



Messfehler oder Prozessanomalie?

Datenvalidierung für eine zuverlässige Prozessüberwachung in Kanalnetzen



Andy Disch
Frank Blumensaat

Wir messen...

Fließgeschwindigkeit (Hoch_Flo-Dar)

Fließgeschwindigkeit [m/s]

04 Sep 00:00 00:30 01:00 01:30 02:00 02:30 03:00 03:30 04:00 04:30 05:00 05:30 06:00 06:30 07:00 07:30 08:00 08:30 09:00 09:30 10:00 10:30 11:00 11:30 12:00 12:30 13:00 13:30 14:00 14:30 15:00 15:30 16:00 16:30 17:00 17:30 18:00 18:30 19:00 19:30 20:00 20:30 21:00 21:30 22:00 22:30 23:00 23:30

Abfluss (Hoch_Flo-Dar)

Abfluss [l/s]

04 Sep 00:00 00:30 01:00 01:30 02:00 02:30 03:00 03:30 04:00 04:30 05:00 05:30 06:00 06:30 07:00 07:30 08:00 08:30 09:00 09:30 10:00 10:30 11:00 11:30 12:00 12:30 13:00 13:30 14:00 14:30 15:00 15:30 16:00 16:30 17:00 17:30 18:00 18:30 19:00 19:30 20:00 20:30 21:00 21:30 22:00 22:30 23:00 23:30

Messungen in Ordnung?

Füllstand [mm]


04 Sep 00:00 00:30 01:00 01:30 02:00 02:30 03:00 03:30 04:00 04:30 05:00 05:30 06:00 06:30 07:00 07:30 08:00 08:30 09:00 09:30 10:00 10:30 11:00 11:30 12:00 12:30 13:00 13:30 14:00 14:30 15:00 15:30 16:00 16:30 17:00 17:30 18:00 18:30 19:00 19:30 20:00 20:30 21:00 21:30 22:00 22:30 23:00 23:30

Wassertemperatur (DS18B20)

Wassertemperatur [°C]

04 Sep 00:00 00:30 01:00 01:30 02:00 02:30 03:00 03:30 04:00 04:30 05:00 05:30 06:00 06:30 07:00 07:30 08:00 08:30 09:00 09:30 10:00 10:30 11:00 11:30 12:00 12:30 13:00 13:30 14:00 14:30 15:00 15:30 16:00 16:30 17:00 17:30 18:00 18:30 19:00 19:30 20:00 20:30 21:00 21:30 22:00 22:30 23:00 23:30

Messfehler oder Prozessanomalie?




Wir messen vieles...

Urban Water Observatory (<https://www.uwo-opendata.eawag.ch/>)



Sind Messwerte plausibel?
...muss Simon ins Feld oder nicht?



Limitationen von urbanhydrologischen Signalen

- Systembestimmende Regenereignisse → **zufällig, extrem**
- **Belastungswechsel** Regen- und Trockenwetter  
- «Zensierte» Signale → **einseitige Beschränkungen**, z.B. Drosselabfluss
- **Nicht-lineare** Prozesse → Randbedingungen schwer definierbar


Methoden im Test: warum diese Methoden?

- ARIMA
 - Transparent, skalierbar
 - Erklärbar


Methoden des maschinellen Lernens

- One-Class Supportvektor Maschine
 - Klassischerweise eingesetzt
 - «unsupervised»
- Autoencoder²
 - Flexibel, ausbaufähig
 - «supervised» → **Labeling**

Forecasts from ARIMA(1,0,7) with non-zero mean



Forecasts from ARIMA(0,0,6) with non-zero mean




Bildquelle: <https://www.analyticsindiamag.com/keep-photos-watermark-safe-google-claims-computers-can-easily-remove/>

1 J. Ma, S. Perkins, "Time-series novelty detection using one-class support vector machines", *Proc. Int. Jt. Conf. Neural Networks*, vol. 3, 2003.


2 S. Russo, et al. "Anomaly Detection using Deep Autoencoders for in-situ Wastewater Systems Monitoring Data", *Watermatex*, 2019.

Illustration der Validierungsmethoden


Rohdaten




ARIMA



OCSVM




Autoencoder



Herangehensweise

Synthetische Daten




Gemessene Daten

Datenvorverarbeitung beeinflusst
Genauigkeit der Gütebestimmung


Metrik

-  Normaler Messpunkt
-  Anomalie
-  Identifiziert als Anomalie

Genauigkeit $\approx$ «Wieviele der Messungen sind Anomalien?»





Trefferquote $\approx$ «Wieviele der Anomalien sind selektiert?»



$$F_1 = 2 * \frac{\text{Genauigkeit} * \text{Trefferquote}}{\text{Genauigkeit} + \text{Trefferquote}}$$

Resultate



Resultate

- **Grad der Datenaufbereitung** relevant
- Unterscheidung zwischen **Trocken- und Regenwetter** sinnvoll
 - sinnvoll bei Verfeinerung der Algorithmen Architektur
- **Keine eierlegende Wollmilchsau**
 - Aufgabe der Erklärbarkeit für eine genauere Vorhersagbarkeit

Ausblick

- **Weitere Methoden** testen
 - GSOM¹, Kopplung physikalisch-basiertes Modell mit CNN²-Fehlermodell, strukturelle RNN³s

¹ growing self-organizing map

² convolutional neural network

³ recurrent neural network


Ausblick

- Weitere Methoden testen
- **Erweitertes Bewertungskriterium**
 1. «Labeling» Aufwand
 2. keine falsch positiven Ergebnisse
 3. viele echt positive Ergebnisse
 4. vollautomatisch
 5. minimale Parametrisierung
 6. Berechnungsaufwand
 7. keine vorausschauende Komponente

Ausblick

- Weitere Methoden testen
- Erweitertes Bewertungskriterium
- **Subjektivität des «Labeling»-Prozesses** überprüfen
- **Klassifizierung der Signale** nach ihrer Charakteristik für Wahl der geeigneten Methode

Fazit und Zusammenfassung



- Automatische Validierung der UWO-Signale
- Datenvalidierung beginnt im Feld
- Datenvorverarbeitung **insbesondere** für Methoden des maschinellen Lernens relevant

Danksagung




GEMEINDE FEHRALTORF



decentlab

Herzlichen Dank für die Aufmerksamkeit!

Messfehler oder Prozessanomalie?



ENGINEERING TIP:
WHEN YOU DO A TASK BY HAND,
YOU CAN TECHNICALLY SAY YOU
TRAINED A NEURAL NET TO DO IT.