

血流動態モデルを用いた血流波形予測に関する研究

小林 航也

指導教員：神山 斉己

1 はじめに

動脈硬化症の非侵襲的な診断手法として FMD(Flow-Mediated Dilatation) 検査, CAVI(Cardio-Ankle Vascular Index) 検査等がある。しかし、これらの検査には問題点がいくつかある。検査時間が約 10~20 分程度となっており、駆血も伴うこと、検査時に身体を固定する必要があることなどである。これらのことから、被験者にストレスを与える検査となっている。

検査をより簡単なものにするためには、ヒトの全身の血流動態を細部まで把握して解析する必要がある。しかし、血管構造が複雑なため、詳細が明らかになっていない箇所もある。ここで、動脈系に着目すると、拍出部を根とした木構造を持っていることから、ある部位の血流動態は他部位の血流動態情報が含まれていると推測される。このことから、計測データを元に学習モデルを用いることで、複雑な箇所の血流動態を予測することができると考えられる。しかし、データの与え方や学習モデルには多くの手法が存在する。

そこで本研究では、複雑な箇所の血流波形を予測可能にする展望を踏まえ、ある部位の血流波形を元に他部位の血流波形を予測するモデル(以下、予測モデル)の構築を行い、有用であるモデル構造、データの与え方を示す。学習モデル構築には多くのデータを与える必要がある。しかし、実際に様々なパターンの計測データを多く集めることは困難なため、全身血流動態モデルを用いて、パラメータを変化させることでデータ収集を行った。入出力はモデルからデータを得ることができること、計測可能な箇所であることから、上腕動脈の血流波形を入力、橈骨動脈の血流波形を出力とした。収集したデータを元に予測モデルの構築を行い、計測したデータを用いて汎化性能の確認を行った。

2 血流動態モデルとデータ

2.1 0次元全身血流動態モデル

Avolio の 0 次元全身血流動態モデルは、円筒管モデルを 1 つのセグメントとして考え、解剖学的知見に基づいて 128 個接続することで、動脈系の血流動態モデルを提案した [1]。シミュレーションを行うことで、セグメント毎に血流速度や血圧を求めることができる。しかし、複雑な箇所は省略、または末梢抵抗とされており、その箇所の血流動態や条件による変化などはシミュレーションで得ることはできない。

2.2 データセット収集

前小節で解説を行った Avolio のモデルを用いてデータセット収集を行う。収集方法は血管物性パラメータそれぞれに対して乱数をかけることで様々な構造状態を実現する。変化させたパラメータは血管半径、血管壁厚、ヤング率の 3 つとし、乱数の生成範囲は 0.9~1.1 とした。

2.3 計測データ

姿勢を仰向けにし、上腕と手首にカフを装着して同時に計測を行う。なお、本研究は愛知県立大学研究倫理審査委員会の承認を得て行った。すべての実験は被験者に実験の趣旨及び方法を書面によって説明し、文書による承諾を得た上で実施した。

図 2 の上部が上腕動脈の計測データであり、下部が手首の計

測データである。このデータを予測モデルに与えることで予測モデルの汎化性能を測る。




図 1 計測方法

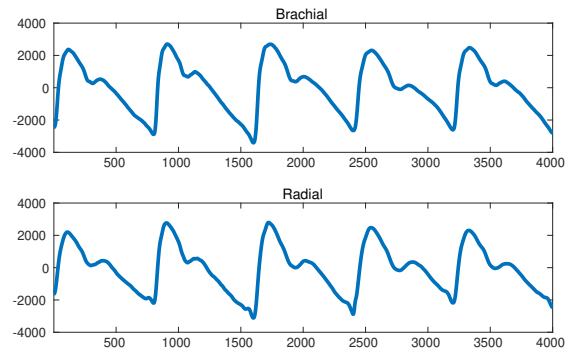


図 2 計測データ

2.4 データの正規化・入出力パターン

Avolio モデルから得たデータと計測データをどちらも正規化し、血圧波形の形状を表す数値データに変換する。正規化の範囲は波形データ全体を正規化するか、1 周期毎に正規化するかの 2 パターンで行った。

1. 波形データ全体を正規化
2. 1 周期毎に正規化

また、予測モデル構築を行う際にデータをどのように与え、入出力をどのようにするかはいくつか考えられる。本研究では 5 パターンで検証を行った。

1. 過去の 1 周期波形から 1 点を求める
2. 1 周期波形から 1 周期波形を求める
データを与える際に、ランダムな箇所から 1 周期分与える
3. 過去の 1 周期波形と現在の 1 周期波形の 2 周期分から 1 周期波形を求める
データを与える際に、ランダムな箇所から 2 周期分与える
4. 1 周期波形から 1 周期波形を求める
データを与える際に、波形の立ち上がり箇所から 1 周期分与える
5. 過去の 1 周期波形と現在の 1 周期波形の 2 周期分から 1 周期波形を求める
データを与える際に、波形の立ち上がり箇所から 2 周期分与える

したがって、正規化 2 パターンと入出力 5 パターンで、 $2 \times 5 = 10$ パターンの検証を行った。概要を図 3 に示す。

3 予測モデル

本研究では 5 つの予測モデル構築を行った。多変量解析の 1 種である重回帰、重回帰に正則化を組み込んだ Lasso 回帰、Ridge 回帰、ニューラルネットワークの 1 種である多層パーセプトロン、RNN を用いて予測モデルを構築した。学習データは

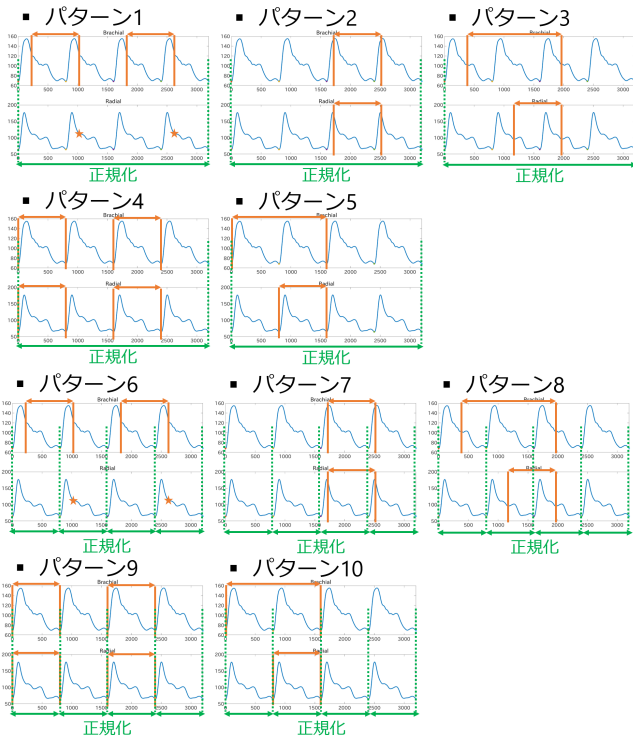


図 3 パターン概要

5000 個用意し，評価関数は決定係数 (R^2) によって予測精度を測った．結果として，5 つの予測モデルの中で，RNN を用いた時が高い予測精度であったため，RNN を用いた予測モデル構造を図 4 に示す．入出力は小節 2.4 で示したパターンによって可変である．予測モデル構築条件を表 1 に示す．活性化関数とノード数はそれぞれ変化させて予測モデル構築を行った．

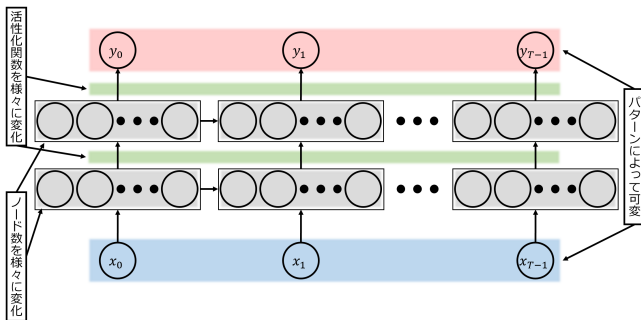


図 4 RNN を用いた予測モデル構造

表 1 予測モデル構築条件

学習データ数	5000
エポック数	80
バッチサイズ	32
最適化アルゴリズム	adam
Loss 関数	平均二乗誤差 (MSE)
評価関数	決定係数 (R^2)
1 層目の活性化関数	elu, softplus, softsign, relu, tanh
1 層目のノード数	20, 40, ... 100
2 層目の活性化関数	elu, softplus, softsign, relu, tanh
2 層目のノード数	20, 40, ... 100

4 予測結果

表 1 を元に，RNN を用いて隠れ層 2 層のニューラルネットワークモデルを構築した．構築したモデルに図 2 に示した計測データを与えて予測精度を計った．構築した予測モデルの中で予測精度が高かった上位 5 つのモデル構造を表 2 にまとめる．ただし，結果をプロットする際に表記しやすくするために，モデル構造にラベル付けを行っている．また， N_{L1} , A_{L1} は隠れ層 1 層目のノード数と活性化関数， N_{L2} , A_{L2} は隠れ層 2 層目のノード数と活性化関数をそれぞれ示している． p は入出力と正規化のパターンを示している．

最も予測精度が高かった予測モデルの予測結果を図 5 に示す．結果からおおよそ計測データを予測することができている．表 2 の予測精度が高い上位 5 つのパターンを見ると，どのパターンも 1 周期波形から 1 周期波形を求めるパターンである．また， $p = 9$ と $p = 7$ は 1 周期毎に正規化を行っているパターンであり，予測モデルの 4 つがそれに当たる．これらのことから，本研究で試した入出力パターンの中では，1 周期波形から 1 周期波形を求め，1 周期毎に正規化を行う手法が有用であることが示唆された．

表 2 予測精度の高い RNN モデル構造

ラベル	p	N_{L1}	A_{L1}	N_{L2}	A_{L2}	決定係数
RNN1	9	80	softplus	100	relu	0.9765
RNN2	4	100	softplus	20	softplus	0.9735
RNN3	9	80	softplus	20	softplus	0.9733
RNN4	7	40	softplus	20	relu	0.9731
RNN5	7	80	elu	20	elu	0.9725




図 5 RNN1 による計測データ予測結果

5 まとめ

複雑な箇所の血流波形を予測可能にする展望を踏まえ，本研究では上腕動脈の血流波形から橈骨動脈の血流波形を予測するモデル構築を行った．多変量解析とニューラルネットワークを用いて様々な予測モデル構築を行い，血流波形予測には RNN が有用であることが示された．そして，Avolio モデルから得たデータを元に汎用性の高い予測モデルを構築することができた．また，予測モデルの入出力とデータと与え方としては，1 周期波形から 1 周期波形を求め，1 周期毎に正規化する手法が有用であることも示唆された．

今後の課題としては，他の部位でも同様な手法で汎用性の高い予測モデルを構築することができるかの検証や，より精度の高い予測モデル構造を実現することが挙げられる．また，現在は健康状態のデータを学習データとしているため，動脈硬化が発生した場合でも予測ができるように予測モデルの表現力を上げる必要がある．

参考文献

- [1] A. P. Avolio, "Multi-branch model of the human arterial system", *Medical & Biological Engineering & Computing*, 1980, 18, 709-718 .