

Modellierung der zukünftigen Netznutzung elektrischer Übertragungssysteme als stochastischer Prozess

Andreas Moormann, Oliver Scheufeld, Simon Krahl, Albert Moser

Forschungsgemeinschaft für Elektrische Anlagen und Stromwirtschaft e.V. (FGH)
Roermonder Straße 199, 52072 Aachen, Deutschland; +49 241 99785716
andreas.moormann@fgh-ma.de; <http://www.fgh-ma.de>

Kurzfassung: Zur Gewährleistung einer sicheren, zuverlässigen und effizienten Versorgung mit elektrischer Energie führen europäische Übertragungsnetzbetreiber (ÜNB) die Prozesse der Betriebsplanung und -führung aus. Die Komplexität beider Prozesse hat sich durch die Veränderungen im europäischen Energieversorgungssystem in den letzten Jahren deutlich erhöht. So führen insbesondere in Deutschland der stetige Anstieg der Anzahl und damit verbunden der installierten Kapazität von Erzeugungsanlagen auf Basis erneuerbarer Energien (EE-Anlagen) und die zunehmende Integration nationaler Märkte zu einem gemeinsamen europäischen Markt für elektrische Energie zu Differenzen zwischen den im Rahmen der Betriebsplanung verwendeten Prognosen der Netznutzung und dem tatsächlich in Echtzeit realisierten Netznutzungsfall (NNF) zu einem definierten Zeitpunkt.

Um diesen Herausforderungen zu begegnen, wird in diesem Beitrag ein Modell vorgestellt, das die zukünftige Netznutzung als Markoff-Kette nachbildet. Ziel ist es, auf Basis historischer Netznutzungsfälle eine Gruppierung (Clustering) vorzunehmen, d.h. eine Zuordnung mehrerer NNF mit ähnlicher Charakteristik zu einem Cluster durchzuführen. Das gesamte Cluster kann nach erfolgter Zuordnung durch einen NNF repräsentiert werden. Mit Hilfe dieses Modells lässt sich weiterhin ableiten, welche Cluster im nächsten Zeitschritt zu erwarten sind. Der Vorteil dieser Modellierung liegt in der Tatsache, dass es nicht erforderlich ist, die bei einer stündlichen Auflösung vorliegenden 24 NNF eines Tages individuell zu prüfen, sondern allein durch die Zuordnung zu einem Cluster Aussagen über die einem NNF zeitlich folgenden NNF treffen zu können. Somit ist es möglich, die Prognoseunsicherheiten implizit zu berücksichtigen und die im Rahmen der Betriebsplanung dazu notwendigen Berechnungen und Simulation auf einige wenige repräsentative NNF zu beschränken.

Keywords: Übertragungsnetzbetrieb, Netznutzung, Clustering, Markoff-Kette

1 Einleitung

Die Betriebsplanung und -führung stellen Kernaufgaben europäischer ÜNB zur Gewährleistung einer sicheren und zuverlässigen Versorgung mit elektrischer Energie dar. Durch die politisch getriebene Entwicklung der Anzahl und der installierten Erzeugungskapazität von EE-Anlagen in Deutschland [1] sowie die durch die Europäische Kommission vorangetriebene Integration nationaler Märkte für elektrische Energie [2] hat sich die Komplexität dieser Kernaufgaben deutlich erhöht. Die genannten Entwicklungen haben u.a. zur Folge, dass die absoluten Prognosefehler der Einspeisung aus EE-Anlagen sowie des grenzüberschreitenden Austauschs stetig größer werden und folglich das Vorhandensein entsprechender Maß-

nahmen zur Sicherstellung der Systemsicherheit während des Betriebsführungsprozess zwingend erforderlich ist. Weiterhin verursacht die aufgezeigte Entwicklung, dass Erfahrungswerte aus der Vergangenheit, welche die Basis für betriebliche Heuristiken bilden, für die Beherrschung zukünftiger Situationen nicht mehr ausreichend sein werden.

Um dieser Entwicklung und den daraus resultierenden Folgen zu begegnen, stellt dieser Beitrag eine Option vor, die zukünftige Netznutzung als stochastischen Prozess zu modellieren. Dieser Lösungsansatz erlaubt dabei, einen prognostizierten NNF zu klassifizieren und die durch die Prognosefehler verursachten Unsicherheiten vereinfacht und implizit zu berücksichtigen, indem der prognostizierte NNF durch einen vorab identifizierten NNF des entsprechenden Clusters repräsentiert wird. Somit kann bereits auf Analysen und Simulationen zurückgegriffen werden, die für diesen repräsentativen NNF vorab durchgeführt worden sind. Darüber hinaus erlaubt die Ermittlung von Übergangswahrscheinlichkeiten zwischen den verschiedenen Clustern eine Vorhersage für die zeitlich folgenden NNF. Durch diesen Schritt wird der notwendige Betrachtungsbereich aller potenziell auftretenden NNF deutlich eingeschränkt.

In einem ersten Schritt werden im Folgenden die aktuellen Betriebsplanungsprozesse eines europäischen Übertragungsnetzbetreibers vorgestellt. Hier liegt der Fokus auf dem sog. „Day-Ahead Congestion Forecast“ (DACF). Im Anschluss erfolgt die für diesen Beitrag relevante Definition des Systemzustands. Die Berücksichtigung von Prognoseunsicherheiten im Rahmen des DACF-Prozesses ist Gegenstand des vierten Kapitels. Hier wird nach einer Einleitung in die Thematik die Zusammenfassung historischer NNF in Gruppen adressiert. Weiters wird die Formulierung der Optimierungsaufgabe vorgenommen. Abgeschlossen wird das Kapitel mit der Beschreibung einer Modellierung der Netznutzung als stochastischer Prozess. Das nachfolgende Kapitel hat das methodische Vorgehen zum Inhalt. Nach der Vorstellung der hier gewählten Methodik folgt die Beschreibung des angewendeten Clustering-Algorithmus'. Der letzte Abschnitt dieses Kapitels bildet die Bestimmung der Markoff-Kette als gewählten stochastischen Prozess. Die Funktionalität des vorgestellten Modells wird anhand exemplarischer Ergebnisse nachgewiesen. Den Abschluss des Beitrags bilden eine Zusammenfassung sowie ein Ausblick auf weiterführende Entwicklungsschritte.

2 Betriebsplanungsprozesse

Der Betriebsplanungsprozess europäischer ÜNB lässt sich in zahlreiche zeitlich aufeinanderfolgende Stufen unterteilen. Er beginnt mit einem maximalen Planungshorizont von ungefähr einem Jahr und endet unmittelbar vor bzw. mit der (Echtzeit-) Betriebsführung. Dabei sind die Übergänge zwischen den Stufen mit dem jeweils größten und kleinsten Planungshorizont und den zeitlich angrenzenden Prozessen fließend, d.h. eine exakte Abgrenzung zur Netzplanung (Planungshorizont > 1 Jahr) und der Betriebsführung (Echtzeit) ist nicht sinnvoll definierbar.

Die hier im Folgenden vorgestellte Modellierung der zukünftigen Netznutzung bezieht sich in erster Linie auf den Zeithorizont der vortäglichen Stufe des Betriebsplanungsprozesses, welche von den Mitgliedern des „European Network of Transmission System Operators for Electricity“ (ENTSO-E) in Form des sog. DACF durchgeführt wird [3]. Hierbei handelt es sich um eine kurzfristige Prognose des quasi-stationären Leistungsflusses zu definierten Zeitpunkten des Folgetages. Weiters erfolgt eine Bewertung der Systemsicherheit auf Basis der

Ergebnisse von Ausfallsimulationen unter Berücksichtigung des N-1 Kriteriums. Ein schematischer Überblick des Prozesses ist in Abb. 1 dargestellt.

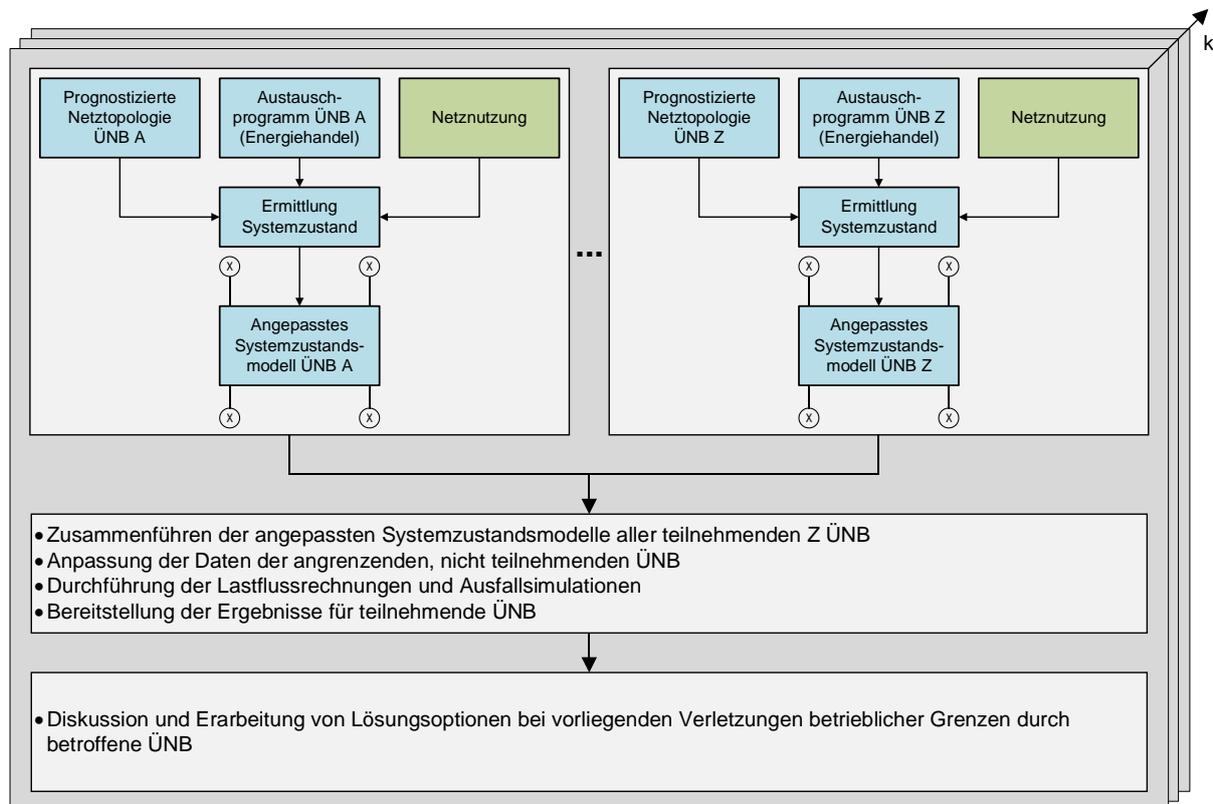


Abbildung 1: Schema DACF-Prozess (vgl. [3])

Die am in Abb.1 dargestellten Prozess teilnehmenden Z ÜNB ermitteln aus ihrer prognostizierten Netztopologie, dem Austauschprogramm mit anderen (angrenzenden) ÜNB sowie der Netznutzung den Systemzustand für einen der k definierten Zeitstempel des Folgetags. In der Regel wird dieser Prozess für jede Stunde des Folgetags durchgeführt, d.h. in diesem Fall gilt $k = 24$. Nach Anpassungen des Systemzustandsmodells durch den jeweiligen ÜNB unter Einbeziehung der Verbindungen mit dem Netzen angrenzender ÜNB (X-Knoten), wird der resultierende Datensatz an eine zentrale Einrichtung übermittelt. Hier werden die Datensätze zusammengeführt und Anpassungen bzw. Ergänzungen für jene Netzbereiche vorgenommen, deren verantwortliche ÜNB nicht an diesem Prozess teilnehmen. Im Anschluss erfolgt die Durchführung von Leistungsflussrechnungen und Ausfallsimulationen, deren Ergebnisse den teilnehmenden ÜNB zur Verfügung gestellt werden. Sofern diese Ergebnisse Verletzungen betrieblicher Grenzen aufweisen, erfolgt eine Diskussion der betroffenen ÜNB, die in der Erarbeitung von Lösungsoptionen mündet. Falls erforderlich wird der vorangegangene Arbeitsschritt wiederholt.

Ein zentrales Eingangsdatum für diesen Prozess ist die stündliche Prognose aller Lasten und Einspeisungen des Folgetags. Die Kombination bzw. Aggregation aller Lasten und Einspeisungen für einen der 24 definierten Zeitpunkte in einem betrachteten Netzbereich wird als NNF bezeichnet und ist in Abb. 1 in grün dargestellt.

3 Systemzustand

Zur Nachbildung des europäischen Übertragungsnetzes, welches als Basis für das in Abbildung 1 dargestellte Systemzustandsmodell dient, wird auf ein Knoten-Zweig-Modell zurückgegriffen. Das Prinzip dieses Modellierungsansatzes ist in Abbildung 2 exemplarisch skizziert.

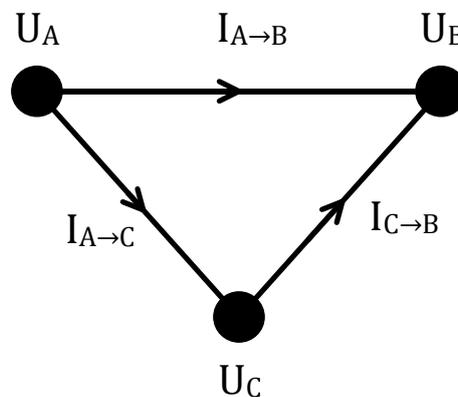


Abbildung 2: Exemplarisches Knoten-Zweig-Modell zur Modellierung eines elektrischen Netzwerks

Neben den Knotenspannungen U_A , U_B und U_C beschreiben die Zweigströme $I_{A \rightarrow C}$, $I_{A \rightarrow B}$ und $I_{C \rightarrow B}$ den quasi-stationären Zustand des in Abb. 2 dargestellten Systems. Anhand dieser beiden Systemgrößen wird im Rahmen des DACF-Prozesses ermittelt, ob sich das betrachtete System zu einem der definierten Zeitpunkte des Folgetages voraussichtlich in einem sicheren, gefährdeten oder kritischen Zustand befinden wird. Dazu werden Grenzen für die Knotenspannungen und die Zweigströme definiert, bei deren Annäherung sich das System in einem gefährdetem und bei deren Überschreitung es sich in einem kritischen Zustand befindet. Neben der Topologie des betrachteten Systems beeinflusst die Netznutzung die Höhe der auftretenden Systemgrößen maßgeblich und unmittelbar. Daher erlaubt eine Prognose zukünftiger NNF unter Berücksichtigung ihrer Zeitkopplung einen Rückschluss auf den resultierenden Systemzustand im Rahmen des Betriebsplanungsprozesses für elektrische Übertragungsnetze.

4 Berücksichtigung von Prognoseunsicherheiten

4.1 Einleitung und Hintergrund

Im Rahmen dieses Beitrags beschränkt sich die Modellierung von Prognoseunsicherheiten für den Betriebsplanungsprozess von elektrischen Übertragungsnetzen auf die Netznutzung. Weitere Unsicherheiten wie beispielsweise die Verfügbarkeit von Betriebsmitteln werden im Folgenden nicht behandelt.

Die Netznutzung umfasst alle Einspeisungen und Lasten verursacht durch Erzeuger und Verbraucher elektrischer Energie, die mittel- und unmittelbar an das Übertragungsnetz angeschlossen sind. Im Einzelnen sind dies EE-Anlagen, konventionelle (thermische) Kraftwerke sowie die vertikale Netzlast, die an den Knoten des Übertragungsnetzes angeschlossen bzw. wirksam sind. Hierbei setzt sich die vertikale Netzlast aus allen Lasten und Einspeisungen

zusammen, welche auf einer unterlagerten Spannungsebene an das Energieversorgungssystem angeschlossen sind, aber auf einen Übertragungsnetzknotten wirken. Die Mehrzahl der EE-Anlagen ist in Deutschland in den dem Übertragungsnetz unterlagerten Verteilungsnetzen angeschlossen und ist somit Teil der vertikalen Netzlast. Aus der Subtraktion der vertikalen Netzlast und aller unterlagerten Einspeisungen lässt sich die sog. bereinigte Netzlast ermitteln.

Während die Prognose der bereinigten Netzlast seit Jahrzehnten zu den Aufgaben der Betriebsplanung gehört, stellt die Prognose der Einspeisung aus EE-Anlagen eine neue Herausforderung für ÜNB dar. Diese Prognosen sind aufgrund verschiedener Einflüsse mit Unsicherheiten behaftet. Einer der wesentlichen Einflussfaktoren auf die Exaktheit der Prognosen ist in beiden Fällen die Wettervorhersage. Dies beruht einerseits auf der Temperaturabhängigkeit der Netzlast, andererseits auf der Abhängigkeit der EE-Erzeugungsanlagen vom Dargebot ihrer jeweiligen Primärenergieträger (Wind bzw. solare Einstrahlung).

Auf Basis historischer Netznutzungsfälle werden ähnliche NNF gruppiert. Dieser Verfahrensansatz wird im Folgenden näher erläutert.

4.2 Gruppierung von historischen Netznutzungsfällen

Übertragungsnetzbetreibern steht in der Regel eine umfangreiche Datenbasis historischer Netznutzungsfälle z.B. aus vergangenen Betriebsplanungsprozessen oder periodisch durchgeführten Momentaufnahmen („Snapshots“) des Übertragungssystems zur Verfügung. Diese unter Umständen sehr großen Datenbestände können genutzt werden, um Regelmäßigkeiten, Wiederholungen bzw. Gesetzmäßigkeiten in der Netznutzung zu identifizieren.

Auf Basis einer geeigneten Definition der Ähnlichkeit von Netznutzungsfällen können diese in Gruppen zusammengefasst werden. Die derart ermittelten Gruppen können demnach typische Muster in der Netznutzung widerspiegeln, z.B. Situationen mit geringer Verbrauchslast oder hoher Einspeisung aus dargebotsabhängigen EE-Anlagen.

Mit Hilfe dieser Gruppen ist es ÜNB möglich, Systemanalysen bzw. -berechnungen durchzuführen, die jeweils eine konsistente Aussage für die gesamte Gruppe liefert. So können auf diese Weise beispielsweise optimale Schaltzustände für einen Einsatz in der Betriebsplanung ermittelt werden, da aufgrund betrieblicher Randbedingungen eine Identifikation wiederkehrender Schaltzustände sinnvoll ist [4].

Insbesondere zur Reduktion der benötigten Rechenzeit ist die Modellierung einer Gruppe von NNF durch einen *repräsentativen* NNF zumeist unabdingbar. Weiterhin ist es vorteilhaft in Abhängigkeit vom konkreten Anwendungszweck die Anzahl gewünschter Gruppen von NNF vorzugeben. Die Gruppenbildung von Netznutzungsfällen ist eine Optimierungsaufgabe, deren Formulierung im folgenden Kapitel 4.3 vorgenommen wird.

Neben der individuellen Bewertung bzw. Optimierung einer Gruppe von NNF kann aufgrund der erläuterten Unsicherheiten in der Netznutzung ebenfalls der Übergang von einer Gruppe in eine andere bedeutsam sein. Im genannten Beispiel zur Ableitung optimaler Schaltzustände auf Basis der gebildeten Gruppen muss der Übergang von einem Schaltzustand in den anderen technisch möglich sein [4]. Zu diesem Zweck wird im Kapitel 4.4 eine Beschreibung der zukünftigen Netznutzung durch einen stochastischen Prozess hergeleitet.

4.3 Formulierung der Optimierungsaufgabe

4.3.1 Einleitung

Zunächst wird eine mathematische Formulierung der Optimierungsaufgabe zur Gruppierung von NNF in generischer Form hergeleitet. Im vorherigen Abschnitt wurde die Aufgabe als eine Zusammenfassung von „ähnlichen“ NNF zu einer Gruppe definiert. Die ermittelten Gruppen werden im weiteren Verlauf als Cluster bezeichnet und das methodische Vorgehen zur Ermittlung der Cluster dementsprechend als Clustering-Algorithmus. In diesem Abschnitt wird zunächst eine allgemeine Formulierung der Optimierungsaufgabe beschrieben. Die benötigte Definition der Ähnlichkeit von NNF erfolgt in Kapitel 5.

In Gleichung (1) werden die Eingangsdaten der Optimierungsaufgabe definiert. Hierbei handelt es sich um m historische, zeitlich aufeinander folgende NNF. Jeder NNF besteht aus einem Datenvektor a^i im d -dimensionalen Raum. Dabei gibt d die Anzahl der Datenpunkte pro Netznutzungsfall an. Die Anzahl entspricht hier der Summe der relevanten Lasten bzw. Einspeisungen multipliziert mit dem Faktor zwei zur Berücksichtigung sowohl der Wirk- als auch der Blindleistung.

$$\{a^1, a^2, \dots, a^m\}; a^i \in \mathbb{R}^d; m \in \mathbb{N} \quad (1)$$

4.3.2 Variablen

Gemäß Abschnitt 4.2 soll jedes Cluster von NNF möglichst durch einen repräsentativen NNF modelliert werden. Im Rahmen anschließender Systemberechnungen soll dieser NNF stellvertretend für das gesamte Cluster zu denselben Erkenntnisse führen, wie eine vollständige Berücksichtigung aller NNF des entsprechenden Clusters.

Daher werden als Variablen der Optimierung sogenannte Clusterzentren verwendet. Die mathematische Formulierung ist in (2) vorgenommen. Jedes Clusterzentrum C^j entspricht einem Datenvektor im d -dimensionalen Raum, d.h. es hat dieselbe Dimension wie ein NNF. In Gleichung (2) gibt n die Anzahl der Cluster an.

$$\{C^1, C^2, \dots, C^n\}; C^j \in \mathbb{R}^d \quad (2)$$

4.3.3 Nebenbedingungen

Die Optimierungsaufgabe unterliegt Nebenbedingungen, die im Folgenden erläutert werden. Nach Festlegung der Optimierungsvariablen soll eine eindeutige Zuordnung der NNF zu den entsprechenden Clustern erfolgen. Diese Zuordnung wird mit Hilfe der Variable $A_{i,j}$ beschrieben und gibt an, ob der NNF i zum Cluster j zugehörig ist. Diese Variable darf somit nur Werte der Menge $\{0,1\}$ annehmen. Eine teilweise Zuordnung von NNF zu Clustern ist nicht zulässig. Die Zuordnung eines NNF zu einem Cluster wird auf Basis der Funktion $g(a^i, C^j)$ entschieden. Der Funktionswert von $g(\cdot)$ entspricht der noch zu definierenden „Ähnlichkeit“: Je kleiner der Wert dieser Funktion, desto ähnlicher sind der NNF und das Clusterzentrum. Allgemein wird der Funktionswert als sogenanntes Proximitätsmaß bezeichnet, da die Verwendung sowohl von Ähnlichkeits- als auch Distanzmaßen (auch: *Unähnlichkeitsmaße*) üblich ist. Grundsätzlich wird somit ein NNF demjenigen Cluster zugeordnet, für dessen Zentrum

das Proximitätsmaß den kleinsten Zahlenwert annimmt. Zusammengefasst gibt Gleichung (3) die beschriebene Nebenbedingung an.

$$A_{i,j} = \begin{cases} 1, & \text{falls } g(a^i, C^j) \leq g(a^i, C^k); \forall k \in \{1, \dots, n\}; k \neq j \\ 0, & \text{sonst} \end{cases} \quad (3)$$

Weiterhin darf jeder NNF nur genau einem Cluster zugeordnet werden. Diese Nebenbedingung ist durch Einhaltung der Gleichung (4) erfüllt.

$$\sum_{j=1}^n A_{i,j} = 1; i = 1, \dots, m \quad (4)$$

Darüber hinaus ist in dieser Ausarbeitung gefordert, dass die Anzahl der zu ermittelnden Cluster exogen vorgegeben wird. Dieser Sachverhalt ist in Nebenbedingung (5) formalisiert, wobei $N_{Cluster}$ die Anzahl an gewünschten Clustern beschreibt.

$$n = N_{Cluster} \quad (5)$$

4.3.4 Zielfunktion

Die generische Formulierung der Zielfunktion ist in Gleichung (6) gegeben. Die Zielfunktion $f(A_{i,j}, a^i, C^j)$ ermöglicht die Bewertung einer Clusterlösung, d.h. von Clusterzentren und zugeordneten NNF: Je kleiner der Wert dieser Funktion, desto besser wird eine entsprechende Clusterlösung bewertet.

$$f(A_{i,j}, a^i, C^j) \rightarrow Min; \forall i \in \{1, \dots, m\}; \forall j \in \{1, \dots, n\} \quad (6)$$

4.4 Beschreibung der Netznutzung als stochastischen Prozess

Ein stochastischer Prozess ist eine mathematische Beschreibung zeitlich geordneter, jedoch zufälliger Abfolgen. Ein NNF beschreibt die Nutzung des Übertragungssystems zu einem definierten Zeitpunkt. Im Rahmen der Betriebsplanungsprozesse werden zeitlich aufeinander folgende NNF prognostiziert. Aufgrund der zugrunde liegenden Unsicherheiten und der gewählten Modellierung, kann die Netznutzung im Rahmen der Betriebsplanung als zeitdiskreter und stochastischer Prozess beschrieben werden. In diesem Beitrag wird die Netznutzung mit Hilfe einer homogenen Markoff-Kette abgebildet. Hierbei entspricht ein Zustand der Markoff-Kette einem Cluster von historischen Netznutzungsfällen. Die sequentielle Abfolge der historischen Netznutzungsfälle erlaubt in diesem Zusammenhang eine Bestimmung der Übergangswahrscheinlichkeiten von einem Cluster in einen anderen (siehe Kapitel 5).

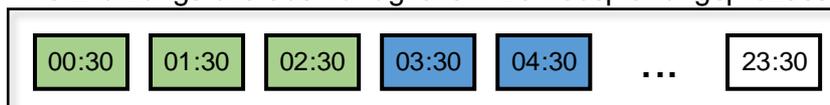
Durch Anwendung einer Markoff-Kette wird vorausgesetzt, dass Zustandsänderungen mit ausreichender Genauigkeit von der Vergangenheit unabhängig sind und somit nur durch den aktuellen Zustand bestimmt sind („Gedächtnislosigkeit“) [5]. Diese Voraussetzung ist mathematisch in Gleichung (7) dargestellt. Liegen somit die Clusterzuordnungen (entspricht dem Zustandsraum der Markoff-Kette) vergangener Netznutzungsfälle (entsprechen den Zufallsvariablen der Markoff-Kette) vor, so hängt die Wahrscheinlichkeit, mit der ein NNF $t+1$ zum Cluster k_{t+1} gehört, nur von k_t und nicht von k_0, \dots, k_{t-1} ab.

$$\begin{aligned}
 &P(A_{t+1,k_{t+1}} = 1 | A_{1,k_1} = 1, \dots, A_{t-1,k_{t-1}} = 1, A_{t,k_t} = 1) \\
 &= P(A_{t+1,k_{t+1}} = 1 | A_{t,k_t} = 1); k_t \in \{1, \dots, n\}
 \end{aligned}
 \tag{7}$$

Übertragen auf den hier skizzierten Anwendungsfall der Markoff-Ketten, kann die Gedächtnislosigkeit nicht ohne weiteres postuliert werden. So ist es z.B. denkbar, dass der Übergang von einer Gruppe von NNF in eine andere Gruppe durchaus von den Vorzuständen abhängt. Als exemplarisches Beispiel sei die Einspeisung elektrischer Energie durch Windenergieanlagen (WEA) genannt. So kann nicht ausgeschlossen werden, dass der Übergang einer Gruppe von NNF, die maßgeblich durch eine geringe Einspeisung aus WEA geprägt ist, über eine Gruppe mit mittlerer Windeinspeisung hin zu einer mit hoher Windeinspeisung stattfindet, d.h. die Übergangswahrscheinlichkeit von einem „mittleren“ in ein „hohes“ Cluster kann sehr wohl vom Vorzustand (hier: „gering“) beeinflusst sein. Da jedoch davon auszugehen ist, dass ein Cluster nicht ausschließlich durch die Varianz eines Faktors (hier: Windeinspeisung) charakterisiert ist, sondern vielmehr aus einer Kombination der Varianzen aller relevanten Faktoren zurückzuführen ist, erscheint es zulässig, die für die Anwendung von Markoff-Ketten erforderliche Eigenschaft der Gedächtnislosigkeit anzunehmen

Die Anwendung und der Nutzen der so ermittelten Markoff-Kette im Betriebsplanungsprozess werden im Folgenden anhand eines qualitativen Beispiels verdeutlicht. Im Rahmen der vortäglichen Betriebsplanungsprozesse werden im DACF-Prozess 24 zeitlich aufeinander folgende Netznutzungsfälle prognostiziert. Diese Netznutzungsfälle können nun den bestehenden Clustern mit Hilfe des Proximitätsmaßes zugeordnet werden. Im Beispiel nach Abb. werden die ersten drei Netznutzungsfälle Cluster B und die darauffolgenden Netznutzungsfälle Cluster D zugeordnet. Neben dem bereits prognostizierten Übergang von Cluster B nach D, ist ebenfalls ein Übergang von Cluster B nach C gemäß der Markoff-Kette wahrscheinlich. Somit kann der ÜNB diese Information im Betriebsplanungsprozess nutzen und z.B. bei der Auswahl von Maßnahmen zur Vermeidung von Grenzwertverletzungen berücksichtigen.

Netznutzungsfälle aus vortäglichem Betriebsplanungsprozess



Markoff-Kette der Netznutzung auf Basis historischer Daten

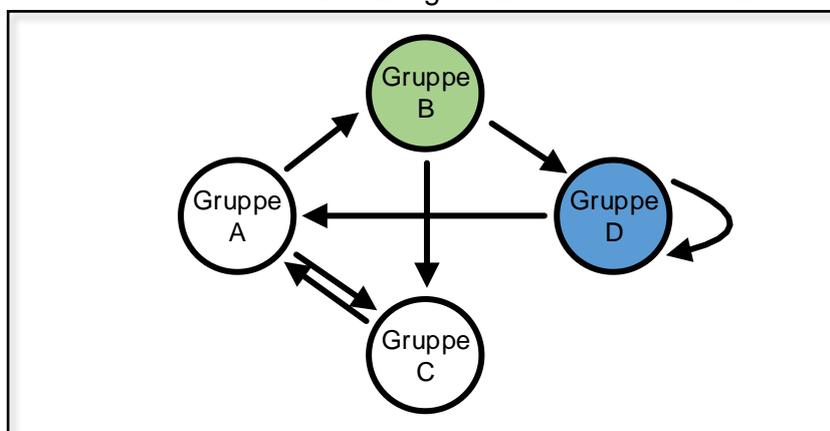


Abbildung 3: Beispiel zur Zuordnung von Netznutzungsfällen zum Markoff-Prozess

5 Methodisches Vorgehen

5.1 Auswahl der verwendeten Methodik

Clustering-Algorithmen lassen sich in graphentheoretische, hierarchische und partitionierende Verfahren unterteilen. Zusätzlich bietet sich grundsätzlich die Anwendung von meta-heuristischen Optimierungsverfahren zur Lösung der in Kapitel 4.3 formulierten Aufgabe an.

Sowohl graphentheoretische als auch hierarchische Verfahren zeichnen sich unter anderem dadurch aus, dass eine einmal festgelegte Zuordnung von Eingangsdaten zu Clustern im Verfahrensverlauf nicht mehr verändert wird. Demgegenüber kann bei partitionierenden Verfahren eine stetige Umgruppierung der Clusterzuordnungen erfolgen. Letzteres erscheint vor dem Hintergrund der vorliegenden Aufgabe geeigneter, da in der Regel eine klare Unterscheidung zwischen Netznutzungsfällen aufgrund der großen Anzahl von Einflussfaktoren nicht gegeben ist. In Anlehnung an [6] wird in dieser Ausarbeitung eine Kombination aus einem hierarchischem Verfahren, dem k-Means Algorithmus, sowie einem meta-heuristischen Optimierungsverfahren, der Partikelschwarm-Optimierung, genutzt.

5.2 Clustering-Algorithmus

5.2.1 Ausgestaltung der Optimierungsaufgabe

Mit Hilfe des in Kapitel 4.3.3 eingeführten Proximitätsmaßes wird die Zuordnung eines NNF zu einem Cluster bestimmt. Zu diesem Zweck muss die in Gleichung (4) berücksichtigte Funktion $g(a^i, C^j)$ definiert werden. Im Rahmen dieser Ausarbeitung wird exemplarisch die euklidische Distanz als Proximitätsmaß verwendet:

$$g(a^i, C^j) = \sqrt{\sum_{k=1}^d (a_k^i - C_k^j)^2} \quad (8)$$

Die euklidische Distanz beschreibt die Entfernung zwischen zwei Datenvektoren im d -dimensionalen Raum.

Weiters muss die Zielfunktion zur Bewertung von Clusterlösungen definiert werden. Mit Hilfe einer solchen Definition können Clusterlösungen untereinander verglichen werden. Eine allgemeingültige Definition zur Bewertung von Clusterlösungen ist nicht möglich und stets abhängig von der konkreten Aufgabenstellung [7]. In dieser Ausarbeitung wird ohne Beschränkung der Allgemeinheit die Summe der maximal auftretenden euklidischen Distanz pro Cluster als Zielfunktionswert angewendet:

$$f(A_{i,j}, a^i, C^j) = \max(A_{i,j} \cdot g(a^i, C^j)) ; \forall i \in \{1, \dots, m\}; \forall j \in \{1, \dots, n\} \quad (9)$$

5.2.2 Partikelschwarm-Optimierung

Das zufallsabhängige Verfahren der Partikelschwarm-Optimierung (PSO) basiert auf dem Ansatz, mit Hilfe von Schwarmintelligenz eine Optimierungsaufgabe zu lösen. In Analogie zu natürlichen Vorgängen wird ein Schwarm aus möglichen Lösungen der Optimierungsaufgabe, die von sogenannten Partikeln gehalten werden, erzeugt. Diese Partikel werden inner-

halb des Suchraums bewegt und versuchen so, eine bessere Lösung zu finden. Die Bewegungen werden dabei durch die eigenen und die Erfahrungen anderer Partikel beeinflusst, um sich auf diese Weise dem globalen Optimum des Problems zu nähern [8].

Die PSO besteht aus einer endlichen Anzahl von Iterationen, die aus den für alle Partikel synchron ausgeführten Arbeitsschritten Auswertung, Vergleich und Verschiebung der Partikel bestehen. Diese Arbeitsschritte werden im Folgenden erläutert.

Vor der ersten Iteration wird ein Satz von Partikeln auf zufällig ausgewählte Positionen im Lösungsraum verteilt. Eine Position ist definiert durch das Festlegen aller Variablen mit einem bestimmten Wert und stellt somit eine mögliche Lösung des Optimierungsproblems dar. Diese Positionen werden nun *ausgewertet*, das heißt es wird ihr Zielfunktionswert bestimmt, der auch als Fitness einer Position bezeichnet wird. Im nächsten Schritt werden die Positionen aller Partikel hinsichtlich dieses Wertes *verglichen*. Bei einer Minimierungsaufgabe stellt bei einem Vergleich zweier Positionen diejenige Position mit der kleineren Fitness die bessere Lösung dar. Um die Partikel *verschieben* zu können, wird zunächst eine sogenannte Geschwindigkeit berechnet und anhand dieser die neuen Positionen bestimmt. Der Terminus Geschwindigkeit bezeichnet in der Partikelschwarm-Optimierung die Differenz zwischen zwei Positionen. Die Berechnung der Geschwindigkeit stellt die Kernkomponente der PSO dar. Für die Kalkulation wird ein Kompromiss aus drei grundsätzlichen Möglichkeiten angewendet. Zu diesen Möglichkeiten gehören das Folgen der bisherigen Geschwindigkeit, das Streben in Richtung der besten, bisher erreichten Position und das Streben in Richtung der besten Position des gesamten Schwarms. Die Parameter der PSO werden nach [6] festgelegt.

5.2.3 Generierung von Startlösungen für die PSO

In Anlehnung an [6] wird der k-Means Algorithmus genutzt um bessere Startlösungen für die PSO zu identifizieren. Die Startlösung für den k-Means selbst wird zufällig aus der Menge aller NNF gezogen. Aufgrund der starken Abhängigkeit des Ergebnisses von der gewählten Startlösung ist eine mehrfache Ausführung des k-Means Algorithmus sinnvoll. Der k-Means Algorithmus läuft in folgenden Schritten ab:

1. Zufällige Wahl von Start-Clusterzentren:
Aus der Menge aller Netznutzungsfälle werden $N_{Cluster}$ zufällige Netznutzungsfälle ausgewählt und bilden jeweils das Zentrum eines Clusters.
2. Zuordnung der NNF:
Mittels des Proximitätsmaßes lassen sich alle Netznutzungsfälle den aktuellen Clusterzentren zuordnen.
3. Anpassung der Clusterzentren:
Aus der Menge aller Netznutzungsfälle eines Clusters werden neue (synthetische) Clusterzentren ermittelt. Dabei ist jede Variable eines neuen Clusterzentrums das arithmetische Mittel aller Ausprägungen dieser Variable aller Netznutzungsfälle innerhalb des entsprechenden Clusters.
4. Wiederholung der Schritte 2 und 3:
Die Schritte 2 und 3 werden so lange wiederholt, bis sich die Clusterzuordnung aus Schritt 2 nicht mehr durch eine Anpassung der Clusterzentren in Schritt 3 verändert.

Für den k-Means Algorithmus wird ausschließlich das Proximitätsmaß benötigt, da die zwischenzeitlich entstehenden Clusterzuordnungen (Ergebnis von Schritt 2) nicht bewertet wer-

den. Das Bewertungsmaß kann jedoch verwendet werden um verschiedene k-Means Ergebnisse untereinander vergleichbar zu machen. Bei mehrfacher Ausführung des k-Means Algorithmus kann somit die Clusterlösung mit dem kleinsten Fitnesswert ermittelt werden. Die Clusterzentren dieser Clusterlösung dienen schließlich der PSO als verbesserte Startlösung.

5.3 Ableitung der Markoff-Kette

Auf Basis der ermittelten Cluster lassen sich deren Übergangswahrscheinlichkeiten ermitteln. Zu diesem Zweck wird die historische Abfolge der Netznutzungsfälle betrachtet und um die Information zur Clusterzugehörigkeit ergänzt. Auf Basis dieser Informationen können die Übergänge zwischen Clustern gewonnen werden.

Zur Berechnung der entsprechenden Übergangswahrscheinlichkeiten wird zunächst eine Matrix erstellt, aus der hervorgeht wie häufig aus einem bestimmten Cluster alle anderen Cluster erreicht werden. Dabei wird ebenfalls der Verbleib in einem Cluster berücksichtigt, d.h. der aktuelle und der zeitlich unmittelbar folgende NNF befinden in einem Cluster. Abschließend werden die Wahrscheinlichkeiten für einen Clusterwechsel mit Hilfe einer Division der Matrixeinträge durch die entsprechenden Zeilensummen ermittelt.

Die Clusterzentren sind aufgrund der Mittelwertbildungen des k-Means Algorithmus und der Anpassungen der PSO in der Regel zunächst keine real aufgetretenen NNF des Ausgangsdatensatzes. Daher ist es möglich, dass ein solcher synthetischer NNF nicht realistisch ist. So könnten zum Beispiel unzulässig große Bilanzabweichungen auftreten, die unter Umständen zu nicht-konvergenten Leistungsflussberechnungen führen. Daher ist es sinnvoll, aus der Menge aller Netznutzungsfälle eines Clusters einen real aufgetretenen NNF als Clusterzentrum zu verwenden. Hierbei wird derjenige reale NNF ausgewählt, bei dem die Unterschiede zum synthetischen Clusterzentrum minimal sind. Die Wahl wird somit ebenfalls mit Hilfe des Proximitätsmaßes getroffen.

6 Exemplarische Untersuchungen

Auf Basis des in Kapitel 5 vorgestellten Verfahrens werden im Folgenden historische NNF zehn Clustern zugeordnet. Hierzu werden NNF in stündlicher Auflösung für den Betrachtungszeitraum eines Jahres verwendet. Die Netznutzung beschränkt sich auf die Lasten und Einspeisungen eines Ausschnitts des europäischen Übertragungssystems und setzt sich aus insgesamt 538 Elementen zusammen. Damit ergibt sich eine Rohdatenmatrix mit 8760 Zeilen und 1076 Spalten (Berücksichtigung der Wirk- und Blindleistung für die 8760 Stunden eines Jahres). Die nachfolgend dargestellten Ergebnisse beruhen auf 500 Iterationen des k-Means-Algorithmus zur Identifikation einer geeigneten Startlösung sowie 100.000 Iterationen der PSO.

Abb. 4 zeigt exemplarisch die Zuordnung der historischen Wirkleistungsbezüge einer Belastung zu den zehn ermittelten Cluster. Dargestellt sind jeweils pro Cluster die bezogene Wirkleistung auf der Abszisse und die entsprechende Häufigkeit dieses Wertes auf der Ordinate für die gewählte Belastung. Das Clusterzentrum ist jeweils durch einen blauen Stern auf der x-Achse gekennzeichnet. Es ist grundsätzlich zu erkennen, dass die repräsentativen Wirkleistungswerte in den Clustern variieren. Cluster 10 enthält beispielsweise tendenziell die Werte geringer Belastung und Cluster 5-7 Werte mit maximaler Belastung. Weiterhin ist

ableitbar, dass das Clustering-Ergebnis auf allen Einflussfaktoren beruht; für die in Abb. 4 betrachtete Belastung sind z.B. die Unterschiede zwischen Cluster 1 und Cluster 2 vernachlässigbar. Die Aufteilung in diese zwei Cluster ist somit durch andere Einflussfaktoren begründet.

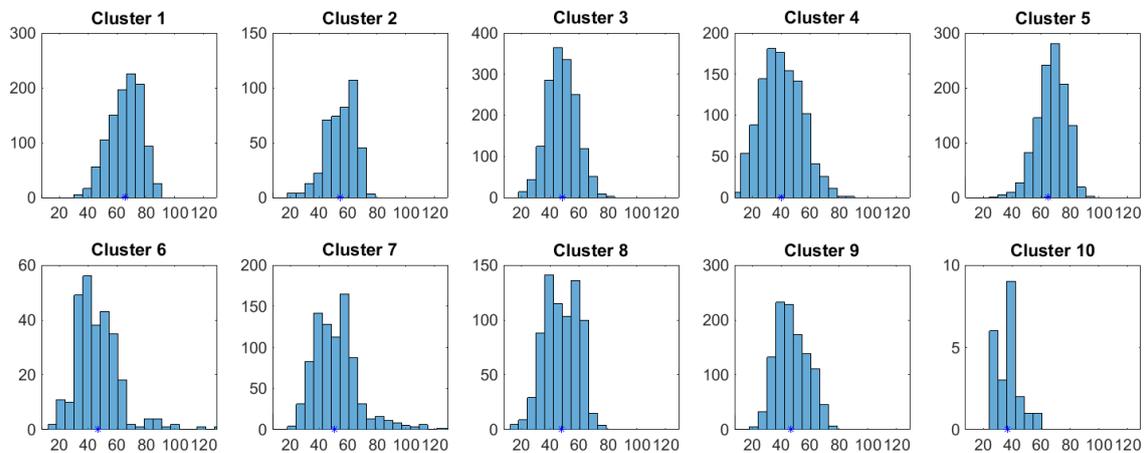


Abbildung 4: Beispiel zur Zuordnung einer Belastung zu den Clustern

Die Matrix der Übergangswahrscheinlichkeiten ist in Gleichung (9) dargestellt. Hier ist beispielsweise zu erkennen, dass vom Cluster 1 nur Übergänge in die Cluster 8-10 wahrscheinlich sind. Weiters sind Übergänge in das Cluster 1 nur aus Cluster 8 und 9 zu berücksichtigen. Außerdem ist grundsätzlich die Wahrscheinlichkeit, dass in einem Cluster verbleiben wird, hoch. Die Diagonaleinträge der Matrix (9) geben die Wahrscheinlichkeiten für einen solchen Verbleib im Cluster an.

$$P_{kl} = \begin{pmatrix} 91,3 & 0 & 0 & 0 & 0 & 0 & 0 & 0,3 & 3,1 & 5,3 \\ 0 & 81,8 & 0 & 4,5 & 0 & 0 & 9,1 & 4,5 & 0 & 0 \\ 0 & 0,1 & 78,3 & 2,3 & 8,5 & 0,4 & 6,5 & 0,9 & 0,7 & 2,3 \\ 0 & 0 & 3,7 & 78,0 & 6,3 & 11,7 & 0 & 0 & 0 & 0,2 \\ 0 & 0 & 18,5 & 8,9 & 31,6 & 0,9 & 34,7 & 3,3 & 0 & 2,2 \\ 0 & 0,7 & 4,4 & 68,9 & 3,7 & 19,3 & 0,7 & 0 & 0,7 & 1,5 \\ 0 & 0,1 & 7,1 & 0 & 13,2 & 0,2 & 73,1 & 2,6 & 1,4 & 2,3 \\ 0,2 & 0 & 3,2 & 0 & 2,1 & 0 & 5,7 & 85,1 & 2,4 & 1,3 \\ 2,2 & 0 & 0,8 & 0 & 0 & 0,1 & 0,9 & 0,9 & 87,9 & 7,2 \\ 3,9 & 0 & 3,0 & 0,1 & 0,9 & 0,1 & 1,8 & 0,8 & 4,7 & 84,8 \end{pmatrix} \quad (9)$$

7 Zusammenfassung und Ausblick

Die europäischen Übertragungsnetzbetreiber führen die Prozesse der Betriebsplanung und -führung zur Gewährleistung einer zuverlässigen Versorgung mit elektrischer Energie aus. Signifikante Veränderungen des europäischen Energieversorgungssystems erhöhen dabei die Komplexität dieser Prozesse. Insbesondere der stetige Anstieg der installierten Kapazität von EE-Anlagen sowie ein zunehmender grenzüberschreitender Handel mit elektrischer Energie führen zu signifikanten Unsicherheiten in der Prognose der zukünftigen Netznutzung.

Um die daraus folgenden Herausforderungen in Betriebsplanungsprozessen zu begegnen, wurde in diesem Beitrag ein Modell vorgestellt, das die zukünftige Netznutzung als Markoff-Kette nachbildet. Zu diesem Zweck wurde ein Verfahren entwickelt, das eine zeitliche Abfolge von historischen Netznutzungsfällen gruppiert und darauf aufbauend eine Markoff-Kette ableitet. Auf Basis exemplarische Untersuchungen wurde der entwickelte Algorithmus auf realen historischen Eingangsdaten getestet.

Die bisher noch fehlende Validierung des vorgestellten Modellierungsansatzes ist in einem nächsten Entwicklungsschritt durchzuführen. Hier liegt der Fokus auf dem Nachweis der Funktionalität. Zudem sind im Rahmen der Validierung verschiedene Proximitätsmaße hinsichtlich ihrer Sensitivität auf die Ergebnisse des Cluster-Algorithmus' zu überprüfen.

8 Literatur

- [1] Bundesministerium für Wirtschaft und Energie (BMWi) und Bundesministerium für Umwelt, Naturschutz und Reaktorsicherheit (BMU), *Energiekonzept für eine umwelt-schonende, zuverlässige und bezahlbare Energieversorgung*.
- [2] *Decision of the European Council of Ministers; 7224/1/07 REV 1*, 2007.
- [3] Union for the Co-ordination of Transmission of Electricity (UCTE), "Operation Hand-book," 2004.
- [4] A. Moormann, S. Krahl, A. Moser, and G. Mika, "Robust Switching States for an Appli-cation in Transmission System Operation," in *ETG-Fachbericht-International ETG Con-gress 2015*, 2015.
- [5] Albert Moser, *Planung und Betrieb von Elektrizitätsversorgungssystemen: Skriptum zur Vorlesung*, 2012.
- [6] van der Merwe, D.W. and A. P. Engelbrecht, "Data clustering using particle swarm op-timization," in *Evolutionary Computation, 2003. CEC '03. The 2003 Congress on*, 2003, pp. 215–220.
- [7] O. Maimon and L. Rokach, *Data mining and knowledge discovery handbook*, 2nd ed. New York, London: Springer, 2010.
- [8] M. Clerc, *Particle swarm optimization*. London, Newport Beach: ISTE, 2006.