

KI im Energiemanagement

1	Ganzheitliche Energiestrategie 2026	3	Digitale Energiemanagement-Software
2	Strukturierte Energiebeschaffung	4	ISO 50001, Regulatorik & Industriestrompreis
2.1	Power Purchase Agreements (PPAs)	5	KI im Energiemanagement

KI-Taxonomie – Einordnung relevanter Begriffe

Begriffshierarchie

- **Künstliche Intelligenz** – Oberbegriff: Maschinen lösen Aufgaben, die menschliche Intelligenz erfordern
- **Machine Learning (ML)** – KI lernt aus Daten, ohne explizit programmiert zu werden
- **Neural Networks / Deep Learning** – Schichtenbasierte Modelle für komplexe Mustererkennung
- **Generative KI** (z. B. Claude, ChatGPT) – Erstellt neue Inhalte auf Basis von Trainingsdaten

Für Energiemanagement relevante Modelle

- **NLP & Computer Vision** – bekannteste KI-Anwendungsfälle (ChatGPT etc.), aber für EnM Nebenschauplatz
- **Zeitreihenprognose (TSF)** – Hauptfokus für Energiemanagement
- **LSTM (Long Short-Term Memory)** – Erster großer Durchbruch für Zeitreihen
- **Transformer** – Goldstandard für komplexe Vorhersagen, Grundlage moderner KI
- **MLP (Multi-Layer-Perceptron)** – Einfacher Einstieg, besser als klassische ARIMA-Modelle

Von Energiedaten zu Mehrwerten

Forecasting

Fortschrittliche Analytik zur genauen Vorhersage des Energieverbrauchs – Effizienz optimieren und Kostenrisiken abwenden

Insight

Unregelmäßigkeiten in Energieprozessen frühzeitig erkennen – Risiken minimieren und Effizienz des Systems maximieren

Analytics

CO₂-Bilanz in Echtzeit überwachen und kontinuierlich verbessern – Nachhaltigkeitsziele erreichen und übertreffen


Decision Support

Fundierte und optimierte Entscheidungen mit datenbasierten Anwendungen – strategische Vorteile mathematisch optimal sichern

Neural Networks – Aufbau & Lernprozess

Aufbau & Black-Box-Problem

- Neuronen = Wegpunkte, die Zahlen zwischen 0,0 und 1,0 speichern
- Versteckte Layer = Zwischenschritte: je mehr Layer, desto mehr wird „nachgedacht“
- Große KI-Modelle: Milliarden an Parametern (als Matrix gespeichert)
- **Black-Box:** Wir kennen die Zahlen, aber sie sagen uns nichts → immer mit Domänenwissen prüfen
- Lernziel: Fehler minimieren (wie Kurvendiskussion) · Lokaler ≠ globaler Tiefpunkt → Hyperparameter-Tuning
- Datenaufteilung: Training (~70 %) · Testing (~20 %) · Evaluation (~10 %)



KI im Energiemanagement

KI-gestützte Lastspitzenprognose – Beispielanwendung Fraunhofer IPA

Frühzeitige Identifizierung von Lastspitzen mit intelligenten Algorithmen – Evaluierung des unternehmensspezifischen Potenzials zur Lastspitzenreduktion und flexible Steuerung der Intervalle.

① Dateneingabe	② Datenvorverarbeitung	③ Prognose mit ML	④ Ergebnis
<ul style="list-style-type: none"> Historische Verbrauchsdaten Standortspezif. Daten Wetterdaten Kalender Produktionsdaten 	<ul style="list-style-type: none"> Bereinigung & Normalisierung Behandlung fehlender Werte Konsistenzprüfung Zeitreihenaufbereitung „Mist rein = Mist raus“ 	<ul style="list-style-type: none"> LSTM / Transformer Modell Training (~70 %), Testing (~20 %), Evaluation (~10 %) Hyperparameter-Tuning Prognose-Nachbearbeitung 	<ul style="list-style-type: none"> Anteil erkannter Lastspitzen Erreichbare Reduktion der Spitzenlast Auswahl der Intervalle Maßnahmenempfehlung

Datenqualität als Grundgerüst – Hindernisse in der Praxis

Warum Datenvorverarbeitung entscheidend ist

- Gute Prognosemodelle benötigen **saubere, vollständige, konsistente** Daten
- Energiedaten sind immer **Zeitreihendaten** – zukünftige Punkte hängen von vergangenen ab (autoregressive Eigenschaften)
- Spezielle Modelle nötig: klassische statistische Methoden (ARIMA) reichen nicht mehr aus
- Ein sauberer Lastgang reicht als Einstieg – keine 100 Untermessungen nötig

Häufige Hindernisse (Energieeffizienz-Index dt. Industrie)

- 64 %** – Fehlende Zeit für Datenaufbereitung
- 51 %** – Fehlende technische Voraussetzungen
- 48 %** – Fehlende finanzielle Mittel
- Besonders KMU ohne automatisierte Datenerfassung betroffen
- Positive Nachricht:** Anteil an einzelnen Maschinen vergleichsweise hoch → Einstieg mit einem Standort möglich

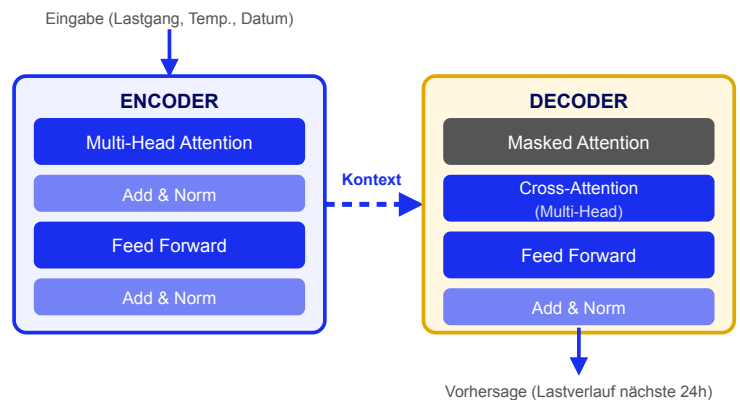
LSTM & Transformer – Architektur & Funktionsweise

LSTM – Long Short-Term Memory

Erster großer Durchbruch für Zeitreihenprognose

- Gezielte Speicherung wichtiger Muster, Verwerfen unwichtiger Informationen
- Cell State** = Langzeitgedächtnis: löst das Kernproblem einfacher Netze – Informationsverlust bei langen Zeitreihen
- Forget Gate (σ):** Entscheidet, welche Informationen aus dem Cell State vergessen werden
- Input Gate ($\sigma + \tanh$):** Wählt neue, speicherungswürdige Informationen aus
- Output Gate (σ):** Bestimmt, welcher Teil des Cell State als Ausgabe h_n weitergegeben wird
- Bildet Tagesgang, Wochenrhythmus & saisonale Schwankungen gleichzeitig ab
- Erkennt Relevanz von Temperatur, Uhrzeit & Feiertagen automatisch – keine manuelle Vorgabe nötig

Transformer – Goldstandard für komplexe Vorhersagen



- Encoder:** Komprimiert Eingabedaten (Lastgang, Temperatur, Datum) in wesentliche Muster
- Decoder:** Erzeugt Vorhersage schrittweise auf Basis des Encoder-Kontexts
- Multi-Head Attention:** Analysiert Zusammenhänge parallel aus mehreren Perspektiven – ein Kopf für Tagesrhythmus, einer für Wochenstruktur
- Bezieht gleichzeitig letzten Dienstag, gestrigen Morgen & Feiertage ein – ohne manuelle Vorgabe

KI im Energiemanagement

Vergleich LSTM vs. Transformer

LSTM	Transformer
Sequentielle Verarbeitung (Schritt für Schritt)	Parallele Verarbeitung (alle Zeitpunkte gleichzeitig)
Cell State als Langzeitgedächtnis	Attention berechnet Einflüsse direkt
Stabile Ergebnisse bei wenigen Daten	Bessere Ergebnisse bei vielen Datenpunkten
Langsamer trainierbar, geringere Serveranforderungen	GPU-Training möglich → schneller in Rechenzentren

Beide Modelle keine selbstdenkenden Maschinen – sie geben den statistisch wahrscheinlichsten nächsten Wert aus, basierend auf vergangenen Daten.

Ein typischer Tag als Energiemanager – heute vs. morgen

Aufgabe	Heute (ohne KI)	Morgen (mit KI)
Ankunft / Monitoring	Excel öffnen, hunderte Untermessstellen – Auffälligkeiten werden schlicht nicht entdeckt	System hat über Nacht alle Messstellen geprüft – Sie sehen nur relevante Abweichungen mit Kontext & Handlungsempfehlung
ISO-Dokumentation	Normtexte manuell lesen, Dokumente formulieren – nötiges Spezialwissen fehlt oft	KI-Assistent kennt die Norm, erstellt Entwürfe, prüft Dokumente gegen Anforderungen – Sie kontrollieren & finalisieren
Energiebeschaffung	Entscheidungen nach Bauchgefühl, keine Transparenz über tatsächlichen Endpreis	Live-Marktdaten mit automatischer Meldung bei Preisausreißern – fundierte Basis statt Bauchgefühl
Reporting	Daten aus verschiedenen Excel-Dateien stundenlang zusammensuchen & aufbereiten	Reports und Grafiken automatisch erstellt und aktuell gehalten – Zeit für Interpretation statt Datensammlung

Wo anfangen? – Leitfaden für erste Schritte

- Schritt 1** Use Case identifizieren: Wo verbringen Sie die meiste Zeit mit repetitiver Analyse? Wo fallen Probleme regelmäßig zu spät auf? → Dort zuerst ansetzen.
- Schritt 2** Datengrundlage prüfen: Stammdaten gepflegt? Messstellen korrekt? Ein sauberer Lastgang reicht als Einstieg – keine 100 Untermessungen nötig.
- Schritt 3** Klein starten: Ein Standort, ein Anwendungsfall – nicht „KI-Strategie für alle Werke“. Lernen was funktioniert, dann skalieren.
- Schritt 4** Ergebnisse kritisch prüfen: KI-Ergebnisse immer mit Domänenwissen abgleichen – nie blind vertrauen.

Anwendungsfälle für KI im Energiemanagement

① Anomalie- & Maßnahmenerkennung
Intelligentes Monitoring

- Echtzeit-Anomalieerkennung (Leckagen, Lastspitzen, Fehlfunktionen)
- Mustererkennung im Verbrauchsverhalten
- Frühwarnsystem statt manueller Excel-Kontrolle
- Reduzierte Störzeiten & Energieverluste
- **90 % geringerer manueller Aufwand**
- **80 % des Werts mit 20 % der Komplexität**

② Wissensmanagement & ISO-Dokumentation
KI als Norm-Assistent

- LLMs erklären Normanforderungen verständlich
- Automatische Erstellung von Entwürfen für ISO-Dokumente
- Prüfung bestehender Dokumente gegen Normvorgaben
- Audit-fähige Dokumentstruktur ohne manuellen Aufwand
- Audit-Vorbereitung in Stunden statt Tagen

③ Transparenz in der Energiebeschaffung
Datenbasierte Einkaufsentscheidungen

- KI analysiert komplexe Energiemarktfragen & liefert aktuelle Analysen
- Automatische Meldung bei Preisausreißern
- Unterstützung bei strategischen Beschaffungsentscheidungen
- KI generiert Einkaufsdokumente & Zertifizierungsunterlagen regelkonform

KI im Energiemanagement

Was in der Praxis wirklich funktioniert – Lessons Learned

Einfach anfangen, nicht alles auf einmal

- Anomalieerkennung liefert 80 % des Werts mit 20 % der Komplexität
- Kein Data-Science-Team nötig, um loszulegen

KI als Kommunikationsebene nutzen

- LLMs sind stark im Erklären von Daten und Beantworten von Fragen
- Die eigentliche Analyse bleibt besser deterministisch & nachvollziehbar

Datenqualität vor Algorithmen

- Die meisten KI-Projekte scheitern nicht an der KI – sondern an fehlender oder schlechter Datengrundlage

Transparenz schafft Vertrauen

- Verstehen **warum** eine Anomalie gemeldet wird ist entscheidend für Akzeptanz
- Black-Box-Modelle werden in der Praxis ignoriert

Ausblick – Wohin sich KI im Energiemanagement entwickelt

Proaktiv statt reaktiv

- Systeme empfehlen Maßnahmen, **bevor** Probleme entstehen

Geschlossener Kreis

- Daten → Analyse → Entscheidung → Umsetzung → nachgewiesene Einsparung – durchgängig in einem System

KI als Co-Pilot

- Strategische Entscheidungen bleiben beim Menschen
- KI übernimmt Routineanalysen & Dokumentation

Ihre nächsten Schritte

Schritt 1 **Daten zusammenführen:** Lastgänge und Kontextdaten (Produktionszahlen, Wartungsinfos, Notizen) an einem Ort. Erst der Kontext macht aus Messdaten Entscheidungen.

Schritt 2 **Größten Pain identifizieren:** Wo verbringen Sie die meiste Zeit mit Routinearbeit? Wo fallen Probleme zu spät auf? → Dort zuerst ansetzen.

Schritt 3 **Anfangen mit fertigen Lösungen:** KI im Energiemanagement ist kein Forschungsprojekt mehr – fertige Lösungen funktionieren heute. Fokus auf Anwenden, nicht auf Bauen.

Ihre Referenten



Jan Besler

Wissenschaftlicher Mitarbeiter



E-Mail: jan.besler@ipa.fraunhofer.de
 Adresse: Nobelstraße 12, 70569 Stuttgart
 Website: www.ipa.fraunhofer.de



Jannis Zipp

Product Lead



E-Mail: jannis.zipp@ecoplanet.tech
 Website: www.ecoplanet.tech