

Unscharfe Modellierung, Anpassung und Verdichtung von DGA-Interpretationsmethoden für eine präzisere Zustandsabschätzung

Fuzzy modelling, adjustment and merging of DGA's interpretation methods for a more accurate assessment of conditions

Dipl.-Ing. Markus Fischer, Prof. Dr.-Ing. Stefan Tenbohlen, Institut für Energieübertragung und Hochspannungstechnik, Stuttgart, Deutschland, markus.fischer@ieh.uni-stuttgart.de

Kurzfassung

Bei der Gas-in-Öl-Analyse werden verschiedene Interpretationsmethoden zur Zustandsabschätzung genutzt. Für deren Verbesserung stellt der Artikel drei Strategien vor. Die erste Strategie nutzt Fuzzy-Inferenz-Systeme und Zustandswahrscheinlichkeiten zur Modellierung der Interpretationsmethoden. Die Interpretationsmethoden können dadurch komplexe Leistungstransformatorzustände erkennen. Die zweite Strategie beschreibt die Anpassung unscharf modellierter Interpretationsmethoden mit Hilfe eines Trainings mit verifizierten Transformatorzuständen. Als Folge werden Genauigkeit und Zuverlässigkeit der Interpretationsmethoden erhöht. Die dritte Strategie beschreibt die Verdichtung der trainierten Interpretationsmethoden in einem Zustandsbaum, mit dessen Hilfe schließlich mehr Transformatorzustände als mit den einzelnen Methoden unterschieden werden können. Darüber hinaus wird die Genauigkeit und Zuverlässigkeit der Interpretationsmethoden weiter verbessert. Abschließend werden die erzielten Ergebnisse anhand eines Beispiels diskutiert.

Abstract

The dissolved gas analysis uses various interpretation methods for condition assessment. The paper presents three strategies to improve those methods: The first strategy uses fuzzy inference systems and condition probabilities in order to model the interpretation methods. The interpretation methods are therefore able to detect complex transformer conditions. The second strategy intends to adjust the fuzzy-modelled interpretation methods by training with verified transformer conditions. The interpretation methods thereby improve their accuracy and reliability. The third strategy merges the interpretation methods in a condition tree. As a result, more transformer conditions can be distinguished than by the single interpretation methods. Furthermore, the method's accuracy and reliability are further improved. The paper finally discusses the effectuated results by example.

1 Einleitung

Leistungstransformatoren sind unverzichtbare Bestandteile von Energieversorgungsnetzen. Der Ausfall eines Leistungstransformators kann hohe Instandsetzungskosten und gegebenenfalls eine unterbrochene Energieversorgung zur Folge haben. Um Leistungstransformatoren vor Ausfällen zu bewahren, sind verschiedene Inspektionstechniken in Entwicklung. Eine Inspektionstechnik, die sich bereits im Einsatz bewähren konnte, ist die Gas-in-Öl-Analyse (englisch: Dissolved Gas Analysis, kurz DGA).

Die DGA wiederum kennt zahlreiche Interpretationsmethoden zur Abschätzung des Leistungstransformatorzustandes. Dazu zählen beispielsweise „General Electric“, „Doernenburg Ratios“ und „Duval Triangle“ [1]. Allen Methoden gemeinsam sind zwei Nachteile: Erstens benutzen die Interpretationsmethoden zur Bestimmung des Transformatorzustandes Schwellwerte und zwar sowohl für die Schlüsselgase als auch für die Schlüsselgasverhältnisse. Dies kann zur Folge haben, dass ähnliche Schlüsselgasmuster oder Schlüsselgasverhältnismuster auf zwei unähnliche Transformatorzustände zurückgeführt werden. Zweitens berücksichtigen die meisten Interpretationsme-

thoden keine Fehler mit Mehrfachausprägung. Tatsächlich aber gibt es Fehler in Leistungstransformatoren, die sich etwa elektrisch und thermisch ausprägen [2]. In Abschnitt zwei werden Fuzzy-Inferenz-Systeme (FIS) eingeführt, die das Problem durch unscharfe Modellierung lösen.

Weiterhin ist die Zuverlässigkeit der Interpretationsmethoden zu verbessern. Interpretationsmethoden irren sich zum einen gelegentlich in der Art des Transformatorfehlers. Zum anderen werden Transformatoren, obwohl tatsächlich gesund, manchmal als fehlerhaft klassifiziert. Abschnitt drei führt ein Trainingsverfahren für FIS ein, das die Fehlentscheidungen der Interpretationsmethoden minimiert. Das Verfahren optimiert die Interpretationsmethoden mit Hilfe von verifizierten Normal- und Fehlerzuständen und verbessert so deren Zuverlässigkeit [3].

Abschließend ist festzustellen, dass Interpretationsmethoden den Fehlertyp unterschiedlich stark eingrenzen können. Während die einen relativ grob entscheiden (z.B. „Thermischer Fehler“ bei Doernenburg Ratios) sind andere präziser (z.B. „Thermischer Fehler hoher Temperatur“ bei General Electric). Die ermittelten Fehler sind also verwandt aber unterschiedlich exakt. Abschnitt vier präsentiert daher einen Entscheidungsbaum, der die Einzelergebnisse der Interpretationsmethoden zusammenführt.

2 Modellierung

Die Abschätzung von Leistungstransformatorzuständen auf Grundlage einer DGA lässt sich am besten mit der medizinischen Diagnostik vergleichen: Der Mediziner entnimmt dem Patienten eine Blutprobe, analysiert diese und schließt von den Analyseergebnissen auf den physischen Zustand des Patienten. Verglichen dazu werden bei der DGA Ölproben entnommen und diese auf gelöste Gase untersucht. Art und Menge der gelösten Gase lassen dann eine Abschätzung des Transformatorzustands zu (**Bild 1**).

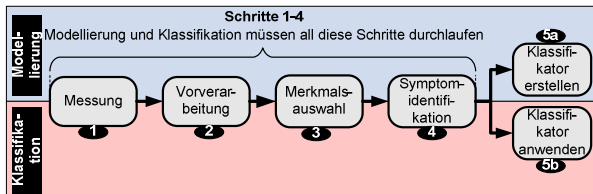


Bild 1 Fünf Schritte für Modellierung und Klassifikation.

Am Anfang der Interpretationskette stehen Probenahme und Gasanalyse (**Bild 1.1**), auf die der Artikel jedoch nicht weiter eingeht. Wenn etwa die Qualität der gemessenen Gaswerte verbessert werden muss, ist als nächstes eine Vorverarbeitung (**Bild 1.2**) notwendig. Ein Beispiel für eine Vorverarbeitung ist die Mittelwertbildung zur Reduktion zufälliger Fehler. Nach der Vorverarbeitung müssen die Gaswerte in den Merkmalsraum überführt werden (**Bild 1.3**). Dazu werden Gasverhältnisse berechnet und Schwellwerte für die Gaswerte und die Gasverhältnisse festgelegt. Unter den Merkmalen werden schließlich diejenigen ausgesucht, die symptomatisch für bestimmte Leistungstransformatorzustände sind. Bei diesen Merkmalen handelt es sich dann um Symptome (**Bild 1.4**). Im Gegensatz zur Medizin wird im Folgenden der Begriff Symptom nicht nur in Verbindung mit Fehlerzuständen, sondern auch in Verbindung mit einem gesunden oder undefinierten Zustand gebraucht. Die eigentliche Zuordnung zwischen Symptom und Leistungstransformatorzustand erfolgt durch so genannte Klassifikatoren (**Bild 1.5b**), die auf Grundlage bekannter Interpretationsmethoden wie beispielsweise „General Electric“, „Doernenburg Ratios“ oder „Duval Triangle“ modelliert werden (**Bild 1.5a**). Darüber hinaus sind Klassifikatoren viel versprechend, die mit unscharfer Logik und Wahrscheinlichkeiten operieren.

2.1 Unscharfe Klassifikatoren

Unscharfe Klassifikatoren werden mit FIS modelliert. FIS berücksichtigen Schwellwerte, vermeiden aber unstete Abbildungen bei Über- oder Unterschreiten der Schwellwerte wie das bei den konventionellen Verfahren der Fall ist. Die Abbildung ist also stetig und die Funktionswerte lassen sich als Zustandswahrscheinlichkeiten interpretieren. Der Artikel geht nicht näher auf die Funktionsweise von FIS ein. Auch die detaillierte Modellierung von Klassifikatoren mit FIS bleibt außen vor. Für einen Einstieg in die Grundlagen der FIS sei [4] und für die Grundlagen der Klassifikatormodellierung [5] empfohlen. Im weiteren Verlauf des Artikels soll aber gezeigt werden, wie man

von binären klassischen Klassifikatoren zu Klassifikatoren mit Zustandswahrscheinlichkeiten kommt.

Der originäre Klassifikator von General Electric bildet Symptome auf Basis von Schwellwerten exakt ab. **Bild 2** zeigt eine räumliche Darstellung des Klassifikators.

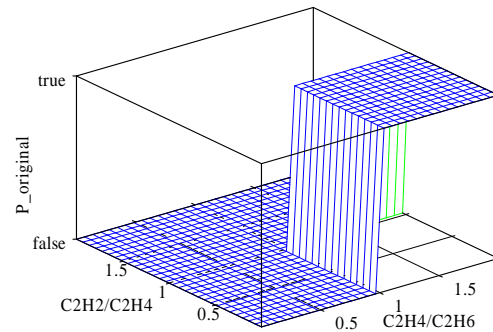


Bild 2 Ursprünglicher Klassifikator von General Electric, der Symptome exakt zuordnet.

Wie dem Bild zu entnehmen ist, wird die Symptommenge „ $C_2H_4/C_2H_6 > 1$ und $C_2H_2/C_2H_4 < 1$ “ dem Zustand „Thermischer Fehler hoher Temperatur“ zugeordnet (true), während die Symptome anderer Fehlerarten nicht zugeordnet werden (false). Setzt man FIS für die Modellierung von Klassifikatoren ein, können Symptome unscharf auf Transformatorzustände abgebildet werden. Mengentheoretisch gesehen sind Transformatorzustände unscharfe Mengen, deren Elemente (Symptome) bis zu einem gewissen Grad zugeordnet werden. Ein „wird zugeordnet“ oder „wird nicht zugeordnet“ gibt es nicht mehr (**Bild 3**).




Bild 3 Unscharfe Version des Klassifikators nach Bild 2.

Für die unscharfe Abbildung benötigt das FIS geeignete Zugehörigkeitsfunktionen. Die Wahl fiel auf Zugehörigkeitsfunktionen, die sich von der Kosinusfunktion ableiten, weil diese punktsymmetrisch sind und den gesamten Wertebereich zwischen 0 und 1 abdecken. Für den unscharfen Klassifikator von General Electric nach Bild 3 werden zwei dieser Zugehörigkeitsfunktionen benötigt. Eine dieser Zugehörigkeitsfunktionen ist durch **Gleichung 1** gegeben, die zweite Zugehörigkeitsfunktion ist komplementär dazu.

$$f(x) = \begin{cases} 1, & \text{for } x < 0.5 \\ (1 + \cos((x - 0.5) \cdot \pi)) / 2, & \text{for } 0.5 \leq x \leq 1.5 \\ 0, & \text{for } x > 1.5 \end{cases} \quad (1)$$

3 Training der Methoden

Unschärf abbildende Klassifikatoren identifizieren Transformatorzustände nicht notwendigerweise perfekt. Tatsächlich kann der wahre Transformatorzustand von dem Befund eines Klassifikators abweichen. Es ist Sache des Trainings, die Klassifikatoren, wo nötig, zu justieren. Für den Artikel wurden dafür Trainingsdaten aus der IEC TC 10 Datenbank verwendet. Der Inhalt der Datenbank ist aus [6] entnommen. Die Datenbank enthält Daten verschiedener Betriebsmittel. Ziel war es, die Klassifikatoren für Leistungstransformatoren mit offenem Lastschaltergefäß zu verbessern. Es wurden daher nur die entsprechenden Daten aus der Datenbank benutzt. Das Training für andere Betriebsmittel erfolgt mit den jeweiligen Daten analog. Insgesamt wurden 41 Daten für das Training herangezogen. **Tabelle 1** zeigt nur einen Auszug davon, um Platz zu sparen.

$\frac{C_2H_4}{C_2H_6}$	$\frac{C_2H_2}{C_2H_4}$	Nicht definiert, z.B. gesund	Elektr. Fehler	Therm. Fehler (niedriger Temp.)	Therm. Fehler (hoher Temp.)
1.00	0.10	90 %	0 %	0 %	0 %
2.34	0.06	90 %	0 %	0 %	0 %
0.77	0.30	90 %	0 %	0 %	0 %
...
12.64	0.04	0 %	0 %	0 %	100 %
6.05	0.03	0 %	0 %	0 %	100 %
2.81	0.00	0 %	0 %	0 %	100 %
...

Tabelle 1 Auszug der IEH TC 10 Datenbank aus [6].

Die Daten bestehen aus gemessenen Gaswerten und den durch Inspektion festgestellten Leistungstransformatorzuständen. Zeile 5-8 gibt einen Auszug für thermische Fehler hoher Temperatur wieder. Darüber hinaus beinhaltet die Datenbank gemessene Gaswerte, für die die Leistungstransformatoren in 90 % aller Fälle als gesund befunden wurden. Einen Auszug zeigen Zeile 1-3.

Wird der unscharfe Klassifikator mit den Daten aus **Tabelle 1** trainiert, verändert sich dessen Gestalt (**Bild 4**).




Bild 4 Trainierter unscharfer Klassifikator von Bild 3.

Aus dem Bild ist zu entnehmen, dass sich das Training in diesem Fall nur lokal ausgewirkt hat. Um die Auswirkungen des Trainings besser sichtbar zu machen, ist in **Bild 5** die Differenz zwischen dem trainierten unscharfen Klassifikator (Minuend) und dem untrainierten unscharfen Klassifikator (Subtrahend) gegeben.

fikator (Minuend) und dem untrainierten unscharfen Klassifikator (Subtrahend) gegeben.




Bild 5 Der Einfluss des Trainings auf den untrainierten Klassifikator.

In **Bild 5** sind zwei Bereiche, die augenscheinlich und auch tatsächlich vom Training betroffen sind:

1. $C_2H_4/C_2H_6 > 1$ und $C_2H_2/C_2H_4 < 1$: Die Wahrscheinlichkeit eines thermischen Fehlers hoher Temperatur ist merklich vermindert.
2. $C_2H_4/C_2H_6 < 1$ und $C_2H_2/C_2H_4 < 1$: Die Wahrscheinlichkeit eines thermischen Fehlers niedriger Temperatur ist leicht erhöht.

3.1 Trainingsalgorithmus

Der vorangegangene Abschnitt betrachtet das Training auf Anwenderebene. Um die Arbeitsweise des Trainings besser nachvollziehen zu können, ist ein Blick auf den Trainingsalgorithmus notwendig (**Bild 6**).

Zunächst muss man sich in Erinnerung rufen, dass Klassifikatoren mit FIS modelliert werden. Aus diesem Grunde muss der Trainingsalgorithmus auf die FIS-Struktur aufsetzen. Das Training kommt ursprünglich von den Künstlichen Neuronalen Netzen und nicht etwa von den FIS. Eine spezielle Art Künstlicher Neuronaler Netze sind die so genannten Radialen Basisfunktionen Netze. Sie sind funktionell äquivalent zu den FIS nach Sugeno [7]. Es sollte also möglich sein, die Trainingseigenschaft wenigstens in diesem Fall von den Künstlichen Neuronalen Netzen auf FIS zu übertragen

Es ist weiterhin zu beachten, dass FIS die Zuordnung zwischen einem Symptom und einem Zustand mit Hilfe genau einer Produktionsregel vollzieht. Jede Produktionsregel ist mit einem Faktor im Bereich [0, 1] gewichtet, um deren Zuverlässigkeit relativ zu den anderen Regeln berücksichtigen zu können. Um zwischen einer Produktionsregel und der äquivalent Menge an Trainingsdaten wechseln zu können, ist ein Vertrauensfaktor notwendig. Jener Vertrauensfaktor ist nicht in der FIS-Struktur repräsentiert und kann folglich nur extern gespeichert werden.

In Zeile 1 des Trainingsalgorithmus werden zunächst das FIS, der Vertrauensfaktor und schließlich die Trainingsdaten geladen. Alle Regelgewichte sind anfangs auf 1 gesetzt. Das bedeutet, dass alle Regeln als gleich zuverlässig angesehen werden. Der Vertrauensfaktor ist zu Anfang auf 100 gesetzt. Dies bedeutet, dass die zuverlässigste Regel

mit 100 Trainingsdaten gleichzusetzen ist. In den nachfolgenden Zeilen 2-4 wird die Normalisierung der Regelgewichte aufgehoben. Dann wird in den Zeilen 5-13 für jedes Trainingsdatum analysiert, welche Regel modifiziert werden muss. Schlussfolgerung und Gewicht der identifizierten Regeln werden angepasst. Die neue Schlussfolgerung ist definiert als der gewichtete Mittelwert aus der alten Schlussfolgerung und der Aussage des Trainingsdatums. Das neue Regelgewicht ist definiert als das um 1 erhöhte alte Regelgewicht. In Zeile 14-17 wird der neue Vertrauensfaktor berechnet. Die Regelgewichte werden in den Zeilen 18-20 wieder normalisiert. Abschließend werden in Zeile 21 das modifizierte FIS und der neu berechnete Vertrauensfaktor gespeichert.

```

01 load fis, trustFactor, trainingVectors
02 for each r of fis.rules {
03   r.weight = r.weight * trustFactor
04 }
05 for each t of trainingVectors {
06   for each r of fis.rules {
07     if r.premise(t.C2H2DivByC2H6, t.C2H2DivByC2H4) > 0,5 {
08       r.conclusion = (r.conclusion * r.weight +
09         t.thermalFaultLowTemperature) / (r.weight + 1)
10       r.weight = r.weight + 1
11     }
12   }
13 }
14 trustFactor = 0
15 for each r of fis.rules {
16   trustFactor = maximum(trustFactor, r.weight)
17 }
18 for each r of fis.rules {
19   r.weight = r.weight / trustFactor
20 }
21 save fis, trustFactor

```

Bild 6 Trainingsalgorithmus in Pseudocode.

Zusammenfassend ist zu sagen, dass der Trainingsalgorithmus den gewichteten Mittelwert nutzt, um das FIS mit Hilfe der Trainingsdaten anzupassen. Die relative Zuverlässigkeit einer Regel ist durch ihr Gewicht gegeben. Der Vertrauensfaktor ist notwendig, um Regeln und Trainingsdaten miteinander vergleichen zu können.

3.2 Regression und Erwartungswert

Im vorangehenden Abschnitt wurde für das Training der gewichtete Mittelwert benutzt. Noch immer unbeantwortet ist aber die Frage, ob der Ansatz sinnvoll ist oder nicht.

Das Training von unscharfen Klassifikatoren ist tatsächlich verwandt mit der Ausgleichsrechnung. Im Kontext der Statistik wird die Ausgleichsrechnung Regressionsanalyse genannt. Das Ziel der Regressionsanalyse ist es, eine gegebene parametrisierte Funktion an gegebene Datenpunkte anzupassen. Typische parametrisierte Funktionen sind polynominal wie in **Gleichung 2**. Bei Gleichung 2 handelt es sich um eine Funktion mit zwei Variablen, x_1 und x_2 , die in der Lage ist, zweistellige Datenpunkte durch eine Fläche anzunähern.

$$f_1(x_1, x_2) = a_0 + b_1x_1 + b_2x_2 + c_1x_1^2 + c_2x_2^2 + \dots \quad (2)$$

Es gibt zwei grundsätzliche Möglichkeiten, um die Fläche eines Klassifikators zu justieren: Entweder versucht man

es im Ganzen mit globaler oder Schritt für Schritt mit lokaler Regression. Die Wahl fiel auf die lokale Regression, weil FIS auf lokal arbeitenden Produktionsregeln beruhen und die Absicht des Trainings darin besteht, diese Produktionsregeln zu justieren. Darüber hinaus ist es nicht das Ziel, die Form der verwendeten Zugehörigkeitsfunktionen zu verändern. Ausschließlich Niveaus sind von Interesse. Aus diesem Grund ist Gleichung 2 auf **Gleichung 3** zu reduzieren.

$$f_1'(x_1, x_2) = a_0 \quad (3)$$

Mit der Regressionsanalyse wird das Ziel verfolgt, die undefinierten Parameter der parametrisierten Funktion zu bestimmen. Im Falle von Gleichung 3 handelt es sich nur um Parameter a_0 . Für die Parameterbestimmung wird in der Regressionsanalyse oft die Methode der kleinsten Fehlerquadrate verwendet (**Gleichung 4**).

$$f_2(a_0) = (p_1 - a_0)^2 + (p_2 - a_0)^2 + \dots + (p_n - a_0)^2 \quad (4)$$

Die Methode der kleinsten Fehlerquadrate leitet sich von der euklidischen Norm ab, welche unter allen Normen die größte Anschauung bietet. Für die Identifikation von a_0 muss Gleichung 4 zunächst differenziert, die Ableitung dann zu Null gesetzt und abschließend nach a_0 aufgelöst werden. Das Ergebnis ist durch **Gleichung 5** gegeben.

$$a_0 = \frac{p_1 + p_2 + \dots + p_n}{n} = \frac{\overbrace{(n-1) \cdot p}^{p=p_1=p_2=\dots=p_{n-1}} + p_n}{n} \quad (5)$$

Im ersten Teil der Gleichung 5 wird a_0 als das arithmetische Mittel aller p_i definiert. Das arithmetische Mittel wiederum ist eine Schätzfunktion für den Erwartungswert $E(P)$. P ist die Zufallsvariable der Aussagen aller Trainingsdaten p_i , wobei p_i entweder „Thermischer Fehler hoher Temperatur“ oder nicht „Thermischer Fehler hoher Temperatur“ annehmen kann. Das Gesetz der großen Zahl sagt nun: Je mehr aussagekräftige Trainingsdaten verwendet werden, desto besser ist die Schätzung des Erwartungswertes. Im zweiten Teil der Gleichung 5 wird a_0 als das gewichtete arithmetische Mittel definiert. Teil 1 und 2 sind äquivalent, wenn $p=p_1=p_2=\dots=p_{n-1}$ gilt. Die Definition aus Teil 2 wurde in den Zeilen 8-9 des Trainingsalgorithmus (Bild 6) verwendet, um iterativ die neue Schlussfolgerung einer Produktionsregel zu berechnen.

4 Verschmelzung der Methoden in einem Zustandsbaum

In den Abschnitten zuvor wurde erklärt, wie man Klassifikatoren einzelner Interpretationsmethoden verbessert. So verbesserte Klassifikatoren können dann in den jeweiligen Interpretationsmethoden eingesetzt werden, um die von den Interpretationsmethoden bekannten Transformatorzustände mit Wahrscheinlichkeiten zu belegen. Unter allen Transformatorzuständen gibt es solche, die von allen Interpretationsmethoden, und andere, die nur von wenigen berücksichtigt werden. Nachfolgend soll gezeigt werden,

wie Interpretationsmethoden zusammenarbeiten können, um gemeinsam mehr Transformatorzustände und diese mit einer erhöhten Zuverlässigkeit identifizieren zu können. Zunächst benötigt jeder Klassifikator einen eigenen Entscheidungsbaum. Der Entscheidungsbaum von General Electric zum Beispiel ist in **Bild 7** zu sehen. Es handelt sich um einen hierarchischen Entscheidungsbaum, dessen Knoten zweierlei beinhalten: Erstens die geschätzte Wahrscheinlichkeit (P) für den jeweiligen Transformatorzustand und zweitens die Zuverlässigkeit (R) dieser Schätzung. Unter allen Transformatorzuständen kennt General Electric nur „nicht definiert“, „elektrischer Fehler“, „hohe Temperatur“ und „niedrige Temperatur“. Die Wahrscheinlichkeiten dieser Zustände werden mit Hilfe von Klassifikatoren bestimmt und die Zuverlässigkeit der Schätzung ist als das Produkt des größten Regelgewichts und des Vertrauensfaktors gegeben. Für alle übrigen Knoten muss die Wahrscheinlichkeit und Zuverlässigkeit berechnet werden.




Bild 7 Zustandsbaum von General Electric

Die Zuverlässigkeit (R) eines Knoten ist definiert als die Zuverlässigkeit des Nachfolgeknotens ($Succ_i$) mit der größten Wahrscheinlichkeit (Max_p) (**Gleichung 6**). Während die Wahrscheinlichkeit eines Knotens als die größte Wahrscheinlichkeit aller Nachfolgeknoten definiert ist (**Gleichung 7**). Der Algorithmus, der die Wahrscheinlichkeiten und die Zuverlässigkeiten berechnet, arbeitet „bottom up“. Das heißt, er beginnt seine Berechnungen mit den untersten Knoten und endet mit dem Wurzelknoten.

$$R(node) = R(Max_p(Succ_1(node), \dots, Succ_n(node))) \quad (6)$$

$$P(node) = P(Max_p(Succ_1(node), \dots, Succ_n(node))) \quad (7)$$

Um zu zeigen, wie Interpretationsmethoden vereint werden können, ist neben General Electric mindestens noch ein weiteres Interpretationsverfahren von Nöten. Die Wahl fiel auf Doernenburg Ratios, um Platz zu sparen, denn dessen Entscheidungsbaum (**Bild 8**) ist ähnlich kompakt wie der von General Electric (**Bild 7**). Doernenburg Ratios kennt unter allen Transformatorzuständen nur „nicht definiert“, „Teilentladung“, „Entladung“ und „thermisch“. Erneut müssen alle übrigen Knoten, wie bereits für General Electric beschrieben, berechnet werden.

Der gesamte Entscheidungsbaum ist in **Bild 9** zu sehen. Er beinhaltet die Knoten der Elternbäume General Electric und Doernenburg Ratios. Während „Teilentladung“ und „Entladung“ bzw. „hohe Temperatur“ und „niedrige Temperatur“ nur von einem Elternbaum bereitgestellt werden,

werden alle anderen Knoten durch beide Elternbäume zur Verfügung gestellt.




Bild 8 Zustandsbaum von Doernenburg Ratios




Bild 9 Gesamter Entscheidungsbaum mit allen Knoten der Elternbäume.

Für den gesamten Entscheidungsbaum ist die Zuverlässigkeit (R) jedes Knoten gegeben als die Summe der Zuverlässigkeiten der korrespondierenden Elternknoten (Par_i) (**Gleichung 8**). Hingegen ist die Wahrscheinlichkeit jedes Knotens gegeben als die gewichteten Wahrscheinlichkeiten der korrespondierenden Elternknoten (**Gleichung 9**).

$$R(node) = R(Par_1(node)) + \dots + R(Par_m(node)) \quad (8)$$

$$P(node) = \frac{R(Par_1(node)) \cdot P(Par_1(node)) + \dots}{R(Par_1(node)) + \dots + R(Par_m(node))} \quad (9)$$

5 Anwendung der neuen Methode

Die Leistungsfähigkeit der beschriebenen Strategien ist nun am Beispiel eines defekten 385MVA Maschinentransformators zu zeigen. Die Ausfallursache wurde zweifelsfrei durch eine Inspektion als Teilleiterbruch identifiziert. Der Teilleiterbruch zeigte als Ausprägung einen Heißpunkt und Teilentladungen. Außerdem war Zelluloseisolation mit involviert. Mit Hilfe einer DGA konnten folgende Konzentrationen gelöster Gase in ppm festgestellt werden: Wasserstoff (300), Methan (1740), Ethin (<1), Ethen (3500) und Ethan (1190). Zunächst wurden die Gaswerte durch die konventionellen Klassifikatoren von General Electric und Doernenburg Ratios ausgewertet, anschließend auch durch die trainierten unscharfen Klassifikatoren, die über den Zustandsbaum verknüpft sind (**Bild 10**).

Der originale Klassifikator von General Electric behauptet, es wäre ein thermischer Fehler mit hoher Temperatur. Doernenburg Ratios wiederum kann nur einen thermischen

Fehler unbestimmter Temperatur identifizieren. Beide Klassifikatoren sind demnach nur in der Lage, den thermischen Anteil (Heißpunkt) der tatsächlichen komplexen Fehlerausprägung (Heißpunkt, Teilentladung, Zellulosedegradation) zu erkennen. Der in Bild 10 gezeigte Entscheidungsbaum zeigt ein differenzierteres Zustandsbild. In der ersten Ebenen, direkt nach dem Wurzelknoten, wird ein Fehler (P=64%) als wahrscheinlichster Zustand angesehen. Wobei auch die Möglichkeit eines undefinierten Zustandes (P=31%) besteht. Ebene zwei kann den Fehler weiter präzisieren. Er zeigt sich am stärksten als thermischer Fehler (P=64%), wobei auch ein schwächerer elektrischer Anteil (P=10%) vorhanden ist. Auf der dritten Ebenen zeigt sich der thermische Fehler zu P=1% als thermischer Fehler mit hoher Temperatur und zu P=55% als thermischer Fehler mit hoher Temperatur. Der elektrische Fehler kann nicht weiter präzisiert werden. Zusammenfassen lässt sich sagen, dass sich im Zustandsbaum der Zustand des Maschinentransformators als Fehler mit dominanter thermischer Ausprägung zeigt, allerdings ist auch ein weniger dominante elektrische Ausprägung sichtbar. Über die Beteiligung von Zellulose kann keine Aussage getroffen werden, weil sie im Zustandsbaum nicht repräsentiert wurde.

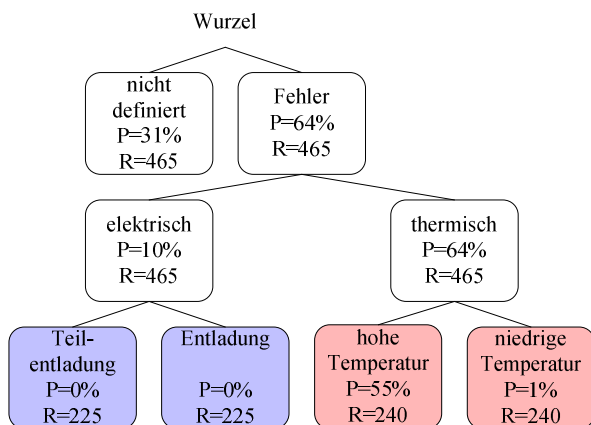


Bild 10 Gesamter Entscheidungsbaum mit Wahrscheinlichkeit und Zuverlässigkeit je Knoten.

Darüber hinaus werden die Schätzungen der Zustandswahrscheinlichkeiten durch eine Zuverlässigkeit R bewertet, die sich aus der Menge der Trainingsdaten ergibt, die für die Schätzung der Zustandswahrscheinlichkeiten herangezogen werden. Während die detaillierten Zustände auf der dritten Ebene nur durch jeweils einen Elternbaum bestimmt werden (geringere Zuverlässigkeit) werden die eher allgemeinen Zustände der zweiten und dritten Ebene durch beide Elternbäume bestimmt (hohe Zuverlässigkeit). Zusammenfassend ist zu sagen, je detaillierter Zustände bestimmt werden, desto weniger zuverlässig ist das Ergebnis und umgekehrt.

6 Schlussfolgerungen

Als erstes wurde die Strategie der unscharfen Modellierung angewandt und dadurch verhindert, dass bei ähnlichen Gaswerten unähnliche Zustände identifiziert werden. Durch den Einsatz von Zustandswahrscheinlichkeiten an-

stelle von Schwellwerten wurde die Identifikation komplexer Fehler ermöglicht.

Zweitens wurde eine Anpassungsstrategie eingeführt. Ein Trainingsverfahren bewirkt, dass sich die Genauigkeit und Zuverlässigkeit der Klassifikatoren verbessert. Das Training erfolgt durch die Berechnung des arithmetischen Mittelwerts. Bewiesener Maßen nähert sich ein Klassifikator umso besser an den idealen Erwartungswert-Klassifikator an, je mehr repräsentative Trainingsdaten zur Verfügung stehen. Allerdings ist das Training mit dem arithmetischen Mittel anfällig für Ausreißer in den Trainingsdaten. Ein viel versprechender Ansatz könnte daher sein, ein Median-Trainingsalgorithmus zu implementieren, der weniger empfindlich für Trainingsdatenausreißer ist, aber sich dennoch eignet, einen Klassifikator an den Erwartungswert-Klassifikator anzunähern.

Die letzte Strategie kombinierte die trainierten Klassifikatoren, um die Zahl der identifizierbaren Zustände zu maximieren und gleichzeitig die Genauigkeit und Zuverlässigkeit der Zustandsabschätzung zu erhöhen. Zustände sind hierarchisch entsprechend ihrem Detailgrad geordnet. Je spezifischer der Zustand, desto weniger zuverlässig ist die Schätzung seiner Auftretenswahrscheinlichkeit und umgekehrt. Es ist also die Entscheidung des Anwenders überlassen, ob er Details oder Zuverlässigkeit bevorzugt.

7 Literatur

- [1] J.-P. Gibeault, "Tutorial: On-line monitoring of key fault gases in transformer oil – operational experiences accumulated over the years", 10th ISH, Montréal, Canada, August, 1997
- [2] J. Aragón-Patil, M. Fischer and S. Tenbohlen, "Improvement of dissolved gas analyses (DGA) by means of experimental investigation of generated fault gases and a fuzzy logic based interpretation scheme", 15th ISH, Ljubljana, Slovenia, August 27-31, 2007, Proceedings of the ISH, paper No. T7-157
- [3] J. Aragón-Patil, M. Fischer, S. Tenbohlen; Z. D. Wang and M. Schäfer, "Investigation on Sampling, Measurement and Interpretation of Gas-in-Oil Analysis for Power Transformers", CIGRE Session 2008, Paper D1-204, Paris, France.
- [4] T. Terano, K. Asai, M. Sugeno, "Fuzzy Systems Theory and its Applications", Academic Press, San Diego, USA, 1992
- [5] J. Aragón-Patil, M. Fischer, S. Tenbohlen, "Improvement of interpretation of dissolved gas analysis for power transformers", 3rd APTADM, Wrocław, Poland, September 26-28, 2007, page No. 91-97
- [6] M. Duval, A. dePablo, "Interpretation of Gas-In-Oil Analysis Using New IEC Publication 60599 and IEC TC 10 Databases", IEEE Electrical Insulation Magazine, Vol. 17, Issue 2, Mar./Apr. 2001, pp. 34-37
- [7] H. C. Anderson, A. Lotfi, L. C. Westphal, "Comments on 'Functional Equivalence Between Radial Basis Function Networks and Fuzzy Inference Systems'", IEEE Transactions on Neural Networks, Vol. 9, No. 6, Nov. 1998, pp. 1529-1531