

KURZZEITPROGNOSE DER LEISTUNG VON WINDKRAFTANLAGEN MIT FUZZY PATTERN KLASSIFIKATION

Päßler, M. , Amft, O. , Bocklisch, S. , Hiller, W.
Technische Universität Chemnitz, Fakultät für Elektrotechnik und Informationstechnik
09107 Chemnitz
mipa@hrz.tu-chemnitz.de

Zusammenfassung

In Zusammenarbeit mit einem regionalen Energieanbieter wurde an der TU Chemnitz eine Studie zur Prognose der Leistung von Windkraftanlagen durchgeführt. Von besonderem Interesse war dabei die Kurzzeitprognose für die folgenden 15 Minuten, da dieser Bereich für das Unternehmen eine erhebliche Bedeutung im Energiemanagement hat. Die Arbeit stützte sich auf eine konkrete Datenbasis von Messungen aus 34 sächsischen Windenergieeinspeisern im Zeitraum 1998/99. Diese Daten wurden unter Verwendung der Methodik der Fuzzy Pattern Klassifikation in eine unscharfe Beschreibung (Fuzzy Pattern Klassifikator) überführt. Dabei unterschied man 7 Verlaufstypen und verwendete zwei gezielt ausgesuchte Merkmale, basierend auf den vorliegenden Daten. Die Prognoseergebnisse wiesen für die 15- bis 30-Minuten-Vorhersage in über 90 Prozent aller Fälle einen Fehler unter 4 Prozent auf. [6]

1. Einleitung

Im Energiemanagement ist es von großem Interesse, sowohl die Last, als auch die durch nicht beeinflussbare Energieerzeuger (z.B. Windkraftanlagen und Sonnenkollektoren) zur Verfügung gestellte Leistung bestmöglich zu prognostizieren, um eine kostengünstige Planung der vorhandenen beeinflussbaren Ressourcen (z.B. eigene Energieanlagen und der Einkauf von Energie über Großerzeuger) zu gewährleisten. Dabei spielt vor allem die Kurzzeitprognose für die nächste ¼ Stunde eine erhebliche Rolle. Nachdem von Seiten der TU Chemnitz bereits in einer früheren Studie nachgewiesen wurde, daß es mit der Methodik der Fuzzy Pattern Klassifikation möglich ist, die regionalen Lastverläufe nicht nur im Kurzzeitbereich sehr gut vorherzusagen [1], sollte eine weitere Studie die Leistungsfähigkeit der Fuzzy Pattern Klassifikation für die Windenergieprognose zeigen.

Die Vorgehensweise und die vorläufigen Ergebnisse der Studie sollen in diesem Artikel dargelegt werden. Dabei erfolgt im zweiten Punkt eine Darstellung der Methodik der Fuzzy Pattern Klassifikation (FPK). In den weiteren Punkten wird die Anwendung dieser Methodik auf die hier zu besprechende Aufgabe und die erreichten Ergebnisse dargelegt sowie die zukünftigen Möglichkeiten der Windenergieprognose mit FPK aufgezeigt.

2. Die Methode der Fuzzy Pattern Klassifikation

2.1. Der Aufbau von Fuzzy Pattern Klassifikatoren

Die Methode der Fuzzy Pattern Klassifikation [2] beruht prinzipiell auf der Beschreibung von Zusammenhängen und Gesetzmäßigkeiten beispielsweise physikalischer oder mechanischer Erscheinung mittels Mustern – sogenannten Pattern. Die Grundlage dafür bilden wohldefinierte Merkmale, die sich aus den Ereignissen der Erscheinungen ableiten lassen. Diese Merkmale können dabei rein

physikalische Größen (Meßgrößen), abgeleitete Größen aber auch linguistische Beschreibungen sein. Für jedes Ereignis kann so ein Objekt definiert werden, welches durch alle derartigen Merkmale beschrieben wird. Die entstehenden Objekte können wiederum zu sogenannten Klassen zusammengefaßt werden, die gleiche oder ähnliche Vorgänge innerhalb der betrachteten Problematik repräsentieren. Dadurch entsteht ein Muster in einem (in der Regel hochdimensionalen) Merkmalsraum.

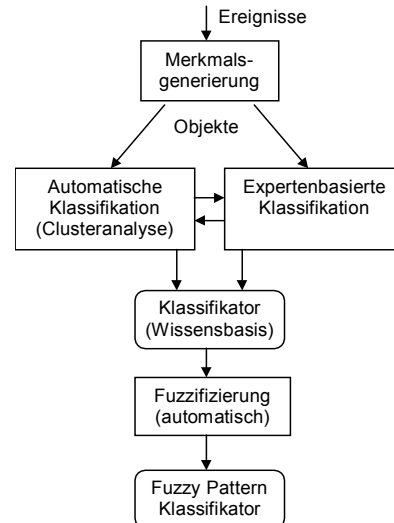


Abb. 1: Aufbau einer unscharfen Wissensbasis

Die Muster können dabei auf sogenannten natürlichen Klassen beruhen, die in der Regel durch eine automatische Klassifikation (Clusterbildung) gefunden werden. Daneben besteht jedoch auch die Möglichkeit, die Objekte per „Experten“ zu Klassen mit gleichen bzw. ähnlichen Eigenschaften zusammenzufassen. Das Ergebnis muß dabei nicht einer natürlichen Struktur entsprechen. Im allgemeinen werden Mischformen der Klassifikation verwendet, die sich meist durch eine iterative Vorgehensweise

und den Wechsel zwischen automatischer Clusterbildung und expertenbasierter Klassifikation auszeichnen.

Die durch die Objekte diskret beschriebenen Klassen können durch geeignete Algorithmen [2][3] in unscharfe parametrische Beschreibungen – die Fuzzy Pattern Klassen überführt werden (Fuzzifizierung). Die Gesamtheit aller Klassen wird als Fuzzy Pattern Klassifikator bezeichnet.




Abb. 2: objektbasierter (scharfer) Klassifikator




Abb. 3: Fuzzy Pattern Klassifikator

2.2. Identifikation

Der Fuzzy Pattern Klassifikator enthält alle „angelernten“ Informationen der ihm zugehörigen Problematik. Wird nun ein neues unbekanntes Objekt mit den aus der Modellbildung (Klassifikatorbildung) festgelegten Merkmalen dem Klassifikator „vorgeführt“, so kann ihm für jede Klasse ein sogenannter Sympathiewert zugeordnet werden – das Objekt wird identifiziert. Dieser Sympathiewert kennzeichnet die Zugehörigkeit eines Objektes zu einer bestimmten Klasse des Klassifikators. Die Gesamtheit aller Sympathiewerte zu einem Objekt wird als Sympathievektor bezeichnet. Neben der direkten Zuordnung eines Objektes in eine Klasse (maximale Sympathie zu dieser Klasse) können aber auch Trends (höchste Nebensympathiewerte) des entsprechenden Objektes zu anderen Klassen festgestellt werden.

Des weiteren können Zuordnungen für Objekte getroffen werden, die nicht direkt im Definitionsbereich der Klassen liegen, da die unscharfen Beschreibungen in der Regel weiter in den Merkmalsraum hineinreichen.

Als Ergebnis kann ein bestimmter Objekttyp – eine bestimmte Objekteigenschaft festgestellt werden, gegebenenfalls mit einem Trend zu einer oder mehreren anderen Eigenschaften (Klassen).

Diese Ergebnispräsentation wird oft in der Überwachung von Maschinen und Prozessen eingesetzt (Monitorsystem) [4].

In den meisten technischen Einsatzgebieten wird jedoch ein konkreter Ausgabewert gefordert. Für diese Anforderung werden die durch die Klassen

repräsentierten Eigenschaften durch konkrete Stellgrößen beschrieben, welche mittels Defuzzifizierung in eine resultierende numerische Größe überführt werden [5]. Ein oft verwendeter Ansatz ist hierbei die Schwerpunktbildung über die mit den Sympathiewerten gewichteten Klassengrößen.

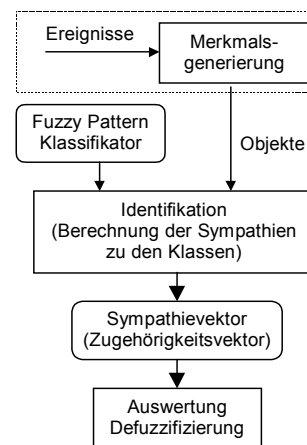


Abb. 4: Schema der Identifikation

Es können natürlich auch vektorielle Ausgangsgrößen vorliegen, deren Verknüpfung ebenfalls durch entsprechend geeignete Defuzzifikationsmethoden erfolgen kann.

3. Übertragung der Methodik der Fuzzy Pattern Klassifikation auf die Problemstellung der Prognose der Leistung von Windkraftanlagen

3.1. Aufgabenstellung

In Zusammenarbeit mit einem regionalen Energieanbieter bestand die Aufgabe in der Berechnung eines Prognosewertes der Leistungsabgabe aller Windenergieanlagen der entsprechenden Region für die nächste Abrechnungsperiode von 15 Minuten. Die Vorhersage konnte sich dabei auf eine (teilweise unvollständige) Datenbasis der 15-Minuten-Mittelwerte aller Einspeiser von Windenergie aus den Jahren 1998 und 1999 stützen. Die 15-Minuten-Mittelwerte liegen somit alle 15 Minuten (zu diskreten Zeitpunkten) vor. Zur Vorhersage wurden Analyse- und Prognosemethoden aus der Fuzzy Pattern Klassifikation verwendet, welche seit mehr als 10 Jahren erfolgreich von der Professur für Systemtheorie in vielen Bereichen der Überwachung, Beurteilung und Vorhersage von Prozessen in den verschiedensten Bereichen der Wissenschaft und Industrie eingesetzt wurden.

Ähnlich der Ansätze der meisten Vorhersageverfahren wird auch bei der FPK ein zweistufiges Prinzip angewandt. In einem ersten Schritt, der Anlernphase, wird der vorliegende Prozeß analysiert, anhand seiner Daten für die zu verwendende Methodik aufbereitet und in ein entsprechendes Modell überführt (Punkt 3.2. und 3.3.). In einem zweiten Schritt wird das Modell, in diesem Fall ein Fuzzy Pattern Klassifikator, benutzt, um einen Prozeßzustand zu erkennen und eine Prognose durchzuführen.

3.2. Festlegung der Merkmalsstruktur

Der dynamische (zeitabhängige) Verlauf der Leistungsabgabe der Windkraftanlagen soll durch einen statischen (zeitunabhängigen) Klassifikator beschrieben werden (Zustandsbeschreibung). Es gilt nun Merkmale zu finden, welche die im Prozeß enthaltene Dynamik ausreichend charakterisieren. In der Regel wird für die Prognose einer Zeitreihe nur ein begrenztes Zeitfenster der Vergangenheit (ausgehend von einem Vorhersagezeitpunkt t_V) verwendet. Die Länge dieses Zeitfensters gilt es als erstes festzulegen. Im vorliegenden Fall wurde eine Analyse der Daten mittels Autokorrelation durchgeführt und die Zeitfensterlänge auf 4 festgelegt (Grenzkorrelation bei 0,8 [7]).

Als Merkmale wurden aus den im Zeitfenster vorliegenden Werten folgende Größen in einem ersten Schritt festgelegt:

Nr.	Merkmal	Bez.
1	Anstieg der Regressionsgeraden der Leistungswerte aller 4 Punkte des Zeitfensters	Δr_{ZF}
2	Anstieg der Regressionsgeraden der Leistungswerte der Zeitpunkte t_0, t_1, t_2 des Zeitfensters	Δr_{02}
3	Anstieg der Regressionsgeraden der Leistungswerte der Zeitpunkte t_1, t_2, t_3 des Zeitfensters	Δr_{13}
4	Anstieg der Leistungswerte von t_0 zu t_3	Δx_{ZF}
5	Anstieg der Leistungswerte von t_0 zu t_2	Δx_{02}
6	Anstieg der Leistungswerte von t_1 zu t_3	Δx_{13}
7	Anstieg der Leistungswerte von t_2 zu t_3	Δx_{23}
8	Mittelwerte der Leistungswerte des Zeitfensters	m_{ZF}
9	Standardabweichung bezogen auf m_{ZF}	σ_{ZF}/m_{ZF}

Tabelle 1: Merkmale der Leistungsverläufe

Die Zeitpunkte t_0 bis t_3 ($=t_V$) kennzeichnen dabei in chronologischer Reihenfolge die Zeitpunkte des Zeitfensters.

Aus der Problemanalyse heraus bestand die Bestrebung, weitere Merkmale aus Umweltgrößen wie Windgeschwindigkeiten, Turbulenzintensitäten des Windes der letzten ¼ Stunde, Sonnenintensität, Temperatur oder auch maximale Windgeschwindigkeiten zu extrahieren, was aufgrund der unzureichenden und in diesem Bereich auch fehlerhaften Datenbasis jedoch nicht möglich war.

3.3. Festlegung der Klassenstruktur

Zur Klassifikation der Objekte wurden drei verschiedene Ähnlichkeitskriterien Δx^K untersucht (Tabelle 2). Die Ähnlichkeitskriterien müssen dabei so gewählt werden, daß verschiedene Zustände des Prozesses unterschieden werden können und somit eine Klassenbildung möglich ist.

Die beste Unterscheidbarkeit verschiedener Prozeßzustände konnte bei der 3. Variante festgestellt werden.

Variante	Beschreibung	Berechnungsvorschrift
1	Anstiegswert zwischen Leistungswert zum Zeitpunkt t_{V+1} und t_0 des Zeitfensters ($=t_{V-3}$)	$\Delta x^K = x_{t_{V+1}} - x_{t_{V-3}}$
2	Anstiegswert zwischen Leistungswert zum Zeitpunkt t_{V+1} und dem Mittelwert m_{ZF}	$\Delta x^K = x_{t_{V+1}} - m_{ZF}$
3	Anstiegswert zwischen Leistungswert zum Zeitpunkt t_{V+1} und dem Vorhersagezeitpunkt t_V	$\Delta x^K = x_{t_{V+1}} - x_{t_V}$

Tabelle 2: Klassifikationskriterien

Die Untersuchungen stützten sich dabei auf die Ermittlung von Beziehungen zwischen Δx^K und den Merkmalen der entsprechenden Objekte. So wurde beispielsweise ein mittlerer linearer Zusammenhang zwischen Δx_{ZF} und Δx^K für alle Varianten festgestellt, welcher prinzipiell einer seriellen Korrelation entspricht. Für diesen Zusammenhang waren für Variante 3 sowohl der Anstieg der resultierenden Regressionsgeraden als auch die Streuung bezogen auf diese Regressionsgerade bestmöglich.




Abb. 5: Mittelwerte und maximale Streuung von Δx^K bezogen auf Δx_{ZF}

Die Auswahl dieses Klassifikationskriteriums konnte mit der Auswertung der Prognoseergebnisse nochmals bestätigt werden.

Mit dem Klassifikationskriterium $\Delta x^K = x_{t_{V+1}} - x_{t_V}$ wurden 7 Anstiegsbereiche als Klassen festgelegt.

Klassifikator	Δx^K
Klasse 1	Großer positiver Anstieg
Klasse 2	Mittlerer positiver Anstieg
Klasse 3	Kleiner positiver Anstieg
Klasse 4	Anstieg nahe Null
Klasse 5	Kleiner negativer Anstieg
Klasse 6	Mittlerer negativer Anstieg
Klasse 7	Großer negativer Anstieg

Tabelle 3: Klassifikatorstruktur

Diesen Klassen wurden als Prognose ein Gradient zugeordnet, der den Mittelwert aller Δx^K der Lernobjekte einer Klasse darstellt.

Die Prognosestrategie bildete der Mittelwert der über die Zugehörigkeiten eines Objektes gewichteten Gradienten aller Klassen.

3.4. Resultierender Fuzzy Pattern Klassifikator und Merkmalsreduktion

Aus der Datenbasis wurden 77 Tage ausgewählt, die sehr wenig Meßausfälle und Fehlmessungen aufwiesen, um den Klassifikator bestmöglich anzulernen. Mittels des Klassifikationskriteriums und der entsprechenden Klasseneinteilung erfolgte die Klassenzuordnung der Objekte. Die resultierende Klassenstruktur wurde mittels des Softwaretools „BUILD“ [8] automatisch in einen Fuzzy Pattern Klassifikator überführt. Dieser Klassifikator diente als Basis für weitere Untersuchungen und der Optimierungen sowohl des Klassifikators als auch der Merkmale.

Als Resultat zeigte sich, daß die Merkmalsstruktur auf zwei der 9 Merkmale eingeschränkt werden konnte. Die Merkmale Δx_{23} und m_{ZF} reichten aus, um einen Klassifikator zu erzeugen, welcher ähnliche Prognoseergebnisse lieferte. Die anderen Merkmale lieferten nur redundante Informationen.

Die Prognosegüte von $\lambda = 80,4\%$ bei dem Klassifikator mit 9 Merkmalen veränderte sich lediglich auf $\lambda = 79,9\%$, wobei

$$\lambda = \left[1 - \frac{3\sigma}{x_{\max}} \right] \cdot 100\%$$

gilt und σ die empirische Standardabweichung des absoluten Prognosefehlers sowie x_{\max} der reale Maximalwert der betrachteten Zeitreihe ist.




Abb. 6: Resultierender Klassifikator

4. Leistungsfähigkeit des Fuzzy Pattern Klassifikators

Um die Leistungsfähigkeit der Prognose zu bewerten, wurden neben der Prognosegüte λ noch Fehlerklassen $e_{p\%}$ eingeführt, mit welchen die Summenhäufigkeiten für Prognosefehler unter $p\%$ angegeben werden.

Neben der 15-Minuten-Prognose wurde mit dem gleichen Ansatz eine 30-Minuten-Prognose durchgeführt. Die Ergebnisse sind dabei ebenfalls als gut einzuschätzen.

Prognosehorizont	$e_{1\%}$ [%]	$e_{2\%}$ [%]	$e_{4\%}$ [%]	λ [%]
15 Minuten	68,2	85,8	96,6	79,9
30 Minuten	53,3	73,3	90,2	74,2

Tabelle 4: Güterwerte der Prognose

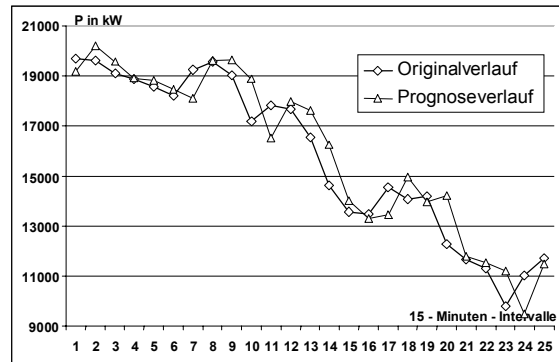


Abb. 7: Prognosebeispiel

Die obige Abb. 7 zeigt beispielhaft einige Ergebnisse für die 15-Minuten-Vorhersage. Eine umfassende Darstellung der Methodik und der Ergebnisse ist bei Amft [6] zu finden.

5. Ausblick

Im Bereich der Einarbeitung von Umweltdaten und der Wettervorhersage in die Klassifikatoren ist eine Verbesserung der Prognoseergebnisse zu vermuten. Insbesondere in der Einarbeitung von wagen Informationen wie der Wettervorhersage und der automatischen Adaption der Klassifikatoren sind erhebliche Potentiale für die FPK vorhanden.

Untersuchung zur Auffindung von Gebieten ähnlichem Windverhaltens legen des weiteren die Vermutung nahe, daß die differenzierte Betrachtung dieser Windgebiete die Leistungsprognose zusätzlich verbessern kann sowie über Korrelationen des Windverhaltens in den einzelnen Windgebieten und über die Abhängigkeiten zwischen ihnen weitere Merkmale gewonnen werden können.

6. Literatur

- [1] Kurzbeschreibung der Zeitreihenanalyse und -prognose mittels Fuzzy Pattern Klassifikation für die Problematik der Energielast- und -bezugsprognose, Studie, TU Chemnitz, Professur für Systemtheorie (1998)
- [2] Bocklisch: Prozeßanalyse mit unscharfen Verfahren, Verlag Technik Berlin (1987)
- [3] Päßler: Mehrdimensionale Zeitreihenmodellierung und -prognose mittels Fuzzy Pattern Modellen, Diplomarbeit, TU Chemnitz (1998)
- [4] Bocklisch, Sehm: INFO 08/99, Monitoring mit der Fuzzy-Pattern-Klassifikation, TU Chemnitz, Professur für Systemtheorie (1998)
- [5] Kahlert J., Frank H.: Fuzzy-Logik und Fuzzy-Control, Vieweg Verlag (1994)
- [6] Amft: Untersuchung zur Erfassung, leittechnischen Prozessanbindung und Kurzzeitprognose der Leistung von Windkraftanlagen, Diplomarbeit, TU Chemnitz (1999)
- [7] Harvey: Zeitreihenmodelle, Oldenburg Verlag (1995)
- [8] INFO 04/99: FX-System, TU Chemnitz, Professur für Systemtheorie (1999)