



EVOLUTIONARY MULTI-OBJECTIVE DIRECT POLICY SEARCH (EMODPS), EINE HEURISTISCHE ENTSCHEIDUNGSHILFE IN DER WASSERWIRTSCHAFT

15. Symposium Energieinnovation

Christoph Libisch-Lehner

Graz, 15.02.2018



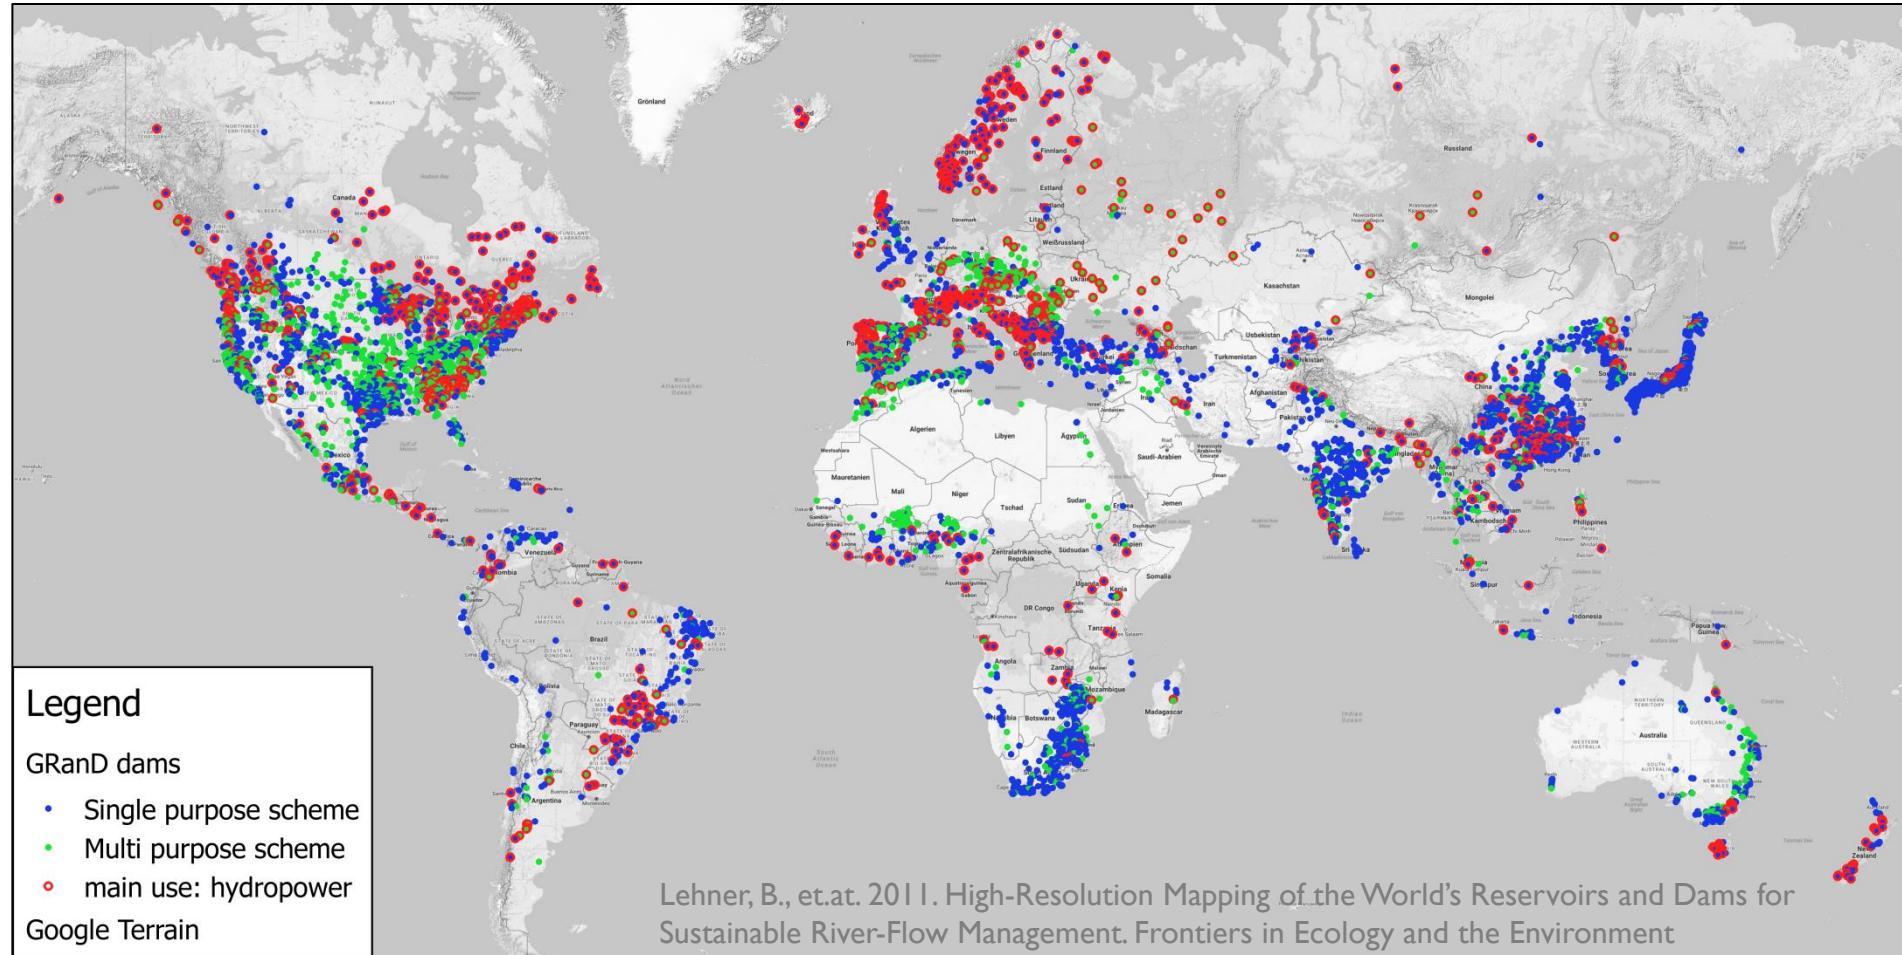
EINLEITUNG

Evolutionary Multi-Objective Direct Policy Search

- Simulationsbasiertes Optimierungsverfahren zur:
 - langfristigen Planung und Wirkungsmodellierung von Wasserressourcenentwicklung in Flussgebieten
 - kurzfristige Einsatzplanung (Betriebsstrategien von wasserwirtschaftlichen Anlagen in real-time)
- Forschungsbedarf gegeben aufgrund von:
 - Integrierten Wasserressourcenmanagement
 - “Globaler Wandel”
 - Datenverfügbarkeit
 - Limitierungen klassischer Optimierungsalgorithmen

EINLEITUNG

Mehrziel-Planung



EINLEITUNG

Mehrziel-Planung

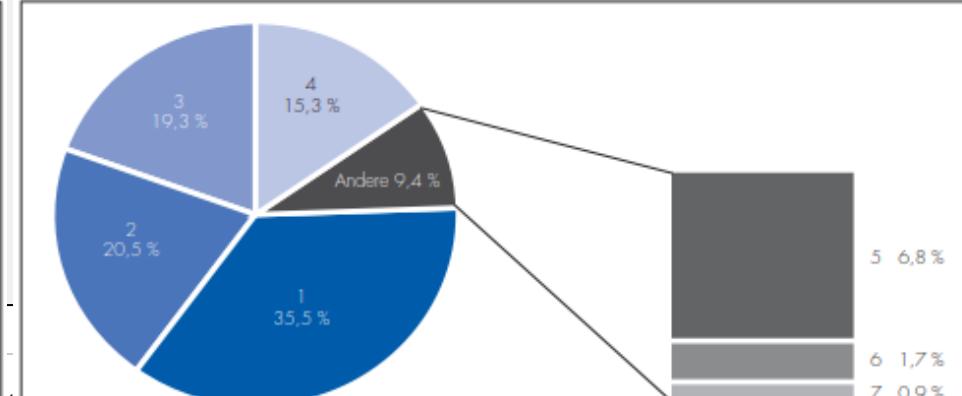
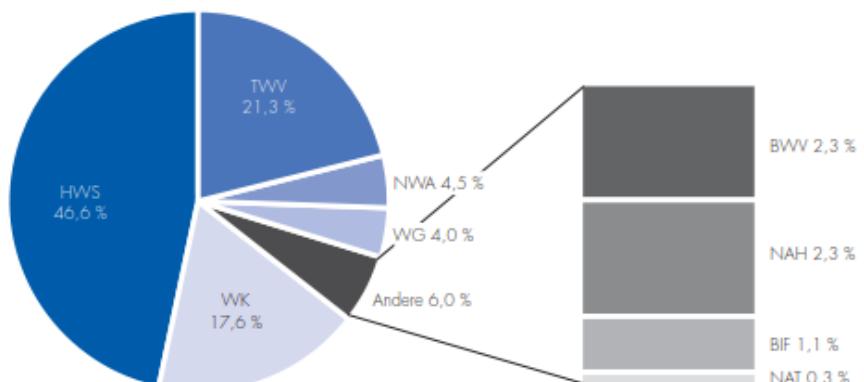
Global:

Hauptnutzung:

- 25 % Bewässerung
- 22 % Wasserkraft
- 12 % Trinkwasserversorgung
- 8 % Hochwasserschutz

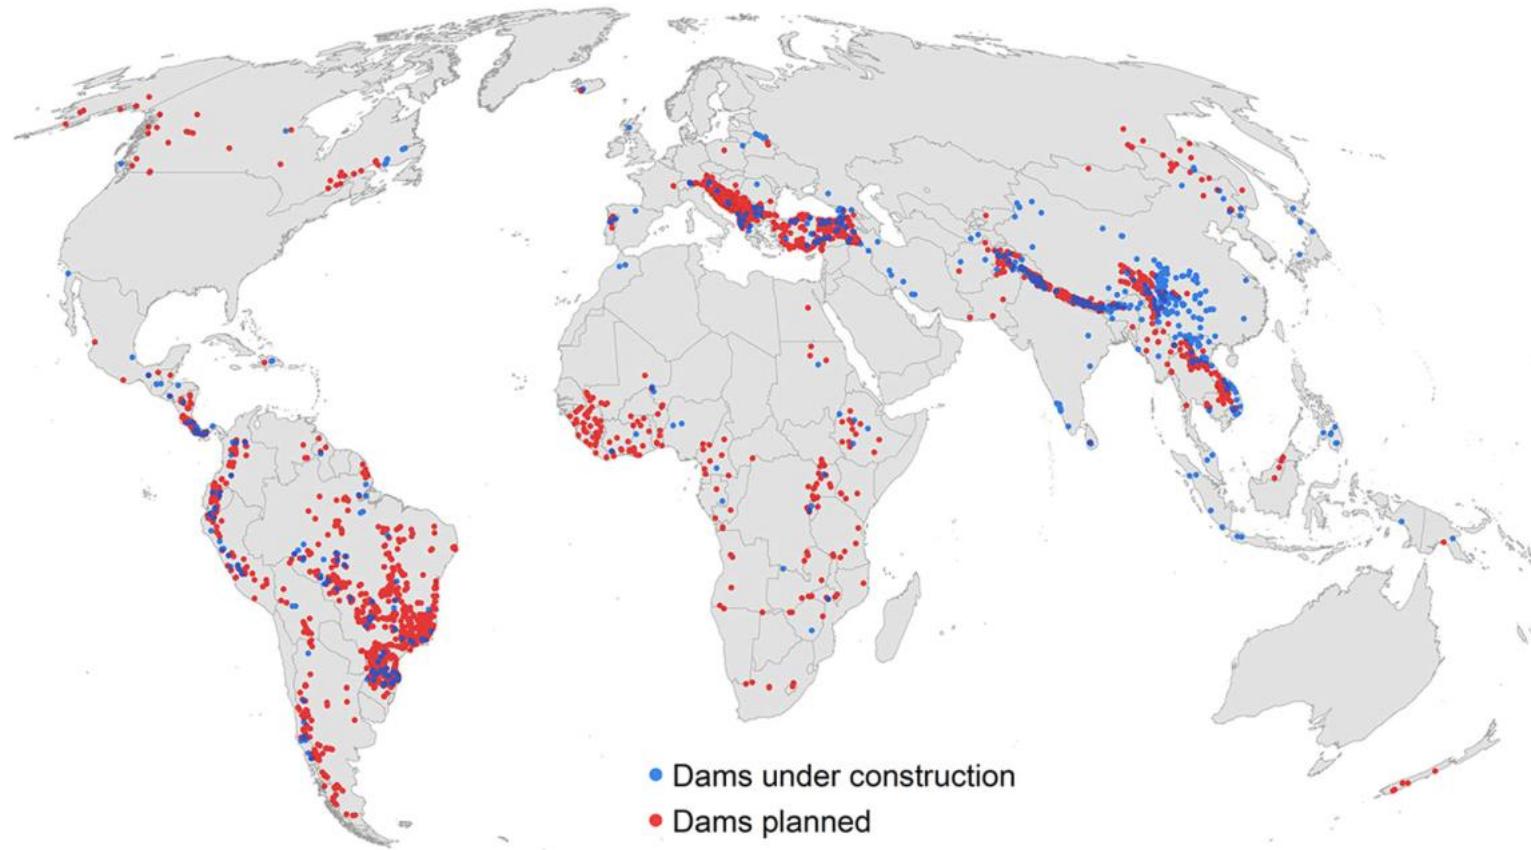
30 % Mehrzweckanlagen

Deutschland:



EINLEITUNG

Integriertes Wasserressourcenmanagement



Zarfl, C., Lumsdon, A. E., Berlekamp, J., Tydecks, L., & Tockner, K. (2014). A global boom in hydropower dam construction

EINLEITUNG

“Globaler Wandel” und neue Chancen

- Klimawandel
 - Unsicherheit zukünftiger hydrologischer Verhältnisse
 - Veränderung von Extremereignissen
 - Veränderungen im Wasserverbrauch
- Sozio-Ökonomischer Wandel
 - Energiemarkt
 - Ökologisch verträglicher Betrieb (z.B. Schwall und Sunk)
- Chancen
 - Mehr und neue Daten
 - Gesteigerte Rechenleistung
 - verbessertes Systemverständnis

PROBLEMSTELLUNG

Optimales Steuerungsproblem:

$$p^* = \arg \min_p J(p, x_0)$$

Markov-Entscheidungsprozess:

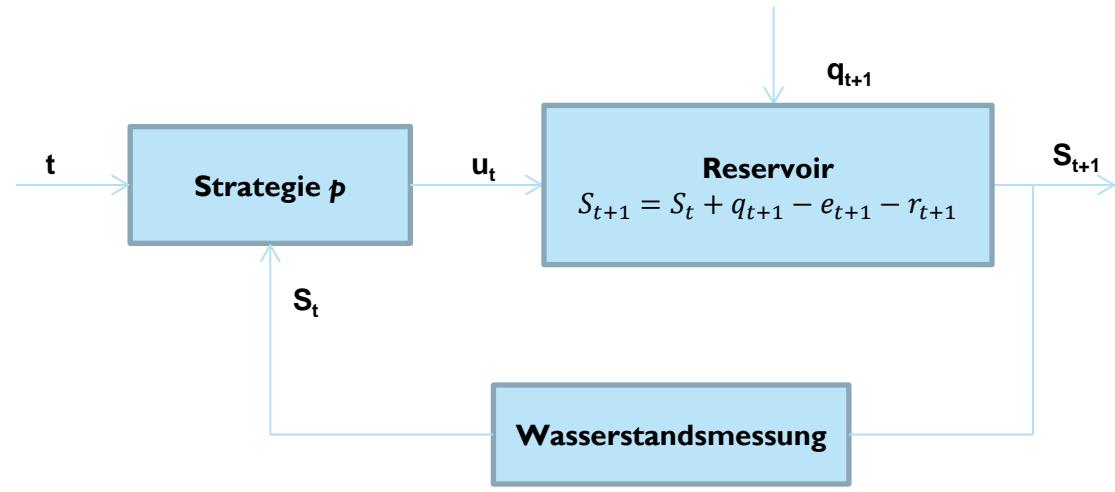
$$x_{t+1} = f_t(x_t, u_t)$$

$$x_t = [S_t]$$

$$p = \{m_0, m_1, \dots, m_{T-1}\}$$

$$u_t = m_t(x_t)$$

Feedback-Control-Framework:



Castelletti, A., de Rigo, D., Rizzoli, A. E., Soncini-Sessa, R., & Weber, E. (2007). Neuro-dynamic programming for designing water reservoir network management policies.

PROBLEMSTELLUNG

Optimales Steuerungsproblem:

$$p^* = \arg \min_p J(p, x_0)$$

Partiell beobachtbarer Markov-Entscheidungsprozess:

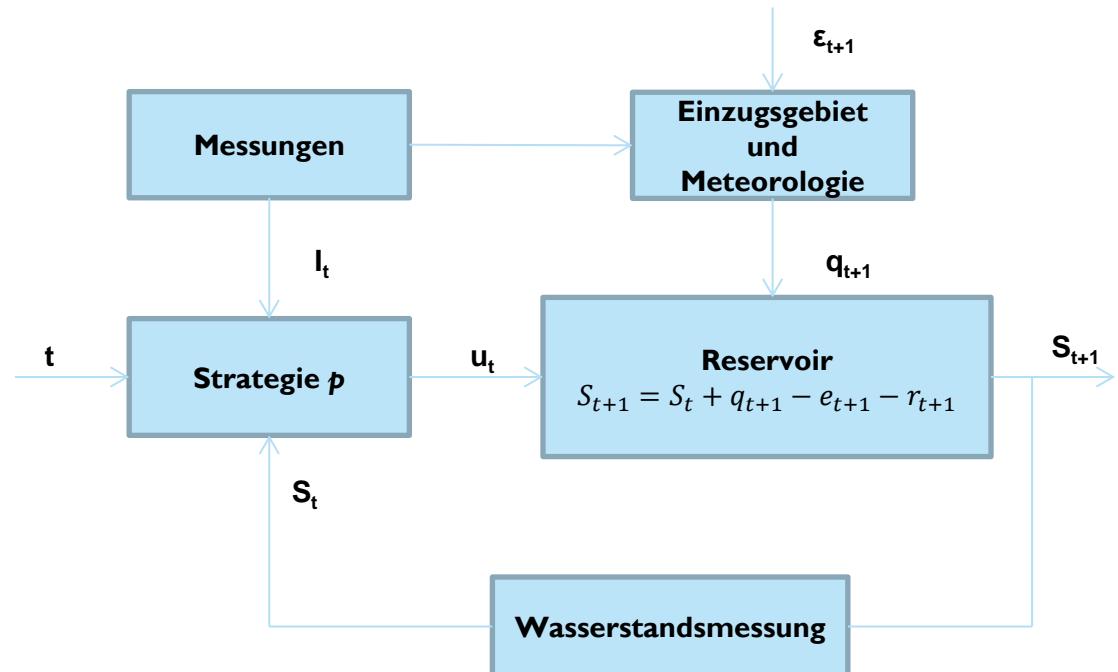
$$x_{t+1} = f_t(x_t, u_t, \varepsilon_{t+1})$$

$$x_t = [S_t, I_t]$$

$$p = \{m_0, m_1, \dots m_{T-1}\}$$

$$u_t = m_t(x_t)$$

Feedback-Control-Framework:



Castelletti, A., de Rigo, D., Rizzoli, A. E., Soncini-Sessa, R., & Weber, E. (2007). Neuro-dynamic programming for designing water reservoir network management policies.

LÖSUNGSWEGE

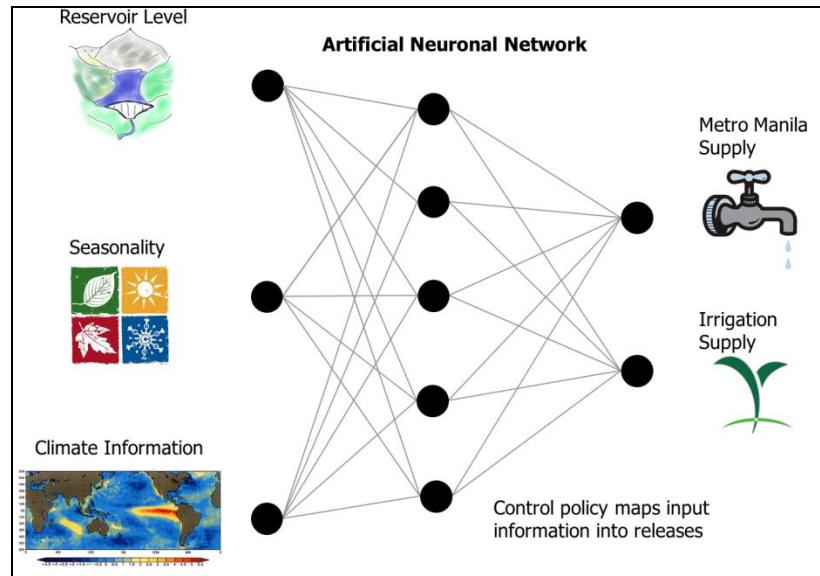
Reinforcement Learning

- “value function-based” vs. “policy search-based”
 - **Klassische Lösung:** *Dynamic Programming*
 - Optimalitätsprinzip nach Bellman
 - Limitierungen:
 - “Fluch der Dimension”
 - “Fluch der Modellierung”
 - “Fluch der Mehrzielplanung”
- 
- exponentieller Anstieg in der Berechnungszeit

LÖSUNGSWEGE

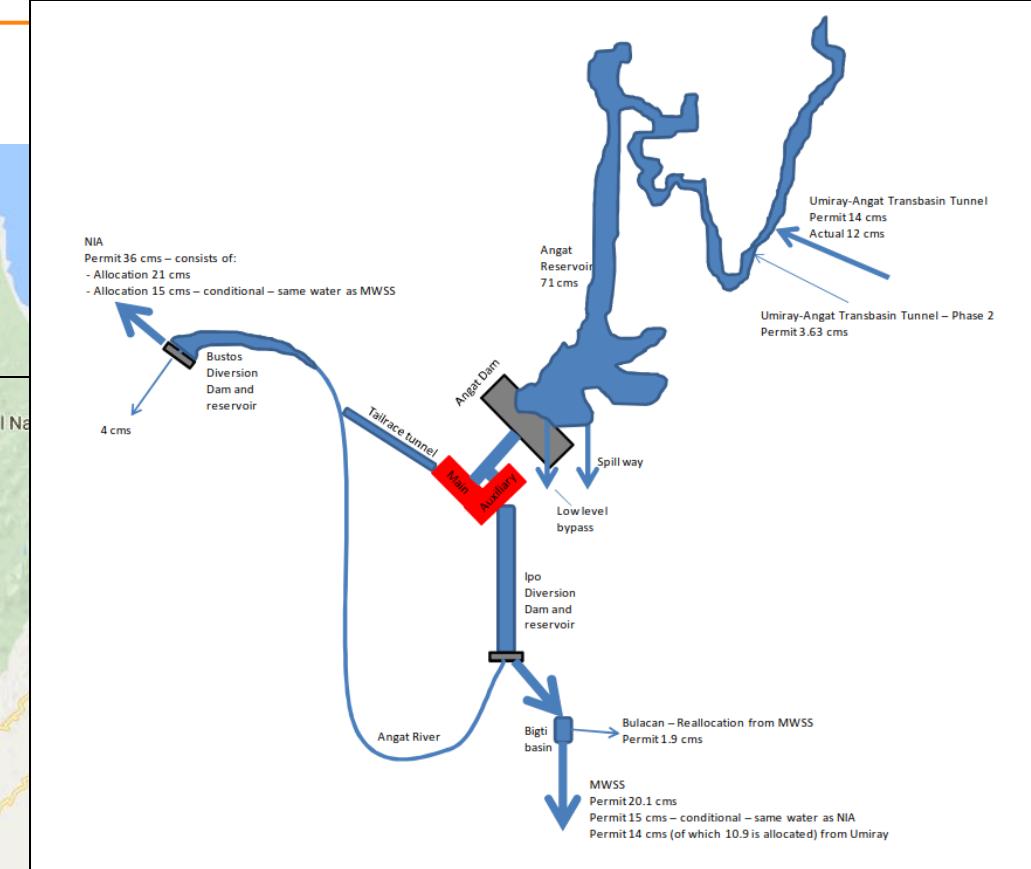
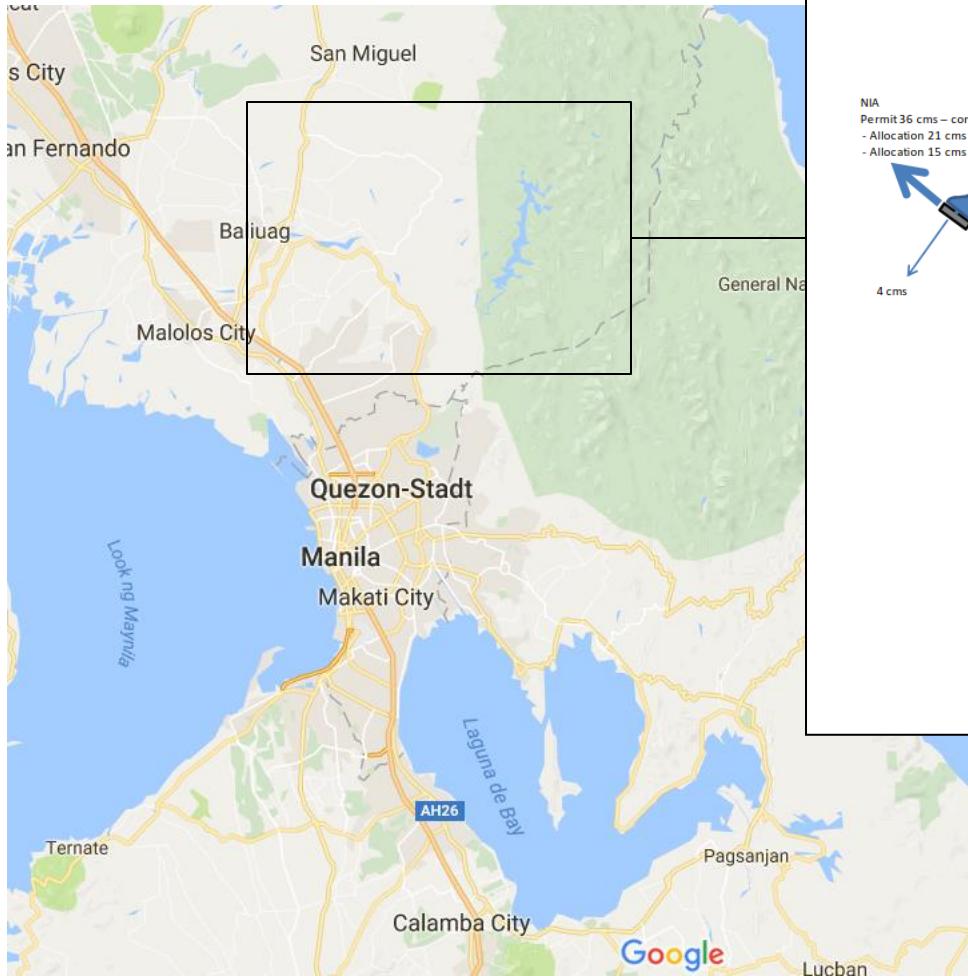
Reinforcement Learning: “policy search-based” - EMODPS

- Betriebsregel wird parametrisiert (linear vs. nicht linear)



- Suche nach optimalen Parameter der Betriebsregel: $u_t = m_t(x_t, \theta_t)$
- externe Optimierung: Evolutionsalgorithmus (BORG, NSGA2, ...)

Fallstudie – Metro Manila



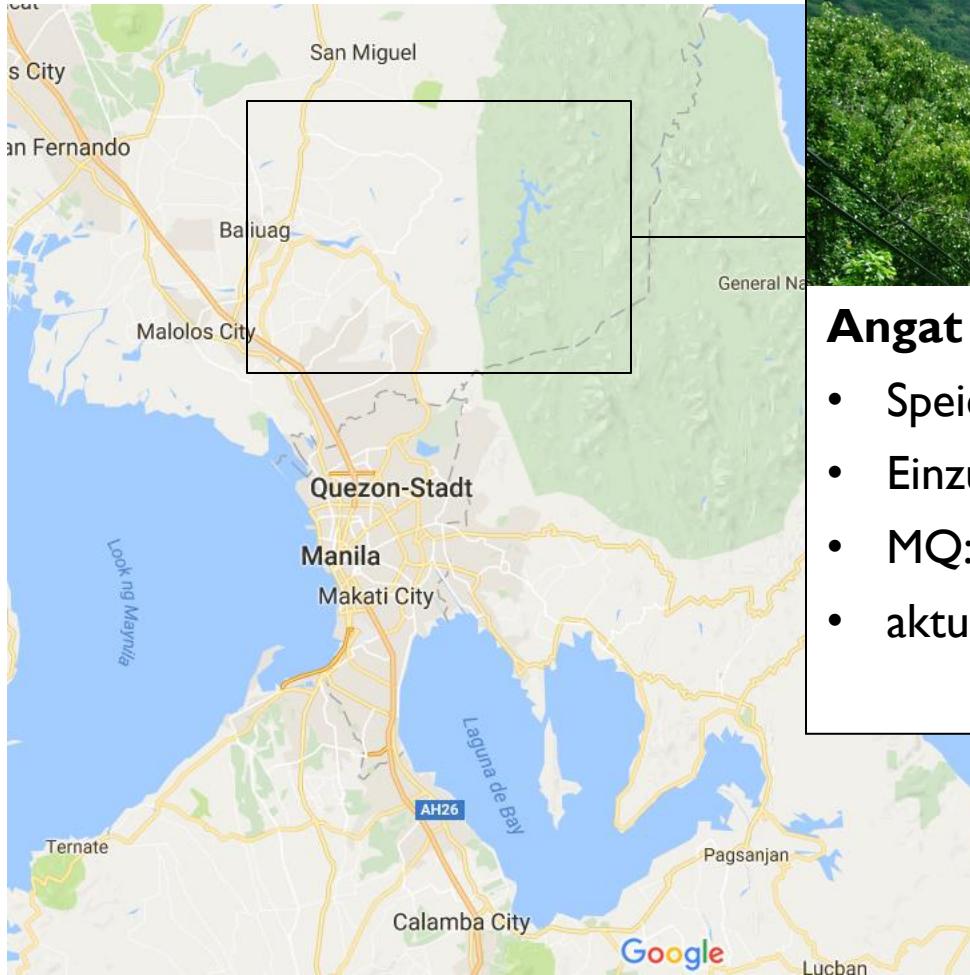
Wasserwirtschaftliches System:

- 3 Anlagen
- Mehr-Ziel-Planung:
 - Trink-/Brauchwasserversorgung
 - Bewässerung
 - Hochwasserschutz
 - (Wasserkrafterzeugung)

Metro Manila: 13 Millionen Einwohner

Angat Reservoir: stellt 98 % des Wasserbedarfs zur Verfügung

Fallstudie – Metro Manila



Angat Reservoir:

- Speichergröße: 743 hm^3
- Einzugsgebietsgröße: 545 km^2
- MQ: $71 \text{ m}^3/\text{s}$
- aktuelle Betriebsregel: $u_t = f(S_t)$

Warum diese Fallstudie?

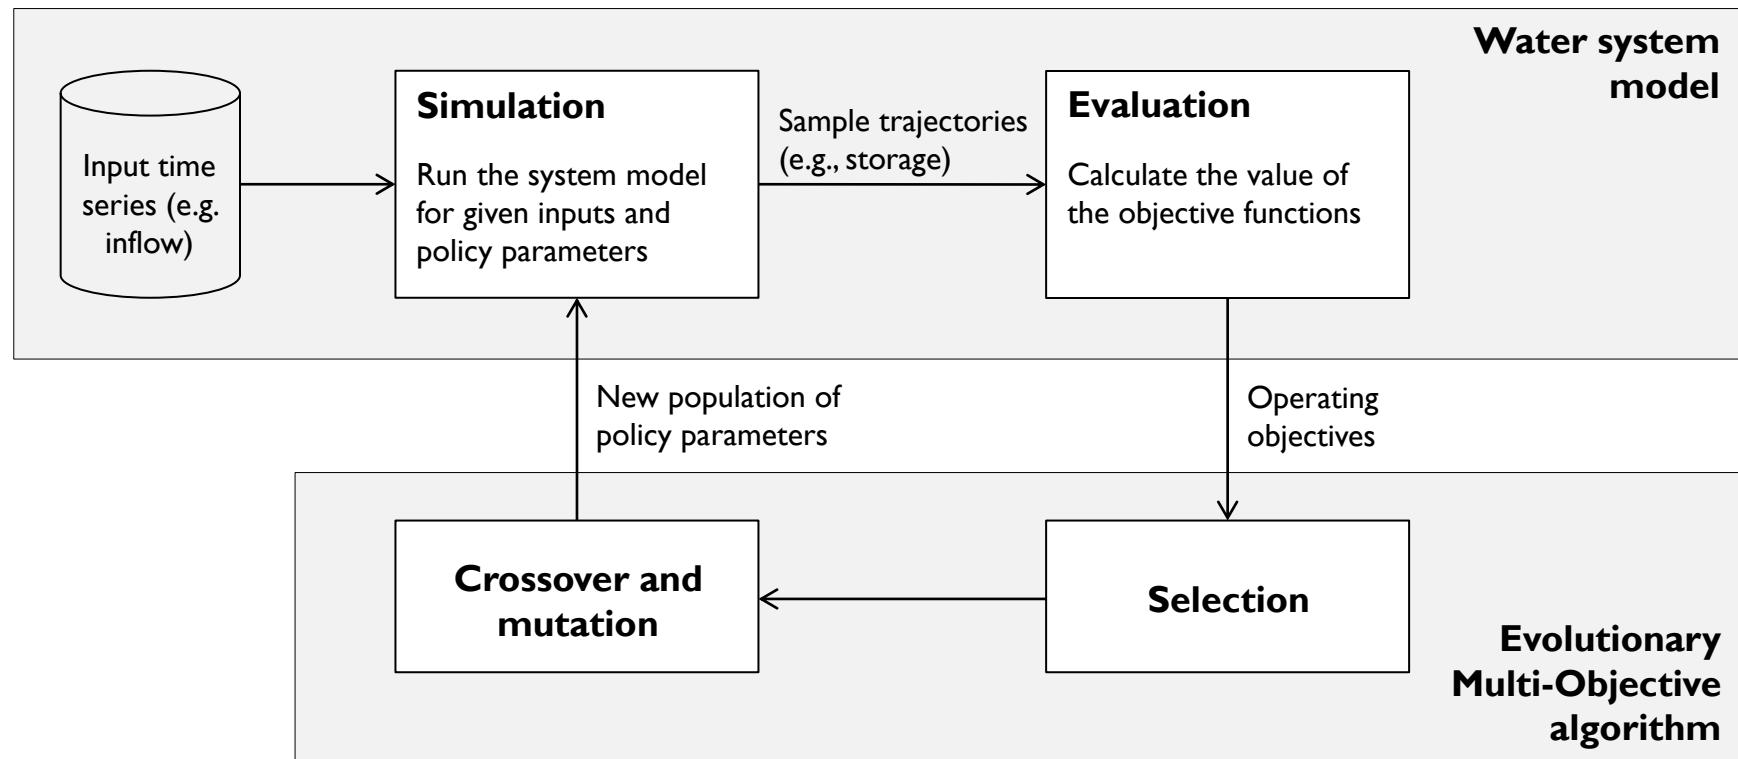
- Konkurrierende Nutzer
- Vulnerabel während El Niño Phasen: 1997/1998 keine Bewässerung und nur 70% der Trinkwasserversorgung gedeckt

Metro Manila: 13 Millionen Einwohner

Angat Reservoir: stellt 98 % des Wasserbedarfs zur Verfügung

Computational framework

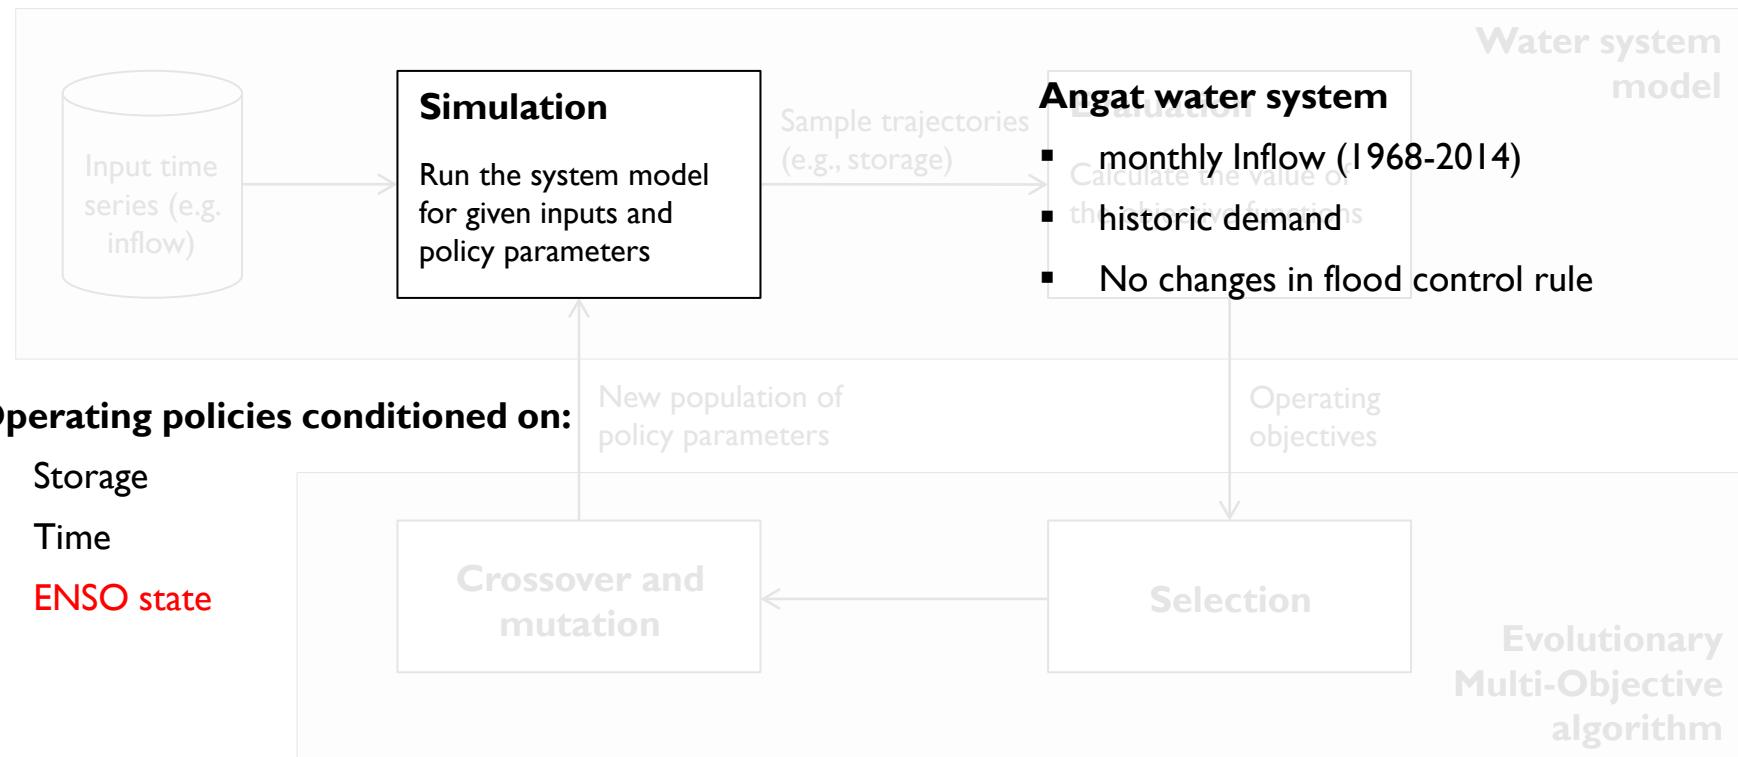
Evolutionary Multi-Objective Direct Policy Search (EMODPS)



Giuliani, M., Castelletti, A., Pianosi, F., Mason, E., & Reed, P. M. (2015). Curses, tradeoffs, and scalable management: Advancing evolutionary multiobjective direct policy search to improve water reservoir operations. *Journal of Water Resources Planning and Management*, 142(2), 04015050.

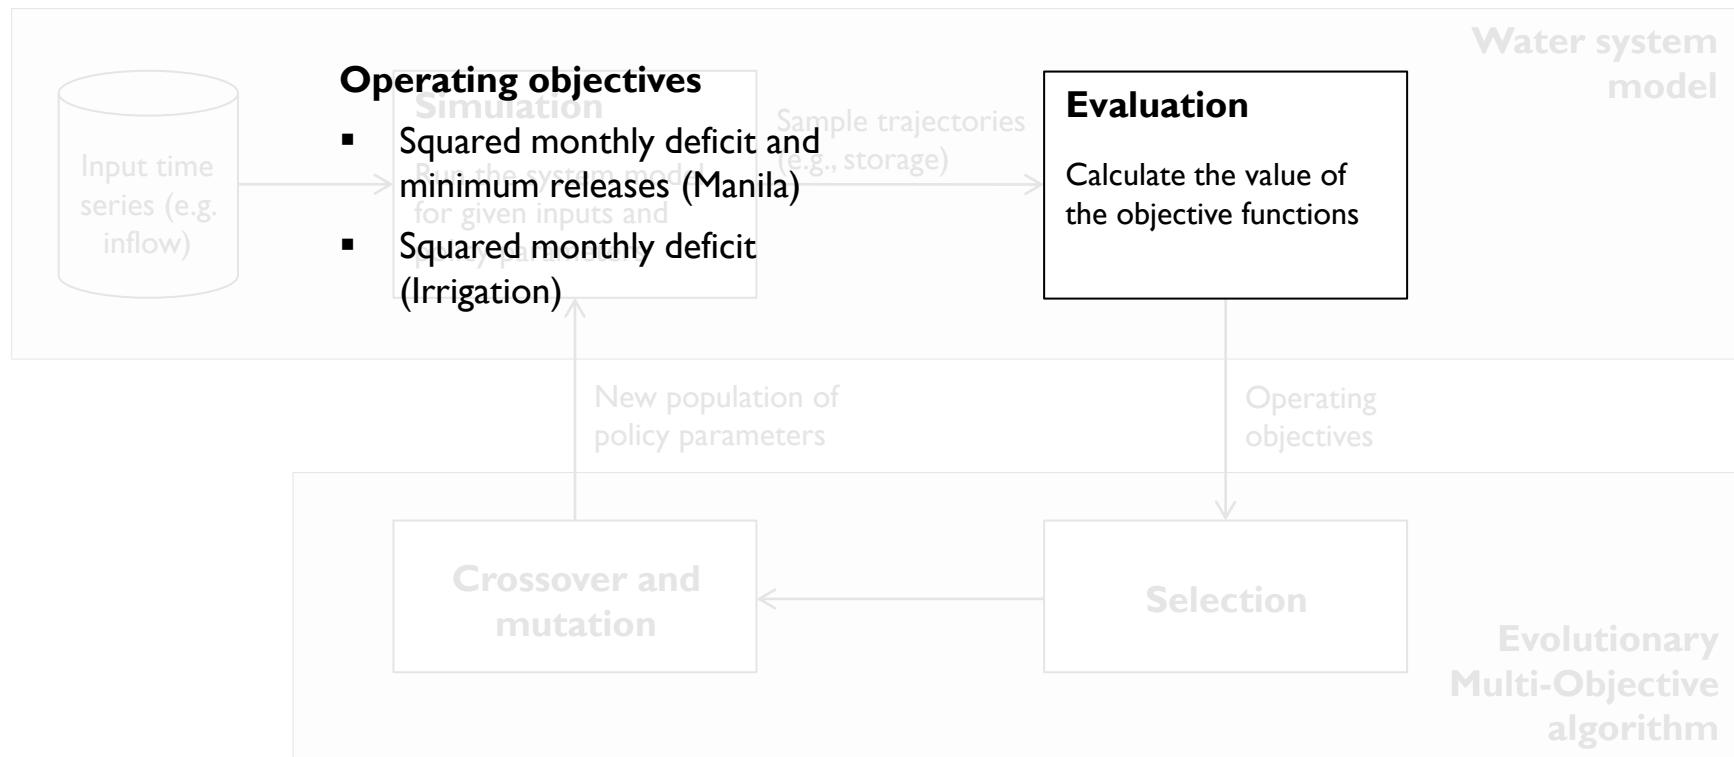
Computational framework

Evolutionary Multi-Objective Direct Policy Search (EMODPS)



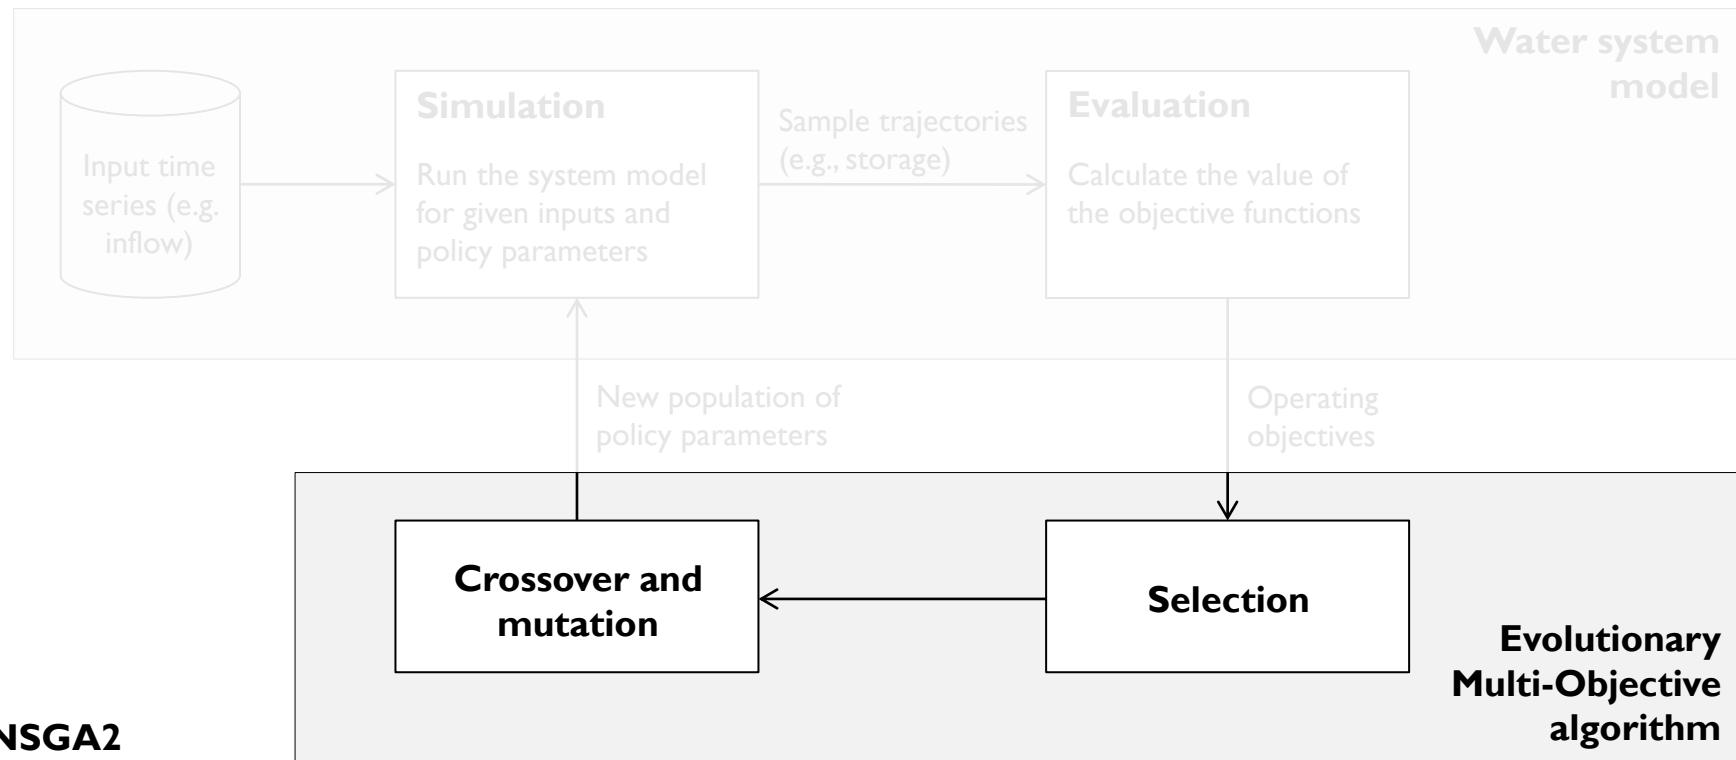
Computational framework

Evolutionary Multi-Objective Direct Policy Search (EMODPS)



Computational framework

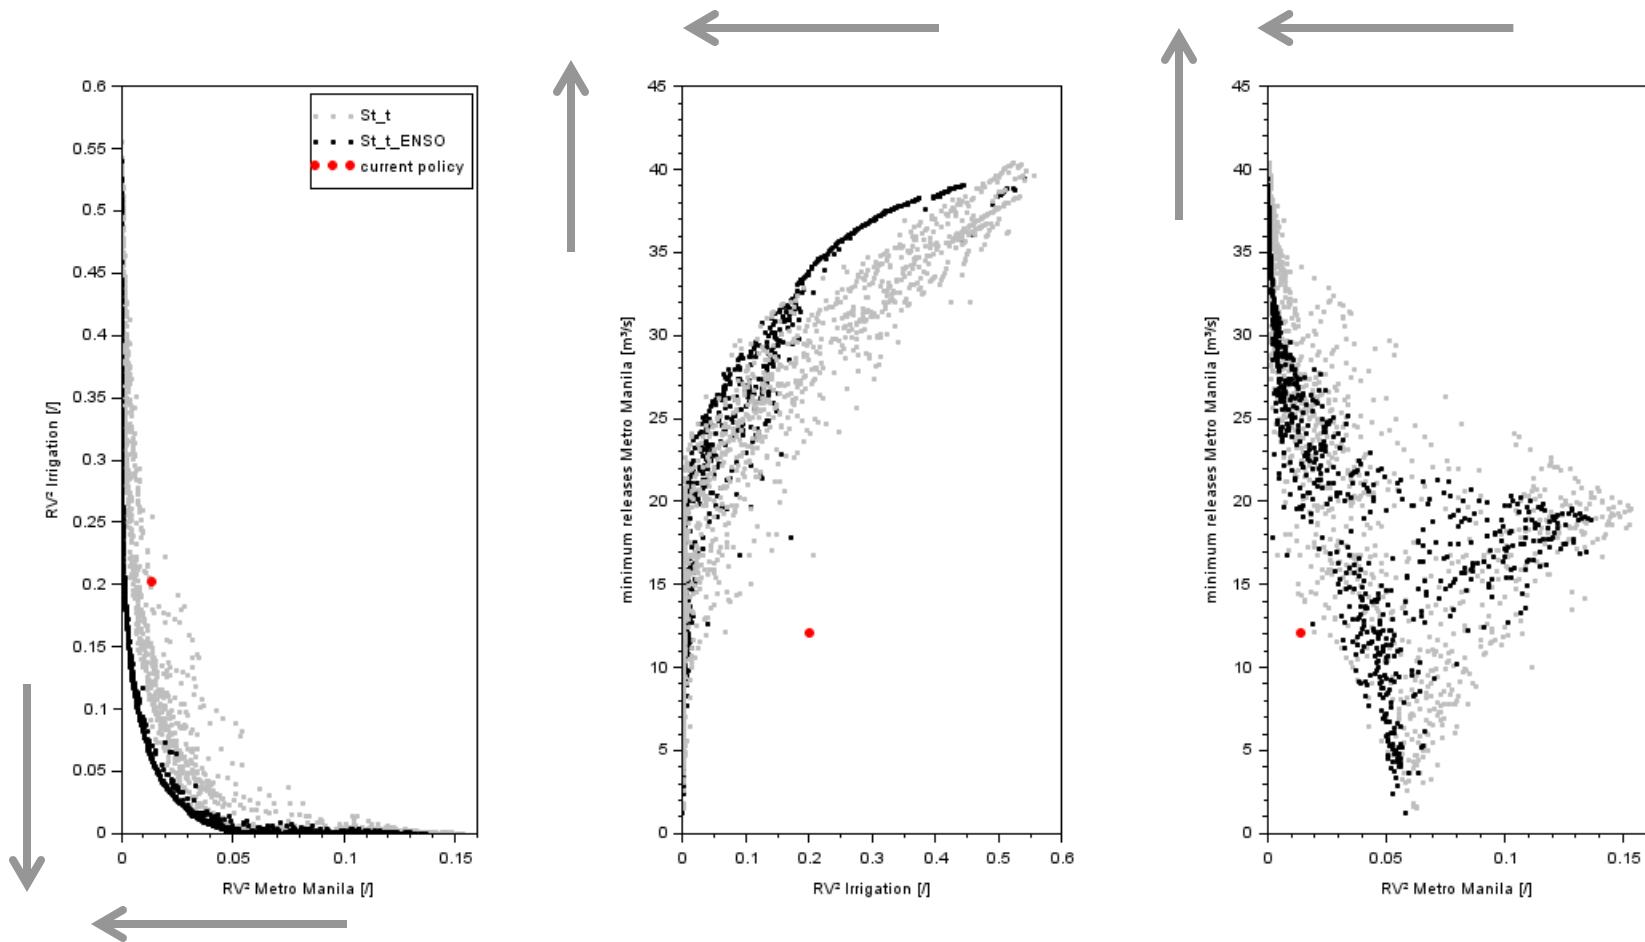
Evolutionary Multi-Objective Direct Policy Search (EMODPS)



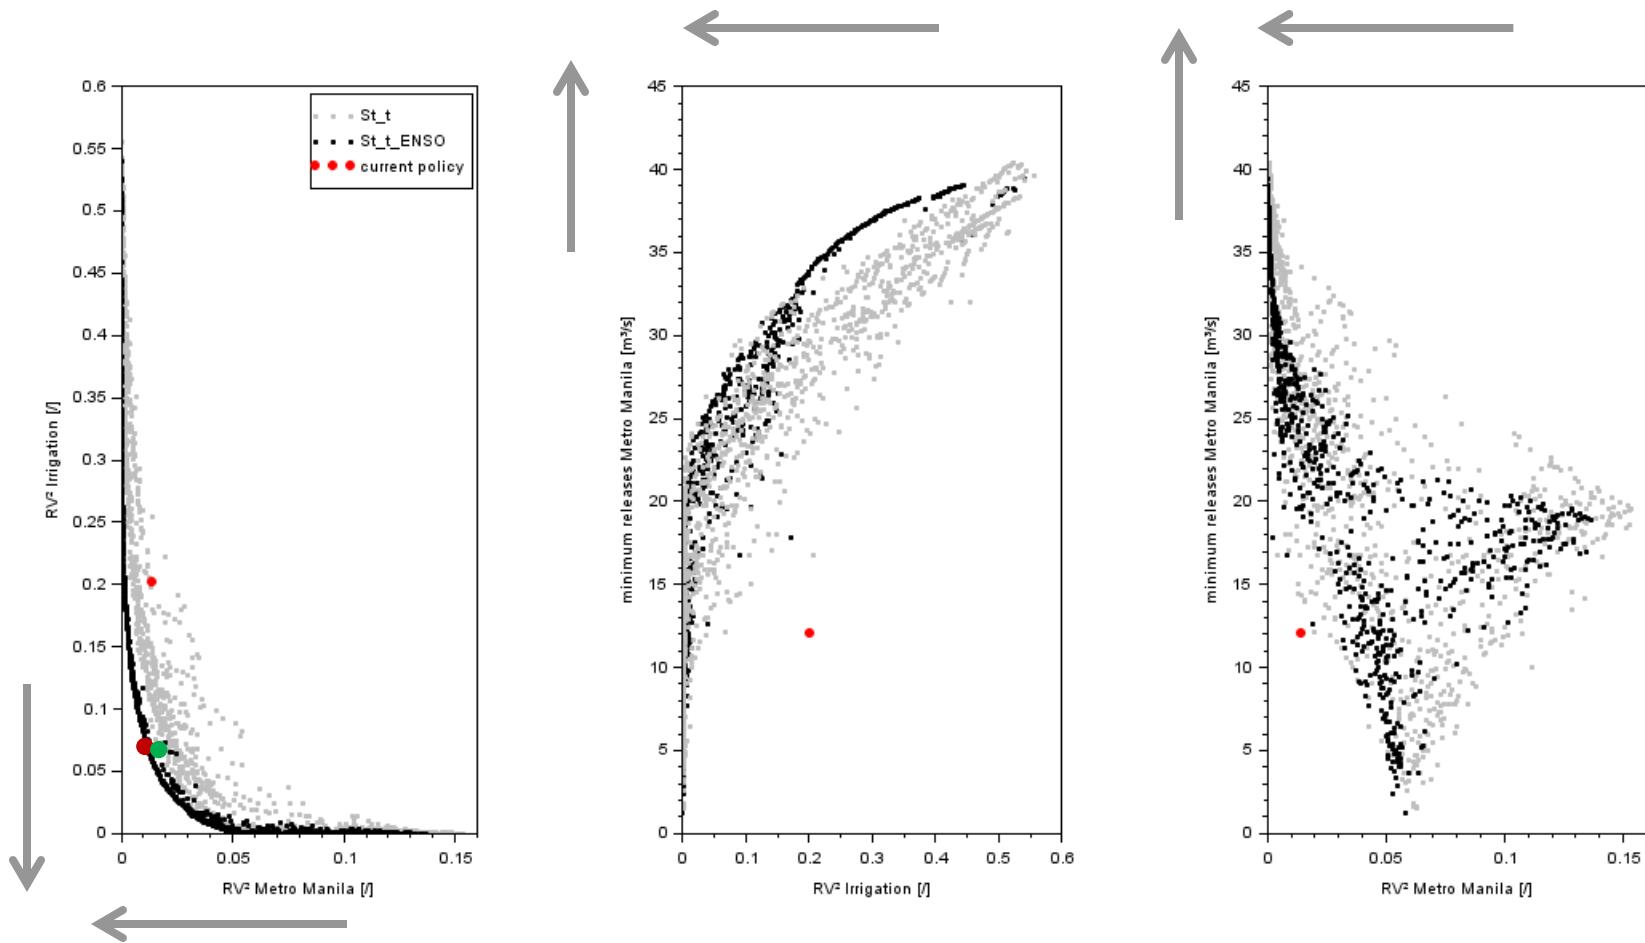
NSGA2

- 4,000,000 NFE
- 6 restarts

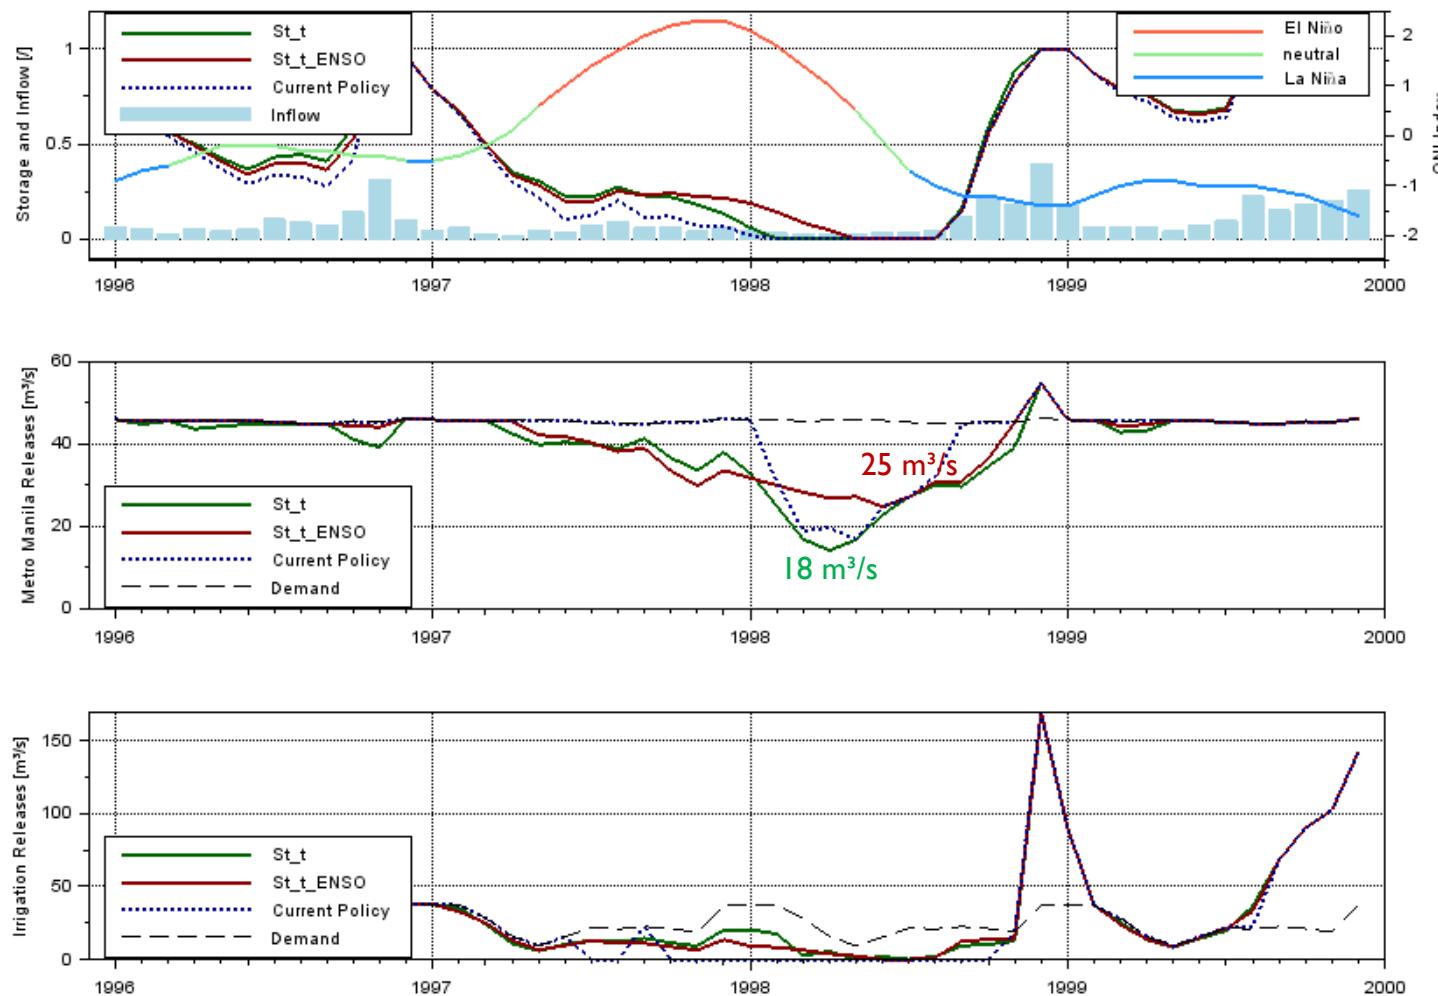
ERGEBNISSE



ERGEBNISSE



ERGEBNISSE



SCHLUSSFOLGERUNGEN

• Vorteile:

- Erhalt der Systemkomplexität (kein “Fluch der Dimensionalität”)
- Keine Diskretisierung nötig (kein “Fluch der Dimensionalität”)
- Einfache Implementierung exogener Informationen (kein “Fluch der Modellierung”)
- Mehrzieloptimierung durch Kombination mit MOEA (kein “Fluch der Mehrzielplanung”)
- Rechenzeit wächst linear mit dem Simulationshorizont und Anzahl von Reservoirs

• Herausforderungen:

- Keine Garantie für optimale Lösung
- Sorgfältige Wahl der Input-Daten (vermeiden von Redundanz)
- Wie reagiert die optimierte Strategie auf unbekannte Zustände?
- Equifinality
- Definition des Zielfunktionsvektors



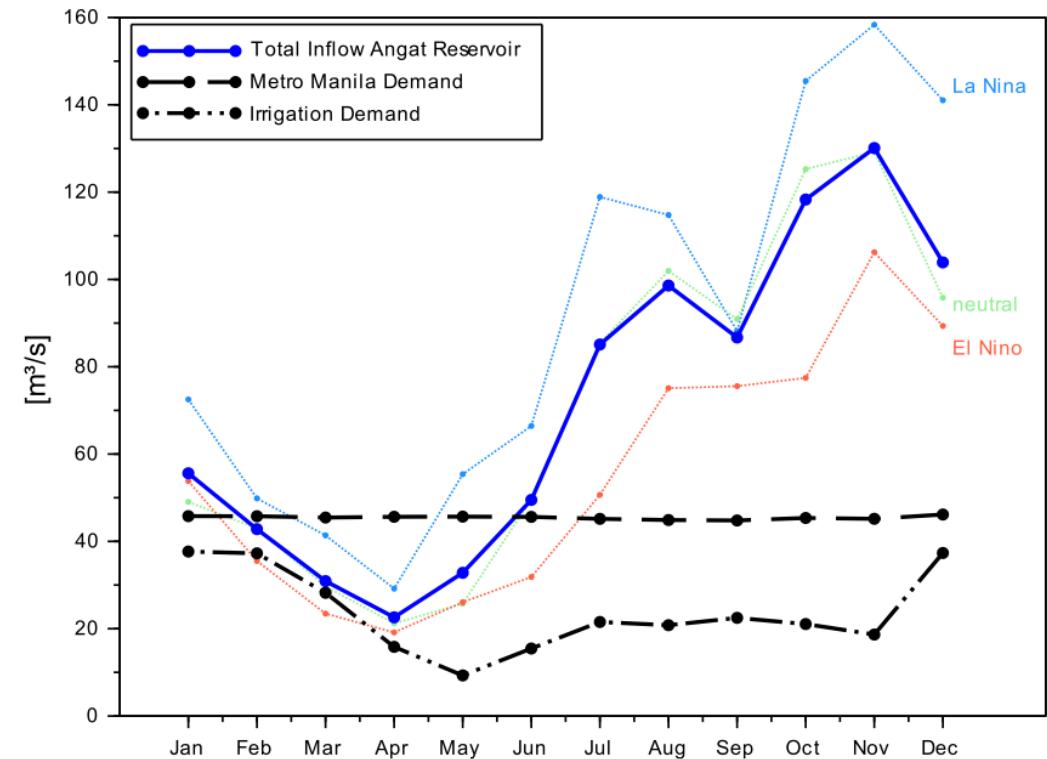
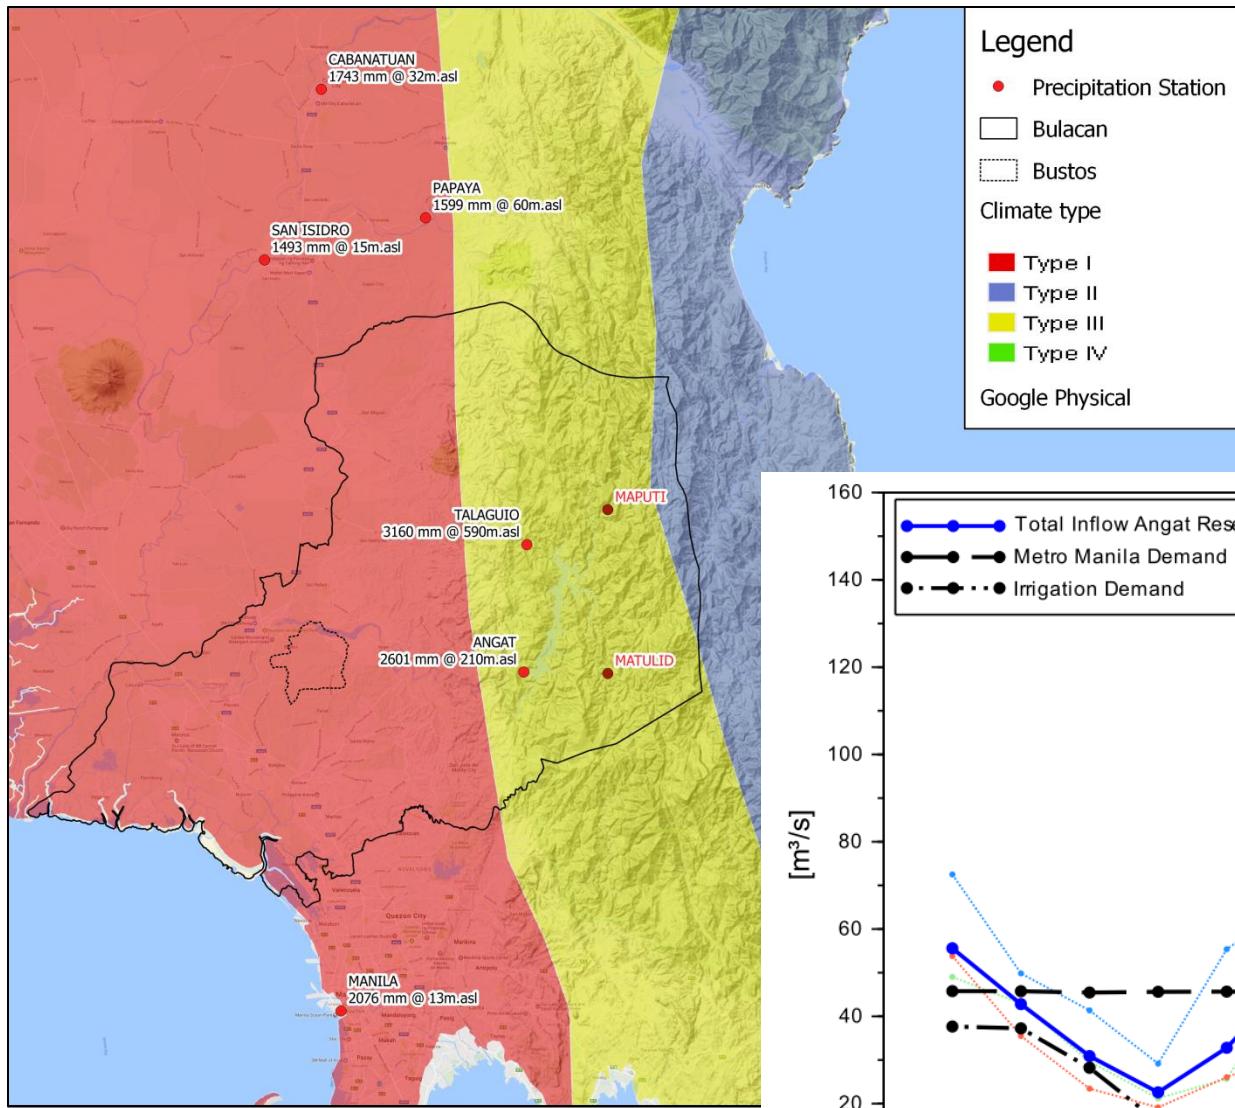
The connected company

Consulting. Engineering. Projects. Operations.

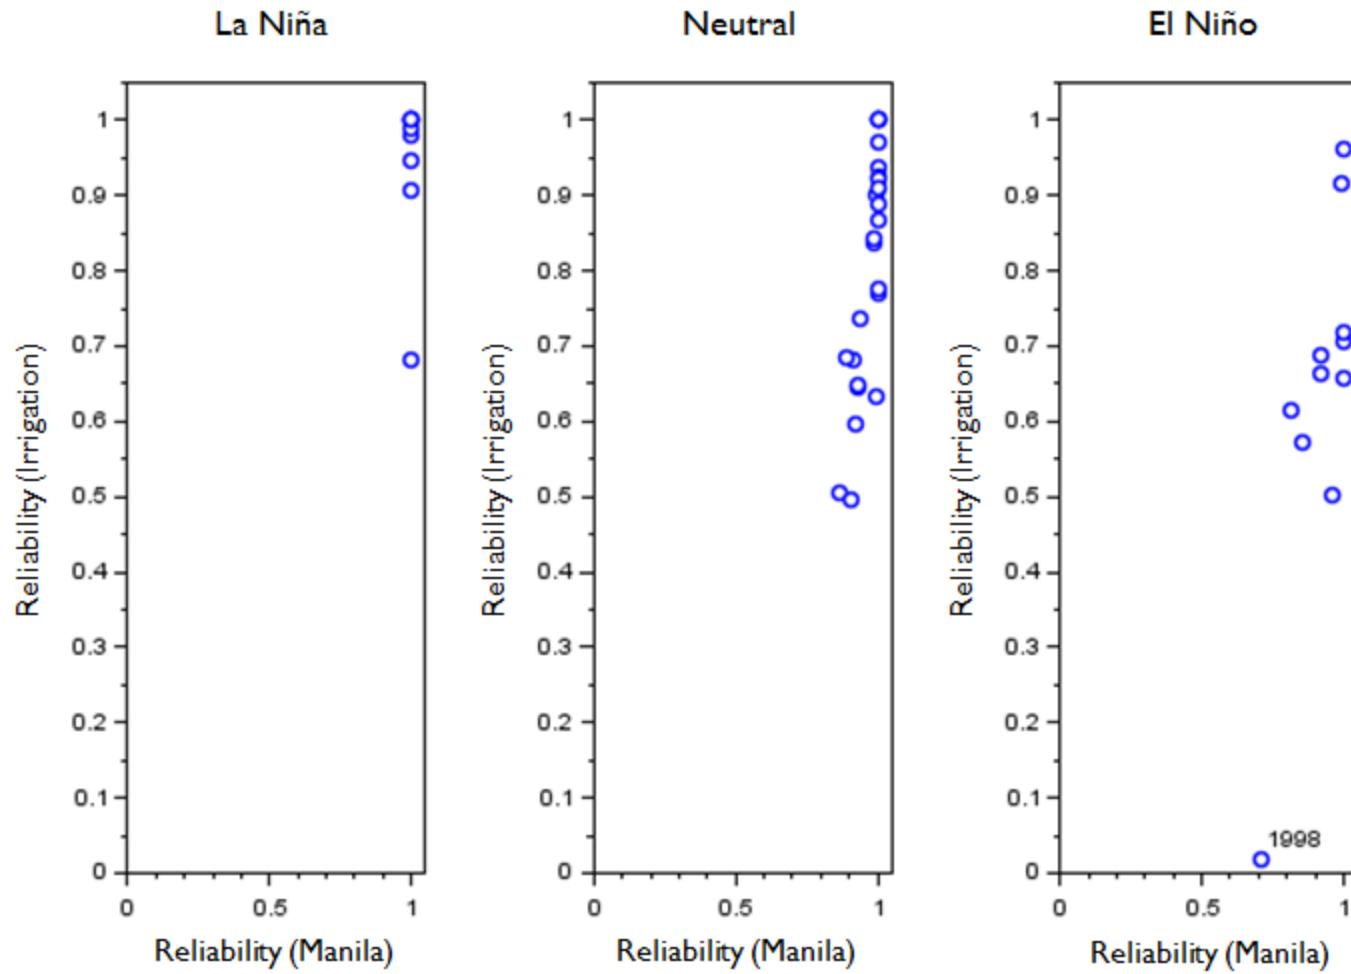
www.poyry.com



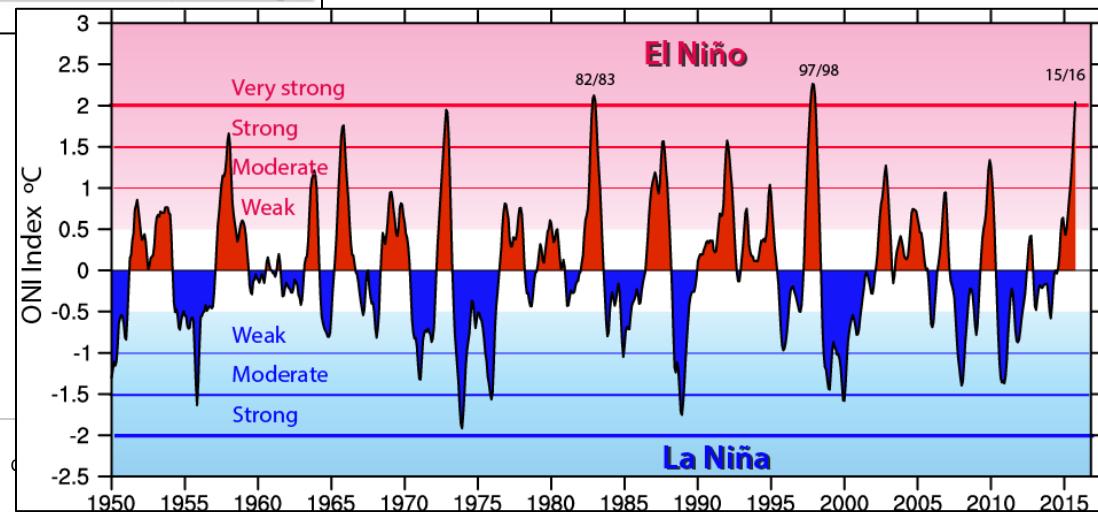
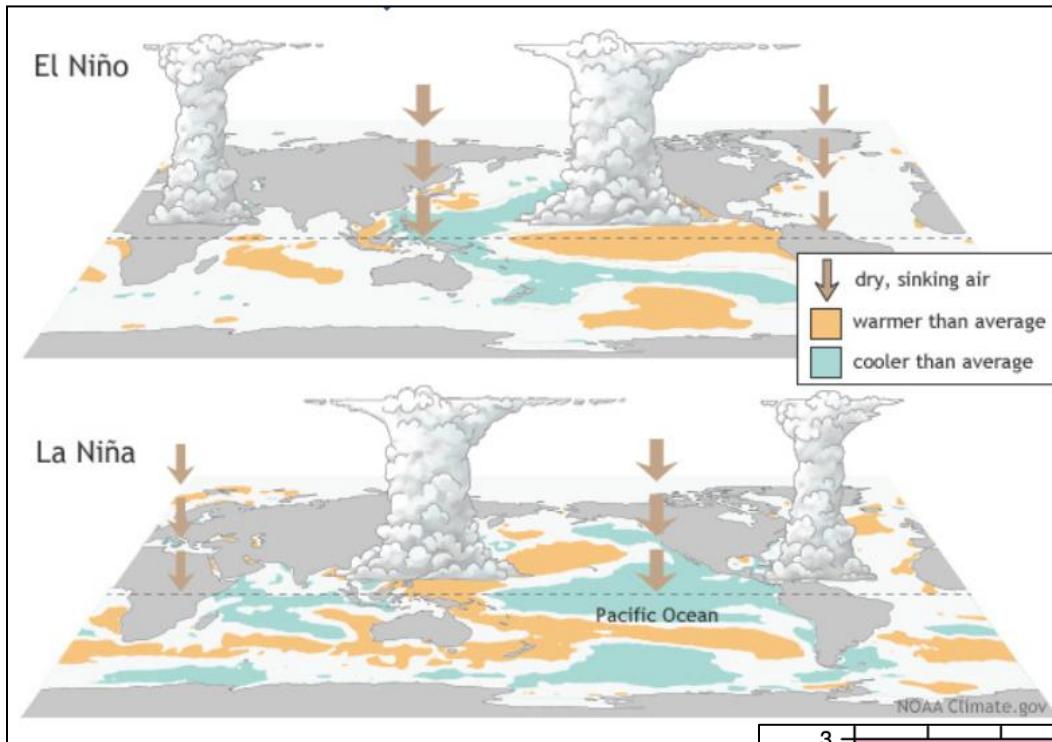
Hydrologie



Einfluss von ENSO auf bestehenden Betrieb

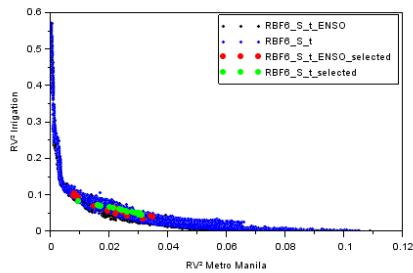


El Niño Southern Oscillation - ENSO

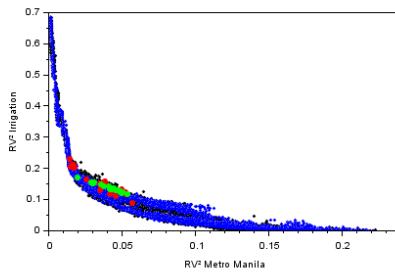


6-D Optimierungsproblem

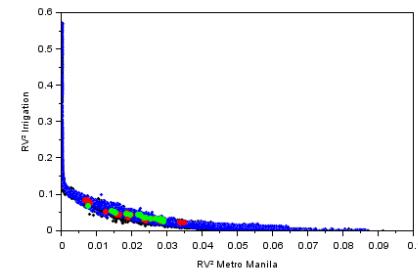
Total



El Nino



neutral



La Nina

