

[研究論文] 特微量選択手法およびシステム構成の
最適化によるうつ病 CAD の高性能化

牧優太¹・和田昇太¹・安倍和弥²・武尾英哉²・永井優一³

1 博士前期課程電気電子工学専攻

2 電気電子情報工学科

3 国立がん研究センター東病院

Improving the performance of Depression CAD
by using feature selection methods and optimizing system configuration

Yuta MAKI¹, Shota WADA¹, Kazuya ABE², Hideya TAKEO², Yuichi NAGAI³

Abstract

The number of subjects with depression in Japan has been increasing and the number of medical examinees has also been increasing. Therefore, more appropriate diagnosis is required. However, the diagnosis of depression and other mental disorders has not been made using objective indicators such as biomarkers, and the accuracy of the diagnosis has been questioned. Therefore, we are developing a system for calculating the confidence of depression to help physicians to make a diagnosis. To achieve a higher accuracy than the conventional discrimination accuracy, we optimized the program's configuration by adding a voice classifier and using Leave-one-out cross-validation etc. Also, we performed feature selection using 18 feature selection methods and extraction of the optimal model using a brute force algorithm of feature combinations. As a result, the discrimination accuracies of 90 %, 95 %, and 100 % for male, female, and mixed-sex data were achieved, respectively, which is higher than the conventional accuracy of 83 %.

Keywords: Depression, Feature selection, Optimization

1. はじめに

我が国におけるうつ病患者は増加傾向にある。その要因は複数あるが、一つとして受診者数の増加があげられる。そのようなになったのは、以下のような結果が現れてきたからである。

- 1) 「うつ病は心の風邪で、誰にでもなりうる」といった風潮の広がりによる、精神科病院への受診の抵抗感の低下¹⁾
- 2) 国や民間の啓蒙活動によるうつ病の症状の認知

この受診者数の増加によって、過剰診断等の問題が見逃げせないものとなったため、より適切な診断を行えるようになることが求められている²⁾。

このうつ病等精神疾患の診断方法であるが、問診によって患者の症状及びその期間を聞き取り、DSM-5(精神障害の診断と統計マニュアル第5版)やICD-10(国際疾病分類第10版)などの診断基準に照らし合わせ、診断を行うという方法をとっている³⁾。しかしながら、この診断方法には次のような問題がある。

- 1) 患者自身の自覚症状の有無や自己申告に頼らざるを得ない
- 2) 診断には医師の主観が影響してしまう
- 3) 客観的な指標(バイオマーカー等)がない

上記の問題から、うつ病をはじめとした精神疾患は、客観性の欠けた方法で診断が行われているというのが現状である。

以上を踏まえ、我々はうつ病の客観的な診断のために、画像工学技術等を利用してうつ病である確信度を算出し、医師の診断の参考にしてもらうシステムの開発を行っている。

本論文のようにうつ病の症状等を定量化し、その数値をバイオマーカーとして用いることを試みる研究や、うつ病の判別を行う研究、重症度を推定する研究は国内外で行われている。例えば音声に関しては、篠原ら⁴⁾は、ゼロ交差率とハースト指数の関係性に基づく音声指標を用いて重症度測定を行い、その有効性を示唆している。四井ら⁵⁾はうつ病患者の重症度の算出のため、音声の波形データを画像として扱い、CNNでうつ病か健常者かどうかの判別を行うことをしている。医用画像に関しては、清水ら⁶⁾はfMRI画像に対し主にLASSOを用いた機械学習を行った結果、

90%以上の精度でうつ病の判別を行えている。また、市川ら⁷⁾も fMRI 画像を用いた複数の機械学習アルゴリズムによる判別で、84%の精度を得られている。一般画像では、Andrew ら⁸⁾が Instagram に投稿した画像から、うつ傾向のある人物を約 70%の精度で識別している。本研究では、上記で示したような音声や画像等の情報単体で判別等を行うのではなく、複数の情報を用いて、総合的にうつ病である確信度の算出等を行う。

このうつ病である確信度を算出するシステムについて、従来の研究では2段 stacking 構成で行っていた。これは、視線方向と表情に着目し、それぞれのデータを単体の判別器で学習させ⁹⁾、その2つのモデルの出力を組み合わせる。そして、それを入力として複数の判別器で学習を行い、逐次選択型という方法などで、スコアの算出を行う方法である。その結果、約 83%の精度でうつ病患者と健常者の判別を行うことができていた^{10), 11)}。

本論文では、より判別精度を向上させる、より正確なうつ病である確信度を出せるようにするために行った、特徴量選択の手法や2段 stacking 構成の最適化などの方法とその結果について記す。

また、第2章で本論文に使用している動画とラベル付けについて、第3章では精度向上のために用いる手法等を説明する。第4章では第3章の手法による結果を、第5章は第4章の結果からの考察をまとめている。第6章では現在の取り組みについて述べる。

2. データについて

本論文に使用されている動画は、動画投稿サイトに投稿されていたものを使用している。使用した動画の条件としては、投稿者がカメラの正面に位置し、カメラに向かって話し、なおかつ BGM が無いものとして収集を行った。収集した動画に対するうつ病患者と健常者のラベル付けは、動画内で自身がうつ病だと明言している人物をうつ病患者、同様にうつ病だと明言していない人物を健常者というように行った。本来であれば、実際のクリニック等で診断を受けた様子の、もしくは確実に診断を受けた患者の動画を用いることが望まれる。しかしながら、医師の協力を得られなかったため、上記のような動画の使用、ラベル付けを行った。今後医師の協力が得られたあかつきには、現在使用している動画の評価や動画の提供を依頼し、信頼性の高いシステムを構築していくことを目指していく。この収集の結果として、表1のようにそれぞれうつ病患者 10 名、健常者 10 名の計 20 名のデータを、男女別に集めることができ、サンプル数は 40 名となった。

本論文では、実験用データの作成にあたって、使用する動画の長さを 200 秒から 240 秒の間と一定にしている。

Table 1 動画サンプル

	Depression	Normal	Total
Men	10	10	20
Women	10	10	20
Mix	20	20	40

3. 手法

本論文で用いた、うつ病確信度算出、ひいてはうつ病判別システムに用いるプログラムの構成を図1に示す。全体的な構成は従来の2段 stacking 構成とほぼ同じであるが、異なる点を以下に示す。

- 1) 音声を用いた判別器の追加
- 2) 特徴量選択手法のアンサンブル化モデルの実装
- 3) 特徴量の組み合わせの総当たりアルゴリズムの実装
- 4) 2段 Stacking 構成の最適化

これらの詳細もしくは概要を本章 3.1, 3.2, 3.3, 3.4 に述べる。

3.1. 音声を用いた判別器の追加

和田ら¹²⁾が作成した、音声によるうつ病判別器を Stage1 に組み込んだ。これは、図2に示すように、音声信号から発話量などに着目して 42 種類の特徴量を作成し、それらを用いて線形 SVM で学習を行ったものである。作成した特徴量等の詳細については、同研究報告論文 No. 4 に記載されているため、そちらを参考にしてほしい。

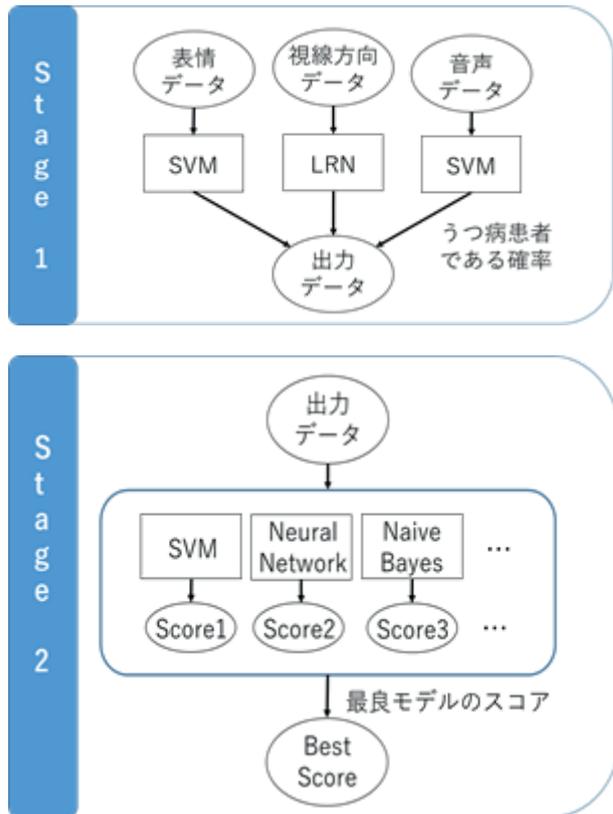


Fig. 1 2段階の stacking モデル

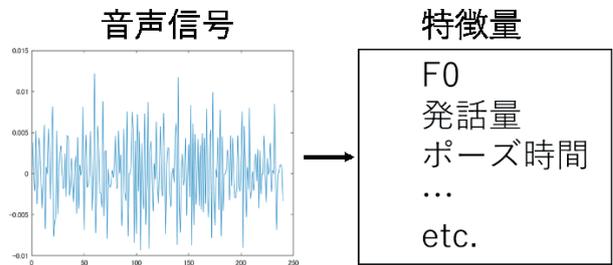


Fig. 2 音声データからの特徴量作成

3.2. 特徴量選択のアンサンブル化モデルの実装

図3に今回使用した特徴量選択のアンサンブル化モデル(以降、アンサンブル化モデルと呼ぶ)の概要について記す。このアンサンブル化モデルは、複数の特徴量選択手法で、段階に分けて特徴量を選択する方法である。図に示した通り、複数の特徴量選択手法を用いて特徴量選択を行い、共通部分(厳密に言えば、手法毎の組み合わせによる

共通部分も斜線部分に入る)にある特徴量を選択する。Phase1では共通部分の特徴量の中で、X回以上各手法で選択されれば採用とし、Phase2に移行。Phase1で採用された特徴量に対し複数の手法で特徴量選択を行い、Y回以上で最終的な特徴量の採用としている。

表2に、各Phaseでの、特徴量選択の手法を大まかなタイプに分けたときの総数を示す。表より、Phase1ではFilter法で8、wrapper法で1、Embedded法で6の総計15種類の特徴量選択手法を用いている。Phase2では、Decision tree そのものや、それを用いたランダムフォレストなどの3種類を用いている。表3および表4にPhase1での、wrapper法を除いたFilter法とEmbedded法で用いた特徴量選択手法と、選択する際に目安とした値について示す。

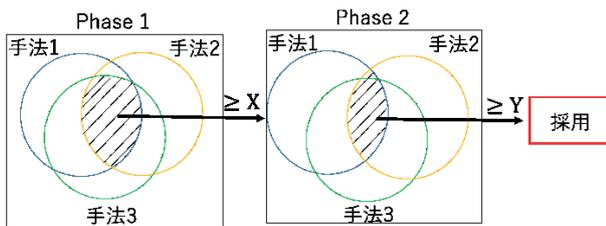


Fig. 3 アンサンブル化モデル

Table 2 各Phase, 方法での特徴量選択手法の数

Phase	Method	Total
1	Filter	8
	wrapper	1
	Embedded	6
2	Decision tree	3

Table 3 Filter法で用いた特徴量選択手法

method	parameter
分散分析	F値
χ^2 統計量	p値 (-log (p))
最小冗長性特徴選択	スコア
F検定	p値 (-log (p))
ラブラシアンスコア	スコア
相関の高さを利用した特徴量選択	相関係数
近傍成分分析	重み
ReliefFアルゴリズム	重要度(重み)

Table 4 Embedded法で用いた特徴量選択手法

method	parameter
線形判別分析分類器	係数
ECOC(誤り訂正出力符号)	係数
線形回帰モデルのあてはめ	係数
リッジ回帰モデル	係数
ElasticNetを用いた正則化	係数
LASSO正則化	係数

以下にPhase1で使用した手法と選択の仕方について簡単に記す。

1) Filter法

・分散分析
分散分析を使用して、個々の特徴量のF統計量を算出する。そして、その値が大きいものから選択する。

・ χ^2 統計量
カイ2乗検定を使用して、個々の特徴量の検定統計量p値を算出する。そして、真数として $-\log()$ の式に入力し、そのスコアが大きいものから選択する。

・最小冗長性特徴選択
最小冗長性最大関連性 (mRMR) アルゴリズム¹³⁾を使用して、各特徴量のスコア (重要度) を算出する。その値の大きいものから選択する。

・F検定
応答 (ラベル) をうつ病患者 1, 健常者 0 というように数値化し (以降、数値化と呼ぶ)、それに対しF検定を行う。各特徴量の値でグループ化された応答値が同じ平均の母集団から抽出されたという帰無仮説を、母集団の平均がすべて同じではないという対立仮説に対して検定を行い、p値を得る。そして、真数として $-\log()$ の式に入力し、そのスコアが大きいものから選択する。

・ラブラシアンスコア
初めに数値化を行ってから、ラブラシアンスコア¹⁴⁾を使用して、各特徴量のスコア (重要度) を算出する。そして、そのスコアが大きいものから選択する。

・相関の高さを利用した特徴量選択
初めに数値化し、その応答値と各特徴量との相関係数を算出する。そして、相関の高い (正負は問わない) のものから選択する。

・近傍成分分析
正則化パラメーターの値を変えながら5分割交差検証法で近傍成分分析に学習を行い、最小の損失となる時の、最適な正則化パラメーターを見つける。そのパラメーターの状態での、学習済みモデルの特徴量の重みを抽出し、その重みが大きいほうから選択する。

・ReliefFアルゴリズム
k最近傍分析 (k=10) をReliefFアルゴリズム¹⁵⁾に適応し、各特徴量の重みを算出する。そして、その重みが大きいほうから選択する。

2) wrapper法

・前方特徴量選択
特徴量を0から、1つ1つと特徴量を追加していく。基準となる誤分類率が減少しなくなるまで続けていき、追加を終了した時点での特徴量を、追加が早い順に選択する。

3) Embedded法

・線形判別分析分類器
線形判別分析分類器の学習の際、5分割交差検証損失が最小となるようなハイパーパラメーターの最適化を行い、その状態の時の各特徴量に対応する係数を求める。そして、その係数の大きい方から選択する。

・ECOC
ロジスティック回帰学習器を使用する線形分類モデルを基とした、ECOC (誤り訂正出力符号) モデルを用いる。5分割交差検証損失が最小となるようなLASSOペナルティ (L1正則化項) を見つけ、その時の線形係数を求め、その値の大きい方から選択する。

・線形回帰モデル
ロジスティック回帰学習器を使用する線形分類モデルを用いる。LASSOペナルティの値を変化させたときの、線形分類モデルの交差検証AUCと使用された特徴量数 (係数の非0の数) のグラフを作成する。そのグラフを図4に示

す。この図から特徴量数と AUC の高さのバランスがとれている LASSO ペナルティの値を選択し、その値の時の線形係数を求め、その値の大きい方から選択する。

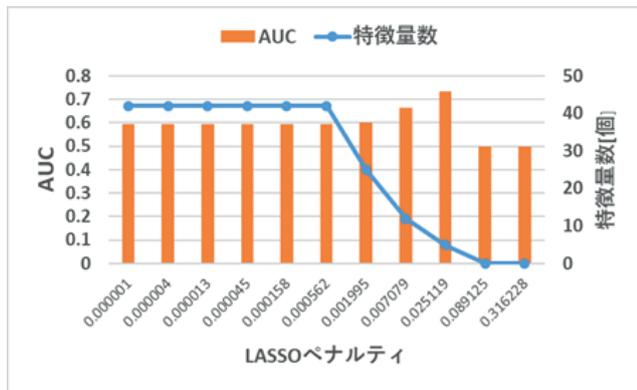


Fig. 4 特徴量数と AUC の 2 軸グラフ

・リッジ回帰モデル

初めに数値化を行う。次にリッジ パラメーターを 5、スケールを 0 に設定して学習を行った時の、リッジ回帰モデルの係数を求める。そして、その係数の大きい方から順に選択する。

・ElasticNet を用いた正則化

初めに数値化を行う。次に 10 分割交差検証と L_1 正則化の重みを 0.75 と設定した時の ElasticNet 法を用いて、線形回帰モデルの係数を求める。そして、MSE と最小 MSE の差が 1 標準誤差以内になる最大の正則化係数の値を求め、その値の大きい方から選択する。

・LASSO 正則化

初めに数値化を行う。次に 10 分割交差検証を使用して LASSO 近似を求める。そして、MSE と最小 MSE の差が 1 標準誤差以内になる最大の正則化係数の値を求め、その値の大きい方から選択する。

Table 5 Phase2 で用いた特徴量選択手法

method	parameter
分類木	重要度
分類木のアンサンブル	重要度
ランダム フォレスト	重要度

表 5 に Phase2 で用いた特徴量選択手法と選択する際に目安とした値について示す。以下に Phase2 で使用した手法、選択の仕方について簡単に記す。

・分類木

代理分岐がある分類木を使用し、CART 法を用いて学習を行う。そして、各特徴量の分割によるリスクの変化を合計したものを、ノード数で割ることで重要度を算出し、その重要度の大きい方から選択する。

・分類木のアンサンブル

ブースティングされた分類木のアンサンブルモデルを用いる。初めに 150 本のブースティングされた分類木のアンサンブルに 5 分割交差検証で学習を行う。次に、アンサンブル内の木の木の本数が増加する度に誤分類率を算出させ、その誤分類率が最小になる最大分割数、木の木の本数および学習率を特定する。そして、それらを用いて学習を行い、分類木の時と同様に重要度を算出し、その値の大きい方から選択する。

・ランダムフォレスト

バギングされた 200 本の分類木のアンサンブルに学習をさせて、out-of-bag 分類誤差とモデル(使用された値)の誤差を求める。各決定木でその 2 つの差を求め、重要度である木あたりの平均を得る。そして、その値の大きい方から選択する。

以上である。本論文は各手法の簡単な説明にとどまっている。そのため、より詳しく知りたいのであれば次の資料を参考にしてほしい¹⁶⁾。

3.3. 特徴量の組み合わせ総当たりアルゴリズムの実装

図 5 に示すような特徴量の組み合わせの総当たり(全組み合わせ)アルゴリズムを作成した。Stage1 の学習においては、このアルゴリズムを用いて学習を行い、その組み合わせ毎の判別精度の中で、最も判別精度の良かった時のスコア(うつ病患者である確信度)を Stage2 への入力に採用した。

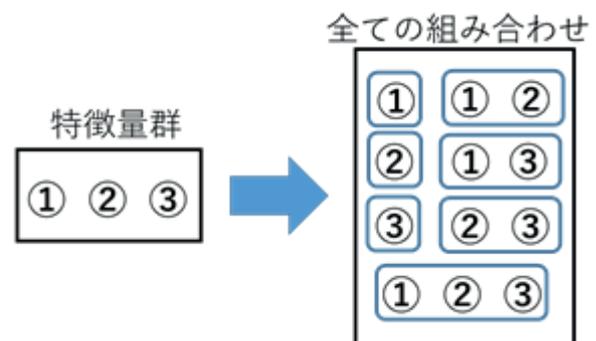


Fig. 5 特徴量の全組み合わせ

3.4. Stacking 構成の最適化

従来の Stacking 構成における Stage2 での学習では、逐次選択型を用いていた。しかしながら、その効果は見込めなかったため、本論文では 60 モデルのうち最も高い判別精度の出したモデルとその精度を採用するようにした。また、学習方法も 4 分割交差検証ではなく、1 個抜き交差検証(Leave-one-out cross-validation)に変更を行った。

3.5. 比較

作成したアンサンブル化モデルと、ランダムフォレスト単体を以下の 2 点で比較した。

- 1) Stage1 での各方法による視線方向データと音声データに対する判別精度
- 2) Stage2 での判別精度

データは表 1 に示した男性 20 名と女性 20 名、合わせた 40 名のデータを基に作成した、視線方向データセットと音声データセットを用いる。このデータセットの 1 人当たりの特徴量の個数は、視線方向は 12 種類、音声は 42 種類である。

特徴量の選択については、アンサンブル化モデルは視線方向: $X = 7$, $Y = 2$, 音声信号: $X = 7$, $Y = 3$, 各 18 手法の特徴量選択数は入力される特徴量数の半分としている。このように設定した時に採用された特徴量とした。一方、ランダムフォレストにおいては 10 回特徴量選択を行ったうち、7 回以上選ばれたものとした。こちらも、アンサンブル化モデルと同様に 1 回の特徴量選択数は入力特

微量数の半分とした。

学習にあたってはどちらも線形 SVM を用い、1 個抜き交差検証で学習を行った。なお、今回は特微量選択の方法の違いによる判別精度の比較のため、Stage1 での表情データのスコアはどちらも同様のものを使用しており、単体での判別精度はどのデータに対しても 65 % となっている。

4. 結果

表 6 にアンサンブル化モデルとランダムフォレストによって選択された特微量を用いて学習した時の、各 SVM での判別精度を示す。この表は、同データに対して判別精度が高い方法の方は、赤色で塗りつぶしている。音声データに対しては一部アンサンブル化モデルの方が高めのももあったが、全体的にはランダムフォレストの方が精度は高めであるという結果となった。

次に、表 7 に Stage2 での判別精度を示す。表より男性のデータに対してアンサンブル化モデルの方が若干精度は低いものの、他に対してはほぼ同値を示した。最終的に、どのデータに対しても 90% 以上の判別精度を得られ、前回の判別精度である 83% を超え、判別精度の向上を行うことができた。

Table 6 特微量選択手法、データ別の判別精度

Method	Data	Men	Women	Mix
Ensemble	Eye_direction	75.0	75.0	62.5
	Voice	75.0	93.8	75.0
Random	Eye_direction	100.0	81.3	75.0
	Voice	75.0	75.0	79.2

Table 7 特微量選択手法別の判別精度

	Men	Women	Mix
Ensemble	90.0	95.0	100.0
Random	100.0	95.0	100.0

5. 考察

表 8 に、アンサンブル化モデルとランダムフォレストで特微量選択を行った時の、選択された特微量の数を示す。また、表 9 に特微量の組み合わせの総当たりアルゴリズムを適用して学習を行った時の、最高精度時に入力された特微量の数を示す。

表 8 より全体的に見れば、相対的にランダムフォレストの方が選択される特微量数が多い傾向にある。視線方向データに関していえば、アンサンブル化モデルは選択した特微量数がランダムフォレストの方より少ない。しかしながら精度は 60 から 70 半ばでとどまっているので、判別に有効な特微量を選べていないと考えられる。一方として音声データに関していえば、アンサンブル化モデルはより少ない特微量でほぼ変わらないか高い判別精度を得られている。以上のことから、アンサンブル化モデルは特微量を厳しく絞り込むので、比較的多数の特微量に対しては有効である。その一方、少量の特微量に対しては、X と Y の値を適切に設定する必要があると考えられる。また、表 9 より、最高精度となるときの特微量の個数は、視線方向に関しては 1 つ 2 つと極々少数となっている。確かに最高精度となるものの、これは 1 つの値だけみて判別を行っていることに等しく、汎化性があるとはとてもいえない。そのため、最高精度を算出するこの特微量組み合わせの総当たりアルゴリズムに、最低限の数の特微量を組み合わせただで、

最高精度のモデル選択をできるようにする必要があると考えられる。

Table 8 各特微量選択方法で採用された特微量数

Data	Method	Men	Women	Mix
Eye	Ensemble	3	2	1
	Randomforest	7	1	6
Voice	Ensemble	6	7	8
	Randomforest	8	8	14

Table 9 特微量選択手法別最高判別精度時の特微量数

Data	Method	Men	Women	Mix
Eye	Ensemble	2	1	1
	Randomforest	1	1	1
Voice	Ensemble	3	2	3
	Randomforest	3	3	5

6. 現在の取り組み

本章では、3 章で述べたうつ病確信度算出(判別)システムへ適応予定の、判別器作成等の取り組みについて記す。現在、以下のようなことに取り組んでいる。

- 1) 表情データの特微量化
- 2) 動作速度に着目した判別器の作成

これらの概要を本章 6.1, 6.2 にて述べる。

6.1. 表情データの特微量化

現在のところ、表情データの学習に関しては時系列データそのものを使用している。このデータそのものであっても単体モデルでは 65 % ほどの判別精度を持つが、他のモデルと見比べるとやはりいくらか見劣りしてしまうのが現状である。そのため、より精度の向上の目的として、表情に関する、特微量ベースによる判別器の作成を行っている。表情の時系列データから作成した、特微量の例を一つあげる。女性の表情データより、表情変化の回数に着目し、1 分あたりの表情変化の回数の平均をとったものをまとめたグラフを図 6 に示す図より、相対的に見て、健常者の方が値は大きいことがわかる。また、このグラフに 2.5 の閾値を設け、その値より上であれば健常者、それ以下はうつ病患者とする。そうすると健常者は 7/10、うつ病患者は 9/10 正しく判別されたことになり、その判別精度は 80 % である。この表情データの特微量化は、現状の判別精度を超えることを目標に、分離性の高い特微量を作成し SVM に学習を行わせて、評価をしていく。

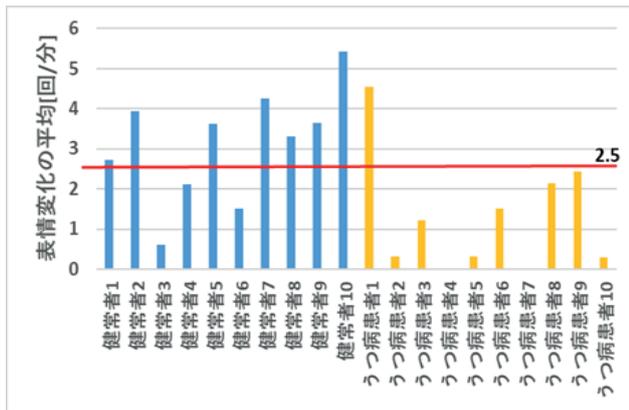


Fig. 6 1分あたりの表情変化回数の平均

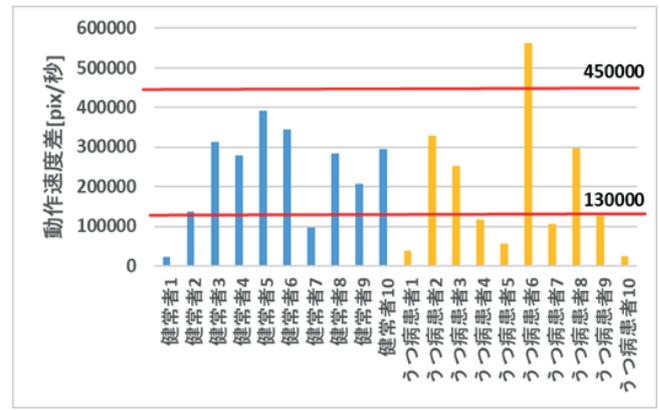


Fig. 8 動作速度の最小値と最大値の差

6.2. 動作速度に着目した判別器の作成

うつ病患者には、以下のような特徴がある。

1) 動作速度

動作が鈍くなり、ゆっくりとした動きになる。まるでロボットのように体の動きが遅くごちなくなる^{17), 18)}

2) 落ち着きのなさ

強い不安、焦燥感からイライラして足踏みをしたり、ソワソワと落ち着きなく動き回ったりする¹⁷⁾

上記の特徴に着目し、それらを用いた新しい判別器の作成を行っている。

図7に動作速度の算出方法を示す。上半身を検出する事前学習済みの分類器を用いて、30 毎秒フレームの画像の上半身を特定する。そして、特定した際の境界ボックスの左下の座標を利用し、フレーム間毎の移動速度を式(1)で求める。

$$v = \frac{\sqrt{(x'-x)^2 + (y'-y)^2}}{t} \quad (1)$$

そして1秒ごとの平均値を求めまとめた。そのデータを用いて、特徴量の作成を行っている。

表情と同様に、作成した特徴量の例の一つあげる。女性の動作速度の時系列データより、最大と最小の値の差をとったものをまとめたグラフを図8に示す。このグラフに130000と450000の閾値を設ける。前者はその値より下であれば、後者はその値より上であればうつ病患者とし、この2つの閾値の間であれば健常者とする。そうすると健常者は8/10、うつ病患者は7/10正しく判別されたことになり、その判別精度は75%である。このように分離性の高い特徴量を作成し、それらでSVMに学習を行わせて、判別精度を評価していく。

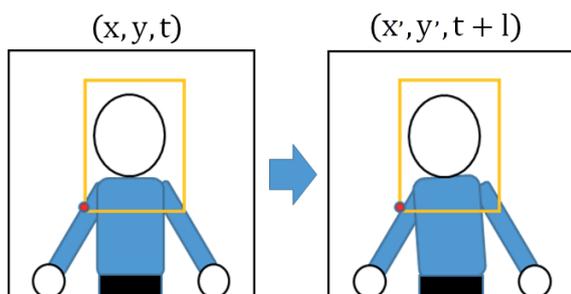


Fig. 7 上半身の検出と座標、時間

7. まとめ

本論文では、アンサンブル化モデルという特徴量選択や従来の構成の最適化などを行った。その結果、前回の約83%の判別精度を超える、90%以上の精度を得ることができた。

今後の取り組みとしては、上記の表情データの特徴量化や、動作速度に着目した判別器の追加の他に、汎化性の高い総当たりアルゴリズムに改善する、現在の構成に対し、段を追加するなどの更なる最適化を行う予定である。

参考文献

- [1] 大坪 天平: うつ病を診る上で注意すべきこと, 女性心身医学, 20 卷 (3 号), 271-275, (2016)
- [2] 日本うつ病学会: うつ病 Q&A, <https://www.secretariat.ne.jp/jsmid/ippan/qa.html>, (2020 年)
- [3] 二村隆史: うつ病治療薬開発の難しさ, ファルマシア, 53 卷 (7 号), 696-698, (2017)
- [4] 原 修二, 戸田 裕之, 中村 光晃, 大宮 康宏, 樋口 政和, 高野 毅, 斎藤 拓, 谷知 正章, 光吉 俊二, 吉野 相英, 徳野 慎一: ハースト指数とゼロ交差率に基づく音声指標によるうつ重症度測定, 生体医工学, Annual 57 卷 (Abstract 号), S247_1, (2019)
- [5] 四井 美月, Liang Kuo-ching, 廣原 茉耶, 北沢 桃子, 吉村 道孝, 江口 洋子, 藤田 卓仙, 岸本 泰士郎, 榊原 康文: 音声データを用いたうつ病重症度の深層学習解析, 2018 年度人工知能学会全国大会 (第 32 回), 4C2-OS-27b-02, (2018)
- [6] Yu Shimizu, Junichiro Yoshimoto, Shigeru Toki, Masahiro Takamura, Shinpei Yoshimura, Yasumasa Okamoto, Shigeto Yamawaki, Kenji Doya: Toward Probabilistic Diagnosis and Understanding of Depression Based on Functional MRI Data Analysis with Logistic Group LASSO, PLOS ONE, 10(5), e0123524, (2015)
- [7] Naho Ichikawa, Giuseppe Lisi, Noriaki Yahata, Go Okada, Masahiro Takamura, Ryu-ichiro Hashimoto, Takashi Yamada, Makiko Yamada, Tetsuya Suhara, Sho Moriguchi, Masaru Mimura, Yujiro Yoshihara, Hidehiko Takahashi, Kiyoto Kasai, Nobumasa Kato, Shigeto Yamawaki, Ben Seymour, Mitsuo Kawato, Jun Morimoto & Yasumasa Okamoto: Primary functional brain connections associated with melancholic major depressive disorder and modulation by antidepressants, Scientific Reports, 10, 3542, (2020)
- [8] Andrew G Reece, Christopher M Danforth, Instagram photos reveal predictive markers of Depression, EPJ Data Science, 6, 15, (2017)

- [9] Yuta Maki, Kazuya Abe, Hideya Takeo, Yuichi Nagai : Quantification of the diagnosis of depression through application of image recognition technology, Computer Assisted Radiology and Surgery 33rd International Congress and Exhibition (CARS2019), S181-S82, (2019)
- [10] 牧優太, 和田昇太, 安倍和弥, 武尾英哉, 永井優一 : 画像認識技術によるうつ病診断の定量化, 第38回日本医用画像工学会大会(JAMIT2019) 予稿集, OP1-17, (2019)
- [11] Yuta Maki, Shota Wada, Kazuya Abe, Hideya Takeo, Yuichi Nagai : Developing High Performance CAD for Depression by Integrating Multiple Classifier Systems, Computer Assisted Radiology and Surgery 34rd International Congress and Exhibition (CARS2020), S204-S205, (2020)
- [12] Shota Wada, Yuta Maki, Kazuya Abe, Hideya Takeo, Yuichi Nagai : Developing High Performance CAD for Depression by Employing Image and Voice Information, Computer Assisted Radiology and Surgery 34rd International Congress and Exhibition (CARS2020), S203-S204, (2020) [13] Chris Ding, Hanchuan Peng : Minimum redundancy feature selection from microarray gene expression data, Journal of Bioinformatics and Computational Biology, 3 (2), 185-205, (2005)
- [14] Xiaofei He, Deng Cai, Partha Niyogi : Laplacian Score for Feature Selection, Advances in neural information processing systems [Neural Information Processing Systems, NIPS 2005], 18, 507-514, (2005)
- [15] Marko Robnik-Šikonja, Igor Kononenko : Theoretical and empirical analysis of ReliefF and RReliefF, Machine Learning, 53, 23-69, (2003)
- [16] MathWorks : Introduction to Feature Selection, <https://jp.mathworks.com/help/stats/feature-selection.html?lang=en>, (2020)
- [17] うつ病の情報・サポートサイト こころの陽だまり : うつ病症状の進行, <https://www.cocoro-h.jp/untreated/overview/symptoms.html>, (2020)
- [18] 磐田こころのクリニック : うつ病について, https://www.iwatakokorono-cl.com/target_disease/depression/, (2020)