

AUTOMATISIERTE ERSTELLUNG UNTERNEHMENSSEZIFISCHER KLASSIFIKATIONSSYSTEME

Stefan Sander, Jörg Weißkopf

Zusammenfassung

Angesichts steigenden Wettbewerbsdrucks und zunehmender Globalisierung kommt der schnellen Verfügbarkeit von Informationen zunehmend strategische Bedeutung zu. Durch die sich ständig verkürzenden Produktentwicklungszeiten sowie den massiven Einsatz rechnergestützter Verfahren steigt die Menge der verfügbaren Informationen sehr stark an. Die Produktion immer neuen Wissens führt jedoch ohne eine Systematisierung des vorhandenen Wissens in eine Sackgasse, da die jeweils relevanten Informationen in der ständig wachsenden Flut an Daten mit vertretbarem Aufwand nicht mehr auffindbar sind. Aus diesem Grund gebührt der Systematisierung von Wissen der gleiche wissenschaftliche Rang wie der originären Forschung.

Vor diesem Hintergrund wird derzeit unter der Koordination des Instituts für Rechneranwendung in Planung und Konstruktion (RPK), Universität Karlsruhe (TU) das Verbundprojekt „Automatisierte Erstellung und Pflege unternehmensspezifischer Klassifikationssysteme in heterogenen Datenlandschaften“ (Kurztitel: KLAUSTER: Klassifikationssysteme automatisiert erstellen) durchgeführt. Das Projekt wird gefördert durch das Bundesministerium für Forschung und Technologie im Rahmen des Förderprogramms „PRO*morgen“, Projektträger des Verbundprojektes ist die Projektträgerschaft Produktion und Fertigungstechnologien, PFT Forschungszentrum Karlsruhe. Verbundprojektspartner sind die Firmen Paradine Deutschland GmbH, AUCOTEAM GmbH, MAN Turbomaschinen AG GHH BORSIG, PASIO GmbH und Vectriz Solutions GmbH.

Ziel des Verbundprojektes ist die Entwicklung von Verfahren und Werkzeugen, mit deren Hilfe es möglich ist, Tätigkeiten bei der Erstellung und Anpassung unternehmensspezifischer Klassifikationssysteme - schwerpunktmäßig produzierender Unternehmen im Bereich Maschinenbau - zu automatisieren. Hierdurch sollen Fehlerquellen und großer Zeitaufwand der manuellen Erstellung von Klassifikationssystemen vermieden werden. Darüber hinaus soll die Entwicklung unternehmensspezifischer, effizient einsetzbarer Klassifikationssysteme gewährleistet werden. In diesem Beitrag wird der Lösungsansatz dargestellt, der zum Erreichen dieses Zieles verfolgt werden soll. Grundlage des Lösungsansatzes sind klassische Clusteranalyseverfahren, die jedoch um eine Reihe wesentlicher Verfahren und Konzepte erweitert werden müssen.

1 Die Notwendigkeit von Klassifikationssystemen

Bereits frühzeitig wurde erkannt, dass die Klassifikation ein geeignetes Mittel ist, um die Strukturierung großer Datenbestände durchzuführen. Die Notwendigkeit und das Nutzenpotential einer funktionierenden Klassifikation in einem Unternehmen ist allgemein anerkannt. Die meisten Anbieter von Systemen zur Produktdatenverwaltung reagieren hierauf, indem sie in den jeweiligen Systemen die Möglichkeit bieten,

Klassifikationsstrukturen zu definieren und die verwalteten Daten entsprechend dieser Strukturen zu klassifizieren. Beide Tätigkeiten sind jedoch manuell auszuführen, was Fehleranfälligkeit und großen Zeitaufwand nach sich zieht. Insbesondere die manuelle Erstellung und Anpassung unternehmensspezifischer Klassifikationssysteme ist mit großem Zeitaufwand verbunden.

2 Die bestehenden Ansätze zur automatischen Erstellung von Klassifikationssystemen und deren Defizite

Die Klassifikation ist ein anerkanntes Mittel, den Zugriff auf bestehendes Erfahrungswissen in einem Unternehmen zu ermöglichen. Gleichzeitig ist jedoch der Aufwand für die manuelle Erstellung und Pflege eines Klassifikationssystems so hoch, dass viele Unternehmen vor der Einführung zurückschrecken. Daher wurden in der Vergangenheit verschiedene Ansätze mit dem Ziel entwickelt, den Zugriff auf bestehendes Erfahrungswissen zu ermöglichen. Zwei wichtige Ansätze werden im Folgenden kurz vorgestellt.

2.1 Neuronale Netze

Ein künstliches neuronales Netz ist ein informationsverarbeitendes System, welches sich am Vorbild des menschlichen Gehirns orientiert. Es besteht aus einer großen Anzahl von einfachen, stark untereinander vernetzten Prozessoren. Neuronale Netze lernen wie Menschen an Beispielen und werden für bestimmte Aufgaben durch einen Lernprozess trainiert. Wie bei biologischen Neuronalen Netzen besteht der Lernprozess in der Veränderung der synaptischen Verbindungen zwischen den Neuronen [1].

Einer der Vorteile dieses Ansatzes liegt im Lernen anhand von Beispielen. Das neuronale Netz orientiert sich selbst durch Training an seiner Umwelt. Es arbeitet mit dem in Beispielen implizit enthaltenen Wissen, es zeigt Strukturen auf anstatt sie vorgeben zu lassen, es gibt wahrscheinliche Antworten, kann ungenaue oder widersprüchliche Daten handhaben und ergänzt teilweise fehlende Information. Es wird nicht für jedes Problem ein spezielles Programm erstellt, sondern das Netz selber muss im Lernprozess die richtige Konfiguration finden [2].

Die wichtigsten Anwendungsgebiete für neuronale Netze sind Probleme, die zur Lösung eine nichtlineare Modellbildung voraussetzen. Leistungsfähige, auf neuronalen Netzen basierende Problemlösungen gibt es im Bereich der Muster- und Spracherkennung, für Prognoseprobleme, zur Regelung technischer Prozesse sowie für vielfältige Klassifikationsprobleme.

Weitere Beispiele hierfür findet man gleichfalls in der medizinischen Diagnostik (z.B. Tumorerkennung) in der Fertigungskontrolle (z.B. Erkennung von Defekten in Oberflächen), Gesichtserkennung (Zugangskontrollsysteme) oder der Erkennung kritischer Betriebszustände (z.B. elektrischer Bauteile).

Für die automatische Klassifikation von Produktdaten bzw. Teilen in einem Unternehmen sind Ansätze mit neuronalen Netzen nicht geeignet. Neuronale Netze haben ein Black-Box-Verhalten; es können a priori keine Regeln angegeben werden. Außerdem muss das Neuronale Netz bei jeder auch leicht geänderter Problemstellung neu „eingelernt“ werden. Da das Konzept eines Klassifikationssystems in einem Unternehmen jedoch gerade ein solches Regelwerk darstellt, das es umzusetzen gilt, sind für diese Aufgabe lineare Ansätze anzuwenden.

2.2 Clusteranalysen

Bei den Clusteranalysen handelt es sich um mathematisch-statistische, multivariante Verfahren der rechnergestützten Klassifikation von Objekten. Sie eignen sich für Untersuchungen, Vergleiche und die Gruppenbildung von Objekten im mehrdimensionalen Merkmalraum.

In Unternehmen des Maschinenbaus werden Clusteranalysen im CAD-Umfeld zur Teilegruppierung [3], zur Teilefamilienbildung für die Fertigung und Fertigungsvorbereitung [4][5], für die Klassifizierung von Arbeitsplänen und die Strukturierung von Fertigungs- und Montageeinrichtungen verwendet [6].

Die Clusteranalyse verfolgt das Ziel, Klassen von Objekten zu bilden. Alle Objekte innerhalb einer Klasse sollen möglichst ähnlich sind, während die Klassen untereinander so unähnlich wie möglich sein sollen. Die spezifischen Merkmale von Teilen können als resultierende Vektoren in einem mehrdimensionalen Raum betrachtet werden, deren Abstände als Maß für die Gruppenbildung dienen [7]. Für die Klassifizierung werden die interessierenden, für alle Objekte gleichen Merkmale ausgewählt und Daten- und Distanzmatrizen erzeugt.

- Datenmatrix : Da Merkmale in unterschiedlichen Skalierungen (metrisch, nominal, ordinal) und in unterschiedlichen Wertebereichen auftreten können, ist, um sie vergleichbar zu machen, eine Merkmalstransformation bzw. -standardisierung erforderlich. Nach Transformation und Wichtung erhält man eine $n \times m$ -Matrix, in der für alle Elemente "n" die sie auszeichnenden "m" Eigenschaften abgespeichert sind.
- Distanzmatrix : Für alle Bauteile sind sog. Ähnlichkeitskoeffizienten zu berechnen, die ein Maß für die Ähnlichkeit zwischen Bauteilen festlegen.

Das Ergebnis einer Clusteranalyse kann, nach Durchführung von Fusions- oder Teilungsrechnungen, in einem sog. Dendrogramm hierarchisch dargestellt werden.

2.3 Defizite bestehender Ansätze

Die aufgeführten Ansätze bieten adäquate Verfahren zur Ermittlung von Abhängigkeiten in großen Datenbeständen, der Bildung von Objektgruppen und der Bewertung von „Objektähnlichkeiten“. Für die Unterstützung bei der Erstellung effizienter, unternehmensspezifischer Klassifikationssysteme, insbesondere im Maschinenbau, weisen die Methodiken jedoch gravierende Defizite auf:

- Die Bildung von Gruppen ähnlicher Objekte wird zwar unterstützt, nicht jedoch die Ableitung von verständlichen, nachvollziehbaren Regeln, welche die Zugehörigkeit eines Objektes zu einer Gruppe definieren. Die Erweiterung und Pflege wird dadurch erheblich erschwert.
- Die Auswahl klassifikationsrelevanter Merkmale wird nicht oder nur unzureichend unterstützt.
- Abhängigkeiten zwischen Merkmalen werden zwar erkannt, eine Unterstützung bei der Bewertung der Relevanz dieser Abhängigkeiten erfolgt jedoch nicht.

- Gefundene Abhängigkeiten zwischen Merkmalen werden nicht weiter ausgewertet, z.B. zur Gewinnung weiterer, klassifikationsrelevanter Merkmale.
- Die zu analysierenden Datenbestände müssen vor einer Analyse i.d.R. aufwendig aufbereitet werden.
- Die Analyse, Anpassung und Erweiterung bestehender Klassifizierungssysteme wird bislang nicht oder nur unzureichend unterstützt.

Die aufgeführten Defizite führen zu dem Schluss, dass die genannten Methodiken zwar durchaus bei der Entwicklung eines Systems zur automatischen Erstellung von Klassifikationssystemen eingesetzt werden können, jedoch um eine Reihe wesentlicher Verfahren und Konzepte erweitert werden müssen.

3 Der neue Ansatz

3.1 Lösungsansatz

In Bild 1 ist die geplante Architektur des Systems zur automatisierten Erstellung von Klassifikationssystemen dargestellt. Kern des Systems ist ein Klassifizierungsmodul, welches auf Basis flexibel einstellbarer Parameter klassifikationsrelevante Merkmale, Klassendefinitionen und Klassenstrukturen erzeugt. Ein Analysemodul untersucht hierfür zunächst die Datenbestände (Nutzdatenquellen), für die ein Klassifikationssystem erstellt werden soll. Diese Datenbestände können in einer heterogenen Datenlandschaft verteilt sein, z.B. geometrische Informationen aus CAD-Systemen in Verbindung mit Teilstämmen aus einem PDM-System. Die Ergebnisse der Klassifizierung können über eine neutrale Schnittstelle abgerufen und für verschiedene Zwecke weiterverwendet werden, z.B. zur Einrichtung von Sachmerkmal-Leisten in einem PDM-System.

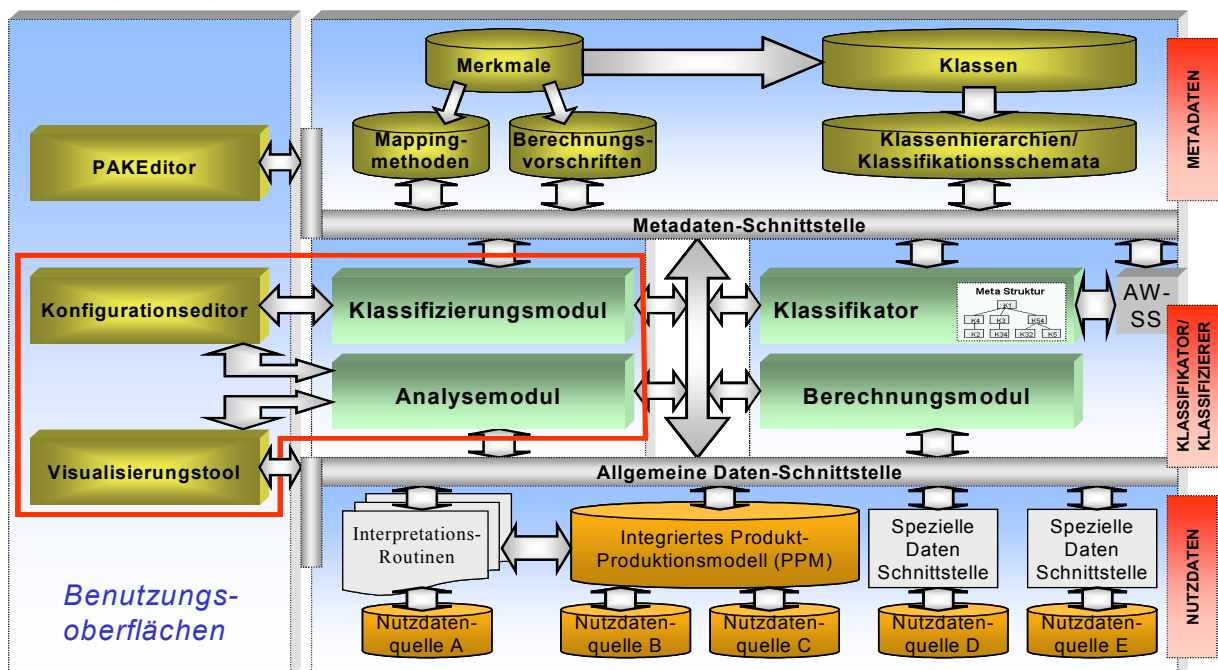


Bild 1: Architektur des Klassifizierungssystems

Das Klassifikatormodul ist in der Lage, mit Hilfe der durch das Klassifizierungsmodul ermittelten Merkmale, Klassendefinitionen und Klassenstrukturen die in den Nutzdatenquellen gespeicherten Produktdaten automatisch zu klassifizieren, d.h. die Objekte automatisch den entsprechenden Klassen zuzuordnen.

Das Klassifizierungsmodul muss eine Reihe von Methoden beinhalten, um aus dem zur Verfügung stehenden Datenbestand sinnvolle Klassenstrukturen ableiten zu können. Im folgenden werden die wichtigsten dieser Methoden aufgeführt sowie erste Lösungsansätze für deren Realisierung beschrieben.

3.1.1 Merkmalgewinnung

Bei der klassischen Clusteranalyse werden für alle klassifikationsrelevanten Merkmale Vektoren definiert, die einen n-dimensionalen Vektorraum aufspannen. Jedes Produkt entspricht nun einem Punkt in diesem Vektorraum. Anzahl und Art der zu berücksichtigenden Merkmale müssen vor Beginn einer klassischen Clusteranalyse bekannt sein. In dem hier beschriebenen Ansatz werden zunächst alle ermittelbaren Merkmale zur Bildung des Vektorraumes verwendet. Im folgenden wird beschrieben, wie diese Basismenge an Merkmalen auf die relevanten Merkmale eingeschränkt bzw. um zusätzliche Merkmale erweitert werden kann.

3.1.1.1 Ermittlung nicht-klassifikationsrelevanter Merkmale

Entsprechend der Verfahrensweise der klassischen Clusteranalyse werden zunächst alle n ermittelbaren Merkmale des zu klassierenden Produktspektrums auf Merkmalsachsen aufgetragen. Diese Merkmalsachsen spannen einen n-dimensionalen Vektorraum auf, in dem jedes Produkt durch einen Punkt repräsentiert wird. Die Punkte werden nun auf alle Merkmalsachsen projiziert. Aus der Verteilung der Punkte entlang einer Achse lassen sich Rückschlüsse bzgl. der Klassifikationsrelevanz dieses Merkmals ziehen (vgl. Bild 2).

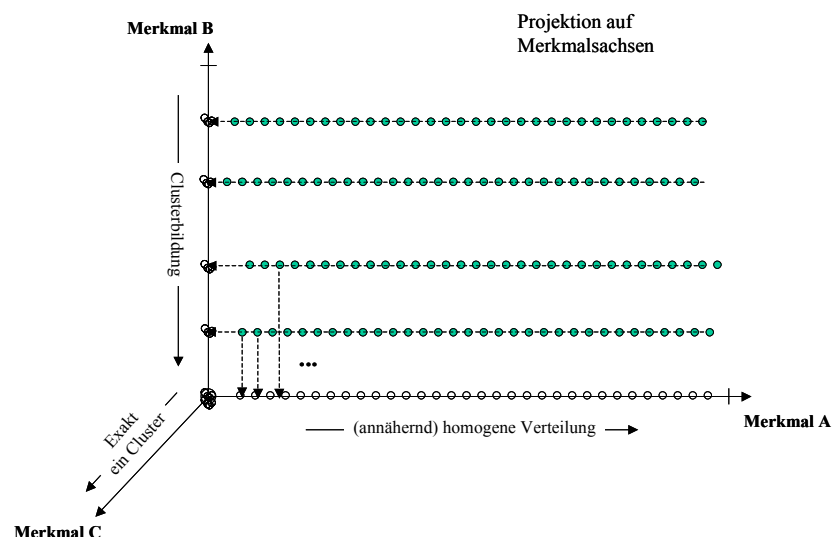


Bild 2: Ermittlung nicht-klassifikationsrelevanter Merkmale

3.1.1.2 Ermittlung zusätzlicher klassifikationsrelevanter Merkmale

Werden bei der Untersuchung, ob ein Merkmal für die Klassifikation relevant ist oder nicht, lediglich die Verteilungen entlang der einzelnen Achsen untersucht, können für die Klassifikation wichtige Informationen verloren gehen. In Bild 3 ist ein Beispiel dargestellt, in dem alle Produkte sowohl hinsichtlich Merkmal A als auch hinsichtlich Merkmal B annähernd homogen im Vektorraum verteilt sind. Eine Projektion der Produkte auf die von A und B aufgespannte Ebene zeigt jedoch, dass die Anordnung der Punkte auf dieser Ebene nicht homogen ist.

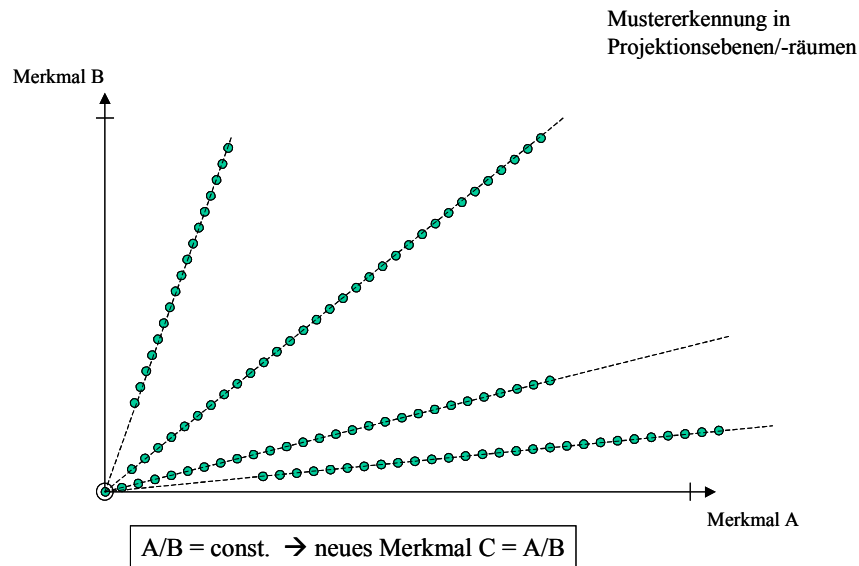


Bild 3: Gewinnung zusätzlicher klassifikationsrelevanter Merkmale

Durch geeignete Verfahren, z.B. Mustererkennung, lässt sich feststellen, dass die Punkte linear angeordnet sind, in diesem Beispiel auf Ursprungsgeraden. Hieraus lässt sich ermitteln, dass eine Verknüpfung der Merkmale A und B zu einem Merkmal führt, das klassifikationsrelevant ist. Die Art der Verknüpfung ergibt sich aus der Anordnung. In obigem Beispiel ist die Anordnung linear durch den Ursprung, d.h. alle Punkte können durch eine Funktion $y = a_n \cdot x$ beschrieben werden, wobei n der Anzahl der Ursprungsgeraden entspricht. Durch Bildung der Umkehrfunktion ergibt sich der Zusammenhang: A/B annähernd konstant (für jeden Strahl der A-B Ebene). Das heißt entlang einer Merkmalsachse $C = A/B$, die in den Vektorraum eingefügt wird, ergeben sich n Cluster, ein zusätzliches, mit hoher Wahrscheinlichkeit klassifikationsrelevantes Merkmal C wurde gefunden.

3.1.2 Klassenbildung

Das Ergebnis einer konventionellen Clusteranalyse besteht in der Bildung von Objektgruppen. Die Zugehörigkeit eines Objektes, das durch einen Punkt p im Vektorraum repräsentiert wird, zu einem Cluster, ergibt sich aus dem Abstand des Punktes zum Clustermittelpunkt. Zur Berechnung des Abstandes sowie der Position des Clustermittelpunktes kommen verschiedene Verfahren zum Einsatz. Allen Verfahren ist gemein, dass ein Cluster und damit auch sein Mittelpunkt sich mit jedem Objekt ändert, das dem Cluster zugeordnet wird. Zu einem definierten Zeitpunkt ist es daher möglich, Mittelpunkt und Geometrie exakt zu bestimmen. Ein erster Ansatz für die Bildung einer Klasse ist daher die Geometrie des Clustervolumens V . Für jedes ermittelte Cluster C_n mit

dem Clustervolumen V_n wird eine Klasse K_n angelegt. Jede dieser Klassen besitzt die definierende Eigenschaft $P \in V_n$, wobei P die Punktrepräsentation eines zu klassifizierenden Objektes im Vektorraum und V_n die Beschreibung des Clustervolumens ist. Die Evaluierung dieser definierenden Eigenschaft ergibt einen booleschen Wert, der die Zugehörigkeit eines Objektes zu dieser Klasse festlegt.

Die mathematische Beschreibung eines Clustervolumens im n -dimensionalen Raum ist i.d.R. außerordentlich komplex. Dies hat zur Folge, dass die aus dem Clustervolumen abgeleitete definierende Eigenschaft einer Klasse sehr schwer bzw. überhaupt nicht lesbar oder für einen Menschen nachvollziehbar wird. Damit entsteht ein unerwünschtes „Blackbox“-Verhalten, die Klassifikationsentscheidungen des Systems können daher nicht bzw. nur mit sehr großem Aufwand nachvollzogen werden. Außerdem sind manuelle Modifikationen am Klassifikationssystem bzw. den definierenden Eigenschaften der Klassen nahezu unmöglich. Diese werden jedoch i.d.R. notwendig sein, die letzte Entscheidung über den Aufbau eines zu entwickelnden Klassifikationssystems muss immer bei einem Menschen liegen. Daher ist es unumgänglich, dass die von einem System zur automatischen Klassifizierung vorgeschlagenen Klassen und Regeln lesbar und nachvollziehbar sind.

In Bild 4 ist ein Ansatz dargestellt, wie einfach nachvollziehbare, definierende Eigenschaften einer Klasse abgeleitet werden können. Für jedes Merkmal des Vektorraumes wird für einen Cluster ein Intervall gültiger Merkmalsausprägungen ermittelt. Liegt die Punktrepräsentation eines zu klassifizierenden Objektes innerhalb dieser Intervalle, wird es dieser Klasse zugeordnet. Die Clustergeometrien werden hierbei durch umhüllende, kubische Vektorräume angenähert. Diese Vereinfachung wird in vielen Fällen bereits zu befriedigenden Ergebnissen führen.

Eine Verbesserung der Genauigkeit des soeben beschriebenen Verfahrens lässt sich durch die Verknüpfung mehrerer kubischer Räume zur Annäherung einer Clustergeometrie erreichen.




Bild 4: Verknüpfung kubischer Vektorräume

Die Klasse, die aus dem in Bild 4 dargestellten Cluster hervorgeht, hat in diesem Beispiel die definierende Eigenschaft:

$$(P \in I_{A1} \text{ AND } P \in I_{B1}) \text{ OR } (P \in I_{A2} \text{ AND } P \in I_{B2})$$

Auf die dargestellte Weise lassen sich Clustergeometrien relativ exakt durch nachvollziehbare Regeln beschreiben.

3.1.3 Hierarchische Strukturierung der Klassen

Für die Erstellung eines Klassifikationssystems ist es notwendig, die ermittelten Objektklassen in Beziehung zueinander zu setzen. Es gibt verschiedene Möglichkeiten, Klassifikationssysteme zu strukturieren: nicht-hierarchisch, hierarchisch, hybrid (Verknüpfung hierarchischer und nicht-hierarchischer Elemente), hierarchisch mit Mehrfachvererbung oder netzartig. In der Praxis hat sich gezeigt, dass hierarchische Klassifikationssysteme die größte Akzeptanz finden, da sie ausreichende Strukturierungsmöglichkeiten bieten und die Handhabbarkeit auch bei großer Klassenanzahl gewährleistet ist. Im Folgenden soll daher ein Ansatz aufgezeigt werden, wie sich auf Basis von Clusteranalysen gefundene Objektklassen hierarchisch strukturieren lassen.




Bild 5: Erzeugen hierarchischer Strukturen durch Clusterprojektionen

In Bild 5 ist ein Beispiel dargestellt, in dem zwei Objektklassen I.1 und I.2 sowie deren definierende Eigenschaften ermittelt wurden. Durch eine iterative Reduktion der Dimensionalität des Vektorraumes lässt sich ermitteln, dass beide Cluster in einem um den Merkmalsvektor A reduzierten Vektorraum zu einem Cluster verschmelzen. Wird dieser Cluster in eine Objektklasse I überführt, so ist I eine Oberklasse von I.1 und I.2.

4 Die praktische Umsetzung des Klassifikationskonzepts bei Paraldine

Die heutige Strategie von Fertigungsunternehmen ist es, den Anteil der Zukauf- und Wiederholteile in ihren Produkten so weit als möglich zu erhöhen. Als logische Konsequenz daraus finden sich immer mehr Anbieter von Teilen und Komponenten am Markt. Aufgrund

unzureichender Informationen für den Produktentwickler, setzen Fertigungsunternehmen jedoch unnötig oft neue Teile und Komponenten ein. Dies hat zur Folge, dass die stetige Zunahme der Teilezahl die Betriebe über Gebühr finanziell belastet. Paradine hilft diese Kosten durch strategisches Teile- und Lieferantenmanagement zu senken.

Darüber hinaus werden die Bestrebungen von Unternehmen zur Steigerung ihrer Wettbewerbsfähigkeit durch effizientes Management der „Inbound Supply Chain“ unterstützt [8]. Modernste Such- und Klassifikationsmethoden ermöglichen eine breite Wiederverwendung von Komponenten. In der Folge werden weniger neue Komponenten verwendet und Dubletten im Datenbestand aussortiert. Konstrukteure legen bereits in der Entwicklungsphase über 80% der Produktkosten fest. Unzureichende Informationen über die wirtschaftlich relevanten Daten des vorhandenen Teilespektrums verursachen in der Folge enorme Kosten. Das erhöht den Produktpreis und verringert damit die Wettbewerbsfähigkeit.

Paradines Kernprodukt EPTOS™ ist ein modulares Software-Paket, das Unternehmen der Fertigungsindustrie im Inbound Supply Chain Management unterstützt. EPTOS™ verknüpft die überwiegend technischen Daten aus PDM-, CAx- und EDM-Systemen miteinander. Eine Business-to-Business (B2B) Komponente bindet zusätzlich die Informationen verschiedener Hersteller ein. EPTOS™ beinhaltet ein Windows-, sowie Web-basierendes Teile-Managementsystem für alle Unternehmensbereiche. Die benutzte Hardware-Plattform und das Betriebssystem sind dabei unerheblich, da EPTOS™ vollständig in JAVA™ realisiert ist.

Paradine offeriert zu ihrer Component & Supplier Management (CSM) Lösung EPTOS™ Consulting-Dienstleistungen, um vorhandene Datenbestände eines Kunden bei Bedarf zu bereinigen und optimal zu strukturieren. Das Consulting Services Expertenteam nimmt zunächst eine kundenspezifische Datenbestandsanalyse vor, welche den Ist- und Soll-Zustand der Stammdatensätze ermittelt und eine sinnvolle Grobstrukturierung der Datenbestände beinhaltet. Diese klassifizierten Datenbestände werden bereinigt und konsolidiert, wobei fehlerhafte oder unvollständige Datensätze eliminiert oder ergänzt werden. Ebenso werden in diesem Schritt bereits Dubletten aus dem Datenbestand entfernt. Bei dieser Verschlinkung und Optimierung der Datenbestände bietet Paradine die Möglichkeit die Klassifizierung der Teile entweder durch eigenes Fachpersonal vom Kunden durchführen zu lassen, oder auf hauseigene Spezialisten im Rahmen des Consulting-Angebotes zurückzugreifen.

Beratungsleistungen beim individuellen Aufbau und der weltweiten Verknüpfung von Teilebibliotheken und Online-Katalogen für ein kundenspezifisches „globales Engineering Network“ runden das Service-Angebot ab. Um den Austausch von wertvollem firmeninternem Produkt- und Konstruktionswissen bestens zu gewährleisten, umfasst die Leistungspalette zudem innovative Konzepte und Systeme zur idealen Vernetzung von Kunden und Zulieferern in einer zeitgemäßen Business-to-Business (B2B) Umgebung. Dies wird nicht zuletzt durch eine moderne Technologien erreicht, welche die Anbindung von PDM-, CAx- und ERP-Systemen verschiedener Hersteller ermöglicht.

Im Rahmen der Consulting-Dienstleistungen hat Paradine die Erfahrung gemacht, dass auch heute noch in vielen Unternehmen technische Daten in sehr unstrukturierter Form vorliegen, was eine effiziente Wiederverwendung nahezu unmöglich macht. Ein Großteil der Dienstleistungen bezieht sich daher auf die Systematisierung und Klassifizierung von Altdatenbeständen. Diese Tätigkeit wird derzeit noch weitgehend manuell durchgeführt. Die Ergebnisse des Verbundprojekts versprechen daher eine erhebliche Unterstützung in diesem Bereich.

5 Literaturverzeichnis

- [1] Clark D. W., „An Introduction to neural networks“, <http://members.home.net/neuralnet/introtonn/index.htm>, 1997.
- [2] Rojas R., „Theorie der neuronalen Netze, Eine systematische Einführung“, Springer Lehrbuch 1993
- [3] Freist, C., „Einsatzmöglichkeiten statistischer Verfahren in CAD/CAM-Systemen“, Dissertation, Universität Hannover, 1984.
- [4] Fried, W.; Siefke, U.; Seidler, R., „Wiederholteil- und Ähnlicheilsuche - Ermittlung über assoziative Ähnlichkeit“, VDI-Z 136, Heft 3, S.43-45, 1994.
- [5] Lesser, H.-J., „Rechnergestützte Methoden zur Auswahl anforderungsgerechter Verbindungselemente“, Forschungsberichte aus dem Institut für Werkzeugmaschinen und Betriebstechnik, Universität Karlsruhe, 1988.
- [6] Kälberer, G., „Automatische Klassifizierung von Arbeitsplätzen mit Hilfe der Cluster-Analyse“, Zwf 75, Nr.3, S.109-112, 1980.
- [7] Grabowski, H.; Benz, T., „Suchsystem zur Informationsfindung“, VDI-Berichte Nr.647, VDI-Verlag, S.75-100, 1987.
- [8] Sander, S.; Kasan, R.-D.; Ondracek, N.: Kostensenkungspotenziale in der Produktentwicklung - Lösungsmöglichkeiten durch das Inbound Supply Chain Management. Zwf 96, Nr. 7-8, S. 408-412, 2001.

Dipl.-Ing. Jörg Weißkopf
Institut für Rechneranwendung in Planung und Konstruktion
Universität Karlsruhe (TH)
Adenauerring 20
76131 Karlsruhe
Telefon: +49 (721) 608-6464
Fax: +49 (721) 661138
E-Mail: weiskopf@rpk.mach.uni-karlsruhe.de

Dr.-Ing. Stefan Sander
Paradine Deutschland GmbH
Roonstraße 21
90429 Nürnberg
Telefon: +49 (911) 9269-159
Fax: +49 (911) 9269-314
E-Mail: stefan.sander@paradine.de