



### 深層学習時代の医用画像処理に おけるデータと計算環境

### 名古屋大学 大学院情報学研究科 小田 昌宏





- コンピュータによる医療支援
- ・現在の医療
  - -診断,治療から構成
  - ※医師個人の技術に依存
  - ご患者に提供される医療の 質の格差発生
- コンピュータを用いた自動化による医療支援
   診断,治療に含まれる様々なプロセス自動化
   一定水準が保証された医療の提供







- 深層学習を用いない場合
  - 開発者の考えに基づき判断基準・特徴量作成
     \* 性能が開発者依存
     \* 工学研究者が人体解剖構造を理解して 研究開発を行う必要あり
- 深層学習
  - ・
    実際のデータに基づいた判断基準を自動作成
  - ジン学習用データが多いほど 判断の精度向上





### コンピュータ医療支援の現状と今後

- ・医療支援の現在の利用法
  - 診断・治療に有用な情報を医師に提示
  - 誤り,見落とし軽減
- 今後は医療の自動化へ
  - 診断・治療に含まれるルーチンワークを自動化
  - 医師はレア・特殊な症例に集中
  - 医師不足の解消
  - 常に一定水準の医療を提供





### 深層学習を用いた 医療支援研究の紹介





### 医用画像の例:X線透視像

- ・体内の様子を1方向に投影した2D画像
- 体を傷つけることなく体内を観察可能





## 医用画像の例:内視鏡画像

- 内視鏡は細長いケーブル先端にカメラ搭載
- ・患者の負担を抑え
   つつ体内の
   臓器観察















X線透視像 X線CT像



眼底画像 [Dasgupta16] 内視鏡像 皮膚画像 [Derma]

その他



[Dasgupta16] A Dasgupta, et al., A fully convolutional neural network based structured prediction approach towards the retinal vessel segmentation, IEEE ISBI, [Derma] http://www.mirai.ne.jp/~seisinc5/cancer.htm, [US] https://www.jsmoc.org/kiso/pulse2.html





### 深層学習による医療支援

- 診断支援
  - 腫瘍の自動検出
  - 腫瘍の定量評価



- 治療支援
  - 手術等で医師の
     判断を支援する
     情報提供

手術シーン







### 血管名自動識別







# 3Dプリンタ造形への応用

- 3Dデータの真の3D表示
  - 画面上での3D表示はあくまで2D投影されたもの
  - 3Dプリンタ造形により3D形状の大きさ, 位置関係を視覚,触覚で直観的に把握可能





#### 3Dプリンタで作成した臓器模型





## 医用画像に対する主な解析処理

- 検出
  - 画像分類, 画像上のターゲットの位置同定



セグメンテーション

 画像上のターゲット領域を塗る











# 検出の例:クモ膜下出血の検出

- 自動診断による医師の判断支援
- 救急医療における専門外医師の判断補助









# 検出の例:クモ膜下出血の検出

CNNにより画像を出血ありorなしに分類
 CT像はAxialスライス画像(2D)単位で処理



• CT像33例使用





## 検出の例:クモ膜下出血の検出



F1 score	Original dataset	Augmented dataset
VGG-16	82.20%	83.96%
GoogLeNet	84.22%	85.39%
<b>ResNet-50</b>	75.96%	85.23%
DenseNet-121	<b>85.58%</b>	84.13%





### 検出の例:大腸治療での内視鏡利用

- 大腸内視鏡
  - 治療が必要かどうか判断には生検が必要
- 超拡大内視鏡Endocytoscope

となる可能性あり

- 通常の大腸内視鏡と同じ画像から 超拡大画像(x1 to x500)まで撮影可能

- 超拡大画像からの判断が生検の代替手段



Endocytoscope (Olympus)

x380 magnification





### 検出の例:内視鏡像からの腫瘍鑑別

超拡大大腸内視鏡(Endocyto, Olympus)を用いた腫瘍自動鑑別システム 昭和大学,名古屋大学,サイバネットシステムの共同研究で開発





### 検出の例:CT像からのポリープ検出

- 機械学習を用いない手法[Oda09]
  - 6mm以上の球形物を検出する フィルタを手動設計
  - 検出率91.2%, 過検出7.9/症例



機械学習を用いる手法[Umehara17]
 ディープラーニング使用
 検出率93.5%,過検出3.9/症例

 [Oda09] M. Oda, et al., Digital bowel cleansing free colonic polyp detection method for fecal tagging CT colonography, Academic Radiology, 16(4), 486-494, 2009
 [Umehara17] K. Umehara, et al., Deep ensemble learning of virtual endoluminal views for polyp detection in CT colonography, SPIE Med Imag, 101340G, 2017





2Dセグメンテーション

・深層学習を用いて
 X線画像から臓器ラベル画像を推定



[Ronneberger15] O. Ronneberger, et al., U-Net: Convolutional Networks for Biomedical Image Segmentation, MICCAI 2015, 9351, pp.234-241, 2015.





2Dセグメンテーション

・眼底画像からの血管セグメンテーション [Dasgupta16]







[Dasgupta16] A Dasgupta, et al., A fully convolutional neural network based structured prediction approach towards the retinal vessel segmentation, IEEE ISBI, 2







反射可視光



[Dasgupta16] A Dasgupta, et al., A fully convolutional neural network based structured prediction approach towards the retinal vessel segmentation, IEEE ISBI,

[Derma] http://www.mirai.ne.jp/~seisinc5/cancer.htm, [US] https://www.jsmoc.org/kiso/pulse2.html





### 医用画像の例:CT像

- ・体の断面を撮影した2次元画像
- 体を傷つけることなく体内を観察可能







# 3Dボリューム画像

- CT像は0.5mm間隔で撮影可能
- 多数のCT像を立体的に積み上げると 3次元の仮想的な人体を作成可能











3Dボリューム画像と 3Dサーフェイスモデルの違い

#### **3Dボリューム画像**: 内部まで画素値が 詰まっている



#### **3Dサーフェイスモデル**: 表面のみ







### 3D画像からの臓器セグメンテーション

• 2D画像は3D形状の一部しか捉えられない







• 3D処理では臓器の立体的構造を考慮







### 2Dと3Dの臓器認識手法の差



- 2Dはサイズの小さい臓器の精度低
- 3Dはサイズに関わらず精度高





### 3D臓器セグメンテーション結果例







### 膵臓セグメンテーション精度推移

CT像からの自動識別研究の推移
 –機械学習により大幅な精度向上

年	手法	識別精度
2013	統計形状アトラス[Chu13]	69.1%
2016	機械学習(Regression forests)[Oda16]	75.1%
2017	3D情報を用いた深層学習[Roth17]	82.2%
2018	3D情報を用いた深層学習[Roth18]	89.7%

識別精度: DICE index (臓器領域の正解との重なり率)

- [Chu13] C. Chu, et al., Multi-organ segmentation based on spatially-divided probabilistic atlas from 3D abdominal CT images, MICCAI, LNCS 8150, 165-172, 2013
- [Oda16] M. Oda, et al., Regression forest-based atlas localization and direction specific atlas generation for pancreas segmentation, MICCAI, LNCS 9901, 556-563, 2016
- [Roth17] H.R. Roth, et al., Hierarchical 3D fully convolutional networks for multi-organ segmentation, arXiv:1704.06382, [Roth18] H.R. Roth, et al., Towards dense volumetric pancreas segmentation in CT using 3D fully convolutional networks, arXiv:1711.06439, 2018





### 深層学習登場による 計算環境の変化





深層学習以前の3Dセグメンテーション手法

- 多数の画像DBから臓器に関する情報抽出
  - 臓器の濃度値





• 情報を基に未知画像のセグメンテーション実施









- アルゴリズム構築において
   数百~数千の3Dボリューム画像を使用
  - 画像処理に必要な主記憶容量
    - 3D画像1枚ごとに 約500<sup>3</sup>画素×2Byte = 約250MByte
    - 300画像なら250MByte×300 = 75GByte
    - 処理中の一時記憶等でさらに記憶域使用
- 主記憶256GByte程搭載したコンピュータで
   処理可能





#### 深層学習以前の3Dセグメンテーション: 実行環境

- プログラミング言語
  - -主にC/C++
  - 並列化など行い処理高速化
- 使用コンピュータ
   デスクトップPC,小規模なサーバ
  - スパコン利用も可能

#### CPU計算速度,主記憶容量が 処理に影響





### 深層学習を用いた3Dセグメンテーション手法

- ・3Dボリューム画像であるCT像からの認識
- 3Dベース深層学習(3D U-Net等)を使用





#### 深層学習を用いた3Dセグメンテーション手法: 実行環境

- プログラミング言語
  - $-\pm$ CPython + TensorFlow
- 使用コンピュータ

処理に影響

- NVIDIA製GPU搭載PC

GPU (NVIDIA)



DeepLearning Box (GDEP) (GDEP) DGX-1 (NVIDIA)





#### 深層学習を用いた3Dセグメンテーション手法: 実行環境の問題点

- 学習に数百~数千の3D画像使用
- GPUメモリ量による読み込み画像サイズ制限
  - 3D深層学習ネットワークがGPUメモリ消費
  - GPUメモリ24GByteで 256<sup>3</sup>画素の3D画像を2枚程しか読めない
- 三問題点
  - 学習の反復処理に時間がかかる
  - ネットワーク最適化においてミニバッチ数が小さく 局所解に陥り,セグメンテーション精度悪化

GPUメモリ量の制限が速度と精度に悪影響





### GPUのメモリ

・ メモリの多いNVIDIA GPU

– 24GB : NVIDIA Quadro RTX6000/P6000

- 48GB : NVIDIA Quadro RTX8000
- 1GPUあたり48GBまでしか選択できず 深層学習を用いた3D画像処理には十分でない





### 3Dセグメンテーションにおける GPUメモリ節約の工夫1

• 画像を小画像に切り分けて処理

じ切り分け境界部分で不連続な形状が発生



セグメンテーション結果 CT像の切り分け

H. Roth et al. arXiv 1704.06382





### 3Dセグメンテーションにおける GPUメモリ節約の工夫2

- 画像の解像度を下げて処理 (5123→1283画素)
  - ・血管等の小さい臓器を見落とし
     ・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・

     ・















[Dasgupta16] A Dasgupta, et al., A fully convolutional neural network based structured prediction approach towards the retinal vessel segmentation, IEEE ISBI, [Derma] http://www.mirai.ne.jp/~seisinc5/cancer.htm, [US] https://www.jsmoc.org/kiso/pulse2.html 39







- 異常有無の判断のため組織を
   切除して顕微鏡で観察
- ・
   ・
   画像のデータ量大
  - 画像1枚が 50000×30000画素×2Byte×3色 = 9GByte
- 深層学習による画像解析では GPUメモリ節約の工夫が必要







[Dasgupta16] A Dasgupta, et al., A fully convolutional neural network based structur

[Derma] http://www.mirai.ne.jp/~seisinc5/cancer.htm, [US] https://www.jsmoc.org/kiso/pulse2.html





### 医用画像処理の現状

- 深層学習が急速に浸透
  - 従来の画像解析より良好な成果
  - GPUを用いた画像処理が一般化
- ・GPUを用いた画像処理
  - 2D画像処理は問題少ない
  - データ量の大きい画像ではGPUメモリ量による 制限を受ける(計算速度と精度において)







- 医用画像処理における深層学習の 適用例,応用例を紹介
- ・ 画像のデータ量によって
   深層学習の適用容易さが変化
   - GPUメモリ量が重要

 今後のGPUメモリ増加と深層学習の実装の工夫 により3D画像のビッグデータの活用に期待