

生活関連機器への組み込みを目的とした 心電図認証システムにおける識別手法の検討

生体計測工学研究室 2181227 小林誠耶

(主査：京相 雅樹 教授， 副査：桐生 昭吾 教授， 桃沢 愛 准教授)

1. はじめに

現在日本に於いて 2 番目に死因の割合として高いのが心疾患である [1]. この疾病の早期発見・治療のために日常的な心電図の計測を行い，長期間の検査を行うことが有効とされており，近年では便器等の家具をモチーフとしたデバイスに埋め込んだ電極から心電図を計測する技術の研究が行われている．しかしこのような家具は複数人が共有するケースが想定されるため，計測したデータから健康状態を類推するには，あらかじめ個人ごとのデータに分類する機能が必要となる．先行研究では 3 層ニューラルネットワークを用い，ある程度特定された心電データから個人のデータに分類，集約することを目的とした個人識別が検証されている [2]. 一方で家具に取り付けられるスペックのコンピュータを用いて個人識別を行う場合，特徴量抽出や識別に要する計算量は極力低い方が望ましい．そこで本研究では，浴槽内に設置した電極から計測した 11 人分の心電図に対して機械学習を行い，個人データごとに分類を行った．心電図に含まれる幾何学的な特徴量を 17 個抽出し，それぞれをニューラルネットワーク，サポートベクタマシンに入力することで識別率及び識別に要する計算時間を比較検証した．またノイズの多く含まれるデータに対しても汎用的に高精度識別が可能となるよう，データ集合ごとに特徴量の最適化を行った際の識別率改善の検証を行った．

2. 理論

2.1 心電図

心臓が有効なポンプとして機能するには，心筋が収縮・弛緩を繰り返す必要があり，これは刺激伝導系によって行われている．正常な心臓では，洞房結節の細胞がペースメーカーとして電気的興奮を惹き起こし，左右の心房に伝播した後，房室結節，ヒス束，左脚・右脚を介してプルキンエ線維に伝わり心臓全体に広がる．心電図の構成要素は心房の脱分極に伴い発生する P 波，心室の脱分極に伴い発生する QRS 波，心室の再分極に伴い発生する T 波で構成される．Fig.1 に刺激伝導路，Fig.2 に心電図波形の構成を示す．




Fig.1 Conduction system




Fig.2 Composition of ECG waveform

2.2 ニューラルネットワーク

ニューラルネットワーク(NN)は多層パーセプトロンとも呼ばれ、単純パーセプトロンを多数組み合わせさせた構造をした機械学習アルゴリズムである。単純パーセプトロンを組み合わせることで、単体のみでは実現不可能な非線形分離が可能となる。NN は様々な形状が存在するが、本研究では 3 層型のフィードフォワード型 NN を用いた。この NN は入力層、中間層、出力層の 3 層から成り、入力値と重みパラメータの積の合計値に対し活性化関数を用いて計算し、最終的に出力層の数値をもとに分類を行う。入力層には入力変数分のノード数、出力層には分類したいクラス分のノード数を設定する。

2.3 サポートベクタマシン

サポートベクタマシン(SVM)は複数のデータグループに対して、マージンが最大となるように各データから最も離れた決定境界を学習する機械学習アルゴリズムである。線形 SVM では n 次元空間に於いて、各データ集合を分離超平面で区切ることで分類を行う。このとき、学習データのうち最も超平面に近いものと超平面との距離をマージンと呼ぶ。

学習データの特徴ベクトルを $\mathbf{x}^T = (x_1, x_2, \dots, x_n)$ 、重みパラメータを $\mathbf{w}^T = (w_1, w_2, \dots, w_n)$ とする。また各グループから分離超平面に最も近いデータをそれぞれ \mathbf{x}_+ , \mathbf{x}_- とすると、マージン d は式(1)で求めることが可能である。

$$d = \frac{|\mathbf{w}^T \mathbf{x}_+ + b|}{\|\mathbf{w}\|} = \frac{|\mathbf{w}^T \mathbf{x}_- + b|}{\|\mathbf{w}\|} \quad (1)$$

ここで、分離超平面 H と、 \mathbf{x}_+ , \mathbf{x}_- の間にはデータが存在しないため、SVM の問題は「全てのデータは超平面からの距離が少なくとも d 以上であるという条件下で、マージン d を最大とする \mathbf{w} , b を求める」という問題に帰着する。即ち、式(2)によって SVM の最適化を行うことができる。

$$\{\hat{\mathbf{w}}, \hat{b}\} = \arg \max_{\mathbf{w}, b} d(\mathbf{w}, b) \text{ s. t. } \frac{|\mathbf{w}^T \mathbf{x}^i + b|}{\|\mathbf{w}\|} \geq d \quad (2)$$

3. 方法

3.1 計測方法

Fig.3 に浴槽を用いた計測の概略を示す。お湯を張った浴槽内の被験者に対し、浴槽背面部に埋め込まれた電極から 11 人分の背部心電図を計測した。実用的なデータ分類を想定し、異なるタイミングで計測した安静状態の計測データを 2 種類、スマートフォンを操作しながら計測したデータを 1 種類、マッサージ時のデータ 1 種類の計 4 種類を作成した。また計測したデータに対し、Table 1 に示すフィルタを用いてノイズ除去を行った。




Fig.3 Measurement position

Table 1 Digital filter settings

Parameter	Setting
Filter type	Butterworth
High Pass Filter[Hz]	2
Low Pass Filter[Hz]	100
Hum Filter[Hz]	50

3.2 説明変数の抽出

波形データを用いて識別を行う場合、心拍数や体動の変化に起因するノイズの影響で波形が歪み、識別率が低下する可能性がある。そこで先行研究を参考に Table 2 に示す 17 個の特徴量を抽出し、機械学習の説明変数として用いた [3]。Christov 法を用いて R 波ピークを検出し、このピークを基準として他特徴量を抽出した [4]。なお RS, ST, RT 間隔は心拍数によって変動するため、RR 間隔を用いて正規化した。

Table 2 List of features

Feature	Detail	Feature	Detail
Q_{amp}	Q wave amplitude	DR	R peak amplitude 1 st derivative waveform
R_{amp}	R wave amplitude	DS	S peak amplitude 1 st derivative waveform
S_{amp}	S wave amplitude	DS / DR	DS divided by DR
T_{amp}	T wave amplitude	Angle QR	Angle between Q,R
RS_{int}/RR_{int}	Normalized RS interval by RR interval	Angle QS	Angle between Q,S
ST_{int}/RR_{int}	Normalized ST interval by RR interval	Angle RS	Angle between R,S
RT_{int}/RR_{int}	Normalized RT interval by RR interval	Angle ST	Angle between S,T
S_{amp}/R_{amp}	S amplitude divided by R amplitude	S_{QRS}	Area of region bounded by QRS
T_{amp}/R_{amp}	T amplitude divided by R amplitude		

3.3 NN 及び SVM を用いた識別率評価

抽出した特徴量を用いた機械学習によりデータの個人分類を行った。先行研究で用いられていた NN との比較対象として、線形 SVM の識別結果を算出した。Table 3 に学習データとテストデータの組み合わせを示す。学習データの内ランダムに選択した 70% をモデルの学習に、テストデータのうちランダムに選択した 30% を性能の評価に用いた。Table 4 に NN, Table 5 に SVM のパラメータ設定を示す。なお本研究では機械学習モデルの識別性能を正解率 (accuracy) で定義した。正解率は全データの内、正しく識別できた割合を表す。Table 6 に混同行列の定義、式(3)に accuracy の算出法を示す。学習及び評価は 5 回行い、識別率の平均・分散を算出した。また、NN と SVM の個人識別処理に必要な計算量を比較するため、識別に要する処理時間の計測を行った。各機械学習モデルに学習データを入力し、学習及びデータの識別が終了するまでの時間を計測し、平均・分散を比較した。なお、処理を行った PC のスペックは、CPU AMD Ryzen 5 1400 Quad-Core Processor 3.20GHz, メインメモリ 16GB である。

Table 3 Combination of training and test data

学習データ	テストデータ
安静時データ 1	安静時データ 2
安静時データ 1	スマホ操作時データ
安静時データ 1	マッサージ時データ
安静時データ 2	スマホ操作時データ
安静時データ 2	マッサージ時データ

Table 4 Neural network settings

Parameter	Setting
Input layer size	Number of features
Hidden layer size	16
Hidden activation	relu
Output layer size	8
Output activation	softmax
Optimizer	adam
Loss function	Categorical crossentropy
Batch size	8
Epochs	50

Table 5 Support vector machine settings

Parameter	Setting
Kernel	linear
C	1.0
Gamma	1/number of features

Table 6 Confusion matrix

		predicted	
		positive	negative
true	positive	TP	FN
	negative	FP	TN

$$accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (3)$$

3.4 5人分のデータを用いた場合の識別率

3.3の検証によって得られた混同行列より、11人分のデータを用いた場合被験者によって大きく識別率が異なることが判明した。そこで11人分のデータから5人分のデータを選択する全組み合わせでSVMによる識別を行い、被験者グループごとの識別率変化を検証した。

3.5 5人のデータグループに対する特徴量の最適化

3.4の検証結果より、被験者グループによって識別率に大きな差が生じることが判明した。そこで各データの組み合わせに於いて特に識別率の低かった被験者組みの特徴量データについて、17種類の特徴量から10個の特徴量を選択する組み合わせを全てSVMに入力し、識別率が最大でどの程度まで改善するか検証した。

3.6 全被験者グループに於ける特徴量の最適化

3.5の結果より、5人グループの被験者については特徴量の最適化を行うことで識別率が大幅に増加することが確認できた。そこで11人分の全被験者に対する分類についても同様に特徴量を最適化し識別率の改善率を調べた。本検証についても各データの組み合わせについて17個の特徴量から10個を選択することで、識別率が最大でどの程度改善するのか検証した。

4. 結果・考察

4.1 計測方法

Fig.4 に被験者 A の安静時 1, 安静時 2, スマホ操作時, マッサージ時データについて, 計測波形とフィルタ済み波形を示す. 安静時とスマホ操作時は比較的明瞭な波形が計測できていたが, マッサージ時は体動に由来すると考えられるノイズ混入やピーク振幅の低減等が確認された. 波形に含まれるノイズは, デジタルフィルタ処理によって除去することができ, 安定した波形データを生成することができた.

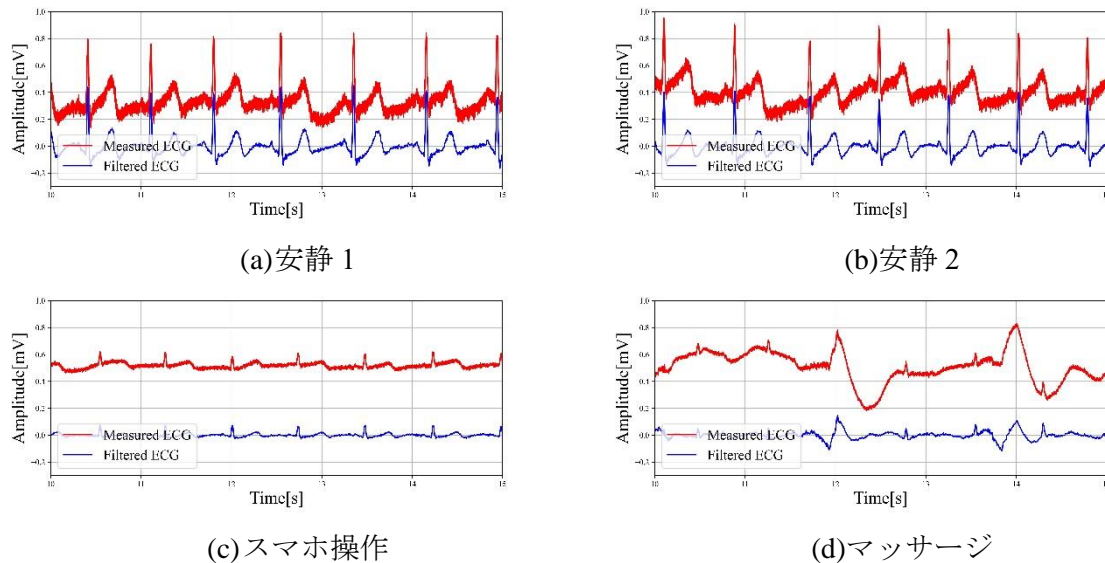


Fig.4 Measured ECG and filtered ECG

4.2 説明変数の抽出

Fig.5 に全被験者の安静 1, スマホ操作, マッサージ時から抽出した特徴量の内 R_{amp} , S_{amp} , T_{amp} の値を 3次元にプロットした結果を示す. 散布図をみると, 安静時及びスマホ操作時の特徴量は被験者ごとにおおよそ集中して分布していたが, マッサージの分布には大きな分散があり, 被験者間で分布が混在している領域が確認された. そのためデータごとに最適な特徴量を選択しなければ明瞭な識別は困難であると考えられる.

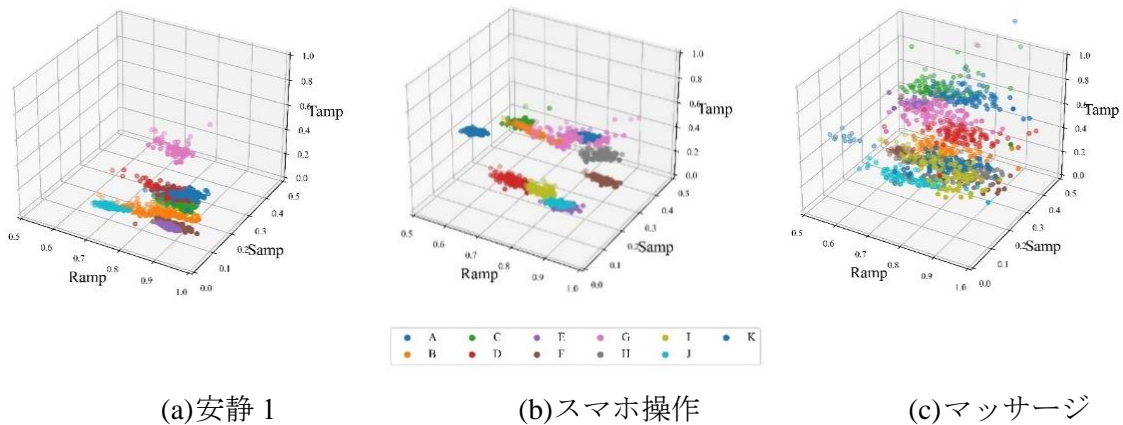




Fig.5 Distribution of features

4.3 NN 及び SVM を用いた識別率評価

Fig.6 の(a), (b)に NN と SVM に 17 個の特徴量を入力した際の識別率を示す. 各グラフ横軸は”{学習データ}-{評価データ}”の組み合わせを表す. 各グラフを見ると, NN と SVM を用いた場合の識別率に大きな差は見られなかった. また各データを用いて学習と評価を行った結果として, 安静時は約 80%の識別ができていたのに対し, スマホ操作時は平均約 55%, マッサージ時は平均約 30%程度まで低下していた. 体動ノイズ等を多く含むスマホ操作, マッサージ時データは安静時と比較して識別率が低下したのだと考えられる. また処理に要した時間は, NN が 6.19 秒, SVM が 8.84 ミリ秒となり, SVM により処理時間を約 99.8%削減できた. そのため SVM を用いることで, 識別率を保持したまま大幅に計算量を削減できると考えられる.



(a)NN を用いた分類の識別率



(b)SVM を用いた分類の識別率

Fig.6 Identification rate using NN and SVM

4.4.5 人分のデータを用いた場合の識別率

Fig.7 に 11 人分の被験者から 5 人を選択し, 各被験者グループの特徴量を SVM で分類した結果を示す. グラフ内の赤字は最も識別率の高かった被験者組み合わせ, 青字は最も低かった被験者組み合わせを表す. いずれのデータに於いても被験者の組み合わせにより大きく識別率が変化することが分かった. 安静時データ, スマホ操作データをテストデータに用いた場合, 最高識別率はほぼ 100%である一方, 最低識別率は 30~50%まで低下していた. 似た波形を持つ被験者同士のデータを用いて分類を行った場合, 誤判定が多くなり識別率が低下するのだと考えられる. またマッサージ時のデータを用いた場合, 最高識別率は約 70%まで低下した.

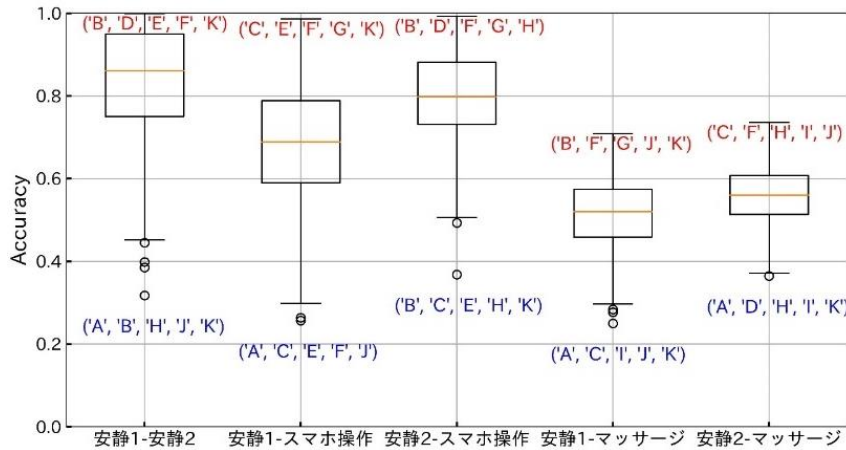


Fig.7 Change in identification rate in subject combinations

4.5 5人分のデータを用いた場合の識別率

Fig.8 に特徴量の最適化を行った場合の識別率の変化を示す。グラフ中の青いプロットは Fig.7の各データの組み合わせに於いて最も識別率の低かった被験者組み合わせの識別率を示し、赤いプロットは、同じ被験者組み合わせに於いて特徴量を最適化した際の最高識別率を示す。特徴量を被験者の組み合わせごとに最適化することで大幅に識別率を改善することに成功した。Fig.8 を見るといずれのデータについても約 70%を超える識別率に改善しており、システムを利用するユーザの組み合わせに応じて最適な特徴量の組み合わせを選択することで、高い識別率で分類システムを運用することが可能になると考えられる。

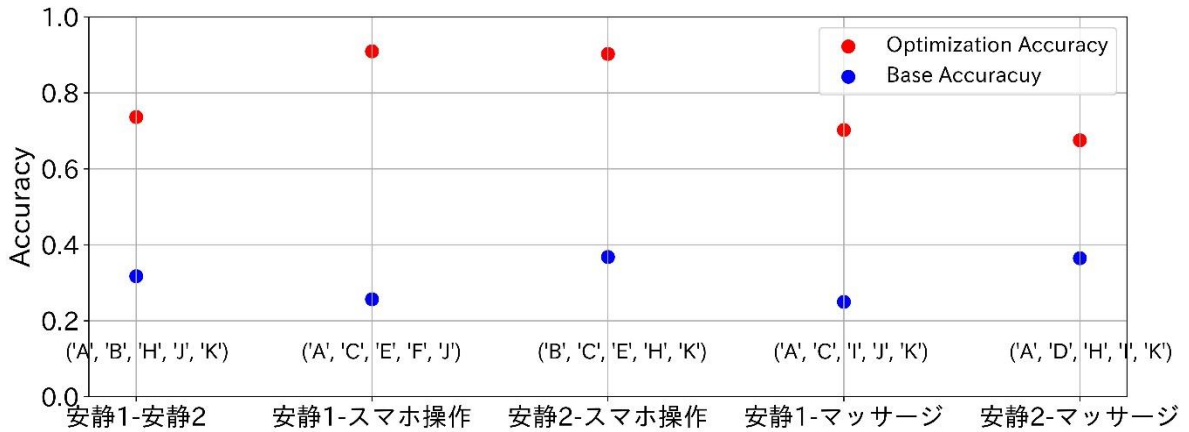


Fig.8 Change in identification rate with feature optimization

4.6 全被験者グループに於ける特徴量の最適化

Fig.9 に、11人分の被験者データについて特徴量を最適化した際の識別率変化について示す。グラフ中の青い点は17個全ての特徴量を用いた際の識別率を示し、赤い点は最適化により特徴量を10個選んだ際の識別率を示す。最適化を行った場合、識別率は10~20%ほど向上した。この結果より、識別の対象となるグループの人数に関わらず、特徴量を最適化すること

で識別率を向上させることが可能であると考えられる。一方で Fig.8 に示す比較的少人数のデータグループに対する特徴量最適化の結果と比較すると、識別率の改善率は小さかった。これは対象となる被験者数が多いために、特徴量最適化の識別率への影響が緩和されるためであると考えられる。




Fig.9 Change in identification rate with feature optimization for all subjects

5. まとめ

本研究では浴槽背面に設置した電極から計測した心電データから特徴量を抽出し個人識別を行った。結果として、特徴量を SVM に入力することで、NN と比較して識別率を保持したまま処理時間を最大 99.8%削減できることが判明した。またデータの組み合わせに応じて特徴量の組み合わせを変更し最適化することで識別率を改善できることが判明し、SVM による個人分類アルゴリズムと特徴量最適化を用いることで高い識別率を保持したまま大幅に計算量を削減できることが分かった。本研究では特徴量最適化に総当たりで特徴量を選択する方法を採用しているため、非常に大きな計算量が必要となる。そこで本提案手法に、より効率的な特徴量最適化アルゴリズムを組み合わせることで、マイコンレベルのスペックを持つコンピュータを用いて、個人分類システムを実装することが可能になると推察される。

参考文献

- [1] 厚生労働省, 平成 29 年(2017)人口動態統計(確定数)の概況, 統計情報白書.
- [2] 川口哲, 心電図の個人識別における心拍変動時の性能評価と改善, 東京都市大学 総合理工学研究科 電気・化学専攻 修士論文, 令和 2 年.
- [3] 中川新太, 金主賢, 中島一樹, 便座心電図を用いた個人識別の基礎的研究, 生体医工学 56 卷 5 号, 2018.
- [4] I.Christov, Real time electrocardiogram QRS detection using combined adaptive threshold, BioMedical Engineering Online 3:28, 2004.