

呼吸音検出アルゴリズムのための判別器の作成と評価*

計算機構成研究室 加科 優希 (情・コン科)

指導教員 三好 和憲 教授

2013 年度卒業論文

*Classifier implementation and evaluation for snoring detection system. by KASHINA, Yūki, MIYOSHI, Kazunori (Department of Computer Science, Faculty of Informatics, Kogakuin University)

目次

1	はじめに	3
2	研究目的およびアプローチ	3
2.1	本研究の目的	3
2.2	アプローチ	3
3	機械学習による呼吸音の判別器の実装	3
3.1	機械学習	3
3.2	教師あり学習	4
3.3	線形判別器	4
3.4	アルゴリズム	4
3.4.1	Fisher の線形判別 (FLD, Fisher's linear discriminant)	4
3.4.2	線形判別分析 (LDA, linear discriminant analysis)	5
3.4.3	サポートベクターマシン (SVM, support vector machine)	5
3.5	動作確認	6
4	機械学習アルゴリズムと特徴量の評価	6
4.1	客観評価に用いる特徴量	7
4.2	クローズドテストによる理論性能評価	7
4.3	誤判別率 (MCR, missclassification rate) の正当性評価	7
4.4	オープンテストによる汎化能力評価	9
5	評価結果の分析による判別器構成要素の決定	9
5.1	正当性検証	9
5.2	評価結果の分析	9
5.2.1	FLD	9
5.2.2	MFCC	9
5.2.3	エンベロープおよび音圧レベル	9
5.2.4	LDA	10
5.2.5	SVM	10
5.2.6	呼吸音検出に最適な機械学習アルゴリズムおよび特徴量の決定	10
5.3	選定した判別器および特徴量の汎化能力	10
6	総括	10
6.1	今後の課題	10

1 はじめに

本研究は、JSPS 科研費 24500213 の助成による「睡眠時無呼吸症候群の簡易診断システムの構築」四カ年計画 (Table 1) の一部である。今年度の研究はその 2 年目にあたり、本学・数理音響学研究室所属の和井田・本間との共同研究となっている。詳細は両名の論文^[1-3]を参照されたい。

Table 1 A four-year plan for "SAS simple diagnosis system implementation".

年度 (区分)	研究内容
2011 (予備検討期間)	(i) 呼吸音による睡眠状態判別ソフトウェアの構築 (ii) 睡眠時の呼吸音検出に関する研究
2012 (1 年目)	(A) 睡眠時における音環境調査 ^[4] (B) ハードウェア要件の明確化 ^[4]
2013 (2 年目)	(C) 呼吸音の特徴量抽出 (和井田・卒業研究) ^[2] (D) 判別器の作成と評価 (本研究) (E) 睡眠時環境音の SN 比評価および睡眠計・睡眠アプリの調査 (本間・卒業研究) ^[3]
2014 (3 年目)	精度評価およびパラメータチューニングによる精度向上
2015 (4 年目)	SAS の簡易診断システムの構築

2 研究目的およびアプローチ

四カ年計画の目的は低コストで精度の高い呼吸音による睡眠時無呼吸症候群 (SAS, sleep apnea syndrome, 以後 SAS と称す) の簡易診断システムの構築である。

2.1 本研究の目的

前述のシステムにおいて、SAS の簡易診断を行う基盤となる判別器を作成する。

2.2 アプローチ

呼吸音の判別器を機械学習の手法を用いて実装する。実装の過程でテストデータによる動作確認を行う。機械学習アルゴリズムにおいて使用する特徴量としてピーク周波数、音圧レベル、エンベロープ、メル周波数ケプストラム係数 (MFCC, mel frequency cepstral coefficients, 以後 MFCC と称す)、フォルマント周波数を用いる。詳しくは 3 章にて述べる。各機械学習アルゴリズムの実装後、機械学習アルゴリズムと特徴量の最適な組み合わせを分析し、それを判別器とする。詳しくは 4 章および 5 章にて述べる。なお、以後判別器といった場合、その文脈における機械学習アルゴリズムと特徴量の組み合わせを指すものとする。

3 機械学習による呼吸音の判別器の実装

波形から抽出される特徴量を入力としてクラスを出力する能力を有する線形判別器を実装する。クラスを隔てる境界線が直線となるような判別器を線形判別器という。以後特に断りがない場合、判別器は線形判別器を指すものとする。実装に際して「パターン認識と機械学習: ベイズ理論による統計的予測」^[5](PRML, "Pattern Recognition and Machine Learning") を参照した。また、本研究における実装環境は Table 2 に示すとおりである。

3.1 機械学習

機械学習とは人間の学習プロセスをモデル化した手法で、教師あり学習、教師なし学習、半教師あり学習などの種類がある。教師あり学習は学習の過程でデータとともに対応するラベルを与える方式である。本研究では SAS や呼吸音など明確なラベル付けができるデータを扱うため、教師あり学習

Table 2 Implementation environment.

環境名	環境
HW	Apple MacBook Pro (Late 2013)
OS	Apple OS X Mavericks (10.9.1)
CPU	Intel Core i7-4750HQ (2.00GHz)
RAM	Apple 16GB 1600 MHz DDR3
言語	MathWorks MATLAB R2013a

を採用した。

3.2 教師あり学習

教師あり学習には生成モデル，識別モデル，識別関数などがある．結合確率 $p(\mathbf{x}, C_k)$ をモデル化する方法が生成モデル，クラス事後確率 $p(C_k|\mathbf{x})$ を直接モデル化する方法が識別モデルである．ここで，モデルとはクラス事後確率のことである．また，生成モデルについてクラス条件付き確率 $p(\mathbf{x}|C_k)$ とクラス事前確率 $p(C_k)$ からベイズの定理によってクラス事後確率 $p(C_k|\mathbf{x})$ を求める方法もある．生成モデル，識別モデル共に，クラス事後確率を求める推論問題を解きモデルを得る推論段階 (inference stage) と，求めたモデルを用いて入力 \mathbf{x} をクラスに分類する決定段階 (decision stage) からなる．この両段階を統合した識別関数では確率はもはや現れず，入力 \mathbf{x} をクラスに写像する関数 $f(\cdot)$ あるいはパラメータ x を見つける学習問題に置き換わる．

3.3 線形判別器

判別器は (Eqn. 3.3.1) で表される．これは一般化線形モデル (generalized linear model) と呼ばれる形式である． D 次元の入力ベクトル \mathbf{x} から，訓練 (学習) は決定境界とよばれる $D - 1$ 次元の超平面を，識別 (判別) はスカラーを得る操作である．実際には，訓練は決定境界の傾きを決める重みベクトル \mathbf{w} と決定境界の位置を決めるバイアス w_0 を求めている．ただし，決定境界は重みベクトルとバイアスから求めることができるので両者は実質的に同義である．また，決定境界のなす領域を決定領域といい，その1つに着目するとき，特にクラスという．決定領域が2つになるものを2クラス判別器，複数になるものを多クラス判別器などという．本研究では2クラス判別器を実装する．

$$y(\mathbf{x}) = f(\mathbf{w}^T \mathbf{x} + w_0) \quad (\text{Eqn. 3.3.1})$$

3.4 アルゴリズム

今日教師あり学習として知られている代表的なアルゴリズムから，本研究では Fisher の線形判別 (FLD, Fisher's linear discriminant, 以後 FLD と称す)，線形判別分析 (LDA, linear discriminant analysis, 以後 LDA と称す)，サポートベクターマシン (SVM, support vector machine, 以後 SVM と称す) の3種類を用いる．FLD および SVM は識別モデル，LDA は生成モデルである．前述のとおり，本研究では線形判別器を実装する．そのため，各アルゴリズム共にカーネルトリックと呼ばれる手法は用いていない．

3.4.1 Fisher の線形判別 (FLD, Fisher's linear discriminant)

FLD は一般に (Eqn. 3.4.1) で表される関係を指す． \mathbf{w} は重みベクトル， S_W は総クラス内共分散行列， \mathbf{m}_1 および \mathbf{m}_2 はそれぞれのクラスにおける平均ベクトルである．FLD を用いた判別器の実装は (Eqn. 3.4.2) である． y はクラス， \mathbf{x} は入力ベクトル， \mathbf{w} は重みベクトル， \mathbf{m} は平均ベクトルである．実装において FLD の関係を用いて重みベクトルを (Eqn. 3.4.3) にて求めた．以後特に断りがない場合 C_1 が呼吸音， C_2 が非呼吸音のクラスを指すものとする．また，本研究において FLD は実装を含めた (Eqn. 3.4.2) を指すものとする．

$$\mathbf{w} \propto \mathbf{S}_W^{-1}(\mathbf{m}_1 - \mathbf{m}_2) \quad (\text{Eqn. 3.4.1})$$

$$y(\mathbf{x}) = \begin{cases} C_1 & \mathbf{w}^T(\mathbf{x} - \mathbf{m}) < 0 \\ C_2 & (\text{otherwise}) \end{cases} \quad (\text{Eqn. 3.4.2})$$

$$\mathbf{w} = \mathbf{S}_W^{-1}(\mathbf{m}_1 - \mathbf{m}_2) \quad (\text{Eqn. 3.4.3})$$

3.4.2 線形判別分析 (LDA, linear discriminant analysis)

前述したとおり LDA は生成モデルであるため、クラス事後確率を直接モデル化する。具体的には、クラス条件付き密度を (Eqn. 3.4.4) により推論し、これを用いてベイズ定理によりクラス事後確率を求める。ここで、 D は次元数、 Σ は共分散行列、 μ_k はクラス標本平均である。共分散行列は全クラスでプール (共有) すると仮定している。

$$p(\mathbf{x}|C_k) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\Sigma|^{1/2}} \exp \left\{ -\frac{1}{2}(\mathbf{x} - \mu_k)^T \Sigma^{-1}(\mathbf{x} - \mu_k) \right\} \quad (\text{Eqn. 3.4.4})$$

判別の際は (Eqn. 3.4.5) および (Eqn. 3.4.6) で表されるクラス事後確率において尤度が高いクラスを割り当てる。ここで、 $\sigma(a)$ は一般にロジスティックシグモイド関数 (Eqn. 3.4.7) として知られているものである。重みベクトルとバイアスは (Eqn. 3.4.8)、(Eqn. 3.4.9) にて求める。

$$p(C_1|\mathbf{x}) = \sigma(\mathbf{w}^T \mathbf{x} + w_0) \quad (\text{Eqn. 3.4.5})$$

$$p(C_2|\mathbf{x}) = 1 - \sigma(\mathbf{w}^T \mathbf{x} + w_0) = 1 - p(C_1|\mathbf{x}) \quad (\text{Eqn. 3.4.6})$$

$$\sigma(a) = \frac{1}{1 + \exp(-a)} \quad (\text{Eqn. 3.4.7})$$

$$\mathbf{w} = \Sigma^{-1}(\mu_1 - \mu_2) \quad (\text{Eqn. 3.4.8})$$

$$w_0 = -\frac{1}{2}\mu_1^T \Sigma^{-1} \mu_1 + \frac{1}{2}\mu_2^T \Sigma^{-1} \mu_2 + \ln \frac{p(C_1)}{p(C_2)} \quad (\text{Eqn. 3.4.9})$$

3.4.3 サポートベクターマシン (SVM, support vector machine)

サポートベクターマシンは (Eqn. 3.4.10) の制約下で (Eqn. 3.4.11) について重みベクトル、バイアスが最大となるものを選択し、一般化線形モデル (Eqn. 3.3.1) において $w_0 = b$ とした式で判別を行う。ここで、 $t_n \in \{-1, 1\}$ である。また、 $\phi(\cdot)$ について本研究では線形カーネル $\phi(\mathbf{x}) = \mathbf{x}$ を用いる。

$$t_n(\mathbf{w}^T \phi(\mathbf{x}_n) + b) \geq 1, \quad n = 1, \dots, N \quad (\text{Eqn. 3.4.10})$$

$$\arg \max_{\mathbf{w}, b} \|\mathbf{w}\|^2 \quad (\text{Eqn. 3.4.11})$$

これは二次計画法 (QP, quadratic programming, 以後 QP と称す) の問題を解決することに等しい。SVM における QP の解法としては逐次最小最適化法^[6] (SMO, sequential minimal optimization) が知られている。

3.5 動作確認

Fisher のアヤメ (Fisher's Iris) とよばれる 3 クラス 4 次元のデータを用いて動作確認を行った。このデータは、seosa 種、versicolor 種、virginica 種のアヤメそれぞれについて、萼片の長さ・幅、花弁の長さ・幅を 50 標本ずつ調べた測定値データである [7, 8]。アヤメの種別がクラス、萼片の長さ・幅、花弁の長さ・幅が特徴量に対応する。テストには versicolor 種と virginica 種に関する花弁の長さ・幅の測定値データを用いた。この結果、実装した判別器がすべて正常に動作することが確認された。

4 機械学習アルゴリズムと特徴量の評価

判別器の訓練と評価をクローズドテストおよびオープンテストにより行った。入力データは、共同研究者の和井田が呼吸音収録波形 [4] から抽出した音響特徴量である。特徴量抽出に関する詳細は和井田の論文 [1, 2] にて報告する。このデータの標本数は Table 3 の通りである。表中の”訓練対象外”とは、明確に呼吸音とも非呼吸音とも分類できないため判別器の訓練には使用しないデータである。特徴量は Table 4 に示すものを用いた。

Table 3 Information of Waveform.

呼吸音の強さ	呼吸音標本数 C_1	非呼吸音標本数 C_2	訓練対象外標本数
強 (高 SN 比)	234	1190	74
弱 (低 SN 比)	47	872	179

Table 4 Information of feature.

特徴量番号	特徴量名	次元数
F_1	ピーク周波数	1
F_2	音圧レベル	1
F_3	エンベロープ	1
F_4	MFCC	12
F_5	フォルマント周波数	3

誤判別率 (MCR, misclassification rate, 以後 MCR と称す) は (Eqn. 4.0.1) で記述される評価基準である。x は特徴量行列、 σ は総クラス数、 $|\mathbf{x}|_N$ は特徴量行列における標本数、 $y(\cdot)$ は機械学習アルゴリズムである。特徴量行列は (Eqn. 4.0.2) で記述される行が標本、列が特徴量を表す行列である。クローズドテストは MCR 評価において訓練と評価に全標本を使用する条件による方式、オープンテストは MCR 評価において訓練標本を評価標本に含めない条件による方式で、代表的な手法のうち今回は $K = 10$ とした K-分割交差検証法 (K-fold cross validation) を用いた。

$$f_{\text{MCR}}(\mathbf{x}) = 1 - \frac{\sum_{k=1}^{\sigma} y(\mathbf{x} \in C_k) \in C_k}{|\mathbf{x}|_N} \quad (\text{Eqn. 4.0.1})$$

$$\mathbf{x} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1D} \\ x_{21} & x_{22} & \ddots & x_{2D} \\ \vdots & \ddots & \ddots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{ND} \end{pmatrix} \quad (\text{Eqn. 4.0.2})$$

4.2 節ではクローズドテストによる MCR を求め、理論的な限界性能を評価した。4.3 節では、オーバーオールレベル (OA, overall sound pressure level, 以後 OA と称す) の波形に判別結果を重ね合わせる方法で作図し、主観評価により前節の MCR の正当性を裏付けた。4.4 節では、オープンテストによる MCR を求め、未知データに対する汎化能力を評価した。4 章では評価結果を示すことととめ、詳細な議論は 5 章にて行う。

Table 5 Information of feature pattern.

パターン番号	特徴量の組み合わせ	次元数
P_1	F_1	1
P_2	F_2	1
P_3	F_3	1
P_4	F_1, F_2, F_3	3
P_5	F_4	12
P_6	F_1, F_2, F_3, F_4	15

4.1 客観評価に用いる特徴量

フォルマント周波数は周波数スペクトルの概形に見られるピーク周波数であり，当然にピーク周波数と類似した性質を持つ．ところでピーク周波数の算出時間とフォルマント周波数の算出時間を比較すると，ピーク周波数が約 2.8 秒である一方フォルマント周波数は 21.8 秒であった．このようにピーク周波数の算出に比べ約 8 倍の計算時間を要することから，MCR による客観評価は類似した性質を持つピーク周波数に集約し，フォルマント周波数は対象から除外した．ただし，フォルマント周波数は人間の声道特性を反映した複数次元の特徴量であるため，ピーク周波数よりも呼吸音の判別に有利に働くと考えられる．フォルマント周波数算出の高速化及び特徴量としての利用は来年度以降の研究計画にて検討する．

4.2 クローズドテストによる理論性能評価

FLD, LDA, SVM それぞれの MCR(小数点第 4 位四捨五入)，訓練・評価に使用した特徴量，呼吸音の強弱の別を Table 6 に示す．これは機械学習アルゴリズム 3 種類，特徴量の組み合わせ 15 パターン，呼吸音の強弱 2 種類からなる全組み合わせ 90 パターンのうち評価・検討の根拠として有効と考えられる 36 パターンを抜粋したものである．特徴量の組み合わせは Table 5 のパターン番号に対応している．また，呼吸音の強弱は暗騒音等に対する呼吸音の強弱であり SN 比との対応付けがなされる．評価に際して，弱い呼吸音においても正しく判別が可能な判別器は，前述の SN 比との関連からも判別性能が高いと考えられる．

Table 6 MCR comparison in closed test.

パターン番号	クローズドテスト条件別 MCR [%]					
	呼吸音 強 (高 SN 比)			呼吸音 弱 (低 SN 比)		
	FLD	LDA	SVM	FLD	LDA	SVM
P_1	83.567	17.767	9.340	14.037	27.530	27.530
P_2	83.567	0.562	0.070	89.880	36.235	40.044
P_3	83.567	0.000	0.000	90.751	7.617	5.114
P_4	83.567	0.000	0.000	79.325	6.855	4.461
P_5	0.140	0.000	0.000	66.485	0.000	0.000
P_6	0.281	0.000	0.000	91.621	0.000	0.000

4.3 誤判別率 (MCR, missclassification rate) の正当性評価

機械学習アルゴリズムおよび特徴量の組み合わせを変えながら，強弱それぞれの呼吸音の OA に判別器の出力を重ねることで 90 パターンのグラフを得た．評価に有用と思われる 6 パターンのグラフを Fig. 1-Fig. 6 に示す．ここで“+”のマーカで表される判別器の出力は $x \in \{0, 1\}$ に写され，OA で正規化されている．呼吸音と判別されたものが y 軸上部側，非呼吸音と判別されたものが y 軸下部側にプロットされている．

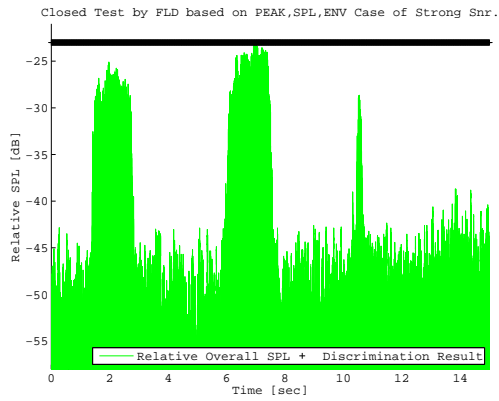


Fig. 1 Correlation (Weak snr., FLD, P_4)




Fig. 2 Correlation (Strong snr., FLD, P_6)




Fig. 3 Correlation (Weak snr., FLD, P_6)




Fig. 4 Correlation (Weak snr., LDA, P_3)

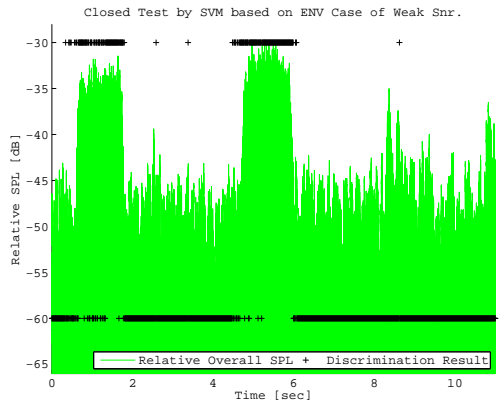


Fig. 5 Correlation (Weak snr., SVM, P_3)




Fig. 6 Correlation (Weak snr., SVM, P_6)

4.4 オープンテストによる汎化能力評価

オープンテストにおける MCR を Table 7 に示す．表の形式等は Table 6 と同様である．

Table 7 MCR comparison in open test.

パターン番号	オープンテスト条件別 MCR [%]					
	呼吸音 強 (高 SN 比)			呼吸音 弱 (低 SN 比)		
	FLD	LDA	SVM	FLD	LDA	SVM
P_1	83.567	17.767	12.219	14.037	27.965	26.877
P_2	83.567	0.632	0.070	89.880	36.670	35.365
P_3	83.567	0.000	0.000	90.751	7.617	5.332
P_4	83.567	0.070	0.000	79.434	6.746	5.005
P_5	0.140	0.070	0.000	65.615	0.000	0.000
P_6	0.281	0.000	0.070	90.316	0.000	0.000

5 評価結果の分析による判別器構成要素の決定

強い呼吸音と弱い呼吸音が SN 比に対応付けられることは既に述べた．したがって，SN 比が高い場合のみならず SN 比が低い場合にもよく判別できる判別器が強力であることは自明である．また，使用する特徴量すなわち次元を削減しても一定以上の判別性能を維持できる場合，多少の誤差を許容することは計算資源の節約のため有益だと考えられる．これらの観点から機械学習アルゴリズムおよび特徴量を分析し，判別器として使用する組み合わせを決定した．

5.1 正当性検証

Fig. 1-Fig. 6 に示される図および Table 6 において図と MCR の間に乖離は認められないため，理想性能を表すクロズドテストの評価結果は正しいと考えられる．以上より，MCR の正当性が検証された．

5.2 評価結果の分析

Fig. 1-Fig. 6，Table 6，Table 7 を用い評価結果を分析する．

5.2.1 FLD

Fig. 1 は特徴量の組み合わせにパターン P_3 を用いた FLD で強呼吸音を判別した結果である．この組み合わせではすべて C_1 と判別され，強呼吸音を判別できていない．

Fig. 3 は Fig. 2 と同様の特徴量と判別器を用いて弱呼吸音を判別した結果である．後述する優れた特徴量である MFCC を含む条件でも判別不可能な場合が存在する．これは SN 比が低い場合に判別が難しくなることの表れといえる．理想性能を表すクロズドテストにて，SN 比が高い強呼吸音においても正しく判別できないため，FLD は呼吸音の判別器として適さないことがわかる．

5.2.2 MFCC

Fig. 2 は Fig. 1 の特徴量に MFCC を加えた特徴量で判別した結果である．Fig. 1 と Fig. 2 を比較すると，MFCC を導入することにより判別可能となることがわかる．これより，MFCC が呼吸音の判別に有効な特徴量であるといえる．

5.2.3 エンベロープおよび音圧レベル

Table 4 および Table 6 より，1 次元ではエンベロープが最も優れた特徴量で，次に優れた特徴量は音圧レベルであるといえる．

5.2.4 LDA

Fig. 4 はエンベロープのみを特徴量とし，LDA を用いて弱呼吸音を判別した結果である．この図より，LDA の判別性能は高く，Table 6 と Table 7 のパターン P_3 を見ても，汎化能力を含め優れていることがわかる．

5.2.5 SVM

Fig. 5 は Fig. 4 と同様にエンベロープのみを特徴量として SVM により弱呼吸音を判別した結果である．この図より，LDA よりも SVM の方がさらに高性能であることがわかる．

5.2.6 呼吸音検出に最適な機械学習アルゴリズムおよび特徴量の決定

これまでの議論より，FLD は呼吸音の検出には適さない (Fig. 1-Fig. 3)，LDA を用いることにより少ない特徴量で判別ができる (Fig. 4)，SVM は呼吸音検出において LDA よりも適したアルゴリズムである (Fig. 5) ことなどがわかった．また次元数が増えるが，LDA および SVM をアルゴリズムとして選択した場合，MFCC を特徴量として用いると今回の条件ではほぼ 100% 判別できることがわかった (Table 6, Table 7)．

以上を踏まえると，精度を保ちながらも次元を削減し判別器を実装するにはピーク周波数，音圧レベル，エンベロープの 3 つを特徴量として用いるとよいといえる．また，呼吸音検出アルゴリズムとしては SVM を用いるとよいといえる．したがって，この組み合わせを判別器として用いることとする．

5.3 選定した判別器および特徴量の汎化能力

5.2 節よりピーク周波数，音圧レベル，エンベロープを特徴量として用いた SVM を判別器として用いることとした．この判別器の汎化能力は，Table 7 から実用に耐えうるものであると考えられる．

6 総括

本研究によりピーク周波数，音圧レベル，エンベロープを特徴量に用いた SVM による判別器の呼吸音検出に対する有効性が確認された．

6.1 今後の課題

SAS の簡易診断のため，医療現場で用いられる無呼吸・低呼吸指数 (AHI, apnea hypopnea index) の予測を可能にすることが今後の主な課題である．また，精度向上のため様々な条件の標本を多数用いてモデル化することが望ましい．

謝辞 本研究を進めるにあたり理論的側面から適切なお助言を頂いた鶴秀生博士に感謝致します．本研究を進めるにあたり医学的側面から適切なお助言を頂いた東京大学付属病院の山口泰弘医師に感謝致します．

参考文献

- [1] 和井田将広，「呼吸音検出アルゴリズムの為の音響特徴量の抽出」，音講論集 2014 春，2-P4-24，2014 年 3 月
- [2] 和井田将広，「呼吸音検出アルゴリズムの構築～呼吸音の特徴量抽出～」，本学・卒業論文，2014 年 3 月
- [3] 本間賢広，「睡眠時環境音の SN 比評価および睡眠アプリ・睡眠計の調査」，本学・卒業論文，2014 年 3 月
- [4] 数納聖牙，神藤徳彦，「睡眠時無呼吸症候群の簡易診断システムの構築のための音環境調査とハードウェア要件の明確化」信学技報，vol.112，pp.1-6，2013.

- [5] C.M. ビショップ, "パターン認識と機械学習 上・下 ベイズ理論による統計的予測", 丸善出版株式会社, 東京, 2012.
- [6] Platt J.C. *et al.*, "Fast Training of Support Vector Machines using Sequential Minimal Optimization", "Advances in Kernel Methods: Support Vector Learning", pp.185-208, MIT Press, 1999.
- [7] Anderson E., "The Species Problem in Iris", "Annals of the Missouri Botanical Garden", 23, pp.457-509, 1936.
- [8] Fisher R.A., "The use of multiple measurements in taxonomic problems", "Annals of Eugenics", 7, 2, pp.179-188, September 1936.