

肺動脈楔入圧推定のための回帰型 CNN における 教師データサイズに対する汎化性能の収束性評価

○三浦 朋樹¹, 大前 佑斗¹, 齋藤 佑記², 深町 大介²,
永嶋 孝一², 奥村 恭男², 柿本 陽平¹, 豊谷 純¹
¹日本大学 生産工学部, ²日本大学 医学部 循環器内科

1. まえがき

肺動脈楔入圧 (PAWP) は心不全の重症度に関連する重要な指標であり, 右心カテーテル検査により測定される. 静脈にカテーテルを挿入させるその測定法は侵襲的で合併症のリスクもあるため, 非侵襲的で客観的な検査をするために研究が進められている. 特に, 機械学習の活用が盛んに行われており, とりわけ, 畳み込みニューラルネットワーク (CNN) は画像解析で高い性能を持つ機械学習モデルで, 医療分野においてもいくつか活用事例が報告されている. 例えば, Saito et al. [1] は CNN を回帰型に応用して, 胸部 X 線画像から PAWP を実数値で推定する研究を行っている. また, これに対し, 診断の簡易的な支援を目的に Miura et al. [2] は PAWP を 3 クラスで推定する CNN を構築している.

ここで, 医療分野における機械学習の活用について, 臨床上の観点から, その推定性能は可能な限り高いものであることが望ましい. 実際, Saito et al. [1] は Data augmentation を用いて CNN の性能を高める工夫を行なっている. しかし, Data augmentation におけるデータ拡張サイズを増やせば増やすほど性能が向上するわけではないという報告がある [3]. これは, 新規のデータサイズを増やしているわけではないことが原因であることが想像される. そのため, 新規のデータサイズを増やせば性能が向上する可能性があるものの, その真偽は不明である. 侵襲性のある検査を実施しなければ新規のデータを増やせないと考えれば, 汎化性能の向上が期待できる場合にのみ集めた方がよいだろう. そのため本研究では, すでに収集し

ているデータを使用し, データサイズに対する汎化性能の変化を観測し, その傾向が比例的か対数的かを確認する (ここでいうデータサイズとは, Data augmentation による水増しを考慮したものではなく, オリジナルの画像枚数であることを注意). この結果として, 汎化性能が比例で増加するならばデータを増やすべきであり, 収束しているならばデータ収集に対する汎化性能の増加は見込めないことになる. 本稿はこの結果について報告するものである.

2. 実験概要

2.1 データセット

本研究で使用したデータは, 日本大学医学部附属板橋病院で撮影された 936 枚の胸部 X 線画像と右心カテーテル検査により測定された PAWP の実測値ラベルである. 各画像はグレースケールで表現されており, $256 \times 256 \times 1$ (高さ \times 幅 \times 深さ) となっている. 次に, データセット分割の流れを図 1 に示す. まず, 全サンプルの 80% (748 枚) を教師データ, 20% (188 枚) をテストデータとしてランダムに割り当てた. 続いて, 教師データを均等に約 50 枚ずつ 15 セットに分割する. 各セットへの割り当て方を図 2 に示す. まず, ランダムに並んだ測定値を降順にソートする. この時, 画像と測定値が対応するように画像も一緒に並べ替えている. 次に, ソートされたデータの 1 番目を 1 セット目, 2 番目のデータを 2 セット目といったように, 順番に割り当てている. さらに, 各セットのうち, 約 75% をメイン教師データ, 約 25% を検証データに割り当てた. 方法について, セット 1 を例にして図 3 に示す. 割り当て方を規則的にすることで, メイン教師データと検証データの平均値, 標準偏差が近似するようにしている. 最終

Convergence evaluation of generalization performance with respect to training data size in regressive CNN for estimating pulmonary artery wedge pressure

Tomoki MIURA, Yuto OMAE, Yuki SAITO, Daisuke FUKAMACHI,
Koichi NAGASHIMA, Yasuo OKUMURA,
Yohei KAKIMOTO and Jun TOYOTANI

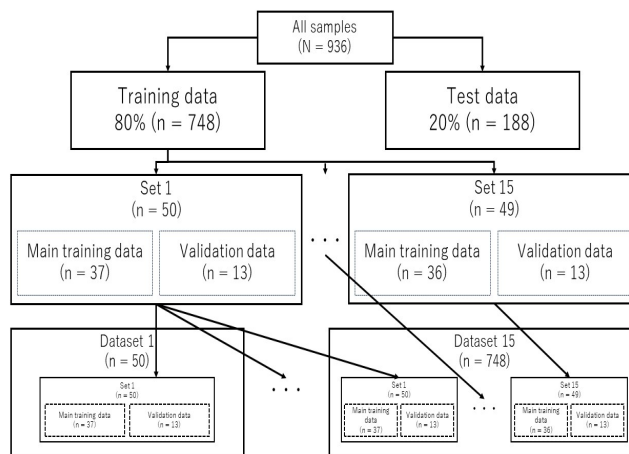


図1 データセット分割

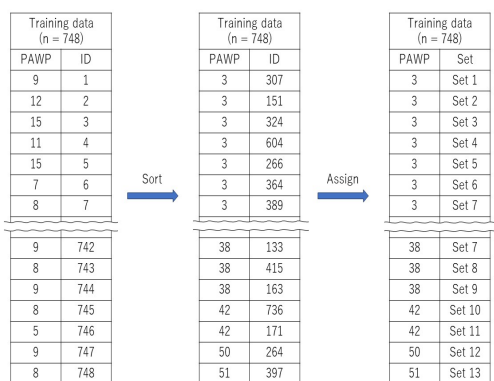


図2 セットの割り当て

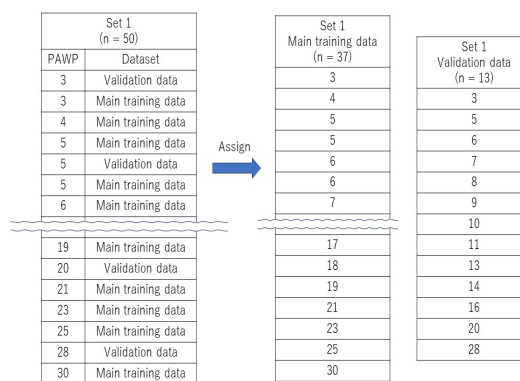


図3 教師, 検証データの割り当て

的に, セット1からセット15まで追加していき, 15パターンのサイズのデータセットを作成した(図1)。

2.2 モデルと学習条件

推定モデルとして畳み込みニューラルネットワークを採用し, 学習と構築を行っている。構造について, 入力層の画像入力サイズとして $256 \times 256 \times 1$ を設定し, 畳み込み層 10 層とプーリング層 5 層で構成される中間層を設計した。その後, Global Average Pooling (GAP) 層により, 特徴量マップが平均化され, 特徴量ベクトルが生成される。GAP 層により得られた 512 次元の特徴量ベクトルを 64 次元に圧縮し, その後 1 次元の回帰推定値を得る。これが PAWP の推定値である。入力層, 及び中間層の活性化関数は ReLU 関数, 損失関数には平均二乗誤差を採用した。

学習条件としては, 学習回数500回, 学習係数 $10^{-5.5}$, バッチサイズ32を設定し, 学習後に検証データの平均二乗誤差が最も小さい学習回

数を探索した。CNNには乱数依存の学習アルゴリズムが採用されているため, 乱数の出方によっては, 性能が高めに出ることもあれば, 低めに出ることがある。偶然に結果を乱されないようにするため, 30の乱数シードでCNNを30モデル構築した。この操作を15セットすべてで実行し, 異なるデータサイズによるCNNの推定性能の変化を記録する。

3. 結果と考察

検証データにより学習回数が最適化されたモデルを用いて, テストデータの推定を行った。1セット30シード分の実測と推定の相関係数の平均値, 15データセット分の結果を図4に示す。図4より, データサイズが大きくなるほど, CNNの性能が比例的に向上している。続いて, 15データセット分の二乗誤差の平均値を図5に示す。こちら, データサイズが大きくなることで, 推定値と正解値の誤差が小さくなることが示された。Aは急激で, Bは緩やかになっている。さらにデータを収集することで, わず




図4 データサイズの変化に対する
実測と推定の相関係数




図5 データサイズの変化に対する
平均二乗誤差

かに性能が上がる可能性はあるものの、いずれは変化がなくなると見込まれる。

4. まとめ

本研究では、回帰型CNNによるPAWP推定における教師データサイズに対する汎化性能の傾向を調査した。結果は、データサイズ拡大に対して、CNNの性能傾向は比例的であることがわかった。本研究結果を、PAWP推定におけるCNNの構築において、適切なデータサイズの決定をするための1つの指針として活用することができる。

Appendix

本研究は日本大学医学部附属板橋病院 臨床研究倫理審査委員会での承認を得て施行された(RK-210112-09)。

参考文献

- 1) Y. Saito, Y. Omae, D. Fukamachi, K. Nagashima et al., Quantitative estimation of pulmonary artery wedge pressure from chest radiographs by a regression convolutional neural network, *Heart and Vessels*, vol.37, pp.1387-1394, DOI: 10.1007/s00380-022-02043-w, 2022.
- 2) T. Miura, Y. Omae, Y. Saito, D. Fukamachi et al., Three-State Classification of Pulmonary Artery Wedge Pressure from Chest X-Ray Images Using Convolutional Neural Network, *ICIC Express Letters, Part B: Applications*, Vol.14, No.3, pp.271-277, Mar. 2023. DOI: 10.24507/icicelb.14.03.271
- 3) Y. Omae, Y. Saito, D. Fukamachi, K. Nagashima et al., Impact of Chest Radiograph Image Size and Augmentation on Estimating Pulmonary Artery Wedge Pressure by Regression Convolutional Neural Network, *AIP Conference Proceedings (IC-MSQUARE 2022)*, vol.2872