

Künstliche Intelligenz in der medizinischen Bilddiagnostik

Andreas Boss


Institut für Diagnostische und Interventionelle Radiologie
UniversitätsSpital Zürich

Artificial Intelligence in Medicine: Hope or Hype?

The application of artificial intelligence in the promise for improving patient health, but will be comfortable using it?




By **Brian Scogland**
January 2, 2018 in *Software*



AI beats docs in cancer s...

A new study provide learning as an impor Biegler reports.



A doctor searches for signs of breast c... the job faster, and more accurately.
CREDIT: GETTY IMAGES

Machine Learning Plays Central Role at RSNA 2017

BY MIKE BASSETT

November 1, 2017



Machine Learning (ML) and the role it will play in the future of radiology will be central to a broad scope of programming at RSNA 2017.

Along with numerous educational and scientific sessions exploring the revolutionary technology from every angle, RSNA is featuring a Machine Learning Community in the Learning Center and a Machine Learning Showcase in the Technical Exhibits hall.

Despite the technology's growing presence in healthcare, there are still obstacles to overcome before ML is fully embraced by radiology, said Curtis Langlotz, MD, the RSNA Board of Directors liaison for information technology and annual meeting.

"No question — machine learning will change the way radiologists practice in the years ahead, sometimes dramatically," said Dr. Langlotz, a professor of radiology and biomedical informatics and associate chair for Information Systems in the Department of Radiology at Stanford University. "But there is much work to be done before ML becomes commonplace."

Along with facing regulatory issues, ML requires large, labeled image data sets for big data processing. But while most radiology practices have millions of imaging studies, most are not labeled, he said.

RSNA News



Langlotz




Kinahan



- Bisherige radiologische Ansätze
- Einsatz von Textur-Analyse
- "Konventionelles" Machine Learning
- Kulturwende: Deep Learning



Abraham-Louis Breguet
1747-1823
Erfinder des Tourbillon-Uhrwerks



Morphologie des Gesamten



Einzelkomponenten,
z.B. Unruh und Spiralfeder

- Materialeigenschaften
- Trägheitsmoment I
- Federlänge l
- Federstärke s
- Federbreite h
- Elastizitätsmodul E

$$T = 2\pi \sqrt{\frac{12 \cdot I \cdot l}{E \cdot h \cdot s}}$$

Funktion

Morphologie



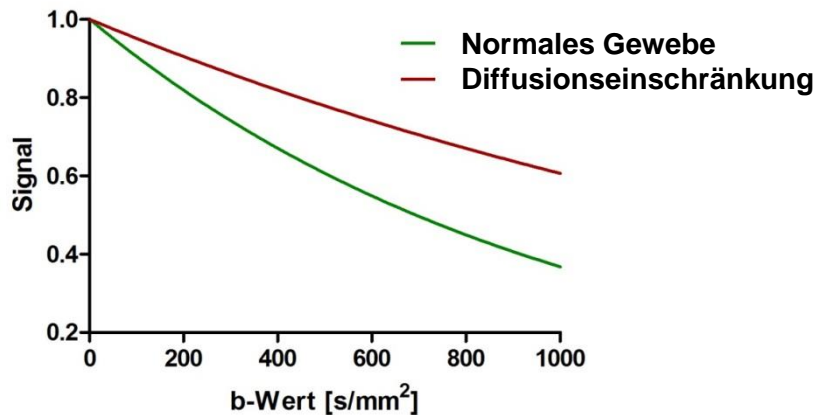
Gewebeeigenschaften



Pathophysiologie


Bei der Diffusionsbildgebung wird das diffundierende Wasser einem Diffusionsgradienten ausgesetzt, welcher mit dem b-Wert beschrieben wird. Das Signal zerfällt gewebespezifisch mit einer Exponential-Funktion.

Signalabfall durch Diffusionsgewichtung




$$\frac{S_b}{S_0} = \exp(-b \text{ ADC})$$

ADC: apparent
diffusion coefficient
B: b-value



Hirninarkt



Prostatakarzinom

- Man definiert eine charakteristische Diffusionskonstante, den Apparent Diffusion Coefficient (ADC in mm²/s).
- Gehirninfarkte und Tumoren weisen eine Diffusionsrestriktion auf, sie sind hell in der DWI.

«gewöhnliche»
Diffusion

$$\frac{S_b}{S_0} = \exp(-b ADC)$$

ADC: apparent diffusion coefficient






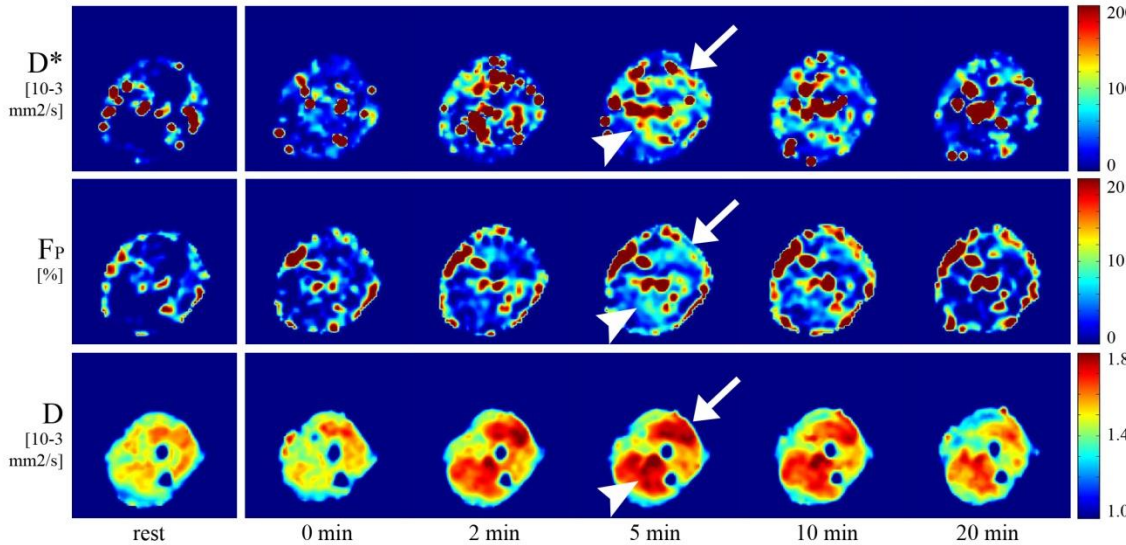
IVIM

(Berücksichtigung von
Perfusionseffekten)

$$\frac{S_b}{S_0} = (1 - f_p) * \exp(-bD_t) + f_p * \exp(-bD_p)$$

D_t : Diffusionskoeffizient
 f_p : Perfusionsfraktion
 D_p : Pseudodiffusion











Muskelperfusion nach Belastung



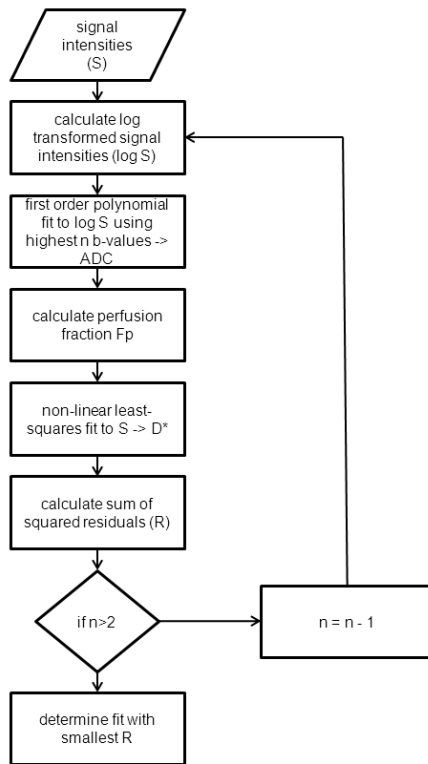
● active muscle
○ inactive muscle

Intravoxel Incoherent Motion (IVIM)

Perfusionsparameter D_p korreliert mit der microvessel density (MVD).

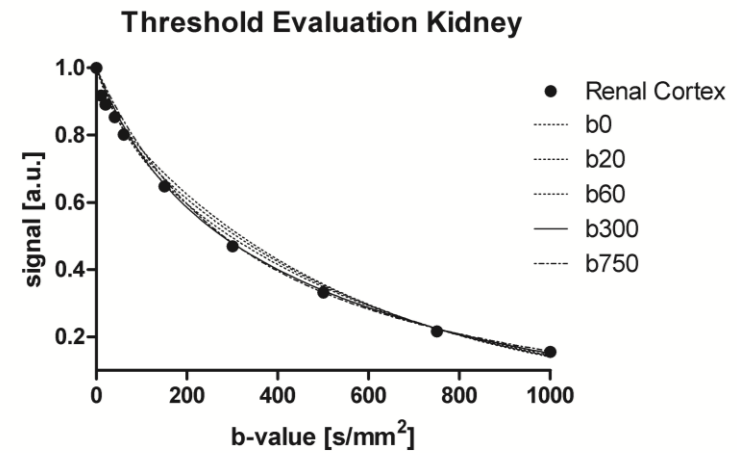
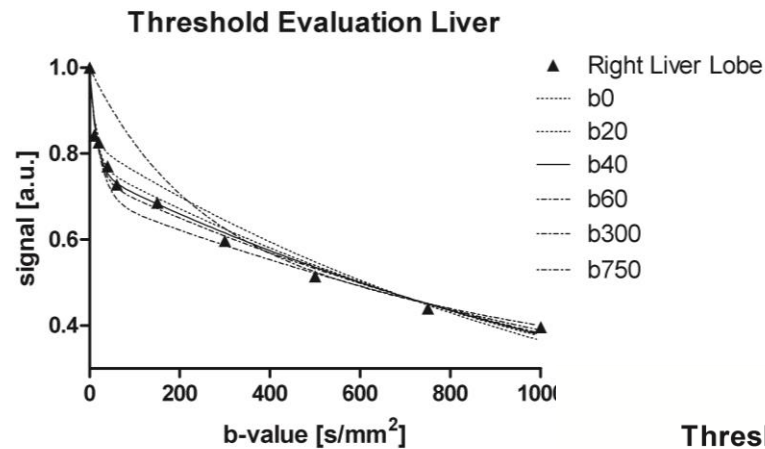


CD31 Färbung




```

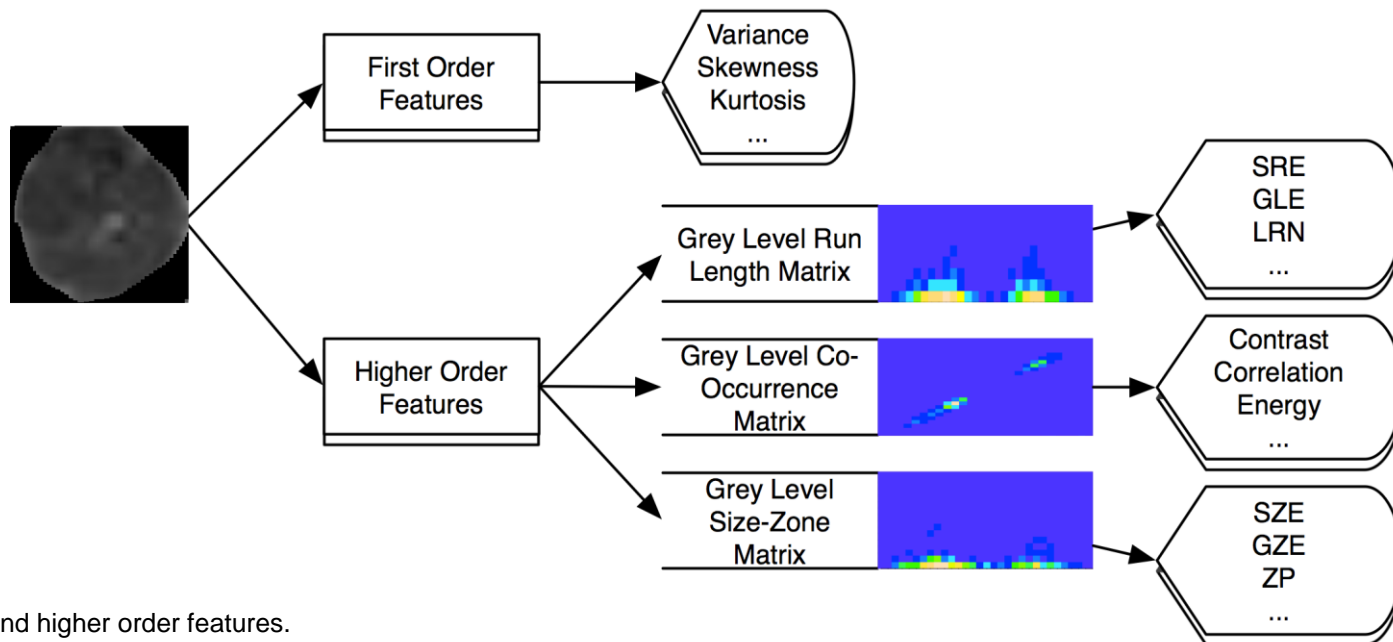
1  n=number of used b-values
2
3  while n>1 do
4      calculate D with first order polynomial fit using the n highest b-values;
5      calculate Fp;
6      calculate D* with non-linear least-squares fit using all b-values with fixed D and Fp;
7      calculate sum of squared residuals from non-linear least-squares fit (R);
8      n = n - 1;
9  end
10 determine fit with smallest R;
  
```




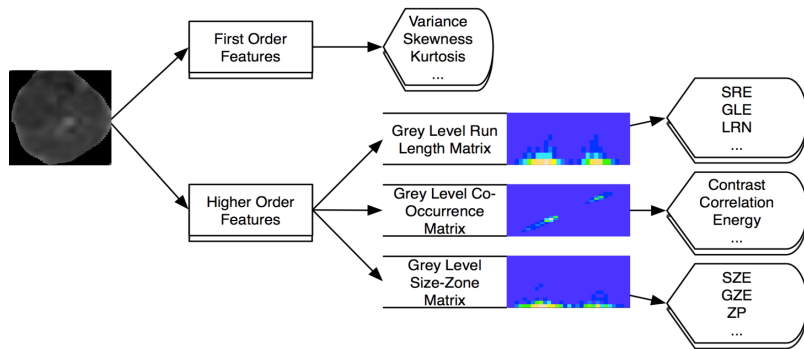
- Der menschliche Verstand entwickelt ein «logisches» Modell, das die Messergebnisse beschreibt
- Die Parameter des Modells haben eine physikalische oder physiologische Bedeutung
- Das Modell erlaubt uns ein tieferes Verständnis der physikalischen und physiologischen Zusammenhänge



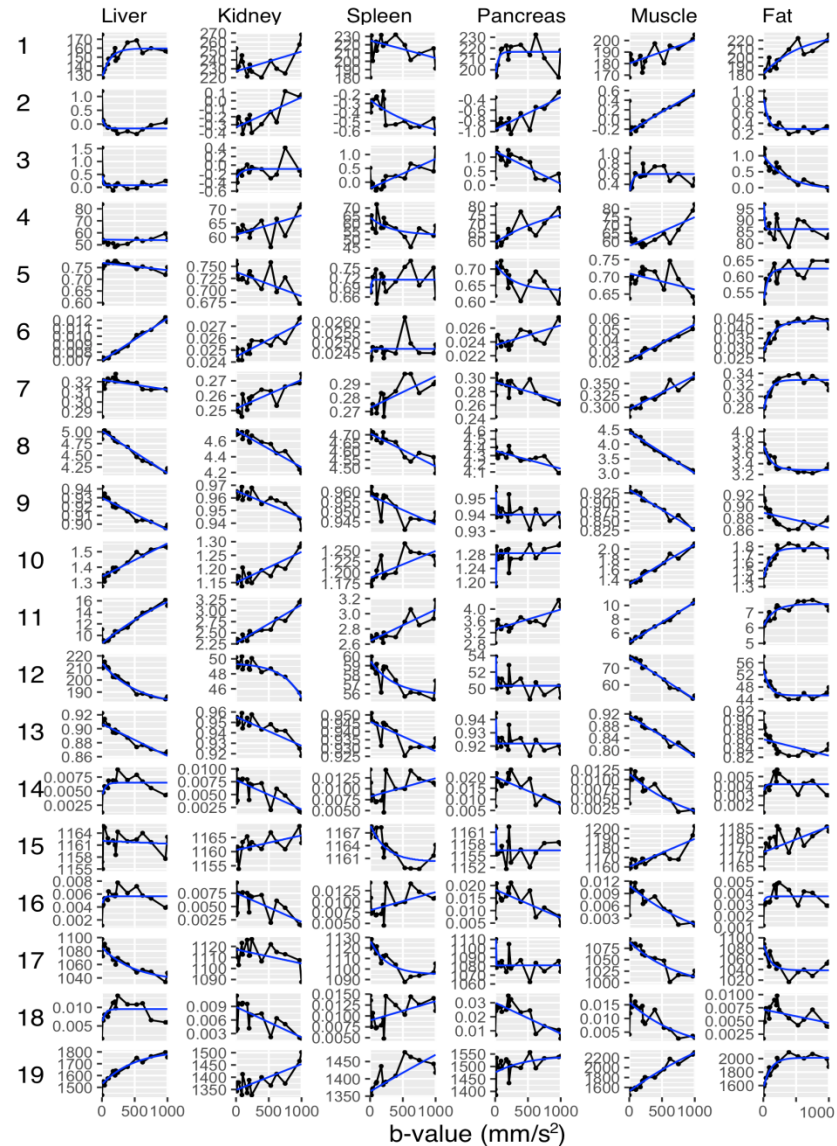
Beispiel: Grey Level Co-Occurrence Texture (GLCM).



First and higher order features.


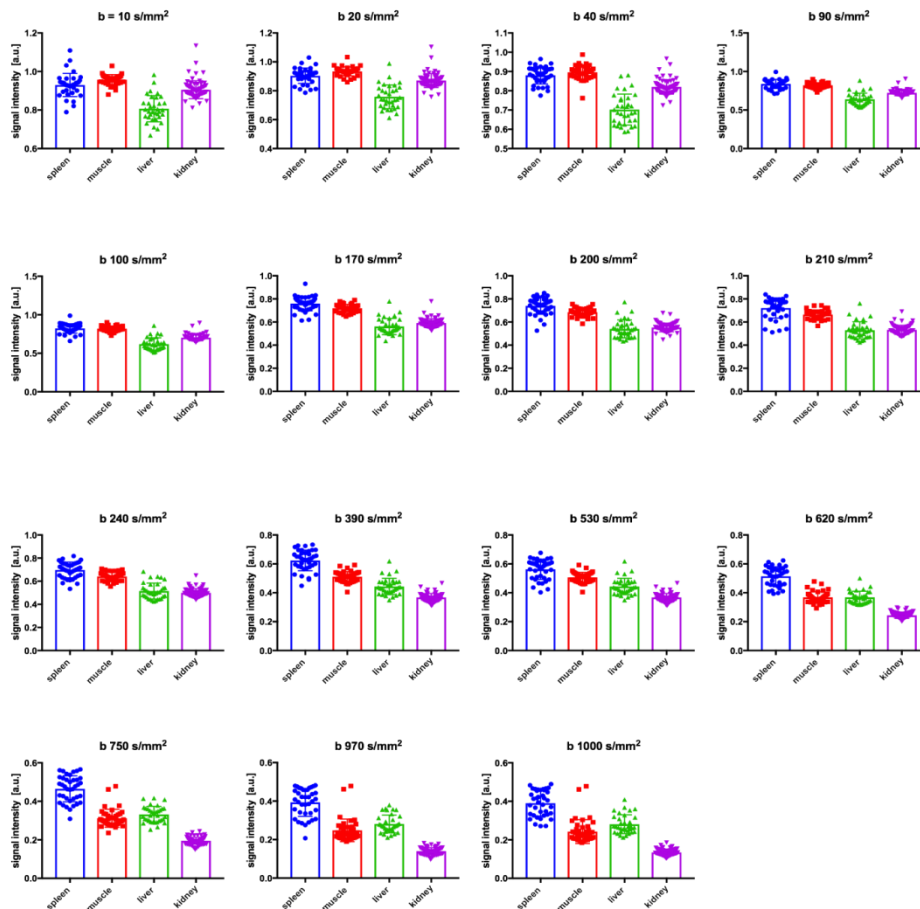


Entropie-Karten von zwei Patientinnen mit Zervixkarzinom, oben gut differenziertes Plattenepithelkarzinom, unten schlecht differenziertes Adenokarzinom.
Becker AS. Acta Radiol Open, 2017.



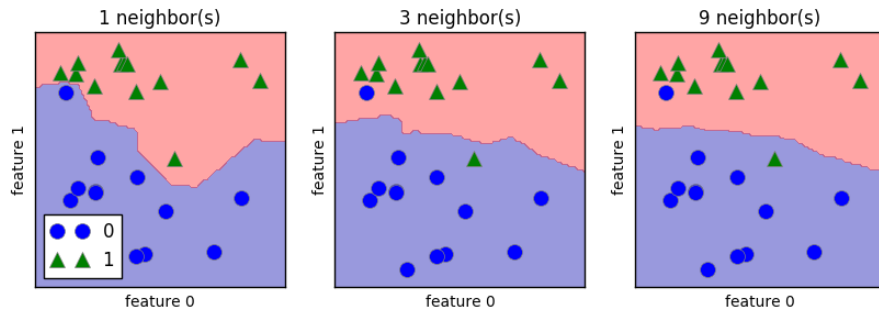
Änderung der Texturen durch Variation des b-Werts -> Generierung neuer Biomarker
Becker AS. NMR in Biomed, 2017.

- Quantifiziert spezifische «Muster» des Gewebes
- Ist in der Lage, Muster zu erkennen, die das menschliche Auge/Verstand nicht erkennen kann
- Textur-Analyse ist deskriptiv, nicht «intelligent»
- Texture features können jedoch als Input für Machine-Learning-Algorithmen dienen

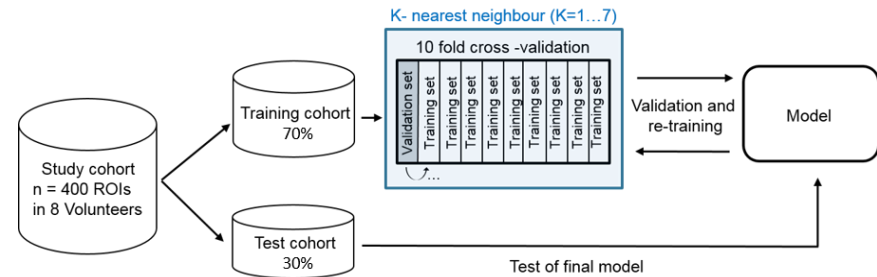


- 8 gesunde Freiwillige
- Diffusionsgewichtete Bildgebung mit 16 b-Werten

K-nearest neighbor algorithm




Training/validation



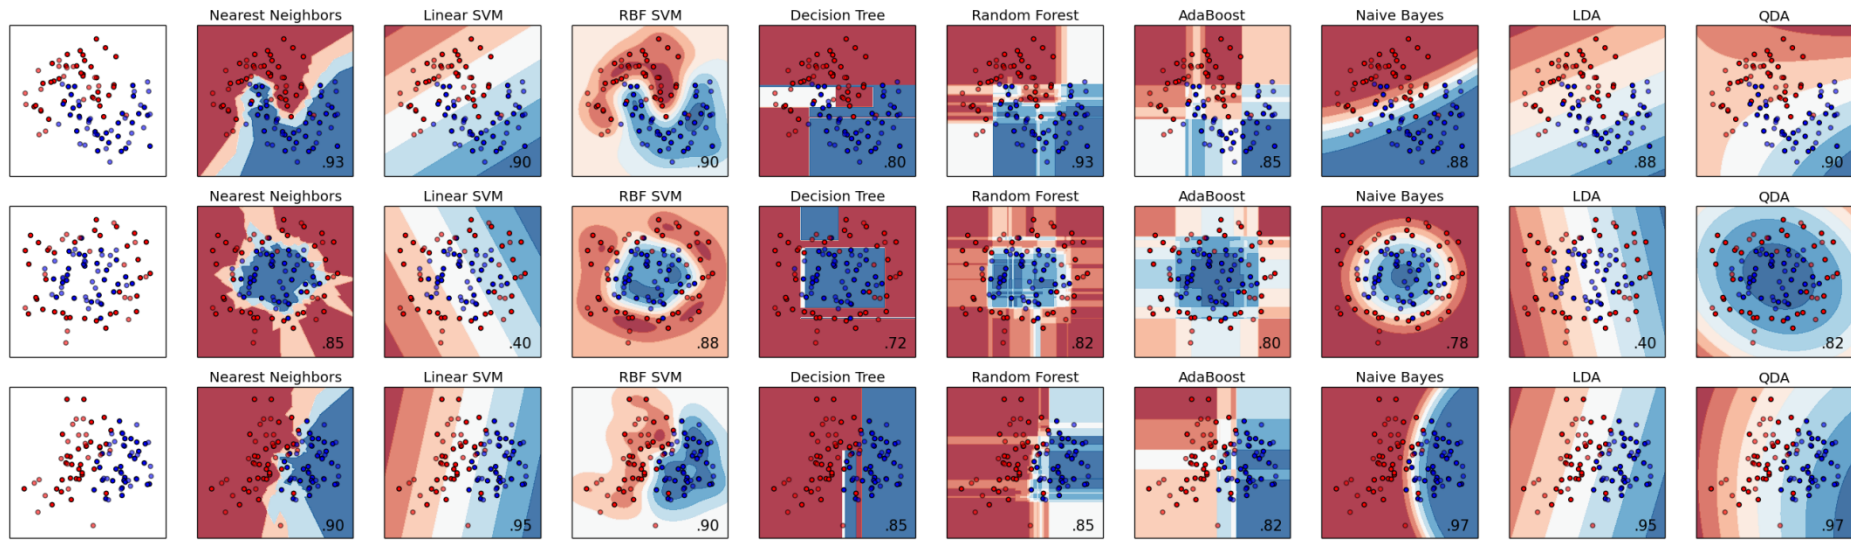
Accuracy, confusion matrix

K=11 Training dataset	true spleen	true kidney	true muscle	true liver	class precision
predicted spleen	33 (33)	0 (0)	0 (1)	3 (5)	91.89 % (84.62 %)
predicted kidney	0 (0)	69 (70)	2 (2)	0 (0)	98.61 % (97.22 %)
predicted muscle	0 (0)	1 (0)	40 (39)	0 (0)	95.12 % (100.00 %)
predicted liver	4 (4)	0 (0)	0 (0)	33 (31)	87.57 % (88.57 %)
class recall	89.19 % (89.19 %)	98.57 % (100 %)	95.24 % (92.86 %)	91.67 % (86.11 %)	Average accuracy: 94.53 % (93.71 %)
K=11 "real world " dataset	true spleen	true kidney	true muscle	true liver	class precision
predicted spleen	14 (15)	0 (0)	0 (0)	1 (1)	93.33 % (93.75 %)
predicted kidney	0 (0)	27 (27)	0 (0)	0 (0)	100 % (100 %)
predicted muscle	0 (0)	3 (3)	18 (18)	0 (0)	91.67 % (84.62 %)
predicted liver	2 (1)	0 (0)	0 (0)	14 (14)	91.67 % (93.33 %)
class recall	87.50 % (93.75 %)	90.00 % (90.00 %)	100 % (100.00 %)	93.33 % (93.33 %)	Average accuracy: 92.00 % (93.67 %)

Principle Component Analysis




Neu: der Computer-Algorithmus braucht kein Modell, er sucht sich selbst den Zusammenhang!



Classifier: Overview scikit learn

- Für jeden ML-Algorithmus sind “gelabelte” Daten notwendig: hier Farbe
- Die Daten besitzen features: hier 2 Dimensionen
- Der Algorithmus versucht, anhand der features das Label zu bestimmen



- Der Algorithmus lernt an einem Trainingsdatensatz
- Gewünscht ist eine hohe Vorhersagekraft an einem unbekanntem (Test-)Datensatz
- Lernt der Algorithmus den Trainingsdatensatz zu genau, so ist seine Vorhersagekraft gering

- Die Machine Learning Algorithmen **bestimmen selbst**, welche features für die Entscheidung gebraucht werden.
- Eine Modellvorstellung ist nicht mehr notwendig
- Die Entscheidungen sind im Prinzip nachvollziehbar
- Der Daten- und Rechenaufwand ist noch überschaubar

SPIEGEL ONLINE

DER SPIEGEL SPIEGEL TV



Anmelden

NETZWELT

Schlagzeilen | Wetter | DAX 11.572,03 | TV-Programm | Abo

Nachrichten > Netzwelt > Web > Künstliche Intelligenz > Künstliche Intelligenz: Wenn Maschinen lernen lernen

Künstliche Intelligenz

Wenn Maschinen lernen lernen

Das neue Lieblingsthema der Hightech-Branche: künstliche Intelligenz. Auf der Digitalkonferenz DLD wird nun darüber verhandelt, was es eigentlich für den Nutzer bedeutet, wenn Maschinen immer schlauer werden.



Von Angela Gruber, München



Neue Zürcher Zeitung

Abonnieren

ANMELDEN

MENÜ

Startseite

Meinung

International

Wirtschaft

Finanzen

Schweiz

Feuilleton

Zürich

Sport

Wissenschaft

Panorama

Startseite > Wirtschaft

Künstliche Intelligenz

Wir sind immer noch besser als Maschinen

von Robin Schwarzenbach / 17.1.2017, 05:30 Uhr

Im Zuge der «digitalen Revolution» könnte jede zweite Stelle verloren gehen, heisst es in Studien. Das düstere Szenario unterschätzt die Wandelbarkeit des Menschen und verkennt seine grösste Stärke.



KOMMENTARE



Roboter übernehmen immer mehr Aufgaben in unserem Alltag – eine Bedrohung für die berufstätige Bevölkerung in der Schweiz? (Bild: Keystone)

MEISTGELESEN IN DIESEM RESSORT

US-Vizepräsident bei Abschiedsrede in Davos




Biden attackiert Putin scharf

Michael Rasch, Davos / vor 2 Stunden

FDP-Bundesrat Didier Burkhalter
«Ich war viel zu optimistisch, was die Personenfreizügigkeit betrifft»

INTERVIEW Heidi Gmür / 18.1.2017

Ray Dalio, Lawrence Summers und Christine Lagarde am WEF
«Populisten haben eine Vision – die Europäer nicht»




$$a_1^{(2)} = g(\Theta_{10}^{(1)} x_0 + \Theta_{11}^{(1)} x_1 + \Theta_{12}^{(1)} x_2 + \Theta_{13}^{(1)} x_3)$$

$$a_2^{(2)} = g(\Theta_{20}^{(1)} x_0 + \Theta_{21}^{(1)} x_1 + \Theta_{22}^{(1)} x_2 + \Theta_{23}^{(1)} x_3)$$


$$a_3^{(2)} = g(\Theta_{30}^{(1)} x_0 + \Theta_{31}^{(1)} x_1 + \Theta_{32}^{(1)} x_2 + \Theta_{33}^{(1)} x_3)$$

$$h_{\Theta}(x) = a_1^{(3)} = g(\Theta_{10}^{(2)} a_0^{(2)} + \Theta_{11}^{(2)} a_1^{(2)} + \Theta_{12}^{(2)} a_2^{(2)} + \Theta_{13}^{(2)} a_3^{(2)})$$

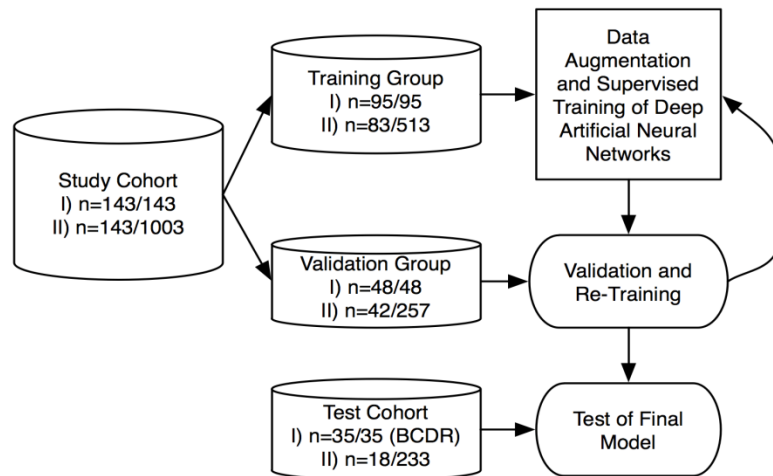
- Deep Learning meint einen speziellen Machine-Learning Algorithmus: tiefe neuronale Netzwerke
- Sie sind besonders geeignet für die Bildanalyse
- Im Prinzip ein System von linearen Gleichungen, dessen Koeffizienten optimiert werden.



- Rechenpower (e.g. NVIDIA GPUs)
- Deep Learning Bibliotheken(e.g. Google´s TensorFlow)
- Eine Menge «gelabelter» Daten

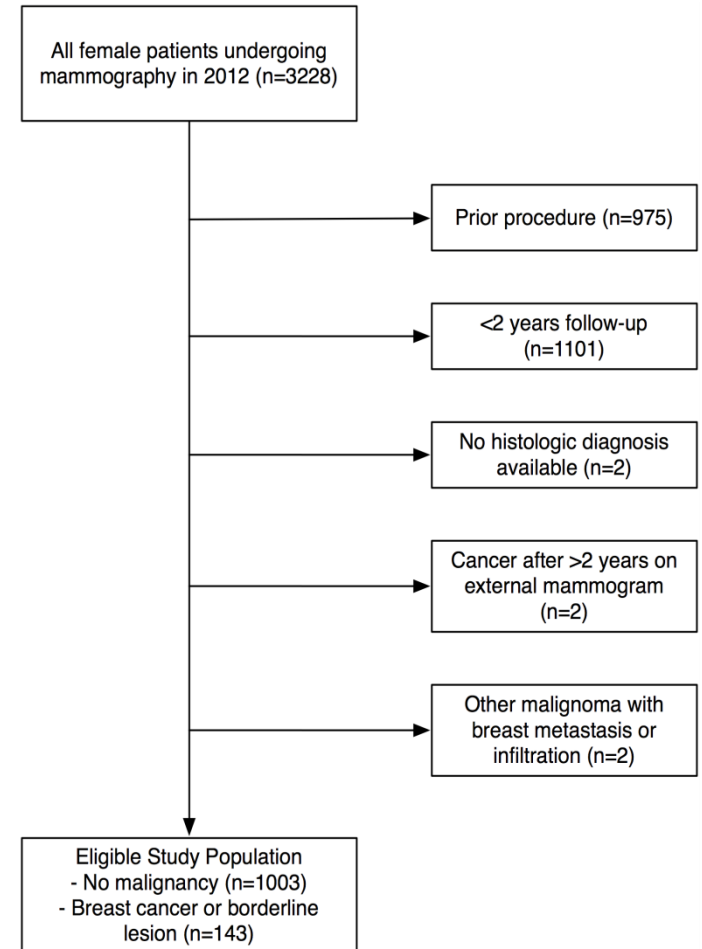



Kommerzielle Industrie-Software
Cognex Vidi-Suite (Natick, USA)




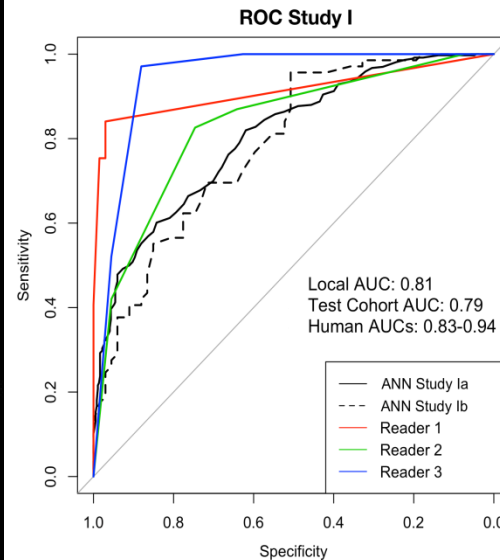
Training-/Test-Kohorte

Retrospektives Studiendesign



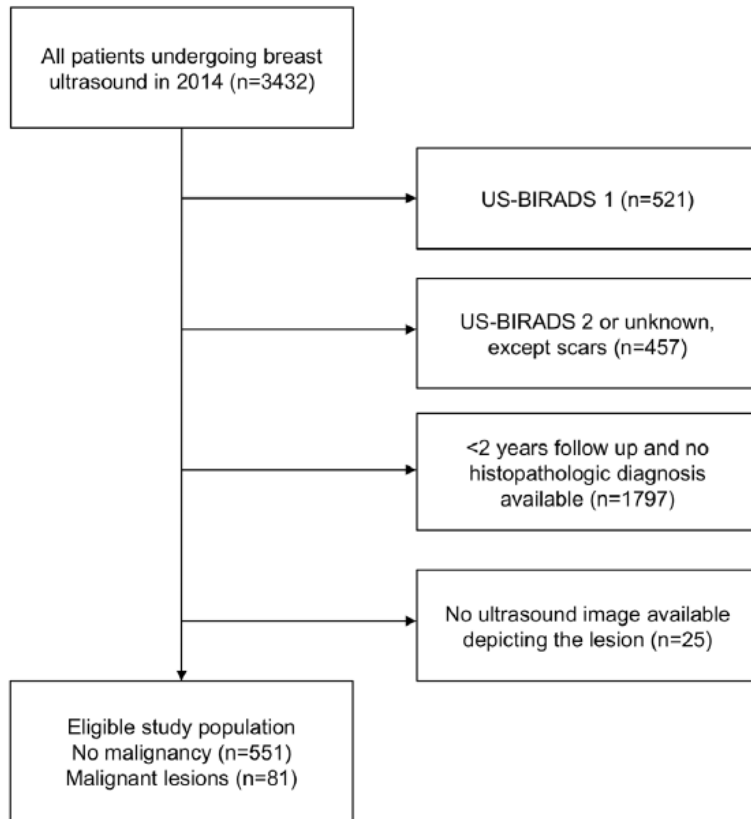


46-jährige Patientin mit inv-dukt.
Brustkrebs





Becker AS. Investigative Radiology, 2017.

- Neuronales Netzwerk weist eine Genauigkeit auf, die vergleichbar ist mit derjenigen von Radiologen
- Radiologen haben jedoch eine niedrigere Sensitivität, dafür höhere Spezifität



Histology	<i>n</i> (Training)	<i>n</i> (Validation)
Invasive ductal carcinoma	39	13
Invasive lobular carcinoma	8	2
Mucinous carcinoma	1	0
Tubular carcinoma	1	0
Ductal carcinoma <i>in situ</i>	6	1
Spindle cell sarcoma	2	0
Angiosarcoma	1	0
Lymphoma	0	1
Breast metastasis of a melanoma	0	1
Phyllodes tumour	1	1
Lobular intraepithelial neoplasia	1	0
Flat epithelial atypia	1	0
Papillary lesion	1	1
Total	62	20

- Retrospective study design
- 82 malignant lesions, 551 benign lesions
- Histology or follow-up as reference



	AUC (95% CI)	Specificity (%)	Sensitivity (%)	PPV (%)	NPV (%)
Neural network (training)	0.96 (0.92–0.99)	96.9	87.5	82.4	97.9
Neural network (validation)	0.84 (0.75–0.93)	80.3	84.2	32.0	97.9
Reader 1	0.89 (0.79–0.98)	89.0	84.2	45.7	98.1
Reader 2	0.89 (0.79–0.98)	82.7	84.2	34.8	97.9
Reader 3	0.79 (0.69–0.89)	72.8 ^a	73.7 ^a	23.0	96.2


AUC, area under the receiver operating characteristic curve; PPV, positive predictive value; NPV, negative predictive value.

^a $p < 0.05$ compared to both other readers and the NN.

Vidi ist Black-Box -> Start from Scratch notwendig!!!

"Das mammographische Brustkrebs-Screening ist ineffizient !? "

- Fehlende Empfindlichkeit bei Patienten mit dichten Brüsten (ACR a: 87%, ACR d: 63%)¹.
- Ultraschall hilft zusätzliche Brustkrebsläsionen in dichter Brust zu finden².
- S3 Leitlinie: zusätzlicher Ultraschall für Brustdichte ACR c und d empfohlen!!!
- Bei mammographisch sehr dichter Brust ist das Krebsrisiko 2 bis 6 mal höher als bei dünner Brust.
 - ❖ Beurteilung der mammographischen Brustdichte durch den Radiologen hochgradig subjektiv (acc. ~ 60-70%)



Mammographic Breast density ACR a-d.

American College of Radiology BIRADS catalogue, 5th edition

TABLE 2
Sensitivity of Each Modality for Cancer Detection in Women with Different Breast Densities

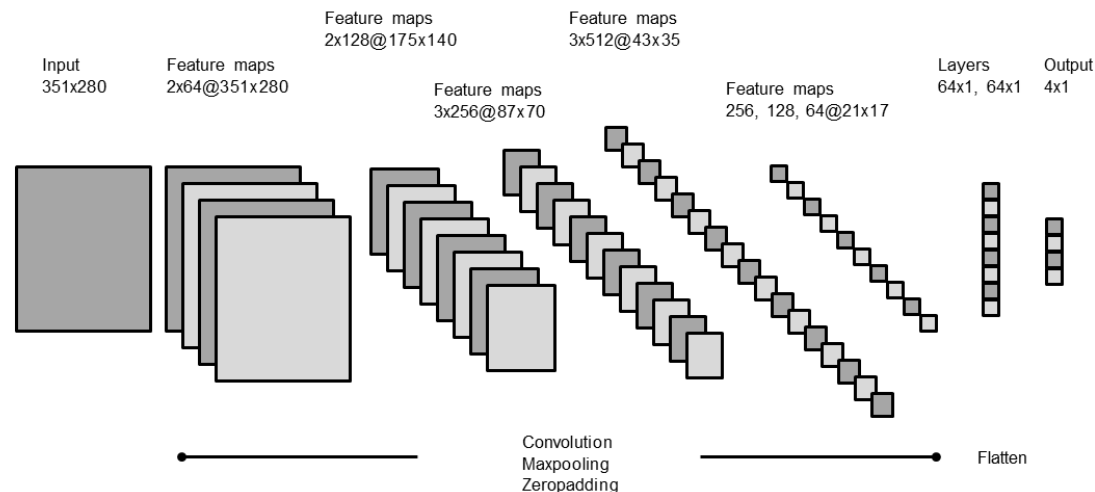
Modality	BI-RADS Category				
	1	2	3	4	2-4
Mammography	98.0 (98/100)	82.9 (34/41)	64.4 (38/59)	47.8 (22/46)	64.4 (94/146)
US	NP	65.9 (27/41)	81.4 (48/59)	76.1 (35/46)	75.3 (110/146)
PE	22.0 (22/100)	31.7 (13/41)	28.8 (17/59)	34.8 (16/46)	31.5 (46/146)

Note.—Data are percentages. Data in parentheses are numbers used to calculate percentages. NP = not performed.

¹ Kolb TM, Lichy J, Newhouse JH. Comparison of the performance of screening mammography, physical examination, and breast US and evaluation of factors that influence them: an analysis of 27,825 patient evaluations. *Radiology*. 2002 Oct;225(1):165-75.

² Berg WA, Blume JD, Cormack JB, et al. Combined screening with ultrasound and mammography vs mammography alone in women at elevated risk of breast cancer. *JAMA*. 2008;299(18):2151-63.

Künstliche Intelligenz mit deep convolutional neural networks



- Unsere Technologie analysiert Mammographien mit Machine Learning (hoch standardisiert, keine Leistungskurve am Tag).
- Basierend auf TensorFlow (Google)
- Ausgebildet mit der Expertise eines Radiologen-Teams.
- 20.578 Trainings- /Validierungsfälle, 5221 Patientinnen
- Die Technik ist auch bei Bildern mit niedriger Qualität robust.

Testen Sie den Prototyp! Es funktioniert!

Home

www.b-rayz.ch

Meistbesucht Erste Schritte javascript:function0%... Login Website

b-rayZ
predictive analytics

SERVICES ABOUT PRESS CONTACT

Deep Learning Analytics for Medical Images

AUTOMATIC BREAST DENSITY COMPUTATION

TRY IT NOW

WHAT WE DO

- FOR YOU**
Automated evaluation of your personal medical images
- FOR INSTITUTIONS**
Deep learning analysis of big medical data sets
- FOR RESEARCH**
Development of predictive analytical solutions for medical data

ABOUT US


b-rayZ is a spin-off of the University Hospital Zurich. Our team consists of professional radiologists, data scientists and physicians, with more than 15 years of work experience in medical imaging and radiology. We develop and provide predictive deep learning analytical tools and algorithms for the assessment of your personal medical images.

Prof. Dr. med. Dr. sc. hum. Dipl. phys. Andreas Boss

Dr. rer. medic. Alexander Ciritsis

PD Dr. Cristina Rossi

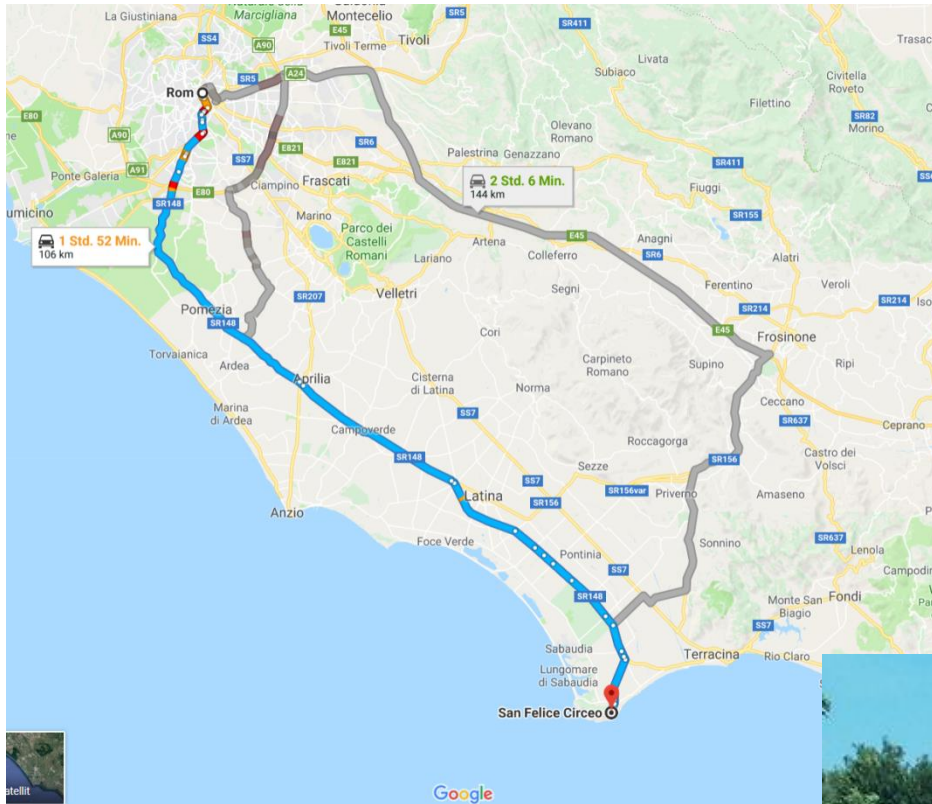
Dr. med. Anton Becker



- Position: Sliding Window
- Grösse: Veränderung der Auflösung



Weg zum Deep Learning



- Der Deep Learning Algorithmus wählt Muster, die nicht mehr nachvollziehbar sind
- Das Lernen erfolgt durch Brute-Force (Daten und Rechenleistung)
- Ein Problem wird in Teilprobleme zerlegt, von denen jedes einzelne durch Deep Learning gelöst werden kann

- Standardisierung der Befundung
- Reduktion der Untersucherabhängigkeit
 - Weniger falsch-positive Befunde -> weniger unnötige Biopsien
 - Weniger verpasste Karzinome
 - Querschnitt über viele Meinungen
 - Qualität unabhängig von der «Tagesform» des Radiologen
- Senkung der Gesundheitskosten

Für die Universitätsklinik

- Neues wichtiges Forschungsthema
- Möglichkeit der Entwicklung von eigenen Produkten
 - Patente
 - Spin-offs
- Aber auch allgemein: Schulung des Personals notwendig

- Warum erreichen wir keine 100% Genauigkeit?

- Der entscheidende Vorteil des Deep Learning liegt in der Standardisierung der radiologischen Befunde
- KI Algorithmen können sich Ihre Entscheidungskriterien selbst suchen
- Um KI klinisch anwendbar zu machen, muss der Entscheidungsweg nachvollziehbar sein
- Die KI wird wohl nicht besser werden als eine Schwelle, welche in der maximalen intrinsischen Information des Bildes liegt