

Entwicklung von Methoden zur Prognose der Blindleistungsbilanz von Mittelspannungsnetzen zur Steuerung eines dezentralen Blindleistungsabrufs

B.Eng. Johannes Rauch, M.Sc. Maksym Klitsman, M.Sc. Matthias Haslbeck,
Prof. Dr.-Ing. Oliver Brückl

OTH Regensburg, Forschungsstelle für Energienetze und Energiespeicher (FENES)
Seybothstraße 2, 93053 Regensburg

Tel.: +49 941-943-9885

E-Mail: johannes.rauch@oth-regensburg.de

Internet: www.oth-regensburg.de, www.fenes.net

1 Einleitung

Durch den starken Zubau an dezentralen Erzeugungskapazitäten ergeben sich bei den Verteilungsnetzbetreibern zunehmend Probleme bei der Erbringung von Systemdienstleistungen. Die Entwicklung neuartiger Regelkonzepte können hierbei Abhilfe schaffen. Ein Beispiel hierfür ist die Bereitstellung von Blindleistung aus bisher ungenutzten Quellen zur Kompensation des Netzblindleistungsverhaltens. Durch ihren gezielten Einsatz können durch Kompensationsmaßnahmen Investitionskosten beim Netzausbau eingespart werden. Das vom BMWi geförderte Forschungsprojekt SyNErgie (03/2015 bis 05/2018) beschäftigt sich mit der Weiterentwicklung von Netzplanungsprozessen [1]. Im Fokus steht dabei die Modellierung von Blindleistungsflüssen und die dezentrale Nutzung von Blindleistungsquellen (z. B. Wechselrichter, Ladedrosseln, Kondensatoren) in Mittelspannungsnetzen. Im Rahmen dieses Beitrags wird deshalb auf die Prognose des Gesamtblindleistungsverhaltens einer Netzgruppe mittels Regressions- und Zeitreihenanalyse eingegangen.

2 Dezentrales Blindleistungsregelkonzept

In großflächigen MS-Netzen wird aufgrund der fehlenden Kommunikationstechnik und räumlichen Verteilung von potenziellen Blindleistungsquellen die Entwicklung eines dezentralen autarken Regelkonzeptes angestrebt. Ziel ist es, die Blindleistungsquellen zu Zwecken des Blindleistungsbilanzausgleichs nur über lokal verfügbare Informationen (Messgrößen) und/oder historische Messdaten zu steuern. Damit entfällt eine aufwändige und kostenintensive Kommunikationsanbindung zur Netzleitstelle. Um einen dezentralen Blindleistungsabruf in Abhängigkeit einer definierten Kompensationszielsetzung Q_{Soll} an der jeweiligen Blindleistungsquelle koordinieren zu können, bedarf es geeigneter Methoden zur Prognose des Ist-Blindleistungsverhaltens Q_{Ist} am HS/MS-Transformator, auf die in den nachfolgenden Abschnitten näher eingegangen wird. Abbildung 2.1 illustriert das diskutierte Konzept.

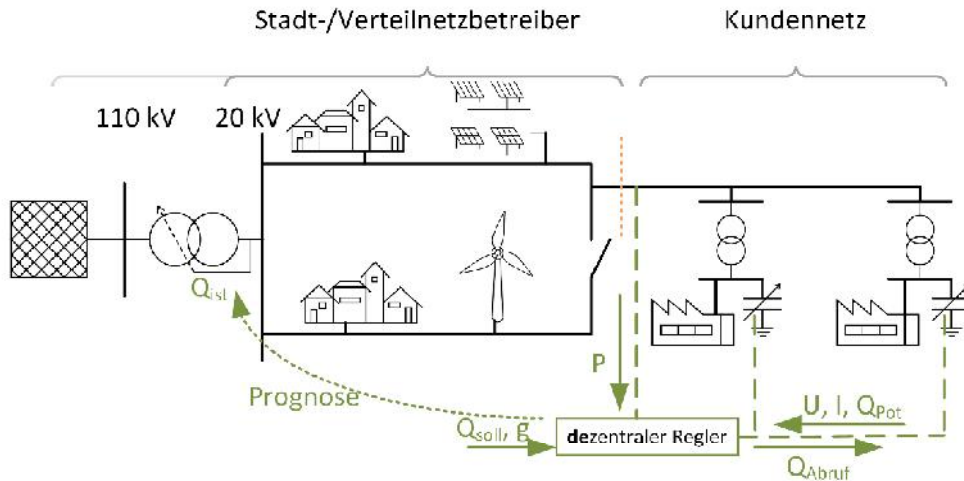


Abbildung 2.1: Steuerungsprinzip eines dezentralen Blindleistungsregelsystems, bei dem das Ist-Blindleistungsverhalten der Netzgruppe auf Basis lokaler Messgrößen der Blindleistungsquelle prognostiziert wird

3 Regressionsbasierte Prognose mittels lokaler Führungsgrößen

Als lokale Führungsgrößen werden direkt an der Blindleistungsquelle ermittelbare Größen (z. B. Wirkleistungsfluss, Spannung, Tageszeit oder Umgebungsbedingungen am Netzverknüpfungspunkt) bezeichnet, über die mittels Regressionsfunktionen eine Prognose abgeleitet werden kann. Um geeignete lokale Führungsgrößen zu identifizieren, eignet sich die Ermittlung von Korrelationskoeffizienten. Der Korrelationskoeffizient nach Bravais-Pearson (siehe Formel (1)) ist ein normiertes Maß für den linearen Zusammenhang zwischen zwei betrachteten Variablen. Der Korrelationskoeffizient kann Werte zwischen +1 (direkte Proportionalität) und -1 (umgekehrte Proportionalität) annehmen [2]:

$$r_{xy} = \frac{cov_{xy}}{s_x \cdot s_y} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}} \quad 3.1$$

Unter Regression versteht man die Beschreibung einer einseitig gerichteten stochastischen Abhängigkeit. Mit einer Regressionsfunktion lässt sich die Abhängigkeit der Zufallsvariable Q_{Prog} von einer (= einfache Regression) oder mehreren anderen (= multiple Regression) Variablen (= Führungsgrößen) x_k ($k = 1, \dots, m$) approximieren. Nach der Feststellung eines Zusammenhangs mittels einer Korrelationsanalyse besteht die Aufgabe der Regression darin, den identifizierten Zusammenhang mathematisch zu beschreiben. Im Falle einer multiplen linearen Regression wird eine Regressionsgleichung der Form

$$Q_{Prog} = b_0 + b_1 x_{i1} + b_2 x_{i2} + \dots + b_m x_{im}, \quad i = 1, \dots, n \quad 3.2$$

aufgestellt. Die sog. Regressionskonstante b_0 dient als Ausgleichskonstante und gibt den Schnittpunkt der Regressionshyperebene mit der Ordinatenachse an. Die Regressionsparameter b_1, \dots, b_m geben den mittleren partiellen Einfluss der Führungsgrößen x_k ($k = 1, \dots, m$) an und werden so gewählt, dass die mittleren quadratischen Abweichungen der Messpunkte minimal sind [2].

Zur Bewertung lokaler Führungsgrößen wurden umfangreiche Korrelationsuntersuchungen in einem realen Mittelspannungsnetz durchgeführt. Dieses besitzt eine Ausdehnung von 450 km², einen Verkabelungsgrad von 19 % und weist eine ländliche Topologie auf. Charakterisierend für dieses Netz ist der hohe Anteil an dezentralen Erzeugungsanlagen (EZA), der zu einer Rückspeisung von maximal 30 MW führt. Die installierte EZA-Leistung zeigt Abbildung 3.1.



Abbildung 3.1: Zusammensetzung der installierten Erzeugungsleistung unter Differenzierung des Anlagentyps

Abbildung 3.2 zeigt den Zusammenhang aller betrachteten Größen im Kontext der Korrelationsanalyse.

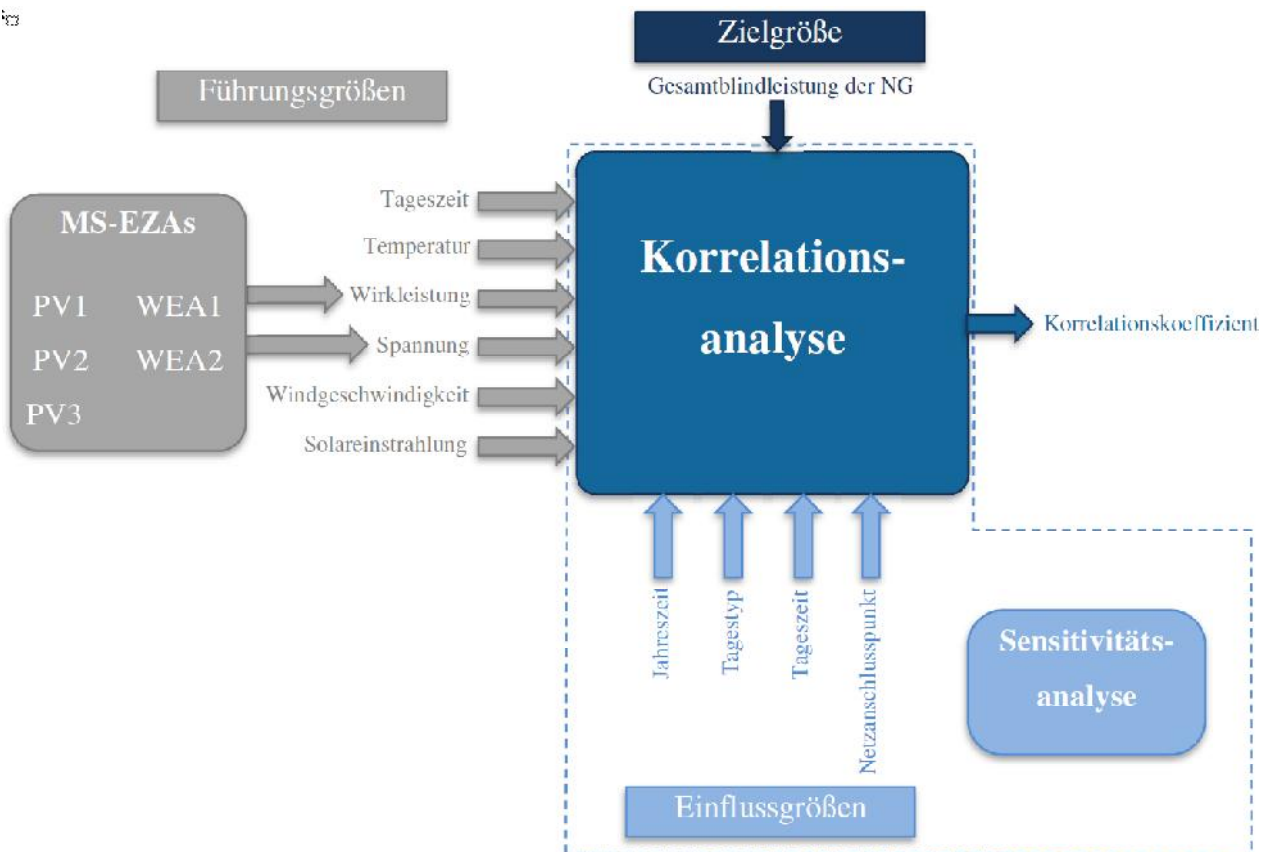


Abbildung 3.2: Auswerteprozess der betrachteten Führungs- und Zielgrößen unter Berücksichtigung verschiedener Einflussgrößen

Als Führungsgrößen werden Tageszeit, Temperatur, Windgeschwindigkeit, Solareinstrahlung sowie die Wirkleistung und Spannung von fünf verschiedenen MS-Erzeugungsanlagen untersucht, die als potentielle Blindleistungsquellen angesehen werden. Die Ergebnisse dieser Untersuchungen sind in Tabelle 3.1 zusammengefasst.

Tabelle 3.1: Übersicht über die Korrelationskoeffizienten aller betrachteten Führungsgrößen mit Einfärbung nach Betrag des Korrelationskoeffizienten (grün: hohe Korrelation; gelb: mittlere Korrelation; rot: geringe Korrelation)

Tageszeit t	Wirkleistung P	Solareinstrahlung I	Windgeschwindigkeit v	Spannung U	Umgebungstemp. T
0,07	PV1	0,77	0,3	PV1	0,35
	PV2	0,76		PV2	0,16
	PV3	0,75		PV3	0,37
	WEA1	0,05		WEA1	-0,10
	WEA2	0,03		WEA2	-0,46
		0,75			0,27

Während die Wirkleistung an den PV-Anlagen sowie die Solareinstrahlung die höchsten Korrelationen aufweisen, zeigen Tageszeit, P_{WEA1} , P_{WEA2} und U_{WEA1} über den gesamten Zeitraum global betrachtet keine Korrelation. Es ist erkennbar, dass v. a. PV-bezogene Führungsgrößen wie P_{PV} , I und U_{PV1} grundsätzlich am besten korrelieren. Der Hauptgrund liegt in der gleichzeitigen Einspeisung aller PV-Anlagen bei hoher Solareinstrahlung im betroffenen Netzgebiet. Der Bedarf an induktiver Blindleistung seitens der Netzbetriebsmittel steigt zu solchen Zeitpunkten mit zunehmender Auslastung überproportional an.

Der blau gestrichelte Bereich in Abbildung 3.2 stellt die Sensitivitätsanalyse der Korrelationsuntersuchung dar, bei der untersucht wurde, inwieweit sich die Einflussgrößen Jahreszeit, Tagestyp (Werktag, Wochenende, Feiertag), Tageszeit und Netzanschlusspunkt auf das Korrelationsverhalten der jeweiligen Führungsgröße zur Zielgröße Q_{Ist} auswirken. Die Sensitivitätsanalyse zeigt, dass v. a. die Tageszeit starke korrelative Schwankungen bei den betrachteten Führungsgrößen hervorruft. Diesen Zusammenhang lässt sich am Beispiel der Wirkleistungskorrelationen verdeutlichen. Da nachts keine PV-Einspeisung stattfindet, ist zu dieser Zeit keine Korrelation vorhanden. Die Einspeisedominanz wechselt in diesen Stunden deutlich zu den Windenergieanlagen, was sich positiv auf deren Korrelationsverhalten auswirkt. Abbildung 3.3 zeigt diesen gegensätzlichen Zusammenhang. In der Mittagszeit, in der die höchsten zu kompensierenden induktiven Blindleistungswerte auftreten, liefern die PV-Anlagen – bezogen auf ihre Wirkleistung – die höchste Prognosegenauigkeit, während die WEA keine Korrelation aufweisen. Der Tagestyp nimmt nur sehr wenig Einfluss auf die Güte des Korrelationsverhaltens. Allerdings ist zu berücksichtigen, dass hohe induktive Blindleistungswerte nur an Werktagen auftreten, wodurch ein absoluter Blindleistungswerteverrsatz auftritt, der vom Korrelationskoeffizient nicht erfasst wird.

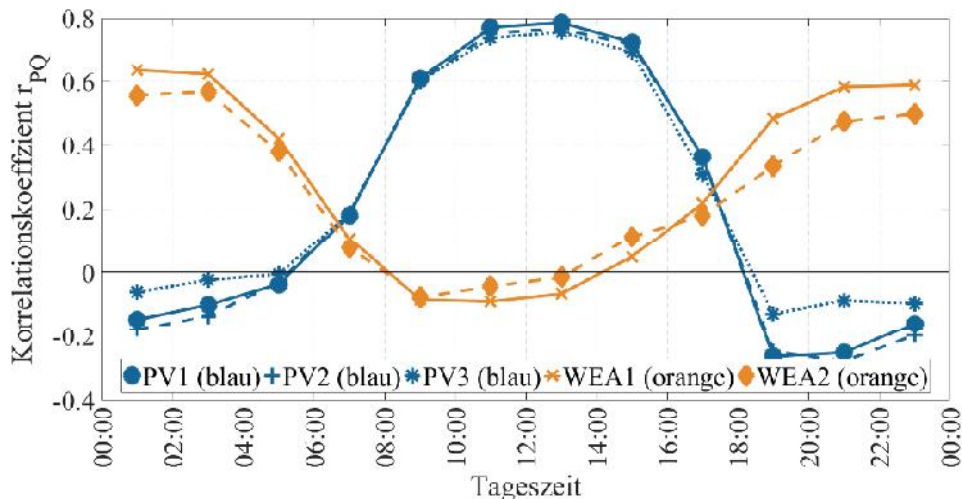


Abbildung 3.3: Verlauf der Korrelationskoeffizienten zwischen der Wirkleistung P aller betrachteten EZAs zur Blindleistung Q am UW-Transformator in Abhängigkeit der Tageszeit

Zusammenfassend wird für das dezentrale Regelkonzept im betrachteten Netz der Einsatz von PV-Anlagen befürwortet. Bei der Erstellung des Regressionsmodells ist es durch die leistungsbilanzierende Dominanz der PV-Anlagen in diesem Netz empfehlenswert, die Wirkleistung und/oder die Spannung an der jeweiligen PV-Anlage als Prädiktorvariable zu verwenden. Zur Erfassung der zeitlichen Einflussgrößen im Regressionsmodell werden die Regressionsparameter zu Vektoren $\vec{b}_1, \dots, \vec{b}_m$ erweitert. Es resultiert somit förmlich ein Prognosekatalog.

In einem benachbarten Mittelspannungsnetz wurden die Leistungsflussdaten eines lokalen Betriebes mit einer PV-Anlage analysiert. Die Kompensationsanlagen des Betriebes wurden im Rahmen des Projektes SyNERgie als potentielle Blindleistungsquellen für einen dezentralen Blindleistungsabruf identifiziert. Das Netz, in der dieser Betrieb angeschlossen ist, ist mit einem maximalen Lastbezug von ca. 10 MW und einer maximalen Rückspeisung von ca. 10 MW deutlich lastgeprägter als das vorhergehend betrachtete Netz. Daher wurde das Korrelationsverhalten neben der lokalen Führungsgrößen P_{PV} auch der Lastbezug des Betriebes $P_{Betrieb}$ zum Ist-Blindleistungsverhalten der Netzgruppe untersucht. Da der Leistungsbezug eines Betriebes i. d. R. vom betrachteten Tag abhängig ist, wurde bei den Analysen zwischen den Tagtypen (Werktag, Wochenende und Feiertag) differenziert. Tabelle 3.2 zeigt die errechneten Korrelationskoeffizienten.

Tabelle 3.2: Korrelationskoeffizienten zwischen dem Ist-Blindleistungsverhalten am UW und den lokalen Wirkleistungs-führungsgrößen unter Differenzierung des Tagtyps

Tagtyp	Korr.-koeffizient r_{PV}	Korr.-koeffizient $r_{Betrieb}$
Werktag	0,37	0,63
Wochenende	0,11	0,42
Feiertag	0,32	0,41

Es lässt sich erkennen, dass die Korrelation der Wirkleistung der PV-Einspeisung im Allgemeinen deutlich schlechter als in einem einspeisedominierenden Netz ist. Dagegen erhält man in diesem lastgeprägten Netz solide Korrelationen beim Wirkleistungsbezug des Betriebes (insbesondere an Werktagen). Der tagestypabhängige Bezug von Wirkleistung seitens des Betriebes führt aus oben genannten Gründen zu einer Variation des Korrelationskoeffizienten. Durch den verminderten Bezug an Wochenenden und Feiertagen ist die horizontale Ausdehnung der P-Q-Wolken in Abbildung 3.4 links geringer, was zu einer schlechteren Korrelation führt. Da das Blindleistungsverhalten am HS/MS-Transformator in diesem Netz hauptsächlich vom Lastverhalten der Betriebe beeinflusst wird und damit auch tagestypabhängig ist, ergibt sich in beiden Fällen in Bezug auf eine Differenzierung des Tagtyps eine vertikale Verschiebung der P-Q-Streudiagramme (vgl. Abbildung 3.4).

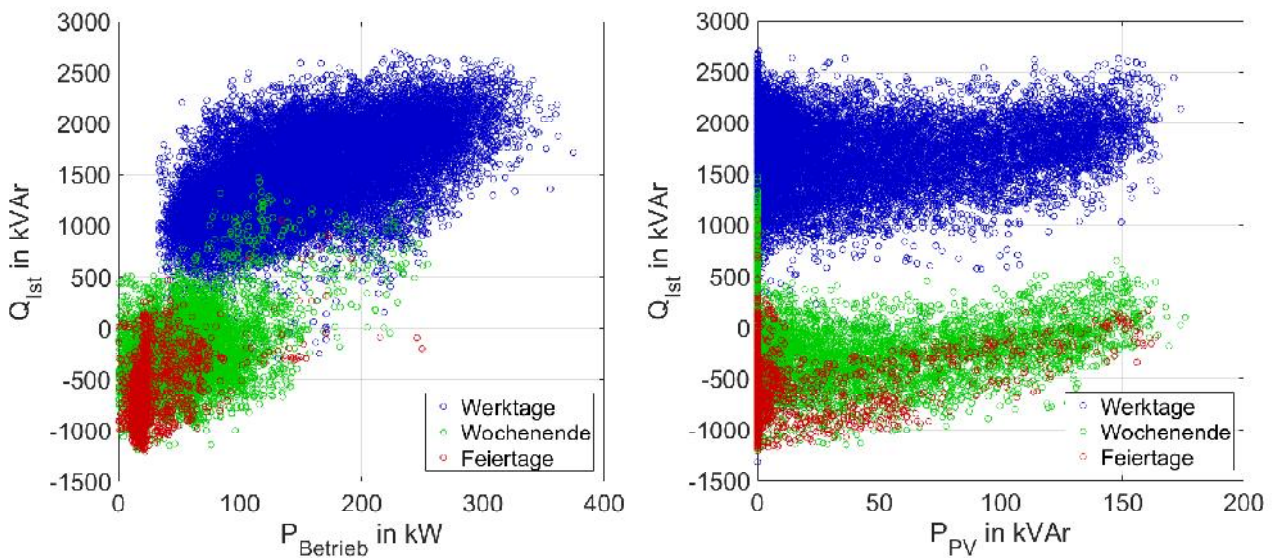


Abbildung 3.4: Korrelationsverhalten zwischen dem Wirkleistungsbezug des Betriebes (links) bzw. der Wirkleistungseinspeisung der betrieblichen PV-Anlage zum Ist-Blindleistungsverhalten des Netzes

Beide lokale Führungsgrößen werden als Prädiktorvariablen in eine multiple lineare Regressionsgleichung überführt, die mit Formel 3.3 beschrieben ist und mit den tagestypabhängigen Koeffizienten aus Tabelle 3.3 definiert ist:

$$Q_{Prog} = b_0(\text{Tagtyp}) + b_1(\text{Tagtyp}) \cdot P_{Betrieb} + b_2(\text{Tagtyp}) \cdot P_{PV} \quad 3.3$$

Tabelle 3.3: Koeffizientenkatalog der Regressionsparameter unter Differenzierung der Tagtypen

Tagtyp	b_0 in kVAR	b_1 in kVAR/kW	b_2 in kVAR/kW
Werktag	847	2,91	4,03
Wochenende	-521	2,98	2,87
Feiertag	-621	2,85	1,81

Abbildung 3.5 zeigt die mit Formel 3.3 errechnete Regressionsfläche zu den realen Daten am Beispiel des Tagtyps Werktag.

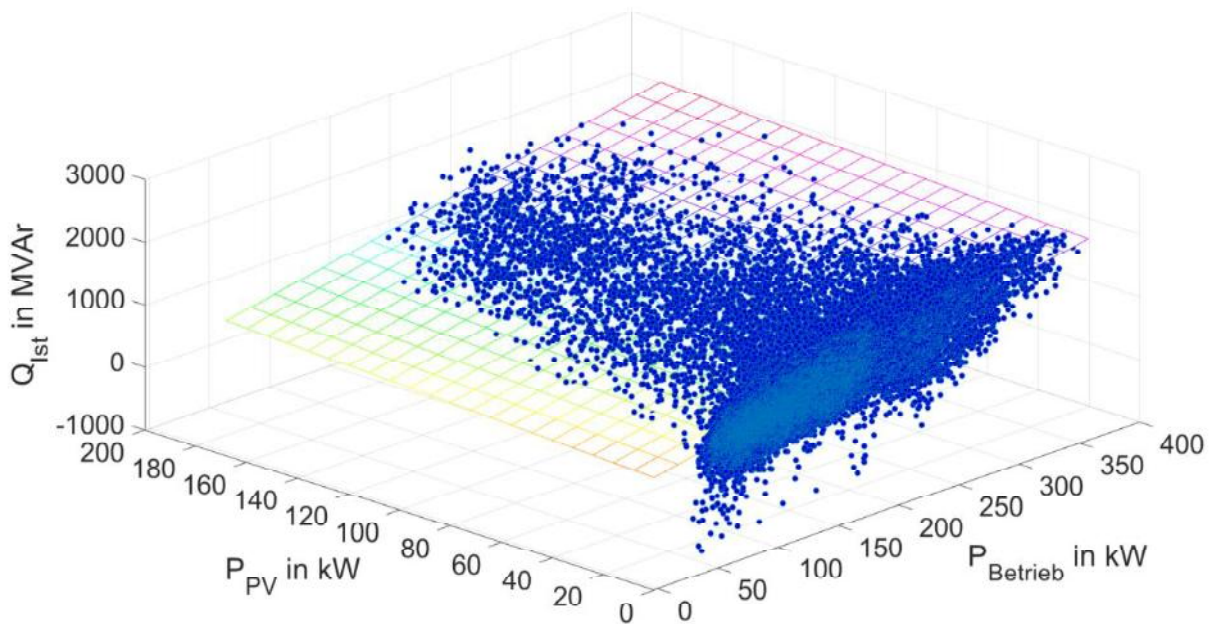


Abbildung 3.5: Regressionsfläche zur Regressionsfunktion für das Ist-Blindleistungsverhalten des Gesamtnetzes in Abhängigkeit der Wirkleistungseinepeisung der PV-Anlage und des Wirklastbezuges des Betriebes zu den realen Daten für den Tagtyp Werktag

4 Prognose mittels Zeitreihenanalyse

Als Alternative zur regressionsbasierten Prognosemethode wird die Zeitreihenanalyse mit dem additiven Komponentenmodell betrachtet. Dabei wird das bekannte zeitliche Verhalten $Q_{Ist}(t)$ nach dem klassischen Komponentenmodell der Zeitreihenanalyse in die Bestandteile Zyklus- (Z), Trend- (T) und Restkomponente (ϵ) zerlegt, die sich additiv überlagern [3].

$$Q_{Ist}(t) = Z(t) + T(t) + \epsilon(t) \quad 4.1$$

Anhand der Abbildung 4.1 soll die Zerlegung des zeitlichen Verhaltens $Q(t)$ aufgezeigt werden. Dazu ist ein exemplarischer Ausschnitt (drei Wochen) des Ist-Blindleistungsverhaltens eines Netzes, in dem der in Kapitel 3 vorgestellte Betrieb angeschlossen ist, in der Abbildung links oben gegeben. Die Zerlegung dieses Blindleistungsverhaltens erfolgt in eine Zykluskomponente $Z(t)$ (rechts oben, mit Mittelwert), Trendkomponente $T(t)$ (links unten) und Restkomponente $\epsilon(t)$ (rechts unten). Die zyklische Komponente $Z(t)$ (vgl. Abbildung 4.1 rechts oben) beschreibt Werte, die aus dem gemittelten Wochenverlauf eines Jahres für jeden 15-Minuten-Wert resultierten. Diese Komponente gibt die tageszeitlichen und uhrzeitabhängigen Schwankungen in einer Woche wieder und beinhaltet in diesem Fall den Gleichanteil des zeitlichen Verhaltens $Q(t)$. Die Trendkomponente $T(t)$ wird nach der Methode des einfachen zentrierten gleitenden Durchschnitts mit gerader Ordnung ermittelt. Dabei werden fortlaufend aus $n = 2k$ Werten der Zeitreihe arithmetische Mittelwerte für jeden 15-Minuten-Wert gebildet [4].

$$T(t) = \frac{1}{2k} \sum_{t-k}^{t+k-1} x(t)$$

4.2

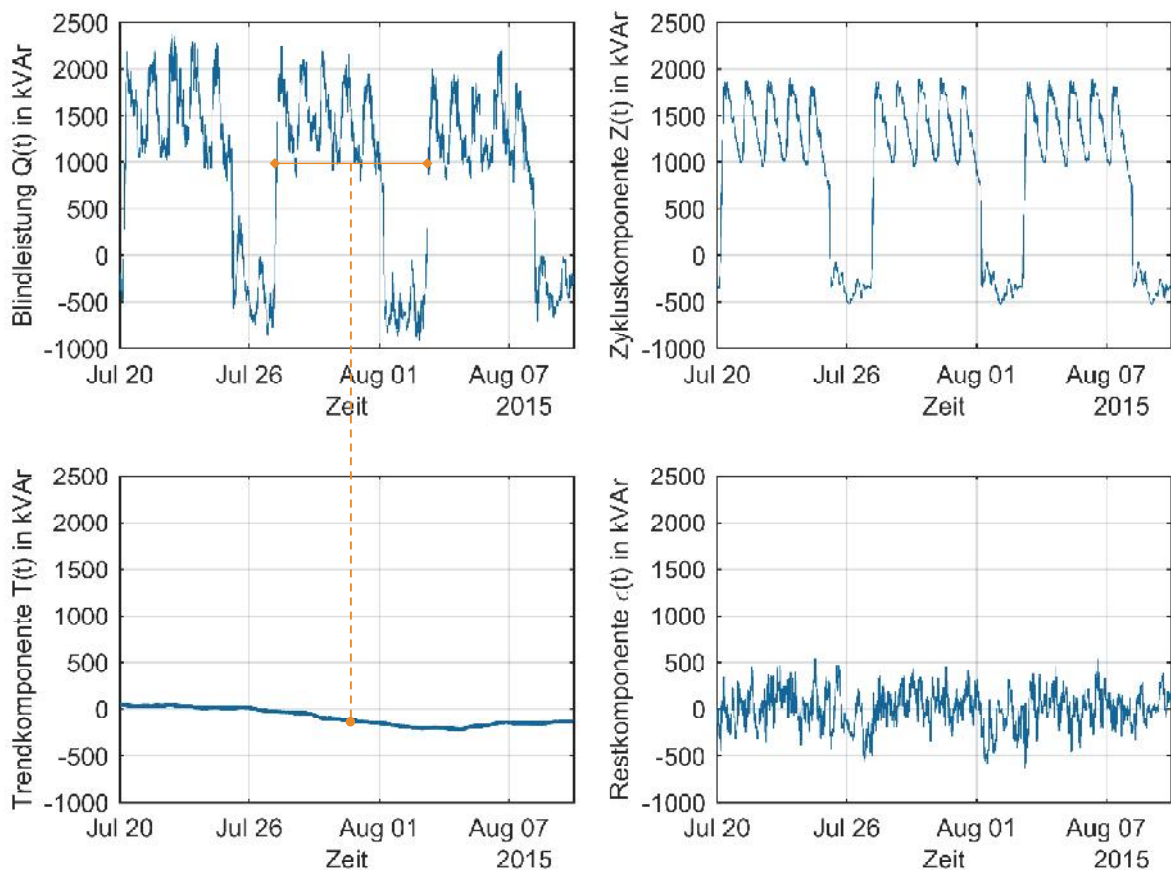


Abbildung 4.1: Zeitlicher Verlauf (Ausschnitt von drei Wochen im Jahr 2015) der zu prognostizierenden Zeitreihe $Q(t)$ links oben sowie deren additive Zerlegungskomponenten: Zykluskomponente mit Mittelwert $Z(t)$ rechts oben, Trendkomponente $T(t)$ links unten und Restkomponente $\epsilon(t)$ rechts unten

Der Trend spiegelt damit den jahreszeitlichen Einfluss außerhalb der zyklischen Komponente wider, indem die langfristige systematische Veränderung des mittleren Niveaus der Zykluskomponente bestimmt wird. Für jeden 15-Minuten-Wert wird so das arithmetische Mittel für den Datensatzumfang n einer Zykluskomponente errechnet. In Bezug auf eine 15-Minuten-Auflösung und eine Zyklusdauer von einer Woche werden $n = 2k = 672$ Werte in die Berechnung aufgenommen. Im Messdatenverlauf in Abbildung 4.1 links oben ist die Spannweite der berechnungsrelevanten Daten (orange) zu einem beispielhaft errechneten Trendkomponentenwert (in Abbildung 4.1 links unten orange markiert) aufgezeigt. Die Restkomponente $\epsilon(t) = Q(t) - [Z(t) + T(t)]$ fasst Einflüsse und Störungen zusammen, die nicht durch die beiden anderen Ursachenkomponenten erklärt werden können [3]. Im betrachteten Datensatz besitzt die zyklische Komponente (auch mit einer Gleichanteilsbereinigung) den größten additiven Anteil, während der Trend und die stochastische Unsicherheit hinsichtlich der Restkomponente eher gering ausfällt. Der langfristig leicht absinkende Verlauf der Messdaten über die drei Beispielwochen lässt sich im Trend gut erkennen.

Für die Prognose des darauffolgenden Jahres wird konstatiert, dass die drei Komponenten unverändert bleiben. Jeder 15-Minuten-Wert wird additiv aus der Zyklus- und Trendkomponente errechnet. Da das Verhalten der Restkomponente stochastischer Natur ist, wird diese bei der Berechnung der zu prognostizierenden Zeitreihe ausgeschlossen und somit ein Erwartungswert verwendet.

$$Q_{prog}(t) = Z(t) + T(t) \quad 4.3$$

Es ist anzumerken, dass – unabhängig von dieser Komponentenrekonstruktion – Zeitreihen von Feiertagen des Vorjahres zu den Feiertagen des zu rekonstruierenden Jahres kalendarisch zugeordnet und unverändert übernommen werden. Schaltjahre werden durch Anpassung der Anzahl der zu prognostizierenden Tage berücksichtigt. Durch eine zusätzliche Transformation der Restkomponente in den Frequenzbereich mittels Fourieranalyse können deterministische Schwingungsanteile detektiert werden (siehe Abbildung 4.2).




Abbildung 4.2: Zeitliches Verhalten der Restkomponente ϵ des Blindleistungsverhaltens $Q(t)$ (links) und dessen Transformation in den Frequenzbereich mit Amplitudenspektrum (rechts)

Diese Anteile können mit ihrer Amplituden- und Phaseninformation zusätzlich in die Prognosezeitreihe aufgenommen werden. Untersuchungen anhand der vorliegenden Messdaten zeigen, dass die Verbesserung der Prognose dadurch nur geringfügig ist. Tabelle 4.1 stellt die anhand Formel 4.4 ermittelten Standardabweichungen s der Abweichungen x_i der prognostizierter Q -Zeitreihe Q_{prog} von den realen Blindleistungsmessdaten eines Netzes Q_{Ist} für zwei exemplarische Jahre dar.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad 4.4$$

Tabelle 4.1: Mittelwert und Standardabweichungen der Abweichungen der Prognosen von den realen Q-Messdaten für zwei exemplarische Prognosejahre

Prognosejahr	Abweichungen der Prognose von der Messzeitreihe			
	Mittelwert \bar{x} in kVAr		Standartabweichung s in kVAr	
	Ohne FA*	Mit FA	Ohne FA	Mit FA
2015	43,56	43,47	317,65	315,27
2016	-166,95	-166,74	286,60	279,17

*FA = Fourier-Analyse

5 Evaluierung der Prognosemethoden im Rahmen eines Feldversuchs

Die beiden vorgestellten Prognosemethoden werden im Rahmen des Forschungsprojektes SyNErgie anhand realer Messdaten aus einem Feldversuch mit den in Abschnitt 3 erwähnten Betriebes evaluiert. Dazu werden die Wirkleistungsbezüge des Betriebes P_{Betrieb} , die PV-Einspeisung P_{PV} und das Ist-Blindleistungsverhalten am UW-Transformator Q_{Ist} gemessen. Die beiden lokalen Wirkleistungsflüsse dienen als Führungsgrößen für die regressionsbasierte Prognose anhand Formel 3.3. Die Zeitreihenanalyse wird anhand Formel 4.3 durchgeführt. Die beiden prognostizierten Zeitreihen $Q_{\text{Regression}}$ (orange) und $Q_{\text{Zeitreihenanalyse}}$ (blau) werden dem realen Ist-Blindleistungsverhalten Q_{Ist} (schwarz) in einem exemplarischen Ausschnitt von zwei Wochen in Abbildung 5.1 gegenübergestellt.

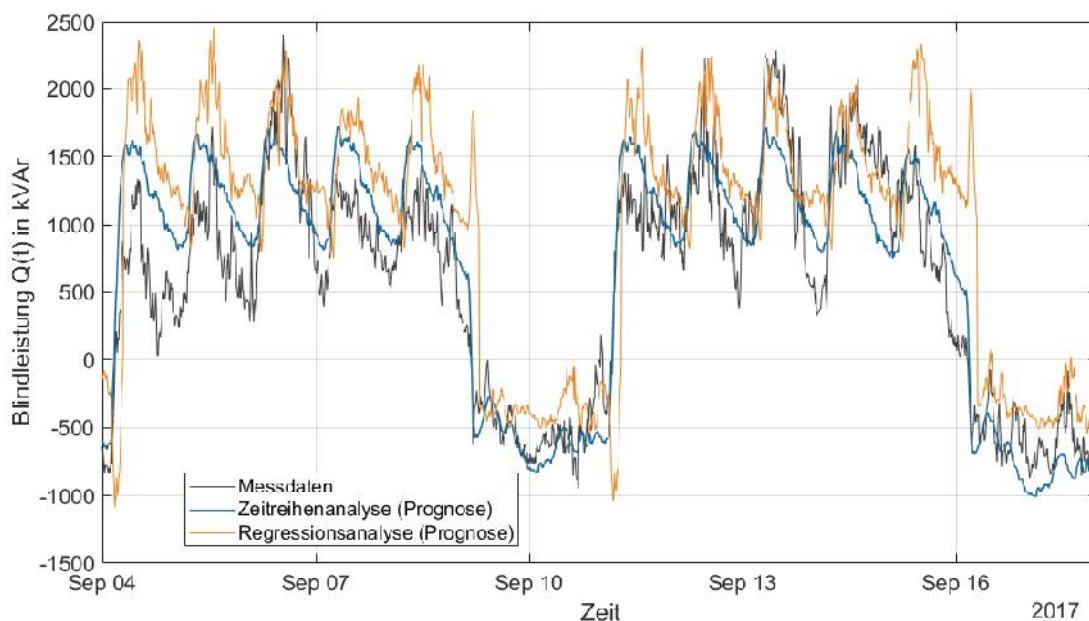


Abbildung 5.1: Vergleich der Blindleistungsprognosen mit den vorgestellten Methoden zum realen Ist-Blindleistungsverhalten am UW- am Beispiel von KW 36/37 (Jahr 2017) mit realen Messdaten aus dem Feldversuch

In den dargestellten Wochen zeigen sich allgemein nur geringe Abweichungen zwischen Prognose- und Messwerten. Dabei können die Prognosen keine stochastischen Abweichungen vom „Normalverhalten“ erfassen. Das lässt sich am Beispiel des dritten Tages der ersten Woche erkennen, wo das reale Blindleistungsverhalten auf ein lokales Maximum ansteigt. Da dieses Maximum vom tagestypischen Verlauf abweicht, kann es durch die Prognose mittels Zeitreihenanalyse nicht genau prognostiziert werden. Die regressi-

onsbasierte Prognose liefert hier ein zuverlässigeres Ergebnis. Für die zwei dargestellten Wochen ist jedoch erkennbar, dass die Prognose mittels Regression zu einer leichten Überschätzung neigt. Zum Vergleich der beiden Prognosevarianten werden deren Abweichungen anhand von Verteilungsdarstellungen in Abbildung 5.2 dargestellt.

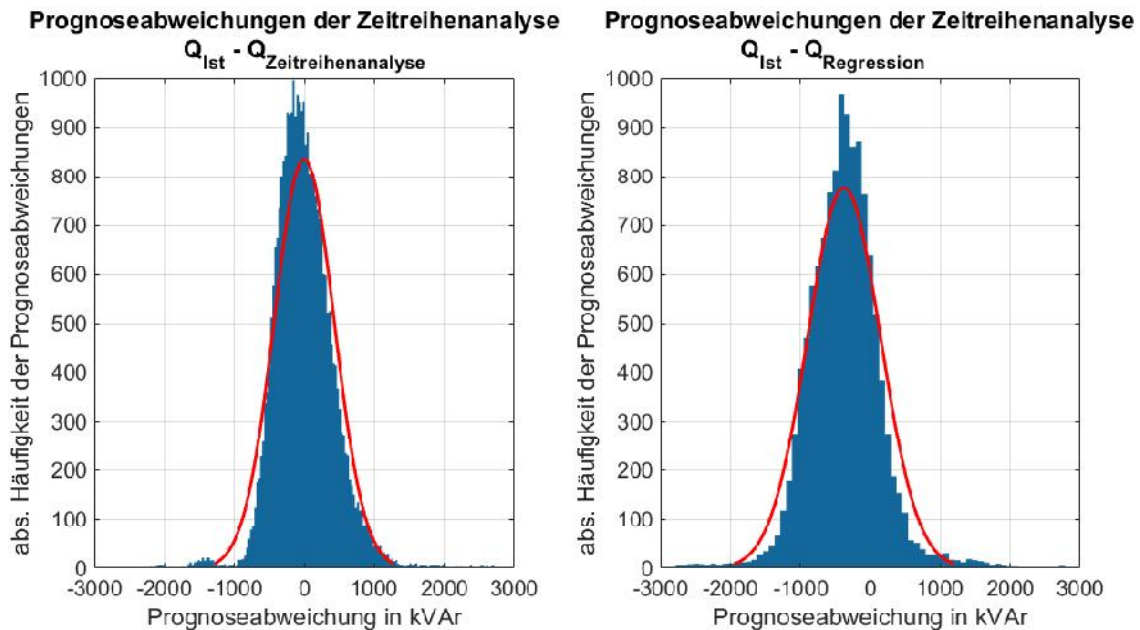


Abbildung 5.2: Vergleich der betrachteten Prognosemethoden anhand deren Abweichungen zu den realen Messdaten

Tabelle 5.1 zeigt den Mittelwert und die Standardabweichung der Verteilungsfunktionen. Es kann konstatiert werden, dass beide Verteilungen der Prognoseabweichungen annähernd normalverteilt und damit stochastischer Natur sind. Dabei ist in diesem Anwendungsfall die Prognose mittels Zeitreihenanalyse präziser. Zu erkennen ist dies an der geringeren Standardabweichung und an einem zentralen Mittelwert nahe 0 (vgl. dazu Tabelle 5.1). Der Mittelwert der Prognoseabweichungen der Regression zeigt, dass diese Prognosemethode in diesem Fall zu einer leicht überhöhten Prognose gegenüber den realen Blindleistungsverhalten neigt.

Tabelle 5.1: Mittelwert und Standardabweichungen der Abweichungen der betrachteten Prognosemethoden

Tagtyp	Mittelwert \bar{x} in kVAr	Standardabweichung s in KVar
Prognose mit Zeitreihenanalyse	-2,3	427,7
Prognose mit Regressionsanalyse	-374,7	523,7

Für den betrachteten Anwendungsfall lässt sich auf Basis der Ergebnisse festhalten, dass grundsätzlich beide Prognosemethoden geeignet sind. Der Grund hierfür liegt, dass das Netz, in dem sich der betrachtete Betrieb befindet hinsichtlich installierter Erzeuger- und Verbraucherleistung ausgeglichen ist. Die Prognose mittels Zeitreihenanalyse liefert präzisere Prognoseergebnisse. Das Blindleistungsverhalten dieses Netzes ist also verstärkt vom zeitlichen Verhalten der angeschlossenen Betriebe abhängig.

6 Zusammenfassung

Im Rahmen dieses Beitrags konnten verschiedene Methoden zur Prognose des Gesamtblindleistungsverhalten eines MS-Netzes aufgezeigt werden. Entscheidend für die Wahl der Prognosemethode ist die Art des MS-Netzes und der Blindleistungsquelle. Es ist zu analysieren, welche Abnehmer oder Einspeiser das Gesamtblindleistungsverhalten maßgeblich beeinflussen. An diesen „Verursachern“ ist eine hohe Prognosegenauigkeit möglich. Sie eignen sich daher besonders als Blindleistungsquellen. In EZA-geprägten Netzen stellt die regressionsbasierte Prognosemethode an EZA als Blindleistungsquellen eine gute Wahl dar. Dabei eignen sich v. a. Führungsgrößen an EZA, deren Anlagentyp im Netz leistungsmäßig dominierend vorherrscht. Die Prognose mittels Zeitreihenanalyse ist in solchen Netzen an EZA mit volatilen Einspeisecharakteristiken aufgrund der mangelnden zeitlichen Abhängigkeit nicht zielführend. In lastdominierenden Netzen ist der Wirk- und Blindleistungsfluss über den Umspannwerkstransformator v. a. durch betriebliche Lastbezüge charakterisiert, die einer zeitlichen Abhängigkeit unterliegen. In diesem Fall eignet sich v. a. die Zeitreihenanalyse als Prognosemethode. Durch die im Rahmen eines Feldversuches gewonnenen Daten konnten die Prognosemethoden getestet werden. Für das betrachtete Netz, in dem die installierte Erzeuger- und Verbraucherleistung ausgeglichen ist, zeigten beide Methoden gute Ergebnisse. Die Zeitreihenanalyse hat sich im dargestellten Anwendungsfall als präzisere Methode erwiesen.

Literaturverzeichnis

- [1] Forschung Stromnetze, *SyNErgie (Systemoptimierenden Netz- und Energiemanagement der Zukunft: Neues Blindleistungsmanagement für Verteilnetze*. [Online] Verfügbar unter: <http://forschung-stromnetze.info/projekte/neues-blindleistungsmanagement-fuer-verteilnetze/>. Zuletzt geprüft am: 14.12.2017.
- [2] B. Rönz und E. Förster, *Regressions- und Korrelationsanalyse: Grundlagen, Methoden, Beispiele*. Wiesbaden: Gabler, 1992.
- [3] R. Schlittgen und B. H. J. Streitberg, *Zeitreihenanalyse*, 9. Aufl. München: Oldenbourg, 2001.
- [4] H. Holland und K. Scharnbacher, *Grundlagen der Statistik: Datenerfassung und -darstellung, Maßzahlen, Indexzahlen, Zeitreihenanalyse*, 8. Aufl. Wiesbaden: Gabler, 2010.