

Effiziente nichtlineare Registrierung mittels diskreter Optimierung

Ben Glocker^{1,2}, Nikos Komodakis^{1,3}, Nikos Paragios¹, Georgios Tziritas³,
Nassir Navab²

¹GALEN Group, Mathématiques Appliquées aux Systèmes, Ecole Centrale de Paris

²Computer Aided Medical Procedures (CAMP), Technische Universität München

³Computer Science Department, University of Crete

glocker@in.tum.de

Kurzfassung. In diesem Beitrag wird eine neuartige Methode für die nichtlineare Bildregistrierung vorgestellt. Dabei wird das klassische Energieminimierungsproblem Intensitäts-basierter Methoden in eine Markov Random Field Formulierung eingebettet. Dieses ermöglicht die Nutzung von effizienten diskreten Optimierungsmethoden, die unabhängig von der tatsächlich verwendeten Kostenfunktion eine quasi-optimale Lösung berechnen. Free Form Deformations werden als Transformationsmodell in Betracht gezogen und die Registrierung wird so auf ein diskretes Labeling-Problem reduziert. Jedem Kontrollpunkt wird eine Verschiebung zugeordnet und so die optimale Konfiguration des Modells errechnet. Das viel versprechende Potential des Frameworks wird klinischen Daten evaluiert.

1 Einleitung

Die nichtlineare Registrierung ist eine der schwierigsten Problemstellungen in der medizinischen Bildverarbeitung. Allgemeines Ziel dabei ist es, eine lokale Transformation zu bestimmen, die zwei Signale zueinander in Beziehung setzt. Obwohl diese Signale gleiche oder zumindest ähnliche Objekte abbilden, unterscheiden sie sich oftmals erheblich in ihrer Form und Intensität, wie zum Beispiel in der Bildregistrierung bei Daten aus unterschiedlichen Bildmodalitäten. Da die abgebildeten Objekte oftmals zusätzlich ihre Form über die Zeit ändern, werden Methoden benötigt, die diese nichtlineare Beziehung berücksichtigen und kompensieren können. Um die entsprechende Transformation zu berechnen, wird häufig ein mathematisches Modell in Form einer Kostenfunktion aufgestellt, die im allgemeinen hochgradig nichtkonvex, und daher schwierig zu optimieren ist. Viele der in der Literatur vorgeschlagenen Methoden können nur suboptimale Lösungen liefern. In diesem Beitrag stellen wir ein neuartiges Framework zur nichtlinearen Bildregistrierung vor. Die hier präsentierte Kombination von kontinuierlichen Deformationsmodellen mit diskreten Optimierungsmethoden hat zwei entscheidende Vorteile:

1. Nutzung von effizienten und diskreten Optimierungsalgorithmen mit quasi-optimale Lösungen

2. Unabhängigkeit und damit Flexibilität in der Auswahl der Kostenfunktion

Nichtlineare, lokale Bildregistrierung wird oft anhand geometrischer oder photometrischer Kriterien durchgeführt. Landmarken-basierte Verfahren [1, 2] sind klassische Beispiele für Verfahren, die geometrische Merkmale benutzen. Oft werden dafür anatomische Merkmale [3] oder Strukturen extrahiert, die zum Beispiel mittels Minimierung der Euklidischen Distanz registriert werden. Ein Hauptnachteil dabei ist die teilweise schwierige Selektion und Extraktion von geeigneten Landmarken, wo hingegen die Stärke in der Einfachheit des Optimierungsprozesses liegt.

Intensitäts-basierte Verfahren suchen nach visuellen Korrespondenzen zwischen dem Ziel- und Quellbild [4] und versuchen mittels Gradientenabstiegsverfahren [5] oder variationellen Methoden [6] eine Kostenfunktion basierend auf einem Ähnlichkeitsmaß zu minimieren. Ähnlichkeitsmaße können dabei zum Beispiel die Summe der quadrierten Differenzen [7], Cross Correlation [7] oder nichtlineare Maße, wie Mutual Information [8], Kullback-Liebler divergence [9] oder Correlation Ratio [10] sein. Die Implementierung des Optimierungsprozesses muss dabei meist speziell auf das verwendete Ähnlichkeitsmaß angepaßt werden.

2 Material und Methoden

In diesem Beitrag präsentieren wir eine neue Methode, die für intra- und intermodale nichtlineare Bildregistrierung genutzt werden kann. Um die Glattheit des zu bestimmenden Deformationsfeldes zu garantieren und den Parameterraum des Problems zu reduzieren repräsentieren wir die Transformation mittels Free Form Deformations (FFD). Das Registrierungsproblem wird in eine Markov Random Field (MRF) Formulierung eingebettet und mit Hilfe effizienter MRF-Algorithmen gelöst, wobei eine Zuordnung von sogenannten Labels zu den Kontrollpunkten berechnet wird, die eine Minimierung der Kostenfunktion zum Ziel hat. Die Optimierung ist dabei unabhängig von der Konstruktion des MRFs und damit unabhängig von der Wahl der Kostenfunktion, da keine Ableitungen bestimmt werden müssen. Unseres Wissens, ist dies die erste Arbeit, in der kontinuierliche Deformationsmodelle, wie FFD, mit effizienter MRF-Optimierung kombiniert werden. Neben der bereits erwähnten Vorteile, die Unabhängigkeit von der Kostenfunktion und den quasi-optimalen Lösungen durch die diskrete Optimierung, wird eine signifikante Verbesserung der Performanz im Vergleich zu herkömmlichen Methoden basierend auf Gradientenabstiegs-Verfahren erzielt.

Im Folgenden wird die mathematische Herleitung unseres Frameworks skizziert. Für weitere Details verweisen wir auf [11]. Das Registrierungsproblem kann als Energieminimierungsproblem formuliert werden:

$$E(\mathcal{T}) = \int_{\Omega} \rho(g(\mathbf{x}), f(\mathcal{T}(\mathbf{x}))) d\mathbf{x} \quad (1)$$

wobei \mathcal{T} die gesuchte Transformation des Quellbildes f beschreibt, um dieses mit dem Zielbild g zu registrieren. Die optimale Registrierung wird durch Minimierung der Energie E unter Berücksichtigung des Ähnlichkeitsmaßes ρ erreicht.

Das Transformationsmodell und das zugehörige Deformationsfeld \mathcal{D} basierend auf FFD kann wie folgt formuliert werden:

$$\mathcal{T}(\mathbf{x}) = \mathbf{x} + \mathcal{D}(\mathbf{x}) \quad \text{und} \quad \mathcal{D}(\mathbf{x}) = \sum_{p \in G} \eta(|\mathbf{x} - \mathbf{p}|) \mathbf{d}_p \quad (2)$$

wobei $\eta(\cdot)$ die Gewichtungsfunktion ist, die den Einfluss der einzelnen Kontrollpunkte bestimmt. In unserer Implementierung betrachten wir hierfür kubische B-Splines. Die neutrale Position eines Kontrollpunkts wird als \mathbf{p} definiert und dessen aktuelle Verschiebung durch \mathbf{d}_p . Ziel ist die optimale Konfiguration der Kontrollpunkte zu bestimmen, so dass die beiden Bilder bestmöglich registriert sind.

Unser neuartiger Ansatz für die Lösung dieses Problems beruht auf der Idee, das Problem als diskretes Labeling aufzufassen. Dabei agieren die Kontrollpunkte als diskrete Variablen und die möglichen Verschiebungen \mathbf{d}_p werden durch sogenannte Labels u_p ausgedrückt. Jedem Kontrollpunkt wird ein Label zugewiesen, das die bestmögliche Deformierung beschreibt. Ein solches diskretes Labeling-Problem kann als klassisches MRF-Problem ausgedrückt werden:

$$E_{\text{total}}(u) = \sum_{p \in G} V_p(u_p) + \sum_{p, q \in N} V_{pq}(u_p, u_q) \quad (3)$$

Hierbei steht u für das Labeling. Die sogenannten Singleton Potentials $V_p(u_p)$ beschreiben die Kosten, die eine Zuweisung des Labels u_p zu dem Kontrollpunkt $p \in G$ verursachen. Die Pairwise Potentials dienen als Regularisierungsterm für die Zuweisung der Labels u_p und u_q an die benachbarten Kontrollpunkte $p, q \in N$. Durch eine proportionale Bestrafung der Distanz zwischen zwei Labels wird eine Glättung des resultierenden Labelings erreicht.

Um das Registrierungsproblem in die MRF-Formulierung einzubetten, definieren wir die beiden Potentialfunktionen wie folgt:

$$V_p(u_p) = \frac{1}{|G|} \int_{\Omega} \eta^{-1}(|\mathbf{x} - \mathbf{p}|) \rho(g(\mathbf{x}), f(\mathbf{x} + \mathbf{d}^{u_p})) d\mathbf{x} \quad (4)$$

Diese Datenterme können als lokale Auswertung des Ähnlichkeitsmaßes aufgefasst werden. An jedem Kontrollpunkt wird entsprechend der inversen Gewichtungsfunktion [11], ausgedrückt durch η^{-1} , bestimmt, wie gut die Registrierung lokal im Bereich des Kontrollpunkts ist. Als Regularisierungsterm betrachten wir eine stückweise glatte Distanzfunktion:

$$V_{pq}(u_p, u_q) = \lambda_{pq} \min(|\mathbf{d}^{u_p} - \mathbf{d}^{u_q}|, T) \quad (5)$$

Da die Menge der Labels endlich definiert wird, jedoch die vorliegende Deformation oftmals unbekannt ist, benutzen wir einen Multi-Level Ansatz. Sowohl die Bild- und FFD-Auflösung wird sukzessive erhöht als auch die Menge der möglichen Kontrollpunktverschiebungen sukzessive verfeinert [11].

Für die Optimierung verwenden wir einen kürzlich entwickelten effizienten MRF-Optimierungsalgorithmus basierend auf linearer Programmierung, Fast-PD [12]. Dessen Stärke liegt insbesondere in der hohen Performanz und den quasi-optimalen Lösungen für MRF-Probleme.

Tabelle 1. Ergebnisse für die graue Gehirnschubstanz bei der MR Registrierung. Die linken Zahlen sind die Ergebnisse nach affiner Registrierung, rechts die Ergebnisse nach nichtlinearer Registrierung. In Klammern ist die prozentuale Verbesserung angegeben

Datensatz	DICE	Sensitivität	Spezifität
1	0.6959 / 0.8752 (26%)	0.7466 / 0.8752 (17%)	0.9650 / 0.9847 (2%)
2	0.7188 / 0.8365 (16%)	0.7082 / 0.8365 (18%)	0.9796 / 0.9894 (1%)
3	0.6964 / 0.8053 (16%)	0.6402 / 0.8053 (26%)	0.9821 / 0.9878 (1%)
4	0.7261 / 0.8927 (23%)	0.7803 / 0.8927 (14%)	0.9718 / 0.9851 (1%)
5	0.6959 / 0.8672 (25%)	0.7252 / 0.8672 (20%)	0.9695 / 0.9828 (1%)
6	0.7001 / 0.8012 (14%)	0.6214 / 0.8012 (29%)	0.9854 / 0.9901 (1%)
7	0.6900 / 0.8601 (25%)	0.6554 / 0.8601 (31%)	0.9779 / 0.9867 (1%)

3 Ergebnisse und Diskussion

Wir evaluieren unsere Registrierungsmethode quantitativ anhand medizinischer Datensätze und können zeigen, dass sub-voxel Genauigkeit mit verschiedensten Kostenfunktionen erreicht wird. Beispielhaft wird hier eines der Experimente präsentiert. Segmentierte 3D MR Gehirndatensätze werden benutzt, um die Registrierungs-genauigkeit zu bestimmen. Die Datensätze inklusive Referenzsegmentierungen wurden vom Center for Morphometric Analysis am Massachusetts General Hospital zur Verfügung gestellt und stehen unter folgender Adresse zum Download bereit: <http://www.cma.mgh.harvard.edu/ibsr/>. In Tabelle 1 sind die Ergebnisse zu sehen, wenn wir einen der 8 Datensätze als Atlas auswählen und zu den restlichen 7 registrieren. Die übertragene Segmentierung der grauen und

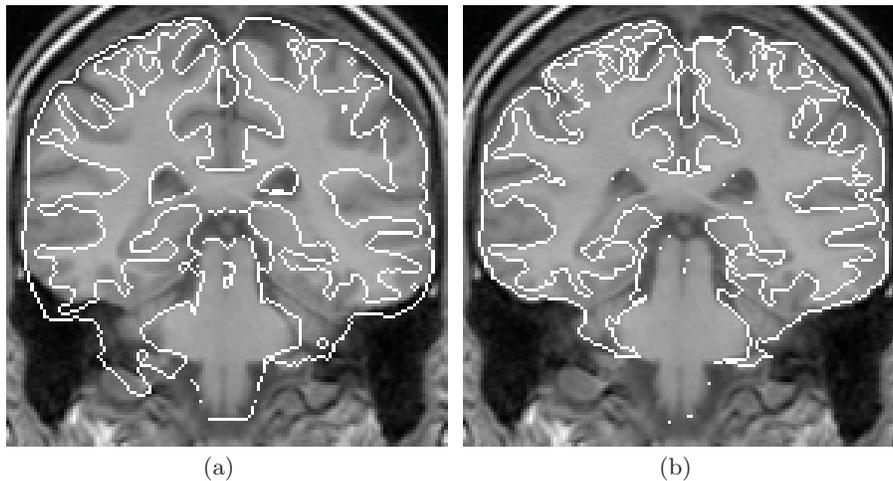


Abb. 1. Überlagerung des Umrisses der grauen Gehirnschubstanz nach (a) affiner (DICE 0.726) und (b) unserer nichtlinearen Registrierung (DICE 0.893)

weißen Gehirns substanz wurde dann mit den entsprechenden manuellen Referenzsegmentierungen verglichen.

Weitere klinische Daten wurden benutzt, um den Vergleich mit dem bisherigen quasi Gold-Standard FFD Registrierer [5] basierend auf Gradientenabstiegsverfahren zu ermöglichen. Wir konnten zeigen, dass mit unserem Framework eine 3D-3D Registrierung mit einem immensen Geschwindigkeitsvorteil bei visuell besseren Ergebnissen erzielt werden kann. Die Registrierungszeit der herkömmlichen Gradienten-basierten Methode wurde von ca. 120 Minuten auf 2 Minuten reduziert [11]. Weitere Anwendungsgebiete und Ergebnisse präsentieren wir in [13].

Literaturverzeichnis

1. Hellier P, Barillot C. Coupling dense and landmark-based approaches for nonrigid registration. *IEEE Trans Med Imaging*. 2003;22(2):217–27.
2. Rohr K, Fornefett M, Stiehl HS. Spline-based elastic image registration: integration of landmark errors and orientation attributes. *Comp Vis Image Understand*. 2003;90(2):153–68.
3. Pennec X, Ayache N, Thirion JP. Landmark-based registration using features identified through differential geometry. In: *Handbook of Medical Imaging*; 2000. p. 499–513.
4. Cachier P, Bardinet E, Dormont D, et al. Iconic feature based nonrigid registration: the PASHA algorithm. *Comp Vis Image Understand*. 2003;89(2-3):272–98.
5. Rueckert D, Sonoda L, Hayes C, et al. Nonrigid registration using free-form deformations: Application to breast MR images. *IEEE Trans Med Imaging*. 1999;18(8):712–21.
6. Modersitzki J. *Numerical Methods for Image Registration*. Oxford University Press; 2004.
7. Hajnal J, Hill DLG, Hawkes DJ, editors. *Medical Image Registration*. CRC Press; 2001.
8. Maes F, Collignon A, Vandermeulen D, et al. Multimodality image registration by maximization of mutual information. *IEEE Trans Med Imaging*. 1997;16(2):187–98.
9. Zollei L, Fisher J, Wells W. An introduction to statistical methods of medical image registration. In: Paragios N, Chen Y, Faugeras O, editors. *Handbook of Mathematical Models in Computer Vision*. Springer; 2005.
10. Roche A, Malandain G, Pennec X, et al. The correlation ratio as a new similarity measure for multimodal image registration. *Proc MICCAI*. 1998.
11. Glocker B, Komodakis N, Paragios N, et al. Inter and intra-modal deformable registration: Continuous deformations meet efficient optimal linear programming. In: *Information Processing in Medical Imaging*; 2007.
12. Komodakis N, Tziritas G, Paragios N. Fast, Approximately optimal solutions for single and dynamic MRFs. *Proc CVPR*. 2007.
13. Glocker B, Komodakis N, Paragios N, et al. Primal/Dual linear programming and statistical atlases for cartilage segmentation. *Proc MICCAI*. 2007.