국민연금기금의 인공지능 활용에 관한 연구

김 장 호

경희대학교 공과대학
산업경영공학과, 빅데이터응용학과

국민연금기금의 인공지능 활용에 관한 연구

인공지능과 기계학습 기술이 발달하면서 금융산업 전반적으로 기술의 도입이 논의되고 있다. 인공지능은 기금운용을 위한 경제전망 분석, 기업 및 시장 조사, 업무 자동화 등에 적용이 가능하며, 다양한 대안적 데이터도 활용할 수 있다. 이러한 변화는 국민연금기금의 운용에도 변화를 가져올 수 있다. 특히, 국민연금기금은 데이터분석 중심의 정량적 투자방식으로 기금운용 방식이 변화하고, 패시브 투자가 증가하고 있으며, 연기금 규모 증가로 효율적인 운용이 필요한 시점이다. 따라서 본 보고서는 인공지능의 기술 성숙도와 발전 방향을 분석하고, 기계학습 기법을 활용한 국내외 금융기관의 투자 분석 사례를 조사 및 검토한다. 또한, 국민연금기금의 발전을 위해 인공지능과 기계학습 기법 활용 방안과 도입 단계도 살펴본다.

목차

I. 서론 6
1. 연구배경과 목적 6
2. 연구범위 7
II. 인공지능과 기계학습 적용 사례 8
1. 국내 현황 및 적용 사례 8
2. 해외 사례 10
2.1. 거시경제 전망 11
2.2. 주식시장 및 기업 분석 21
2.3. 펀드 관리 및 특성 분석 36
2.4. 그외 적용 사례 39
III. 인공지능과 기계학습 도입 및 활용 방안 40
1. 인공지능 및 기계학습 활용 방안 40
2. 인공지능 도입 단계 42
IV. 결론 48
참고 문헌 49

표 차례

[표 1] 해외 연구 요약 9
[표 2] 거시경제 전망 관련 연구 요약 10
[표 3] 실업률 예측 오차 (Hall, 2018) 12
[표 4] 실업률 변곡점 예측 오차 (단위: 개월) (Hall, 2018) 13
[표 5] 실업률(12개월 전망) 모델 변수 (Hall, 2018) 13
[표 6] 심층신경망 실업률 예측 결과 (Cook & Hall, 2017) 15
[표 7] 감성지수를 반영한 경제성장률 분석 결과 (Sharpe 외, 2017) 17
[표 8] 물가상승률 예측 오차 (Chakraborty & Joseph, 2017) 18
[표 9] 주식시장 및 기업 분석 관련 연구 22
[표 10] 감성지수와 다른 리스크 지수의 상관계수 (Nyman et al., 2018) 26
[표 11] 주식, 채권, 환율시장 감성의 상관계수 (Kolanovic & Krishnamachari, 2017) 27
[표 12] 텍스트 기반 감성 정보 (Zhao, 2018) 28
[표 13] 텍스트 기반 행동 시그널 (Zhao, 2018) 29
[표 14] 실적발표 분석에 사용된 주제 및 태그 (Zhao, 2020) 30
[표 15] 가중치가 반영된 감성 시그널 (Zhao, 2020) 31
[표 16] 트위터 시그널과 다른 요인의 상관계수 (Kolanovic & Krishnamachari, 2017) 32
[표 17] 이상탐지 기계학습 결과 비교 (Chakraborty & Joseph, 2017) 34
[표 18] 국민연금기금의 인공지능 도입 단계(안) 46

그림 차례

[그림 1] 실업률 순환 예측치 (top: 3개월 전망, bottom: 12개월 전망) (Hall, 2018) . 12
[그림 2] 실업률 순환기간 예측 결과 (Cook & Hall, 2017) 15
[그림 3] Greenbook(2005-2009년)의 긍정/부정 워드 클라우드 (Sharpe 외, 2017).... 16
[그림 4] Greenbook(1973-2009) 감성지수 (Sharpe 외, 2017)..... 16
[그림 5] 신문기사 분석을 통한 감성지수 (Shapiro 외, 2020) 19
[그림 6] 긍정적인 감성 쇼크의 영향 (Shapiro 외, 2020) 20
[그림 7] 변수 개수에 따른 기계학습 성과 비교 (Puglia and Tucker, 2020)..... 20
[그림 8] 감성지수와 주식 수익률의 관계 (Lam, 2018) 23
[그림 9] ICA 기법을 적용한 뉴스 요인 (Dimov, 2018) 23
[그림 10] 감성지수 비교 (Nyman et al., 2018) 24
[그림 11] Excitement/Anxiety 감성지수 (Nyman et al., 2018) 25
[그림 12] 감성 쇼크에 의한 시장 영향 (Nyman et al., 2018) 26
[그림 13] 미국 국채 감성지수 (Kolanovic & Krishnamachari, 2017) 27
[그림 14] 감성 및 행동 시그널의 수익률 설명력 (Zhao, 2018) 29
[그림 15] 트위터를 활용한 S&P 500 지수 시그널 (Kolanovic & Krishnamachari, 2017) 32
[그림 16] ESG 데이터를 활용한 주가 분석 결과 (Bloomberg Quant Research, 2020) 33
[그림 17] 기계학습 기법 결과(AUC) 비교 (Pike, Sapriza, & Zimmermann, 2019)... 34
[그림 18] 스타트업 클러스터링 결과 (초록색: 성공 기업, 빨간색: 성공 클러스터) (Chakraborty & Joseph, 2017) 35
[그림 19] 심층신경망의 입력값과 출력값 (Sasaki et al., 2018) 37
[그림 20] 심층신경망 구조 (Tajiri, Sasaki, and Kitano, 2019) 37
[그림 21] 펀드 분석 결과 예시 (Sasaki et al., 2018) 38
[그림 22] 펀드 유사도 분석 결과 예시 (Tajiri, Sasaki, and Kitano, 2019) 39

I. 서론

1. 연구배경과 목적

인공지능(Artificial intelligence)과 기계학습(Machine learning) 기술이 발달하면서 금융산업 전반적으로 기술의 도입이 논의되고 있으며, 금융기관의 기금운용 전반에 걸쳐 인공지능을 단계적으로 접목시키기 위한 노력을 기울이고 있다. 특히, 기금운용을 위한 경제전망 분석, 기업 및 시장 조사, 업무 자동화 등에 적용이 되고 있으며, 경제지표와 금융시장 데이터 뿐만 아니라 다양한 대안적 데이터(Alternative data)가 활용된다.

이러한 변화는 국민연금기금의 운용에도 변화를 가져올 수 있다. 국민연금기금은 정성적 분석에 기반을 둔 투자방식에서 데이터분석 중심의 정량적 투자방식으로 기금운용 방식이 변화하고 있으며, 특히 향후에는 액티브 투자 중심에서 패시브 투자로 투자 패러다임의 변화가 예상된다. 한편, 국민연금기금 규모가 향후 급격히 증가할 것으로 예상되는 상황에서 기금을 운용하는데 있어 운용의 효율화에 대한 고민이 필요하다. 인공지능 기반 투자가 이러한 고민을 일부 해소시켜 줄 것이라 기대되며, 따라서 널리 확산되고 있는 인공지능 기반 투자분석 방법을 국민연금기금 운용에 활용할 수 있는 로드맵을 검토할 시점이다.

따라서 본 보고서는 인공지능의 기술 성숙도와 발전 방향을 분석하고, 기계학습 기법을 활용한 금융기관의 투자 분석 사례를 조사 및 검토한다. 또한, 국민연금기금의 발전을 위해 인공지능과 기계학습 기법 활용 방안과 도입 단계도 살펴본다. 인공지능 현황 및 발전 방향을 파악하고 국민연금기금의 인공지능 적용방안을 검토함으로써, 국민연금기금의 인공지능 활용에 대한 시사점을 제공하고 도입 방식 논의에 기여할 것으로 기대한다.

2. 연구범위

본 보고서는 국민연금기금 관점에서 최근의 인공지능 기술 발전 방향과 국민연금기금의 운용 프로세스를 고려한 분석을 진행한다. 전 세계적으로 진행되고 있는 인공지능 및 기계학습 기법 연구를 분석하여 현재 기술 수준과 적용 사례를 포괄적으로 조사한다. 또한, 금융기관의 인공지능 활용 사례 및 최신 인공지능 연구를 토대로 인공지능 기술 활용을 위한 국민연금기금의 도입 과정에 기여하는 목표를 갖고 있다.

보고서, 백서, 사례연구, 학술연구 등을 통해 인공지능의 활용 분야 및 현황을 파악하고, 기술 분석에 활용된 데이터와 기계학습 기법이 명시되어 있으며 실증분석 결과도 포함된 자료를 중점적으로 조사한다. 따라서, 기계학습의 적용 가능성을 확인하는 분석 자료 내용을 자세히 살펴본다. 국내보다 앞서 인공지능 기술을 도입한 해외 금융기관의 사례에 초점을 두며 단기적으로 적용 가능한 사례에 집중한다.

초과수익을 목표로 인공지능을 적용하는 전략이나 시스템매매에 인공지능 기법을 활용하는 예시도 찾아볼 수 있으나, 국민연금기금의 규모를 고려하면 도입 단계에 적합한 적용분야가 아니라고 판단되어, 경제, 시장 분석, 리스크 관리 등 연관성이 깊은 분석을 살펴보고 활용 방안을 논의한다.[1] 같은 이유로 핀테크 기업의 특정한 적용 사례보다는 중앙은행의 경제지표 분석 사례를 더 유심히 확인한다.

금융산업에 데이터분석 기법을 활용하는 사례는 많으나, 인공지능 기술의 도입보다는 기계학습 기술을 적용한 경우가 많다. 따라서, 본 보고서는 포괄적으로 기계학습을 적용한 사례까지 확장하여 조사를 진행하며, 국민연금기금의 인공지능과 기계학습 활용 방안에 대한 논의를 진행한다.

---

[1] AQR Capital Management (2019)는 최신 기계학습 기법으로도 주식 추천 또는 수익률 예측은 아직 한계가 있다고 보며 자산운용사에서 적용할 수 있는 단계가 아니라고 판단한다.

II. 인공지능과 기계학습 적용 사례

1. 국내 현황 및 적용 사례

국내 금융산업에 기계학습과 인공지능 기술의 도입 및 활용에 대한 논의는 많이 진행된 상태이다. 국내 금융기업의 인공지능 기술 활용 분야는 신용평가 및 리스크 관리, 이상거래탐지, 업무 자동화, 투자 분석으로 파악된다. 실제 도입된 사례를 살펴보면, 신용평가와 챗봇(Chatbot)에 적용된 경우가 많다. 신용평가 부문에서 인공지능 기술은 뉴스, 보고서, 소셜네트워크 정보 등의 비재무, 비금융 데이터를 활용한 개인 및 기업의 신용평가 또는 부도예측 모델에 활용되는 것이 대표적이다. 챗봇 부문에서 인공지능 기술은 자연어처리(Natural language processing) 기법의 고도화를 통한 다양한 비대면 고객 응대 서비스에 활용되는 것이 조사된다.

해외에서 적용되는 사례에 비해서 국내에는 활용되는 데이터 종류와 적용 분야가 넓지 않으며 아직 도입 단계에 있다고 할 수 있다. 글로벌 금융시장의 기술 성장 방향에 맞춰 최근 국내 금융투자 영역에서도 대안적 데이터와 인공지능을 활용한 투자 의사결정 지원 역량을 개발하거나 갖추려는 것으로 파악된다.

최근에는 한국은행 경제연구원에서 기계학습을 적용한 연구보고서를 발표하였다. 김수현 외 (2019)는 텍스트 분석을 통한 경제 분석 기술을 상세히 살펴보며 활용 방안을 논의하였다. Lee, Kim, and Park (2019)은 신문기사 텍스트 마이닝을 통해 통화정책 서프라이즈가 자산가격에 미치는 영향을 분석하였다. Kim (2020)은 경제 및 금융시장 데이터를 활용하여 딥러닝을 적용하는 분석의 가능성을 확인하였다. 빈도가 낮은 거시경제 데이터와 오차가 많은 금융시장 데이터의 특성을 반영하여 앙상블 학습(Ensemble learning)과 베이지안(Bayesian) 기법으로 통관기준수출액과 환율의 분석에 딥러닝을 활용하는 방법론을 제시한다. 이러한 연구를 통해 기계학습의 국내 시장 분석 활용 가능성을 확인할 수 있다.

[표 1] 해외 연구 요약

분류		기관명	저자(연도)
2.1. 거시경제 전망	2.1.1. 실업률	Federal Reserve Bank of Kansas City	Hall (2018) Cook & Hall (2017)
	2.1.2. 그외 경제지표	Federal Reserve Board	Sharpe, Sinha, & Hollrah (2017)
		Bank of England	Chakraborty & Joseph (2017)
	2.1.3. 경제상황 전망	Federal Reserve Bank of San Francisco	Shapiro, Sudhof, & Wilson (2020)
		Federal Reserve Board	Puglia & Tucker (2020)
2.2. 시장 및 기업 분석	2.2.1. 뉴스 데이터	Bloomberg	Lam (2018) Dimov (2018)
		J.P. Morgan	Kolanovic & Krishnamachari (2017)
		Bank of England	Nyman et al. (2018)
	2.2.2. 실적 발표 데이터	S&P Global	Zhao (2018) Zhao (2020)
	2.2.3. SNS 데이터	J.P. Morgan	Kolanovic & Krishnamachari (2017)
	2.2.4. ESG 데이터	Bloomberg	Bloomberg Quant Research (2020)
	2.2.5. 재무제표 정보	Federal Reserve Board	Pike, T., Sapriza, H., & Zimmermann, T. (2019)
		Bank of England	Chakraborty & Joseph (2017)
2.3. 펀드 관리 및 특성 분석		GPIF	Sasaki et al. (2018) Tajiri, Sasaki, & Kitano (2019)
2.4. 그외 적용 사례		Cao, L. (2019), Denev, A., & Amen, S. (2020), Eagle Alpha (2018), Kolanovic & Krishnamachari (2017),	

2. 해외 사례

인공지능과 기계학습에 해외 금융기관에 적용된 사례는 [표 1]처럼 거시경제 전망, 시장 및 기업 분석, 펀드 관리 및 특성 분석, 그리고 그외 적용 사례로 분류하여 생각할 수 있다. 참고 문헌을 기준으로 사례를 살펴보면, 주식 시장 및 기업 분석에 가장 다양하게 적용되었고 그 다음은 거시경제 전망에 적용된 것을 확인할 수 있다. 거시경제 전망은 학습에 사용되는 데이터 종류가 비슷한 경향을 보이고 있어서 모델의 예측 목표를 기준으로 세부분류할 수 있으며, 시장 및 기업에 관한 분석은 활용되는 데이터의 종류가 다양하여 데이터를 기준으로 세부분류하는게 가능하다.

[표 2] 거시경제 전망 관련 연구 요약

	경제지표	기관	분석 기법	저자(연도)
2.1.1. 실업률	실업률	Federal Reserve Bank of Kansas City	Elastic net	Hall (2018)
	실업률	Federal Reserve Bank of Kansas City	Deep neural networks (Feed-forward fully connected NN, CNN, LSTM, Encoder-decoder network)	Cook & Hall (2017)
2.1.2. 그외 경제지표	물가상승률	Bank of England	*k*-NN, Decision trees, Random forest, ANN, SVM	Chakraborty & Joseph (2017)
	실업률, 물가상승률, 경제성장률	Federal Reserve Board	Sentiment analysis (TF-IDF)	Sharpe, Sinha, & Hollrah (2017)
2.1.3. 경제전망	경제심리지수	Federal Reserve Bank of San Francisco	Bag-of-Words, TF-IDF, Lasso	Shapiro, Sudhof, & Wilson (2020)
	경기침체	Federal Reserve Board	ANN, SVM, Random forest, XGBoost, LightGBM	Puglia & Tucker (2020)

2.1. 거시경제 전망

기계학습 기반 거시경제 전망에 대한 분석은 실업률, 경제성장률, 물가상승률 등의 경제지표를 예측하는 분석이 큰 비중을 차지한다. 그리고 거시경제 모델링에 가장 많이 활용되는 자기회귀모델(Autoregressive model, AR) 또는 전문가 설문을 통한 전망치와 성과를 비교하는 것이 일반적인 분석 방법이다. 관련 연구는 [표 2]에 요약되어 있다. 중앙은행에서 여러 분석을 수행하는 것으로 파악되며, 적용되는 기계학습 기법도 다양한 것을 확인할 수 있다.[2]

2.1.1. 실업률

실업률은 대표적인 경제지표로써 금융정책에도 중요한 지표로 사용되며, 발표 이후 수정되는 경우가 적기 때문에 분석에 많이 활용된다(Cook & Hall, 2017). Hall (2018)은 Elastic net 회귀분석 기법으로 미국의 실업률에 대한 분석을 실시하였다. FRED(Federal Reserve Economic Data)에서 138개의 거시경제지표를 1959년부터 2017년까지 수집하여 분석을 진행하였고 1988년까지 데이터를 기본 학습에 사용하였다.[3] 실업률 전망에 대한 3개월부터 24개월까지 예측치까지 계산하여 정확도를 확인한 결과는 [표 3]과 같다. Elastic net 모델의 예측값 오차가 랜덤워크(Random walk)를 비롯하여 자기회귀모델과 설문기반 전망치(Blue Chip Economic Indicator) 보다도 낮은 것으로 나타났으며, 단기간부터 24개월 전망기간까지 모두 상대적으로 높은 정확도를 보였다. 12개월이상 전망치는 설문결과도 비교적 높은 것으로 나오나, Elastic net 기법의 단기간 정확도가 특히 의미있는 것으로 나타났다.

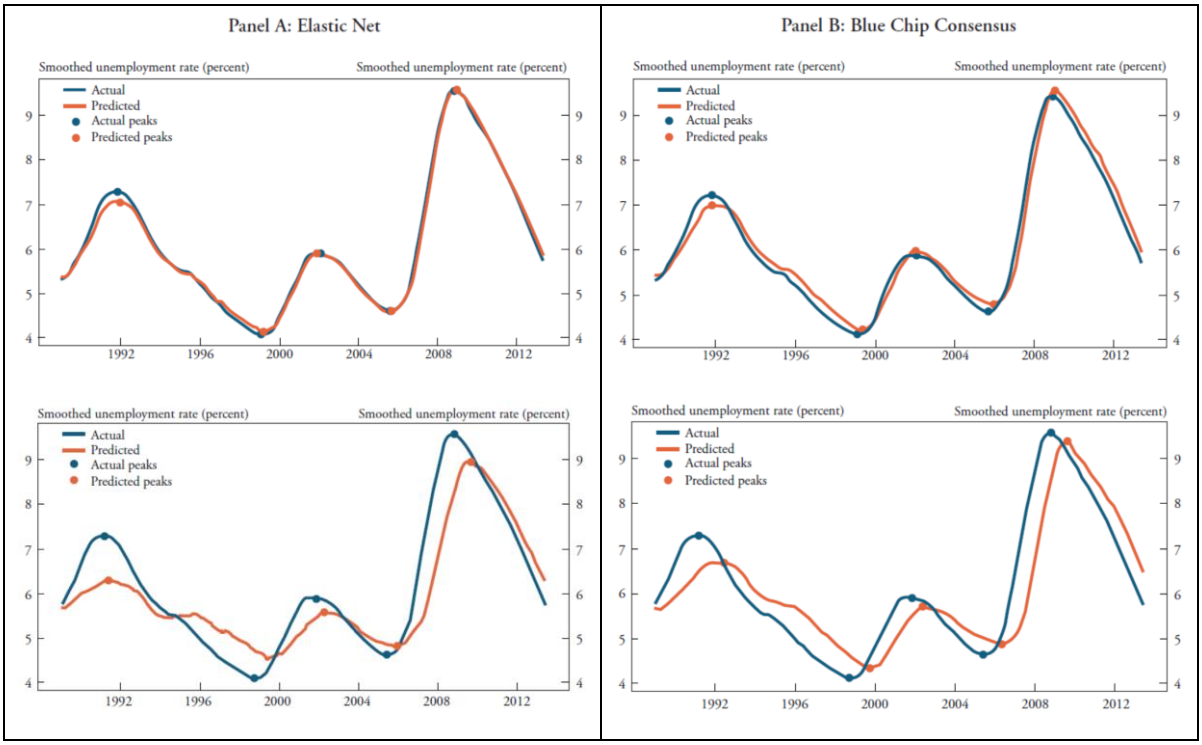
---

[2] Shapiro and Wilson (2019)은 텍스트 분석을 통한 물가 목표치 분석을 진행하였다.

[3] FRED는 세인트루이스 연방준비은행(Federal Reserve Bank of St. Louis)에서 관리하는 경제 데이터베이스이며 767,000이상의 시계열 데이터를 제공한다(https://fred.stlouisfed.org/).

[표 3] 실업률 예측 오차 (Hall, 2018)

Horizon (months)	Random walk (percent)	AR (percent)	Blue Chip (percent)	Elastic Net (percent)
3	0.35	0.23	0.26	0.17
6	0.53	0.38	0.39	0.27
9	0.79	0.58	0.52	0.42
12	1.00	0.82	0.65	0.58
15	1.22	1.04	0.76	0.74
18	1.49	1.30	0.92	0.88
21	1.69	1.55	–	1.02
24	1.91	1.78	–	1.20
Average	1.12	0.96	–	0.66



[그림 1] 실업률 순환 예측치 (top: 3개월 전망, bottom: 12개월 전망) (Hall, 2018)

[표 4] 실업률 변곡점 예측 오차 (단위: 개월) (Hall, 2018)

Horizon	Random walk	AR	Blue Chip	Elastic Net
3	6.2	4.0	4.2	0.6
6	8.4	6.0	7.0	1.4
9	10.8	8.8	9.2	4.0
12	15.8	10.8	11.8	6.4
15	17.8	12.8	14.0	7.0
18	18.6	13.4	12.8	8.8
21	20.8	14.2	–	7.0
24	19.8	13.8	–	10.0
Average	14.7	10.4	–	5.65

[표 5] 실업률(12개월 전망) 모델 변수 (Hall, 2018)

Description	Coefficient	Category
Consumer sentiment index	–0.015 (0.006)	Consumption, orders, and inventories
Help-wanted index for United States	–0.036 (0.016)	Labor market
New private housing permits, Northeast (SAAR)	–0.165 (0.082)	Housing
Six-month Treasury minus federal funds	–0.205 (0.065)	Interest and exchange rates
Three-month Treasury minus federal funds	–0.216 (0.060)	Interest and exchange rates
Average weekly hours: manufacturing	–0.237 (0.073)	Labor market
Civilian unemployment rate	0.590 (0.062)	Labor market

Note: Standard errors are in parentheses.

거시경제지표는 경기순환이 반영되는 것도 중요하기 때문에 [그림 1]과 같이 실업률 순환 예측 여부도 확인하였다. [표 4]는 모델에서 예측된 실업률의 고점·저점이 실제 실업률 순환의 고점·저점과 얼마나 차이가 발생하는지를 보여주고 있으며, 자기회귀모델이 설문보다 우월하지만 Elastic net이 경기순환도 가장 빠르게 인지하는 것으로 나타났다. Elastic net은 회귀분석에 정규화(regularization)가 추가된 기법이므로 유의미한 독립변수에 정보를 확인할 수 있다. 미국 실업률의

12개월 전망치는 [표 5]에 나타난 변수들이 유의미한 것으로 나타났다.

Cook and Hall (2017)은 실업률 예측을 위해 심층신경망(Deep neural network)을 중점적으로 분석하였다. 기계학습 기법은 Feed-forward fully connected neural network, Convolutional Neural Network(CNN), Long short term memory (LSTM), Encoder-decoder network을 사용하여 시계열분석에 적합한 신경망까지 분석을 진행하였다. 미국의 실업률 예측을 위해 과거 실업률 시계열 정보를 사용하였으며, 과거 36개월 실업률 데이터와 1차, 2차 차분까지 입력층으로 구성하여 모델을 학습하였다.[4] 여러 변수를 추가하여 모델을 설계하는 것이 가능하지만, 실업률의 시계열 데이터만으로 신경망의 학습효과를 확인하기 위하여 비교적 간단한 모델을 사용하여 가능성을 파악하는 것을 목표로 설정하였다. 1963년부터 2014년 실업률 데이터 중 1996년까지 데이터로 기본 학습을 진행하였고, 0부터 12개월 예측치까지 계산하였다.

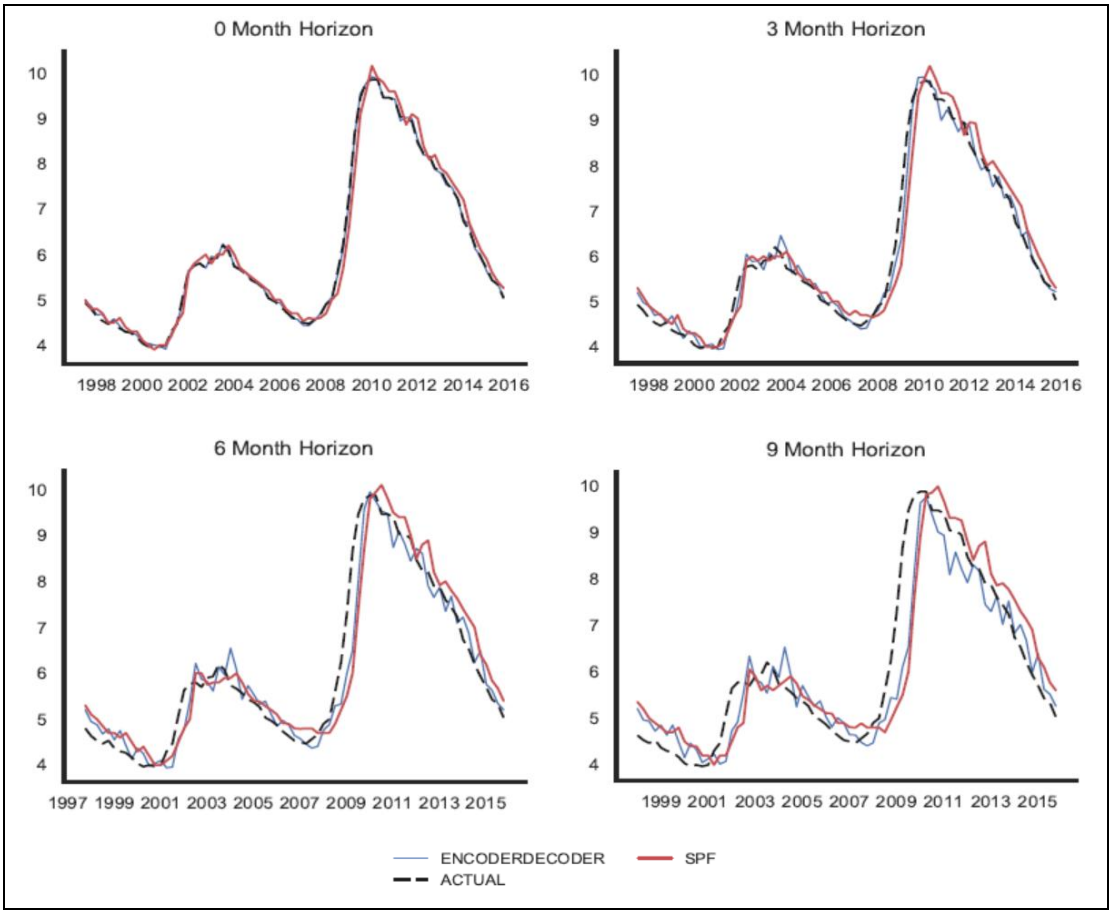
[표 6]의 결과를 보면, CNN과 LSTM의 9개월이상 전망을 제외하고는 신경망 모델이 자기회귀모델(AR) 보다 비교적 낮은 오차를 보여주고 있다. 설문을 통한 예측(Survey of Professional Forecasters, SPF)까지 고려해도 Encoder-decoder 기법은 모든 분석 기간에서 예측이 더 정확한 것으로 보였다.[5] 실업률의 변곡점을 확인한 결과도 [그림 2]와 같이 Encoder-decoder 기법이 설문예측보다 고점과 저점을 더 빠르게 인지하는 것으로 보여졌다.

[4] Data source: US Bureau of Labor and Statistics (Civilian unemployment rate, UNRATE)

[5] Survey of Professional Forecasters는 Federal Reserve Bank of Philadelphia에서 분기마다 발표되는 거시경제 예측치이며, 1968년부터 진행된 가장 오래된 경제지표 설문 예측이다. (https://www.philadelphiafed.org/surveys-and-data/real-time-data-research/survey-of-professional-forecasters)

[표 6] 심층신경망 실업률 예측 결과 (Cook & Hall, 2017)

Horizon		Fully Connected	CONV	LSTM	Encoder Decoder	AR	SPF
0 Months	Mean MAE	7.6	13.4	10.4	4.4	11.7	13.5
	St. Dev.	2.7	5.4	05.8	0.2		6.3
3 Months	Mean MAE	25.3	25.7	27.3	18.4	32.8	27.1
	St. Dev.	2.9	3.5	2.8	0.1		9.3
6 Months	Mean MAE	44.1	48.3	47.3	30.5	49.3	41.2
	St. Dev.	4.1	3.1	6.6	0.5		15.7
9 Months	Mean MAE	63.8	80.4	74.8	46.1	65.8	56.8
	St. Dev.	4.8	4.7	11.0	0.7		22.8
12 Months	Mean MAE	87.0	111.6	101.7	62.0	90.7	72.0
	St. Dev.	4.9	5.7	20.7	0.6		29.1



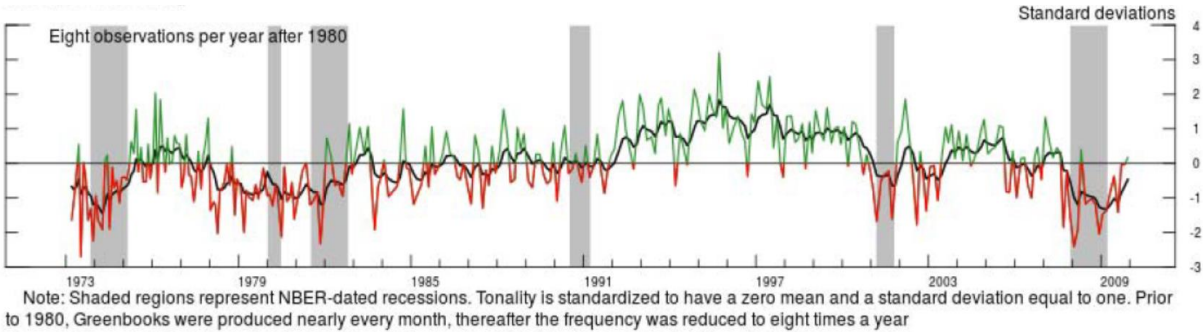
[그림 2] 실업률 순환기간 예측 결과 (Cook & Hall, 2017)

2.1.2. 그외 경제지표

Sharpe, Sinha, and Hollrah (2017)는 경제시장 분석을 위해 텍스트 마이닝을 통한 감성분석(Sentiment analysis)까지 포함하였다. 미국 연방공개시장위원회(FOMC) 회의 이전에 발표되는 연방준비제도이사회(Federal Reserve Board)의 Greenbook으로 감성분석을 진행하여 전망에 긍정 또는 부정적인 감성을 시장 예측에 반영하였다. 금융위기가 포함된 2005년부터 2009년까지 기간에는 [그림 3]의 워드클라우드(Word cloud)처럼 긍정 및 부정 단어가 관측되었다. 1973년부터 2009년까지 분석된 결과는 [그림 4]에 포함되어 있으며, 지수가중이동평균 (Exponential weighted moving average)을 보면 경기순환이 반영되는 것을 확인할 수 있다.



[그림 3] Greenbook(2005-2009년)의 긍정/부정 워드 클라우드 (Sharpe 외, 2017)



[그림 4] Greenbook(1973-2009) 감성지수 (Sharpe 외, 2017)

도출된 감성지수가 경제 예측에 유의미한지를 확인하여 위하여 Greenbook에 명시되어 있는 전망치와 비교하여 Greenbook의 감성지수가 추가 설명력이 있는지를 회귀분석을 통해 확인하였다. 감성지수(Tonality)를 지수가중이동평균을 사용한 트랜드(Trend tonality)와 그 오차(Tonality shock)로 분류하여 분석을 진행한 결과, [표 7]처럼 단기예측보다는 2분기 또는 4분기 전망에 유의미한 결과가 확인되었다. 비슷한 분석을 통해 Greenbook의 감성 정보를 실업률 예측에도 활용할 수 있다고 보였다.

[표 7] 감성지수를 반영한 경제성장률 분석 결과 (Sharpe 외, 2017)

Quarters Ahead	1	2	4	1	2	4	1	2	4
Panel B. 1990-2009									
Staff Forecast	0.95***	0.92***	0.76***	0.86***	0.79***	0.60***	0.83***	0.74***	0.56***
	(0.14)	(0.16)	(0.22)	(0.13)	(0.14)	(0.17)	(0.13)	(0.13)	(0.18)
Tonality				0.16**	0.31***	0.71***			
				(0.08)	(0.12)	(0.26)			
Trend Tonality							0.24	0.54**	1.22***
							(0.15)	(0.26)	(0.47)
Tonality Shock							0.08	0.07	0.09
							(0.08)	(0.12)	(0.20)
Intercept	0.24	0.33	0.91	0.28	0.45	1.18	0.28	0.47	1.12
	(0.21)	(0.39)	(0.99)	(0.20)	(0.34)	(0.76)	(0.20)	(0.33)	(0.74)
P(Forecast = 1)	0.701	0.606	0.274	0.292	0.130	0.021	0.189	0.052	0.013
Observations	154	154	154	154	154	154	154	154	154
Adjusted R^2	0.53	0.45	0.25	0.55	0.49	0.36	0.55	0.50	0.41
Residual Std. Error	0.74	1.06	1.80	0.73	1.02	1.67	0.73	1.01	1.60

Chakraborty and Joseph (2017)는 영국의 물가상승률 2년 전망치에 대한 분석을 진행하였다. 중기 전망을 학습하기 위하여 1988년부터 2015년까지 13개 거시경제지표 분기별 데이터를 사용하였다.[6] 물가상승률 모델링을 위해 *k*-NN, Decision trees, Random forest, Deep feed-forward artificial neural network (dFFANN), Support vector machine (SVM) 기계학습 기법을 비교하였고, 글로벌 금융위기

[6] Data source: Bank of England Statistical Interactive Database, Office for National Statistics, Bank for International Settlements, World Bank

전후의 변화도 확인하였다. 분석 결과가 정리된 [표 8]을 보면 심층신경망(dFFANN)과 SVM이 금융위기 이전에 가장 정확도가 높으며, 두 모형의 조합을 사용하면 전체기간 가장 좋은 예측결과를 보였다. 이는 기존 경제분석에 대표적으로 활용되는 자기회귀모델(AR), 벡터자기회귀모델(VAR)보다 더 정확한 것으로 결과가 나타났다.

[표 8] 물가상승률 예측 오차 (Chakraborty & Joseph, 2017)

	testing (full period)			testing (pre-crisis)			testing (post-crisis)		
method	error	SD	corr.	error	SD	corr.	error	SD	corr.
k-NN	0.95	1.11	0.23	1.00	1.07	0.60	0.92	1.23	0.02
regression tree	0.90	1.20	0.16	0.97	1.03	0.60	0.84	1.44	-0.18
random forest	0.86	1.16	0.21	0.93	0.97	0.65	0.82	1.39	-0.12
dFFANN	0.97	1.76	0.39	0.59	0.76	0.87	1.23	1.80	0.44
SVM	0.78	1.33	0.16	0.47	0.84	0.73	1.01	1.17	-0.26
SVM-dFFANN	0.67	1.27	0.41	0.48	0.73	0.84	0.83	1.39	0.31

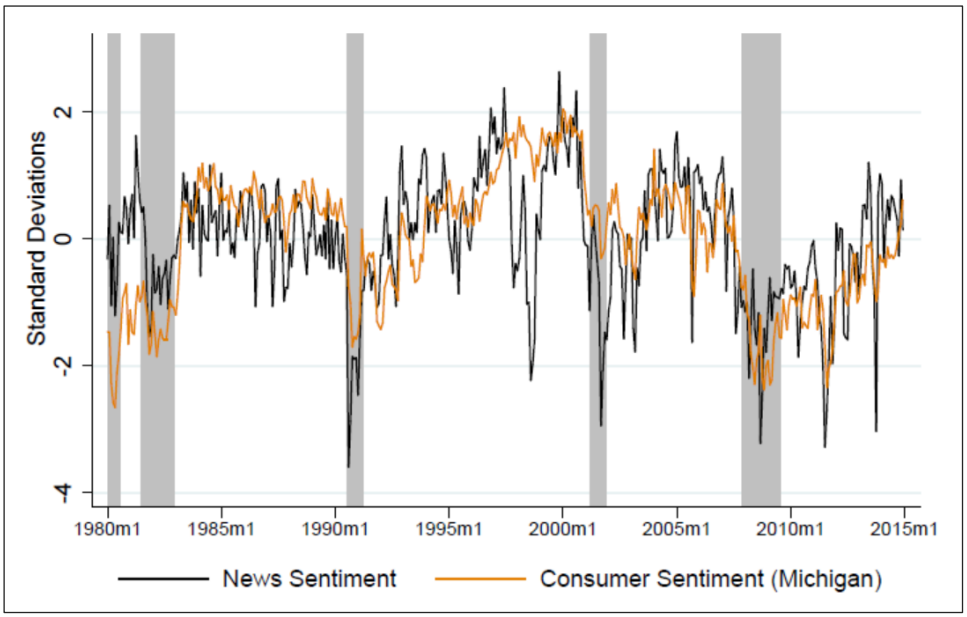
2.1.3. 경제 전망

Shapiro, Sudhof, and Wilson (2020)은 신문기사 감성분석을 통해 경제에 대한 전반적인 감성을 측정하는 분석을 진행하였다. 이를 위해 1980년부터 2015년까지 16개 언론사의 신문기사 238,685개를 수집하였다. 정확도를 비교하는 과정에서는 연구진이 직접 800개 기사의 감성 수준을 확인하여 검증에 활용하였다. 연구의 첫번째 단계에서는 여러 감성분석 기법을 비교하여 신문기사 분석에 활용하였고, 그 이후 단계에서는 경제지표를 예측하는데 활용할 수 있는지 확인하였다.

먼저, Bag-of-Words(BoW) 기법으로 신문기사를 분석하였다. 경제지 및 금융 관련 기사를 분석하는 경우, 여러 어휘사전을 통합하여 사용하면 특정 분야에 치중되어 있는 어휘사전의 제한성을 보완할 수 있으나, 영화후기처럼 연관이 적은 분야의 어휘사전은 추가되는 설명력이 적은 것으로 보여졌다. 추가로 문장 구조를 반영하는 분석도 진행하였고, 특히 부정어 포함여부는 감성 정확도를

높여주는 것으로 확인되었다.[7]

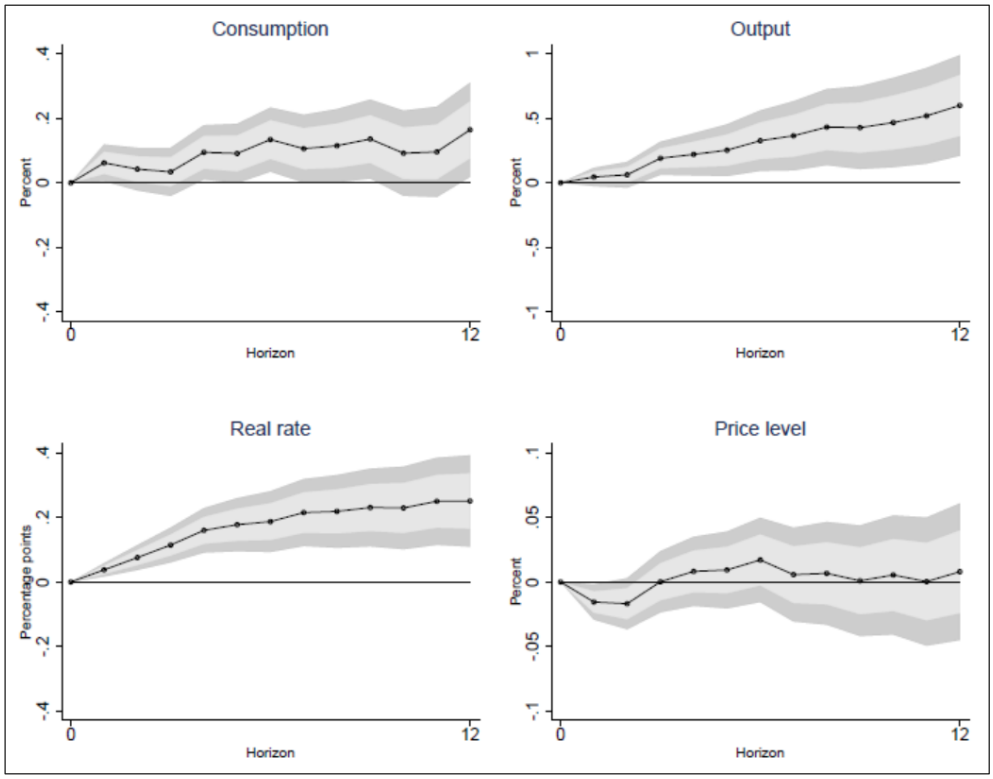
학습된 감성분석 모델을 통해 감성지수를 구성하면 [그림 5]와 같이 경기 불황이 반영되고 설문기반 예측과 높은 상관관계를 보인다.[8] 특히, 비교적 관측주기가 긴 설문에 비해 감성의 변화를 빠르게 포착할 수 있으며, 설문기반 전망을 예측할 수 있는 것도 확인하였다. 또한, 이러한 감성지수를 활용하면 감성 쇼크에 경제지표가 어떻게 반응하는지도 확인할 수 있음을 보였다. [그림 6]의 결과는 긍정적인 쇼크로 인해 소비, 생산은 상승하는 반면에 물가는 하락하는 경향을 확인할 수 있다. Lasso 회귀분석 기법으로 변수선택을 진행한 결과, 감성지수는 여러 경제지표를 설명하기 위한 유의미한 변수인 것으로 나타났기 때문에 감성과 경제지표의 관계가 더욱 중요하다는 것을 보였다.



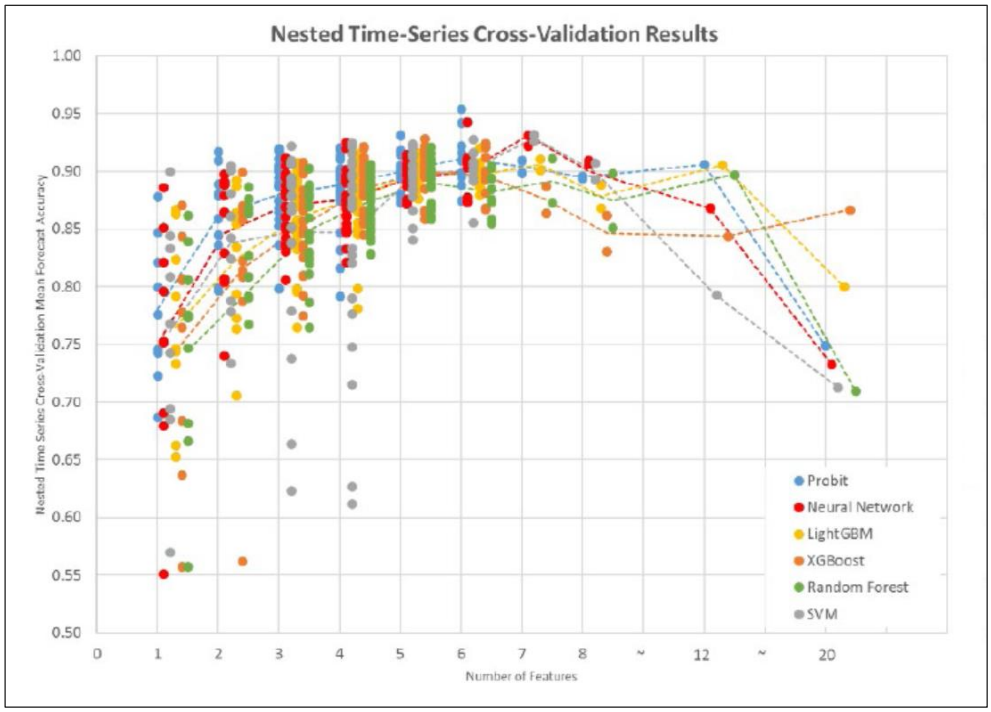
[그림 5] 신문기사 분석을 통한 감성지수 (Shapiro 외, 2020)

[7] GloVe(Global Vectors), BERT(Bidirectional Encoder Representations from Transformers) 기계학습 기법도 적용하였으나, 800개 기사만 사용했기 때문에 충분히 학습되지 않은 것으로 판단했다.

[8] Shapiro, Sudhof, and Wilson (2020)에서는 설문을 사용한 Michigan Consumer Sentiment Index와 Conference Board's Consumer Confidence Index와 비교하였다.



[그림 6] 긍정적인 감성 쇼크의 영향 (Shapiro 외, 2020)



[그림 7] 변수 개수에 따른 기계학습 성과 비교 (Puglia and Tucker, 2020)

Puglia and Tucker (2020)는 기계학습을 통해 경기침체를 모델링하는 분석을 진행하였다. 경제상황을 반영하는 수익률곡선 기울기, S&P 500 지수, 연방기금금리 등 9개 지표를 사용하여 ANN, SVM, Random forest, XGBoost, LightGBM 기법을 비교하였다. 시계열데이터 분석에 적합한 Nested cross-validation을 제안하여 1972년부터 2019년까지 월별 데이터로 분석을 진행한 결과, [그림 7]과 같이 설명변수를 추가하여도 8개 이상은 설명력 증가에 큰 영향이 없다는 것을 보였다. 그리고 기본적인 Cross-validation의 결과와 다르게 제안하는 Nested cross-validation을 사용하면 기계학습 기법보다 비교적 간단 Probit regression의 성과가 좋게 나왔으나, 더 많은 변수로 추가 분석을 진행해볼 필요가 있다고 언급하였다.

2.2. 주식시장 및 기업 분석

데이터 분석 기법의 발전과 더불어 다양한 데이터 수집이 가능해지면서 금융시장과 기업 분석에 대안적 데이터를 활용하는 사례가 증가하고 있다. 그 중에서도 텍스트 마이닝(Text mining)과 자연어처리기술(Natural language processing)로 감성분석(Sentiment analysis)을 적용하는 사례가 많은 것으로 조사된다. 텍스트 마이닝을 통한 분석은 기존의 가격 또는 지표 등 정형화되어 있는 데이터에서 추출할 수 없는 내재된 정보까지 반영이 가능하여 기존 방법론을 보완할 수 있다. 시장 및 기업 분석에 활용되는 다양한 데이터 종류에 중점을 두며 사례를 소개하기 위하여, 본 절에서는 [표 9]에 요약된 것 같이 뉴스, 실적발표, 소셜미디어, ESG, 재무제표 데이터로 세분화하여 관련 연구를 소개한다.

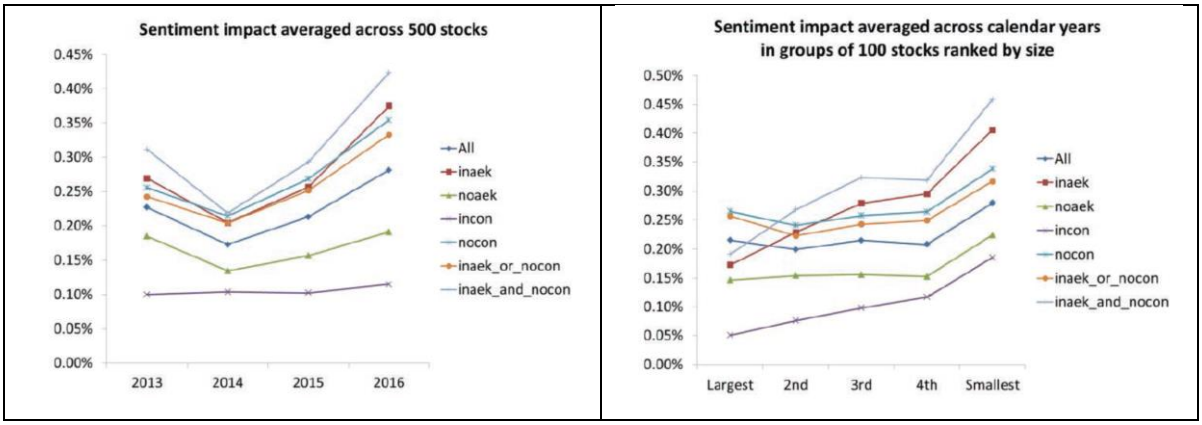
2.2.1. 뉴스 데이터

뉴스 데이터는 가장 대표적으로 활용되는 대안적 데이터이다. 뉴스 데이터는 웹크롤링(Web crawling)을 통해 뉴스 기사 정보를 수집하는 방법도 있으나, 최근에는 가공된 뉴스 데이터를 제공한 서비스도 증가하고 있다.

[표 9] 주식시장 및 기업 분석 관련 연구

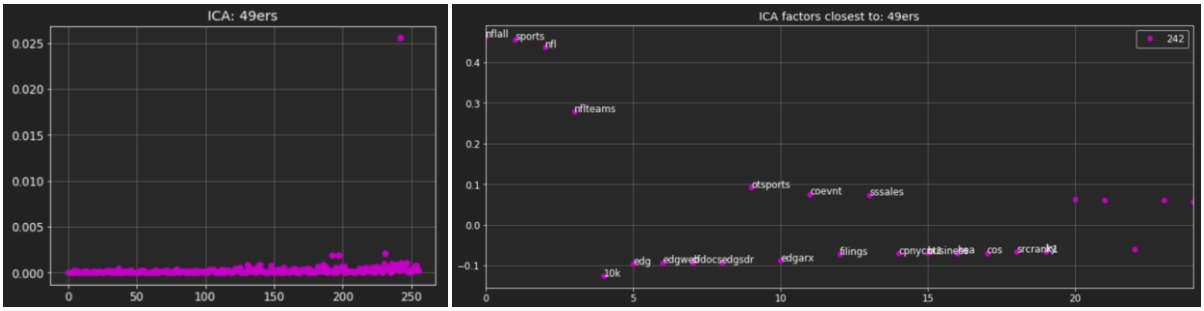
	기관	분석 기법	저자(연도)
2.2.1. 뉴스 데이터	Bloomberg	OLS Regression	Lam (2018)
	Bloomberg	LSA, ICA	Dimov (2018)
	Bank of England	Sentiment analysis (Bag-of-Words)	Nyman et al. (2018)
	J.P. Morgan	Sentiment analysis	Kolanovic & Krishnamachari (2017)
2.2.2. 실적발표 데이터	S&P Global	Sentiment analysis (BoW, TF-IDF)	Zhao (2018)
	S&P Global	Sentiment analysis (TF-IDF, Cosine similarity)	Zhao (2020)
2.2.3. SNS 데이터	J.P. Morgan	Sentiment analysis	Kolanovic & Krishnamachari (2017)
2.2.4. ESG 데이터	Bloomberg	Gradient boosting tree (xgboost)	Bloomberg Quant Research (2020)
2.2.5. 재무제표 정보	Federal Reserve Board	Logistic regression, Random forest, Gradient boosting trees, ANN, SVM	Pike, T., Sapriza, H., & Zimmermann, T. (2019)
	Bank of England	Naïve Bayes, *k*-NN, Decision trees, Random forest, ANN, SVM	Chakraborty & Joseph (2017)
	Bank of England	*k*-means clustering	Chakraborty & Joseph (2017)

Lam (2018)은 Bloomberg에서 제공하는 뉴스피드(Newsfeed) 데이터를 통한 감성분석이 주가와 어떠한 연관이 있는지 확인하였다. 첫번째 분석에서는 '주요 주식 뉴스(Key equity news)'와 '논란(Controversial)'이란 주제로 분류된 뉴스 정보로 일별 감성수치를 추출하고, OLS 회귀분석(OLS regression)을 통해 2013년부터 2016년까지 미국시장 500개 주식의 수익률과 감성점수의 관계를 분석하였다. [그림 8]에 요약된 결과를 보면 주식의 움직임은 주식 뉴스와 높은 연관성을 보이고 시가총액이 작은 기업일수록 높은 연관성이 있는 것으로 나타났다.



[그림 8] 감성지수와 주식 수익률의 관계 (Lam, 2018)

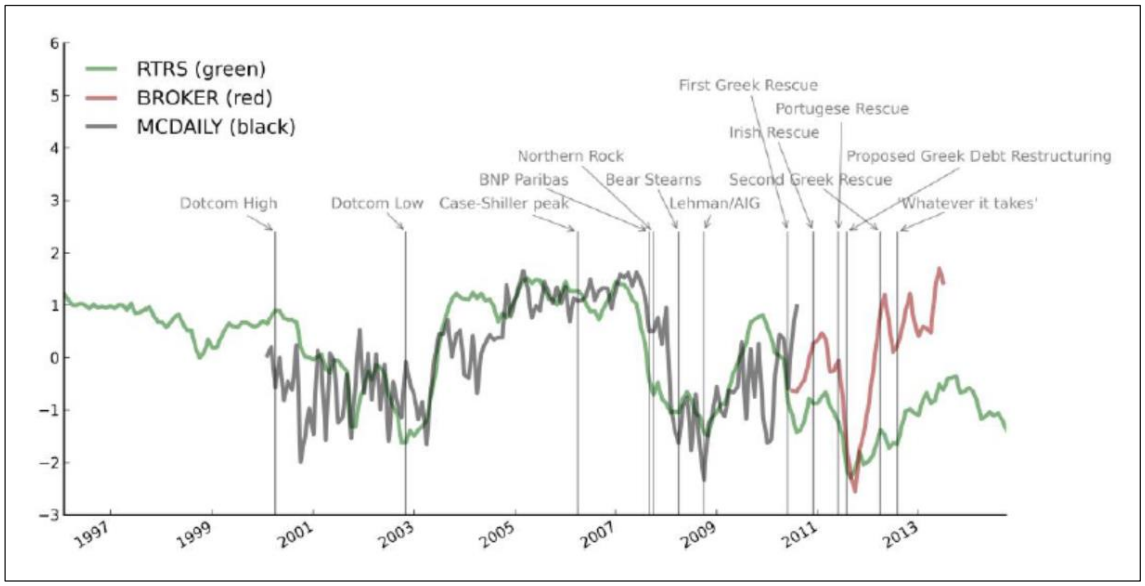
분석의 첫 단계에서는 두 가지 뉴스 주제만 사용하여 가능성을 확인해 보았으나, 블룸버그(Bloomberg) 뉴스 데이터는 수만개의 주제로 분류되어 있다. 따라서, 후속 연구에서는 방대한 뉴스 데이터에서 의미있는 정보를 추출하는 기법에 대한 분석을 추가로 진행하였다. 수만개의 주제를 모두 분석하는 것은 비효율적이므로, Dimov (2018)은 LSA(Latent semantic analysis)와 ICA(Independent component analysis) 기법을 사용하여 차원축소 과정을 통해 의미있는 뉴스 주제를 추출하였다. 수만개 뉴스 주제를 256개의 차원으로 70%정도가 설명 가능한 것으로 확인하였다. 분석 예시로 포함된 [그림 9]에서는 미국 NFL 미식축구팀 '49ers'의 기사가 256개 중 1개의 요인으로 대부분 설명이 가능하며, 그 요인은 운동 관련 주제들로 구성되어 있는 것을 알 수 있다.



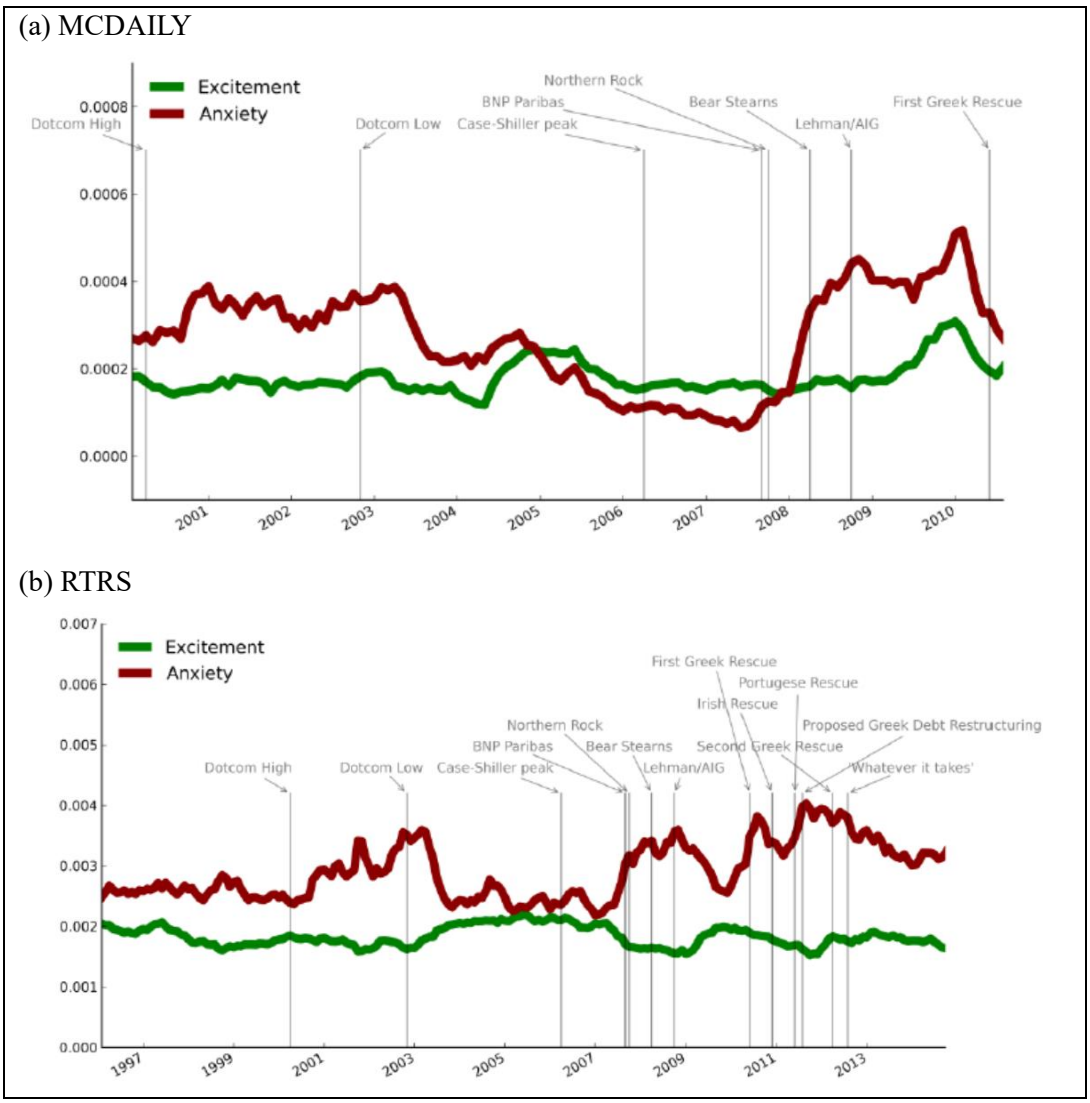
[그림 9] ICA 기법을 적용한 뉴스 요인 (Dimov, 2018)

Nyman 외 (2018)는 세 가지 데이터 종류를 활용하여 주식시장의 감성분석을 확인해보았다. 로이터(Reuter)의 뉴스 기사, 14개 증권사의 보고서, 뉴스 관련 영란은행(Bank of England)의 내부 자료를 비교 분석하였다. Bag-of-Words를 통한 분석으로 [그림 10]과 같이 감성지수를 계산할 수 있으며, 세 가지 데이터가 비슷한 감성 패턴을 보여주는 것을 확인할 수 있다. 그림에서 로이터 뉴스는 RTRS, 증권사 보고서는 BROKER, 영란은행 내부 자료는 MCDAILY로 표시되었다.

감성을 기대감(Excitement)과 불안감(Anxiety)로 나누게 되면, [그림 11]과 같이 시장에 대한 불안감이 변동성에 영향을 주는 것을 알 수 있다. 이는 뉴스 관련 내부 자료인 MCDAILY와 뉴스 데이터 RTRS의 결과 보두 비슷하게 불안감에 큰 변동성이 존재하고 감성지수에 반영된다.



[그림 10] 감성지수 비교 (Nyman et al., 2018)



[그림 11] Excitement/Anxiety 감성지수 (Nyman et al., 2018)

Nyman 외 (2018)에서 추출한 감성지수를 다른 지수들과 비교해보면 [표 10]과 같이 확인된다.[9] [표 10]에는 VIX지수, MCI지수(Michigan Consumer Sentiment Index)와의 상관계수가 포함되어 있으며, *t*시점의 감성지수 값은 두 지수의 *t*+1시점과 더 높은 상관계수를 보이고 있다. 즉, 감성분석을 통한 지수가 다른 시장지수보다 선행하는 움직임을 보인다고 할 수 있다. 그리고 감성지수의

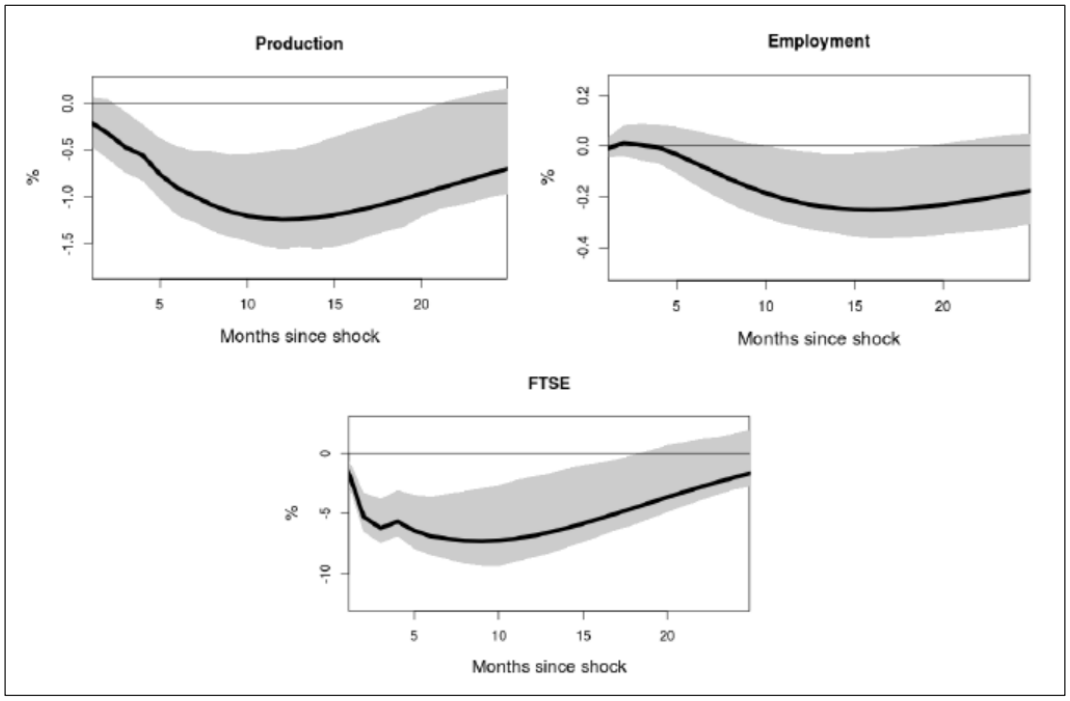
[9] Nyman 외 (2018)는 더 많은 지수와 비교하였고 인과관계(Granger causality test) 분석도 진행하였다.

설명력을 활용하면 시장 감성에 쇼크가 발생했을 때 경제와 금융시장이 어떻게 반응하는지도 살펴보는게 가능하다. [그림 12]에서는 감성에 부정적인 쇼크가 발생했을 때 경제지표와 주식시장 지수가 기간에 따라 어떤 영향을 받는지 보여주고 있다.

[표 10] 감성지수와 다른 리스크 지수의 상관계수 (Nyman et al., 2018)

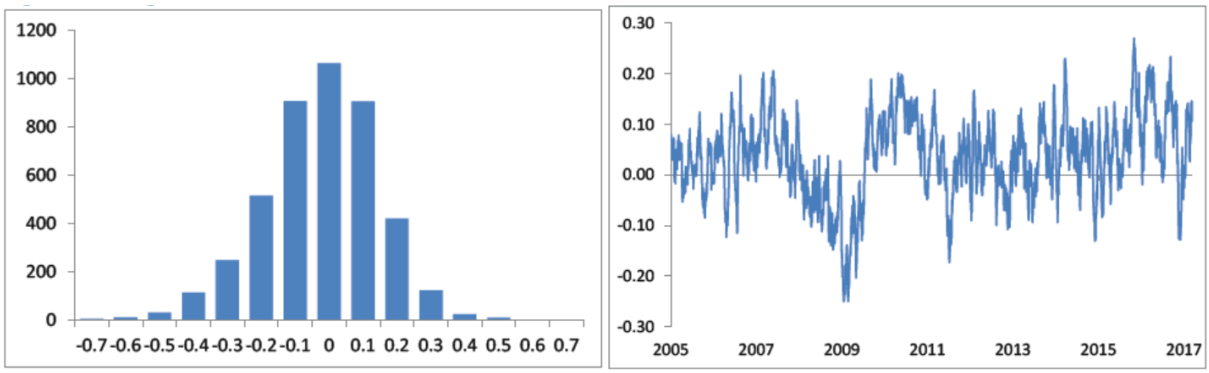
	MCD	RTRS	BRO	VIX(-1)	VIX	VIX(+1)	MCI(-1)	MCI	MCI(+1)
MCD	1	0.59	-	0.54	0.62	0.66	0.24	0.26	0.27
RTRS	-	1	0.71	0.23	0.37	0.40	0.49	0.54	0.58
BRO	-	-	1	0.34	0.60	0.68	0.34	0.66	0.87

MCI: Michigan Consumer Sentiment Index



[그림 12] 감성 쇼크에 의한 시장 영향 (Nyman et al., 2018)

JP 모건(JP Morgan) 인공지능 보고서는 뉴스 데이터의 감성분석을 통해 주식시장뿐만 아니라 국채, 환율, 상품시장 분석에도 활용할 수 있다는 것을 보였다(Kolanovic and Krishnamachari, 2017). RavenPack에서 제공하는 뉴스 기반 감성 데이터를 활용하여 감성지수를 구성하였다. [그림 13]은 국채의 감성지수 변화와 히스토그램을 보여주고 있고, [표 11]은 주식, 채권, 환율의 대표적인 리스크 요인과의 상관계수를 포함하고 있다. 감성 데이터로 구성된 요인은 다른 요인들과 낮은 상관관계를 보이므로 리스크분석에 충분히 활용될 수 있음을 보여주고 있다.



[그림 13] 미국 국채 감성지수 (Kolanovic & Krishnamachari, 2017)

[표 11] 주식, 채권, 환율시장 감성의 상관계수 (Kolanovic & Krishnamachari, 2017)

Risk Premia		1	2	3	4
Volatility - Equity	1				
Value - Equity	2	0.16			
MoM - Equity	3	0.02	0.14		
Carry - Equity	4	0.16	0.03	-0.16	
Sentiment - Equity	5	0.04	0.09	0.08	-0.04

Risk Premia		1	2	3	4
Volatility - Bond	1				
Value - Bond	2	-0.04			
MoM - Bond	3	0.00	0.63		
Carry - Bond	4	-0.04	0.49	0.44	
Sentiment - Bond	5	-0.03	0.04	0.03	0.10

Risk Premia		1	2	3	4
Volatility - FX	1				
Value - FX	2	-0.02			
MoM - FX	3	-0.06	-0.06		
Carry - FX	4	0.22	0.08	0.01	
Sentiment - FX	5	-0.03	-0.03	-0.02	-0.02

2.2.2. 실적 발표 데이터 (Earnings call transcript)

기존에는 실적 예측치 또는 발표되는 실적 정보를 투자관리에 반영하였으나, 기계학습 기법을 적용하면 비정형화 데이터를 수치화하여 사용하는게 가능해진다. S&P 글로벌(S&P Global)은 실적발표 회의 텍스트 기록을 학습하여 의사결정에 반영하는 분석을 진행하였다(Zhao, 2018, 2020).

Zhao (2018)는 실적발표 회의 기록을 분석하여 감성 정보와 행동 정보를 추출하여 기업의 전망에 반영하였다. 감성분석은 Bag-of-Words, TF-IDF(Term frequency-inverse document frequency) 기법을 적용하여 [표 12]과 같이 네 가지 수치를 측정하였으며, 이를 통해 감성수치, 전년동기대비 감성수치, 최근 실적발표 대비 감성수치의 변화를 시그널로 사용하였다. 또한, 행동 정보가 반영된 시그널을 [표 13]과 같이 추가로 세 가지를 구성하였다. 행동 정보는 실적 발표시 간단한 표현을 사용하여 명확하게 설명하거나 숫자를 많이 사용하는지를 측정한다. 마지막으로 기업전망을 긍정적으로 평가하는 애널리스트 선호도를 측정하여 분석에 반영하였다.

실적발표 이후 주가와 비교해보면 감성수치가 높을수록 더 상승하는 경향이 있고, 간단한 표현과 숫자를 많이 사용하는 행동 정보가 많이 관측될수록 상승한다는 것을 보였다. 질의응답 과정에서 보이는 감성이 중요한 요소이고 기업의 최고경영자의 감성이 가장 중요한 것으로 나타났다. 리스크관리 관점에서 더 중요한 분석 결과는 [그림 14]에 요약되어 있으며, 감성 시그널과 행동 시그널이 기존 리스크 요인(Beta, Size, Value, Momentum 등)이 설명하지 못하는 부분을 유의미한 수준에서 설명한다는 것이다. 비록 동일한 데이터로 감성과 행동 시그널을 추출하였으나, 서로 낮은 상관관계를 보여서 리스크 분석에 모두 활용하는 것이 효과적이다고 보였다.

[표 12] 텍스트 기반 감성 정보 (Zhao, 2018)

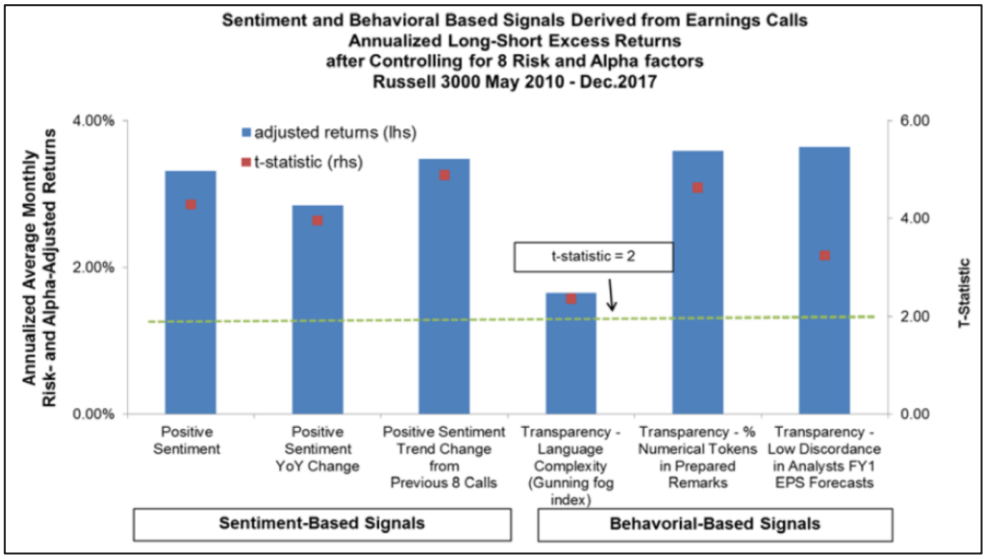
Signal	Construction	Sort Order	Intuition
Positivity	# positive words / # total words	D	The frequency of usage of positive words by executives in an earnings call may reveal their (true) sentiment about their firm's future prospects
Negativity	# negative words / # total words	A	Executives use negative words in an earnings call when compelled to fulfill legal or fiduciary obligations; the absence of negative words is viewed favorably in our narrative
Net Positivity	(# positive words - # negative words) / # total words	D	Takes into account both positive and negative words
Positivity to Negativity	# positive words / # negative words	D	Similar to net positivity but amplifies the magnitude of the difference between positive and negative word frequency

Note: D = descending sort; A = ascending sort

[표 13] 텍스트 기반 행동 시그널 (Zhao, 2018)

Signal	Construction	Sort Order
Transparency: Language Complexity	Gunning Fog Index = 100 * (average words per sentence + % of polysyllabic words in a call) where the polysyllabic cutoff is 3+ syllables	A
Transparency: Presenting Using More Numbers	Ratio = Numerical Tokens / Total Word Tokens	D
Transparency: Analyst Favoritism	% Difference = (A – B) / Abs(B) • A = average metric of analysts called on • B = average metric of analysts not called on • metric = {FY1 EPS estimate, price target, numerical stock recommendation}	A

Note: D = descending sort; A = ascending sort



[그림 14] 감성 및 행동 시그널의 수익률 설명력 (Zhao, 2018)

Zhao (2020)에서는 기존의 모델에 변수가공(Feature engineering) 기법을 적용하였다. 실적 관련 키워드를 사용하고 감성수치 계산에 사용되는 가중치를 보완하여 더욱 의미있는 결과를 도출하였다. 먼저, 도메인지식을 바탕으로 효과적인 기업실적 분석을 위해 [표 14]에 요약된 주제 키워드를 사용하여

실적발표 데이터를 분석하였다. 실적 관련 태그('Topic'), 실적 방향성을 나타내는 태그('Directional'), 전망 관련 태그('Guidance')에 중점을 두어 감성 시그널을 추출한다. 추가로 [표 15]처럼 TF-IDF 가중치를 통해 태그의 중요도를 측정하고, 전년 대비 낮은 코사인 유사도(Cosine similarity)를 나타내는 경우 높은 가중치를 부여하는 방법도 적용하여 더 정확한 분석이 가능함을 보였다.

[표 14] 실적발표 분석에 사용된 주제 및 태그 (Zhao, 2020)

Topic Category	Topic Tags
Revenue	{"sales", "revenue", 'top line', 'top bottom line', 'net revenue', 'organic revenue growth', 'organic sales growth', 'operational sales'}
Earnings	{"eps", "earnings", "earnings per share", "net income", "bottom line", "top bottom line"}
Profitability	{"margin", "gross margin", "operating margin", "return invested capital", "return capital"}

Directional Category	Directional Descriptor Tags
Positive Direction	{ "increase", "increased", "increases", "increasing", "increasingly", "expand", "expanded", "expanding", "expands", "expansion", "expansions", "grow", "grows", "grew", "growth", "growths", "improve", "improved", "improves", "improvement", "improvements", "strong", "stronger", "strongest", "strongly" }
Negative Direction	{"decline", "declined", "declines", declining", "deteriorate", "deteriorates", "deteriorated", "deteriorating", "compress", "compressed", "compresses", "compressing", "compressible", "compression", "reduce", "reduces", "reduced", "reducing", "reduction", "reductions", "weak", "weaker", "weakest", "weaken", "weakens", "weakened", "weakening", "weakness", "weaknesses"}

Guidance Category	Guidance Tags
Guidance	{"full year outlook", "full year expect", "guidance", "outlook", "forecast", "expect", "expects", "expected", "expecting", "expectation", "expectations"}

[표 15] 가중치가 반영된 감성 시그널 (Zhao, 2020)

Signal	Construction	Sort Order
TF-IDF Weighted Average Sentiment	Weighted Average = A/B or A - B • A = Call Level TF-IDF Positive Weighted Average Sentiment • B = Call Level TF-IDF Negative Weighted Average Sentiment	D

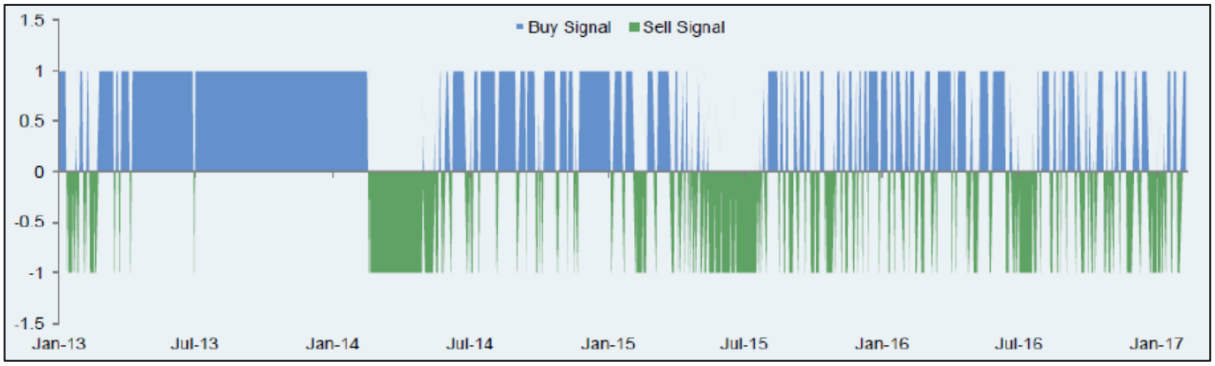
Signal	Construction	Sort Order
YoY Change in Simple Sentiment Average * Call Similarity (t, t-4)	Score = A / B • A = YoY change in simple sentiment average between call(t) and call(t-4) • B = Call similarity score between call(t) and call(t-4) where t = {earnings calls for firm i}	D

2.2.3. 소셜미디어 데이터 (SNS 데이터)

최근에 소셜미디어 데이터를 분석에 활용하는 예시도 증가하도 있다. 대표적으로 트위터(Twitter) 데이터 예시가 많고, 뉴스 데이터와 동일하게 직접 크롤링도 가능하지만 가공된 SNS 정보를 제공하는 데이터 제공자도 있다.

JP 모건(JP Morgan)은 인공지능 보고서에서 트위터 메시지 기반으로 제공되는 iSentium의 감성 데이터를 통한 주식시장 분석결과를 보여준다(Kolanovic and Krishnamachari, 2017). 미국 S&P 500 지수를 분석하기 위해 100개 기업의 트위터 데이터를 분석하였다. 감성분석을 통해 각 기업의 감성수치가 반영된 총 감성점수를 분단위로 계산하고, 최근 10일 감성점수의 지수가중이동평균으로 일별 감성지수를 계산한다.

이와 같이 구성된 감성지수를 활용하면 [그림 15]처럼 투자 의사결정에 반영할 수 있는 정보를 추출할 수 있다. 이러한 방법론이 중요한 이유는 [표 16]에 나타난 것 같이 대표적인 주식시장의 위험요인과 상관계수가 낮다는 것이다. 결국 기존 위험요소에 종속되거나 대체되는 정보가 아니라 보완해주는 변수로 충분히 유의미하다는 것을 확인할 수 있다.



[그림 15] 트위터를 활용한 S&P 500 지수 시그널 (Kolanovic & Krishnamachari, 2017)

[표 16] 트위터 시그널과 다른 요인의 상관계수 (Kolanovic & Krishnamachari, 2017)

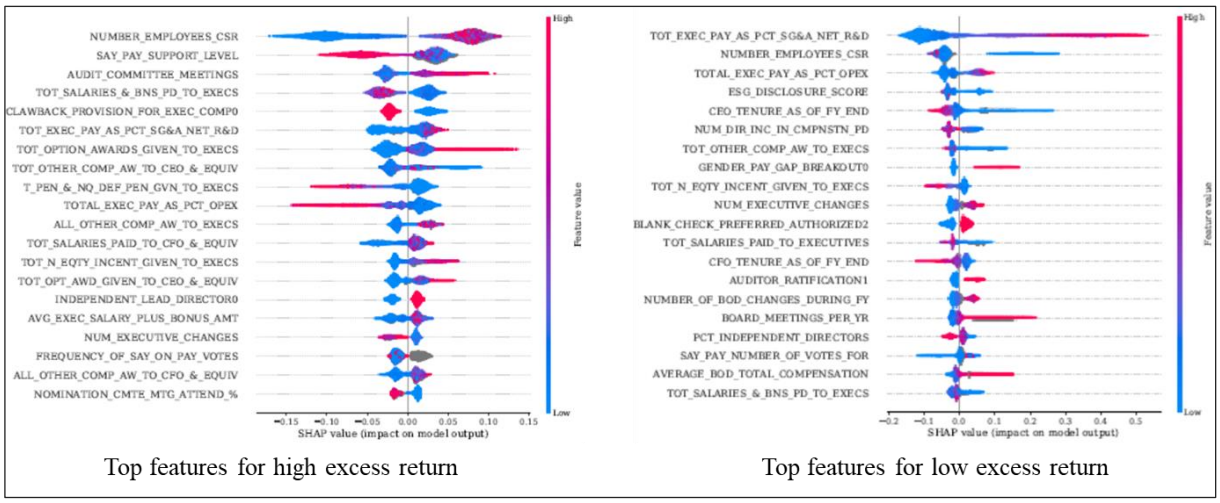
	Twitter-based	Global multi-factor	Value	Size	Momentum	Quality
Global multi-factor	0.05					
Value	-0.01	0.05				
Size	-0.01	-0.07	0.37			
Momentum	0.03	0.42	-0.64	-0.42		
Quality	0.03	0.38	0.02	-0.33	0.11	
Low volatility	0.03	0.75	-0.05	-0.23	0.22	0.50

2.2.4 ESG 데이터

최근에는 '착한 기업'에 투자하기 위해 ESG 요소가 중요해지고 있다. ESG는 환경(Environment), 사회(Social), 지배구조(Governance)를 나타내며, 기업의 사회적 영향과 지속가능성을 평가하는데 사용된다. 기업의 ESG는 정형화된 데이터로 보여지는 부분이 아니기 때문에 비정형 데이터를 통한 기계학습 분석이 필요하다. 특히, 기업 ESG 관련 정보는 의무가 아닌 기업의 자발적인 보고만 이행되고 있으며, 정보 관측 및 정확도에 대한 검증이 어려운 상황이다. 따라서, 대안적 데이터를 사용한 기업의 ESG 분석이 더욱 중요해지고 있다.

Bloomberg Quant Research (2020)에서는 ESG 데이터를 활용한 기업 주가 분석을 진행하였다. Bloomberg의 ESG 데이터는 300개이상의 관련 항목을 제공하며, 분석에서는 2007년부터 2018년까지 데이터를 활용하였다. ESG

데이터로 Gradient boosting tree (XGBoost)를 학습시켜 각 기업의 기대수익률을 3개의 그룹으로 분류하였다. 이렇게 학습된 정보를 반영하면 비교적 위험이 적은 투자가 가능하다는 것을 보였고, [그림 16]처럼 성과에 영향을 주는 ESG 요인을 파악하는게 가능하다는 것을 보였다.



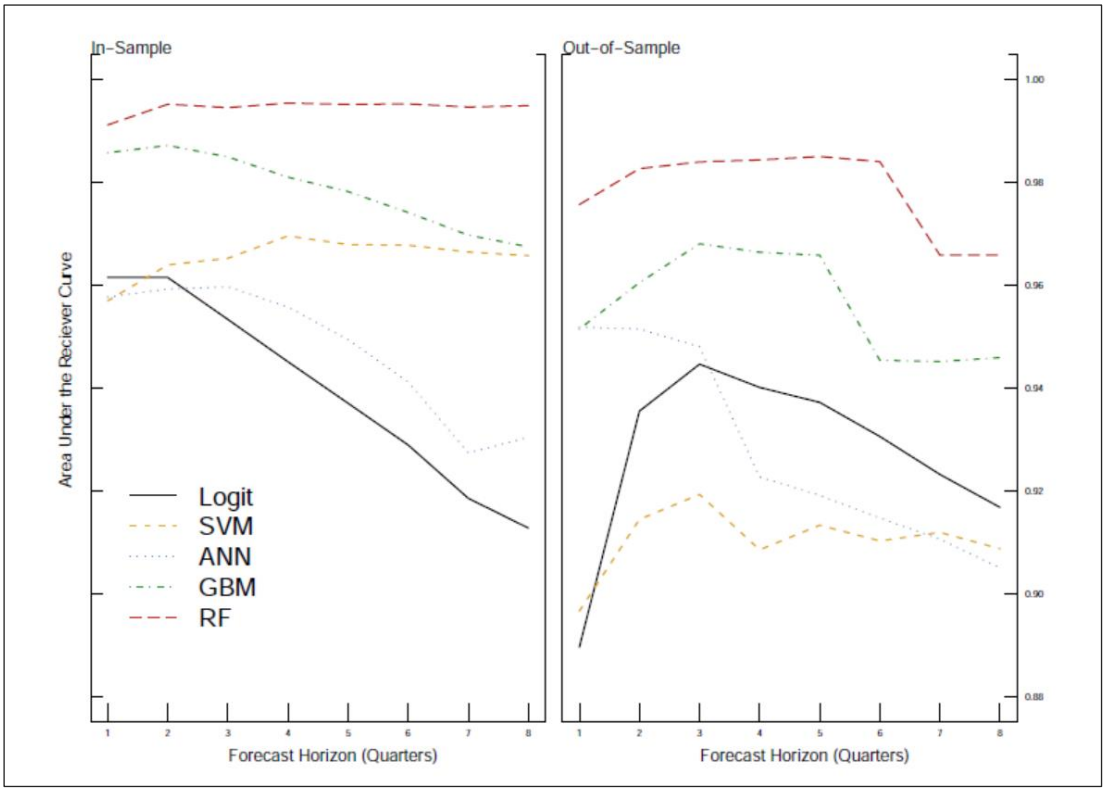
[그림 16] ESG 데이터를 활용한 주가 분석 결과 (Bloomberg Quant Research, 2020)

2.2.5. 재무제표 정보

위에서 소개된 것 같이 대안적 데이터를 활용하면 새로운 영역에서 금융시장 및 기업 분석을 하는게 가능해진다. 그러나 기업분석에 대표적으로 활용되는 재무제표 등 기업 정보 데이터로 기계학습 기법을 학습하는 사례들도 찾아볼 수 있다.

Pike, Sapriza, and Zimmermann (2019)은 손익계산서, 대차대조표 등 재무제표 정보로 기업의 채무불이행 가능성을 예측하는 분석을 진행하였다. 총 26개의 기업 정보를 활용하여 Logistic regression, Random forest, Gradient boosting trees, ANN, SVM을 비교하였는데, Random forest가 가장 예측력이 높다는 결과를 [그림 17]과 같이 확인하였다. Random forest는 0에서 2년 기간 모두 가장 높은 정확도를 보였다. 추가로 개별 기업의 채무불이행을 예측하는 모델을 통해 시장 전체 및

경제 상황을 분석하는데 활용할 수 있다는 것도 보였다.



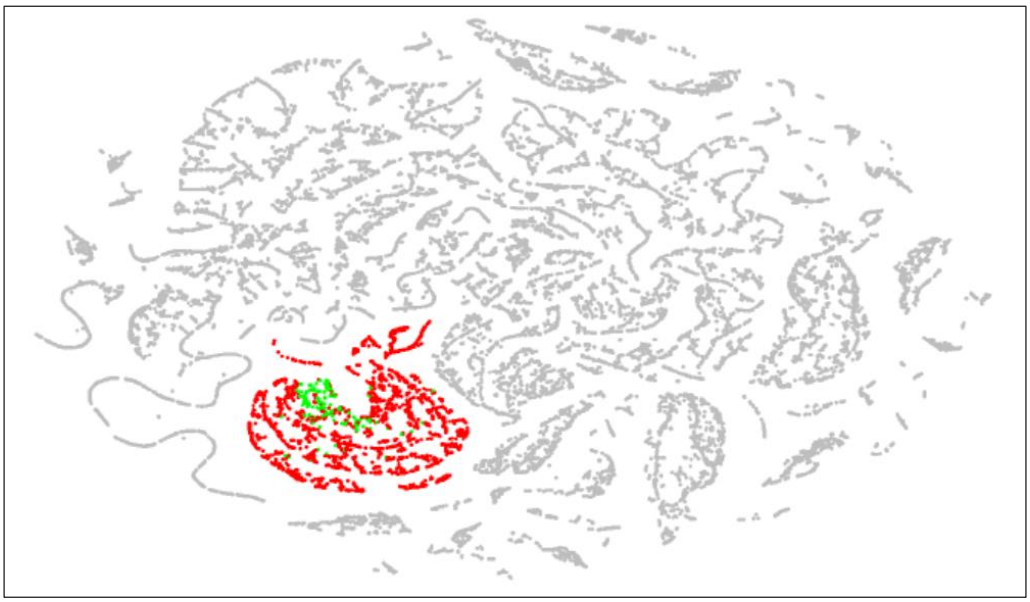
[그림 17] 기계학습 기법 결과(AUC) 비교 (Pike, Sapriza, & Zimmermann, 2019)

[표 17] 이상탐지 기계학습 결과 비교 (Chakraborty & Joseph, 2017)

method	acc_{train}	acc_{test}	*precision*	*recall*	F_1
naïve Bayes	75.8	74.8	38.5	64.4	48.2
k-NN	94.8	91.4	81.4	68.4	74.3
decision tree	98.2	90.4	76.3	68.9	72.4
random forest	100	92.3	84.6	70.5	76.9
FFANN	93.0	91.7	82.5	69.8	75.4
SVM	96.0	92.0	83.1	70.2	76.1
Logit	81.5	81.2	36.1	4.2	7.6

Chakraborty and Joseph (2017)는 대차대조표 정보로 학습된 모델을 통해 이상탐지 분석을 진행하였다. 분기별 Leverage, Capital, Profitability, Assets 데이터를 활용하여 Naïve Bayes, *k*-NN, Decision trees, Random forest, ANN, SVM을 학습시켰고, 3개 이상 데이터에서 이상치가 발견되는 경우를 확인하였다. 그 결과 [표 17]처럼 대부분 기계학습 기법이 기존에 사용되던 로짓 회귀분석(Logit regression)보다 뛰어나다는 것을 보였다.

동일한 보고서에서 Chakraborty and Joseph (2017)는 비상장 스타트업 기업을 비교하는 분석도 포함하였다. 연간 투자유치 금액(funding raised per year), 연간 투자유치 횟수(number of funding received per year), 연간 평균 개인투자자 인원수(average number of individual investors per year), 투자자 평균 점수(과거 투자 점수, the average score of investors) 정보를 활용하여 33,000개 기업을 *k*-means clustering을 통해 분석하였다. [그림 18]에는 초록색으로 표시된 실제로 성공한 기업 주변에 빨간색 클러스터가 존재하는 것을 알 수 있다. 이 클러스터는 성공한 기업들을 포함하고 있으며 다른 클러스터와는 확연하게 거리가 있는 것을 확인할 수 있다.



[그림 18] 스타트업 클러스터링 결과 (초록색: 성공 기업, 빨간색: 성공 클러스터) (Chakraborty & Joseph, 2017)

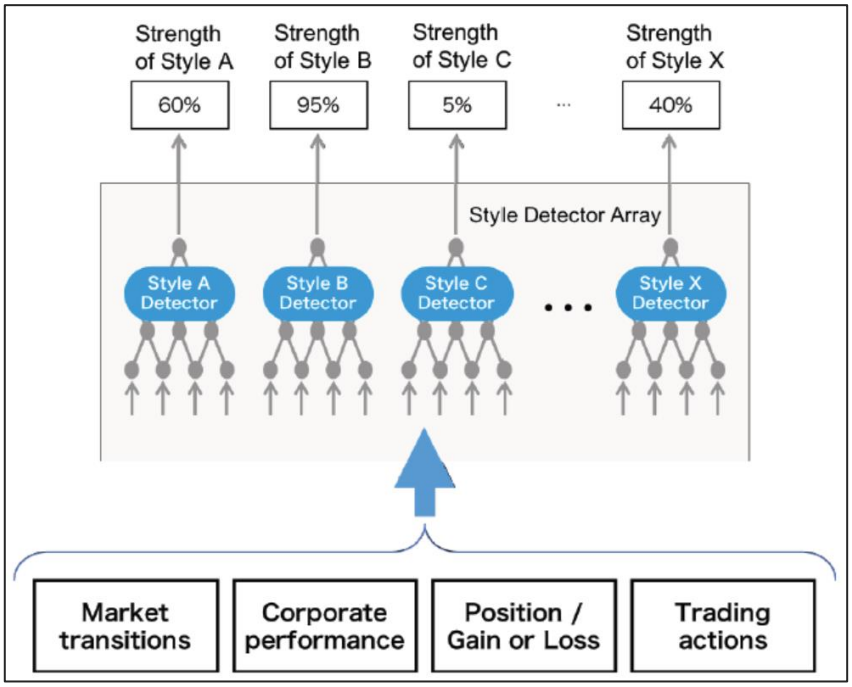
2.3. 펀드 관리 및 특성 분석

일본 공적연금(GPIF, Global Pension Investment Fund)은 펀드 관리를 위하여 딥러닝(Deep learning)을 펀드 분석에 적용하였다.[10] 일본 공적연금은 운용자산이 170조엔에 육박하는 전 세계 최대 연기금이므로 효율적인 펀드 관리가 매우 중요하다. 따라서, 이 분석에서는 인공지능을 활용하여 효율적인 펀드매니저 선정 및 관리를 제안하고 있다.

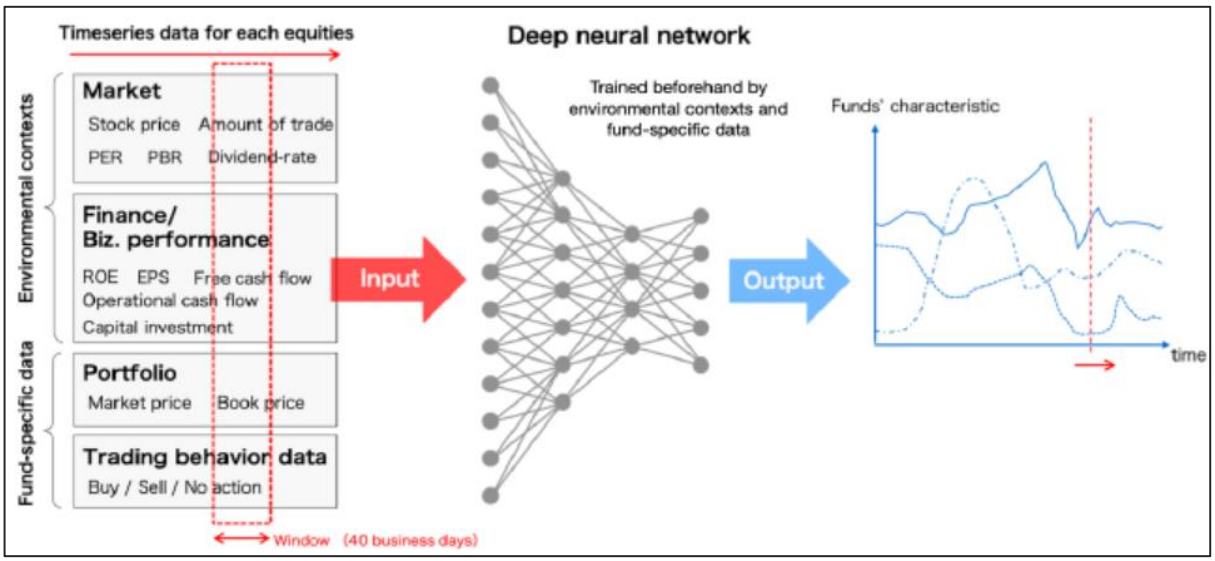
첫번째 분석에서는 딥러닝을 통해 매니저의 운용스타일을 분석하였다(Sasaki et al., 2018). 신경망의 입력값은 크게 펀드 운용 데이터와 시장 데이터로 나뉜다. 펀드 운용 데이터는 각 펀드의 Position, Unrealized loss/gain for each stock, Daily trading actions 등이 포함되고, 시장 데이터는 개별 주식의 주가, 거래량, 배당금을 비롯하여 주가수익비율(Price-earnings ratio, PER) 등 재무제표 정보도 사용된다. 펀드 정보, 주식시장과 기업 데이터도 입력값으로 사용하여 신경망이 특정 펀드뿐만 아니라 시장의 전반적인 움직임도 반영할 수 있도록 구성하였고, 출력값은 특정 투자 스타일과의 유사도를 계산하게 된다. [그림 19]와 같이 스타일마다 심층신경망을 학습시켜서 각 스타일과의 유사도를 구할 수 있게 된다.

실증분석에서는 대형주 100개의 정보로 입력층을 구성하였고, 가장 대표적인 8가지 투자 스타일(High dividend, Minimum volatility, Momentum, Value, Growth, Quality, Fixed weight, Technical)을 학습시켰다. [그림 20]과 같이 입력값은 40 거래일 데이터이며 총 76,000개(주식 100개 × 요인 19개 × 40일) 요소로 입력층을 구성하였다. 각 운용 스타일의 가상 거래 데이터를 2005년부터 2015년까지 생성하여 모델을 학습시키고 그 이후 1년반을 검증기간으로 활용하였다.

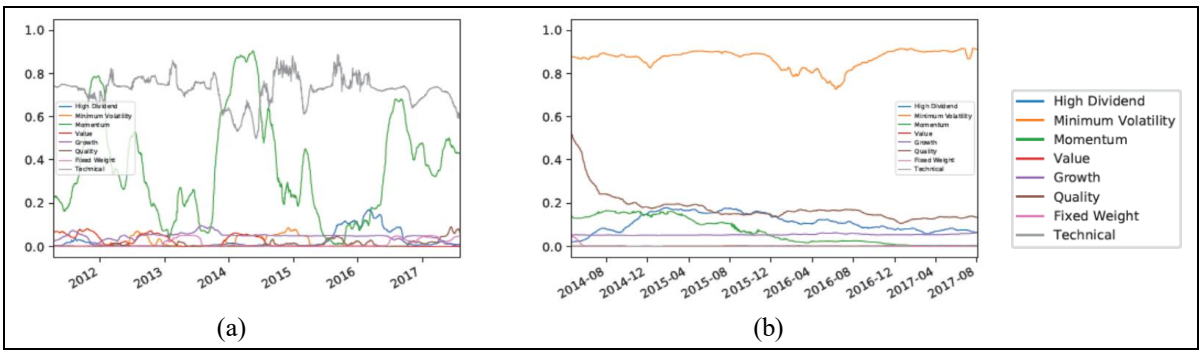
[10] 일본 공적연금이 소니 컴퓨터사이언스 연구소(Sony Computer Science Laboratories, Sony CSL)와 진행한 연구이다.



[그림 19] 심층신경망의 입력값과 출력값 (Sasaki et al., 2018)



[그림 20] 심층신경망 구조 (Tajiri, Sasaki, and Kitano, 2019)



[그림 21] 펀드 분석 결과 예시 (Sasaki et al., 2018)

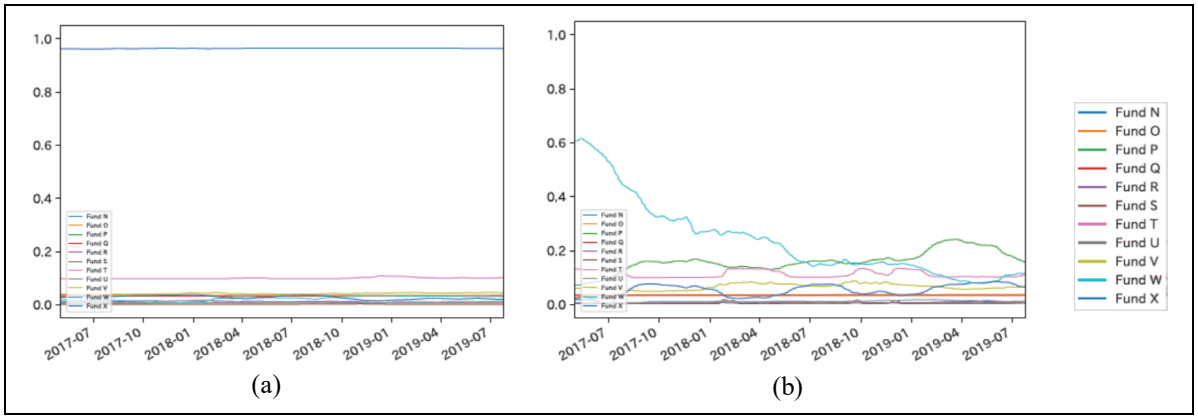
[그림 21]은 두 가지 펀드 분석 결과를 보여주고 있다. 첫번째 펀드 (a)의 경우에는 전체 기간동안 Technical 스타일과 0.5이상의 유사도를 보여주고 일시적으로 Momentum 전략의 형태도 보여주는 것을 알 수 있다. 반면에 펀드 (b)는 항상 Minimum volatility 스타일로 투자하며 다른 스타일과는 비교적 낮은 유사도를 보이는 것을 확인할 수 있다.

후속연구로 진행한 두번째 분석에서는 정해놓은 투자 스타일과의 유사도가 아닌 각 펀드와의 유사도를 딥러닝으로 분석하였다(Tajiri, Sasaki, and Kitano, 2019). 학습 결과가 펀드 유사도이므로 어떤 펀드가 그 펀드의 과거 투자 특성을 얼마나 유지하는지 파악할 수 있고, 다른 펀드와 얼마나 차별성이 있는지도 유추할 수 있다. 그리고 실제 펀드의 특징을 기준으로 유사도를 계산하므로 실제 거래 데이터를 활용하여 모델 학습을 진행하게 된다. 또한, 후속 단계에서는 1,000개의 주식으로 확장시켜 더 포괄적인 분석을 진행하였다.

분석 결과가 포함된 [그림 22]에서 (a)는 특정 펀드가 학습된 자신의 특성을 계속 유지하며 다른 펀드와의 유사도는 일정하게 낮은 것을 확인할 수 있다. 반면에 (b)는 펀드가 다른 펀드뿐만 아니라 자신의 과거 특성과도 유사도가 낮은 것을 보여주고 있다.

제안된 심층신경망 모델을 활용하면 이렇게 실제 펀드의 특성을 시계열로 분석하는게 가능하며, 본 분석에서 유사도 측정에 사용된 투자 스타일 또는 펀드의 과거 패턴 뿐만 아니라 다양한 유사도 분석을 실시할 수 있다. 기계학습 기반 분석을 통해 특성이 바뀌었을 때 빠르게 감지하는 것이 가능해지고, 특히

금융시장에 쇼크가 발생했을 때 각 펀드가 어떻게 반응하는지 살펴볼 수 있다. 그리고 데이터 기반 분석을 진행하므로 편견에 영향 받지 않는 투자 유형을 추출하는게 가능하다는 장점도 있다.



[그림 22] 펀드 유사도 분석 결과 예시 (Tajiri, Sasaki, and Kitano, 2019)

2.4. 그외 적용 사례

그외에도 주식시장과 기업 분석에 기계학습을 적용하는 사례를 많이 찾아볼 수 있다. JP 모건 인공지능 보고서는 대안적 데이터를 적용하는 다양한 사례가 포함되어 있다(Kolanovic and Krishnamachari, 2017). 온라인 결제의 이메일 영수증 정보(Eagle Alpha), 스마트폰 위치 정보(Advan), 드론의 지형공간 데이터(RS Metrics) 등을 통해 분석을 진행하는 사례를 소개한다.

CFA(Chartered Financial Analyst)의 인공지능 투자관리 보고서는 11개의 적용사례를 소개하고 있다(Cao, 2019). State Street Corporation, Goldman Sachs, Schroders 등 글로벌 자산운용사에서 인공지능 및 기계학습을 활용하는 내용을 담고 있다. Eagle Alpha (2018)는 대안적 데이터의 적용사례 50여개를 소개하고 있으며, Denev and Amen (2020)도 대안적 데이터 분석 기법을 설명하면서 다양한 적용 예시를 포함하고 있다.

III. 인공지능과 기계학습 도입 및 활용 방안

1. 인공지능 및 기계학습 활용 방안

본 보고서에서 확인한 국내외 적용 사례를 바탕으로 국민연금기금의 인공지능과 기계학습 활용 방안을 살펴본다. 기계학습 기법의 성숙도와 금융시장 적용 과정을 고려하면 거시경제 분석, 위기지수 구축, 시장 및 기업 분석, ESG 평가, 펀드 관리, 업무 자동화에 적용할 수 있을 것으로 판단된다.

1.1. 거시경제 분석

미국과 영국의 중앙은행을 중심으로 기계학습이 가장 활발히 적용되고 있는 분야는 거시경제 분석으로 파악된다. 일반적으로 경제지표는 발표주기가 길고 설문을 통한 예측도 정해진 주기에 조사를 진행하게 되는데, 데이터분석을 통한 경제지표 예측 및 경제전망은 현재 상황을 반영하는게 가능해진다. 또한, 대안적 데이터를 활용하면 경제지표 및 전반적인 경제 상황에 영향을 주는 여러 요인을 예측에 반영할 수 있다. 경제전망에 대한 분석은 자산배분 의사결정에 중요하므로 거시경제 분석에 기계학습 기법과 대안적 데이터 활용을 고려해볼 수 있으며, II.2.1절에 소개된 자료를 참고할 수 있다.

1.2. 위기지수 구축

기금 운용의 리스크관리를 위하여 종합 위기지수, 국가별 위기지수, 자산군 위기지수 등을 구축하고, 이를 통해 시장 리스크를 측정하는 것도 효과적인 활용 방안이 될 수 있다. 특히, 대안적 데이터, 감성분석, 기계학습 기법을 활용하면 다방면으로 시장의 안전성과 건정성을 측정할 수 있게 되어 포괄적이면서도 세분화된 리스크 분석이 가능해질 것으로 판단된다. 위기지수 모니터링을 통한 투자 리스크 분석과 선제적인 위기 대응도 강화할 수 있을 것으로 기대되며,

II.2.1절의 거시경제 분석과 II.2.2절의 주식시장 분석 내용을 활용할 수 있다.

1.3. 기계학습을 활용한 시장 및 기업 분석

뉴스, 소셜미디어, 회의 기록 등 다양한 데이터의 분석이 가장 많이 적용된 주제는 주식시장 및 기업 분석인 것으로 조사되며, 대안적 데이터로 감성분석을 진행하는 사례가 특히 많은 것으로 파악된다. 국민연금기금은 이러한 기술을 개별주식 투자에 적용하는 것은 실효성이 낮을 수 있으나, 기계학습 기법을 활용하면 퀀트기반 투자 확대와 액티브 전략 내재화에 기여할 수 있을 것으로 예상한다. 또한, 팩터기반 리스크 분석에도 활용이 가능하며, 감성정보가 포함된 팩터모델을 활용하는 것도 고려해볼 수 있다. 관련 사례는 II.2.2절과 II.2.4절에서 소개되었다.

1.4. ESG 평가

ESG 요소를 고려한 책임투자가 사회적으로 강조되고 있으며, 국민연금은 2019년에 책임투자 활성화 방안을 발표한 이후에 ESG 투자를 확대할 것으로 알려졌다. 현시점에서 정형화된 데이터로 기업의 ESG 정보를 파악하는 것은 한계가 있으므로 대안적 데이터 분석도 ESG 평가에 고려해볼 수 있다. 이를 통해 ESG 기준에 부적절한 기업과 펀드를 식별하는 작업에 사용할 수 있으며, 특히 해외 주식의 투자 결정에 활용할 수 있을 것으로 기대한다. II.2.2.4절의 분석 예시를 참고할 수 있다.

1.5. 펀드 관리

주식시장의 데이터와 함께 실제 거래 데이터까지 활용하면 펀드의 특성을 자세히 분석하는게 가능하다. 단순히 리스크 정도만 측정하는 것이 아니라 펀드가 어떠한 투자방식 또는 전략과 유사함을 보이고 있으며, 시장 상황에 어떻게 반응하는지를 수리적으로 살펴볼 수 있다. 펀드의 특성을 기계학습으로

분석하면 위탁 운용 평가에 활용하는데 효과적일 수 있다. 직접 운용을 확대하는 과정에서 전략 내재화를 위한 펀드를 선별하는 단계에서 활용할 수 있을 것으로 예상되며, 액티브와 퀀트기반 전략을 분석하는 모델로써도 활용도가 높을 수 있다. II.2.3절에 소개된 GPIF의 적용사례를 참고하는 것이 가능하다.

1.6. 업무 자동화

금융시장 데이터에 특화된 모델링 기법은 아직 연구 초기 단계이지만, 인공지능을 통한 프로세스 자동화는 기술 성숙도가 높고 여러 분야에서 사용되고 있다. 금융산업에서도 업무 자동화를 통해 업무의 효율과 비용 절감을 실현할 수 있다. 금융시장을 분석하는 과정에서 자료(뉴스, 보고서 등) 수집, 번역, 정보 추출 등은 인공지능을 활용하는게 가능하다. 회의 기록, 자료 및 이메일 생성 자동화를 통해 업무 효율을 향상 시킬 수 있으며, 연금 가입자에게 정보 전달, 상담, 교육 등을 자동화하는 것도 가능하다. 인공지능의 도입이 장기적으로는 해외투자 인력 및 인프라 확대에 크게 기여할 수 있을 것으로 기대한다.[11]

2. 인공지능 도입 단계

데이터분석 기술은 공공부문에서도 널리 활용되는 것을 확인할 수 있다. Central Banking (2018)에서 전 세계 총 52개 중앙은행의 데이터 활용에 관한 설문을 진행했다. 52개 중앙은행 중 29개는 빅데이터 관련 프로젝트를 진행 중이며, 이중 절반 이상은 2018년도 기준으로 1년 내에 프로젝트가 시작된 것으로 조사되었다. 국민연금기금 도입 단계를 논의하기에 앞서, 활발히 진행되고 있는 글로벌 도입 현황을 살펴본다.

[11] Accenture (2018) 보고서는 투자 운용사의 전반적인 프로세스에 인공지능을 활용할 수 있는 부분을 조사하였다.

2.1. 기술 도입 현황

기계학습을 적용하는 과정에서 개발 툴에 대한 진입장벽은 낮다고 볼 수 있다. 기계학습의 실증분석을 진행한 보고서는 오픈소스(Open source) 소프트웨어를 사용하는 경우가 많으며, 파이썬(Python) 프로그래밍 언어로 Scikit-learn, TensorFlow, Keras 등 오픈소스 라이브러리를 통해 분석을 진행했다. 심층신경망을 포함하여 여러 기계학습 기법이 구현되어 있는 라이브러리를 사용하여 분석을 진행하게 되면 구현시간 단축, 학습 효율 극대화 등의 이점을 기대할 수 있다.

복잡한 연산을 요구하는 인공지능과 기계학습 기법 적용은 일반적으로 클라우드 컴퓨팅(Cloud computing) 기술도 같이 활용하게 된다.[12] 클라우드는 개발 및 분석 속도를 단축시키며, 비용을 절감할 수 있으며, 확장성이 뛰어나기 때문에 데이터분석에 이용된다. 금융권에서도 클라우드 컴퓨팅은 필요한 기술로 인식이 되는 것으로 파악된다. 연방준비제도(Federal Reserve)는 글로벌 금융시스템에 클라우드 서비스의 중요도를 인지하고 신뢰성과 복원성 등을 검토하기 위하여 아마존 웹서비스(Amazon Web Services, AWS) 데이터센터를 방문했다는 것이 보도되었고(Hoffman, Mattioli, and Tracy , 2019), Federal Reserve Bank of Richmond (2020)는 2020 Cloud Summit을 개최하여 클라우드 서비스 활용에 대한 토론을 진행하였다.

클라우드 컴퓨팅은 비용, 편리성 등에 큰 장점이 있음에도 불구하고 도입에 쟁점이 되는 부분은 보안이다(Oracle, 2020). 그러나 보안 때문에 사용을 전격으로 자제하는 것이 아니라, 체계적인 관리를 통해 필요에 따라 활용하는 것을 권장하는 경향이다. Financial Stability Board (2019)는 자체적으로 관리하는 기존 데이터센터에 비해 보안면에서도 클라우드가 우수할 수 있다고 판단하였다. 또한, 미국 정부에서 2010년부터 추진하였던 Cloud First 전략과 2018년부터 새로 추진하고 있는 Cloud Smart 전략은 클라우드 기술을 배제하는 것이 아니라,

[12] II장에서 소개된 GPIF의 펀드 분석도 딥러닝 학습을 위해 클라우드를 사용하였다 (Sasaki et al., 2018; Tajiri, Sasaki, and Kitano, 2019).

정확히 파악하고 상황에 맞게 적용하여 효과적으로 관리하는 것을 권장하고 있다(Figliola, 2020; Kent, 2019).

민간 부문에서는 데이터베이스 관리와 데이터분석에 클라우드 컴퓨팅이 활발히 활용되는 것으로 파악된다. Schroders와 American Century도 기계학습을 적용하는 분석은 클라우드를 활용한다고 밝혔고(Cao, 2019), Vanguard는 데이터센터를 클라우드기반으로 전환하는 것으로 알려졌다.[13] 미국 Depository Trust and Clearing Corporation (DTCC)도 연산 효율성을 위해 클라우드 서비스를 선택한 대표적인 사례로 알려져있다.[14]

2.2. 전문인력 구성

금융기업에서 인공지능 또는 기계학습 업무를 집중적으로 담당하는 조직을 구성하는 사례가 많이 발견된다. 블랙록 자산운용(BlackRock)의 경우에는 2018년에 BlackRock Lab for Artificial Intelligence을 개설하여 운용 프로세스에 전반적으로 인공지능을 적용하는 분석을 진행하고 있는 것으로 알려졌다(Wigglesworth and Flood, 2018). UBS는 최신 인공지능과 기계학습 기법을 다양하게 적용하기 위하여 2018년에 Strategic Development Lab을 만들었다.[15]

인공지능 전문인력은 금융전문가로 제약을 두는 것이 아니라 데이터분석 전문지식 및 경험이 있는 전분야 전문가를 모집하는 경향이 있다. 최신 기술 도입뿐만 아니라 인력양성을 위해 학계와 협업을 하는 경우도 찾아볼 수 있다. Man Group은 University of Oxford와 공동연구 및 협업을 하기 위해 2007년부터 Oxford-Man Institute을 공동으로 운영하고 있으며 최근에는 금융시장에 기계학습과 데이터분석을 적용하는 연구를 집중적으로 수행하고 있다.[16]

---

[13] https://aws.amazon.com/ko/solutions/case-studies/vanguard-case-study/

[14] https://aws.amazon.com/ko/solutions/case-studies/DTCC/

[15] https://www.ubs.com/global/en/investment-bank/strategic-development-lab.html

[16] https://www.oxford-man.ox.ac.uk/

2.3. 국민연금의 도입 단계

국민연금기금의 인공지능 도입을 위해서는 기술 인프라를 갖춰야 한다. 본 보고서에서 클라우드 컴퓨팅에 대한 자세한 분석을 진행하지는 않았으나, 지속적으로 인공지능을 활용하는 것을 고려하는 현시점에서 클라우드 서비스 도입을 검토해볼 필요가 있다고 판단된다. 클라우드 서비스를 통해 인공지능 기술 도입 비용을 절감할 수 있으며, 기계학습 관련 연구, 분석, 개발에 소요되는 시간을 단축할 수 있다는 장점도 명확하다. 국내외 인프라 확대 과정에서 클라우드 컴퓨팅의 활용을 고려할 수 있다.

기술의 도입만큼 중요한 것이 인공지능 전문인력을 갖추는 것이다. 우선적으로 인공지능과 기계학습을 중점적으로 다루는 데이터사이언스(Data Science) 전문 조직을 구성하는게 효과적일 것이다. 금융분야 전문가로 제한을 두지 않고 데이터분석 전문성을 중심으로 조직을 구성할 수 있다. 기술 도입을 위해 충분한 데이터분석 전문인력 충원이 필수라고 판단된다. 또한, 관련 기술을 적용할 수 있는 많은 기회가 주어지도록 지속적인 지원이 필요하다. 대학교 및 연구소와 공동연구 수행하면 기술 도입 뿐만 아니라 석박사급 인력 충원에도 효과가 있을 것으로 기대된다.

신기술 도입을 준비하면서 현재 분석 환경에 대한 점검도 필요할 것으로 생각한다. 효과적으로 데이터를 활용하기 위해서는 효율적인 데이터베이스 관리가 반드시 필요하다. 현재 보유하고 있는 데이터량이 많더라고 체계적인 관리가 되어 있지 않다면 기계학습 분석에 효과적으로 활용하는게 어려울 수 있다. 따라서, 인공지능을 도입하는 과정에서 현재 기금운용의 데이터베이스부터 효율적으로 관리하는 작업이 동시에 이루어져야 될 것으로 판단된다.

국민연금기금의 도입 과정을 단계별로 나누면 [표 18]과 같이 요약할 수 있다. 1단계에서는 적용 가능성과 도입 방향을 확인하여 보고, 2단계에서는 적용 기술과 자산군을 확대하며, 3단계에서는 기금운용 전분야에 인공지능과 기계학습 기술을 적용할 수 있도록 활용하는 것이다.

[표 18] 국민연금기금의 인공지능 도입 단계(안)

1단계
▸ 전문 데이터사이언스 조직 구성 ▸ Python/Open source library와 Public data로 활용 가능성 확인 ▸ 실증분석에 필요한 클라우드 서비스 조사

2단계
▸ 데이터분석 전문인력 충원 ▸ Data provider 검토 및 클라우드 서비스 활용 확대 검토 ▸ 기계학습 기술을 적용하는 자산군 확대

3단계
▸ 데이터사이언스 조직 확대 ▸ 필요시 클라우드 기반 데이터센터 구축 ▸ 기금운용 전분야에 인공지능/기계학습 적용

2.4. 인공지능 활용 한계점

인공지능을 도입하는 단계에서 기술의 한계점도 인지할 필요가 있다. 먼저, 국민연금기금의 규모를 고려하면 인공지능과 기계학습의 도입으로 인해 단기적으로 수익률에 직접적인 영향을 기대하기에는 한계가 있다. 인공지능 기술을 통해 경제 및 금융시장 분석 효율성을 극대화 하는 것이 적절한 목표라고 평가한다. 인공지능 기술을 효과적으로 활용하기 위해서는 전문 조직이 필요하므로 도입 초기부터 조직을 구성하는 것을 고려할 수 있다. 중·장기적인 목표를 향한 지속적인 지원이 필요하며, 도입 시기가 늦어지면 데이터기반 기술을 적용하는 것이 더욱 어려워질 수 있다.

기계학습 기법 중에는 학습된 모델을 설명하기 어려운 블랙박스(Black box) 기법이 존재하므로 이를 고려하여 방법론을 적용할 필요가 있다. 또한, 채권시장과 대체투자에 적용된 사례는 비교적 적으므로 초기 단계에는 다른 자산군을 중심으로 비교적 간단하게 적용 가능한 부분을 찾아서 진행해보는 것이 가능하다.

IV. 결론

인공지능과 기계학습 기술은 공공부문을 포함하여 금융산업에 다양한 적용 사례를 찾아볼 수 있다. 특히, 경제 전망, 시장 분석 등 분야에는 활용도가 높은 것으로 파악되며, 대안적 데이터를 활용한 감성분석, ESG 평가 등으로 기존 분석을 보완하는 것도 가능하다.

국민연금기금은 인공지능과 기계학습을 도입하여 거시경제 분석, 위기관리, 시장 조사, 펀드 관리 등에 활용할 수 있을 것으로 예상된다. 인공지능 자산관리사의 고수익률을 기대하는 단면적인 목표가 아니라, 데이터 분석을 통해 시장의 이해, 기업의 이해, 투자위험에 대한 이해를 다방면으로 할 수 있으며 프로세스 자동화에도 활용될 수 있는 관점으로 기술을 도입해야 할 것이다. 적용 가능성 검토부터 시작하여 단계적으로 활용을 넓혀가며, 기술 도입에 필요한 인프라 구축 및 전문인력 충원에 충분한 지원이 있기를 기대한다.

참고 문헌

김수현 (2020). 딥러닝을 활용한 거시경제 및 금융시장 분석과 예측. 한국은행.

김수현, 이영준, 신진영, 박기영 (2019). 경제 분석을 위한 텍스트 마이닝. 한국은행.

Accenture. (2018). Research on AI's Impact on Asset Management – Potential Use for GPIF's Overall Operations. Accenture Strategy.

AQR Capital Management. (2019). Can Machines "Learn" Finance? AQR Capital Management, Portfolio Solutions Group.

Bloomberg Quant Research. (2020). Seeking Signals from ESG Data. Bloomberg Quant Research.

Cao, L. (2019). AI Pioneers in Investment Management. CFA Institute, Research Reports.

Central Banking. (2018). Big Data in Central Banks. Central Banking Focus Report (in association with BearingPoint).

Chakraborty, C., & Joseph, A. (2017). Machine Learning at Central Banks. Working Paper No. 674, Bank of England.

Cook, T. R. & Hall, A. S. (2017). Macroeconomic Indicator Forecasting with Deep Neural Networks. Federal Reserve Bank of Kansas City, Research Working Papers 17-11.

Denev, A., & Amen, S. (2020). The Book of Alternative Data: A Guide for Investors, Traders and Risk Managers. John Wiley & Sons.

Dimov, I. (2018). Sentiment impact on stock prices of news with selected topic codes: Part Two. Bloomberg L.P. Quantitative Research.

Federal Reserve Bank of Richmond. (2020). Richmond Fed Announces Financial Technology Summit 2021. https://www.richmondfed.org/press_room/our_news/2020/20200604_financial_technology_summit.

Figliola, P. M. (2020). Cloud Computing: Background, Status of Adoption by Federal Agencies, and Congressional Action. Congressional Research Service, R46119.

Hall, A. S. (2018). Machine learning approaches to macroeconomic forecasting. Federal Reserve Bank of Kansas City Economic Review, issue Q IV, 63-81.

Hoffman, L., Mattioli, D., and Tracy, R. (2019). Fed examined Amazon's cloud in new scrutiny for tech. *Wall Street Journal*. https://www.wsj.com/articles/fed-examined-

amazons-cloud-in-new-scrutiny-for-tech-11564693812.

Kent, S. (2019). Federal Cloud Computing Strategy. https://www.whitehouse.gov/wp-content/uploads/2019/06/Cloud-Strategy.pdf.

Kim, S. (2020). Macroeconomic and Financial Market Analyses and Predictions through Deep Learning. Bank of Korea, BOK Working Paper No. 2020-18.

Kolanovic, M., & Krishnamachari, R. T. (2017). Big data and AI strategies: Machine learning and alternative data approach to investing. J.P. Morgan Global Quantitative & Derivatives Strategy Report.

Lam, D. (2018). Sentiment impact on stock prices of news with selected topic codes: Part One. Bloomberg L.P. Quantitative Research.

Lee, Y., Kim, K., & Park, K. Y. (2019). Measuring Monetary Policy Surprises Using Text Mining: The Case of Korea. Bank of Korea, BOK Working Paper No. 2019-11.

Nyman, R., Kapadia, S., Tuckett, D., Gregory, D., Ormerod, P., & Smith, R. (2018). News and narratives in financial systems: Exploiting big data for systemic risk assessment. Bank of England Staff Working Paper No. 704.

Oracle. (2020). Oracle and KPMG Cloud Threat Report. https://www.oracle.com/security/cloud-threat-report/.

Pike, T., Sapriza, H., & Zimmermann, T. (2019). Bottom-up leading macroeconomic indicators: An application to non-financial corporate defaults using machine learning. Finance and Economics Discussion Series 2019-070. Washington: Board of Governors of the Federal Reserve System, https://doi.org/10.17016/FEDS.2019.070.

Puglia, M., & Tucker, A. (2020). Machine learning, the Treasury yield curve and recession forecasting. Finance and Economics Discussion Series 2020-038, Board of Governors of the Federal Reserve System (U.S.), https://doi.org/10.17016/FEDS.2020.038.

Sasaki, T., Koizumi, H., Tajiri, T., & Kitano, H. (2018). A Study on the Use of Artificial Intelligence within Government Pension Investment Fund's Investment Management Practices (Summary Report). Sony CSL.

Shapiro, A. H., Sudhof, M., & Wilson, D. (2020). Measuring News Sentiment. Federal Reserve Bank of San Francisco Working Paper 2017-01, https://doi.org/10.24148/wp2017-01.

Shapiro, A. H., & Wilson, D. (2019). Taking the Fed at its Word: A New Approach to Estimating Central Bank Objectives using Text Analysis. Federal Reserve Bank of San Francisco Working Paper 2019-02. https://doi.org/10.24148/wp2019-02.

Sharpe, S. A., Sinha, N. R., & Hollrah, C. (2017). What's the story? A new perspective on the value of economic forecasts. Finance and Economics Discussion Series 2017-107, Board of Governors of the Federal Reserve System (U.S.) https://doi.org/10.17016/FEDS.2017.107r1

Tajiri, T., Sasaki, T., & Kitano, H. (2019). A Step Toward a Cybernetic Whale: An Interim Report on "A Study on the Use of Artificial Intelligence for Learning Characteristics of Funds' Behavior". Sony CSL.

Wigglesworth, R. & Flood, C. (2018). BlackRock bulks up research into artificial intelligence. Financial Times, https://www.ft.com/content/4f5720ce-1552-11e8-9376-4a6390addb44.

Zhao, F. (2018). Natural Language Processing - Part II: Stock Selection. S&P Global Market Intelligence Quantamental Research.

Zhao, F. (2020). Natural Language Processing - Part III: Feature Engineering. S&P Global Market Intelligence Quantamental Research.