

**Zeitschrift:** bulletin.ch / Electrosuisse  
**Herausgeber:** Electrosuisse  
**Band:** 95 (2004)  
**Heft:** 23

**Artikel:** Modellierung ferromagnetischer Werkstoffe  
**Autor:** Cernat, R. / Nierobisch, T. / Peier, D.  
**DOI:** <https://doi.org/10.5169/seals-858017>

### **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:** 04.02.2026

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

# Modellierung ferromagnetischer Werkstoffe

## Neuronale Netze modellieren magnetische Elemente

Elektrische Geräte werden miniaturisiert, die Funktionsdichte steigt. Kernbaugruppen werden dabei bis zur physikalischen Grenze integriert, die einzelnen Bauteile müssen präzise dimensioniert werden. Dominieren die magnetischen Elemente, wie bei elektrischen Maschinen und Transformatoren, muss das nichtlineare Verhalten dieser Werkstoffe im Detail modelliert werden. Künstliche neuronale Netze bilden die magnetischen Materialien auch für Oberschwingungen und Gleichstromanteile zuverlässig nach.

Magnetische Werkstoffe werden entweder physikalisch oder mathematisch modelliert [1]. Einer der bekanntesten physikalischen Ansätze ist das Jiles-Atherton-Modell [2], das, ausgehend von der ferromagnetischen Struktur, eine Dif-

R. Cernat, T. Nierobisch, D. Peier

ferenzialgleichung erster Ordnung mit vier materialspezifischen Parametern aufstellt. Das Verfahren benötigt eine Kalibriermessung, um die Parameter zu ermitteln und ist auf eine sinusförmige Erregung beschränkt. In [3] wird ein erweiterter Ansatz einer physikalischen Modellierung vorgestellt. Basierend auf den Kräften zwischen Elementardipolen wird die Bewegung einer 180°-Blochwand beschrieben und daraus auf das magnetische Verhalten des Materials hochgerechnet. Das kalibrierte Modell prognostiziert das Materialverhalten für beliebige, zeitveränderliche Feldbelastungen. Die komplexe Kalibrierroutine setzt aber Expertenwissen und Erfahrungswerte voraus.

Ein in der Technik verbreitetes mathematisches Verfahren zur Modellierung von Hystereseeigenschaften ist das Preisach-Modell [4]. Dieses verwendet eine Parallelschaltung von Hystereseelementen, deren Ausgänge gewichtet aufsummiert werden. Dadurch können äussere und innere Schleifen monofrequent nachgebildet werden. Eine Erweiterung des Preisach-Modells [5] bietet die Möglichkeit, auch Übergangskurven zweiter Ordnung zu simulieren. Um die Gewichtungsfaktoren der einzelnen Hystereseelemente anhand von Messdaten zu be-

stimmen, wird in [6] der Einsatz von neuronalen Netzen vorgeschlagen. Neuronale Netzwerke werden zudem als Black Box zur Modellierung des Hystereseverhaltens verwendet [7,8]. Mit mehreren neuronalen Netzwerken werden in [7] charakteristische Zustände des magnetischen Werkstoffes wie zum Beispiel die Neukurve, der aufsteigende und der abfallende Zweig nachgebildet. Ein wissenschaftlicher Algorithmus garantiert, dass das entsprechende neuronale Netzwerk für den jeweiligen Anregungszustand verwendet wird. In [8] werden monofrequente Hysteresekurven für verschiedene Intensitäten der Erregung simuliert.

Der hohe Anspruch an ein Modellierungsverfahren besteht darin, anhand von wenigen einfachen Messungen sowohl

die Nichtlinearität des Werkstoffes als auch die Frequenzabhängigkeit nachzubilden. Das Verfahren darf die Erregung nicht beschränken, sonst findet es in der Praxis kein breites Anwendungsgebiet. Künstliche neuronale Netzwerke können mehrdimensionale Zusammenhänge nichtlinear interpolieren und sind daher ein interessanter Ansatz zur Modellierung magnetischer Werkstoffe. Speziell in der Energieversorgung sind neben den sinusförmigen Erregungen bei beliebigen Frequenzen auch Simulationen Oberschwingungs- und gleichanteilbehafteter Verläufe gefragt. Das hier beschriebene, auf weichmagnetische Materialien angepasste Modell besteht aus einem neuronalen Netzwerk, das mit monofrequenten Messungen angelernet wird und beliebige Verläufe aus dem abgedeckten Trainingsraum nachbildet.

### Magnetische Werkstoffe qualifizieren

Der Magnetisierungszustand eines Werkstoffes wird von zwei physikalischen Grössen – der magnetischen Feldstärke  $H$  und der magnetischen Flussdichte  $B$  – vollständig beschrieben. Diese Grössen sind mit dem Erregerstrom beziehungsweise mit dem magnetischen Fluss proportional und können sich innerhalb eines homogenen Mediums nicht sprunghaft ändern. Ein magnetischer Werkstoff erfährt somit einen kontinuier-




Bild 1 Nichtlinearer Parameterraum eines weichmagnetischen Werkstoffes






Bild 2 Aufbau des neuronalen Netzes

lichen Übergang aus einem Magnetisierungszustand in einen anderen, wobei der Endzustand von dem Ausgangszustand, der Intensität der Erregung und dem Gradienten der Erregung beeinflusst wird. Ausgehend von der Definition der differentiellen Permeabilität  $\mu_{diff}$  gilt:

$$dB = \mu_0 \cdot \mu_{diff} \cdot dH \quad (1)$$

wobei  $\mu_{diff} = f(H, B)$ . Zusammengefasst ergibt sich:

$$\frac{dB}{dt} = f\left(H, \frac{dH}{dt}, B\right) \quad (2)$$

Somit lässt sich die zeitliche Ableitung der magnetischen Flussdichte als ein funktioneller Zusammenhang zwischen der magnetischen Feldstärke, der zeitlichen Ableitung der magnetischen Feldstärke und der magnetischen Flussdichte ausdrücken. Dieser Zusammenhang wird anhand von mehreren Messungen bei verschiedenen Frequenzen, Amplituden und Oberschwingungsgehalten in einer vierdimensionalen Darstellung visualisiert (Bild 1). Für die vierte Dimension wird dem Wertebereich ein Farbverlauf zugeordnet. Dass die räumliche Farbverteilung der Messdaten bei unterschiedlichem Charakter stetig bleibt, zeigt, dass diese Beschreibung konsistent ist.

Anhand der Darstellung ist eine Berechnung beliebiger zeitveränderlichen Magnetisierungen in den Grenzen des bekannten Parameterraumes möglich. Als Eingangsgrösse für die Berechnung wird der zeitliche Verlauf der magnetischen Feldstärke gewählt. Somit steht auch die zeitliche Ableitung der magnetischen Feldstärke fest. Ausgehend von einem In-

itialwert der Flussdichte wird die zeitliche Ableitung der Flussdichte aus dem Diagramm abgelesen und somit der nächste Wert für die Flussdichte bestimmt:

$$B_{k+1} = B_k + \frac{dB}{dt}\left(H_k, \frac{H_k - H_{k-1}}{\Delta t}, B_k\right) \cdot \Delta t \quad (3)$$

Nach diesem Iterationsprinzip könnte der zeitliche Verlauf der Flussdichte mit einem Runge-Kutta-Verfahren konstruiert werden. Das Verfahren scheitert jedoch an der Vielzahl von Messungen, die nötig sind, um den gesamten Parameterraum mit einer ausreichenden Schrittweite zu erfassen. Für eine Modellierung des Werkstoffes anhand weniger Messungen ist der Einsatz künstlicher neuronaler Netzwerke geeignet. Neuronale Netzwerke können zwischen den gegebenen Stützstellen nichtlinear interpolieren und bilden somit den trainierten Bereich des Parameterraumes nach.

### Hystereseverläufe mit neuronalen Netzwerken modellieren

Eine Modellierung des gesamten Parameterraumes scheitert an der Vielzahl der Zustände, die das neuronale Netzwerk lernen müsste. Um dieses zu umgehen, wird der Parameterraum auf ein für die Simulation relevanten Bereich eingegrenzt und systematisch durch Messungen abgetastet.

Um gezielt Bereiche des Parameterraumes messtechnisch zu erfassen, stehen drei Freiheitsgrade zur Verfügung: Amplitude, Frequenz und Oberschwingungsgehalt der Erregung. Die Amplitude be-

stimmt die maximale magnetische Flussdichte, die Frequenz beeinflusst die Wirbelstromverluste und somit die Breite des Hystereseverlaufes und implizit die magnetische Feldstärke. Über die Signalform und die Steilheit der einzelnen Abschnitte wird der gewünschte Wert für die zeitliche Ableitung der magnetischen Feldstärke eingestellt.

Die verwendete Netzstruktur ist in Bild 2 dargestellt. Es handelt sich um ein rückgekoppeltes neuronales Netzwerk, bei dem der Ausgang über mehrere Verzögerungselemente auf den Eingang zurückgekoppelt wird. Für jeden Wert der magnetischen Feldstärke am Eingang liefert das Netzwerk den Wert der magnetischen Flussdichte am Ausgang. Die Eingangs- und Ausgangswerte werden auf einen Bereich von -1 bis 1 normiert. Die magnetische Flussdichte wird auf die Sättigungsflussdichte bezogen, während der Referenzwert für die magnetische Feldstärke sich aus der maximalen Stromstärke des Messaufbaus ergibt. Die zeitlichen Ableitungen der magnetischen Feldstärke und der Flussdichte werden intern über die Verzögerungsglieder gebildet. Bei Vorgabe einer magnetischen Feldstärke sind zum Startzeitpunkt einer Simulation die Werte der magnetischen Flussdichte zu null initialisiert. Demzufolge schwingt sich der Ausgang des neu-




Bild 3 Monofrequent sinusförmige Erregung bei 180 Hz und variierender Amplitude




Bild 4 Oberschwingungen nach EN 50160 bei 200 Hz



ronalen Netzwerkes erst ein, nachdem an den Verzögerungsgliedern die richtigen Werte der magnetischen Flussdichte anliegen. Intern ist das Netzwerk in vier Schichten strukturiert, wobei die Anzahl der Neuronen progressiv von der Eingangsschicht zum Ausgangsschicht ab-

nimmt. Die Eingangsschicht benutzt eine hyperbolische Aktivierungsfunktion (*tansig*), die innere Schicht eine Sigmoidfunktion (*logsig*), während die Ausgangsschicht eine lineare Aktivierungsfunktion hat. Zwischen Eingang und Ausgang besteht folgender funktioneller Zusammenhang:

$$B_k = \sum_i W_{oi} \cdot \text{logsig} \left( \sum_j W_{H2ij} \cdot \text{logsig} \left( \sum_m W_{H1jm} \cdot \text{tansig} \left( \sum_{n=0}^3 W_{lmn} \cdot H_{k-n} + \sum_{n=1}^3 W_{lmn} \cdot B_{k-n} + b_{lm} \right) + b_{H1j} \right) + b_{H2i} \right) + b_o. \quad (4)$$

Durch eine passende Wahl der Gewichte und Bias-Werte lässt sich Gleichung (3) nachbilden. Das neuronale Netzwerk wird in Matlab implementiert und mit gemessenen Daten angelernet. Die Optimierung der Gewichte erfolgt in zwei Schritten: erst mit dem Resilient-Backpropagation-Algorithmus [9], um den Suchraum einzugrenzen, und dann mit Levenberg-Marquardt Algorithmus [10]. Durch die Kombination der zwei Methoden wird eine hohe Genauigkeit bei minimaler Trainingsdauer erreicht. Während des Trainings wird die optimale Netzstruktur anhand von Testdatensätze ermittelt. Die Anzahl der Neuronen pro Schicht und die Verzögerungszeiten werden in einer vorgegebenen Schrittweite variiert, um die Netzstruktur mit den besten Ergebnissen zu ermitteln. Die Testdatensätze unterscheiden sich von den Trainingsdaten, um ein Netz mit einem hohen Generalisierungsvermögen zu erhalten und um ein Overfitting zu vermeiden.

## Simulation weichmagnetischer Werkstoffe

Die Netzstruktur wird einmalig anhand eines Messdatensatzes einer Materialprobe optimiert und kann für andere weichmagnetische Werkstoffe eingesetzt werden. Somit besteht nur beim ersten Trainingsdurchlauf ein grosser Zeitaufwand, während das System weitere Materialien verhältnismässig schnell lernt. In diesem Fall wird die Netzstruktur anhand der Messungen mit der Epsteinrahmenprobe bestimmt und für die Ringkernprobe neu antrainiert. Auf einem handelsüblichen PC dauern die Optimierung der Netzstruktur 24 Stunden und das Antrainieren eines neuen Materials ungefähr 10 Minuten.

Dargestellt werden Simulationsergebnisse von künstlich generierten Erregungen, für die Vergleichsmessungen durchgeführt werden konnten. Im Gegensatz zu den monofrequenten Messungen für das Training benötigen die Vergleichsmes-

sungen einen anspruchsvollen Messaufbau. Zudem kann der magnetische Fluss nicht direkt gemessen werden, dieser wird aus der induzierten Spannung bis auf einen Gleichanteil durch Integration bestimmt. Das Modell bildet Verläufe mit Gleichanteil nach, liefert also Ergebnisse über die Grenzen der Messtechnik hinaus. Die Güte des Modells wird anhand von monofrequenten, überschwingungs- und offsetbehafteten Messungen bestimmt.

Der Trainingsdatensatz beinhaltet Messungen bei 50, 150 und 250 Hz. In Bild 3 werden die Simulationsergebnisse für Hystereseverläufe bei 180 Hz und

verschiedenen Amplituden der Erregung dargestellt. Für Oberschwingungen wird ein Verlauf nach EN 50160 entsprechend der Nieder- und Mittelspannungsebene als Referenz gewählt. Demzufolge sind die Schwingungen 5. Ordnung mit 6% und die Schwingungen 3. und 7. Ordnung mit 5% gegenüber der Grundschwingung vertreten. Ein solcher Verlauf wird für 200 Hz in Bild 4 dargestellt.

Auf Grund der Zunahme der 5. Oberschwingung innerhalb der Verteilernetze in den letzten Jahren wird diese als besonders kritisch angesehen. Bild 5 zeigt Simulationsergebnisse von Verläufen, die ausschliesslich mit der 5. Oberschwingung behaftet sind. Simulierte Hysteresekurven bei sinusförmiger Erregung mit DC-Anteil werden in Bild 6 dargestellt. Das neuronale Netz kann auch asymmetrische Erregungen verlässlich prognostizieren.

Künstliche neuronale Netzwerke haben für die Modellierung weichmagnetischer Werkstoffe eine zunehmende Bedeutung. Im Gegensatz zu klassischen Simulationsverfahren bilden sie das Werkstoffverhalten, in einem vorgegebenen Rahmen, frequenzunabhängig nach. Es wird gezeigt, dass das Modell auch bei




Bild 5 Simulation der 5. Oberschwingung

Simulation mit harmonischen Verläufen bei 100 Hz mit 5. Oberschwingung. Bild 5a: Oberschwingungsgehalt 6%; Bild 5b: Oberschwingungsgehalt 25%.




Bild 6 Simulationen mit DC-Anteil

Simulationen sinusförmiger Erregung mit DC-Anteil. Bild 6a: 110Hz; Bild 6b: 180 Hz.



verschiedenen zeitlichen Erregungen gültig ist und dass die Netzstruktur materialunabhängig ist.

Für gute Simulationsergebnisse ist eine zweckmässige Wahl des Trainingsdatensatzes von grosser Bedeutung. Das neuronale Netzwerk interpoliert den Parameterraum nichtlinear. Verlässt der Eingang den abgedeckten Bereich, werden die Hysteresekurven nur noch schlecht prognostiziert, da neuronale Netzwerke nur mit geringer Konfidenz extrapolieren.

### Referenzen

- [1] A. Nicolaide: Magnetism and Magnetic Materials, Transilvania University Press, Brasov, 2001.
- [2] D. C. Jiles, D. L. Atherton: Theory of Ferromagnetic Hysteresis, Journal of Magnetism and Magnetic Materials, Vol. 61, 1986, pp. 48-60.
- [3] M. Wetter: Prognose des Verhaltens weichmagnetischer Werkstoffe in beliebig zeitveränderlichen magnetischen Feldern. Dissertation Universität Dortmund, Shaker Verlag, Aachen, 1998
- [4] F. Preisach: Über die magnetische Nachwirkung, Zeitschrift für Physik, 94, 1935, S. 277-302.
- [5] I. D. Mayergozy, G. Friedman: Generalized Preisach Model of Hysteresis, IEEE Transactions on Magnetics, Vol. 24, 1988, No. 1, pp. 212-217.
- [6] A. A. Adly, S. K. Abd-El-Hafiz: Using neural Networks in the Identification of Preisach-Type Hysteresis Models, IEEE Transactions on Magnetics, Vol. 34, 1998, No. 3, pp. 629-635.
- [7] M. Kuczmann, A. Ivanyi: A New Neural-Network-Based Scalar Hysteresis Model, IEEE Transactions on Magnetics, Vol. 38, 2002, No. 2, pp. 857-860.

- [8] A. Nafalski, B. G. Hoskins, A. Kundu, T. Doan: The use of neural networks in describing magnetisation phenomena, Journal of Magnetism and Magnetic Materials, Vol. 160, 1996, pp. 84-86.
- [9] M. Riedmiller, H. Braun: A direct adaptive method for faster backpropagation learning: The RPROP algorithm, Proceedings of the IEEE International Conference on Neural Networks, 1993.
- [10] M. T. Hagan, M. Menhaj: Training feedforward neural networks with the Marquardt algorithm, IEEE Transactions on Neural Networks, Vol. 5, 1994, No. 6, pp. 989-993.

### Angaben zu den Autoren

Dipl.-Ing. **Radu-Marian Cernat** hat an der TU-Braunschweig sein Studium der Elektrotechnik absolviert und ist seit 2002 wissenschaftlicher Mitarbeiter am Lehrstuhl für Hochspannungstechnik und EMV der Universität Dortmund. Er befasst sich mit der Modellierung

weichmagnetischer Werkstoffe und Geometriesynthese magnetischer Kreise.

Kontakt: Universität Dortmund, Lehrstuhl für Hochspannungstechnik und EMV, D-44221 Dortmund, radu.cernat@hse.e-technik.uni-dortmund.de

Dipl.-Ing. **Thomas Nierobisch** hat an der Universität Dortmund Allgemeine Elektrotechnik studiert und ist seit 2004 wissenschaftlicher Mitarbeiter am Lehrstuhl für Hochspannungstechnik und EMV.

Kontakt: Universität Dortmund, Lehrstuhl für Hochspannungstechnik und EMV, D-44221 Dortmund, thomas.nierobisch@hse.e-technik.uni-dortmund.de

Prof. Dr.-Ing. **Dirk Peier** hat an der TU-Braunschweig promoviert und war anschliessend einige Jahre Laborleiter an der PTB-Braunschweig. Seit 1982 ist er Inhaber des Lehrstuhls für Hochspannungstechnik und EMV der Universität Dortmund.

Kontakt: Universität Dortmund, Lehrstuhl für Hochspannungstechnik und EMV, D-44221 Dortmund, dirk.peier@uni-dortmund.de

## Modélisation de matériaux ferromagnétiques

### Des réseaux neuronaux servent à modeler des éléments magnétiques

Les appareils électriques sont miniaturisés, la densité des fonctions croît. Les éléments de base sont intégrés jusqu'aux limites physiquement possibles, les composants doivent être dimensionnés avec précision. Lorsque les éléments magnétiques sont prédominants, comme dans le cas des machines électriques et transformateurs, le comportement non linéaire de ces matériaux doit être modélisé en détail. Des réseaux de neurones artificiels imitent fiablement les matériaux magnétiques également au niveau des harmoniques et des composantes de courant continu.




## Gemeinsam optimale Wachstumsbedingungen schaffen.

**Mit dem richtigen Finanzpartner.** Bei UBS stehen Sie und der Erfolg Ihrer Firma im Zentrum. Im gemeinsamen Gespräch nehmen wir uns Zeit, Ihre individuellen Bedürfnisse kennen zu lernen und Ihr Geschäft zu verstehen. So können wir rasch und kompetent Finanzlösungen bereitstellen, die Ihren Erwartungen und Marktchancen am besten entsprechen. Sie und UBS: eine Partnerschaft, mit der Sie wachsen können. **Willkommen bei UBS Business Banking.**

UBS Service Line für KMU: 0844 853 002. [www.ubs.com/business-banking](http://www.ubs.com/business-banking)







Egal, welches Ziel Sie verfolgen: Die optimale Kommunikationslösung mit **Festnetz, Mobile, Internet und Data** für Ihr KMU ist nur einen Anruf weit entfernt. Melden Sie sich einfach bei uns für eine **persönliche und kostenlose Beratung**. **Luzern** 041 367 25 25, **Olten** 062 832 18 18, **St. Gallen** 071 492 21 21, **Zürich** 044 295 37 77, **Lausanne** 021 216 61 61, **Tessin** 091 822 08 22. [www.swisscom-fixnet.ch/kmu](http://www.swisscom-fixnet.ch/kmu)

# Dank unserer persönlichen Beratung für KMUs kann Bruno Bondi noch effizienter arbeiten.

**swisscom** **fixnet**  
Einfach verbunden.