

6.1 Blaupause 15: Erzeugungs- und Lastprognosen mittels maschinellen Lernens

Blaupause	
Zielgruppen	<ul style="list-style-type: none"> ■ Netzbetreiber, Energieversorger ■ Anbieter von Prognose-/ Optimierungssystemen ■ Forschung ■ Gesetzgeber
Ausgangslage und Problemstellung	<p>Last- und Erzeugungsprognosen sind die Grundlage für die Prognose des Netzzustandes und damit auch für die Identifikation drohender Engpässe im Netz. Für das Engpassmanagement im Verteilnetz werden damit räumlich hoch aufgelöste Last- und Erzeugungsprognosen benötigt, die derzeit noch nicht verfügbar sind oder eine unzureichende Prognosegüte aufweisen. Eine weitere Herausforderung stellt – in Abhängigkeit von der Netzebene sowie dem jeweiligen Netzgebiet – die teilweise geringe Verfügbarkeit von prognoserelevanten Daten dar.</p>
Lösungsansatz	<p>Die Eignung von Prognoseverfahren aus dem Bereich KI/ML konnte für verschiedene Prognosefragen demonstriert werden. Eine für die Netzzustandsprognose hinreichende Prognosegüte kann für die Mittelspannung und höhere Spannungsebenen bei DA sowie ID-Prognosen erreicht werden.</p>
Einordnung in Prozessschema der Flexplattformen	<pre> graph LR Input[Wetter, Zeit, andere Inputgrößen] --> Erzeugung[Erzeugung (Wind, PV, Konventionelle)] Input --> Last[Last] Input --> Verfügbarkeit[Verfügbarkeit Flexibilitätsoptionen] Erzeugung --> Netzzustand[Netzzustand/ Engpass] Last --> Netzzustand </pre>
Technologiereifegrad	<p>1 2 3 4 5 6 7 8 9</p> <p>TRL 6 – 9: Von z. T. Demonstrationsanlage/-konzept in anwendungsähnlicher Umgebung funktioniert bis zu z. T. kommerziellem Einsatz.</p>
Eingeflossene SINTEG-Aktivitäten	<div style="display: flex; justify-content: space-between;"> <div style="text-align: center;"> <ul style="list-style-type: none"> ■ GridSage ■ Netz-sensitivitätsmatrix ■ Erweiterte PV-Stammdaten ■ ISInet ■ PV-Eigenverbrauchsprofile </div> <div style="text-align: center;"> <ul style="list-style-type: none"> ■ Prognoseservices für das NS-Netz </div> <div style="text-align: center;"> <ul style="list-style-type: none"> ■ Vertikale Netzlastvorhersage ■ e-Now Plattform ■ Simulationstool zukünftiger Netzbetrieb </div> <div style="text-align: center;"> <ul style="list-style-type: none"> ■ Szenarienbasierte Windprognosen ■ Prognoseoptimierung für Märkte und Systemführung </div> <div style="text-align: center;"> <ul style="list-style-type: none"> ■ Erzeugungsprognosen mit Smart-Meter-Daten </div> </div>
Innovationsgehalt	<ul style="list-style-type: none"> ■ Prognosemethoden im Bereich KI sind im Forschungskontext bereits etabliert. Im Rahmen von SINTEG konnten Methoden für verschiedene Anwendungsfälle im Energiebereich weiterentwickelt und in die Praxis übertragen werden. ■ Marktreife Lösungen für die Prognose von Last und Erzeugung auf Ebene der NS-/ MS-Umspannung konnten entwickelt werden.
Bedingungen für Übertragbarkeit und Skalierbarkeit	<ul style="list-style-type: none"> ■ In Abhängigkeit von Prognosefrage und Modellwahl wird ein Mindestmaß an Datenbasis benötigt (u. a. Erzeugungs-, Verbrauchszeitreihen). ■ Für Skalierung in der mittleren Frist ist Anpassung der Anreizregulierung notwendig sowie Rollout geeigneter IKT-Infrastruktur für Datenintegration, -aufbereitung, -verarbeitung.

PROBLEMSTELLUNG

Das Zusammenspiel von Erzeugung und Last bestimmt den Netzzustand und damit das Auftreten von Netzengpässen. Die Prognose von dezentraler – insbesondere erneuerbarer – Erzeugung und Last im Verteilnetz ist demnach essenziell für das Netzengpassmanagement. Die relevante Netzebene hängt dabei von den zu erwartenden Engpässen ab. Im Allgemeinen gilt, dass mit niedrigerer Spannungsebene die Anforderungen an Prognosesysteme steigen. Es werden Prognosen für geringe Poolgrößen und geringe räumliche Ausdehnungen der Netzgebiete benötigt. Damit fallen Ausgleichseffekte, die bei Prognosen auf Systemebene die Prognosequalität erhöhen können, auf Verteilnetzebene geringer aus. Derartige Ausgleichseffekte dämpfen bspw. den Einfluss kleinräumiger Wetterereignisse auf Energieprognosen.

Während derzeit eine mangelnde Datenverfügbarkeit für niedere Spannungsebenen eine Herausforderung darstellt, steigt perspektivisch die Durchdringung mit Anlagen (Erzeuger, Verbraucher, Netzbetriebsmittel), die Betriebsdaten messen und bereitstellen. Dies verbessert Beobachtbarkeit sowie Datenverfügbarkeit und ermöglicht neue Prognoseansätze. Gleichfalls steigt jedoch auch die Unsicherheit, da steuerbare Lasten zusätzliche Variabilität in die Einspeise- und Verbrauchsprofile von Prosumern bringen.

AUSSERHALB VON SINTEG ERREICHTER KENNTNIS- UND ENTWICKLUNGSSTAND

ML für Erzeugungs- und Lastprognosen wurden während der SINTEG-Laufzeit in den kommerziellen Einsatz überführt, um Prognosen der Netzbelastung im Übertragungsnetz zu unterstützen. Auch Energieprognosen in der für das Verteilnetz notwendigen Granularität wurden erst in den vergangenen Jahren als Forschungsgegenstand etabliert. Zugleich wurden Prognosen für die Verteilnetzebene auch als Anwendungsfeld für Methoden des ML/KI erschlossen.

IN SINTEG AUFGEZEIGTE WEITERFÜHRENDE LÖSUNGSANSÄTZE BZW. ALTERNATIVE LÖSUNGSANSÄTZE

Im Rahmen von SINTEG konnte durch den Einsatz von Methoden des ML eine Verbesserung der Prognosegüten erreicht werden. Es wurde demonstriert – teilweise im Rahmen von Forschungsprojekten, teilweise auch im Rahmen der praktischen Anwendung – dass die Ansätze für vielfältige Prognosefragen genutzt werden können: kurzfristige (ID, DA) Prognosen für Erzeuger und Lasten beliebigen Typs auf verschiedenen Aggregationsleveln, von der Einzelanlage bis hin zu aggregierten Lastflüssen auf höheren Spannungsebenen.

Der Einsatz von ML-basierten Prognosemodellen wurde dabei im Zusammenspiel mit weiteren Prognosekonzepten realisiert. Dadurch konnten Lösungen entwickelt werden, um die aufgezeigten Problemstellungen im Bereich der Energieprognose zu adressieren. In Tabelle 16 findet sich eine Erläuterung dieser Konzepte, hinterlegt mit konkreten Beispielen aus SINTEG sowie einer Zuordnung zu den adressierten Problemen.

Demonstrierte Prognosekonzepte, adressierte Herausforderungen und Aktivitäten der SINTEG-Schaufenster

Transfer Learning: Bei dieser Methode des ML wird das Modell einem mehrfachen Lernprozess unterzogen. Zunächst wird ein umfangreicher, generischer Datensatz (bspw. Einspeisezeitreihe einer PV-Anlage) für das Vortraining des Modells genutzt. Anschließend kann das Modell mit einem Datensatz geringeren Umfangs (bspw. Einspeisezeitreihe der zu prognostizierenden PV-Anlage) nachtrainiert werden und auf die spezifische Prognosefrage zugeschnitten werden.

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
	X	X	X

Mehrwert: Verringerter Datenbedarf

SINTEG-Aktivität: Im Schaufenster WindNODE entwickelte Solandeo eine kommerzielle Lösung für PV-Prognosen weiter (TAP 4.4). Datenbasis für das Training der ML-Modelle sind historische Zeitreihen anlagenscharfer Erzeugungszeitreihen sowie Wetterprognosen. Für jeden Anlagenstandort werden eigene Modelle (neuronale Netze) trainiert. Zunächst werden die Modelle auf Basis generischer Daten vortrainiert und anschließend mit standortspezifischen Daten nachtrainiert. Für letzteres ist nur ein geringer Datenumfang notwendig (eine Woche Trainingsdaten ausreichend). Durch diesen doppelten Trainingsprozess werden lokale Gegebenheiten in den Modellen besser abgebildet.

Referenzprognosen: Für die Prognose einer spezifischen Erzeugungs- und Verbrauchsanlage kann auf die Zeitreihendaten von ähnlichen Anlagen (bspw. gleicher Anlagentyp, räumliche Nähe) zurückgegriffen werden. Durch automatisierte Feature Selektion in Verbindung mit maschinellem Lernen können aus einem großen Pool an gemessenen Anlagen, diejenigen ausgewählt werden, die den größten Mehrwert für die Prognose der spezifischen Anlage liefern.

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
	X	X	X

Mehrwert: Zur Verfügung stehende Daten werden besser genutzt und die Prognosegüte kann verbessert werden.

SINTEG-Aktivität: Im Schaufenster WindNODE (TAP 4.4, Erzeugungsprognosen mit SM-Daten) entwickelte Solandeo eine kommerzielle Lösung für PV-Prognosen weiter. Für die Prognose greift das Modell auf die aktuelle Einspeisung der Anlage zurück. Ungemessene Anlagen können durch Referenzprognosen gemessener Anlagen mit nahem Standort abgebildet werden. Darüber hinaus kann das Modell auch auf die Messdaten eines Pools zahlreicher anderer, über Deutschland verteilter Anlagen zurückgreifen. Durch automatisierte Feature Selection kann das Modell aus den Daten dieses Anlagenpools diejenigen Anlagen und Standorte auswählen, aus denen sich Rückschlüsse auf die zu prognostizierende Anlage ziehen lassen. Die aktuelle Einspeisung der ausgewählten Anlagen findet dann ebenfalls Eingang in die Erzeugungsprognose. Dadurch können bspw. aufziehende Wetterfronten besser abgebildet werden. (WindNODE, 2020, 110f)

Nutzung zusätzlicher Datenquellen: Luftbilder – Mittels ML können Luftbilder analysiert werden, um die vorhandenen Stammdaten und GIS-Daten von Erzeugungsanlagen zu ergänzen. So können bspw. Standorte spezifiziert werden, oder Ausrichtung/Neigung von PV-Anlagen bestimmt werden.

Wolkenkameras – Durch Methoden der KI können Daten von Wolkenkameras, Strahlungs- und Verschmutzungssensoren ausgewertet werden, um lokale Kurzfristprognosen für PV-Einspeisung zu verbessern.

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
	X	X	X

Mehrwert: Die verbesserte Datengrundlage ermöglicht räumlich höher aufgelöste Prognosen und eine höhere Prognosegüte.



SINTEG-Aktivität: Im Schaufenster C/sells entwickelten Fraunhofer ISE/TenneT/KIT eine Methodik weiter, die es ermöglicht, mittels Bilderkennungsverfahren (Deep Learning, Convolutional Neural Networks) aus Luftbildern Azimut- und Neigungswinkel von PV-Anlagen zu ermitteln. Die im MaStR vermerkten Anlagen können durch das System identifiziert, verortet, kategorisiert und durch weitere technische Parameter beschrieben werden (kommerziell verfügbar unter dem Namen „greenventory“).⁴⁶ In Demonstrationen konnten 83 % der PV-Anlagen mittels Algorithmus lokalisiert und parametrisiert werden (C/sells, 2021, S. 151). Im Schaufenster C/sells wurden mit ISinet autarke Messsensoren mit Einstrahlungssensoren und Wolkenkameras entwickelt. Diese wurden am Flughafen Stuttgart genutzt, um Kurzfrist-PV-Prognosen zu verbessern (C/sells, 2021, S. 150–159).

Hierarchische Prognosen: Erzeugung und Last werden nach Technologien/Kundengruppen getrennt auf geringer Aggregationsebene prognostiziert und anschließend über die verschiedenen Netzebenen hinweg aggregiert. Bspw. kann der vertikale Lastfluss an der Umspannung zwischen zwei Netzebenen in Last- und Erzeugung der nachgelagerten Netzebene disaggregiert werden. Durch die Prognose von Last- und Erzeugung auf niedriger Aggregationsebene bis hin zur Prognose von Einzelanlagen kann die Prognose auf vorgelagerten Netzebenen verbessert werden, Spezifika einzelner Technologien/Kundengruppen können in den Prognosemodellen beachtet werden und Prognosen können unabhängig vom Schaltzustand des Netzes erstellt werden. Die Zuordnung von EE-Anlagen mit Netzanschluss in niedrigen Netzebenen zu Netzknotenpunkten in vorgelagerten Ebenen (bspw. HS/HöS) kann dabei auf Basis einer (dynamischen) Sensitivitätsmatrix vorgenommen werden.

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
X		X	X

Mehrwert: Prognosen in hoher Granularität, verbesserte Prognosegüte.

SINTEG-Aktivität: Im Schaufenster C/sells wurde durch das ZSW ein Gesamtkonzept für die Prognose dezentraler Erzeugung sowie Last für Verteilnetze umgesetzt (kommerziell verfügbar unter dem Namen „GridSage“) (Haller, Langniß, Reuter & Spengler, 2020; Tomschitz et al., 2020). Während für gemessene Erzeuger und Verbraucher (PV-Großanlagen, RLM-Kunden) mittels ML eigene anlagenscharfe Prognosen erstellt werden, werden Kleinanlagen und Kunden mit Standardlastprofil (SLP) entsprechend geografischer Nähe einem ONT zugewiesen und jeweils aggregiert als Pool auf ONT-Ebene prognostiziert.

Weiterhin wurde in C/sells durch TransnetBW eine dynamische Netzsensitivitätsmatrix entwickelt, die in Abhängigkeit von Schaltzustand des Netzes sowie aktueller Einspeise-/Lastsituation die Wirkung von EE-Anlagen auf Umspannpunkte bestimmt (TransnetBW, 2021).

Im Schaufenster enera demonstrierte energy & meteo systems ein Prognosesystem für die vertikale Netzlast eines Umspannwerkes (Goldkamp et al., 2021, 218f). Die vertikale Netzlast wird in Komponenten für einzelne Erzeugerarten und die Residuallast aufgespalten, welche jeweils getrennt prognostiziert werden. Ein ähnliches Vorgehen wurde in enera auch durch das Deutsche Zentrum für Luft- und Raumfahrt (DLR) demonstriert. Weiterhin implementierte der ÜNB TenneT die e-now Plattform, welche für Kurz-/Kürzestfristprognose eingesetzt werden kann. Es kommen hierarchische Prognosen zum Einsatz, wobei ausgehend von der PLZ-Ebene EE-Anlagen Netzknoten zugewiesen und aufaggregiert werden. (Goldkamp et al., 2021, S. 222–224)

Auch im Schaufenster NEW 4.0 setzten TenneT und das Fraunhofer IEE dieses Verfahren in Kombination mit „Extreme Machine Learning“ für die Prognose der vertikalen Lastflüsse an den HöS/HS-Transformatoren ein unter Berücksichtigung von Winderzeugungsprognosen. (NEW 4.0 - Norddeutsche Energiewende, 2021a, S. 847–849, NEW 4.0 - Norddeutsche Energiewende, 2021a, S. 31–36)

Kombination von Prognoseansätzen (Ensemble Machine Learning): Die Kombination verschiedener Prognoseansätze für die gleiche Prognosefrage kann die Prognosegüte erhöhen. So können bspw. mehrere Ansätze aus dem Bereich des ML kombiniert werden.

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
		X	X

Mehrwert: Verbesserte Prognosegüte, verbesserte Ausnutzung der vorhandenen Datenbasis.

⁴⁶ Siehe [greenventory.de](https://www.greenventory.de)

SINTEG-Aktivität: Im Schaufenster DESIGNETZ demonstrierte das Deutsche Forschungszentrum für Künstliche Intelligenz (DFKI) die Kombination verschiedener Prognoseansätze (case-based Reasoning, neuronale Netze, Random Forest), wobei eine Verbesserung der Güte von PV- und Lastprognose erreicht werden konnte. Die Prognosemethoden werden mit Hilfe von Ensemble Machine Learning kombiniert. (DESIGNETZ, 2021c, S. 473–487)

Probabilistische Prognosen: Die Verwendung probabilistischer Prognosen für Last- und Erzeugung ermöglicht eine Quantifizierung der Prognose inhärenten Unsicherheit – auch für die anschließende Prognose des Netzzustandes.

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
		X	

Mehrwert: verbesserter Informationsgehalt der Prognosen, auch bei abnehmender Prognosegüte für kleinräumige Netzgebiete.

SINTEG-Aktivität: Im Schaufenster NEW 4.0 untersuchte das Fraunhofer IEE probabilistische Windprognosen und den Einfluss der Unsicherheit auf die weitere Verwendung der Prognose im Rahmen der Netzzustandsrechnung (NEW 4.0 - Norddeutsche Energiewende, 2021a, S. 838–846). Methoden zur probabilistischen Prognose für das Engpassmanagement wurden in enera im Rahmen eines Simulationstools weiterentwickelt (Goldkamp et al., 2021, 92ff).

Nutzung von Live-Daten: Durch die zunehmende Verbreitung von gemessenen Anlagen (Erzeuger, Verbraucher, Netzbetriebsmittel) mit IKT-Anbindung stehen viele prognoserelevante Daten nicht nur als historische Datenreihe, sondern auch nah an Echtzeit zur Verfügung und können als Eingangsdaten für Prognosesysteme genutzt werden.

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
		X	X

Mehrwert: stark verbesserte Prognosegüte, insbesondere für den ID-Zeithorizont.

SINTEG-Aktivität: Die Verbesserung der Prognosegüte durch die Einbindung von Live-Daten wurde von mehreren Schaufenstern demonstriert. So nutzte bspw. das ZSW in C/sells Live-Daten der letzten 24h für die Erzeugungsprognose neben Stamm- und historischen Bewegungsdaten der Anlagen sowie Rohdaten verschiedener Wettermodelle als Eingangsdaten für einen maschinellen Lernprozess (Deep Neural Network, DNN).

Ähnliche Ansätze finden sich bspw. bei DESIGNETZ (DESIGNETZ, 2021c, S. 489–491) und WindNODE (WindNODE, 2020, 110f).

Akteursübergreifende Implementierung: Der Aufbau eines Prognosesystems erfordert den aktorsübergreifenden Austausch von Daten und die Definition entsprechender Schnittstellen. So können zusätzliche Datenquellen einbezogen werden.

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
X	X		

Mehrwert: Wege zur Implementierung aktorsübergreifender Plattformen für Datenaustausch wurden aufgezeigt.

SINTEG-Aktivitäten: Die Anbindung externer Prognosedienstleister an die IKT-Infrastruktur eines Netzbetreibers wurde in mehreren Schaufenstern demonstriert. Hierfür kamen teilweise dezidierte Datenplattformen zum Einsatz.⁴⁷ Beispiele finden sich in DESIGNETZ sowie C/sells (Anbindung ZSW an Stadtwerke Schwäbisch Hall).

Neue Standardlastprofile: Verbraucher ohne Lastgangmessung werden mittels Standardlastprofilen bilanziert und prognostiziert. Durch Berücksichtigung des PV-Eigenverbrauchs von Haushalten in den Profilen kann die Prognosegüte verbessert werden.



⁴⁷ Siehe hierzu Blaupause: Daten- und Serviceplattformen für aktorsübergreifenden Informationsaustausch, Abschnitt 2.6

Adressierte Herausforderungen bei Erzeugungs- und Lastprognosen:

Operationalisierung	Datenverfügbarkeit	Prognosegüte	Prognosen für MS-/NS-Netze
	X	X	X

Mehrwert: Verbesserte Lastprofile wurden entwickelt. Zudem wurde gezeigt, dass auch bei Nutzung synthetischer Last-/Erzeugungsprofile für Haushalte ohne gemessene Netzanschlüsse eine Netzzustandsbestimmung in der Niederspannung innerhalb des Toleranzbereiches möglich ist (C/sells, 2021, S. 297).

SINTEG-Aktivitäten: In C/sells wurden durch statistische Auswertung realer Last- und Erzeugungszeitreihen von Haushalten mit PV-Eigenverbrauch neue Lastprofile entwickelt (TransnetBW, 2021).

Weiterhin wurde eine Netzzustandsbestimmung für die Niederspannung auf Basis realer Messwerte und synthetischer Last-/Einspeiseprofile für das Testgebiet Hittistetten umgesetzt (C/sells, 2021, S. 295–312).

Tabelle 16: Demonstrierte Prognosekonzepte, zugeordnete SINTEG-Aktivitäten und erzielter Mehrwert für Umsetzung eines Prognosesystems

INNOVATIONSGEHALT

Energieprognosen mittels ML sowie die weiteren dargestellten Konzepte waren bereits vor SINTEG Forschungsgegenstände. Es konnte jedoch durch die Übertragung der Ansätze auf die Praxis der deutschen Energiewirtschaft (teilweise durch Implementierung, teilweise durch Nutzung entsprechender Daten und Netzmodelle) deren konkrete Anwendbarkeit in Bezug auf verschiedene Prognosefragen demonstriert werden. Im Einzelfall konnte eine Steigerung des Technologiereifegrades bis hin zur marktreifen Lösung erreicht werden.

BEDINGUNGEN FÜR ÜBERTRAGBARKEIT UND SKALIERBARKEIT

Voraussetzung für die Übertragung eines Prognosesystems ist die Verfügbarkeit der entsprechenden Datengrundlage. Netzbetreiber und/oder spezialisierte Dienstleister müssen hierfür ggf. neue Datenquellen erschließen und unter Berücksichtigung der Datenschutzerfordernungen in ihre IKT-Infrastruktur integrieren können. Bei den Verteilnetzbetreibern findet sich im Hinblick auf diese Voraussetzungen ein sehr diverses Bild – während einzelne Netzbetreiber relevante Datenquellen bereits umfangreich in Data Warehouse Systeme integriert haben, liegen bei anderen Netzbetreibern relevante Daten zur Netztopologie teilweise noch analog vor. Herausforderungen für die Datenintegration sind, dass diese mit einem hohen Aufwand einhergeht und sich nur bedingt automatisieren lässt. Erschwerend für die Übertragung von Prognosesystemen kommt hinzu, dass Netzbetreiber auf individuelle Lösungen für das Netzleitsystem zurückgreifen, wodurch manuelle Anpassungen bei der Integration von Prognosesystemen notwendig sind.

Die Skalierbarkeit der Lösungen ist damit zum heutigen Zeitpunkt auf Netzbetreiber begrenzt, die bereits eine entsprechende IKT-Infrastruktur vorweisen. Kurzfristig kann jedoch die Ausgestaltung einheitlicher Schnittstellen für den Datenaustausch sowie die fortschreitende Datenintegration bei Netzbetreibern die Skalierbarkeit verbessern.

Die wirtschaftlichen Vorteile verbesserter Prognosesysteme sind spezifisch für die jeweilige Netzsituation. Auf mittlere Frist können bei steigender Durchdringung mit volatilen EE und steuerbaren Verbrauchseinrichtungen bei vielen Verteilnetzbetreibern durch Prognosesysteme Effizienzpotenziale gehoben werden. Voraussetzung hierfür ist jedoch die Anerkennung der entstehenden Kosten in der Anreizregulierung.

Durch die Einführung des Redispatch 2.0-Regimes wurden auch Anlagen im Verteilnetz in das vorausschauende Netzengpassmanagement mit einbezogen. Für entsprechende Redispatch 2.0-Anlagen werden Prognosen mit einem DA-Zeithorizont benötigt. In SINTEG konnten hierfür wichtige Erfahrungen gesammelt werden.

WEITERE ENTWICKLUNGSMÖGLICHKEITEN

Weiterer Entwicklungsbedarf besteht im Hinblick auf die derzeit mangelhafte Datenverfügbarkeit, insbesondere bei Prognosen für die Niederspannungsebene. Während Prognosealgorithmen bereits eine praxistaugliche Güte erreicht haben, bleibt zu klären, wie bei möglichst geringen Investitionskosten die Erschließung von Datenquellen und damit die Beobachtbarkeit des Netzes verbessert werden kann: Welche neuralgischen Punkte im Netz sollten mit Messtechnik ausgestattet werden, um effizient prognoserelevante Daten zu liefern? Zwar konnte in SINTEG gezeigt werden, dass nach erfolgtem Smart-Meter-Rollout eine Netzzustandsschätzung für die Niederspannung auf Basis von iMSys-Daten möglich ist (Netzzustandserfassung Ulm Einsingen/Hittistetten, (C/sells, 2021, S. 287–312)). Gerade für die Phase des graduellen Smart-Meter-Rollouts bei geringer Datenverfügbarkeit werden jedoch neue Methoden benötigt – für die Zustandsschätzung sowie den gezielten Smart-Meter-Rollout.

Weiterer Entwicklungsbedarf besteht im Hinblick auf die Lastprognosen für Prosumer. Zwar wurden in SINTEG neue Standardlastprofile für Haushalte mit PV-Eigenverbrauch entwickelt, um die Prosumenten Ebene besser abbilden zu können; eine Berücksichtigung steuerbarer Lasten steht jedoch noch aus. Schließlich sinkt perspektivisch durch die Verbreitung steuerbarer Lasten die Güte der Lastprognose – solange Steuerungseingriffe nicht in der Prognose abgebildet werden können. Für geringe Aggregationsebenen wie die Niederspannungsebene werden damit perspektivisch Methoden benötigt, die individuelles Verbraucherverhalten besser abbilden können.

HANDLUNGSEMPFEHLUNGEN

Die Datengewinnung und -aufbereitung muss künftig eine stärkere Rolle in Demonstrationsprojekten einnehmen. Entwickelte Lösungen stehen häufig hinter dem eigentlichen Anwendungsfall der Daten zurück und sind wenig dokumentiert.

Im Forschungskontext ist die Vergleichbarkeit von Prognoseansätzen häufig nicht gegeben, da typischerweise auf eine projektspezifische Datenbasis zurückgegriffen wird. Das Etablieren eines offenen Datenaustauschs oder die Durchführung von Prognose-„wettbewerben“ kann die Entwicklungsdynamik steigern.

Die häufig verwendeten herstellereinspezifischen Datenmodelle und Schnittstellen schränken die Nutzbarkeit von Daten stark ein. Da Daten die Grundlage einer jeden Prognose darstellen, ermöglicht die breite Nutzung von Standards für Daten und Datenaustausch eine effizientere Datenverarbeitung und somit Prognoseerstellung. Zur Anwendung kommen kann hierbei das Common Information Model (CIM, siehe Synthesefeld 3 – Digitalisierung). Darüber hinaus kann der Zugriff auf regulatorisch geforderte, öffentliche Daten (bspw. Marktstammdatenregister) durch Schnittstellen verbessert werden. Auch der Umfang von Stammdaten sollte für verbesserte Energieprognosen erhöht werden. Die SINTEG-Erfahrungen zeigen, dass das Marktstammdatenregister derzeit nur mittels aufwändiger Datenaufbereitung für Prognosen genutzt werden kann.