

# KI gestützte Sensitivitätsanalyse für Energiesysteme im industriellen Kontext

Jana Reiter<sup>1(1)</sup>, Carles Ribas Tugores<sup>2(1)</sup>, Jürgen Fluch<sup>3(2)</sup>, Sarah Meitz<sup>4(1)</sup>

<sup>(1)</sup> AEE - Institut für Nachhaltige Technologien  
Feldgasse 19, A-8200 Gleisdorf

<sup>(2)</sup> FH Joanneum Kapfenberg  
Werk-VI-Straße 46, 8605 Kapfenberg

## **Kurzfassung:**

Zur Analyse industrieller Energiesysteme wird in der vorliegenden Arbeit eine künstliche Intelligenz (KI) gestützte Methode der globalen Sensitivitätsanalyse eingesetzt. Anhand von zwei Anwendungsfällen aus der Industrie werden die Vorteile der Methodik diskutiert. Einerseits wird die Unterstützung einer simulationsbasierten Optimierung eines Energieversorgungssystems betrachtet, andererseits die prognosebasierte Analyse eines realen industriellen Systems ohne den Zwischenschritt einer physikbasierten Simulation.

**Keywords:** Industrielle Energiesysteme, globale Sensitivitätsanalyse, Gaußsche Prozessemulatoren, Künstliche Intelligenz

## **1 Motivation und zentrale Fragestellung**

Der industrielle Sektor umfasst viele verschiedene Prozesse mit spezifischem Energiebedarf sowie der dafür eingesetzten und verfügbaren Energieversorgungsstrategien und daraus resultierend eine Vielfalt an Energie- und Produktionssystemen. Das Verhalten dieser industriellen Systeme wird von vielen verschiedenen prozessbedingten Faktoren und deren Interaktionen bestimmt. Zur nachhaltigen und effizienten Dekarbonisierung ist ein gutes Systemverständnis und vor allem das Wissen um den Einfluss der verschiedenen Faktoren auf wichtige Key Performance Indikatoren (KPIs) wie Energiebedarf, CO<sub>2</sub>-Ausstoß oder ökonomische Parameter wie beispielsweise die Wärmegehaltungskosten (Levelized Cost of Heat, LCOH) unabdingbar. Zu diesem Zweck untersucht der vorliegende Beitrag den Einsatz der KI gestützten Sensitivitätsanalyse für Energiesysteme und Produktionssysteme im industriellen Kontext.

---

<sup>1</sup> Jungautorin, Tel: +43 (0)3112-5886-453, j.reiter@aee.at

<sup>2</sup> c.ribastugores@aee.at

<sup>3</sup> juergen.fluch@fh-joanneum.at

<sup>4</sup> Jungautorin, s.meitz@aee.at

## 2 Methodische Vorgangsweise

Um eine globale Sensitivitätsanalyse zu Zwecken der Parameterstudie durchzuführen, bedarf es eines Modells des betrachteten Systems. Eine Möglichkeit das zu erreichen, ist eine physikbasierte Formulierung des industriellen Systems. In einfachen Fällen kann mithilfe dieser Gleichungen eine analytische Form der globalen Sensitivitätsanalyse erfolgen. Ist dies nicht möglich, wird eine stochastische Herangehensweise mittels einer Computersimulation nötig, welche üblicherweise mit tausenden Auswertungen der ursprünglichen Systemsimulation verbunden ist und damit einen erheblichen Rechenaufwand bedeutet. Eine Möglichkeit dieses Problem zu umgehen ist die Verwendung von sogenannten Emulatoren, die mithilfe von KI das Verhalten der Systemsimulation lernen und nach der abgeschlossenen Trainingszeit Simulationsergebnisse in einem Bruchteil der ursprünglichen Simulationszeit reproduzieren (emulieren) können. Ein Vorteil dieser Herangehensweise ist, dass bei hoher Datenqualität und ausreichend vielen Datenpunkten auch ein direktes Training des Emulators anhand von realen Messdaten möglich ist. In diesem Fall lernt die KI das reale industrielle System anstatt die Simulation zu emulieren. Die KI kann anschließend einerseits zur Parameterstudie des realen industriellen Systems verwendet werden und andererseits zur Prognose der erlernten KPIs.

In der vorliegenden Arbeit werden beide Herangehensweisen – (1) Training eines Emulators mit einer Systemsimulation und (2) Training eines Emulators mit einer Datenbasis – anhand zweier Anwendungsfällen demonstriert.

Für die computergestützte Umsetzung wurde die auf SALib (Iwanaga, Usher, & Herman, 2022) und GPyTorch (Gardner, et al., 2018) basierende Bibliothek GPERks (<https://github.com/stelong/GPERks>, 2021) verwendet.

## 3 Ergebnisse

### 3.1 Training eines Emulators anhand einer Systemsimulation

Im Rahmen einer Studie zur technischen, exergetischen und ökonomischen Optimierung unterschiedlicher Kombinationen erneuerbarer Technologien zur Energieversorgung industrieller Systeme wurden computergestützte Simulationen dieser Systeme für mehrere industrielle Anwendungen an unterschiedlichen Standorten eingesetzt. Aufgrund der vielen einflussnehmenden Parameter komplexer Energieversorgungssysteme stellte sich die Systemoptimierung als komplex und sehr rechenaufwändig heraus. An dieser Stelle wurde mittels globaler Sensitivitätsanalyse Abhilfe geschaffen. In einem ersten Schritt wurden Trainingsdaten erzeugt. Hierfür wurde für die Auswahl der jeweiligen Inputparameter die Latin Hypercube Sampling Methode (Implementierung von SALib (Iwanaga, Usher, & Herman, 2022)) verwendet, um den hochdimensionalen Parameterraum bestmöglich abzutasten. Anschließend wurde die KI trainiert und daraufhin der entstandene Emulator zur Berechnung der Sobol Indizes (varianzbasierte Sensitivitätsanalyse) verwendet.

Beispielhaft ist in Abbildung 1 das Energieversorgungssystem von einem der betrachteten Anwendungsfälle, ein industrieller Standort aus dem Bereich der Baustoff-Steine-Erden-Industrie, abgebildet. In diesem Fall wurden zwei Konfigurationen untersucht, die jeweils unterschiedliche Kombinationen erneuerbarer Energiequellen nutzen: 1 – Solarthermie +

Abwärme + Photovoltaik, 2 – Abwärme + Photovoltaik. Die Notwendigkeit der KI-Einbindung wird anhand einer Rechenzeitabschätzung anschaulich: Die vollständige Dymola-Simulation des Energieversorgungssystems umfasste 18 variable Inputparameter und die Laufzeit für eine Jahressimulation des Energiesystems betrug rund 20 Minuten. Daraus ergibt sich aufgrund der hohen Anzahl an nötigen Simulationsdurchläufen zum Abtasten des Parameterraumes eine geschätzte Dauer zur Berechnung einer globalen Sensitivitätsanalyse von etwa 1,5 Jahren. Im Vergleich dazu benötigte die im Rahmen dieser Studie durchgeführte Sensitivitätsanalyse mithilfe des trainierten Emulators weniger als zehn Minuten, wobei zusätzlich sowohl die Trainingszeit des Emulators in der Größenordnung von Minuten, als auch die Erstellung der Trainingsdaten mit der ursprünglichen Simulation in der Größenordnung von einigen Stunden zu berücksichtigen ist.

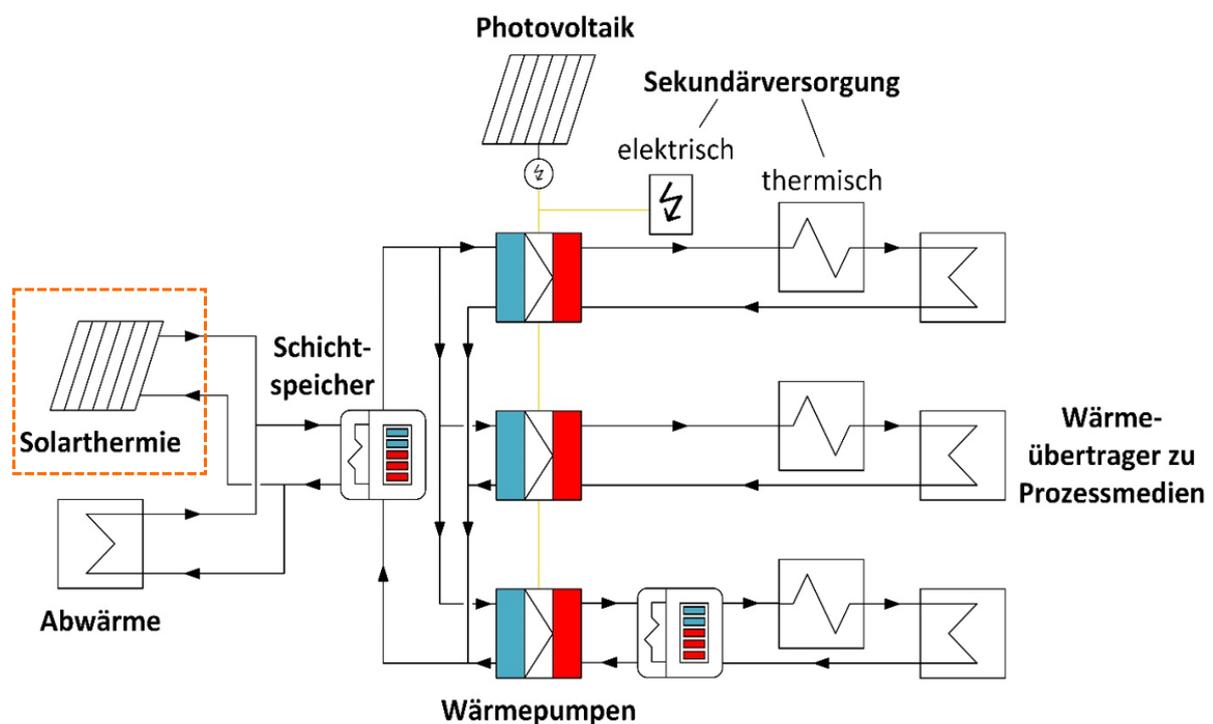


Abbildung 1: Zwei Systemkonfigurationen eines Energieversorgungssystems: 1 – Solarthermie + Abwärme + Photovoltaik, 2 – Abwärme + Photovoltaik (Quelle: Dominik Seliger, TU Wien, Projekt CORES)

Zur Interpretation der Ergebnisse der Sensitivitätsanalyse sind nachfolgend die betrachteten KPIs angeführt:

- Der Anteil an erneuerbarer Energie (Share of Renewables, SOR), siehe ((3-1)), errechnet sich aus dem Verhältnis zwischen der eingesetzten Energie aus erneuerbaren Quellen  $E_n$ , siehe ((3-2)) und des gesamten Energiebedarfs ( $E_{ges}$ ).

$$SOR = \frac{E_n}{E_{ges}} \quad (3-1)$$

$$E_n = E_{ST} + E_{WHX} + E_{PV,HP} \quad (3-2)$$

Hier steht  $E_{ST}$  für die durch Solarthermie,  $E_{PV,HP}$  für die durch Photovoltaik und  $E_{WHX}$  für die aus Abwärme  $E_{WHX}$  gewonnene Energie.

- Die CO<sub>2</sub>-Emissionen werden durch den Energiebedarf der Sekundärversorgung verursacht und bestehen aus Anteilen aufgrund der Prozesswärmebereitstellung durch Erdgasverbrennung und der Bereitstellung elektrischer Leistung aus dem Stromnetz zur Versorgung der Wärmepumpen, siehe ((3-3).

$$\varepsilon = \varepsilon_{Gas} + \varepsilon_{el} \quad (3-3)$$

- Die Wärmegestehungskosten (Levelized Cost of Heat, LCOH), siehe ((3-4), errechnen sich aus den Investitionskosten  $A_0$ , der Nutzungsdauer  $TN$ , sowie den laufenden Kosten in der Periode  $t$   $A_t$  und der bereitgestellten Energie in der Periode  $t$   $E_{ges,t}$

$$LCOH = \frac{\left(\frac{A_0}{TN} + A_t\right)}{E_{ges,t}} \quad (3-4)$$

In Abbildung 2 sind die Ergebnisse der Sensitivitätsanalyse bezüglich der KPIs dargestellt. Die hier verwendete varianzbasierte Sensitivitätsanalyse gibt Auskunft über die Auswirkung der Varianz der Inputparameter auf die Varianz des jeweiligen KPIs: Der Sobol Index erster Ordnung (S1) beschreibt den direkten Einfluss der Varianz des Inputparameters auf die Varianz des jeweiligen KPIs während der Gesamteffekt Sobol Index (ST) den Einfluss der Varianz des Inputparameters auf die Varianz des jeweiligen KPIs unter Berücksichtigung der Wechselwirkungen mit den Varianzen der anderen Inputparameter beschreibt. Bei Betrachtung der Ergebnisse ist ersichtlich, dass die erneuerbaren Energiequellen Solarthermie (ST) und Photovoltaik (PV) den größten Einfluss auf SOR haben, was direkt aus der Definition dieses KPI erklärbar ist, siehe ((3-1) und ((3-2). Im Vergleich dazu scheint hier die Abwärme nicht als relevant auf, da die Menge der Abwärme im Rahmen der Simulation als konstant betrachtet wurde und somit zu keinen Schwankungen in der SOR führen kann. Die Parametergrenzen für die zugehörige Wärmetauscherfläche (WHX\_area) wurden in der Simulation so gewählt, dass keine wesentliche Verschlechterung der Prozesswärmebereitstellung durch Abwärme möglich war. Die KPIs LCOH und CO<sub>2</sub>-Emissionen werden am stärksten von den festgelegten Wärmepumpennennleistungen (Pn\_HP\_P) beeinflusst, was durch den Zusammenhang mit dem für den Betrieb der Wärmepumpen benötigten Strom und den damit assoziierten Kosten und Emissionen erklärbar ist, da der nicht durch PV bereitgestellte Anteil durch die Sekundärversorgung aus dem Netz gedeckt wird. In weiterer Folge fällt auf, dass die Wärmepumpe des zweiten Prozesswärmebedarfs (P2) im Vergleich zu den anderen beiden Wärmepumpen keinen Einfluss zu haben scheint. Das liegt an der wesentlich kleineren Größe dieses Abnehmers und der in diesem Fall entsprechend klein gewählten Nennleistung.

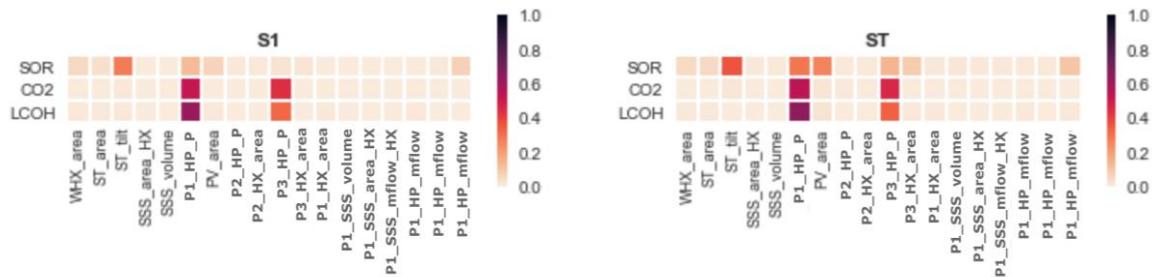


Abbildung 2: Sobol Indizes erster Ordnung (links) und Gesamteffekt Sobol Index (rechts) für das Energieversorgungssystem eines industriellen Standortes aus dem Bereich der Baustoff-Steine-Erden-Industrie

Durch die erläuterten Erkenntnisse konnte auf der einen Seite eine Parameteroptimierung des Energiesystems effizient durchgeführt werden und auf der anderen Seite ein verbessertes Systemverständnis erlangt werden. Auch während der Entwicklung der Systemsimulation sind die Ergebnisse der Sensitivitätsanalyse wertvolle Indizien, um mögliche konzeptionelle Fehler sowie Potentiale zur Vereinfachung der Simulation durch das Festlegen von Parametern oder die Vernachlässigung von Teilprozessen zu identifizieren.

### 3.2 Training eines Emulators anhand einer Datenbasis

Hier wurde das Produktionssystem einer Bäckerei untersucht, das aufgrund der vielen verschiedenen Produkte und Produktionswege sowie der saisonalen Sortimentsschwankungen nur schwer in einer Simulation abzubilden ist. Daher wurde aus den vorhandenen Daten (Produktionslisten, Wetterdaten, Wochentage und Energieverbrauch) ein Emulator trainiert, um auf der einen Seite ein umfassendes Systemverständnis aus den Ergebnissen der Sensitivitätsanalyse zu erlangen und auf der anderen Seite eine Vorhersage des zu erwartenden Energieverbrauches aus der Auftragsliste zu generieren.

Im Gegensatz zum vorigen Anwendungsbeispiel lagen hier die Herausforderungen hauptsächlich in der Aufbereitung der verfügbaren Daten:

- Bereinigen der Daten
- Sortieren der Produkte in für den Energieverbrauch relevante Gruppen: Um die große Anzahl der verschiedenen Produkte (439) angesichts des im Vergleich relativ kleinen Datensets (427 Produktionstage) zu händelbar machen, ist die Einteilung der Produkte in insgesamt 20 Gruppen sinnvoll. Mit einem zukünftig größeren Trainingsdatenset wird eine Verfeinerung oder sogar Auflösung der Produktgruppen zur Erhöhung der Genauigkeit angestrebt.
- Richtiges wählen der Zeitfenster für den angefallenen Energiebedarf bezüglich des Produktionsbetriebs.
- Beachten verschiedener Produktionsweisen gleicher Güter und darauf abgestimmte Differenzierung der Energieträger zur Versorgung. In diesem Schritt wurde der Fokus auf fertige gebackene Ware gelegt und Tiefkühlware vernachlässigt. Dementsprechend wurde der durch den hauptsächlich mit den Öfen der Bäckerei korrelierenden Gasverbrauch entstehenden Energiebedarf betrachtet, wobei durch Produkte die in unterschiedlichen Öfen (Holzbacköfen sowie Gasöfen) gebacken werden und kleinere andere Gasverbraucher, nach wie vor eine Verzerrung der Datenlage besteht.

- Zusätzliche Betrachtung von Wetterdaten sowie Wochentagen zur Verbesserung der Datenlage. Für eine zukünftige Verbesserung der Prognosegenauigkeit könnte das Hinzufügen eines Indikators für die Saison (Kalenderwoche oder Laufindex über das gesamte Jahr) angedacht werden, um die Saisonalität der Produktion zu beachten. Allerdings ist ein besonders guter Effekt voraussichtlich erst ab einer Datenlage über mehrere Jahre zu erwarten.

Zur Validierung der Prognose wurde ein Teil des Datensets nicht zum Training des Emulators sondern als Testset benutzt. In Abbildung 3 ist die Auswertung des Testsets und die daraus entstandene Gegenüberstellung des prognostizierten Energieverbrauches zum tatsächlich angefallenen Energieverbrauch dargestellt. Die Balken in der Grafik beschreiben die Unsicherheit der Prognose mit plus/minus zwei Standardabweichungen (~95% Konfidenzintervall). Die Verwendung Gaußscher Prozessemulatoren hat den Vorteil, dass durch die probabilistische Betrachtung die Vorhersage, im Gegensatz zur Punktprognose anderer herkömmlicher KI Methoden, in Form einer Normalverteilung erfolgt und damit ein Maß der Unsicherheit gegeben ist.

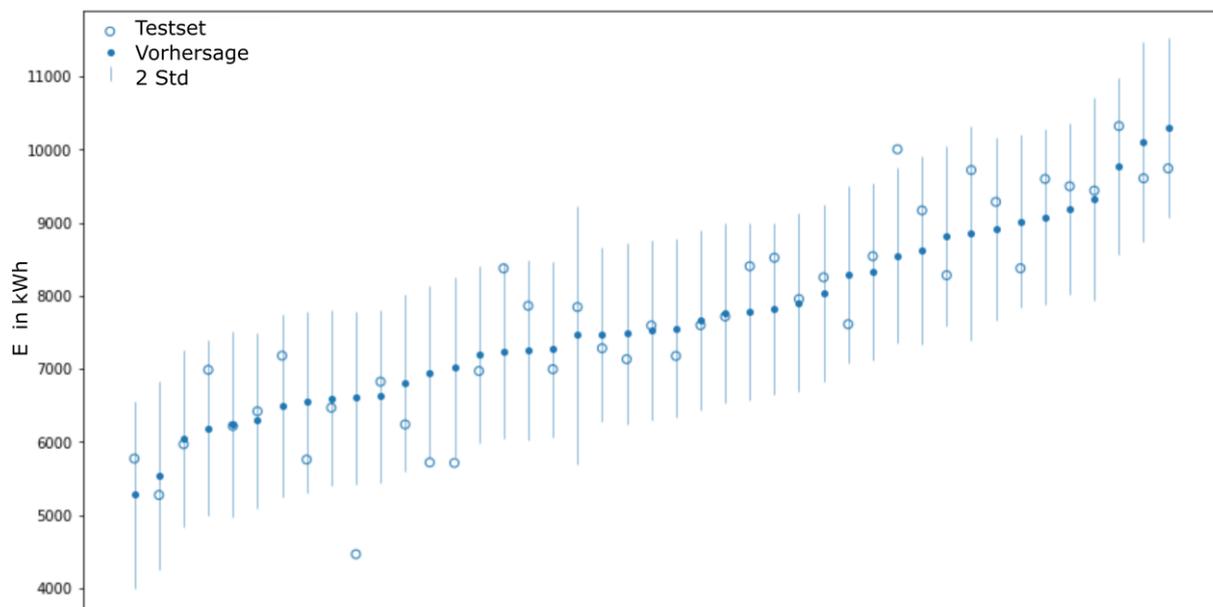


Abbildung 3: Evaluation des Emulators zur Vorhersage des Energieverbrauches eines Bäckereibetriebes inklusive Unsicherheitsangabe anhand eines Testsets

Anhand dieses Emulators wurde eine Sensitivitätsanalyse zur Bewertung der Einflüsse der betrachteten Parameter (Produktgruppe, Wochentag, Außentemperatur) auf den Energieverbrauch der Bäckerei erstellt. Die Ergebnisse der Analyse sind in Abbildung 4 dargestellt. Hier zeigt sich der große Einfluss der Umgebungstemperatur, welcher die saisonale Abhängigkeit des Energiebedarfs widerspiegelt. Der Einfluss des Wochentags ist aus dem beobachteten wöchentlichen Verhalten, das hauptsächlich auf den Betriebszeiten der Bäckerei beruht, nachvollziehbar. Weiters zeigen sich drei Produktgruppen sowie zwei Einzelprodukte aufgrund von regelmäßigen Großbestellungen als besonders relevant. Die Produktgruppen Kleingebäck sowie Semmel sind nur bezüglich ihres ST wichtig und sind insofern nur in Kombination mit anderen Parametern relevant für den Energieverbrauch. Da aus den Sobol Indizes zweiter Ordnung keine klare Relation mit anderen Parametern

ersichtlich ist, müssen die Interaktionen höherer Ordnung auftreten. Beispielsweise ist eine vermehrte Abhängigkeit vom Wochentag sowie besonderen saisonalen Produktionsunterschieden die mit der Außentemperatur korrelieren und dem Produktionsumfang anderer Produktgruppen wahrscheinlich. Eine genauere Analyse dieser Zusammenhänge ist durch die Berechnung der Sobol Indizes höherer Ordnung unter Aufwand von mehr Rechenzeit möglich, wurde aber im Rahmen dieser Studie nicht als notwendig erachtet.

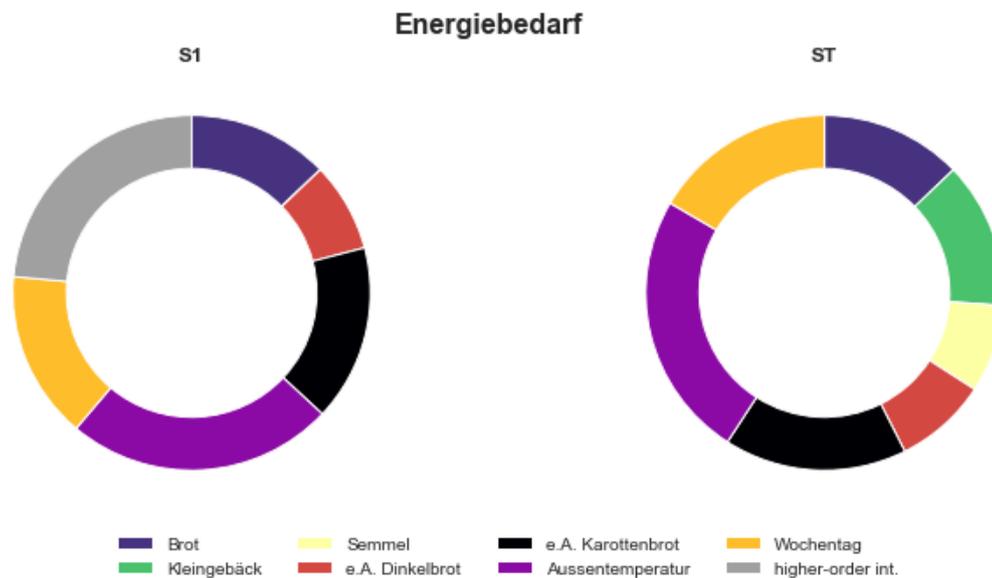


Abbildung 4: Sobol Index erster Ordnung (links) und Gesamteffekt Sobol Index (rechts) des emulierten Energieverbrauches einer Bäckerei (Werte der Indizes von weniger als 1% haben, werden in dieser Grafik nicht angezeigt)

## 4 Resümee

Die vorliegende Arbeit zeigt klar die Vorteile des Einsatzes einer KI gestützten Sensitivitätsanalyse für industrielle Systeme. In beiden Anwendungsfällen konnte ein verbessertes Systemverständnis erreicht werden. Im Fall der Emulation der Energiesystemsimulation wurde die Sensitivitätsanalyse durch die erhebliche Verkürzung der Rechenzeit erst möglich und konnte als Hilfestellung in der Simulationsentwicklung sowie zur anschließenden Parameteroptimierung verwendet werden. Im Fall des direkt anhand einer Datenbasis trainierten Emulators zeigt das entstandene Modell neben der Nutzung für die Sensitivitätsanalyse große Potentiale zur Energieverbrauchsprognose inklusive einer Unsicherheitsangabe, insbesondere bei einer weiteren Verbesserung der zum Training verwendeten Datenlage.

**Literatur**

Gardner, J. R., Pleiss, G., Bindel, D., Weinberger, K. Q., Wilson, & Gordon, A. (2018). GPyTorch: Blackbox Matrix-Matrix Gaussian Process Inference with GPU Acceleration. *Advances in Neural Information Processing Systems* .

<https://github.com/stelong/GPERks>. (2021).

Iwanaga, T., Usher, W., & Herman, J. (2022). Toward SALib 2.0: Advancing the accessibility and interpretability of global sensitivity analyses. *Socio-Environmental Systems Modelling*.

**Acknowledgements**

Dieser Beitrag wurde im Rahmen der Forschungsprojekte DSM\_Opt und CORES erstellt. DSM\_Opt (Projektnummer 880772) wurde im Rahmen der Vorzeigeregion Energie 2019 durch den österreichischen Klima- und Energiefonds finanziert. CORES (Projektnummer 871669) wurde im Rahmen des Energieforschungsprogrammes 2018 durch den österreichischen Klima- und Energiefonds finanziert.