

Kooperatives Arbeiten und rechnergestützte Ferndiagnostik mittels neuronaler Netze auf ISDN-Leitungen

Ch. Busch¹⁾, M. Groß¹⁾, H. Handels²⁾, Th. Roß²⁾, Ch. Hahn²⁾, E. Rinast³⁾, K. Rösler⁴⁾,
H. Putzar⁴⁾, J. Miehe⁵⁾, S. Nowacki⁶⁾, A. Will⁶⁾, U. von Lukas⁵⁾

- 1) Zentrum für Graphische Datenverarbeitung e. V., Darmstadt
- 2) Institut für Medizinische Informatik, Medizinische Universität zu Lübeck
- 3) Institut für Radiologie, Medizinische Universität zu Lübeck
- 4) Radiologische Klinik, Universität Rostock
- 5) Zentrum für Graphische Datenverarbeitung e. V., Außenstelle Rostock
- 6) Fraunhofer Institut für Graphische Datenverarbeitung, Außenstelle Rostock

Zusammenfassung

Kooperatives Arbeiten gewinnt in der radiologischen Diagnostik zunehmend an Bedeutung. Für den Einsatz kooperativer Bildverarbeitungstechniken in der medizinischen Anwendung ist die Entwicklung leistungsfähiger Methoden zum *computer supported cooperative work* (CSCW) notwendig. Eine exemplarische Realisierung von CSCW-Funktionen zur Unterstützung des kooperativen Arbeitens in der Radiologie wird in dem Kooperationsprojekt KAMEDIN (Kooperatives Arbeiten und Rechnergestützte Medizinische Diagnostik auf Innovativen Netzen der Telekom) entwickelt: Radiologische Bilddaten werden zwischen räumlich getrennten medizinischen Experten über ISDN-Verbindungen ausgetauscht und interaktiv bearbeitet; Anwenderaktionen werden vom System verwaltet und synchronisiert. Im Gegensatz zu bereits existierenden Systemen (z.B. [1]) spielen hier Einschränkungen bezüglich der begrenzten ISDN-Bandbreite beim Systementwurf eine wesentliche Rolle. Zur Diagnoseunterstützung werden künstliche neuronale Netzwerke und high-level-Bildverarbeitungsverfahren eingesetzt mit dem Ziel der Klassifikation und 3D-Rekonstruktion von Gewebsstrukturen. Besonders Kohonen-Feature-Maps ([2], [3] und [4]) haben bei der Analyse multidimensionaler medizinischer Bilddaten vielversprechende Ergebnisse gezeigt.

Einleitung

Aufgrund der allgemeinen Verfügbarkeit innovativer Kommunikations-Infrastrukturen, wie z.B. ISDN, gewinnt rechnergestütztes, kooperatives Arbeiten in der medizinischen Diagnostik mehr und mehr an Bedeutung. Darüber hinaus werden durch die flächendeckende Vernetzung neue Möglichkeiten zur Ausnutzung der Kapazitäten entfernt liegender Höchstleistungsrechner (Tele-Supercomputing) eröffnet. Im Projekt KAMEDIN werden im Verbund zwischen Lübeck, Rostock und Darmstadt verschiedene Dienste zur Diagnoseunterstützung in der Radiologie unter Einbindung eines Supercomputers in einer Workstationumgebung auf der Basis einer ISDN-Vernetzung zur Verfügung gestellt (Abb. 1).

Kooperatives Arbeiten auf ISDN-Netzen

Innerhalb einer Telekonferenz ermöglichen die Techniken des kooperativen Arbeitens räumlich getrennten Experten die gemeinsame Analyse medizinischer Bilddaten. Das kooperative Arbeiten beinhaltet multimediale Komponenten, die die gleichzeitige Verwendung und Verarbeitung von textueller, visueller und auditiver Information erlauben. Der Datenaustausch sowie die Kommunikation während einer Konferenz wird über das Schmalband-ISDN-Netz der Telekom (S_0 -Basisschnittstelle) realisiert. Für die Point-to-Point Verbindung wird das TCP/IP-Protokoll benutzt. Der begrenzten Bandbreite des ISDN-Kommunikationskanals wird durch eine Batch-orientierte Vorbereitung einer Telekonferenz Rechnung getragen. Große Bilddatenmengen werden bereits vor der Telekonferenz an den Gesprächspartner übertragen und liegen damit zu Beginn einer kooperativen Sitzung als Konferenzakte auf den lokalen Rechnern vor. Während einer Konferenz müssen lediglich die Steuerkommandos übertragen werden, die die quasiparallele Ausführung von identischen Bildverarbeitungsoperationen auf den räumlich getrennten Rechnern anstoßen. Dem Benutzer stehen innerhalb der Telekonferenz folgende Basisbildverarbeitungsoperationen zur Verfügung: Ausgabe von Sequenzübersichten, Einzel- oder Doppelbildausgabe, Dichtemessung, Fensterung der Signalwerte etc. sowie die Einzeichnung von regions of interests (ROI) für die Gewebeklassifikation. Die Benutzung bzw. der Aufruf der Bildverarbeitungsoperationen während einer Telekonferenz wird durch die Vergabe eines Rederechts gesteuert, das eindeutig einem der beiden Konferenzpartner zugeordnet ist und auf Anforderung an den anderen Konferenzpartner übergehen kann.

Abb. 1: Netzkonfiguration bestehend aus lokalen Workstations und einem Supercomputer

Rechnerbasierte Diagnoseunterstützung

Zur Diagnoseunterstützung stehen dem Anwender high-level-Bildverarbeitungsalgorithmen und künstliche neuronale Netze zur Verfügung, durch die medizinische Bilddaten automatisch analysiert und klassifiziert werden können. Ziel des Klassifikationsprozesses ist es, die einzelnen Gewebsstrukturen in den Originaldaten voneinander zu trennen und insbesondere pathologische Bereiche zu segmentieren. Als Ergebnis liegen dem Anwender klassifizierte Bild- bzw. Volumendaten vor, die farbkodiert Lage und Ausmaß pathologischer Gewebsstrukturen verdeutlichen. Die Datenanalyse wird durchgeführt unter Einsatz künstlicher neuronaler Netze. Diese Algorithmen, die sich an der Funktion und dem Aufbau von Nervenzellenverbindungen im Gehirn - den biologischen neuronalen Netzen - orientieren, sind besonders dann geeignet, wenn multidimensionale Texturmerkmale für die Klassifikation und Segmentierung verwendet werden. Die Vorgehensweise der Analyse kann in die folgenden Einzelschritte unterteilt werden (Abb. 2):

- 1.) Definition bekannten Wissens (-> Klasseneinteilung)
- 2.) Formulierung bekannten Wissens (-> Definition von Trainingsgebieten)
- 3.) Beschreibung der Textur (->Merkmalsextraktion)
- 4.) Anpassung neuronaler Netze an das Klassifikationsproblem (->Training)
- 5.) Anwendung (->Analyse)

Abb. 2: Schematische Darstellung des Analyseprozesses

Klasseneinteilung: Die Klasseneinteilung orientiert sich an den medizinischen Fragestellungen und den abgebildeten anatomischen Objekten des jeweiligen Akquisitionsverfahrens. Bei gegebenem gutem Weichteilkontrast in den Bilddaten kann eine Unterteilung in mehrere Klassen vorgenommen werden (Beispiel: Tumor, Liquor, Fettgewebe, Knochen,..).

Definition von Trainingsgebieten: Zum Training eines neuronalen Netzes ist eine statistisch repräsentative Auswahl von Daten für jede Gewebestruktur (Klasse) erforderlich. Diese Auswahl wird aus den Originaldaten durch die Definition von Trainingsgebieten gewonnen. Für jede Klasse werden aus diagnostizierten Fällen typische ROI's in einer Datenbasis abgelegt, wobei neben der Klasseninformation die Parameter der Bildakquisition (Aufnahmeverfahren, Kontrastmittelgabe, Relaxationszeiten, etc.) mit abgespeichert werden. Dieses Expertenwissen bildet die Grundlage für die Güte einer automatischen Klassifikation.

Merkmalsextraktion: Zur Extraktion der relevanten Texturmerkmale wird die lokale, dreidimensionale Nachbarschaft eines Volumenelementes berücksichtigt. Für die Analyse multidimensionaler Volumendaten, wie sie beispielsweise in Doppel- oder Multiechosequenzen anfallen, werden die Merkmale korrespondierender Pixel in einem Merkmalsvektor akkumuliert.

Training: Im Trainingsprozeß wird ein künstliches neuronales Netz iterativ an das Klassifikationsproblem angepaßt. Für die automatische Datenanalyse stehen Backpropagation-Netzwerke und Kohonen-Feature-Maps zur Verfügung. Besonders bewährt hat sich die Verwendung einer dreidimensionalen Kohonen-Feature-Map, deren Ausgabeschicht aus einem Würfel mit $6 \times 6 \times 6$ Neuronen besteht. Hierbei liefert die Eingabeschicht des Netzes für jedes Volumenelement einer Körperschicht $3 \times 3 \times n$ Merkmalsausprägungen eines vierdimensionalen rezeptiven Feldes, wobei n die Dimension der analysierten Bilddaten angibt. Durch interaktive Modifikation der Klassen-Label kann der Zustand des Klassifikators nachträglich optimiert werden.

Analyse: Trainierte neuronale Netze stehen dem Anwender zur Diagnoseunterstützung zur Verfügung, wenn die Akquisitionsparameter der zu analysierenden Bildsequenz denen des Trainingsdatensatzes entsprechen.

Die intensiven Rechenprozesse der Datenanalyse können zur Entlastung der lokalen Workstation eines Anwenders auf einen Supercomputer ausgelagert werden. Dazu wurde in das System der Höchstleistungsrechner Siemens-Fujitsu S400/40 des Landes Hessen integriert, der mit einer vektoriellen Peakleistung von 2×2500 MFlops die Klassifikation batchorientiert durchführt. Die Ergebnisse der automatischen Klassifikation können vom Anwender als Schichtbilder visualisiert werden. Darüber hinaus kann aus dem klassifizierten Volumendatensatz eine dreidimensionale Ansicht von rekonstruierten Objektflächen erzeugt werden (z.B. Lage des Tumors im Schädel).

Literatur:

- [1] Ricke, H., Kanzow, J.: BERKOM, Breitbandkommunikation im Glasfasernetz, R. v. Decker, 1991.
- [2] Franzke, M., Handels, H.: Topologische Merkmalskarten zur automatischen Mustererkennung in medizinischen Bilddaten, in: Fuchs, S., Hoffmann, R. (Hrsg.), Mustererkennung 1992, Informatik aktuell, 329-334, 1992.
- [3] Groß, M., Seibert, F.: Visualization of Multidimensional Image Data Sets using a Neural Network, to appear in "The Visual Computer", Vol. 10, 1993.
- [4] Rinast, E., Linder, R., Weiss, HD.: Neural Network Approach for Computer-assisted Interpretation of Ultrasound Images of the Gallbladder, Radiology 1992, 185 (P): 191, 1992.