

敵対的生成ネットワークによる疑似訓練データを用いた 深層学習に基づく脈波形状からのカフレス血圧推定

島崎 正太

指導教員：小栗 宏次

1 はじめに

血圧は動脈硬化やストレスなどに反映されるため、健康管理において重要な指標の一つである。血圧測定法としては上腕にカフを巻いて測定する方法が最も一般的であるが、拘束性が高いため、より低負荷な血圧測定法が求められている。そこで、脈波は心血管系の状態に応じて波形が変化するため、単一の光電容積脈波センサから血圧を推定する研究がなされている。先行研究 [1] では、脈波や加速度脈波から幾何学的な特徴量を抽出し、回帰分析を用いて血圧値を推定している。しかしながら、それらの特徴量のみでは十分な回帰を行うことができない。従来の特徴量のみでは血圧の変化に伴って変形する脈波形状の特徴を十分に表現できていないことが原因として考えられるが、他に有効な脈波形状の特徴に関する知見はまだない。

そこで、本研究では人が設計した特徴量の情報表現性能を超える複雑な特徴表現が可能とされている深層学習に注目し、脈波形状に秘められた新たな特徴量を抽出する。また、敵対的生成ネットワークを用いて疑似脈波データを生成し、訓練データに応用することで推定精度がどう変化するかを検証する。

2 血圧推定手法

本研究では畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) を用いて脈波の特徴量を抽出し、血圧値を推定する。CNN のネットワークは入力層、畳み込み層、プーリング層、全結合層、回帰層で構成される。CNN の入力には1拍に切り出した脈波信号を使用する。脈拍数とアンケートで収集した年齢、身長、体重、性別、服薬の有無は全結合層に追加する。活性化関数にはランプ関数を使用し、真値と推定値の二乗平均平方根誤差が最小になるよう学習を実行する。また、ノード数等はパラメータ調整用のデータセットを使用して、グリッドサーチにて決定した。本研究で使用する CNN のネットワーク構成を図 1 に示す。




図1 ネットワーク構成図

3 血圧推定実験

3.1 脈波・血圧計測実験

本研究の主旨について十分に説明をした後、被験者に対してインフォームド・コンセントを行い、同意が得られた場合のみ計測を行う。被験者は男性が87名、女性が159名の合計246名であった。年齢分布を図2に、血圧分布を図3に示す。




図2 年齢分布




図3 血圧分布

計測前には個人情報 (年齢、身長、体重、性別、降圧剤服薬の有無) に関するアンケートに答えてもらった後、安静時の脈波と血圧を同時に計測する。脈波は、光電容積脈波センサを左手人差し指の指先に装着し計測した。また血圧は、カフ式の血圧計を使用し、カフの中心を心臓の高さに合わせたうえで右上腕に装着して計測を行った。血圧値は1分毎に計測を行い、脈波信号のサンプリング周波数は1000 Hzとした。計測実験環境を図4に示す。



図4 計測実験環境

3.2 推定結果

脈波・血圧計測実験で収集したデータを用いて血圧推定を行った。なお、被験者246名のうち60%を訓練データ、20%を調整データ、20%を評価データに分類し、ホールドアウト法を用いて性能を検証した。また、真値と推定値の相関係数 R と誤差標準偏差 SD 、絶対誤差平均 MAE を評価指標として使用し、学習器を評価した。先行研究では $R=0.64$ 、 $SD=12.82$ mmHg、 $MAE=10.24$ mmHg だったのに対して、提案手法では $R=0.72$ 、 $SD=11.41$ mmHg、 $MAE=9.04$ mmHg と、先行研究法を上回る結果が得られた。

3.3 考察

提案手法で推定した結果を図5に示す。図5において青、赤、黄でプロットしたデータは、真値と推定値の絶対誤差が30 mmHg以上のものを示している。この3名の被験者情報を表1に示す。推定精度改善のために、これらの被験者と訓練データ群との関係性を確認した。全データにおける血圧と年齢分布を

表2 血圧推定結果

Method	Source	Features	R	SD [mmHg]	MAE [mmHg]
重回帰分析	脈波, 加速度脈波	幾何学的特徴量, 個人情報	0.64	12.82	10.24
CNN	脈波	CNN 特徴量, 個人情報	0.72	11.41	9.04
CNN	脈波, 疑似脈波	CNN 特徴量, 個人情報	0.73	11.37	8.86

図6に示す。図6より、推定誤差の大きい被験者は60歳以上で低血圧であった。また、60歳以上の訓練データヒストグラム(図7)を確認すると、低血圧のデータが不足していることが確認できる。

表1 誤差 30 mmHg 以上の被験者情報

色	身長	体重	年齢	性別	服薬	真値 [mmHg]
青	159	49	67	女性	無し	90
赤	151	50	69	女性	無し	100
黄	157	56	66	女性	無し	102




図5 血圧推定結果




図6 血圧-年齢分布




図7 60歳以上の訓練データヒストグラム




図8 GANの概念図

4.2 推定結果・考察

推定結果を表2に、実際に計測した脈波データと生成した疑似脈波データの一つ(血圧値:97 mmHg)を図9に示す。表2の推定結果より、僅かに推定精度が向上した。また図9より、同一血圧値の様々な波形を生成することができた。訓練データに存在しない新たな波形を追加することで学習が安定し、推定精度が向上したと考えられる。

ここで、疑似脈波データを使用する場合と使用しない場合の推定値を比較する。推定結果を同時にプロットした散布図を図10に示す。図10から、いずれの方法でも低血圧においては真値より高めに推定されているものの、疑似脈波データを追加した場合にはその推定値が真値に近づいていることが確認できる。




図9 計測脈波と疑似脈波の波形




図10 推定結果の比較

4 疑似脈波データ生成

第3章では、低血圧のデータ不足が課題として挙げられた。そこで本章では敵対的生成ネットワークを用いて低血圧の疑似脈波データを生成し、訓練データに追加することで推定精度が向上するかを検証する。

4.1 敵対的生成ネットワーク

敵対的生成ネットワーク (Generative Adversarial Network:GAN) [2] は、学習させたデータと類似した特徴を持つデータを生成するアルゴリズムである。GANは生成モデル G と分類モデル D の二つのネットワークで構成されている。本研究で用いるGANの概念図を図8に示す。GANでは、両モデルの学習を交互に進めていくことで、競い合うように学習が進んでいき、最終的に高性能な生成モデルを得ることができる。

5 おわりに

本研究では、カフレス血圧推定において深層学習を用いることで推定精度が向上するかを検証した。結果として、CNNを用いて血圧と関係のある特徴量を抽出し、推定に使用することで従来の手法より推定精度が向上した。また、データ生成アルゴリズムを用いて疑似脈波データを作成し、訓練データに追加することで推定精度が僅かに向上した。今後の課題として、不足しているデータの収集を行うことや、ハイパーパラメータの調整法を検討することが挙げられる。

参考文献

- [1] R.Kondo, *et al*, IEEE EMBC, pp.1851-1854, 2014.
- [2] I. J. Goodfellow, *et al*, NIPS, pp.2672-2680, 2014.