Bilder aus Diagnostik und Behandlungsplanung in der Strahlentherapie zur Auswertung von Online-daten mit neuronalen Netzen

Gerald Krell*, Bernd Michaelis*, Mathias Walke**, Roman Calow*, Nils Riefenstahl*

Otto-von-Guericke-Universität Magdeburg
*Institut für Elektronik, Signalverarbeitung und Kommunikationstechnik
**Klinik für Strahlentherapie
Postfach 4120, Universitätsplatz 2, D-39016 Magdeburg, Germany
Email: krell@iesk.et.uni-magdeburg.de

Zusammenfassung. Die Technik der elektronischen Portalbilder konnte sich zu einem wichtigen Werkzeug bei der Verifizierung der korrekten Patientenlagerung in der Strahlentherapie entwickeln. Im Gegensatz zu klassischen Verfahren der Bildverbesserung wird bei der vorgestellten Methode a-priori-Wissen aus vorab gewonnenen Bildern benutzt, um die Aussagekraft der Bildinformation wesentlich zu erhöhen. Zusätzlich werden Daten eines optischen Oberflächensensors für die Vermessung der tatsächlichen Patientenlagerung einbezogen und um eine eindeutige Registrierung zwischen den Bildmodi sowie die Verfolgung von Patientenbewegungen zu ermöglichen.

Schlüsselwörter: Strahlentherapie, Bildkorrektur, Sensorfusion, neuronale Netze, Portalbild

1 Einleitung

Elektronische Portalbilder (EPI, electronic portal image) werden durch Projektion des Körperinneren mit dem Behandlungsstrahl auf einen Bildschirm erzeugt und nach Aufnahme z. B. durch eine Kamera als digitales Bild zur Verfügung gestellt. Wegen der hohen Energie des Behandlungsstrahls weisen die unverarbeiteten EPIs jedoch eine deutlich geringere Bildqualität im Vergleich zu den sonst zur Verfügung stehenden Bildern aus Diagnostik und Behandlungsplanung auf.

Die Grundidee besteht in der Fusion von on-line-Daten der EPIs mit dem a-priori-Wissen aus Bildern der Behandlungssimulation, die im Rahmen der Behandlungsplanung durchgeführt wird. Während Diagnostik und Behandlungssimulation werden routinemäßig Bilder zur Zielvolumenlokalisation aufgenommen, die gewöhnlich als Röntgenfilm, CT oder MR zur Verfügung stehen (Simulatorbilder). Im vorgestellten System fließen zusätzliche Daten eines neuartigen Oberflächensensors ein. Es wird zunächst ein speziell strukturiertes künstliches neuronales Netz - ein modifizierter Assoziativspeicher - mit den Simulatorbildern trainiert. Der Assoziativspeicher ist in der Lage, Prototypbilder abzuspeichern, wobei mögliche Variationen des Körperinneren bezüglich Lage und Form simuliert und bei der Lerndatengenerierung berücksichtigt werden.

Der Recall des Assoziativspeichers mit einem On-line-Bild, wie es das EPI darstellt, ist dann (vereinfacht ausgedrückt) eine Interpolation der ähnlichsten Prototypbilder. Die Bilder werden in Regionen aufgeteilt und ein Matchingalgorithmus angewendet, um korrespondierende Merkmale zu ermitteln. Dieser Vorgang wird durch die Daten des optischen Oberflächensensors unterstützt. Eine geringe Zahl von markanten Punkten ist für die Detektion von Bewegungen ausreichend. In einem weiteren Schritt erfolgt der Recall des Assoziativspeichers mit den korrespondierenden Regionen im EPI.

2 Überblick

Abb. 1 illustriert das zweistufige Verfahren. Das unverarbeitete EPI ist gewöhnlich von niedriger Qualität im Vergleich zu den Simulatorbildern aus Diagnostik und Behandlungsplanung, und die Wirkung herkömmlicher Bildverarbeitungsalgorihmen ist begenzt [3]. Deshalb wird zusätzlich dieses a-priori-Wissen für die Auswertung der on-line-Bilder herangezogen, indem die Simulatorbilder zur Generierung von Trainingsdaten für den Assoziativspeicher benutzt werden, die den Eingang des Assoziativspeichers während des Anlernvorgangs bilden.

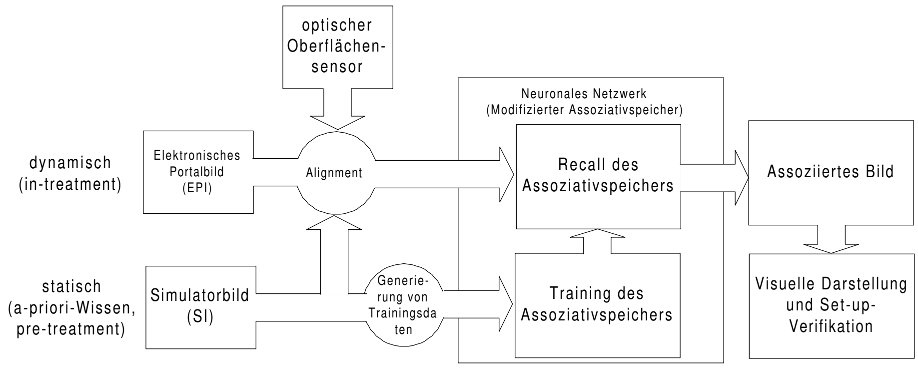

Abb. 1: Systemüberblick

Der Recall des Assoziativspeicher erfolgt dann mit dem aktuellen EPI. Dabei wird das Abrufbild unter Verwendung eines Alignment-Verfahrens mit den abgespeicherten Informationen in Deckung gebracht. Dieser Vorgang wird durch den optischen Oberflächensensor hinsichtlich Geschwindigkeit und Konvergenzsicherheit unterstützt.

3 Assoziativspeicher zur Abspeicherung von a-priori-Wissen

Es wird ein spezieller Typ eines neuronalen Netzes, ein modifizierter Assoziativspeicher, für die Einbeziehung von a-priori-Wissen in die EPI-Auswertung benutzt (Abb. 3). In herkömmlichen Anwendungen werden Assoziativspeicher für die Mustererkennung verwendet. Die Eigenschaft bestimmter Assoziativpeichern, zwischen abgespeicherten ähnlichen Mustern zu interpolieren, wird hier für eine "assoziative Restauration" zur Einbeziehung von a-priori-Wissen ausgenutzt. Um dies zu erreichen, werden neben den eigentlichen Simulatorbildern auch noch die zu erwartenden Variationen als Lerndatensatz in den Assoziativspeicher "eintrainiert". Dies geschieht durch Rauschüberlagerung, grauwertmorphologische Operationen und leichte Verzerrung in gewissen Grenzen.

Die linke Seite in Abb. 2 zeigt den Aufbau des Assoziativspeichers flächig entsprechend der 2D-Charakteristik der betrachteten Bilder. Für die numerische Berechnung werden die Daten jedoch vektorisiert (Abb. 2, rechts) und die Formeln darauf bezogen angegeben.

Die Mittelung aller Lerndaten ergibt ein Mittelwertbild, das für den Lernvorgang von allen Bildern im Lerndatensatz abgezogen und im Recall zum Ergebnis addiert wird. Dadurch ist im Assoziativspeicher die zu erwartende Variabilität des Simulatorbildes enthalten. Dieses Vorgehen vereinfacht die mathematischen Beziehungen und erlaubt die Anwendung von Standardverfahren (hier die Karhunen-Loéve-Transformation).

Für das verwendete lineare Netz ergeben sich die assoziierten Pixel $\vec{\mathbf{d}}^* = \mathbf{G} * \vec{\mathbf{a}}$,

wobei $\vec{\mathbf{a}} = \mathbf{W} * \vec{\mathbf{d}}^*$

die Ausgänge der Hiddenlayerneuronen sind, und es folgt

$$\vec{\mathbf{d}}^* = \mathbf{GW} * \mathbf{d} \ .$$

Die Gewichte in ***G*** werden konventionell durch die Lösung des Eigenwertproblems bestimmt [2]. Die Matrix **W** wird identisch zu $\mathbf{G}^{\,t}$ gewählt, da es sich um eine autoassoziative Aufgabe handelt. Der Datenumfang wird in den Hiddenschicht erheblich reduziert, denn $m << l, n$.

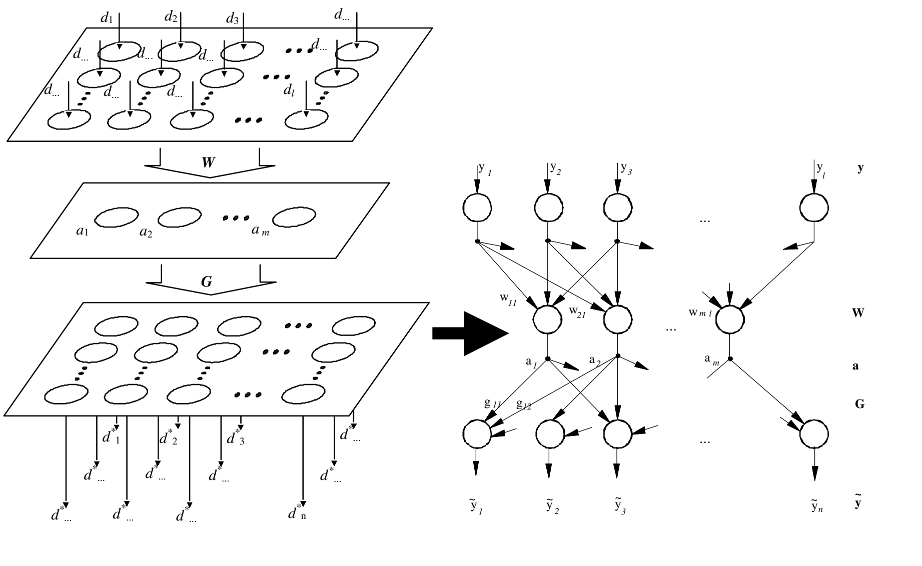

Abb. 2: Modifizierter Assoziativspeicher: flächiger Input/Output (links), Struktur zur Berechnung (rechts)

Bei einer geringen Anzahl von zu ermittelnden Hiddenneuronen, wie hier im allgemeinen möglich, kann ein Hebb'sches Lernverfahren für die schnellere Bestimmung der Gewichte verwendet werden [4]. Da die Eigenvektoren entsprechend der Größe der Eigenwerte geordnet sind, gestattet die gewählte Anzahl von Hiddenneuronen m auch die Wahl des gewünschten Einflusses des aktuellen Inputs auf den Recall: je größer m gewählt wird, um so mehr treten feine Variationen des Inputs gegenüber dem Mittelwertbild in Erscheinung bzw. je kleiner m, desto besser die Unterdrückung von Störungen.

Die Erkennung von anatomischen Merkmalen in bezug auf die erwünschte Position laut Bestrahlungsplanung ist eine wichtige Forderung. Fehllagerung und Bewegung des Patienten während der Bestrahlung können zu Abweichungen führen. Außerdem liegen im allgemeinen zwischen Diagnostik, Behandlungsplanung und eigentlicher Bestrahlung größere Zeiträume, so daß sich das Erscheinungsbild der Anatomie ändern kann. Daher werden für den Recall die anatomischen Merkmale in den Bildmodi durch ein elastisches Warpingverfahren [1] in Deckung gebracht (Alignment). Die Startwerte für diesen Algorithmus werden dabei durch Vermessung mit dem optischen Sensor ermittelt. Hierbei handelt es sich um System bestehend aus zwei Kameras und einem Projektor, die zur photogrammetrischen Vermessung benutzt werden [5].

4 Beispiel

Abb. 3 zeigt das Stereobildpaar des optischen Sensors, der ausgewählte Punkte auf der Körperoberfläche verfolgen soll. Die Punkte wurden im Beispiel zweimal vermessen. In der Abbildung rechts sind die Verschiebungsvektoren dargestellt, wie sie durch die Atembewegungen des Patienten hervorgerufen wurden. Um Parameter für das Alignment des assoziativen Recalls werden die Komponenten der 3D-Vektoren in der Ebene des EPI verwendet.
Abb. 4 zeigt ein Beispiel für den Abruf des Assoziativspeichers mit einem EPI (Abb. 4b), nachdem er mit einem aus einem Simulatorbild (Abb. 4a) generierten Lerndatensatz trainiert wurde. Signifikante Oberflächenpunkte wurden während des Bestrahlungsverlaufs vermessen. Zusammen mit dem Ergebnis des Alignmentvorgangs resultieren die Verschiebungsvektoren nach Abb. 4c. Durch den Abruf des Assoziativspeichers mit dem EPI kann für kann ein wesentlich verbessertes Bild des Patienten (Abb. 4d) bei der Bestrahlung gewonnen werden, da a-priori-Wissen einbezogen wurde. m beträgt im gewählten Beispiel 10. Abweichungen von Form und Lage anatomischer Merkmale werden berücksichtigt.

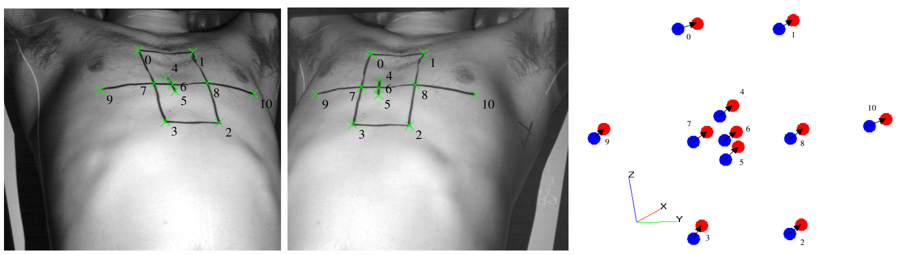

Abb. 3: Segmentierte Marker zum Oberflächentracking (l.), durch Atmung hervorgerufene Markerverschiebung (r.)

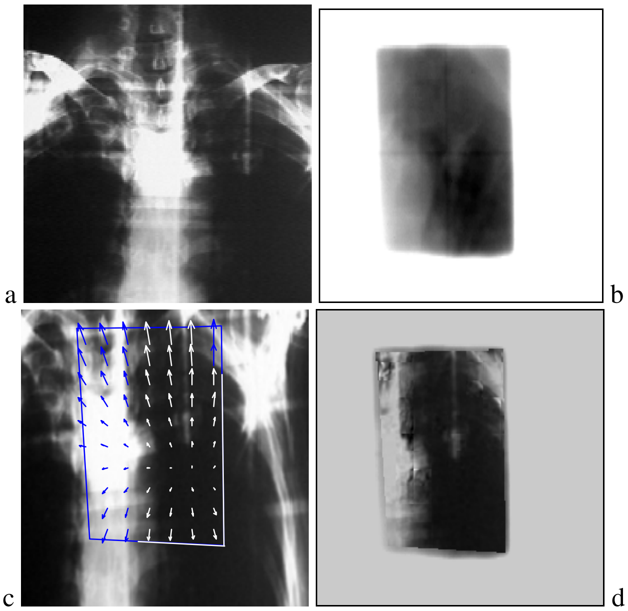

Abb. 4: Beispiel für die assoziative Restauration (Brustkorb): a) Simulatorbild; b) EPI; c) an aktuelles EPI angepaßtes Simulatorbild mit gekennzeichnetem Feld und Verschiebungsvektoren; d) Recall des Assoziativspeichers

5 Fazit

Das vorgeschlagene Verfahren nutzt a-priori- und Oberflächendaten für die EPI-Auswertung. Oberflächenpunkte werden getrackt, um die aktuelle Lagerung des Patienten zu verfolgen. Auf diese Weise stehen neuartige Werkzeuge zu Überprüfung der Patientenlagerung zur Verfügung.

Diese Arbeit wurde durch das Land Sachsen-Anhalt (FKZ 0002KE0099) und die EU-Förderung des Projekts ARROW (CT96-3660) unterstützt.

6 Literatur

1. Krell G, Tizhoosh HR, Lilienblum T, Moore CJ, Michaelis B: Enhancement and Associative Restoration of Electronic Portal Images in Radiotherapy. International Journal of Medical Informatics, vol. 49/2, Elsevier Science Ireland, 157-171, 1998.
2. Abbas HM, Fahmy MM: A Neural Model for Adaptive Karhuen Loéve Transformation (KLT). Int. Joint Conf. on Neural Netw., Baltimore, Maryland, vol. 2, 975-980, 1992.
3. Leszczynski K W, Shalev S, Cosby NS: The enhancement of radiotherapy verification images by an automated edge detection technique. Med. Phys. 19 (3), 1992.
4. Oja, E, Ogada, H, Wangviwattana, J: Learning in nonlinear, constained Hebbian networks. In: Kohonen et al. (eds), Artificial Neural Networks, Proc ICANN'91, North-Holland, Amsterdam, 385-375, 1991.
5. Albrecht P, Michaelis B: Improvement of the Spatial Resolution of an Optical 3-D Measurement Procedure. IEEE Transactions on Instrumentation and Measurement, Vol 47, No 1, 158-162, Februar 1998.