


Ausblick: Intelligente Steuerung von Wärmenetzen

**Optimierter und automatisierter Wärmenetzbetrieb für
sichere, bezahlbare und nachhaltige Wärme**

Wärmenetze werden durch neue, verteilte Erzeugungstechnologien und Speichern komplexer zu steuern.


Heute: Wenige große, ähnlich strukturierte WEAs

- ▶ Vergleichsweise (!) einfache Erzeugereinsatzplanung (aktuell mit BoFIT)
- ▶ Kombiniert mit komplexer hydraulischer Netzsteuerung (SIR 3S)



Zukunft: Zahlreiche dezentrale WEAs und Speicher

- ▶ Höhere Komplexität bei der Synchronisation der Erzeuger
- ▶ Höherer Anteil EE-Strom = größere (wahre) Preisvolatilität für WP und BHKW



Implikation: Höhere Intelligenz benötigt

- ▶ Wärmenetz wird gleichzeitig zu signifikanter Flexibilitätsreserve
- ▶ Intelligente, automatisierte Echtzeitsteuerung wird zur notwendigen Voraussetzung für den wirtschaftlichen Betrieb

Zunehmende Anzahl verschiedener Einflussparameter bestimmen die Optimalität der Erzeugersteuerung.

Einflussparameter (exemplarisch)



Optimierungsmodell




Durch dynamischen Algorithmus, der

- ▶ Die gegenseitige Wechselwirkung der Parameter zueinander berücksichtigt und
- ▶ Aus der schier unbegrenzten Anzahl an Kombinationsmöglichkeiten die beste herausucht

Steuerungsmodell:

Automatisierte Übertragung des ermittelten, optimalen Fahrplans in Echtzeit* an WEAs und Speicher



Feedback aus den Anlagen in das Optimierungsmodell

*z.B. in 15 – 60 Min. Intervallen

Die jeweils beste Optimierungsmethode hängt von der vorherrschenden Komplexität des Wärmenetzes ab.

	Aktueller Marktstandard	Aktueller Entwicklungsstand Kelvin Green	In Vorbereitung
Komplexität			
Netzsystem-eigenschaften	▶ Wenige, ähnliche WEAs (GuD/BHKW + Spitzenlastkessel) ▶ Einzelne kleine Pufferspeicher	▶ Wenige unterschiedliche WEAs (z.B. WP+BHKW+ST) ▶ Mehrere Kurzfristspeicher	▶ Viele unterschiedliche WEAs (z.B. 3 WP+BHKW+ ST+Abwärme+GT etc.) ▶ Kurz- und Langfristspeicher
Beste Optimierungsmethode	▶ Regelbasierte, lineare mathematische Optimierung (z.B. Merit-Order) ▶ Geringe Vorhersagbarkeit, lange Vorlaufzeiten	▶ TPE-HO^{®1} als Sequential Model-Based Optimization (SMBO) Ansatz ▶ Hohe Vorhersagbarkeit, Echtzeit-Optimierung mit geringem Trainingsaufwand	▶ RE-HO[®] als Reinforcement Learning Ansatz ▶ Approximation hochdimensionaler Parameterräume in Echtzeit, gewisser Trainingsaufwand

¹ Tree-structured Parzen Estimator for Heat Optimization by Kelvin Green

Der TPE-HO[®] Ansatz ist der Einstieg in die intelligente Steuerung, der bei begrenzt komplexen Settings die besten Ergebnisse liefert.

ILLUSTRATIV

Schritt 1: Konfiguration

Dynamische Randbedingungen, u.a.

- ▶ Wärmebedarf
- ▶ Lastprognose
- ▶ Potenzial Erzeugungsanlagen (bspw. Solarthermie-Ertrag)
- ▶ Speicherkapazitäten und Füllstände
- ▶ Wetter (Sonnenstunden, Temperatur)
- ▶ Markt & Politik (Strompreis, Förderung)
- ▶ ...

Initialer Einsatzplan (random)

- ▶ WP-1: 70% Last
- ▶ Solarthermie: 100% einspeisen
- ▶ WP-2: 50% Last
- ▶ Speicher A: 65% füllen
- ▶ Speicher B: 30% Last (ausspeisen)

Schritt 2: Optimierung für Zeitraum $t_x - t_0$

Komplexe
Kostenfunktion

TPE-HO Modell
berechnet n Alternativen
auf stochastischer Basis

n
Iterationen

Vorschlag zur
wahrscheinlich besseren
Einsatzplanung

Schritt 3: Finaler Fahrplan


Optimierter Einsatzplan

- ▶ WP-1: 50% Last
- ▶ ST: 100% einsp
- ▶ WP-2: 70% Last
- ▶ Speicher A: 100% füllen
- ▶ Speicher B: 30% füllen

Beste Variante
aus n Iterationen

In einer Simulation haben wir unseren TPE-HO[©] Ansatz einer regelbasierten Merit Order-Logik gegenübergestellt.

TPE-HO[©] Modell



- ▶ Prognostiziert Parameter (hier: Strompreis, Lastprognose, Wetter)
- ▶ Füllt den Wärmespeicher entsprechend prädiktiv, z.B. wenn der Strompreis günstig ist und keine Sonne zu erwarten ist etc.

vs.

Merit-Order Regellogik



- ▶ Wählt die jeweils günstigste Wärmequelle zum Zeitpunkt X so lange bis Wärmebedarf gedeckt ist
- ▶ Wärmespeicher wird immer nur gefüllt, wenn Solarthermie überschüssig vorhanden ist

Ergebnis: Unser TPE-HO[©] Ansatz ergibt ein Optimierungspotenzial von rund 30% bei den Betriebskosten.

Gewähltes fiktives Netz-Setup für die Simulationen (vereinfacht)



Wärmeerzeugungsanlagen

- ▶ Wasser-Wasser- Wärmepumpe, 20 MW, COP 3,0 konstant
- ▶ Luft-Wasser-Wärmepumpe, 10 MW, COP variabel (je nach °C außen)
- ▶ Solarthermie-Anlage, 15 MW



Wärmeabnehmer

- ▶ 30 MW max. Wärmebedarf
- ▶ Bedarfsprognose auf Basis Standard-Lastprofilen



Speicher

- ▶ 60 MW, entspricht 2 Stunden Autarkie



Markt & Politik


- ▶ Börsenstrompreise aus 2022, Intraday
- ▶ Keine Betriebskostenförderung
- ▶ Gestehungskosten Solarthermie = 0 EUR



Wetter

- ▶ Historische Wetterdaten 2022 (Globalstrahlung, Außentemperatur)

Ergebnis der Simulation: Arbeitskosten (in cent/kWh)



validate_results.ipynb M

optimizer_helper.py 2, M

optimizer_script.py 1, M

optuna > validate_results.ipynb > fig = px.line(results[plot_cols])

+ Code

+ Markdown

Run All

Restart

Clear All Outputs

Variables

Outline

.env (Python 3.10.12)

52

merit_order_cost_per_kwh_list = []

53

merit_order_storage_in_list = []

54

merit_order_storage_out_list = []

55

merit_order_storage_flow_list = []

56

57

observations_prepared = {

58

"n_hours": n_hours,

59

"buffer_start_value": buffer_state_old,

60

"max_buffer": MAX_BUFFER,

61

"obs_demand": heat_demand,

62

"obs_price_hp_water": price_hp_water,

63

"obs_price_hp_air": price_hp_air,

64

"obs_price_st": price_st,

65

"obs_max_hp_water": max_hp_water,

66

"obs_max_hp_air": max_hp_air,

67

"obs_max_solarthermic": max_st,

68

}

69

for step in range(n_hours):

70

71

merit_order_cost_per_kwh, merit_order_allocation = calculate_merit_order(

72

observations_prepared["obs_demand"][step],

73

observations_prepared["obs_price_hp_water"][step],

74

observations_prepared["obs_price_hp_air"][step],

75

observations_prepared["obs_max_solarthermic"][step],

76

observations_prepared["obs_max_hp_water"][step],

77

observations_prepared["obs_max_hp_air"][step],

78

buffer_merit_order,

79

)

80

merit_order_cost_per_kwh_list.append(merit_order_cost_per_kwh)

81

82

merit_order_hp_water_list.append(merit_order_allocation.get("hp_water", 0))

83

merit_order_hp_air_list.append(merit_order_allocation.get("hp_air", 0))

84

merit_order_solarthermic_list.append(merit_order_allocation.get("st", 0))

85

86

merit_order_buffer_state_list.append(buffer_merit_order.storage_state)

87

Live DEMO

Kelvin Green GmbH | 2024 | Streng vertraulich

8

 Betriebskosten analysieren

	Betriebskosten Details anzeigen	▼ 4,5 ct/KWh
	EEX-Spot Details anzeigen	▲ 29,2 ct/KWh
	Flexibilitätsmarkt Details anzeigen	▲ 18,2 ct/KWh



Zeitschritt	WP1	Fluss-WP	Solar	Krupp	Speicher	Bedarf gedeckt
 Nächster Zeitschritt wird berechnet						
05.09.2023 14:00 - 15:00	67%	82%	100%	14%	100%	+2%
05.09.2023 13:00 - 14:00	65%	84%	100%	18%	100%	+4%
05.09.2023 12:00 - 13:00	60%	85%	100%	10%	50%	+5%
05.09.2023 11:00 - 12:00	50%	90%	100%	8%	-50%	+1%
05.09.2023 10:00 - 11:00	67%	82%	100%	14%	100%	+2%
05.09.2023 09:00 - 10:00	65%	84%	100%	18%	100%	+4%
05.09.2023 08:00 - 09:00	60%	85%	100%	10%	50%	+5%
05.09.2023 07:00 - 08:00	60%	85%	100%	10%	50%	+5%
05.09.2023 06:00 - 07:00	50%	90%	100%	8%	-50%	+1%

Alle Berechnungen anzeigen


Die Vorteile einer intelligenten, automatisierten Steuerung liegen auf der Hand:

Weniger Kosten, weniger Arbeit, weniger Fehler, weniger Ärger – mehr bezahlbare grüne Wärme.



Spart Zeit, weil...

- ▶ Weniger manuelle Planungs- und Steuerungsprozesse



Spart Geld, weil...

- ▶ Brennstoffeinkauf (v.a. WP-Strom) zum optimalen Zeitpunkt
- ▶ Stromvermarktung (grüne BHKW) zum optimalen Zeitpunkt plus ggf. Flexprämien
- ▶ Weniger personalintensiv



Spart Ärger, weil...

- ▶ Weniger fehleranfällig vor allem bei komplexen Settings