

# Unsicherheit und Vagheit: Begriffe, Methoden, Forschungsthemen

Christian Borgelt und Rudolf Kruse

**Kurzfassung** Da in Anwendungen das vorliegende Wissen selten exakt und sicher ist, Menschen aber dennoch mit Hilfe dieses Wissens Schlüsse ziehen und Entscheidungen treffen können, stellt sich für die künstliche Intelligenz die Aufgabe, unsicheres und vages Wissen der Verarbeitung durch einen Rechner zugänglich zu machen. In diesem Aufsatz versuchen wir, nach einer einleitenden Begriffsklärung einen Überblick über Methoden und Forschungsthemen dieses wichtigen Gebietes zu geben.

## 1 Einleitung

Menschliches Expertenwissen ist oft unsicher und vage. Dennoch ist es nicht unbrauchbar, denn Menschen sind durchaus in der Lage, mit diesem Wissen Schlüsse zu ziehen und sinnvolle Entscheidungen zu treffen. So weiß man etwa in der Medizin, daß bestimmte Symptome oft — aber doch nicht immer — auf bestimmte Krankheiten hindeuten. Ein Arzt kann daher die Krankheit eines Patienten nur selten mit Sicherheit erschließen und stellt doch meist richtige Diagnosen. In einem Industriebetrieb bedient ein Arbeiter eine Maschine mit Hilfe einer Regel der Art „Wenn der Druck hoch und die Temperatur normal ist, sollte das Ventil weit geöffnet werden.“ und kann trotz der Vagheit dieser Regel die Maschine erfolgreich steuern.

Computerprogrammen fällt es dagegen sehr viel schwerer, unsichere und vage Informationen zu verarbeiten. In vielen Anwendungen kann man jedoch auf die Verarbeitung solcher Information kaum verzichten, denn exakte Daten stehen häufig nicht zur Verfügung oder sind nur kostspielig zu beschaffen, und Abhängigkeiten zwischen relevanten Größen sind meist Zufallseinflüssen unterworfen oder nur näherungsweise bekannt. Die Darstellung von unsicherem und vagem Wissen in einem Rechner und das automatische Schließen mit solchem Wissen gehören daher zu den wichtigsten Forschungsgebieten im Bereich der künstlichen Intelligenz.

In diesem Aufsatz versuchen wir, einen Überblick über einige Ansätze zu geben, mit denen man versucht, Unsicherheit und Vagheit zu behandeln. Wegen der Vielzahl bekannter Ansätze kann dieser Versuch natürlich nicht vollständig gelingen. Auch können wir uns von Vorlieben für Ansätze in bestimmten Richtungen (speziell numerische Ansätze) nicht ganz freisprechen. Wir hoffen, daß uns trotzdem eine ausgewogene Darstellung gelungen ist.

## 2 Begriffe

Bevor wir uns Methoden und Techniken zuwenden, ist es sinnvoll, einige Begriffe zu klären, um die zu behandelnden Erscheinungen und auftretenden Probleme präzise charakterisieren zu können. In der künstlichen Intelligenz geht es

um die Modellierung von *Wissen* und von *Schlußfolgerungen* mit diesem Wissen. Da, wie bereits gesagt, praktisch relevantes Wissen selten völlig exakt und absolut sicher ist, wird besonderer Wert auf die Behandlung *imperfekten Wissens* gelegt, das sich mit Hilfe der Eigenschaften *Impräzision*, *Unsicherheit* und *Vagheit* klassifizieren läßt.

**Impräzision** Aussagen wie „Der Ball ist grün oder blau oder türkis.“ oder „Die Geschwindigkeit des Autos lag zwischen 50 und 60 km/h.“ nennen wir *impräzise*. Sie sind *impräzise*, weil sie nicht nur einen Wert einer Eigenschaft angeben sondern eine *Menge von Alternativen*. Im Gegensatz dazu nennen wir Aussagen, die nur einen Wert für eine Eigenschaft angeben, *präzise*. Ein Beispiel einer präzisen Aussage ist „Der Patient hat 39.3° Fieber.“

**Unsicherheit** Wenn man Aussagen wie die obigen Beispiele liest, setzt man i.a. implizit voraus, daß die Aussagen *sicher* sind, d.h., daß alle Alternativen, die in den Aussagen nicht genannt sind, definitiv ausgeschlossen werden können. So nimmt man etwa an, daß der Ball bestimmt nicht rot ist und daß das Auto auf jeden Fall schneller als 40 km/h fuhr. Falls solche, in der betrachteten Aussage nicht genannten Alternativen *nicht* ausgeschlossen werden können, nennen wir die Aussage *unsicher*. Denn die Aussage könnte ja falsch sein, da es möglich ist, daß eine dieser nicht genannten Alternativen die wahre Situation beschreibt. Man beachte, daß sowohl präzise als auch *impräzise* Aussagen *unsicher* sein können. Was eine Aussage *sicher* oder *unsicher* macht, ist, ob alle möglichen Alternativen in ihr genannt sind oder nicht.

**Vagheit** Die meisten Begriffe der Alltagssprache sind *vage*: Wenn wir sagen, Peter sei *groß* oder an einem Sommertag sei es *heiß*, dann meinen wir keine bestimmte Körpergröße und keine bestimmte Temperatur, ja nicht einmal ein Intervall wie bei *impräzisen* Aussagen. Die Bereiche der Körpergrößen und Temperaturen, die als *groß* bzw. *heiß* bezeichnet werden können, sind nicht scharf begrenzt. Zwar gibt es Werte der Körpergröße, die sicher als *groß* bezeichnet werden können, z.B. 220 cm, und solche, die sicher nicht als *groß* bezeichnet werden können, z.B. 140 cm. Genauso gibt es Temperaturen, die sicher *heiß* sind, z.B. 35° C, und solche, die es sicher nicht sind, z.B. 5° C. Doch zwischen diesen Körpergrößen und Temperaturen, für die klar entschieden werden kann, ob der Begriff anwendbar ist oder nicht, liegt eine *Penumbra* (lat. für *Halbschatten*) von Werten, die nicht eindeutig zugeordnet werden können.

## 3 Methoden und Techniken

**Logik** Die Logik stellt eine formale Sprache bereit, in der sich Aussagen präzise und eindeutig formulieren lassen.

Außerdem liefert sie Schlußregeln, mit denen sich rein syntaktisch alle logischen Folgerungen einer gegebenen Menge von Aussagen ableiten lassen.

Es ist klar, daß sich mit den Mitteln der Logik immerhin Impräzision behandeln läßt: Endliche Mengen von Alternativen kann man einfach durch Disjunktionen darstellen, in denen die Alternativen aufgezählt werden, und Intervalle können beschrieben werden, indem man Vergleichsprädikate  $\geq$  und/oder  $\leq$  einführt. Da die klassische Logik aber nur zwischen „wahr“ und „falsch“ unterscheidet, ist sie zur Behandlung von Unsicherheit nicht unmittelbar geeignet. Sie kann jedoch entsprechend erweitert werden: Z.B. führt man in der sogenannten *Modallogik* die *Modalitäten* „notwendig“ und „möglich“ ein, um Aussagen als sicher oder unsicher *kennzeichnen* zu können.

Eine einfache Kennzeichnung ist jedoch oft nicht ausreichend, da sie keine Hilfestellung mehr bietet, wenn man sich zwischen mehreren unsicheren Aussagen zu entscheiden hat. In einem solchen Fall braucht man Kalküle, in denen man mindestens *Präferenzen* zwischen unsicheren Aussagen ausdrücken kann oder in denen sich sogar die Sicherheit einer Aussage in Form eines Sicherheits- oder Vertrauensgrades *quantifizieren* läßt. Dies führt zu verschiedenen *mehrwertigen Logiken* in denen es neben den Wahrheitswerten „wahr“ und „falsch“ weitere gibt, die für verschiedene Stufen der Sicherheit stehen.

In der künstlichen Intelligenz ist der Sicherheitsfaktorenansatz [14], der sich als eine mehrwertige Logik mit Wahrheitswerten zwischen  $-1$  (falsch) und  $+1$  (wahr) deuten läßt, am bekanntesten geworden. Er wurde in dem medizinischen Expertensystem MYCIN zur Diagnose bakteriogener Infektionskrankheiten eingesetzt [15]. Zwar war diese Anwendung recht erfolgreich, doch zeigte eine genaue Analyse [7] (ausgelöst durch fehlgeschlagene Übertragungen auf andere Gegenstandsbereiche), daß dieser Ansatz implizit starke Unabhängigkeitsannahmen macht, die oft nicht erfüllt sind. Er wurde daher durch die Forschung fallengelassen, ist jedoch wichtig, da durch ihn ein Kernproblem der Modellierung von Unsicherheit erkannt wurde.

**Wahrscheinlichkeit** Die bekannteste Theorie zur Quantifizierung von Sicherheit bzw. Möglichkeit ist die *Wahrscheinlichkeitstheorie*. In ihr wird jedem *Ereignis* ein Zahlenwert — seine *Wahrscheinlichkeit* — zugeordnet. Die Eigenschaften dieser Wahrscheinlichkeiten werden mathematisch durch die bekannten *Kolmogorow-Axiome* beschrieben. Geschlossen wird in der Wahrscheinlichkeitstheorie i.w. durch die Berechnung *bedingter Wahrscheinlichkeiten* (wobei die Bedingungen durch die vorliegenden Beobachtungen gegeben sind).

In ihrer direkten Form ist die Wahrscheinlichkeitstheorie auf die Behandlung präziser Information beschränkt. Dies liegt i.w. daran, daß sie die Definition eines Ereignisraumes mit Elementarereignissen erfordert, die alle möglichen Situationen erschöpfen, aber auch einander ausschließen. Will man impräzises Wissen behandeln, so ist man gezwungen, entweder auf Familien von Wahrscheinlichkeitsverteilungen überzugehen (wodurch man zwar den Rahmen der Wahrscheinlichkeitstheorie nicht verläßt, was aber die mathematische Behandlung erheblich erschwert) oder

Metaprinzipien, wie etwa das Prinzip des unzureichenden Grundes (insufficient reason principle), einzuführen, um wieder eine eindeutige Verteilung zu erhalten.

Als Alternative bietet sich die *Possibilitätstheorie* an, die sich aus der (als nächstes zu besprechenden) Theorie der Fuzzy-Mengen entwickelt hat. Mit ihr versucht man explizit, die Behandlung von Unsicherheit und Vagheit zu vereinen, ohne die Einführung von Metaprinzipien oder eine komplexe mathematische Behandlung in Kauf nehmen zu müssen. Allerdings ist dies nicht zu erreichen, ohne Abstriche bei der Genauigkeit der Ergebnisse zu machen. In Anwendungen kann dies jedoch akzeptabel sein, wenn die Kosten einer genaueren Lösung ihren Nutzen übersteigen.

**Unschärfe Mengen** Zur Behandlung von Vagheit verwendet man gewöhnlich eine Theorie der „unscharfen Mengen“, wobei die Theorie der „groben“ oder „ungenauen Mengen“ (rough sets) [12] und die Theorie der oder Fuzzy-Mengen (fuzzy sets) [17] am bekanntesten sind.

Eine „grobe Menge“ (rough set) besteht eigentlich aus zwei ineinandergeschachtelten Mengen: Einer inneren, die die sicher oder notwendig unter einen Begriff fallenden Objekte bzw. Situationen enthält, und einer äußeren, die die möglicherweise unter einen Begriff fallenden Objekte bzw. Situationen enthält. Auf diese Weise wird die Penumbra eines vagen Begriffs beschrieben: Sie besteht aus den Elementen der Differenz der äußeren und der inneren Menge. Aus dieser Beschreibung kann man auch ablesen, daß die Theorie der „rough sets“ offenbar mit der Modallogik (siehe oben) eng verwandt ist.

Die Theorie der Fuzzy-Mengen geht noch einen Schritt weiter als die Theorie der „rough sets“. In ihr werden die Elemente der Penumbra nicht nur identifiziert, sondern es wird ihnen außerdem ein *Zugehörigkeitsgrad* zugeschrieben, mit dem sie zu der unscharfen Menge der unter den betrachteten Begriff fallenden Objekte bzw. Situationen gehören. Durch diese Zugehörigkeitsgrade ist es möglich, Vagheit zu quantifizieren, doch handelt man sich durch ihre Einführung auch ein schwieriges Problem ein: Denn es ist nicht ohne weiteres klar, welche genaue Bedeutung man einem Zugehörigkeitsgrad geben soll. Trotz umfangreicher Untersuchungen in dieser Richtung ist die Semantik der Zugehörigkeitsgrade nach wie vor eines der Hauptprobleme der Fuzzy-Mengentheorie.

Diese semantischen Probleme verhinderten jedoch nicht den Erfolg der Fuzzy-Mengentheorie in der Regelungstechnik, was i.w. daran liegt, daß die hier verwendeten „Regelsysteme“ (die, auch wenn sie mit „Wenn . . . , dann . . .“ Aussagen arbeiten, nicht als Regelsysteme im Sinne der Logik gesehen werden sollten), als Interpolationsmethode interpretiert werden können, durch die ein punktweise angegebenes Kennfeld eines Reglers vervollständigt wird.

## 4 Forschungsthemen

**Erweiterungen der Logik** Nach dem Fehlschlag des Sicherheitsfaktorenansatzes (siehe oben) verfolgte man in der Logik i.w. zwei Ansätze. Der erste besteht darin, die Unsicherheitsmodellierung auf die Wahrscheinlich-

keitstheorie zu gründen und die impliziten Unabhängigkeitsannahmen dadurch zu behandeln, daß man nicht mit Punktwahrscheinlichkeiten sondern mit Wahrscheinlichkeitsintervallen arbeitet, die dann den logischen Aussagen zugeordnet werden [6, 16]. Die Hauptschwierigkeit dieses Ansatzes besteht darin, die Wahrscheinlichkeitsintervalle klein zu halten, da zu große Intervalle den Nutzen der Modellierung mindern, weil sie u.U. für eine Entscheidungsfindung zu unspezifisch sind. Dies gelingt jedoch nicht immer, da eben möglicherweise bestehende Abhängigkeiten berücksichtigt werden müssen, die eine verlässliche Einschränkung der Intervalle verhindern.

Der zweite Ansatz verzichtet auf eine Quantisierung der Sicherheit bzw. Möglichkeit einer Aussage und beschränkt sich auf eine qualitative Beschreibung durch nichtmonotone Logiken [1]. Unter diesen sind besonders die verschiedenen Spielarten der Default-Logik von Interesse, mit denen man versucht, oft (aber eben nicht immer) richtige Schlußfolgerungen zu ermöglichen, solange keine explizite gegenteilige Information vorliegt. Beispielsweise möchte man aus der Tatsache, daß Tweety ein Vogel ist, folgern, daß Tweety fliegen kann, solange nicht explizit bekannt ist, daß Tweety ein Pinguin oder ein Strauß ist.

Die Hauptprobleme der Default-Logiken sind ihre Operationalisierung, d.h., wie sich die bei gegebenen Beobachtungen und Defaults möglichen Schlußfolgerungen effizient berechnen lassen, sowie Probleme, die sich dadurch ergeben, daß die einfachen Logiken dieser Art keine Möglichkeit bieten, Präferenzen zwischen Default-Regeln auszudrücken. Letztere versucht man dadurch zu beheben, daß man eine Rangfolge von Aussagenmengen einführt, wobei Aussagen aus in der Rangfolge tiefer stehenden Mengen eher aufgegeben werden als Aussagen aus in der Rangfolge höher stehenden Mengen [1]. Aber auch in diesen Ansätzen scheint das Problem der impliziten Unabhängigkeitsannahmen noch nicht vollständig gelöst.

**Graphische Modelle** Da heuristische Ansätze oft an impliziten Unabhängigkeitsannahmen scheitern (vgl. z.B. den oben erwähnten Sicherheitsfaktorenansatz), wandte man sich in der Wahrscheinlichkeitstheorie der expliziten Modellierung bestehender Abhängigkeiten und Unabhängigkeiten von Variablen zu, wobei sich die Theorie der graphischen Modelle [13, 9, 2] als sehr vielversprechend erwies. Besonders durch die Verknüpfung dieses Ansatzes mit einer kausalen Modellierung durch Pearl [13] führte zu einem starken Aufschwung dieser Forschungsrichtung. Heute sind graphische Modelle eine der populärsten Methoden zur Modellierung wissensbasierter Systeme und Gegenstand intensiver Forschung.

Die wesentliche Idee der graphische Modelle ist, daß sich unter bestimmten Bedingungen (insbesondere, wenn bestimmte Unabhängigkeiten gelten) hochdimensionale Verteilungen in (ggf. überlappende) Verteilungen auf niedrigdimensionalen Unterräumen zerlegen lassen. Diese Zerlegung kann bequem durch einen Graphen über den verwendeten Variablen beschrieben werden, der die (bedingten) Abhängigkeiten und Unabhängigkeiten darstellt. Außerdem gibt der Graph die Pfade an, auf denen durch Beobachtung gewonnene Informationen übertragen werden

müssen, um Schlußfolgerungen über die Werte unbeobachteter Variablen zu ziehen. Der große Vorteil der graphischen Modelle ist, daß sie eine saubere mathematische Grundlage besitzen und zu korrekten und dennoch effizienten Evidenzpropagationsalgorithmen führen.

Abschließend sei erwähnt, daß sich graphische Modelle nicht nur auf der Wahrscheinlichkeitstheorie, sondern auch z.B. auf der Possibilitätstheorie aufbauen lassen, wodurch man in die Lage versetzt wird, auch mit gleichzeitig impräzisen und unsicheren Informationen umzugehen [5].

**Lernen aus Daten** Durch die rasante Entwicklung der Computertechnik in den vergangenen Jahren ist es heute möglich, riesige Datenmengen zu sehr geringen Kosten zu sammeln, zu übertragen und zu speichern. Es stellte sich dann aber heraus, daß Daten allein nicht ausreichen, es aber sehr schwer ist, aus diesen Daten das ggf. verborgene Wissen (in Form von Regelmäßigkeiten, Mustern etc.) herauszuziehen. Als Antwort auf diese Herausforderung entwickelten sich die neuen Forschungsgebiete des Data Mining und der Wissensentdeckung in Datenbanken (Knowledge Discovery in Databases).

Diese Entwicklung beeinflusste natürlich auch die Forschung im Bereich Unsicherheit und Vagheit, und zwar unabhängig von der Modellierungsmethode. So versucht man etwa im Bereich der induktiven logischen Programmierung [10] logische Regeln aus Daten zu gewinnen, die u.U. nicht sicher, aber doch mit hoher Wahrscheinlichkeit gelten. Spätestens mit [3, 8] wandte man sich verstärkt dem Lernen (probabilistischer) graphischer Modelle aus Daten zu und konnte beachtliche Erfolge erzielen. Und im Bereich der Fuzzy-Theorie wurden verschiedene Kopplungen von neuronalen Netzen und Fuzzy-Systemen entwickelt (sogenannte Neuro-Fuzzy-Systeme) mit denen sich Fuzzy-Regelsysteme aus Daten lernen lassen [11].

## 5 Zusammenfassung

Speziell die Erfahrungen mit dem Sicherheitsfaktorenansatz haben gezeigt, daß heuristisch motivierte Erweiterungen der klassischen Logik nicht ausreichen, um Unsicherheit zu modellieren, da sie starke implizite Unabhängigkeitsannahmen machen. Die daraus erwachsenden Probleme kann man zwar vermeiden, indem man sich auf Wahrscheinlichkeitsintervalle zur Beschreibung der Gültigkeit von Formeln zurückzieht, doch ist es nicht leicht, die Intervalle so klein zu halten, daß die durch sie dargestellte Information noch nützlich ist.

Erfolgversprechender ist u.U. der Ansatz der nichtmonotonen Logiken, speziell der Default-Logiken, mit denen nur eine qualitative Behandlung von Unsicherheit angestrebt wird. Sie lassen sich ggf. erweitern, um auch Präferenzen zwischen Aussagen darzustellen. Allerdings sind auch hier die Probleme der impliziten Unabhängigkeitsannahmen noch nicht vollständig gelöst.

Am populärsten sind daher gegenwärtig wahrscheinlichkeitstheoretische Ansätze im Bereich der graphischen Modellierung, bei der auf die bestehenden Abhängigkeiten und Unabhängigkeiten explizit Rücksicht genommen wird.

Diese Richtung gewinnt, nicht zuletzt wegen ihrer sauberen mathematischen Grundlage, zunehmend an Boden.

Zur Behandlung von Vagheit ist die Fuzzy-Mengen-theorie weitgehend unangefochten. Trotz des kommerziellen Erfolges von Fuzzy-Methoden durch Anwendungen in der Regelungstechnik (oder vielleicht gerade wegen dieses Erfolges, der bestimmte Fragen nicht aufkommen ließ), krankt die Fuzzy-Theorie aber immer noch an einer unzureichend definierten Semantik der Zugehörigkeitsgrade, was für einen Einsatz von Fuzzy-Methoden in wissensbasierten Systemen etwas hinderlich ist.

Die aktuelle Forschung beschäftigt sich in allen angesprochenen Bereichen verstärkt mit dem Lernen von Modellen aus Daten (Data Mining, Knowledge Discovery in Databases), da die manuelle Erstellung von wissensbasierten Systemen oft aufwendig und langwierig ist.

## Literatur

- [1] G. Brewka. Kapitel 7: Nichtmonotones Schließen. *Handbuch der Künstlichen Intelligenz*, 237–266. Oldenbourg, München 2000
- [2] E. Castillo, J.M. Gutierrez und A.S. Hadi. *Expert Systems and Probabilistic Network Models*. Springer, New York, NY, USA 1997
- [3] G.F. Cooper und E. Herskovits. A Bayesian Method for the Induction of Probabilistic Networks from Data. *Machine Learning* 9:309–347. Kluwer, Dordrecht, Niederlande 1992
- [4] D. Dubois und H. Prade. *Possibility Theory*. Plenum Press, New York, NY, USA 1988
- [5] J. Gebhardt and R. Kruse. POSSINFER — A Software Tool for Possibilistic Inference. In: D. Dubois, H. Prade, R. Yager, eds. *Fuzzy Set Methods in Information Engineering: A Guided Tour of Applications*, 407–418. J. Wiley & Sons, New York, NY, USA 1996
- [6] U. Güntzer, W. Kießling, H. Thöne. New Directions for Uncertainty Reasoning in Deductive Databases. *Proc. ACM SIGMOD Conference*, 178–187. Denver, CO, USA 1991
- [7] D.E. Heckerman. Probabilistic Interpretations for MYCIN's Certainty Factors. In: L.N. Kanal und J.F. Lemmer. *Uncertainty in Artificial Intelligence*. North-Holland, Amsterdam, Niederlande 1986
- [8] D. Heckerman, D. Geiger und D.M. Chickering. Learning Bayesian Networks: The Combination of Knowledge and Statistical Data. *Machine Learning* 20:197–243. Kluwer, Dordrecht, Niederlande 1995
- [9] S.L. Lauritzen. *Graphical Models*. Oxford University Press, Oxford, Großbritannien 1996
- [10] S. Muggleton, ed. *Inductive Logic Programming*. Academic Press, San Diego, CA, USA 1992
- [11] D. Nauck, F. Klawonn, and R. Kruse. *Foundations of Neuro-Fuzzy Systems*. J. Wiley & Sons, Chichester, United Kingdom 1997
- [12] Z. Pawlak. *Rough Sets — Theoretical Aspects of Reasoning about Data*. Kluwer, Dordrecht, Netherlands 1991
- [13] J. Pearl. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann, San Mateo, CA, USA 1988 (2nd edition 1992)
- [14] E.H. Shortliffe und B.G. Buchanan. A Model for Inexact Reasoning in Medicine. *Mathematical Biosciences* 23:351–379, 1975
- [15] E.H. Shortliffe. *Computer Based Medical Consultations: MYCIN*. Elsevier, New York, NY, USA 1976
- [16] H. Thöne, W. Kießling, U. Güntzer. Towards Precision of Probabilistic Bounds Propagation. *Proc. 8th Conf. on Uncertainty in Artificial Intelligence*, 315–322. Stanford University, CA, USA 1992
- [17] L.A. Zadeh. Fuzzy Sets. *Information and Control* 8:338–353, 1965. Academic Press, San Diego, CA, USA 1965
- [18] L.A. Zadeh. The Concept of a Linguistic Variable and Its Application to Approximate Reasoning. *Information Sciences* 9:43–80. 1975

**Christian Borgelt** studierte Informatik an der Technischen Universität Braunschweig und promovierte an der Otto-von-Guericke-Universität Magdeburg mit einer Arbeit über das Lernen graphischer Modelle aus Daten.

**Rudolf Kruse** studierte Mathematik an der Technischen Universität Braunschweig, und promovierte und habilitierte sich dort mit Arbeiten über Statistik mit vagen Daten. Von 1986 bis 1996 war er Professor für Informatik in Braunschweig, seit 1996 hat er einen Lehrstuhl für praktische Informatik an der Otto-von-Guericke-Universität Magdeburg inne.

Otto-von-Guericke-Universität Magdeburg  
Institut für Wissens- und Sprachverarbeitung  
Universitätsplatz 2, D-39106 Magdeburg  
E-mail: {borgelt,kruse}@iws.cs.uni-magdeburg.de