

[研究助成 (A)]

X 線検査における深層学習を用いた撮影技術に関する
最適化ツールの開発

Development of improvement for scan technique of X-ray with deep learning

2211019



研究代表者	札幌医科大学附属病院 放射線部	副部長	高 島 弘 幸
共同研究者	札幌医科大学附属病院 放射線部	主 査	中 西 光 広
		診療放射線 技師	今 村 壘
			赤 塚 吉 紘
			越 後 雷 蔵
			浦 瀧 夏 実
	札幌医科大学 医学部 整形外科科学講座	助 教	黄 金 勲 矢

[研究の目的]

今や医療の現場では、画像診断は欠かせないものとなっている。そのような中でも単純 X 線検査は、検診や日常診療で最も多く用いられている。単純 X 線検査は、診療放射線技師または医師、歯科医師が行っており、診断に関わる画像の質については撮影条件に依存する機械的な部分、ポジショニングなど人間の技術に依存する部分があり、どちらも適切な診断を行うためには必要不可欠である。前者は最近の技術開発により自動化されている部分があるが、後者は未だ個々の経験や技量に依存するところが多く、ポジショニングなどの影響により診断に必要な解剖学的構造が十分に描出されていない場合、それらを改善するために再撮影となることが多い。それは解剖学的な知識や経験をもとに画像を観察すれば、ほぼ適切に修正することが可能である。しかし、撮影者が被検者のポジショニングを行う際に実際に視るまたは触れることができるのは、被検者の体表のみであるこ

とがこれらを難しくする。本研究では、この個々の経験や技量の部分を deep learning で補い、人間の負担軽減、最終的には単純 X 線検査の半自動化を目指すためのプログラム開発を目的とした。

[研究の内容、成果]

本研究では、札幌医科大学附属病院で膝関節の CT が撮影された 179 例（右 109 例、左 110 例）を対象とした。なお、本研究は、札幌医科大学附属病院自主臨床研究として承認されている。

(1) データセットの作製

膝関節が撮影されている CT 画像を画像ワークステーションに取り込み、軸位、矢状、冠状断を同時に参照し、解剖学的基準点から正面像を定義した（図 1）。軸位断の基準線（x 軸）には、人工膝関節置換術において大腿骨コンポーネントの回旋設置位置の指標として用いら




図1 膝関節画像の作成方法および基準

れる外科的上顆軸 (surgical epicondylar axis: SEA) を用いた。SEA は大腿骨内上顆と外上顆を結ぶ線である。SEA からの垂線で顆間窩隆起中央を通る線を冠状断の基準軸 (y 軸) とした。矢状断の基準軸 (z 軸) は、内側の脛骨上面角に合わせ、関節間隙が最も広く描出される角度とした。また、y 軸に対して内旋、および z 軸に対して後傾 (X 線入射角が尾頭方向) をプラス方向と定義した。基準軸設定後、画像表示方法を ray summation (raysum) 処理することで 63 方向 (正面, y 軸に対し -20° から $+20^{\circ}$ まで, z 軸に対し -15° から $+15^{\circ}$ まで 5° ずつ変化させた方向) の仮想 X 線画像を作製した (図 2)。

作製画像は 2048×2048 pixels, portable network graphics (PNG) 形式で保存した。raysum 処理は、3D 画像データがある投影面から見たとき、その投影経路中の平均値を 2D 画像の信号値として表示する処理であり、X 線画像と類似した投影画像を得ることが可能である。

作製した raysum 画像のピクセルサイズを 64×64 pixels に変更し、左右反転・拡大処理




図2 CT データから作成した仮想 X 線画像

(100%, 150%, 200%)・回転処理 (0° , $\pm 3^{\circ}$, $\pm 6^{\circ}$) を加え、データ数を 30 倍に拡張した。

(2) ネットワーク構築

ハードウェア環境は CPU: Core i9-10980XE 3.00 GHz, GPU: NVIDIA GeForce RTX 3090, ソフトウェア環境は OS: Ubuntu20.04.4 LTS, フレームワーク: TensorFlow, Keras, Python 3.6 である。

上記のデータセットを用いて deep convolutional neural network (DCNN) による分類を行った。はじめから多くの角度を分類するネットワークを構築することは困難であるため、まずは正面、内旋 $10^{\circ} \cdot 20^{\circ}$ 、外旋 $10^{\circ} \cdot 20^{\circ}$ の 5 つの角度を分類するネットワークの構築を試みた。本研究では畳み込み層 4 層、プーリング層 2 層、全結合層 2 層からなるネットワークを用いた (表 1)。畳み込み層の活性化関数は rectified linear unit (ReLU) 関数、出力層は softmax 関数を使用した。拡張したデータのうち 2,850 枚 (570 枚/angle) を test 画像とし、残りの画像枚数の 75% である 22,500 枚 (4500 枚/angle) を training 画像、25% である 7,500 枚 (1,500 枚/angle) を validation 画像とした (表 2)。学習には training 画像を用い、1 回の学習ごとに validation 画像を用いて汎化性能を確認した。学習のエポック数は 50、バッチサイズは 128 とした。

表1 DCNN

Layer	Kernel size	Strides	Activation
Convolution	7×7	1×1	ReLU
Convolution	7×7	1×1	ReLU
Max pooling	2×2		
Dropout			
Convolution	3×3	1×1	ReLU
Convolution	3×3	1×1	ReLU
Max pooling	2×2		
Dropout			
Full connect			ReLU
Dropout			
Full connect			Softmax

表2 データセット

角度	元画像 [枚]	拡張後 [枚]	Test 画像 [枚]	Training 画像 [枚]	Validation 画像 [枚]
内旋 20°	219	6,570	570	4,500	1,500
内旋 10°	219	6,570	570	4,500	1,500
正面	219	6,570	570	4,500	1,500
外旋 10°	219	6,570	570	4,500	1,500
外旋 20°	219	6,570	570	4,500	1,500

(3) 分類精度評価

構築したネットワークを用いてテスト用画像を分類し, accuracy (式 1), recall (式 2, 3), precision (式 4, 5) を算出することで分類精度を評価した。本研究では多クラス分類を行ったため, accuracy に関してはテスト用画像全体の枚数に対する各クラスの true positive (TP) の和の割合を求めた。また, recall, precision に関してはある一つのクラスを positive, 他のクラスを negative として評価値を計算した後でそれらの平均値を求め, 全体の評価値とした。

$$Accuracy = \frac{\sum_{n=1}^5 TP_n}{\text{テスト用画像全体の枚数}} \quad (\text{式 1})$$

$$Recall_n = \frac{TP_n}{TP_n + FN_n} \quad (\text{式 2})$$

$$Recall = \frac{\sum_{n=1}^5 Recall_n}{5} \quad (\text{式 3})$$

$$Precision_n = \frac{TP_n}{TP_n + FP_n} \quad (\text{式 4})$$

$$Precision = \frac{\sum_{n=1}^5 Precision_n}{5} \quad (\text{式 5})$$

TP : True Positive

FN : False Negative

FP : False Positive

n : 分類クラス (1~5)

[結 果]

DCNN の学習により得られた学習曲線を図 3 に示す。Epoch 数が増えるごとに training, validation とともに accuracy が向上しており, 適切な学習が行われたことが確認できる。学習終了時点での training 画像および validation 画像に対する accuracy はそれぞれ 0.94, 0.94 であった。




図3 Epoch と Accuracy

学習済みのネットワークにテスト用画像を入力した時の混同行列を表 3 に示す。表 3 より, accuracy=0.81, recall=0.81, precision=0.81 と算出された。また, 角度ごとの recall, precision を表 4 に示す。表 4 より, 角度が大きくなるほど recall, precision とともに高値を示す傾向にあることが分かる。

表3 混同行列

		分類結果				
		内旋 20 度	内旋 10 度	正面	外旋 10 度	外旋 20 度
実際の 角度	内旋 20 度	536	34	0	0	0
	内旋 10 度	76	429	59	4	2
	正 面	0	85	410	74	1
	外旋 10 度	0	0	74	419	77
	外旋 20 度	0	0	0	62	508

表4 角度ごとの recall, precision

角 度	Recall	Precision
内旋 20 度	0.86	0.94
内旋 10 度	0.78	0.75
正 面	0.76	0.72
外旋 10 度	0.75	0.74
外旋 20 度	0.86	0.89

[今後の研究の方向, 課題]

今回の検討では, 学習時の accuracy は 0.94 と高い値が得られていたのに対してテスト画像の分類では accuracy は 0.81 と低い値になった。実用性を鑑みると accuracy をより向上させることが必要であるため, 今後 DCNN のパラメータの設定や学習時の交差検証などについて検討していかなければならないと考える。

また, 今回は5つの角度のみの分類を試みた

が, 膝関節の単純 X 線検査においては尾頭方向のずれも診断に直接関係する因子である。そのため, 今後は尾頭方向の分類についても検証を進めていく予定である。

[成果の発表, 論文等]

なし