



Bildnachweis: Shutterstock/TechSolution

Last- und Erzeugungsprognose

Prognosen für Last und Erzeugung sind ein essenzieller Bestandteil des Netzbetriebs und der Netzplanung. Mit der zunehmenden Volatilität durch erneuerbare Energien und neue Lasten steigt ihre Bedeutung weiter. Mithilfe von KI können sie deutlich verbessert werden.

Die Last- und Erzeugungsprognose ist ein seit Jahren etablierter und zentraler Anwendungsfall für datenbasierte Modelle im Energiesystem. Sie bildet die Grundlage für zahlreiche weitere Anwendungen im Netzbetrieb und in der Planung. Dabei ist grundsätzlich zwischen langfristigen Prognosen für die Netzausbauplanung über Zeiträume von mehreren Jahren und kurzfristigen Prognosen für den operativen Netzbetrieb im Bereich von Minuten bis Stunden zu unterscheiden. Ein wesentlicher Unterschied liegt dabei in den Anforderungen an zeitliche und räumliche Auflösung sowie an die Aktualität der Daten und Ergebnisse. Die Qualität der Prognosen beeinflusst direkt die Effizienz operativer Prozesse sowie die Zuverlässigkeit von Planungs- und Betriebsentscheidungen, beispielsweise im Engpassmanagement. Mit dem Aufkommen von fluktuierenden erneuerbaren Energien und von neuen Anwendungen wie Elektromobilität wird der Bedarf an geeigneten und verbesser-

ten Prognosen steigen (Fraunhofer-Institut für System- und Innovationsforschung ISI, 2019) (siehe Abbildung 1).




Abbildung 1: KI-basierte Last- und Erzeugungsprognosen

Bewertung der Umsetzbarkeit

Die Umsetzbarkeit von Prognoseanwendungen ist insgesamt als gut zu bewerten, da sowohl methodische Ansätze als auch relevante Datenstrukturen in vielen Unternehmen bereits vorhanden sind.

Zur Bewertung der Umsetzbarkeit einer datenbasierten Prognose werden im Folgenden der Stand der Technik, der Datenbedarf und die Datenqualität, der Implementierungsaufwand sowie regulatorische und sicherheitsrelevante Aspekte genauer beleuchtet.

Stand der Technik

Last- und Erzeugungsprognosen gehören zu den technologisch ausgereiftesten Anwendungsfällen im Bereich datenbasierter Methoden. Datenbasierte Verfahren sind heute Stand der Technik und werden branchenübergreifend eingesetzt (Fraunhofer-Institut für System- und Innovationsforschung ISI, 2019). Sowohl kurzfristige Prognosen für den operativen Netzbetrieb als auch langfristige Prognosen für Planungs- und Ausbauszenarien gelten dabei als etabliert, unterscheiden sich jedoch insbesondere hinsichtlich der Anforderungen und Unsicherheiten im jeweiligen Anwendungskontext. Mit dem zunehmenden Aufkommen neuartiger Verbraucher wie Wärmepumpen und Elektrofahrzeuge steigt allerdings die Komplexität der Lastprognose, da deren Verhalten stärker stochastisch geprägt ist und historische Daten noch begrenzt verfügbar sind.

Typische Modellansätze umfassen künstliche neuronale Netze, Deep-Learning-Modelle sowie Long Short-Term Memory¹ (Tamilselvan, 2025), die nichtlineare Zusammenhänge und langfristige Abhängigkeiten in Zeitreihen abbilden und dadurch in der Regel eine höhere Prognosegenauigkeit als klassische statistische Verfahren wie lineare Regression erzielen. Komplexere Prognosemodelle und zusätzliche Eingangsdaten bieten dabei weiteres Potenzial zur Genauigkeitssteigerung, erhöhen jedoch gleichzeitig den Bedarf an Rechenleistung und Speicherplatz. Es besteht somit ein Zielkonflikt zwischen Modellkomplexität und Ressourceneffizienz, der bei der Modellauswahl explizit berücksichtigt werden sollte.

Datenbedarf, Datenverfügbarkeit und Datenqualität

Datenbedarf

Der Datenbedarf unterteilt sich in Trainingsdaten, die für die Modellentwicklung benötigt werden, und operative Eingangsdaten, die im laufenden Betrieb für die Erstellung von Prognosen erforderlich sind.

Für das Training bilden historische Zeitreihen von Last- und Einspeisedaten die zentrale Grundlage. Die erforderliche zeitliche Auflösung hängt dabei vom jeweiligen Anwendungsfall ab (z. B. Tages-, Intraday- oder Kurzfristprognosen). Ergänzend können historische Wetterdaten sowie Zeit- und Kalenderinformationen die Modellgüte signifikant verbessern, da sie saisonale Muster und externe Einflussfaktoren auf Last und Erzeugung abbilden.

Für den operativen Betrieb werden aktuelle Wetterprognosen als zentraler Eingangsdatensatz benötigt, da das Wetter der maßgebliche Einflussfaktor für kurzfristige Last- und Einspeiseschwankungen ist. Ergänzend fließen Echtzeitmesswerte, sofern verfügbar, sowie aktuelle Kalender- und Zeitinformationen in die Prognoseberechnung ein. Die Qualität und Aktualität dieser operativen Eingangsdaten haben dabei direkten Einfluss auf die Prognosegüte im laufenden Betrieb (Deutsche Energie-Agentur, 2023).

Bei langfristigen Prognosen verschiebt sich der Datenbedarf von hochaufgelösten Betriebsdaten hin zu strukturellen Einflussgrößen. Neben historischen Lastdaten sind insbesondere Informationen zu Bevölkerungsentwicklung, wirtschaftlichen Rahmenbedingungen, der Marktdurchdringung neuer Technologien wie Elektrofahrzeugen und Wärmepumpen sowie sektorale Entwicklungsszenarien relevant. Aufgrund der wachsenden Bedeutung von Flexibilität werden zudem langfristige Prognosen zunehmend mit einer hohen zeitlichen Auflösung erstellt (Lindberg K. B., 2019).

Datenverfügbarkeit & Datenqualität

Historische Daten liegen je nach Rahmenbedingungen beim Netzbetreiber – insbesondere der bestehenden Mess- und Dateninfrastruktur sowie dem Digitalisierungsgrad – in

¹ LSTM (Long Short-Term Memory) ist eine Spezialform eines rekurrenten neuronalen Netzes, das besonders für die Modellierung zeitlicher Abhängigkeiten in Zeitreihen geeignet ist.

unterschiedlichem Umfang und unterschiedlicher Qualität vor. Mit dem fortschreitenden Rollout intelligenter Messsysteme und der zunehmenden Digitalisierung der Verteilnetze steigt die verfügbare Datenmenge kontinuierlich. Insbesondere die höhere Granularität der Daten verbessert die Grundlage für Prognosen.

Implementierungsaufwand & Ressourcenbedarf

Der Implementierungsaufwand hängt maßgeblich von der gewählten Umsetzungsstrategie ab:

- **Interne Entwicklung:** Erfordert den Aufbau geeigneter IT-Infrastruktur (z. B. Server), die Verfügbarkeit qualifizierten Personals im Bereich Datenanalyse und Prognosemodellierung sowie die Etablierung neuer Prozesse. Der initiale Aufwand ist entsprechend hoch, insbesondere wenn vergleichbare Anwendungen bisher nicht im Unternehmen eingeführt wurden (Deutsche Energie-Agentur, 2023).
- **Externe Bereitstellung durch Dienstleister:** Reduziert den internen Aufwand auf die Bereitstellung und Aufbereitung der benötigten Daten (z. B. Stammdaten, historische Messwerte) seitens des VNBs. Dadurch steigen allerdings die Anforderungen an den Datenschutz, und die Kontrolle über Daten und Modelle sinkt (Deutsche Energie-Agentur, 2023).

Die Wahl der Umsetzungsstrategie sollte entsprechend primär von der Unternehmensgröße und den vorhandenen Kompetenzen abhängen. Eine interne Entwicklung empfiehlt sich für größere VNBs, die bereits über Datenanalyse-Kompetenz verfügen, hohe Anforderungen an Datensouveränität haben oder Prognosen als strategische Kernkompetenz langfristig intern aufbauen wollen. Kleinere VNBs ohne entsprechende IT- und Fachkapazitäten profitieren hingegen in der Regel stärker von einer externen Lösung, die einen schnellen Einstieg mit geringerem initialen Aufwand ermöglicht – vorausgesetzt, Datenschutz- und Schnittstellenanforderungen sind klar geregelt.

Eingriffstiefe der Anwendung in Prozesse

Prognosen sind sowohl in der Netzplanung als auch im Netzbetrieb bereits etabliert (z. B. Standardlastprofile, Regressionsmodelle oder Fahrplanprognosen). Der Einsatz

datenbasierter Verfahren stellt daher primär einen Methodenwechsel innerhalb bestehender Prognoseprozesse dar. Die erforderlichen Anpassungen betreffen vor allem Datenhaltung, Modellmanagement und die IT-Systeme zur Prognoseerstellung, während die übergeordneten Planungs- bzw. Betriebsprozesse weitgehend unverändert bleiben. Die Eingriffstiefe in die Prozesse unterscheidet sich jedoch je nach Einsatzart:

- **Planungsbezogene Prognosen:** Geringe Eingriffstiefe, da die Ergebnisse typischerweise zur Unterstützung von Netzplanungs- und Investitionsentscheidungen genutzt werden. Die Prognosen wirken dabei indirekt auf Entscheidungen und unterliegen in der Regel einer fachlichen Überprüfung durch Planer. Echtzeitanforderungen und unmittelbare Auswirkungen auf den Netzbetrieb bestehen nicht.
- **Operative Prognosen:** Höhere Eingriffstiefe, insbesondere wenn Prognosen in betriebliche Entscheidungsprozesse integriert werden. Dies betrifft beispielsweise Last- und Erzeugungsprognosen, die als Grundlage für operative Maßnahmen dienen. Der Einfluss auf nachgelagerte Prozessketten ist hierbei größer, insbesondere bei einer weitgehenden Automatisierung der Entscheidungsfindung (beispielsweise bei Steuereingriffen im Rahmen des Engpassmanagements).

Durch die Differenzierung der Eingriffstiefen ergibt sich auch eine regulatorische Unterscheidung hinsichtlich der Risikoeinstufung des Anwendungsfalls im EU AI Act.

Planungsprognosen weisen wahrscheinlich ein geringes Risiko auf, da keine direkten Auswirkungen auf den Netzbetrieb entstehen. Fehlerhafte operative Prognosen führen in der Regel nicht unmittelbar zu sicherheitskritischen Situationen, können jedoch wirtschaftliche Nachteile oder einen erhöhten betrieblichen Aufwand, beispielsweise durch zusätzliche Redispatch-Maßnahmen, verursachen. Prognosen unterstützen Planungs- und Betriebsentscheidungen, während die eigentliche Maßnahmenauswahl und -umsetzung typischerweise durch nachgelagerte Systeme oder menschliche Entscheidungsträger erfolgt. Eine Einordnung als Hochrisiko-KI-System im Sinne des EU AI Acts ist dementsprechend unwahrscheinlich und nur im Einzelfall bei Integration in automatisierte Prozesse denkbar.

Robustheit & Fehlertoleranz

Herausforderungen für die Robustheit ergeben sich insbesondere durch strukturelle Veränderungen im Netz (Concept Drift²), extreme Wetterereignisse sowie atypische Lastmuster, die nicht in den Trainingsdaten enthalten sind. Darüber hinaus führen besondere Kalendereffekte, wie Brücken- oder Sonderfeiertage, zu schwer modellierbaren Lastmustern. Eine kontinuierliche Überwachung der Prognosegüte sowie regelmäßige Modellanpassungen sind daher entscheidend für einen stabilen Einsatz. Zur Erhöhung der Robustheit gegenüber einzelnen Modellfehlern empfiehlt sich der Einsatz von Ensemble-Methoden, bei denen mehrere Modelle kombiniert werden. Dies reduziert die Anfälligkeit gegenüber Ausreißern und liefert gleichzeitig Konfidenzintervalle, die eine bessere Einschätzung der Prognoseunsicherheit ermöglichen.

Erklärbarkeit & Nachvollziehbarkeit

Komplexe KI-Modelle weisen häufig eine eingeschränkte Nachvollziehbarkeit auf („Black-Box“-Charakter). Einfachere Modelle bieten eine höhere Transparenz, jedoch häufig eine geringere Prognosegüte. Im Vergleich zu vielen anderen KI-Anwendungen sind die Anforderungen an die Erklärbarkeit bei Prognosen grundsätzlich geringer, da sie in der Regel keine autonomen Entscheidungen oder direkten Systemeingriffe auslösen, sondern als Entscheidungsgrundlage für nachgelagerte Prozesse dienen. Die Anforderungen variieren jedoch je nach Einsatzkontext. In der Netzausbauplanung sind sie tendenziell moderat, da die Prognosen in langfristige Planungs- und Investitionsentscheidungen einfließen. Operative Prognosen können hingegen direkt in betriebliche Entscheidungsprozesse integriert werden und beispielsweise Steuereingriffe oder Redispatch-Maßnahmen vorbereiten, wodurch die Anforderungen an Nachvollziehbarkeit und Transparenz steigen.

Organisatorische & regulatorische Rahmenbedingungen

Regulatorische Anforderungen, insbesondere im Rahmen von Redispatch 2.0, machen den Einsatz von Prognosen für dezentrale Einspeisung und Last zu einem zentralen Bestandteil des Netzbetriebs. Netzbetreiber sind dabei zunehmend darauf angewiesen, belastbare Prognosen bereitzustellen, um Eingriffe in das Netzgeschehen effizient und vorausschauend planen zu können (Consentec GmbH, 2024). Gleichzeitig ergeben sich aus der Nutzung entsprechender

Daten erhöhte Anforderungen an den Umgang mit sensiblen Informationen. Insbesondere Verbrauchsmessungen weisen häufig einen Personenbezug auf, wodurch datenschutzrechtliche Vorgaben zu berücksichtigen sind. Die Einhaltung der Datenschutz-Grundverordnung (DSGVO) sowie Anforderungen an Datensicherheit und -verarbeitung sind daher wesentliche Rahmenbedingungen bei der Implementierung (Deutsche Energie-Agentur, 2023).

Kosten-Nutzen-Analyse

Genauere Prognosen von Last und Erzeugung durch den Einsatz von datenbasierten und KI-Methoden sichern den zuverlässigen Netzbetrieb, indem sie Methoden wie die Nutzung von Standardlastprofilen ersetzen und dadurch höhere Genauigkeiten bereitstellen. Dies zeigt sich vor allem in Anwendungen, die auf den Prognosen aufbauen, wie der Netzzustandsschätzung, bei der kritische Netzzustände zuverlässiger erkannt werden können (Deutsche Energie-Agentur, 2023). Leistungsfähige Deep-Learning-Modelle extrahieren dabei automatisch relevante Merkmale und erfassen nichtlineare sowie langfristige Zusammenhänge in Zeitreihen, wodurch oft genauere Vorhersagen als mit klassischen statistischen Modellen möglich sind. Der Mehrwert konnte im Rahmen mehrerer Studien und Projekten (Fraunhofer IEE, Universität Kassel, Georg-August-Universität Göttingen, Green Excellence GmbH, 2024) gezeigt werden. Zudem ermöglichen genauere Prognosen eine verbesserte Planbarkeit und somit eine Kostensenkung, da die Ausgleichskosten durch geringere Prognosefehler reduziert werden können.

Durch die Integration zusätzlicher Datenquellen, wie etwa hochaufgelöster Wetterdaten oder Sensorik (z. B. Wetterkameras), können auch sehr kurzfristige Prognosen realisiert werden. Gleichzeitig ermöglicht eine höhere zeitliche Auflösung der Daten eine präzisere Erfassung von Last- und Erzeugungsspitzen. Die Nutzung umfangreicher historischer und standortspezifischer Daten verbessert zudem die Erkennung von Mustern und Anomalien und führt in der Regel zu einer deutlich höheren Prognosegenauigkeit im Vergleich zu Ansätzen, die nur auf kurzen Datenhistorien beruhen. Da entsprechende Systeme bereits in der Praxis eingesetzt werden, können sie kontinuierlich weiterentwickelt und an neue Rahmenbedingungen angepasst werden.

Der Einsatz daten- und KI-basierter Verfahren zur Prognose bietet erhebliches Potenzial, ist jedoch mit entsprechenden

² Schleichende Veränderung der statistischen Eigenschaften der Eingangsdaten, die dazu führt, dass ein trainiertes Modell an Genauigkeit verliert.

Investitions- und Betriebskosten verbunden, die bei der Umsetzungsentscheidung realistisch einzuplanen sind.

Einmalige Investitionskosten

Die einmaligen Investitionskosten (CAPEX) für datenbasierte Prognoseanwendungen ergeben sich vor allem aus dem Aufbau einer belastbaren Datengrundlage, wie aus Abbildung 2 hervorgeht. Projektplanung und Anforderungsanalyse fallen mit überschaubarem Aufwand an, da der Scope klar definierbar ist. Bei Dateninfrastruktur und Pipeline (ETL-Prozesse³, Storage und cloud-agnostische Anbindung⁴) treiben vor allem Datensilos, Qualitätsprobleme und die Komplexität der ETL-Prozesse die Kosten. Die Modellentwicklung und das Training sind hingegen vergleichsweise kostengünstig, da klassische ML-Modelle keine GPU-Infrastruktur erfordern. Eine SCADA- oder EMS-Integration ist nur dann relevant, wenn Echtzeitanforderungen bestehen, was bei reinen Planungsprognosen in der Regel nicht der Fall ist. Da Prognosen nicht als Hochrisikosystem im Sinne des EU AI Acts eingestuft werden, sind Validierungs- und Zertifizierungsaufwand begrenzt. Auch der Aufwand für Schulung und Change Management ist moderat, da viele verfügbare Toolboxes gut bedienbar sind.




Abbildung 2: Einmalige Investitionskosten. Anteile sind indikativ.

Jährliche Kosten

Die laufenden Betriebskosten (OPEX) ergeben sich primär aus dem Betrieb der Inferenz sowie der Pflege der zugrunde liegenden Modelle und Daten. Der Inferenz-Server läuft im Batch-Betrieb⁵ ohne Echtzeitanforderung, was die Serverkosten begrenzt. GPU-Ressourcen für das Retraining sind bei Standard-ML-Modellen nicht zwingend erforderlich. Zeitreihendaten haben ein geringes Volumen, sodass die Speicherkosten niedrig bleiben. Ein relevanter Kostenblock entsteht jedoch durch Backup und Archivierung, die weniger durch die Datenmenge als durch Compliance-Anforderungen getrieben werden. Das Monitoring ist bei Prognosen eher unkritisch, da keine aktiven Steuerentscheidungen getroffen werden. Zusätzliche OPEX-Treiber sind die Beschaffung kommerzieller Wetterdaten, sofern die Auflösung der Daten des Deutschen Wetterdienstes (DWD) nicht ausreicht, sowie Plattform-Lizenzen, falls ein kommerzielles Prognosetool genutzt wird. Insgesamt ergibt sich ein jährlicher Betriebskostenblock im unteren Bereich, der maßgeblich durch Daten- und Lizenzkosten geprägt ist.

Fazit

Die Implementierung KI- und datenbasierter Last- und Erzeugungsprognosen bietet ein relevantes Nutzenpotenzial, insbesondere durch eine höhere Prognosegenauigkeit gegenüber klassischen Verfahren wie Standardlastprofilen, eine verbesserte Planbarkeit und die Möglichkeit, Ausgleichskosten zu reduzieren. Gleichzeitig ist der Anwendungsfall technologisch bereits weit entwickelt und in vielen Unternehmen durch bestehende Datenstrukturen und Prozesse gut vorbereitet. Dadurch können vorhandene Erfahrungen und Infrastrukturen genutzt und Modelle schrittweise weiterentwickelt werden. Besonders hervorzuheben ist das Potenzial zur kontinuierlichen Verbesserung durch die Integration zusätzlicher Datenquellen und eine wachsende Datenbasis.

Der mit der Umsetzung verbundene Aufwand ist im Vergleich zu anderen datenbasierten Anwendungen im Netzbetrieb überschaubar. Der initiale Investitionsaufwand entsteht vor allem durch den Aufbau einer belastbaren Dateninfrastruktur und geeigneter ETL-Prozesse. Die laufenden Betriebskosten ergeben sich insbesondere aus dem Betrieb der Modelle und der Pflege der zugrunde liegenden Daten. Da weder Echtzeitanforderungen noch GPU-intensive Infrastruktur zwingend erforderlich sind, sind die technischen

³ Extract, Transform, Load – Prozess zur Extraktion, Umwandlung und Übertragung von Daten zwischen Systemen.

⁴ Systemarchitektur, die unabhängig von einem spezifischen Cloud-Anbieter betrieben werden kann und damit einen Wechsel des Anbieters ohne grundlegende Systemänderungen ermöglicht.

⁵ Verarbeitungsmodus, bei dem Berechnungen gebündelt zu festen Zeitpunkten stattfinden (im Gegensatz zu Echtzeit-Verarbeitung).

Voraussetzungen für eine Umsetzung vergleichsweise gut beherrschbar.

Insgesamt eignet sich die Anwendung besonders als Einstiegsprojekt für KI- und datenbasierte Anwendungen im Netzbetrieb. Die Kombination aus bereits hoher technologischer Reife, guter Umsetzbarkeit und einem relevanten Nutzenpotenzial ermöglicht einen niedrigrschwelligen Start und schafft zugleich eine Grundlage für eine spätere Weiterentwicklung. Mit wachsender Datenbasis und steigender Prognosequalität kann der Anwendungsfall perspektivisch eine höhere Priorität erlangen.

Referenzen

- Consentec GmbH. (2024). *Sachverständigengutachten zum Festlegungsverfahren BK6-23-241 - Weiterentwicklung von Redispatch 2.0*.
- Deutsche Energie-Agentur. (2023). *Datenanalysen und künstliche Intelligenz im Stromverteilnetz*.
- Fraunhofer IEE, Universität Kassel, Georg-August-Universität Göttingen, Green Excellence GmbH. (2024). *SyLas-KI – Synthetische Lastzeitreihen für Energiesystemanalysen mit Verfahren der Künstlichen Intelligenz*. Von <https://www.iee.fraunhofer.de/de/projekte/suche/2021/sylas-ki.html> abgerufen
- Fraunhofer-Institut für System- und Innovationsforschung ISI. (2019). *Künstliche Intelligenz für die integrierte Energiewende - Einordnung des technologischen Status quo sowie Strukturierung von Anwendungsfeldern in der Energiewirtschaft*.
- Lindberg K. B., S. P. (2019). Long-term electricity load forecasting: Current and future trends. *Utilities Policy*, 102-119. doi:<https://doi.org/10.1016/j.jup.2019.04.001>
- Tamilselvan, S. (2025). *A Machine Learning-Based Adaptive Prediction Model for Energy Optimization in Smart Grid Networks*. doi:<https://doi.org/10.1109/AISP68263.2025.11396145>



Bundesministerium
für Wirtschaft
und Energie

Die Veröffentlichung dieser Publikation erfolgt im Auftrag des Bundesministeriums für Wirtschaft und Energie. Die Deutsche Energie-Agentur GmbH (dena) unterstützt die Bundesregierung in verschiedenen Projekten zur Umsetzung der energie- und klimapolitischen Ziele im Rahmen der Energiewende.

KONTAKT
Dr. Jakob Schieder-Hestermann
Themengebietsleiter Stromnetze

Tel.: +49 30 66 777-159
E-Mail:
Jakob.Schieder-Hestermann@dena.de

Deutsche Energie-Agentur GmbH (dena)
Chausseestraße 128 a
10115 Berlin

<https://www.dena.de/> | Stand: 10/2026

Alle Rechte sind vorbehalten. Die Nutzung steht unter dem Zustimmungsvorbehalt der dena.