

Nicht-lineare voxelbasierte Registrierung unter Einbeziehung von Differentialeigenschaften

Dennis Säring¹, Jan Ehrhardt², Heinz Handels¹,
und Siegfried J. Pöpl²

¹Institut für Medizinische Informatik, Universität Hamburg, 20246 Hamburg

²Institut für Medizinische Informatik, Universität Lübeck, 23538 Lübeck

Email: d.saering@uke.uni-hamburg.de

Zusammenfassung. Es wird ein nicht-lineares voxelbasiertes Verfahren präsentiert, welches basierend auf einem erweiterten Distanzmaß die Registrierung medizinischer Bilddaten ermöglicht. In diesem Registrierungsverfahren werden, neben den Grauwertintensitäten, die Normalen- und die Krümmungsinformationen jedes Voxels bei der Berechnung der Ähnlichkeit durch das Distanzmaß einbezogen. Es werden geeignete Verfahren zur Berechnung dieser Informationen in medizinischen Grauwertbildern vorgestellt. In einer ersten Evaluation kann gezeigt werden, dass das präsentierte Distanzmaß die Identifikation anatomisch korrespondierender Punkte verbessert. Testergebnisse auf dem Gebiet des Atlas-Patienten Matchings zeigen, dass durch die vorgeschlagene Einbeziehung von Differentialeigenschaften eine Verbesserung der automatischen Segmentierung gegenüber Verfahren, die auf dem Least-Squares Distanzmaß basieren, erzielt wurde.

1 Einleitung

Die Segmentierung der durch bildgebende Verfahren erstellten Patientenaufnahmen ist ein wesentlicher Bestandteil der Diagnostik und der Planung weiterführender Maßnahmen wie beispielsweise operative Eingriffe [1]. Die Identifikation der anatomischen Strukturen erfolgt häufig durch zeit- und arbeitsaufwendige halb-automatische Verfahren. Eine Möglichkeit der vollständigen Automatisierung und somit die Reduzierung von Zeit- und Arbeitsaufwand erschließt sich durch die Entwicklung von digitalen medizinischen Atlanten [2]. Für eine automatisierte Übertragung von Segmentierungsinformationen aus dem Atlas auf den Patientendatensatz werden nicht-lineare Registrierungsansätze benötigt (Atlas-Patienten Matching). Nach erfolgreicher Registrierung der Bilddaten können dann mit Hilfe der berechneten Transformation die Atlasinformationen direkt auf den Patientendatensatz übertragen werden. Bestehende voxelbasierte Registrierungsverfahren verwenden i.A. grauwertbasierte Distanzmaße wie die Least-Squares Distanz, Mutual Information oder Variance of Ratio zur Ähnlichkeitsmessung. Hierbei werden alle Punkte mit ähnlichen Grauwerten als korrespondierend erkannt, so dass eine ausreichende Identifikation anatomisch identischer Voxel im Atlas- und Patientendatensatz mit diesen Maßen nur schwer

zu erreichen ist. In dieser Arbeit wird ein erweitertes Distanzmaß vorgestellt und evaluiert, welches zur Bestimmung der Ähnlichkeit zweier Voxel neben deren Intensitätswerten, Normalen- und Krümmungsinformationen berücksichtigt. Hierdurch wird die Charakterisierung der Punkte erhöht und ihre anatomische Zuordnung erleichtert. Die Verwendung des neu vorgestellten Distanzmaßes in einem Registrierungsverfahren zeigt eine verbesserte Übertragung der Labelinformationen beim Atlas-Patienten Matching.

2 Methode

Im Bereich der nicht-linearen voxelbasierten Registrierung lassen sich die meisten Verfahren auf ein Minimierungsproblem eines Funktionals bestehend aus Distanzmaß D und Regularisierer S zurückführen [3]. Dabei bestimmt der Regularisierer den Raum aus dem die berechnete Transformation stammen soll. In der Literatur werden eine Reihe von Regularisierungsverfahren vorgestellt [3]. In dieser Arbeit wird ein von Thirion [4] vorgeschlagenes Verfahren verwendet, dabei wird die Regularisierung durch eine Glättung der Transformation mittels Gauss-Filter K_{gauss} realisiert. Dieser Ansatz zeichnet sich durch einen moderaten Implementationsaufwand aus und seine Anwendbarkeit auf das Atlas-Patienten Matching wurde bereits gezeigt [5]. Das Distanzmaß D wird als Maß für die anatomische Ähnlichkeit verwendet. In D fließen neben den Grauwertinformationen, welche bei der Least-Squares Distanz ausschließlich verwendet werden, auch Differentialeigenschaften des Bildes ein. Für die Registrierung ergeben sich folgende Schritte:

1. **Initialisierung:**
 - Kraftvektoren und Transformation vorinitialisieren
2. **Berechnung des Kraftfeldes:**
 - Differentialeigenschaften der Bilddaten berechnen
 - Korrespondierende Punktpaare in Atlas- und Patientendaten finden.
 - Kraftvektoren auf Basis der gefundenen Zuordnungen berechnen.
3. **Aktualisierung die Transformation:**
 - Transformation mit den berechneten Kraftvektoren aktualisieren.
 - Aktualisierte Transformation mit dem Gauss-Filter glätten.
4. **Abbruchkriterium:**
 - Ist eine maximale Anzahl an Iterationen erreicht ?
 - Sind Veränderungen bei den Distanzen beider Daten festzustellen ?

Die Implementierung der einzelnen Schritte kann individuell auf die Problemstellung angepaßt werden.

2.1 Nicht-lineare voxelbasierte Registrierung unter Einbeziehung von Differentialeigenschaften

Die Berechnung des Kraftfeldes in Schritt 2 erfolgt durch den von Besl [6] vorgestellten *Iterativ-Closest-Point* Algorithmus. Für jeden Punkt \mathbf{p} im Patientenbild P wird der Punkt \mathbf{m}_i aus dem Atlas M gesucht, der innerhalb einer Umgebung

$$N = \{\mathbf{m}_i \in M \mid \|\mathbf{m}_i - \mathbf{p}\| < r\} \quad (1)$$

liegt und bezüglich

$$D(\mathbf{p}, \mathbf{m}_i) = \lambda_1 (g(\mathbf{p}) - g(\mathbf{m}_i))^2 + \lambda_2 |\mathbf{n}(\mathbf{p}) - \mathbf{n}(\mathbf{m}_i)|^2 + \lambda_3 (\kappa(\mathbf{p}) - \kappa(\mathbf{m}_i))^2 \quad (2)$$

die minimale Distanz aufweist. Hierbei berechnet $g(\mathbf{x})$ den Intensitätswert, $\mathbf{n}(\mathbf{x})$ den Normalenvektor und $\kappa(\mathbf{x})$ den Krümmungswert (vgl. Abschnitt 2.2) des Punktes \mathbf{x} . Die Gewichte λ_j basieren zum einen auf einer statistischen Berechnung und zum anderen ist eine manuelle Gewichtung durch den Anwender möglich. Der Punkt $\mathbf{m}_i \in M$, welcher die Gleichung

$$\mathbf{m}_i = \min_{\mathbf{m}_i \in N} D(\mathbf{p}, \mathbf{m}_i) \quad (3)$$

erfüllt wird als anatomisch korrespondierend angenommen. Der Vektor, der durch die Punkte \mathbf{p}, \mathbf{m}_i aufgespannt wird, ist der ermittelte Kraftvektor zum Referenzpunkt \mathbf{p} . Im Gegensatz zur oberflächenbasierten Registrierung wird hier für jeden Punkt im Patientendatensatz ein Kraftvektor ermittelt, es ist somit keine vorherige Berechnung von Oberflächenmodellen nötig. Die aktuelle Transformation in Schritt 3 erhält man durch positionswise Aktualisierung der Transformation des vorherigen Iterationsschrittes mit dem berechneten Kraftfeld und der Glättung mit dem Gauss-Filter. Diese Schritte werden dann mit dem, mittels aktueller Transformation registrierten, Atlasdatensatz solange wiederholt, bis ein Abbruchkriterium das Verfahren beendet.

2.2 Berechnung der Differentialeigenschaften eines Voxels


Für die in Abschnitt 2.1 vorgeschlagene voxelbasierte Registrierung sind Verfahren zur Bestimmung von Differentialeigenschaften nötig. Grundlegend für diese Verfahren ist die Approximation der ersten Ableitung in einem Bild für jeden Bildpunkt. Die Differentiation wird mit Hilfe des Operators von Deriche [7] berechnet, dieser ist separierbar, rekursiv implementierbar und durch eine interne Glättungsfunktion wenig rauschempfindlich.

Die Berechnung des Normalenvektors erfolgt über die Normalisierung der approximierten Gradientenvektoren. In dieser Arbeit wird die Normalenrichtung verwendet, dies schränkt den Wertebereich ein und erleichtert somit die Gewichtung der Normaleninformation.

Die Definition der Krümmung eines Punktes in einem Bild ist nicht eindeutig definiert, daher wurden unterschiedliche Ansätze implementiert und bezogen auf die Verwendung im Distanzmaß evaluiert. Hierbei stellte sich heraus, dass Ansätze aus der Analysis wie beispielsweise die Gauss-Krümmung oder der Operator nach Kitchen und Rosenfeld [8] nur bedingt für dieses Verfahren anwendbar sind. Die berechneten Krümmungswerte waren schwer zu gewichten und korrespondierten nicht direkt zur Position der sichtbaren Krümmung (vgl. Abb. 1). Der Operator nach Förstner [9] hingegen liefert ein für dieses Registrierungsverfahren nützliches Ergebnis. Förstner berechnet zunächst die Matrix

$$C_g = \overline{\nabla g (\nabla g)^T}, \quad (4)$$

Abb. 1. Darstellung des Testbildes (a), die überlagerten Krümmungswerte der Gauss-Krümmung (b), des Förstner-Operators (c) sowie das Krümmungsbild des Förstner Operators bei einem realen Datensatz (d)



wobei ∇g die erste Ableitung des Bildes und der Querstrich die Glättung durch einen 3×3 Mittelwertfilter repräsentiert. Den Krümmungswert erhält man dann durch

$$\kappa(\mathbf{x}) = \frac{\det(C_{g(\mathbf{x})})}{\text{trace}(C_{g(\mathbf{x})})}. \quad (5)$$


3 Ergebnisse und Diskussion

Für erste Ergebnisse des präsentierten Verfahrens standen ein CT Patientendatensatz des Beckens und ein auf dem Visible Human Datensatz basierender anatomischer Atlas zur Verfügung. Desweiteren wurde ein Programm geschrieben, welches eine Visualisierung des Distanzmaßes (siehe Gl. 2) ermöglicht um so eine Aussage über die Güte der Erweiterung treffen zu können. Abschließend wurde dann das Verfahren bei der automatischen Segmentierung des Beckens eingesetzt und die Testergebnisse mit bestehenden Verfahren verglichen.

Die Evaluation des erweiterten Distanzmaßes hat gezeigt, dass dieses gegenüber dem grauwertbasierten Distanzmaß mehr korrespondierende Punktepaare richtig erkennt. Die Visualisierung der Distanzen (Abb. 2(c)) eines Referenzpunktes (Abb. 2(a)) aus dem Patientenbild zu allen Punkten aus dem Atlasbild läßt dort ein lokales Minimum erkennen, wo der zum Referenzpunkt als anatomisch korrespondierend erkannte Punkt (Abb. 2(d)) des Atlasdatensatzes liegt. In (Abb. 2(b)) ist das Distanzbild bezüglich der Least-Squares Distanz abgebildet, es ist deutlich zu erkennen, dass eine Vielzahl an Punkten eine minimale Distanz (im Bild dunkel dargestellt) aufweisen und somit häufig irrtümlich anatomische Korrespondenz angenommen wird.

Die Registrierung dreidimensionaler Datensätze aus dem Bereich der Hüfte mit anschließender Übertragung von Atlasinformationen ergab, dass bei der Verwendung der Least-Squares Distanz 97,8 % und bei Verwendung des hier vorgestellten erweiterten Distanzmaßes 98,7 % der Voxel richtig segmentiert wurden. Durch die Charakterisierung jedes Punktes im Bild wurde die automatisierte Segmentierung verbessert.

Abb. 2. Darstellung des Referenzpunktes \mathbf{p} (a), der berechneten Least-Squares Distanz (b), der Multi-Information Distanz (c) und des Punktes \mathbf{m}_i (d) mit minimaler Distanz in (c)



Die ersten Ergebnisse zeigen bereits ein verbessertes Segmentierungsergebnis, lediglich die Laufzeit des Registrierungsverfahrens ist mit 23 Stunden für einen Datensatz der Größe 160x160x120 zu hoch. Da der Algorithmus an vielen Stellen noch Raum für Verbesserungen bietet, ist weitere Forschungsarbeit an diesem Ansatz nötig. Es wäre z.B. möglich neben den Differentialeigenschaften auch Textur- oder Korrelationsinformationen im Distanzmaß einfließen zu lassen.

Literaturverzeichnis

1. Handels H, Ehrhardt J, Peters P, Plötz W, Pöpl S J: Computergestützte Planung von Hüftoperationen in virtuellen Körpern. Bildverarbeitung für die Medizin: 177-181, 1999.
2. Höhne K H, et al.: VOXEL-MAN 3D Navigator: Inner Organs. Regional, Systemic and Radiological Anatomy. Springer-Verlag Electronic Media, Heidelberg, 2000. (3 CD-ROMs, ISBN 3-540-14759-4).
3. Fischer B, Modersitzki J: A unified approach to fast image registration and a new curvature based registration technique. Technical Report A-02-07, Institute of Mathematics, Medical University of Lübeck, 2002.
4. Thirion J-P: Image matching as a diffusion process: an analogy with Maxwell's demons. Medical Image Analysis 2, no. 3, 243-260, 1998.
5. Dawant B M, et al.: Automatic 3D segmentation of internal structures of the head in MR images using a combination of similarity and free form transformations. SPIE Medical Imaging: Image Processing, no. 3338, 545-554, 1998.
6. Besl P J, McKay N D: A method for registration of 3-D shapes. IEEE Transaction on Pattern Analysis and machine Intelligence 14(2):239-258, 1992.
7. Monga O, Deriche R, et al.: Recursive filtering and edge tracking: two primary tools for 3D edge detection. Image and Vision Computing 9, no. 4, 203-214, 1991.
8. Kitchen L and Rosenfeld A Gray level corner detection. Pattern Recognition Letters 1, 95-102, 1982.
9. Rohr K: Differential operators for detecting point landmarks. Image and Vision Computing 15(3):219-233, 1997.