

EINSATZ NEURONALER NETZE ZUR KOMPENSATION VON KOMMUNIKATIONS- AUSFÄLLEN IM SPEICHERBETRIEB

Lorenz Viernstein, Rolf Witzmann, Antonius v. Perger

Technische Universität München / Professur für Elektrische Energieversorgungsnetze,
Theresienstraße 90 80333 München, Tel: +49 (0)89 289 25586,
Lorenz.Viernstein@tum.de, www.een.ei.tum.de

Kurzfassung: Im vorliegenden Beitrag wird die Kompensation von Kommunikationsausfällen durch den Einsatz neuronaler Netze untersucht. Ziel ist es eine Konfiguration zu finden, die über den gesamten Betrachtungszeitraum von mehreren Tagen robust gute Ergebnisse bei der Steuerung von Batteriespeichern zur Netzentlastung zeigt. Betrachtet werden dafür sowohl neuronale Netze mit Feed-Forward Struktur als auch nichtlineare, autoregressive neuronale Netze mit externem Eingang. Zum Vergleich werden konventionelle algorithmenbasierte Rückfallstrategien herangezogen, denen wie auch den neuronalen Netzen, eine Prognose über die Einspeisung aus Photovoltaikanlagen zur Verfügung steht.

Keywords: Verteilnetz, Batteriespeicher, Neuronale Netze, Kommunikation

1 Rolle von Speichern zur Netzentlastung & Kommunikation

Der Ausbau dezentraler Erzeugungseinheiten stellt momentan den stärksten Treiber für den Ausbau von Verteilnetzen dar. Da dieser sehr kostenintensiv und aufwendig ist, stehen zunehmend andere Lösungsansätze im Fokus. Zur Einhaltung der Spannungsgrenzwerte sind Blindleistungsregelung, Längsregler und regelbare Ortsnetztransformatoren gute Alternativen zum konventionellen Netzausbau. Wenn aber neben den Spannungsgrenzwerten auch die Stromtragfähigkeit von Leitungen bzw. die Nennleistung der Transformatoren überschritten wird, müssen andere Ansätze verfolgt werden. Dafür stehen neben dem Leitungsausbau sowohl die Abregelung von dezentralen Erzeugungsanlagen als auch Batteriespeicher zur Verfügung. Letztere erfahren nicht zuletzt aufgrund der dynamischen Preisentwicklung [1, 2] eine stark gesteigerte Aufmerksamkeit.

Um das volle Potential von Batteriespeichern vollständig ausschöpfen zu können, ist die Einbindung von lokalen und entfernten Messpunkten von großer Bedeutung. Nur so können nicht nur individuelle Interessen wie Maximierung des Eigenverbrauchs erfüllt, sondern auch der maximale Beitrag zur Entlastung des Stromnetzes geleistet werden. Da dezentrale Erzeugungsanlagen sich oftmals außerhalb von Ballungszentren befinden, ist die Versorgung mit Mobilfunk nicht in allen Fällen gewährleistet [3–5], sodass auf eine parallele Funk-Infrastruktur zum Informationsaustausch zurückgegriffen werden muss. Da diese im Falle eines Defekts längere Ausfallzeiten aufweist, ist die Implementierung einer robusten Rückfalllösung von entscheidender Bedeutung, um auch im Falle ohne Datenverbindung zuverlässig die Netzentlastung sicherstellen zu können. Die Eignung neuronaler Netze für diesen Anwendungsfall wird im Folgenden untersucht.

2 Vorstellung des untersuchten Netzgebietes

Für die vorliegenden Untersuchungen wird ein Mittelspannungsnetz (MS) betrachtet, das über 403 MS/NS Transformatoren die unterlagerten Niederspannungsnetze (NS) versorgt. Das Netzgebiet ist geprägt durch hohe Einspeisung aus dezentralen Erzeugungsanlagen, vorwiegend aus Photovoltaik (PV)- und Biogasanlagen. Durch die in weiten Teilen niedrige Lastdichte, wird das Netzgebiet durch den starken Zuwachs von erneuerbaren Erzeugern besonders belastet. Abbildung 1 zeigt eine Übersicht des Netzgebietes, sowie die Auslastungen der MS/NS Transformatoren im Rückspeisefall (Lasten vernachlässigt).




Abbildung 1 Überblick über das untersuchte Netzgebiet

3 Vorgehensweise

Zur Untersuchung der Überbrückung von Kommunikationsausfällen wird der Einsatz von Batteriespeichersystemen (BSS) in Niederspannungsnetzen zur Netzentlastung betrachtet. Diese sollen dabei neben der Entlastung von MS/NS Transformatoren und des HS/MS Transformators auch den Eigenverbrauch in den Niederspannungsnetzen erhöhen [6]. Die Simulationsschrittweite beträgt eine Minute. Dazu sind die BSS sowohl mit dem MS/NS als auch mit dem Hochspannungs-Mittelspannungs-Transformator über eine als ideal angenommene Kommunikationsstrecke verbunden (Abbildung 2). Für die vorliegenden Untersuchungen wird ein gleichzeitiger Ausfall beider Kommunikationsstrecken angenommen, sodass jegliche Grundlage für einen kommunikationsbasierten Speicherbetrieb fehlt. Die




Abbildung 2 Schematische Darstellung der Kommunikationspfade

jeweils geforderten Leistungen zur Entlastung der Transformatoren werden nach dem zugehörigen Kommunikationspfad als $P_{HS/MS}$ bzw. $P_{MS/NS}$ aufgeschlüsselt gespeichert und dem neuronalen Netz als Eingänge zur Verfügung gestellt.

3.1 Untersuchte Anwendungsfälle

Die Speicher werden in den Niederspannungsnetzen platziert, wo das größte Missverhältnis aus installierter Erzeugungsleistung und Transformatorleistung vorliegt. Im vorliegenden Fall wird die Anzahl der installierten Speicher aus Performance-Gründen auf fünf beschränkt.

Um den Nachweis zu erbringen, dass die vorgestellte Methodik für das ganze Spektrum an Einsatzfällen tauglich ist, werden Kommunikationsausfälle an zehn exemplarischen Tagen untersucht. Diese unterscheiden sich nach Saison (Sommer/Winter/Übergangszeit) sowie der Charakteristik der Stromerzeugung aus Photovoltaikanlagen (Clear-Sky/wechselhafter Tag/Tag mit minimaler PV-Erzeugungsleistung) (Abbildung 3). Entscheidend für die erfolgreiche Netzentlastung durch die Fall-Back Regler ist dabei, dass sowohl der Tag mit der maximalen PV-Einspeisung, welcher die höchste Belastung für das elektrische Netz darstellt, als auch der Tag mit der maximalen Variabilität in der PV-Erzeugung (1) durch das neuronale Netz erfolgreich abgebildet werden kann. Auf diesen Tag wird im Folgenden detaillierter eingegangen, da er die höchsten Anforderungen an das neuronale Netz stellt.

$$v = \sum_t \frac{d}{dt} P(t) \quad (1)$$




Abbildung 3 Exemplarische Sommertage

Ein Kommunikationsausfall tritt dabei immer um 01:00 Uhr in der Nacht auf und dauert kontinuierlich an bis zum Ende des jeweiligen Simulationszeitraumes vier Tage nach Simulationsbeginn. In dieser Zeit wird die gesamte Regelung vom neuronalen Netz bzw. vom konventionellen Rückfall-Regler übernommen. Zum Zeitpunkt 01:00 Uhr kann davon ausgegangen werden, dass Prognosedaten für die Folgetage bereits an das BSS übermittelt wurden, sodass auf diese Informationen zurückgegriffen werden kann.

3.2 Rückfallregler und Implementierung PV-Prognose

Als Vergleich für die neuronalen Netze dient eine konventionell umgesetzte Rückfall-Reglerheuristik, welche auf die auch den neuronalen Netzen bereitstehenden Daten zurückgreift. Den konventionellen Rückfall-Reglern stehen somit nur eine Prognose der PV-Einstrahlung zur Verfügung, Informationen über den Leistungsfluss über den Transformator oder über die aktuell anliegende Last liegen in diesem Fall aufgrund der fehlenden Kommunikationsverbindung nicht vor. Da für die genutzten Photovoltaik- und Lastprofilen keine Prognosen vorliegen, wurde die bekannte, reale PV-Einspeisung mit einem Fehler beaufschlagt, der die gleiche Charakteristik aufweist, wie die Auswertung von realen Messdaten und einer zugehörigen PV-Leistungsprognose aus dem Jahr 2016. Die resultierende Fehlerverteilung kann Abbildung 4 entnommen werden.




Abbildung 4 Verwendete Fehlercharakteristik zur Generierung der PV-Prognosewerte

3.3 Bewertungsmetrik

Um die Ausgabewerte des neuronalen Netzes o_{NN} bewerten zu können, liegt die Ausgangsleistung der Batteriebetriebsstrategie o_{Regler} , aufgeteilt nach anfallender Entlastung für den MS/NS sowie HS/MS Transformator vor. Um das Ergebnis einzuordnen wird die mittlere quadratische Abweichung zwischen o_{Regler} und o_{NN} bewertet (2) [7, 8]. Im vorliegenden Fall ist o_{NN} ein Vektor, der die Speicherleistung enthält

$$MSE = \sum_{i=1}^N \frac{o_{NN} - o_{Regler}}{N} \quad (2)$$

Dabei wird zwischen der Performance (PF) im trainierten und nicht-trainierten Zeitbereich unterschieden. Da für den gewünschten Anwendungsfall auch robust mit unbekannten Situationen umgegangen werden muss, ist eine gute Performance für die Evaluierung unbekannter Datensätze von großer Bedeutung und wird im Folgenden als Cross-Performance (CPF) bezeichnet. Eine gute Performance im trainierten Zeitbereich lässt darauf schließen, dass bereits bekannte Situationen gut behandelt werden können, eine gute Cross-Performance im nicht-trainierten Zeitbereich weist auf eine gute Abstraktionsfähigkeit hin.

4 Neuronale Netze

Im Rahmen dieser Arbeit kommen sowohl reine Feed-Forward Netze als auch nichtlineare, autoregressive neuronale Netze mit externem Eingang (NARX) zum Einsatz. Beide Strukturen werden untersucht und die jeweiligen Ergebnisse gegenübergestellt. Für das Training der neuronalen Netze findet ausschließlich Offline-Training statt, eine Adaption im Betrieb ist nicht implementiert.

Das wichtigste Designkriterium für neuronale Netze ist die Anzahl der zum Einsatz kommenden Neuronen. Zu viele Neuronen führen dazu, dass das Netz übertrainiert wird und auswendig lernt, wobei die Anpassungsfähigkeit verloren geht. Ein wichtiger Indikator dafür ist, dass die Unterschiede in der Performance zwischen Trainings- und Validierungsdatensatz zu groß sind. Zu große Fehler im Trainingsdatensatz lassen auf eine nicht ausreichend große Lernfähigkeit, also zu wenige Neuronen schließen [9].

4.1 Trainieren neuronaler Netze

Für das Training von neuronalen Netzen mit bis zu wenigen hundert Gewichten schlägt die Literatur den Levenberg-Marquardt-Algorithmus als schnellste Trainingsfunktion vor, alternativ wird der „Scaled-conjugate-gradient“ Algorithmus (SCG) [10] verwendet [7]. Dieser hat den Vorteil, dass er in der verwendeten Implementierung auf der GPU ausgeführt werden kann und somit einen Geschwindigkeitsvorteil mitbringt. Eine Untersuchung hinsichtlich des Einflusses der Trainingsfunktion auf das Ergebnis für neuronale Netze mit Feed-Forward Struktur wird in Abschnitt 5.2 vorgestellt.

4.2 Verwendeter Trainingsdatensatz

Als Referenz und Trainingsdatensatz für die neuronalen Netze dient eine Jahressimulation mit dauerhaft bestehender Kommunikation. Von diesem Datensatz werden den neuronalen Netzen die Daten der ersten 16 Tage jedes Monats zur Verfügung gestellt, welche wiederum in Trainings-, Test- und Validierungsdatensatz im Verhältnis 70% - 15% - 15% [7] unterteilt werden. Die restlichen Daten werden genutzt, um das Verhalten der neuronalen Netze anhand längerer, unbekannter Zeiträume zu evaluieren. Enthaltene Zeitreihen sind die PV-Erzeugungsleistungen, die Lastdaten der Niederspannungsnetze, sowie die Leistungen die zur Entlastung der MS/NS Transformatoren bzw. des HS/MS Transformators abgerufen werden. Darüber hinaus sind die Bemessungsleistungen der Transformatoren, Speichernennleistung, und die installierte PV-Leistung bekannt.

Zum Trainieren der neuronalen Netze stehen den Eingangsneuronen neben den Zielwerten für die Entlastung auch Informationen über die aktuelle Zeit, PV-Einstrahlungsleistung und Informationen über Sonnenaufgangs- und Sonnenuntergangszeiten [11] zur Verfügung.

4.3 Feed-Forward Struktur

Wie [12] zeigt, lässt sich bereits mit nur einer versteckten Schicht und ausreichend vielen Neuronen für eine sehr große Klasse von Problemen eine beliebige Funktion approximieren, weshalb nur diese Konfiguration mit einer versteckten Schicht berücksichtigt wird. Abbildung 5 zeigt, wie sich die Performance im trainierten und nicht-trainierten Zeitbereich mit unterschiedlichen Neuronenzahlen verhält.




Abbildung 5 Performance der Batterie 4, 30 Trainingsdurchgänge

Da die genaue Konfiguration des neuronalen Netzes auf Basis stochastischer Prozesse bei der Initialisierung der Übergangsgewichte zustande kommt, wurden 30 unterschiedliche Realisierungen des neuronalen Netzes unter Nutzung des gesamten Trainingsdatensatzes trainiert. So lässt sich eine Aussage über die erzielbaren Ergebnisse generieren. Die Ergebnisse sind exemplarisch für Batterie 4 im Boxplot dargestellt, die neuronalen Netze für die anderen Batterien zeigen ein vergleichbares Verhalten. Einen guten Kompromiss aus Lernfähigkeit und Abstraktionsvermögen stellt dabei die Konfiguration mit 25 Neuronen dar. Zwischen den einzelnen Trainingsdurchgängen gibt es durchaus große Unterschiede, sodass die Auswahl des richtigen trainierten Netzes von großer Bedeutung ist.

Da die Cross-Performance in der realen Anwendung nicht bekannt ist, muss die Entscheidung für die Auswahl des Netzes anhand der Performance des trainierten Zeitraumes getroffen werden. Um die Wahrscheinlichkeit, bei der Auswahl ein besonders schlechtes Netz zu treffen zu reduzieren, hat es sich bewährt ein Netz mit einer Performance nahe am Median aller Realisierungen zu verwenden (Abbildung 6). Diese weisen in der Regel auch für die Cross-Performance einen Wert nahe des Medians auf.

Eine Auswertung hinsichtlich der Auswahl der richtigen Realisierung zeigt, dass die Wahl des Netzes mit der besten Performance bedeutet, dass die Cross-Performance dieses Netzes um etwa 7 bis 8 Ränge schlechter ist, als bei Auswahl des Netzes mit einer Performance nahe des Medians. Da für die zukünftige Aufgabe des neuronalen Netzes sowohl Konstellationen, die den trainierten Zeiträumen sehr ähnlich sind, als auch noch nicht trainierte Situationen auftreten können, müssen beide Größen in einem akzeptablen Wertebereich liegen.




Abbildung 6 Performance der Batterie 3 über alle Trainingsdurchgänge für 25 Neuronen (Werte normiert auf Median der Performance für trainierten bzw. auf Median der Crossperformance für nicht-trainierten Zeitraum)

4.4 NARX

Bei NARX Netzen kommt neben der Anzahl der versteckten Schichten und Neuronen eine weitere Dimension hinsichtlich des Designs zum Tragen: Die Anzahl der Input-Delays (ID), also die Anzahl der historischen Zeitschritte der Eingangssignale, die zusätzlich zum aktuellen Wert übergeben werden, sowie die Anzahl der Feedback-Delays (FD), die die Verzögerung des zurückgeführten Ausgangssignals darstellen.

4.4.1 Autokorrelation der Ausgänge

Für die Definition der Anzahl der rückzuführenden Zeitschritte des Ausgangs wird die Autokorrelation der beiden Ausgänge (Abbildung 7) betrachtet. Wie sich schon vermuten lässt, haben die weniger weit in der Vergangenheit liegenden Werte einen größeren Einfluss auf die aktuelle Ausgabe des neuronalen Netzes, als weiter zurückliegende. Daher werden im folgenden Konfigurationen mit maximal 60 Feedback-Delays berücksichtigt. Bei der

Betrachtung der MS/NS Regelung fällt auf, dass Zeitschritte die mehrere Stunden zurückliegen wieder eine signifikante Korrelation aufweisen. Dieser Effekt hat seinen Ursprung darin, dass die Entladeleistung der Batterien über Nacht in Zusammenhang mit der verfügbaren Kapazität und damit mit der verfügbaren Ladeleistung für den folgenden Tag steht. Ebenso hängt die verfügbare Energie in der Nacht zur Versorgung von Haushalten vom Strahlungsdargebot tagsüber und somit von der Ladeleistung der MS/NS Regelung ab.




Abbildung 7 Autokorrelation der Ausgänge

5 Ergebnisse

5.1 Feed-Forward Struktur

Für die Einordnung der Einsatzfähigkeit der Rückfall-Regler bzw. der neuronalen Netze wird die maximale Auslastung der Transformatoren sowie die zusätzlich aus dem MS Netz bezogene Energie betrachtet (Abbildung 8). Aufgrund der schnellen Konvergenz kommt zunächst für alle Netze der SCG-Algorithmus zum Einsatz [7]. In Abschnitt 5.2 wird zum Vergleich auf die Ergebnisse des Levenberg-Marquardt Algorithmus eingegangen.

Im Einsatz zeigen sich zwischen den verschiedenen Realisierungen nur geringe Unterschiede, auch die schlechteste Konfiguration mit 25 Neuronen gewährleistet eine zuverlässige Entlastung am wechselhaften Sommertag. Dies zeigt, dass die Wahl von 25 Neuronen sehr verlässlich zu einer erfolgreichen Konfiguration führt.

Die gewählte Implementierung der konventionellen Fallback-Regler sorgt durch die Vernachlässigung der vorhandenen Last für eine stärkere Entlastung des MS/NS Transformators, erkennbar an den niedrigeren maximalen Auslastungen. Dies geschieht aber immer auf Kosten eines zusätzlichen Energiebezuges (zu sehen an dem größeren zusätzlichen Energiebezug ΔE) aus dem Mittelspannungsnetz, was zwei Nachteile mit sich bringt. Zum einen erreicht der Speicher dadurch schneller seinen maximalen Ladezustand (SoC), weiter muss die zusätzlich durch den Speicher bezogene Energie vergütet werden.

Wie der geringeren Steigerung der Auslastung und des zusätzlichen Energiebezuges gegenüber der Heuristik zu entnehmen ist, reagieren neuronale Netze weniger sensibel auf Prognosefehler, was zu einem robusteren Verhalten beiträgt.




Abbildung 8 Vergleich unterschiedlicher Netzkonfigurationen für wechselhaften Sommertag

Erläuterung

- base Fall ohne Batteriespeicher
- ref Referenzregler mit intakter Kommunikation
- a15 Rückfallregler mit 15-min PV-Prognoseauflösung (perfekte Vorhersage)
- a15-pvrr Rückfallregler mit 15-min PV-Prognoseauflösung (fehlerbehaftet nach Abbildung 4)
- n25 Neuronales Netz – Median der Performance (perfekte Vorhersage)
- n25-best Neuronales Netz – beste Performance (perfekte Vorhersage)
- n25-worst Neuronales Netz – schlechteste Performance (perfekte Vorhersage)
- n25-pvrr Neuronales Netz – Median der Performance (fehlerbehaftet nach Abbildung 4)

5.2 Einfluss der Parameter für Feed-Forward Netze

Wie Abbildung 9 zu entnehmen ist, bringt der Levenberg-Marquart Trainingsalgorithmus (*n25-trainlm*) für die an dieser Stelle eingesetzten Feed-Forward Netze keine signifikanten Vorteile gegenüber dem SCG-Algorithmus hinsichtlich der Benchmark-Werte, sodass im Folgenden auf die aufwändigere Berechnung anhand des Levenberg-Marquart Algorithmus verzichtet werden kann. Das neuronale Netz mit 25 Neuronen mit SCG-Trainingsfunktion erzielt einen RMSE von 5,38 (PF) respektive 6,14 (CPF).

Die zusätzliche Information über die gesamt zu erwartende PV-Energie (*n25-pvprogsum*) verbessert die Ergebnisse hingegen deutlich. Vor dem Hintergrund der durch das neuronale Netz nachgebildeten Betriebsstrategie, welche einen möglichst hohen SoC zur maximalen Eigenversorgung des Ortsnetzgebietes in der Nacht anstrebt, lässt sich dieser Umstand gut nachvollziehen. Allerdings zeigt die genauere Untersuchung der anderen Referenztage, dass die Einführung dieses Eingangs zu einer stärkeren Entlastung gegenüber dem Referenzregler führt - erkennbar an dem hohen zusätzlichen Energiebezug - was einen signifikanten Nachteil darstellt. Die Information über die PV-Energie des vergangenen Tages (*pastpvsum*), liefert hingegen keinen Mehrwert für die Entlastung, verbessert aber den zusätzlichen Energiebezug marginal. Ausschließlich am Tag mit maximaler PV-Einstrahlung ergeben sich durch ein verbessertes Entlade-Verhalten in der Nacht dadurch leichte Vorteile in Bezug auf die zusätzlich aus dem Netz bezogene Energie.

Durch die Einbeziehung des aktuellen SoC (*n25-soc* bzw. *n25-soc-best*) lassen sich ähnliche Verbesserungen erzielen wie bei Bereitstellung der (perfekt) prognostizierten PV-Energie. Durch die Tatsache, dass der SoC robust als lokaler Messwert ohne größere Unschärfe

vorliegt, kann das neuronale Netz so verlässlich verbessert werden (RMSE: 3,47/3,74 PF/CPF). Einen weiteren Vorteil bei der Verwendung der Konfiguration mit zusätzlich bereitgestelltem SoC stellt die Tatsache dar, dass bei dieser Realisierung eine bessere Performance zugleich immer zu einer besseren Crossperformance führt. Somit lässt sich hier zuverlässig das beste Netz auswählen (*n25-soc-best*), ohne wie bei den anderen untersuchten Varianten eine Verschlechterung der Crossperformance in Kauf nehmen zu müssen. Bei fehlerbehafteten Prognosewerten ist jedoch nicht in allen Fällen eine bessere Performance feststellbar (*n25-soc-best-pverr*).

Die Umstellung der PV-Prognose von viertelstündlichen auf stündliche Prognosewerte verschlechtert erwartungsgemäß die Benchmark-Werte signifikant. Die Qualität des neuronalen Netzes hängt in diesem Fall jedoch davon ab, ob bereits mit der verringerten Prognoseauflösung trainiert wurde (*pvm60-n25*), oder ob lediglich ein bereits trainiertes Netz mit den reduzierten Datensätzen versorgt wird (*n25-pvm60*). Auch wenn ein mit höherer zeitlicher Auflösung trainiertes Netz prinzipiell auch mit geringer aufgelösten Prognosewerten arbeiten kann, verbessert ein dediziert darauf ausgerichtetes Training die Ergebnisse im Jahresverlauf.




Abbildung 9 Vergleich unterschiedlicher Input-Daten für wechselhaften Sommertag

Erläuterung	
n25	25 Neuronen, 15 min PV-Prognose, trainscg
trainlm-n25	25 Neuronen, 15 min PV-Prognose, trainlm
n25-pvprogsum	zusätzlicher Eingang: prognostizierte PV-Energie für den Tag
n25-pastpvsum	Zusätzlicher Eingang: PV-Energie des vergangenen Tages
n25-soc	Zusätzlicher Eingang: aktueller SoC des Batteriespeichers
n25-soc-best	Zusätzlicher Eingang: aktueller SoC des Batteriespeichers, beste Realisierung
pvm60-n25	25 Neuronen, 60-min PV-Prognose, mit 60-min PV-Prognose trainiert, trainscg
n25-pvm60	25 Neuronen, 60-min PV-Prognose, mit 15-min PV-Prognose trainiert, trainscg
n25-soc-best-pverr	Zusätzlicher Eingang: aktueller SoC des Batteriespeichers, fehlerbehaftete Prognose

5.3 NARX Netze

Wie in Abschnitt 4.4 bereits dargestellt, ist bei NARX-Netzen die Wahl der Input- und Feedback Delays ein wichtiges Designkriterium. Aufgrund der Vielzahl der sich daraus ergebenden Eingangskonfigurationen soll an dieser Stelle nur auf die jeweils besten Realisierungen von

NARX Netzen eingegangen werden. Untersucht wurden unterschiedliche Neuronenzahlen (10/15/20/25/30) und Konfigurationen von Input-/Feedbackdelays.

Darüber hinaus sind bei NARX Netzen zwei unterschiedliche Performance-Werte von Bedeutung: Die Open-Loop-Performance, also die Qualität des Ergebnisses, das sich erzielen lässt, wenn der korrekte Zielwert zurückgeführt wird (Ein-Schritt-Vorhersage), und die Closed-Loop-Performance, welche für eine Prognose über mehrere Zeitschritte hinweg entscheidend ist, also der Ausgang des neuronalen Netzes wiederum als Eingangswert bereitgestellt wird. Die beste Closed-Loop-Performance wird durch ein gezieltes Nachtrainieren von vorab in Open-Loop Form trainierten Netzen erreicht (*cl-best* bzw. *cl-rt-best*) [7, 13]. Wie Abbildung 10 zeigt, sind die Netze, die ausschließlich in Open-Loop Form trainiert wurden (*ol-best*) sowohl in Hinblick auf die realisierte Transformatorentlastung, als auch in Bezug auf die zusätzlich bezogene Energiemenge schlechter.

Durch gezieltes Nachtrainieren der Netze mit der besten Konfiguration (RMSE: 5,73/6,23 PF/CPF) werden Performance-Werte ähnlich von Feed-Forward Netzen erzielt, der gegenüber der einfacher zu trainierenden Feed-Forward Struktur gesteigerte Trainingsaufwand schlägt sich hier nicht in verbesserten Ergebnissen nieder. Darüber hinaus ist die Angabe einer optimalen Neuronenzahl nicht so einfach möglich wie bei Feed-Forward Netzen. Die besten Konfigurationen bewegen sich zwischen 15 und 25 Neuronen, um die optimale Konfiguration zu finden muss daher ein weiterer Suchbereich abgedeckt werden. Um eine klare Empfehlung für die Wahl der richtigen Netzkonfiguration aussprechen zu können, bedarf es weiterer Untersuchungen. Als relativ robuste Konfiguration erweist sich die Wahl von ca. 25 Neuronen mit 5 Feedback-Delays und ausgewählten Input-Delays, die bis zu 30 Minuten in der Vergangenheit liegen.




Abbildung 10 Vergleich unterschiedlicher NARX-Netzkonfigurationen für wechselhaften Sommertag

Erläuterung

cl-rt-best	Bestes NARX-Netz hinsichtlich Closed-Loop-Performance(nachtrainiert)
cl-rt-best-pvrr	cl-rt-best mit fehlerbehafteter PV-Prognose
cl-best	Bestes NARX-Netz hinsichtlich Closed-Loop-Performance (nicht nachtrainiert)
cl-median	Median NARX-Netz hinsichtlich Closed-Loop-Performance (nicht nachtrainiert)
ol-best	Bestes NARX-Netz hinsichtlich Open-Loop-Performance (nicht nachtrainiert)

5.4 Vergleich Ausgang Feed-Forward und NARX für wechselhaften Sommertag

Abbildung 11 zeigt die erzielten Ergebnisse für die neuronalen Netze am Beispiel des wechselhaften Sommertages, jeweils für die beste Konfiguration jeder Netzstruktur. Diese ist bei den Feed-Forward-Netzen die beste Realisierung des Netzes mit 25 Neuronen und zusätzlich

bereitgestelltem SoC. Bei den NARX-Netzen zeigt das nachtrainierte Netz mit 25 Neuronen, 5 Feedback-Delays und ausgewählten Input-Delays (1...5 min, 15 min, 30 min) die besten Eigenschaften.

Erkennbar ist, dass die Verläufe gut mit dem angestrebten Referenzregler übereinstimmen. Lediglich in der Nacht ist der Entladevorgang für beide Netztypen schwer nachzuvollziehen. Da für diesen keine weitere Information in Form von Prognosen bereitstehen, sondern sich das neuronale Netz ausschließlich auf die gelernten Erfahrungswerte über das Lastverhalten




Abbildung 11 Verlauf der Speicherleistung im Vergleich (Referenz/Neuronales Netz mit Feed-Forward-Struktur/Neuronales Netz mit NARX-Struktur)

in den Nachtstunden verlassen muss, liegt dies nahe. Auch kurze Extremwerte können von den neuronalen Netzen nicht adäquat nachgebildet werden. Zum einen gerät hier die PV-Prognose an die Grenzen der Zuverlässigkeit, zum anderen lassen sich durch die relativ niedrige Auflösung und den begrenzten Informationsgehalt der Eingangsdaten diese kurzfristigen Phänomene nicht geeignet durch neuronale Netze abbilden. Aufgrund der thermischen Trägheit von Transformatoren sind solche kurzfristigen Auslastungsspitzen jedoch von untergeordneter Bedeutung.

6 Fazit und Ausblick

Der Einsatz neuronaler Netze zur Überbrückung von Kommunikationsausfällen kann einen wichtigen Beitrag zum robusten Einsatz von Batteriespeichern im Verteilnetz leisten. Es konnte gezeigt werden, dass der vorgestellte Ansatz große Vorteile gegenüber einfachen Rückfallreglern bietet und die Betriebsstrategie in Grenzen gut nachbilden kann. Insbesondere beim Einsatz von mehreren Speichern im Verbund ist diese Zuverlässigkeit hinsichtlich der Verhaltensweise für den Netzbetreiber von großer Bedeutung. Wenn, wie in [6] vorgestellt, alle Speicher auch die Entlastung des HS/MS Transformators gewährleisten sollen, ist dies entscheidend.

Da sich jede Verbesserung des Referenzreglers auch auf das Ergebnis des neuronalen Netzes auswirkt, kann ohne größeren Aufwand auch eine weiter optimierte Betriebsstrategie durch neuronale Netze abgebildet werden. Wichtig ist dabei wieder die Auswahl der richtigen Konfiguration des neuronalen Netzes und ein entsprechend darauf abgestimmtes Training. Es konnte gezeigt werden, dass die Implementierung eines neuronalen Netzes mit Feed-Forward Struktur und einer versteckten Schicht mit 25 Neuronen robust gute Ergebnisse liefert. Dieses Ergebnis ist unabhängig von der verwendeten Trainingsfunktion gültig. Für das Erzielen der besten Ergebnisse ist die Bereitstellung des SoC als zusätzliche Eingangsgröße notwendig.

In der vorgestellten Arbeit wurde ausschließlich Offline-Training betrieben, eine weitergehende Adaption im Betrieb wurde nicht berücksichtigt. Da somit noch keine sich ändernde

Netzstruktur bzw. der Zubau weiterer PV-Anlagen abgebildet werden kann, beschäftigen sich weiterführende Arbeiten mit diesem Ansatz. In diesem Zusammenhang ist auch die Generalisierbarkeit der neuronalen Netze, also der Einsatz eines einmal trainierten neuronalen Netzes auch für andere Standorte/Batteriekonfigurationen von Interesse.

Der vorgestellte Ansatz verknüpft allgemein Eingangszeitreihen mit einer Zielgröße, diese Methodik lässt sich daher auch auf andere intelligente Betriebsmittel übertragen. Denkbar sind in diesem Zusammenhang beispielsweise kommunikativ nicht angebundene, regelbare Ortsnetztransformatoren die über ein, entsprechend mit realen Netzdaten trainiertes, neuronales Netz ein Verhalten zeigen, wie es sonst nur mit abgesetzter Messung erzielbar wäre.

7 Literaturverzeichnis

- [1] Automobilwoche, Ed., "Weltweite Preisentwicklung für Lithium-Ionen-Batterien von 2013 bis 2020 (in Euro/kWh)," Statista. [Online] Available: <https://de.statista.com/statistik/daten/studie/534429/umfrage/weltweite-preise-fuer-lithium-ionen-akkus/>. Accessed on: Dec. 15 2017.
- [2] B. Nykvist and M. Nilsson, "Rapidly falling costs of battery packs for electric vehicles," *Nature Climate change*, vol. 5, no. 4, pp. 329–332, 2015.
- [3] Telefónica Germany GmbH & Co. OHG, *Netzabdeckung Telefónica Germany GmbH & Co. OHG*. [Online] Available: <https://www.o2online.de/service/netz-verfuegbarkeit/netzabdeckung/>. Accessed on: Dec. 15 2017.
- [4] Telekom Deutschland GmbH, *Netzabdeckung Telekom Deutschland GmbH*. [Online] Available: <https://www.telekom.de/start/netzausbau>. Accessed on: Dec. 15 2017.
- [5] Vodafone GmbH, *Netzabdeckung Vodafone GmbH*. [Online] Available: <https://www.vodafone.de/hilfe/netzabdeckung.html>. Accessed on: Dec. 15 2017.
- [6] L. Viernstein, R. Witzmann, and J. Przibylla, "Grid voltage level spanning operational strategies for battery energy storage systems in distribution grids," in *2016 IEEE Electrical Power and Energy Conference (EPEC)*, Ottawa, ON, Canada, 2016, pp. 1–6.
- [7] M. T. Hagan, H. B. Demuth, M. H. Beale, and O. de Jesús, *Neural network design*, 2nd ed. [S. l.: s. n.], 2016.
- [8] S. Lawrence, C. L. Giles, and A. C. Tsoi, "What Size Neural Network Gives Optimal Generalization? Convergence Properties of Backpropagation," Jun. 1996, rev. Aug. 1996. [Online] Available: <https://clgiles.ist.psu.edu/papers/UMD-CS-TR-3617.what.size.neural.net.to.use.pdf>. Accessed on: Jan. 19 2018.
- [9] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. Cambridge, MA: MIT Press, 2017.
- [10] M. F. Møller, "A scaled conjugate gradient algorithm for fast supervised learning," *Neural Networks*, vol. 6, no. 4, pp. 525–533, 1993.
- [11] A. Redwoods. [Online] Available: <http://sunrisesunset.de/>. Accessed on: Jul. 13 2017.
- [12] K. Hornik, "Approximation capabilities of multilayer feedforward networks," *Neural Networks*, vol. 4, no. 2, pp. 251–257, 1991.
- [13] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," (eng), *IEEE transactions on neural networks*, vol. 1, no. 1, pp. 4–27, 1990.