



Netzzustandsermittlung

Optimierungsbasierte Methoden zur Netzzustandsermittlung stoßen in Niederspannungsnetzen aufgrund begrenzter Messinfrastruktur an ihre Grenzen. KI- und datenbasierte Methoden ermöglichen dennoch eine zuverlässige Ermittlung des Netzzustands bei begrenzter Datenlage.

Der Begriff der Netzzustandsschätzung, auch State Estimation (SE) genannt, ist insbesondere aus höheren Spannungsebenen bekannt und dort als etabliertes Verfahren zur Bestimmung eines konsistenten Netzzustands verbreitet. In diesen Netzebenen steht in der Regel eine ausreichende Anzahl an Messwerten zur Verfügung, sodass das zugrunde liegende Netzgleichungssystem *überbestimmt* ist. Auf dieser Grundlage können fehlende oder fehlerbehaftete Zustandsgrößen mithilfe eines mathematischen Netzmodells geschätzt und Messabweichungen gezielt berücksichtigt werden (VDE FNN, 2025).

Eine unmittelbare Übertragung dieser Verfahren auf Niederspannungsnetze ist jedoch nur eingeschränkt möglich. In vielen Niederspannungsnetzen ist die Durchdringung mit installierter Messtechnik bislang gering, sodass das Netzgleichungssystem häufig *unterbestimmt* ist. Vor diesem

Hintergrund wird im Kontext von Mittel- und Niederspannungsnetzen häufig von Netzzustandsermittlung gesprochen. Die Netzzustandsermittlung verfolgt ebenfalls das Ziel, den aktuellen Netzzustand zu bewerten und kritische Situationen wie Überlastungen oder Spannungsbandverletzungen zu erkennen. Hierbei werden auf Grundlage von Echtzeitmessungen und unter Berücksichtigung der technischen Parameter des Netzbereichs mithilfe eines mathematischen Modells alle fehlenden Größen zur Definition eines konsistenten Netzzustands bestimmt (siehe Abbildung 1). Die Kernidee besteht darin, die unbekannten Netzgrößen so zu bestimmen, dass Messfehler und Ungenauigkeiten minimiert werden, um daraus die Netzauslastung abzuleiten (VDE FNN, 2025). Die Relevanz dieser Ansätze wird insbesondere durch die Vorgaben der Bundesnetzagentur zur Steuerbarkeit gemäß §14a EnWG unterstrichen, deren Umsetzung in den kommenden Jahren durch Verteilnetz-

betreiber erfolgen muss. Eine erfolgreiche Umsetzung dieser Anforderungen setzt jedoch eine ausreichende Beobachtbarkeit des Netzes voraus, die durch Verfahren der Netzzustandsschätzung gewährleistet werden kann. Während hierfür in höheren Spannungsebenen etablierte Verfahren der Netzzustandsschätzung zur Verfügung stehen, sind in Niederspannungsnetzen angepasste Verfahren der Netzzustandsermittlung erforderlich. Datenbasierte Verfahren und KI-Anwendungen können hier einen wesentlichen Beitrag leisten, indem sie vorhandene Messdaten, Netzmodelle und historische Betriebsinformationen kombinieren und so die Beobachtbarkeit auch bei geringer Messdurchdringung verbessern.




Abbildung 1: Schematische Darstellung der Netzzustandsermittlung

Bewertung der Umsetzbarkeit

Wesentliche Faktoren für die praktische Umsetzbarkeit der Netzzustandsermittlung sind sowohl die Echtzeitfähigkeit als auch die Genauigkeit der Ergebnisse. Zur Durchführung der Netzzustandsermittlung werden aktuelle Messwerte in minütlicher Auflösung (TAF10-Werte) verarbeitet. Da der Prozess der netzorientierten Steuerung nach §14a EnWG einschließlich der Netzzustandsermittlung innerhalb weniger Minuten erfolgen soll, steht für die einzelnen Prozessschritte nur ein begrenztes Zeitbudget zur Verfügung. Insbesondere Übertragungs- und Kommunikationslatenzen können einen relevanten Anteil dieses Zeitbudgets beanspruchen und sind durch das Verfahren zur Netzzustandsermittlung selbst kaum beeinflussbar. KI-Modelle zeichnen sich dabei insbesondere durch sehr kurze Inferenzzeiten von unter einer Sekunde aus und bieten damit deutliche Vorteile gegenüber optimierungsbasierten Verfahren.

Dadurch können Auswirkungen der Verzögerungen in der Datenübertragung reduziert werden, indem für die anschließende Netzzustandsermittlung nur ein geringer zusätzlicher Zeitbedarf entsteht. Die Unterschiede hinsichtlich der Echtzeitfähigkeit zwischen optimierungs- und KI-basierten Verfahren zur Netzzustandsermittlung sind schematisch in Abbildung 2 dargestellt.




Abbildung 2: Schematischer Vergleich der Echtzeitfähigkeit optimierungs- und KI-basierter Netzzustandsermittlung

Bezüglich der Genauigkeit ergeben sich für die zuverlässige Erkennung von Netzengpässen Anforderungen an die Schätzfehler von Spannungs- und Stromwerten. Unter Berücksichtigung des 99-Prozent-Perzentils sind höchstens 2 Prozent für die Schätzfehler der Spannungen und 10 Prozent für die Leitungsauslastung einzuhalten (VDE FNN, 2025).

Zur Bewertung der Umsetzbarkeit KI- und datenbasierter Methoden zur Netzzustandsermittlung werden im Folgenden zunächst geeignete Modellansätze vorgestellt. Darauf aufbauend erfolgt eine Einordnung hinsichtlich Implementierungsaufwand, Datenanforderungen und praktischer Integrationsaspekte.

Stand der Technik

Im Hinblick auf Genauigkeit und Echtzeitfähigkeit wurden bereits verschiedene Modelle zur Netzzustandsermittlung entwickelt. In der Forschung existiert hierfür eine etablierte Grundlage (Dehghanpour, 2019), (Habib, 2023), auf der aktuelle Entwicklungen aufbauen können. Ergänzend werden erste Proof-of-Concept-Anwendungen bereits im Feld getestet, was die grundsätzliche Praxistauglichkeit entsprechender Ansätze belegt (Winter, 2025). Geeignete Modelle umfassen sowohl Regressionsmodelle als auch Deep-Learning-Modelle wie Graph-Neuronale Netze (GNN)¹ oder physikalisch informierte neuronale Netze (PINN)². GNN eignen sich besonders für die Netzzustandsermittlung, da sie die physikalische Struktur elektrischer Netze direkt als Graph verarbeiten und dadurch flexibel auf Topologieänderungen

¹ GNN: Neuronale Netze, die die Topologie und Zusammenhänge graphbasierter Strukturen, wie elektrischer Netze, explizit berücksichtigen.

² PINN: Neuronale Netze, die physikalische Gleichungen und Randbedingungen direkt in den Lernprozess integrieren.

sowie unterschiedliche Netzgrößen reagieren können. PINN erweitern das neuronale Netz durch die Integration physikalischer Gesetzmäßigkeiten in den Lernprozess, wodurch insbesondere die Generalisierungsfähigkeit für unbekannte Netzzustände verbessert wird. Insbesondere GNN erreichen bei bekannten Netztopologien mittlere absolute Fehler von unter 1 Prozent (Habib, 2023).

Datenbedarf, Datenverfügbarkeit & Datenqualität

Datenbedarf

Der Datenbedarf umfasst neben statischen Netzparametern, wie Netztopologie, Betriebsmitteldaten, thermischen Grenzströmen und Leistungsspektren der Lastknoten, auch Echtzeit-Mess- und Zustandsdaten. Hierzu zählen insbesondere Messwerte aus dezentralen Direktmessungen an Transformatorstationen, Kabelverteilerschränken oder intelligenten Messsystemen (iMSys) sowie Ersatzwerte für nicht gemessene Kunden, sogenannte Pseudomesswerte (Winter, 2025; VDE FNN, 2025; Deutsches Forschungszentrum für Künstliche Intelligenz GmbH (DFKI), Power Engineering Saar (PowerEngS), Stadtwerke Saarlouis GmbH, VSE Verteilnetz GmbH, 2025). Für KI-basierte Modelle ist dabei zwischen Trainingsdaten und operativen Eingangsdaten zu unterscheiden: Trainingsdaten umfassen historische Mess-, Zustands- und Ereignisdaten, wie Strom-, Spannungs-, Wirk- und Blindleistungswerte, Schaltzustände sowie weitere netzbetriebliche Kenngrößen. Neben historischen Messdaten können auch probabilistische Zeitreihen zum Training der Modelle genutzt werden. Operative Eingangsdaten werden im laufenden Betrieb genutzt und bestehen aus Echtzeitmesswerten.

Datenverfügbarkeit & Datenqualität

Stammdaten zu Betriebsmitteln und Netztopologie sind meist vorhanden, jedoch häufig auf verschiedene Systeme verteilt. Eine zentrale Herausforderung besteht daher in der Zusammenführung der Daten in ein konsistentes Datenbanksystem bzw. einen digitalen Zwilling, wobei der Aufwand stark von der bestehenden Systemlandschaft abhängt. Messdaten sind in manchen Netzbereichen verfügbar. Insbesondere in Mittel- und Niederspannungsnetzen ist die Datenverfügbarkeit jedoch oft lückenhaft, da Ortsnetzstationen häufig nicht fernüberwacht werden. Daher besteht vielfach zusätzlicher Bedarf an Messtechnik in Ortsnetzstationen. Gleichzeitig bestehen hohe Anforderungen an die Datenqualität, insbesondere hinsichtlich Synchronität und konsistenter Dokumentation. Ein zeitlich versetzter Versand der TAF10-Daten innerhalb einer Minute kann zwar zur Optimierung der Übertragungskapazitäten beitragen (VDE FNN, 2025), jedoch können Übertragungslücken oder

Kommunikationsausfälle zu größeren Zeitversätzen führen und dadurch fehlerhafte Ergebnisse verursachen.

Implementierungsaufwand & Ressourcenbedarf

Der Implementierungsaufwand für die Netzbetreiber hängt maßgeblich von der gewählten Umsetzungsstrategie ab:

- **Interne Entwicklung:** Für KI-basierte Modelle ist der Aufbau einer geeigneten KI-Infrastruktur (z. B. GPU-Ressourcen) erforderlich. Zudem werden spezialisierte Fachkräfte aus den Bereichen Künstliche Intelligenz und Netzbetrieb benötigt. Eine zentrale Herausforderung ist die Integration in bestehende Netzleitsysteme. Hierfür sind Schnittstellen zu Echtzeitmessdaten sowie zu Engpassmanagementsystemen erforderlich. Dieser Ansatz ist insbesondere dann vorteilhaft, wenn netzspezifische Anforderungen oder individuelle Topologien bestehen. Werden Daten für Training, Validierung oder Betrieb genutzt, müssen diese so aufbereitet und anonymisiert werden, dass keine Rückschlüsse auf einzelne Kundinnen und Kunden, Anschlussnehmer oder Verbraucherverhalten möglich sind. Wenn keine geeigneten Ansätze bestehen, um die erforderlichen Daten datenschutzkonform, anonymisiert und sicher für externe Lösungen bereitzustellen, kann eine interne Entwicklung oder ein internes Deployment die geeignetere Variante sein.
- **Externe Bereitstellung durch Dienstleister:** Bereits entwickelte und teilweise vorkonfigurierte Lösungen können durch externe Dienstleister bereitgestellt werden, wodurch sich die Umsetzung beschleunigen lässt. Dies kann insbesondere für einen schnellen Einstieg, Pilotprojekte oder standardisierte Anwendungen vorteilhaft sein. Die externe Bereitstellung erfordert geeignete Anonymisierungs-, Aggregations- oder Pseudonymisierungskonzepte sowie vertragliche und technische Schutzmaßnahmen. Dieser Ansatz ist insbesondere dann geeignet, wenn eine schnelle Umsetzung angestrebt wird, nur begrenzte interne KI-Ressourcen verfügbar sind und die erforderlichen Daten sicher, anonymisiert oder aggregiert bereitgestellt werden können.
- **Nutzung von Open-Source-Modellen:** Open-Source-Modelle und frei verfügbare Frameworks können sowohl im Rahmen einer internen Entwicklung als auch bei der Anpassung externer Lösungen genutzt werden. Sie bieten den Vorteil, dass bestehende Modellarchitekturen, Trainingsroutinen oder Auswertungsverfahren wiederverwendet und an den jeweiligen Anwendungsfall ange-

passt werden können. Dadurch lassen sich Entwicklungsaufwand und Implementierungsdauer reduzieren. Gleichzeitig ist zu prüfen, ob die Modelle fachlich geeignet, ausreichend dokumentiert, sicher und langfristig wartbar sind. Insbesondere bei Anwendungen im Netzbetrieb müssen Modellqualität, Nachvollziehbarkeit, Lizenzbedingungen, IT-Sicherheit und Integrationsfähigkeit bewertet werden. Open-Source-Modelle ersetzen daher nicht die fachliche Validierung und Systemintegration, können aber als Baustein für interne oder externe Implementierungsansätze genutzt werden.

Auch die Wahl des Modells spielt eine wichtige Rolle. Mit steigender Modellkomplexität können Fehleranalyse und Kalibrierung schwieriger werden, wodurch die Erzielung optimaler Ergebnisse erschwert wird. Beispielsweise lassen sich GNNs gut auf ähnliche Netztopologien übertragen, können jedoch unter sogenannten Over-Smoothing-Effekten leiden, die die Modellperformance reduzieren (Rusch, 2023).

Eingriffstiefe der Anwendung in Prozesse

Die Eingriffstiefe in bestehende Prozesse und Systemarchitekturen hängt vom Integrationsgrad der Anwendung ab und kann vom Netzbetreiber unterschiedlich gestaltet werden (VDE Impuls, 2020). Dabei ist zwischen der KI-Anwendung selbst, dem übergeordneten Netzzustandsermittlungssystem und möglichen nachgelagerten Steuerungsfunktionen zu unterscheiden. Die Integration erfolgt typischerweise entlang der Kette aus Messsystemen, Datenkonzentratoren, Netzleitsystemen sowie Modulen zur Netzzustandsermittlung und nachgelagerten Steuerung.

- Parallelbetrieb (Shadowing): Die KI-Anwendung läuft parallel zu bestehenden Verfahren ohne operative Relevanz. Betriebsprozesse und Haftungsstrukturen bleiben unverändert, wodurch die Eingriffstiefe gering ist.
- Übernahme ergänzender Funktionen innerhalb bestehender Prozesse: KI übernimmt unterstützende Aufgaben, beispielsweise die Imputation fehlender Messwerte, Bad-Data-Detection oder die Generierung von Pseudomesswerten. Dafür sind Schnittstellen zu den statischen Parametern erforderlich, die Eingriffstiefe bleibt jedoch moderat.
- Einsatz als zentrale Funktion innerhalb der Netzzustandsermittlung: Eine hohe bis sehr hohe Eingriffstiefe liegt vor, wenn bestehende Verfahren zur Netzzustandsermittlung ganz oder teilweise ersetzt werden. Dabei sind regulatorische Anforderungen, insbesondere im

Kontext kritischer Infrastrukturen (KRITIS/BSI), zu berücksichtigen. Dies umfasst unter anderem die Implementierung von Risikomanagementmaßnahmen sowie Meldepflichten bei Sicherheitsvorfällen. Besondere Relevanz ergibt sich hierbei in Kombination mit nachgelagerten Steuerungsfunktionen und den damit verbundenen Nachweispflichten.

Robustheit & Fehlertoleranz

Die Robustheit und Fehlertoleranz hängen maßgeblich von der Vollständigkeit und Vielfalt der Daten ab. Eine breite und realistische Abbildung unterschiedlicher Betriebszustände ermöglicht es den Modellen, auch Extremfälle implizit aus den Daten zu erkennen, ohne diese, wie bei Optimierungsverfahren, explizit gewichten zu müssen. Da Fehlschätzungen potenziell Auswirkungen auf Steuerungs- und Betriebsentscheidungen haben können, bietet die Kombination KI-basierter Verfahren mit klassischen Zustandsschätzverfahren zusätzliche Sicherheit und erhöht die Zuverlässigkeit des Gesamtsystems. Zur Verbesserung der Fehlertoleranz eignen sich insbesondere Ensemble-Verfahren sowie physikalisch informierte Hybridmodelle, da sie die Robustheit gegenüber Abweichungen erhöhen können (Varga, 2025). Solche Verfahren sind jedoch insbesondere in frühen Entwicklungs- oder Integrationsphasen mit zusätzlicher Komplexität verbunden. Ihre Einführung sollte daher schrittweise erfolgen, sobald eine belastbare Datenbasis, geeignete Validierungsprozesse und ausreichend Domänenwissen für die korrekte Parametrierung und Bewertung der Modelle vorliegen.

Erklärbarkeit & Nachvollziehbarkeit

Die Erklärbarkeit und Nachvollziehbarkeit der eingesetzten Modelle stellen weiterhin eine Herausforderung dar. Insbesondere KI-Modelle sind inhärent schwer interpretierbar, da ihre Entscheidungsprozesse nicht unmittelbar transparent sind. Dennoch ermöglichen Methoden der formalen Verifikation die Ableitung von Sicherheitsgarantien für die KI-Modelle. Für den praktischen Einsatz bieten sich außerdem Hybridansätze an. Diese kombinieren klassische, physikalisch basierte Rechenverfahren mit KI-Modellen, um sowohl die Leistungsfähigkeit als auch die Nachvollziehbarkeit zu erhöhen. Ein konkretes Beispiel hierfür sind sogenannte Warm-Start-Methoden, bei denen KI-Modelle genutzt werden, um eine geeignete Startlösung für klassische rechnerische Verfahren bereitzustellen. Dadurch lässt sich die Effizienz steigern, während gleichzeitig die Transparenz und Akzeptanz der Gesamtlösung verbessert werden. Solche Ansätze sind jedoch differenziert zu betrachten: Sie erhöhen nicht zwangsläufig die vollständige Erklärbarkeit des KI-Modells selbst, sondern verbessern vor allem die

Nachvollziehbarkeit und Plausibilisierbarkeit der Gesamtlösung. Zudem erfordern Hybridansätze eine sorgfältige Kopplung zwischen KI-Komponente und physikalischem Modell, geeignete Schnittstellen sowie Domänenwissen, um physikalische Nebenbedingungen korrekt zu berücksichtigen und Fehlinterpretationen zu vermeiden. Damit können sie die Akzeptanz im praktischen Einsatz erhöhen, sind jedoch insbesondere zu Beginn mit zusätzlichem Integrations- und Validierungsaufwand verbunden.

Organisatorische & regulatorische Rahmenbedingungen

Der Einsatz KI- und datenbasierter Netzzustandsermittlung erfolgt innerhalb eines regulatorischen Rahmens, der insbesondere Anforderungen an Datenschutz, IT-Sicherheit und Dokumentation stellt. Im Kontext der DSGVO müssen Smart-Meter-Daten so anonymisiert und aggregiert werden, dass keine Rückschlüsse auf einzelne Personen oder Standorte möglich sind. Ebenso sollen beispielsweise Netzmodelle keine Informationen über die geografische Lage des Netzes enthalten. Bei interner Nutzung im regulären Netzbetrieb können detaillierte Netz- und Messdaten erforderlich sein, sofern geeignete Zugriffs-, Sicherheits- und Dokumentationsmechanismen bestehen. Werden die Daten jedoch für KI-Training, externe Validierung, oder automatisierte Entscheidungsunterstützung genutzt, steigen die Anforderungen an Datenanonymisierung, Zweckbindung und Nachvollziehbarkeit. Daher sollte bereits bei der Datenaufbereitung geprüft werden, welche Informationen notwendig sind und welche Merkmale abstrahiert, aggregiert oder entfernt werden können. Zudem sind Anforderungen an die IT-Sicherheit, insbesondere im KRITIS-Umfeld sowie gemäß BSI-IT-Grundschutz und IEC 62443, zu berücksichtigen. In diesem Zusammenhang sind insbesondere Risiken durch gezielte Angriffe auf die Datenbasis zu berücksichtigen, etwa durch Data-Poisoning-Angriffe, die die Trainings- oder Eingabedaten manipulieren und damit die Modellgüte beeinträchtigen können. Insgesamt erfordert der Einsatz solcher Verfahren daher umfassende Sicherheits- und Validierungsmechanismen entlang der gesamten Daten- und Prozesskette. Außerdem unterstreicht die Anwendung die Notwendigkeit, ein Informationssicherheitsmanagementsystem (ISMS) nach ISO 27001 einzuführen und zu zertifizieren (VDE FNN, 2017). Auch regulatorische Entwicklungen wie der EU AI Act spielen eine Rolle. Die Einstufung von KI-Anwendungen hängt dabei maßgeblich vom Integrationsgrad und der Eingriffstiefe in bestehende Prozesse ab. KI-Anwendungen zur Netzzustandsermittlung sind daher nicht pauschal als Hochrisiko-Systeme einzuordnen. Eine geringe regulatorische Eingriffstiefe ist

insbesondere dann anzunehmen, wenn die Anwendung lediglich im Parallelbetrieb eingesetzt wird oder unterstützende Vorverarbeitungsfunktionen übernimmt, ohne operative Entscheidungen unmittelbar zu beeinflussen.

Anders zu bewerten sind Anwendungen, bei denen KI-basierte Ergebnisse eine zentrale Grundlage für Engpassmanagement im Netzbetrieb bilden oder direkt in automatisierte Steuerungsfunktionen einfließen. In diesem Fall kann die KI-Anwendung Teil eines sicherheitsrelevanten Gesamtsystems werden. Die regulatorische Bewertung hängt dann davon ab, ob die KI-Funktion als sicherheitsrelevante Komponente im Betrieb kritischer Infrastruktur wirkt und ob ein Fehlverhalten erhebliche Auswirkungen auf Versorgungssicherheit, Betriebssicherheit oder nachgelagerte Steuerungsentscheidungen haben kann (VDE ETG, 2025). Entscheidend ist nicht die Netzzustandsermittlung als solche, sondern die Rolle der KI innerhalb der Prozesskette: von einer rein unterstützenden Analysefunktion über eine zentrale Schätzfunktion bis hin zur direkten Kopplung mit automatisierten Steuerungs- oder Betriebsentscheidungen.

Kosten-Nutzen-Analyse

Die Netzzustandsermittlung bildet die Grundlage und dient der Rechtfertigung netzorientierter Steuerungsmaßnahmen an steuerbaren Verbrauchseinrichtungen (SteuVE) in der Niederspannung. Abhängig vom Beobachtbarkeitsgrad und der Notwendigkeit von Übergangslösungen ergeben sich unterschiedliche Kostenfaktoren und Effizienzgewinne.

Eine ausreichende Datengrundlage für konventionelle Verfahren würde eine flächendeckende Ausstattung der Netze mit Messtechnik erfordern, was mit hohen Kosten verbunden wäre. KI-basierte Verfahren, insbesondere Ansätze auf Basis neuronaler Netze, benötigen hingegen deutlich weniger Messstellen und ermöglichen dennoch eine zuverlässige Schätzung des gesamten Netzzustands. Dabei können insbesondere Messwertkorrelationen auf Basis historischer Daten und der Netzstruktur implizit erlernt werden. Dadurch eignen sich diese Ansätze besonders für schlecht beobachtbare Netze (Fraunhofer IEE, 2022; Deutsches Forschungszentrum für Künstliche Intelligenz GmbH (DFKI), Power Engineering Saar (PowerEngS), Stadtwerke Saarlouis GmbH, VSE Verteilnetz GmbH, 2025). Zudem lassen sich einmal trainierte Modelle mit geringem Rechenaufwand im Betrieb einsetzen. Sie stellen daher insbesondere als Übergangslösung hin zu einem fortgeschrittenen Ausbau der Messtechnik im Netz eine vielversprechende Alternative dar.

Ungeachtet des gewählten Ansatzes ermöglicht eine funktionierende Netzzustandsermittlung die zielgerichtete und netzorientierte Steuerung von SteuVE, wodurch Netzausbaumaßnahmen verzögert oder vermieden werden können. Darüber hinaus entstehen Effizienzgewinne durch eine verbesserte Betriebsführung (Verlustminimierung, Spannungshaltung), eine erhöhte Transparenz für Netzbetreiber sowie eine belastbare Grundlage für die Netzplanung. Bei KI-basierten Ansätzen entstehen zusätzliche Wissensgewinne durch die Analyse der Daten und Modelle sowie Skaleneffekte bei der Übertragung auf weitere Netzgebiete. So können wiederkehrende Muster in Betriebszuständen erkannt und relevante Messpunkte identifiziert werden, an denen zusätzliche Messgeräte die Netzzustandsermittlung gezielt verbessern könnten. Außerdem können Anwendungen wie Engpassprognosen oder die Ableitung von Engpassmanagementmaßnahmen einfach in die bestehenden Modelle integriert werden, was mehr Transparenz und Informationsgrundlagen schafft.

Es besteht ein hohes Potenzial für KI- und datenbasierte Verfahren zur Netzzustandsermittlung. Dennoch sind mit der Implementierung entsprechender Anwendungen Investitions- und Betriebskosten verbunden. Eine Übersicht der Kosten ist im folgenden Diagramm zu sehen.

Einmalige Investitionskosten

Die einmaligen Investitionskosten setzen sich aus mehreren Kostenblöcken zusammen, die je nach Komplexität der Umsetzung unterschiedlich stark ins Gewicht fallen, wie aus Abbildung 3 hervorgeht. Je nach Qualität der Bestandsdaten können Vorarbeiten für die Datenaufbereitung einen signifikanten Anteil der Gesamtkosten ausmachen, bieten jedoch langfristig den Mehrwert einer konsistenten, nachnutzbaren Datenbasis für weitere Betriebsprozesse (z. B. Netzplanung, Fehlerdiagnose). Ein wesentlicher Kostenblock umfasst die Modellentwicklung und das Training geeigneter Modelle. Ebenfalls relevant sind die Kosten für die Integration in bestehende Netzleitsysteme, die eine enge Anbindung an die bestehenden Schnittstellen erfordern. Weitere Aufwände entstehen im Rahmen des Test- und Validierungsbetriebs, der Implementierung einer Überwachungs- und Dokumentation sowie durch Schulungsmaßnahmen und begleitendes Change-Management zur Einführung der neuen Systeme. Zusätzlich müssen Kosten für Sicherheit und KI-Compliance berücksichtigt werden, insbesondere im Hinblick auf regulatorische Anforderungen wie den EU AI Act. Die größten Kostentreiber sind dabei die Datenaufbereitung, die Modellentwicklung sowie Sicherheits- und Integrationsaspekte.




Abbildung 3: Einmalige Investitionskosten. Anteile sind indikativ.

Jährliche Kosten

Die jährlichen Betriebskosten setzen sich aus mehreren laufenden Kostenblöcken zusammen. Ein wesentlicher Vorteil KI-basierter Anwendungen ist dabei die geringe erforderliche Rechenleistung im Betrieb. Dadurch können Edge-Computing-Lösungen verwendet werden, die Übertragungskapazitäten optimieren und die Kommunikationsinfrastruktur entlasten (VDE ETG, 2025). Ergänzend entstehen Kosten für GPU-Compute-Ressourcen, die insbesondere für regelmäßiges oder ereignisgetriebenes Retraining der Modelle benötigt werden, um deren Aktualität und Leistungsfähigkeit sicherzustellen. Hinzu kommen Aufwände für Speicherressourcen, die Messdaten, Modellversionen sowie Protokolldaten umfassen. Zusätzlich sind Kosten für Backup- und Archivierungslösungen zu berücksichtigen, beispielsweise in Form von Cold Storage und revisionssicheren Audit-Logs, insbesondere im Kontext kritischer Infrastrukturen (KRITIS). Ein weiterer relevanter Kostenblock ist der Betrieb eines Monitoring-Stacks, der die Überwachung der Systemperformance, Datenqualität sowie Modellgüte im laufenden Betrieb sicherstellt. Daraus ergeben sich insgesamt jährliche Betriebskosten, die insbesondere durch den Bedarf an Rechenressourcen sowie durch sicherheitsrelevante Anforderungen an Speicherung und Monitoring geprägt sind.

Fazit

Die KI-gestützte Netzzustandsermittlung bietet ein hohes Nutzenpotenzial und gewinnt vor dem Hintergrund zunehmender dezentraler Erzeugung, neuer flexibler Verbrauchseinrichtungen und begrenzter Messinfrastruktur weiter an Bedeutung. KI-basierte Methoden ermöglichen es, aus begrenzten, heterogenen und teilweise unvollständigen Messdaten ein konsistentes Bild des Netzzustands abzuleiten. Dabei können insbesondere datenbasierte Modelle komplexe Zusammenhänge zwischen verschiedenen Messgrößen erfassen und Zustände auch für nicht oder nur unzureichend gemessene Netzbereiche schätzen. Auch bei einem weiteren Ausbau der Messtechnik bleibt die KI-gestützte Netzzustandsermittlung relevant, da Messdaten fehlerhaft, verzögert oder unvollständig sein können und nicht jeder relevante Netzteilnehmer dauerhaft messtechnisch erfasst wird. Damit schafft sie eine wichtige Grundlage für eine höhere Netztransparenz sowie einen sicheren und effizienten Netzbetrieb.

Die Umsetzung ist mit einem hohen technischen und organisatorischen Aufwand verbunden. Der initiale Investitionsaufwand und die laufenden Betriebskosten entstehen insbesondere durch den Aufbau der erforderlichen Dateninfrastruktur, das Training und die Weiterentwicklung der KI-Modelle sowie die Integration in bestehende Systeme. Gleichzeitig stehen geeignete KI-Methoden und etablierte Verfahren zur Verfügung, sodass die technische Umsetzung grundsätzlich gut realisierbar ist.

Insgesamt ist die KI-gestützte Netzzustandsermittlung als Anwendung mit hoher Priorität einzuordnen. Ausschlaggebend dafür ist die Kombination aus einem hohen und perspektivisch weiter zunehmenden Nutzenpotenzial sowie einer grundsätzlich guten Umsetzbarkeit. Insbesondere die Fähigkeit KI-basierter Methoden, aus begrenzten Messdaten belastbare Aussagen über den Netzzustand abzuleiten, macht die Netzzustandsermittlung zu einem wichtigen Baustein für die Digitalisierung des Netzbetriebs und schafft zugleich eine wichtige Grundlage für weitere datenbasierte Anwendungen.

Referenzen

- Dehghanpour, K. (2019). *A Survey on State Estimation Techniques and Challenges in Smart Distribution Systems*. IEEE Transactions on Smart Grid. doi:doi: 10.1109/TSG.2018.2870600
- Deutsches Forschungszentrum für Künstliche Intelligenz GmbH (DFKI), Power Engineering Saar (PowerEngS), Stadtwerke Saarlouis GmbH, VSE Verteilnetz GmbH. (2025). *GridAnalysis: KI-basierte Systemanalyse von Stromverteilnetzen im Normal- und Kurzschlussbetrieb*.
- Fraunhofer IEE. (2022). *Datenanalysen und Künstliche Intelligenz im Stromverteilnetz*.
- Habib, B. (2023). *Deep Statistical Solver for Distribution System State Estimation*. doi:https://doi.org/10.48550/arXiv.2301.01835
- Hochschule für Technik und Wirtschaft des Saarlandes, Deutsches Forschungszentrum für Künstliche Intelligenz GmbH, Institut für Elektrische Energiesysteme, Stadtwerke Saarlouis GmbH, VSE Verteilnetz GmbH. (2020). *GridAnalysis: KI basierte Systemanalyse von Stromverteilnetzen im Normal und Kurzschlussbetrieb*. Retrieved from www.gridanalysis.de
- Rusch, T. K. (2023). *A Survey on Oversmoothing in Graph Neural Networks*.
- Varga, J. D. (2025). *Learning-based state estimation in distribution systems with limited real-time measurements*. Electric Power Systems Research.
- VDE ETG. (2025). *Künstliche Intelligenz in der Netzeittechnik*.
- VDE FNN. (2017). *Vom Netz zum System: Der Fahrplan für die Weiterentwicklung der Netze 2017–2021*.
- VDE FNN. (2025). *Standardisiertes Vorgehen für die Durchführung von Netzzustandsermittlungen auf Basis von Echtzeit-Messwerten in der Niederspannung*.

VDE Impuls. (2020). *Systematisierung der Autonomiestufen in der Netzbetriebsführung.*

Winter, A. F. (2025). *Entwicklung einer hybriden Künstlichen Intelligenz für die Identifikation und Optimierung von Netzzuständen in elektrischen Verteilungsnetzen.*



**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.