

Autoencoder を用いた 無呼吸状態推定システムの提案

高尾郁也^{†1} 西尾啓汰^{†1} 鏑木崇史^{†2} 栗原陽介^{†1}
青山学院大学^{†1} 国際基督教大学^{†2}

1. はじめに

現在、世界における、最も死亡者数の多い死因は虚血性心疾患であり、948 万人が死亡していることが分かっている[1].そして、近年、この虚血性心疾患と睡眠呼吸障害との関連が明らかになってきている[2]. 虚血性心疾患の患者全体に占める睡眠時無呼吸症候群の併発率は 30%以上となっていて[3], 特に、虚血性心疾患の一つである虚血性心不全に至っては、患者の 76%が睡眠時無呼吸症候群を併発している[4]. このため、睡眠時無呼吸症候群の早期発見、および治療が必要である。しかしながら、無呼吸状態が睡眠時にしか発生しないことから、自覚症状が無く、患者の受診率は 15%に留まっている。このことから、日常的なモニタリングにより、睡眠時無呼吸症候群の疑いのある患者を見つける必要性があるといえる。

先行研究[5]では、睡眠時の無呼吸状態を無拘束に推定する手法が提案されているが、特定の長さのデータが無呼吸状態を含むか否かを推定することに主眼が置かれているため、無呼吸状態の発生回数を正しく評価することができないという問題がある。

筆者らによって、無呼吸状態の発生回数を正しく評価する目的で、高感度圧力センサ[6]を用いた無呼吸状態推定システムの先行研究が行われている[7]. ここでは、取得した生データに遮断周波数を 0.15Hz-0.45Hz としたデジタルバンドパスフィルタを適用し、デジタルバンドパスフィルタの出力信号 $I(k)$ に対してウェーブレット変換を行うことで得られた、各時刻の周波数分布 $A(f,k)$ から特徴量を算出していた。各時刻の周波数分布 $A(f,k)$ に非負値行列因子分解を施し、寄与率が最も大きい周波数と 2 番目に大きい周波数を f_{low} , f_{high} として、(1)式で示す、周波数強度の和 $rFDE(k)$ を特徴量として無呼吸推定を行っていた。

$$rFDE(k) = \sum_{f=f_{low}}^{f_{high}} A(f,k) \quad (1)$$

しかしながら、判別に用いる周波数分布のデータについて、周波数強度の和 $rFDE(k)$ の場合、 f_{low} , f_{high} 区間の分布情

報が消えてしまっていた。また、周波数強度の強い f_{low} , f_{high} 区間のみに限定して用いていたため、データの使用区間を変更した場合に、判別精度にどのような影響を及ぼすのか検証が行われていなかった。そのため、個人差や臥位による影響を受け、判別精度の低下を招いていた。

そこで、本研究では、先行研究において特徴量として用いていた各時刻の周波数分布の分布情報を残すために Autoencoder を使用し、次元圧縮によって特徴量算出を行う。また、先行研究ではセンサから取得したデータから周波数分布を算出する際に、遮断周波数を 0.15Hz-0.45Hz としたデジタルバンドパスフィルタを適用しており、Autoencoder に入力する各時刻の周波数分布を算出する際にバンドパスフィルタの有無がどのような影響を及ぼすのかについても検証を行う。さらに、特徴量抽出のための次元圧縮手法として用いる活性化関数を変更した場合の判別精度の検証も行う。

2. 提案手法

2.1 データ取得

まず、圧力センサから出力されるエアマットレス内の圧力変化の連続信号 $x(t)$ を、A/D コンバータを通してコンピュータに取り込む。この $x(t)$ は、単位時間あたりの肺胸部体積 $L(t)$ 、脈波や体動といったノイズとなる成分 $n(t)$ の和となっている。取り込まれたデータは離散信号 $x(k)$ とする。

2.2 特徴量抽出

データ取得後、データの時系列性を保持したまま周波数領域における情報を取得するため、ウェーブレット変換を行う。ウェーブレット変換により、時刻 k における f Hz 周波数成分の肺胸部系呼吸エネルギーが時刻 k と周波数 f の関数として求まる。その後、図 1 に示すような、スケール数 F の各時刻の周波数分布 $A(f,k)$ を入力とした Autoencoder の学習を行う。Autoencoder の中間層の数は、1~2 のいずれかとし、1 層目の次元数を l 、特徴量を $H_l(k)$ 、2 層目の次元数を m 、特徴量を $H_2(k)$ とする。

^{†1} IKUYA TAKAO, Aoyama Gakuin University.
^{†1} KEITA NISHIO, Aoyama Gakuin University
^{†2} TAKASHI KABURAGI, International Christian University
^{†1} YOSUKE KURIHARA, Aoyama Gakuin University.




図1 $A(f,k)$ を入力とした Autoencoder

2.3 無呼吸状態推定

図2に示すような、ウェーブレット変換と Autoencoder によって算出した特徴量 $H(k)$ を入力とし、2次元の出力 $a_i(k)$ を有するニューラルネットワークの学習を行う。その際、呼吸状態を0、無呼吸状態を1とした教師ラベルを用いる。その後、図3に示すように、2次元の出力 $a_i(k)$ を、(2)式で示す softmax 関数によって確率値 $y_i(k)$ に変換し、確率値の大きい方をラベル $est(k)$ として出力する。

$$y_i(k) = \frac{\exp(a_i(k))}{\sum_{i=1}^2 \exp(a_i(k))} \quad (2)$$




図2 $H(k)$ を入力とした2層のニューラルネットワーク

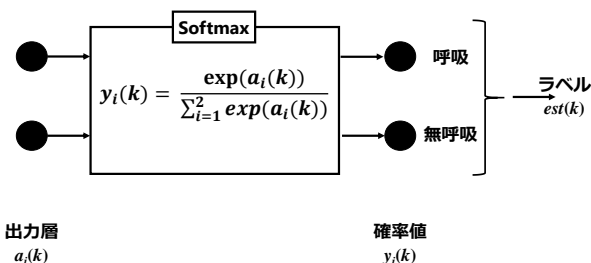


図3 Softmax による確率値変換とラベル出力

2.4 パラメータの調整

特徴量抽出に用いる Autoencoder と2次元の出力を持つニューラルネットワークを結合し、正解ラベルをもとに誤差逆伝搬法によって、Autoencoder と2次元の出力を持つニューラルネットワークのパラメータ調整を同時に行う。

3. 実験

3.1 実験条件

検証実験では、図4に示すような $245\text{mm} \times 800\text{mm}$ のシート2枚、ゴムチューブ、コンデンサマイクから構成される高感度圧力センサを用いる。ゴムチューブの一端を封じ、もう一端にコンデンサマイクロフォンが取り付けられており、シートに力が加わったときには、ゴムチューブ内の圧力変化をコンデンサマイクロフォンが電気信号として出力する。

この圧力センサを図5に示すように、一般的なベッドマットレスの下に設置する。設置位置は、ベッドフレームの頭側から 60cm の位置とし、被験者が横になった際に心臓の直下になるようにした。

A/D コンバータとして、Multifunction I/O Device USB-6000(National Instruments Corporation)を使用し、サンプリング間隔は 10ms 、計測時間は 180s とした。よって、 18000 点の離散信号 $x(k)$ が取得された。




図4 使用した高感度圧力センサ



図5 圧力センサの設置状況



図6 被験者が仰臥位を取った様子

3.2 実験手順

本実験では、体格の異なる20代の健康な男女5名(ID.1~ID.5)を被験者として、それぞれの被験者が図6~9に示すように、仰臥位、腹臥位、右側臥位、左側臥位(No.1~No.4)の4状態でデータ計測を行い、総データ数は20となった。データ計測開始前に40秒の安静時間を設け、その後、180秒間のデータ計測が開始される。計測開始後、20秒後から40秒後、80秒後から100秒後、140秒後から160秒後の3区間において呼吸を止めて無呼吸状態を再現した。このとき、無呼吸状態開始時と終了時にはそれを知らせる音声ファイルが再生される。その後、取得したデータに対して、以下の3つの実験条件を設け、判別精度の比較を行った。

実験1

l を75、 m を50として提案手法を適用し、無呼吸状態の推定を行った。その際、 $x(k)$ に対して、0.15~0.45Hzのバンドパスフィルタを適用した場合と適用しない場合で、判別精度の比較を行った。

実験2

Autoencoderへの入力をウェーブレット変換によって算出した各時刻の周波数分布における、16次元の0.15~0.45Hz区間とし、 l を10として検証を行った。その際、 $x(k)$ に対して、0.15~0.45Hzのバンドパスフィルタを適用した場合と適用しない場合において、判別精度の比較を行った。

実験3

l を75、 m を50として提案手法を適用し、無呼吸状態の推定を行った。その際、活性化関数は、ロジスティックシグモイド関数(logsig)、正の線形飽和関数(satlin)とした。



図7 被験者が腹臥位を取った様子



図8 被験者が右側臥位を取った様子



図9 被験者が左側臥位を取った様子

3.3 評価方法

実験結果は、表1に示すように混同行列に集計する。 TP は無呼吸状態が正しく推定された場合、 TN は呼吸状態が正しく推定された場合、 FP は呼吸状態が誤って無呼吸状態と推定された場合、 FN は無呼吸状態が誤って呼吸状態と推定

された場合である。これらの値から、(3)~(8)式に示す6つの評価指標を算出する。(3)式は、感度(*Sen*)、(4)式は特異度(*Spe*)、(5)式は陽性的中率(*PPV*)、(6)式は陰性的中率(*NPV*)、(7)式はF値(*Fvalue*)、(8)式は正答率(*Acc*)を示す。

また、本実験では、被験者単位の交差検定、臥位単位の交差検定を行い、6つの評価指標を算出することで評価を行う。被験者単位の交差検定では、全被験者によって得られた20データの内、一人分の4データをテストデータとし、残り16データを学習データとする。臥位単位の交差検定では、全被験者によって得られた20データの内、1種類の臥位において得られた5データをテストデータとし、残り15データを学習データとする。

表1 推定結果の分類

		真の状態	
		無呼吸状態	呼吸状態
推定状態	無呼吸状態	<i>TP</i>	<i>FP</i>
	呼吸状態	<i>FN</i>	<i>TN</i>

$$Sensitivity(Sen) = \frac{TP}{TP + FN} \quad (3)$$

$$Specificity(Spe) = \frac{TN}{TN + FP} \quad (4)$$

$$PPV = \frac{TP}{TP + FP} \quad (5)$$

$$NPV = \frac{TN}{TN + FN} \quad (6)$$

$$F_{value} = \frac{2Sensitivity \cdot PPV}{Sensitivity + PPV} = \frac{2TP}{2TP + FP + FN} \quad (7)$$

$$Accuracy(Acc) = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

4. 結果

4.1 取得したデータ

図10には、取得した生データの一例、図11は、図10で示す生データにウェーブレット変換をすることで得られた各時刻の周波数分布を示す。図10を見ると、無呼吸状態である20秒から40秒、80秒から100秒、140秒から160秒の区間において、振幅が小さくなっていることが分かる。また、図11を見ると、無呼吸状態の区間において、周波数強度が小さくなっていることが分かる。




図10 生データの一例

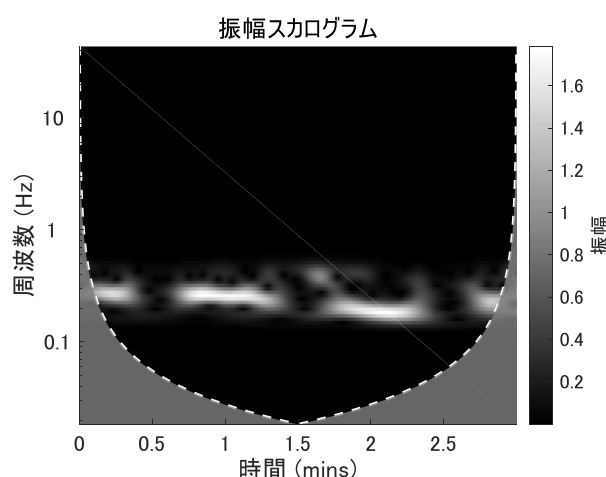


図11 各時刻の周波数分布

4.2 評価結果

実験1

表2, 3には生データに0.15~0.45Hzのバンドパスフィルタを適用し、Autoencoderのパラメータ*l*を75、*m*を50としたときの、被験者、臥位ごとの交差検定によって得られた評価指標を示す。また、表4, 5には、生データに0.15~0.45Hzのバンドパスフィルタを適用せずに、Autoencoderのパラメータ*l*を75、*m*を50としたときの被験者、臥位ごとの評価指標を示す。

表2 被験者単位の交差検定 (*l*=75,*m*=50,BPF有)

ID.	<i>Sen</i>	<i>Spe</i>	<i>PPV</i>	<i>NPV</i>	<i>Fvalue</i>	<i>Acc</i>
1	0.867	0.939	0.876	0.934	0.871	0.915
2	0.867	0.908	0.825	0.932	0.845	0.894
3	0.846	0.834	0.718	0.916	0.777	0.838
4	0.890	0.945	0.890	0.945	0.890	0.927
5	0.831	0.973	0.939	0.920	0.882	0.926

表 3 臥位単位の交差検定の結果 ($l=75, m=50, \text{BPF 有}$)

No.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.831	0.930	0.855	0.917	0.843	0.897
2	0.889	0.913	0.836	0.943	0.862	0.905
3	0.829	0.918	0.834	0.915	0.831	0.888
4	0.905	0.917	0.845	0.951	0.874	0.913

表 4 被験者単位の交差検定 ($l=75, m=50, \text{BPF 無}$)

ID.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.753	0.948	0.879	0.885	0.811	0.883
2	0.59	0.937	0.824	0.82	0.688	0.821
3	0.965	0.435	0.46	0.961	0.623	0.611
4	0	1	0	0.667		0.667
5	0.728	0.939	0.857	0.873	0.787	0.869

表 5 臥位単位の交差検定の結果 ($l=75, m=50, \text{BPF 無}$)

No.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.553	0.987	0.955	0.815	0.7	0.842
2	0.585	0.984	0.947	0.826	0.723	0.851
3	0.858	0.694	0.584	0.907	0.695	0.749
4	0.822	0.822	0.698	0.902	0.755	0.822

図 12 には、各時刻の周波数分布の算出の際にバンドパスフィルタを適用した場合としない場合における、被験者ごとの交差検定によって得られた正答率、図 13 には、各時刻の周波数分布の算出の際にバンドパスフィルタを適用した場合としない場合における、臥位ごとの交差検定によって正答率をプロットした箱ひげ図を示す。図 12, 13 を見ると、バンドパスフィルタを適用した場合の方がばらつきが小さく、平均値が大きくなっていることが分かる。

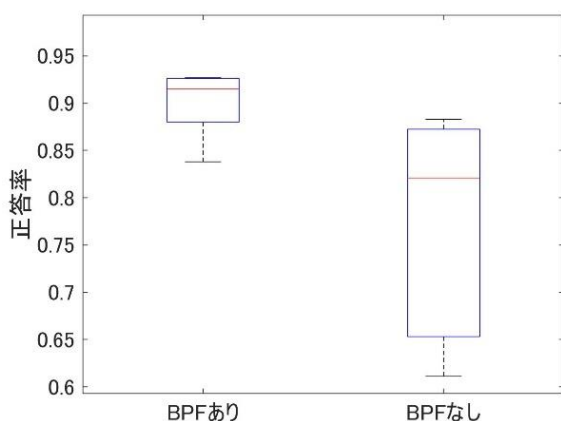


図 12 BPF の有無に関する検証 (被験者交差検定)

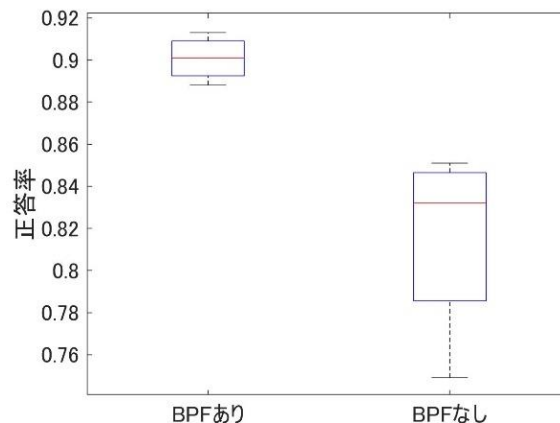


図 13 BPF の有無に関する検証 (臥位交差検定)

実験 2

表 6, 7 には、バンドパスフィルタを適用した場合に、層数を 1, l を 10 としたときの被験者、臥位ごとの評価指標を示す。表 8, 9 には、バンドパスフィルタを適用しなかった場合に、層数を 1, l を 10 としたときの被験者、臥位ごとの評価指標を示す。

表 6 被験者単位の交差検定 ($l=10, \text{BPF 有}$)

ID.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.89	0.874	0.78	0.941	0.831	0.879
2	0.787	0.901	0.8	0.895	0.793	0.863
3	0.799	0.857	0.737	0.895	0.767	0.838
4	0.902	0.926	0.86	0.95	0.88	0.918
5	0.889	0.941	0.883	0.944	0.886	0.923

表 7 臥位単位の交差検定 ($l=10, \text{BPF 有}$)

No.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.848	0.973	0.939	0.927	0.891	0.931
2	0.842	0.953	0.899	0.924	0.87	0.916
3	0.801	0.886	0.779	0.899	0.79	0.858
4	0.925	0.92	0.852	0.961	0.887	0.922

表 8 被験者単位の交差検定 ($l=10, \text{BPF 無}$)

ID.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.7	0.897	0.773	0.857	0.735	0.832
2	0.53	0.978	0.923	0.806	0.673	0.829
3	0.957	0.472	0.476	0.956	0.636	0.634
4	0.607	0.972	0.917	0.832	0.73	0.851
5	0.797	0.875	0.762	0.896	0.779	0.849

表 9 臥位単位の交差検定 ($l=10, \text{BPF 無}$)

No.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.623	0.957	0.879	0.835	0.729	0.846
2	0.457	0.989	0.953	0.785	0.618	0.812
3	0.893	0.628	0.546	0.922	0.678	0.717
4	0.854	0.734	0.616	0.91	0.716	0.774

図 14 には、被験者ごとの交差検定によって得られた正答率、図 15 には、臥位ごとの交差検定によって正答率をプロットした箱ひげ図を示す。図 14, 15 において、1 列目には表 2, 3 で示した正答率をプロットし、2 列目には表 6, 7 で示した正答率、3 列目には表 8, 9 で示した正答率をプロットしている。図 14 を見ると、被験者ごとの交差検定では、層数の違いに関わらず、ばらつき、平均値、共に目立った差は見られなかった。しかしながら、図 15 を見ると、臥位ごとの交差検定では、層数に関わらず、平均値はあまり変わらなかったが、ばらつきに関しては、層数を 2 とした場合に著しく小さくなった。




図 14 BPF 区間のみの検証 (被験者交差検定)

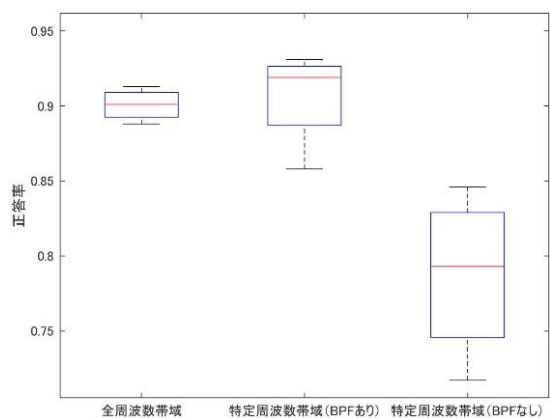


図 15 BPF 区間のみの検証 (臥位交差検定)

実験 3

表 10, 11 には、バンドパスフィルタを適用した場合に、層数を 2, l を 75, m を 50, 活性化関数を正の線形飽和関数 (satlin) としたときの被験者、臥位ごとの評価指標を示す。

表 10 被験者単位の交差検定 ($l=75, m=50, \text{BPF 有}, \text{satlin}$)

ID.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.83	0.942	0.877	0.917	0.853	0.905
2	0.813	0.908	0.816	0.907	0.814	0.877
3	0.842	0.847	0.734	0.915	0.784	0.845
4	0.886	0.93	0.864	0.942	0.875	0.916
5	0.827	0.972	0.937	0.918	0.879	0.924

表 11 臥位単位の交差検定 ($l=75, m=50, \text{BPF 有}, \text{satlin}$)

No.	Sen	Spe	PPV	NPV	F_{value}	Acc
1	0.825	0.941	0.876	0.915	0.85	0.903
2	0.874	0.947	0.892	0.937	0.883	0.923
3	0.766	0.908	0.807	0.886	0.786	0.861
4	0.926	0.907	0.833	0.961	0.877	0.913

図 16 には、被験者ごとの交差検定によって得られた正答率、図 17 には、臥位ごとの交差検定によって正答率をプロットした箱ひげ図を示す。図 16, 17 において、1 列目には表 2, 3 で示した正答率をプロットし、2 列目には表 10, 11 で示した正答率をプロットしている。図 16 を見ると、被験者ごとの交差検定では、層数の違いに関わらず、ばらつき、平均値、共に目立った差は見られなかった。しかしながら、図 17 を見ると、臥位ごとの交差検定では、活性化関数を正の線形飽和関数 (satlin) としたときと logsig としたときに、ばらつきが大きくなった。

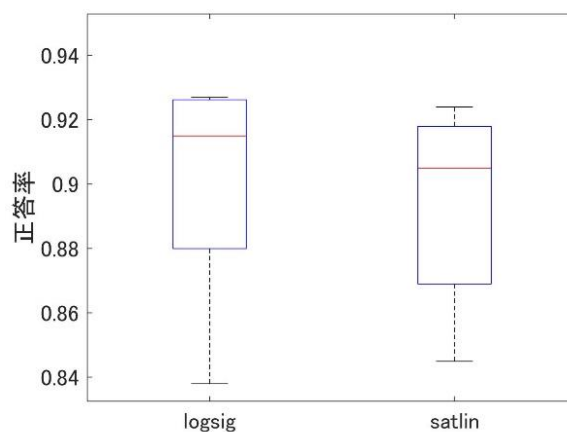


図 16 活性化関数の検証 (被験者交差検定)

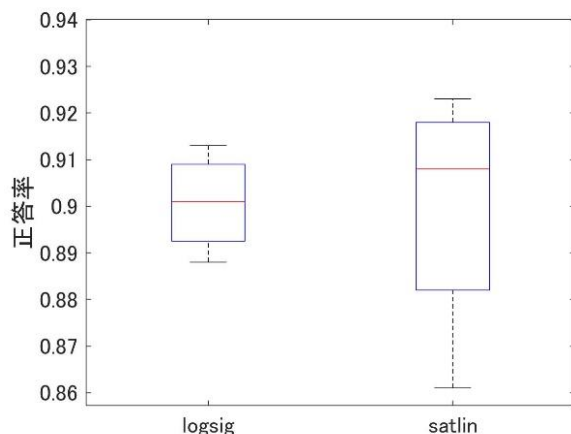


図 17 活性化関数の検証 (臥位交差検定)

5. 考察

実験 1 では、被験者単位、臥位単位の交差検定において、バンドパスフィルタをかけた場合の方が判別精度は高いという結果になった。原因としては、バンドパスフィルタを適用しなかったとき、Autoencoder によってデータを学習する際に、余分なノイズが含まれてしまったためと考えられる。

実験 2 では、被験者単位での交差検定では、バンドパスフィルタを適用しなかった場合に、平均値、ばらつきが小さくなった。また、臥位単位の交差検定ではバンドパスフィルタの有無に関わらず、ばらつきが大きいう結果になった。このような結果となった原因としては、Autoencoder に入力する周波数帯域の幅が大きいが情報量が多く、より高度な無呼吸判別モデルを構築できるためと考えられる。

実験 3 では、被験者単位の交差検定では、活性化関数の種類に関わらず、平均値、ばらつき、共に、大きな差は見られなかったが、臥位単位の交差検定では、活性化関数に正の線形飽和関数(satlin)を使用した場合に、ばらつきが大きくなった。

以上より、Autoencoder の条件を変えた場合、臥位の違いが判別精度に大きな影響を及ぼすことが分かった。また、本研究において、無呼吸推定に用いる Autoencoder の条件としては、バンドパスフィルタを適用し、層数を 2、 l を 75、 m を 50、活性化関数を正のロジスティックシグモイド関数した場合が、最も適当であるといえる。

6. むすび

本研究では、各時刻の周波数分布の分布情報を残すために Autoencoder を使用し、次元圧縮によって特徴量算出を行った。また、遮断周波数を 0.15Hz-0.45Hz としたデジタルバンドパスフィルタを適用し、Autoencoder に入力する各時刻の周波数分布を算出する際にバンドパスフィルタの有無が

どのような影響を及ぼすのかについても検証を行った。さらに、特徴量抽出のための次元圧縮手法として用いる活性化関数を変更した場合の判別精度についても検証した。検証実験の結果、被験者単位、臥位単位の交差検定において、正答率は 0.838 以上となり、無呼吸状態推定システムとして十分な精度が得られたといえる。

今後は、無呼吸データの学習が不要なシステムを構築するために敵対的生成ネットワーク (GAN) を使用した場合の判別精度検証を行っていきたい。

参考文献

- [1] GBD 2016 Causes of Death Collaborators, "Global, regional, and national age-sex specific mortality for 264 causes of death, 1980–2016: a systematic analysis for the Global Burden of Disease Study 2016," *THE LANCET*, vol.390, issue.10100, pp.1151-1210, Sept. 2017
- [2] 百村伸一, "睡眠呼吸障害と循環器疾患:Overview", 第 59 回日本心臓病学会学術集会シンポジウム
- [3] F. Maia, A. Goulart, L. Drager, H. Staniak, I. Santos, P. Lotufo and I. Bensenor. "Impact of High Risk for Obstructive Sleep Apnea on Survival after Acute Coronary Syndrome: Insights from the ERICO Registry," *Arquivos Brasileiros de Cardiologia*, vol.108, no.1, pp.31-37, January 2017.
- [4] O. Oldenburg, B. Lamp, L. Faber, H. Teschler, D. Horstkotte and V. Topfer. "Sleep-disordered breathing in patients with symptomatic heart failure A contemporary study of prevalence in and characteristics of 700 patients," *European Journal of Heart Failure*, vol.9, pp.251-257, 2007
- [5] M. Zakrzewski, A. Vehkaoja, A. Joutsen, K. Palovuori and J. Vanhala, "Noncontact Respiration Monitoring During Sleep With Microwave Doppler Radar," *IEEE Sensors Journal*, vol.15, no.10, Oct. 2015
- [6] Y. Kurihara and K. Watanabe, "Sleep Stage Decision Algorithm by Using Heartbeat and Body Movement Signals," *IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans*, vol.42, no.6, pp.1450-1459, 2012
- [7] 西尾啓汰, 高尾郁也, 鍋木崇史, 栗原陽介, "周波数強度の分布を活用した睡眠時の無呼吸状態検出アルゴリズム", 2019 年電子情報通信学会総合大会