# 前処理を利用した血管 3D データに対するセグメンテーションモデルの学習

土松千紗† 平川翼† 山下隆義† 藤吉弘亘†

†中部大学

E-mail: matsuno@mprg.cs.chubu.ac.jp

## 1 はじめに

脳動脈に異常が起きることが原因で発症する病気で ある脳血管疾患は,発症した場合の死亡率,また後遺 症の発症率が高い.そのため,検査による早期発見が 重要である.脳血管疾患の検査には,Time-of-flight法 による磁気共鳴血管画像 (TOF-MRA)を用いることが 多い.これは,TOF-MRA が放射線を使用しない検査 手法であるため,また血管造影の感度が高いためであ る.検査は,造影されたTOF-MRA データをフレーム ごとに観察して脳血管疾患の診断を行う.この手法は 医師の負担が大きいという問題点があるため,医師の 診察支援を目的として,様々な血管領域や疾患領域の 自動検出手法が提案されている.

血管領域の自動検出手法として,ボクセルごとに血 管であるかを出力する,3次元セマンティックセグメン テーション手法[1,2]が提案されている.これらの手法 は,血管領域のアノテーションを行った大量の3次元 データを用いて学習する必要がある.しかし大量の学 習用データの用意は困難である場合が多い.原因とし て,血管領域のアノテーションが行える人物が医師な どの有識者に限られている点,TOF-MRA データは3 次元データであるためアノテーションの手間が大きい 点,既存手法で使用されるデータセットが患者のプラ イバシー保護の観点から非公開である場合が多い点が 挙げられる.

また血管領域に加えて分岐点を導出することは,血 管の負荷がかかり血管疾患を発症しやすい分岐点への 注目が容易になることから,診察支援として有効であ る.血管の分岐点の導出手法の1つとして,血管領域 のセグメンテーション結果を細線化し,隣接するボク セル数に基づき導出する手法があるが,血管領域のセ グメンテーション精度に依存する.

そこで本研究では、合成データで学習したモデルに 対し、実データを入力した場合のセグメンテーション 精度、分岐点の導出精度を向上させることを目的とし て、モデル入力前のデータ処理によるセグメンテーショ ン精度、分岐点の導出精度による分析を行う.また分 析をもとに、前処理を実施したデータに対するセグメ ンテーション結果を疑似ラベルとした半教師あり学習 手法を提案する.評価実験より,前処理を用いた疑似 ラベル作成が血管領域に対するセグメンテーション精 度,分岐点の導出精度の向上に有効であることを示す.

## 2 関連研究

本章では,血管領域のセグメンテーション手法,損 失関数について述べる.

### 2.1 セグメンテーション手法

代表的な血管領域のセグメンテーション手法として, U-Net[1], DeepVesselNet (DVN) [2] が挙げられる. U-Net はエンコーダ・デコーダ構造からなるセグメンテー ション手法である.特徴として,畳み込み層から逆畳 み込み層へのスキップ結合を持つ点が挙げられる.

DVN は細い血管のセグメンテーション精度を向上さ せるために,ダウンサンプリング,アップサンプリング を不使用としたセグメンテーション手法である.その 他の特徴として,偽陽性,偽陰性に基づく損失関数を 使用する点が挙げられる.DVN にて使用する損失関数 *L*を式 (1) に示す.

$$\mathcal{L} = -\frac{1}{N_{TP} + N_{FP}} \sum_{i \in N_{TP} + N_{FP}} \log P(y_i = 1) - \frac{1}{N_{TN} + N_{FN}} \sum_{i \in N_{TN} + N_{FN}} \log P(y_i = 0) - \frac{1}{N_{TP} + N_{FP}} \sum_{i \in N_{FP}} \log P(y_i = 0) - \frac{1}{N_{TN} + N_{FN}} \sum_{i \in N_{FN}} \log P(y_i = 1)$$
(1)

ここで、 $y_i$ は *i* 番目のボクセルの正解クラス、 $N_{TP}$ 、 $N_{TN}$ 、 $N_{FP}$ 、 $N_{FN}$ はそれぞれ真陽性、真陰性、偽陽性、偽陰性のボクセル数である.

#### 2.2 損失関数

TOF-MRA データにおいて血管クラスのボクセルは 非常に少なく、多くのボクセルは背景である. このよ うなラベルごとのボクセル数が不均衡であるデータの セマンティックセグメンテーションは、Accuracy に基 づく損失関数を用いて学習すると学習に失敗しやすい ため、解決策として DVN にて使用される損失関数以外 にも様々な損失関数が提案されている. DiceLoss[3] は



図1 血管領域,中心線,分岐点の導出手順

Dice 係数に基づく損失関数である. Dice 係数は誤検出 数に注目した評価指標である Precision と,未検出数に 注目した評価指標である Recall の調和平均であるため, クラス不均衡なデータに対しての認識精度が向上しや すい. DiceLoss を式 2 に示す.

DiceLoss = 
$$\frac{1}{N} \sum_{i} \left[ 1 - \frac{2p_{i1}y_{i1} + \gamma}{p_{i1}^2 + y_{i1}^2 + \gamma} \right]$$
 (2)

ここで、Nはボクセル数、 $p_{i1}$ はi番目のボクセルに対 する True クラスの予測確率、 $\gamma$ は平滑化のための変数 である.また、 $y_{i1}$ はi番目のボクセルに対する正解ク ラスが True であるときに1を取り、その他で0を取る.

clDice[4] は Dice 係数とネットワーク構造の類似度を 反映する損失関数である.血管は網状であるため、ト ポロジカルな類似度を反映することで認識精度が向上 しやすい. clDice を式 (3) に示す.

$$clDice = 2 \times \frac{\operatorname{Tprec}(S_p, V_y) \times \operatorname{Tsens}(S_y, V_p)}{\operatorname{Tprec}(S_p, V_y) + \operatorname{Tsens}(S_y, V_p)}$$
(3)  
$$\operatorname{Tprec}(S_p, V_y) = \frac{|S_p \cap V_y|}{|S_p|}$$
  
$$\operatorname{Tsens}(S_y, V_p) = \frac{|S_y \cap V_p|}{|S_y|}$$

ここで、 $V_p$  は予測クラスが True のボクセル集合、 $V_y$ は正解クラスが True のボクセル集合、 $S_p$  は $V_p$  を細線 化したボクセル集合、 $S_y$  は $V_y$  を細線化したボクセル 集合である.

#### 2.3 データセット

血管 3D データにおいて,オープンデータセットの例 として合成データである Tetteh らが作成した人工血管 データセット [2],実データである Note らが作成した TOF-MRA データセット [5] が挙げられる.Tetteh らが 作成したデータセットは,血管の造形をシミュレーショ ンしたデータであり,1データ当たり(325×304×600) のボクセルで構成される.またデータセット内に136 個 のデータが含まれる.特徴として,ボリュームデータ全 体に血管のボクセルが存在する点が挙げられる.Note



らが作成したデータセットは、脳腫瘍検出を目的として 脳腫瘍患者と健常者の脳を TOF-MRA で造影したデー タセットであり、健常者データが 130 個、患者データが 169 個の合計 299 個のデータが含まれる.特徴として、 比較的大きな動脈のみ造影されているためボリューム データ内の血管クラスのボクセルに偏りが存在する点、 濃淡が 4096 階調で表現されている点、1 データを構成 するボクセル数がデータによって大きく異なる点が挙 げられる.合成データ、TOF-MRA データの画素値ヒ ストグラムを図 2 に示す.図 2 より、TOF-MRA デー タは頻度が高い画素値が約 500 以下に偏っている.

DeepLearning において、学習用データを増やすこと は、セグメンテーションの精度向上に繋がる.しかし、 学習用データとして利用するためには正確に正解位置 をアノテーションする必要がある.TOF-MRA データ は3次元かつ専門性が高いことからアノテーションの コストが高いため、アノテーション済みデータの数が 少ないという問題点がある.また TOF-MRA データは 患者のプライバシー保護の観点からデータの入手が困 難であるという問題点もある.

## 3 血管領域のセグメンテーションに適した前 処理の調査

本分析では,前処理を実施したデータをモデルに入 力した時のセグメンテーション結果,分岐点の導出結 果を比較することで,合成データを用いて学習したモ デルに対して有効な前処理を調査する.データの前処 理にはローパスフィルタ,画素の階調変更,ガンマ補正

表1 合成データに対するセグメンテーション精度

前処理の種	重類	Prec. [%]	Rec. [%]	Dice [%]	IoU [%]
前処理な	l	99.91	99.94	4 99.92 9	
- 22	$\gamma = 1.5$	8.07	100.00	14.94	8.07
カンマ相止	$\gamma = 2.0$	2.22	100.00	4.35	2.22
ローパスフィルタ	$\tau = 5$	99.91	99.94	99.92	99.84
	$\tau = 10$	99.91	99.94	99.92	99.84
	$\tau = 50$	99.91	99.93	99.92	99.84
	$\tau = 100$	99.68	99.06	99.37	99.74



図 3 導出結果と正解ボクセル間の L2 norm 表 2 1 データ当たりの血管領域,分岐点のボクセ ル数

前処理の種類		血管領域の	正解からの	分岐点の	正解からの	血管領域に対する 公共内の割合 19/1
		ホンモル奴 [面]	有成业 [四]	ホアモル奴 [間]	和成业 [四]	力岐点の割百 [76]
正解ラベル	r	1003587	/	1746	/	0.17
前処理なり	前処理なし		+285	2483	+737	0.25
ガンマ補正	$\gamma = 1.5$	12432692	+11429105	2059711	+2057966	16.57
	$\gamma = 2.0$	45143383	+44139795	16943368	+16941622	37.53
ローパスフィルタ	$\tau = 5$	1003872	+285	2483	+738	0.25
	$\tau = 10$	1003872	+285	2483	+738	0.25
	$\tau = 50$	1003852	+265	2485	+739	0.25
	$\tau = 100$	997274	-6314	2418	+673	0.24

を使用する.血管領域のセグメンテーション,血管の 中心線,分岐点の導出手順を図1に示す.

分析条件として、モデルは DVN、学習データセットは 合成データセットのうち 100 個、エポック数は 10、バッ チサイズは 16、学習率は 0.001 である.またテストデー タセットは合成データセットのうち 36 個、TOF-MRA データセットの健常者データのうち 36 個を使用する. ここで学習、テストにおいて、使用メモリ量を削減する ために、各データを (64×64×64) に分割してモデルに入 力する.ローパスフィルタの閾値を  $\tau = [5, 10, 50, 100]$ , ガンマ補正の  $\gamma \varepsilon [1.5, 2.0]$ とする.合成データに対す るセグメンテーションの評価指標は、Precision (Prec.) 、Recall (Rec.) 、Dice 係数、Intersection over Union (IoU) を使用する.また分岐点の評価指標は、導出結果 と正解ラベルのボクセル間の L2 norm を使用する.

#### 3.1 合成データに対する影響の調査

前処理を施した場合の合成データに対するセグメン テーション精度,分岐点の導出精度から,合成データ に対する前処理の効果を分析する.合成データを入力 時の血管領域のセグメンテーション精度を表1に,分 岐点の導出結果と正解ボクセル間のL2 norm を図 3 に示す. 表1よりセグメンテーション精度に関して,  $\gamma = [1.5, 2.0]$ のガンマ補正を使用する場合に Precision, Dice, meanIoU において精度が大きく低下した.また,  $\tau = [5, 10, 50]$ のローパスフィルタを使用する場合に全 ての評価指標において精度の変化していないことを確 認した.対して, $\tau = 100$ のローパスフィルタを使用す



る場合に全ての評価指標において 1pt 以下の精度が低下 していることを確認した.図3より,  $\tau = 100$ のローパ スフィルタを使用する場合に,導出結果と正解との L2 norm が約1.732 ボクセル以内である割合は前処理を使 用しない場合より低いが,導出結果と正解との L2 norm が5ボクセル以内である割合は前処理を使用しない場 合より高いことを確認した.表2より,  $\tau = [5,10,50]$ のローパスフィルタを使用する場合に1データ当たり の血管領域,分岐点のボクセル数がほぼ変化しないこ とを確認した.また, $\gamma = [1.5, 2.0]$ のガンマ補正を使 用する場合に血管領域,分岐点のボクセル数が大きく 増加していることを確認した.

次に,前処理を使用しない場合,  $\tau = 100$ のローパ スフィルタを使用する場合の血管領域のセグメンテー ション結果,中心線と分岐点の導出結果をを図4に示 す.中心線と分岐点の導出結果において,赤色のボクセ ルは分岐点,青色のボクセルは中心線を示す.図4よ り前処理を施した場合,セグメンテーション結果,中 心線,分岐点の導出結果はほぼ変化しなかった.以上 からデータの前処理として  $\tau = [5, 10, 50, 100]$ のローパ スフィルタを使用することは,合成データに対する血 管領域のセグメンテーション精度,中心線,分岐点の 導出精度を低下させないと考える.

#### 3.2 TOF-MRA データに対する影響の調査

前処理を施した場合の TOF-MRA データに対する血 管領域のセグメンテーション結果,分岐点の導出結果 から,TOF-MRA データに対する前処理の効果を分析 する.前処理ごとの1データ当たりの血管領域,分岐 点と予測したボクセル数を表3に示す.また,TOF-MRA データに対する血管領域のセグメンテーション 結果のうち太い血管が造影されている箇所を図5に,細い血管が造影されている箇所を図6に,血管がほと んど造影されていない箇所を図7に示す. 表3より,  $\tau = [5, 10, 50, 100]$ のローパスフィルタを使用した場合 に1データ当たりの血管領域,分岐点のボクセル数が 減少することを確認した.対して, $\gamma = [1.5, 2.0]$ のガ



図 7 血管がほとんど造影されていない TOF-MRA データに対するセグメンテーション結果

			10	/	<u> </u>		$\mathcal{A}, \mathcal{I} \in \mathcal{I}$			
ガンマ	マ補正	ローパスフィルタ		血管領域の	前処理なしの場合	分岐点の	前処理なしの場合	血管領域に対する		
$\gamma = 1.5$	$\gamma = 2.0$	$\tau = 5$	$\tau = 10$	$\tau = 50$	$\tau = 100$	ボクセル数 [個]	からの増減量 [個]	ボクセル数 [個]	からの増減量 [個]	分岐点の割合 [%]
						406056		20528		5.06
		$\checkmark$				392604	-13452	16252	-4276	4.14
			$\checkmark$			282244	-123813	10463	-10065	3.71
				$\checkmark$		13392	-392665	70	-20458	0.52
					$\checkmark$	1130	-404927	5	-20523	0.45
$\checkmark$						420378	+14321	17766	-2762	4.23
$\checkmark$		$\checkmark$				421288	+15232	17194	-3334	4.08
$\checkmark$			$\checkmark$			425784	+19728	15984	-4544	3.75
$\checkmark$				$\checkmark$		44883	-361174	181	-20347	0.40
$\checkmark$					$\checkmark$	9021	-397035	49	-20479	0.54
	$\checkmark$					410783	+4727	13216	-7312	3.22
	$\checkmark$	$\checkmark$				420476	+14420	13464	-7064	3.20
	$\checkmark$		$\checkmark$			421790	+15733	13403	-7125	3.18
	$\checkmark$			$\checkmark$		301745	-104312	11675	-8853	3.87
	$\checkmark$				$\checkmark$	19081	-386976	79	-20449	0.41

表3 1データ当たりの血管領域、分岐点と予測したボクセル数

表 4 合成データに対する各モデルのセグメンテー ション精度

使用モデル	Prec. [%]	Rec. [%]	Dice [%]	IoU [%]
DVN	99.91	99.94	99.92	99.84
U-Net+DiceLoss	99.79	99.79	99.79	99.58
U-Net+clDice	99.92	99.88	99.90	99.80

ンマ補正を組み合わせた場合に血管領域のボクセル数 は増加するが、分岐点のボクセル数は減少することを 確認した.特に $\gamma = 1.5$ のガンマ補正と $\tau = 50$ のロー パスフィルタを使用した場合に、血管領域のボクセル数 に対する分岐点のボクセル数の割合が合成データの正 解の割合に近い. 図 5, 図 6, 図 7 より,  $\tau = [50, 100]$ のローパスフィルタを使用した場合に血管領域である ボクセルの分類に失敗していること、ノイズが増加し ていることを確認した. また,  $\gamma = [1.5, 2.0]$ のガンマ 補正と τ = [5,10] のローパスフィルタを使用した場合, ノイズは存在するが他の血管領域のボクセルと隣接し ないノイズであることを確認した. これらのノイズは 後処理として隣接する血管領域のボクセル数に基づく 削除を行うことで削減できると考える.以上から,血管 領域のボクセルが減少し、かつ合成データの血管領域 の正解ボクセル数に対する分岐点の正解ボクセル数の 割合に最も近い結果であった τ = 10 のローパスフィル タを前処理として使用し、隣接する血管領域のボクセ ル数に基づく削除を後処理として使用することが、疑 似ラベルの作成に最も有効であると考える.

#### 3.3 他モデルに対する前処理の効果の調査

分析結果をもとに, *τ* = 10 のローパスフィルタ, 隣 接する血管領域のボクセル数に基づく削除によるデー タ処理の他のモデルにおける有効性を調査する.比較 対象のモデルはセグメンテーションにおいて頻繁に用 いられる手法である U-Net[1],損失関数は DiceLoss と clDice を用いる.

合成データに対する各モデルの血管領域のセグメン テーション精度を表4に示す.次に,TOF-MRAデー

表 5	1 データ当たりの血管領域,	分岐点と予測した
ボクセ	レ数	



タに対して前処理を行う前後において,1データ当た りの血管領域、分岐点と予測したボクセル数を表5に 示す. また, TOF-MRA データに対する血管領域のセ グメンテーション結果を図8に示す. 表5より,損 失関数に clDice を用いた U-Net においてデータの前処 理を行う場合に血管領域と予測したボクセル数が減少 すること、全てのモデルにおいて分岐点と予測したボ クセル、血管領域のボクセル数に対する分岐点のボク セル数の割合が減少することを確認した.また、図8 より血管領域のセグメンテーションにおいて、損失関 数に clDice を用いた U-Net の入力データに前処理を行 う場合にノイズが減少することを確認した.以上から, TOF-MRA データの前処理として階調変更を実施後、  $\tau = 10$ のローパスフィルタを使用することは、DVN 以 外のモデルである損失関数に clDice を用いた U-Net に おいても有効であると考える.



図 9 提案手法による学習の流れ

使用モデル		追加学	習前		追加学習後				
	Prec. [%]	Rec. [%]	Dice [%]	IoU [%]	Prec. [%]	Rec. [%]	Dice [%]	IoU [%]	
DVN	99.91	99.94	99.92	99.84	99.59	99.82	99.70	99.40	
U-Net+DiceLoss	99.79	99.79	99.79	99.58	97.93	97.77	98.84	97.71	
U-Net+clDice	99.92	99.88	99.90	99.80	99.94	96.39	98.13	96.33	



図 10 追加学習前後の導出結果と正解ボクセル間の L2 norm の比較

## 4 提案手法

分析結果をもとに、前処理を施したラベルなし実デー タに対するセグメンテーション結果、分岐点の導出結果 を疑似ラベルとした半教師あり学習を提案する.提案 手法による学習の流れを図9に示す.まず、ラベルあり データである合成データを用いてモデルの学習を行う. モデルの学習後、ラベルなしデータである TOF-MRA データに対して前処理として 256 階調への変更、ロー パスフィルタを使用し、合成データで学習したモデル へ入力し、血管領域のセグメンテーションを行う.そ の後、後処理として隣接する血管領域ボクセル数に基 づくボクセルの削除を行う.前処理、後処理の有無で1 データ当たりの予測した血管領域のボクセル数を比較 する.そこで、ボクセル数の差が閾値以上の場合、予 測した血管領域を疑似ラベルとする.そして、疑似ラ ベルが付与された TOF-MRA データと合成データを併



せて入力し, 合成データで学習したモデルの追加学習 を行う.

### 5 評価実験

提案手法の有効性を調査するために評価実験を行う. 追加学習を行う前後のモデルで,合成データに対する セグメンテーション精度,分岐点の導出精度を比較し, TOF-MRA データセットに対する1 データ当たりの血 管領域,分岐点と予測したボクセル数,セグメンテー ション結果,中心線,分岐点の導出結果を比較する.

#### 5.1 実験条件

モデルは DVN,U-Net, データセットは合成データで ある Tetteh らが作成した人工血管データセットのうち

表 6 合成データに対するセグメンテーション精度

衣 ( 1 ナーダヨたりの血官頑與, 万岐県と丁側したホクセル数							
使用モデル	血管領域 [個]		分岐点 [個]		血管領域に対する分岐点の割合 [%]		
	追加学習前	追加学習後	追加学習前	追加学習後	追加学習前	追加学習後	
DVN	406056	64671	20528	168	5.06	0.26	
U-Net+DiceLoss	855124	117223	52199	1090	6.10	0.93	
U-Net+clDice	305020	116880	8936	1587	2.93	1.36	

表7 1データ当たりの血管領域、分岐点と予測したボクセル数

10 個と、実データである Note らが作成した TOF-MRA データセットの健常者データのうち 90 個を使用する. テスト時に合成データである Tetteh らが作成した人工 血管データセットのうち 36 個, 実データである Note ら が作成した TOF-MRA データセットの健常者データの うち 36 個使用する. ここで学習, テストにおいて, 使用 メモリ量を削減するために、各データを(64×64×64) に分割してモデルに入力する. 学習回数は合成データ のみでの学習を10エポック、合成データと実データを 用いた学習を5エポック行う. バッチサイズは16, 学 習率は 0.001 とし、10 エポック以降は 0.0001 とする. 損失関数は DVN に対しては誤陽性, 誤陰性に基づく 損失関数, U-Net に対しては DiceLoss と clDice を用い る. ローパスフィルタの閾値を τ = 10 とする. 血管領 域ボクセルの削除は、26 近傍で隣接する血管領域ボク セルが存在しない場合に行う. また合成データに対す るセグメンテーションの評価指標は, Precision (Prec.) , Recall (Rec.), Dice 係数, Intersection over Union (IoU)を使用する. また分岐点の評価指標は, 導出結果 と正解ラベルのボクセル間のL2 normを使用する.

#### 5.2 実験結果

追加学習前後における.合成データに対する血管領 域のセグメンテーション精度を表6に,導出結果と正 解ボクセル間のL2 norm を図10に,血管領域のセグ メンテーション結果を図11に示す.表6,図10より追 加学習を行うことで合成データに対するセグメンテー ション精度,分岐点の導出精度が低下することを確認 した.特に損失関数にclDiceを用いたU-Netにおいて, 分岐点の導出精度が大きく減少した.また,図11より U-Netにおいてセグメンテーション結果の変化が小さ いことが分かる.これは表6,図11よりセグメンテー ション精度の変化が少ないことから,中心線の導出に 失敗したためだと考える.以上から,中心線の導出に 用いる細線化アルゴリズムの改良により分岐点の導出 精度の低下を抑制できると考える.

次に,追加学習前後における,TOF-MRA データに 対する1 データ当たりの血管領域,分岐点と予測した ボクセル数を表7に,血管領域のセグメンテーション結 果を図12に,中心線,分岐点の導出結果を図13に示 す.図13において,赤色のボクセルは分岐点,青色の ボクセルは中心線を示す.表7より追加学習を行った 場合に,血管領域,分岐点と予測したボクセル数が大幅



(d) DVN (追加学習後) (e) U-Net+DiceLoss (f) U-Net+clDice (追加学習後)
図 13 追加学習前後における TOF-MRA データの中心線、分岐点の導出結果

に減少することを確認した.また,図12,図13より追加学習を行った場合に,セグメンテーション結果,中心線,分岐点の導出結果に含まれるノイズが追加学習前よりも減少することを確認した.以上から,TOF-MRA データに対して前処理,後処理を用いたセグメンテーション結果を疑似ラベルとして付与することは,学習に有効であると考える.

#### 6 おわりに

本研究では、合成データで学習したモデルに対し実 データを入力した場合の血管領域のセグメンテーショ ン精度を向上させるデータの前処理の効果を調査し、前 処理を実施したデータに対するセグメンテーション結 果を疑似ラベルとした半教師あり学習手法を提案した. 評価実験にて合成データに対するセグメンテーション精 度、分岐点の導出精度の低下割合が小さく、かつ TOF-MRA データに対するセグメンテーション精度、分岐点 の導出精度が向上したことを確認した.今後は TOF-MRA データ以外の脳血管データに対する半教師あり学 習手法の効果を調査する.

## 参考文献

- O. Ronneberger, et al., "U-Net: Convolutional Networks for Biomedical Image Segmentation", In Medical Image Computing and Computer-Assisted Intervention, pp. 234–241, 2015.
- [2] G. Tetteh, et al., "DeepVesselNet: Vessel Segmentation, Centerline Prediction, and Bifurcation Detection in 3-D Angiographic Volumes", In Frontiers in Neuroscience, pp. 1–17, 2020.
- [3] X. Li, et al., "Dice Loss for Data-imbalanced NLP Tasks", In Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, pp. 465–476, 2020.
- [4] S. Shit, et al., "clDice A Novel Topology-Preserving Loss Function for Tubular Structure Segmentation", In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 16560–16569, 2021.
- [5] T. Di Noto, et al., "Towards Automated Brain Aneurysm Detection in TOF-MRA: Open Data, Weak Labels, and Anatomical Knowledge," In Neuroinformatics, pp. 1–14, 2022.