

ニューラルネットによる至適運動強度閾値予測 Estimating the optimal exercise intensity threshold with neural networks

渡邊 朝子[†] 高橋伸弥[†] 末松 保憲[‡] 松田 拓朗[§] 藤見 幹太[§] 三浦 伸一郎[‡]
Asako Watanabe Shinya Takahashi Yasunori Suematsu Takuro Matsuda Kanta Fujimi
Shin-ichiro Miura

1. はじめに

運動は有酸素運動とレジスタンス運動に大別される。有酸素運動は、体重減少、生活習慣病の改善、心臓病の再発予防・予後改善効果があり、心血管疾患患者に推奨される運動である[1-2]。しかしながら、嫌気性代謝閾値(anaerobic threshold: AT)を超える強度では、交感神経活性を亢進させ、狭心症、心筋梗塞、不整脈のリスクを高める。低負荷であれば十分な効果は得られないが、過負荷では心血管疾患患者の心血管イベントへのリスクが大きくなる。至適運動強度は同じ患者であっても病態やその日の体調、メンタル、睡眠状況によって毎日異なる[3-6]ため、毎回測定することが望ましい。

至適運動強度は、年齢と安静時心拍数を用いてカルボネン法[1]で算出することができるが、日々変化する至適運動強度を求める事は不可能である。また、運動負荷をかけて至適運動強度を求める方法として、呼気ガス分析装置を用いた心肺運動負荷試験(cardiopulmonary exercise test: CPX)があるが、測定が複雑であるため、日々のATの把握には適さない。また、至適運動強度を超える運動負荷を行わなければならないため、運動前に至適運動強度を知ることが出来ない。

ATは、収縮期血圧(systolic blood pressure: SBP)と心拍数(heart rate: HR)の積であるダブルプロダクト(double product: DP)の傾きが急上昇する屈曲点(double product break point: DPBP)と一致することが知られている[7]。我々の先行研究[3-6]においても、非侵襲的な連続血圧モニタリングを用いて得られたDPBPが心血管疾患患者におけるATと有意に関連することがわかった。つまり、安静時から準備運動までのDPの変化から運動負荷時の変化を予測しDPBPを求める事ができれば、準備運動段階でその日の至適運動強度を知ることができる。

至適運動強度の予測に関する研究では、運動時の筋電データから酸素摂取量の予測をするLSTMモデル[8]、呼気ガスの検査項目を用いたATの予測をするAttention-LSTMモデル[9]が提案されているが、DPBPに着目したものではない。

本研究では、心血管疾患患者及び健康者でCPX実施時の安静時からウォーミングアップにおけるDPの変化から至適運動強度を予測するニューラルネットワークモデルを構築した。先行研究[8-9]より、モデルはLSTM(Long

Short-Term Memory)とMHA(Multi-head attention)を組み合わせた。①DPBPの時刻を直接予測するモデルと②将来のDPの変動を予測したのちDPBPの時刻を算出するモデル、③これら2つを複合したモデルの3つを作成し、予測されたDPBPと実測のDPBPとの時刻差を評価した。

2. 方法

CPXにおける安静時からウォーミングアップ時のDPの時系列データを入力とし、DPBPの時刻またはその後のDPを予測するニューラルネットワークを構築した。LSTMとMHAを組み合わせるにより、時系列データの長期依存性と重要な時間ステップに対する選択的な注目を併用し、高精度な予測を実現することを目指す。モデルとして、DPBP時刻直接予測モデル(方法1)とDP変動予測モデル(方法2)、DP変動&DPBP時刻予測モデル(方法3)の3パターンにおいて予測精度を検証した。なお、方法2では予測されたDP変動からDPBPを算出している。図1に方法の概略図を示す。

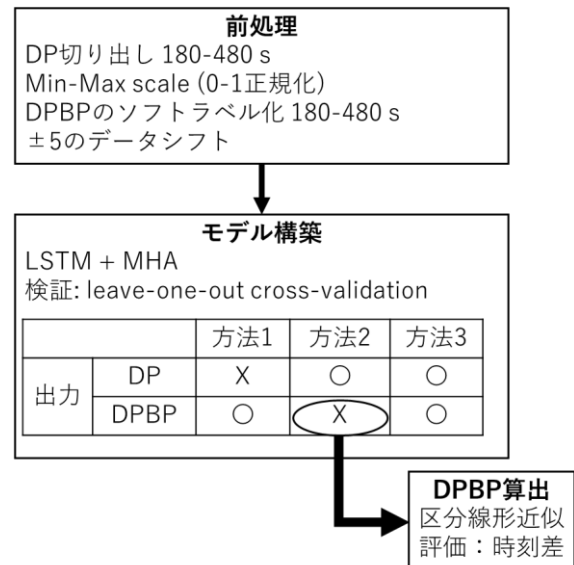


図1 方法の概略図

2.1 心肺運動負荷試験

心血管疾患患者71例(62.4 ± 14.0歳、男性52名)及び健康者46例(41.1 ± 15.5歳、男性26名)の計117例を対象に、以下のCPXを実施した。プロトコルは4分間の安静、4分間の10Wでのウォーミングアップ、続いて1分毎に10Wずつ負荷を漸増させるRamp負荷法とした(表1)。CPXに参加した被験者は呼気ガス分析装置及び非侵襲的な連続血圧測定器を装着している。本研究は、福岡大学倫理委員会の承認を得て実施された(承認番号: U22-10-012)。

[†] 福岡大学 工学部電子情報工学科 Department of Electronics Engineering and Computer Science, Faculty of Engineering, Fukuoka University, JAPAN

[‡] 福岡大学病院 循環器内科 Department of Cardiovascular Medicine, Fukuoka University Hospital, JAPAN

[§] 福岡大学病院 リハビリテーション部 Department of Rehabilitation, Fukuoka University Hospital, JAPAN

すべての被験者は、実験参加前に研究の目的、方法、参加者の権利について説明を受け、書面によるインフォームド・コンセントを取得した。

表 1 CPX : 心肺運動負荷試験

時間範囲 [s]	状態	負荷 [W]
0-240	安静	0
240-480	ウォーミングアップ	10
480-540	漸増負荷運動	20
540-600		30
600-660		40
660-720		50
720-780		60
780-840		70

2.2 データ構成

先行研究[3-6]で算出した DPBP を本研究の正解データと位置づけ、実 DPBP と定義する。実 DPBP は、負荷と DP を両対数軸に変換し 2 区間の区分線形近似、二乗平均平方根誤差を算出し、最小となる点である。

学習データと予測データの割合は 8:2 とした。入力データは、CPX の安静とウォーミングアップに当たる 180-480 s (300 点) の DP の 1 次元の時系列とした。±5 ステップの範囲でデータをシフトし、データ拡張を行った。DP の時系列データは、Min-Max スケーリングにより 0-1 に正規化した。教師データは、DPBP が頻出する 480-720 s (240 点) の DP の 1 次元の時系列及び DPBP のソフトラベル時系列 (240 点) とした。DPBP のソフトラベルは、DPBP が発現したタイミングを中心とし、その前後 3 s に渡り重みが徐々に減衰するように設計した。方法 1 では DPBP のみ、方法 2 では DP のみ、方法 3 では DP 及び DPBP を教師データとした。

DPBP が 480-720 s の範囲外にあった例及び 720 s 以内で負荷試験を終了した例を除外し、患者 46 例と健康者 41 例の計 87 例を本研究における研究対象とした。なお、学習時は心血管疾患患者と健康者のデータは同様に扱う。

2.3 モデル構成

入力データは長さ 300 の特徴量次元数 1 である。LSTM のレイヤー数 2、隠れ状態の次元 256、ドロップアウト率 0.2 とした。MHA の入力には LSTM の最終層から得られる隠れ状態系列である。MHA のアテンションヘッド数 8 とし最終タイムステップに対応するコンテキストベクトルを抽出し、全結合層により出力次元 240 とした。

損失関数は、DP に対して平均二乗誤差 (Mean Squared Error: MSE)、DPBP に対して 2 値交差エントロピー (Binary Cross Entropy: BCE) を用いた。方法 3 では、DP 損失と DPBP 損失を重み付きで加算した合成損失関数を用いた。重みは DP に 0.6、DPBP に 0.4 を設定した。パラメータ最適化には Adam 最適化アルゴリズム (学習率 $1e-5$) を用いた。最大エポック数は 3000 とし、過学習を防ぐため検証損失の改善が 10 エポック以上見られない場合に学習を終了する Early Stopping を適用した。データの検証には leave-one-out cross-validation (LOOCV) を用いた。つま

り、検証する被験者 1 例を除く 86 例で学習させたモデルでその 1 例の予測精度を検証することを被験者数分行った。

2.4 DPBP の決定

方法 1 及び 3 では、予測モデルから出力された 240 点の DPBP のソフトラベル時系列データに対し最大値を持つ点を DPBP とした。方法 2 では、予測モデルから出力された 240 点の DP の時系列データに対し区分線形近似を用いて DPBP を算出した (図 2)。

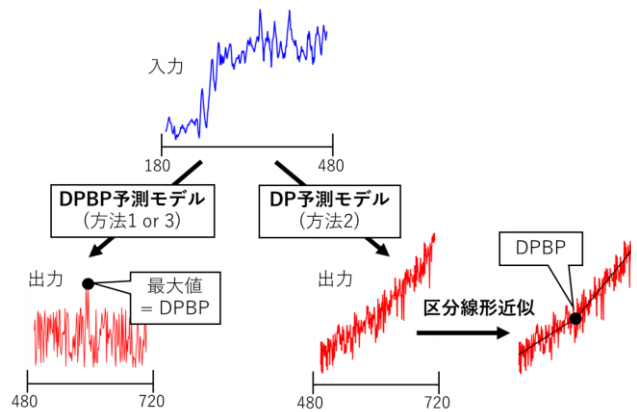


図 2 DPBP 推定までの流れ

区分線形近似とは、時系列データの 1 つの分割点の前後それぞれに一次関数を当てはめ、誤差が最小となる分割点を探索する手法である。区分線形近似により得られた分割点を DPBP とした。データの分割点の探索範囲は、最低区間長 10 を超えるよう時系列データの前後 10 点を除いた。前半区間に線形回帰を適用し、最適な直線を求める。その後、後半区間にも線形回帰を適用するが、この直線については、前半区間の直線との連続性を保つように傾きを最適化した。関数全体の連続性を保ちながら、前半及び後半区間に対する回帰結果から得られる予測誤差の合計を評価指標とし、この合計誤差が最も小さくなる分割点を探索した。

2.5 評価

方法 2, 3 の予測モデルが出力した DP の予測精度は二乗平均平方根誤差 (Root Mean Square Error: RMSE)、方法 1 から 3 で予測した DPBP は実 DPBP との時刻差で評価した。1 分毎に 10 W ずつ負荷を増やす CPX のプロトコルに基づき、時刻差 60 s 未満で予測できたデータは予測誤差の許容範囲とし、許容データ数を求め全体のデータ数における割合を算出した。

3. 結果

方法 2 による予測結果の例 (図 3) に示す実 DP (青) と予測された DP (赤) はよく一致 (RMSE = 1.19) し、算出された DPBP (x 軸と緑破線の交点 = 603) は実 DPBP = 603 と完全に一致した。一方、方法 3 による予測結果の例 (図 4) では、実 DP と予測された DP の概形は似ているが方法 2 に比べると一致しない (RMSE = 1.49)。しかし、算出された DPBP は 648 で実 DPBP = 603 との時刻差は 45 s となり、予測誤差の許容範囲である 60 s 以内での予測ができた。

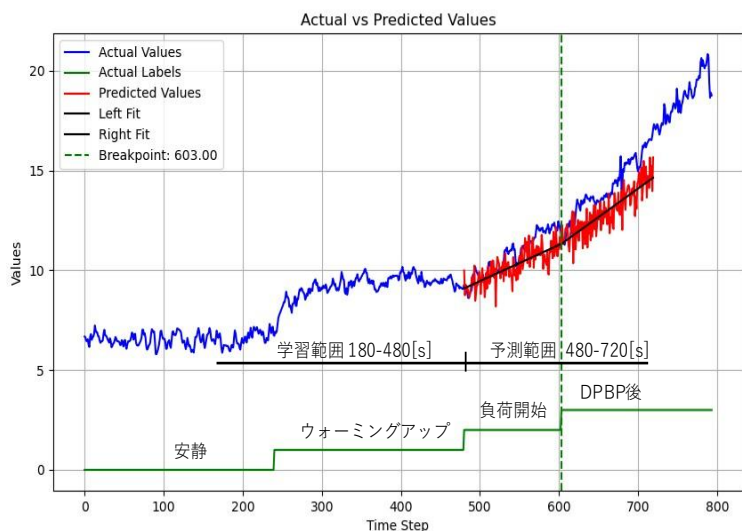


図3 方法2の結果

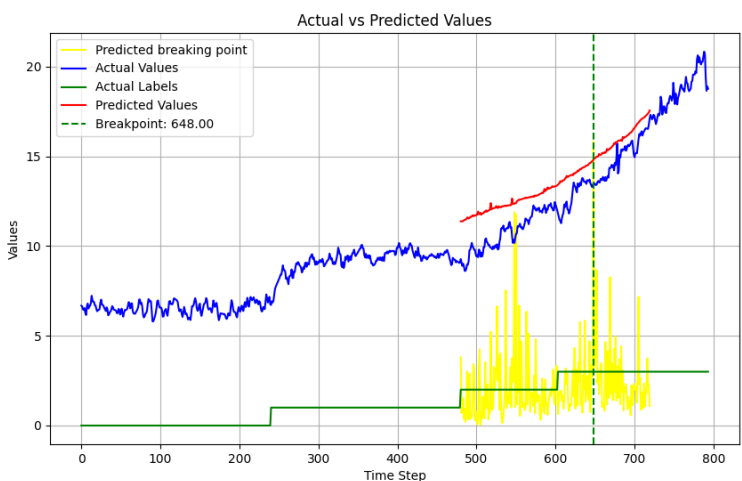


図4 方法3の結果

LOOCV による DP の予測精度 (RMSE) と DPBP の予測精度 (時刻差)、時刻差 60 s 未満となる許容データ数とその全体における割合を表 2 に示す。患者群、健常群、及び両群を含む全体の結果をそれぞれまとめて示した。

両群を含む全体に対し手法 2 を用いて算出した DPBP の予測精度 (時刻差) のヒストグラムを図 5 に示す。時刻差 60 s 以上となるデータもあるが、0 を中心にピークを持つ正規分布に近い形状となった。

予測精度が一番高かったのは、許容データ数の割合が 67.4% となった患者群における方法 2 を用いた場合である。RMSE を比べると、方法 3 より方法 2 で小さい値であることから、予測した DP が実 DP によく一致していた (図 3, 4) ことがわかる。また、時刻差を比べると、DPBP を直接予測する方法である方法 1 と方法 3 よりも、誤差を少なく DP を予測した上で DPBP を算出する方が小さい値となった。しかし、RMSE と時刻差のプロット (図 6) から、RMSE の値が小さくとも時刻差が大きい場合がある。つまり、正しく DP を予測できたとしても DPBP の算出の際にずれが生じてしまうことが示された。

4. 考察

予測誤差の許容範囲 60 s 以内のデータは最大 67.4% だった。予測された DPBP と実 DPBP の時刻差の平均 + SD の最大が 77.1 s である。これは、実 DPBP が正規分布であることからデータの 84% 程度が 77.1 s 範囲内で予測できていることがわかる。実 DPBP の正規性は Shapiro-Wilk 検定により評価した結果、正規分布が確認された ($p = 0.29 > 0.05$)。今回、CPX のプロトコルから 60 s を基準としたが、77.1 s は 10 W の誤差であり、臨床的に大きな差ではない。80% 以上のデータを小さい誤差で予測できたことから、現状の予測性能であっても臨床に利用できる可能性がある。

ただし、より高い予測精度を求めため、モデルのパラメータや学習データの範囲、方法 3 にお

表 2 モデル評価

		方法 1			方法 2			方法 3		
		全体	健常	患者	全体	健常	患者	全体	健常	患者
RMSE	mean	/			1.92	2.05	1.80	3.10	3.31	2.91
	SD				1.45	1.87	0.96	2.50	3.21	1.66
時刻差	mean	67.8	69.8	65.9	49.7	53.7	46.2	69.2	66.5	71.6
	SD	51.7	59.1	44.6	34.8	38.7	30.9	55.1	55.4	55.3
	mean + SD	119.5	129.0	110.5	84.5	92.3	77.1	124.3	122.0	126.9
	< 60	47	23	24	55	24	31	45	23	22
	< 60 [%]	54.0%	56.1%	52.2%	63.2%	58.5%	67.4%	51.7%	56.1%	47.8%

全体 (n=87), 健常者 (n=41), 患者 (n=46)

ける損失関数の重みの調整、別モデルの使用等、予測精度を向上させられるか検証する余地がある。特に、方法 3 での合成損失関数の重みは DP に 0.6、DPBP に 0.4 と設定したが、方法 1 の予測精度が方法 2 よりも低いことから、DP の重みをより大きく、DPBP の重みをより小さくすることで予測精度が向上する可能性がある。

また、方法 3 で出力される DP は DPBP 算出に利用されていない。方法 2 の区分線形回帰を用いた DPBP の予測精度が高かったことから、方法 3 で出力される DP に対しても区分線形回帰を用いて DPBP を推定し、直接予測された DPBP との平均を取ることで予測精度が向上する可能性がある。また、方法 2 における正しく DP を予測できたとしても DPBP の算出の際にずれが生じてしまう問題に対して、区分線形回帰の手法の修正を検討する。

生体データ特有のノイズを考慮し DPBP を一点で算出するのではなく複数の候補となる DPBP を算出し平均を取ることで改善される可能性がある。

5. 結論

安静時から準備運動までの DP の変化を用いて至適運動強度を予測するニューラルネットワークモデルを構築した。予測された DPBP と実 DPBP の時刻差は予測誤差の許容範囲内であるものが 67%となり、84%のデータは 10 W 誤差で判定が可能であった。以上より、現在の予測性能でも臨床に利用できる可能性がある。安静時から準備運動までのデータから DPBP を予測可能となると、日々の至適運動強度の把握に有用である。今後は、更に予測精度を向上させるため、現在のモデルのパラメータ調整や学習データ範囲の変更、DPBP 算出方法の変更、他のニューラルネットワークモデルの適用等を検討していく予定である。

謝辞

本研究は、日本学術振興会の科学研究費助成事業「非侵襲連続血圧計による心筋酸素消費量指標開発と最適な運動処方アルゴリズムの実用化（基盤研究 C、2023 年 4 月～2026 年 3 月、課題番号: 23K10468）」により支援を受けて実施されました。また、データを提供いただいた被験者の皆さまに感謝いたします。

参考文献

- [1] 田畑 稔, “有酸素運動の基本”, 理学療法ジャーナル, Vol. 42, Issue 6, Pages 515-526 (2008)
- [2] Taylor Jenna L., Bonikowske Amanda R., Olson Thomas P., “Optimizing Outcomes in Cardiac Rehabilitation: The Importance of Exercise Intensity”, *Frontiers in Cardiovascular Medicine*, Vol. 8, Article 734278 (2021)
- [3] 末松 保憲, “非侵襲連続血圧を用いたダブルプロダクトによる嫌気性代謝閾値の測定について”, 日本心臓リハビリテーション学会 第 8 回東北支部地方会 教育講演 (2023)
- [4] 末松 保憲, “指先で測定する非侵襲連続血圧計による Double product breaking point と AT との相関要因について”, 第 29 回日本心臓リハビリテーション学会学術集会 一般口演 (2023)
- [5] 末松 保憲, “Strategy of non-invasive, simple, and accurate determination of anaerobic threshold in patients with cardiovascular diseases”, 6th APCMS Congress, keynote lecture (2023)
- [6] 末松 保憲, “運動負荷時の血圧・心拍応答を改めて見直す”, 第 28 回日本心臓リハビリテーション学会学術集会 学術委員会特別企画シンポジウム (2023)
- [7] Tanaka H, Kiyonaga A, Terao Y, Ide K, Yamauchi M, Tanaka M, Shindo M, “Double product response is accelerated above the blood

lactate threshold”, *Medicine & Science in Sports & Exercise*, Vol. 29, Issue 4, Pages 503-508 (1997).

- [8] Kenta Kawamura, Kazumichi Ae, Kazuhide Tomita, “Prediction of the oxygen uptake patterns during an incremental exercise test using long short - term memory in electromyography”, *Japanese Journal of Physical Fitness and Sports Medicine*, Vol. 70, Issue 6, Pages 355-362 (2021).
- [9] X. Guo, Z. Lun, Q. Chu, “Detection of the Anaerobic Threshold from Cardiopulmonary Exercise Test Data with EO-Attention-LSTM”, 42nd Chinese Control Conference, Pages 8229-8233 (2023)

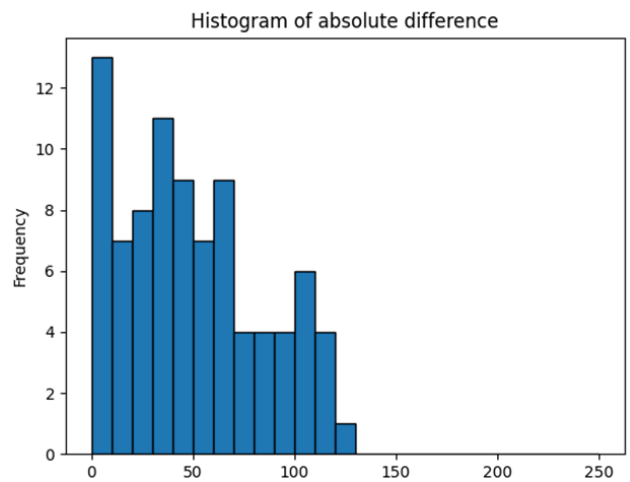


図 5 方法 2 の時刻差のヒストグラム

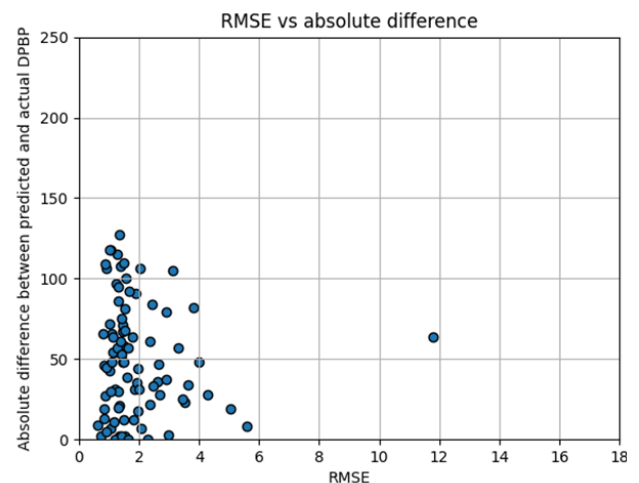


図 6 方法 2 の RMSE vs 時刻差