

# Visualisierung Bayesscher Netze zur Diagnoseunterstützung

Dipl.-Inform. **Matthias Steinbrecher** und Prof. Dr. **Rudolf Kruse**,  
Otto-von-Guericke-Universität Magdeburg

## Kurzfassung

Bayessche Netze [7, 8, 5] haben sich in der Vergangenheit als sehr leistungsfähige Methode erwiesen, um in großen Datenmengen Abhängigkeiten und Zusammenhänge mithilfe ihrer inhärenten Graphenstruktur darzustellen und abzuleiten. Allerdings werden durch diese globale – rein strukturelle – Sichtweise nicht alle Auffälligkeiten erkennbar. Es wird in diesem Aufsatz daher eine Methode motiviert, die es ermöglicht, die lokale Komponente eines Bayesschen Netzes – die bedingten Wahrscheinlichkeitsverteilungen – zu visualisieren.

## 1 Einleitung

Damit heutige Industrieunternehmen im globalen Wettbewerb bestehen können, müssen Innovationen immer schneller zu marktreifen Produkten entwickelt werden. Eine damit einhergehende Verkürzung der Produktionszyklen macht eine intensivere produktbegleitende Analyse und Diagnose notwendig, um Qualitätsprobleme frühzeitig zu erkennen und gegebenenfalls sehr zeitnah zu reagieren.

Die für eine lebenszyklusbegleitende Diagnose notwendigen Datenmengen sind nur noch unter Einsatz speziell zugeschnittener Data-Mining-Lösungen zu analysieren. Eine prominente Technik stellen die Bayesschen Netze [7, 8, 5] dar, die auf sehr intuitive Weise Abhängigkeiten zwischen Einflussgrößen und anderen Variablen darstellen können. Diese Abhängigkeiten können sowohl von Experten vorgegeben als auch automatisch aus vorhandenen Daten extrahiert werden [4, 6, 9, 2]. In der vorliegenden Anwendung werden beide Ansätze kombiniert: Dem Experten wird ein aus Daten induziertes Netz gezeigt, in welchem er Abhängigkeiten hinzufügen oder entfernen kann, um bestimmte Szenarien zu veranschaulichen.

Abschnitt 2 gibt einen Einblick in die hier verwendeten Konzepte Bayesscher Netze, während in Abschnitt 3 die Visualisierung motiviert und vorgestellt wird. Abschnitt 4 zeigt konkrete Anwendungsbeispiele bevor Abschnitt 5 einen Ausblick auf mögliche Erweiterungen gibt.

## 2 Grundlagen

Als zugrunde liegende Datenbasis  $D$  werde eine Tabelle angenommen, welche  $n$  Spalten und  $N$  Zeilen besitzt. Jede Spalte symbolisiert ein Attribut  $A_i$  ( $1 \leq i \leq n$ ), das für jedes Tupel  $t \in D$  jeweils einen diskreten Wert aus dem endlichen Wertebereich

$$\text{dom}(A_i) = \{a_{i1}, \dots, a_{in_i}\} \text{ für alle } 1 \leq i \leq n$$

annimmt:  $A_i(t) = a_{ik}$ . Jede Zeile entspricht einem Tupel  $t_h$  ( $1 \leq h \leq N$ ), welches ein Objekt des Anwendungsszenarios modelliert.

Möchte man bestimmte Abhängigkeiten der Attribute untereinander kodieren, so wird hierzu eine (gerichtete, azyklische) Graphenstruktur verwendet, deren Knoten den Attributen entsprechen. In der hier verwendeten Erläuterung seien die Kanten von Experten eingefügt worden, um einen kausalen Zusammenhang zu modellieren. Wurden die Kanten hingegen automatisch aus einer Datenbasis induziert, ist diese Interpretation natürlich nicht mehr gegeben!

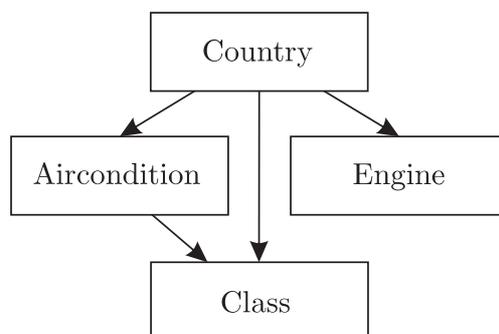


Bild 1: Ein einfaches Bayessches Netz mit drei Einflussgrößen und einer Klassenvariable.

Ein stark vereinfachtes Bayessches Netz ist in Bild 1 zu sehen. Es handelt sich um ein fiktives Szenario, wie es etwa in einem Automobilkonzern Anwendung finden könnte. Man erkennt das Zusammenspiel dreier Einflussgrößen (*Country*, *Aircondition* und *Engine*) und einer Klassenvariable, die in diesem Beispiel als zweiwertig betrachtet werden soll und angibt, ob ein Fahrzeug schadhaft ist oder nicht. Das abgebildete Bayessche Netz sei mithilfe eines

Lernverfahrens aus den Daten erzeugt worden, die das betreffende Unternehmen pflegt. In der vorgestellten Anwendung wurde der K2-Algorithmus [3] verwendet.

Der Graph in Bild 1 wird auch als globale oder qualitative Komponente eines Bayesschen Netzes bezeichnet und eröffnet dem Techniker schon erste wertvolle Einblicke in den zugrunde liegenden Problembereich. Beispielsweise hat das Land, in das ein Fahrzeug verkauft wurde (*Country*) und der Typ der verbauten Klimaanlage (*Aircondition*) einen Einfluss auf die Art des Schadens (*Class*).

Allerdings sind wichtige Informationen aus einer reinen Graphenstruktur nicht abzulesen: Welche Kombinationen von Einflussgrößen (hier: welches genaue Land und welche genauen Klimaanlagearten) haben was für einen Einfluss auf die Klassenvariable? Diese Informationen sind in der lokalen oder quantitativen Komponente eines Bayesschen Netzes kodiert.

Diese Elemente der lokalen Komponente lassen sich für Teilnetze sehr einfach aus der gegebenen Datenbasis schätzen: Ein Teilgraph bestehend aus einem Knoten von Interesse und seinen direkten Elternknoten kodiert eine Menge von bedingten Wahrscheinlichkeitsverteilungen. Aus Bild 1 lassen sich mithilfe der Graphenstruktur aus der Datenbasis beispielsweise die Verteilungen

$$P_D(\textit{Class} \mid \textit{Aircondition}, \textit{Country})$$

ableiten. Hierfür wird für jede konkrete Kombination von Werten für *Aircondition* und *Country* die relative Häufigkeit für das Attribut *Class* aus den Daten geschätzt. Genau diese Verteilungen sind es, die dem Nutzer wertvolle Aufschlüsse über den Zusammenhang zwischen Attributen geben und für die eine Visualisierung vorgeschlagen wird.

### 3 Visualisierung diskreter bedingter Wahrscheinlichkeitsverteilungen

Betrachtet man einen Eintrag der oben genannten Beispielverteilung genauer, lassen sich im Wesentlichen drei verschiedene Aspekte benennen, an denen ein Anwender im Rahmen einer Untersuchung eines Attributes interessiert ist:

- Welche genauen Werte der Bedingungsattribute haben einen besonderen Einfluss auf das Zielattribut?
- Welcher Wert des Zielattributes wird besonders beeinflusst?
- In welcher Weise macht sich der Zusammenhang bemerkbar?

Beispielsweise könnte ein fiktiver Fehler im obigen Szenario lauten: „Fahrzeuge, die nach Ägypten verkauft wurden und den Klimaanlageentyp KA1 besitzen, fallen doppelt so häufig aus, wie der Durchschnitt.“

Es sei  $C$  das Attribut von Interesse und  $A_1, \dots, A_m$  seine direkten Vorgänger, das heißt seine Bedingungsattribute. Die Einträge der Verteilungen  $P(C | A_1, \dots, A_m)$  können dann als Assoziationsregeln [1] interpretiert werden: Sei  $C = \text{Class}$  und  $A_1 = \text{Aircondition}$ , sowie  $A_2 = \text{Country}$ , dann lautet die obige Aussage wie folgt:

$$p^* = P(\text{schadhaft} | A_1 = \text{KA1}, A_2 = \text{AEG}) = 2 \cdot P(\text{Class} = \text{schadhaft})$$

In Regelform ausgedrückt erhält man:

„Wenn  $A_1 = \text{KA1} \wedge A_2 = \text{AEG}$ , dann  $C = \text{schadhaft}$  mit Konfidenz  $p^*$ .“

Aufgrund dieses Zusammenhangs lassen sich unmittelbar sämtliche Bewertungsmaße [10] für Assoziationsregeln auf die Einträge der bedingten Verteilungen anwenden. Um nun diese Einträge graphisch darzustellen, wird nach folgendem Schema verfahren:

- Für jeden Eintrag der bedingten Verteilungen  $P(C | A_1, \dots, A_m)$  wird ein Kreis generiert, der später in einem zweidimensionalen Diagramm positioniert werden soll.
- Die Farbe eines Kreises korrespondiert mit dem Wert des Attributs  $C$ .
- Die Fläche jeder dieser Kreise entspricht dem Wert eines vorher ausgewählten Bewertungsmaßes. In diesem Beispiel wählen wir den sog. Support, also die (relative) Anzahl von Instanzen, die der jeweiligen Attributwertkombination des Eintrages entsprechen. Somit korrespondiert die Größe des Kreises direkt mit der Anzahl von Instanzen, die er abdeckt.
- In einem letzten Schritt werden die eben erstellten Kreise positioniert. Die Werte für die x- und y-Koordinaten werden wieder von vorher festgelegten Bewertungsmaßen bestimmt. Im Beispiel seien dies Recall<sup>1</sup> und Lift<sup>2</sup>.

---

<sup>1</sup> Der Recall einer Assoziationsregel ist mit  $P(A_1 = a_{1l_1}, \dots, A_m = a_{ml_m} | C = c)$  definiert.

<sup>2</sup> Der Lift zeigt an, um welches Vielfache die Wahrscheinlichkeit für  $C = c$  steigt, wenn die Bedingung  $A_1 = a_{1l_1}, \dots, A_m = a_{ml_m}$  bekannt ist im Vergleich zu  $P(C = c)$ .

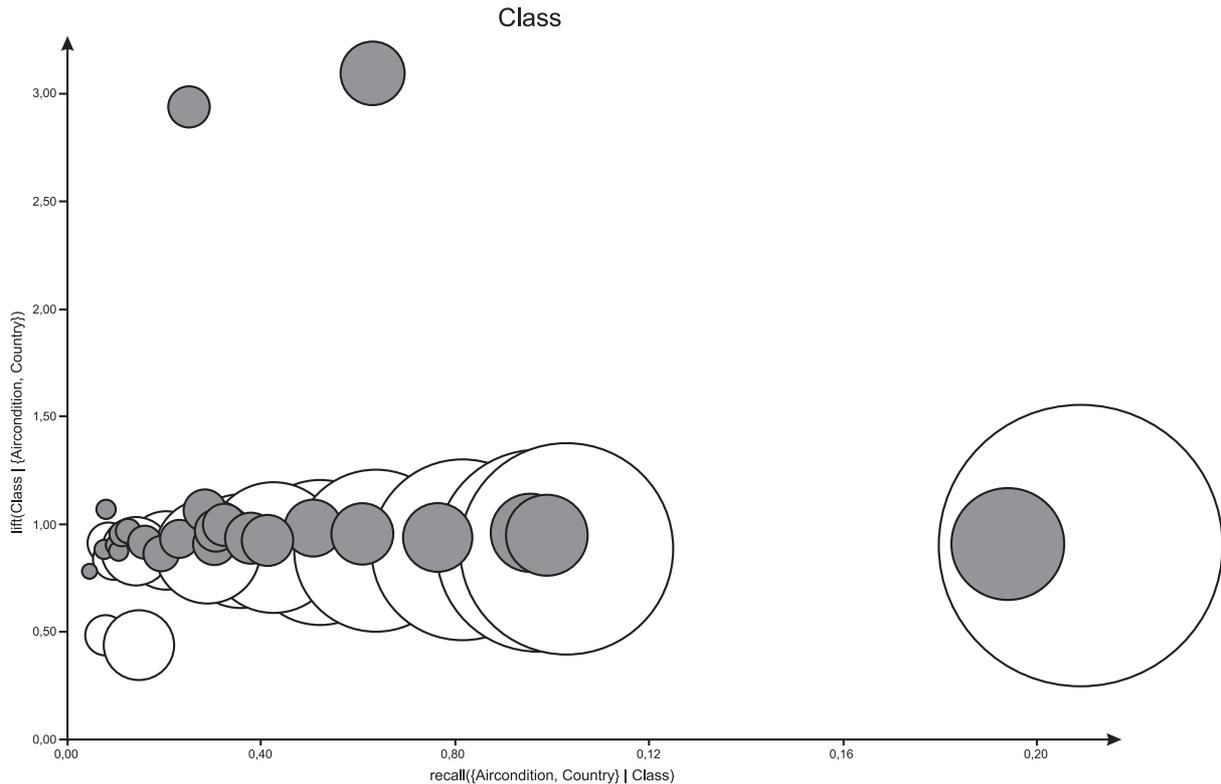


Bild 2: Die beiden grauen Kreise am oberen Bildrand symbolisieren eine Menge von Fahrzeugen, deren Ausfallquote signifikant über dem Durchschnitt liegt. Selbstverständlich können die genauen Werte (Ausfallquote, Anzahl der Fahrzeuge, gemeinsame Einflussgrößenwerte) in der entwickelten Anwendung für jede dargestellte Menge abgerufen werden.

In Bild 2 ist ein auf dem oben angegebenen Netz basierender Datensatz dargestellt. Das Klassenattribut wurde farblich kodiert (weiß entspricht *okay*, grau *schadhaft*). Das Attribut *Country* hatte fünf Ausprägungen (Island, Norwegen, Oman, Ägypten, Deutschland), *Engine* drei (*M1* bis *M3*) und *Aircondition* konnte fünf Werte (*KA1* bis *KA5*) annehmen. Die zu findende Auffälligkeit betraf das häufigere Ausfallen des Klimaanlageagentyps *KA1* in Ägypten und Oman.

Genau diesen beiden Konstellationen entsprechen die beiden grauen Kreise am oberen Rand des Diagramms in Bild 2. Bei der aktuellen Wahl der Bewertungsmaße für Koordinatenachsen und Kreisfläche lässt sich eine für Anwender einfache Analyseheuristik dieser Darstellungen angeben:

„Große Fahrzeugmengen weit oben rechts im Diagramm sind auffällig.“

Je weiter oben sich ein Kreis befindet, desto höher ist der Lift der zugehörigen Assoziationsregel. Eine Lage im rechten Teil des Diagramms bedeutet einen größeren Recall und die Kreisgröße lässt auf die Anzahl der betroffenen Fahrzeuge schließen.

#### 4 Praktischer Einsatz

Es sollen nun einige Beispielanalysen aus Realdaten vorgestellt werden, um die Anwendbarkeit der gezeigten Visualisierung zu demonstrieren. Es handelt sich um Fahrzeugdaten eines großen Automobilkonzerns. Die Attributnamen sind aus Datenschutzgründen anonymisiert bzw. vereinfacht.

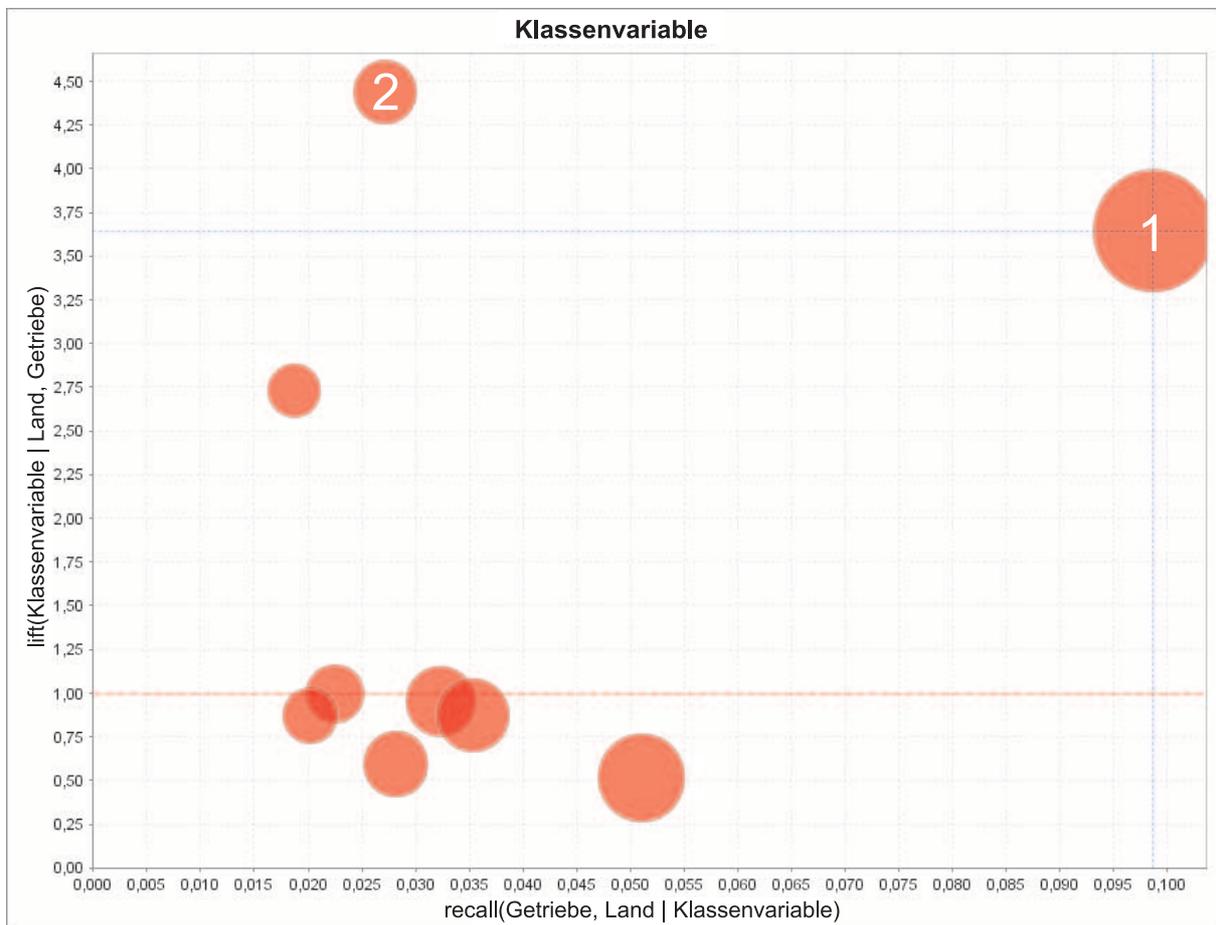


Bild 3: Die mit „1“ markierte Menge entspricht ca. 1000 Fahrzeugen, deren Attributwerte für *Land* und *Getriebe* einen kausalen Zusammenhang mit der Klassenvariable ergeben. Für Menge „2“ wurde keine solche Erklärung gefunden.

Bild 3 zeigt das Ergebnis einer Analyse von 60000 Fahrzeugen. Aus Gründen der Übersichtlichkeit wurden nur schadhafte Fahrzeuge dargestellt. Zur eigentlichen Analyse wurden selbstverständlich alle Fahrzeugbeschreibungen verwendet. Die beiden Bedingungsattribute mit maßgeblichem (stochastischen) Einfluss auf die Klassenzugehörigkeit sind *Getriebe* und *Land*. Es fallen die beiden mit „1“ und „2“ markierten Fahrzeugmengen auf. Für die Menge „1“ konnte durch Experten ein kausaler Zusammenhang aufgrund der Werte der Bedingungsattribute nachgewiesen werden. Für die Menge „2“ konnte leider keine kausale Bedeutung gefunden werden.

Ein weiteres Beispiel soll zeigen, dass auch geringe Fahrzeugmengen im Diagramm erkannt werden können, selbst wenn der Lift nicht maximal ist. In Bild 4 wurden ca. 300000 Fahrzeuge analysiert. Die unterschiedliche Einfärbung der Mengen begründet sich in der großen Anzahl von Werten für die Klassenvariable (über 3000). Obwohl für die Mengen „3“ keine Erklärung (in Bezug auf die Attribute *Geländart* und *Laufleistung*) gefunden werden konnte, so ließ sich die mit „4“ bezeichnete Menge von ca. 900 Fahrzeugen identifizieren, deren Ausfallquote auf die entsprechenden Attributwert für *Geländart* und *Laufleistung* zurückzuführen war.

## 5 Zusammenfassung und Ausblick

Im vorliegenden Aufsatz wurde ausgehend von einer anwenderorientierten Sichtweise auf die Konzepte Bayesscher Netze die Verbindung zu Assoziationsregeln erschlossen, mithilfe derer sich eine intuitive Visualisierungsform umsetzen ließ. Die Darstellung ermöglicht es, mit einfachen Heuristiken aus einer umfangreichen Datenbasis auffällige Teilmengen zu lokalisieren. Zwei Beispiele aus einer Kooperation mit einem Industriepartner dienten als Beispiel dafür, dass die vorgestellte Visualisierung einen Beitrag zur effizienteren Fehleranalyse leisten kann.

Die verwendeten Datenquellen waren in allen Beispielen statisch und zeigten jeweils nur einen Zustand der Datenbank zu einem gegebenen fixen Zeitpunkt (eben dem Zeitpunkt des Erstellens der Datensicht). In der Praxis werden gerade bei produktbegleitenden Datensammlungen über längere Zeiträume hinweg Informationen erhoben, die dann in Form von Zeitreihen vorliegen. Soll diese temporale Komponente in die Darstellung einfließen, könnten beispielsweise nicht die Bewertungsmaße selbst, sondern deren Ableitungen nach der Zeit als Achsenmaße verwendet werden.

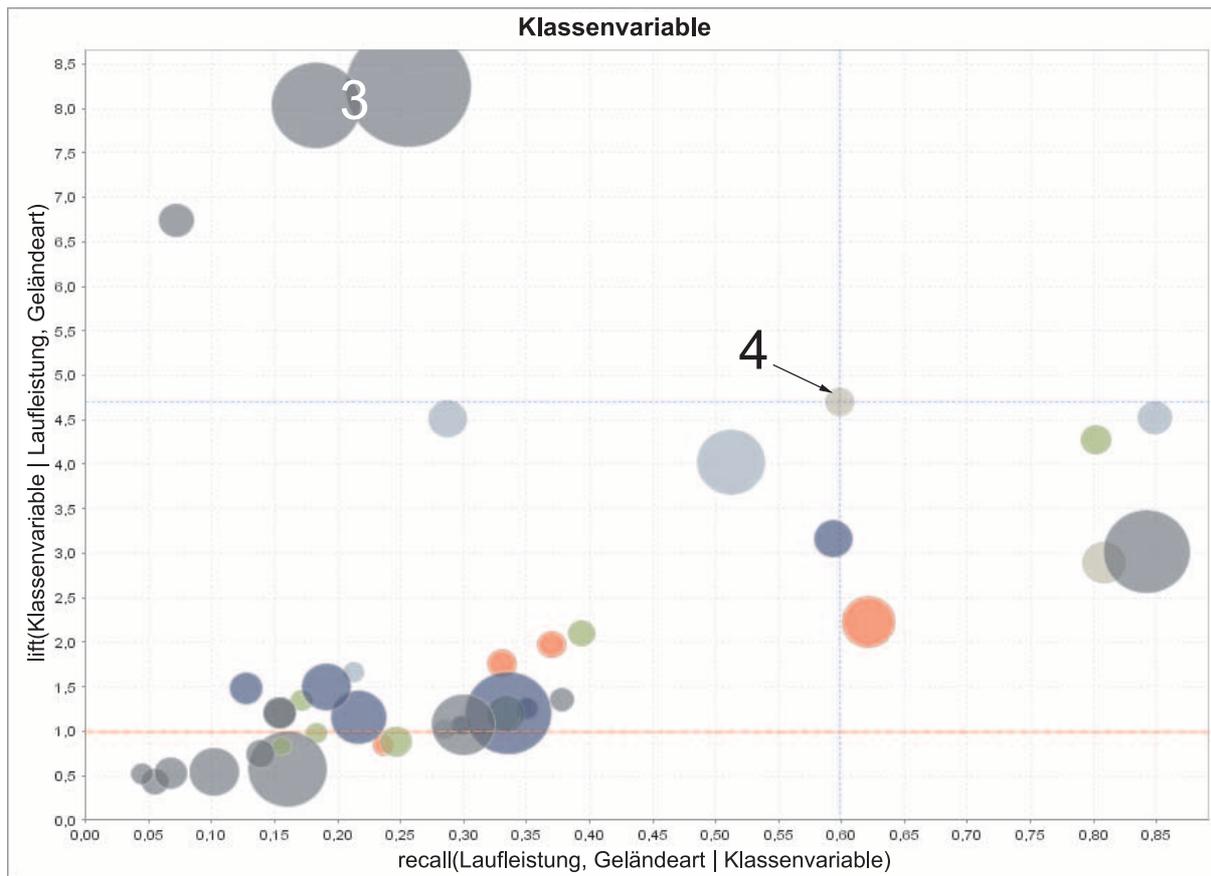


Bild 4 Obwohl die Mengen „3“ keinerlei Aufschluss bot, konnte mit Menge „4“ ein kausaler Fehlfunktionszusammenhang nachgewiesen werden.

### Literatur

- [1] R. Agrawal, T. Imielinski und A. Swami. Mining Association Rules Between Sets of Items in Large Databases, 1993.
- [2] Ch. Borgelt und R. Kruse. Graphical Models – Methods for Data Analysis and Mining. John Wiley & Sons, United Kingdom, 2002.
- [3] G. F. Cooper und E. Herskovits. A Bayesian Method for the Induction of Probabilistic Networks from Data, 1992.
- [4] D. Heckerman. A Tutorial on Learning with Bayesian Networks. Technical Report MSR-TR-95-06, Microsoft Research, Advanced Technology Division, Redmond, WA, 1995. Revised June 1996.
- [5] D. Heckerman, D. Geiger und D. M. Chickering. Learning Bayesian Networks: The Combination of Knowledge and Statistical Data. Technical Report MSR-TR-94-09, Microsoft Research, Advanced Technology Division, Redmond, WA, 1994. Revised February 1995.

- [6] P. Larrañaga, M. Poza, Y. Yurramendi, R. H. Murga und C. M. H. Kuijpers. Structure Learning of Bayesian Networks by Genetic Algorithms: A Performance Analysis of Control Parameters. *IEEE Journal on Pattern Analysis and Machine Intelligence*, 18(9): 912-926, 1996.
- [7] J. Pearl. Aspects of Graphical Models Connected with Causality. In 49<sup>th</sup> Session of the International Statistics Institute, 1993.
- [8] J. Pearl und S. Russel. *Bayesian Networks*, 1994.
- [9] Th. Verma und J. Pearl. An Algorithm for Deciding if a Set of Observed Independencies has a Causal Explanation. In *Proceedings of the 8<sup>th</sup> conference on Uncertainty in Artificial Intelligence*, 323-330, San Francisco, CA, USA, Morgan Kaufmann Publishers Inc., 1992.
- [10] Y. Y. Yao und N. Zhong. An Analysis of Quantitative Measures Associated with Rules. In *Methodologies for Knowledge Discovery and Data Mining*. Springer Verlag Berlin, 1999.