

G-17

患者背景情報を用いた睡眠時無呼吸症候群のリスク判別に関する検討

- 長浜コホートを使用した機械学習モデルの性能比較 -

A Study on Risk Classification of Sleep Apnea Syndrome Using Patient Background Information

- Performance Comparison of Machine Learning Models Using the Nagahama Study -

○野島純¹, 関弘翔², 村瀬公彦³, 赤星俊樹^{4,5}, 田原康玄^{3,6}, 中山健夫³, 松田文彦³, 権寧博⁴, 陳和夫⁴, 細野裕行²*Jun Nojima¹, Hiroto Seki², Kimihiko Murase³, Toshiki Akahosi^{4,5}, Yasuharu Tabara^{3,6}, Takeo Nakayama³, Fumihiko Matstuda³, Yasuhiro Gon⁴, Kazuo Chin⁵, Hiroyuki Hosono²

Abstract : This study examines the development of a system to predict apnea hypopnea index (AHI), which is used to discriminate sleep apnea syndrome (SAS) risk, based on patient background information.

1. 研究背景

睡眠時に 10 秒以上続く気流停止を睡眠時無呼吸という。睡眠時無呼吸症候群 (SAS : Sleep Apnea Syndrome) は、睡眠時間 1 時間あたりの無呼吸低呼吸指数 (AHI : Apnea Hypopnea Index) や臨床症状の有無などから診断される。SAS を AHI \geq 5 かつ昼間の過度の眠気と定義した際、その有病率は男性の 5 %前後、女性の 2~3 %前後とされる。SAS の危険因子には肥満 (高 BMI)、性別 (男性)、年齢が挙げられている^[1]。

SAS リスクの検査には体内の酸素飽和度などを測るため、一晩かけて行う必要がある。このため、簡易的に SAS リスクの判別を行う手法が必要とされている。

先行研究^[2]では、患者背景情報を用い、全結合層 4 層からなるニューラルネットワークによる SAS リスクの分類モデルが構築された。AHI に基づいて無症状、軽症、中等症、重症の 4 クラス分類を学習した際の精度は 50%であり、精度改善が課題として挙げられた。

本研究では、新たに約 7,000 人規模の長浜コホートを用い、患者背景情報から AHI の回帰および SAS リスクの分類を行う決定木モデルの構築を行った。また、説明可能な XAI の一つである SHAP (SHapley Additive exPlanations)^[3]を用いて判断根拠の可視化を行い、構築したモデルの科学的妥当性を検証した。

2. 方法

本研究は日本大学医学部附属板橋病院における臨床研究倫理審査委員会の承認(RK-230613-5)を受けて実施した。

データセットとして、新宿睡眠・呼吸器内科クリニックで収集された 80 人分の診察データと、約 7,000 人分の長浜コホートを用いた。データセットはモデルの

学習用とテスト用に 9 対 1 の割合でランダム分割している。また、モデルの説明変数として、患者背景情報から「年齢」「性別」「身長」「体重」「腹囲」「BMI」「高血圧の有無」「糖尿病の有無」の 8 属性を用いた。

精度評価には二乗平均平方誤差 (RMSE : Root Mean Square Error) と、予測された AHI より算出した 4 クラスの SAS リスクの正解率を用いた。ここで SAS リスクは、AHI 5 未満をリスク 0, $5 \leq$ AHI < 15 をリスク 1, $15 \leq$ AHI < 30 をリスク 2, AHI \geq 30 をリスク 3 と定義している。

3. 結果

本研究では、表形式データの学習に長けた決定木ベースのアンサンブル学習手法であるランダムフォレスト、LightGBM、XGBoost を用いて AHI 予測精度および SAS リスク分類精度を比較した。Python の機械学習ライブラリである scikit-learn^[4]を用いて実装した。さらにニューラルネットワークを用いた先行研究^[2]の結果も比較に用いた。

決定木モデルのハイパーパラメータ (決定木の数や決定木の深さ、形成した木の葉の最小サンプル数など) は、ハイパーパラメータ探索ツールの Optuna^[5]を用いて最適化した。結果を Table 1 に示す。

Table 1 より、分類精度では LightGBM の 63.61%が最も高い精度となったが、RMSE では XGBoost の 6.10 が最も良い精度となった。

Fig. 1 に、AHI 回帰の指標である RMSE が最良であった XGBoost での出力結果に対し、SHAP を用いて判断根拠を可視化した図を示す。Fig. 1 は縦軸の上から順に予測に影響を与えた説明変数が並んでおり、横軸は各説明変数が AHI を高める方向に寄与したか、下げる

1 : 日大理工・学部・情報 2 : 日大理工・教員・情報 3 : 京都大学大学院医学研究科 4 : 日大医・教員・医

5 : 新宿睡眠・呼吸器内科クリニック 6 : 静岡社会健康医学大学院大学

方向に寄与したかを SHAP 値として表している。カーブスケールは各説明変数の値に対応している。

結果より、性別、年齢、腹囲、BMI、体重が AHI 予測に影響が大きいとわかる。男性を 0、女性を 1 としているため、男性であるほど AHI を高めていることもわかる。さらに、年齢、腹囲、BMI、体重それぞれ、値が大きいほど AHI を高く、つまり SAS リスクを高く予測する傾向が見られ、既知の科学的妥当性^[1]と相違ない結果が得られた。

本研究で使用した長浜コホートは一般人口のコホートであるため SAS リスク 2, 3 のデータ数がリスク 0, 1 のデータ数に対して極端に少ない。その問題に対処するため、入力データに対して SMOGN^[6]と呼ばれる回帰のための合成オーバーサンプリング法を使用して、少数クラスのデータ数を増やし、データ全体の不均衡を修正した。修正したデータを使用し XGBoost による学習を行った結果を Table 2 に示す。また Fig. 2 に、データ不均衡調整前後の混同行列を示す。

データ不均衡修正後では、修正前と比較してテストデータ全体の RMSE は上昇し、分類精度は低下したが、リスク 2, 3 の RMSE は低下し、分類精度は向上した。

4. まとめ

本研究では、約 7,000 人規模の長浜コホートを用いて決定木ベースの 3 種のモデルを構築し、患者背景情報から AHI 回帰および SAS リスク分類を行った。

結果より、AHI 回帰においては XGBoost が最良のモデルとなった。学習データに存在するデータの不均衡を修正することで、データ数が少ない高リスク帯での精度は向上したが、全体の精度は悪化した。XAI による判断根拠の可視化結果より、構築した XGBoost モデルは、既知の科学的知見と相違ない結果が得られた。

謝辞

データ提供にご協力いただいた新宿睡眠・呼吸器内科クリニックの遠藤大介先生、伊藤辰也先生に感謝申し上げます。

Table 1. Result of each model

	RMSE	SASrisk Accuracy
Neural Network	7.47	63.13%
Random Forest	6.25	62.89%
LightGBM	6.22	63.75%
XGBoost	6.10	63.61%

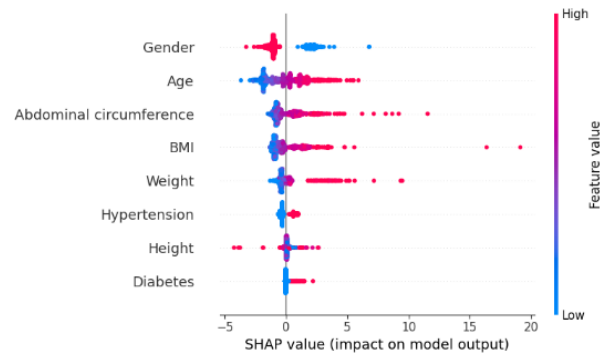


Figure 1. SHAP Analysis of the XGBoost Model

Table 2. Results of XGBoost with SMOGN Applied

RMSE	SASrisk Accuracy
8.34	55.87%

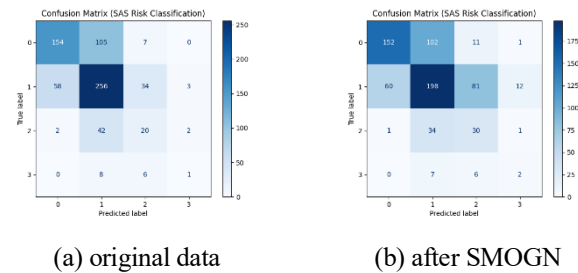


Figure 2. XGBoost Confusion Matrix

参考文献

- [1] 日本呼吸器学会, “睡眠時無呼吸症候群 (SAS) の診療ガイドライン 2020,” 2020.
- [2] 石井尊琉, 他 “患者背景情報を用いた睡眠時無呼吸症候群のリスク判別に関する検討,” 令和 6 年度 (第 68 回) 日本大学理工学部学術講演会予稿集, G-12, 2025
- [3] S. M. Lundberg and S.-I. Lee, “A Unified Approach to Interpreting Model Predictions,” in Advances in Neural Information Processing Systems, Vol. 30, pp. 4765-4774, 2017.
- [4] F. Pedregosa, et al., “Scikit-learn: Machine learning in Python,” Journal of Machine Learning Research, vol. 12, pp. 2825 - 2830, 2011.
- [5] T. Akiba, et al., “Optuna: A next-generation hyperparameter optimization framework,” in Proc. 25th ACM SIGKDD Int. Conf. Knowledge Discovery & Data Mining, pp. 2623 - 2631, 2019.
- [6] P. Branco, L. Torgo, and R. P. Ribeiro, “SMOGN: A pre-processing approach for imbalanced regression,” in Proc. First Int. Workshop on Learning with Imbalanced Domains: Theory and Applications (LIDTA), PMLR, Vol. 74, pp. 36–50, 2017.