

Maschinelle Lernverfahren zur Diagnose nicht-nominaler Betriebszustände in Biomassekesseln

Kerstin Wurdinger, DBFZ



29. Fachgespräch „Arbeitskreis Holzfeuerung“, Straubing (TFZ), 10. Juni 2026

Zur Motivation



DeDiaPro –

Demonstration von Methoden zur Diagnose, Prognose
und Behebung von nicht-nominalen Betriebszuständen in
biomassebasierten Versorgungssystemen

Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

FKZ-Nr.: 03EI5471




European Institute
for Energy Research
by EDF and KIT



Laufzeit:
01.02.2024 – 31.07.2026

Maschinelles Lernen (ML) - Einordnung



Maschinelles Lernen verarbeitet Massendaten zu Black-Box-Modellen

**Eingangsgrößen,
messbar/beobachtbar**

Temperatur Vorlauf



Brennstoffzufuhr



Brennstoff-
zusammensetzung




Leistung Gebläse



USW...



Black Box



Wärmeerzeugung in
Biomassekessel

**Ausgangsgrößen,
messbar/beobachtbar**

Temperaturen Rücklauf,
Rauchgas



O₂-Gehalt Abgas



CO₂-Gehalt Abgas




Aschegehalt/
-zusammensetzung



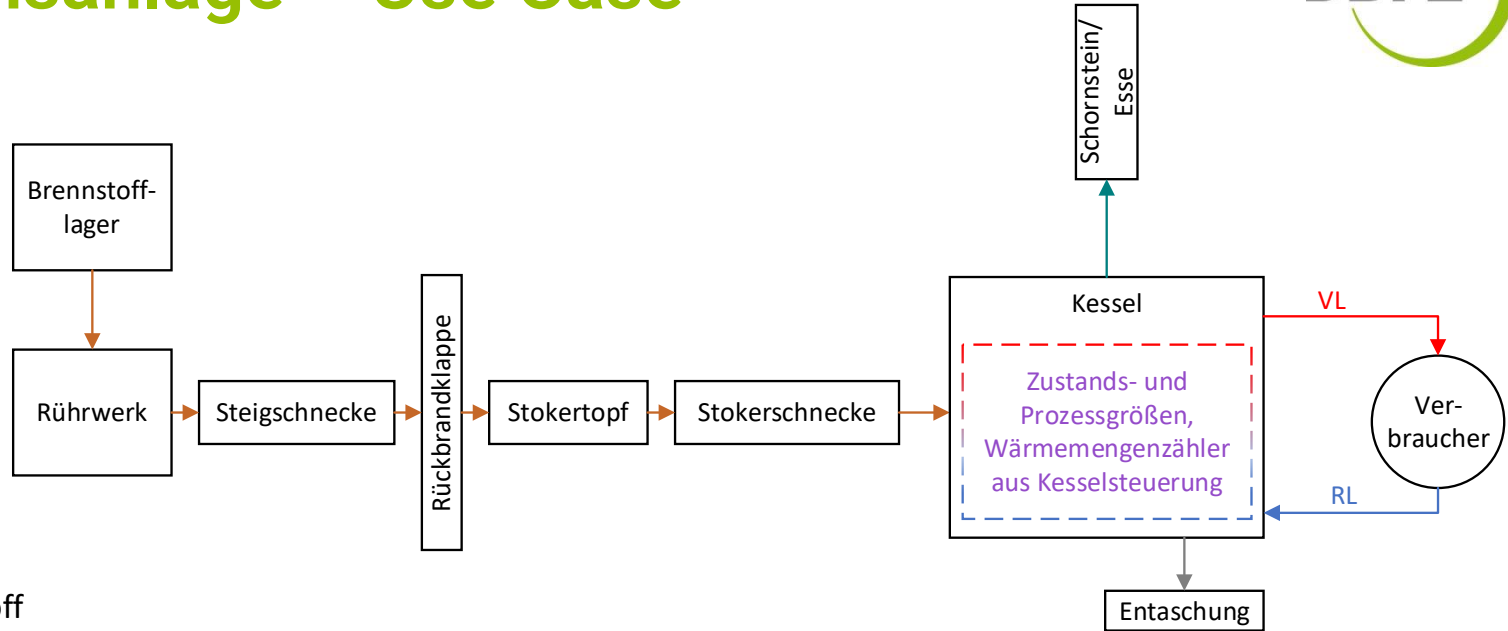
USW....



Maschinelles Lernen verarbeitet Massendaten zu Black-Box-Modellen



Versuchsanlage – Use Case



Legende Medien:


- > Brennstoff
- > Verbrennungs-, Abgase
- > Asche
- > Heizungswasser, Vorlauf
- > Heizungswasser, Rücklauf

Legende Messungen:

- - -> Siemens-SPS: Messung, Aufzeichnung


Steuerungsdaten aus Feldanlage (Auszug)

Kessel allgemein



Musteränderungen in den Daten im Verlauf von Verbrennungszyklen

- Analyse experimenteller Zeitreihendaten einer Feldanlage
- Identifizierung von Intervallen kompletter Verbrennungszyklen, die von einem Referenzzyklus abweichen → Musteränderungen der Istwerte bzw. Stellgrößen
- Betrachtetes Datenset bestand aus multivariaten Zeitreihen (11 Variablen) mit 29.866 Records (Datensätzen)



F-Measure-Metrik (F-Score)


für verschiedene Klassifikationsalgorithmen

$$\text{FScore} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Mit welchen ML-Modellen erhält man die beste Aussage dazu, ob ein Verbrennungszyklus gut oder schlecht abläuft bzw. abgelaufen ist?

Beste Ergebnisse liefern

- Random-Forest-Klassifikator
- Neuronales Netz
- k-Nearest-Neighbour-Klassifikator



Fazit und Ausblick 1/2

Zur Diagnose von Betriebszuständen eines Biomassekessels außerhalb des Nennbetriebes

- sind ML-Methoden des **überwachten Lernens geeignet**
- benötigen zufriedenstellende Lösungen aus dem Bereich des unüberwachten bzw. verstärkenden Lernens zusätzliches Augenmerk auf Datenqualität und -verfügbarkeit
 - für die jeweilige Fragestellung festgelegte Systemgrenzen
 - saubere Erhebung und Selektion von Referenzdaten als Trainingsdaten
 - gepflegte Betriebs- und Wartungslogbücher zu Anlage und Brennstoff
 - Datenaufzeichnung von Steuerungsdaten (inkl. Parametereinstellungen)

Gibt es (zu) viele Unsicherheiten oder Interpretationsspielräume bei der Anwendung der genutzten Daten?

- Ist Expertenwissen und Aufwand zur Anreicherung vorhandener Daten mit Zusatzinformation notwendig
 - (manuelles) Labeling von Anlagenzuständen
 - Ergänzung reiner, datengetriebener Black-Box-Modelle durch Komponenten aus der theoretischen Modellierung (Fuzzy-Modelle mit Parameterabschätzung) → Dark-Grey-Box-Modelle



Smart Bioenergy – Innovationen für eine nachhaltige Zukunft

Kontakt:

Prof. Dr. mont. Michael Nelles

Dr. Christoph Krukenkamp

Dr. Romy Brödner/Stefan Majer (interim)

Dr. agr. Peter Kornatz

Prof. Dr.-Ing. Volker Lenz

Dr.-Ing. Franziska Müller-Langer

Prof. Dr. rer. nat. Ingo Hartmann

**DBFZ Deutsches
Biomasseforschungszentrum
gemeinnützige GmbH**

Torgauer Straße 116

D-04347 Leipzig

Tel.: +49 (0)341 2434-112

E-Mail: info@dbfz.de

www.dbfz.de