

公衆衛生分野における機械学習活用の可能性 ～自殺リスクの予測モデルを参考に～

○中川優馬、近藤文乃、持永展孝
宮崎県福祉保健課

I. はじめに

機械学習とは、大量のデータの中からパターンや法則を見つけ、予測や判断を自動化する技術である。機械学習による自殺リスクの予測は、諸外国において報告がされている¹⁾が、我が国における公衆衛生的アプローチに関する報告はまだ少ない。

今回、プログラミング言語であるPythonを用いて、機械学習モデルを構築し、公衆衛生分野における機械学習活用の可能性について検討した。

II. 方法

(1) 機械学習の実行環境

Python in Excel に標準搭載されたライブラリを使用した。

(2) 学習に用いたデータ

平成29年から令和5年までの間に県警察本部から保健所に情報提供のあった自殺未遂者410名に関するデータの内、年齢、市町村、性別、自殺未遂時の手段、自殺未遂に至った要因、要因数、情報提供書への「うつ病」の記載の有無、職業（有職・学生生徒等・無職）を説明変数として用いた。

また、平成31年から令和5年までの人口動態統計死亡個票と自殺未遂者410名を照合し、死因が自殺である死亡個票と一致した場合に【既遂】、それ以外を【生存】として正解ラベルを付与し、目的変数とした。

(3) 学習に用いたモデル

ランダムフォレストをベースモデルとした教師あり学習を行った。また、不均衡データに対する重み付けとして、BalancedBaggingClassifierを用い、アンダーサンプリングとバギングを行った。

III. 結果

(1) ホールドアウト検証

410名のデータについて、学習データと検証データを7:3(277名:133名)に分け、学習データを基に検証をした結果を図1に示す。

縦軸が個別のケースに対して機械学習が予測した自殺リスク(Suicide risk)、横軸がケース数を示している。

判別の閾値を0.5とした場合の混同行列を表1に示す。機械学習が自殺のリスクが高いと判断した者は20名であり、そのうち3名が実際に既遂をした者であった。

検証データに対するAUC(Area Under the ROC Curve)値は、0.80であった。

(2) 交差検証(層状K分割法)

410名のデータを正解ラベルが均等に含まれるよう5分割し、学習と検証を5回繰り返した上でその平均を取る交差検証(クロスバリデーション)で学習モデルの評価を行った。

5回のROC曲線とAUC値、それぞれの平均を図2に示す。交差検証の平均AUC値は、0.798であり、最も低いAUC値を示したのは、【fold 1】(AUC=0.612)であった。

【fold 1】において、既遂を必ず検出し、偽陽性をできるだけ少なくするような閾値(optimal threshold)は、0.214であった。そのときの混同行列を表2に示す。

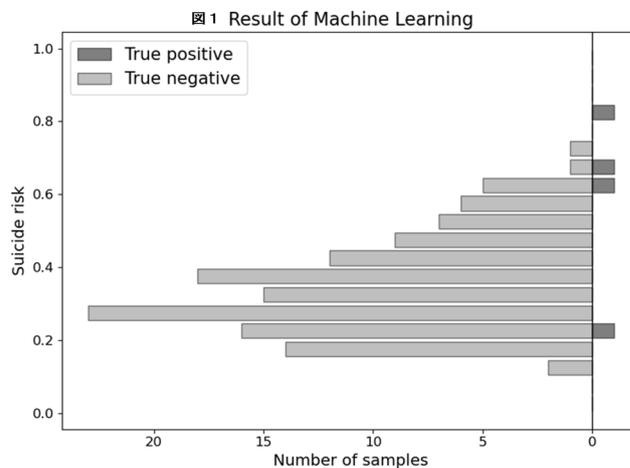


表1

		正解ラベル	
		True negative (生存)	True positive (既遂)
機械学習による 自殺リスクによる	高	20	3
	低	109	1

感度: 0.75

陽性的中率: 0.13

検証データ N=133

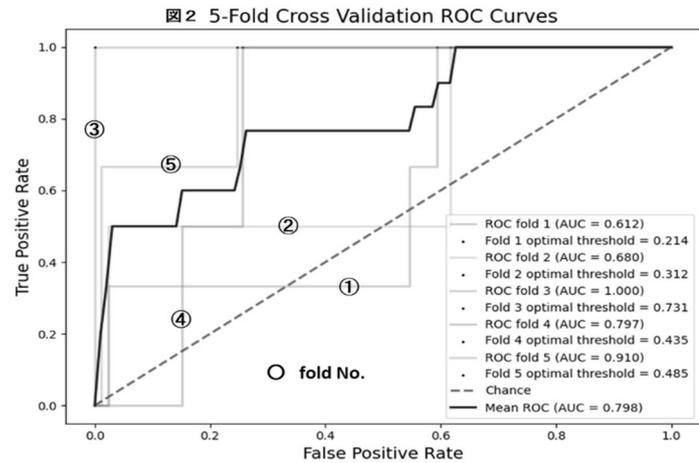
※閾値=0.500

表2 (fold 1:optimal threshold)

		正解ラベル	
		True negative (生存)	True positive (既遂)
機械学習による予測リスク	高	51	3
	低	35	0

感度：1.00
陽性的中率：0.06

検証データ N=89
※閾値=0.214



IV. 考察

(1) モデルの解釈

今回構築した機械学習モデルの交差検証における AUC 値は、0.798 であった。機械学習において AUC 値が 0.5 である場合、ランダム予測と変わらないものとして取り扱うことから、今回構築した機械学習モデルは中程度の予測性能を持っていると考えられる。

一方で、今回用いたデータのように正解ラベルに偏りがあるデータ（不均衡データ）の場合、負例（本稿では、生存）を予測した結果が AUC 値に大きな影響を与えるため、感度と陽性的中率を考慮する必要がある。

表 1 より、閾値を 0.5 とした感度が 0.75、陽性的中率が 0.13 であったことから、正例（既遂）の予測精度は、まだ実用に耐えないレベルである。予測精度については、学習データの量に左右されることから、今後データの蓄積によって改善する可能性がある。

(2) 閾値の設定

今回の 410 人のデータに対して、既遂（正例）を必ず検出し、偽陽性をできるだけ少なくするような閾値は、0.214 であった。

機械学習における閾値の設定については、予測したい正解ラベルの特性や適用される分野によって決められるべきである。今回の様に人命に関わる予測については、できるだけ正例を拾うように設定をすべきであり、この閾値の設定についても、予測精度の改善とともに検討していく必要がある。

(3) 実務への適用と公衆衛生分野への活用

機械学習が予測した自殺リスクの活用方法について、例えば、一定以上の自殺リスクがあると判断された場合に、通常行う支援に加えて、介入頻度を増やしたり、支援期間を通常より長く設定する等が挙げられる。

また、今回は自殺未遂者のデータを用いて予測モデルを構築したが、例えば、過去の結核の登録票情報を学習データに用いて再発リスクを予測したり、県民健康・栄養調査の結果から特定の傾向を持つ集団の抽出（クラスタリング）など活用の範囲は多岐に渡る。

先行研究においては、健診データから生活習慣病を予測する機械学習モデル²⁾³⁾の検討等がなされており、今後、公衆衛生分野における活用が加速していくことが予想される。そのため、行政職員においても知見を深めていく必要がある。

(4) 倫理的配慮

機械学習を用いたツールを開発・社会実装するにあたっては、種々の倫理的・法的・社会的な課題について配慮することが求められている。機械学習を含めた AI 利用に関わる最終判断は人が行うとする「人間中心の原則」⁴⁾を守りながら、新たな技術活用を進めていくことが重要である。

1) 木下翔太郎:機械学習を用いた自殺予防の可能性とその問題点, 日本生物学的精神医学会誌, 31 巻 3 号

2) Tadao Ooka: Random forest approach for determining risk prediction and predictive factors of type 2 diabetes: large-scale health check-up data in Japan, BMJ Nutr Prev Health, 2021, 4(1), 140-148

3) 恒川 充: 健診データを用いた生活習慣病の発症予測, 人工知能学会第二種研究会資料, 2019 年, 2019 巻, AIMED-007 号, 10-

4) 内閣府: 人間中心の AI 社会原則, 統合イノベーション推進会議決定, 2019