigen Lösung zum gültigen Entscheidungsraum. Die hier vorgeschlagene Formulierung  $\text{ung}(\mathbf{x})$  nutzt die normierten Entscheidungsvariablen des Optimierungsalgorithmus des entsprechenden monatlichen Wertes einer Regelkurve  $x_s^{L,v} \rightarrow Z_i^{L,u}$

$$\text{ung}(\mathbf{x}) = \sum_L^G \sum_v^{u-1} \sum_s^{12} \left( \min(\max(x_s^{L,v} - x_s^{L,v+1}), 0) \right) \quad (\text{B.3})$$

aus. Hierbei sind  $L$  eine Talsperre im System,  $v$  kennzeichnet die Ordnung der Regelkurve in Bezug auf die Randbedingung in Gleichung 8.21 und  $s$  kennzeichnet die jeweilige Saison (in diesem Fall den Monat). Die Zielfunktionen  $FF1$ ,  $FF2$  und  $FF3$  des Szenarios S-BEO beschränken den Zielfunktionsraum durch einen Strafterm auf einen Teilbereich des Zielfunktionsraums (siehe Abschnitt 8.5.4). Der Zielraum wird mittels der Schwellenwerte  $\lambda_i$ ,  $i = 1, \dots, n$  eingegrenzt. Im Folgenden werden zwei unterschiedliche Sätze von Schwellenwerten verwendet. Benchmark A verwendet einen Satz mit niedrigeren Schwellenwerten. Mit  $\lambda_1 = 0,995$ ,  $\lambda_2 = 0,99$  und  $\lambda_3 = 0,95$  kann der gewünschte Zielfunktionsraum leichter erreicht werden als im Benchmark B mit höheren Schwellenwerten von  $\lambda_1 = 0,9995$ ,  $\lambda_2 = 0,995$  und  $\lambda_3 = 0,99$ . Die psMO-CMA-ES nutzt eine Populationsgröße von 48.

## Ergebnisse

Zunächst werden die Ergebnisse des Benchmarks A mit den niedrigeren Schwellenwerten betrachtet. Abbildung B.1 (links) zeigt den Verlauf des  $H_c$ -Kriteriums über den Verlauf der Modellevaluationen. Hellgrau gekennzeichnet ist der Verlauf der MKOs ohne RCS und schwarz mit RCS. Das erste Individuum mit einer gültigen Lösung tritt ohne RCS nach 333 Iterationen auf. Deutlich wird dies durch den Sprung über den Schwellenwert, der in Abbildung B.1 mit *Randbedingung* (für Gleichung B.1) gekennzeichnet ist und ein  $H_c$ -Kriterium auf 0,996 ermöglicht. Insgesamt konvergieren innerhalb von 750 Iterationen fünf Läufe in den gültigen Entscheidungsraum. In keinem Lauf werden jedoch Lösungen gefunden, die Versorgungssicherheiten über den Schwellenwerten  $\lambda_i$  erreichen (in Abbildung B.1 mit *Zielfunktionsraum* gekennzeichnet).

Mit RCS starten 10 von 25 im Benchmark A bereits mit einem  $H_c$  von 0,996. Lediglich fünf von 25 Läufe benötigen mehr als eine Iteration um Lösungen mit Versorgungssicherheiten  $P(\text{BSS}\{1, \dots, 3\})$  über den Schwellenwerten zu generieren. Mit der 600-sten Iteration sind alle Läufe in den gewünschten Zielfunktionsbereich konvergiert. Dementsprechend bestätigt auch der Mann-Whitney-Test signifikant bessere Ergebnisse der MK-SBO mit RCS. Benchmark B erweist sich durch die höheren Schwellenwerte als deutlich schwierigerer Benchmark. Ohne RCS konvergieren, nach Abbildung B.1 (rechts) fünf Lösungssätze in den gültigen Entscheidungsraum. Der gewünschte Zielfunktionsraum mit  $P(\text{BSS}\{1, \dots, 3\}) \geq \lambda_{\{1, \dots, 3\}}$  wird in keinem Lauf erreicht. Mit RCS konvergieren insgesamt vier Läufe in den




Abbildung B.1: Verlauf des  $H_c$ -Kriteriums über die Evaluationen für 25 Realisierungen des Benchmarks A (links) und des Benchmarks B (rechts).

gewünschten Zielfunktionsraum. Die hierzu benötigten Modellevaluationen liegen zwischen 220 und 689 Iterationen. Der Mann-Whitney-Test bestätigt für die MK-SBO mit RCS signifikant bessere Optimierungsergebnisse.

## Zusammenfassung

In zwei Benchmarks, die sich auf das Szenario S-BEO stützen, zeigt sich, dass mit Rule-Curve-Stacking signifikant bessere Ergebnisse in der multikriteriellen Optimierung der Talsperrenbewirtschaftung möglich sind, als mit einem alternativen Constraint-Handler. In beiden Benchmarks können ohne RCS nach jeweils über 18 000 Modellevaluationen keine Lösungen gefunden werden die den geforderten Mindestversorgungssicherheiten genügen. Mit RCS konvergiert die Pareto-Front in Benchmark A in 24 Läufen bereits bei unter 3500 Evaluationen in den Bereich der geforderten Mindestversorgungssicherheiten. In Benchmark B erreichen dies innerhalb des Abbruchkriteriums vier Läufe.

## Initialisierung

### Methodik

Mit zwei Benchmarks wird das Verhalten der psMO-CMA-ES bei einer Initialisierung der Startpopulation untersucht. Beide Benchmarks basieren ebenfalls auf dem Szenario S-BEO (Abschnitt 8.5.3). Wie in vorherigen Abschnitt wird das bedeckte Hypervolumen-Kriterium zur Bewertung herangezogen. Alle MK-SBO-Läufe nutzen das Rule-Curve-Stacking. Die Schwellenwerte sind mit  $\lambda_1 = 0,9$ ,  $\lambda_2 = 0,8$  und  $\lambda_3 = 0,6$  sehr niedrig angesetzt. Vor Beginn




Abbildung B.2: Verlauf des  $H_c$ -Kriteriums über die Evaluationen für 25 Realisierungen des Benchmarks C (links) und des Benchmarks D (rechts).

der Benchmarks wird ein einzelner MK-SBO-Lauf (Vorlauf) durchgeführt, um Lösungen für die Initialisierung zu generieren. Die psMO-CMA-ES nutzt eine Populationsgröße von 48. Der erste Benchmark (Benchmark C) umfasst jeweils 25 Läufe mit vorgegebener und zufälliger Initialisierung. Die Läufe mit Initialisierung nutzen für die Startpopulation jeweils die identischen Entscheidungsvektoren von Individuen aus der ersten Iteration des Vorlaufs. Benchmark D ist wie Benchmark B gestaltet, die Entscheidungsvektoren entstammten jedoch der tausendsten Iteration des Vorlaufs.

## Ergebnisse

Abbildungen B.2 zeigt für die Benchmarks C (links) und D (rechts) den Verlauf des bedeckten Hypervolumen-Kriteriums. Für alle Läufe mit Initialisierung ist der jeweils identische  $H_c$ -Wert der Startpopulation deutlich zu erkennen.

Unter Benchmark C sind durch die zufällige Initialisierungen vier Startpopulationen schlechter als mit Initialisierung. Keine der Startinitialisierungen weist eine Lösung mit ausreichenden  $\lambda_{\{1,\dots,3\}}$  auf und nach Straffunktion (Gleichung 8.9) wird ein Aufschlag auf die ermittelten Zielfunktionswerte vorgenommen. Nach 18 000 Evaluationen ist der Unterschied in den  $H_c$  jedoch sehr gering. Der Mann-Whitney-Test lehnt mit  $p = 0,12$  einen signifikanten Unterschied zwischen den Läufen mit und ohne Initialisierung ab. Deutlich höhere  $H_c$ -Kriterien erhalten die initialisierten Läufe in Benchmark D bereits in der Startpopulation. Mit fortschreitender Evaluationszahl gleichen sich die beiden bedeckten Hypervolumen einander an. Nach Ablauf von 18 024 Modellevaluationen scheidet die Optimierung mit Initialisierung jedoch auch weiterhin signifikant ( $p = 0,0245$ ) besser ab.

## Zusammenfassung

Die MO-CMA-ES erreicht mit schlechter Initialisierung vergleichbare Ergebnisse wie mit rein zufälliger Initialisierung. Eine Initialisierung mit vorgegebenen Startwerten kann demnach auch vorgenommen werden, wenn nicht klar ist, ob diese nahe an der wahren Pareto-Front liegt. Schlechtere Ergebnisse sind hierdurch nicht zu erwarten. Mit guter Initialisierung sind die durchgeführten Läufe bezüglich des  $H_c$ -Kriteriums zu Beginn deutlich besser. Mit Initialisierung lässt sich eine statistisch signifikant bessere Konvergenz nach 18 024 Evaluationen feststellen. Eine Initialisierung zahlt sich also vor allem bei zeitintensiven Simulationen aus, wenn die Anzahl der Evaluationen stark begrenzt ist. Die Schwellenwerte  $\lambda$  sind bei beiden Benchmarks sehr gering gesetzt. Es bleibt anzunehmen, dass ein schwierigerer Benchmark mit höheren  $\lambda$ -Werten die Optimierung mit entsprechend guter Initialisierung weiter bevorteilt.

# C Fallstudie 1

## Modul A

Tabelle C.1: Relevante Kenndaten der Talsperren Klingenberg (KL), Lehmühle (LM) und Rauschenbach (RB) (Übersicht nach Winkler, 2009)

Kennwerte		KL	LM	RB
Baujahr		1908-1914	1927-1931	1960-1968
Hauptfließgewässer		Wilde Weißeritz		Flöha
<i>Stauraumaufteilung</i>				
Totraum	(hm <sup>3</sup> )	0,00	0,00	0,00
Reserveraum	(hm <sup>3</sup> )	2,00	2,50	2,30
Betriebsraum	(hm <sup>3</sup> )	12,37	12,42	8,90
Gew. HQ-Raum	(hm <sup>3</sup> )	2,00	7,00	4,00
Gesamtstauraum	(hm <sup>3</sup> )	16,38	21,92	15,20
<i>Ausbaugrade</i>				
Eigeneinzugsgebiet	(-)	1,46 *	0,63	0,81 °
Gesamteinzugsgebiet	(-)	0,35 **	-	0,36 °°
<i>Einzugsgebiete</i>				
Eigeneinzugsgebiet	(km <sup>2</sup> )	29 *	60,4	26,9 °
Gesamteinzugsgebiet	(km <sup>2</sup> )	89,4 *	-	70,5 °°
<i>Zuflüsse</i>				
Eigeneinzugsgebiet	(hm <sup>3</sup> a <sup>-1</sup> )	11,0	34,7	18,9
Gesamteinzugsgebiet	(hm <sup>3</sup> a <sup>-1</sup> )	45,7	-	42,2
<i>Energieerzeugung</i>				
Ausbauleistung	(kW)	850	600	22
Jahresarbeitsvermögen	(GWh)	1,8	2,0	0,2

\* ohne LM, \*\* mit LM, ° ohne Talsperre Flaje, °° mit Talsperre Flaje

Tabelle C.2: Untere und obere Randbedingungen ( $x^{\min}$  bzw.  $x^{\max}$ ) der Entscheidungsvariablen des Bodenmodells der Modellgebiete A und C.

Modell- gebiet	Rand- bedingung	Entscheidungsvariable					
		$K_1$	$K_2$	$K_B$	$Q_D$	$D_R$	$S_{DF}$
A	$x^{\min}$	0,001	0,001	0,1	0,5	6,0	0,01
	$x^{\max}$	100	200	2,2	2,2	80	0,5
C	$x^{\min}$	0,001	0,001	0,1	0,5	8,0	0,01
	$x^{\max}$	100	200	2,2	2,2	70	0,5






Abbildung C.1: Morphologie (links) und Landnutzung (rechts) des Untersuchungsgebiets.




Abbildung C.2: Geologie (links) und Bodentypen (rechts) des Untersuchungsgebiets.

Tabelle C.3: Untere und obere Randbedingungen ( $x^{\min}$  bzw.  $x^{\max}$ ) der Entscheidungsvariablen des Schneemodells der Modellgebiete A und C.

Rand- bedingung	Entscheidungsvariable									
	$T_0$	$T_{OR}$	$T_{TOR}$	$C_1$	$C_2$	CHW	CRFR	$RF_{\min}$	$RF_{\max}$	
$x^{\min}$	0,0	-1,0	-3,0	1E-03	1E-03	0,01	-1,0	0,0	0,0	
$x^{\max}$	5,0	3,0	4,0	3	0,5	0,5	3,0	5,0	5,0	




Abbildung C.3: Auf der linken Seite: Einzugsgebiet der Wilden Weißeritz bis zum Pegel Hainsberg 3 mit den verwendeten 94 Niederschlags- und Klimastationen des Deutschen Wetterdienstes (DWD) und des Tschechischen Hydrologisch-Meteorologischen-Dienstes (CHMI) sowie der WETTREG 2010. Auf der rechten Seite: Übersicht über das CLM-Raster in der REGKLAM-Modellregion und die drei ausgewählten Rasterzellen (türkis).




Abbildung C.4: Normalisierte Entscheidungsvektoren für (a) das Modellgebiet A und (b) das Modellgebiet C. Die Lösungen sind nach dem NSE geordnet und durch den farblichen Verlauf markiert. Die Abfolge der Variablen ist:  $T_{TOR}$  (1),  $T_{OR}$  (2),  $T_O$  (3),  $C_1$  (4),  $C_2$  (5),  $CHW$  (6),  $CRFR$  (7),  $RF_{Min}$  (8) und  $RF_{Max}$  (9),  $K_1$  (10),  $K_2$  (11),  $D_R$  (12),  $K_B$  (13),  $Q_0$  (14) und  $S_{DF}$  (15) für das TEZG Rehefeld im Modellgebiet A und für das Modellgebiet C.  $K_1$  (17),  $K_2$  (18),  $D_R$  (19),  $K_B$  (20),  $Q_0$  (21) und  $S_{DF}$  (22) sind Entscheidungsvariablen des TEZG Ammeldorf im Modellgebiet A. Für beide Modellgebiete ist  $k_{rec,H}$  (16).




Abbildung C.5: Abflusspende der Modellgebiete A (a, b) und C (c, d) im Kalibrierungszeitraum im monatlichen (links) und jährlichen (rechts) Zeitschritt. Dargestellt ist jeweils der Median (schwarze Linie), die Spannweite (graue Fläche) der Abflussmodellierungen der Pareto-optimalen Lösungen und die Beobachtungswerte (rote Linie).




Abbildung C.6: Boxplots über die Veränderungen im Jahresgang der rezenten und projizierten mittleren Abflusspenden unter WETTREG 2010 (Grau: DWD Datensatz 1961–1990; Rot: Kontrollläufe WETTREG 2010; Grün: Zeitscheibe 1991–2020; Blau: 2021–2050 und Braun: Zeitscheibe 2071–2100). Die grauen waagerechten Linien illustrieren die Mittelwerte der Beobachtungsdaten der Referenzperiode (1961–1990)




Abbildung C.7: Abflusspende der Modellgebiete A (a, b) und C (c, d) im Validierungszeitraum im monatlichen (links) und jährlichen (rechts) Zeitschritt. Dargestellt ist jeweils der Median (schwarze Linie), die Spannweite (graue Fläche) der Abflussmodellierungen der Pareto-optimalen Lösungen und die Beobachtungswerte (rote Linie).




Abbildung C.8: Entwicklung der Jahreswerte (Median) der korrigierten Niederschlagssumme (N), der Summe der Abflusspenden (A) und der realen und potentiellen Evapotranspiration (ETR und ETP) im Einzugsgebiet der Talsperren Klingenberg und Lehmühle.

## Modul B

Tabelle C.4: Statistische Kennwerte der beobachteten und synthetischen Zeitreihen der lokalen Zuflüsse A, B, C und D (1921-2007).

Es ist  $\mu$  der Mittelwert (gegeben in  $\text{hm}^3$  je Monat und  $\text{hm}^3$  je Jahr),  $\sigma$  die Standardabweichung,  $\xi$  die Schiefe und  $r_1$  der Autokorrelationskoeffizient für Lag-1.

Zufluss	Kennwert		Nov	Dez	Jan	Feb	März	April	Mai	Juni	Juli	Aug	Sept	Okt	Jahr	
A	$\mu$	beob	2,22	2,77	3,31	4,07	5,00	4,42	3,36	2,22	1,07	1,20	1,18	1,59	32,42	
		synth	2,23	2,83	3,34	4,02	5,04	4,41	3,38	2,26	1,06	1,17	1,19	1,58	32,51	
	$\sigma$	beob	0,48	0,66	0,63	0,77	0,65	0,70	0,57	0,69	0,67	0,68	0,50	0,46	2,82	
		synth	0,48	0,67	0,63	0,75	0,65	0,72	0,57	0,73	0,65	0,64	0,51	0,44	2,81	
	$\xi$	beob	0,66	1,14	0,91	1,18	0,48	0,82	1,18	3,77	4,32	4,15	3,40	1,49	0,61	
		synth	0,69	1,15	0,94	1,36	0,51	0,96	1,26	3,90	4,36	4,20	3,34	1,46	0,71	
	$r_1$	beob	0,34	0,21	0,16	0,13	0,16	0,27	0,27	0,13	0,28	0,28	0,40	0,47	0,27	
		synth	0,28	0,21	0,13	0,14	0,16	0,28	0,23	0,15	0,24	0,29	0,40	0,45	0,12	
	B	$\mu$	beob	0,72	0,93	1,10	1,32	1,74	1,68	1,15	0,51	0,30	0,31	0,30	0,48	10,56
			synth	0,73	0,95	1,12	1,31	1,75	1,68	1,16	0,53	0,30	0,31	0,31	0,48	10,64
$\sigma$		beob	0,17	0,23	0,23	0,25	0,23	0,27	0,22	0,22	0,21	0,22	0,15	0,15	1,07	
		synth	0,17	0,24	0,23	0,25	0,23	0,27	0,22	0,24	0,20	0,21	0,15	0,15	1,16	
$\xi$		beob	1,08	1,35	1,00	1,06	0,56	0,81	1,28	5,50	5,32	4,87	4,12	1,81	0,72	
		synth	1,05	1,33	1,05	1,14	0,56	0,86	1,29	5,52	5,30	4,98	4,05	1,84	0,85	
$r_1$		beob	0,50	0,32	0,28	0,26	0,17	0,37	0,35	0,16	0,29	0,43	0,57	0,59	0,26	
		synth	0,48	0,33	0,25	0,29	0,16	0,38	0,31	0,17	0,27	0,44	0,56	0,59	0,24	
C		$\mu$	beob	1,07	1,34	1,64	2,10	2,51	2,34	1,72	1,26	0,74	0,74	0,70	0,86	17,02
			synth	1,08	1,36	1,66	2,08	2,52	2,34	1,73	1,27	0,74	0,74	0,71	0,86	17,10
	$\sigma$	beob	0,20	0,29	0,31	0,32	0,27	0,30	0,30	0,15	0,24	0,25	0,14	0,20	1,17	

Zufluss	Kennwert		Nov	Dez	Jan	Feb	März	April	Mai	Juni	Juli	Aug	Sept	Okt	Jahr
D	$\xi$	synth	0,20	0,30	0,31	0,32	0,27	0,30	0,30	0,16	0,23	0,23	0,14	0,20	1,22
		beob	0,81	1,61	1,20	1,04	0,49	1,37	2,17	3,92	4,66	4,84	2,34	2,10	0,65
	$r_1$	synth	0,80	1,57	1,20	1,12	0,49	1,45	2,17	3,89	4,58	4,93	2,29	2,08	0,72
		beob	0,40	0,24	0,20	0,18	0,13	0,31	0,31	0,13	0,27	0,42	0,56	0,51	0,19
	$\mu$	synth	0,36	0,23	0,17	0,21	0,12	0,32	0,27	0,16	0,23	0,39	0,54	0,50	0,17
		beob	0,32	0,37	0,45	0,53	0,73	0,74	0,48	0,37	0,20	0,17	0,18	0,22	4,76
		synth	0,33	0,37	0,45	0,53	0,73	0,74	0,48	0,37	0,20	0,17	0,18	0,22	4,78
		beob	0,06	0,07	0,08	0,08	0,06	0,07	0,08	0,02	0,06	0,06	0,04	0,06	0,29
		synth	0,06	0,07	0,08	0,08	0,06	0,07	0,08	0,03	0,06	0,06	0,04	0,06	0,31
		beob	0,82	1,62	1,21	1,05	0,49	1,38	1,96	3,96	4,71	4,89	2,37	2,12	0,64
		synth	0,80	1,57	1,20	1,12	0,49	1,45	1,94	3,89	4,58	4,93	2,29	2,08	0,73
		beob	0,39	0,24	0,21	0,18	0,13	0,31	0,31	0,12	0,26	0,43	0,56	0,51	0,15
	$r_1$	synth	0,36	0,23	0,17	0,21	0,12	0,32	0,27	0,16	0,23	0,39	0,54	0,50	0,18




Abbildung C.9: Autokorrelogramme auf jährlicher Zeitskala für den Reanalysezeitraum des regionalen Klimamodells WETTREG 2010. Dargestellt sind die ACF der einzelnen Realisierungen aus WETTREG 2010, des HKNN-SMA-Modells, des HKNN-Modells, des verwendeten Gesamttrainingsdatensatzes und die Bandbreite an Autokorrelogrammen aus 10 000 zufälligen Rekombinationen des Trainingsdatensatzes..

## Modul C




Abbildung C.10: Exponentielle Zunahme des Defizitvolumens  $V_{FSA}$  mit den Abgabeanforderungen  $c_{crit}$  für den Gesamttalsperrenzufluss der Talsperren KL und LM (Zeitscheibe 2021-2050 unter WETTREG 2010, A1B).




Abbildung C.11: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe für den lokalen Zufluss A (1921-2007).




Abbildung C.12: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe für den lokalen Zufluss B (1921-2007).




Abbildung C.13: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe für den lokalen Zufluss C (1921-2007).






Abbildung C.14: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe für den lokalen Zufluss D (1921-2007).

## Modul D bis F

Tabelle C.5: Übersicht über die mittleren lokalen Zuflüsse für das regionale Klimamodell WETTREG 2010 in den Zeitscheiben 1961-1990, 1991-2020, 2021-2050 und 2071-2100. Weiterhin sind die beobachteten mittleren Zuflüsse im Zeitabschnitt 1921-2010 und 1961-1990 gegeben.

Zeitscheibe	Szenario	mittlerer lokaler Zufluss ( $\text{m}^3\text{s}^{-1}$ )			
		A	B	C*	D
1921-2007	Beobachtet	1,14	0,31	0,60	0,14
1961-1990	Beobachtet	1,16	0,32	0,60	0,15
1961-1990	Reanalyse	1,03	0,34	0,54	0,15
1991-2020	A1B	1,03	0,34	0,54	0,15
	B1	1,05	0,34	0,55	0,15
	A2	1,03	0,33	0,54	0,15
2021-2050	A1B	0,8	0,26	0,45	0,13
	B1	0,97	0,31	0,52	0,14
	A2	0,86	0,27	0,47	0,13
2071-2100	A1B	0,53	0,18	0,36	0,11
	B1	0,54	0,17	0,36	0,1
	A2	0,54	0,17	0,36	0,1

\* ohne die Regel-Abgabe der Talsperre Flaje von  $0,075 \text{ m}^3\text{s}^{-1}$

Tabelle C.6: Übersicht über die mittleren lokalen Zuflüsse für das regionale Klimamodell CLM in den Zeitscheiben 1961-1990, 1991-2020, 2021-2050 und 2071-2100. Weiterhin sind die beobachteten mittleren Zuflüsse im Zeitabschnitt 1921-2010 und 1961-1990 gegeben.

Zeitscheibe	Szenario	mittlerer lokaler Zufluss ( $\text{m}^3\text{s}^{-1}$ )			
		A	B	C*	D
1921–2007	Beobachtet	1,14	0,31	0,60	0,14
1961–1990	Beobachtet	1,16	0,32	0,60	0,15
1961–1990	Reanalyse	0,96	0,43	0,59	0,16
1991–2020	A1B	0,94	0,42	0,58	0,16
	B1	0,91	0,40	0,57	0,16
2021–2050	A1B	0,97	0,43	0,59	0,16
	B1	0,95	0,43	0,59	0,16
2071-2100	A1B	0,91	0,41	0,58	0,16
	B1	0,96	0,43	0,59	0,16

\* ohne die Regel-Abgabe der Talsperre Flaje von  $0,075 \text{ m}^3\text{s}^{-1}$

Tabelle C.7: Einstellungen und Ergebnisse der Module D bis F im rezenten Zeitraum (1921-2007).

Modul	Parameter (-)	Szenario		
		S-BEO	S-AKT	S-5RK
Modul D	Initialisierung	S-AKT	Lauf 1	S-AKT
	$\lambda_1$	0,99	0,6* / 0,985**	0,7
	$\lambda_2$	0,995	0,8* / 0,995**	0,8
	$\lambda_3$	0,9995	0,98* / 0,9994**	0,9
	$\mu$	48	48	48
	$\lambda$	48	48	48
	$n_M$	144 000	175 734	131 736
	$n_{PM}$	284	915	597
Modul E	$n_N$	-	360	360
	$n_E$	284	317	315
	$n_P$	175	99	165
	$n_G$	26	317	315
Modul F	$\alpha_1$	12	12	12
	$n_C$	3	4	5

\* Lauf 1, \*\* Lauf 2




Abbildung C.15: Regelkurven der Lösungen mit den jeweils geringsten 1-Normen (siehe Abbildung 8.31) aus den Szenarien S-2071-A1B (Schwarz), S-2071-A2 (Dunkelgrau), S-2071-B1 (Hellgrau)

Tabelle C.8: Einstellungen und Ergebnisse der Module D bis F in den Zeitscheiben 2021-2050 und 2071-2100.

Modul	Parameter	Szenario					
		(-)	2021 A1B	2021 A2	2021 B1	2071 A1B	2071 A2
Modul D	Initialisierung	S-AKT	S-2021 -A1B	S-AKT	S-2021 -A1B	S-2071 -A1B	S-2071 -A1B
	$\lambda_1$	0,99	0,7	0,99	0,6	0,6	0,6
	$\lambda_2$	0,993	0,8	0,994	0,8	0,8	0,8
	$\lambda_3$	0,9994	0,9	0,9993	0,9	0,9	0,9
	$\mu$	48	48	48	48	48	48
	$\lambda$	48	48	48	48	48	48
	$n_M$	96 000	96 000	96 000	96 000	96 000	96 000
	$n_{PM}$	2673	3549	799	5260	6187	4344
Modul E	$n_N$	360	360	360	360	360	360
	$n_E$	359	360	277	359	355	358
	$n_P$	314	57	91	257	265	283
Modul F	$\alpha_w$	12	12	12	12	12	12
	$n_C$	6	6	5	6	6	5




Abbildung C.16: Gegenüberstellung der in der MKO und der Validierung (VAL) erzielten Versorgungssicherheiten und Zielfunktionswerte für das Szenario S-5RK. Die strich-punktiierte Linie markiert die Ausgleichsgerade. Die einzelnen Kompromisslösungen sind in jeder Abbildung gleich schattiert.




Abbildung C.17: Gegenüberstellung der in der MKO und der Validierung (VAL) erzielten Versorgungssicherheiten und Zielfunktionswerte für die Szenarien S-2021-A1B (a), S-2021-A2 (b) und S-2021-B1 (c). Die strich-punktierte Linie markiert die Ausgleichsgerade. Die einzelnen Kompromisslösungen sind in jeder Abbildung gleich schattiert.




Abbildung C.18: Level-Diagramme der Szenarien S-2021-A1B (a), S-2021-A2 (b) und S-2021-B1 (c). Die strich-punktuierten Linien kennzeichnen jeweils  $R(\text{BSS} \{1, \dots, 3\})$ .




Abbildung C.19: Darstellung der optimalen Regelkurven der Szenarien S-2021-A1B (oben), S-2021-A2 (mitte) und S-2021-B1 (unten) zur Steuerung der Trinkwasserabgabe (links) und der Überleitung (rechts) nach Kompromissklassen. Farbige Flächen kennzeichnen die Spannweite der jeweiligen Regelkurve. Die Kompromissklassen sind für A1B a) Cl-1, b) Cl-2, c) Cl-3, d) Cl-4, e) Cl-5; für A2 a) Cl-1, b) Cl-2, c) Cl-3, d) Cl-4, e) Cl-5 und für B1 a) Cl-1, b) Cl-2 und c) Cl-3.




Abbildung C.20: Level-Diagramme der Szenarien S-2071-A1B (a), S-2071-A2 (b) und S-2071-B1 (c). Die strich-punktierten Linien kennzeichnen jeweils  $R(\text{BSS} \{1, \dots, 3\})$ .






Abbildung C.21: Darstellung der optimalen Regelkurven der Szenarien S-2071-A1B (oben), S-2071-A2 (mitte) und S-2071-B1 (unten) zur Steuerung der Trinkwasserabgabe (links) und der Überleitung (rechts) nach Kompromissklassen. Farbige Flächen kennzeichnen die Spannweite der jeweiligen Regelkurve. Die Kompromissklassen sind für A1B a) Cl-1, b) Cl-2, c) Cl-3, d) Cl-4, e) Cl-5, f) Cl-6; für A2 a) Cl-1, b) Cl-2, c) Cl-3, d) Cl-4, e) Cl-5 und für B1 a) Cl-1, b) Cl-2, c) Cl-3, d) Cl-4 und e) Cl-5.




Abbildung C.22: Gegenüberstellung der in der MKO und der Validierung (VAL) erzielten Versorgungssicherheiten und Zielfunktionswerte für die Szenarien S-2071-A1B (a), S-2071-A2 (b) und S-2071-B1 (c). Die strich-punktiierte Linie markiert die Ausgleichsgerade. Die einzelnen Kompromisslösungen sind in jeder Abbildung gleich schattiert.

## D Fallstudie 2

Tabelle D.1: Netzgewichte der Modellimplementierung in OASIS (Fallstudie 2).

		Speicher				
Knoten		911	922	933	999	944
Allgemein						
Netzgewicht	Totraum			7500		50
	Reserveraum			100		20
	Bewirtschaftungsraum			20		10
	Hochwasserschutzraum			-150		-100
		Bewässerungslandwirtschaft				
Knoten			580, 571, 572, 573			
Netzgewicht	Allgemein			50		
		Trinkwasserbereitstellung				
	Knoten					577
Netzgewicht	Allgemein					200
		Wasserkraftanlage				
	Knoten					574
Netzgewicht	Allgemein					11
		Wasserfall Tis-Issat				
	Knoten					575
Netzgewicht	Allgemein					30
		Ökologische Mindestdurchflüsse				
	Fließwege			78-80, 71-81, 72-82, 73-83		
Netzgewicht	Allgemein					1000

Tabelle D.2: Vorgegebene Staulamellengrößen (akkumuliert als obere und untere Randbedingungen) und Gesamtstauinhalte der einzelnen Speicher  $r$ .

Staulamelle	Megech	Koga	Ribb	Gumera	Tanasee
Totraum, $Z_s^{r, \text{Tot}}$ (hm <sup>3</sup> )	32,7	0,4	26,4	34,0	23 153
Gew. HQ-Raum, $Z_s^{r, \text{HQ}}$ (hm <sup>3</sup> )	182,6	78,5	233,7	57,2	32 277
Gesamtstauraum (hm <sup>3</sup> )	206,2	166,2	265,0	66,1	32 277

Tabelle D.3: Mittlere monatliche Zuflusssummen nach Knoten der Modellimplementierung in OASIS (siehe Abbildung 9.6).

Monat	Mittlere monatliche Zuflusssummen ( hm <sup>3</sup> je Monat) nach Knotennamen									
	80	81	82	83	84	401	402	403	404	405
Jan	1,3	38,8	7,2	4,3	8,6	5,2	2,0	6,6	3,5	9,2
Feb	1,0	28,5	5,6	3,2	6,4	4,1	1,5	4,9	2,7	7,0
März	0,8	27,0	4,6	2,6	5,8	3,4	1,4	4,2	2,3	5,8
Apr	0,7	26,6	3,9	2,3	5,2	3,0	1,5	3,7	2,0	5,1
Mai	0,9	39,9	3,9	2,6	7,0	3,3	2,2	5,5	3,1	5,8
Jun	4,4	121,7	6,8	5,3	11,4	5,7	5,4	10,0	5,5	12,4
Jul	24,8	495,4	86,2	62,9	95,2	24,9	21,2	114,8	63,5	50,3
Aug	44,7	844,8	241,9	158,9	218,4	64,0	39,6	208,8	113,5	117,7
Sept	22,0	542,2	116,6	79,5	122,4	41,4	25,0	104,8	57,8	84,8
Okt	10,7	282,0	38,1	30,3	51,4	21,2	13,4	42,0	23,7	44,4
Nov	3,9	109,4	16,9	11,6	23,2	11,3	5,6	17,6	9,5	21,9
Dez	2,1	59,4	10,3	6,4	13,5	7,2	3,1	9,8	5,3	13,2
Summe	117,4	2615,7	542,1	370,0	568,3	194,6	122,0	532,8	292,3	377,7

Tabelle D.4: Mittlere monatliche Bedarfssummen an den Knoten und Fließwegen der Modellimplementierung in OASIS (siehe Abbildung 9.6).

Monat	Mittlere monatliche Bedarfssummen ( hm <sup>3</sup> je Monat) nach Knoten- und Fließwegname									
	577	580	571	572	573	575	78-80	71-81	72-82	73-83
Jan	2,5	6,4	7,2	35,8	13,4	94,1	1,1	1,1	1,1	1,6
Feb	2,6	11,2	12,7	36,1	22,9	88,6	1,0	1,0	1,0	0,1
März	2,9	10,8	9,4	32,2	20,5	74,0	1,0	0,8	0,8	0,1
Apr	2,9	2,3	1,7	12,2	4,6	42,3	1,2	0,6	0,6	0,1
Mai	2,9	0,2	0,0	9,0	0,3	23,0	1,8	0,8	0,8	0,1
Jun	2,5	0,0	0,0	0,0	0,0	21,0	1,2	0,0	0,0	0,1
Jul	2,5	0,0	0,0	0,0	0,0	39,0	0,0	0,0	0,0	0,8
Aug	2,5	0,0	0,0	0,0	0,0	83,0	0,0	0,0	0,0	0,9
Sept	2,5	1,3	0,0	1,6	0,4	192,0	0,0	0,0	0,0	0,8
Okt	2,5	5,1	2,9	15,1	7,5	117,0	3,6	2,7	2,7	0,9
Nov	2,5	2,3	3,1	4,9	5,3	124,7	1,8	1,6	1,6	0,6
Dez	2,5	2,2	2,9	25,0	3,6	112,1	0,9	0,8	0,8	0,3
Summe	31,6	41,8	39,9	171,8	78,4	1011,0	13,5	9,3	9,3	6,5

Es ist 577 der Trinkwasserbedarf der Stadt Gondor, 580 der Bewässerungsbedarf des Megech Landwirtschaftsprojekts, 571 der Bewässerungsbedarf des Koga Landwirtschaftsprojekts, 572 der Bewässerungsbedarf des Ribb Landwirtschaftsprojekts, 573 der Bewässerungsbedarf des Gumera Landwirtschaftsprojekts, 575 der Durchflussbedarf des Tis-Issat Wasserfalls; 78-80 der Mindestdurchfluss unterhalb des Landwirtschaftsprojekts Megech, 71-81 der Mindestdurchfluss unterhalb des Landwirtschaftsprojekts Koga, 72-82 der Mindestdurchfluss unterhalb des Landwirtschaftsprojekts Ribb und 73-83 der Mindestdurchfluss unterhalb des Landwirtschaftsprojekts Gumera

Tabelle D.5: Mittelwerte  $\mu$  der beobachteten und mit dem HKNN-SMA-Modell simulierten lokalen Zuflüsse in  $\text{hm}^3$  je Monat bzw.  $\text{hm}^3$  je Jahr.

Knoten	Kennwert	Jan	Feb	März	April	Mai	Juni	Juli	Aug	Sept	Okt	Nov	Dez	Jahr
80	synth	1,38	0,89	0,77	0,69	0,96	5,04	28,79	47,03	21,86	11,84	4,14	2,12	125,29
	beob	1,35	0,88	0,79	0,69	0,96	4,37	25,30	45,59	21,68	10,88	3,87	2,10	118,28
81	synth	40,91	26,85	27,41	27,53	39,28	118,26	511,36	890,10	554,15	297,89	111,53	61,42	2706,62
	beob	39,54	26,25	27,53	26,23	40,63	120,03	504,71	860,79	534,65	287,35	107,88	60,49	2635,95
82	synth	7,41	5,16	4,60	3,88	3,91	6,11	86,34	251,24	115,78	38,53	16,94	10,47	549,56
	beob	7,38	5,12	4,66	3,86	3,98	6,75	87,82	246,49	114,96	38,84	16,65	10,51	546,26
83	synth	4,47	3,01	2,62	2,20	2,62	5,01	59,45	164,01	79,19	31,33	11,90	6,64	371,91
	beob	4,39	2,97	2,68	2,25	2,69	5,27	64,14	161,93	78,35	30,85	11,41	6,52	372,86
86	synth	8,73	5,92	5,84	5,15	6,37	10,23	84,68	217,51	121,13	49,76	22,33	13,14	550,62
	beob	8,79	5,89	5,92	5,10	7,11	11,20	96,97	222,56	120,68	52,33	22,84	13,72	572,72
401	synth	5,38	3,83	3,47	2,99	3,25	5,69	27,48	68,21	42,12	22,79	11,59	7,46	204,46
	beob	5,25	3,75	3,47	2,98	3,31	5,62	25,33	65,24	40,79	21,63	11,17	7,30	196,09
402	synth	2,14	1,44	1,49	1,50	2,11	5,11	21,86	42,40	25,55	14,00	5,71	3,25	126,57
	beob	2,05	1,39	1,46	1,43	2,28	5,36	21,57	40,35	24,66	13,64	5,57	3,19	122,97
403	synth	6,50	4,47	4,22	3,57	4,35	7,38	102,45	211,00	104,37	40,12	16,31	9,51	513,42
	beob	6,67	4,53	4,31	3,60	5,62	9,91	116,96	212,74	103,35	42,84	17,38	10,03	536,94
404	synth	3,51	2,41	2,27	1,92	2,33	4,02	56,27	114,22	57,58	22,29	8,81	5,14	280,33
	beob	3,61	2,44	2,32	1,93	3,12	5,38	64,69	115,65	57,01	24,13	9,40	5,45	294,60
405	synth	9,71	6,64	5,93	5,11	5,97	12,90	57,96	126,31	85,65	47,53	22,60	13,88	400,67
	beob	9,38	6,47	5,92	5,06	5,94	12,27	51,26	119,90	83,61	45,23	21,57	13,48	380,65

Tabelle D.6: Standardabweichung  $\sigma$  der beobachteten und mit dem HKNN-SMA-Modell simulierten lokalen Zuflüsse in  $\text{hm}^3$  je Monat bzw.  $\text{hm}^3$  je Jahr.

Knoten	Kennwert	Jan	Feb	März	April	Mai	Juni	Juli	Aug	Sept	Okt	Nov	Dez	Jahr
80	synth	0,12	0,07	0,05	0,06	0,23	2,49	11,38	8,82	3,44	4,00	0,92	0,25	27,20
	beob	0,11	0,07	0,08	0,06	0,21	2,24	9,76	8,37	3,15	3,88	0,81	0,24	24,25
81	synth	2,32	1,45	1,82	3,04	6,48	37,50	112,92	119,91	58,81	51,72	16,19	5,15	282,50
	beob	2,76	1,66	1,87	3,40	7,12	36,57	106,27	110,85	58,72	49,52	16,30	5,74	278,80
82	synth	0,32	0,21	0,18	0,21	0,29	1,09	28,09	32,36	17,64	8,58	1,59	0,62	72,92
	beob	0,34	0,22	0,22	0,22	0,32	1,62	27,42	33,27	17,94	9,17	1,43	0,61	73,60
83	synth	0,26	0,15	0,10	0,14	0,32	0,72	14,58	13,68	9,12	5,11	1,57	0,54	32,17
	beob	0,23	0,15	0,12	0,16	0,35	0,83	15,38	14,71	9,64	4,95	1,29	0,45	35,79
86	synth	0,72	0,41	0,44	0,55	1,46	2,86	19,50	27,99	14,76	9,86	3,56	1,65	62,53
	beob	1,00	0,53	0,49	0,57	2,18	2,97	20,38	26,16	13,74	10,87	4,45	2,42	60,30
401	synth	0,41	0,25	0,16	0,17	0,34	1,41	9,57	16,41	7,87	5,07	1,88	0,72	38,55
	beob	0,38	0,24	0,18	0,17	0,33	1,32	8,21	15,31	7,27	4,69	1,78	0,71	34,98
402	synth	0,14	0,11	0,10	0,23	0,46	1,95	5,35	6,90	3,93	2,30	0,89	0,30	12,78
	beob	0,16	0,12	0,11	0,25	0,53	1,95	5,36	6,16	3,83	2,28	0,96	0,33	13,49
403	synth	0,54	0,28	0,21	0,24	1,41	3,74	25,06	23,75	14,38	9,92	2,85	1,13	61,05
	beob	0,73	0,38	0,27	0,27	2,54	4,54	24,30	22,57	13,42	10,99	3,73	1,56	58,78
404	synth	0,30	0,15	0,11	0,13	0,82	2,12	13,69	12,66	7,84	5,83	1,55	0,64	33,26
	beob	0,42	0,21	0,15	0,14	1,56	2,52	13,64	12,08	7,22	6,65	2,04	0,90	32,79
405	synth	0,72	0,45	0,30	0,32	0,82	3,18	23,19	32,20	14,33	10,79	3,63	1,36	79,03
	beob	0,70	0,47	0,45	0,37	0,76	2,92	19,78	29,42	13,47	10,41	3,49	1,37	70,98

Tabelle D.7: Schiefe  $\xi$  (-) der beobachteten und mit dem HKNN-SMA-Modell simulierten lokalen Zuflüsse.

Knoten	Kennwert	Jan	Feb	März	April	Mai	Juni	Juli	Aug	Sept	Okt	Nov	Dez	Jahr
80	synth	0,85	0,86	0,81	1,53	2,34	1,53	1,51	0,95	0,54	1,72	1,50	1,14	1,08
	beob	1,10	1,02	2,23	1,42	2,46	1,89	1,84	1,02	0,57	2,54	2,00	1,54	1,17
81	synth	0,30	0,34	0,88	0,34	0,71	2,13	0,96	0,14	-0,46	1,06	1,26	1,04	-0,05
	beob	0,29	0,25	0,73	0,37	0,86	2,32	1,25	0,07	-0,34	1,15	1,25	1,09	-0,22
82	synth	0,70	0,54	1,91	0,72	0,13	3,99	1,32	0,13	0,16	2,39	0,48	0,48	0,43
	beob	0,66	0,59	1,72	1,01	0,20	3,44	1,38	0,13	0,22	3,17	0,67	0,62	0,40
83	synth	0,50	0,40	1,97	2,15	0,31	1,11	1,36	-0,58	0,18	0,48	1,00	0,76	-0,16
	beob	0,38	0,27	1,60	1,77	0,41	1,15	1,35	-1,16	-0,19	0,48	1,05	0,70	-0,42
86	synth	1,86	1,08	0,58	0,74	2,49	1,79	0,44	0,56	-0,08	1,51	1,56	2,82	0,04
	beob	2,52	1,68	0,69	1,04	2,86	1,41	0,21	0,36	-0,15	1,53	2,31	3,12	-0,49
401	synth	0,87	0,73	0,82	1,40	1,31	1,23	1,55	1,00	0,64	1,33	1,39	1,15	0,84
	beob	1,45	1,23	0,96	1,72	1,25	1,51	1,89	1,10	0,85	1,97	2,00	1,87	0,92
402	synth	0,42	0,98	0,50	0,96	1,30	2,54	1,38	1,36	0,28	0,36	1,34	0,86	0,01
	beob	0,15	0,86	0,45	0,97	1,33	2,65	1,87	1,15	0,54	0,28	1,32	0,67	0,21
403	synth	2,69	1,99	1,11	1,18	5,15	2,75	0,02	0,90	0,10	1,83	2,32	3,03	0,06
	beob	2,61	2,02	1,35	1,21	3,30	1,66	-0,33	0,85	0,04	1,60	2,26	2,79	-0,48
404	synth	2,86	2,13	1,11	1,02	6,10	2,84	0,06	0,82	-0,03	1,90	2,41	3,28	0,03
	beob	2,78	2,16	1,41	1,07	3,53	1,72	-0,21	0,72	-0,10	1,69	2,34	2,97	-0,45
405	synth	0,66	0,53	0,23	1,43	1,87	1,35	1,87	1,51	0,48	1,51	1,33	1,02	1,19
	beob	0,82	0,61	1,47	1,18	1,90	1,58	2,42	1,69	0,45	2,10	1,74	1,42	1,27

Tabelle D.8: Autokorrelationskoeffizienten  $r_1$  (-) der beobachteten und mit dem HKNN-SMA-Modell simulierten lokalen Zuflüsse.

Knoten	Kennwert	Jan	Feb	März	April	Mai	Juni	Juli	Aug	Sept	Okt	Nov	Dez	Jahr
80	synth	0,90	0,84	0,61	0,06	0,51	0,88	0,83	0,75	0,74	0,66	0,94	0,95	0,36
	beob	0,96	0,76	0,44	0,03	0,53	0,82	0,82	0,72	0,67	0,77	0,96	0,96	0,54
81	synth	0,86	0,32	0,48	0,39	0,75	0,91	0,31	0,58	0,29	0,78	0,98	0,92	-0,02
	beob	0,94	0,43	0,47	0,49	0,72	0,91	0,41	0,63	0,45	0,78	0,97	0,94	0,07
82	synth	0,69	0,60	0,47	0,42	0,22	0,00	0,73	0,59	0,69	0,76	0,94	0,68	0,31
	beob	0,92	0,70	0,71	0,39	0,32	-0,04	0,75	0,54	0,69	0,69	0,97	0,98	0,12
83	synth	0,91	0,59	0,41	0,32	0,71	0,18	0,43	0,43	0,49	0,90	0,99	0,99	0,10
	beob	0,94	0,51	0,58	0,27	0,72	0,08	0,46	0,54	0,58	0,86	0,99	0,99	0,45
86	synth	0,88	0,35	0,61	0,44	0,69	0,61	0,58	0,77	0,47	0,81	0,94	0,95	0,01
	beob	0,95	0,61	0,60	0,36	0,62	0,54	0,48	0,74	0,33	0,83	0,97	0,98	-0,10
401	synth	0,96	0,89	0,76	0,19	0,66	0,82	0,89	0,80	0,74	0,82	0,97	0,96	0,45
	beob	0,98	0,91	0,81	0,18	0,73	0,71	0,87	0,81	0,68	0,92	0,99	0,98	0,55
402	synth	0,83	0,39	0,43	0,36	0,60	0,81	-0,03	0,67	0,10	0,81	0,89	0,82	-0,01
	beob	0,90	0,56	0,56	0,43	0,58	0,83	0,14	0,70	0,30	0,81	0,90	0,85	0,10
403	synth	0,95	0,57	0,61	0,46	0,62	0,40	0,57	0,69	0,45	0,72	0,99	0,99	0,00
	beob	0,98	0,84	0,78	0,54	0,48	0,46	0,49	0,66	0,34	0,75	0,99	0,99	-0,20
404	synth	0,96	0,57	0,62	0,42	0,57	0,41	0,55	0,69	0,43	0,76	0,98	0,99	0,01
	beob	0,98	0,85	0,76	0,51	0,44	0,48	0,48	0,65	0,30	0,80	0,98	0,99	-0,17
405	synth	0,96	0,87	0,73	0,12	0,52	0,87	0,90	0,86	0,68	0,80	0,97	0,97	0,35
	beob	0,97	0,82	0,68	0,11	0,59	0,80	0,88	0,84	0,63	0,89	0,98	0,97	0,52



Tabelle D.9: Übersicht über gewählte Parameterwerte und Ergebnisse der Monte-Carlo-Rekombination in Fallstudie 2.

$n_{\text{ha}}$ (-)	$Q$ ( $\text{hm}^3$ je Monat)	$c_{\text{crit}}$ ( $\text{hm}^3$ je Monat)	$n_r$ (-)	$P_T$ (-)	$\rho_{\text{min}}$ (-)	$n_{\text{he}}$ (-)	$\rho$ (-)	$L_R$ (Jahre)
9248	5783	3167	600	0,8	0,9	618	0,91	679

Tabelle D.10: Kennwerte der MKO der Talsperrenbewirtschaftung in Fallstudie 2.

Modul	Parameter (-)	Szenario			
		S-2D-65-20y	S-2D-65-679y	S-3D-65-20y	S-3D-65-679y
Modul D	$n_{\text{PM}}$	1900	5254	1583	2591
Modul E	$n_N$	80	80	80	80
	$n_E$	52	77	80	80
	$n_P$	27	52	79	80

Modul	Parameter (-)	Szenario			
		S-2D-120-20y	S-2D-120-679y	S-3D-120-20y	S-3D-120-679y
Modul D	$n_{\text{PM}}$	331	453	389	1609
Modul E	$n_N$	80	80	80	80
	$n_E$	75	79	79	80
	$n_P$	6	10	31	80




Abbildung D.1: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe des Knotens 401.




Abbildung D.2: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe des Knotens 402.




Abbildung D.3: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe des Knotens 404.




Abbildung D.4: Statistische Kennwerte der langjährigen synthetischen Zeitreihe und der Proxyzeitreihe des Knotens 86.




Abbildung D.5: Streudiagramme der Zielfunktion aus der MKO und der Validierung, a) für das Szenario S-2D-65-20y, b) für das Szenario S-2D-65-679y. Die einzelnen Kompromisslösungen sind in jeder Abbildung gleich schattiert. \* Die Zielfunktion  $FF3$  ist gesondert gekennzeichnet, da diese der Zielfunktion nach Gleichung 9.3 entspricht, jedoch in den beiden Szenarien nicht zur Formulierung der MKO gehört.




Abbildung D.6: Streudiagramme der Zielfunktion aus der MKO und der Validierung, a) für das Szenario S-2D-120-20y, b) für das Szenario S-2D-120-679y. Die einzelnen Kompromisslösungen sind in jeder Abbildung gleich schattiert. \* Die Zielfunktion  $FF3$  ist gesondert gekennzeichnet, da diese der Zielfunktion nach Gleichung 9.3 entspricht, jedoch in den beiden Szenarien nicht zur Formulierung der MKO gehört.




Abbildung D.7: Streudiagramme der Zielfunktion aus der MKO und der Validierung, a) für das Szenario S-3D-65-20y, b) für das Szenario S-3D-65-679y. Die einzelnen Kompromisslösungen sind in jeder Abbildung gleich schattiert.




Abbildung D.8: Streudiagramme der Zielfunktion aus der MKO und der Validierung, a) für das Szenario S-3D-120-20y, b) für das Szenario S-3D-120-679y. Die einzelnen Kompromisslösungen sind in jeder Abbildung gleich schattiert.

Tabelle D.11: Extreme der Zielfunktionswerte  $FF1$  und  $FF2$  für die Pareto-optimalen Lösungen der Szenarien S-2D-x-x in der Validierung.  $\min(D_1)$  repräsentiert die Lösung mit der geringsten 1-Norm bei einer ausschließlichen Wertung der jeweiligen Pareto-Menge eines entsprechenden Szenarios.

Szenario	Lösung	$FF1$ (hm <sup>3</sup> )	$FF2$ (GWh)	$FF3^*$ (m.ü.NN)
S-2D-65-20y	$\min(D_1)$	96,9	1881,9	1785,6
	$\min(FF1)$	43,1	1863,3	1785,5
	$\max(FF2)$	193,9	1897,6	1785,7
S-2D-65-679y	$\min(D_1)$	32,9	1834,0	1785,7
	$\min(FF1)$	31,2	1807,3	1785,8
	$\max(FF2)$	152,4	1891,4	1785,6
S-2D-120-20y	$\min(D_1)$	9,2	1649,7	1785,5
	$\min(FF1)$	8,5	1243,0	1785,1
	$\max(FF2)$	10,2	1659,7	1785,5
S-2D-120-679y	$\min(D_1)$	28,3	1732,8	1785,8
	$\min(FF1)$	15,1	1518,4	1785,0
	$\max(FF2)$	102,8	1779,4	1785,7

\* stellt keine Zielfunktion der MKO dar.

Tabelle D.12: Zielfunktionswerte  $FF1$ ,  $FF2$  und  $FF3$  für die Pareto-optimalen Lösungen in der Validierung der Szenarien S-3D-x-x.  $\min(D_1)$  repräsentiert die Lösung mit der geringsten 1-Norm bei einer ausschließlichen Wertung der jeweiligen Pareto-Menge eines entsprechenden Szenarios.

Szenario	Lösung	$FF1$ (hm <sup>3</sup> )	$FF2$ (GWh)	$FF3$ (m.ü.NN)
S-3D-65-20y	$\min(D_1)$	31,1	1647,2	1786,1
	$\min(FF1)$	31,0	1709,7	1786,0
	$\max(FF2)$	189,7	1895,3	1785,7
	$\max(FF3)$	171,1	1462,1	1786,6
S-3D-65-679y	$\min(D_1)$	31,1	1613	1786,1
	$\min(FF1)$	31,0	1548,6	1786,1
	$\max(FF2)$	174,9	1891,9	1785,6
	$\max(FF3)$	36,2	446,2	1786,6
S-3D-120-20y	$\min(D_1)$	9,5	1581,5	1786,1
	$\min(FF1)$	9,1	1576,5	1786,0
	$\max(FF2)$	9,5	1614	1786,0
	$\max(FF3)$	9,8	1511,7	1786,1
S-3D-120-679y	$\min(D_1)$	10,8	1560,8	1786,1
	$\min(FF1)$	9,2	1453	1786,2
	$\max(FF2)$	162,7	1889,3	1785,6
	$\max(FF3)$	56,5	875,1	1786,4