

Zeitschrift: Bulletin des Schweizerischen Elektrotechnischen Vereins, des Verbandes Schweizerischer Elektrizitätsunternehmen = Bulletin de l'Association suisse des électriciens, de l'Association des entreprises électriques suisses

Herausgeber: Schweizerischer Elektrotechnischer Verein ; Verband Schweizerischer Elektrizitätsunternehmen

Band: 85 (1994)

Heft: 7

Artikel: Neuronale Signalverarbeitung für sicheren Schutz : die Anwendung neuronaler Netzwerke auf das Problem der Sättigung von Stromwandlern

Autor: Cozzio, Rico / Peck, David

DOI: <https://doi.org/10.5169/seals-902552>

Nutzungsbedingungen

Die ETH-Bibliothek ist die Anbieterin der digitalisierten Zeitschriften auf E-Periodica. Sie besitzt keine Urheberrechte an den Zeitschriften und ist nicht verantwortlich für deren Inhalte. Die Rechte liegen in der Regel bei den Herausgebern beziehungsweise den externen Rechteinhabern. Das Veröffentlichen von Bildern in Print- und Online-Publikationen sowie auf Social Media-Kanälen oder Webseiten ist nur mit vorheriger Genehmigung der Rechteinhaber erlaubt. [Mehr erfahren](#)

Conditions d'utilisation

L'ETH Library est le fournisseur des revues numérisées. Elle ne détient aucun droit d'auteur sur les revues et n'est pas responsable de leur contenu. En règle générale, les droits sont détenus par les éditeurs ou les détenteurs de droits externes. La reproduction d'images dans des publications imprimées ou en ligne ainsi que sur des canaux de médias sociaux ou des sites web n'est autorisée qu'avec l'accord préalable des détenteurs des droits. [En savoir plus](#)

Terms of use

The ETH Library is the provider of the digitised journals. It does not own any copyrights to the journals and is not responsible for their content. The rights usually lie with the publishers or the external rights holders. Publishing images in print and online publications, as well as on social media channels or websites, is only permitted with the prior consent of the rights holders. [Find out more](#)

Download PDF: 15.04.2026

ETH-Bibliothek Zürich, E-Periodica, <https://www.e-periodica.ch>

Elektroenergiesysteme werden dauernd mit Hilfe moderner Schutztechnik überwacht; sie hat die Aufgabe, in einem Fehlerfall die betroffenen Teile rasch abzuschalten. Die dabei zur Strommessung eingesetzten Messwandler unterliegen aber bei sehr hohen Strömen Sättigungseffekten. Um eine Überfunktion zu verhindern, muss das Schutzsystem die dabei auftretenden Signalverzerrungen mit aufwendigen Massnahmen kompensieren. In einem Forschungsprojekt wurden Methoden entwickelt, welche erlauben, mit einem neuronalen Netzwerk den tatsächlichen Strom aus dem verzerrten Messsignal zu rekonstruieren. Das Netzwerk erreicht ohne genaue Kenntnis der Wandler- und Systemparameter eine Rekonstruktionsqualität, welche den erfolgreichen Einsatz in Schutzsystemen ermöglicht. Dadurch werden sowohl die Robustheit erhöht als auch die Zuverlässigkeit des Schutzes gesteigert.

Neuronale Signalverarbeitung für sicheren Schutz

Die Anwendung neuronaler Netzwerke auf das Problem der Sättigung von Stromwandlern

■ Rico Cozzio und David Peck

In der modernen Schutztechnik für Elektroenergiesysteme ist es nötig, den Zustand des Systems dauernd zu überwachen, um in einem Fehlerfall die betroffenen Teile schnell abschalten zu können. Zur Messung der Ströme werden Messwandler eingesetzt; es sind dies im wesentlichen zu Messzwecken ausgelegte Transformatoren mit Eisenkern. Bei sehr grossen Strömen ist es solchen Messwandlern nicht mehr möglich, den zu messenden Strom getreu wiederzugeben, da Sättigungseffekte auftreten. Das Schutzsystem erhält somit Messsignale, die ein verzerrtes Abbild der tatsächlichen Verhältnisse ergeben. Im Schutzsystem müssen deshalb aufwendige Massnahmen getroffen werden, um eine Überfunktion zu verhindern. In einem Forschungsprojekt wurden nun Möglichkeiten untersucht, wie mit einem neuronalen Netzwerk aus dem verzerrten Messsignal

der tatsächliche Strom rekonstruiert werden kann. Das Netzwerk wurde dabei mit einer Datenbank von simulierten Störfällen trainiert, um die Rekonstruktion der verfälschten Signale zu erlernen. Das Netzwerk erreicht ohne genaue Kenntnis der Wandler- und Systemparameter eine gute Qualität der Rekonstruktion; einem erfolgreichen Einsatz in einem Schutzsystem steht daher nichts im Wege. Dadurch lässt sich die Robustheit des Schutzes erhöhen und die Zuverlässigkeit steigern.

Moderne Schutztechnik für Elektroenergiesysteme

Die Schutzeinrichtungen von Elektroenergiesystemen haben die Aufgabe, Auswirkungen von Störungen auf ein Minimum zu reduzieren und möglichst lokal zu beschränken. Störungen können extern durch Umwelteinflüsse, zum Beispiel Blitzschlag, aber auch intern durch Überlast entstehen. Bei Hochspannungseinrichtungen werden im Störfall sehr grosse

Adressen der Autoren:

Rico Cozzio, Dipl. Informatik-Ing. ETH,
ABB Forschungszentrum, 5405 Baden, und
Dr. David Peck, ABB Relays AG, 5401 Baden.




Bild 1 Vergleich von Primär- und Sekundärstrom eines Stromwandlers bei schwacher Sättigung




Bild 2 Vergleich von Primär- und Sekundärstrom eines Stromwandlers bei starker Sättigung

Energiebeträge frei, was zu grossen Schäden führen kann. Es ist deshalb sehr wichtig, dass ein Schutzsystem schnell reagiert und die gefährdeten Teile vom restlichen System trennt. Dabei muss darauf geachtet werden, dass der Schutz selektiv nur die betroffenen Komponenten abschaltet, um die Auswirkungen auf das restliche System, und damit die Kosten des Ausfalls, zu minimieren.

Moderne Schutzsysteme übernehmen zunehmend, neben den eigentlichen Schutzaufgaben, auch administrative Aufgaben wie beispielsweise die Datenerfassung für statistische Analysen. Dies ist heute möglich durch den Generationswechsel von analogen zu digitalen Schutzsystemen, sowie durch den verstärkten Einsatz von digitalen Rechnern. Eine gute Einführung in die Schutztechnik für Elektroenergiesysteme wird in [14] gegeben.

Entstehung von Wandlersättigung

Ein zu schützendes System wird in einzelne Schutzzonen eingeteilt, für die jeweils eine Gruppe von Schutzeinrichtungen zuständig ist. Diese müssen feststellen, ob ein Fehlerfall vorliegt und ob dieser in die Zuständigkeit der eigenen Zone fällt (interner Fehler), wonach die zugehörigen Geräte abgekoppelt werden. Dazu werden Messwandler eingesetzt, die Strom- und

Spannungsmessungen an die Schutzrelais weiterleiten. Das Problem besteht nun darin, dass Störfälle die Messwandler in die magnetische Sättigung treiben können, weil dabei starke Ströme auftreten. Die gemessenen Signale bilden dann die tatsächlichen Ströme nicht mehr getreu ab. Einfache Schutzalgorithmen, wie die Anwendung der Kirchhoffschen Summenregel, bei der eine Abweichung der Summe aller eingehenden und abgehenden Ströme von Null einen Fehler signalisiert, können im Grenzfall die internen Fehler nicht mehr von den externen unterscheiden. Dadurch entsteht die Gefahr von Überfunktion. Da beispielsweise beim Ausfall einer Sammelschiene mehrere angeschlossene Leitungen mitbetroffen sind, muss solches Verhalten verhindert werden. Die Bilder 1 und 2 zeigen die mögliche Wirkung von Sättigung auf den übertragenen Sekundärstrom. (In diesen Bildern wurde der Sekundärstrom mit dem Übersetzungsverhältnis skaliert, so dass die Kurven für Primär- und Sekundärstrom bei idealer Übertragung identisch wären.)

Klassische Lösungsansätze für das Wandlersättigungsproblem

Um das Problem der Wandlersättigung in den Griff zu bekommen, werden heute folgende Massnahmen angewendet:

- Grosszügige Dimensionierung der eingesetzten Wandler.
- Kürzere Reaktionszeit des Schutzes, um noch vor Sättigungseintritt den Schutz auszulösen; diese Lösung ist technisch aufwendig und teuer.
- Höhere Schwellwerte beim Schutzalgorithmus, um die Robustheit gegenüber Sättigung zu steigern; dies vermindert aber die Empfindlichkeit und verlängert die Reaktionszeit.

Die beste Lösung wäre natürlich, Wandlersättigung überhaupt zu vermeiden. In naher Zukunft werden dazu wohl alternative Messverfahren mit besseren Eigenschaften zur Verfügung stehen, wie zum Beispiel optische Messverfahren. Es wird aber noch lange dauern, bis die klassischen Wandler und damit auch das Sättigungsproblem verschwunden sind.

In der Zwischenzeit wurden bereits numerische Verfahren entwickelt, um aus dem gesättigten Sekundärstrom den tatsächlichen Primärstrom zu errechnen (siehe zum Beispiel [8]). Diese Verfahren beruhen auf der numerischen Integration der Differentialgleichungen, die den Wandler beschreiben. Sie haben den Nachteil, dass die Wandlerkennlinie sowie die Netzparameter exakt bekannt sein müssen. Dies ist in der Realität selten gegeben, da grosse Hochspannungsnetze einem ständigen Wandel unterliegen und auch Alterungsprozesse von Komponenten hineinspielen.

Eine andere Lösung besteht darin, den ursprünglichen «ungesättigten» Strom nachzubilden. Wenn die Frequenz und der richtige Nulldurchgang des Stromsignals bekannt sind und die Amplitude vor Sättigungseintritt ermittelt wird, ist es möglich, das sinusförmige Stromsignal durch Synchronisierung und Amplitudenanpassung mit einer gespeicherten sinusförmigen Kurve zu erzeugen (siehe [11]).

Der Einsatz neuronaler Netzwerke

Künstliche neuronale Netzwerke sind eine mathematische Vereinfachung der Informationsverarbeitung biologischer Nervensysteme, mit zum Teil ähnlichen Eigenschaften (siehe zum Beispiel [1], [7] oder [15]). Eine für technische Anwendungen besonders attraktive Eigenschaft solcher Netzwerke ist die Fähigkeit, aus Beispielen lernen zu können. Mit Hilfe geeigneter Lernalgorithmen können neuronale Netzwerke durch die Präsentation von Beispielen soweit trainiert werden, dass sie komplexe Zusammenhänge nachbilden können. Vielversprechende Anwendungsgebiete sind Muster- und Spracherkennung, Signalverarbeitung, maschinelles Lernen,




Bild 3 Architektur des Gesamtsystems




Bild 4 Verarbeitungsschritte zur Rekonstruktion des Primärstroms

Diagnose, Prognose, Optimierung sowie Steuerung und Regelung.

Im Kontext der Wandlersättigung sind auch folgende Eigenschaften von Bedeutung:

- **Fehlertoleranz:** Kleine Abweichungen der Eingabedaten oder der Ausfall einiger Neuronen führen nur zu geringen Ausgabefehlern.
- **Verallgemeinerungsfähigkeit:** Wird das Netzwerk geeignet trainiert, so kann es auch für neue, noch nie gesehene Eingabedaten gute Ergebnisse liefern. Es hat die trainierten Beispiele nicht einfach «auswendig gelernt», sondern kann auch neue Situationen verarbeiten.

Diese Eigenschaften werden benötigt, da die Bedingungen nicht genau bekannt sind, unter denen die gesättigten Ströme entstehen. Sowohl die Wandlerkennlinie als auch die übrigen Kenngrößen des Hochspannungsnetzes sind nur näherungsweise bekannt, so dass die Anwendung exakter mathematischer Modelle nicht möglich ist. Es ist deshalb naheliegend, neuronale Netzwerke für die Rekonstruktion gesättigter Ströme einzusetzen.

Neuronale Netzwerke können aber nicht einfach als Black-Box betrachtet werden, die nur mit den Rohdaten gefüttert werden muss und die nach der Anwendung eines Lernverfahrens automatisch das richtige Ergebnis liefert. Wie bisherige Erfahrungen gezeigt haben, sollte möglichst viel Problemwissen bei der Vorverarbeitung der Eingabedaten, wie auch beim Entwurf der neuronalen Netze berücksichtigt werden, damit die Komplexität des Lernproblems reduziert wird. Die Erfahrungen aus den Voruntersuchungen in [3] und [4] haben zu folgenden Überlegungen geführt:

- Beim Stromdifferentialschutz, wie auch bei einigen anderen Schutzmethoden,

wird nur die 50-Hz-Komponente des gemessenen Signals verwendet und nicht das vollständige Zeitsignal. Es ist deshalb günstiger, nur die 50-Hz-Komponente zu rekonstruieren.

- Da nur die 50-Hz-Komponente interessiert, soll das Netzwerk so gewährt werden, dass es nur sinusförmige Signale erzeugen kann. Dies führt zu robusteren Ergebnissen, als wenn das Netzwerk beliebige Signale generieren kann. (Diese Einschränkung muss eventuell gelockert werden, falls auch Schaltvorgänge usw. berücksichtigt werden sollen.)
- Im Unterschied zu [3] und [4] wird hier Frequenzinformation als Eingabegröße verwendet. Dies ergibt im Vergleich zur Verwendung von Abtastwerten des Signals ein kleineres Netzwerk, das effizienter trainiert werden kann.
- Ein kleines Netzwerk verbessert ausserdem die Verallgemeinerungsfähigkeit, da weniger Gefahr besteht, dass nur die präsentierten Beispiele gespeichert werden und neue Situationen dagegen zu schlechten Ergebnissen führen.

Aus diesen Gründen wird das neuronale Netzwerk nur für die Rekonstruktion der 50-Hz-Komponente des Primärstromes trainiert, wobei ein Teil des Frequenzspektrums des Sekundärstroms dem Netz zur Eingabe dient. Die 50-Hz-Komponente wird dabei als sinusförmiges Signal via Amplitude und Phase rekonstruiert. Die Gesamtarchitektur ist in Bild 3 dargestellt.

Vorverarbeitungsschritte

Die Rekonstruktion der 50-Hz-Komponente ist in mehrere Verarbeitungsschritte strukturiert (Bild 4). Zuerst wird das Signal mit 2,4 kHz abgetastet und in Zeitfenster

der Grösse einer 50-Hz-Periode eingeteilt, und dann wird mit Hilfe einer Fourieranalyse (FFT) über dem Zeitfenster das Frequenzspektrum ermittelt. Anschliessend werden pro Zeitfenster die ermittelten Amplituden und Phasen normalisiert und an zwei neuronale Netzwerke weitergeleitet, die je die Amplitude und die Phase der 50-Hz-Komponente des Primärstroms rekonstruieren. Diese werden nach einer Rücktransformation dem Schutzalgorithmus übergeben.

Architektur der neuronalen Netzwerke

Die Hauptaufgabe im Rekonstruktionsalgorithmus übernehmen zwei neuronale Netzwerke, die Amplitude und Phase der 50-Hz-Komponente bestimmen. Da sie eine Abbildung von Eingabedaten zu Ausgabedaten berechnen, ist die klassische «Feedforward»-Architektur, das heisst eine Schichtenstruktur ohne Rückkopplung, dem Problem angemessen (siehe Bild 5). Diese Architektur wird auch «Multilayer-Perceptron» genannt (siehe [7,9,10]), wobei gemäss Theorie (siehe [6], Theorem 2, S. 132) für eine Approximationsaufgabe ein dreischichtiges Netz ausreicht. Die Neuronen der Mittelschicht besitzen eine sigmoide Aktivierungsfunktion (tanh), während das Ausgabeneuron eine lineare Aktivierungsfunktion verwendet (Bilder 6–7). Dabei ist jede nachfolgende Schicht vollständig mit der vorangehenden verknüpft, und jede Verbindung ist mit einem Gewicht versehen. Somit berechnet das Netzwerk eine Funktion nach Formel (1).

$$y = \sum_{i=1}^N w_i \cdot \tanh\left(\sum_{j=1}^M w_{i,j} \cdot x_j - \theta_i\right) - \theta \quad (1)$$

- N Anzahl Neuronen in Mittelschicht (4)
- M Anzahl Neuronen in Eingabeschicht (6)
- x_j Eingabewerte
- $w_{i,j}$ Gewichte der Verbindungen von Eingabe- zu Mittelschicht
- w_i Gewichte der Verbindungen von Mittel- zu Ausgabeschicht
- θ, θ_i Schwellwerte
- y Ausgabe des Netzwerkes

Grösse der Netzwerke

Um eine gute Verallgemeinerungsfähigkeit, aber auch eine ausreichende Approximationsgenauigkeit zu erreichen, muss eine optimale Netzwerkgrösse gewählt




Bild 5 Architektur der neuronalen Netze




Bild 6 Transferfunktion der Ausgabeschicht

Für die Aktivierungsfunktion der Ausgabeschicht wird eine lineare Funktion $f(x)$ verwendet




Bild 7 Transferfunktion der Mittelschicht

Für die Mittelschicht wird eine sigmoide Aktivierungsfunktion $f(x) = \tanh(x)$ eingesetzt

werden. Wird ein zu kleines Netz gewählt, so verbessert sich im allgemeinen die Verallgemeinerungsfähigkeit, aber das Netz kann unter Umständen die zu lernende Funktion nur ungenau implementieren. Wird hingegen das Netz zu gross gewählt, können die trainierten Beispiele vielleicht exakt gelernt werden, aber die Verallgemeinerung ist schlecht. Die optimale Grösse ist problemabhängig und kann meist nur empirisch ermittelt werden. Als Faustregel ist aber zu beachten, dass wie bei allen Approximationsproblemen, die Anzahl bekannter Punkte (Beispiele) grösser als die Anzahl freier Parameter des Netzwerkes (Gewichte) sein sollte. Sind die Daten veräuscht, so müssen sogar wesentlich mehr Beispiele als Parameter vorhanden sein.

Nach einer Frequenzanalyse einiger Beispieldaten und verschiedenen Experimenten mit variabler Netzgrösse haben sich die

Amplituden und Phasen der 50-Hz-Komponente des Signals (das heisst des Sekundärstroms des Messwandlers) und seiner ersten zwei Oberwellen als Eingabegrössen geeignet erwiesen. Mit einer Mittelschicht von 4 Neuronen ergibt sich somit ein Netz von total 11 Neuronen mit 33 Verbindungen bzw. Gewichten (inkl. Schwellwerte). Ein solch kleines Netz hat auch den Vorteil, dass es für den Einsatz in Echtzeit wesentlich kostengünstiger zu implementieren ist als ein grosses Netz.

Beschaffung von Trainingsdaten

Da es aus Kostengründen nicht möglich ist, Messwerte von tatsächlichen Messwandlern in ausreichender Menge zu beschaffen, ist man bei der Datenbeschaffung auf Simulation angewiesen. Die Simulation von Wandler sättigung stützt sich auf das vereinfachte Wandlermodell in Bild 8 mit der zugehörigen Differentialgleichung in Formel (2) (siehe [2]):

$$L_{\mu}(i_{\mu}) \cdot \frac{di_{\mu}}{dt} = L \cdot \frac{di_2}{dt} + R \cdot i_2$$

$$i_1 \cdot \ddot{u} = i_2 + \dot{i}_{\mu}$$

- i_1 Primärstrom
- i_2 Sekundärstrom
- i_m Magnetisierungsstrom
- L_m Hauptinduktivität des Wandlers
- R Gesamtwiderstand der Sekundärseite
- L Geamtinduktivität der Sekundärseite
- \ddot{u} Übersetzungsverhältnis

Im allgemeinen Fall ist die genaue Kennlinie des Wandlers und somit die Hauptinduktivität $L_{\mu}(i_{\mu})$ (Bild 9) nicht genau bekannt. In Datenblättern werden jedoch Angaben zum Fehler bei einem bestimmten Überstromfaktor geliefert: Die Fehlerklasse «5P20» bedeutet beispielsweise, dass ein entsprechender Wandler 5% Abweichung bei einem 20fachen Über-




Bild 8 Für die Simulation benütztes Wandlermodell

strom aufweisen darf. Durch diese grobe Klassifizierung von Wandlern ist es möglich, zu einer Fehlerklasse eine Reihe von Wandlerkennlinien nach dem Modell von Formel (3) aus [2] zu simulieren:

$$L_{\mu}(i_{\mu}) = \frac{L_{\mu \max} - L_{\mu \min}}{1 + \left(\frac{i_{\mu}}{i_{\text{sat}}}\right)^{\alpha}} + L_{\mu \min}$$

- $L_{\mu \max}$ Induktivität ohne Sättigung
- $L_{\mu \min}$ Induktivität bei Sättigung
- i_{sat} Sättigungsstrom
- α Krümmungsfaktor

Zu jeder Fehlerklasse werden separate Netzwerke trainiert, die nur für diese Wandlerklasse zuständig sind.

Neben der eigentlichen Wandlerkennlinie müssen auch die übrigen Kenngrössen festgelegt und für die Erzeugung von Lerndaten geeignet variiert werden. Als Fehler-signale werden Kurzschlussströme nach dem Modell von Formel (4) (siehe [14], S. 12) an den Wandler angelegt:

$$i_1(t) = I_{\max} \cdot \left[e^{-t/\tau} \cdot \cos(\alpha) - \cos(\omega \cdot t + \alpha) \right]$$

- α Phasenwinkel des Fehlereintritts
- ω $2\pi \cdot$ Frequenz = 100 π
- τ Netzzeitkonstante
- I_{\max} Amplitude des Kurzschlussstromes




Bild 9 Beispiel einer Wandlerkennlinie

Parameter	Amplitude 5P5, 5P20	Phase 5P5, 5P20
Lernschritte	100 000	100 000
Anfangslernrate η	0,4	0,001
Moment α	0,9	0,9
Anfangsgewichte w	zufällig, 0 ... ± 1	zufällig, 0 ... ± 1
Fehler nach Training	0,0008	0,001

Tabelle I Lernparameter

η Schrittweite
 α Moment
 $\partial E/\partial w$ Gradient des Fehlers bezüglich Gewicht w

Die Schrittweite η wird in Abwandlung der Originalmethode dem Lernerfolg angepasst:

- Nach 5 Lernschritten mit abnehmendem Fehler wird die Schrittweite um 50% erhöht.
- Nach einem Schritt mit zunehmendem Fehler wird die Schrittweite um 50% reduziert.

Datensätze	Mittelwert \bar{K}_{max}	Standardabweichung $\sqrt{\text{var}(\bar{K}_{max})}$	Maximum \hat{K}_{max}	Anzahl Signale
Lerndaten L5P5	0,257	0,312	0,365	30
Testdaten T5P5	0,287	0,198	0,539	27
Lerndaten L5P20	0,120	0,085	0,247	30
Testdaten T5P20	0,149	0,144	0,261	17

Tabelle II Grösster K-Faktor

Da beim Backpropagation-Algorithmus die Gefahr besteht, in einem lokalen Minimum stecken zu bleiben, wurden auch Versuche mit stochastischen Lernverfahren durchgeführt (siehe [7]). Es konnten keine wesentlichen Verbesserungen erzielt werden, aber der Rechenaufwand stieg deutlich. Genaue Angaben über die Lernparameter sowie den erreichten Fehler sind der Tabelle I zu entnehmen.

Datensätze	Mittelwert \bar{K}_{2max}	Standardabweichung $\sqrt{\text{var}(\bar{K}_{2max})}$	Maximum \hat{K}_{2max}	Anzahl Signale
Lerndaten L5P5	0,10	0,07	0,30	30
Testdaten T5P5	0,09	0,05	0,22	27
Lerndaten L5P20	0,03	0,03	0,05	30
Testdaten T5P20	0,04	0,06	0,07	17

Tabelle III Zweitgrösster K-Faktor

Die eigentlichen Lerndaten bestehen aus dem Primär- und dem Sekundärstromverlauf, die bei fixen Wandler- und Netzparametern durch Simulation gewonnen werden.

Es ist hier anzumerken, dass auch die hier beschriebenen neuronalen Netzwerke auf einem Computer simuliert werden. Die Simulation ist normalerweise einfacher und flexibler als die Verwendung spezialisierter Hardware. Sobald die Netzwerke aber in Echtzeit betrieben werden, ist man bei grösseren Netzen möglicherweise auf die höhere Rechenleistung von «Neuro-Chips» angewiesen.

Für die Korrektur der Gewichte stehen verschiedene Lernalgorithmen zur Verfügung. Im Prinzip kann jede Methode zur Funktionsminimierung eingesetzt werden. Da es sich bei den verwendeten neuronalen Netzen um kleine Netze handelt, ist eine Variante des beliebten «Backpropagation»-Algorithmus ausreichend (siehe [1], [7] oder [16]). Die Verbindungsgewichte im Netzwerk werden iterativ nach dem Schema von Formel (6) korrigiert; dabei werden die Schwellwerte wie Gewichte behandelt:

Trainieren der neuronalen Netzwerke

Die neuronalen Netzwerke werden trainiert, indem die Ergebnisse der Vorverarbeitung eines Zeitfensters des Sekundärstroms an die Netzwerke angelegt werden und die Antwort der Netze berechnet wird. Aus dem Vergleich der gewünschten Ausgabe (Primärstrom) mit der tatsächlichen Antwort (rekonstruierter Primärstrom) wird ein Fehlersignal erzeugt, das zur Korrektur der Gewichte in den neuronalen Netzen so verwendet wird (Formel (5)), dass der Fehler möglichst klein wird:

$$E = \sum_{v=1}^V (d_v - y_v)^2 \quad (5)$$

$$\Delta w = -\eta \cdot \frac{\partial E}{\partial w} + \alpha \cdot \Delta w_{alt} \quad (6)$$

E Fehler des Netzwerkes
 V Anzahl Beispiele
 d_v gewünschte Ausgabe zu Beispiel v
 y_v tatsächliche Ausgabe zu Beispiel v

Δw Gewichtsänderung pro Lernschritt
 Δw_{alt} Gewichtsänderung bei letztem Schritt

Beurteilungskriterium

Um die Rekonstruktionsqualität der neuronalen Netzwerke insgesamt beurteilen zu können, wird der K-Faktor nach Formel (7) eingeführt:

$$K = \frac{\sqrt{1 + \left(\frac{A_{rec}}{A_{orig}}\right)^2 - 2 \cdot \cos(\Delta\varphi) \cdot \frac{A_{rec}}{A_{orig}}}}{1 + \frac{A_{rec}}{A_{orig}}} \quad (7)$$

K Rekonstruktionsfehler
 A_{orig} ursprüngliche 50-Hz-Amplitude
 A_{rec} rekonstruierte 50-Hz-Amplitude
 $\Delta\varphi$ Phasendifferenz zwischen Original und rekonstruiertem Signal

Dieser Faktor vereint Amplituden- und Phasenabweichung in ein Gesamtfehlermass, das zwischen 0 (kein Fehler) und 1 (ganz schlecht) variieren kann. Der K-Faktor wird jeweils über dem Zeitfenster ermittelt, das als Eingabe für die neuronalen Netzwerke dient. Je kleiner der K-Faktor ist, desto genauer ist die Rekonstruktion des Primärstroms. Der höchste noch akzeptable K-Faktor hängt vom Schutzalgorithmus ab, der das rekonstruierte Signal benutzt. Als Richtwert wird ein Maximum von 0,5 angenommen.

Ergebnisse

Es muss natürlich die Rekonstruktionsqualität sowohl bei den gelernten Beispielen




Bild 10 Primärstrom und gesättigter Sekundärstrom für ein Beispiel aus der Lerndatenmenge

Wandler 5P5, $I_{max} = 15kA$, $\alpha = 0$




Bild 11 Ursprüngliche und rekonstruierte 50-Hz-Komponente

Resultat für das Beispiel nach Bild 10: $K_{max}=0,3392$




Bild 12: Primärstrom und gesättigter Sekundärstrom für ein Beispiel aus der Testdatenmenge

Wandler 5P5, $I_{max} = 7kA$, $\alpha = 0$




Bild 13 Ursprüngliche und rekonstruierte 50-Hz-Komponente

Resultat für das Beispiel nach Bild 12: $K_{max}=0,1984$

len, als auch bei einer unabhängigen Testmenge ermittelt werden. Diese erlaubt ja erst die Beurteilung der Verallgemeinerungsfähigkeit für unbekannte Wandlerkennlinien (innerhalb der trainierten Fehlerklasse) und abweichende Netz- und Signalparameter. Die Tabellen II und III fassen die statistische Verteilung des K-Faktors zusammen.

Die Ergebnisse sind vielversprechend. Die Rekonstruktion des Primärstroms der Lernbeispiele erfüllt überall die Qualitätsanforderungen. Typischerweise ist der K-Faktor am Anfang eines Kurzschlussignals am grössten und klingt anschliessend schnell ab. Das ist aus den Statistiken der zweitgrössten K-Faktoren ersichtlich.

Ein Vergleich der K-Faktoren der Testdaten mit denjenigen der Lerndaten zeigt, dass sie von derselben Grössenordnung sind und dass somit eine gute Verallgemeinerung erreicht werden konnte. Ein einziger Testfall ist knapp über dem Referenzwert für den maximalen K-Faktor, was aber für den Schutzalgorithmus bei weitem nicht kritisch ist.

Um die Rekonstruktionsqualität auch visuell darstellen zu können, wurden in den Bildern 10–13 je ein Signalverlauf aus der Menge der Lerndaten und ein Beispiel aus den Testdaten in ein Zeitsignal zurücktransformiert. Beim Übergang vom rekonstruierten Signal eines Zeitfensters zur Rekonstruktion des nächsten sind dabei kleine Sprungstellen zu sehen.

Schlussfolgerungen

Die hier beschriebene Studie zeigt, dass neuronale Netzwerke erfolgreich zur Lösung des Problems der Wandlersättigung eingesetzt werden können. Wird die Forderung nach exakter Rekonstruktion von Primärströmen aus gesättigten Sekundärströmen etwas abgeschwächt, ist es möglich, mit wenig Wissen über die Wandlercharakteristik und über das Umfeld des Wandlers auszukommen und dabei eine für Schutzzwecke gute Rekonstruktionsqualität zu erreichen. Obwohl das Hauptgewicht der Studie auf eine Anwendung im Sammelschienenschutz ausgerichtet war, ist der verwendete Ansatz auch in anderen Schutzsystemen einsetzbar, wo ebenfalls nur die 50-Hz-Komponente des Signals benötigt wird.

Mit der Wahl einer Frequenzanalyse als Vorverarbeitung konnte das neuronale Netzwerk klein gehalten werden, wodurch es effizient trainiert werden konnte und ein gutes Verallgemeinerungsverhalten erreicht wurde. Ein kleines Netzwerk eignet

sich auch besser für die Implementation in einer Echtzeitumgebung.

Ausblick

Neuronale Netzwerke können grundsätzlich auf zwei verschiedene Arten eingesetzt werden. Zum einen kann man ein Netzwerk im Labor für seine Aufgabe trainieren und anschliessend im Feld ohne weiteres Dazulernen einsetzen. Zum anderen ist es aber auch möglich, dass ein Netzwerk während der Erfüllung seiner Aufgabe kontinuierlich weiterlernt. Dazu muss aber ein Rückkoppelungssignal zur Verfügung stehen, das ihm mitteilt, wie gut es seine Aufgabe erfüllt. Beim Problem der Rekonstruktion gesättigter Ströme ist dies aber nicht möglich, da erstens kein solcher wissender «Lehrer» vorhanden ist und zweitens sich ein Netzwerk bei dieser Anwendung keine Fehler leisten kann. Ein neuronales Netzwerk lernt aber nur aus Fehlern.

Es gibt aber noch eine Reihe weiterer Verbesserungsmöglichkeiten, die untersucht werden können. Eine Möglichkeit besteht in der Integration der Schutzalgorithmen in die neuronalen Netzwerke, d.h. die Netzwerke werden nicht für die Signalrekonstruktion allein trainiert, sondern direkt für die Erzeugung von Schutzentscheiden. Der Schutz kann so möglicherweise schneller reagieren, die Verifikation seiner Entscheidungen wird allerdings schwieriger.

In der Realität kommen ausser Normalströmen und Kurzschlussströmen noch weitere Signaltypen vor, zum Beispiel jene bei Schaltvorgängen. Die Berücksichtigung solcher Signaltypen hat bei einer Weiterführung der Untersuchungen höhere Priorität als die Erzeugung von Schutzentscheiden. Im weiteren wird die Realisierung der neuronalen Netzwerke in Hardware, zum Beispiel durch den Einsatz eines kommerziellen Neurochips, oder die Simulation auf schnellen Rechnern erwogen.

Danksagung

Der Dank der Autoren gilt vor allem den ehemaligen Studenten der HTL Brugg-Windisch, *R. Kramer* und *T. Sutter*, die mit ihrer Diplomarbeit [13] entscheidend zu dieser Arbeit beigetragen haben. Auch möchten sie *Dr. J. Bernasconi* und *Dr. H. J. Wiesmann* für anregende Dis-

kussionen und Ratschläge danken. Dank gebührt schliesslich auch dem Schweizerischen Nationalfonds, der dieses Projekt im Rahmen des Nationalen Forschungsprogramms 23, Künstliche Intelligenz und Robotik, finanziell unterstützt hat.

Literatur

- [1] *J. Bernasconi*: Neuronale Netzwerke – Theorie und Praxis. Bull. SEV/VSE 82(1991)13, S. 11–16.
- [2] *A. Böhm*: Numerisches Berechnungsverfahren für das Stromwandlerverhalten unter Berücksichtigung der Eisensättigung. ETZ-A 94(1973)10.
- [3] *U. Braun, F. Engler and K. Feser*: Application of Neural Networks in Numerical Busbar Protection Systems. Proc. of International Forum on Application of Neural Networks to Power Systems, Seattle, 1991, pp. 171–121.
- [4] *U. Braun, K. Feser and D. Peck*: Restoring Current Signals in Real Time Using Feedforward Neural Nets. Proc. of International Forum on Application of Neural Networks to Power Systems, Yokohama, 1993.
- [5] *R. Cozzio, T. Sutter and R. Kramer*: Reconstruction of Saturated Current Signals Using Neural Networks. To be published.
- [6] *R. Hecht-Nielsen*: Neurocomputing. Addison-Wesley, 1989.
- [7] *J. Hertz, A. Krogh and R.G. Palmer*: Introduction to the Theory of Neural Computation. Addison-Wesley, 1991.

[8] *T. Konrad*: Numerische Korrektur der Sekundärströme gesättigter Stromwandler in Echtzeit. Dissertation der Technischen Hochschule Darmstadt, 1989.

[9] *J.-F. Leber und M.B. Matthews*: Neuronale Netzwerke – eine Übersicht. Bull. SEV/VSE 80(1989)15, S. 923–932.

[10] *R.P. Lippmann*: An Introduction to Computing with Neural Nets. IEEE ASSP Magazine, April 1987.

[11] *J. De Mesmaeker und Ch. Steiner*: Das Verhalten des Distanzrelais LZ95 bei extremer Sättigung der Hauptstromwandler. Brown Boveri Technik Nr. 2, 1985.

[12] *T. Sutter und R. Kramer*: Erkennung der Sättigung eines Stromwandlers mit Hilfe von neuronalen Netzwerken. Semesterarbeit an der HTL Brugg-Windisch, 1992.

[13] *T. Sutter und R. Kramer*: Rekonstruktion der 50-Hz-Komponente des Primärsignals aus dem Sekundärsignal eines gesättigten Stromwandlers mit Hilfe von neuronalen Netzwerken. Diplomarbeit an der HTL Brugg-Windisch, 1992.

[14] *H. Ungrad, W. Winkler and A. Wiszniewski*: Schutztechnik in Elektroenergiesystemen. Springer-Verlag, 1991.

[15] *D. E. Rumelhart and J. L. McClelland*: Parallel distributed processing – Explorations in the microstructure of cognition. Cambridge, MA, Bradford Books, 1986.

[16] *D. E. Rumelhart, G. E. Hinton and R. J. Williams*: Learning internal representations by error backpropagation, in Parallel distributed processing – Explorations in the microstructure of cognition. D. E. Rumelhart and J. L. McClelland, eds., Cambridge, MA, Bradford Books, 1986.

Traitement des signaux neuronal pour une protection sûre

L'utilisation des réseaux neuronaux au problème de la saturation des transformateurs d'intensité

Les transformateurs de mesure utilisés dans les systèmes de protection des systèmes d'énergie électrique subissent des effets de saturation due à des courants très élevés (figures 1 et 2). Pour éviter un fonctionnement intempestif, le système de protection doit alors compenser les distorsions des signaux causées par les transformateurs de mesure. Le présent article montre comment on peut reconstruire, à l'aide d'un réseau neuronal, le courant effectif à partir du signal de mesure distordu. Le réseau, sans connaissance précise des paramètres du système et du transformateur, atteint une qualité de reconstruction qui permet l'utilisation fructueuse de ce réseau dans les systèmes de protection.

Le réseau neuronal utilisé (figure 5) a été entraîné pour réaliser la reconstruction de l'amplitude et de la phase de la composante 50 Hz du courant primaire du transformateur de mesure, une partie du spectre de fréquences du courant secondaire servant au réseau pour l'introduction. Le signal, c'est-à-dire le courant secondaire, est d'abord balayé avec 2,4 kHz et divisé en fenêtres de temps de la taille d'une période 50 Hz. Puis, à l'aide d'une analyse de Fourier (FFT), on en détermine le spectre de fréquences sur la fenêtre de temps. Les amplitudes et phases déterminées sont ensuite transmises à deux réseaux neuronaux qui reconstruisent chacun l'amplitude et la phase de la composante 50 Hz du courant primaire. Les figures 10 et 11 renseignent sur la qualité de reconstruction obtenue pour un exemple tiré de l'ensemble des données apprises et les figures 12 et 13 pour un autre exemple tiré des données de test.

Information - ein 1. Schritt zur Rationalisierung

Steuerungstechnik

EINLADUNG

Installationsplanung

CAD/CAE - INFO-TAGE 1994


Elektrotechnik: Erfolgreiche CAD/CAE-Lösungen im praktischen Einsatz

- Auswahlkriterien
- Integrationsmöglichkeiten
- Schnittstellen zu anderen Programmen
- Erfahrungen aus der Praxis
- Funktionalitäten
- Praktische Systemvorführungen

speziell für:

- Elektroplaner, Elektro-Installationsplaner
- Schematechniker, Schaltanlagenbauer
- SPS- und GLS-Spezialisten

BN Computer AG CH-6280 Hochdorf



Telefon 041-88 52 22 Fax 041-88 43 62

auch in Ihrer Nähe!

SARGANS 26. April

BASEL 3. Mai

WINTERTHUR 27. April

BERN 4. Mai

ZÜRICH 5. Mai


BRIG 28. April

Die Teilnahme ist kostenlos!

Verlangen Sie noch heute per Telefon oder Fax das Detailprogramm (inkl. Anmeldeformular)



HAUG-Ionisationssysteme beseitigen
störende statische Elektrizität.



Statische Aufladungen führen in vielen Fertigungsprozessen zu Störungen. HAUG-Ionisationssysteme lösen dieses Problem bei der Folien- und Papierverarbeitung sowie in der Textil- und Kunststoffindustrie.

HAUG BIEL AG

Johann-Renfer-Strasse 60 · CH-2504 Biel-Bienne
Telefon 0 32 / 41 67 67-68 · Telefax 0 32 / 41 20 43

Fribos



**Im Explosionsschutz
kennen wir uns aus**

Explosionsgeschützte

- Leuchten
- Installationsgeräte
- Befehlsgeräte
- Meldegeräte
- Steuerungen
- MSR-Geräte
- Feldmultiplexer



Fribos AG, Muttenerstrasse 125
CH-4133 Pratteln 2, Telefon 061 821 41 41, Fax 061 821 41 53

01/207 86 34

Direktwahl zu Ihrem Zielpublikum.

Elektroingenieure ETH/HTL
Leser des Bulletin SEV/VSE
mit Einkaufsentscheiden