

修士論文

大規模 CT 画像データベースにおける 骨盤形状パラメータの全自動計測

田中雄基

奈良先端科学技術大学院大学

先端科学技術研究科

データサイエンスプログラム

主指導教員: 佐藤 嘉伸 教授

生体医用画像研究室 (情報科学領域)

令和 2 年 3 月 13 日提出

本論文は奈良先端科学技術大学院大学先端科学技術研究科に
修士（工学）授与の要件として提出した修士論文である。

田中 雄基

審査委員：

佐藤 嘉伸 教授	（主指導教員, 情報科学領域）
金谷 重彦 教授	（副指導教員, 情報科学領域）
末次 志郎 教授	（副指導教員, バイオサイエンス領域）
大竹 義人 准教授	（副指導教員, 情報科学領域）
Mazen Soufi 助教	（副指導教員, 情報科学領域）
日朝 祐太 助教	（副指導教員, 情報科学領域）

大規模 CT 画像データベースにおける 骨盤形状パラメータの全自動計測*

田中 雄基

内容梗概

この論文では，大規模 CT 画像データベースにおける Convolutional Neural Network(CNN) を用いた解剖学的ランドマークの自動検出によって，特に骨盤の矢状面アライメントに関する骨盤形状パラメータの全自動計測方法を示す．本来 CNN が画像の特徴の位置に対してロバストであるがランドマーク検出では位置について敏感である必要があるため，改善したネットワークを提案する．大阪大学医学部附属病院で撮影された 100 症例の CT 画像で提案するネットワークの評価および訓練を行い，ランドマークの検出誤差の中央値が 2.36 mm であった．すべてのランドマークの 4 mm 以下での検出成功率は 83.4% であった．1 つの画像に対して 5 秒ですべての骨盤形状パラメータの計測をでき，臨床における骨盤形状パラメータの自動計測に対する有用性を示した．また，骨盤形状パラメータを解剖学ランドマークの自動検出によるアプローチによって 10000 症例を超える大規模 CT 画像データベースに対して適用を行い，最大のコホートによって得られる骨盤形状パラメータを報告する．骨盤の矢状面アライメントを定量化する Pelvic Incidence, Sacral Slope, Pelvic Tilt の平均値はそれぞれ男性で $50.99 \pm 10.78^\circ$ ， $40.76 \pm 10.16^\circ$ ， $10.23 \pm 5.84^\circ$ であり，女性では $52.80 \pm 10.59^\circ$ ， $40.43 \pm 9.95^\circ$ ， $12.38 \pm 6.57^\circ$ であった．提案されたアプローチは幅広い年齢層の大規模な CT 画像データベースに対して適用が可能であり，年齢と性別に関連した骨盤の矢状面アライメントの平均値を理解することが出来た．

キーワード

convolutional neural network, 骨盤形状パラメータ, 大規模 CT 画像データベース, 解剖学的ランドマーク

*奈良先端科学技術大学院大学 先端科学技術研究科 修士論文, 令和 2 年 3 月 13 日.

Automated Measurement of Pelvic Parameter in Large-scale CT Image Database*

Yuki Tanaka

Abstract

In this paper, I proposed an automated approach for measuring the pelvic parameters related to the sagittal pelvic alignment by using a convolutional neural network (CNN). Originally, CNN is translation-invariant with respect to the features; however, the landmark detection needs to be sensitive to the feature translation, which was not considered in baseline networks. Therefore, I proposed an improved network to address these issues. The proposed network was trained and evaluated on 100 CT images. The median landmark detection error was 2.36 mm. The 4-mm successful detection rate of the all landmarks was 83.4%. The calculation time of the pelvic parameters was approximately 5.0 s per image. Thus, the usefulness of the proposed approach for automatic measurement of pelvic parameter was showed. The proposed approach was also applied to a large-scale CT image database with more than 10,000 cases, and report the pelvic parameters. Pelvic Incidence, Sacral Slope, and Pelvic Tilt, which quantify pelvic sagittal alignment, averaged $50.99 \pm 10.78^\circ$, $40.76 \pm 10.16^\circ$, and $10.23 \pm 5.84^\circ$ for males, respectively. For females, the averages were $52.80 \pm 10.59^\circ$, $40.43 \pm 9.95^\circ$, and $12.38 \pm 6.57^\circ$, respectively. The proposed approach was applicable to the large-scale database from the general population with a wide age range, and provided an understanding of age- and gender-related mean pelvic sagittal alignment parameters.

Keywords:

convolutional neural network, pelvic parameter, large-scale CT image database, anatomical landmark

*Master's Thesis, Department of Information Science, Graduate School of Information Science, Nara Institute of Science and Technology, March 13, 2020.

目次

図目次		v
第 1 章	はじめに	1
第 2 章	骨盤の矢状面アライメント	3
2.0.1	解剖学的ランドマーク	4
2.0.2	解剖学的座標系	4
2.0.3	骨盤形状パラメータ	5
	Sacral Slope	6
	Pelvic Tilt	6
	Pelvic Incidence	6
第 3 章	方法	8
3.1	手法概要	9
3.1.1	scSE-UNet	9
3.2	学習方法	12
3.2.1	Gaussian Heatmaps	12
第 4 章	実験	17
4.1	データセット	17
4.1.1	片側変形性股関節症患者データセット	17
4.1.2	NII データセット	18
4.2	評価指標	18
4.2.1	Mean Radial Error	20
4.2.2	Successful Detection Rate	20
4.2.3	Mean Angle Error	20
4.3	実験内容	21
4.3.1	Training Procedure	21
4.3.2	Data preparation	22

4.3.3	scSE-UNet の精度評価	23
4.3.4	大規模データベースへの適用	23
4.4	実験結果	24
4.4.1	scSE-UNet の精度評価	25
4.4.2	NII データセット	27
第 5 章	考察	35
第 6 章	総括	37
	謝辞	38
	参考文献	39
	発表リスト	45

図目次

2.1	解剖学的平面の定義. 青い平面が冠状面 (Coronal), 赤い平面が矢状面 (Sagittal), 緑の平面が水平面 (Axial)	3
2.2	骨盤形状パラメータの計測に必要な 7 点の解剖学的ランドマーク.	5
2.3	解剖学的座標系の定義. (左)Coronal View(右)Sagittal View	6
2.4	骨盤の矢状面アライメントを定量化するパラメータ (Pelvic Incidence, Sagittal Slope, Pelvic Tilt).	7
3.1	提案手法の概要	9
3.2	CNN の概要図	10
3.3	concurrent spatial and channel Squeeze-and-Excitation blocks の概要図. (a)Fully CNN に組み込む位置. (b-d)scSE blockss の説明. [29]	11
3.4	2D の畳み込み層と CoordConv 層の比較. (左) 従来の畳み込み層は $H \times W \times C$ の特徴量から $H' \times W' \times C'$ の特徴量にマッピングする. (右)CoordConv 層は最初に座標のチャンネルを連結してからマッピングを行う. [18]	12
3.5	ヒートマップ画像の例. 各チャンネルの各ランドマークを中心としたガウス分布をプロットすることによって groundtruth のヒートマップが生成される. [40]	13
3.6	σ_i の違いによるヒートマップの例. (上) 小さい σ_i を選択した際のモデルの応答. σ_i が小さすぎるため, 複数のピークが検出されている. (中央) 適切な σ_i を選択した際のモデルの応答. (下) 大きい σ_i を選択した際のモデルの応答. σ_i が大きすぎるため過度に平滑化されている. ターゲット座標は赤色で示されており, 推論された座標は緑色で示されている. [25]	15
3.7	サブピクセルの定義.	16
4.1	NII データセットにおける症例数と年齢の分布	19

4.2	baseline となる UNet の構造.	24
4.3	ランドマークごとの radial error.	26
4.4	自動計測された骨盤形状パラメータの結果.	28
4.5	PI で 10 度以上の計測誤差を認める症例. 誤差が最も大きい症例 が #1 であり, #1, #2, #3, #5, #6 が仙骨癒合を認める症例. (中 央) 赤い球が医師によってラベル付された正解のランドマーク. 青 い球が提案手法によって推定されたランドマーク. (右) 解剖学的 ランドマークから計測された矢状面アライメントに関する骨盤形 状パラメータ.	31
4.6	整形外科医と提案手法によって推定された PI の Bland–Altman プロット. 2 つの計測値の差の平均 (実線) と平均 $\pm$ 1.96 標準偏 差 (SD) の水平線 (破線) がプロットされている.	32
4.7	年齢ごとの Pelvic Incidence の結果. 中央に症例数と中央値を示 す.	33
4.8	年齢ごとの Sacral Slope の結果. 中央に症例数と中央値を示す. . .	33
4.9	年齢ごとの Pelvic Tilt の結果. 中央に症例数と中央値を示す. . .	34

第 1 章 はじめに

人の姿勢を理解するために矢状面上の脊柱と骨盤のアライメントを把握することが重要である。立位姿勢の理想的なアライメントは重心線と同じとされており，このような立位姿勢は身体の各部位の負担が少なく，筋の収縮も必要最小限のため，エネルギー効率が最も優れた姿勢とされている。そのため，脊椎と骨頭を結ぶラインに位置する骨盤は体重の伝達を考える上で重要で，このアライメントに異常があると他の部位でバランスを取る必要が生まれる。結果的に脊椎全体のアライメントに異常をきたし，脊椎の各部位と重心線の位置関係を変化させるため，腰痛や変形性股関節症の原因になる。しかしながらこのアライメントは様々な因子が関係しており，まだその要因に関しては不明な点が多い。この要因の解明のため，骨盤の矢状面アライメントに関連する 3 つの骨盤形状パラメータ，Pelvic Incidence, Sacral Slope, Pelvic Tilt の解析が注目されている [8]。特に Pelvic Incidence は骨盤を基準とした仙骨の傾斜を表し，撮影時の患者の位置や方向に関係なく，各個人に固有な解剖学的尺度 [14] とされており，骨盤の解剖学的特性を表す固定の角度である [35, 30]。

このように上半身の荷重伝達を考える上で医学的に非常に重要な指標であることと容易に計測されることから最も広く使用される基準角になっており，一番多く解析されている因子である [37]。しかしながら，上記のような理由で様々な計測値が報告されているが，過去の論文の報告の結果にはばらつきがあり，計測値の変動の大きさ [34, 35] や人種間による差 [44] があり，また，その解析の規模も限られているため本邦に特化した研究は少ない。そのため日本人にはそのまま応用することが出来ない。そのため特に変形性股関節といったような疾患との関係を解析するためにこの Pelvic Incidence を代表とした骨盤形状パラメータの基準値を知ることが必要となる。また，過去数十年にわたり，医用画像を解析することはデジタルイメージング技術に爆発的な進歩によって大きく促進されている。しかし，医用画像を解析する従来の手法は膨大な量の画像データを利用することが難しく限られた成功しか収めていない。その理由の一つとして病院の画像アーカイブまたは通信システム (PACS) に保存されている医療画像は患者の情報，スキャンされた身体部位，FOV などのアノテーションが不足されているためであり，特に機械学習のアルゴリズム

を直接適用することは困難であるためである．そこで AMED が支援する医学系学術団体と国立情報学研究所 (NII) とが連携して構築している大規模 CT 画像データベースを使用する．これは日本の複数の病院の PACS から日常の業務で毎日取得される CT 画像を収集しているデータベースであり，2020 年 1 月現在で 30 万件以上のデータが含まれており，各データには複数の CT 画像と放射線レポートがある．以上から本研究では，大規模 CT 画像データベースを用いて，複数のスキャナー，多様な患者コホートから日本人の骨盤形状パラメータのバリエーションについて調べることを目的とする．

Vrotovec ら [37] によってレビューされた研究の殆どは PI を 2 次元矢状 X 線画像で計測しており，個々の脊椎機能を説明できておらず，矢状 X 線画像を用いて脊椎バランスを計測する方法は一貫していないことを指摘している．これは X 線画像を用いて計測する方法は観察者の経験と知識に依存しており，特に，矢状面の X 線画像から 2 つの大腿骨頭の中心を認識することは不可能であるとしている．Pelvic Incidence は解剖学的パラメータという特性から一般に仰臥位で撮影される 3 次元 CT 画像で計測することができる．したがって仙骨，骨盤および股関節の解剖学的構造と幾何学的関係は骨盤の矢状面アライメントのパラメータで定義することができ，よりよく観察することができることは明らかである．一方で大規模 CT 画像データベースへの適用の問題点として，大規模なデータベースで計測を行うにはコストと時間がかかってしまう．Pelvic Incidence を自動計測している手法はいくつか報告されている [38, 11, 4] がいずれも手動で定義されたポイントに基づいているため，完全に自動化されていない．そのため本研究では，3 次元 CT 画像を用いて PI を計測するのに必要な解剖学的ランドマークを自動で検出し，PI の完全自動計測を行う

本論文の構成は次の通りである．2 章では骨盤の矢状面アライメントを表す骨盤形状パラメータについて述べる，3 章では本研究の提案手法について述べる．4 章では，実験について述べる．5 章では，考察について述べる．最後に 6 章で，本研究の総括を述べる．

第 2 章 骨盤の矢状面アライメント

本研究における 3 つの基準平面を冠状面 (Coronal), 矢状面 (Sagittal), 水平面 (Axial) と定義する. 3 つの基準平面を図 2.1 に示す.




図 2.1 解剖学的平面の定義. 青い平面が冠状面 (Coronal), 赤い平面が矢状面 (Sagittal), 緑の平面が水平面 (Axial)

骨盤の矢状面アライメントは姿勢の平衡 [6] と脊椎のバランス [14] を維持するための基本メカニズムを表している. そのため, 脊柱疾患を解釈するために矢状面アライメントの影響は非常に重要である [28]. 2 次元矢状 X 線画像から正常および疾患の骨盤アライメントを評価するための多くの方法が開発されている. その中でも Pelvic Incidence(PI) は骨盤の矢状面アライメントを表す最も重要なパラメータの 1 つであり, Vrtovec ら [37] の調査によると脊柱に関するパラメータの中で, 最も研究されている解剖学的パラメータ (71%) である. これは PI が骨盤の矢状面アライメントを表すパラメータである Sagittal Slope(SS) と Pelvic Tilt(PT) の合計値であるためと考えられる. PI は股関節軸 (両方の大腿骨頭の中心のを結んだ線) の中点と矢状面から観察したときの仙骨上面の中心を結ぶ線との間の角度で表される. PI は大腿骨頭に対する仙骨終板の相対的な位置であるため矢状面における骨盤の解剖学的特徴と仙骨に乗っている腰椎のバランスを説明しており, 患者個人特有の指標とされ, 注目されている [6, 14, 28, 37]. 骨盤の矢状面アライメントの定

量的評価は、腰骨盤領域の二次元矢状 X 線画像で行われる。仙骨と腸骨の動きは比較的小さいため、既存のアプローチはすべて仙腸関節の動きを考慮していない。骨盤の矢状面アライメントを定義するための骨盤形状パラメータは一般に 2 次元矢状 X 線画像で評価され Vrtovec ら [37] によると次の 2 つのグループに分類できる。

- Positional Parameter

Positional Parameter は CT 画像の座標系によって定義されるパラメータを示し、観察対象の位置と方向に関連する水平および垂直の基準線で表される。これは各被験者ごとによって位置や方向が異なるため、単純にパラメータを比較することは困難である。

- Anatomic Parameter

Anatomic Parameter は解剖学的に関連する基準線によって表される身体座標系によって定義されるパラメータを示す。これらは被験者の位置と方向に対して依存しないため、被験者間で比較することを可能とし、立位、座位、仰臥位で評価することができる。

2.0.1 解剖学的ランドマーク

本研究で計測するパラメータを計測するためには基準となる座標系 (解剖学的座標系) と計測に必要なランドマークが必要である。基準となる座標系に必要な解剖学的ランドマークは両上全腸骨棘, 恥骨結合の 3 点であり, パラメータを計測するために必要な解剖学的ランドマークは両骨頭中心, 仙骨上面最前縁点, 仙骨上面最後縁点の 4 点であり, 合計 7 点のランドマークが必要である。計測に必要な 7 点のランドマークを図 2.2 に示す。

2.0.2 解剖学的座標系

骨盤形状パラメータを計測する際に、症例間での位置や方向に左右されないよう解剖学的座標系を定義することで空間的に正規化を行う。本研究で扱う骨盤の解剖学的座標系の定義は Lewinnek ら [16] によって提案された前骨盤平面 (APP:




図 2.2 骨盤形状パラメータの計測に必要な 7 点の解剖学的ランドマーク.

Anterior Pelvic Plane) を基準とする骨盤解剖学的座標系を用いる．図 2.3 に解剖学的座標系を示す．パラメータの計測には CT 矢状断面への投影点，かつ，解剖学的座標系を用いての計測を行う．解剖学的座標系は X 軸が左右方向，Y 軸が前後方向，Z 軸が頭尾方向とする．左右上前腸骨棘と恥骨結合を含む平面の前骨盤平面 (APP: Anterior Pelvic Plane) を XZ 平面として設定する．左右上前腸骨棘を結ぶ軸を X 軸とする．恥骨結合を APP に投影した点を座標系の原点とする．APP 上で X 軸に垂直である軸を Z 軸とする．上記で得られた X 軸と Z 軸から求められる軸を Y 軸とする．

2.0.3 骨盤形状パラメータ

本研究では骨盤の矢状面アライメントを定量化するパラメータである Pelvic Incidence(PI), Sagittal Slope(SS), Pelvic Tilt(PT) の 3 つの角度を扱う．骨盤の矢状面アライメントのパラメータを図 2.4 に示す．SS と PT は一般的に 2 次元 X 線画像で検査される際に被験者の位置や方向の影響を受けるため Positional Parameter であるが，本研究では Imai[9] らと同様に Anterior Pelvic Plane(APP) が 0 度になるように修正するため Anatomic Parameter とみなす．




図 2.3 解剖学的座標系の定義. (左)Coronal View(右)Sagittal View

Sacral Slope

SS(Sacral Slope) は仙骨上縁の傾きを示す指標であり，仙骨椎体上面と仙骨椎体上面後方点からの水平線のなす角によって定義される．

Pelvic Tilt

PT(Pelvic Tilt) は大腿骨頭を中心とした骨盤の回旋角度を示す指標であり，仙骨上面の midpoint と骨頭中心を結んだ線と骨頭中心からの垂線のなす角によって定義される．骨盤が大腿骨頭に対して後方に回転 (後傾) すると PT は低下し，前方に回転している場合は PT は増加する．

Pelvic Incidence

PI の角度は仙骨上面の傾斜に直行する線と仙骨上面の中心を通る線との成す角で定義される．したがって 4 つの解剖学的基準，左大腿骨頭の中心，右大腿骨頭の中心，仙骨上面の前端，仙骨上面の後端から決定することができる．大腿骨頭の中心は股関節軸を形成し，2 次元画像の場合はその中心点を利用する．3 次元の仙骨上面の正確な中心は仙骨上面を L5 椎体の下に配置し，前端と後端の間，および右端と左端の間の線の中点を見つけることによって自動的に決定される．最後に PI




図 2.4 骨盤の矢状面アライメントを定量化するパラメータ (Pelvic Incidence, Sagittal Slope, Pelvic Tilt).

は仙骨上面の傾斜に直行する線と仙骨上面の中心と股関節軸を結ぶ線との成す角度として自動的に計算される。

第 3 章 方法

本研究では骨盤形状パラメータの自動推定にディープラーニングモデルを使用することを提案する。ディープラーニングモデルの 1 つとして Convolutional Neural Network(CNN) がある。CNN は画像分類タスクで従来の画像処理アルゴリズムよりも優れていることがわかったため、2012 年から注目を集めている [12]。それ以来、CNN は医療画像分析においてもますます使用されている [17, 31]。CNN は主に畳み込み層を積むことによって構成されており、画像の低レベルから高レベルの特徴を取得するために設計された一連の学習可能な特徴抽出器である。一般に物体の色やさまざまな方向のエッジなどの基本的な画像の特徴は浅い畳み込み層によって学習される。一方、物体の外観などの複雑な特徴は深い畳み込み層によって学習される。したがって十分に訓練された CNN は解剖学的ランドマークの自動検出のタスクに有用である。解剖学的ランドマークの自動検出はセグメンテーションの前処理や術前計画での利用などの臨床での用途として重要である。医療画像におけるランドマークの検出では 3 次元データでの解析が必要であることが多く、深層学習を用いていくつかのアプローチが提案されている。Yang ら [42] の研究では大腿骨遠位端上のランドマーク検出を行っており、CNN で 2 次元の MRI のスライス各平面 1 つずつの独立した 3 つのセットに分割して処理を行うことでランドマークの 3 次元上の位置の検出を行っている。また、Payer ら [24] はネットワークの学習方法を改善しており、既存の研究ではランドマークの座標を直接回帰していたが、これは画像から座標へと高度に非線形な変換を行うため学習が困難である。そこで、ランドマークの解剖学的ランドマークを中心としたガウス分布によって作成されたヒートマップ画像を推定するアプローチを取っており、既存の座標を直接回帰する手法よりも高い精度でランドマークを検出していることを示しており、CNN を使用した解剖学的ランドマークの自動検出は一般的に良好な結果が得られていると考えられる。

以上から本研究では CNN を用いてランドマークの自動検出を行う。以下では提案手法の流れについて説明する。




図 3.1 提案手法の概要

3.1 手法概要

本研究で提案する手法の概要を図 3.1 に示す。Training Phase では CNN を用いたランドマーク自動検出器を作成し、Inference Phase では未知の CT 画像を CNN に与える。次に得られたヒートマップ画像からランドマークの候補点を自動抽出し、骨盤形状パラメータを自動計測する。

3.1.1 scSE-UNet

本研究で提案する CNN の概要図を図 3.2 に示す。本研究では 3 次元 CT 画像で骨盤形状パラメータを計測するための解剖学的ランドマークの自動検出を行い、提案手法である scSE-UNet の性能を調査した。UNet は CNN の一種のアーキテクチャである。UNet は Ronneberger ら [26] によって提案された深い層によって生成された特徴と浅い層によって生成された大局的な位置情報を組み合わせることによって性能を改善したネットワークである。特にこのネットワークの構造は医療画像解析において最も一般的なアーキテクチャである。そのため、本研究では UNet をベースとする。UNet をベースとしたアーキテクチャではダウンサンプリングの繰り返しによって構成されているエンコーダとアップサンプリングの繰り返




図 3.2 CNN の概要図

しによって構成されているデコーダによって構成されている。UNet のメリットとして、セグメンテーション精度が高いこと、畳み込み層だけで構成されているため計算速度が速いこと、また構造がシンプルのため理解がしやすいことが挙げられる。デメリットでは、エンコーダーでは pooling 層によってダウンサンプリングを行うので、細かい位置情報が有失してしまうこと、デコーダーではアップサンプリング後に連結して畳み込みを行うため、メモリが大幅に必要なことが挙げられる。理想的には pooling 層を取り除き高い空間解像度維持したまま畳み込み処理を行う必要があるが、畳み込みの処理は狭い範囲で限られた処理であるため、pooling 層のない UNet は画像内の全体的な特徴を学習できない。そこでネットワークが効率良くランドマークを検出できるようにいくつかの修正を加える。まず最初にエンコーダーとデコーダーの各ブロックの後に concurrent spatial and channel Squeeze-and-Excitation(scSE) blocks[29] を追加する。scSE blocks は図 3.3 で示されるようにアテンション機構の一種であり、有益な情報の重要性を高めつつ、関

連性の低い情報を抑制することで、個々の次元を効率化し、ネットワークが深くなることによって生じるパフォーマンスの低下を避けることが可能になる。Roy ら [29] の実験では scSE を使った場合 UNet と比べて計算量が 1.5% 程度の増加で済んでいる。




図 3.3 concurrent spatial and channel Squeeze-and-Excitation blocks の概要図. (a)Fully CNN に組み込む位置. (b-d)scSE blockss の説明. [29]

従来の畳み込み演算は位置情報の変化にロバストであるため、画像分類などの一部のタスクに適しているが本研究のランドマーク検出ではこの位置に敏感なモデルである必要がある。そこで Liu ら [18] によって提案された畳み込み演算に正規化されたピクセル座標を連結させる CoordConv と呼ばれる手法を取り入れる。ピクセル座標を含む入力と同じ空間サイズのテンソルを作成し、 $[-1, 1]$ に正規化する。このテンソルを入力に連結し次のレイヤーに渡される。これによって従来の CNN モデルに空間把握機能を追加させることができる。元の特徴テンソルが $H \times W \times C$ の場合、新しいテンソルのサイズは $H \times W \times (C + 2)$ となり、最後の 2 つのチャンネルは x-y ピクセル座標になる。

この研究では scSE-UNet な 3 次元 CT 画像に適用する。既存の手法と比べて異なるのは画像をパッチに分割しないことである。これは前処理と後処理のステップ




図 3.4 2D の畳み込み層と CoordConv 層の比較. (左) 従来の畳み込み層は $H \times W \times C$ の特徴量から $H' \times W' \times C'$ の特徴量にマッピングする. (右) CoordConv 層は最初に座標のチャンネルを連結してからマッピングを行う. [18]

が増えてしまうことと, 1 症例分を作成するのに複数回推論する必要があるためである. そのため画像のサイズをダウンサンプリングし後処理として, ランドマークの座標だけを Rescale した.

このアーキテクチャの欠点は, パッチを適用しなかった場合, 画像のサイズが大きくなってしまい GPU の RAM が不十分になることである. また, UNet と比べて scSE blocks や CoordConv などの層を追加しているためモデルのパラメータの数が多くなってしまうため推論時間が遅くなることである.

3.2 学習方法

3.2.1 Gaussian Heatmaps

ランドマークの座標を直接回帰する CNN では画像から座標へと高度に非線形な変換を行うモデルなため多くのネットワークのパラメータが必要であり学習が困難である. 本研究ではヒートマップ画像を推定する手法に基づいており, これは入力として与えられた画像に対応したヒートマップ画像を生成するため画像から

画像の変換である．したがって UNet のような完全畳込みネットワークに基づくためネットワークの重みの一人計算の複雑さを軽減させることができる．Gaussian Heatmap は N をランドマークの総数とすると，目的とする座標値 $\hat{x}_i$ を持つランドマーク $L_i, i = \{1, \dots, N\}$ の d 次元ヒートマップ画像 $G_i(\mathbf{x}; \sigma_i)$ は式 (3.2.1) のように定義される．

$$G_i(\mathbf{x}; \sigma_i) = \frac{1}{(2\pi)^{d/2} \sigma_i} \exp \left(-\frac{\|\mathbf{x} - \hat{\mathbf{x}}_i\|^2}{2\sigma_i^2} \right) \quad (3.2.1)$$

σ はガウスの幅を制御するパラメータである． σ の値は広いガウス分布がランドマークの位置の予測に高い不確実性をもたらす可能性があるため，なるべく小さい値を設定する必要がある．ただし，シグマが小さすぎる場合，ランドマークより外側にある領域のほとんどの位置で 0 を予測する可能性がある．ヒートマップの例を図 3.5 に示す．




図 3.5 ヒートマップ画像の例．各チャンネルの各ランドマークを中心としたガウス分布をプロットすることによって groundtruth のヒートマップが生成される．[40]

本研究では，Payer ら [25] の手法から σ_i を訓練可能な未知のパラメータとして扱い，CNN のトレーニング中にネットワークの予測信頼度に応じてランドマークごとに最適なヒートマップのピーク幅 (σ_i) を学習させる．しかしながら Payer ら

の損失関数では Mean Square Error(MSE) のような値域に影響しない損失関数と同時に使用することが前提になっている．MSE は値域に影響しないことから小さなエラーに敏感ではないこと，低品質なヒートマップが推定された際に前景のヒートマップが低くぼやけて膨張される傾向があることが挙げられる．また L1 Loss では勾配が一定値であるため，小さな誤差のピクセルは大きな誤差のピクセルと同じ影響を与えるがゼロ点で連続的ではない．つまり収束のために正のエラーがあるピクセルの量と負のエラーがある量とが正確に等しくなければならない．このような微妙なバランスを克服することが難しいため，トレーニングプロセスが不安定になり振動する可能性がある．そのため本研究では値域の範囲が決まっており，かつゼロ点で連続的な CrossEntropyLoss をベースとして σ_i を適応的に学習する損失関数を提案する．提案する損失関数を式 (3.2.2) に定義する．

$$Loss = \min_{\mathbf{w}, \mathbf{b}, \sigma} \sum_{i=1}^N \sum_{\mathbf{x}} E(h_i(\mathbf{x}; \mathbf{w}, \mathbf{b}), \mathbf{G}_i(\mathbf{x}; \sigma_i)) + \frac{\alpha}{\|\sigma\|_2} \quad (3.2.2)$$

ここで E は CrossEntropyLoss をベースとした損失関数である． $h_i(\mathbf{x}; \mathbf{w}, \mathbf{b})$ はネットワークの出力であるランドマーク L_i すべての予測ヒートマップである． $\sigma = (\sigma_1, \dots, \sigma_N)^T$ は学習可能なネットワークパラメータである．係数 α はヒートマップのピーク幅に対する正則化項であり，ペナルティを与える度合いを示す．1 項目は σ_i が小さくなるように学習させるが，2 項目では σ_i が可能な限り大きくなるように促す作用をしている．これによってネットワークはランドマークを検出するための最適なピーク幅を決定することができ，予測が正しいと確信しているランドマークでは狭いピーク幅を予測し，正確に予測することが難しいヒートマップに対してはより不確実なランドマークとして広いピーク幅を予測する．

この損失関数は Payer ら [25] の Loss 関数を CrossEntropyLoss で学習するように拡張したものである．この目的関数はネットワークの予測信頼度に応じて，各ランドマークの最適なヒートマップの σ を個別に学習することができる．つまり，図 3.2.1 に示されているように，ネットワークの予測で確信度の高いランドマークではヒートマップのピーク幅を狭く予測し，より不確実なランドマークに対しては広いピーク幅によって予測する．また過度に小さいピーク幅ではネットワークがヒートマップを誤検出してしまい，複数のピークが検出されている．

この作業ではすべてのランドマークは各々のヒートマップによって推測される．




図 3.6 σ_i の違いによるヒートマップの例. (上) 小さい σ_i を選択した際のモデルの応答. σ_i が小さすぎるため, 複数のピークが検出されている. (中央) 適切な σ_i を選択した際のモデルの応答. (下) 大きい σ_i を選択した際のモデルの応答. σ_i が大きすぎるため過度に平滑化されている. ターゲット座標は赤色で示されており, 推論された座標は緑色で示されている. [25]

各ヒートマップの最大値位置はサブピクセル精度で計算される. ヒートマップの最大位置に対応する点をランドマークの推定位置とみなすと解像度の影響を受けてしまう. そこで図 3.7 に示すように最大位置の前後のピクセルを参照してサブピクセル精度まで特徴位置を推定する. 本研究では argmax によって得られた最大位置の近傍 1 ボクセル上で 3 次元のガウスフィッティングを行いランドマークの推定を行う.




図 3.7 サブピクセルの定義.

第 4 章 実験

以下に実験の流れを示す.

- 入力画像の前処理
- scSE-UNet でランドマークの自動検出
- 骨盤形状パラメータの計測
- 精度評価

4.1 データセット

本研究で扱うデータセットは二種類ある. モデルを評価, 学習するためのデータセットと大規模な医用画像データセットである.

4.1.1 片側変形性股関節症患者データセット

本研究では, 大阪大学医学部附属病院で撮影された骨頭の変形が著しくない片側変形性股関節症患者 100 例 (女性被験者 74 例, 男性被験者 26 例) を対象として CNN を学習する. 仰臥位 CT 画像に対して経験豊富な一人の整形外科医によって手動で 7 点のランドマーク (両上全腸骨棘, 両骨頭中心, 仙骨上面最前縁点, 仙骨上面最後縁点, 恥骨結合) を作成し, 骨盤形状パラメータの手動計測を行った. 表 4.1 にデータセットの詳細を示す. この内 13 症例は身長と体重の情報が取得することが出来なかった.

100 症例のランドマークの位置を CNN3 章によって学習を行う. 矢状面骨盤アライメントである Pelvic Incidence(PI), Pelvic Tilt(PT), Sacral Slope(SS) を自動で計測する. 同じ症例を用いて 4-fold 交差検証によってそれぞれの矢状面骨盤アライメントの計測精度を検証する.

表 4.1 片側変形性股関節症患者データセット

	mean	range	std	median
Age	59.0	15.0-86.0	14.3	60.5
Height [cm]	157.6	144.0-182.0	8.5	155.0
Width [cm]	59.5	36.7-95.0	12.8	57.0
PI [°]	54.1	31.7-83.6	10.6	52.2
SS [°]	38.5	23.4-58.1	7.8	37.9
PT [°]	15.7	0.0-38.2	7.0	15.7

4.1.2 NII データセット

本研究で提案する手法を大規模な CT 画像データベースに適用することで矢状面骨盤アライメントの統計解析を目的とする。本研究では国立研究開発法人日本医療研究開発機構 (AMED) が支援する医学系学術団体と国立情報学研究所 (NII) とが連携して構築している医療画像ビッグデータベースを使用する。これは日本の複数の病院の PACS から日常の業務で毎日取得される CT 画像を収集しているデータベースであり、2020 年 1 月現在で 30 万件以上のデータが含まれており、各データには複数の CT 画像と放射線レポートがある。Otake ら [22] によって収集された CT 画像の中から股関節領域を自動抽出された 12522 症例に対して矢状面骨盤アライメントを自動計測する。得られた 12522 人の被験者 (平均年齢: 64 歳; SD: 14 歳; 範囲: 21-99 歳) は、年齢別に 9 つのグループ (10 歳ごとに 20-89 歳) および性別に従って 2 つのグループ (男性被験者: 6762 人; 女性被験者: 5760 人) に分けた。各年齢層の詳細な分布は図 4.1 と表 4.2 に示す。

4.2 評価指標

ランドマーク検出のパフォーマンスは検出の精度とランドマークの誤認に対する堅牢性の両方の観点から評価される。本研究では、過去の文献を参考に [39, 25, 42, 24, 41] を参考にランドマークの MRE (Mean Radial Error; 平均半径誤差) とランドマークの SDR (Successful Detection Rate; 検出率) を使用して評価




図 4.1 NII データセットにおける症例数と年齢の分布

表 4.2 NII データセット

	Total	Male	Female
Number of patients	12522	6762	5760
Age strata (years)			
≤49	2119	759	1360
50-59	2018	998	1020
60-69	3182	1879	1303
70-79	3562	2204	1358
80+	1641	922	719

する。

4.2.1 Mean Radial Error

Radial error R は式 (4.2.1) として定義される．ここで Δx , Δy , Δz はそれぞれ x 軸, y 軸, z 軸の予測と正解のランドマーク間の絶対誤差を示す．

$$R = \sqrt{\Delta x^2 + \Delta y^2 + \Delta z^2} \quad (4.2.1)$$

MRE とその標準偏差 (SD) は以下のように定義される．ここで N はランドマークの総数である．

$$MRE = \frac{\sum_{i=1}^N R_i}{N} \quad (4.2.2)$$

$$STD = \sqrt{\frac{\sum_{i=1}^N (R_i - MRE)^2}{N - 1}} \quad (4.2.3)$$

4.2.2 Successful Detection Rate

Successful Detection Rate(SDR) は検出されたランドマークが正解のランドマークよりも z mm (ここで $z = 2, 2.5, 3, 4$) 以下の場合, このランドマークは検出が成功したとみなし, そうでなければ誤検出であるとみなす指標である． z mm 以下の SDR は式 (4.2.4) によって定義される．ここで N_a は正確に検出されたランドマークの数であり, N はランドマークの総数である．

$$SDR = \frac{N_a}{N} * 100\% \quad (4.2.4)$$

4.2.3 Mean Angle Error

検出されたランドマークから矢状面アライメントを定量化する骨盤形状パラメータを計測しており, 本研究では重要な意味を持つ [34, 19, 3, 27, 37, 1, 43, 9]. 骨盤形状パラメータは本研究ではいずれも角度によって定義されているため, Mean Angle Error(MAE: 平均角度誤差) を計測して評価する．Mean Angle Error は式 (4.2.5) によって定義される．ここで $Angle_t$ は医師によってアノテーションされ

たランドマークによって計算された骨盤形状パラメータである PI, SS, PT の角度, $Angle_y$ は CNN によって推論されたランドマークによって計算された角度である.

$$MAE = \frac{\sum_{i=1}^n \Delta Angle_n}{n} \quad (4.2.5)$$

4.3 実験内容

本研究では次の実験が実行および評価される.

1. scSE-UNet の精度評価

この実験では提案手法の有効性を検証するために 4-fold 交差検証を行う. ベースとなる UNet と比較して本提案手法がどの程度パフォーマンスを向上させているかを確認する.

2. 大規模 CT 画像データベースへの適用

大規模 CT 画像データベースへ本提案手法を適用して自動的に矢状面アライメントを定量化する骨盤形状パラメータを計測する. この実験で計測された Parameter から既存の研究結果と比較を行う.

4.3.1 Training Procedure

1 つの GPU(NVIDIA GTX1080Ti) によってトレーニングされ, バッチサイズは 2 に設定した. 損失関数として Cross Entropy Loss または Adaptive Sigma Loss を選択した. また, Adam[10] を使用して最適化を行った. トレーニング中, 学習率は 0.001 に設定され, validation loss が 40epoch 間減少しなければ 0.1 の係数分減少させることにした. トレーニングに使用する epoch 数は 1000 に設定され, 最終モデルは検証データで最高のパフォーマンス (最低の loss 値) を発揮したチェックポイントから選ばれた. モデルの構築とトレーニングには Pytorch[23] を使用した.

4.3.2 Data preparation

ネットワークをトレーニングするために対応するランドマーク位置を含む 3 次元 CT 画像のデータセットが必要である，男性患者と女性患者合わせて 100 の CT で 7 つのランドマークを経験のある医師によって手動でラベル付けされた．ランドマークの位置はいずれも骨盤形状パラメータの計測に必要なもので，投影画像で解剖学的に一貫して識別できるように選択されている．

ネットワークの入力画像の前処理は次のように実行される．データセットのすべての画像についてネットワークの入力画像と出力ヒートマップ画像のサイズをピクセル単位で一定に保つ．入力画像はネットワークの入力に合わせてアスペクト比を固定したまま再スケーリングされる．リサンプリングでは bi/trilinear 補間を使用する．学習データはすべて $128 \times 128 \times 128$ の等ピクセルにダウンサンプリングする．片側変形性股関節症患者データセットでのダウンサンプリング後の画像の解像度は $[2.8125 - 3.125, 2.8125 - 3.125, 2.0]$ であった．各データセットの画素範囲は $-1024 \sim 4000$ のハウズフィールド単位 (HU) である． -1024 HU 未満の値は実際には撮像されなかった視野外の画像の領域である．通常関心のあるデータ範囲に絞って画像処理を行う．本研究では骨盤領域を対象にしているため， $-150 - 350$ HU の範囲の画素を扱う．そのため階調処理を行い， $[0, 1]$ に線形に補間する．データセットのサイズとデータセットの variance を増強させるためにデータセットの拡張を行う．事前に y-z 平面を対称としたフリップ処理を適用した．一人の患者の画像が train valid test のセット間で共有されないことが保証されている．また，訓練中にオンザフライでデータを増強させる．画像は $[-25, 25]$ mm だけランダムに平行移動され，x 軸中心に $[-30, 30]$ 度，y 軸中心に $[-15, 15]$ 度，z 軸中心に $[-15, 15]$ 度回転され， $[0.8, 1.2]$ だけスケーリングされる．すべての Augmentation は一様分布からランダムにサンプリングされている．これらのパラメータはデータセット内のランドマークの分布を参考に手動で設定された．データセットを拡張するための処理は入力画像とランドマークと両方に適用する．ネットワークの重みは標準偏差 0.001 のガウス分布によって初期化する．これは小さい重みでないとネットワークが収束しないためであり，0 に近い初期ヒートマップを生成させるために必要である．

4.3.3 scSE-UNet の精度評価

本研究で提案する scSE-UNet の有効性を検証する．本研究ではネットワークの構造，CoordConv の導入，scSE blocks の導入，CrossEntropyLoss をベースとした損失関数 (以後 Adaptive Sigma Loss とする．) を提案する．そこで以下の 4 項目について比較の実験を行い，それぞれについて精度が向上しているか検討する．

1. UNet (baseline)

baseline となる UNet の構造を図 4.2 に示す．これはセグメンテーションやランドマーク推定において一般的に [26, 24, 25, 17, 31] 使用されている UNet の構造であり，この構造を比較対象のベースラインとする．

2. UNet (proposed architecture)

本研究で提案する scSE-UNet の構造を用いた UNet であり，CoordConv と scSE blocks を使用しないネットワークである．

3. UNet + CoordConv

2.UNet (proposed architecture) における $3 \times 3 \times 3$ Conv を CoordConv に置き換えたネットワークである．

4. scSE-UNet + CoordConv

3.UNet + CoordConv に scSE blocks を取り込んだネットワークである．

5. scSE-UNet + CoordConv + Adaptive Sigma Loss

本研究で提案するネットワーク (3.1.1 章) である．

4.3.4 大規模データベースへの適用

大規模な CT 画像データベースに対して本研究の手法を適用する．得られたランドマークから自動的に骨盤形状パラメータを計測を行う．計測された骨盤形状パラメータは被験者の年齢と性別に従って並べられ，平均，標準偏差 (SD)，95% 信頼区間 (CI) の観点から分析される．




図 4.2 baseline となる UNet の構造.

4.4 実験結果

結果では 2 つのセクションに分割されている，第一に医師によってラベル付けされた 100 症例での 4-fold 交差検証の結果，第二に 100 症例をすべて学習させたモデルによって NII データセットに適用した結果を示す．この目的のためにネットワークが再トレーニングされているがハイパーパラメータの変更は行われてはいない．どちらの場合も結果は定性的または定量的に示している．各ランドマークの絶

対誤差を使用してモデルのパフォーマンスを評価した。ピクセルの誤差を計算するためにランドマークの予測位置を元の画像の解像度 (resize や padding されていない) に変換し、真のランドマークと予測ランドマークの位置を使用して誤差を計算した。次に画像の解像度を使用してピクセル誤差を mm に変換した。

4.4.1 scSE-UNet の精度評価

片側変形性股関節症 100 症例での 4-fold 交差検証の結果を図 4.3 と表 4.3 に示す。UNet(baseline), UNet(proposed architecture), UNet + CC, scSE-UNet + CC, scSE-UNet + CC + ASLoss(提案手法) の MRE はそれぞれ 3.25, 3.28, 3.13, 3.05, 3.04 であった。いくつかのランドマークは全体的に低いエラー (例えば恥骨結合では 2.17 mm の誤差) であるが、他のものは不十分 (例えば仙骨上面最前縁点では 2.94 mm であり、恥骨結合との平均誤差の差は 0.87 mm である) に検出されている。不十分に検出されている部位はいずれも仙骨上に位置するランドマークであり、仙骨上のランドマークの検出が寛骨や大腿骨のランドマークと比較して検出が難しいことを示している。




図 4.3 ランドマークごとの radial error.

また、自動検出された解剖的ランドマークを元に骨盤形状パラメータの自動計測の角度誤差の結果を図 4.4 と表 4.4 に示す．提案手法での PI の平均値は $53.75 \pm 8.85^\circ$ ，SS の平均値は $38.55 \pm 6.95^\circ$ ，PT の平均値は $15.10 \pm 6.60^\circ$ であった．手動での計測値の PI, SS, PT の平均値はそれぞれ $54.18 \pm 10.64^\circ$ ， $38.51 \pm 7.78^\circ$ ， $15.67 \pm 7.02^\circ$ であった．提案手法と手動での絶対誤差平均は PI, SS, PT のそれぞれ $3.49 \pm 4.41^\circ$ ， $3.23 \pm 3.10^\circ$ ， $1.48 \pm 2.58^\circ$ であった．PI が 10 度以上の計測誤差を認める症例は 6 症例で，その内 5 症例が腰椎と仙椎に癒合を認める症例であった．PI の計測誤差が大きかった 6 症例を図 4.5 に示す．腰椎と仙椎の癒合を認める症例を除外した場合 2 種の計測法による PI, SS, PT の絶対値誤差平均は $2.55 \pm 2.06^\circ$ ， $2.79 \pm 2.26^\circ$ ， $0.98 \pm 0.78^\circ$ であった．また，整形外科医と提案手法との Bland-Altman プロットを図 4.6 示す．これら 2 つの推定値の差の平均値は -1.5 mm であった．

pi (51.63613239704201, 52.01328439461543) (50.735920065650674, 51.2510579516467)
 (52.52957490602641, 53.07892617660782) ss (40.433163754592755, 40.7872161859172)
 (40.52090742434248, 41.00680172813246) (40.17079718309113, 40.68741373164482)
 pt (11.104163632438597, 11.32487321870901) (10.09011160529293, 10.369157259529485)
 (12.204596498897889, 12.545693669000688)

4.4.2 NII データセット

NII データベース 12522 症例に提案手法を適用して骨盤形状パラメータを計測した．その内，解剖学的ランドマーク間での位置の矛盾や解剖学的に PI や SS は負にならないといった条件を用いて明らかに誤検出であると疑わしき 95 症例を省いた．12427 症例での計測結果である PelvicIncidence, SacralSlope, PelvicTilt の Boxplot をそれぞれ図 4.7, 図 4.8, 図 4.9 に示す．12427 症例で自動計測された骨盤形状パラメータ PI, SS, PT について統計解析を行った．計測結果として PI は男性被験者で平均 50.99° (SD: $\pm 10.29^\circ$; 95% CI: 50.74-51.25)，女性被験者で平均 52.80° (SD: $\pm 10.59^\circ$; 95% CI: 52.53-53.08)，全被験者で 51.82° (SD: $\pm 10.73^\circ$; 95% CI: 51.64-52.01) であった．SS は男性被験者で 40.76° (SD: $\pm 10.16^\circ$; 95% CI: 40.52-41.01)，女性被験者で 40.43° (SD: $\pm 9.95^\circ$; 95% CI: 40.17-40.69)，全被




図 4.4 自動計測された骨盤形状パラメータの結果。

験者で 40.61° (SD: $\pm 10.07^{\circ}$; 95% CI: 40.43-40.79) であった。PT は男性被験者での 10.23° (SD: $\pm 5.84^{\circ}$; 95% CI: 10.09-10.37), 女性被験者で 12.38° (SD: $\pm 6.57^{\circ}$; 95% CI: 12.20-12.55), 全被験者で 11.21° (SD: $\pm 6.28^{\circ}$; 95% CI: 11.10-11.32) であった。年齢ごとでの解剖学パラメータの統計量を表 4.5 に示す。

表 4.3 4-fold 交差検証の結果

		Radial Error (in mm)		SDR (in %)			
		Median	Mean±SD	z = 2 mm	z = 2.5mm	z = 3mm	z = 4mm
仙骨上面最前縁点	UNet (baseline)	3.27	4.69±5.36	15.00	30.00	42.00	64.00
	UNet (proposed architecture)	3.09	4.51±5.62	23.00	38.00	46.00	63.00
	UNet + CC	3.10	4.70±5.60	14.00	29.00	46.00	67.00
	scse-UNet + CC	3.01	4.15±4.64	26.00	39.00	49.00	67.00
	scse-UNet + CC + ASLoss	2.94	4.32±5.63	29.00	44.00	52.00	72.00
仙骨上面最後縁点	UNet (baseline)	3.03	4.76±5.84	18.00	33.00	48.00	66.00
	UNet (proposed architecture)	3.24	4.89±5.45	20.00	30.00	45.00	62.00
	UNet + CC	3.18	4.84±5.84	16.00	33.00	44.00	67.00
	scse-UNet + CC	2.98	4.97±6.12	18.00	31.00	51.00	66.00
	scse-UNet + CC + ASLoss	2.88	4.10±4.75	24.00	38.00	52.00	71.00
右上前腸骨棘	UNet (baseline)	3.17	3.37±1.40	14.00	32.00	46.00	74.00
	UNet (proposed architecture)	3.13	3.28±1.53	23.00	32.00	46.00	75.00
	UNet + CC	2.72	3.15±1.87	20.00	41.00	55.00	78.00
	scse-UNet + CC	2.87	3.05±1.58	26.00	41.00	53.00	80.00
	scse-UNet + CC + ASLoss	2.81	3.04±1.58	21.00	40.00	57.00	83.00
左上前腸骨棘	UNet (baseline)	2.85	3.25±1.87	24.00	37.00	55.00	69.00
	UNet (proposed architecture)	2.93	3.32±1.86	26.00	40.00	51.00	73.00
	UNet + CC	2.60	3.13±1.81	28.00	44.00	57.00	77.00
	scse-UNet + CC	2.70	3.11±1.89	29.00	47.00	55.00	77.00
	scse-UNet + CC + ASLoss	2.50	3.12±2.23	33.00	50.00	66.00	78.00
右骨頭中心	UNet (baseline)	2.39	2.34±1.12	36.00	58.00	80.00	94.00
	UNet (proposed architecture)	2.56	2.77±1.26	27.00	49.00	59.00	87.00
	UNet + CC	2.25	2.45±1.18	44.00	57.00	72.00	90.00
	scse-UNet + CC	2.28	2.52±1.36	40.00	65.00	78.00	87.00
	scse-UNet + CC + ASLoss	1.95	2.12±1.06	50.00	72.00	85.00	92.00
左骨頭中心	UNet (baseline)	2.27	2.43±1.19	35.00	59.00	72.00	91.00
	UNet (proposed architecture)	2.65	2.77±1.26	25.00	45.00	65.00	89.00
	UNet + CC	2.23	2.41±1.06	41.00	65.00	76.00	90.00
	scse-UNet + CC	2.38	2.62±1.35	34.00	57.00	68.00	84.00
	scse-UNet + CC + ASLoss	1.94	2.04±0.98	52.00	72.00	84.00	98.00
恥骨結合	UNet (baseline)	2.57	2.68±1.23	30.00	47.00	65.00	88.00
	UNet (proposed architecture)	2.38	2.86±3.14	35.00	56.00	70.00	88.00
	UNet + CC	2.42	2.56±1.24	40.00	53.00	65.00	86.00
	scse-UNet + CC	2.20	2.78±2.71	36.00	62.00	70.00	89.00
	scse-UNet + CC + ASLoss	2.17	2.39±1.22	42.00	62.00	74.00	90.00
合計	UNet (baseline)	2.74	3.36±3.34	24.57	42.29	58.29	78.00
	UNet (proposed architecture)	2.81	3.49±3.46	25.57	41.43	54.57	76.71
	UNet + CC	2.64	3.32±3.42	29.00	46.00	59.29	79.29
	scse-UNet + CC	2.53	3.32±3.39	29.86	48.86	60.57	78.57
	scse-UNet + CC + ASLoss	2.36	3.02±3.16	35.86	54.00	67.14	83.43

表 4.4 自動計測された骨盤形状パラメータの Mean Angle Error.

		Angle Error (in degree)	
		Median	Mean $\pm$ SD
Pelvic Incidence			
	UNet (baseline)	3.52	5.44 $\pm$ 7.34
	UNet (proposed architecture)	2.88	4.66 $\pm$ 5.67
	UNet + CC	3.57	4.68 $\pm$ 5.09
	scse-UNet + CC	3.45	5.27 $\pm$ 6.32
	scse-UNet + CC + ASLoss	2.08	3.49$\pm$4.41
Sacral Slope			
	UNet (baseline)	3.42	7.69 $\pm$ 5.22
	UNet (proposed architecture)	3.39	4.42 $\pm$ 5.09
	UNet + CC	3.37	4.44 $\pm$ 5.15
	scse-UNet + CC	3.50	5.48 $\pm$ 7.10
	scse-UNet + CC + ASLoss	2.23	3.23$\pm$3.10
Pelvic Tilt			
	UNet (baseline)	1.15	1.78 $\pm$ 2.47
	UNet (proposed architecture)	0.94	1.77 $\pm$ 2.89
	UNet + CC	0.82	1.66 $\pm$ 2.74
	scse-UNet + CC	0.89	1.71 $\pm$ 2.44
	scse-UNet + CC + ASLoss	0.84	1.48$\pm$2.58
合計			
	UNet (baseline)	2.31	4.15 $\pm$ 6.5
	UNet (proposed architecture)	2.13	3.62 $\pm$ 4.87
	UNet + CC	2.12	3.59 $\pm$ 4.66
	scse-UNet + CC	2.39	4.16 $\pm$ 5.91
	scse-UNet + CC + ASLoss	1.57	2.73$\pm$3.55




図 4.5 PI で 10 度以上の計測誤差を認める症例．誤差が最も大きい症例が #1 であり，#1, #2, #3, #5, #6 が仙骨癒合を認める症例．(中央) 赤い球が医師によってラベル付された正解のランドマーク．青い球が提案手法によって推定されたランドマーク．(右) 解剖学的ランドマークから計測された矢状面アライメントに関する骨盤形状パラメータ．




図 4.6 整形外科医と提案手法によって推定された PI の Bland–Altman プロット． 2 つの計測値の差の平均 (実線) と平均 ± 1.96 標準偏差 (SD) の水平線 (破線) がプロットされている．

表 4.5 NII データベースでの年齢ごとの骨盤形状パラメータの自動計測結果.

Age strata (years)	Pelvic Incidence($^{\circ}$)				Sacral Slope($^{\circ}$)				Pelvic Tilt($^{\circ}$)			
	Male		Female		Male		Female		Male		Female	
	Median	Mean $\pm$ SD	Median	Mean $\pm$ SD	Median	Mean $\pm$ SD	Median	Mean $\pm$ SD	Median	Mean $\pm$ SD	Median	Mean $\pm$ SD
≥ 49	47.98	49.40 $\pm$ 10.29	51.19	51.32 $\pm$ 9.62	36.39	37.56 $\pm$ 9.42	36.64	36.94 $\pm$ 8.49	11.73	11.84 $\pm$ 5.46	14.33	14.38 $\pm$ 6.18
50-59	50.22	51.51 $\pm$ 10.44	52.63	53.09 $\pm$ 9.37	38.72	40.00 $\pm$ 9.83	38.54	39.06 $\pm$ 9.37	11.51	11.52 $\pm$ 5.58	14.06	14.03 $\pm$ 6.18
60-69	50.07	51.29 $\pm$ 10.71	52.14	52.47 $\pm$ 9.55	40.04	40.80 $\pm$ 10.03	39.96	40.29 $\pm$ 8.79	10.34	10.49 $\pm$ 5.77	12.04	12.18 $\pm$ 6.19
70-79	49.36	51.03 $\pm$ 10.95	52.59	53.29 $\pm$ 11.32	39.97	41.28 $\pm$ 10.30	41.46	42.30 $\pm$ 10.48	9.66	9.75 $\pm$ 5.75	11.05	10.99 $\pm$ 6.56
80+	50.31	51.06 $\pm$ 11.12	52.88	54.89 $\pm$ 12.28	42.11	42.92 $\pm$ 10.38	44.45	45.70 $\pm$ 11.21	7.91	8.15 $\pm$ 5.97	9.18	9.19 $\pm$ 6.63
Total	49.59	50.99 $\pm$ 10.78	52.24	52.80 $\pm$ 10.59	39.63	40.76 $\pm$ 10.16	39.71	40.43 $\pm$ 9.95	10.16	10.23 $\pm$ 5.84	12.48	12.38 $\pm$ 6.57




図 4.7 年齢ごとの Pelvic Incidence の結果。中央に症例数と中央値を示す。




図 4.8 年齢ごとの Sacral Slope の結果。中央に症例数と中央値を示す。




図 4.9 年齢ごとの Pelvic Tilt の結果. 中央に症例数と中央値を示す.

第 5 章 考察

いくつかの研究は PI は男性被験者と女性被験者との間の有意差を報告していない。Vialle ら [36] によると男性と女性の間で PI に統計的に有意な差を報告し、女性の PI 値が高いことを報告している。また、PI と年齢との関係についても調べており、正常な高齢者の方が正常な成人よりも PI が高いことが報告されている。Rousseau ら [27] によると片側股関節全置換術を行った 328 人の無症候性患者の側面 X 線画像での骨盤形状パラメータの計測の結果、APP の平均値は $-0.4^{\circ} \pm 20.5^{\circ}$ 、Sacral Slope の平均値は $34.8^{\circ} \pm 21.2^{\circ}$ 、Pelvic Incidence の平均値は $53.7^{\circ} \pm 27.1^{\circ}$ と報告している。60-79 歳 (平均 70.4) での計測結果のためか、Vialle らと異なり性差は無かった。Vrtovec ら [38] による 3 次元画像での PI の半自動計測では健常な 370 人 (平均年齢; 41.5 歳) で男性被験者では $46.6^{\circ} \pm 9.2^{\circ}$ 、女性被験者では $47.6^{\circ} \pm 10.7^{\circ}$ であった。男女間では統計的に有意な差は得られていないが、PI と年齢の間では比較的弱い統計的に有意な相関 (相関係数 $r=0.20$) を得ることは出来た。しかし、最近の知見として Medoza-Lattes ら [20] は PI は骨格の成熟後に直線的に増加し、仙骨大腿骨頭間の距離が寿命とともに増加し続け、骨盤の形態学的変化を示唆することを示している。Vrtovec らは [38] 以前までの研究では 2 次元矢状 X 線画像から手動で計測されていたため、X 線撮影での計測は実際の PI よりも過大に評価されている可能性があることを指摘している。

近年骨盤形状パラメータは人種でも差があることをいくつか報告されており、それらのほとんどは白人集団よりもアジア集団の PI が小さいことを主張している。以前までの日本人を対象とした研究で幅広い年齢でかつ最大のコホートで研究されているものは Asai ら [1] による矢状面 X 線画像を用いた研究であり年齢範囲が 19-94 歳の 1461 人の日本人被験者に対して X 線画像を用いて骨盤形状パラメータの計測を行っている。PT の計測値は男性被験者で $15.8^{\circ} \pm 7.6^{\circ}$ 、女性被験者で $19.5^{\circ} \pm 9.7^{\circ}$ 、PI の計測値は男性被験者で $47.7^{\circ} \pm 9.9^{\circ}$ 、女性被験者で $51.2^{\circ} \pm 10.8^{\circ}$ であった。PT と PI は女性よりも男性の方が有意に小さいことを報告しており、また PT は年齢とともに増加していることも報告している。しかし性差よりも個人差の方がはるかに大きいため、臨床的に重要な違いを考慮する場合、この調査結果を裏付けるさらなる縦断研究を実施する必要があることを指摘している。

55.8 ± 10.6 の [33] による日本の研究と一致していない．これは本提案手法の計測ミスに起因するものであると考える．今後の課題としてランドマーク検出の精度を更に向上させることが挙げられる．

scSE-UNet ベースのフレームワークを使用すると推論時間は 1 画像あたり約 4.5 秒 (NVIDIA GTX1080Ti 1 つ) だった．この結果は推論時間が短く自動化された骨盤形状パラメータ計測器として術前または術後の患者に対して使用することができる．

本研究での提案手法は将来的に矢状面アライメントとは別の筋骨格パラメータの計測に拡張することが可能である．この研究にはいくつかの制限がある．第一に、データセットの制限である．本研究のデータセットでは前述したとおり仙骨の癒合または変形が認められた症例が 3 つ含まれていた．この 3 症例によって 4-fold の交差検証の数値が変動し、結果仙骨のバリエーションによって予測に大きな影響を与えると考えられる．しかし、仙骨癒合の症例の場合、正しくランドマークを検出することは人間の専門家にとっても深層学習にとっても難しいことがわかった．Yokoyama ら [43] の研究では日本の健常人 17.4%(29/167) に腰仙部移行椎と認められたと報告されている．したがって、仙骨癒合の症例を収集し、学習させることで適切に処理ができると期待している．

第 6 章 総括

本研究では，大規模データ解析を目的とした CT 画像からの骨盤形状パラメータを全自動で計測した．骨盤矢状面アライメントを表すパラメータの自動計測は整形外科において大きな影響を与えていると考えられている．scSE-UNet をベースとしたフレームワークを使用して，骨盤形状パラメータを計測するための完全自動モデルを開発した．提案したモデルでは 3.23° の PI の角度誤差の中央値を示した．1 つの画像の推定時間は 4.5 秒かかった．これは大規模 CT 画像データベースに対して高速スクリーニングに役立つ．このモデルによって推定された骨盤形状パラメータは経験豊富な医師の評価と比較された．提案された手法は整形外科医が手術前の術前計画および手術後の評価に対しても使用が可能である．さらにこの方法はより多くの臨床応用のためにより多くのランドマークを検出することが可能である．

この論文での主な貢献は 3 つある．第一に現在のディープラーニング技術を使用して，骨盤形状パラメータの自動計測が可能であることを検証した．有効性を示すために医師にラベル付された筋骨格領域の 3 次元 CT 画像 100 症例に対して 4-fold 交差検証によって検証した．第二に scSE-UNet と人間の専門家との間で推定値を比較を行った．第三に 1 万症例を超える大規模なデータベースに対して推論を行い，24 時間以内に計測することを可能にした．

現在の研究は以前の研究と比較して，幅広い年齢層の一般集団からの最大の cohorts (1 万人以上の患者) を利用している．研究は不特定な地区で行われているものの年齢と性別に関連した矢状面骨盤アライメントの平均値を理解することが出来た．したがってこの結果は成人の脊椎，股関節変形を有する患者の治療の改善に役立つ可能性があると考えられる．

謝辞

本研究を進めるにあたり，日頃より有益な助言と丁寧な御指導御鞭撻を賜りました奈良先端科学技術大学院大学 先端科学技術研究科 生体医用画像研究室 佐藤嘉伸教授に深く感謝申し上げます．また，研究発表の際，貴重なご助言を賜りました奈良先端科学技術大学院大学 先端科学技術研究科 計算システムズ生物学的研究室 金谷重彦 教授，分子医学細胞生物学 末次 志郎 教授に厚くお礼申し上げます．本研究を遂行するにあたり，日頃より多くの有益なご助言と丁寧な御指導を頂きました 奈良先端科学技術大学院大学 先端科学技術研究科 生体医用画像研究室 大竹 義人准教授，Mazen soufi 助教，日朝 祐太助教 上村 圭亮特任助教に深く感謝申し上げます．本研究を進めるにあたり，CT 画像のご提供ならびに，大阪大学大学院 医学系研究科 運動器医工学治療学講座 菅野 伸彦 教授，高尾 正樹 講師，岩佐 諱先生に厚く御礼申し上げます．大学院生活全般にわたり様々な面で支えて頂きました 田川 郁代 秘書をはじめ，奈良先端科学技術大学院大学 先端科学技術研究科 生体医用画像研究室内の皆様に心からの感謝を申し上げます．最後に，大学院修了まで多大な支援を頂いた家族に深く感謝し，ここに謝辞とさせていただきます．

参考文献

- [1] Asai, Y., Tsutsui, S., Oka, H., Yoshimura, N., Hashizume, H., Yamada, H., ... Yoshida, M. (2017). Sagittal spino-pelvic alignment in adults: The Wakayama Spine Study. *PLoS ONE*, 12(6), 1–10.
- [2] Bailey, D. G. (2003). Sub-Pixel Estimation of Local Extrema. *Proceeding of Image and Vision Computing*, 414–419.
- [3] Boulay C, Tardieu C, Hecquet J, Benaim C, Mitulescu A, Marty C, Prat-Pradal D, Legaye J, Duval-Beaupère G, Pélissier J. Anatomical reliability of two fundamental radiological and clinical pelvic parameters: incidence and thickness. *Eur J Orthop Surg Traumatol*. 2005;15:197–204.
- [4] Chen, H. F., Mi, J., Zhang, H. H., & Zhao, C. Q. (2019). Pelvic incidence measurement using a computed tomography data-based three-dimensional pelvic model. *Journal of Orthopaedic Surgery and Research*, 14(1), 1–9. <https://doi.org/10.1186/s13018-018-1050-4>
- [5] Cross, M., Smith, E., Hoy, D., Nolte, S., Ackerman, I., Fransen, M., ... March, L. (2014). The global burden of hip and knee osteoarthritis: Estimates from the Global Burden of Disease 2010 study. *Annals of the Rheumatic Diseases*, 73(7), 1323–1330.
- [6] During J, Goudfrooij H, Keessen W, et al. Toward standards for posture: postural characteristics of the lower back system in normal and pathologic conditions. *Spine* 1985;10:83–7.
- [7] Hu, J., Shen, L., Sun, G. (2018). Squeeze-and-Excitation Networks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 7132–7141.
- [8] Le Huec, J. C., Aunoble, S., Philippe, L., Nicolas, P. (2011). Pelvic parameters: origin and significance. *European Spine Journal : Official Publication of the European Spine Society, the European Spinal Deformity Society, and the European Section of the Cervical Spine Research Society*, 20 Suppl 5, 564–571.

- [9] Imai, N., Suzuki, H., Nozaki, A., Miyasaka, D., Tsuchiya, K., Ito, T., ... Endo, N. (2019). Evaluation of anatomical pelvic parameters between normal, healthy men and women using three-dimensional computed tomography: A cross-sectional study of sex-specific and age-specific differences. *Journal of Orthopaedic Surgery and Research*, 14(1), 1–7.
- [10] Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, 1–15.
- [11] Korez, R., Putzier, M., & Vrtovec, T. (2019). Automated measurement of Pelvic incidence from X-Ray images. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11404 LNCS, 146–152.
- [12] Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- [13] Lazennec JY, Charlot N, Gorin M, et al. Hip-spine relationship: a radio-anatomical study for optimization in acetabular cup positioning. *Surg Radiol Anat* 2004;26:136.
- [14] Legaye J, Duval-Beaupere G, Hecquet J, Marty C. Pelvic incidence: a fundamental pelvic parameter for three-dimensional regulation of spinal sagittal curves. *Eur Spine J* 1998;7:99–103.
- [15] Lembeck B, Mueller O, Reize P, et al. Pelvic tilt makes acetabular cup navigation inaccurate. *Acta Orthop* 2005;76:517.
- [16] Lewinnek GE, Lewis JL, Tarr R, Compere CL, Zimmerman JR. Dislocations after total hip-replacement arthroplasties. *The Journal of Bone and Joint surgery. American Volume*. 1978 Mar;60(2):217-220.
- [17] Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- [18] Liu, R., Lehman, J., Molino, P., Such, F. P., Frank, E., Sergeev, A., Yosin-

- ski, J. (2018). An intriguing failing of convolutional neural networks and the CoordConv solution. *Advances in Neural Information Processing Systems*, 2018-Decem(NeurIPS), 9605–9616.
- [19] Mac-Thiong JM, Roussouly P, Berthonnaud E, Guigui P. Sagittal parameters of global spinal balance: normative values from a prospective cohort of seven hundred nine Caucasian asymptomatic adults. *Spine (Phila Pa 1976)* 2010;35(22):E1193–E1198.
- [20] Mendoza-Lattes, S., Ries, Z., Gao, Y., & Weinstein, S. L. (2010). Natural history of spinopelvic alignment differs from symptomatic deformity of the spine. *Spine*, 35(16), 792–798.
- [21] Nishihara S, Sugano N, Nishii T, et al. Measurements of pelvic flexion angle using three-dimensional computed tomography. *Clin Orthop Relat Res* 2003;140.
- [22] Otake, Y., Sato, Y., Takao, M., Hiasa, Y., & Sugano, N. (2019). Analysis of Large Scale CT Image Database using AI for Understanding of Musculoskeletal Anatomy and Application in Computer Assisted Surgery. *Medical Imaging Technology*, 37(2), 89–94.
- [23] Paszke, A., Gross, S., Chintala, S., Chanan, G., Yang, E., Devito, Z., Lin, Z., Desmaison, A., Antiga, L., & Lerer, A. (2017). Automatic differentiation in PyTorch.
- [24] Payer, C., Štern, D., Bischof, H., Urschler, M. (2016). Regressing heatmaps for multiple landmark localization using CNNs. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9901 LNCS(June), 230–238.
- [25] Payer, C., Štern, D., Bischof, H., Urschler, M. (2019). Integrating spatial configuration into heatmap regression based CNNs for landmark localization. *Medical Image Analysis*, 54, 207–219.
- [26] Ronneberger, O.; Fischer, P.; Brox, T. U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015*. MICCAI 2015; Navab, N.,

- Hornegger, J., Wells, W., Ronneberger 2015 Frangi, A., Eds.; Springer: Cham, Switzerland, 2015; pp. 234–241.
- [27] Rousseau, M. A., Lazennec, J. Y., Boyer, P., Mora, N., Gorin, M., Catonné, Y. (2009). Optimization of Total Hip Arthroplasty Implantation. Is the Anterior Pelvic Plane Concept Valid *Journal of Arthroplasty*, 24(1), 22–26.
- [28] Roussouly, P., Nnadi, C. (2010). Sagittal plane deformity: An overview of interpretation and management. *European Spine Journal*, 19(11), 1824–1836.
- [29] Roy, A. G., Navab, N., Wachinger, C. (2018). Concurrent spatial and channel ‘squeeze & excitation’ in fully convolutional networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11070 LNCS, 421–429.
- [30] Schuller, S., Charles, Y. P., & Steib, J. P. (2011). Sagittal spinopelvic alignment and body mass index in patients with degenerative spondylolisthesis. *European spine journal : official publication of the European Spine Society, the European Spinal Deformity Society, and the European Section of the Cervical Spine Research Society*, 20(5), 713–719.
- [31] Shen, D., Wu, G., Suk, H. I. (2017). Deep learning in medical image analysis. *Annual review of biomedical engineering*, 19, 221–248.
- [32] Tannast M, Langlotz U, Siebenrock KA, et al. Anatomic referencing of cup orientation in total hip arthroplasty. *Clin Orthop Relat Res* 2005;436:144.
- [33] Takeda, N., Kobayashi, T., Atsuta, Y., Matsuno, T., Shirado, O., & Minami, A. (2009). Changes in the sagittal spinal alignment of the elderly without vertebral fractures: A minimum 10-year longitudinal study. *Journal of Orthopaedic Science*, 14(6), 748–753.
- [34] Vaz G, Roussouly P, Berthonnaud E, Dimnet J. Sagittal morphology and equilibrium of pelvis and spine. *Eur Spine J*. 2002;1(11):80–87.
- [35] Vialle, R., Levassor, N., Rillardon, L., Templier, A., Skalli, W., & Guigui, P. (2005). Radiographic analysis of the sagittal alignment and balance of the spine in asymptomatic subjects. *Journal of Bone and Joint Surgery -*

Series A, 87(2), 260–267.

- [36] Vialle, R., Ilharreborde, B., Dauzac, C., & Guigui, P. (2006). Intra and inter-observer reliability of determining degree of pelvic incidence in high-grade spondylolisthesis using a computer assisted method. *European Spine Journal*, 15(10), 1449–1453.
- [37] Vrtovec, T., Janssen, M. M. A., Likar, B., Castelein, R. M., Viergever, M. A., Pernuš, F. (2012). A review of methods for evaluating the quantitative parameters of sagittal pelvic alignment. *Spine Journal*, 12(5), 433–446.
- [38] Vrtovec, T., Janssen, M. M. A., Pernuš, F., Castelein, R. M., Viergever, M. A. (2012). Analysis of pelvic incidence from 3-dimensional images of a normal population. *Spine*, 37(8), 479–485.
- [39] Wang, C. W., Huang, C. T., Lee, J. H., Li, C. H., Chang, S. W., Siao, M. J., ... Lindner, C. (2016). A benchmark for comparison of dental radiography analysis algorithms. *Medical Image Analysis*, 31, 63–76.
- [40] Wang, X., Bo, L., Fuxin, L. (2019). Adaptive Wing Loss for Robust Face Alignment via Heatmap Regression. 6971–6981. Retrieved from <http://arxiv.org/abs/1904.07399>
- [41] Weng, C.-H., Wang, C.-L., Huang, Y.-J., Yeh, Y.-C., Fu, C.-J., Yeh, C.-Y., Tsai, T.-T. (2019). Artificial Intelligence for Automatic Measurement of Sagittal Vertical Axis Using ResUNet Framework. *Journal of Clinical Medicine*, 8(11).
- [42] Yang, D., Zhang, S., Yan, Z., Tan, C., Li, K., Metaxas, D. (2015). AUTOMATED ANATOMICAL LANDMARK DETECTION ON DISTAL FEMUR SURFACE USING CONVOLUTIONAL NEURAL NETWORK Department of Computer Science , University of North Carolina at Charlotte , NC , US Department of Industrial and Systems Engineering , Rutgers University ,. 17–21.
- [43] Yokoyama, K., Kawanishi, M., Sugie, A., Yamada, M., Tanaka, H., Ito, Y., Yamashita, M. (2018). Spinopelvic Alignment and Sagittal Balance in Asymptomatic Adults with Six Lumbar Vertebrae 第6腰椎と全脊椎矢状面

アライメントについて. Spinal Surgery, 32(1), 85–87.

- [44] Zhu, Z., Xu, L., Zhu, F., Jiang, L., Wang, Z., Liu, Z., ... Qiu, Y. (2014). Sagittal Alignment of Spine and Pelvis in Asymptomatic Adults. Spine, 39(1), E1–E6.

発表リスト

- [1] 田中 雄基, 日朝 祐太, 大竹 義人, 高尾 正樹, 上村 圭亮, 菅野 伸彦, 佐藤 嘉伸, ” 疾患股関節の CEA の自動計測と大規模データベースでの有用性の検討”, 第 38 回日本医用画像工学会, 2019.7.