

XAI 를 활용한 기업 부도예측 분류모델 연구

김지흥, 문남미

호서대학교 벤처대학원 융합공학과

jh.wisard@gmail.com, nammee.moon@gmail.com

A Study on Classification Models for Predicting Bankruptcy using XAI

Jihong Kim, Nammee Moon

Dept. of Convergence Engineering, Hoseo Graduate School of Venture,

Hoseo Univ.

요 약

최근 금융기관에서는 축적된 금융 빅데이터를 활용하여 차별화된 서비스를 강화하고 있다. 기업고객에 투자하기 위해서는 보다 정밀한 기업분석이 필요하다. 본 연구는 대만기업 6,819개의 95개 재무데이터를 가지고, 비대칭 데이터 문제해결, 데이터 표준화 등 데이터 전처리 작업을 하였다. 해당 데이터는 로지스틱 회귀, SVM, K-NN, 나이브 베이즈, 의사결정나무, 랜덤 포레스트 등 9가지 분류모델에 5겹 교차검증을 적용하여 학습한 후 모델 성능을 비교하였다. 이 중에서 성능이 가장 우수한 분류모델을 선택하여 예측 결정 이유를 판단하고자 설명 가능한 인공지능(XAI)을 적용하여 예측 결과에 대한 설명을 부여하여 이를 분석하였다. 본 연구를 통해 데이터 전처리에서부터 모델 예측 결과 설명에 이르는 분류예측모델의 전주기를 자동화하는 시스템을 제시하고자 한다.

1. 서론

금융기관에서는 축적된 금융 빅데이터를 활용한 다양한 연구가 활발하게 진행되고 있다. 특히 중소기업을 대상으로 이루어지는 투자와 대출은 기업들의 성장에 중요한 밑거름이 된다. 금융기관의 기업 신용도 분석은 재정 건전성 강화에 아주 중요한 부분이며, 기업의 부도로 인한 부정적인 요소와 경제적 손실을 줄이는데 필요한 부분이다.

본 연구에서는 대만 경제 저널에서 1999~2009년 동안 수집된 6,819개 기업의 95개 재무적 속성데이터를 활용하여 로지스틱 회귀, SVM(Support Vector Machine), K-NN, 나이브 베이즈, 의사결정나무, 랜덤 포레스트, XGBoost, LightGBM, CatBoost 알고리즘을 가지고 기업부도 여부를 예측한다. 이 중에서 정확도가 가장 높은 알고리즘을 선택하고, 설명 가능한 인공지능 기법을 활용하여 기업부도에 영향을 미치는 요인을 분석한다. 이를 통해 관련 금융기관이 투자에 적합한 기업을 분석하는데 필요한 환경을 지원하고자 한다.

2. 관련 연구

최근 연구에 따르면 다변량 정규성, 다중 공선성, 올바르게 않은 분류비율 등의 기존 분류모델의 약점을 보완하기 위한 앙상블 프레임워크는 부도예측에 유용한 방식이다. 더 나은 분류 성능을 달성하기 위해 다양한 머신러닝 기술이 시도되었으며, <표1>은 부도예측에 그래디언트 부스팅(Gradient Boosting)을 사용한 주요 연구들이다[1].

3. 방법론 및 이론적 배경

본 연구에서는 가장 잘 알려진 기계학습 모델 9가지 기술로 대만기업 부도를 예측하여 성능을 측정하고자 한다.

<표 1> 부도예측 분류모델 사용 연구사례

연구	모델	우수모델
Zięba et al. (2016) [2]	선형판별분석, 의사결정나무, 로지스틱회귀, AdaBoost, SVM, XGBoost, EXGB	EXGB
Jones (2017) [3]	로지스틱회귀, XGBoost	XGBoost
Huang and Yen (2019) [4]	SVM, HACT, XGBoost, DBN	XGBoost
Carmona et al. (2019) [5]	로지스틱회귀, 랜덤포레스트, XGBoost	XGBoost
Son et al. (2019) [6]	로지스틱회귀, 랜덤포레스트, XGBoost, LightGBM	XGBoost, LightGBM

* 참고 : EXGB(저자가 구현한 앙상블알고리즘), HACT(하이브리드 연관분류기), DBN(Deep Belief Network)

로지스틱 회귀(Logistic Regression)는 분류분석 효율이 높지 않다는 한계는 있지만 부도 예측에서 질적 종속변수는 회사의 상태(부도, 정상)를 나타내는 특정 설명변수 정의를 가능하게 한다. 최근 SVM은 신용등급, 시계열 예측 및 사기 탐지와 같은 금융 애플리케이션에 사용되었다[7]. 랜덤 포레스트는 다양한 분류 및 예측 문제에서 사용되었으며, Hyperparameter가 다른 알고리즘보다 적어도 우수한 성능을 도출한다는 장점이 있다. XGBoost는 분산환경에서 효과적인 데이터 처리문제를 위해 데이터 정렬 및 분할을 병렬 처리하여 학습 속도를 향상하였다[8]. LightGBM은 의사결정트리 기반의 순위 및 분류를 위한 기계학습 알고리즘이며, 매우 높은 정확도와 빠른 수행이 가능하다[9]. CatBoost는 순열 기반의 Ordered Boosting 구현과 범주형 피쳐 처리를 위한 알고리즘이다.

SHAP은 개별 예측 값에 대한 각 독립변수들의 영향력을 모델에 상관없이 개별 예측에 대한 추가적인 해석방법을 제공한다. 이때 영향력을 측정하는 값으로

Shapley Value를 사용한다. SHAP은 개별 예측 결과에 대한 설명력을 제공하는 Local Interpretation과 함께 전체 데이터의 변수별 기여도를 시각화하여 설명 가능한 해석을 할 수 있는 Global Interpretation을 함께 제공한다[10].

4. 실험 및 결과 분석

1) 데이터 전처리


본 연구의 기업부도 데이터는 대만경제저널에 제공된 6,819개 기업데이터이며, 영업총이익, 영업이익률, 영업비율, 주당순가치 등 95개 독립변수로 구성되어 있다. 종속변수는 부도여부(bankruptcy value 0/1)이다. 데이터에는 제조, 서비스 및 기타 산업들이 포함되어 있다.

전체 데이터 중 부도기업은 220개로 비대칭 데이터 문제가 발생할 수 있다. 데이터 클래스 비율이 너무 차이가 나면 우세한 클래스를 택하는 모델의 정확도가 높아지므로 모델의 성능판별이 어려워진다. 즉, 정확도(accuracy)가 높아도 데이터 개수가 적은 클래스의 재현율(recall-rate)이 급격히 작아지는 현상이 발생할 수 있다. 이런 문제를 해결하기 위해 복합샘플링(Combining Over- and Under-Sampling)기법을 적용(그림1) 하여 해결한다[11]. 샘플링을 통해 생성된 데이터는 부도 5,426개, 정상 6,256개 이다 <표2>.

데이터 내 포함된 기업들은 업종과 규모가 서로 다르므로 이를 위해서 데이터 표준화(Standardization) 작업을 진행하고 독립변수들의 결측치와 이상치 값을 확인하여 정제하는 과정을 진행한다.

<표 2> 데이터 구성

	정상	부도	전체데이터
기본데이터	6,599	220	6,819
복합샘플링	훈련	4,990	9,345
	테스트	1,266	2,337
	합계	6,256	5,426



(그림 1) 복합샘플링

2) 평가 방법

학습한 분류 모델의 성능을 심층 비교하기 위해서 본 연구에서는 (그림2)와 같이 5겹 교차검증(5-Fold Cross Validation)을 적용하였다[12]. 전체 데이터셋에서 비복원 추출 방식을 통해 5개의 폴드로 나누고, 한 개의 폴드에 있는 데이터를 다시 5개로 쪼갬 다음, 4개는 훈련데이터, 1개는 검증데이터 셋으로 지정하여 모델을 학습하고 예측을 진행한다. 다음 폴드에서는 검증데이터 셋을 바꿔서 지정하고 이전 폴드와 같이 학습을 진행한다. 이런 방식으로 총 5번을 반복 검증한다. 전체 데이터 셋이 작은 경우 모델의 신뢰성을 높일 수 있는 장점이 있다.

3) 평가 지표

본 연구에서는 분류 모델의 성능 평가 지표로 정밀

도(Precision), 정확도(Accuracy), F1-Score를 측정하였으며, 모든 평가지표들은 혼동행렬(Confusion Matrix)을 기반으로 평가한다.




(그림 2) 교차검증

4) 결과 분석

평가 방법에서 설명한 5겹 교차검증으로 분류 모델을 구성하여 도출한 측정치는 평균값을 기준으로 각 예측모델별 성능은 <표3>에 나타내었다. 시각적 이해를 돕기 위해 모델별 분류성능 비교를 (그림3)으로 구성하였다.

<표 3> 분류모델별 Test Set 성능비교

예측모델	Precision	F1-score	Accuracy
로지스틱회귀	0.92	0.93	0.9221
SVM	0.91	0.93	0.9242
K-NN	0.92	0.96	0.9524
나이브 베이즈	0.82	0.87	0.8498
의사결정나무	0.95	0.96	0.9607
랜덤포레스트	0.97	0.98	0.9756
XGBoost	0.98	0.99	0.9865
LightGBM	0.98	0.99	0.9908
CatBoost	0.97	0.99	0.9841



(그림 3) 모델별 분류성능 비교

모델별 분류성능 비교시 LightGBM 알고리즘이 높은 성능을 보였다. XGBoost와 CatBoost 알고리즘도 높은 분류예측 성능을 기록하였다.


본 연구에서는 모델 분류에서 가장 높은 성능을 보여준 LightGBM 모델에 SHAP을 적용하여 기업부도 예측 시각화를 진행하였다. (그림4)는 SHAP value를 도출하는데 영향을 미친 변수들을 SHAP summary plot에서 확인한 내용이다.

세후연속이자율(Continuous interest rate), 총자산 대비 이익잉여금(Retained Earnings to Total Assets), 매출현금흐름(Cash Flow to Sales)이 높을수록 기업부도를 예측할 확률이 낮으며, 총자산 대비 당기순이익(Net Income to Total Assets), 현재 자산회전율(Current Asset Turnover Rate)이 낮을수록 기업부도를 예측할 확률이 높은 것으로 분석되었다.


(그림5)에서는 95개 독립변수들의 중요도를 내림차순으로 상위 20개를 표현한 것이다. 맨 위의 총 부채/총 순자산(Total Debt/Total net worth)은 두 번째 변수인 세후연속이자율(Continuous interest rate)보

다 모델분류에 더 많이 기여했다는 것을 나타낸다.

특정 데이터에 대한 SHAP value를 분해하고 시각화한 것은 (그림6) 에서 제공된다. force_plot 예측값은 -7.83 이 나왔고, 기업부도에 긍정적인 영향을 준 요인은 자기자본대비 부채(Equity to Liability), 총 부채/총 순자산(Total Debt/Total net worth)이며, 부정적인 영향을 준 요인은 세후연속이자율(Continuous interest rate), 총자산 대비 이익잉여금(Retained Earnings to Total Assets)으로 분석되었다.



(그림 4) SHAP value of Test Set



(그림 5) Feature Importance by mean(|SHAP value|)



(그림 6) 개별기업의 SHAP Value

5. 결론 및 향후 과제

본 연구에서는 대만경제저널 기업부도 데이터를 가지고 로지스틱 회귀분석, SVM, K-NN, 나이브 베이즈, 의사결정나무, 랜덤 포레스트, XGBoost, LightGBM, CatBoost 알고리즘을 이용한 9가지 분류모델에 5겹 교차검증을 적용하여 학습한 후 모델 성능을 비교하였다. 그 결과 LightGBM이 정확도 0.9908와 F1-Score 0.99로 가장 우수한 성능을 보였다. LightGBM 분류모델의 예측 결과에 영향을 주는 재무적 계량지표(연속

이자율, 총자산 대비 이익잉여금, 매출현금흐름 등)를 판단하기 위해 XAI 기법 중 SHAP을 이용하여 분류 모델 예측 값의 판단 근거에 대한 설명을 제공했다.

향후 분류모델 성능 고도화와 예측결과에 대한 설명가능 요약 자동화 연구를 진행하고자 하며, 데이터 전처리에서부터 모델 예측 결과 설명에 이르는 분류 예측모델의 전주기를 자동화하는 시스템을 제시하고자 한다.

참고문헌

[1] Jabeur, Sami Ben, et al., "CatBoost model and artificial intelligence techniques for corporate failure prediction.", *Technological Forecasting and Social Change*, 2021, 166, 120658.

[2] Zięba, Maciej, Sebastian K. Tomczak, and Jakub M. Tomczak., "Ensemble boosted trees with synthetic features generation in application to bankruptcy prediction.", *Expert systems with applications*, 2016, 58, 93-101.

[3] Jones, Stewart., "Corporate bankruptcy prediction: a high dimensional analysis.", *Review of Accounting Studies*, 2017, 22.3, 1366-1422.

[4] Huang, Yu-Pei, and Meng-Feng Yen., "A new perspective of performance comparison among machine learning algorithms for financial distress prediction.", *Applied Soft Computing*, 2019, 83, 105663.

[5] Carmona, Pedro, Francisco Climent, and Alexandre Momparler., "Predicting failure in the US banking sector: An extreme gradient boosting approach.", *International Review of Economics & Finance*, 2019, 61, 304-323.

[6] Son, Hwijae, et al., "Data analytic approach for bankruptcy prediction.", *Expert Systems with Applications*, 2019, 138, 112816.

[7] Wu, Yue, Yunjie Xu, and Jiaoyang Li., "Feature construction for fraudulent credit card cash-out detection.", *Decision Support Systems*, 2019, 127, 113155.

[8] Chen, T. & Guestrin, C., "Xgboost: A scalable tree boosting system.", In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785-794.

[9] Ke, Guolin, et al., "Lightgbm: A highly efficient gradient boosting decision tree.", *Advances in neural information processing systems*, 2017, 30.

[10] Lundberg, Scott M., and Su-In Lee., "A unified approach to interpreting model predictions.", *Advances in neural information processing systems*, 2017, 30.

[11] Sun, Jie, et al., "Class-imbalanced dynamic financial distress prediction based on Adaboost-SVM ensemble combined with SMOTE and time weighting.", *Information Fusion*, 2020, 54, 128-144.

[12] Rodriguez, Juan D., Aritz Perez, and Jose A. Lozano., "Sensitivity analysis of k-fold cross validation in prediction error estimation.", *IEEE transactions on pattern analysis and machine intelligence*, 2009, 32.3, 569-575.