

Automatische Segmentierung von kontrastmittelaufnehmenden Hirntumoren in multispektralen MR-Bilddaten mittels Backpropagation-Netzwerken

Chr. Sieg*, H. Handels, S. J. Pöppel

Institut für Medizinische Informatik
Medizinische Universität zu Lübeck, 23538 Lübeck
*jetzt: ZN Vision Technologies AG
Universitätsstraße 160, 44801 Bochum
Email: christian.sieg@zn-ag.com
handels@medinf.mu-luebeck.de

Zusammenfassung. In diesem Beitrag werden topologie-optimierte Backpropagation-Netzwerke vorgestellt und evaluiert, die zur neuronalen Segmentierung kontrastmittelaufnehmender, intrakranieller Tumoren und anatomischer Strukturen in registrierten, multispektralen MR-Bildfolgen entwickelt wurden. Für das Training der Netze werden 4-dimensionale Pixelvektoren aus einer Falldatenbank mit 22 interaktiv segmentierten Hirntumoren der Typen Meningeom, Glioblastom sowie Metastase verwendet. Nach der pixelbezogenen Tumorklassifikation wird der Tumor als größte 3D Zusammenhangskomponente in der Menge der markierten Pixel extrahiert. In 19 Fällen (86%) konnte ein zur manuellen Segmentierung adäquates Ergebnis durch die automatische Segmentierung erzielt werden. Segmentierungsfehler, die eine interaktive Nachbearbeitung der Segmentierungsergebnisse notwendig machten, traten nur in 3 Fällen (14%) auf und waren auf die relativ geringe Kontrastmittelaufnahme der Tumoren zurückzuführen.

1 Einleitung

In der neuroradiologischen Untersuchung von Hirntumorpatienten ist die MR-Tomographie von hoher Relevanz. Hierbei werden in dem untersuchten Kopfbereich dreidimensionale, multispektrale MR-Bildfolgen generiert. Die Segmentierung des Hirntumors ist sowohl für die neuroradiologische Diagnostik als auch für die Planung neurochirurgischer Eingriffe von zentraler Bedeutung.

Innerhalb dieses Beitrages werden topologie-optimierte Multilayer-Perzeptron-Netzwerke (MLP) zur automatischen 3D-Segmentierung kontrastmittelaufnehmender Hirntumoren vorgestellt und die erzielten Ergebnisse evaluiert. Ausgangspunkt der Analyse bilden 4-kanalige 3D-Bilddaten bestehend aus T1-gewichteten Bildern vor und nach Kontrastmittelgabe sowie T2- und spindichtegewichteten Bildern (Abb. 1).




Abb. 1. 4-kanalige MR-Schichtaufnahme eines Meningeoms

2 Tumorsegmentierung mit Backpropagation-Netzen

Da die verschiedenen gewichteten Bildfolgen in mehreren Messvorgängen erzeugt wurden, werden die dreidimensionalen MR-Bilddaten eines Patienten im ersten Schritt zur Kompensation von Patientenbewegungen etc. mittels rigider Registrierungsalgorithmen unter Verwendung der Materialinformation als Ähnlichkeitsmaß in einem Koordinatensystem ausgerichtet [1]. Nachfolgend ist nun jedem Volumenelement einer Kopfschicht ein vierdimensionaler Pixelvektor zugeordnet.

Für die Segmentierung der Hirntumoren in den so erhaltenen, multispektralen MR-Daten werden Multilayer-Feedforward-Netze mittels dem Backpropagation Lernalgorithmus [4] trainiert und eine pixelorientierte Klassifikation vorgenommen. Hierbei entspricht die Zahl der verwendeten MR-Merkmale der Anzahl der Input-Neuronen, die Zahl der zu unterscheidenden Klassen der Anzahl der Output-Neuronen [5] (Abb. 2). Untersuchungen zur Verwendung bestimmter MR-Merkmale zeigen, daß die zur Klassifikation signifikanten Informationen in der T1-Gewichtung nach Kontrastmittelgabe sowie der T2-Gewichtung




Abb. 2. Multi-Layer-Feedforward-Netz zur pixelorientierten Klassifikation von kontrastmittelaufnehmenden Hirntumoren in multispektralen MR-Daten

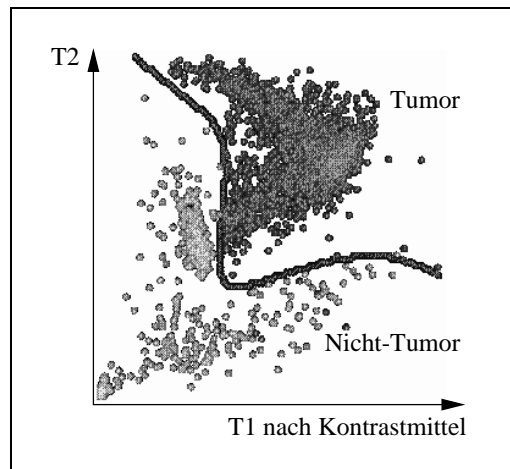


Abb. 3. Zweiklassenproblem im 2D-Merkmalraum eines kontrastmittelaufnehmenden Hirntumors und des Nicht-Tumorgewebes. Der separierende Polygonzug zeigt die Fähigkeiten eines hierauf trainierten Neuronalen Netzes.

enthalten sind (Abb. 3). Unter Hinzunahme der übrigen Merkmale wird ein Training auf einer größeren Trainingsmenge erleichtert, was letztendlich zu einer besseren Generalisierungsfähigkeit des Netzes verhilft. Die Anzahl der Hidden-Layer sowie die Anzahl der Hidden-Neuronen wird problemspezifisch optimiert. Zur Optimierung der Klassifikationsleistung wird der Einfluß der Netzwerktopologie systematisch untersucht. Die Optimierung der Netzwerktopologie sowie die Bewertung der Segmentierungsergebnisse wird auf der Grundlage manuell bzw. halbautomatisch durch den Arzt segmentierter Hirntumoren möglich.

Für die Segmentierung verschiedener, kontrastmittelaufnehmender Hirntumoren werden MLP-Netzwerke mit den beiden Klassen "Tumor" und "Nicht-Tumor" als Output-Neuronen betrachtet (Abb. 2). Das Training des Hirntumor-Netzwerks wird auf der Basis ausgewählter, vorsegmentierter Hirntumorbereiche vorgenommen. Die zu segmentierenden Bilddaten werden punktweise durch das trainierte Netz propagiert. Die zu jedem Bildpunkt ermittelten Ausgangsaktivitäten (aus $[0,1]$) des Netzes werden zu sogenannten Aktivierungskarten zusammengefaßt. Zur Segmentierung werden alle Bildpunkte mit Aktivierungswerten oberhalb eines Schwellwertes in der Aktivierungskarte selektiert und die größte 3D-Zusammenhangskomponente ermittelt. Die so selektierten Bildpunkte repräsentieren den aktiven, kontrastmittelaufnehmenden Tumoranteil. Durch anschließende Anwendung eines 3D-Filling-Algorithmus wird insbesondere bei heterogenen Tumoren wie Glioblastomen eine Auffüllung von Segmentierungslöchern erzielt. Die Aktivierungskarten eignen sich gegenüber binären Segmentierungsergebnissen zu weiteren Auswertungen, durch die beispielsweise Partialvolumeneffekte teilweise sichtbar gemacht werden können.

Zur Bewertung des neuronalen Segmentierungsverfahrens werden die automatisch ermittelten Segmentierungsergebnisse mit den manuell durch den Arzt




Abb. 4. 3D-Rekonstruktion eines Meningeoms und der Gehirnmasse

vorgenommen Segmentierungen verglichen. Eine automatische Segmentierung wird als gleichwertig zur manuellen eingestuft, wenn die Abweichungen auf wenige Pixel im Randbereich des Tumors beschränkt sind.

3 Ergebnisse und Diskussion

Zur Optimierung der Netzwerktopologie werden systematisch verschiedene Anzahlen von Hidden-Neuronen und Hidden-Layern betrachtet. Beste Segmentierungsergebnisse erzielt ein MLP mit 3 Hidden-Layern und der Struktur 4-8-8-6-2. Mit dem neuronalen Segmentierungsverfahren werden 22 multispektrale 3D-Datensätze mit unterschiedlichen, kontrastmittelaufnehmenden Hirntumorarten vom Typ Meningeom, Metastase und Glioblastom analysiert. In 19 Fällen kann durch die automatische Segmentierung ein zur manuellen Segmentierung adäquates Ergebnis erzielt werden. In 3 Fällen kommt es aufgrund der geringen Kontrastmittelaufnahme im Tumor zu Segmentierungsfehlern, die eine interaktive Nachbearbeitung der Segmentierungsergebnisse notwendig macht.

Darüber hinaus werden auch Netze zur Segmentierung der Hirnmasse auf der Basis der Pixelvektoren in benutzerdefinierten ROI trainiert. Die Gehirnmasse kann in allen getesteten Datensätzen segmentiert werden. Die im 3D-Datensatz segmentierten Bildobjekte (Tumor, Hirnmasse) können in dem entwickelten Analysesystem direkt dreidimensional dargestellt werden (Abb. 4).

Die in den Aktivierungskarten gespeicherten Aktivierungswerte können als Schätzer der Klassenzugehörigkeitswahrscheinlichkeiten interpretiert werden [2]. In den Geweberandbereichen kommt es vermehrt zu Partialvolumeneffekten. Durch pixelweise Multiplikation der Aktivierungskarten (Tumor und Nicht-Tumor) werden denjenigen Bildpunkten hohe Werte zugeordnet, die mit hoher Wahrscheinlichkeit zu beiden Klassen gehören und somit den Partialvolumen-pixeln zugeordnet werden können. Mit dieser Technik können somit Teile des




Abb. 5. Partialvolumenkandidaten ermittelt durch Multiplikation der Aktivierungskarten der Klassen "Tumor" und "Nicht-Tumor"

Tumorübergangsbereiches zur gesunden Hirnmasse sichtbar gemacht werden (Abb. 5).

Die interaktive 3D-Segmentierung von Tumoren ist für den Arzt sehr zeitintensiv. Durch das entwickelte neuronale Segmentierungsverfahren wird in 86% der untersuchten Fälle eine automatische Segmentierung der Hirntumoren erreicht, die keine Nachverarbeitung mehr erfordert. Durch die automatische Segmentierung der Hirnsubstanz ist es darüber hinaus möglich, die räumliche Lage und Ausbreitung des Tumors im Gehirn sichtbar zu machen, die insbesondere bei der neurochirurgischen Operationsplanung von Bedeutung ist. Das Verfahren zur neuronalen 3D-Segmentierung von Hirntumoren in multispektralen MR- Bilddaten wurde unter Verwendung des neuronalen Netzwerk-Tools SNNS [6] entwickelt und in das an unserem Institut entwickelte System zur Analyse von Hirntumoren integriert [3].

Literatur

1. Collins D.L., Neelin P., Peters T.M., Evans A.C.: Automatic 3D Inter-Subject Registration of MR Volumetric Data in Standardized Talairach Space. *Journal of Computer Assisted Tomography*, 18(2):192-205, 1994
2. Handels H.: *Medizinische Bildverarbeitung*. Teubner Verlag, Stuttgart, 2000.
3. Roßmanith C., Handels H., Rinast E., Weiss H.-D., Pöpl S.J.: Characterisation and Classification of Brain Tumours in Three-Dimensional MR Image Sequences. *Visualisation in Biomedical Computing*, vol. 1131, Lecture Notes in Computer Science, Höhne K.-H. and Kikinis R., Eds. Berlin: Springer Verlag, pp. 429-438, 1996
4. Rumelhart D.E., Hinton G.E., Williams R.J.: Learning Internal Representations by Error Propagation. *Parallel Distributed Processing. Exploration in the Microstructures of Cognition*, Rumelhart D.E. and McClelland J.L., Eds. Cambridge, MA: MIT Press, 1986
5. Schürmann J.: *Pattern Classification*, New York: John Wiley & Sons, 1996
6. Zell A.: *Simulation Neuronaler Netze*, Addison-Wesley, 1994

