

ENERGIEEFFIZIENZ 4.0 IN DER PRODUKTION: BESTANDSAUFNAHME UND AUSBLICK

Martin Paczona

8330 Feldbach, contact@martin-paczona.com

Kurzfassung: Die industrielle Produktion steht vor der Aufgabe, Energieeffizienz als zentralen Hebel der Dekarbonisierung systematisch zu nutzen. Trotz fortschreitender Digitalisierung bleiben erhebliche Effizienzpotenziale ungenutzt – bedingt durch fragmentierte Datenlandschaften, heterogene Maschinenparks und fehlende modellbasierte Optimierungsmechanismen. Gleichzeitig erhöhen EU-Green-Deal, Energieeffizienzrichtlinie sowie die zunehmende Elektrifizierung industrieller Prozesse den Transformationsdruck. Bestehende Normen wie ISO 50001 schaffen organisatorische Grundlagen, adressieren digitale Schlüsseltechnologien wie Digitale Zwillinge, Maschinelles Lernen, oder Cyber-Physische Systeme nur in Ansätzen. Basierend auf einer systematischen Literaturanalyse wird ein physikalisch fundiertes fünf-Säulen-Framework „Energieeffizienz 4.0“ zur Effizienzsteigerung vorgeschlagen, das thermodynamische Grundprinzipien mit digitalen Technologien systematisch verknüpft und die Funktionsweise durch ein Anwendungsbeispiel für Druckluftsysteme demonstriert.

Keywords: Energieeffizienz, Digitale Zwillinge, Energy Waste, Produktionssysteme

1 Einleitung – Energieeffizienz in der Produktion

Die industrielle Produktion steht unter enormem regulatorischem und ökonomischem Transformationsdruck. Der European Green Deal sowie die verschärfte Energieeffizienzrichtlinie (EED) 2023/1791 definieren Reduktionsziele: Eine obligatorische jährliche Energieeinsparung von mindestens 1,49% des nationalen Endenergieverbrauchs bis 2030 (Art. 4 EED). Gleichzeitig erfordern sektorspezifische Vorgaben eine systematische Reduktion der CO₂-Emissionen um 55% bis 2030 gegenüber 1990 (Europäisches Parlament und Rat der Europäischen Union, 2023).

In der Europäischen Union entfielen im Jahr 2023 24,6% des Endenergieverbrauchs auf den Industriesektor, womit dieser nach dem Verkehrssektor (32,0%) und den privaten Haushalten (26,3%) den drittgrößten Energieverbraucher darstellt (Eurostat, 2025). Innerhalb des Industriesektors dominiert das verarbeitende Gewerbe mit 93,6% den Energieverbrauch, während Baugewerbe (4,7%) und Bergbau (1,7%) nur marginale Anteile aufweisen. Energieeffizienzmaßnahmen im verarbeitenden Gewerbe stellen damit einen wichtigen Hebel zur Reduktion des industriellen Energieverbrauchs dar.

Das zentrale Forschungsparadigma fokussiert auf „Energy Waste“ – operationalisiert als der quantifizierbare Energieverbrauch oberhalb des theoretisch minimal erforderlichen Niveaus für definierte Wertschöpfungsprozesse. Im weiteren Verlauf wird der Begriff „Energieverschwendung“ dafür verwendet. Analysen dokumentieren, dass 20–40% der Gesamtenergie in industriellen Systemen als technisch vermeidbare Verschwendung klassifiziert werden können, während zusätzliche 40–70% auf prozessnotwendige, jedoch nicht direkt wertschöpfende Funktionen entfallen (Schmitt et al., 2025). Laut Cullen & Allwood (2010) liegt die globale Effizienz der Primärenergie-zu-Nutzenergie-Konversion lediglich bei 11%.

Niederländische Studien zeigen, dass trotz 15% Einsparpotenzial nur 70% der Firmen entsprechende Investitionen durchführten (Bremer et al., 2024). Lange Amortisationszeiten und unklare ROI-Perspektiven verhindern Investitionsentscheidungen trotz nachgewiesener Einsparpotenziale (Cagno et al., 2013).

Ein kritischer Aspekt ist die Diskrepanz zwischen prognostizierten und realisierten Energieeinsparungen in der industriellen Praxis. Analysen dokumentieren, dass Effizienzmaßnahmen ohne systematisches Energiemanagement häufig deutlich hinter den Prognosen zurückbleiben, wobei diese Realisierungslücke auf fehlerhafte Annahmen über Nutzungsprofile, unzureichende Implementierungsqualität und vernachlässigte Verhaltenseffekte zurückzuführen ist (Gerarden et al., 2017). Im Gegensatz dazu realisieren Organisationen mit Energiemanagementsystemen im Mittel 11% jährliche Einsparungen des Gesamtenergieverbrauchs innerhalb der ersten Implementierungsjahre und erreichen eine um 165% erhöhte Implementierungsrate von Effizienzmaßnahmen gegenüber konventionellen Ansätzen (Schützenhofer, 2021; IEA, 2025). Diese systematische Herangehensweise verkürzt Amortisationszeiten signifikant und validiert die Wirtschaftlichkeit strukturierter Energiemanagement-Implementierungen.

KI-gestützte Technologien sind in der Lage, Ineffizienzen in Echtzeit zu identifizieren und die Energieverschwendung in industriellen Anwendungen um bis zu 20% zu reduzieren (Bera et al., 2025).

In produktionstechnischen Systemen manifestiert sich Energieverschwendung durch fragmentierte Datenarchitekturen, heterogene Maschinenparks ohne einheitliche Kommunikationsprotokolle sowie das Fehlen integrierter, modellbasierter Optimierungsalgorithmen. Besonders kritisch erweisen sich Nebenaggregate wie pneumatische, hydraulische oder thermische Konditionierungssysteme, deren Energiebedarf häufig den der primären Produktionsprozesse übersteigt und eine physikalisch-basierte Modellierung, kontinuierliche diagnostische Überwachung sowie intelligente Regelungsstrategien erfordert (Diaz et al., 2019; Kulterer et al., 2019; Wolf et al., 2024).

Etablierte normative Frameworks wie ISO 50001:2018 definieren zwar organisatorische Strukturen für Energiemanagement, adressieren jedoch digitale Schlüsseltechnologien ausschließlich auf konzeptioneller Ebene und sind überwiegend auf deskriptives Monitoring beschränkt – bedingt durch unzureichende Datenqualität, fehlende semantische Interoperabilität zwischen heterogenen Systemarchitekturen sowie mangelhafte Integration in operative Produktionsleitsysteme und strategische Enterprise-Resource-Planning-Systeme (Meng et al., 2018; Mohamed et al., 2019; Schmitt et al., 2025). Digital Twins, KI-gestützte Prognosemodelle oder Cyber-Physische Systeme finden kaum systematische

Berücksichtigung (Barenji et al., 2021; Wang et al., 2022), obwohl IoT-basierte Sensornetze für granulare Echtzeitdatenerfassung und physikalisch-informierte digitale Zwillinge eine quantitative Analyse komplexer Energieflüsse ermöglichen (Meng et al., 2018; Flórez-Orrego et al., 2023).

Diese Diskrepanz zwischen regulatorischen Anforderungen, vorhandenen Energiemanagementlösungen und technologischen Implementierungsmöglichkeiten konstituiert eine kritische Forschungslücke. Die systematische Integration dieser Industrie 4.0-Technologien erfordert ein strukturiertes, fundiertes Framework, das physikalische Grundprinzipien mit digitalen Technologien methodisch verknüpft und den paradigmatischen Übergang von reaktiven zu proaktiven, selbstadaptiven Energiesystemen unterstützt (Barenji et al., 2021).

1.1 Forschungsfrage

Wie kann ein physikalisch fundiertes Framework die systematische Reduktion von Energy Waste in industriellen Produktionssystemen durch Integration von Industrie 4.0 Technologien ermöglichen?

F1: Welche technologischen Säulen müssen integriert werden, um Energieverschwendung quantifizierbar zu reduzieren?

F2: Wie kann das Framework den ROI von Energieeffizienzmaßnahmen verbessern?

Hypothese: Die systematische Integration von Industrie 4.0-Technologien ermöglicht eine wesentlich stärkere Reduktion der Energieverschwendung bei gleichzeitig verbesserter Wirtschaftlichkeit, als dies durch aktuelle Monitoring-basierte-Energiemanagementsysteme möglich ist.

2 Methodik – Systematische Literaturanalyse

Zur Identifikation der technologischen Säulen des Energieeffizienz 4.0-Frameworks wurde eine systematische Literaturanalyse durchgeführt.

Suchstrategie: Die Literaturrecherche erfolgte in der Datenbank Google Scholar für den Zeitraum 2015-2025. Dieser Zeitrahmen wurde gewählt, um die Entwicklung von Industry 4.0-Technologien seit der deutschen Digitalisierungsinitiative systematisch zu erfassen.

Suchstrings: Die Recherche basierte auf drei kombinierten Suchstrings:

- "energy waste" AND manufacturing AND (digitalization OR "industry 4.0" OR "smart manufacturing")
- Energieeffizienz AND Produktion AND ("Digitalisierung" OR "Industrie 4.0")
- energy efficiency AND manufacturing AND (digitalization OR "industry 4.0" OR "smart manufacturing")

Auswahlkriterien: Einschluss von peer-reviewten Publikationen in englischer und deutscher Sprache. Ausschluss von Büchern und nicht-wissenschaftlichen Quellen.

Bewertungsverfahren: Zweistufiges Screening durch Titel-/Abstract-Analyse, gefolgt von Volltext-Bewertung anhand einer vierstufigen Relevanzskala (0=irrelevant bis 3=Kernpublikation). Die thematische Kategorisierung erfolgte mittels qualitativer Inhaltsanalyse zur Identifikation wiederkehrender technologischer Komponenten.

Ergebnisse: Von 75 identifizierten Publikationen wurden 10 als Kernpublikationen (Relevanz 3) für die vertiefte Auswertung klassifiziert. Die Analyse ergab fünf zentrale technologische Säulen, die als Grundlage des entwickelten Frameworks dienen.

3 Ergebnisse

3.1 Framework „Energieeffizienz 4.0“

Das Framework „Energieeffizienz 4.0“ in Abbildung 1 integriert physikalische Grundprinzipien, Modellierungsmethoden und Wirtschaftlichkeit systematisch mit digitalen Technologien zur ganzheitlichen Optimierung von Produktionssystemen. Energieflüsse in technischen Systemen folgen physikalischen Gesetzmäßigkeiten– nur durch deren explizite Berücksichtigung, durch die adäquate Modellierung lassen sich Ineffizienzen zuverlässig identifizieren und nachhaltige Optimierungsmaßnahmen entwickeln. Weiters sind Maßnahmen nur umsetzbar, wenn diese Wirtschaftlich attraktiv sind. Das Framework basiert strukturell auf fünf technologischen Säulen, die durch ein fünfstufiges Prozessmodell systematisch vernetzt werden. Die technologischen Säulen umfassen: (1) Dateninfrastrukturen für die granulare, echtzeitfähige Erfassung und Verwaltung von Energiedaten, (2) Standardisierungs- und Interoperabilitätsmechanismen für die nahtlose systemübergreifende Integration, (3) Maschinelles Lernen (ML) für prädiktive Analysen , Anomalieerkennung und datenbasierte Modellierung, (4) Digital Twins zur physikalisch-fundierten Modellierung und Simulation und Echtzeitvergleich (5) Cyber-Physische Systeme für die autonome Ausführung der Optimierungsmaßnahmen. Der strukturierte fünfstufige Prozess vernetzt diese technologischen Säulen methodisch: (1) Problemerkennung – systematische Erkennung von Energieineffizienzen durch datengestützte Monitoring-Systeme, (2) Ursachenanalyse – physikalisch-fundierte Identifikation und Quantifizierung von Ineffizienzen, (3) Lösungsentwicklung – modellbasierte Konzeption und Simulation von Optimierungsmaßnahmen, (4) Implementation – technische Umsetzung der entwickelten Lösungen in Cyber-Physischen Systemen und (5) Evaluation und kontinuierliche Verbesserung. Das erreichbare Effizienzsteigerungspotenzial ist dabei vom digitalen Reifegrad des Unternehmens abhängig, d.h. welche der fünf technologischen Säulen bereits implementiert sind und wie effektiv diese in der Praxis umgesetzt wurden.

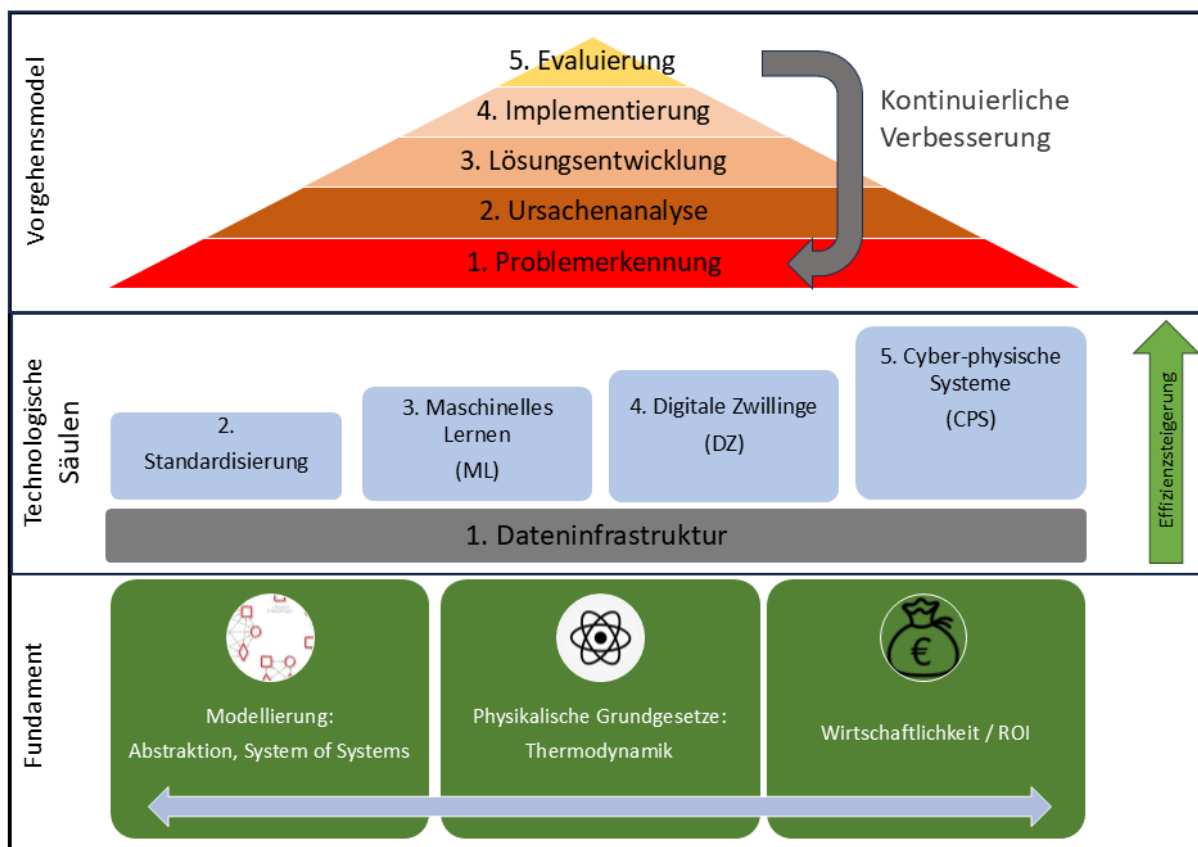


Abbildung 1: Framework Energieeffizienz 4.0.

3.1.1 Fundament der Energieeffizienz

Die physikalischen Gesetze bilden die Basis für die systematische Analyse und Optimierung von Energieflüssen in Produktionssystemen. Die Integration thermodynamischer Prinzipien mit digitalen Technologien ermöglicht eine umfassende Effizienzsteigerung gegenüber konventionellen, rein empirischen Energiemanagement-Ansätzen (Yasuri, 2025). Die physikalisch fundierte Modellierung übernimmt dabei im Sinne der pragmatischen Ersetzungsfunktion von Modellen (Stachowiak, 1973) eine Schlüsselrolle und ermöglicht eine belastbare ROI- und Risikobewertung, indem Energieverluste und Einsparpotenziale quantifiziert sowie über Echtzeit-Monitoring fortlaufend gegen Performance Gaps validiert und nachgeführt werden (Trianni et al., 2014; May et al., 2015).

Modellierung

Nach Stachowiak (1973) erfüllen Modelle eine pragmatische Ersetzungsfunktion für spezifische Optimierungsaufgaben. Diese Modelltheorie bildet die Grundlage für die systematische Modellierung industrieller Energiesysteme, wobei Energieflussmodelle als vereinfachte Abbilder realer Produktionsprozesse dienen. Die pragmatische Funktion zielt auf Energieoptimierungsaufgaben ab: Energieverschwendung identifizieren, Effizienzpotenziale quantifizieren und wirtschaftlich realisierbare Optimierungsmaßnahmen ableiten. Die

Modellierung erfolgt unter definierten ROI-Randbedingungen, um die Diskrepanz zwischen prognostizierten und realisierten Energieeinsparungen zu minimieren.

Physikalisch fundierte Modellierungsansätze und Validierung: Die Modellierung energetischer Prozesse erfordert thermodynamisch konsistente Beschreibung der Energieumwandlungen mit Erhaltungsgesetzen als strukturierende Prinzipien (Dincer & Rosen, 2001). Asrai et al. (2018) demonstriert dies durch ein mechanistisches White-Box-Modell für CNC-Werkzeugmaschinen mit 0,67% RMS-Fehler. Mechanistische Modelle bieten physikalisch interpretierbare Parameter mit definierten Gültigkeitsbereichen, während datengetriebene Ansätze höhere Flexibilität bei reduzierter Extrapolationsfähigkeit ermöglichen. Die Modellvalidierung erfordert systematische Unsicherheitsquantifizierung (UQ) zur Bewertung von Parameter-, Struktur- und Eingangsunsicherheiten.

Sparsamkeitsprinzip und System-of-Systems: Das Sparsamkeitsprinzip reduziert überflüssige Komplexitäten durch minimalen Modellaufwand bei maximaler Informationsgewinnung (Sober, 1981). Bacher & Madsen (2011) implementieren dies mittels Grey-Box-Modellen, die physikalisches Vorwissen mit datengetriebener Parametrierung kombinieren. Laut Bermeo-Ayerbe et al. (2022) kann die Gesamtsystemeffizienz durch Multipurpose-Energiemodelle gesteigert werden, in indem diese Modelle externen Systemen wie z.B. Energiemanagement, Diagnosesystemen und Vorhersagesystemen zur Verfügung stellt werden.

Moderne Produktionsanlagen erfordern eine hierarchische System-of-Systems-Architektur (May et al., 2015), da die Eigenschaften komplexer Netzwerke nur durch Mehrschicht-Modellierung erfassbar sind. Die hierarchische Strukturierung folgt ISO 20140-5 (2024): operative Modelle für Komponenten-Regelung (ms-s), taktische Modelle für Subsystem-Optimierung (min-h) und strategische Modelle für System-Planung (Tage-Monate). Multi-Scale-Modellierung ermöglicht konsistente Kopplung verschiedener Abstraktionsebenen bei optimaler Balance zwischen Modellkomplexität und praktischer Umsetzbarkeit (Tan et al., 2021).

Interoperabilität: Digital Twin-Architekturen implementieren System-of-Systems-Modelle durch Bidirektionalität zwischen physischem System und digitalem Abbild (Flórez-Orrego et al. 2023). Barenji et al., 2021) während (Wang et al. 2022) systematische Frameworks für Smart Manufacturing entwickelt.

"Knowledge Graphs bilden die Brücke zwischen physikalischen Modellen und datengetriebenen Ansätzen, wobei LLM-Integration kontextualisierte Wissensabfragen ermöglicht (Theuner et al. 2025). OPC Foundation et al. (2025) definiert eine standardisierte Spezifikation das Management des Energieverbrauchs. DataOps-Ansätze gewährleisten kontinuierliche Qualitätssicherung durch automatisierte Metriken für Datenvalidität, -vollständigkeit und -aktualität als Grundlage aller Modellierungsebenen. Diese prozessorientierte Methodologie integriert Best Practices aus DevOps, agiler Entwicklung und Etablierung robuster Data Pipelines mit automatisierten Alarm-Mechanismen um schneller Erkenntnisse aus den Daten zu gewinnen (Munappy et al., 2020).

Physikalische Grundgesetze

Der Energieverbrauch industrieller Produktionsanlagen unterliegt unveränderlichen physikalischen Gesetzmäßigkeiten – den Hauptsätzen der Thermodynamik und den Prinzipien der Exergie-Analyse (Dincer & Rosen, 2001; Haseli, 2020). Rein datengetriebene Big Data-Ansätze ohne physikalische Fundierung stoßen daher an fundamentale Grenzen der Interpretierbarkeit und Generalisierbarkeit (Bermeo-Ayerbe et al., 2022). Diese Erkenntnis spiegelt sich in der wachsenden Forschungsaktivität zu Physics-informed ML wider (Raissi et al., 2019; Zhao et al., 2025), das physikalische Gesetzmäßigkeiten systematisch in Lernalgorithmen integriert und dabei Vorhersagegenauigkeit, physikalisch konsistente Ergebnisse und Dateneffizienz verbessert.

Der Erste Hauptsatz der Thermodynamik – Energie wird nicht verbraucht, sondern umgewandelt – bildet das übergeordnete Rahmenwerk für alle Energieeffizienzbetrachtungen. Cullen & Allwood (2010) nutzen diese Fundierung für ihre exergiebasierte Effizienzanalyse, die nicht nur die Energiemenge, sondern auch die Energiequalität berücksichtigt. Die Exergieeffizienz $\varepsilon = \text{Exergieoutput}/\text{Exergieinput}$ ermöglicht den objektiven Vergleich unterschiedlicher Energiekonversionsgeräte.

Der Zweite Hauptsatz der Thermodynamik setzt die fundamentalen Obergrenzen jeder Umwandlung (z.B. Wärme \rightarrow Arbeit). Irreversibilitäten durch Reibung, Mischung, Drosselung oder endliche Temperaturdifferenzen erzeugen Entropie und reduzieren die maximal erreichbare Effizienz.

Die von Cullen & Allwood (2010) identifizierten Verlustmechanismen zeigen die quantitative Bedeutung dieser physikalischen Prinzipien: Wärmeübertragung verursacht über 40% der globalen Energieverluste, gefolgt von Verbrennungsprozessen mit 30%.

Die Anwendung des Energieeffizienz 4.0 Frameworks erfordert die Integration relevanter physikalischer Gesetzmäßigkeiten in ML-Algorithmen entsprechend der jeweiligen Anwendungsdomäne. In der Strömungsmechanik bilden die Navier-Stokes-Gleichungen und die Impulserhaltung die theoretische Grundlage für die Optimierung von Fluid- und Pneumatiksystemen. Physics-informed Neuronale Netze (PINNs) implementieren diese Constraints durch erweiterte Verlustfunktionen (Raissi et al., 2019).

Für thermische Prozesse werden das Fourier'sche Gesetz, das Newton'sche Abkühlungsgesetz und das Stefan-Boltzmann-Gesetz herangezogen. Die elektrotechnischen Komponenten industrieller Anlagen erfordern die Anwendung des Ohm'schen Gesetzes und der Maxwell-Gleichungen. Mechanische Bewegungs- und Kraftübertragungsprozesse werden durch die Newton'schen Gesetze charakterisiert, während für die energetische Bewertung von Verbrennungsprozessen Reaktionsenthalpien und die Gibbs-Energie als thermodynamische Größen verwendet werden. Die Berücksichtigung der physikalischen Gesetzmäßigkeiten in ML-Modellen gewährleistet thermodynamisch konsistente Vorhersagen auch bei begrenzten Trainingsdaten.

Wirtschaftlichkeit / ROI

Wirtschaftliche Machbarkeit fungiert als unveränderliches Constraint aller Energieeffizienz-Betrachtungen, analog zu thermodynamischen Hauptsätzen. Ohne positive ROI-Perspektive finden auch technisch scheinbar optimale Lösungen keine Anwendung. Das Fundament integriert Return on Investment (ROI) als fundamentales Bewertungskriterium, während Echtzeit-Monitoring die Leistung der umgesetzten Lösung kontinuierlich prüft (Trianni et al., 2014; May et al., 2015).

Die Kostenbetrachtung erfordert die Berücksichtigung versteckter Faktoren. So können durch Technologiewandel Investitionen vorzeitig entwerten (Stranded Assets), während Mitarbeiterschulungen für Cyber-Physische Systeme substantielle, oft unterschätzte Kostenblöcke darstellen. Dynamische Energiepreise, regulatorische Änderungen und technologische Obsoleszenz verstärken zusätzlich die belastbare ROI-Abschätzung. Empirische Untersuchungen zeigen, dass wirtschaftliche und organisatorische Barrieren die Implementierung von Energieeffizienzmaßnahmen erheblich verzögern (Cagno et al., 2013). Daher sind eine robuste Risikobewertung und die schrittweise Integration entscheidend.

Das physikalische Fundament bildet das unverzichtbare Gerüst für die erfolgreiche Implementierung von Energieeffizienz 4.0 in industriellen Produktionssystemen. Die systematische Integration thermodynamischer Prinzipien, zielgerichteter Modellierung (Asrai et al., 2018), intelligenter Komplexitätsreduktion (Sober, 1981; Bacher & Madsen., 2011) und systemischer Monitoring-Ansätze (Vikhorev et al., 2012; Tan et al., 2021) lassen sich die Grundlagen für die digitale Transformation industrieller Energiesysteme schaffen um robuste, generische, skalierbare und wirtschaftlich attraktive Lösungen zu erhalten.

3.1.2 Technologische Säulen der Energieeffizienz

Dateninfrastruktur

Energieoptimierung erfordert eine durchgängige digitale Infrastruktur als Grundlage für energetische Transparenz. Zentrale Bestandteile umfassen skalierbare IoT-, Cloud/Fog- und Big-Data-Architekturen (Meng et al., 2018), hochauflösende Messsysteme (Bermeo-Ayerbe et al., 2022; Wolf et al., 2024) sowie eine durchgängige OT/IT-Integration (Mohamed et al., 2019).

Real-time-Energieoptimierung erfordert niedrige Latenzzeiten für kritische Regelkreise, die durch Edge-basierte lokale Verarbeitung realisiert werden, um Netzwerkbedingte Verzögerungen zu vermeiden (Naeem et al., 2025). Cloud-Computing bietet überlegene Rechenkapazität für komplexe ML-Modelle, während hybride Architekturen Edge-basierte Sofortentscheidungen mit Cloud-basierten strategischen Optimierungen kombinieren (Wang, Y. et al., 2025).

Die gewählte Monitoring-Ebene (Maschine, Linie, Werk) bestimmt fundamental die Effektivität von Energieeffizienzmaßnahmen. Vikhorev et al. (2013) entwickelten ein Energiemanagement-Framework, das mittels Echtzeit-Messung und systematischer Datenanalyse die Energietransparenz in Produktionssystemen steigert und damit die Grundlage für evidenzbasierte Effizienzmaßnahmen schafft. Interoperabilität zwischen

Produktions- und energiebezogenen Systemen ermöglicht die Identifikation von System-of-Systems Ineffizienzen, die auf isolierter Maschinenbetrachtung nicht erkennbar wären (Flórez-Orrego et al., 2023).

Die Heterogenität industrieller Kommunikationsprotokolle stellt eine zentrale Barriere für die nahtlose Datenintegration dar (Mohamed et al., 2019). Brownfield-Implementierungen erfordern kostenintensive Gateway-Lösungen für Modbus, PROFIBUS und proprietäre Systeme, die die Echtzeitfähigkeit durch zusätzliche Latenzzeiten beeinträchtigen können (Sain et al., 2025). Legacy-Systeme benötigen spezialisierte OPC UA Aggregations-Server für sichere Datenbrücken zwischen isolierten Sicherheitszonen, wodurch die Komplexität der Systemarchitektur erheblich steigt (OPC Foundation et al., 2025).

Kulterer (2019) identifizierte Smart Motor Sensors als zentrale Komponenten, die Magnetfeld, Temperatur und Vibrationen messen, während drahtlose Strom- und Spannungssensoren verschiedene Leistungsparameter überwachen. Diese Sensorik ermöglicht die parallele Nutzung derselben Infrastruktur für Energieeffizienz- und Condition Monitoring (Bermeo-Ayerbe et al., 2022).

Hochauflösende Messsysteme mit Frequenzbereichen von 1 Hz bis 40 kHz erfassen transiente Zustände, um Schaltvorgänge und Betriebszustandswechsel zu identifizieren sowie Abweichungen vom Normverhalten frühzeitig zu detektieren (Wolf et al., 2024; Bermeo-Ayerbe et al., 2022).

Digitale Zwillinge

Die systematische Kopplung physikalischer Modelle mit Maschinellen Lernen ermöglicht die Entwicklung digitaler Prozessabbilder, die energiebezogene Diagnose, Multi-Szenario-Analysen und die algorithmische Ableitung energieoptimierter Betriebsmodi unterstützen (Mohamed et al., 2019; Barenji et al., 2021). Digital Twins fungieren als Cyber-Physische Repräsentationen realer Produktionssysteme und gewährleisten die bidirektionale Verbindung zwischen physischen und digitalen Entitäten für Informationsaustausch, Visualisierung, Monitoring und Management (Arowoia et al., 2024). Sie ermöglichen die Echtzeitsimulation, quantitative Evaluierung und kontinuierliche Optimierung industrieller Prozesse zur systematischen Steigerung der Energieeffizienz (Mohamed et al., 2019).

Flórez-Orrego et al. (2023) beschreiben das Konzept des "Industrial Digital Energy Twin" als Ansatz zur Optimierung industrieller Prozesse durch integrierte Energiemodellierung. Die von Barenji et al. (2021) implementierte Architektur folgt dem ISA-95-Standard und umfasst drei funktionale Ebenen: Physikalische Ebene (reale Roboterkomponenten mit Sensorintegration), Virtuale Ebene (CAD-Modelle, MATLAB-basierte Simulation, kinematische und dynamische Modelle) sowie Digitale Datenaustauschebene (bidirektionale Echtzeitdatenverbindung zwischen physischen und virtuellen Komponenten). Die kinematische Modellierung ermöglicht die mathematische Berechnung energieoptimaler Trajektorien basierend auf Newton-Euler-Formulierungen.

Digital Twins ermöglichen nicht nur die reaktive Optimierung bestehender Prozesse, sondern auch die proaktive Analyse systematischer Energieverschwendung durch kontinuierliche Soll-Ist-Vergleiche (Flórez-Orrego et al., 2023; Barenji et al., 2021). Wang et al. (2022) dokumentieren die Anwendung digitaler Zwillinge für Energiemanagement. Kulterer (2019)

demonstriert, dass Digital Twins durch die kontinuierliche Vergleichsmöglichkeit zwischen realem Betrieb und Modellzuständen Transparenz für energieoptimierte Betriebsführung schaffen.

Barenji et al. (2021) entwickelten eine Digital Twin-Methode für Roboterzellen, die autonome Entscheidungsfindung, Echtzeitsimulation und energetische Analyse realisiert. Die Methode basiert auf einem agentenbasierten Entscheidungsmodell welches ermöglichte die Energieeffizienz bei Pick-and-Place-Operationen um bis zu 7,7% zu steigern.

Maschinelles Lernen (ML)

Potentiale und Grenzen datengetriebener Ansätze: Datengetriebene Verfahren transformieren die industrielle Energieoptimierung durch automatische Identifikation komplexer Energieverbrauchsmuster ohne explizites Prozesswissen. ML-Methoden nutzen Produktionsdaten zur adaptiven Modellbildung und ermöglichen energieeffiziente Systeme auch bei heterogenen Maschinenparks unbekannter Spezifikationen (Tan et al., 2021; Bermeo-Ayerbe et al., 2022).

Da der Energieverbrauch unveränderlichen physikalischen Gesetzmäßigkeiten unterliegt (Dincer & Rosen, 2001), stoßen rein datengetriebene Ansätze oft an fundamentale Grenzen der Interpretierbarkeit und Generalisierbarkeit. Komplexe ML-Modelle neigen zur Überanpassung und bilden physikalische Zusammenhänge unzureichend ab, diese sind jedoch für die robuste Generalisierung essentiell ist. Der klassische Bias-Variance-Tradeoff zeigt, dass Modelle ein Gleichgewicht zwischen Unter- und Überanpassung finden müssen - reich genug, um zugrundeliegende Datenstrukturen zu erfassen, aber einfach genug, um falsche Muster zu vermeiden (Belkin et al., 2019). Diese Erkenntnisse unterstützen das Parsimony-Prinzip, das die einfachste Struktur fordert die den Zweck erfüllt (Sober, 1981).

Privacy: Federated Learning ermöglicht kollaborative Modellentwicklung zwischen Industriepartnern ohne Preisgabe sensibler Betriebsdaten. Multi-Agent Federated Reinforcement Learning (MARL-FL) Frameworks demonstrieren erfolgreiche Implementierung unter GDPR-Compliance (Rahmati, 2025), während Bonura et al. (2021) validierte Privacy-preserving federated ML in realen Fertigungsumgebungen ohne zentrale Datenaggregation demonstriert.

Process Mining und Fehlererkennung: Process Mining-Algorithmen analysieren Ereignislogs zur automatischen Erkennung fehlerhafter Produktionsabläufe durch Maschinendefekte oder menschliches Fehlverhalten. ML-basierte Process Mining-Frameworks und Deep Neural Networks steigern die Anomalieerkennungsgenauigkeit. Shi et al. (2024) entwickeln den Trend-Value Fusion Process Mining (TVPM) Ansatz, der durch Kombination von Datentrends mit Mittelwerten eine Repräsentation industrieller Prozessereignisse ermöglicht. Diese Fusionsmetrik erfasst komplexe Details operativer Events, während ein neuartiger Algorithmus Verhaltensmuster und Sequenzinformationen extrahiert. Bei einer Roboterapplikation erreichte Holtz et al. (2025) mit einem active learning Ansatz zur Anomalieerkennung eine um 59% höhere Genauigkeit (F1-Score) als unüberwachtes Lernen. Trend-Value Process Mining (TVPM) Methoden kombinieren Symbolic Aggregate Approximation mit Trend-Diskrimination zur robusten Erkennung

industrieller Prozessanomalien, wodurch operative und energetische Optimierungspotentiale systematisch erschlossen werden (Wang et al., 2024).

Tan et al. (2021) implementieren das MIGRATE Framework, das maschinenspezifische Energieprofile aus zentralen Stromnetzen durch Non-Intrusive Load Monitoring (NILM) extrahiert. Dieser Ansatz reduziert die erforderliche Sensorinfrastruktur erheblich und verbessert gleichzeitig die Systemtransparenz durch zentrale Datenerfassung.

Adaptive Modellierung und Anwendungsfelder: Concept-Drift-Erkennung stellt robuste Energieprognosen trotz Maschinenalterung sicher. Bermeo-Ayerbe et al. (2022) demonstrierten Fit-Raten von 82% bei adaptiven Modellen, während nicht-adaptive Ansätze weniger als 66% erreichten.

ML-Verfahren ermöglichen die Modellierung transienter Betriebszustände wie Hochlauf-, Umschalt- und Stillstandsphasen, deren energetische Ineffizienzen substantielle Optimierungspotenziale bieten. Hybride Ansätze integrieren Echtzeitprozessdaten mit physikalischen Simulationsmodellen zur kontinuierlichen Anomalieerkennung und frühzeitigen Identifikation energetischer Ineffizienzen (Tan et al., 2021). ML-basierte Condition-Monitoring-Systeme steigern die operative Energieeffizienz durch präventive Wartungsstrategien und frühzeitige Fehlererkennung (Bermeo-Ayerbe et al., 2022; Geng & Evans, 2022).

Large Language Models: Large Language Models ermöglichen die automatisierte Auswertung komplexer Energiedaten und generieren Empfehlungen in natürlicher Sprache für Optimierungsmaßnahmen unter simultaner Berücksichtigung technischer und wirtschaftlicher Constraints. Die Integration von Knowledge Graphs mit LLMs schafft einen robusten Rahmen für das Management und die Analyse komplexer Daten, der Unternehmen hilft, intelligente Systeme zu entwickeln, die präzise und kontextrelevante Informationen zur richtigen Zeit über verschiedene Domänen hinweg liefern (Ibrahim et al., 2024). Durch die semantische Verknüpfung von strukturiertem Domänenwissen ermöglichen LLM-Knowledge-Graph-Systeme eine kontextualisierte Wissensabrufung, die so die Genauigkeit, das Verständnis und das domänenspezifische Wissen verbessert, was besonders für ingenieurstechnische Anwendungen relevant ist (Theuner et al., 2025).

Herausforderungen und systematische Lösungsansätze: Charakteristische Herausforderungen des ML-Einsatzes in der industriellen Energieeffizienz umfassen begrenzte und domänenspezifische Datenbasis, hohe Systemkomplexität sowie mangelnde Generalisierbarkeit zwischen verschiedenen Anlagen und Prozessen (Bermeo-Ayerbe et al., 2022; Geng & Evans, 2022; Schmitt et al., 2025).

Systematische Lösungsansätze zur Überwindung dieser Herausforderungen: (1) Physics-informed ML zur Integration physikalischer Constraints um den erforderlichen Datenbedarf zu reduzieren und die und um die Modellrobustheit zu verbessern (Raissi et al., 2019; Zhao et al., 2025), (2) Parsimony-Prinzip für optimierte Sensorik und robustere Modelle mit minimaler Komplexität (Sober, 1981), (3) systematisches Feature Engineering zur Abstraktion relevanter Prozesscharakteristika und Zustandserkennung (Tan et al., 2021; Holtz et al., 2025), (4) Multi-Purpose-Ansätze zur ROI-Optimierung durch kombinierte Energieeffizienz- und Condition-Monitoring-Funktionalitäten (Bermeo-Ayerbe et al., 2022; Shi et al., 2024), sowie (5) Federated Learning für datenschutzkonformes, herstellerübergreifendes Lernen bei begrenzter Datenverfügbarkeit (Rahmati, 2025; Mehta et al., 2024).

Cyber-Physische Systeme (CPS)

Die enge Integration von Maschinen, Peripheriesystemen, Steuerungstechnik, IoT-Infrastrukturen und digitalen Diensten führt zu echtzeitfähigen, vernetzten und lernfähigen Energiesystemen. Diese verbinden Monitoring, Diagnose, Optimierung und autonome Eingriffe in einem integrierten System-of-Systems-Ansatz (Meng et al., 2018; Mohamed et al., 2019; Barenji et al., 2021; Ghobakhloo & Fathi, 2021). Moderne CPS ermöglichen adaptive Mensch-Maschine-Interfaces, die Weiterentwicklung der reaktiven Dashboards zu interaktiven Optimierungsumgebungen (Schmitt et al., 2025). Diese Systeme berücksichtigen die Personalentscheidungen in Echtzeit-Energieentscheidungen, während ML aus menschlichen Eingriffen lernt und die Automatisierung anpasst.

CPS ermöglichen auf allen Fertigungsebenen (Maschinen-, Linien-, Anlagenebene) die Informationsnutzung und führen zur Auflösung der traditionellen Automatisierungspyramide hin zu lokal gesteuerten Modulen ohne Hierarchie. CPS ermöglichen Regelungsstrategien durch Lastspitzenreduktion, Lastprofilglättung und Lastreduktion mittels optimierungsbasierter Algorithmen, die die Gesamtlastnachfrage minimieren. MPC-Regler für selektives Ein-/Ausschalten von Peripheriegeräten haben als Regelungsstrategie zur Verbesserung der Energieeffizienz an Bedeutung gewonnen. CPS ermöglichen robustere Steuerungssysteme, die in Echtzeit reagieren und durch globale Vernetzung Kooperation über Systemgrenzen hinweg ermöglichen (Diaz & Ocampo-Martinez, 2019).

Standardisierung

Regulatorische Rahmenbedingungen: Die EU-Taxonomie für nachhaltige Aktivitäten etabliert spezifische technische Bewertungskriterien für Energieeffizienz in industriellen Tätigkeiten und fordert quantifizierbare Nachweise zu Klimaschutzziele (Europäisches Parlament und Rat der Europäischen Union, 2020). Das Framework unterstützt diese Anforderungen durch systematische Energieleistungsindikatoren und kontinuierliches Monitoring gemäß der EU-Energieeffizienz-Richtlinie (Europäisches Parlament und Rat der Europäischen Union, 2023). Die Integration von Digital Twins und ML-basierten Prognosen ermöglicht die erforderliche Dokumentation von Energieeffizienzverbesserungen für Taxonomie-Konformität.

Normative Defizite und semantische Standardisierung: ISO 50001:2018 etabliert systematische Energiemanagement-Frameworks, fokussiert jedoch primär auf organisatorische Strukturen ohne spezifische Implementierungsrichtlinien für digitale Technologien (May et al., 2015). ISO 50006 definiert Energieleistungskennzahlen, während ISO 20140 Bewertungsmethoden für Fertigungssysteme spezifiziert. Diese Normen vernachlässigen jedoch technologische Aspekte wie semantische Interoperabilität, prädiktive Analysen und hybride Optimierungslogiken. Die systematische Integration heterogener Systeme erfordert daher erweiterte semantische Modelle: IEC 62264 (ISA-95) definiert hierarchische Informationsmodelle, Cullen & Allwood (2010) entwickeln Taxonomien für Energieumwandlungsprozesse, und OPC Foundation et al. (2025) operationalisiert diese Grundlagen durch maschinenlesbare Spezifikationen für das Management des Energieverbrauchs. DataOps-Ansätze gewährleisten kontinuierliche Qualitätssicherung durch

automatisierte Metriken für Datenvalidität, -vollständigkeit und -aktualität (Munappy et al., 2020).

Reifegrad: Schmitt et al. (2025) identifizierten ein strukturiertes Sechs-Stufen-Modell digitaler Energieeffizienz: Computerization, Connectivity, Visibility, Transparency, Predictive Capacity und Adaptability. Geng & Evans (2022) etablierten Energy Value Stream Mapping (EVSM) als Standardmethode zur Energiefluss.

3.1.3 Das Dach der Energieeffizienz: Fünfstufiges Prozessmodell

Das Prozessmodell basiert auf bewährten Methoden zur kontinuierlichen Verbesserung und integriert Industrie 4.0-Technologien in einen Plan-Do-Check-Act-basierten Optimierungszyklus (Trianni et al., 2014). Methodisch fundiert folgt das Modell etablierten Energieeffizienz-Frameworks mit strukturierter Multi-Level-Optimierung (Schmitt et al., 2025) und unterstützt die Implementierung normkonformer Energiemanagement-Systeme durch die Digitalisierung der Energieeffizienz-Prozesse.

Stufe 1: Problemerkennung

Die Identifikation von Energieeffizienzen erfolgt durch kontinuierliche Datenaufzeichnung und systematischen Vergleich mit theoretischen Minimalverbrauchswerten (Meng et al., 2018; Bermeo-Ayerbe et al., 2022). Die Problemerkennung differenziert zwischen theoretischen und praktisch realisierbaren Einsparpotenzialen durch Digital Twin-Simulationen, die operative Constraints berücksichtigen (Flórez-Orrego et al., 2023).

Säulen-Orchestrierung: Dateninfrastrukturen erfassen kontinuierlich multimodale Energieverbrauchsdaten, Digital Twins dienen als physikalisch-basierte Referenzmodelle, ML analysiert automatisiert Anomalien. Die ISO 20140-Normenserie bietet den umfassenden Rahmen für systematische Energieeffizienz-Bewertungen.

Stufe 2: Ursachenanalyse

Root Cause Analysis erfolgt durch systematische Ursachen-Wirkungs-Analyse mittels DMAIC-Framework, welches das Ishikawa-Diagramm (6M-Kategorisierung: Mensch, Maschine, Material, Methode, Messung, Umgebung) mit der 5-Why-Methode zur Ursachenrückverfolgung kombiniert (Falcon et al., 2012). Moderne RCA-Ansätze integrieren zunehmend Expertenwissen mit datengetriebenen ML-Modellen, um sowohl Interpretierbarkeit als auch automatisierte Mustererkennung zu ermöglichen (Pietsch et al., 2024).

Säulen-Orchestrierung: Digital Twins simulieren Ursachen-Szenarien aus dem Ishikawa-Diagramm, ML identifiziert kausale Zusammenhänge mittels Transfer-Entropie-Analyse und Granger-Kausalität in Energieverbrauchsdaten, Cyber-Physische Systeme validieren Kausalitäten durch Prozessinterventionen. Kontinuierliches Monitoring ermöglicht Echtzeit-Anomalieerkennung kritischer Einflussgrößen. Systementropie-Analyse quantifiziert Energieverschwendung durch thermodynamische Betrachtung (Haseli, 2020; Tshivhi, 2024).

Stufe 3: Lösungsentwicklung

Die entwickelten Modelle berücksichtigen thermodynamischen Gesetzmäßigkeiten (Dincer & Rosen, 2001; Haseli, 2020) und begrenzen den Lösungsraum auf physikalisch realisierbare Szenarien. ROI-Constraints bestimmen die praktische Umsetzbarkeit unter Anwendung des Parsimony-Prinzips für minimale Modellkomplexität (Sober, 1981).

Säulen-Orchestrierung: ML generiert Multi-Objective-Optimierungsvorschläge, Digital Twins simulieren Szenarien unter Berücksichtigung von Investitions- und Betriebskosten. Die Integration von Large Language Models mit Knowledge Graphs schafft einen robusten Rahmen für die Analyse komplexer Optimierungsaufgaben und ermöglicht kontextualisierte, interpretierbare Lösungsentwicklung (Ibrahim et al., 2024; Theuner et al., 2025) unter simultaner Berücksichtigung technischer und wirtschaftlicher Machbarkeitsgrenzen.

Stufe 4: Implementierung

Die Implementierung umfasst Datenerfassungserweiterung, Einrichtung der Konnektivitätslösungen, die Implementierung der Algorithmen im Cyber-physischen System und die Integration in bestehende Unternehmensprozesse entsprechend etablierter Energiemanagement-Praktiken (Mohamed et al., 2019; Ghobakhloo & Fathi, 2021).

Säulen-Orchestrierung: Cyber-Physische Systeme führen entwickelte Lösungen aus, Standardisierung ermöglicht nahtlose Integration, Digital Twins überwachen kontinuierlich, ML-Modelle adaptieren Implementierungsstrategien basierend auf Echtzeit-Feedback und Messwerten.

Stufe 5: Evaluierung

Die parallele Echtzeit-Erfassung von Energiekosteneinsparungen und laufenden Systemkosten dokumentiert die Diskrepanz zwischen prognostizierten und realisierten Effizienzgewinnen (May et al., 2015). Energetische und exergetische Analysemethoden bewerten quantitative und qualitative Aspekte der Energieeffizienzverbesserungen (Dincer & Rosen, 2001).

Säulen-Orchestrierung: Alle Säulen wirken synergetisch zusammen – kontinuierliche Erfolgskennzahlen-Erfassung, Ist-Soll-Vergleiche, Modell-Drift-Erkennung, dynamische Regelungsanpassung, objektive Bewertungskriterien (Trianni et al., 2014). Change-Management durch strukturierte Schulungskonzepte (Schmitt et al., 2025).

Kontinuierliche Verbesserung

-Erkenntnisse verbessern automatisch Anomalie-Detektionsalgorithmen (ML-Säule), verfeinerte Ursachenmodelle ermöglichen präzisere Digital Twins und zielgerichtetere Lösungsentwicklung. Optimierte Implementierungen liefern höher qualitative Sensordaten und umfangreichere Trainingsdatensätze, wodurch nachfolgende ML-Optimierungszyklen kontinuierlich an Leistung gewinnen.

3.1.4 Demonstration am Beispiel Druckluftsysteme

Die Optimierung industrieller Druckluftsysteme demonstriert die Anwendung des "Energieeffizienz 4.0"-Frameworks.

Problemerkennung: Die Druckluftherzeugung weist mit einem Systemwirkungsgrad von typischerweise 10-15% eine hohe Energieintensität auf, wobei Leckagen, Druckverluste und Anwendungseffizienzen die Energiekosten zusätzlich signifikant erhöhen.

Ursachenanalyse: Das physikalische Fundament der Druckluftbereitstellung lässt sich über die polytropische Kompressionsarbeit beschreiben; in der Praxis ist die elektrische Aufnahmeleistung bei gegebenem Druckniveau wesentlich durch den zeitvariablen Volumenstrom $\bar{V}_T(t)$ bestimmt. Für die Ursachenanalyse wird daher die Dynamik des Durchflusses genutzt: Aktive Verbraucher erzeugen zeitliche Lastwechsel, während Leckagen und Grundlasten bei stabilem Netzdruck näherungsweise stationär sind.

Als dimensionslose Kenngröße dient der Variationskoeffizient über ein gleitendes Zeitfenster der Länge T:

$$v_T = \frac{s_T}{\bar{V}_T}$$

mit den Definitionen:

$$s_T = \sqrt{\frac{1}{N-1} \sum_{k=1}^N (V_k - \bar{V}_T)^2}$$

$$\bar{V}_T = \frac{1}{N} \sum_{k=1}^N V_k$$

Variablen:

v_T – Variationskoeffizient über Zeitfenster der Länge T[-]

s_T – Standardabweichung des Volumenstroms im Zeitfenster [m³/min]

\bar{V}_T – arithmetischer Mittelwert des Volumenstroms im Zeitfenster [m³/min]

V_k – Volumenstrom zum Messzeitpunkt k [m³/min]

N – Anzahl der Messwerte im Zeitfenster T [-]

T – Länge des Zeitfensters

Klassifikation basierend auf Zeitfenster-Mittelung: Aktive Prozesse: $v_T > 0,5$
Leakagedominierte Zustände $v_T < 0,15$

Lösungsentwicklung: Die Säulen-Integration umfasst hochauflösende Durchflusssensorik mit OPC-UA-Übertragung, ML-Algorithmen adaptieren die Schwellenwerte v_{Leck} und V_{max} , sowie Cyber-Physische Systeme zur automatisierten Ventilsteuerung. Der Digital Twin bildet das Druckluftnetz Modell ab und prognostiziert kontinuierlich den zu erwartenden Volumenstrom und den Volumenstrom, der sich ohne Segmentabschaltung ergeben hätte (Zustand vor der Einführung der Maßnahme).

In der detaillierten Darstellung konzentrieren wir uns hier nur auf die Umsetzung der Abschaltung im Cyber-Physische Systeme.

Abschaltkriterium für Segment **i** (alle Bedingungen über Zeitfenster der Länge **T**):

$$(v_{T,i} < v_{Leck}) \wedge (\bar{V}_{T,i} < V_{max}) \wedge (\Delta t > t_{min})$$

Variablen:

$v_{T,i}$ – Variationskoeffizient von Segment **i** über Zeitfenster der Länge **T** [–]

v_{Leck} – Grenzwert für Leckagen dominierte Zustände

$\bar{V}_{T,i}$ – mittlerer Volumenstrom von Segment **i** über Zeitfenster der Länge **T** [m³/min]

V_{max} – Volumenstrom-Schwellenwert [m³/min]

Δt – verstrichene Zeit seit Erfüllung der ersten beiden Bedingungen [min]

t_{min} – Mindestwartezeit vor Abschaltung [min]

T – Länge des Analysezeitfensters (typisch 15 min)

Implementierung: Ein Durchflusssensor pro Netzwerksegment ermöglicht die kontinuierliche Messung von $V(t)$ mit einer Abtastrate von 1 Hz. Die v_T -Berechnung erfolgt über gleitende Zeitfenster der Länge $T=15$ min zur Zustandserkennung. Leckagedominierte bzw. inaktive Bereiche werden über $v_{T,i} < 0,15$ in Kombination mit $\bar{V}_{T,i} < V_{max}$ identifiziert; Trennventile erlauben die automatische Abschaltung solcher Segmente nach Mindestwartezeit t_{min} und reduzieren damit Leckagenverluste sowie unnötige Kompressorarbeit. Die Implementierung des Algorithmus erfolgt auf einer Middleware mit integrierten OPC UA Konnektoren.

Systemparameter:

Messintervall: $\Delta t_{mess} = 1s$

Länge des Analysezeitfensters: $T=15$ min

Anzahl der Messwerte pro Zeitfenster: $N=900$ [–]

Volumenstrom-Schwellenwert: $V_{max} = 0,1$ m³/min

Mindestwartezeit: $t_{min} = 5$ min

Aktualisierungsintervall (gleitendes Fenster): $\Delta t_{update} = 1min$

Grenzwert für Leckagendominierte Zustände: $v_{Leck} = 0,15$

Als Trainingsdaten für die durch ML adaptierten Schwellwerte dienen historische Betriebszustände mit zugeordneten Labels (aktiv/inaktiv/Leckage), die während einer initialen Kalibrierungsphase erfasst werden.

In einer initialen Kalibrierungsphase lernt der Digital Twin die charakteristischen Verbrauchsmuster ohne automatische Abschaltungen; anschließend wird im laufenden Betrieb der Baseline-Verbrauch prognostiziert.

Evaluierung: Digital Twins vergleichen systematisch Soll- mit Istverbrauch und liefern die Einsparungen in Echtzeit, durch Vergleich mit dem hypothetischen Verbrauch (ohne Abschaltung). Die Einsparungen werden in Echtzeit auf einem Dashboard visualisiert, wodurch der Return-on-Investment transparent nachweisbar wird.

3.1.5 Limitationen des Frameworks

Das vorgestellte Energieeffizienz 4.0 Framework basiert auf einer Literaturrecherche von 75 wissenschaftlichen Publikationen zu den technologischen Säulen. Diese selektive Analyse ermöglichte eine tiefgreifende Betrachtung der Kernkomponenten, schränkt jedoch die Erfassung peripherer Technologieentwicklungen ein. Ergänzende Literatur zur physikalischen, wirtschaftlichen Fundierung und Modellierung erweitert die theoretische Basis, eine systematische Review nach PRISMA-Richtlinien über alle relevanten Disziplinen hinweg steht noch aus.

Die Betonung technologischer Aspekte vernachlässigt die Tatsache, dass Produktionsunternehmen komplexe sozio-technische Systeme darstellen, in denen Menschen und Maschinen interagieren. Das Framework adressiert unzureichend organisationale Faktoren, Akzeptanzbarrieren und die erforderliche Qualifikationsentwicklung der Mitarbeiter.

Das Framework bietet eine limitierte Betrachtung komplexer Kostenstrukturen und ROI-Berechnungen. Dynamische Energiepreise, regulatorische Änderungen und technologische Obsoleszenz werden unzureichend diskutiert. Gleichzeitig macht die Übertragung der Daten solche Systeme angreifbar für Cyberangriffe, was entsprechende Cybersicherheits-Maßnahmen erfordert (Meng et al., 2018).

Eine Demonstration der Framework-Anwendung in der Praxis steht noch aus. Weitere Beispielanwendungen für unterschiedliche Industriezweige, Unternehmensgrößen und regionale Kontexte sind erforderlich, um die Generalisierbarkeit und praktische Relevanz zu validieren.

4 Schlussfolgerungen und Ausblick

Das entwickelte "Energieeffizienz 4.0" Framework etabliert einen systematischen Ansatz zur Integration von Industrie 4.0-Technologien in die industrielle Energieoptimierung und adressiert damit die kritische Herausforderung, dass die Produktion für 34% der globalen CO₂ Emissionen verantwortlich ist, während bestehende Optimierungsansätze die verfügbaren digitalen Technologien unzureichend nutzen (Geng & Evans, 2022).

4.1 Zentrale Erkenntnisse

F1: Welche technologischen Säulen müssen integriert werden, um Energieverschwendung quantifizierbar zu reduzieren?

Dateninfrastrukturen bilden das unverzichtbare Fundament, ML nützt Daten für intelligente Optimierungsvorschläge, Digital Twins ermöglichen physikalisch-fundierte Modellierung und Simulation, und Cyber-Physische Systeme führen autonome Optimierungen aus (Meng et al., 2018; Barenji et al., 2021; Tan et al., 2021).

F2: Wie kann das Framework den ROI von Energieeffizienzmaßnahmen verbessern?

Das Framework reduziert Prognoseunsicherheiten durch physikalische Fundierung, ermöglicht modulare Implementierung mit sofortigen Teileinsparungen, reduzierte Modellkomplexität bei gleichbleibender Vorhersagequalität, Echtzeit-Monitoring der Einsparungen und maximiert Investitionseffizienz durch Multipurpose-Infrastrukturen, die gleichzeitig Energieeffizienz, Vorausschauende Wartung und Qualitätssicherung unterstützen. Weiters unterstützt es die Anwendung bei begrenzter Datenverfügbarkeit durch die physikalische Fundierung.

4.2 Ausblick

Physics-informed ML gewinnen an Bedeutung für industrielle Energiesysteme. Physics-informed Neural Networks (PINNs) haben ihre Leistungsfähigkeit für wärmeübertragungsdominierte Multiphysiksysteme nachgewiesen (Zhao et al., 2025). Die Kombination mit dateneffizienten Active-Learning-Architekturen für Anomalieerkennung (Holtz et al., 2025) könnte den Messaufwand weiter minimieren, erfordert jedoch Anpassung an industrielle Randbedingungen. Praktische Implementierungen KI-gestützter Energieoptimierung demonstrieren bereits signifikante Erfolge: Eine Pilotstudie von Siemens in Deutschland erreichte durch den Einsatz von AI für Demand Response und Vorausschauende Wartung eine Reduktion des Energieverbrauchs in Fertigungsanlagen um 15%, während Big-Data-Analytics in industriellen Anwendungen Ineffizienzen in Echtzeit identifizieren und die Energieverschwendung um bis zu 20% reduzieren können (Bera et al., 2025).

Die Standardisierung der Dateninfrastruktur schreitet mit der OPC UA Spezifikation Power Consumption Management voran (OPC Foundation et al., 2025). Semantische Knowledge Graphs in Verbindung mit Large Language Models (Theuner et al., 2025; Ibrahim et al., 2024) – ermöglichen kontextualisierte Energiedatenanalyse, bedürfen jedoch energiedomänenspezifischer Ontologien.

Digitale Zwillinge entwickeln sich entsprechend strukturierter Reifegradmodelle. Das Sustainable Digital Twin Maturity Path Framework (Sajadieh & Noh, 2025) definiert progressive Stufen von Datenerfassung bis KI-gestützter Entscheidungsfindung. Der globale Digital-Twin-Markt wird laut Marktforschung von geschätzten 21,14 Mrd. USD (2025) auf projizierte 149,81 Mrd. USD (2030) wachsen, was einer durchschnittlichen jährlichen Wachstumsrate (CAGR) von 47,9% entspricht (MarketsandMarkets, 2025). Industrial Digital Energy Twins (Rubio-Rico et al., 2023), ML-Energieprognosen (Bermeo-Ayerbe et al., 2022) und mehrstufige ML-Frameworks (Tan et al., 2021) bilden die technologische Grundlage.

Datenschutz Kollaborationstechnologien ermöglichen unternehmensübergreifenden Wissensaustausch. Federated Learning zeigt 5,01% Kostenreduktion und 4,60% Emissionsminderung in Gebäudeenergiesystemen im Vergleich zu normalen Reinforcement Learning Methoden (Sievers et al., 2024), sowie Anwendbarkeit in Human-Robot Collaboration (Rahmati, 2025) und Additive Manufacturing (Mehta et al., 2024). Die Übertragung auf Energiemanagement – kollaboratives Training von Benchmark-Modellen ist methodisch plausibel, erfordert jedoch branchenspezifische Anpassungen. Datenschutztechnologien (Bonura et al., 2021) schaffen Grundlagen für kollaborative Wertschöpfungskettenoptimierung (Ghobakhloo & Fathi, 2021). ML-Techniken mit Fully Homomorphic Encryption ermöglichen herstellerübergreifende Vorhersage von Bauteilgeometrien mit bis zu 96% Verbesserung gegenüber isoliertem Lernen (Mehta et al., 2024), wobei eine methodische Übertragung solcher Ansätze auf kollaborative Energieoptimierung plausibel erscheint.

Adoptionsbarrieren bleiben substanziell. Trotz durchschnittlich 11% Energieeinsparungen bei Energiemanagementsystemen (IEA, 2025) werden Effizienzmaßnahmen nicht systematisch priorisiert (Bremer et al., 2024; Cagno et al., 2013). Hohe Anfangsinvestitionen, Fachkräftemangel und Komplexitätsbarrieren hemmen den Industrial Energy Efficiency Markt (Bera et al., 2025). Systematische Analysen identifizieren dabei ein mehrdimensionales Barrierensystem: Neben finanziellen Hürden erschweren technologische Integrationsprobleme – insbesondere die Anpassung bestehender Infrastrukturen an neue energieeffiziente Technologien – sowie regulatorische Unsicherheiten hemmen die Investitionsbereitschaft. Kultureller Widerstand gegen Verhaltensänderungen, unzureichendes Bewusstsein über finanzielle und ökologische Einsparpotenziale sowie eingeschränkter Zugang zu energieeffizienten Produkten und Dienstleistungen in ländlichen oder unterentwickelten Regionen verstärken diese Implementierungslücke (Bera et al., 2025).

Für die systematische Ursachenanalyse von Energieineffizienzen gewinnen hybride Ansätze an Bedeutung, die Explainable KI-Methoden (SHAP, LIME) mit Expertenwissen kombinieren: White-Box-Modelle wie Bayesian Networks und Association Rule Mining ermöglichen verständliche Ursachendiagnosen, wobei Human-in-the-Loop-Ansätze die Zuverlässigkeit der Anomalieerkennung in komplexen Produktionssystemen signifikant erhöhen (Pietsch et al., 2024).

Offene Forschungsfragen betreffen eine systematische automatisierte Energieverschwendungs-Identifikation für alle wesentlichen Systemklassen auf unterschiedlichen Monitoring-Ebenen (Gerät, Linie, Werk) und die Kombination entropiebasierter Innovationen (Yasuri, 2025) mit Exergieanalyse (Tshivhi, 2024; Haseli, 2020) für verbesserte Effizienzabschätzungen bei reduziertem Messaufwand.

5 Referenzen

Arowoiya, V. A., Moehler, R. C., & Fang, Y. (2024). Digital twin technology for thermal comfort and energy efficiency in buildings: A state-of-the-art and future directions. *Energy and Built Environment*, 5(5), 641–656. <https://doi.org/10.1016/j.enbenv.2023.05.004>

Asrai, I., Newman, S. T., & Nassehi, A. (2018). A mechanistic model of energy consumption in milling. *International Journal of Production Research*, 56(1–2), 642–659. <https://doi.org/10.1080/00207543.2017.1404160>

Bacher, P., & Madsen, H. (2011). Identifying suitable models for the heat dynamics of buildings. *Energy and Buildings*, 43(7), 1511–1522. <https://doi.org/10.1016/j.enbuild.2011.02.005>

Barenji, A. V., Liu, X., Guo, H., & Li, Z. (2021). A digital twin-driven approach towards smart manufacturing: Reduced energy consumption for a robotic cell. *International Journal of Computer Integrated Manufacturing*, 34(7–8), 844–859. <https://doi.org/10.1080/0951192X.2020.1775297>

Belkin, M., Hsu, D., Ma, S., & Mandal, S. (2019). Reconciling modern machine-learning practice and the classical bias–variance trade-off. *Proceedings of the National Academy of Sciences*, 116(32), 15849–15854.

Bera, M., Das, S., Garai, S., Dutta, S., Choudhury, M. R., Tripathi, S., & Chatterjee, G. (2025). Advancing energy efficiency: innovative technologies and strategic measures for achieving net zero emissions. *Carbon Footprints*, 4(1), N-A.

Bermeo-Ayerbe, M. A., Ocampo-Martinez, C., & Diaz-Rozo, J. (2022). Data-driven energy prediction modeling for both energy efficiency and maintenance in smart manufacturing systems. *Energy*, 238, Art. 121691. <https://doi.org/10.1016/j.energy.2021.121691>

Bonura, S., Carbonare, D. D., Díaz-Morales, R., Fernández-Díaz, M., Morabito, L., Muñoz-González, L., ... & Purcell, M. (2021). Privacy-Preserving Technologies for Trusted Data Spaces. In *Technologies and Applications for Big Data Value* (pp. 111–134). Cham: Springer International Publishing.

Bremer, L., den Nijs, S., & de Groot, H. L. (2024). The energy efficiency gap and barriers to investments: Evidence from a firm survey in The Netherlands. *Energy Economics*, 133, 107498.

Cagno, E., Worrell, E., Trianni, A., & Pugliese, G. (2013). A novel approach for barriers to industrial energy efficiency. *Renewable and Sustainable Energy Reviews*, 19, 290–308. <https://doi.org/10.1016/j.rser.2012.11.007>

Cullen, J. M., & Allwood, J. M. (2010). Theoretical efficiency limits for energy conversion devices. *Energy*, 35(5), 2059–2069. <https://doi.org/10.1016/j.energy.2010.01.036>

- Diaz, J. L., & Ocampo-Martinez, C. (2019). Energy efficiency in discrete-manufacturing systems: Insights, trends, and control strategies. *Journal of Manufacturing Systems*, 52, 131–145. <https://doi.org/10.1016/j.jmsy.2019.05.002>
- Dincer, I., & Rosen, M. A. (2001). Energy, Entropy and Exergy Concepts and Their Roles in Thermal Engineering. *Entropy*, 3(3), 116-149. <https://doi.org/10.3390/e3030116>
- Falcon, R. G., Alonso, D. V., Fernández, L. G., & Pérez-Lombard, L. (2012). Improving energy efficiency in a naphtha reforming plant using Six Sigma methodology. *Fuel processing technology*, 103, 110-116.
- Rahmati, M. (2025). Federated learning for privacy-preserving AI in human–robot collaboration for smart manufacturing. *Journal of Intelligent Manufacturing and Special Equipment*.
- Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- Europäisches Parlament und Rat der Europäischen Union. (2020). Verordnung (EU) 2020/852 des Europäischen Parlaments und des Rates vom 18. Juni 2020 über die Einrichtung eines Rahmens zur Erleichterung nachhaltiger Investitionen und zur Änderung der Verordnung (EU) 2019/2088. *Amtsblatt der Europäischen Union*, L 198/13. <https://eur-lex.europa.eu/eli/reg/2020/852/oj>
- Europäisches Parlament und Rat der Europäischen Union. (2023). Richtlinie (EU) 2023/1791 des Europäischen Parlaments und des Rates vom 13. September 2023 zur Energieeffizienz und zur Änderung der Verordnung (EU) 2023/955 (Neufassung). *Amtsblatt der Europäischen Union*, L 231/1. <https://eur-lex.europa.eu/legal-content/DE/TXT/?uri=CELEX:32023L1791>
- Eurostat. (2025, July 25). Final energy consumption in industry - detailed statistics. *Statistics Explained*. https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Final_energy_consumption_in_industry_-_detailed_statistics
- Rubio-Rico, A., Mengod-Bautista, F., Lluna-Arriaga, A., Arroyo-Torres, B., & Fuster-Roig, V. (2023). The industrial digital energy twin as a tool for the comprehensive optimization of industrial processes. *Processes*, 11(8), 2353.
- Geng, D., & Evans, S. (2022). A literature review of energy waste in the manufacturing industry. *Computers & Industrial Engineering*, 173, Art. 108713. <https://doi.org/10.1016/j.cie.2022.108713>
- Gerarden, T. D., Newell, R. G., & Stavins, R. N. (2017). Assessing the energy-efficiency gap. *Journal of economic literature*, 55(4), 1486-1525.
- Ghobakhloo, M., & Fathi, M. (2021). Industry 4.0 and opportunities for energy sustainability. *Journal of Cleaner Production*, 295, Art. 126427. <https://doi.org/10.1016/j.jclepro.2021.126427>
- Haseli, Y. (2020). *Entropy Analysis in Thermal Engineering Systems*. Elsevier. ISBN: 978-0-12-819168-2
- Ibrahim, N., Aboulela, S., Ibrahim, A., & Kashef, R. (2024). A survey on augmenting knowledge graphs (KGs) with large language models (LLMs): models, evaluation metrics, benchmarks, and challenges. *Discover Artificial Intelligence*, 4(1), 76.

International Energy Agency. (2025). Industrial facilities could save billions by implementing energy management. IEA Commentary. Retrieved from <https://www.iea.org/commentaries/industrial-facilities-could-save-billions-by-implementing-energy-management>

ISO. (2024). ISO 20140-5:2024 Automation systems and integration — Evaluating energy efficiency and other factors of manufacturing systems that influence the environment — Part 5: Environmental performance evaluation data. International Organization for Standardization.

Sievers, J., Henrich, P., Beichter, M., Mikut, R., Hagenmeyer, V., Blank, T., & Simon, F. (2025). Federated reinforcement learning for sustainable and cost-efficient energy management. *Energy and AI*, 100521.

Kulterer, K. (2019). Industrie 4.0 Loesungen fuer Energieeffizienz in Motorsystemen. In Proc. Internationale Energiewirtschaftstagung (IEWT), Wien, Austria.

MarketsandMarkets. (2025). Digital twin market by deployment (PaaS, SaaS), application (product design & development, predictive maintenance, performance monitoring, business optimization), industry (automotive & transportation, oil & gas) and region - Global forecast to 2030 (Report No. TC 7094). <https://www.marketsandmarkets.com/Market-Reports/digital-twin-market-225269522.html>

May, G., Barletta, I., Stahl, B., & Taisch, M. (2015). Energy management in production: A novel method to develop key performance indicators for improving energy efficiency. *Applied Energy*, 149, 46-61. <https://doi.org/10.1016/j.apenergy.2015.03.065>

Mehta, M., Bimrose, M. V., Mcgregor, D. J., King, W. P., & Shao, C. (2024). Federated learning enables privacy-preserving and data-efficient dimension prediction and part qualification across additive manufacturing factories. *Journal of Manufacturing Systems*, 74, 752-761.

Meng, Y., Yang, Y., Chung, H., Lee, P.-H., & Shao, C. (2018). Enhancing sustainability and energy efficiency in smart factories: A review. *Sustainability*, 10(12), Art. 4779. <https://doi.org/10.3390/su10124779>

Mohamed, N., Al-Jaroodi, J., & Lazarova-Molnar, S. (2019). Leveraging the capabilities of Industry 4.0 for improving energy efficiency in smart factories. *IEEE Access*, 7, 18008–18020. <https://doi.org/10.1109/ACCESS.2019.2897045>

Munappy, A. R., Mattos, D. I., Bosch, J., Olsson, H. H., & Dakkak, A. (2020, June). From ad-hoc data analytics to dataops. In *Proceedings of the International Conference on Software and System Processes* (pp. 165-174).

Naeem, A. B., Senapati, B., Rasheed, J., Baili, J., & Osman, O. (2025). An intelligent job scheduling and real-time resource optimization for edge-cloud continuum in next generation networks. *Scientific Reports*, 15. DOI: 10.1038/s41598-025-25452-z

Sain, D., Rosenstatter, T., Saßnick, O., Schäfer, C., & Huber, S. (2026). Secure Data Bridging in Industry 4.0: An OPC UA Aggregation Approach for Including Insecure Legacy Systems. arXiv preprint arXiv:2601.10929.

Holtz, D., Kaymakci, C., Leuthe, D., Wenninger, S., & Sauer, A. (2025). A data-efficient active learning architecture for anomaly detection in industrial time series data. *Flexible Services and Manufacturing Journal*, 1-32.

OPC Foundation, PROFIBUS Nutzerorganisation e.V., ODVA, & VDMA. (2025). OPC UA Companion Specification for Power Consumption Management. Automation.com. Retrieved from <https://www.automation.com/en-us/articles/may-2025/optimizing-energy-savings-innovative-standards>

Pietsch, D., Matthes, M., Wieland, U., Ihlenfeldt, S., & Munkelt, T. (2024). Root Cause Analysis in Industrial Manufacturing: A Scoping Review of Current Research, Challenges and the Promises of AI-Driven Approaches. *Journal of Manufacturing and Materials Processing*, 8(6), 277. <https://doi.org/10.3390/jmmp8060277>

Sajadieh, S. M. M., & Noh, S. D. (2025). A Review of Digital Twin Integration in Circular Manufacturing for Sustainable Industry Transition. *Sustainability*, 17(16), 7316. <https://doi.org/10.3390/su17167316>

Schmitt, T., Mattsson, S., Flores-Garcia, E., & Hanson, L. (2025). Achieving energy efficiency in industrial manufacturing. *Renewable and Sustainable Energy Reviews*, 216, Art. 115619. <https://doi.org/10.1016/j.rser.2025.115619>

Shi, Y., Zhang, N., Song, X., Li, H., & Zhu, Q. (2024). Novel approach for industrial process anomaly detection based on process mining. *Journal of Process Control*, 136, 103165.

Sober, E. (1981). The principle of parsimony. *The British Journal for the Philosophy of Science*, 32(2), 145-156. <https://doi.org/10.1093/bjps/32.2.145>

Schützenhofer, C. (2021). Overcoming the efficiency gap: energy management as a means for overcoming barriers to energy efficiency, empirical support in the case of Austrian large firms. *Energy Efficiency*, 14(5), 45.

Stachowiak, H. (1973). *Allgemeine Modelltheorie*. Springer-Verlag, Wien.

Tan, D., Suvarna, M., Tan, Y. S., Li, J., & Wang, X. (2021). A three-step machine learning framework for energy profiling, activity state prediction and production estimation in smart process manufacturing. *Applied Energy*, 291, Art. 116808. <https://doi.org/10.1016/j.apenergy.2021.116808>

Theuner, K., Elmgren, T. M., Götling, A., May, M. C., & Akay, H. (2025). Weaving Knowledge Graphs and Large Language Models (LLMs): Leveraging Semantics for Contextualized Design Knowledge Retrieval. *Procedia CIRP*, 134, 1125-1130.

Trianni, A., Cagno, E., & De Donatis, A. (2014). A framework to characterize energy efficiency measures. *Applied Energy*, 118, 207-220. <https://doi.org/10.1016/j.apenergy.2013.12.042>

Tshivhi, K. S. (2024). Entropy generation analysis and optimization of cooling systems in industrial and engineering operations. *Heat Transfer*, 53(2), 733-754.

Vikhorev, K., Greenough, R., & Brown, N. (2012). An advanced energy management framework to promote energy awareness. *Journal of Cleaner Production*, 43, 103-112. <https://doi.org/10.1016/j.jclepro.2012.12.012>

Wang, Y., Kang, X., & Chen, Z. (2022). A survey of digital twin techniques in smart manufacturing and management of energy applications. *Green Energy and Intelligent Transportation*, 1(2), Art. 100014. <https://doi.org/10.1016/j.geits.2022.100014>

Wolf, C., Umgelter, D., Schneider, C., & Sauer, A. (2024). Von der Datenerfassung zur Energie-Effizienz: Messsysteme im Fokus der Energieeffizienzoptimierung. In Proc. Symposium Energieinnovation, Graz, Austria.

Yasuri, A. K. (2025). Harnessing Entropy: Innovations in Energy Efficiency and Sustainability. *Sustainable Futures*, 100952.

Zhao, Z., Wang, Y., Zhang, W., Ba, Z., & Sun, L. (2025). Physics-informed neural networks in heat transfer-dominated multiphysics systems: A comprehensive review. *Engineering Applications of Artificial Intelligence*, 157, 111098.