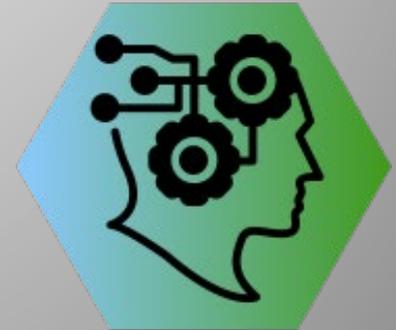


Selbstopimierende Anlage mit KI – wie weit sind wir gekommen?

Sebastian Engell

TU Dortmund, Process Dynamics and Operations Group



KE-3N

Supported by:



Federal Ministry
for Economic Affairs
and Climate Action

on the basis of a decision
by the German Bundestag



Überblick über die Session

Kognitive Sensoren als Voraussetzung für KI-Algorithmen

C. Schlander (Merck) , L. Neuendorf (TU Dortmund), V. Khaydarov (TU Dresden),
T. Kock (TU Dresden), J. Fischer (Merck), N. Kockmann (TU Dortmund)

Recipe optimization of batch distillation trajectories based on a data-driven model

Gerardo Brand Rihm, Erik Esche, Jens-Uwe Repke (TU Berlin) & Merlin Schüler, Corina Nentwich, Michael Kawohl (Evonik)

PID bis KI: optimale Kolonnenregelung in KEEN - was lernen wir daraus?

Stefan Krämer, Yak Ortmanns, Jörn Felix Hecht, Volker Roßmann (Bayer) &
Mohamed Elsheikh, Sebastian Engell (TU Dortmund)

Development and utilization of a dynamic gray-box model for a fermentation process of a sporulating bacterium

Joschka Winz, Sebastian Engell (TU Dortmund) & Supasuda Assawajaruwan, Uwe Piechottka (Evonik)

Wo ist die selbstoptimierende Anlage geblieben?

Per aspera ad astra (Über raue Pfade gelangt man zu den Sternen)!

Auf dem Weg zur selbstoptimierenden Anlage

- Mit einem perfekten Modell und verllässlicher Information über alle externen Einflüsse ist die selbst-optimierende Anlage kein Problem.
- Aber die Modellierung ist der Engpass.
 - Eine Doktorarbeit pro Prozessschritt ist keine realistische Option.
 - Modelle müssen auch gewartet, übergeben, verstanden werden.
- Wenn man kein gutes Modell hat, muss man wenigstens gut messen!
- So ist es logisch, dass alle Vorträge in dieser Session entweder Sensoren (hier Bildverarbeitung) oder Modellierungstechniken behandeln.
- ML Modelle als die magische Lösung des Modellierungsproblems?
- Die Frage ist nicht neu!

Model Predictive Control Using Neural Networks

Andreas Draeger, Sebastian Engell, and Horst Ranke

IEEE Control Systems Magazine 15 (1995), 61-66
>160 citations in Scopus, reprinted 2020

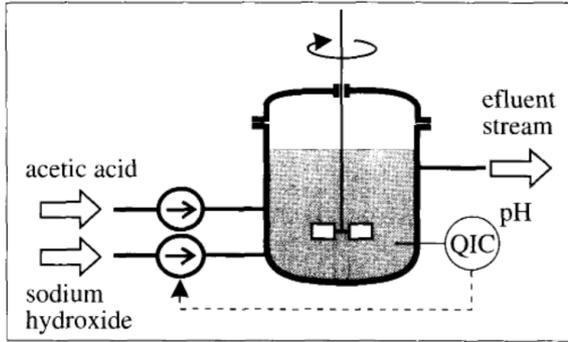


Fig. 1. Neutralization plant.

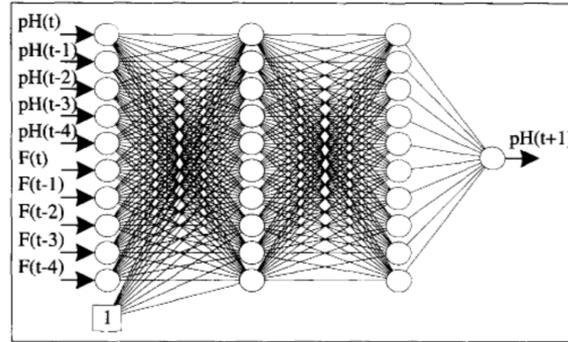
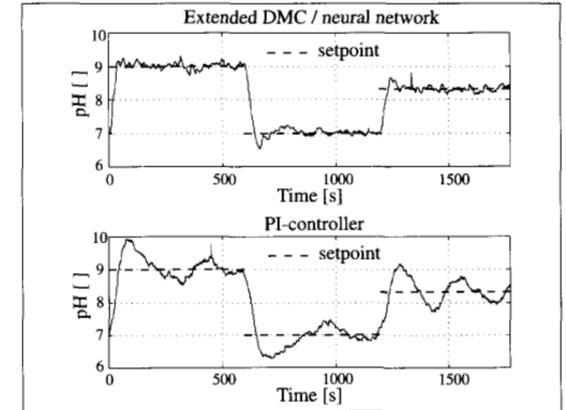


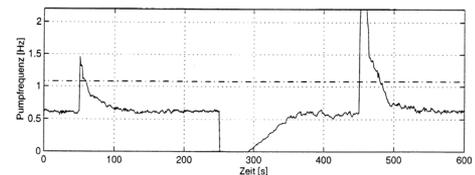
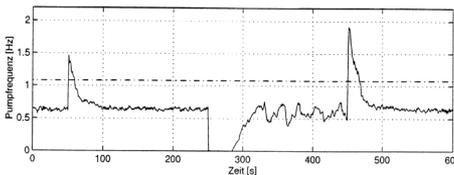
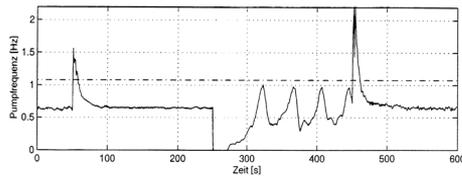
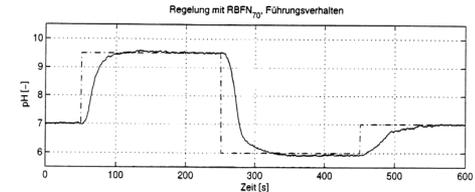
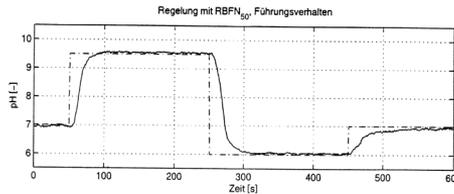
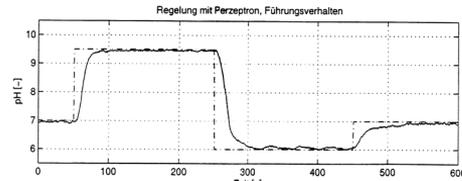
Fig. 3. Topology of the neural network.



Damals viele ähnliche Arbeiten weltweit.

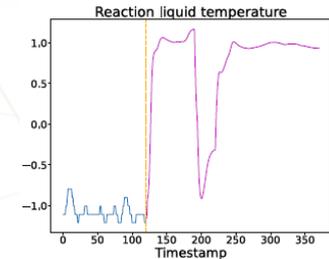
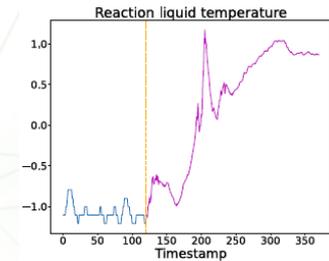
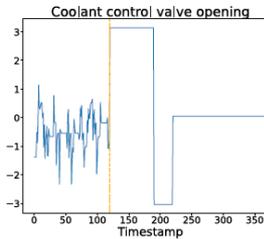
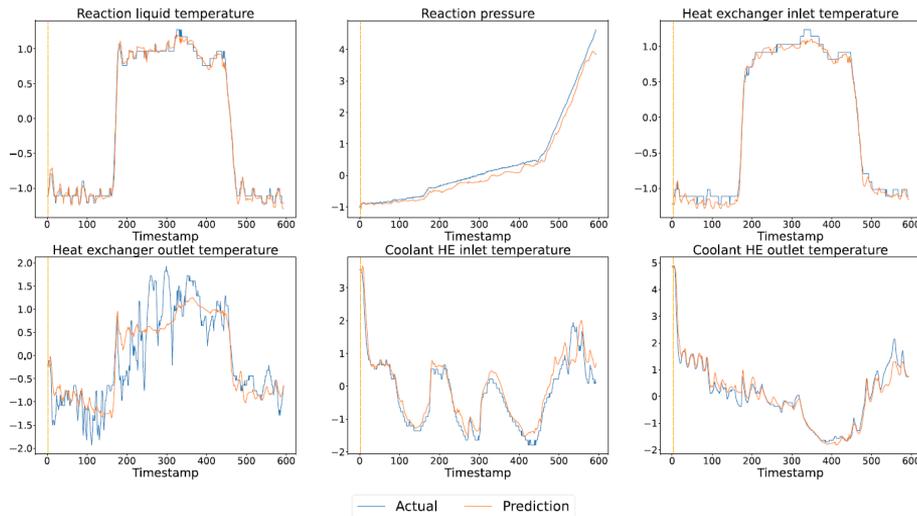
Regelgüte mit verschiedenen NARX-Modellen (NN, RBF)

NARX Models	Data set	RMSE 1 step ahead	RMSE 5 steps ahead
MLP 2 hidden layers, 8 neurons each	Training	1.9 e-03	8.4 e-03
	Test	2.2 e-03	1.2 e-02
RBN 50 centers	Training	2.7 e-03	1.6 e-02
	Test	2.8 e-03	2.0 e-02
RBN 70 centers	Training	2.2 e-03	1.1 e-02
	Test	2.3 e-03	1.4 e-02



Für mich ein Highlight in KEEN: Masterarbeit von Maria Paola Galvis bei **MERCK** unter Betreuung von Balazs Bordas

- Modellierung eines Semi-Batch Reaktors
- 460 Batches, 600 Werte alle Variablen per Batch
- Sorgfältige Wahl der Hyperparameter
- Aber das Modell ist qualitativ falsch, es lernte Korrelationen, keine kausalen Zusammenhänge.
- Die Modellunsicherheit wurde nicht vorhergesagt.



Welche Konsequenzen wurden daraus gezogen?

- **Training von ML Modellen erfolgte vielfach anhand von Simulationen**
 - Dadurch Beschaffung “reicher” Daten wesentlich einfacher
 - Aber man braucht ein Modell
- **Überwachung ob das ML-Modell in einem Bereich verwendet wird, in dem genug Daten vorhanden waren**
 - Kann zu pessimistisch sein
 - Modelladaption im Betrieb
- **“Nachtraining” mit Anlagendaten**
 - Kombination umfangreicher Simulationsdaten mit eher spärlichen Anlagendaten

- **Gray-box Modelle**

- Sicherstellung der Verlässlichkeit der ML-Modellanteile einfacher
- Rigorose Anteile bewirken global verlässliches Verhalten
- ??

Mein Fazit:

- Die Verlässlichkeit von Modellen ist zentral
- Eine Quantifizierung der Unsicherheit wäre sehr nützlich, aber geeignete Methoden sind (mir) nicht bekannt.
- Adaption war mal ein großes Thema ...