

무역통계 및 금융지표 기반 재무성과 예측 방법

이만니

고려대학교 컴퓨터정보통신대학원 빅데이터융합학과

man0388@korea.ac.kr

Financial Performance Prediction Method Based on Trade Statistics and Financial Indicators

Lee Man Ni

Korea Univ.

요약

재무성과는 경제의 다양한 분야에서 중요하게 활용되고 있다. 하지만 실무적·제도적인 사유로 재무성과 공시는 공시 대상 기간으로부터 실제 공시일까지 상당한 시간이 소요되어 정보 이용자가 최신 정보를 즉시 활용하기 어려운 문제가 있다. 이에 본 연구에서는 재무성과 중 매출액과 영업이익을 공시 이전에 예측하여 정보 활용 시차를 극복하고자 하였다. 이를 위해 다양한 머신러닝 모델과 무역통계 및 금융지표 데이터를 활용하여 산업별 최적 매출액, 영업이익 예측 모델을 개발하였다. 그 결과 GBM(Gradient Boosting Machine) 모델이 대부분의 산업에서 뛰어난 매출액, 영업이익 예측 성능을 발휘하였다. 또한, 매출액 고유 특성으로 매출액 예측 성능이 영업이익 예측 성능보다 우수한 것을 확인하였다.

I. 서론

재무성과 공시는 경제에서 중요한 역할을 수행하고 있으나 공시 대상 기간과 실제 공시일은 다소 괴리가 있다. 대표적으로 삼성전자의 2022년 12월 말 기준 재무성과는 2023년 3월 7일에 공시되었으며, 2023년 3월 말 기준 재무성과는 2023년 5월 15일에 공시되었다. 이러한 시차는 공시 대상 기간 종료 이후 재무성과 공시를 위한 결산 등의 실무적인 업무처리 기간 등으로 인하여 발생한다. 그리하여 자본시장법 제159조 및 제160조에서는 분기·반기(3월, 6월, 9월) 재무 사항 보고는 대상 기간의 경과 후 45일 이내로 규정하고 있으며, 연간(12월) 재무 사항 보고는 대상 기간의 경과 후 90일로 규정하고 있다. 이러한 실무적·제도적인 사유로 재무성과는 공시 대상 기간의 종료일로부터 상당 기간이 지난 후에 공시된다.

만약 예측을 통하여 재무성과의 실제 공시일보다 더 빠르게 재무성과를 확인할 수 있다면 은행, 정부와 같은 정보 이용자는 기업의 부실 등을 더욱 빠르게 포착하여 부실이 악화되기 전에 신속하게 대응하여 경제적·사회적 손실을 최소화할 수 있다. 즉, 재무성과 예측은 경제 주체들이 효과적으로 신속하게 의사결정을 할 수 있도록 큰 도움을 줄 수 있다.

이에 본 연구에서는 다양한 재무성과 중 분기별 매출액과 영업이익을 예측 대상으로 선정하였으며 각각의 선정 이유는 다음과 같다.

매출액은 동질적이고 지속성이 높은 요인들로 구성되어 있기에 일반적으로 중요한 재무성과 요소로 간주된다[1]. 또한 매출액은 조작이 어렵고 조작을 위한 많은 자원이 필요하기에 다른 재무성과 요소 대비 신뢰성이 높은 특징을 갖고 있기에[2] 예측 대상으로 선정하였다.

영업이익은 순이익, 포괄이익과 비교했을 때 더 많은 정보를 담고 있기에 투자자들이 영업이익에 더 큰 가치를 부여하고 있다[3]. 또한 영업이익은 다른 재무성과 대비 기업의 수익성 측정에 적합함을 보여주는 특징을 갖고 있기에[4] 매출액과 함께 예측 대상 재무성과로 선정하였다.

아울러, 일반적으로 개별 기업의 재무성과는 경제환경과 같은 외부요인 외에 기업 내부요인의 영향으로 산업군 단위의 재무성과보다 변동성이 높게 나타나며 이는 예측 가능성에 부정적인 영향을 미친다. 이에 FnGuide

에서 정의한 FICS(FnGuide Industry Classification) 7개 산업군(소재, 에너지, 경기소비재, 필수소비재, IT, 의료, 산업재) 기준을 준용하여 산업군 단위 수준의 매출액과 영업이익을 예측 목표인 종속변수로 설정하였다. 종속변수 데이터는 한국예탁결제원 증권정보 포털(SEIBro)에서 제공하는 2008년 1분기부터 2023년 2분기까지의 62개 분기별 FICS 산업군 매출액, 영업이익 데이터를 활용하였다.

II. 본론

적시성 있는 분기별 재무성과 예측을 위하여 일별 또는 월별 기준으로 데이터가 갱신되는 무역통계 데이터와 금융지표 데이터를 예측 모델의 독립변수로 설정하였다.

분기별 무역통계 데이터는 해당 분기 종료일로부터 약 2주 이내에 확인이 가능하다. 또한 한국의 국내총생산에서 수출이 차지하는 비중이 크기에 무역통계는 데이터는 기업 재무성과 예측에 강점이 있다. 분기별 금융지표 데이터는 해당 분기 종료 즉시 확인이 가능하며 기업에 영향을 미치는 경제 환경을 반영하기에 기업 재무성과와 높은 연관성이 있다.

반면에 분기별 재무성과는 해당 분기 종료일로부터 최소 한 달 이후 공시되므로 본 연구에서 제시하는 예측 모델을 통해 현재보다 최소 2주 이상 빠르게 재무성과를 확인할 수 있다.

그러나 주요 독립변수인 무역통계 데이터는 산업군이 아닌 수출품목의 HS(Harmonized System) CODE 기준으로 작성된다. HS CODE는 국가 간 원활한 무역 거래를 위하여 WTO에서 채택한 국제 통일 상품 분류체계로 수출입 품목에 표준화된 번호(HS CODE)를 부여함으로써 통관 등 다양한 목적으로 사용된다. 즉, 라면의 수출입 데이터 확인은 라면의 HS CODE(19-02-30) 조회를 통해 확인할 수 있다. 이와 같이 무역통계 데이터는 HS CODE 기준 데이터이므로 본 연구 목적에 활용하기 위하여 HS CODE를 산업군 단위로 재분류해야 한다.

2.1 FICS 산업군별 무역통계 데이터

HS CODE를 FICS 7개 산업군으로 재분류하기 위하여 대규모 텍스트를 학습한 거대 언어모델인 ChatGPT API(gpt-3.5-turbo)에 아래와 같은 질문을 제시하여 HS CODE별 산업군 분류를 진행하였다.

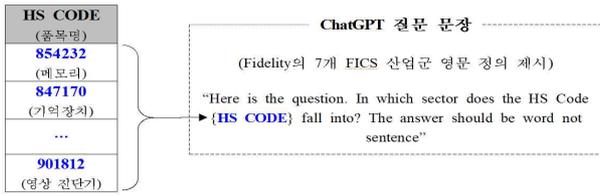


Fig 1.ChatGPT 문답형식 구성

ChatGPT에 2008년 1분기부터 2023년 2분기까지 K-stat 무역통계에 집계된 5,728개 HS CODE의 산업군 분류를 질문한 결과 ChatGPT는 HS CODE 5,377개를 7개 FICS 산업군으로 분류하고 351개를 FICS 산업군으로 분류하지 못했다. 351개의 미분류 HS CODE는 FICS 산업군으로 분류된 HS CODE 중 미분류 HS CODE와 류(Chapter)가 같은 품목에서 분류빈도가 가장 높은 산업군으로 재분류하였다. 대표적으로 HS CODE 89-01-20(탱커)은 ChatGPT에서 미분류 HS CODE였으나, ChatGPT가 분류한 89류 품목 대부분이 산업재였기에 산업재로 재분류하였다.

이 같은 재분류를 통해 산업군별 무역통계 데이터(미화 수출금액, 원화 수출금액, 수출증량, 수출단가)를 분기 단위로 구성하였다.

2.2 공통 금융지표 데이터

금융지표는 일반적으로 경제전망에 활용되는 6개 지표(원 달러 환율, 구리/금 비율, 미국채 10년물-2년물 금리차, 미국채10년물-3개월물 금리차, 미국PMI, 중국PMI)를 산업군 구분 없이 공통 독립변수로 사용하였다.

Bloomberg, Federal Reserve Economic Data, yfinance, 서울 외환증개를 통해 수집이 가능한 6개 지표들은 분기 단위가 아닌 일별, 월별 단위 데이터이므로 분기별 매출액, 영업이익 예측에 활용하기 위하여 각 지표 데이터를 2008년 1분기부터 2023년 2분기까지 수집한 분기별 평균값으로 변환하여 독립변수로 사용하였다.

2.3 데이터 구조 및 예측모델

2.1절 및 2.2절을 통하여 7개 산업군별 재무성과 예측모델에 활용하기 위한 데이터 테이블을 아래와 같이 구성하였다.

Fig 2. 데이터 구조

산업군별로 전체 62개 데이터의 80%인 49개 데이터를 훈련 세트와 활용하고 20%인 13개 데이터를 테스트 세트와 활용하여 모델의 성능을 검증하였으며, 무작위로 데이터를 분할하였다.

일반적으로 금융분야 회귀모델에서 주로 활용된 DNN(Deep Neural Network), 트리기반 모델인 RandomForest, GBM(Gradient Boosting

Machine), XGBoost(eXtreme Gradient Boosting)를 각 산업군별 최적 예측 모델로 후보군으로 선정하였다. 후보군 모델의 성능 평가를 위하여 RMSE(Root Mean Square Error)를 성능지표로 활용하여 가장 낮은 RMSE 모델을 최적의 모델로 선정하였다. 또한 최적 모델을 통한 산업군별 예측 성능 비교를 위하여 보조 성능지표인 NRMSE(Normalized RMSE)를 통해 재무성과 스케일이 다른 산업간 모델 성능을 비교하였다.

III. 결론

실제 공시일보다 빠르게 재무성과 예측이 가능한 산업군별 최적 재무성과 예측 모델은 아래와 같으며, 최적 모델은 RMSE 기준으로 선정하였다.

Table1 산업군별 최적 매출액 예측 모델 및 오차

산업군	최적모델	NRMSE	RMSE
소제	GBM	0.0604	31,450
에너지	GBM	0.0655	59,166
경기소비재	RandomForest	0.0743	115,460
필수소비재	GBM	0.0768	29,371
IT	GBM	0.0877	106,271
의료	DNN	0.1264	16,244
산업재	GBM	0.1410	164,944

Table2 산업군별 최적 영업이익 예측 모델 및 오차

산업군	최적모델	NRMSE	RMSE
소제	XGBoost	0.1135	28,883
에너지	RandomForest	0.1257	10,628
경기소비재	DNN	0.1574	3,380
필수소비재	DNN	0.1965	23,247
IT	GBM	0.2118	15,650
의료	GBM	0.2130	3,864
산업재	GBM	0.2314	33,930

GBM은 매출액과 영업이익 예측에서 전반적으로 뛰어난 성능을 발휘하며 대부분의 산업군에서 최적 모델로 선정되었다. 특히 IT, 산업재 산업군은 매출액, 영업이익 예측 모두 GBM이 가장 높은 성능을 발휘하였다.

또한 전반적으로 매출액 NRMSE가 영업이익 NRMSE보다 낮게 나타났다. 이러한 결과는 매출액 예측 모델의 성능이 영업이익 예측 모델 성능보다 높다는 것을 의미한다. 이는 서론에서 설명한 바와 같이 매출액이 영업이익보다 동질적이고 지속성이 높은 요인들로 구성되어 있기에 예측 가능성이 높기 때문이다.

참고 문헌

- Jegadeesh, Narasimhan, and Joshua Livnat. "Revenue surprises and stock returns." Journal of Accounting and Economics 41.1-2 (2006): 147-171.
- Ertimur, Yonca, Joshua Livnat, and Minna Martikainen. "Differential market reactions to revenue and expense surprises." Review of Accounting Studies 8 (2003): 185-211.
- Cheng, CS Agnes, Joseph K. Cheung, and V. Gopalakrishnan. "On the usefulness of operating income, net income and comprehensive income in explaining security returns." Accounting and Business Research 23.91 (1993): 195.
- Chen, Shimin, and James L. Dodd. "Operating income, residual income and EVATM: Which metric is more value relevant?." Journal of managerial issues (2001): 65-86.