

深層学習を用いた脳血流SPECT短時間 収集画像から標準時間収集画像への生成

Generation of standard time acquisition images from short time acquisition images of cerebral blood flow SPECT using deep learning

山本 泰司¹⁾, 白井 匡人²⁾, 高村 真広³⁾, 松浦 航介⁴⁾, 日野 勇希⁴⁾, 福田 美月⁴⁾, 矢田 伸広⁴⁾,
宮原 善徳⁴⁾, 黒田 弘之⁵⁾, 楢 靖⁶⁾

1) 島根大学医学部 放射線医学講座
2) (助教) 島根大学総合理工学部
3) (助教) 島根大学医学部 脳神経内科学講座
4) 島根大学医学部附属病院 放射線部
5) (講師) 島根大学医学部 放射線医学講座
6) (教授) 島根大学医学部 放射線医学講座

Key words: deep learning, pix2pix, GAN, 3D-SSP, Brain SPECT

【Abstract】

We attempted image generation of cerebral blood flow SPECT from short time acquisition (10 minutes) to standard time acquisition (40 minutes) using artificial intelligence based image generation technique. The model was pix2pix and was constructed from training data of 19484 images both 10 min and 40 min. Using constructed model, 4878 images were generated and evaluated similarity to standard images. MSE, PSNR, SSIM, and DSC were used for physical evaluation, and 3D-SSP was used for visual evaluation. Although image quality improved in the physical evaluation, there were cases where the depiction of abnormal blood flow areas differed from standard time in 3D-SSP. In order to improve the accuracy, we consider it is necessary to reexamine this issue with training data using extended acquisition time.

【要 旨】

人工知能による画像生成技術により、短時間収集（10分）の脳血流SPECTから標準時間収集（40分）への画像生成を試みた。生成モデルはpix2pix、学習データは10分、40分共に19,484枚から構築した。構築した学習データから4,878枚の生成画像を作成し標準画像との類似度を評価した。物理評価にはMSE、PSNR、SSIM、DSCを、視覚的評価には3D-SSPを用いた。物理評価からは画質は改善したものの、3D-SSPから血流異常領域の描出が標準時間収集と異なるケースがあった。精度を上げるためには、収集時間を延長した学習データでの再検討も必要と考える。

緒 言

認知症における画像診断では、核医学での脳血流 Single photon emission computed tomography (SPECT) が重要な役割を担っている。しかし、わずか

なγ線の情報から画像作成していることから検査時間は当施設でのルーティンで40分と長く、脳疾患の患者にとってはつらい検査である。故に、検査データが最終まで収集できずに十分な収集データを得られないまま画像作成するケースも発生し、画像診断への影響も避けられない。またアイソトープを使用することから検査費用が高額で、被ばくを伴う観点からも再検査は困難で、収集データの不足したケースでも診断可能な画質まで改善する方法が存在すればその価値は大きい。

近年は深層学習の画像生成タスクを用いた画質改善が可能となり、先に述べた不足した収集データからの脳血流SPECT画像の画像救済につながる可能性もある。その参考となるさまざまな報告があり、Computed Tomography (CT) では、低線量での収集データから高線量での画像に近い画質を得る研究¹⁾、Magnetic Resonance Imaging (MRI) 領域でも、ノイズ低減効果や画質改善効果を可能とした研究報告がなされている^{2, 3)}。核医学領域では、Positron Emission Tomography (PET) でアイソトープの投与量を低減させ標準投与量の画像と同等の画質が担保できたとする報告がある⁴⁾。そこでわれわれも、深層

YAMAMOTO Yasushi¹⁾, SHIRAI Masato²⁾,
TAKAMURA Masahiro³⁾, MATSUURA Kousuke⁴⁾,
HINO Yuuki⁴⁾, FUKUDA Mitsuki⁴⁾,
YADA Nobuhiro⁴⁾, MIYAHARA Yoshinori⁴⁾,
KURODA Hiroyuki⁵⁾, KAJI Yasushi⁶⁾

- 1) Department of Radiology, Shimane University Faculty of Medicine.
- 2) Interdisciplinary Faculty of Science and Engineering, Shimane University
- 3) Department of Neurology, Shimane University Faculty of Medicine.
- 4) Department of Radiology, Shimane University Hospital
- 5) Department of Radiology, Shimane University Faculty of Medicine.
- 6) Department of Radiology, Shimane University Faculty of Medicine.

Received January 4, 2023; accepted May 16, 2023

学習を用いることで脳血流SPECTの短時間収集データの画質を向上させ、診断に耐え得る画質を生成（画像生成）できるかを検討した。

1. 方法

1-1. 使用機器および収集条件

使用した脳血流SPECTデータは、放射性医薬品 ^{123}I -N-isopropyl-p-iodoamphetamine (^{123}I -IMP) 167MBqを使用し、Graph Plot法^{5,6)}で収集、製剤注入と同時にContinuous modeで5分/360度収集を8ローテーション、計40分（標準検査時間）の収集データを取得した。画像再構成はOrdered subset expectation maximization (OSEM) 法でIterationは2, subsetは24, 散乱線補正はTriple energy window (TEW), 減弱補正はCT-based attenuation correction (CTAC) を使用した。収集装置はGE Healthcare Discovery 670pro, 再構成ワークステーションはXeleris 3.0である。画像生成に使用したコンピューターはサーバー型Philips Intellispace Discovery, CPU: Intel Xeon Gold 5120, RAM: 192 GB, GPU: NVIDIA Tesla V100 16GB, Operating system: Ubuntu 16.04 LTS 64-bit. 画像生成プログラムはPython 3.6.10, フレームワークとしてPyTorch 1.8.0を使用した。また画像評価はMathworks MatLab2021を使用した。なお、本研究は臨床データの使用も含め、全て島根大学 医学研究倫理委員会の承認（研究管理番号: 20211228-1）を得て行っている。

1-1-1. 画像生成の使用データ

画像生成を行うには、学習用のトレーニングデータ群（以下、Train_data）の準備が必要となる。本研究では、短時間収集画像を使用して標準時間収集画像を生成することが目的であることから、収集開始から10分までの収集データで作成したSPECT画像を短時間収集画像（10min_S）とし、同じ症例の40分までの収集データから作成したSPECT画像を標準時間収集画像（40min_S）とし、同一症例で10min_Sと

40min_Sをペアで準備した。Train_dataは、2018年1月から2019年12月までに ^{123}I -IMP Graph Plot法を最終の40分まで施行することが可能であった連続400例、女性191例（ 73.6 ± 13.4 歳）、男性209例（ 73.6 ± 13.4 歳）である。放射線専門医による診断結果から認知症152例、脳血管障害109例、その他疾患47例、異常所見なし92例であった。生成モデルの精度評価に使用するデータ群（Test_data）はTrain_dataとは別に準備する必要がある。2020年1月から同年6月までの連続検査データ101例、女性43例（ 72.6 ± 13.3 歳）、男性58例（ 72.4 ± 11.6 歳）とし、認知症45例、脳血管障害23例、その他疾患7例、異常所見なし26例であった。Train_dataに使用した10min_Sと40min_Sの画像数はそれぞれ19,484枚、Test_dataには4,878枚を使用した。頭頂から小脳下縁まで1症例当たり48枚を基準として構成した。再構成された16bitのDicomデータ（ 128×128 マトリクス、ピクセルサイズ2.94mm）は、画像生成モデルで動作可能な8ビットのPNGファイルに変換した。画像生成に重要な脳実質内の領域を多く含める目的から、PNG変換時に1.7倍拡大し被写体外の面積を減らし、 256×256 のマトリクスで保存することで拡大によるボケを考慮した。

1-2. 画像生成モデル

画像生成は、Isola⁷⁾ らにより報告されたpix2pixと呼ばれるモデルを使用した。pix2pixは、敵対的生成ネットワークGenerative adversarial network (GAN) の派生モデルで、生成器 (Generator)

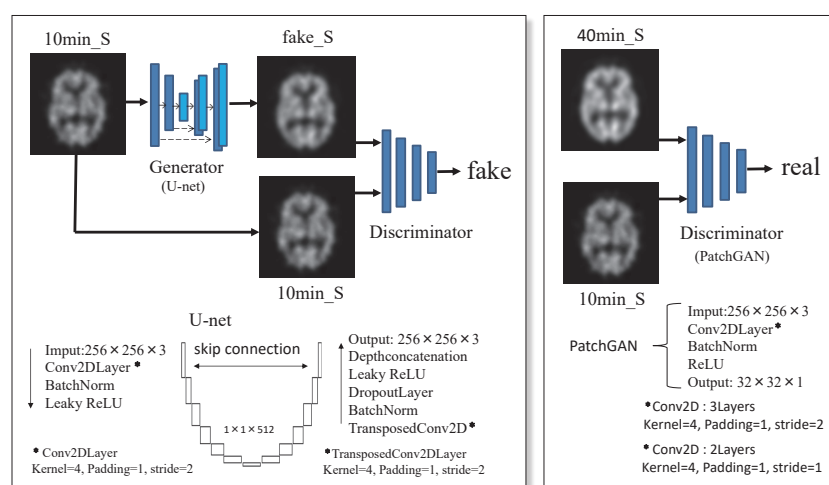


Fig.1 Pix2pix architecture is shown. Generator generates fake_S from 10min_S.

Discriminator is trained to judge 40min_S as real and fake_S as fake. Generator uses U-net and Discriminator uses PatchGAN.

ではできるだけ本物に似た画像を生成し、識別器 (Discriminator) ではその画像を本物か偽物かを識別する。偽物と識別されると Generator に情報がフィードバックされ、最終的には Discriminator が本物と判断する画像生成につながる。その際、GAN では Generator への初期入力ランダムノイズベクトルで、ここから画像生成が開始される。対して pix2pix では、実画像を入力に用いることで実画像に基づいた画像生成が可能となる。本研究でも、同じルールで準備された 10min_S と 40min_S の画像 (同一症例、同一座標) をペアで学習させることで、2 画像間の詳細な対応関係を Artificial intelligence (AI) が見つけ出すことで、短時間収集画像から標準時間収集画像を生成する条件付き敵対的生成ネットワークの学習データが完成する。学習が完了すると、学習データとは別に準備された Test_data である 10min_S を生成器に入力することで、先の学習データの関係性を基に本物に近い 40 分画像 (fake_S) の生成が可能となる。Isola⁷⁾ らの論文を参考に本研究での pix2pix のアーキテクチャーを Fig.1 に示す。Generator には U-net を使用し、Discriminator では PatchGAN⁷⁾ を採用した。損失関数には L1 Loss⁷⁾ を採用し、画像全体、いわゆる低周波成分の領域把握が可能となり、条件画像 (10min_S) と生成画像 (fake_S) と正解画像 (40min_S) の一致度を高めている。また最適化アルゴリズムには Adam⁸⁾ を用いている。pix2pix のアーキテクチャーとハイパーパラメーターについての詳細はオリジナルの論文⁷⁾ を参照いただきたい。ソースコードは PyTorch による実装が公開 (<https://github.com/junyanz/pytorch-CycleGAN-and-pix2pix>) されているものをダウンロードして使用した。

1-3. 類似度の物理評価

生成画像の物理的評価は、福井らの報告⁹⁾ を参考に Mean squared error (MSE), Peak signal to noise ratio (PSNR), Structural similarity index (SSIM), Dice similarity coefficient (DSC) を用いて物理評価を行った。MSE (式-1) は、生成画像 ($\hat{y}_i$) とレファレンス画像 (y_i) の対応するピクセル値の二乗差の総計を全画素数で割った値で、値が小さいほど画像間のピクセル値が近似していることになる。扱う画像が 8 ビットの場合、MSE では最大 255×255 の値を取り評価しづらい値となる。そこで PSNR (式-2) では、R (255) で正規化することで容易に dB 値が大きいほど近似した画像として判断できる。MSE や PSNR では

画像間の対応する座標でのピクセル値の近似を求めて評価しているが、画像診断での視覚的評価とは一致しないケースも想定される。その点、SSIM (式-3-1) ではピクセル値、コントラスト、構造の変化を分散で評価可能であり、画像領域内での位置をずらしながら小領域ごとに算出し、最終的に画像全体の構造差を評価できることから視覚的評価に近い指標である。式-3-1 の μ_x と μ_y 、 σ_x と σ_y は、それぞれ画像の局所的な平均ピクセル値と標準偏差を、 σ_{xy} は共分散を示す。 C_1 と C_2 は、福井らの報告同様⁹⁾ に 8 ビットでの設定で用いられている $C_1 = 0.01 \times 2,562$ 、 $C_2 = 0.03 \times 2,562$ を採用した。Mean SSIM (MSSIM) は算出された小領域ごとの SSIM の画像全体の平均で式-3-2 として求められる。DSC (式-4) は 2 値化画像の形の一致を評価している。 N_x 、 N_y は 2 値化画像の評価対象領域の全ピクセル数、 $N_{(x \cap y)}$ は両画像が同一座標上に重なって存在するピクセル数を示す。以上の物理評価において、画像生成に不必要な脳実質外の領域は評価対象から外して指標値を算出すべきと考え、大津の二値化法¹⁰⁾ により評価対象領域を決定した。この手法は、分割後の各領域の強度分散 (σ_1^2 、 σ_2^2) を重み付けした和 (式-5) が最小になるように画像ごとに最適な閾値 (t) を決定する。また視覚的に SSIM を評価するために、小領域ごとの SSIM を画像化した独自の SSIM マップでも視覚的評価を加えた。

$$MSE = \frac{1}{n} \sum_{i=0}^n (\hat{y}_i - y_i)^2 \dots (1)$$

$$PSNR = 10 \log_{10} \left(\frac{R^2}{MSE} \right) \dots (2)$$

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \dots (3-1)$$

$$MSSIM = \frac{1}{n} \sum_{i=1}^n SSIM(x_i, y_i) \dots (3-2)$$

$$DSC = \frac{2 \times N_{(x \cap y)}}{N_x + N_y} \dots (4)$$

$$\sigma_w^2(t) = w_1(t)\sigma_1^2(t) + w_2(t)\sigma_2^2(t) \dots (5)$$

1-4. 統計画像による評価

¹²³I-IMP SPECT データは Three-dimensional stereotactic surface projections (3D-SSP)¹¹⁾ 解析を行い、健常者に対して血流低下領域を Z-score で脳表画像上に描出させて診断されるのが一般的となっている。そこで生成された PNG データを Dicom 形式に変換することで 3D-SSP 解析を行い、40min_S、

10min_S, fake_SからのZ-score mapで比較した。なお、PNGからDicomへ変換する際には、オリジナルDicom画像とPNGファイルの信号値の比率から算出した128倍を各ボクセル値に乗算することでDicom画像のカウントに近似させ、ヘッダ情報を付加した。Z-score mapは客観的評価が必要なためStereotactic extraction estimation (SEE) 解析¹²⁾を加えた。SEEはTalairach daemonを用い3D-SSPのZ-score mapの各pixelをTalairach脳座標図譜に合致した座標情報に落とし込むことで、Brodmann野の分類に合わせた絶対評価を可能としている。

2. 結果

各評価指標の結果をFig.2に示す。10min_Sとfake_SのMSE平均値と標準偏差はそれぞれ 540.79 ± 458.02 , 333.35 ± 309.1 , PSNR 22.00 ± 3.34 , 23.78 ± 2.56 , MSSIM 0.68 ± 0.10 , 0.73 ± 0.09 , DSC 0.92 ± 0.07 , 0.93 ± 0.06 で、各評価共にfake_Sでは対応のあるt検定で有意差をもって10min_Sより40min_Sに類似した。Fig.3にTest_dataからのpix2pix解析画像を、上段は異常所見なし (No abnormality : N.A), 中段が認知症 (Alzheimer's dementia : AD), 下段が脳血管障害 (Right internal artery stenosis : R.IC) の症例群からの各1症例を示す。N.Aについては、相対的血流低下領域を示すDe-

crease, 相対的血流増加領域を示すIncreaseで示す。ADとR.ICはDecreaseを比較表示した。症例の選択基準について、40min_Sの3D-SSPのみを参照し認知症や脳血管障害の血流低下領域が明確で、かつ基底核領域でのMSSIMが平均値より高値である症例を選択した。SSIMマップは、寒色 (青系) がSSIM低値, 暖色 (黄色系) が高値を示す。MSEは10min_Sで647.76, fake_Sで293.38とより低値に、PSNRはそれぞれ20.02, 23.46でfakeが高値になった。ADでMSEが914.17から395.17, PSNRが18.52から22.16, R.ICでMSE 749.42から237.19, PSNR 19.38から24.38となりN.Aと同じ変化を示した。MSSIMはN.Aで0.63から0.75へ、ADで0.63から0.73, R.ICで0.64から0.72となり全ての症例で高値に変化した。DSCについてはNAで0.96から0.97, AD 共に0.95, R.ICで0.94, 0.95であった。

Fig.4に、Fig.3での3症例について自施設で構築したノーマルデータベースで解析した3D-SSP Z-score mapとSEE解析の結果を示す。3D-SSPのZ-score mapは臨床診断に使用するスケールと同じく下限値1.0, 上限値5.0で表示、SEEはLobule (Level 3) で分類しExtent ratio (%) 表示している。N.Aでの10min_Sにおいて、Decreaseでは上下側頭回領域で15~20%, Increaseでは左右の前頭、側頭葉領域で15~55%のExtent ratioで描出を示すZ-score領域について、40min_Sで描出がなく、fake_Sでも描




Fig.2 The evaluation results of (a) MSE, (b) PSNR, (c) SSIM, and (d) DSC are shown in graphs.

By image generation, fake_S was rated higher than 10min_S with a significant difference in all evaluations.




Fig.3 The images show generated images and SSIM maps for three cases of no abnormality (Upper), Alzheimer's dementia (Middle), and right internal artery stenosis (Lower).

The SPECT images of each case shown in the figure are 40min_S, 10min_S, and fake_S in the same slice. The SSIM map shows 10min_S and fake_S of the same slice as SPECT.




Fig.4 Z-score map (e)(f)(g)(h) and SEE (i)(j)(k)(l) of the three cases in Fig.3.

(e)(i): The indication of low blood flow for N.A, (f)(j): The indication of increased blood flow for N.A,
(g)(k): The indication of low blood flow for AD, (h)(l): The indication of low blood flow for R.IC.

出されていない。AD症例では、全脳領域で40min_Sよりfake_Sが、さらには10min_SでのZ-score描出領域が広範囲となった。またfake_SではADの特異的血流低下領域である楔前部では50%のExtent ratioで描出を示したが、fake_Sでは描出できなかった(SEE⇒)。R.ICでは、左前頭領域で40min_Sで描出のないExtent ratio 20~50%のZ-score描出を認めた(SEE⇒)。

3. 考 察

量子ノイズが多く含まれる短時間収集でのSPECT画像では、深層学習での画質改善効果は最も期待した項目であり、MSEとPSNRの結果からは10min_Sに対してfake_Sでは有意差をもって画質が改善され、40min_Sにより近づいたと判断できる。Fig.3の症例画像からも、fake_Sでは10min_Sに対しノイズ低減が認められ物理評価と一致している。次に問題となるのが、生成画像とレファレンス画像の対応するボクセル間での信号情報の類似精度である。AIではSSIMの値から類似度を評価することが一般的であり、福井⁹⁾らは電子化文書の画像圧縮ガイドライン¹³⁾の指標値を参考にしている。ガイドラインでは文章ファイルを

画像化した際の値で評価しているが、PSNR 30~40 [dB], SSIM 0.90~0.98で「拡大すれば劣化が分かるレベル」、PSNR 30以下 [dB], MSSIM 0.90以下で「明らかに劣化が分かる」としている。fake_Sでは明らかに劣化が分かるレベルとなり満足のいく結果とはならなかった。Fig.2でのMSSIM低値を示す画像群を確認すると、放射性医薬品の取り込み量が少なく描出される脳実質面積の少ない頭蓋底断面の割合が多く、MSSIM 0.3~0.5の画像が大部分であることから評価値を低下させた一因と考えた。これらはMSEやPSNRにも大きく影響していることが予測され、今後は頭蓋底画像を除外しての評価も必要と考える。Fig.3 SSIMマップから、10min_Sに対し40min_SでMSSIMがN.A 16%, AD 13%, R.IC 11%と上昇を認め、マップからも寒色領域が少なくなった領域があり、部分的に類似度評価の画像化が可能であった。次に、Z-score mapでの全脳領域での類似度評価について、検証症例N.AのDecrease, Increaseでは40min_Sとfake_Sでは類似したZ-score mapとなり臨床診断が大きく異なることはないと思われるが、ADではfake_SのRt.LAT 楔前部領域での描出不良があり、ADでの特異的血流低下領域であることから診断結果に影響を与える。R.ICでも40min_Sで描出されていないLt.LAT

前頭領域の描出を認める。DSCについては2値化した画像間の類似度を評価するイメージであり、40min_S、10min_S、fake_Sで大きな差ではなく大津法での閾値設定が各評価指標算出に適していたと考える。最後に、pix2pixの画像生成は10min_Sの画質改善は可能であったが、短時間収集の脳血流分布から標準時間収集の脳血流分布を生成するのは難しいと考える。このことから、10minから収集時間を延長し脳実質領域各ボクセル間での相対的カウント比が40minにより近くなるような収集時間を求め、そのデータで学習させるなど検討する必要がある。

4. 結 語

人工知能による画像生成モデルpix2pixを用い、10分収集データの脳血流SPECT元画像から40分収集データの標準SPECT画像の生成を試みた。MSE、PSNR、MSSIM、DSCの物理評価から生成画像は元画像より画質改善の効果が得られた。3D-SSP解析からも元画像より生成画像の方がより標準画像に類似した。しかし、標準SPECT画像として臨床使用するレベルではなかった。

利益相反

筆頭著者および共著者に開示すべき利益相反はない。

図の説明

- Fig.1 Pix2pixのアーキテクチャーを示す。Generatorは10min_Sからfake_Sを生成する。Discriminatorは40min_Sを本物、fake_Sを偽物と判断できるように訓練する。GeneratorにはU-netを、DiscriminatorにはPatchGANを応用している。
- Fig.2 (a) MSE, (b) PSNR, (c) SSIM, (d) DSCの各評価結果をグラフで示す。画像生成によりfake_Sは、全ての評価で有意差を持って10min_Sより高評価となった。
- Fig.3 画像は、上段 異常所見なし (N.A)、中段 アルツハイマー型認知症 (AD)、下段 右内頸動脈狭窄 (R.IC) の3症例についての生成画像とSSIMマップを示す。各症例のSPECT画像は同一スライスでの左から40min_S、10min_S、fake_Sを示す。SSIMマップはSPECTと同一スライスから算出した10min_Sとfake_Sの結果を示す。

Fig.4 Fig.3で示した3症例のZ-score map (e) (f) (g) (h) とSEE (i) (j) (k) (l) を示す。
(e) (i) : N.A 相対的血流低下表示, (f) (j) : N.A 相対的血流増加表示, (g) (k) : AD 相対的血流低下表示, (h) (l) : R.IC 相対的血流低下表示。

参考文献

- 1) Nakamura Y, Narita K, Higaki T, et al.: Diagnostic value of deep learning reconstruction for radiation dose reduction at abdominal ultra-high-resolution CT. *Eur Radiol*, 31(7): 4700-9, 2021.
- 2) Njeh I, Mzoughi H, Ben Slima M, et al.: Deep Convolutional Encoder-Decoder algorithm for MRI brain reconstruction. *Med Biol Eng Comput*, 59(1): 85-106, 2021.
- 3) Kim M, Kim HS, Kim HJ, et al.: Thin-Slice Pituitary MRI with Deep Learning-based Reconstruction: Diagnostic Performance in a Postoperative Setting. *Radiology*, 298(1): 114-22, 2021.
- 4) Park CJ, Chen W, Pirasteh A, et al.: Initial Experience With Low-Dose 18F-Fluorodeoxyglucose Positron Emission Tomography/Magnetic Resonance Imaging With Deep Learning Enhancement. *J Comput Assist Tomogr*, 45(4): 637-42, 2021.
- 5) Okamoto K, Ushijima Y, Okumura C, et al.: Measurement of cerebral blood flow using graph plot analysis and I-123 iodoamphetamine. *Clin Nucl Med*, 27(3): 191-196, 2002.
- 6) 山本泰司, 小野口昌久, 和田昭彦, 他: ^{123}I -IMP Graph Plot法検査時間短縮プロトコルの検討. *日放技学誌*, 67 (5) : 524-33, 2011.
- 7) Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, et al.: Image-to-Image Translation with Conditional Adversarial Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1125-1134, 2017.
- 8) Diederik P. Kingma, Jimmy Ba: Adam: A Method for Stochastic Optimization. Published as a conference paper at ICLR, 2015.
- 9) 福井亮平, 藤井 進, 二宮宏樹, 他: 深層学習を用いたPET画像の減弱補正を目的とした疑似CT画像の作成. *日放技学誌*, 76 (11) : 1152-62, 2020.
- 10) Nobuyuki Otsu: A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1): 62-66, 1979.
- 11) Minoshima S, Frey KA, Koeppe RA, et al.: A diagnostic approach in Alzheimer's disease using three-dimensional stereotactic surface projections of fluorine-18-FDG PET. *J Nucl Med*, 36(7): 1238-48, 1995.
- 12) Mizumura S, Kumita S, Cho K, et al.: Development of quantitative analysis method for stereotactic brain image: assessment of reduced accumulation in extent and severity using anatomical segmentation. *Ann Nucl Med*, 17(4): 289-95, 2003.
- 13) 小箱雅彦: 標準化への道 標準化委員会報告 (3) 電子化文書の画像圧縮ガイドライン. *月刊IM*, 50 (5) : 21-24, 2011.