



(19)
Bundesrepublik Deutschland
Deutsches Patent- und Markenamt

(10) **DE 10 2006 017 112 A1 2006.11.09**

(12)

Offenlegungsschrift

(21) Aktenzeichen: **10 2006 017 112.8**

(22) Anmeldetag: **10.04.2006**

(43) Offenlegungstag: **09.11.2006**

(51) Int Cl.⁸: **G06T 7/60 (2006.01)**

G06K 9/48 (2006.01)

G06F 17/10 (2006.01)

(30) Unionspriorität:

60/672,649	19.04.2005	US
11/397,040	03.04.2006	US

(74) Vertreter:

Patentanwälte Westphal Mussnug & Partner,
78048 Villingen-Schwenningen

(71) Anmelder:

Siemens Corporate Research, Inc., Princeton,
N.J., US

(72) Erfinder:

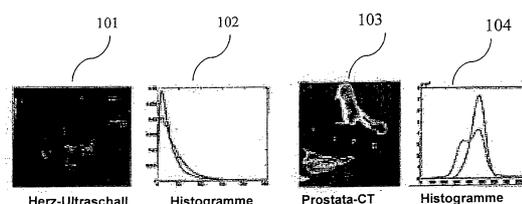
Cremers, Daniel, 53117 Bonn, DE; Rousson,
Mikael, Trenton, N.J., US

Prüfungsantrag gemäß § 44 PatG ist gestellt.

Die folgenden Angaben sind den vom Anmelder eingereichten Unterlagen entnommen

(54) Bezeichnung: **Effiziente Kerndichteschätzung von früheren Form- und Intensitätsbeispielen für die Niveausatz-Segmentierung**

(57) Zusammenfassung: Verfahren und Systeme für die Bildsegmentierung sind offenbart. Ein nicht-lineares statistisches Formmodell eines Bilds wird mit einem nicht-parametrischen Intensitätsmodell integriert, um Eigenschaften eines Bilds zu schätzen und Segmentierungen eines Bilds auf der Basis eines Bayes'schen Rückschlusses von Eigenschaften von früher gelernten Bildern auf der Basis derselben Modelle zu erzeugen.



Beschreibung

Angabe verwandter Anmeldungen

[0001] Diese Anmeldung beansprucht die Priorität der vorläufigen US-Anmeldung 60/672,649 vom 19. April 2005, die hierin mittels Bezugnahme beinhaltet ist.

Hintergrund der Erfindung

[0002] Diese Erfindung betrifft Systeme und Verfahren zum Bearbeiten digitaler Bilder. Spezieller betrifft sie die Bildsegmentierung, bei der ein interessierendes Objekt in einem Bild vom Hintergrund dieses Objekts im Bild getrennt wird.

[0003] Segmentierung ist ein häufig auftretendes Problem bei der Bildverarbeitung. Sie ist besonders wichtig bei der medizinischen Bildgebung, wo es gewünscht ist, ein Objekt, wie beispielsweise ein Organ oder einen Tumor, aus einem Bild zur weiteren Bearbeitung zu extrahieren.

Stand der Technik

[0004] Es gibt viele verschiedene verfügbare Segmentierungsverfahren. Die Effektivität aller Segmentierungsverfahren variiert mit der Qualität der Bilddaten, der Anwendung sowie einer Anzahl anderer Faktoren.

[0005] Segmentierung in medizinischen Bilddaten ist besonders schwierig. Die massive Menge von Daten macht die Segmentierung in diesem Bereich schwierig. Außerdem ist die Qualität der Bilddaten, die von medizinischen Bildgebungsvorrichtungen erhalten wird, nicht immer optimal. Zudem ist die Qualität der Segmentierung im Allgemeinen sehr wichtig, weil die Segmentierung verwendet werden kann, um eine Diagnose oder einen Behandlungsplan zu erstellen.

Aufgabenstellung

[0006] Dementsprechend sind neue und verbesserte Verfahren und Systeme notwendig, die eine Segmentierung von Bildern und Bildvolumina erzeugen.

Zusammenfassung der Erfindung

[0007] Die vorliegende Erfindung betrifft ein Verfahren zum Segmentieren eines Objekts in einem Satz von Bilddaten unter Verwendung von einem oder mehreren früheren Beispielen des Objekts. Gemäß einem Gesichtspunkt der vorliegenden Erfindung umfassen die Schritte das Bestimmen einer nicht-parametrischen Schätzung einer Eigenschaft von dem einem oder den mehreren früheren Beispielen des Objekts in einem Unterraum, der von dem einen oder den mehreren früheren Beispielen des Objekts aufgespannt wird, das Anwenden der nicht-parametrischen Schätzung des einen oder der mehreren früheren Beispiele in einem Bayes'schen Ausdruck auf den Satz von Bilddaten und das Auswählen einer Segmentierung des Objekts im Satz von Bilddaten durch Ausführen eines Niveausatz-Verfahrens, das den Bayes'schen Ausdruck optimiert.

[0008] Die Eigenschaft kann eine Intensität sein. Sie kann auch eine Form sein. Die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts kann auf einem Durchschnittswert einer Eigenschaft basieren, der mit jedem der früheren Beispiele des Objekts assoziiert ist. Die Eigenschaft von dem einem oder den mehreren früheren Beispielen des Objekts kann auf einer Abstandsfunktion basieren. Der Ausdruck kann eine Energiefunktion sein. Die Eigenschaft von dem einem oder den mehreren früheren Beispielen des Objekts kann translations- und rotationsinvariant sein. Die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts kann auf einer Dichtefunktion basieren, beispielsweise der Kerndichte.

[0009] Der Ausdruck kann sein:

$$E(\alpha, h, \theta) = - \int_{\Omega} H_{\Phi} \log p_{in}(I) + (1 - H_{\Phi}) \log p_{out}(I) dx - \log \left(\frac{1}{N\sigma} \sum_{i=1}^N K \left(\frac{\alpha - \alpha_i}{\sigma} \right) \right)$$

[0010] Es ist ein Gesichtspunkt der vorliegenden Erfindung, effiziente Bildsegmentierungsverfahren unter Verwendung von Niveausatz-Segmentierung und Anwendung früherer Kenntnis auf das zu segmentierende Bild zu schaffen.

[0011] Es ist ein weiterer Gesichtspunkt der vorliegenden Erfindung, ein statistisches früheres Formbeispiel vorzusehen, das die Effizienz der niedrig-dimensionalen Verfahren auf PCA-Basis (Analyse der Hauptkomponenten) mit der Genauigkeit von nicht-parametrischen statistischen Formmodellen kombiniert.

[0012] Es ist ein weiterer Gesichtspunkt der vorliegenden Erfindung, Schätzungsverfahren für die statistischen Eigenschaften von Objekten in Bildern zu schaffen.

[0013] Es ist ein weiterer Gesichtspunkt der vorliegenden Erfindung, eine Abstandsfunktion für die Niveausatz-Segmentierung vorzusehen, die nicht-parametrisch ist.

[0014] Es ist ein weiterer Gesichtspunkt der vorliegenden Erfindung, die Formverteilung von Objekten durch die Kerndichteschätzung zu modellieren.

[0015] Es ist ein weiterer Gesichtspunkt der vorliegenden Erfindung, Verfahren der Niveausatz-Segmentierung als Bayes'schen Rückschluss von gelernten früheren Beispielen vorzusehen.

[0016] Es ist ein weiterer Gesichtspunkt der vorliegenden Erfindung, ein Verfahren zu schaffen, um die Intensitätsinformationen im Bild optimal zu verwenden, indem wahrscheinlichkeitstheoretische Intensitätsmodelle verwendet werden, die durch Kerndichteschätzungen von zuvor beobachteten Intensitätsverteilungen von gelernten früheren Beispielen gebildet werden.

[0017] Es ist ein weiterer Gesichtspunkt der vorliegenden Erfindung, ein Verfahren für die kenntnisgesteuerte Niveausatz-Segmentierung zu schaffen, indem mehrere Gesichtspunkte der vorliegenden Erfindung verknüpft werden.

Ausführungsbeispiel

Beschreibung der Zeichnungen

[0018] [Fig. 1](#) zeigt medizinische Bilder mit dazugehörigen Intensitäts-Diagrammen.

[0019] [Fig. 2](#) zeigt verschiedene Dichte-Diagramme.

[0020] [Fig. 3](#) zeigt die Effekte von linearer Forminterpolation gegenüber nicht-linearer Forminterpolation.

[0021] [Fig. 4](#) zeigt den Effekt verschiedener früherer Modelle.

[0022] [Fig. 5](#) zeigt Bilder von Objektsegmentierung.

[0023] [Fig. 6](#) zeigt zusätzliche Bilder von Objektsegmentierung.

[0024] [Fig. 7](#) zeigt das erfindungsgemäße Verfahren gemäß einem Aspekt der vorliegenden Erfindung.

[0025] [Fig. 8](#) zeigt ein Diagramm eines Bildsegmentierungssystems.

Beschreibung einer bevorzugten Ausführungsform

[0026] Ein Niveaueinstellverfahren wurde ursprünglich vorgeschlagen als ein Mittel zum zeitlichen Propagieren von Übergangsstellen, siehe hierzu beispielsweise A. Dervieux und F. Thomasset, "Ein Verfahren mit finiten Elementen für die Simulation von Raleigh-Taylor-Instabilität", Springer Lect. Notes in Math., 771: 145–158 1979, und S. J. Osher und J. A. Sethian, "Frontenpropagierung mit krümmungsabhängiger Geschwindigkeit: Algorithmen auf der Basis von Hamilton-Jacobi-Formulierungen", J. of Comp. Phys., 79: 12–49, 1988.

[0027] Das Niveausatz-Verfahren wurde zunehmend populär als Rahmen für die Bildsegmentierung. Die Schlüsselidee liegt darin, eine Übergangsstelle $\Gamma \subset \Omega$ im Bildbereich $\Omega \subset \mathbb{R}^3$ als den Null-Niveau-Satz einer einbettenden Funktion $\Phi: \mathbb{R}^3 \rightarrow \Omega$ darzustellen:

$$\Gamma = \{x \in \Omega \mid \Phi(x) = 0\}, \quad (1)$$

und Γ zu entwickeln, indem die einbettende Funktion Φ gemäß einer geeigneten partiellen Differentialgleichung

chung propagiert wird. Die ersten Anwendungen dieses Niveausatzformalismus zum Zwecke der Bildsegmentierung wurden vorgeschlagen in V. Caselles, F. Catté, T. Coll und F. Dibos, "Ein geometrisches Modell für aktive Konturen in der Bildbearbeitung", Numer. Math., 66: 1–31, 1993, R. Malladi, J. A. Sethian und B. C. Vemuri, "Ein Topologie-unabhängiges Formmodellierungsschema", SPIE Konferenz über geometrische Verfahren bei der Computervision II, Band 2031, Seiten 246–258, 1994, und S. Kichenassamy, A. Kumar, P. J. Giver, A. Tanenbaum und A. J. Yezzi, "Gradientenströme und geometrische aktive Konturmodelle" Proc. IEEE Intl. Conf. on Comp. Visa, Seiten 810–815, Boston, USA, 1995. Zwei Hauptvorteile gegenüber der expliziten Übergangsstellenpropagierung sind die Unabhängigkeit einer speziellen Parametrisierung und die Tatsache, dass die implizit dargestellte Grenze Γ topologischen Veränderungen wie Aufteilen oder Zusammenfassen unterzogen werden kann. Dies macht den Rahmen gut geeignet für die Segmentierung von mehreren Objekten oder mehrfach verbundenen Objekten. Ein Ansatz, um eine frühere Formenkenntnis bei Objektsegmentierungs-Niveausatz-Verfahren einzuführen und die frühere Kenntnis auf stochastische Weise zum Detektieren eines Objekts in einem Bild einzusetzen, wurde in der US-Patentanmeldung 2005/0169533 "Frühere Kenntnis, Niveausatz-Darstellung und visuelles Gruppieren" von Nikolaos Paragios beschrieben, die hierin durch Bezugnahme in ihrer Gesamtheit beinhaltet ist. Zunächst wird eine kurze Beschreibung des Niveausatz-Ansatzes geliefert.

[0028] Segmentierung wird bei der vorliegenden Erfindung vorzugsweise durch Niveausatz-Verfahren unter Verwendung von sich gemäß einer Strömung entwickelnden Übergangsstellen (z.B. Kurven) durchgeführt. Die Strömung, die die Propagierung der Kurve lenkt, kann durch die Minimierung einer objektiven Funktion, wie einer Energiefunktion, wiedererlangt werden. Um Niveausatz-Darstellungen einzuführen, stelle man sich eine parametrische Kurve vor, die sich gemäß einer vorgegebenen Bewegungsgleichung in Normalrichtung der Kurve (z.B. Krümmung) entwickelt. Diese Strömung kann unter Verwendung eines Lagrange-Ansatzes implementiert sein. Die Kontur wird in diskreter Form unter Verwendung einer Auswahl von Kontrollpunkten dargestellt. Die Kurvenposition kann aktualisiert werden, indem Gleichungen gelöst werden, die die Kurve und ihre Bewegung für jeden Kontrollpunkt beschreiben. Eine solche Technik kann im allgemeinsten Fall die Topologie der sich entwickelnden Kurve nicht verändern, und eine Rückparametrisierung der sich entwickelnden Kurve kann notwendig sein. Das Niveausatz-Verfahren wurde ursprünglich im Bereich von Flüssigkeitsdynamik eingeführt und ist eine sich entwickelnde Technik, die mit verschiedenen Anwendungen in der Bildgebung, Vision und Grafik zurechtkommt. Niveausatz-Verfahren stellen die sich entwickelnde Kurve mit dem Null-Niveau einer Oberfläche dar. Eine solche Darstellung ist implizit, intrinsisch und parameterfrei. Formgesteuerte kenntnisbasierte Segmentierungsverfahren dienen dazu, eine Struktur wiederzuerlangen, die eine konsistente geometrische Form besitzt, wenn sie mit einem früheren Modell verglichen wird. Die Modellbildung des früheren Modells ist notwendig zum Einführen von globalen formgesteuerten Randbedingungen. Dies ist äquivalent zum Extrahieren einer Darstellung für die interessierende Struktur aus einem Satz von Trainingsbeispielen. Die Auswahl der Darstellung betrifft die Form des früheren Modells, das eingeführt werden soll. Die Modellbildung ist ein wichtiger Aspekt von formgesteuerten Segmentierungstechniken. Gemäß einer Ausführungsform der vorliegenden Offenbarung wird eine Formulierung implementiert, um frühere Kenntnis in einem Niveausatz-Verfahren für formgesteuerte kenntnisbasierte Objektextrahierung zu berücksichtigen. Objekte werden unter Verwendung einer stochastischen Abstandsfunktion dargestellt. Randbedingungen werden dem Segmentierungsprozess auf Bayes'sche Weise auferlegt, um nach einer geometrischen Struktur in der Bildebene zu suchen, die zur Familie von Formen gehört, die durch das frühere Modell erzeugt wurden.

[0029] Bei der Segmentierung medizinischer Bilder muss man sich im Allgemeinen mit Rauschen sowie fehlenden oder irreführenden Informationen beschäftigen. Bei bestimmten Bildgebungsverfahren, wie Ultraschall oder CT, unterscheiden sich die interessierenden Strukturen hinsichtlich ihrer Intensitätsverteilung nicht stark vom Hintergrund. Eine beispielhafte Darstellung hiervon ist in [Fig. 1](#) gezeigt. Deshalb können Objekte auf der Basis der Bildinformationen alleine nicht genau segmentiert werden. In jüngeren Jahren haben Forscher daher vorgeschlagen, das Niveausatz-Verfahren mit Hilfe von statistischen früheren Formbeispielen zu verbessern. Wenn ein Satz von Trainingsformen gegeben ist, kann man Informationen darüber einbringen, welche Segmentierungen a priori mehr oder weniger wahrscheinlich sind. Solche Informationen eines früheren Formbeispiels verbesserten erwiesenermaßen die Segmentierungsergebnisse bei gleichzeitigem Vorhandensein von Rauschen oder Verdeckung drastisch. Siehe hierzu beispielsweise die folgenden Publikationen: M. Leventon, W. Crimson und O. Faugeras, "Statistischer Formeinfluss bei geodätischen aktiven Konturen", CVPR, Band 1, Seiten 316–323, Hilton Head Island, SC, 2000; A. Tsai, A. J. Yezzi und A. S. Willsky, "Ein formbasierter Ansatz zur Segmentierung von medizinischen Bildern unter Verwendung von Niveausätzen", IEEE Trans. on Medical Imaging, 22(2): 137–154, 2003; D. Cremers, S. J. Osher und S. Soatto, "Kerndichteschätzungen und intrinsische Ausrichtung für kenntnisgesteuerte Segmentierung: Niveausätzen das Gehen beibringen", Pattern Recognition, Band 3175 von LNCS, Seiten 36–44, Springer, 2004; Rousson, N. Paragios und R. Deriche, "Implizite aktive Formmodelle für die 3D-Segmentierung in der Magnetresonanz-Bildgebung", MICCAI, Seiten 209–216, 2004; E. B. Dam, F. T. Fletcher, S. Pizer, C. Tracton und J. Rosenman, "Prostata-Formmodellierung

auf der Basis grundsätzlicher geodätischer Analyse", MICCAI, Ausgabe 2217 von LNCS, Seiten 1008–1016, September 2004; und D. Freedman, R. J. Radke, T. Zhang, Y. Jeong, D. M. Lovelock und G. T. Chen, "Modellbasierte Segmentierung von medizinischen Bildern durch Verteilungsanpassung", IEEE Trans. Med. Imaging, 24(3): 281–292, März 2005. Die meisten dieser Ansätze basieren auf der Annahme, dass die Trainingsformen, die durch ihre signierte Abstandsfunktion codiert sind, eine Gauß'sche Verteilung bilden. Dies bringt zwei Nachteile mit sich: zum ersten ist der Raum der signierten Abstandsfunktionen kein linearer Raum, und deshalb sind die mittlere Form und lineare Kombinationen von Eigenmoden typischerweise keine signierten Abstandsfunktionen mehr. Selbst wenn der Raum ein linearer Raum wäre, ist es zum zweiten nicht klar, weshalb der gegebene Satz von Beispielformen gemäß einer Gauß'schen Dichte verteilt sein sollte. Wie unter einem Gesichtspunkt der vorliegenden Erfindung gezeigt werden wird, sind sie in der Tat im Allgemeinen nicht gaußverteilt. In jüngster Zeit wurde vorgeschlagen, eine nicht-parametrische Dichteschätzung im Raum von Niveausatz-Funktionen anzuwenden, um nicht-lineare Verteilungen von Trainingsformen zu modellieren. (Die Bezeichnung "nicht-linear" bezieht sich auf die Tatsache, dass die Mannigfaltigkeit von erlaubten Formen nicht lediglich ein linearer Unterraum ist.) Während dies die oben erwähnten Nachteile vermeidet, opfert man die Effizienz des Arbeitens in einem niedrig-dimensionalen Unterraum (der durch die ersten wenigen Eigenmoden gebildet wird) hin zu einem Problem von unbegrenzt-dimensionaler Optimierung.

[0030] Bild **101** in [Fig. 1](#) zeigt ein Ultraschallbild eines Herzens. Bild **102** zeigt die Histogramme, die der empirischen Wahrscheinlichkeit von Intensitäten innerhalb und außerhalb der linken Herzkammer entsprechen. Bild **103** zeigt eine CT-Aufnahme einer Prostata und Bild **104** zeigt die Histogramme, die der empirischen Wahrscheinlichkeit von Intensitäten innerhalb und außerhalb der Prostata entsprechen. Die bereichsbasierte Segmentierung dieser Strukturen ist ein herausforderndes Problem, weil Objekte und der Hintergrund ähnliche Histogramme besitzen.

[0031] In der vorliegenden Erfindung wird ein Rahmen für kenntnisgesteuerte Segmentierungsverfahren und -systeme geliefert. Gemäß einem Gesichtspunkt der Erfindung basiert der Rahmen auf dem Niveausatz-Verfahren. Gemäß anderen Gesichtspunkten der vorliegenden Erfindung fasst der Rahmen drei Beiträge zusammen: zum einen liefert er ein statistisches früheres Formmodell, das die Effizienz von niedrig-dimensionalen Verfahren auf PCA-Basis mit der Genauigkeit von nicht-parametrischen statistischen Formmodellen verbindet. Der Schlüsselaspekt liegt darin, eine Kerndichteschätzung in einem linearen Unterraum durchzuführen, der ausreichend groß ist, um alle Trainingsdaten einzubetten. Zum zweiten wird ein Verfahren zum Schätzen von Posen- und Verschiebungsparametern auf eine eher datengesteuerte Weise vorgesehen. Zum dritten wird die Intensitätsinformation im Bild optimal verwertet, indem wahrscheinlichkeitstheoretische Intensitätsmodelle verwendet werden, die durch Kerndichteschätzungen von zuvor beobachteten Intensitätsverteilungen erhalten werden. Beispieldarstellungen werden geliefert, die die effektive Segmentierung von Objekten durch die erfindungsgemäßen Verfahren demonstrieren.

Niveausatz-Segmentierung als Bayes'scher Rückschluss

[0032] Das Ziel der Niveausatz-Segmentierung kann formuliert werden als die Schätzung der optimalen einbettenden Funktion: $\Phi: \Omega \rightarrow \mathbb{R}$ bei einer gegebenen Abbildung $I: \Omega \rightarrow \mathbb{R}$. Im Bayes'schen Rahmen kann dies berechnet werden durch Maximierung der späteren Verteilung

$$P(\Phi|I) \propto P(I|\Phi)P(\Phi) \quad (2)$$

[0033] Die Maximierung von (2) führt zu einem Problem von unendlichdimensionaler Optimierung. Bei Vorliegen eines Satzes von Trainingsformen, die durch ihre signierten Abstandsfunktionen $\{\Phi_i\}_{i=1..N}$ codiert sind, schlagen Tsai et al. vor, das Segmentierungsproblem auf eine endlich-dimensionale Optimierung zu reduzieren, indem das Optimierungsproblem auf den endlich-dimensionalen Unterraum beschränkt wird, der durch die Trainingsformen aufgespannt wird. Siehe hierzu A. Tsai, A. J. Yezzi und A. S. Willsky, "Ein formbasierter Ansatz für die Segmentierung von medizinischen Bildern unter Verwendung von Niveausätzen", IEEE Trans. on Medical Imaging, 22(2): 137–154, 2003.

[0034] In der vorliegenden Erfindung ist diese kompakte Darstellung der einbettenden Funktion hilfreich. Bei gegebenem Abstand d im Raum der signierten Abstandsfunktionen, definiert durch: $d^2(\Phi_1, \Phi_2) = \int_{\Omega} ((\Phi_1(x) - \Phi_2(x))^2) dx$, richtet die vorliegende Erfindung den Satz von Trainingsformen hinsichtlich Translation und Rotation aus. Nachfolgend beschränkt sie die Niveausatz-Funktion Φ auf eine parametrische Darstellung der Form:

$$\Phi_{\alpha, h, \theta}(x) = \Phi_0(R_{\theta}x + h) + \sum_{i=1}^n \alpha_i \psi_i(R_{\theta}x + h) \quad (3)$$

wobei $\Phi_0(x) = 1/N \sum_{i=1}^N \Phi_i(x)$ die mittlere Form repräsentiert $\{\Psi_i(x)\}_{i=1, \dots, n}$ die Eigenmoden der Verteilung sind und $n < N$ die Dimension des Unterraums ist, der durch die N Trainingsformen aufgespannt wird. Der Parametervektor $\alpha = (\alpha_1, \dots, \alpha_n)$ modelliert Formveränderungen, während die Parameter $h \in \mathbb{R}^3$ und $\theta \in [0, 2\pi]^3$ Translation und Rotation der entsprechenden Form modellieren. Die Einschätzung der früheren Beispiele oder Trainingsobjekte wird in einem Unterraum durchgeführt, was bedeutet, dass in den Schritten gemäß einem Gesichtspunkt der vorliegenden Erfindung nicht der volle Raum verwendet wird, den die früheren Beispiele besetzen. Der Unterraum wird über n Dimensionen aufgespannt, was weniger ist als die N Dimensionen des vollen Raums.

[0035] Das unendlich-dimensionale Bayes'sche Rückschlussproblem in (2) wird daher auf ein endlich-dimensionales Rückschlussproblem reduziert, wobei die konditionale Wahrscheinlichkeit

$$P(\alpha, h, \theta | I) \propto P(I | \alpha, h, \theta) P(\alpha, h, \theta) \quad (4)$$

bezüglich der Formparameter α und der Transformationsparameter h und θ optimiert wird. Im Folgenden wird ein gleichförmiges früheres Beispiel hinsichtlich dieser Transformationsparameter angenommen, d.h. $P(\alpha, h, \theta) = P(\alpha)$. Im nächsten Abschnitt werden drei Lösungen als Gesichtspunkte der vorliegenden Erfindung erläutert, um diese frühere Form zu modellieren.

Ein effizientes nicht-parametrisches statistisches Formmodell

[0036] Bei einem gegebenen Satz von ausgerichteten Trainingsformen $\{\Phi_i\}_{i=1, \dots, N}$ kann jede von diesen durch einen entsprechenden Formvektor $\{\alpha_i\}_{i=1, \dots, N}$ dargestellt werden. Bei dieser Darstellungsart liegt das Ziel des statistischen Formenlernens darin, eine statistische Verteilung $P(\alpha)$ aus diesen Beispielformen abzuleiten. Zwei Lösungen, die vorgeschlagen wurden, basieren auf den Annahmen, dass die Trainingsformen durch eine gleichmäßige Verteilung angenähert werden können [15, 13]: $P(\alpha) = \text{const.}$, oder durch eine Gauß-Verteilung (siehe M. Leventon, W. Crimson und O. Faugeras, "Einfluss statistischer Formen bei geodätischen aktiven Konturen", CVPR, Ausgabe 1, Seiten 316–323, Hilton Head Island, SC, 2000.):

$$P(\alpha) \propto \exp(-\alpha^T \sum^{-1} \alpha), \quad \text{wobei} \quad \sum = \frac{1}{N} \sum_i \alpha_i \alpha_i^T. \quad (5)$$

[0037] Bei der vorliegenden Erfindung wird die nicht-parametrische Dichteschätzung verwendet, um die Formverteilung innerhalb des linearen Unterraums anzunähern. Siehe hierzu F. Rosenblatt, "Bemerkungen zu einigen nicht-parametrischen Schätzungen einer Dichtefunktion", Annals of Mathematical Statistics, 27: 832–837, 1956. Die vorliegende Erfindung modelliert die Formverteilung durch die Kerndichteschätzung:

$$P(\alpha) = \frac{1}{N\sigma} \sum_{i=1}^N K\left(\frac{\alpha - \alpha_i}{\sigma}\right), \quad \text{wobei} \quad K(u) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u^2}{2}\right). \quad (6)$$

[0038] Es existieren verschiedene Verfahren zum automatischen Einschätzen geeigneter Werte für die Breite σ der Kernfunktion, die von Einschätzungen des k -ten nächsten Nachbarn hin zu Vergleichsprüfungen und Bootstrapping reichen. Gemäß einem Gesichtspunkt der vorliegenden Erfindung soll einfach der Satz σ der durchschnittliche Abstand zum nächsten Nachbarn sein:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N \min_{j \neq i} |\alpha_i - \alpha_j|^2.$$

[0039] Im Kontext des Niveausatzes auf der Basis der Bildsegmentierung besitzt die Kerndichteschätzung (6) zwei Vorteile gegenüber der gleichmäßigen Verteilung und der Gauß-Verteilung:

- Die Annahmen einer gleichmäßigen Verteilung oder einer Gauß-Verteilung sind im Allgemeinen nicht erfüllt. In [Fig. 3](#) ist dies für einen Satz von Silhouetten von Beispielformen demonstriert. Der Kerndichteschätzer ist andererseits dafür bekannt, beliebige Verteilungen anzunähern. Unter sanften Annahmen stellte es sich heraus, dass er im Limes unendlicher Beispielgröße zur tatsächlichen Verteilung konvergiert. (Siehe hierzu B. W. Silverman, "Dichteschätzung für Statistik und Datenanalyse", Chapman und Hall, London, 1992.)
- Der Raum der signierten Abstandsfunktionen ist bekanntermaßen kein linearer Raum. Deshalb wird im Allgemeinen weder die mittlere Form Φ_0 noch eine lineare Kombination von Eigenmoden wie in (3) eine signierte Abstandsfunktion sein. Folglich kann nicht erwartet werden, dass die Funktionen $\Phi(x)$, die von der gleichmäßigen Verteilung oder der Gauß-Verteilung favorisiert werden, signierte Abstandsfunktionen sind. Der Kerndichteschätzer (6) favorisiert andererseits Formvektoren α , die in der Nähe der Beispielformvektoren

ren α_i sind. Durch den Aufbau entsprechen diese Vektoren signierten Abstandsfunktionen. In der Tat konvergiert im Limes unendlicher Beispielgröße die Verteilung, die durch den Kerndichteschätzer (6) abgeleitet wurde, hin zu einer Verteilung auf der Mannigfaltigkeit von signierten Abstandsfunktionen.

[0040] [Fig. 2](#) zeigt schematische Darstellungen der drei Verfahren für einen Satz von Beispieldaten, die einen zweidimensionalen Unterraum in \mathbb{R}^3 aufspannen. Der Kerndichteschätzer erfasst die Verteilung ersichtlich am genauesten. Dunklere Schatten zeigen die Flächen hoher Wahrscheinlichkeitsdichte für die entsprechenden Modelle an. Der Kerndichteschätzer adaptiert sich flexibler auf die Trainingsdaten, da er nicht auf spezielle Annahmen hinsichtlich der Form der Verteilung vertraut. In [Fig. 2](#) zeigt Bild **201** eine Darstellung einer Dichteschätzung einer gleichmäßigen Dichte, Bild **202** einer Gauß'schen Dichte und Bild **203** einer Kerndichte. [Fig. 3](#) zeigt eine 3D-Projektion der geschätzten Formdichte, berechnet für einen Satz von Silhouetten einer gehenden Person. Die Bilder **303** und **304** zeigen Formen-Morphing durch Sampling entlang von Geodäten der gleichmäßigen Dichte in **303** und der Kerndichte in **304**. Dies zeigt, dass der Kerndichteschätzer die Verteilung von validen Formen genauer erfasst. Bild **301** zeigt sechs von 49 Trainingsformen. Bild **302** zeigt eine 3D-Projektion der Isofläche der geschätzten (48-dimensionalen) Formverteilung. Letztere ist deutlich weder gleichmäßig noch gaußverteilt. Die Bilder **303** und **304** zeigen ein Morphing zwischen zwei Beispielformen entlang von Geodäten, induziert durch eine gleichmäßige Verteilung im Bild **303** und eine Kernverteilung im Bild **304**. Die gleichmäßige Verteilung induziert ein Morphing, bei dem die Beine verschwinden und wieder erscheinen und bei dem die Armbewegung nicht erfasst wird. Das nicht-lineare Sampling liefert realistischere Zwischenformen. Menschliche Silhouetten werden ausgewählt, weil sie eine ausgeprägtere Formenvariabilität zeigen als die meisten analysierten medizinischen Strukturen.

[0041] In Analogie zum Formenlernen wird die Kerndichteschätzung von Beispielen verwendet, um die konditionale Wahrscheinlichkeit für die Intensitätsfunktion I von (4) zu lernen. Eine ähnliche Vorberechnung von Intensitätsverteilungen mittels Mischmodellen wurde vorgeschlagen in N. Paragios und R. Deriche, "Geodätische aktive Bereiche und Niveausatz-Verfahren für überwachte Textursegmentierung", *Int. J. of Computer Vision*, 46(3): 233–247, 2002. Bei einem gegebenen Satz von vorsegmentierten Trainingsbildern wird die Kerndichteschätzung der Intensitätsverteilungen p_{in} und p_{out} von Objekt und Hintergrund durch die entsprechenden geglätteten Intensitätshistogramme gegeben. Dies liefert zwei Vorteile: zum einen verlässt sich der Kerndichteschätzer nicht auf spezielle Annahmen hinsichtlich der Form der Verteilungen. [Fig. 1](#) zeigt, dass die Intensitätsverteilungen für Ultraschall- und CT-Bilder durch Gauß'sche oder Laplace-Modelle nicht gut angenähert werden. Zum zweiten vereinfacht dies im Gegensatz zur gemeinsamen Schätzung von Intensitätsverteilungen [2] den Segmentierungsprozess, der nicht länger eine Aktualisierung von Intensitätsmodellen erfordert. Außerdem wurde herausgefunden, dass der Segmentierungsprozess in zahlreichen Experimenten hinsichtlich Initialisierung robuster war.

Energieformulierung und -minimierung

[0042] Das Maximieren der späteren Wahrscheinlichkeit in (2) oder auf äquivalente Weise das Minimieren von deren negativem Logarithmus wird die wahrscheinlichste Segmentierung eines gegebenen Bildes erzeugen. Mit den nicht-parametrischen Modellen für Form und Intensität, wie sie oben eingeführt wurden, führt dies zu einer Energie der Form

$$E(\alpha, h, \theta) = -\log P(I|\alpha, h, \theta) - \log P(\alpha), \quad (7)$$

[0043] Das nicht-parametrische Intensitätsmodell erlaubt es auszudrücken, dass der erste Term und Gleichung (6) exakt den zweiten ergeben. Mit der Heaviside-Stufenfunktion H und der Kurzformel $H_\Phi = H(\Phi_{\alpha, h, \theta}(x))$ erhalten wir:

$$E(\alpha, h, \theta) = -\int_{\Omega} H_\Phi \log p_{in}(I) + (1 - H_\Phi) \log p_{out}(I) dx - \log\left(\frac{1}{N\sigma} \sum_{i=1}^N K\left(\frac{\alpha - \alpha_i}{\sigma}\right)\right)$$

Mit

$$\text{Mit } e(x) = \left[\log \frac{p_{out}(I(x))}{p_{in}(I(x))} \right], \quad K_i = K\left(\frac{\alpha - \alpha_i}{\sigma}\right) \quad \text{und} \quad \psi = (\psi_1, \dots, \psi_n)$$

erhalten wir das folgende System von gekoppelten Gradientenabfallgleichungen:

$$\left\{ \begin{array}{l} \frac{d\alpha}{dt} = \int_{\Omega} \delta(\Phi_{\alpha,h,\theta}(x)) \psi(R_{\theta}x + h) e(x) dx + \frac{1}{\sigma^2} \frac{\sum_{i=1}^N (\alpha_i - \alpha) K_i}{\sum_{i=1}^N K_i}, \\ \frac{dh}{dt} = \int_{\Omega} \delta(\Phi_{\alpha,h,\theta}(x)) \nabla \Phi_{\alpha,h,\theta}(x) e(x) dx, \\ \frac{d\theta}{dt} = \int_{\Omega} \delta(\Phi_{\alpha,h,\theta}(x)) (\nabla \Phi_{\alpha,h,\theta}(x) \cdot \nabla_{\theta} R x) e(x) dx. \end{array} \right. \quad (8)$$

[0044] In allen Gleichungen erscheint die Dirac'sche Delta-Funktion δ als Faktor innerhalb der Integrale über den Bildbereich Ω . Dies erlaubt eine Beschränkung aller Berechnungen auf ein enges Band um den Nullpunkt von Φ . Während die Entwicklung der Translation und der Posenparameter h und θ lediglich durch den Datenterm $e(x)$ gesteuert wird, wird der Formvektor α zusätzlich zu jeder Trainingsform hingezogen, und zwar mit einer Stärke, die exponentiell mit dem Abstand zur entsprechenden Form abnimmt.

Experimentelle Ergebnisse und Gültigkeitsprüfung

[0045] Die Verfahren der vorliegenden Erfindung wurden auf die Segmentierung verschiedener Objekte in medizinischen Bildern angewendet, was zur Erläuterung und Bestätigung der erfindungsgemäßen Verfahren dienen wird. Die beispielhaften Darstellungen beziehen sich auf eine Segmentierung des Herzens bei Ultraschall-Bildern und eine Segmentierung der Prostata bei dreidimensionalen CT-Bildern.

Segmentierung des Herzens bei Ultraschall-Bildern

[0046] [Fig. 4](#) zeigt experimentelle Ergebnisse, die für die Segmentierung der linken Herzkammer in 2D-Ultraschall-Aufnahmefolgen des Herzens unter Verwendung von früheren Formbeispielen erhalten wurden, die aus einem Satz von 21 manuell segmentierten Trainingsbildern konstruiert wurden. Im Gegensatz zur Segmentierung mit einem gleichmäßigen früheren Beispiel (Bild [402](#) in [Fig. 4](#)) ermöglicht es das nicht-parametrische statistische frühere Formbeispiel, die Segmentierung genau einzuschränken (Bild [403](#) in [Fig. 4](#)). Dies tritt besonders deutlich hervor in Flächen, wo der Datenterm zu schwach ist. Als quantitative Bewertung berechneten wir den Prozentsatz von korrekt klassifizierten Objektpixeln und von falsch klassifizierten Objektpixeln. Während der Energieminimierung steigt der Prozentsatz von korrekt klassifizierten Pixeln von 56% auf 90%, während der Prozentsatz von falschen, aber positiv klassifizierten Pixeln bei Verwendung des früheren Kernbeispiels von 27% auf 2,7% abnimmt. Bei Verwendung des gleichmäßigen früheren Beispiels erhalten wir 92% korrekt klassifizierte Pixel, aber der Prozentsatz von falschen, positiv klassifizierten Pixeln steigt auf 42%. Ein bloßes Einschränken der Grenzentwicklung auf den linearen Unterraum, der durch die Trainingsbeispiele aufgespannt wird, ist nicht ausreichend, um genaue Segmentierungsergebnisse zu liefern.

Segmentierung der Prostata bei dreidimensionalen CT-Bildern

[0047] Als anderes erläuterndes Beispiel wurde ein nicht-parametrisches 3D-Formmodell der Prostata unter Verwendung von 12 manuell extrahierten Prostatabildern (mit Samenbläschen), die von zwei verschiedenen Patienten gesammelt wurden, entwickelt. [Fig. 5](#) zeigt die Prostatasegmentierung für zwei Patienten mit demselben Formmodell. Jede Spalte mit zwei Bildern [501](#), [502](#), [503](#) und [504](#) zeigt koronale und axiale Schnitte derselben Segmentierung für den ersten Patienten (zwei linke Spalten [501](#) und [502](#)) und für den zweiten Patienten (die beiden letzteren Spalten [503](#) und [504](#)). Die erste Spalte [501](#) zeigt auch die manuelle Segmentierung (schwarze Kontur). Im Gegensatz zum bisherigen Vorgehen verwendeten wir anschließend ein einzelnes Formmodell für die Segmentierung von Bildern von verschiedenen Patienten. Wir wandten eine Strategie an, bei der das interessierende Bild aus der Trainingsphase entfernt wird. [Fig. 6](#) zeigt 2D-Schnitte von einigen Ergebnissen, die unter Verwendung dieser Strategie erhalten wurden. Sie zeigt Segmentierungen, die mit dem früheren Kernbeispiel (weiße Linie) und mit alternativen Ansätzen (schwarze Linie) erhalten wurden. Mit einer Einfachklick-Initialisierung innerhalb des Organs führen erfindungsgemäße Verfahren in weniger als 20 Sekunden zu einer stationären Lösung. Wir erzielten 86% erfolgreich klassifizierte Organ-Voxel und 11% falsch klassifizierte Organ-Voxel. Dies ist im Vergleich mit den Ergebnissen, die in D. Freedman, R. J. Radke, T. Zhang, Y. Jeong, D. M. Lovelock und G. T. Chen "Modellbasierte Segmentierung von medizinischen Bildern durch Anpassung von Verteilungen", IEEE Trans Med Imaging, 24(3): 281–292, März 2005, vorteilhaft.

[0048] [Fig. 5](#) liefert qualitative Vergleiche mit der manuellen Segmentierung, sowie mit Segmentierungen, die mit gleichmäßigen und Gauß'schen Näherungen der Formverteilung erhalten wurden.

[0049] Es wurden Verfahren zum Erzeugen und Anwenden eines effizienten und genauen statistischen früheren Formbeispiels für die Niveausatz-Segmentierung vorgestellt, die auf einer nicht-parametrischen Dichteschätzung im linearen Unterraum basiert, der durch einen Satz von Trainingsdaten aufgespannt wird. Zusätzlich nutzen die vorgeschlagenen Segmentierungsverfahren, die Gesichtspunkte der vorliegenden Erfindung sind, nicht-parametrische Schätzungen von Intensitätsverteilungen und eine effiziente Optimierung von Posen- und Translationsparametern. Eine erläuternde quantitative Berechnung der Segmentierungsgenauigkeit und -geschwindigkeit für Ultraschallbilder eines Herzens und für dreidimensionale CT-Bilder der Prostata wurden vorgestellt, die die Qualität dieser Verfahren bestätigen. Die vorgestellten Beispiele zeigen, dass das vorgeschlagene nicht-parametrische frühere Formbeispiel bessere Ergebnisse liefert als zuvor vorgeschlagene frühere Formbeispiele für die Niveausatz-Segmentierung.

[0050] [Fig. 7](#) zeigt eine Zusammenfassung eines Gesichtspunkts der vorliegenden Erfindung. Der erste Schritt **700** im Segmentierungsprozess ist, ein nicht-parametrisches Modell zu erzeugen, das eine Beschreibung einer Abbildung mit Hilfe von Niveausatz-Verfahren ermöglicht. Ein Modell, das in der vorliegenden Erfindung verwendet wird, ist die Kerndichteschätzung als nicht-parametrische Näherung der Formverteilung. Der nächste Schritt **701** beinhaltet das Lernen der Formen eines Satzes von früheren Beispielen. Hierbei werden die Kerndichteschätzungen der vorsegmentierten Trainingsbilder durch geglättete Intensitätshistogramme geliefert. Im Schritt **702** wird die Kerndichteschätzung des zu segmentierenden Bilds erzeugt. Im Schritt **703** wird eine Energiefunktion $E(\alpha, h, \theta)$ geliefert, die auf Bayes'sche Weise als $E(\alpha, h, \theta) = -\log P(I|\alpha, h, \theta) - \log P(\alpha)$ ausgedrückt werden kann. Die wahrscheinlichste Segmentierung (die wie die früheren Beispiele aussieht) wird erhalten werden, indem die spätere Wahrscheinlichkeit der Minimierung des Energieausdrucks maximiert wird, was in Schritt **704** vorgesehen ist.

[0051] Die Segmentierungsverfahren, die Teil der vorliegenden Erfindung sind, können durch ein System ausgeführt werden, das in [Fig. 8](#) dargestellt ist. Das System ist mit Daten **801** ausgestattet, die das zu segmentierende Bild und die früheren Bilder repräsentieren. Ein Befehlssatz oder -programm **802**, das die Verfahren des Lernens und der Segmentierung unter Verwendung der Verfahren der vorliegenden Erfindung ausführt, ist ebenfalls vorgesehen und wird mit den Daten in einem Prozessor **803** zusammengefasst, der die Befehle von **802**, welche auf die Daten **801** angewendet werden, verarbeiten kann und das segmentierte Bild auf einem Display **804** anzeigen kann. Der Prozessor kann zweckbestimmte Hardware sein, eine GPU, eine CPU oder jede beliebige andere Computervorrichtung, die die Befehle von **802** ausführen kann. Eine Eingabevorrichtung **805**, etwa eine Maus, eine Rollkugel oder eine andere Eingabevorrichtung, ermöglicht es einem Anwender, das ursprüngliche Objekt auszuwählen und den Segmentierungsprozess zu starten. Folglich liefert das in [Fig. 8](#) dargestellte System ein interaktives System für die Objektsegmentierung aus einem Bild unter Verwendung von Niveausatz-Verfahren und früheren Beispielen von Form und Intensität.

[0052] Die folgenden Referenzen liefern Hintergrundinformationen, die allgemein mit der vorliegenden Erfindung in Beziehung stehen und hierin durch Bezugnahme beinhaltet sind: [1] V. Caselles, F. Catté, T. Coll und F. Dibos, "Ein geometrisches Modell für aktive Konturen in der Bildverarbeitung", Numer. Math., 66: 1–31, 1993; [2] T. F. Chan und L. A. Vese, "Aktive Konturen ohne Kanten", IEEE Trans. Image Processing, 10(2): 266–277, 2001; [3] D. Cremers, S. J. Osher und S. Soatto, "Kerndichteschätzung und intrinsische Ausrichtung für kennnistgesteuerte Segmentierung: Niveausätzen das Gehen beibringen", Pattern Recognition, Band 3175 von LNCS, Seiten 36–44, Springer, 2004; [4] E. B. Dam, F. T. Fletcher, S. Pizer, C. Tracton und J. Rosenman, "Prostata-Formmodellierung auf der Basis von geodätischer Bootstrapping-Analyse", MICCA, Ausgabe 2217 von LNCS, Seiten 1008–1016, September 2004; [5] A. Dervieux und F. Thomasset, "Ein Verfahren mit endlichen Elementen für die Simulation von Raleigh-Taylor-Instabilität", Springer Lect. Notes in Math., 771: 145–158, 1979; [6] D. Freedman, R. J. Radke, T. Zhang, Y. Jeong, D. M. Lovelock und G. T. Chen, "Modellbasierte Segmentierung von medizinischen Bildern durch Anpassung von Verteilungen", IEEE Trans Med Imaging, 24(3): 281–292, März 2005; [7] S. Kichenassamy, A. Kumar, P. J. Giver, A. Tannenbaum und A. J. Yezzi, "Gradientenströmungen und geometrische aktive Konturmodelle", Proc. IEEE Intl. Conf. on Comp. Vis., Seiten 810–815 Boston, USA, 1995; [8] M. Leventon, W. Crimson und O. Faugeras, "Einfluss statistischer Formen bei geodätischen aktiven Konturen", CVPR, Band 1, Seiten 316–323, Hilton Head Island, SC, 2000; [9] R. Malladi, J. A. Sethian und B. C. Vemuri, "Ein topologieunabhängiges Formmodellierungsschema", SPIE Conference on Geometric Methods in Computer Vision II, Ausgabe 2031, Seiten 246–258, 1994; [10] S. J. Osher und J. A. Sethian, "Frontenpropagierung mit krümmungsabhängiger Geschwindigkeit: Algorithmen auf der Basis von Hamilton-Jacobi-Formulierungen", J. of Comp. Phys., 79: 12–49, 1988; [11] N. Paragios und R. Deriche, "Geodätische aktive Bereiche und Niveausatz-Verfahren für die überwachte Textursegmentierung", Int. J. of Com-

puter Vision, 46(3): 233–247, 2002; [12] F. Rosenblatt, "Anmerkungen zu einigen nicht-parametrischen Schätzungen einer Dichtefunktion", Annals of Mathematical Statistics, 27: 832–837, 1956; [13] M. Rousson, N. Paragios and R. Deriche, "Implizite aktive Formmodelle für die 3D-Segmentierung in der Magnetresonanz-Bildgebung", MICCAI, Seiten 209–216, 2004; [14] B. W. Silverman, "Dichteschätzung für Statistik und Datenanalyse", Chapman und Hall, London, 1992; [15] A. Tsai, A. J. Yezzi und A. S. Willsky, "Ein formbasierter Ansatz für die Segmentierung von medizinischen Bildern unter Verwendung von Niveausätzen", IEEE Trans. on Medical Imaging, 22(2): 137–154, 2003.

[0053] Jede Bezugnahme auf die Bezeichnung "Pixel" soll hierbei auch als Bezugnahme auf ein "Voxel" gelten.

[0054] Nachdem fundamentale neuartige Merkmale der Erfindung gezeigt, beschrieben und herausgestellt wurden, indem sie auf bevorzugte Ausführungsformen hiervon angewendet wurden, wird es klar sein, dass verschiedene Streichungen und Ersetzungen sowie Veränderungen in der Form und in Details der Vorrichtung sowie in deren Betrieb von einem Fachmann vorgenommen werden können, ohne vom erfinderischen Gedanken abzuweichen. Es ist daher die Absicht, dass eine Einschränkung lediglich durch den Schutzzumfang der beigefügten Ansprüche bestimmt wird.

Patentansprüche

1. Verfahren zum Segmentieren eines Objekts in einem Satz von Bilddaten unter Verwendung von einem oder mehreren früheren Beispielen des Objekts, mit folgenden Schritten:
Bestimmen einer nicht-parametrischen Schätzung einer Eigenschaft aus dem einen oder den mehreren früheren Beispielen des Objekts in einem Unterraum, der durch das eine oder die mehreren früheren Beispiele des Objekts aufgespannt wird;
Anwenden der nicht-parametrischen Schätzung des einen oder der mehreren früheren Beispiele in einem Bayes'schen Ausdruck auf den Satz von Bilddaten; und
Auswählen einer Segmentierung des Objekts im Satz von Bilddaten durch Ausführen eines Niveausatz-Verfahrens, das den Bayes'schen Ausdruck optimiert.

2. Verfahren nach Anspruch 1, wobei die Eigenschaft eine Intensität ist.

3. Verfahren nach Anspruch 1, wobei die Eigenschaft eine Form ist.

4. Verfahren nach Anspruch 1, wobei die Eigenschaft aus dem einen oder den mehreren früheren Beispielen des Objekts auf einem Durchschnittswert einer Eigenschaft basiert, die mit jedem der früheren Beispiele des Objekts assoziiert ist.

5. Verfahren nach Anspruch 1, wobei die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts auf einer Abstandsfunktion basiert.

6. Verfahren nach Anspruch 1, wobei der Ausdruck eine Energiefunktion ist.

7. Verfahren nach Anspruch 1, wobei die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts translations- und rotationsinvariant ist.

8. Verfahren nach Anspruch 1, wobei die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts auf einer Dichtefunktion basiert.

9. Verfahren nach Anspruch 1, wobei die Dichtefunktion die Kerndichte ist.

10. Verfahren nach Anspruch 1, wobei der Kerndichteschätzer eines früheren Beispiels ein geglättetes Intensitätshistogramm ist.

11. Verfahren nach Anspruch 1, wobei der Ausdruck geliefert wird gemäß:

$$E(\alpha, h, \theta) = - \int_{\Omega} H_{\phi} \log p_{in}(I) + (1 - H_{\phi}) \log p_{out}(I) dx - \log \left(\frac{1}{N\sigma} \sum_{i=1}^N K \left(\frac{\alpha - \alpha_i}{\sigma} \right) \right).$$

12. System für die Segmentierung eines Objekts in einem Satz von Bilddaten unter Verwendung von einem

oder mehreren früheren Beispielen des Objekts mit:

einem Prozessor;

Computersoftware, die auf dem Prozessor ausführbar ist, wobei die Computersoftware zu folgenden Schritten in der Lage ist:

Bestimmen einer nicht-parametrischen Schätzung einer Eigenschaft von einem oder mehreren früheren Beispielen des Objekts in einem Unterraum, der durch das eine oder die mehreren früheren Beispiele des Objekts aufgespannt wird;

Anwenden der nicht-parametrischen Schätzung des einen oder der mehreren früheren Beispiele in einem Bayes'schen Ausdruck auf den Satz von Bilddaten; und

Auswählen einer Segmentierung des Objekts im Satz von Bilddaten durch Ausführen eines Niveausatz-Verfahrens, das den Bayes'schen Ausdruck optimiert.

13. System nach Anspruch 12, wobei die Eigenschaft eine Intensität ist.

14. System nach Anspruch 12, wobei die Eigenschaft eine Form ist.

15. System nach Anspruch 12, wobei die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts auf einem Durchschnittswert einer Eigenschaft basiert, die mit jedem früheren Beispiel des Objekts assoziiert ist.

16. System nach Anspruch 12, wobei die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts auf einer Abstandsfunktion basiert.

17. System nach Anspruch 12, wobei der Ausdruck eine Energiefunktion ist.

18. System nach Anspruch 12, wobei die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts translations- und rotationsinvariant ist.

19. System nach Anspruch 12, wobei die Eigenschaft von dem einen oder den mehreren früheren Beispielen des Objekts auf einer Dichtefunktion basiert.

20. System nach Anspruch 12, wobei die Dichtefunktion die Kerndichte ist.

21. System nach Anspruch 12, wobei der Kerndichteschätzer eines früheren Beispiels ein geglättetes Intensitätshistogramm ist.

22. System nach Anspruch 12, wobei der Ausdruck geliefert wird gemäß:

$$E(\alpha, h, \theta) = - \int_{\Omega} H_{\Phi} \log p_m(I) + (1 - H_{\Phi}) \log p_{out}(I) dx - \log \left(\frac{1}{N\sigma} \sum_{i=1}^N K \frac{\alpha - \alpha_i}{\sigma} \right) .$$

Es folgen 5 Blatt Zeichnungen

Anhängende Zeichnungen

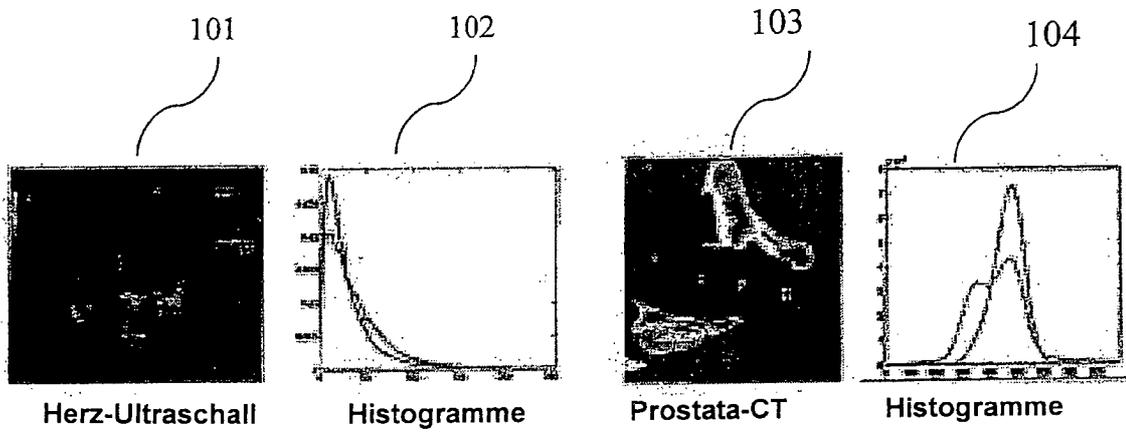


FIG. 1

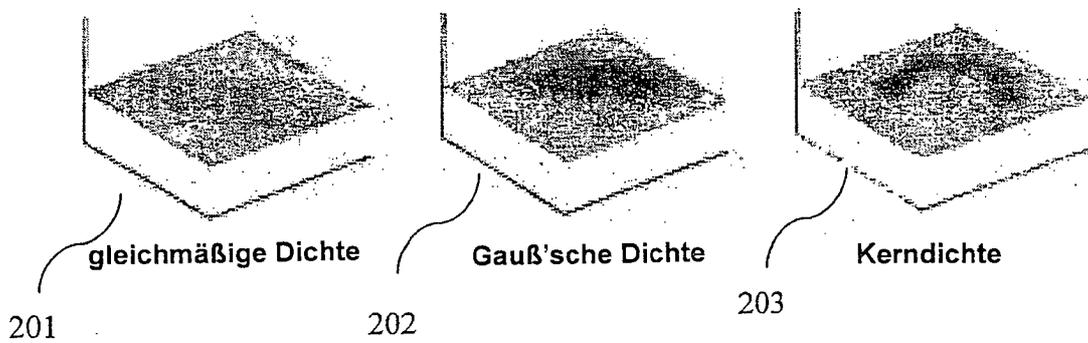


FIG. 2

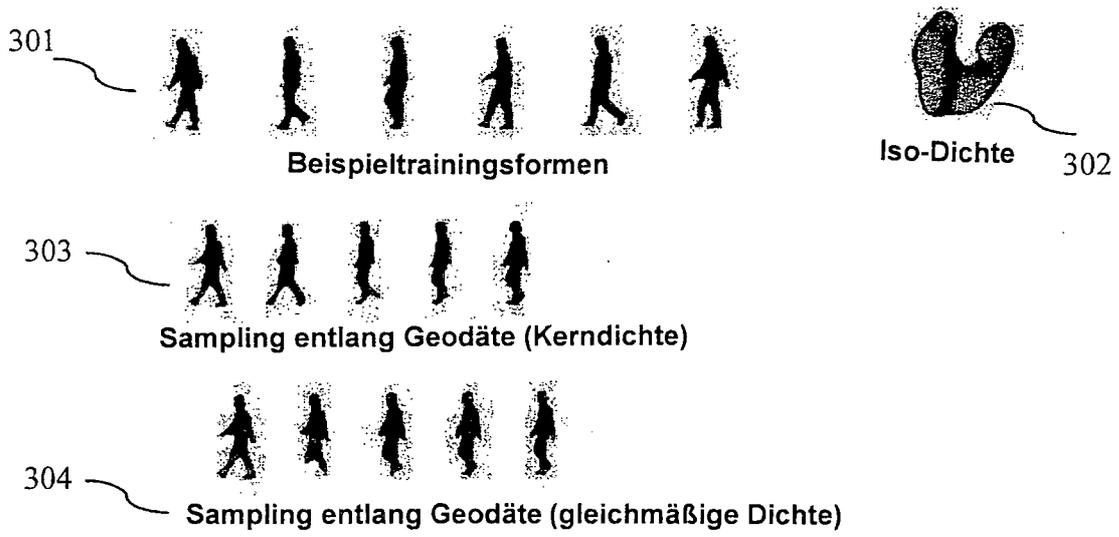


FIG. 3

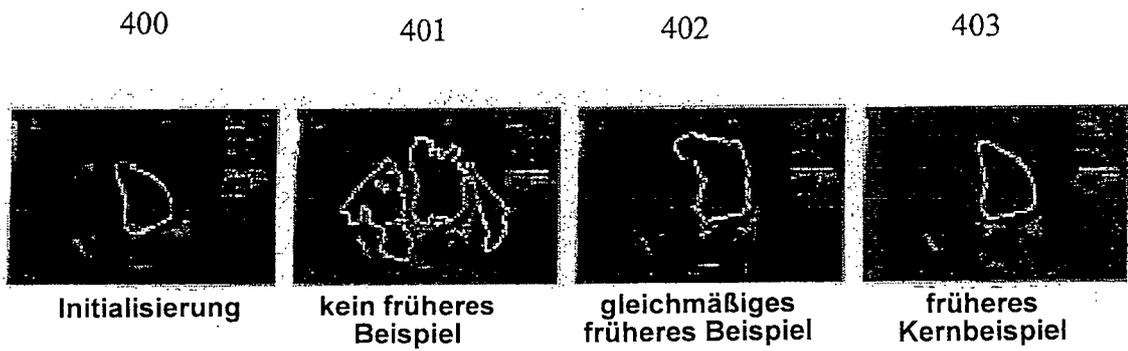


FIG. 4

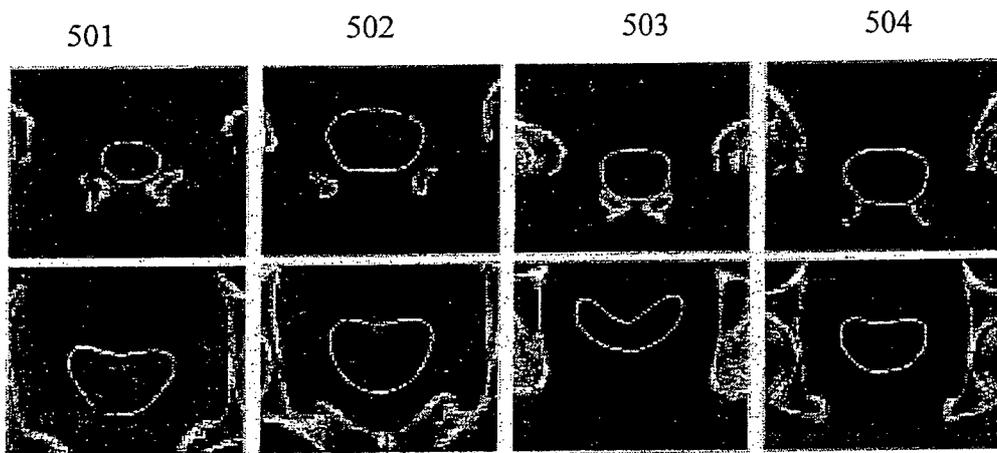


FIG. 5

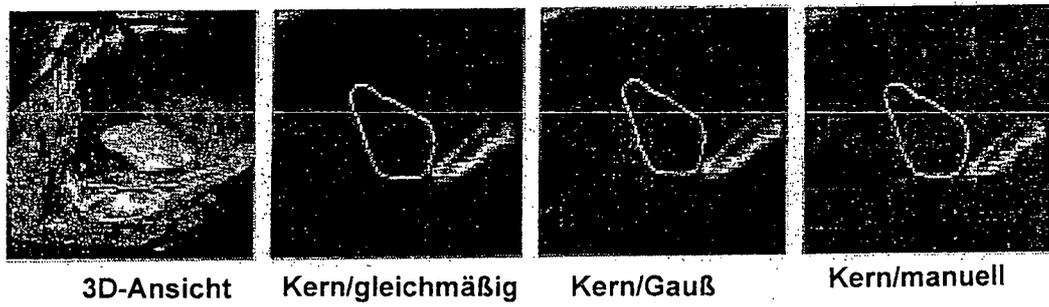


FIG. 6

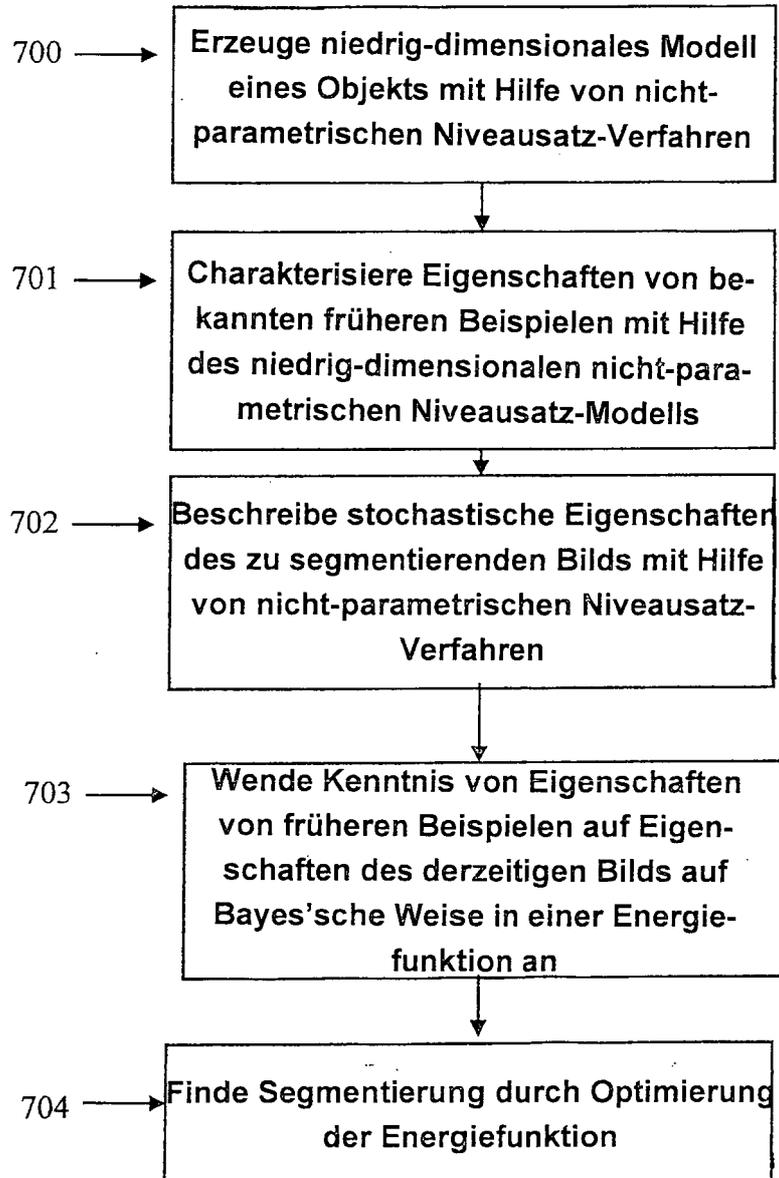


FIG. 7

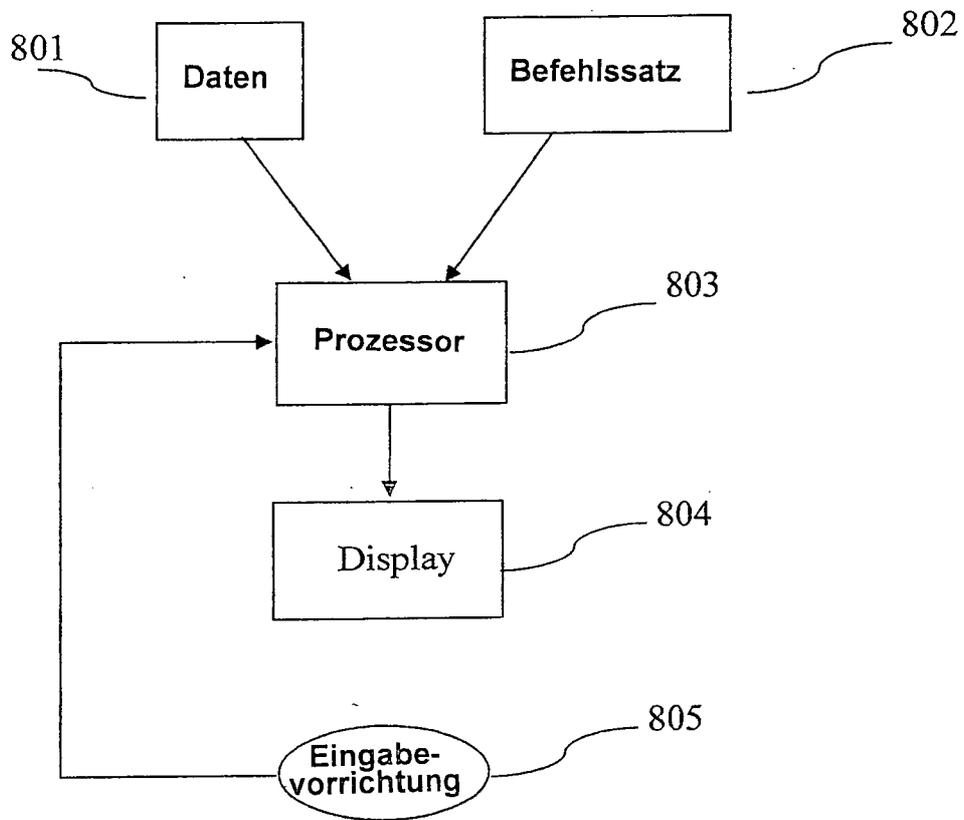


FIG. 8