

# Untersuchung über Ansätze zur intelligenten Auswertung von Netzqualitätsmessungen

## Investigation on intelligent assessment of power quality measurements

Dr. Juan Velásquez, Hubert Göbel GmbH, 59199 Bönen, Deutschland, [j.velasquez@hgmes.de](mailto:j.velasquez@hgmes.de)

M.Eng., Ning Liu, Hubert Göbel GmbH, 59199 Bönen, Deutschland, [n.liu@hgmes.de](mailto:n.liu@hgmes.de)

### Kurzfassung

Im Rahmen einer Überwachung der Netzqualität wird eine sehr hohe Anzahl von Daten gesammelt, die in seltenen Fällen ausgewertet werden. Bei den meisten Überwachungssystemen wird hauptsächlich geprüft, ob die gemessenen Oberschwingungen voreingestellte Schwellenwerte (bzw. Grenzwerte) überschreiten. Es werden jedoch keine Verhaltensmuster oder dynamische Veränderungen der Netzqualitätssituation bewertet. Dieser Beitrag schlägt einen Ansatz vor, der zur intelligenten Auswertung der Messdaten von Oberschwingungen verwendet werden könnte. Der vorgeschlagene Ansatz wird durch echte Messdaten illustriert. Die vorläufigen Ergebnisse dieser Untersuchungen haben gezeigt, dass anhand von Entscheidungsbäumen die Möglichkeit besteht, ein Muster zu extrahieren, unter dem die Oberschwingungssituation eines Netzes bewertet werden kann.

### Abstract

Monitoring systems of power quality record and store a huge amount of data, which usually is assessed in a very limited way. Most of the monitoring systems carried out an assessment of data based on certain limits, which shall not be exceeded. An analysis of the patterns of the power quality situation of the network is however not common. This contribution proposes an approach for an intelligent assessment of data of harmonic measurements. The use of the proposed approach is illustrated with real data of a monitoring system. The preliminary results of the research have shown that the decision tree approach proposed in this work allows extracting a behaviour pattern for the harmonics under which an intelligent monitoring of harmonics can be carried out.

## 1 Einleitung

Zur Sicherstellung der Einhaltung der Netzqualität in der Energieversorgung werden immer mehr Überwachungssysteme zur permanenten Überwachung der Netzqualität installiert. Die kommerziell verfügbaren Netzqualitätsmessgeräte ermöglichen in der Regel eine umfangreiche Überwachung verschiedener Netzqualitätsmerkmale (z.B. Oberschwingungen, Zwischenharmonische, Flicker, etc.). Besonderes Augenmerk wird auf das Verhalten von Oberschwingungen (OS) gelegt, weil diese negativen Rückwirkungen sowohl auf den stabilen Betrieb von Anlagen (z.B. durch Beeinflussung des Regelungssystems von leistungselektronischen Anlagen) als auch auf die Betriebsmittel (z.B. thermische Belastung) haben können [1], [2].

Die zunehmende Marktdurchdringung der erneuerbaren Energien steht i.d.R. in direktem Zusammenhang mit einer zunehmenden Anzahl von leistungselektronischen Anlagen im Netz. Demensprechend ist mit einer kontinuierlichen Veränderung der Oberschwingungssituation im Netz zu rechnen. Aus dem Blickwinkel des Betreibers einer Anlage (z.B. eine Windkraftanlage) stellen diese steti-

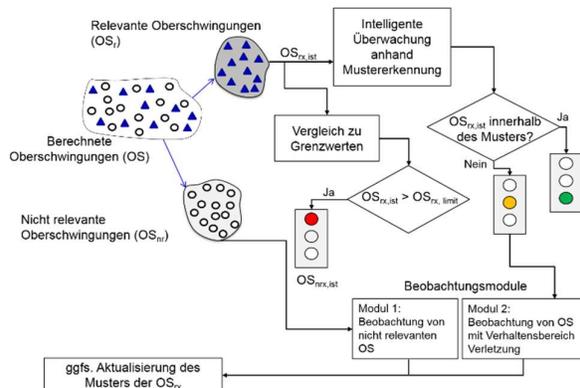
gen Veränderungen der Netzqualitätssituation eine Herausforderung dar. Einerseits führen diese Veränderungen zu der Notwendigkeit einer permanenten Überwachung der Netzqualität. Andererseits wird im Rahmen einer Überwachung eine sehr hohe Anzahl von Daten gesammelt, die in seltenen Fällen ausgewertet werden [3]. Bei den meisten Überwachungssystemen wird hauptsächlich geprüft, ob die gemessenen Oberschwingungen voreingestellte Schwellenwerte bzw. Grenzwerte überschreiten [4]. Es werden jedoch keine Verhaltensmuster oder dynamische Veränderungen der Netzqualitätssituation bewertet. Die Konsequenz ist, dass Netzqualitätsprobleme erst erkannt werden, wenn diese bereits einen Grenzwert überschritten haben. Angesichts der Tatsache, dass sich aus den Daten eines Überwachungssystems Veränderungen der Netzqualitätssituation nachverfolgen lassen, ist es denkbar anhand einer intelligenten Auswertung der Daten (statistische Auswertung, Analyse von Tendenzen, Mustererkennung, etc.) die Aussagekraft eines Netzqualitätsüberwachungssystems zu verbessern. Um die Gültigkeit dieser Hypothese verifizieren zu können, wurde eine Untersuchung über den Ansatz von Mustererkennungsalgorithmen zur Auswertung der Messdaten von Überwachungssystemen durchgeführt. Dieser Beitrag beschreibt die Methodologie und illustriert deren Anwendung anhand echten Messdaten.

## 2 Ansatz zur intelligenten Überwachung von Oberschwingungen

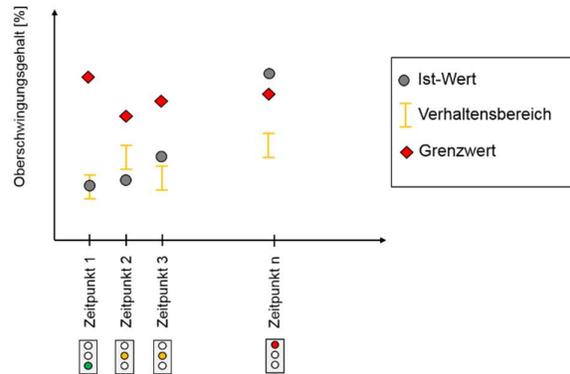
### 2.1 Allgemeines

Das Bild 1 zeigt ein Ablaufdiagramm des vorgeschlagenen Ansatzes. Bei diesem Ansatz werden erst die aus den Daten berechneten OS in zwei Gruppen unterteilt. Die erste Gruppe (Dreiecke im Bild 1) beinhaltet die relevanten Oberschwingungen ( $OS_r$ ).  $OS_r$  sind die Oberschwingungen, die gemäß Messdaten eine erwähnenswerte Aktivität aufweisen (z.B. OS, deren Betrag höher als 0,1 % beträgt). Zur zweiten Gruppe (Kreise) sind die nicht relevanten OS ( $OS_{nr}$ ) zugeordnet. Im Gegensatz zu  $OS_r$  handelt es sich bei  $OS_{nr}$  um OS, deren Aktivität vernachlässigbar ist.

Die  $OS_r$  werden einerseits mit den Grenzwerten des Netzbetreibers verglichen. Bei Überschreitung der Grenzwerte wird eine Warnung in Form einer Ampel mit rotem Licht ermittelt. Andererseits werden die  $OS_r$  mittels eines Mustererkennungsalgorithmus bewertet. Bei der Bewertung wird geprüft, ob sich die Istwerte innerhalb eines Verhaltensmuster im Form eines Verhaltensbereichs befinden. Diese Überprüfung ist schematisch in Bild 2 dargestellt. Sollten die Istwerte der Oberschwingung „x“ ( $OS_{rx,ist}$ ) die Verhaltensbereiche, die vom Mustererkennungsalgorithmus vorgegeben sind, verletzen (siehe orangene Balken im Bild 2), wird eine Warnung in Form einer Ampel mit gelbem Licht ermittelt. Fallen die Istwerte zum Zeitpunkt „t“ innerhalb des Verhaltensbereichs, wird keine Warnung ermittelt. Die ermittelten Warnungen (entweder durch Verletzung der Grenzwerte oder durch Verletzung der Verhaltensbereiche) werden durch den Beobachtungsalgorithmus weiter bewertet. Das Modul 1 des Beobachtungsalgorithmus prüft, ob die Oberschwingungssituation des Netzes eine Musteränderung aufweist (z.B. aufgrund der Zuschaltung einer großen leistungselektronischen Anlage in der Umgebung), oder ob es sich um Einzelereignisse handelt. Es ist darauf zu achten, dass die Istwerte der nicht relevanten OS ( $OS_{nr,ist}$ ) stets durch das Modul 2 des Beobachtungsalgorithmus kontrolliert werden.



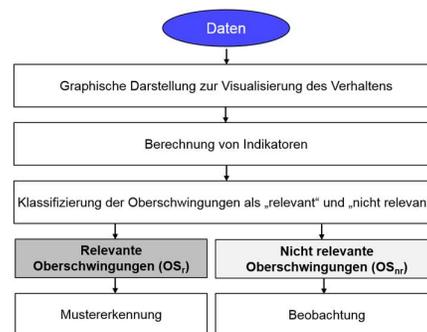
**Bild 1** Ablaufdiagramm des vorgeschlagenen Ansatzes zur intelligenten Überwachung von Oberschwingungen



**Bild 2** Schematische Darstellung der Bewertung der Ist-Werte gegenüber Grenzwerten und den Verhaltensbereichen, die aus dem Mustererkennungsalgorithmus resultieren

### 2.2 Klassifizierung der Oberschwingungen als „relevant“ und „nicht relevant“

Wie im Bild 1 dargestellt, muss im ersten Schritt zwischen relevanten und nicht relevanten Oberschwingungen unterschieden werden. Diese Klassifizierung hat das Ziel, dass nur die OS, die eine erwähnenswerte Aktivität aufweisen, anhand eines Mustererkennungsalgorithmus bewertet werden. Das Bild 3 zeigt die Abläufe zur Klassifizierung der Oberschwingungen. Die Daten werden erst graphisch dargestellt. Anschließend werden Indikatoren (z.B. Maximalwerte, Minimalwerte, Mittelwerte, etc.) berechnet. Es gibt verschiedene Kriterien, die für die Unterscheidung zwischen „relevant“ und „nicht relevant“ zugrunde gelegt werden können. Ein pragmatisches Kriterium wäre z.B. alle OS, die unter einem bestimmten Pegel (z.B. 0,08 %) liegen, als „nicht relevant“ zu klassifizieren. Nur die OS, die als „relevant“ klassifiziert werden, werden durch einen Mustererkennungsalgorithmus bewertet. Die nicht relevanten OS werden durch einen Beobachtungsalgorithmus bewertet, die wie bereits in Kapitel 2.1 erläutert, die Erzeugung bzw. Aktualisierung des Verhaltensmusters triggert. Durch diese Logik wird gewährleistet, dass das System stetig mögliche neue Muster lernt, unter denen die OS-Situation zuverlässig bewertet werden kann.



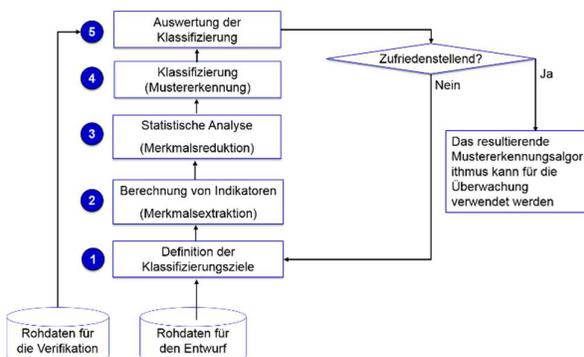
**Bild 3** Abläufe für die Klassifizierung von Oberschwingungen als „relevant“ und als „nicht relevant“

### 2.3 Vorgehensweise für den Entwurf von Mustererkennungsalgorithmen

Eine allgemeine Vorgehensweise für den Entwurf von Mustererkennungsmodellen kann dem Bild 4 entnommen werden. Ziel der Mustererkennung (ME) ist, in einer Menge von Daten Regelmäßigkeiten, Wiederholungen, Ähnlichkeiten oder Gesetzmäßigkeiten zu erkennen. Für die Auslegung des ME-Modells werden Datensätze vorbereitet, die alle für den Entwurf des Modells notwendigen Daten beinhaltet. Eine typische Struktur eines Datensatzes ist in der Tabelle 1 dargestellt. Der Datensatz besteht aus „n“ Instanzen. Jede Instanz beinhaltet Attribute und Klassen. Die Attribute sind Informationen (entweder Messdaten oder berechnete Indikatoren), die im Zusammenhang mit dem, was klassifiziert werden soll (Klassen) stehen.

Die Klassifizierungsziele entsprechen den sogenannten Klassen. Beispiele von Klassen sind: auffällige OS, unauffällige OS, OS im Bereich von 0,2 % bis 0,3 %, OS im Bereich von 0,5 % bis 0,6%, etc. Aus den Rohdaten werden Indikatoren berechnet, unter denen eine Merkmalsextraktion erfolgen kann. Beispiele von Indikatoren sind Maximalwerte und Minimalwerte des OS-Betrages. Anhand einer analytischen Analyse der Daten können Zusammenhänge zwischen Daten bewertet werden. Das ermöglicht einerseits die Identifizierung von potenziellen Eingangsattributen des Modelles und andererseits eine potenzielle Merkmalsreduktion durchzuführen. Zusätzlich dazu könnten z.B. durch die Berechnung von Mittelwerten die 10-minütigen Daten der OS-Messung eines Tages auf stündige Werte reduziert werden.

Nach Auswahl der Eingangsattribute erfolgt die Klassifizierung. Es gibt viele verschiedene Algorithmen bzw. Klassifikationsverfahren, die für Mustererkennung eingesetzt werden können. Vier wesentliche Klassifikationsverfahren bei der Klassifikation sind Entscheidungsbaum, Neuronale Netze, die Bayes-Klassifikation und das Nächste-Nachbarn-Verfahren. Als Mustererkennungsalgorithmus wurden Entscheidungsbaum vorgeschlagen, weil die von Entscheidungsbäumen ermittelten Regeln einfach interpretiert werden können.



**Bild 4** Methodologie für den Entwurf eines Algorithmus zur Mustererkennung

**Tabelle 1** Typische Topologie eines Datensatzes für den Entwurf eines Mustererkennungsmodells

Instanz	Attribute 1	Attribute n	Klasse
1	xx	yy	A
.	xx	yy	B
.			
.			
n	xx	yy	N

#### 2.3.1 Berechnung von Indikatoren und Auswahl der Eingangsattribute

Indikatoren oder Eingangsattribute werden als Merkmale definiert, die die Klassen (in diesem Fall OS) gut beschreiben. Die Indikatoren könnten auch als betriebsrelevante Informationen definiert werden, die zur Veränderung der OS-Situation führen. Die Indikatoren könnten entweder eine physikalische Größe sein (wie z.B. Strom oder Spannung), ein Zeitpunkt (Tag des Jahres und Uhrzeit) oder berechnete Werte (z.B. ein Maximalwert, ein Minimalwert, ein Mittelwert, Änderungsraten, Standardabweichung, etc.). Diese könnten auch binäre Signale sein, die den Status des Schaltzustandes des Netzes beschreiben. Die Nutzung von zeitbasierten Indikatoren ist hauptsächlich sinnvoll, wenn die Zeitverläufe des Signals der OS Periodizität aufweisen. Da i.d.R. die OS-Situation im Zusammenhang mit der Lastsituation bzw. mit dem Energieverbrauch eines Netzes steht, sind zeitbasierte Indikatoren (Tag des Jahres und Uhrzeit) mögliche, gute Eingangsattribute

Es ist bekannt, dass sich der Betrag der Grundschwingung des Stroms und der Spannung im Laufe eines Tages je nach Verbrauch, ändert. Daher könnte intuitiverweise spekuliert werden, dass die Änderungen der Grundschwingungen sowohl vom Strom als auch von der Spannung gute Indikatoren sein könnten.

Änderungsraten der Oberschwingungsaktivität können auch als potenzielle gute Indikatoren eingestuft werden. Ziel ist es, eine frühzeitige Erkennung einer relevanten Änderung der Oberschwingungssituation zu ermöglichen. Folgende Indikatoren können eingesetzt werden: 10-minütige Änderungsrate der relevanten Harmonischen, 1-stündige Änderungsrate der relevanten Harmonischen oder 12-stündige Änderungsrate der relevanten Harmonischen.

Ein weiterer Indikator, der in Betracht gezogen werden kann ist die Berechnung einer harmonischen Impedanz. Dafür muss der Betrag und Phasenwinkel von Strom und Spannung gemessen werden. Aus diesen Daten lässt sich der reale Anteil und der imaginäre Anteil der Impedanz berechnen.

#### 2.3.2 Statistische Analyse

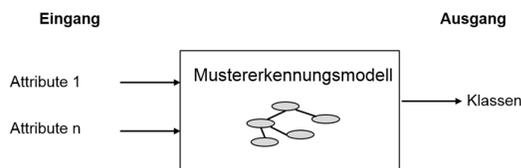
Eine Kernaufgabe der statistischen Analyse ist die Korrelationsuntersuchung. Verschiedene Korrelationskoeffizienten (KK) werden berechnet. Hier ein paar Beispiele:

Korrelation zwischen den Harmonischen und dem Aufzeichnungszeitpunkt, Korrelation zwischen relevanten Harmonischen untereinander, Korrelation zwischen Harmonischen und Zwischenharmonischen, Korrelation zwischen relevanten Harmonischen und der Grundschiwung der Spannung, Korrelation zwischen relevanten Harmonischen und der Grundschiwung des Stroms, Korrelation zwischen Harmonischen der Spannung und Harmonischen des Stroms.

Aus dem Ergebnis der Korrelationsuntersuchung werden die Attribute für den Entwurf des ME-Modells ausgewählt.

### 2.3.3 Klassifizierung

Bei der topologischen Auslegung eines Klassifizierungsmodells gibt es unzählige Möglichkeiten. Vor allem die optimale Anzahl und Auswahl von Attributen ist nicht immer eine triviale Aufgabe. Der Einfachheit halber wird empfohlen so wenige Eingangsattribute wie möglich zu verwenden. Aus der statistischen Untersuchung werden Kandidaten ausgewählt. Die allgemeine Topologie eines Modells wird im Bild 5 dargestellt.



**Bild 5** Allgemeine Topologie eines Mustererkennungsalgorithmus

### 2.3.4 Auswertung der Klassifizierung

Nach dem Trainieren des Modells wird die Performance der Klassifizierung bewertet. Einerseits wird geprüft, ob das Modell erfolgreich Daten aus dem Trainingsdatensatz klassifizieren konnte. Andererseits wird die Performance gegenüber Datensätzen, die nicht für das Trainieren der Algorithmen verwendet wurden, getestet.

Die finale Topologie des Modells wird nach Bewertung der Performance verschiedener Kombinationen festgelegt.

## 3 Fallbeispiel zur Illustrierung des Ansatzes

### 3.1 Beschreibung des Messsystems

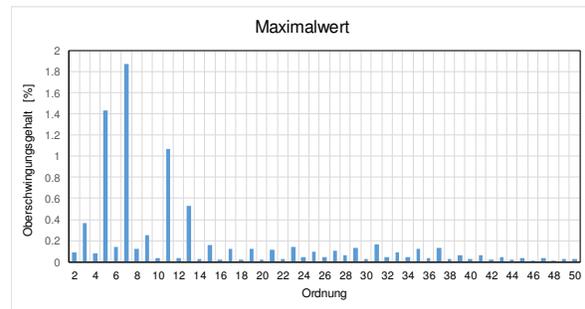
Zur Illustrierung des vorgeschlagenen Ansatzes wurden Daten einer Oberschwingungsmessung an einem Hausanschluss. Alle drei Spannungen gegen Erde (L1-E, L2-E und L3-E) wurden gemessen. Die Messungen wurden mit einem Messgerät durchgeführt, welches die Anforderungen der Norm IEC 61000-4-30 [5] erfüllt. Die OS im Bereich von 2 kHz bis 9 kHz wurden ebenfalls gemessen. Die

in Abschnitt 3.2 dargestellte Auswertung der Daten beschränkt sich auf die Auswertung der Oberschwingungen bis zu 50. Ordnung der Spannung der Phase L1-E.

## 3.2 Auswertung der Daten

### 3.2.1 Graphische Darstellung zur Visualisierung des Verhaltens

Für die Auswertung wurden Rohdaten vom 26.05.2018 bis 28.06.18 berücksichtigt. Aus den Rohdaten wurde für jede OS der Maximalwert, der Minimalwert sowie der Mittelwert berechnet. Das Bild 6 zeigt das Spektrum der Maximalwerte. Aus der Abbildung lässt sich erkennen, dass die 5., die 7., die 11. und die 13. OS die höchsten Werte aufweisen. Dieses Spektrum entspricht dem typischen Oberschwingungsmuster an einem Hausanschluss.



**Bild 6** Maximaler Oberschwingungsgehalt [%]

Die klassische Auswertung der Messdaten erfolgt unter Verwendung der Grenzwerte der Spannungsüberschwingungen im Niederspannungsnetz nach EN 50160. Gemäß Norm dürfen während 95% eines Wochenintervalls die gemessenen OS die in der Norm vorgegebenen Grenzwerte nicht überschreiten.

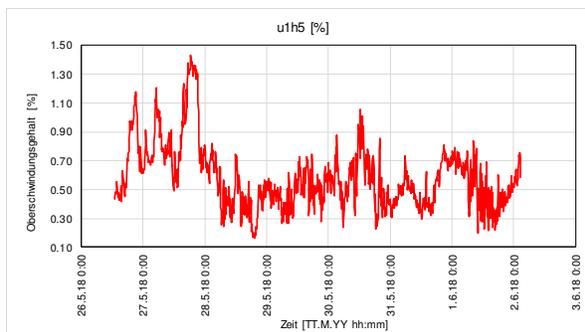
### 3.2.2 Klassifizierung der Oberschwingungen als „relevant“ und „nicht relevant“

Die Festlegung der Kriterien für die Unterscheidung zwischen „relevant“ und „nicht relevant“ soll projektspezifisch mit dem Netzbetreiber /Anlagebetreiber erfolgen.

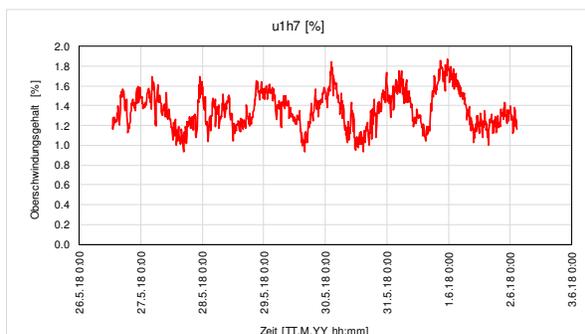
Als Klassifizierungskriterium für die Unterscheidung zwischen relevanten und nicht relevanten Oberschwingungen wurden in diesem Beispiel die OS, deren Betrag höher als 0,2 % beträgt, als „relevant“ bewertet. Die folgenden OS wurden als relevant klassifiziert: 3., 5., 7., 9., 11., und 13.

### 3.2.3 Graphische Darstellung der relevanten Oberschwingungen (OS<sub>r</sub>)

Die Zeitverläufe des Oberschwingungsgehalts der 5. und 7. Oberschwingungen sind in Bild 7 und in Bild 8 dargestellt. Vergleicht man das Bild 7 mit dem Bild 8 stellt man fest, dass die Verhaltensmuster der Zeitverläufe unterschiedlich sind.



**Bild 7** Zeitverlauf des Oberschwingungsgehalts der 5. Oberschwingung



**Bild 8** Zeitverlauf des Oberschwingungsgehalts der 7. Oberschwingung

### 3.3 Mustererkennung

Für die Mustererkennung wurde der C4.5 Algorithmus verwendet. Bei diesem Verfahren durchlaufen die Daten einen Entscheidungsbaum. Anhand der Merkmalsausprägungen der Objekte wird an den einzelnen Knoten geprüft, welcher Pfad im Baum weiterverfolgt wird. Es wird immer ein Blattknoten erreicht. Dieser stellt dann die Klasse des Objektes dar. Ein Entscheidungsbaum wird mit Hilfe von Trainingsobjekten, über einen rekursiven Divide-and-Conquer Algorithmus erstellt.

#### 3.3.1 Definition der Klassifizierungsziele

Die Klassifizierungsziele entsprechen dem, was durch das Mustererkennungsmodell vorhergesagt werden soll. Als Klassifizierungsziele wurden verschiedene Oberschwingungsgehaltbereiche, die das zu erwartende Verhalten der Oberschwingungen beschreiben, definiert. Der Oberschwingungsgehalt wurde beispielhaft in 7 Verhaltensbereiche (A, B, C, D, E, F und G) unterteilt. Siehe Tabelle 2.

**Tabelle 2** Verhaltensbereiche für die Klassifizierung des Verhaltens der relevanten OS

Klasse	Ordnung				
	3	5	7	9	11
A	≤0,109	≤0,091	≤0,071	≤0,046	≤0,147
B	(0,109, 0,168)	(0,091, 0,448)	(0,071, 1,012)	(0,046, 0,104)	(0,147, 0,367)
C	[0,168, 0,228)	[0,448, 0,804)	[1,012, 1,313)	[0,104, 0,162)	[0,367, 0,587)

D	[0,228, 0,287)	[0,804, 1,160)	[1,313, 1,614)	[0,162, 0,220)	[0,587, 0,807)
E	[0,287, 0,346)	[1,160, 1,516)	[1,614, 1,915)	[0,220, 0,278)	[0,807, 1,027)
F	[0,346, 0,406)	[1,516, 1,872)	[1,915, 2,217)	[0,278, 0,336)	[1,027, 1,247)
G	≥0,406	≥1,872	≥2,217	≥0,336	≥1,247

#### 3.3.2 Statistische Analyse

Im Rahmen der statistischen Analyse der Daten wurde einerseits die Korrelation zwischen den Oberschwingungen und der Grundschiwingung der Spannung (siehe Tabelle 3) durchgeführt. Andererseits wurde die Korrelation der Oberschwingungen untereinander untersucht (siehe Tabelle 4). Aus dem berechneten Korrelationskoeffizient lässt sich allerdings feststellen, dass die lineare Abhängigkeit zwischen der Grundschiwingung und den OS schwach ist ( $r=-0,205$ ). Aus dieser Auswertung lässt sich ableiten, dass die Grundschiwingung der Spannung kein gutes potenzielles Eingangsattribut für den Mustererkennungsalgorithmus ist.

**Tabelle 3** Korrelationskoeffizienten zwischen den relevanten Oberschwingungen und der Grundschiwingung der Spannung

$r_{h3-h1}$	-0,048
$r_{h5-h1}$	-0,068
$r_{h7-h1}$	-0,205
$r_{h9-h1}$	-0,021
$r_{h11-h1}$	-0,173
$r_{h13-h1}$	-0,023

Die berechneten Korrelationskoeffizienten zwischen den relevanten Oberschwingungen untereinander können der Tabelle 3 entnommen werden. Zwischen den OS h3 und h5 ( $r_{3,5}=0,44$ ) sowie zwischen den OS h7 und h13 ( $r_{7,13}=0,505$ ) wurde eine gewisse lineare Abhängigkeit beobachtet.

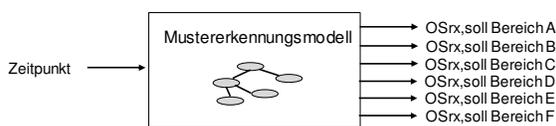
**Tabelle 4** Korrelationskoeffizienten zwischen den relevanten Oberschwingungen untereinander

	h3	h5	h7	h9	h11	h13
h3	1,000	0,440	0,006	0,096	-0,304	-0,080
h5	0,440	1,000	0,001	-0,195	-0,220	-0,231
h7	0,006	0,001	1,000	-0,234	0,355	0,505
h9	0,096	-0,195	-0,234	1,000	-0,191	-0,189
h11	-0,304	-0,220	0,355	-0,191	1,000	0,265
h13	-0,080	-0,231	0,505	-0,189	0,265	1,000

#### 3.3.3 Klassifizierung

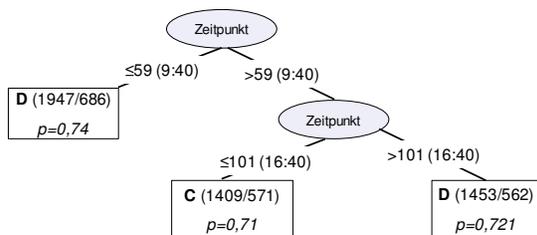
Für die OS h7 wurde ein Mustererkennungsmodell entworfen. Für die Mustererkennung wurde der Klassifizierungsalgorithmus C4.5 (Entscheidungsbaum) verwendet. Die Kunst der Klassifizierung liegt darin, die bestmöglichen Eingangsattribute auszuwählen. Aus der statistischen Analyse werden diese potentiellen Eingangsattribute identifiziert. Die Korrelationsanalyse hat gezeigt, dass die lineare Abhängigkeit zwischen dem Betrag der Grundschiwingung der Spannung und dem Betrag der OS h7 schwach ist. Aus diesem Grund wurde die Spannung als Eingangsattribute

ausgeschlossen. Eine weitere Idee wäre, den Betrag der OS h13 als Eingangsattribute anzugeben. Der Korrelationskoeffizient zwischen h7 und h13 beträgt 0,505. Das deutet daraufhin, dass der Betrag der OS h13 ein möglicheres Eingangsattribut sein könnte. Ein weiterer Kandidat als Eingangsattribut ist der Zeitpunkt der Messung. Aus dem Zeitverlauf (Bild 10) ist eine Periodizität zu erkennen. Das deutet darauf hin, dass der Zeitpunkt der Messung ein gutes Eingangsattribut sein kann. Der Vereinfachung halber wurde zur Illustrierung des vorgeschlagenen Ansatzes nur der Zeitpunkt der Messung als Eingangsattribut angegeben. Da es sich um eine 10-minütige Messung handelt, werden pro Tag 144 Messwerte gespeichert. Das heißt, jeder einzelne Messwert ist einem Zeitpunkt zugeordnet. Der Zeitpunkt 1 entspricht der Uhrzeit 0:00 eines Tages, während dem Messpunkt 144 der Uhrzeit 23:50 eines Tages entspricht. Das Bild 9 zeigt die Topologie des Modells.



**Bild 9** Topologie des Modells

Der resultierende Entscheidungsbaum kann dem Bild 10 entnommen werden. Der Entscheidungsbaum beschreibt das Muster, das aus den Daten extrahiert wurde. In Abhängigkeit des Zeitpunkts bzw. der Uhrzeit des Tages, konnte ein Verhaltensmuster für die OS h7 extrahiert werden. Es gibt zwei Zeitpunkte (09:40 und 16:40), die für das Muster der So h7 maßgebend sind. Aus dem Baum kann z.B. abgeleitet werden, dass zwischen 00:00 und 9:40 (Zeitpunkt  $\leq 59$ ) der Oberschwingungsgehalt im Bereich D liegt, und das mit einer Wahrscheinlichkeit  $p=0,74$ . Der Baum besteht aus 3 Blätter. 62,18 % der Instanzen wurden richtig klassifiziert. Obwohl diese Ergebnisse durch ein sehr einfaches Modell den vorgeschlagenen Ansatz illustrieren, ist das Endergebnis (nur 62,18 % der Instanzen wurden richtig klassifiziert) als nicht zufriedenstellend zu bewerten. Die Performance eines zuverlässigen Modells soll in der Lage sein, mindestens 80 % der Instanzen richtig zu klassifizieren. Laufende Untersuchungen der Autoren im Zusammenarbeit mit einem Übertragungsnetzbetreiber haben gezeigt, dass die Performance der Mustererkennung erheblich verbessert werden kann, wenn der Betrag der Grundschwingung eines Stroms, als Eingangsattribut angegeben wird.



**Bild 10** Entscheidungsbaum

## 4 Zusammenfassung und Ausblick

Die vorläufigen Ergebnisse dieser Untersuchungen haben gezeigt, dass anhand von Entscheidungsbäumen die Möglichkeit besteht, ein Muster zu extrahieren unter dem die Oberschwingungssituation eines Netzes bewertet werden kann. Durch die Erkennung des Verhaltensmusters lassen sich Veränderungen der Oberschwingungssituation erkennen, bevor diese zur Verletzung vorgegebener Grenzwerte führen. Der vorgeschlagene Ansatz wird im Rahmen eines Forschungsprojektes mit einem Netzbetreiber weiterentwickelt und getestet.

## 5 Literatur

- [1] Mohod S.W.; Aware M.V., Power Quality Issue and its Improvement in Wind Energy Generation Interface to Grid System, MIT International Journal of Electrical and Instrumentation Engineering, Vol.1, No.2, Aug. 2011, pp.116-122.
- [2] Golovanov, N. et al.: Power Quality Assessment in Small Scale Renewable Energy Sources Supplying Distribution Systems, *Energies* **2013**, 6, 634-645; doi:10.3390/en6020634, pp. 634-645.
- [3] Gasch E.; et al.: Efficient power quality analysis of big data (case study for a distribution network operator), 23rd International Conference on Electricity Distribution, Lyon, 15-18 June 2015, pp. 1-5.
- [4] DIN EN 50160:2011-02, Merkmale der Spannung in öffentlichen Elektrizitätsversorgungsnetzen; Deutsche Fassung EN 50160:2010 + Cor. :2010
- [5] 61000-4-30 VDE 0847-4-30:2016-01, Elektromagnetische Verträglichkeit (EMV), Teil 4-30: Prüf- und Messverfahren – Verfahren zur Messung der Spannungsqualität