

Benjamin Bustos, Daniel Keim, Dietmar Saupe, Tobias Schreck, Andrada Tatu

## Methoden und Benutzerschnittstellen für effektives Retrieval in 3D-Datenbanken

3D Objekte sind ein wichtiger Typ Multimedia Daten mit einer Reihe vielversprechender Anwendungsmöglichkeiten etwa in der industriellen Produktion, in Simulation, Unterhaltung und Visualisierung. Die Definition von Ähnlichkeit zwischen 3D Objekten und die Implementierung von entsprechenden Ähnlichkeitssuchalgorithmen sind interessant für den Einsatz in 3D-Datenbanksystemen, repräsentieren aber gleichzeitig schwierige Probleme. In dieser Arbeit stellen wir Methoden dar, um effektives Retrieval in 3D-Datenbanken zu realisieren. Wir besprechen zudem Methoden, um Ergebnisse von Ähnlichkeitssuchanfragen sowie ganze 3D Objekträume visuell zu analysieren.

### 1 Einleitung

Die Entwicklung effektiver und effizienter Ähnlichkeitssuchmethoden für Multimedia Daten wie Bilder und Videos ist ein wichtiges Forschungsgebiet geworden aufgrund einer wachsenden Menge an verfügbaren digitalen audio-visuellen Daten. Eine ähnliche Entwicklung kann für 3D Daten erwartet werden, denn 3D Objekte sind ein interessantes Medium für die Informationsverbreitung und Verarbeitung in Anwendungen wie z.B. Design, Simulation, Schulung und Unterhaltung.

Merkmalvektorbasierte Ähnlichkeitssuche ist die Standardmethode zur Realisierung von inhaltsbasierter Suche in Multimedia-Datenbanken. Hierbei werden numerische Werte der Multimediaobjekte extrahiert, welche die Objekte möglichst gut beschreiben und gleichzeitig einen Vektor aus Merkmalen bilden (Merkmalvektor; auch Feature-Vector oder kurz FV). Solche Merkmalvektoren besitzen üblicherweise eine hohe Dimensionalität im Bereich bis zu einigen hundert Dimensionen. Die Ähnlichkeitssuche wird dann auf eine Suche der nächsten Nachbarn eines Anfrageobjekts im Merkmalraum abgebildet. Das

Sucheobjekt ist ebenfalls ein Multimediaobjekt (Query-by-Example Paradigma), dessen Merkmalsvektor zur Ähnlichkeitssuche herangezogen wird.

Für den Einsatz in 3D Datenbanken sollten die Merkmalsvektoren bestimmte wichtige Eigenschaften erfüllen. Gute 3D Merkmalsextraktoren sollten zum einen invariant gegenüber Änderungen in der räumlichen Lage der 3D Objekte sein (Translation, Rotation und Reflexion) sowie in der Skalierung. Das heißt, dass eine Ähnlichkeitssuchanfrage auf einer 3D Datenbank geometrisch ähnliche 3D Objekte auch mit abweichender Lage, Ausrichtung und Skalierung auffinden sollte. Außerdem sollten die Merkmalsvektoren in Bezug auf kleine Änderungen der Auflösung, der Geometrie und der Topologie der Modelle robust sein.

Für d-dimensionale Merkmalsvektoren wird die Ähnlichkeitssuche mittels einer geeigneten Vektorraummetrik wie z.B. den Minkowski Abständen (Manhattan, Euklidische, usw.) realisiert: Die Distanzfunktion wird benutzt um die  $k$  nächsten Nachbarn (d.h. die  $k$  Objekte mit kleinstem Abstand zum Suchobjekt) in der Datenbank zu finden und dem Benutzer zurückzugeben.

Es existieren zwei wesentliche Kriterien für gute Ähnlichkeitssuchsysteme: Effektivität und Effizienz. Ein effektives System soll nur die relevantesten Objekte aus der Datenbank zurückgeben. Folglich muss es diskriminierende Methoden implementieren, um zwischen ähnlichen und nicht-ähnlichen Objekten zu unterscheiden. Zudem sollte ein gutes Suchsystem effiziente Methoden für die Merkmalsextraktion, die Indexierung sowie die Anfragebearbeitung implementieren

#### 1.1 Anwendungen

Das Problem des Suchens nach ähnlichen 3D Objekten ist relevant und tritt in vielen Anwendungen auf. Beispiele umfassen Computer Aided Design und Ma-


nufacturing (CAD/CAM), Virtual Reality (VR), Medizin, molekulare Biologie, militärische Anwendungen sowie Unterhaltung.

- In der Medizin kann die Anfrage von CT Volumenbildern nach ähnlichen Organdeformationen in medizinischen Datenbanken für Diagnosezwecke verwendet werden [Keim 1999].
- Strukturelle Klassifikation ist eine grundlegende Aufgabe in der molekularen Biologie. Dieses Klassifikationsproblem kann durch geometrisch Ähnlichkeitsmodelle unterstützt werden [Ankerst et al. 1999].
- Viele Wettervorhersagen beinhalten Blütenstaubprognosen für Allergiker. Ronneberger et al. [Ronneberger et al. 2002] entwickelten ein Mustererkennungssystem, welches Blütenstaub anhand volumetrischer 3D Daten einstuft, welche mit einem konfokalen Laserscan-Mikroskop erfasst werden. Die 3D Struktur des Blütenstaubs wird extrahiert und ein darauf basierender Merkmalsvektor zur Klassifikation verwendet.
- Eine 3D-Datenbank kann benutzt werden, um CAD-Programme zu unterstützen. Geometrische Ähnlichkeitssuche in CAD-Datenbanken hat viele Anwendungen im industriellen Design. Wenn ein neues Produkt entworfen wird, kann es aus vielen einzelnen Teilen bestehen, welche zusammen passen und das Produkt bilden. Wenn einige dieser Teile einem bereits entworfenen Standardteil ähnlich sind, dann kann der mögliche Ersatz des ursprünglichen Teils mit dem Standardteil zu einer Verringerung von Produktionskosten führen.

## 2 Extraktion von Merkmalsvektoren aus 3D Objekten

### 2.1 Prozessmodell

Vor kurzem konnten wir ein Prozessmodell vorschlagen, um die Vielzahl der vorhandenen Methoden zur Merkmalsextraktion als 3D Modellen zu systematisieren [Bustos et al. 2006]. In dieser Klassifikation wird die Extraktion der Merk-



**Abb. 1: Prozessmodell der Merkmalsextraktion für 3D Objekte.**

malsvektoren als ein mehrstufiger Prozess betrachtet (vgl. Abb. 1). In diesem Prozess wird ein 3D Objekt zunächst vorverarbeitet, um geforderte Invarianz- und Robustheitseigenschaften zu approximieren. Anschließend wird das Objekt abstrahiert, so dass sein Charakter entweder vom Typ Oberfläche, Volumen oder Bild ist. Danach kann eine numerische Transformation dieser Abstraktion stattfinden, von deren Resultat abschließend der Merkmalsvektor gewonnen wird. Im folgenden skizzieren wir die grundlegenden Schritte. Ohne Einschränkung der Allgemeinheit nehmen wir an, dass das 3D Objekt durch ein Polygon-Netz dargestellt wird.

- **Vorverarbeitung:** Wenn durch den Deskriptor erforderlich, wird das 3D Modell (approximativ) für Rotations-, Translations- und/oder Skalierungs-invarianz vorverarbeitet (vgl. Abschnitt 2.2).
- **Art der Objektabstraktion:** Wir definieren drei Arten der Modellabstraktion: Oberfläche, volumetrisch und Bild. Statistiken der Krümmung der Objektoberfläche etwa basieren auf Oberfläche, während die Verteilung der Objektmasse im Raum, gemessen über Moment-Deskriptoren, der volumetrischen Art der Objektabstraktion angehört. Die Projektion von Geometrie auf eine oder mehrere Bildebenen, z.B. mittels eines Tiefenpuffer, repräsentiert dagegen die bildbezogene Objektabstraktion.
- **Numerische Transformation:** Die Haupteigenschaften des abstrahierten Modells können mit unterschiedlichen Methoden numerisch erfasst werden. Z.B. können Voxel- und 2D Rasterbilder Wavelet-transformiert werden, oder Oberflächen adaptiv abgetastet werden. Weitere numerische Transformationen umfassen die Spherical Harmonics- (SH) und die

diskrete Fouriertransformation (DFT). Solche Transformationen ergeben eine numerische Darstellung des zugrundeliegenden Objekts.

- **Deskriptorerzeugung:** In diesem Schritt wird abschließend ein Deskriptor erzeugt. Er kann einer der folgenden drei Kategorien angehören:
  - (1.) Merkmalsvektoren bestehen aus Elementen in einem Vektorraum, der mit einer Metrik versehen ist. In diesem Paper betrachten wir diese Klasse von Beschreibungsmethoden.
  - (2.) In statistischen Deskriptoren werden 3D Objekte auf spezifische Eigenschaften überprüft, welche normalerweise in Form eines Histogramms zusammengefasst werden.
  - (3.) Diese Kategorie entspricht besser der strukturellen Formbeschreibung des 3D Objekts, die in Form eines Graphs dargestellt werden kann [Sundar et al. 2003, Hilaga et al. 2001]. Ein Graph stellt leichter die Struktur eines Objekts dar, das aus mehreren Teilen besteht oder sinnvoll in zusammenhängende Teile zerlegt werden kann, wie z.B. den Körper und die Glieder von Objekten, welche einen menschlichen Körper modellieren.

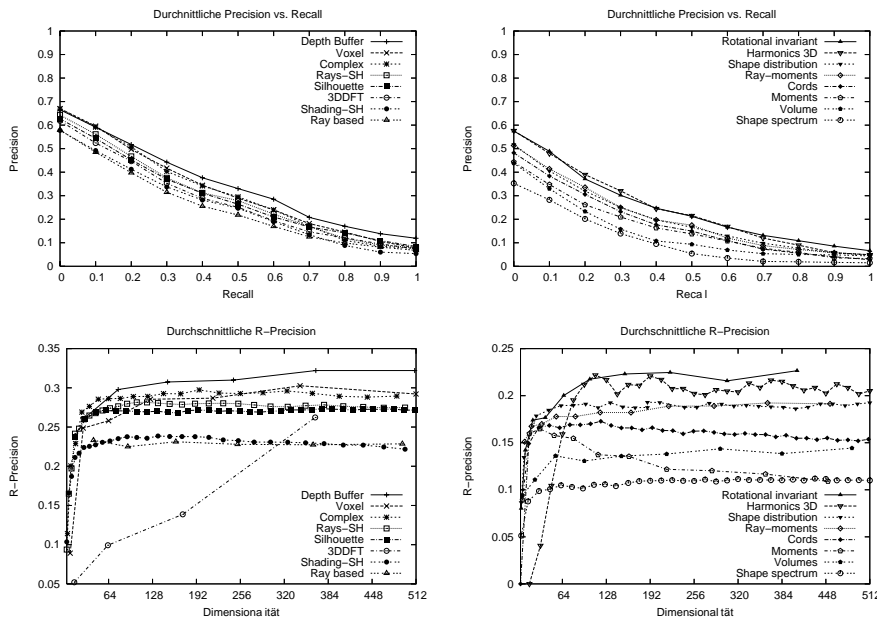
Es existieren eine Vielzahl von Extraktionsmethoden, abgeleitet aus Kombinationen der Schritte dieses Prozessmodells. Z.B. beschreibt der Depth Puffer [Bustos et al. 2005] Merkmalsvektor 3D Objekte bildbasiert: Sechs Graustufen Tiefenbilder werden mit Parallelprojektion der Objekte auf die Seiten des minimal umgebenden Würfels gerendert. Jedes Bildpixel kodiert den Abstand zwischen Objekt und Projektionsfläche. Die sechs Bilder werden anschließend Fourier transformiert, und die Beträge der  $k$  niederfrequentesten Koeffizienten gehen in den entsprechenden Merkmalsvektor ein.

Zu Evaluierungszwecken haben wir 16 unterschiedliche 3D Merkmalsextraktoren implementiert [Bustos et al. 2005]: Depth Buffer, Voxel, Complex, Rays with Spherical Harmonics, Silhouette, 3DDFT, Shading, Ray-based, Rotational Invariant, Harmonics 3D, Shape Distribution with D2, Ray-moments, Cords, Moments, Shape Spectrum und Volume. Für eine ausführliche Diskussion dieser und weiterer Methoden zur 3D Merkmalsextraktion vgl. den aktuellen Überblicksartikel in Bustos et. al. [Bustos et al. 2006].

## 2.2 Invarianzeigenschaften

Invarianz- und Robustheitseigenschaften können explizit oder implizit durch einen Merkmalsextraktor unterstützt werden. Wenn nur relative Objekteigenschaften betrachtet werden, dann sind viele Invarianzen implizit gegeben [Osada et al. 2002]. Diese Methoden sind für gewöhnlich in der Kategorie der statistischen Methoden zu finden. Explizit kann Invarianz in Bezug auf Rotation z.B. über die Summierung der Energie in bestimmten Frequenzbändern der spektralen Darstellung von Modellpunkten erzielt werden [Funkhouser et al. 2003, Kazhdan et al. 2003]. In einer Verallgemeinerung dieser Methode auf volumetrische Darstellungen kann man Rotationsinvarianz durch eine Kombination aus Zernike Momenten [Novotni & Klein 2004] erzielen. Die Invarianz in Bezug auf Translation und Skalierung wird in vielen Fällen durch einen Normalisierungsschritt erzielt, welcher den Objektschwerpunkt in den Ursprung verschiebt und die Modelle in ein kanonisches Volumen skaliert.

Rotationsinvarianz kann explizit durch einen Vorverarbeitungsschritt unterstützt werden, der die Objekte in einen kanonischen Bezugsrahmen orientiert. In solch einem Bezugsrahmen sind Richtungen und Abstände zwischen unterschiedlichen Modellen approximativ vergleichbar. Eine bekannte Methode für das Finden eines solchen Bezugsrahmens ist die Principal Component Analysis (PCA) [Paquet et al. 2000, Vranic et al. 2001], welche ein Objekt so ausrichtet, dass die Achsen des Koordinatensystems mit den



**Abb. 2: Precision vs. Recall für 16 untersuchte Merkmalsextraktoren, gemessen auf unserem 3D Benchmark (obere Charts). R-Precision in steigender Dimensionalität (Auflösung der Abtastung) für die selben Verfahren (untere Charts). Ein Bildbasiertes Verfahren liefert die besten Ergebnisse im Benchmark Durchschnitt.**

Hauptachsen der Verteilung von Modelloberfläche oder Volumen im Raum übereinstimmen.

### 3 Retrievalqualität

#### 3.1 Evaluierungsansatz

Wir haben die Effektivität (Retrievalgüte) der implementierten Merkmalsextraktoren anhand von Retrievalexperimenten über einem 3D-Benchmark evaluiert. Benchmarking von Merkmalsextraktoren ist ein praktisch wichtiger Schritt zum objektiven Vergleich einer wachsenden Menge an 3D Merkmalsextraktoren, die in der Literatur vorgestellt werden. Im Weiteren präsentieren wir einige Ergebnisse unserer Evaluierungen, sowie einen daraus abgeleiteten Ansatz zur Steigerung der Anfrageleistung durch geeignete Kombination von Merkmalsextraktoren.

Die Datenbank, die für unsere Experimente benutzt wird, enthält 1.838 3D Objekte, die wir aus dem Internet zusammengetragen konnten<sup>1</sup>. Aus diesem Be-

stand wurden 472 Objekte manuell anhand globaler geometrischer Ähnlichkeit in 55 unterschiedliche Anfrageklassen eingestuft. Jedes Objekt dieser 55 Klassen dient in unserem Benchmark als Anfrageobjekt, wobei jeweils die Objekte aus der gleichen Klasse wie das Anfrageobjekt als relevante Objekte angesehen werden. Wir verwenden Precision vs. Recall Diagramme [Baeza-Yates & Ribeiro-Neto 1999] um die Retrievalgüte der Merkmalsvektoren zu vergleichen. Wir bilden dazu den Durchschnitt der Precision und Recall Messwerte aller 472 Benchmarkanfragen (Makrobenchmark). Precision ist der Anteil der gefundenen relevanten Objekte in einer gegebenen Menge von Antwortobjekten, und Recall ist der Anteil aller relevanten Objekte der Datenbank, die in der Antwortmenge zurückgegeben werden. Zusätzlich zu Precision vs. Recall Diagrammen berechnen wir auch die R-Precision (ein skalarer Wert) [Baeza-Yates & Ribeiro-Neto 1999], die durch die Precision einer Antwort der Länge N gegeben ist, wobei N die Anzahl aller relevanten Objekte zur jeweiligen Anfrage aus dem Benchmark ist.

Wir untersuchten alle implementierten Merkmalsvektoren mit unterschiedli-


chen Auflösungs-niveaus bis hin zu 512-dimensionalen Vektoren. Wir benutzen die L1 Distanz zwischen Merkmalsvektoren um zu sortierten Listen bezüglich den Anfrageobjekten zu gelangen. In Vorstudien die wir durchgeführt haben, lieferte L1 konsistent die besten Retrievalergebnisse unter den Minkowski Distanzen L1, L2, und der Maximumsdistanz.

#### 3.2 Effektivitätsvergleich

Der effektivste Merkmalsvektor in unserem Experiment ist der Depth Buffer, mit einem Benchmark Score von durchschnittlichen 32% R-Precision. Der Unterschied zwischen dem besten und schlechtesten Verfahren (Depth Buffer und Shape Spectrum - ein Oberflächenbasiertes Verfahren) ist bedeutend (Faktor 3). Jedoch ist der Unterschied zwischen im Ranking benachbarten Vektoren klein unter den besten Methoden. Dieses deutet an, dass in der Praxis diese besten Merkmalsvektoren gleichermaßen gut geeignet sind. Deskriptoren, die eine homogene Orientierung der Polygonfläche voraussetzen (Shape Spectrum oder Volume), weisen eine konsistent schlechte Retrievalgüte auf unserem Benchmark auf, da dieser aus Modellen aus dem Internet beruht, für die konsistente Oberflächenorientierung nicht garantiert werden kann („Polygon Soup“ Problem). Auch die geometrischen Moment-basierten Merkmalsvektoren scheinen nur begrenzte Retrieval-effektivität zu leisten.

Abb. 2 (die beiden linken Charts) gibt die Precision vs. Recall Diagramme für alle verglichenen Deskriptoren wieder. Die beiden rechten Diagramme stellen den Einfluss der Dimensionalität der Vektoren auf die Retrievalqualität dar. Die Abbildung zeigt, dass die Effektivität zuerst mit der Dimensionalität steigt, die Verbesserungsrate jedoch schnell zurückgeht ab ca. 64 Dimensionen. Alle Verfahren konvergieren etwa bei der gleichen Dimensionalität gegen ihr Optimum. Dieses ist ein unerwartetes Resultat wenn man betrachtet dass unterschiedliche Merkmalsvektoren unterschiedliche Eigenschaften der 3D Objekte beschreiben.

1. Konstanz 3D Model Search Engine. <http://merkur01.inf.uni-konstanz.de/CCCC/>



**Abb. 3: Durchschnittliche R-Precision aller möglichen statischen Kombinationen von 10 Merkmalsextraktoren (Scatterplot, links). Precision-Recall Kurven für die jeweils besten Kombinationen zu einer gegebenen Kardinalität (rechts).**

### 3.3 Ergebnisanalyse

Anhand dieser Experimente auf einer Auswahl an 3D Merkmalsextraktoren stellen wir fest, dass die durchschnittlich besten Deskriptoren in unserem Setting bildbasierte sind. Die Depth Buffer, Silhouette und Ray-Based Verfahren benutzen Merkmale, welche von planaren oder sphärischen Projektionen erfasst werden, und liefern mit die besten Retrievalergebnisse. Ebenfalls gute Ergebnisse erzielen der Voxel und der 3DDFT Merkmalsextraktor, welche volumetrische Merkmale betrachten. Oberflächenbasierte Deskriptoren erzielen in unserem Setting schlechtere Ergebnisse, was zum Teil an inkonsistenter Orientierung der 3D Modelle in unserem Benchmark liegt. Alle Merkmalsextraktoren zeigen gute Robustheit bezüglich dem Detaillierungsgrad (Tesselierung). Die gute Retrievalleistung Bildbasierter Deskriptoren in unseren Experimenten stimmt qualitativ mit Chen et al. [Chen et al. 2003] überein, wo ein ausgefeilter, mehrstufig definierter Bildbasierter Deskriptor ebenfalls hervorragende Anfrageergebnisse lieferte.

Solche über alle Anfrageklassen aggregierten Benchmarkergebnisse können verwendet werden, um Rankings von Merkmalsextraktoren zu erhalten. Betrachtet man aber die Anfrageleistung bezüglich einzelner Anfrageklassen (Teilmenen des Benchmarks), so stellen wir signifikante Abweichungen der Verfahrensrankings vom Benchmarkdurchschnitt fest. Für unterschiedliche Objektkategorien ist normalerweise ein unterschiedliches Verfahren das effektivste. Leider konnten wir keine ausgeprägte Korrelation zwischen geometrischen Ei-

genschaften der Klassenkategorie und des jeweils am besten arbeitenden Merkmalsextraktor feststellen. Eine Ausnahme stellt der Shape Spectrum Deskriptor (der schlechteste Deskriptor im Durchschnitt) dar - dieser liefert die beste Effektivität für eine Anfrageklasse bestehende aus Modellen von menschlichen Körpern. Shape Spectrum ist in der Lage, ähnliche Modelle menschlicher Körper in unterschiedlichen Posen zu finden, eine Eigenschaft, welche beim Rest der untersuchten Verfahren nicht gegeben ist. Dies hängt mit der Tatsache zusammen, dass der Shape Spectrum die Verteilung lokaler Krümmung entlang der 3D Oberfläche betrachtet, welche nicht stark zwischen ähnlichen 3D Modellen mit unterschiedlichen Körperhaltungen variiert. Eine andere Beobachtung die wir machten, ist dass jene Objektkategorien, welche schwer mittels PCA kanonisch zu orientieren sind, am besten von Verfahren gefunden werden, welche per Definition rotationsinvariant sind, z.B. der implizit rotationsinvariante Spherical Harmonics Deskriptor [Funkhouser et al. 2003].


Außer diesen spezifischen Ausnahmen ist es schwierig a priori festzustellen, welches Verfahren die beste Retrievalqualität für ein unbekanntes Anfrageobjekt bieten wird. Durchschnittlich sind das Depth Buffer oder Voxel Verfahren relativ gut, jedoch möchte man gegeben ein Anfrageobjekt dynamisch immer den am besten geeigneten Extraktor verwenden. Statische und dynamische Kombinationen aus Merkmalsverfahren stellen hierzu eine Lösung dar, welche wir im nächsten Abschnitt diskutieren.

## 4 Kombinationen von Merkmalsvektoren

### 4.1 Statische Kombinationen

Aus der Analyse der Experimente des letzten Abschnitts geht hervor, dass eine Anzahl von Merkmalsextraktoren existiert, die gute durchschnittliche Retrievalleistung auf der Mehrheit der Anfrageklassen des Benchmarks erzielen, es aber kein Verfahren gibt, welches alle anderen Verfahren in allen Anfrageklassen dominiert. Stattdessen haben die einzelnen Merkmalsextraktoren unterschiedliche Stärken und Schwächen, und sie stellen komplementäre Merkmale zur Beschreibung der 3D Objekte dar. Wir schlagen deshalb vor, Kombinationen von Merkmalsvektoren zu verwenden, um die Retrievalleistung der Ähnlichkeitssuche weiter zu verbessern, bzw. die Nachteile der Verwendung nur eines einzelnen Merkmals zu vermeiden. Es stellen sich hierzu zwei Fragen: a) Welche Merkmalsvektoren sollen in die Kombination eingehen, und b) wie kann die Kombination technisch realisiert werden. Ad a) können wir anhand Benchmarkdurchschnittlicher Retrievalergebnisse die beste Auswahl an Merkmalen, welche kombiniert werden sollen, bestimmen. Ad b) sind prinzipiell die Möglichkeiten (1.) Konkatenation der Vektoren (Hybridvektoren) oder (2.) eine der vielen Möglichkeiten zur Aggregation der individuellen Rankings, so wie sie die ausgewählten Verfahren produzieren, denkbar. Wir haben uns aufgrund der Einfachheit für die zweite Möglichkeit entschieden, in dem wir das kombinierte Ranking über die Summe der entsprechend normalisierten Distanzen, so wie sie die einzelnen Merkmalsvektoren zurückliefern, berechnen. Diese ungewichtete Kombination behandelt alle Merkmalsvektoren einer Kombination als gleich wichtig, um das Gesamtranking zu bestimmen.

Wir führten Benchmarks mit allen  $2^{10}$  Kombinationen der besten 10 Verfahren aus unserem Setting durch. Abb. 3 (links) zeigt einen Scatterplot der durchschnittlichen R-Precision Ergebnisse aller möglichen Kombinationen der Kardinalitäten 1 bis 10. Die Precision-Recall Kurven für die besten Kombinationen der Kardinali-



**Abb. 4: Dynamisch gewichtete Kombinationen.**

tät 1 bis 6 sind in Abb. 3 (rechts) gegeben. Das Resultat bestätigt unsere Annahme, dass FV-Kombinationen existieren, welche im Benchmark Durchschnitt erheblich besser als das beste einzelnen Verfahren (Depth Buffer) abschneiden. Das beste Ergebnis erzielt eine Kombination aus 7 Merkmalsvektoren mit 45% R-Precision, was einer Verbesserung von ca. 40% gegenüber der Leistung des Depth Buffers entspricht. Der größte Verbesserungssprung hinsichtlich der Kombinationskardinalität tritt beim Übergang von einem einzelnen Merkmalsvektor zu einer 2er Kombination auf (von Depth Buffer mit 32% R-Precision zu Voxel+Complex mit 39% R-Precision). Bis 7 Vektoren ist eine Verbesserung möglich, danach sinkt die Anfrageleistung wieder.

## 4.2 Dynamische Kombinationen

Die experimentellen Resultate vom letzten Abschnitt zeigten, dass die Verwendung von Kombinationen eine signifikante Verbesserung der Anfrageleistung in unserem 3D Suchsystem ermöglichen. Jedoch liefert eine statische Kombination nicht notwendigerweise optimale Resultate, weil die Aufnahme von ungeeigneten Verfahren das abschließende Resultat beeinflussen wird. Analog zur Betrachtung einzelner Verfahren zeigt sich zudem, dass die durchschnittlich beste Kombination nicht auch für jede einzelne Anfrageklasse das beste Ergebnis liefert. Folglich besteht das Problem festzustellen, welche Merkmalsvektoren für eine gegebene Anfrage zu kombinieren sind. Um dieses Problem zu lösen, schlagen wir vor, dynamisch bestimmte Gewichte für zur Bildung von

Kombinationen aus Merkmalsvektoren zu verwenden die darauf abzielen, ein hohes Gewicht jenen Vektoren zu geben, die am besten für ein gegebenes Anfrageobjekt geeignet sind. Wir schlagen vor, die zu erwartende Güte eines Merkmalsvektors für ein Anfrageobjekt zunächst auf einer Trainingsdatenbank zu schätzen, und das Schätzmaß als Gewicht zur Bildung einer dynamischen Kombination zu verwenden.

Als Schätzmaß für die zu erwartende Güte hat sich das Entropy-Impurity Maß [Duda et al. 2000] als geeignet erwiesen. Die Entropie ist ein Maß für die Homogenität bzw. Heterogenität einer Verteilung an Symbolen. In unserem Ansatz wird zu einem gegebenen Anfrageobjekt zunächst eine Probeanfrage auf einer klassifizierten Referenzdatenbank ausgeführt. Die Entropie der Verteilung der Klassen im Anfrageergebnis für jeden Merkmalsvektor wird berechnet, und nach entsprechender Normalisierung als Gewicht für die dynamische Kombination zur Ausführung auf der eigentlichen Datenbank verwendet. Die Intuition ist die, dass Merkmalsvektoren, welche für ein Anfrageobjekt gut geeignet sind, auf einer Testdatenbank eine relativ kohärente Verteilung nur weniger verschiedener Klassen liefern, während schlechte Merkmalsvektoren eher zufällige Objekte zurückliefern, was sich in einer heterogenen Klassenverteilung mit relativ hoher Entropie bzgl. der Klassenlabels niederschlägt. Wir haben zu diesem Ansatz ebenfalls Experimente durchgeführt [Bustos et al. 2004b]. Wir benutzen für Kreuzvalidierung einen Teil unseres Benchmarks als Trainingsdatenbank und den Rest als Evaluierungsdatenbank, um dynamische Gewichte für die fünf durchschnittlich besten Verfahren aus Abschnitt 3 zu bilden.

Abb. 4 zeigt die erhaltenen R-Precision Werte für verschiedene Verwendungen der Entropiebasierten Gewichte, wenn die Länge  $k$  des Präfix der Testanfrageergebnisse, welche für die Entropieberechnung herangezogen werden, variiert wird. Zunächst ist eine Selektion von Merkmalsvektoren möglich, die in eine ungewichtete dynamische Kombination eingehen: es werden die jeweils 1, 2, oder 3 am besten geschätzten Vektoren kombi-

niert. Diese Methode liefert R-Precision Ergebnisse im Bereich 36%, 40%, und 42%, und ist robust in der Länge des Präfix  $k$ . Alle diese Ergebnisse sind signifikant besser als das isoliert beste Verfahren (Depth Buffer, 32% R-Precision). Das beste Ergebnis erzielen wir, wenn wir alle Merkmalsvektoren in einer dynamischen, gewichteten Kombination einsetzen (oberste Kurve). Hierbei wird bei der Aggregation von normalisierten Distanzen die Distanz, wie sie von einem jeden Merkmalsvektor zurückgegeben wird, mit dem invertierten Entropiewert skaliert. Verfahren mit niedriger Entropie (kohärenten Testergebnissen) werden entsprechend übergewichtet. Es resultiert eine Retrievalgüte von ca. 43%, was ebenfalls einer signifikanten Steigerung bzgl. dem isoliert besten Verfahren (Depth Buffer) entspricht. Wir bemerken abschließend, dass der Vorteil von dynamisch gewichteten Kombinationen aufgrund eines solchen Schätzschemas zuletzt auch in [Ohbuchi & Hata 2006] bestätigt werden konnte.

## 5. Visuelle Benutzerschnittstellen

Im Vorhergehenden wurde die Retrievalqualität von Merkmalsvektoren unter dem Query-by-Example Suchparadigma experimentell untersucht. Während dieses Paradigma vorherrschend ist, sind weitere merkmalsbasierte Zugriffsmethoden auf große Bestände von Multimedia Daten möglich und hilfreich. Betrachtet man z.B. einen Benutzer, welcher mit einer unbekanntem 3D-Datenbank konfrontiert wird. Sofern noch keine Anfrageobjekte vorhanden sind, wird der Benutzer zunächst versuchen wollen, sich einen Überblick über die in der Datenbank vorhandenen Objektklassen zu verschaffen. Vor diesem Hintergrund sind visuelle Browsing-Schnittstellen wünschenswert. Typischerweise ist die Anzahl vorhandener Objekte jedoch viel zu groß, als dass der vollständige 3D-Datenbestand auf einem typischen Desktop Display dargestellt werden kann - vielmehr sind komprimierte Repräsentationen erforderlich.

Als geeignetes Verdichtungsverfahren für Merkmalsbasierte Multimedia

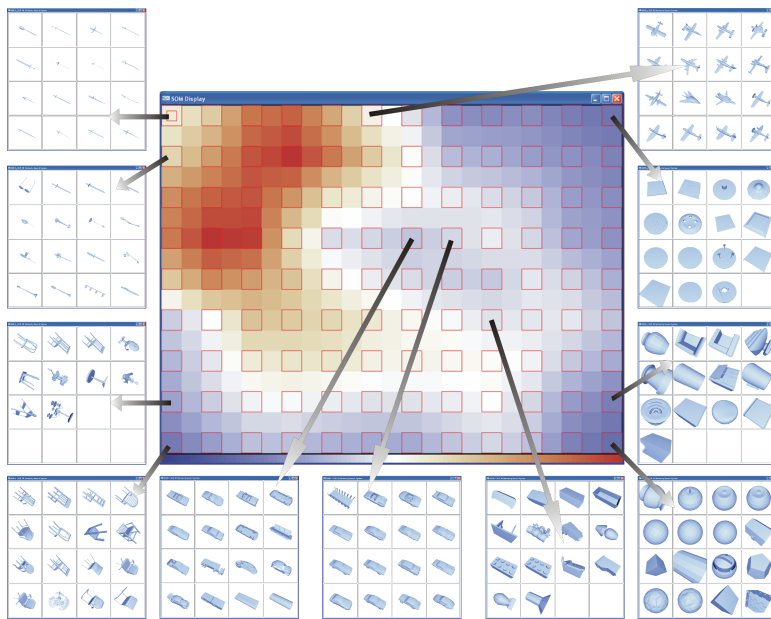


Abb. 5: Selbstorganisierende Karte einer 3D-Datenbank.

Datenbanken haben sich Selbstorganisierende Karten (Self-Organizing Maps, SOMs) [Kohonen 2001] auch für hochdimensional beschriebene 3D Objekte erwiesen [Bustos et al. 2004a]. SOMs wurden schon erfolgreich zur Visualisierung einer ganzen Reihe von Multimedia Datentypen wie z.B. Webdokumenten [Honkela et al. 1997], Musikstücken [Pampalk et al. 2002], oder E-Mail Daten [Keim et al. 2005] eingesetzt. Der SOM-Algorithmus von Kohonen verwendet einen kompetitiven Lernalgorithmus, welcher aus einer Verteilung hochdimensionaler Eingangsvektoren ein regelmäßiges Gitter aus Referenzvektoren lernt. Die Referenzvektoren wiederum repräsentieren bestimmte Eigenschaften der Verteilung der Ausgangsdaten. Während das SOM Verfahren zunächst nichtdeterministisch ist und es schwierig ist, bestimmte Konvergenzeigenschaften zu garantieren, zeigen sich in der Praxis eine Reihe robuster und nützlicher Eigenschaften des Algorithmus, welche das Verfahren ideal für die Organisation großer Mengen an Merkmalsbeschriebener Daten erscheinen lassen. So bildet die SOM approximativ Nachbarschaftsbeziehungen aus den Eingangsdatenverteilungen mittels Nachbarschaftsbeziehungen auf dem SOM Referenzvektorengitter nach. Zudem erhalten häufiger auftretende Datenmuster größere Bereiche auf dem SOM Gitter zugewiesen, als schwächer vertretene Bereiche, so dass annähernd eine

Proportionalität zur Musterverteilung gegeben ist. In unseren Arbeiten konnten wir die praktische Eignung des SOM Algorithmus für extrem hochdimensionale Daten überprüfen, da die diskutierten 3D Merkmalsvektoren üblicherweise über hunderte von Dimensionen verfügen, und der SOM Algorithmus zumeist sehr nützliche Ergebnisse produzieren konnte - ein Ergebnis, das nicht von vornherein zu erwarten war. Wir konnten den Output des SOM Algorithmus aufgrund seiner Eignetheit zur Visualisierung [Vesanto 1999] erfolgreich zur Datenbankbeschreibung, sowie zur Unterstützung des Retrievalprozesses und in der visuellen Merkmalsraum-Evaluierung einsetzen. Die nächsten Abschnitte skizzieren jeweils entsprechende visuelle Benutzerschnittstellen.

### 5.1 SOM-basierter Überblick

Abb. 5 zeigt eine selbstorganisierende Karte unserer Evaluierungsdatenbank, beschrieben unter dem 366-dimensionalen Depth Buffer Merkmalsvektor. Der mittlere Teil der Abbildung visualisiert das Gitter aus Referenzvektoren, sowie ein geglättetes Dichtehistogramm [Pampalk et al. 2002] der Belegung des Gitters mit Datenbankobjekten (die Schattierung visualisiert die Dichte). Darum herum sind Browserfenster angeordnet, welche Mengen von Objekten anzeigen, wie sie im Nächste-Nachbarn Sinn durch ausge-

wählte SOM-Vektoren repräsentiert werden. Die Referenzvektoren der Karte organisieren die 3D Objekte semantisch sinnvoll entlang geometrischer Eigenschaften. In der Ecke oben links befinden sich Objekte mit dünnlich-verlängerten Geometrien wie etwa Schwerter, Lampen, Besteckobjekte etc. Auf der entgegen gelegenen Ecke rechts unten befinden sich entsprechend gegensätzliche Geometrien - voluminöse und kugelförmige Formen sind hier anzutreffen. Auf einem Pfad entgegen der Uhrzeigerrichtung von der Ecke links oben nach rechts unten entlang dem Kartenrand verändert sich die Form der abgebildeten Objekte von dünn verlängerten, über mehr komplex aufgebaute aber immer noch dünnen Objekten (etwa Stühlen). Bewegt man sich diagonal von der Ecke links oben nach rechts unten auf der Karte, so vollzieht sich der Übergang über eher längliche, zugleich voluminöse Objekte wie etwa Flugzeuge oder Automobile. In der Kombination aus Häufigkeitsverteilung und topologischer Anordnung nach geometrischer Ähnlichkeit ist der Benutzer in der Lage, sich einen effektiven Überblick über die Inhalte einer zuvor unbekannteren Datenbanken zu verschaffen. Zudem bieten sich kollaborative Ansätze zur effizienten Annotation von solchen inhaltsbasiert organisierten Karten an.

### 5.2 SOM-basiertes Retrieval

Die SOM Technologie bietet sich auch als benutzerfreundliche Retrievalschnittstelle an. Wir haben ein 3D Suchsystem implementiert, in dem neben einer Query-By-Example Schnittstelle (Auswahl des Anfrageobjekts und Ergebnisbrowser) auch eine SOM-basierte Ansicht zur Verfügung steht, welche mit dem Ergebnisbrowser bidirektional verknüpft ist. Diese Architektur erlaubt es einem Benutzer eine quasi mehrdimensionale Verarbeitung von Suchergebnissen vorzunehmen: Anstatt der Durchsicht einer linearen sortierten Ergebnisliste (nächste-Nachbarn Anfrage) kann der Benutzer alternativ ein Anfrageobjekt auf die SOM abbilden, und dann die Nachbarschaft auf der Karte nach weiteren interessierenden Objekten zu explorieren. Umgekehrt ist es möglich, auf der SOM gefundene Objekte als Suchanfrage für

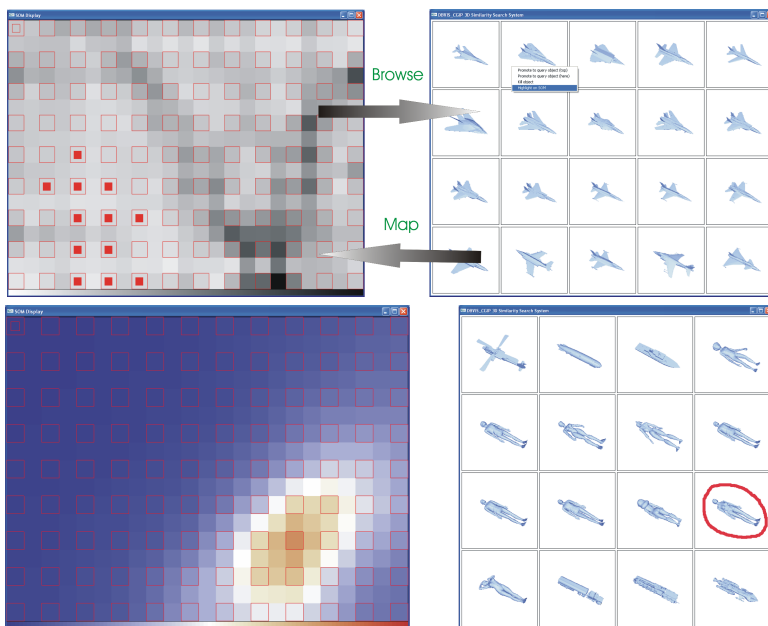


Abb. 6: Retrievalunterstützung durch Browsing und Mapping.

weitere Ähnlichkeitssuchanfragen zu verwenden (vgl. Abb. 6 oben). Durch die Verbindung der Nächste Nachbarn Anfrage mit SOM-gestützter Visualisierung kann der Benutzer schließlich jene Bereiche der Karte explorieren, in denen sich aufgrund des Mappings von Objekten auf die Karte weitere interessante Objekte vermuten lassen. Unterstützt werden kann dieser Explorationsprozess durch so genannte Response Maps, welche die Güte des Matching eines gegebenen Objektes bzgl. den Referenzvektoren einer SOM visuell darstellt. In Abb. 6 (unten) ist eine solche Response Map bezüglich eines markierten Anfrageobjektes gegeben. Die hell-umrandete Region bezeichnet die SOM-Nachbarschaft mit der besten Übereinstimmung der Referenzvektoren mit dem Anfrageobjekt. Der Benutzer kann diese Visualisierung benutzen, um die Karte gezielt zu explorieren: Die SOM Knoten, welche am besten mit dem Anfrageobjekte übereinstimmen, sind gute Kandidaten zum Auffinden weiterer relevanter Objekte.

### 5.3 Unüberwachte Diskriminierungsanalyse

In den vorhergehenden Abschnitten wurden Merkmalsvektoren auf ihre Retrievalgüte hin untersucht unter Verwendung von geeigneten Benchmarks. Retrievalgüte wurde mittels Precision/Re-


call Statistiken gemessen. Eine interessante Alternative zu solchem überwachten Benchmarking besteht in visuellem, unüberwachten Benchmarking. Die grundlegende Idee besteht darin, Visualisierung einzusetzen um auf die in einem gegebenen Merkmalsraum zu erwartende Diskriminierungskraft schließen zu können. Ein solcher Ansatz ist interessant, da nicht in jedem Fall geeignete überwachte Benchmarks vorhanden sind, bzw. diese in der Regel teuer, und in manchen Fällen auch unzuverlässig sind (siehe Müller et al. [Mueller et al. 2002]). In Schreck et al. [Schreck et al. 2006] konnten wir ein Schema zur unüberwachten, vergleichenden visuellen Evaluierung von Merkmalsräumen entwickeln, welches auf SOM Technologie aufsetzt und die unüberwachte Schätzung von Diskriminierungskraft ermöglicht.

Die Grundidee dieses Ansatzes besteht darin, die Verteilung der Distanzen zwischen benachbarten SOM Referenzvektoren zu analysieren. Speziell wird der Grad der Gleichverteilung dieser Distanzen mit dem Grad der Diskriminierungskraft, welche man im gegebenen Merkmalsraum erwarten kann, assoziiert. Dieser Zusammenhang hat sich empirisch durch visuelle comparative Analyse entsprechender SOM-basierter Distanzbilder bestätigt. Die Intuition ist, dass in gut diskriminierenden Merkmalsräumen die Distanzen zwischen benachbarten

Objektclustern annähernd gleich verteilt sind, bzw. ein guter Kontrast zwischen niedrigen und hohen Distanzen beobachtet werden kann. SOMs in wenig diskriminierenden Merkmalsräumen bilden dagegen oftmals keine klaren Objektcluster aus, und viele benachbarte Referenzvektoren weisen ein homogenes, nicht diskriminierendes Distanzniveau auf; in den entsprechenden Distanzhistogrammen können dann Verzerrungen hin zu beliebigen Distanzintervallen beobachtet werden.

In [Schreck et al. 2006] konnte dieser Zusammenhang mittels Regressionsanalyse auf einem 3D Benchmark und für eine Vielzahl an Merkmalsvektoren statistisch bestätigt werden. In der Zwischenzeit wurden von uns ergänzende Experimente auf synthetischen Daten durchgeführt. Es wurden eine Reihe von Merkmalsräumen erzeugt, die sich hinsichtlich ihrer Diskriminierungskraft unterscheiden. Speziell wurde eine Datenbank mit 50 Klassen bestehend aus jeweils 50 Objekten angenommen. Die Klassen wurden mit 128-dimensionalen Merkmalsvektoren beschrieben, wobei alle Merkmalsdimensionen der Klassenmitglieder normalverteilt mit Varianz 1 um ein gegebenes Klassenzentroid herum angenommen wurden. Die Klassenzentroide wurden ihrerseits als gleichverteilt im Datenraum angenommen. Durch Kontrolle der Größe des Datenraumes wurden damit Merkmalsräume mit zunehmender Klassendiskriminierung erzeugt.

Abb. 7 stellt den Zusammenhang zwischen Diskriminierungsgüte einerseits (Größe des Datenraumes; Regressor), und der L1-Distanz zwischen dem SOM-basierten Distanzhistogramm und der theoretischen Gleichverteilung (abhängige Variable) dar. Es bestätigt sich eine klare negative Korrelation bei einem Gütemaß von  $R^2=86\%$  (logarithmische Regression): Je diskriminierender die Merkmalsräume sind, desto mehr ähneln die SOM-basierten Distanzhistogramme der theoretischen Gleichverteilung, gemessen am L1 Abstand. Dieser Zusammenhang ist auf den synthetischen Daten robust sowohl in der Gittergröße der selbstorganisierten Karten, als auch in der Länge der gewählten Histogramme, wie



**Abb. 7: Experiment zur visuellen Evaluierung von Merkmalsvektoren.**

wir in einer Experimentreihe feststellen konnten.

Wir glauben, dass solche visuell motivierten und zugleich numerisch bzw. automatisch auswertbaren, unüberwachten Güteschätzfunktionen den klassischen (überwachten) Benchmarkingansatz erfolgreich ergänzen können. Wir sehen dies insbesondere angesichts einer steigenden Anzahl unterschiedlicher Merkmalsextraktoren, welche laufend heuristisch entwickelt werden, und auch angesichts stetig zunehmender, heterogener Datenbestände, welche das Design und die Durchführung angepasster Benchmarks erschweren bzw. verteuern.

## 6 Offene Probleme

Eine ganze Reihe offener Probleme zeigen sich beim 3D Retrieval sowohl auf Seite der Merkmalsextraktion, als auch beim Design geeigneter Benutzerschnittstellen. Bei der Merkmalsbildung sind zunächst weitere, nicht Geometriebezogene Attribute zu berücksichtigen wie etwa Farbe, Textur, und volumenbezogene Modellspezifikationen, soweit in der Modellrepräsentation enthalten. Das Design von Merkmalsextraktoren und Benchmarks für spezialisierte 3D Inhalte, wie sie etwa in CAD-Datenbanken (z.B. Teilemodelle für den Anlagenbau) vorliegen, stellt ebenfalls interessante zukünftige Arbeit dar. Ein große Herausforderung besteht zudem in der Entwicklung von partiellen Ähnlichkeitsmodellen auf 3D Objekten, wobei die zu erwartende Komplexität zumindest bei nahe liegenden Segmentierungsbasierten Lösungen um Größenordnungen über der Komplexität der globalen Ähnlichkeitssuche, so wie sie die hier beschriebenen Verfahren im-

plementieren, liegen dürfte.

Benutzerschnittstellen spielen eine wichtige Rolle beim Zugriff auf Multimedia Datenbanken sowohl aus Benutzersicht, als auch aus Ingenieurssicht beim Design und der Evaluierung von Merkmalsräumen. Die Entwicklung effektiver visueller Anfrageschnittstellen, welche die für den Benutzer interessanten Objekte im Kontext des gesamten, gegebenen Datenbankinhalts darstellen, erscheint lohnenswert.

## Danksagung

Diese Arbeit wurde unterstützt von der Deutschen Forschungsgemeinschaft DFG im Rahmen des Schwerpunktprogramms "Verteilte Verarbeitung und Vermittlung digitaler Dokumente" (V3D2) in den Projekten KE 740/6-1, KE 740/8-1, und SA 449/10-1. Herr Bustos hat ein Stipendium von der Fakultät für Physik und Mathematik der Universität Chile.

## 7 Literatur

- [Ankerst et al. 1999] Ankerst, M.; Kastenmüller, G.; Kriegel, H.-P.; Seidl, T.: Nearest neighbor classification in 3D protein databases. In Proc. 7th International Conference on Intelligent Systems for Molecular Biology, S. 34-43. AAAI Press, 1999.
- [Bustos et al. 2004a] Bustos, B.; Keim, D.; Panse, C.; Schreck, T.: 2D maps for visual analysis and retrieval in large multi-feature 3D model databases. In Proc. IEEE Visualization (VIS'04), 2004, poster.
- [Bustos et al. 2004b] Bustos, B.; Keim, D.; Saupé, D.; Schreck, T.; Vranic, D.: Using entropy impurity for improved 3D object similarity search. In Proc. IEEE International Conference on Multimedia and Expo (ICME'04), S. 1303-1306. IEEE, 2004.
- [Bustos et al. 2005] Bustos, B.; Keim, D.; Saupé, D.; Schreck, T.; Vranic, D.: Feature-based similarity search in 3D object databases. ACM Computing Surveys, 37(4):345-387. 2005.
- [Bustos et al. 2006] B. Bustos, D. Keim, D. Saupé, T. Schreck, and D. Vranic. An experimental effectiveness comparison of methods for 3D similarity search. International Journal on Digital Libraries, Special Issue on Multimedia Contents and Management in Digital Libraries, 6(1):39-54. 2006.
- [Baeza-Yates & Ribeiro-Neto 1999] Baeza-Yates, R.; Ribeiro-Neto, B.: Modern Information Retrieval. Addison-Wesley, 1999.
- [Chen et al. 2003] Chen, D.; Tian, X.; Shen, Y.; Ouhyoung, M.: On visual similarity based 3D model retrieval. Computer Graphics Forum 22(3):223-232. 2003.
- [Duda et al. 2000] Duda, R.; Hart, P.; Stork, D.: Pattern Classification. Wiley-Interscience, New York, 2001.

- [Funkhouser et al. 2003] Funkhouser, T.; Min, P.; Kazhdan, M.; Chen, J.; Halderman, A.; Dobkin, D.; Jacobs, D.: A search engine for 3D models. ACM Transactions on Graphics 22(1):83-105. 2003.
- [Hilaga et al. 2001] Hilaga, M.; Shinagawa, Y.; Kohmura, T.; Kunii, T.: Topology matching for fully automatic similarity estimation of 3D shapes. In Proc. 28th SIGGRAPH Annual Conference on Computer Graphics and Interactive Techniques, S. 203-212. ACM Press, 2001.
- [Honkela et al. 1997] Honkela, T.; Kaski, S.; Lagus, K.; Kohonen, T.: WEBSOM—self-organizing maps of document collections. In Proc. Workshop on Self-Organizing Maps (WSOM'97), Helsinki University of Technology, 1997.
- [Kohonen 2001] Kohonen, T.: Self-Organizing Maps. Springer, Berlin, 3rd edition, 2001.
- [Kazhdan et al. 2003] Kazhdan, M.; Funkhouser, T.; Rusinkiewicz, S.: Rotation invariant spherical harmonic representation of 3D shape descriptors. In Proc. Eurographics/ACM SIGGRAPH Symposium on Geometry Processing, pp. 156-164. Eurographics Association, 2003.
- [Keim et al. 2005] Keim, D.; Mansmann, F.; Schreck, T.: Mailsom - visual exploration of electronic mail archives using self-organizing maps. In Proc. 2nd Conference on Email and Anti-Spam (CEAS'05), Stanford University, Palo Alto, CA, 2005.
- [Keim 1999] Keim, D.: Efficient geometry-based similarity search of 3D spatial databases. In Proc. ACM SIGMOD International Conference on Management of Data, S. 419-430. ACM Press, 1999.
- [Mueller et al. 2002] Mueller, H.; Marchand-Maillet, S.; Pun, T.: The truth about corel - evaluation in image retrieval. In Proc. International Conference on Image and Video Retrieval (CIVR'02), S. 38-49. Springer-Verlag, 2002.
- [Novotni & Klein 2004] Novotni M.; Klein, R.: Shape retrieval using 3D Zernike descriptors. Computer Aided Design 36(11):1047-1062. 2004.
- [Osada et al. 2002] Osada, R.; Funkhouser, T.; Chazelle, B.; Dobkin, D.: Shape Distributions. ACM Transactions on Graphics 21(4):807-832. 2002.
- [Ohbuchi & Hata 2006] Ohbuchi, R.; Hata, Y.: Combining Multiresolution Shape Descriptors for 3D Model Retrieval. In Proc. 14th International Conference in Central Europe on Computer Graphics, Visualization, and Computer Vision. 2006.
- [Paquet et al. 2000] Paquet, E.; Murching, M.; Naveen, T.; Tabatabai, A.; Rioux, M.: Description of shape information for 2-D and 3-D objects. Signal Processing: Image Communication 16:103-122. 2000.
- [Pampalk et al. 2002] Pampalk, E.; Rauber, A.; Merkl, D.: Using smoothed data histograms for cluster visualization in self-organizing maps. In Proc. International Conference on Artificial Neural Networks (ICANN'02), Springer, 2002.
- [Ronneberger et al. 2002] Ronneberger, O.; Bur-

- hardt, H.; Schultz, E.: General-purpose object recognition in 3D volume data sets using gray-scale invariants - classification of airborne pollen-grains recorded with a confocal laser scanning microscope. In Proc. 16th International Conference on Pattern Recognition, Vol. 2, S. 290-295. IEEE Computer Society, 2002.
- [Schreck et al. 2006] Schreck, T.; Keim, D.; Panse, C.: Visual feature space analysis for unsupervised effectiveness estimation and feature engineering. In Proc. IEEE International Conference on Multimedia and Expo, 2006.
- [Sundar et al. 2003] Sundar, H.; Silver, D.; Gagvani, N.; Dickinson, S.: Skeleton based shape matching and retrieval. In Proc. Shape Modeling International., S. 130-142. IEEE Computer Society, 2003.
- [Vesanto 1999] Vesanto, J.: SOM-based data visualization methods. *Intelligent Data Analysis*, 3(2):111–126, 1999.
- [Vranic et al. 2001] Vranic, D.; Saupe, D.; Richter, J.: Tools for 3D-object retrieval: Karhunen-Loeve transform and spherical harmonics. In Proc. IEEE 4th Workshop on Multimedia Signal Processing, S. 293-298. 2001.
- Benjamin Bustos** ist Doktorand und wissenschaftlicher Mitarbeiter am Lehrstuhl für Datenbanken und Visualisierung an der Universität Konstanz. Seine Dissertation mit dem Titel "Index Structures for Similarity Search in Multimedia Databases" wurde im Juni 2006 eingereicht.
- Daniel Keim** ist Professor für Informatik an der Universität Konstanz und leitet die Arbeitsgruppe Datenbanken, Data Mining und Visualisierung. Seine Arbeitsschwerpunkte sind Ähnlichkeitssuche und Indexierung multimedialer Daten, sowie Data Mining und Informationsvisualisierung.
- Dietmar Saupe** ist Professor für Praktische Informatik an der Universität Konstanz und leitet das DFG-Graduiertenkolleg "Explorative Analysis and Visualization of Large Information Spaces". Sein Forschungsinteresse ist Multimedia-Signalverarbeitung.
- Tobias Schreck** ist Doktorand und wissenschaftlicher Mitarbeiter am Lehrstuhl für Datenbanken und Visualisierung an der Universität Konstanz. Seine Dissertation mit dem Titel "Effective Retrieval and Visual Analysis in Multimedia Databases" wurde im Juli 2006 eingereicht.
- Andrada Tatu** studiert Information Engineering an der Universität Konstanz und arbeitet als Hilfwissenschaftlerin am Lehrstuhl für Datenbanken und Visualisierung. Ihr Forschungsinteresse liegt im Bereich der Informationsvisualisierung.