



70. WVAO Jahreskongress 2019


Bildanalyse mit tiefen neuronalen Netzen

Prof. Dr. Martin Regehly, Dipl.-Phys. Baraa Asfari



Bildanalyse von Fundusaufnahmen



Wunsch: Nicht-invasive, **mobile** Diagnostik mit automatisierter Befundung
→ Augenerkrankungen → **Herz-Kreislauf-Erkrankungen**



Teilschritte der Bildanalyse:
→ Erkennung von Markern
→ **Segmentierung der Gefäße & Analyse**



Systeme zur retinalen Gefäßanalyse



Imedos GmbH (Jena)

Oxymap (Reykjavik, Island)

Stationäre Gefäßanalyse

- Zentraläquivalente, CRAE, CRVE
- arterio-venöses (AV) Verhältnis

Dynamische Gefäßanalyse

- Mikrozirkulation
- Gefäßdilatation/Steifigkeit
- Sauerstoffsättigung



Zielstellung / Inhalt

Mobil einsetzbarer Algorithmus zur vollautomatisierten Gefäßanalyse
für das Screening von Herz-Kreislauf-erkrankungen

Bildverarbeitung mit künstlicher Intelligenz

Vollautomatische Segmentierung der Papille (KI)



Vollautomatisierte Segmentierung des Gefäßnetzes (KI)

Klassifizierung von Arterien und Venen (klassisch)

Ableitung der Gefäßparameter (klassisch)



Wahrnehmung von Objekten im Gehirn





Untersuchung des visuellen Cortex



Neuron am Eingang:

Reaktion auf Winkel





Neuron in tieferer Schicht:

Reaktion auf Winkel
+ spezifische Region/Muster





Bildverarbeitung in tiefen neuronalen Netzen




Audi A7

- Mehrere, verbundene Schichten von Neuronen
- Convolutional Neural Networks (CNN) für die Bildanalyse

Training von neuronalen Netzen






Klassifikation



Objekterkennung



Segmentierung



Implementierung und Training

Python

Anwenderprogramm

Keras (2015, Google & Co.)
Neuronale Netzwerke

Tensorflow (2017, Google)
Numerische Berechnungen

CUDA (2007, Nvidia)
GPU Unterstützung




Training:
~10h auf Nvidia GTX 1080ti
(11.2 TFlops FP32)



U-NET für die Bildsegmentierung

Eingang

Fundus
Aufnahme





Ausgang

Segmentierte
Aufnahme

O. Ronneberger, P. Fischer, T., U-Net: Convolutional Networks for Biomedical Image Segmentation. 2015.



Segmentierung der Papille / Training




annotierter Training Datensatz
ORIGA
Singapore Eye Research
Institute

680 Fundusbilder
- 168 Glaukom Aufnahmen
- 482 ohne Befund

Cup & Disk manuell präpariert

Aufteilung in Trainings- und
Testaufnahmen


ca. 10h Trainingszeit





Segmentierung der Papille / Resultate


Testbild



1. ROI




2. PT




3. Disk / Cup



4. Disk



5. Cup



6. Overlay




7. C/D Ratio

0,40



Segmentierung der Papille / Resultate


Testbild



1. ROI




2. PT




3. Disk / Cup




4. Disk



5. Cup



6. Overlay




7. C/D Ratio

0,64



Segmentierung der Papille / akt. Limits

Testbild



1. ROI




2. PT




3. Disk / Cup



4. Disk



5. Cup



6. Overlay




7. C/D Ratio

Failed.




Segmentierung der Papille / Evaluation

ROC Curve „Receiver Operating Characteristics“



(a) ORIGA dataset



(b) SCES dataset

H. Fu, J. Cheng, Y. Xu, D. Wong, J. Liu, Joint Optic Disc and Cup Segmentation Based on Multi-label deep network and polar transformation, 2018




Segmentierung der Papille / Outlook

Disc Damage Likelihood Scale (DDLS) aussagekräftiger als C/D für Glaukom-Diagnostik

Disc Damage Likelihood Scale (DDLS)

		The thinnest width of the rim (Rim Disc Ratio)		
	Stage	Small disc <1.50 mm	Average size disc 1.50–2.00 mm	Large disc >2.00 mm
Normal	0a	0.5	0.4 or more	0.3 or more
	0b	0.4 up to 0.5	0.3–0.4	0.2–0.3
At Risk	1	0.3 up to 0.4	0.2–0.3	0.1–0.2
	2	0.2 up to 0.3	0.1–0.2	0.05–0.1
Glaucoma damage	3	0.1 up to 0.2	0.01–0.1	0.01–0.05
	4	0.01–0.1	No rim <45 degrees	No rim <45 degrees
	5	No rim <45 degrees	No rim 45–90 degrees	No rim 45–90 degrees
Glaucoma disability	6	No rim 45–90 degrees	No rim 91–180 degrees	No rim 91–180 degrees
	7	No rim >90 degrees	No rim >180 degrees	No rim >180 degrees



$$\text{Rim disc ratio} = \frac{R}{D}$$

Quelle: www.optic-disk.org



Segmentierung der Papille / Outlook

Bestimmung: Disc Damage Likelihood Scale (DDLS)



Disk / Cup Polar Transform





Image name	CDR	disc diameter (px)	the minimum rim width (px)
4	0,3958	288	69
7	0,4246	325	58
40	0,4863	329	66
41	0,4261	291	68
52	0,4187	289	62
73	0,4839	279	58
95	0,4916	238	40
115	0,5207	290	45
140	0,5251	299	46
142	0,6412	340	44
145	0,4914	291	52



Segmentierung des Gefäßsystems





TRAINING

20 Fundusbilder für Training
(768 x 584 Pixel)

Gefäßnetz von Hand
präpariert

weitere
20 Aufnahmen für Evaluation



Quelle:
DRIVE Datenbank, University Medical Center Utrecht


J.J. Staal, M.D. Abramoff, M. Niemeijer, M.A. Viergever, B. van Ginneken, "Ridge based vessel segmentation in color images of the retina", IEEE Transactions on Medical Imaging, 2004, vol. 23, pp. 501-509.



Datenaufbereitung und Netzadaption

Problem: geringe Anzahl an Trainingsbildern

Ansatz: Nutzung der Selbstähnlichkeit



Vergrößerung des Datensatzes:

Zerlegung in Kacheln mit 48 x 48 Pixeln

Gewinnung von 9500 Kacheln pro Bild

-> 171000 Trainingsbilder (90%)

-> 19000 Testbilder (10%)



Reduktion des U-NETs:

operiert nur auf einer Kachel 48x48 Pixel

Reduktion auf 12 Layer



Ergebnisse der Segmentierung



Sensitivität: 77 %, Spezifität: 98 %



Beispiele

Testbild



Hand präpariert




Neurales Netz






Computer Vision klassisch vs neuronal

Traditionell:



Deep Learning:



- Neuronale Netze haben das maschinelle Bildauswertung revolutioniert.
- Große Datenmengen & leistungsfähige Computer notwendig.
- Komplexe Probleme erfordern traditionelle & neuronale Bildverarbeitung.