

Auswirkungen von Modell- und Prognoseunsicherheiten auf die Leistung der modellprädiktiven Regelung eines PV-Batterie-Wärmepumpe-Wärmespeichersystems

Ronny Gelleschus, Thilo Bocklisch

Professur für Energiespeichersysteme

6. Herbstworkshop „Energiespeichersysteme“, Dresden/Online, 30.11.2022

Überblick

1. Motivation

2. Modellunsicherheiten


3. Prognoseunsicherheiten

4. Zusammenfassung und Ausblick

1. Motivation

1. Motivation


PV-Batterie-Wärmepumpen-Wärmespeicher-System



Systembestandteil	Parameter
Elektrische Last	4 MWh
PV-Anlage	5.7 kW / 5 MWh
Netzbezug	$0.30 \frac{\text{€}}{\text{kWh}}$
Netzeinspeisung	$0.10 \frac{\text{€}}{\text{kWh}}$ / max. 2.85 kW
Trinkwarmwasserlast (TWW)	43.8 m ³ / 2.24 MWh
Wärmepumpe/Wärmespeicher	850 W elektrische Leistung / 300 l
Lithium-Ionen Batteriesystem	5 kW / 5 kWh

1. Motivation

Multi-Use-Betriebsführung mit modellprädiktiver Regelung




2. Modellunsicherheiten

2. Modellunsicherheiten


Forschungsfragen und Simulationssetup

Modellstruktur



- Beeinflusst die Struktur des Optimierungsmodells die Performance der Betriebsführung?
- Wenn dem so ist, wie sehr und warum?

Modellparameter



- Beeinflussen die Parameter des Optimierungsmodells die Performance der Betriebsführung?
- Wenn dem so ist, wie sehr und warum?

2. Modellunsicherheiten

Ergebnisse: Modellstruktur


Bewertungskriterium	Definition	MILP	MIQCP
Betriebskosten, k_{BK}	$k_{BK} = \int_t c_{N,B} P_{N,B}(t) - c_{N,E} P_{N,E}(t) dt$	475.12 €	472.33 €
Selbstversorgungsgrad, k_{SV}	$k_{SV} = \frac{\int_t P_L(t) + P_{WP}(t) - P_{N,B}(t) dt}{\int_t P_L(t) + P_{WP}(t) dt}$	53.86 %	53.99 %
Eigenverbrauchsgrad, k_{EV}	$k_{EV} = \frac{\int_t P_{PV}(t) - P_{PV,A}(t) - P_{N,E}(t) dt}{\int_t P_{PV}(t) - P_{PV,A}(t) dt}$	61.83 %	61.69 %
PV-Abregelung, $k_{PV,A}$	$k_{PV,A} = \frac{\int_t P_{PV,A}(t) dt}{\int_t P_{PV}(t) - P_{PV,A}(t) dt}$	$1.23 \cdot 10^{-4}$	$1.20 \cdot 10^{-4}$
Anteil des TWW, das bei unter 50 °C gezapft wurde, k_{TWW}	$k_{TWW} = \frac{\int_t \dot{Q}_{TWW}(t) _{T_{TWW}(t) < 50 \text{ °C}} dt}{\int_t \dot{Q}_{TWW}(t) dt}$	14.57 %	6.71 %

2. Modellunsicherheiten


Ergebnisse: Modellstruktur

Verteilungen der Systemzustände

Quadratisches Optimierungsmodell



Lineares Optimierungsmodell




→ inadäquate Modellstruktur kann die Priorität des Ladens von einem Speicher zum anderen verschieben

2. Modellunsicherheiten

Ergebnisse: Modellparameter

Relative Änderung der Bewertungskriterien infolge von Parametervariation am Optimierungsmodell




- realistische (geringe) Fehler haben vernachlässigbaren Einfluss
- große Parameterfehler können ebenfalls Verschiebung der Ladepriorität hervorrufen

3. Prognoseunsicherheiten

3. Prognoseunsicherheiten

Forschungsfrage

Gemessene und prognostizierte Zeitreihen der PV-, elektrischen Last- und Trinkwarmwasser-Leistung



- Ist es möglich, den Einfluss individueller Typen von Prognosefehlern auf die zukünftige Performance der Betriebsführung zu quantifizieren?
- Welche Fehler haben den größten Einfluss?
- Wie sicher können wir uns dessen sein?

Zeit in h


3. Prognoseunsicherheiten

Vergleich zum Einfluss der Modellstruktur

Bewertungskriterium	MILP, ideale Prognosen	MIQCP, ideale Prognosen	MILP, reale Prognosen
Betriebskosten, k_{BK}	475.12 €	472.33 €	547.82 €
Selbstversorgungsgrad, k_{SV}	53.86 %	53.99 %	47.63 %
Eigenverbrauchsgrad, k_{EV}	61.83 %	61.69 %	58.24 %
PV-Abregelung, $k_{PV,A}$	$1.23 \cdot 10^{-4}$	$1.20 \cdot 10^{-4}$	$14,39 \cdot 10^{-4}$
Anteil des TWW, das bei unter 50 °C gezapft wurde, k_{TWW}	14.57 %	6.71 %	32.83 %

3. Prognoseunsicherheiten Vorgehen

- Reduktion der Dimensionalität
→ Feature Engineering (FE)
- Identifikation möglicher Zusammenhänge
→ Explorative Datenanalyse (EDA)
- Quantifizieren der Zusammenhänge
→ Lineare Regression (LR)
→ Normierung (N)
- Durchführung für 20 verschiedene Haushalte



3. Prognoseunsicherheiten

Feature Engineering

Bewertungskriterien

1. Berechnung für jeden Zeitschritt, in dem eine Prognose und Optimierung durchgeführt wurde
 2. Berechnung der Differenz zwischen realer und idealer Simulation
 3. Berechnung der Änderung über 2 h
- Vorzeichendefinition bei 2. und 3. so, dass negative Werte eine Verschlechterung sind



Prognosefehler

1. Definition von „Features“
 - Leistung im nächsten Zeitschritt
 - Energieinhalt
 - Leistung der geschätzten Maxima
 - Leistung am tatsächlichen Maximum
 - Zeitpunkt des Auftretens des Maximums
2. Aufteilung in Überschätzung und Unterschätzung

3. Prognoseunsicherheiten

Korrelation zwischen Prognosefehlern und Kostenerhöhungen



- Berechnung Korrelation zwischen vorangegangenen Prognosefehlern und späteren Erhöhungen der Kostendifferenz für alle 20 Haushalte
- Problem: Autokorrelation der Prognosefehler



3. Prognoseunsicherheiten


Schätzung der Einflüsse von Prognosefehlern auf Kosten

- lineare Regression
- Problem: unterschiedliche Einheiten und Größenordnungen
- Lösung: Normierung mittels
 - Teilen durch mittleren Kostenanstieg
 - Multiplikation mit mittlerem Prognosefehlerfeature



3. Prognoseunsicherheiten

Zusammengefasste Einflüsse von Prognosefehlern auf Kosten



4. Zusammenfassung und Ausblick

4. Zusammenfassung und Ausblick


Zusammenfassung

- **Modellunsicherheiten**

- Große Modellfehler können das optimierende Betriebsführungsverfahren dazu bringen, die Ladepriorität zwischen den Speichern zu verschieben.
- Kleine Modellfehler hatten keinen nennenswerten Einfluss auf die Performance des Systems.

- **Prognoseunsicherheiten**


- Verkettung von Feature engineering, EDA und Regression, um Prognosefehler mit größtem Einfluss auf Performance des Systems zu identifizieren
- Modellqualität verbesserungswürdig, daher Robustheit der Ergebnisse fragwürdig



4. Zusammenfassung und Ausblick

Ausblick

- **Weitere Forschung zum Einfluss von Prognoseunsicherheiten**
 - Anwendung der Methodik auf restliche Bewertungskriterien
 - Vergleich mit abgewandelten Methodiken (Variablentransformationen, logistische Regression)
 - Analyse einer breiteren Palette von Multi-Use-Kombinationen
- **Verbesserungen der Betriebsführung**
 - Entwicklung eines statistischen Modells für die Prognoseunsicherheiten
 - Nutzung der Informationen über die Unsicherheiten in der Optimierung



Vielen Dank!



Dipl.-Ing. Ronny Gelleschus
(Hauptautor)
ronny.gelleschus@tu-dresden.de
+49 351 463 40332



Prof. Dr.-Ing. Thilo Bocklisch
thilo.bocklisch@tu-dresden.de
+49 351 463 40270

