

AI for the operational optimization of energy systems: Comparison of data- driven and model-based optimization strategies in power engineering


reducing Energy Costs, CO2 Emissions, Downtime Risks and improving Productivity

16.06.2025 | Dr.-Ing. Niklas Panten | niklas.panten@etalytics.com



Agenda

1. Introduction / Context
2. etalytics
3. Deep Dive – Control Optimization: DRL vs. MPC





Transfer to
DC INDUSTRY

10+ Years of Research & Industry Experience to Solve the Puzzle

We combined Energy Science, Engineering and Computer Science / AI and applied it on Large-Scale Industrial Energy Systems.

The Unsustainable Energy Hunger of Data Centers

Facing the Challenges of Rapid Sector Growth



Koot, M., & Wijnhoven, F. (2021). Usage impact on data center electricity needs: A system dynamic forecasting model. *Applied Energy*, 291, 116798. <https://doi.org/10.1016/j.apenergy.2021.116798>

Mastering the Energy Symphony

Orchestrating Systems for Peak Performance



Why Data Center Cooling is Challenging and often Inefficient

Holistic optimization needs the perfect and predictive orchestration of all energy converters involved

Complex Topologies



Huge Control Space



Diverse Interdependences




Dynamic Influences



In a **Critical Infrastructure**
Environment with **fewer staff**


How to...

- ✓ **MAXIMIZE UPTIME ?**
- ✓ **MEET SUSTAINABILITY GOALS ?**
- ✓ **PASS COMPLIANCE AUDITS ?**
- ✓ **AND PROTECT EQUIPMENT ?**



etaONE® — Your Energy Intelligence Layer

Built on physics. Trained on your data. Designed for your energy system and BMS.



Real Results at Scale – Trusted by Global Data Center Leaders

From One Site to a Global Footprint



EQUINIX



EQUINIX FR6, Frankfurt

6.600
m² IT-SPACE

3.000
CABINETS

2017
CONSTRUCTED

49,3 %
Energy Savings (in scope)

>900 MWh/a
Energy Reduction

>240 tCO2/a
CO2 Emissions Reduction

<1 year
Amortization Period



JENS-PETER FEIDNER

Managing Director, Equinix Germany

“ Since implementing etalytics, we've seen a measurable reduction in energy consumption. The platform's ability to dynamically optimize our setpoints has directly contributed to our **cost savings and emissions reductions without compromising performance**.

The platform's safety protocols and fail-safes give us confidence that even though we're using AI, we **maintain full control** and ensure our infrastructure's integrity.


We've always felt supported by etalytics—whether it's through training, troubleshooting, or optimizing the system. They truly understand the needs of critical infrastructure.

Beyond Savings: What AI-Driven Control Feels Like


More stability. More awareness. Less manual stress.




Lower power / energy / runtimes & wear / costs



More stable supply temperatures / SLAs




Transparency, preventive alarms & situational awareness



“ Whether you’re building new or optimizing old, AI is becoming the new standard in operational excellence.

Your Trusted Innovation Partner in Energy Intelligence

Our solutions create impact across industries and applications.



>60 | 120*
Employees | *2026

Frankfurt a.M., DE
Headquarters


San Francisco, CA
US Office




Understanding AI Optimization of Industrial Energy Systems

A Deeper Dive

AI Copilot Addon for Energy System Control



Actor-Critic DRL Control



1 Für Iterationen und mehrere Umgebungen Samples generieren
 $a \sim \pi(a_t | s, \theta)$

2 Mit Sequenzen diskontierte Erträge berechnen

3 Sequenzen durchmischen und in Mini-Batches aufteilen

4 Update der Netzparameter gemäß zu maximierender Zielfunktion

Application Case


Bosch Rexroth Schweinfurt – framework and DRL implementation



Weigold et al.: Method for the application of deep reinforcement learning for optimised control of industrial energy supply systems by the example of a central cooling system

2 ... framework and validation

3 Implementation of DRL algorithm



DRL algorithm

- Proximal policy optimisation (PPO)
- Neural network topology: MLP
- Hyperparameter tuning
- Training phase


Reward function

Weighted sum of individual costs

$$R_t = w_T K_T + w_E K_E + w_S K_S + w_O K_O$$


Implementation

Creating an Python-FMU interface that is compatible to the Gym-Structure




Implementation

Build a Simulation of the supply systems and export it as an FMU




Dymola



► Visit our tutorial: [click here](#)


Reward-Design

Ökonomische Reward-Funktion erweitert mit Straftermen




Evaluierung in zwei Phasen

- Tuning / Training auf Szenario 2017 Daten
- Letztendliche Erprobung auf 2017 sowie unbekannten 2018 Daten, um ggf. zu gute Ergebnisse durch Overfitting zu vermeiden
- Vergleich zu konventioneller Regelung umgesetzt als Agent im Framework




KI bei „Exploration“ des State & Action Space


Algorithmus erkundet Zustands- und Aktionsraum mit jeweiligen Belohnungsgrößen



Parameter-variationen und Versuche

Umfangreiche Evaluierung unterschiedlicher Hyperparameter-Setups für Algorithmus, Reward- und Policy-Shaping sowie bei Mod





Trainingsfortschritt über Episoden

Konvergenz gegen (lokales) Optimum bei geeigneter Parametrierung des Verfahrens

Kritische Diskussion des Verfahrens

Zusammenfassung der Evaluation von funktionalen und formalen Anforderungen




- | | | | |
|--|---|--|--|
| | Konvergenz für komplexe Energiesystem | | Konvergenz in lokale Optima |
| | Einfach anpassbar für andere Umgebungen | | Robustheit: Hyperparameter und Reward-Design |
| | Mehrere Zielgrößen integrierbar | | Integration stark verschiedenartiger Ziele/Systeme |
| | Intrinsisch adaptiv durch Lernfunktion | | Reproduzierbarkeit durch Stochastizität |
| | Sehr reaktiv nach erfolgtem Training | | Nachvollziehbarkeit der Entscheidungen |
| | | | Performance bei Unit-Commitment und Zeitversatz |

Modellgestützte Optimierung

The Model Predictive Control Approach

Powerful 1-shot optimization based on well-fitted plant models and mathematical optimization





Der Begriff der Optimierung, im mathematischen Sinne verwendet, bedeutet die Bestimmung des Maximums oder Minimums einer Funktion f , die auf einem (beschränkten) Bereich S oder Zustandsraum definiert ist.

- Kallrath, 2013, Gemischt-ganzzahlige Optimierung: Modellierung in der Praxis

Example: Typical optimization measures

Optimized Control


Simplified Scenario



Klassifizierungen von Optimierungsproblemen

Optimierung


Nebenbedingungen	Vorhanden	nicht vorhanden	
Linearität der Abhängigkeiten	linear	nicht-linear	
Datentypen	ganzzahlig	nicht-ganzzahlig	gemischtganzzahlig



Inhalt der Vorlesung

Überblick: Verfahren zur Lösung von Optimierungsproblemen

Optimierung



Formulierung eines linearen Optimierungsproblems (LP)

Quelle: Vorlesung Energiesystemtechnik, Lehrstuhl für Technische Thermodynamik, RWTH Aachen

Elemente

- Zielfunktion $f(x) = cx = c_1x_1 + c_2x_2 + \dots + c_nx_n$
 - Zu minimieren / maximieren
- Vektor von Entscheidungsvariablen $x = (x_1, \dots, x_n)$
 - Veränderliche unbekannte Größen
- m unterschiedliche Nebenbedingungen
$$a_1x \leq b_1$$
$$\dots$$
$$a_mx \leq b_m$$
 - Bilanzen (Masse, Energie, ...)
 - Anlagenmodell / -kennlinien
 - Beschränkungen (physikalisch/technisch, mathematisch, gesetzlich)

Formulierung als Matrix

$$\min \{ cx \mid Ax \leq b, x \geq 0\}$$

$$x \in \mathbb{R}^n$$

$$c \in \mathbb{R}^n$$

$$A \in \mathbb{R}^{m,n}$$


$$b \in \mathbb{R}^m$$

Betriebsoptimierung eines Microgrids (LP) - Mathematische Optimierung Energiesysteme

Entscheidungsvariablen: $P_{Speicher,t}$; $E_{Speicher,t}$; $P_{Netz,t}$

$\forall t$

Fallbeispiel



Parameter

- $P_{PV,t(1-4)} = [30; 4; 70; 103] \text{ kW}$
- $Kap = 100 \text{ kWh}$ $E_{start} = 50 \text{ kWh}$
- $P_{max,Speicher} = 100 \text{ kW}$
- $P_{Bedarf,t(1-4)} = [50; 52; 45; 70] \text{ kW}$
- $c_{Börse} = [20; 96; 40; 15] \text{ €/MWh}$
- $\Delta t = 1 \text{ h}$

Mathematische Formulierung

Zielfunktion

$$\min \sum_{t=1}^4 c_{Börse} \cdot P_{Netz,t}$$

Bilanzgleichung elektrische Energie

$$0 = P_{Netz,t} + P_{Bedarf,t} + P_{Speicher,t} - P_{PV,t}$$

Bilanzgleichung Speicher

$$E_{Speicher,t+1} = P_{Speicher,t} * \Delta t + E_{Speicher,t}$$

Speicherleistungsbeschränkung

$$-P_{max,Speicher} \leq P_{Speicher,t} \leq P_{max,Speicher}$$

Kapazitätsbeschränkung

$$0 \leq E_{Speicher,t} \leq Kap$$


Alle Zeitschritte

$\forall t$

Internships, Thesis & Jobs at etalytics

Join our interdisciplinary Teams

Join.etarytics.com



Join our Journey to
INDUSTRIAL ENERGY INTELLIGENCE.

www.etarytics.com



etarytics GmbH

Dr. Niklas Panten

CEO | Co-Founder

niklas.panten@etarytics.com

www.etarytics.com

end