

양상블 학습을 이용한 기업혁신과 경영성과 예측*

안경민** · 이영찬***

〈목 차〉

I. 서론	4.2 일반현황 분석
II. 선행연구	4.3 신뢰성 분석 및 타당성 분석
2.1 기업혁신의 개념	4.4 머신러닝 분석
2.2 기업혁신의 유형화	V. 결 론
2.3 기업혁신과 경영성과	5.1 연구요약
III. 연구방법	5.2 시사점
3.1 양상블 기법	5.3 한계점 및 향후 연구
3.2 예측모형 성능평가	참고문헌
IV. 분석결과	<Abstract>
4.1 조작적 정의 및 측정항목	

I. 서론

최근 경영환경이 급변하면서 기업은 기술혁신과 전사적인 차원에서의 변화관리를 통해 난관을 극복하기 위해 노력하고 있다(최진용, 김상유, 2020). 변화하는 경영환경에 능동적으로 반응하고 적응하기 위한 새로운 기업운영 매커니즘이 요구된다고 볼 수 있으며, 이는 곧 혁신

을 의미한다고 볼 수 있다. 혁신은 기존의 기술, 제품, 관행 등을 파괴하여 새로운 것과 결합하는 과정으로 새로운 상품의 창출, 새로운 생산방법의 개발, 새로운 시장의 개척, 새로운 원자재 공급원의 발굴, 새로운 조직의 구축 등으로 발휘된다(Schumpeter, 1934). 즉, 기업에서 혁신은 새로운 변화에 적응하여 새로운 가치를 창출하고 그것이 기업성적으로 발현되는 것이라

* 이 논문은 2021년 대한민국 교육부와 한국연구재단의 인문사회분야 신진연구자지원사업의 지원을 받아 수행된 연구임(NRF-2021S1A5A8061237)

이 논문은 2021년 박사학위논문의 데이터를 활용하여 재구성하였음.

이 논문은 2021년 한국정보시스템학회 추계학술대회에서 우수상으로 선정된 논문을 수정·보완한 것임.

** 동국대학교 글로벌융합연구소연구사, snss1212@dongguk.ac.kr(주저자)

*** 동국대학교 정보경영학과, chanlee@dongguk.ac.kr(교신저자)

고 볼 수 있다.

하지만 이전의 기업혁신과 경영성과에 관련된 연구는 주로 문헌탐구를 중심으로 혁신의 개념을 정의하거나 가설검증에 초점을 두고 있어 전략적이고 실무적인 활용에 한계점이 있다. 이론적인 한계점 측면에서 Adams et al.(2006)은 기업혁신에 관한 연구가 주로 이론과 문헌 연구에 집중되어 있어 실무에 적용되기 어렵다는 점을 지적하였으며, Becheikh et al.(2006)은 혁신의 과정에서 일반적인 이해가 누락되고 있다는 점을 지적하였다. 또한, Edison et al.(2013)은 선행연구에서 제안되고 있는 혁신에 대한 분석지표는 실무적인 관점이 충분히 고려되고 있지 않다고 하였다. 이것은 변화하는 영역인 혁신을 측정하고 분석하는 데 있어서 현장감이 고려되어야 한다는 것을 의미한다.

한편, 방법론적인 한계점 측면에서 전통적인 방법론은 사회 현상의 예측보다는 이론을 검증하는 것에 초점이 맞춰져 왔다. 이론을 통계적으로 검증하기 위해서는 엄격한 통계적 기준이 요구되며(우종필, 2015), 통계적 기준이 충족되지 않는다면 왜곡된 결과 도출로 인해 연구 시사점에 한계가 나타날 수 있다. 또한, 이러한 문제점은 복잡한 요인 간의 관계를 측정하는 것을 어렵게 만든다. 즉, 기업혁신이라는 복잡한 매커니즘을 포괄적으로 분석하는 것이 제한될 수 있다. 반면, 머신러닝의 경우 분석에 있어서 정형자료와 비정형자료 등을 사용하는 것에 제한이 없고 현상을 예측하는 데 최적화되어 있어 탐색적 수준의 연구에 유용하다. 특히 파라미터 조절 기능은 분석 요인의 최적화가 가능하며 우수한 결과값을 도출할 수 있다는 장점이 있다(안경민, 2021).

이상의 내용을 바탕으로 본 연구에서는 선행 연구의 한계점을 극복하기 위해 다음과 같은 연구주제를 설정하고 목표를 달성하고자 한다. 첫째, 선행연구를 통해 기업혁신과 관련된 기업 활동의 주요 요인과 매커니즘을 탐색하고 기업 성과와의 관계를 고찰하고자 한다. 혁신은 지속적인 경험이 축적되어 발휘되는 시스템적인 구조로 되어있어 결과를 설정하는 것에 따라 선행요인이 달라질 수 있다. 하지만 기업에서 혁신이 갖는 본연의 의미는 궁극적인 변화와 새로운 가치를 창출하는 것이다. 이러한 맥락에서 본 연구에서는 혁신성과를 기업 활동의 결과인 제품변화로 한정하였고, 경영성과는 매출액으로 정의하였다. 둘째, 머신러닝 앙상블 학습을 적용하여 혁신성과와 경영성과를 예측하고 성능을 비교 및 평가하고자 한다. 머신러닝은 인공지능의 한 분야로 컴퓨터가 데이터를 학습할 수 있도록 알고리즘을 개발하고 적용하는 분야이다. 앙상블 학습은 분류, 회귀, 순위 등을 분석할 수 있는 우수한 알고리즘으로 알려져 있다(Breiman, 2001). 앙상블 학습은 약한 학습자(weak learner)을 활용하여 강한 학습자(strong learner)를 만드는 것으로 여러 모형을 조합하여 개선된 결과값을 도출한다. 본 연구에서는 앙상블 학습 중 XGboost, LightGBM, Catboost를 활용하였으며, 전통적인 방법과 비교하여 성능을 평가하였다. 셋째, 분석된 결과를 바탕으로 시사점을 도출하고 후속 연구를 제안하고자 한다.

II. 선행연구

2.1 기업혁신의 개념

기업혁신에 관해서는 다양한 관점이 존재하나 광의적으로 Schumpeter(1934)의 경제발전 이론(The theory of economic development)을 따른다. 그는 혁신을 기존의 기술, 제품, 관행 등을 파괴하여 새로운 것과 결합하는 과정인 창조적 파괴(creative destruction)라고 역설하였다. 이후 이 개념은 연구의 범위에 따라 협의의 의미에서 활용된다(Saunila, 2019). Thompson(1965)은 새로운 제품, 공정, 서비스를 조직에서 최초로 생성, 수행하는 과정이라고 하였고, Utterback(1971)은 기업이 혁신에 대한 필요성을 내외부 자원과 결합하여 제품이나 공정을 새롭게 만들어 내는 것이라고 하였다. Armbruster et al.(2008)은 생산, 공급망 관리, 품질 관리 시스템의 팀워크에서 새로운 관리 방식, 작업 방식, 관행이 구현됨으로써 조직 구조 및 과정이 변경되는 것이라고 하였고, Damanpour and Aravind(2011)는 조직의 전략, 구조, 관리 절차, 시스템에 변화를 일으키는 관리 기능 및 새로운 과정을 수행하기 위한 새로운 지식 접근 방식이라고 하였다. 즉, 기업혁신은 기업의 새로운 변화를 위해 외부 자원을 결합하는 것과 이것을 조직 내부의 독특한 과정을 통해 내재화하여 활용하는 개념까지 포함하는 복잡성과 역동성이 나타난다고 할 수 있다(Teece, 2010; Ferreira et al., 2020).

기업혁신의 다차원성은 기업활동으로 인한

순환 시스템에서 기인한다. Dewangan and Godse(2014)는 혁신이 발명과 활용의 생애주기를 가지고 있다는 점에 주목하고, 기업혁신은 생애주기별로 각 단계를 측정 및 벤치마킹할 수 있는 고유한 활동과 결과물을 가지고 있다고 주장하였다. Jonash and Sommerlatte(2001)는 혁신은 조직이 과업 과정의 반영, 변화, 학습이 순환되는 시스템 구조를 가진다고 하였으며, 기업혁신의 4대 주요 개념은 혁신전략, 혁신조직, 혁신자원, 혁신공정이라고 하였다. 주요 개념의 구성요소에서 혁신전략은 플랫폼, 프로젝트, 파트너를 포함하고 있고, 혁신조직은 리더십, 협업, 제휴로 구성된다고 하였다. 혁신자원은 금융, 지적자산, 인력이고, 혁신공정은 아이디어화, 개발, 사업화라고 하며, 기업혁신을 위해서는 이 같은 주요 개념과 경영 전반을 일치하는 노력이 필요하다고 하였다. 같은 맥락에서 국제기관 OCED(2018)는 기술혁신을 발휘하기 위하여 기업이 수행하는 모든 개발, 재무, 거래 활동과 비즈니스 혁신을 위한 사업 과정 또는 그 조합을 나타낸다고 하였고, ISO(2019)는 ISO 56002라는 혁신관리시스템 표준지침¹⁾ 발표를 통해 기업혁신의 과업 구조를 제안하였다. ISO 56002에서는 기업혁신과 관련된 제품, 서비스, 공정, 비즈니스 모형, 급진적/점진적 혁신의 지침을 제공하고 있을 뿐만 아니라 사용자, 시장, 기술 및 설계 중심의 혁신활동도 포함하고 있다. 다시 말해, 기업에서 혁신은 이전과는 다른 기술, 제품, 서비스, 관행 등으로 인한 조직변화를 의미하며, 순환적인 행태를 통해 전사적인 차원에서 영향을 미치는 것이다.

1) 혁신관리시스템 표준은 혁신 관리 시스템의 성공적인 구현, 유지 보수 및 지속적인 개선을 위하여 유형, 부문, 규모와 관계없이 모든 조직에 일반적인 체제를 제공하기 위해 고안된 포괄적인 표준 과정이다.

2.2 기업혁신의 유형화

기업혁신의 복잡성과 다차원성에 관한 논의는 혁신의 유형과 범위를 설정하는 것에도 영향을 미친다(Saunila, 2019; Berger, 2021). 대표적인 연구로 Knight(1967)는 혁신을 유형화한 초창기 연구에서 혁신을 제품과 서비스, 제품공정, 조직구조, 사람의 4가지 범주로 제안하였다. 제품/서비스는 신제품 또는 새로운 서비스 제공과 관련된 것이고, 제품공정은 기술 발전에 기인하여 물리적이거나 서비스적인 차원에서 조직 운영과 생산 방식을 변화시키는 것을 말한다. 조직구조는 권한, 상호작용, 공식적 보상의 변화와 관련된 것을 의미하며, 사람은 조직 내 직접적인 변화를 일으키는 고용, 해고, 그리고 행동과 신념을 변화시킬 수 있는 교육, 심리와 관련된 것이다. 이후 이 연구는 혁신을 이분법적으로 구분하는 기초자료로 활용되었다.

혁신을 이분법적으로 유형화한 연구로서 Utterback and Abernathy(1975)는 제품혁신과 공정혁신을 중심으로 기업의 경쟁우위를 설명하였고, Damanpour and Evan(1984)은 경영적인 측면과 기술적인 측면으로 구분한 관리혁신과 기술혁신을 연구하였다. Dewar and Dutton(1986)은 변화 속도의 정도와 새로움에 기초하여 급진적 혁신과 점진적 혁신을 고찰하였으며, 이와 유사한 맥락에서 Benner and Tushman(2002)은 새로운 지식 발굴과 기존 지식의 활용이라는 측면에서 탐색적 혁신과 활용적 혁신으로 구분하였다. 또한, Cooper(1998)는 이분법적인 접근보다는 혁신의 입체성을 강조하였으며, 기업혁신에는 관리혁신과 기술혁

신, 제품혁신과 공정혁신, 급진적 혁신과 점진적 혁신이 상호 관련되어 있다고 주장하였다.

이후 연구에서는 기업혁신이 비즈니스 전반에 영향을 미친다는 것이 학자들 사이에 보편적으로 받아들여졌고, 기업혁신의 유형은 제품, 공정, 조직, 마케팅으로 구분하였다(OECD, 2005). 제품혁신은 기본적인 기술과 방법에 상당한 변화를 수반하여 새로운 제품, 새로운 시장을 창출하거나 기존 제품, 방법 또는 관행의 변화, 기존의 방법과 기술로 이루어진 사소한 개선까지 포함하는 것을 의미한다. 공정혁신은 운영 방식이나 수행 방식을 변경하거나 개선하면서 나타나는 제품이나 서비스의 긍정적인 변화를 의미하며(Forés and Camisón, 2016), 조직혁신은 비즈니스 관행, 업무 책임의 분배, 대외 관계의 긍정적인 변화 유무를 의미하고, 마케팅혁신은 시장에 접근하고 효과적으로 커뮤니케이션 채널을 사용하고, 잠재 고객이나 기존 고객을 사로잡기 위한 제품과 서비스를 제공하는 기업의 능력을 의미한다(Lee et al., 2019).

한편, 최근 기업혁신 유형은 비기술적인 영역이 강조된다(Berger, 2021; Skarea and PORADA-ROCHON, 2021). Rowley et al.(2011)은 1) 제품혁신은 제품, 서비스뿐만 아니라 이것들이 혼합된 하이브리드 형태가 나타난다고 하였고 2) 공정혁신은 기술적이고 조직적인 특성이 있으며 관리, 기술, 생산, 조직, 비즈니스 시스템의 영역에서 발생할 수 있다고 하였다. 3) 포지셔닝혁신은 제품의 구성이나 가능성에 큰 영향을 미치지 않지만, 잠재적인 고객 또는 대상으로 선정된 시장 부문에서 유의미한 제품을 의미한다고 하였다. 포지셔닝혁신은 제품에 대한 고객의 관점이나 이해를 변화

시키는 데 목적이 있으며, 시장의 특성을 변화시키거나 존재하지 않는 시장을 창출하는 것이다. 4) 패러다임 혁신이 나타나 전통적인 믿음 체계가 새로운 패러다임으로 대체되고 있다는 점을 제안하였다(Barrena-Martínez et al., 2020). 사물을 바라보는 방식이 재구성될 때 조직과 산업에 중대한 변화가 나타난다는 점을 강조한 것이다. 유사한 연구로 Tidd and Bessant(2018)는 제품혁신, 공정혁신, 포지션 혁신, 패러다임 혁신을 제안한 바 있다. 제품혁신은 조직이 제공하는 제품/서비스의 변화를 의미하고, 공정혁신은 생산 및 제공 방식의 변화이며, 포지션 혁신은 제품/서비스가 도입되는 흐름의 변화를 나타낸다. 패러다임 혁신은 조직의 활동을 구성하는 기본 정신 모형이 변화되는 것을 의미한다. 또한, OECD(2018)는 오슬로 매뉴얼 제4판을 발행하며, 이전 3판까지 핵심적으로 다뤄졌던 기술혁신(제품, 공정), 비기술혁신(마케팅, 조직)에 ‘경영혁신, 비즈니스 과정 및 비즈니스 모델 혁신’을 포함하여 기업혁신의 범위를 확장하였다. 다시 말해, 시대적 변화에 따라 기업혁신에서 비기술적인 영역이 더욱 강조되고 있다는 점을 반영한 것이다.

2.3 기업혁신과 경영성과

기업혁신과 경영성과의 관계를 밝힌 이전 연구에서 기업혁신은 혁신활동과 혁신역량이라는 구조적인 관계가 형성되어 있고(Geldes et al., 2017; Saunila, 2019), 기업혁신은 경영성과의 선행 역할을 한다고 알려져 있다(양울민 등, 2017; Ferreira et al., 2020). 여기서 혁신활동은 제품, 공정, 조직, 마케팅에서의 새로운 시도 및

도입과 함께 내외부 R&D 활동, 지식 획득, 유무형 자산의 획득 및 활용, 기술 정보 원천 등 기업변화를 이끄는 일련의 활동이 모두 포함된다(Geldes et al., 2017; 황정재 등, 2018). 혁신활동과 혁신역량에 있어서 Kafetzopoulos and Psomas(2015)는 혁신역량은 제품, 공정, 마케팅, 조직으로 구성되고 조직 운영과 제품 품질을 증진하는 것에 긍정적인 영향을 미치며, 혁신역량은 경영성과에 직접적인 영향을 미친다고 주장하였다. 양울민 등(2017)은 혁신활동(내부R&D, 외부R&D, 공동R&D)이 기술혁신성과(제품혁신 및 공정혁신) 및 재무성과에 영향을 미친다는 것을 실증적으로 규명하였다. 또한, Ho(2011)는 기술 중심 기업의 기업혁신 영역은 기술, 마케팅, 경영으로 구분될 수 있으며, 이와 같은 기업혁신이 재무성과와 시장성과에 긍정적인 영향이 있다는 것을 밝혔고, Yam et al.(2011)은 제조업에서 학습, 자원할당, 조직역량, 전략계획과 같은 비기술적 혁신이 매출이라는 경영성과에 긍정적으로 작용한다는 것을 증명하였다.

또한, Frank et al.(2016)은 혁신자원의 투입과 결과에 관한 분석을 수행하였다. 주요 혁신자원은 내부 R&D 활동, 외부 R&D 획득, 외부 지식 획득, 소프트웨어 획득, 기계 및 장비 획득, 교육, 사업화 및 제품출시 활동, 산업사업 및 기타 기술 준비이고, 혁신 결과물은 제품 품질 개선, 제품의 다양성, 시장점유율 유지 및 확대, 신시장 개척, 생산능력 확대, 생산 유연성 확대, 생산비 절감, 작업 원가 절감, 자원 소비량 감소, 에너지 소비량 감소, 물 소비량 감소, 보건 및 안전 위험 감소, 환경문제 감소, 보건 및 안전 제어 확대, 내부 시장 법률 적합성 등으로

로, 시장 지향적인 전략이 혁신 결과에 긍정적인 영향이 있으나 기술 획득 전략은 혁신 결과에 부정적인 영향이 있다는 분석 결과를 도출하였다(안경민, 2021).

선행연구를 요약하면, 혁신활동이 늘어나면 신제품 출시, 공정혁신, 특허출원과 같은 혁신의 성과가 늘어나고, 혁신성과는 기업의 운영성과를 높이며, 운영성과는 매출성장률을 향상시킬 수 있는 매커니즘이 형성된다는 것을 알 수 있다.

Ⅲ. 연구방법

3.1 앙상블 학습

머신러닝은 학습 데이터 의존도에 따라 지도 학습과 비지도 학습으로 분류된다. 지도 학습은 입력값에 대한 정답(label)을 사전에 학습시킨 후 새로운 입력값이 주어졌을 때 미리 학습된 데이터를 통하여 결과를 예측하는 방법이다. 비지도 학습은 미분류 데이터가 활용되며, 클러스터링 구조(clustering structure), 저차원 다양체(low-dimensional manifold), 회소 트리 및 그래프(a sparse tree and graph) 등과 같은 데이터의 고유 패턴을 발견하도록 설정된다(안경민, 2021). 본 연구에 사용된 자료는 지도 학습에 적합한 형태로 구성되어 있다. 또한, 예측성능의 비교모델로 사용한 전통적인 머신러닝 알고리즘은 로지스틱 회귀, 의사결정 나무, 랜덤 포레스트, K-근접 이웃으로 한정하였다. 여기에서 랜덤 포레스트는 앙상블 학습의 전통적인 방법이다.

본 연구에서 예측성능 평가에 사용되는 XGboost, LightGBM, Catboost 기법들은 앙상블 학습이라고 부른다. 앙상블 학습은 약한 학습자를 활용하여 강한 학습자를 만드는 것으로 적당한 예측력을 가진 하나의 모형을 사용하기 보다는 여러 모형을 조합하는 것이 더 좋은 결과를 도출할 수 있다는 것에 기반한다. 앙상블 학습에서 약한 학습자는 예측 정확도가 낮은 모형을 의미하고 강한 학습자는 예측 정확도가 높은 모형을 의미한다. 앙상블 학습에는 분류, 회귀, 순위 등에서 보다 진보된 방법이 포함되며, 전처리, 데이터 스트림 학습, 이상 징후 탐지와 같은 분석 과제를 처리하기 용이하다고 알려져 있다(Siroky, 2009). 대표적인 앙상블 학습으로 보팅(voting), 배깅(bagging), 스택킹(stacking), 부스팅(boosting) 등이 있다. 보팅은 새로운 자료에 대해 분류기 예측값들의 가중 투표(weighted vote)를 통해 분류를 수행한다. 배깅은 병렬 형태로 학습시키는 형태로 여러 개의 부트스트랩을 생성하고 각각 부트스트랩 별로 모형화한다. 스택킹은 같은 학습 알고리즘을 사용하는 앙상블과 달리, 서로 다른 모형을 결합하여 새로운 모형을 만들어 내는 방법이다. 부스팅은 약한 학습 데이터를 강한 학습 데이터로 변환시켜 오차를 교정하는 과정을 반복하면서 예측모형의 정확도 향상하는 기법으로, 순차적으로 학습을 시키는 형태를 취한다(Cremer and Freund, 2010). 부스팅은 매 반복 학습마다 잘못 분류된 관측치의 가중치는 더 부여하고 맞게 분류된 관측치의 가중치는 줄여 예측모형을 만든다. 즉, 기본 분류기가 분류하기 어려운 사례에 집중하도록 훈련 예제들의 분포를 변경시키는 데 사용되는 반복적인 절차

이다.

3.1.1 XGboost

XGboost(extreme gradient boosting)는 GBM(gradient boosting machine)²⁾ 기반의 알고리즘이다(Chen and Guestrin, 2016). XGboost는 복수의 분류기 가운데 예측력이 상대적으로 약한 분류기들을 결합하여 예측력이 상대적으로 높은 분류기로 바꿈으로써 전체 모형 내 분산을 줄이고, 예측력을 높인다. 이론적으로 학습 손실을 최소화하고 과적합을 줄이기 위해 의사결정나무의 복잡도를 통제하면서 가장 최적의 모형을 만들며, 분류기준으로는 불순도 척도인 지니계수를 사용한다. 약한 분류기를 개선해 나가는 과정에서는 탐욕적 알고리즘(greedy algorithm)³⁾을 사용하여 분류 모형을 발견하고 분산처리를 통해 최적의 비중을 계산한다.

XGboost에서 사용되는 양상블 모형은 CART(classification and regression tree)로 범주형, 연속형 모두 학습이 가능하며, 모든 잎(leaf)이 모형의 최종 점수에 연관되어 있어 분류 결과를 가지는 의사결정나무 모형끼리 우위를 비교할 수 있다. 분석 단계는 1) 생성된 트리 분류기들은 정확도 스코어를 측정하고, 2) 각 순서에 따라 강한 분류기에서 약한 분류기까지

무작위로 생성한다. 그 후, 3) 순차적으로 개선에 나가며, 강력한 트리 분류기를 생성한다. XGboost는 학습 시에 파라미터로 지정한 max_depth까지 진행한 후, 손실 함수의 개선값이 일정 수준에 미치지 못하면 역방향으로 가지치기 과정을 진행한다(Chen and Guestrin, 2016). 이 과정에서 트리 분류기의 불필요한 부분을 제거하는 가지치기를 통해 모형의 과적합⁴⁾을 사전에 방지할 수 있다.

3.1.2 LightGBM

LightGBM(light gradient boosting machine)은 XGboost의 한계점을 보완하고자 microsoft에서 개발한 모형으로 잎 분할(leaf-wise) 방식을 사용하여 정확도가 높은 모형을 만든다(Kee et al., 2017). 사용되는 histogram-based 알고리즘은 학습 속도를 높이기 위해 시스템 개선사항을 포함하고 있다. 그리고 개별 데이터의 차원 수를 줄이기 위해 다양한 알고리즘을 적용한 gradient boosting 의사결정나무 양상블 학습을 사용한다. 이 기법에서는 의사결정나무의 노드들이 뿌리 노드와 가까운 노드를 우선 순회하고 수평 성장하는 레벨 분할 방식(level wise, depth-first)을 사용한다. 즉, 동일한 잎을 성장시킬 때 더 큰 손실을 줄일 수 있다는 것을 가정하며, 최대 델타 손실(max delta loss)이 큰 노드

- 2) 단계별 적층 모형으로서 손실 함수를 반복적으로 계산하여 가장 가파른 하강을 최소화한 경사하강법을 통해 모형을 생성하며, 예측 함수는 함수 공간의 수치 최적화를 통해 추정한다(Natekin and Knoll, 2013).
- 3) 탐욕 알고리즘은 최적해를 구하는 데에 사용되는 근사적인 방법으로, 여러 경우 중 하나를 결정해야 할 때마다 그 순간에 최적이라고 생각되는 것을 선택해 나가는 방식으로 진행하여 최종적인 해답에 도달한다.
- 4) 과적합(overfitting)은 기계 학습(machine learning)에서 학습 데이터를 과하게 학습하는 것을 뜻한다. 일반적으로 학습 데이터는 실제 데이터의 부분 집합이므로 학습 데이터에 대해서는 오차가 감소하지만 실제 데이터에 대해서는 오차가 증가하게 된다.

에서 분할하여 수직 성장하는 분할 방식을 사용한다.

LightGBM에서 사용되는 고유한 방법으로 GOSS(gradient-based one-side sampling)⁵⁾와 EFB(exclusive feature bundling)⁶⁾은 샘플과 feature를 줄이는 것이다. GOSS는 훈련 집합의 기울기가 안내하는 언더 샘플링(under-sampling)⁷⁾ 기법으로 절대값에서 기울기가 큰 표본이 학습에 더 많은 기여가 있다는 것을 고려하며, 기울기가 작은 데이터의 경우 일정 확률로 무작위 제거된다.

3.1.3 Catboost

Catboost(category boosting)는 Yandex에서 개발한 알고리즘으로 범주형 변수와 과적합을 처리하는 데 유용한 기법이다(Dorogush et al., 2018). Catboost 알고리즘에서 순차적 부스팅(ordered Boosting)은 $t-1$ 까지는 순열 관찰값(permutated observation)을 이용하여 $t-1$ 번째 모델을 학습한다. t 번째 데이터를 $t-1$ 번째 모델로 예측하여 t 와 실제값 y 를 비교한 $r^t(x_t, y_t)$ 의 잔차가 산출되며, 이와 같은 과정을 반복하면서 gradient가 개선된다. 즉, 정보

획득량이 동일한 여러 속성을 하나의 속성으로 묶어 버림으로써, 범주형 변수들을 효과적으로 알고리즘 연산에 반영할 수 있게 설계되었다. 또한, 순차적 부스팅에서 같은 순서로 계산이 지속되는 경우 예측력의 문제가 발생할 수 있다. 이러한 문제를 감안하여 자동으로 섞임(shuffle)이 이뤄지는 구조로 되어있으며, 일부를 선택하는 기능도 포함하고 있다. 또한, 알고리즘 자체적으로 하이퍼 파라미터를 최적화할 수 있어서 조정 절차가 최소화된다는 특징을 가진다.

3.2 예측모형 성능평가

예측모형을 평가하는 방법에서 주로 고려해야 할 사항은 예측력, 해석력, 효율성, 안정성이다⁸⁾. 그중에서 예측 문제를 도출하는데 가장 중요한 고려 사항은 예측력이다. 모형이 안정적이고 효율적이며 해석할 수 있다 하더라도 실제 문제에 적용했을 경우 빗나간 결과를 도출하는 경우 모형이 의미를 가지기 어렵다. 머신러닝 분류기법의 예측력을 평가하는 대표적 지표는 ROC(receiver operating characteristic) 곡선이다. ROC 곡선은 여러 절단 값에서의 민감도와

- 5) 가장 큰 그래데이션으로 자료의 fixed $a\%$ 를 고정하고 나머지 자료에서 무작위로 $b\% * N$ 에 도달할 때까지 유지한다. 데이터 분포를 유지하기 위해 작은 그래데이션으로 표본의 비율은 $\frac{1-a}{b}$ 로 조정한다. 이 방법은 사례의 수를 효과적으로 줄여 학습 시간을 단축할 수 있으며, 전체적인 성능을 향상시킨다.
- 6) EFB는 실제 문제에서 흔히 볼 수 있는 것으로 데이터가 고차원, 고도로 희소한(Sparse) 형상 공간을 이루고 있는 경우 독립변수를 더 적은 개수로 줄이는 방법이다.
- 7) 다수 범주의 집합 S_{major} 에서 무작위로 데이터를 추출하여 $|E| < |S|$ 를 만족하는 집합 E를 만든 뒤 이를 기존 집합 S에서 제거하는 방식이다. 집합 S의 크기는 집합 E의 크기, $|E|$ 만큼 줄어들게 된다. 데이터의 크기가 매우 클 때 효과적이지만 데이터 일부를 버림으로써 정보가 손실된다는 단점이 있다(김경민 등, 2014).
- 8) 예측력은 예측을 잘하는가를 의미하고 해석력은 입력변수와 출력변수와의 관계를 잘 설명하는가를 설명한다. 또한, 효율성은 얼마나 적은 수의 입력변수로 모형을 구축했는가를 의미하며 안정성은 모 집단 내 다른 자료에 적용하는 경우 같은 결과를 주는가를 말한다.

특이도의 관계를 보여주며, 절단 값의 변화를 통해 분류기의 성능을 시각적으로 확인할 수 있다. 하지만 ROC 곡선은 분류기의 예측력을 비교하는 것에 한계가 있다. 따라서 성능값을 도출하는 것은 ROC 곡선 아래의 면적을 산출한 AUC(area-under the curve)가 사용된다. AUC 값을 보완하는 분류 예측모형 평가 방법은 <표 1>의 실제값과 예측값의 혼용행렬(confusion matrix)을 재가공한 값인 정확도(accuracy) 정밀도(precision), 재현율(recall), 민감도(sensitivity), 그리고 F-Score 등이다.

정확도는 전체 중에서 정확하게 맞춘 비율로 알고리즘의 전체적 성능으로 정밀도는 실제값

이 false인 관측치 중 예측치가 적중한 정도이고, 재현율은 실제값이 true인 관측치 중 예측치가 적중한 정도이며, 민감도는 실제값이 false인 관측치 중 예측치가 적중한 정도이다. F-Score는 불균형적인 자료에 적합한 평가 지표로 정밀성과 민감도를 활용하여 산정할 수 있고, 일반적으로 β 는 1로 표기한다. 산출식은 <표 2>에 제시하였다. 머신러닝 회귀기법을 평가하는 지표로는 MAE(mean square error), MSE(mean squared error), RMSE(root mean squared error) 등이 있으며, 낮은 값을 가질수록 높은 정밀도를 갖는다. 산출식은 <표 3>에 제시하였다.

<표 1> 혼용행렬

구분		실제값	
		True(1)	False(0)
예측값	True(1)	true positive	false positive
	False(0)	false negative	true negative

<표 2> 분류모형 평가지표

평가지표	산출식	평가지표	산출식
Accuracy	$\frac{TP+TN}{TP+FN+FP+TN}$	Precision	$\frac{TP}{TP+FP}$
Recall	$\frac{TP}{TP+FN}$	Sensitivity	$\frac{TN}{TN+FP}$
F-Score ⁹⁾	$\frac{(1+\beta^2)(Prec \times Sens.)}{(\beta^2 Prec + Sens.)}$		

<표 3> 회귀모형 평가지표

평가지표	산출식	평가지표	산출식	평가지표	산출식
MAE	$\frac{1}{n} \sum_{i=1}^n Y_i - \hat{Y}_i $	MSE	$\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$	RMSE	$\sqrt{\frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{n}}$

9) F-Score는 불균형적인 자료에 적합한 평가지표로 정밀성과 민감도를 활용하여 을 산정할 수 있다. 일반적으로 β 는 1로 표기한다.

IV. 분석결과

4.1 조작적 정의 및 측정항목

본 연구는 한국기업혁신조사(제조업)를 활용하여 <표 4>와 같이 머신러닝 분석에 적절하도록 전처리하였다(조가원 등, 2018). 한국기업혁신조사는 통계청 승인 자료로 기업혁신을 체계화한 오슬로 매뉴얼(1992)을 근거로 개발되었다. 이 조사는 한국의 기술혁신활동을 파악하는 기초자료로 기업의 일반현황뿐만 아니라 기업 혁신과 관련된 특허수, R&D 연구 지출액, 매출액 중 혁신제품의 비중 등이 포함되어 있다. 이 조사의 모집단은 해당연도 기업 활동을 수행한 상시 근로자수 10인 이상의 업체를 대상으로 하며 다단계 층화계통법으로 표본을 추출한다. 독립변수에는 기업의 혁신활동인 공정혁신, 조직혁신, 마케팅혁신, 탐색적혁신, 활용적혁신과 R&D 활동인 내부 R&D, 공동 R&D, 외부 R&D, R&D 인력, 지적재산권 등이 포함되고 종속변수에는 혁신성과인 급진적 혁신성과, 점진적 혁신성과, 경영성과가 포함된다.

구체적으로, 혁신활동 중 공정혁신은 운영 방식이나 수행 방식을 변경하거나 개선하면서 나타나는 제품이나 서비스의 긍정적인 변화라고 정의하였으며, 3개의 문항으로 측정하였다(Knight, 1967). 조직혁신은 비즈니스 관행, 업무 책임의 분배, 대외 관계의 긍정적인 변화라고 정의하였으며, 3개 문항으로 측정하였다(OECD, 2005). 마케팅혁신은 시장 접근, 효과적인 커뮤니케이션 채널 사용, 잠재적 고객이나 기존 고객을 사로잡기 위한 긍정적인 변화이라고 정의하였으며, 4개 항목으로 측정하였다

(Lee et al., 2019). 탐색적혁신은 새로운 지식을 발굴하거나 기존에 조직에서 보유하고 있는 기술과 상이한 기술의 탐색 및 개발이라고 정의하고 2개 항목으로 측정하였으며, 활용적혁신은 기존 기술에 기반을 두어 새롭게 기술을 개선하는 혁신으로 정의하여 3개 항목으로 측정하였다.

R&D 활동은 내부 R&D, 공동 R&D, 외부 R&D, R&D 인력의 4개 변수로 도출하였으며, 각각은 다음과 같이 정의된다. 내부 R&D는 기업 내부적으로 새로운 또는 실질적으로 개선된 제품, 공정, 응용 프로그램을 위한 지식 사용과 지식 증가의 모든 창의적인 활동이라고 정의되며, 단일 문항으로 측정되었다(Frank et al., 2016). 공동 R&D는 기업 간 협력을 통해 새로운 지식과 기술들을 창출하고 실현하는 활동이라고 정의하며, 단일 항목으로 측정되었다(최은영, 2015). 외부 R&D는 외부 조직(기업 또는 기술 기관)에 의해 수행된 지식 및 기술 취득 활동이라고 정의되며, 단일 문항으로 측정하였다(Frank et al., 2016). R&D 인력은 기술혁신에 필요한 지식과 기술을 가지고 있는 조직 구성원 비율로 정의하였으며(Kianto et al., 2017), 지적재산권은 법률적이고 제도적인 보호 방법으로 지적 재산권의 보호로 정의하였다(Frank et al., 2016)

본 논문에서 도출하고자 하는 궁극적인 결과는 기업의 혁신활동이 혁신성과와 경영성과를 얼마나 잘 예측할 수 있는가이다. 따라서 본 연구에서는 기업의 혁신을 급진적 혁신성과와 점진적 혁신성과로 구분하여 각각 정의하였으며, 더 나아가 기업의 경영성과를 고려하였다. 급진적 혁신성과는 기본적인 기술과 방법에 상당한

변화를 수반하는 새로운 제품, 새로운 시장 창출로 정의되며, 점진적 혁신성과는 기존 제품, 방법 또는 관행의 변화, 일반적으로 기존의 방법과 기술로 이루어진 사소한 개선으로 정의된다(Lee et al., 2019). 또한, 경영성과는 지난 3년간 달성한 매출로 측정하였다(이성희, 이원희, 2017).

4.2 일반현황 분석

본 연구에서는 2018년 제조업 3,500개 자료를 수집하였고 혁신수준이 낮은 산업인 식료품,

음료, 섬유제품, 의복, 의복 액세서리 및 모피제품, 가죽, 가방 및 신발, 목재 및 나무제품, 펄프, 종이 및 종이제품, 인쇄 및 기록매체, 가구, 코스, 연탄 및 석유정제품, 고무제품 및 플라스틱제품, 비금속 광물제품, 1차 금속, 금속가공제품 등을 제외하고 1,817개의 자료가 최종적으로 활용되었다(Hatzichronoglou, 1997). 머신러닝 분석을 수행하기에 앞서 데이터를 분석에 적합한 형태로 전처리하기 위해 양울민 등(2017), 황정재(2018), Lee et al.(2019)의 연구를 참고하여 직접 전처리하였고 <표 5>와 같이 빈도 분석을 수행하였다.

<표 4> 조작적 정의 및 측정항목

변수	조작적 정의	항목	설 명	min	max	출처	
일반사항	기업의 일반정보	Q1_1	설립년도	1	∞	한국기업혁신조사 (2018)	
		Q1_2	산업분류	20	33		
		Q1_3	기업규모	1	3		
		Q1_4	평균 3년 상시종사자 수	0	∞		
혁신 활동	공정 혁신	PRO_Q1	완전히 새롭거나 크게 개선된 생산 방법	0	1	Knight (1967); Forés and Camisón (2016)	
		PRO_Q2	완전히 새롭거나 크게 개선된 물류, 배송, 분배 방법	0	1		
		PRO_Q3	완전히 새롭거나 크게 개선된 지원 활동	0	1		
	조직 혁신	ORG_Q1	업무수행방식의 변화도입	0	1	OECD (2005)	
		ORG_Q2	업무유연성 및 부서간 통합성 등의 업무수행조직 변화 도입	0	1		
		ORG_Q3	외부조직과의 관계 변화 도입	0	1		
	마케팅 혁신	시장 접근, 효과적인 커뮤니케이션 채널 사용, 잠재적 고객이나 기존 고객을 사로잡기 위한 긍정적인 변화	MI_Q1	제품 심미적 디자인, 포장 등에 커다란 변화	0	1	Lee et al. (2019)
			MI_Q2	제품 촉진을 위한 신규 브랜드 출시, 신개념의 광고매체 및 홍보전략 활용	0	1	
			MI_Q3	제품 진열방식 및 신규 판매채널 등 새로운 판매전략 활용	0	1	
			MI_Q4	제품 가격할인 및 가격차별화 등 새로운 가격방식 활용	0	1	
	탐색적 혁신	새로운 지식을 발굴하거나 기존에 조직에서 보유하고 있는 기술과 상이한 기술의 탐색 및 개발	Exr_Q1	완전히 새로운 제품의 출시 활동	1	4	이도명, 임성준 (2010)
			Exr_Q2	새로운 고객층을 확보 활동	1	4	

	활용적 혁신	기존 기술에 기반을 두어 기술을 새롭게 개선	ExI_Q1	기존 제품의 개선 활동	1	4	이도명, 임성준 (2010)
			ExI_Q2	고객 맞춤형 제품/솔루션 개발 활동	1	4	
			ExI_Q3	가격경쟁력 확보 활동	1	4	
R&D 활동	내부 R&D	기업 내부적으로 새로운 또는 실질적으로 개선된 제품, 공정, 응용 프로그램을 위한 지식 사용과 지식 증가의 모든 창의적인 활동	R&D_Q1	새로운 지식을 생산하거나 과학기술적 문제를 해결하기 위하여 회사 내부에서 수행한 연구개발 활동	0	1	Frank et al.(2016)
	공동 R&D	기업 간 협력을 통해 새로운 지식과 기술들을 창출하고 실현하는 활동	R&D_Q2	내부 R&D와 동일한 목적으로 회사 내부 조직과 타기업 또는 타 기관이 계약을 통해 공동으로 수행한 연구개발 활동	0	1	최은영 (2015)
	외부 R&D	외부 조직(기업 또는 기술 기관)에 의해 수행된 지식 및 기술 취득 활동	R&D_Q3	내부 R&D와 동일한 목적으로 타기업 또는 타기관이 외주계약을 통해 수행한 연구개발 활동	0	1	Frank et al.(2016)
	R&D 인력	기술혁신에 필요한 지식과 기술을 가지고 있는 조직 구성원	R&D_Q4	R&D 인력 비율	0	1	Kianto et al.(2017)
	지적재산권	법률적이고 제도적인 방법으로 보호되는 지적 재산권 수	R&D_Q5	(Log)특허권 출원 건	0	∞	Frank et al.(2016)
혁신 성과	급진적 혁신	기본적인 기술과 방법에 상당한 변화를 수반하는 새로운 제품, 새로운 시장 창출	RAD_Q1	기존 제품과 완전히 다른 신(新)제품 출시	0	1	Lee et al. (2019)
	점진적 혁신	일반적으로 기존의 방법과 기술로 이루어진 사소한 개선	INC_Q1	기존 제품에 비해 크게 개선된 제품 출시	0	1	Lee et al. (2019)
경영성과		지난 3년간 달성한 매출	PER_Q1	(Log)3년 평균 매출	0	∞	OECD (2005)

<표 5> 일반현황 분석결과

		빈도	비율			빈도	비율
산업 유형	화학물질 및 화학제품	142	7.82	설립	10년 미만	144	7.93
	의료용 물질 및 의약품	29	1.60		10-20년 미만	710	39.08
	전자부품, 컴퓨터, 영상, 음향 및 통신장비	298	16.40		20-30년 미만	621	34.18
	의료, 정밀, 광학기기 및 시계	121	6.66		30-40년 미만	205	11.28
	전기장비	228	12.55		40-50년 미만	96	5.28
	기타 기계 및 장비	497	27.35		50년 이상	41	2.26
	자동차 및 트레일러	358	19.70		50인 미만	1021	56.19
	기타 운송장비	106	5.83		50-100명 미만	265	14.58
	기타 제품 제조	38	2.09		100-200명 미만	389	21.41
법정 규모	대기업	52	2.86	상시종사자	200-500명 미만	99	5.45
	중기업	1077	59.27		500명 이상	43	2.37
	소기업	688	37.86		합계	1,489	100.0

활용된 자료의 기술통계는 다음과 같다. 산업유형별로 기타 기계 및 장비 497(27.35%), 자동차 및 트레일러 358(19.7%), 전자부품, 컴퓨터

영상, 음향 및 통신장비 298(16.40%), 전기장비 228(12.55%), 화학물질 및 화학제품 142(7.82%), 의료, 정밀, 광학기기 및 시계 121

(6.66%), 기타 운송장비 106(5.83%), 기타 제품 제조 38(2.09%), 의료용 물질 및 의약품 29(1.60%)의 순으로 나타났다. 기업의 법정규모 별로는 중기업 1,077(59.27%), 소기업 688(37.86%), 대기업 52(2.86%)의 순으로 조사되었다. 설립연도는 10-20년 미만 710(39.08%), 20-30년 미만 621(34.18%), 30-40년 미만 205(11.28%), 10년 미만 144(7.93%), 40-50년 미만 96(5.28%), 50년 이상 41(2.26%)의 순이었고, 상시종사자 수는 50인 미만 1021(56.19%), 100-200명 미만 389(21.41%), 50-100명 미만 265(14.58%), 200-500명 미만 99(5.45%), 500명 이상 43(2.37%)의 순으로 조사되었다.

4.3 신뢰성 분석 및 타당성 분석

머신러닝을 활용의 방법론적인 측면으로 보았을 때, 급진적 혁신성과와 점진적 혁신성과는 각각 이진변수(0, 1)로 측정하여 분류 알고리즘

을 사용한 분석이 적절하며, 경영성과는 비율적으로 측정되었으므로 회귀 알고리즘이 적합하다. 조작적 정의를 거쳐 설계된 설문항목이 유효하게 사용되기 위해서는 설문항목의 타당성 및 신뢰성 분석을 통해 정의된 개념들을 제대로 설명하고 있는지 확인해야 한다. 머신러닝 분석에서 과도한 독립변수를 투입하는 것은 차원의 저주(curse of dimensionality)를 발생시켜 분석의 품질을 저하시킬 수 있다(Wang and Chein, 2006). 따라서 본 연구에서는 각 변수의 수용 여부를 확인하고 측정항목의 타당성을 검증하기 위해 확인적 요인분석을 수행하였다. 그 결과 측정문항은 <표 6>과 같이 활용역량(EXR), 탐색역량(EXL), 조직혁신(PRCI), 공정혁신(OI), 마케팅혁신(MI) 등 5개의 요인으로 수렴되었다. 집중타당도 분석은 표준화요인부하량값 0.5이상, AVE 0.5이상, CR 0.7 이상을 확인하였다. 모든 변수가 표준화 요인부하량값과 AVE의 기준치 이상을 나타냈으나 활용역량(EXR, 0.670)과 공정혁신(OI, 0.670)이 CR의

<표 6> 신뢰성 및 타당성 분석결과

연구변수		측정문항	표준화요인부하량	S.E	AVE	C.R	Cronbach's alpha
활용적혁신	EXR	Exr_Q2	0.775	0.399	0.506	0.670	.663
		Exr_Q1	0.642	0.588			
탐색적혁신	EXL	Exl_Q2	0.711	0.494	0.574	0.728	.724
		Exl_Q3	0.801	0.358			
조직혁신	PRCI	Prci_Q3	0.592	0.650	0.532	0.769	.757
		Prci_Q2	0.868	0.247			
		Prci_Q1	0.701	0.509			
공정혁신	OI	Oi_Q3	0.726	0.473	0.504	0.670	.660
		Oi_Q2	0.693	0.520			
마케팅혁신	MI	Mi_Q1	0.668	0.554	0.568	0.839	.738
		Mi_Q2	0.773	0.402			
		Mi_Q3	0.815	0.336			
		Mi_Q4	0.750	0.438			

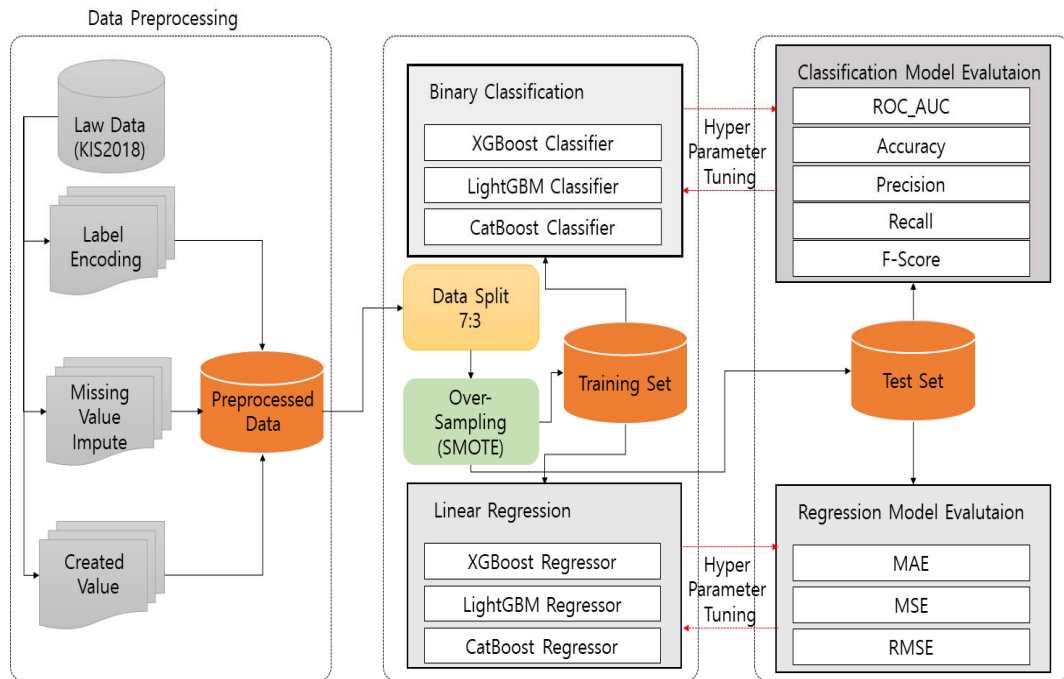
<표 7> 상관관계 분석결과

변수	평균	표준편차	1	2	3	4	5	6	7	8	9	10	11	12	13
EXR	3.032	0.703													
EXL	3.292	0.605	.587**												
OI	0.224	0.356	.276**	.160**											
PRCI	0.083	0.226	.205**	.095**	.379**										
MI	0.155	0.296	.250**	.104**	.588**	.235**									
R&D_Q1	0.420	0.494	.390**	.321**	.330**	.329**	.279**								
R&D_Q2	0.124	0.329	.209**	.170**	.249**	.193**	.188**	.411**							
R&D_Q3	0.102	0.303	.148**	.178**	.244**	.225**	.199**	.375**	.568**						
R&D_Q4	0.196	0.389	.104**	.117**	.111**	.210**	-.018	.245**	.286**	.266**					
R&D_Q5	0.712	0.566	.223**	.144**	.145**	.121**	.122**	.461**	.233**	.215**	.313**				
RAD_Q1	0.107	0.310	.207**	.048*	.152**	.364**	.123**	.357**	.183**	.176**	.189**	.209**			
INC_Q1	0.217	0.412	.228**	.101**	.279**	.401**	.201**	.470**	.285**	.219**	.248**	.238**	.465**		
SR_Q1	0.063	0.286	.015	-.004	-.001	.009	.028	.032	.072**	.039	.065**	.063**	.025	.020	

기준값에 다소 미치지 못하였다. 하지만 집중타당도와 AVE값이 기준값을 충족하고 CR의 기준값에 근소한 차이만 나타나 분석자료에는 포함하였다. 신뢰성 분석은 내적일관성 계수인 cronbach's α 로 확인하였으며 활용역량(EXR, 0.663)과 공정혁신(OI, 0.660)이 임계치인 0.7에 가까운 것으로 나타났다(Hair et al., 2006). 모든 변수들 간 상관관계를 분석한 결과 <표 7>과 같이 각 변수 간 유의함을 보였으나 pearson 상관계수는 낮게 나타났다.

한편, 머신러닝을 활용의 방법론적인 측면으로 보았을 때, 급진적 혁신성과와 점진적 혁신성과는 각각 이진변수(0, 1)로 측정되어 분류 알고리즘을 사용한 분석이 적절하며, 경영성과는 비율척도로 측정되고 있으므로 회귀 알고리즘이 적합하다. 또한, 결과변수인 급진적 혁신성과(‘아니요=1,622개’, ‘예=195개’)와 점진적 혁신성과(‘아니요=1271’, ‘예=546)는 데이터 불균형이 나타난다. 기업 상황을 고려해 봤을

때, 많은 기업에서 혁신을 추구하고 있지만, 환경의 급변성, 예산 및 인력의 부족, 기술 부재 등 현실적인 문제로 인해 실제로는 혁신적인 제품을 개발하기가 쉽지 않다. 따라서 기업혁신 여부를 단순 비교하였을 때는 상당한 차이가 나타난다. 이처럼 소수 데이터 집단과 다수 데이터 집단을 같이 분석하는 경우 데이터 불균형이 발생하게 되며, 데이터 불균형은 분석의 오류를 발생시킨다(Zhou, 2013). 이를 해결하기 위해 오버샘플링 기법인 SMOTE(synthetic minority over-sampling technique)을 사용하여 초기 데이터에서 나타나는 불균형 상태에서부터 표본비율을 일치시켰다. 오버샘플링은 다수 데이터의 표본을 기준으로 소수 데이터의 중복을 발생시켜 그 양을 늘리는 방법이며, 소수 데이터의 크기가 매우 작을 때 효과적이다(Zhou, 2013). 또한, 알고리즘에 따른 분석결과가 다를 수 있다는 점을 고려하여 코딩하는 과정에서 알고리즘을 재검점하는 과정을 여러 차례 수행



<그림 1> 머신러닝 분석과정

하였다. 머신러닝 앙상블 학습의 전반적인 내용은 <그림 1>과 같이 도식화하였다.

4.4 머신러닝 분석

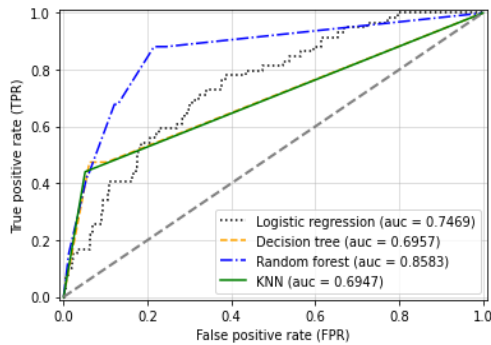
4.4.1 전통적인 머신러닝 예측성능 평가 결과

기업의 혁신활동과 혁신성과를 예측하기 위해 훈련 데이터와 검증 데이터를 7:3 비율로 나누었다. 이진변수를 예측하기에 적합한 전통적인 머신러닝은 로지스틱 회귀분석, 의사결정나무, 랜덤 포레스트, K-최근접 이웃이다.


머신러닝은 파라미터 설정에 따라 결과값이 상이하게 나타날 수 있다. 따라서 동일한 수준에서 결과값이 도출될 수 있도록 가장 기본적인 값으로 파라미터를 설정하여 ROC-AUC 값을 비교분석을 하였다. 설정된 파라미터는 로지

스틱 회귀분석은 solver='liblinear', penalty='l2', C=0.01, random_state=2040, 의사결정나무는 criterion='gini', random_state=2040, K-최근접 이웃은 n_neighbors=1, p=2, metric='minkowski'이다.

분석 결과, 전통적인 머신러닝 방법으로 급진적 혁신성과와 점진적 혁신성과의 예측모형을 분석한 결과, 급진적 혁신성과의 ROC-AUC 값은 <그림 2>와 같이 랜덤 포레스트 0.8583, 로지스틱 회귀 0.7469, 의사결정나무 0.6957, K-최근접 이웃 0.6947 순으로 나타났으며, 랜덤 포레스트가 가장 우수한 예측력을 보였다. 점진적 혁신성과의 예측모형을 분석한 ROC-AUC 값은 <그림 3>과 같이 랜덤 포레스트 0.8430, 로지스틱 회귀분석 0.8092, 의사결정나무 0.7387, K-최근접 이웃 0.7174 순으로 나타



<그림 2> 전통적 머신러닝 급진적 혁신성과 ROC_AUC 비교분석 결과



<그림 3> 전통적 머신러닝 점진적 혁신성과 ROC_AUC 비교분석 결과

났다. 급진적 혁신성과와 마찬가지로 랜덤 포레스트가 가장 우수한 예측력을 보였다. 이 같은 전통적인 머신러닝 기법을 비교해 본 결과, 본 자료를 예측하는 것에는 앙상블 학습이 적합하다는 것을 도출할 수 있다.

4.4.2 급진적 혁신성과 예측분석 성능평가 결과

머신러닝에서 하이퍼 파라미터는 분석 결과에 직접적인 영향을 미치는 것으로 최적화된 하이퍼 파라미터를 설정하기 위해서는 조정(tuning)이 요구된다. 머신러닝은 자동으로 최적화된 하이퍼 파라미터를 제시해 주고 있으나 더 나은 성능을 위해서는 연구자의 개입이 요구된다(Yang and Shami, 2020). 이 같은 결과, 혁신성과인 급진적 혁신성과가 점진적 혁신성과의 예측성능을 평가하기 위해 하이퍼 파라미터를 <표 8>과 같이 설정하였다. XGboost는 max_depth=3, learning_rate=0.05, objective=binary: logistic, eval_metric=logloss, min_child_weight=3, subsample=0.5, random_state=2020으로 설정하였다. LightGBM은 n_

estimators=5000, eval_metric=error, max_depth=15, num_leaves=50, subsample=0.5, learning_rate=0.05, min_child_samples=30으로 설정하였다. Catboost는 n_estimators=5000, eval_metric=AUC, loss_function=Logloss, depth=8, l2_leaf_reg=6, learning_rate=0.05, leaf_estimation_iterations=8, use_best_model=True, random_state=2020으로 설정하였다.

급진적 혁신성과의 예측모형을 분석한 결과 <표 9>와 같이 XGboost 알고리즘의 예측성능은 ROC_AUC 97.69%, 분류 정확도 93.02%, 정밀도 94.48%, 재현율 91.38%, F1 score 92.90%로 각각 나타났고, LightGBM 알고리즘의 예측성능은 ROC_AUC 98.54%, 분류 정확도 93.94%, 정밀도 94.03%, 재현율 93.84%, F1 score 93.94%로 각각 나타났다. 그리고 Catboost 알고리즘의 예측성능은 ROC_AUC 97.90%, 분류 정확도 90.97%, 정밀도 93.28%, 재현율 88.30%, F1 score 90.72%로 각각 나타났다. 종합적으로 판단할 때 급진적 혁신성과를 예측하는 데 LightGBM 알고리즘이 좀 더 나은 예측력을 보인다는 점을 확인할 수 있었다.

<표 8> 혁신성과 하이퍼 파라미터 설정

구분	Hyper parameter	Value
XGboost	max_depth	3
	learning_rate	0.05
	objective	binary:logistic
	eval_metric	logloss
	min_child_weight	3
	subsample	0.5
	random_state	2020
LightGBM	n_estimators	5000
	eval_metric	error
	max_depth	15
	num_leaves	50
	subsample	0.5
	learning_rate	0.05
	min_child_samples	30
	random_state	2020
Catboost	n_estimators	5000
	eval_metric	AUC
	loss_function	Logloss
	depth	8
	l2_leaf_reg	6
	learning_rate	0.05
	leaf_estimation_iterations	8
	use_best_model	True
	random_state	2020


<표 9> 급진적 혁신성과 예측 성능평가

구분	ROC_AUC	정확도	정밀도	재현율	F1 score
XGboost	0.9769	0.9302	0.9448	0.9138	0.9290
LightGBM	0.9854	0.9394	0.9403	0.9384	0.9394
Catboost	0.9790	0.9097	0.9328	0.8830	0.9072


급진적 혁신성과의 예측모형에서 변수의 중요도는 각각 다음과 같은 순으로 나타났다. XGboost 분류 알고리즘을 적용한 예측모형에서 변수의 중요도는 <그림 7>과 같이 R&D_Q5(지적재산권)=6152, EXL(탐색역량)=3296, EXR(활용역량)=2592, R&D_Q4(R&D 인력)=2256, MI(마케팅혁신)=1585, OI(조직혁신)=

1253, PRCI(공정혁신)=793, R&D_Q1(내부 R&D)=660, R&D_Q2(공동 R&D)=405, R&D_Q3(외부 R&D)=298의 순으로 나타났다.


LightGBM 분류 알고리즘을 적용한 예측모형에서 변수의 중요도는 <그림 8>과 같이 지적재산권(R&D_Q5)=703, EXL(탐색역량)=643, EXR(활용역량)=506, R&D_Q4(R&D 인력)=




<그림 4> XGboost ROC_AUC




<그림 5> LightGBM ROC_AUC




<그림 6> Catboost ROC_AUC



<그림 7> XGboost feature importance



<그림 8> LightGBM feature importance



<그림 9> Catboost feature importance

410, MI(마케팅혁신)=315, OI(조직혁신)=234, PRCI(공정혁신)=213, R&D_Q1(내부 R&D) = 71, R&D_Q2(공동 R&D)=60, R&D_Q3(외부 R&D)=21의 순으로 나타났다.

Catboost 분류 알고리즘을 적용한 예측모형에서 변수의 중요도는 <그림 9>와 같이 R&D_Q1(내부 R&D)=14.124, EXR(활용역량)=13.045, 지적재산권(R&D_Q5)=12.564, EXL(탐색역량)=12.039, MI(마케팅혁신)=12.019, PRCI(공정혁신)=11.695, R&D_Q4(R&D 인력)=10.506, OI(조직혁신)=8.061, R&D_Q2(공동 R&D)=3.531, R&D_Q3(외부 R&D)=2.415의 순으로 나타났다.

XGboost 분류 알고리즘과 LightGBM 분류 알고리즘은 공통으로 R&D_Q5(지적재산권), EXL(탐색역량), EXR(활용역량)이 가장 중요




한 순으로 나타났으며, Catboost 분류 알고리즘은 다소 다른 순서가 나타났지만, EXR(활용역량), 지적재산권(R&D_Q5)은 유사한 수준에서 변수의 중요도가 나타났다.

4.4.3 점진적 혁신성과 예측 성능평가 결과

점진적 혁신성과의 예측모형을 분석한 결과 <표 10>과 같이 XGboost 알고리즘의 예측성능은 ROC_AUC 95.49%, 분류 정확도 89.84%, 정밀도 90.50%, 재현율 89.02%, F1 score 89.75%로 각각 나타났고, LightGBM 알고리즘의 예측성능은 ROC_AUC 95.36%, 분류 정확도 88.32%, 정밀도 89.42%, 재현율 86.92%, F1 score 88.15%로 각각 나타났다. 그리고 Catboost 알고리즘의 예측성능은 ROC_AUC 95.26%, 분류 정확도 87.97%, 정밀도 90.12%,

<표 10> 점진적 혁신성과 예측 성능평가 결과


구분	ROC_AUC	정확도	정밀도	재현율	F1 score
XGboost	0.9549	0.8984	0.9050	0.8902	0.8975
LightGBM	0.9536	0.8867	0.8969	0.8738	0.8815
Catboost	0.9526	0.8797	0.9012	0.8528	0.8764




<그림 10> XGboost ROC_AUC <그림 11> LightGBM ROC_AUC <그림 12> Catboost ROC_AUC



<그림 13> XGboost feature importance



<그림 14> LightGBM feature importance



<그림 15> Catboost feature importance

재현율 85.28%, F1 score 87.64%로 각각 나타났다. 점진적 혁신성과를 예측하는 데 XGboost 분류 알고리즘이 다소 우수한 예측력을 보인다는 점을 확인할 수 있었다.

점진적 혁신성과의 예측모형에서 변수의 중요도는 각각 다음과 같은 순으로 나타났다. XGboost 분류 알고리즘을 적용한 예측모형에서 변수의 중요도는 <그림 13>과 같이 지적재산권(R&D_Q5)=5140, EXL(탐색역량)=2955, EXR(활용역량)=2219, R&D_Q4(R&D 인력)=1957, MI(마케팅혁신)=1328, OI(조직혁신)=1092, PRCI(공정혁신)=714, R&D_Q1(내부 R&D)=557, R&D_Q2(공동 R&D)=319, R&D_Q3(외부 R&D)=264로, 급진적 혁신성과와 결과가 유사하다.

LightGBM 분류 알고리즘을 적용한 예측모형에서 변수의 중요도는 <그림 14>와 같이 지적재산권(R&D_Q5)=1421, EXL(탐색역량)=1246, EXR(활용역량)=760, R&D_Q4 (R&D 인력)=687, MI(마케팅혁신)=554, OI(조직혁신)=392, PRCI(공정혁신)=354, R&D_Q1(내부 R&D)=134, R&D_Q3(외부 R&D)=92, R&D_Q2(공동 R&D)=80로, 급진적 혁신성과와 결과가 유사하다.

Catboost 분류 알고리즘을 적용한 예측모형에서 변수의 중요도는 <그림 15>와 같이 지적재산권(R&D_Q5)=14189, EXR(활용역량)=14,021, R&D_Q1(내부 R&D)=12,954, EXL(탐색역량)=12,248, MI(마케팅혁신)=11,207, R&D_Q4(외부 R&D)=10,716, PRCI(공정혁신)=10,456, OI(조직혁신)=7,68, R&D_Q2(공동 R&D)=3,938, R&D_Q3(외부 R&D)=2,591로, 점진적 혁신성과와 결과가 유사하다.

Q2(공동 R&D)=80으로 나타났다.

Catboost 분류 알고리즘을 적용한 예측모형에서 변수의 중요도는 <그림 15>와 같이 지적재산권(R&D_Q5)=14.189, EXR(활용역량)=14.021, R&D_Q1(내부 R&D)=12.954, EXL(탐색역량)=12.248, MI(마케팅혁신)=11.207, R&D_Q4(R&D 인력)=10.716, PRCI(공정혁신)=10.456, OI(조직혁신)=7.68, R&D_Q02(공동 R&D)=3.938, R&D_Q03(외부 R&D)=2.591로 나타났다.

점진적 혁신성과 예측 결과, XGboost 분류 알고리즘과 LightGBM 분류 알고리즘에서 공통으로 R&D_Q5(지적재산권), EXL(탐색역량), EXR(활용역량)이 가장 중요한 것으로 나타났다으며, Catboost 분류 알고리즘은 EXR(활용역량), 지적재산권(R&D_Q5)이 유사한 수준에서 중요한 변수로 조사되었다.

4.4.4 경영성과 예측분석 성능평가 결과

본 연구에서는 최적화된 결과를 도출하기 위해 혁신성과 분석에서 사용하였던 하이퍼 파라미터를 조정하는 과정을 거쳤다. 그 결과, 기업 혁신과 경영성과의 예측성능을 평가하기 위해 하이퍼 파라미터를 <표 11>과 같이 설정하였다. XGboost는 n_estimators=1000, learning_rate=0.05, max_depth=3, gamma=1, colsample_bytree=0.5, subsample=0.8로 설정하였다. LightGBM은 n_estimators=1000, learning_rate=0.05, num_leaves=4, subsample=0.6, colsample_bytree=0.4, reg_lambda=10, n_jobs=-1로 설정하였다. Catboost는 (n_estimators=1000, learning_rate=0.05, subsample=0.8, depth=3, loss_function='RMSE'로 설정하였다.

<표 11> 경영성과 하이퍼 파라미터 설정

구분	Hyper parameter	Value
XGboost	n_estimators	1000
	learning_rate	0.05
	max_depth	3
	gamma	1
	colsample_bytree	0.5
	subsample	0.8
LightGBM	n_estimators	1000
	learning_rate	0.05
	num_leaves	4
	subsample	0.6
	colsample_bytree	0.4
	reg_lambda	10
	n_jobs	-1
Catboost	n_estimators	1000
	learning_rate	0.05
	subsample	0.8
	depth	3
	loss_function	RMSE

<표 12> 경영성과 예측 성능평가 결과

구분	MAE	MSE	RMSE
XGboost	0.550	0.508	0.713
LightGBM	0.506	0.427	0.653
Catboost	0.499	0.418	0.647




R&D_Q1	0.192
R&D_Q3	0.118
PRCI	0.117
INC_Q1	0.094
EXR	0.092
R&D_Q5	0.075
R&D_Q4	0.075
RAD_Q1	0.073
OI	0.053
EXL	0.053
R&D_Q2	0.031
MI	0.026

<그림 16> XGboost feature importance



R&D_Q5	0.181
R&D_Q4	0.165
EXL	0.116
EXR	0.108
PRCI	0.083
MI	0.082
OI	0.072
INC_Q1	0.046
R&D_Q2	0.039
RAD_Q1	0.039
R&D_Q3	0.039
R&D_Q1	0.030

<그림 17> LightGBM feature importance



R&D_Q5	0.286
R&D_Q4	0.185
EXR	0.172
EXL	0.101
PRCI	0.054
MI	0.051
R&D_Q2	0.039
OI	0.038
RAD_Q1	0.027
R&D_Q1	0.021
INC_Q1	0.014
R&D_Q3	0.013

<그림 18> Catboost feature importance

경영성과를 예측하는 경우 비울척도가 사용되고 있으므로 <표 12>와 같이 MAE, MSE, RMSE의 3개 성능평가 지표로 확인하였다.

각각의 결과에서 XGboost 활용한 경영성과 예측모형의 경우, MAE 0.550, MSE 0.508, RMSE 0.713으로 나타나고 있었고, LightGBM은 MAE 0.506, MSE 0.427, RMSE 0.653이 도출되었으며, Catboost는 MAE 0.499, MSE 0.418, RMSE 0.647로 나타났다. 전반적인 평가 영역에서 Catboost를 활용하여 분석하는 것

이 우수하다는 것을 확인하였다.

경영성과를 예측하기 위해 회귀 알고리즘을 적용한 예측모형에서 변수의 중요도 순은 F-Score을 통해서 분석할 수 있다. XGboost, LightGBM, Catboos의 F-Score은 다음과 같다.

XGboost 회귀 알고리즘을 활용한 경영성과 예측모형을 측정된 변수의 F-Score은 <그림 16>과 같이 R&D_Q1(내부 R&D)=0.192, R&D_Q3(외부 R&D)=0.118, PRCI(공정혁신)=0.117, INC_Q1(점진적 혁신성과)=0.094,

EXR(활용역량)=0.092, 지적재산권(R&D_Q5)=0.075, R&D_Q4(R&D 인력)=0.075, RAD_Q1(급진적 혁신성과)=0.073, OI(조직혁신)=0.053, EXL(탐색역량)=0.053, R&D_Q2(공동 R&D)=0.031, MI(마케팅혁신)=0.026의 순으로 나타났다.

LightGBM 회귀 알고리즘을 활용한 경영성과 예측모형을 측정한 변수의 F-Score은 <그림 17>과 같이 지적재산권(R&D_Q5)=0.181, R&D_Q4(R&D 인력)=0.165, EXL(탐색역량)=0.116, EXR(활용역량)=0.108, PRCI(공정 혁신)=0.083, MI(마케팅혁신)=0.082, OI(조직 혁신)=0.072, INC_Q1(점진적 혁신성과)=0.046, R&D_Q2(공동 R&D)=0.039, RAD_Q1(급진적 혁신성과)=0.039, R&D_Q3(외부 R&D)=0.039, R&D_Q1(내부 R&D)=0.030의 순으로 나타났다.

Catboost 회귀 알고리즘을 활용한 경영성과 예측모형을 측정한 변수의 F-Score은 <그림 18>과 같이 지적재산권(R&D_Q5)=0.286, R&D_Q4(R&D 인력)=0.185, EXR(활용역량)=0.172, EXL(탐색역량)=0.101, PRCI(공정 혁신)=0.054, MI(마케팅혁신)=0.051, R&D_Q2(공동 R&D)=0.039, OI(조직혁신)=0.038, RAD_Q1(급진적 혁신성과)=0.027, R&D_Q1(내부 R&D)=0.021, INC_Q1(점진적 혁신성과)=0.014, R&D_Q3(외부 R&D)=0.013의 순이다.

경영성과 예측분석의 F-Score에서 산출된 변수의 중요도를 살펴보면 Catboost 회귀 알고리즘과 LightGBM 회귀 알고리즘은 공통으로 지적재산권(R&D_Q5), R&D_Q4(R&D 인력)가 가장 중요한 변수로 나타났으며, XGboost 회귀 알고리즘은 다소 상이하게 R&D_Q1(내부

R&D), R&D_Q3(외부 R&D)가 중요하다고 나타났다. 알고리즘별로 다른 결과를 명확하게 해석하기는 어려우나 공통으로 R&D가 기업성과를 창출하는 데 중요한 역할을 한다는 점은 짐작할 수 있다.

V. 결론

5.1 연구요약

시대적인 상황에 따라 기업혁신을 정의하는 방법은 차이가 있었으나 기업혁신이 성장과 발전에 지대한 영향을 미치고 있다는 점은 학자들 사이에 이견이 없다. 본 연구에서는 기업의 성과가 혁신에 근거하여 이뤄지고 있다는 선행 연구를 바탕으로 기업혁신 활동과 유형을 도출하였으며 머신러닝 앙상블 학습을 활용하여 혁신성과와 경영성과를 예측하였다. 연구 결과를 요약하면 다음과 같다.

첫째, 문헌 연구를 통해 시대적 변화에 따라 기업혁신의 유형과 범위가 변화되고 있다는 점을 확인하였다. 과거 혁신은 제품, 공정과 같은 기술적인 영역에 한정되었지만, 최근에는 조직, 마케팅과 같은 비기술적인 영역으로 범위가 확대되고 있으며, 기술적인 부분보다 비기술적인 영역의 중요성이 강조되고 있다는 점을 확인하였다. 또한, 기업혁신과 경영성과는 구조적인 관계가 있다는 점도 확인할 수 있었다.

둘째, 전통적인 머신러닝 기법으로 기업혁신과 경영성과의 예측모형을 구성하고 분석한 결과, 랜덤 포레스트 0.8583, 로지스틱 회귀분석 0.7469, 의사결정나무 0.6957, K-최근접 이웃

의 전통적인 머신러닝에서 양상블 학습에 근거한 랜덤 포레스트(0.8583)가 가장 우수한 예측 성능을 보이는 것으로 나타났다. 따라서 본 연구의 자료를 분석하고 예측하는 데 양상블 학습이 적절하다는 것을 알 수 있었다.

셋째, 양상블 학습 간의 비교분석을 통해 예측 성능을 확인하였다. 양상블 학습은 변수의 구성, 파라미터 설정, 예측대상에 따라 결과가 다소 상이하게 나타날 수 있다. 따라서 최적화된 결과를 도출하기 위해서는 다양한 시도가 반드시 수반되어야 한다. 분석 결과, 급진적 혁신 성과를 예측하는 것에 LightGBM이 가장 좋은 성능을 보였고, 점진적 혁신 성과를 예측하는 것은 XGboost가 가장 좋은 성능을 보였다. 그리고 경영성 성과를 예측하는 것은 Catboost가 가장 우수한 성능을 보이는 것으로 나타났다. 양상블 학습 간의 예측력 차이는 유의하지 않은 것으로 조사되었으나 더 나은 예측 성능을 확인하기 위해서는 다양한 비교분석이 필요하다는 점을 확인할 수 있었다.

5.2 시사점

본 연구는 머신러닝 양상블 학습을 활용하여 기업혁신과 경영성과 예측모형을 구축하고 성능평가를 수행하였으며, 다음과 같은 시사점을 도출하였다.

첫째, 선행연구와 이론에 근거하여 기업혁신과 경영성 성과를 정의하고 예측모형을 구성하였다. 이전의 혁신성과 및 경영성과에 관련된 머신러닝 연구는 요인 간의 근거가 불분명하여 결과 해석에 한계점이 있었다(황재성 등, 2018; 김주경·유승경, 2020). 본 연구는 광범위한 선

행연구 고찰을 통해 변수를 도출하고 인과관계를 명확히 설정하여 연구의 타당성과 신뢰성을 견고히 하였고 논리적인 구성으로 진행하였다는 것에 의의가 있다.

둘째, 방법론적인 측면에서 연구범위를 확대하였다. 기업성과와 관련한 전통적인 연구들은 주로 이론 검증에 초점이 맞춰져 있으며, 엄격한 통계적 기준을 요구한다(우종필, 2015). 하지만 머신러닝 분석은 대량의 자료를 기반으로 결과가 도출되어 유연한 분석과 해석을 할 수 있다. 특히 머신러닝은 다양한 알고리즘을 선택할 수 있으며, 파라미터 설정을 통해 우수한 연구 결과 도출이 가능하다. 즉, 기업성과를 예측하는 연구를 진행하는 데 있어 새로운 방법론으로 활용할 수 있다는 점에서 의의가 있다.

마지막으로 이론과 산업의 틈을 줄이고자 하였다. 선행연구에서 지적하고 있는 바와 같이 기업혁신은 다차원적인 요인으로 구성되어 있으므로 이론과 문헌 연구에서 탈피된 연구가 필요하고(Adams et al. 2006), 분석지표는 실무적인 관점이 충분히 고려되어야 한다(Edison et al., 2013). 본 연구는 이론과 실무의 격차를 최소화하고자 한국기업혁신조사(제조업) 2차 자료 1,817개를 활용하였으며, 머신러닝 분석을 통해 다각적인 분석을 시도하였다. 논리적인 분석을 위해 광범위한 문헌 고찰을 수행하였으며, 기업과 산업의 특성과 혁신성을 파악할 수 있는 기업혁신활동 지표를 선정하여 분석을 수행하였다. 그 결과, 공정혁신, 조직혁신, 마케팅혁신, 탐색적혁신, 활용적혁신, 내부 R&D, 공동 R&D, 외부 R&D, R&D 인력, 지적재산권, 급진적 혁신성과, 점진적 혁신성과, 경영성 성과를 아우를 수 있는 예측모형을 구축하였으며, 우수

한 예측성능을 도출하였다는 것에 의의가 있다.

5.3 한계점 및 향후 연구

전술한 시사점에도 불구하고 본 연구는 다음과 한계점을 가지고 있다. 첫째, 산업을 제조업에 한정하였다. 최근 서비스업에서도 다양한 혁신이 이뤄지고 있는 만큼 연구 분야의 확장이 필요하다. 둘째, 기업의 비전, 문화, 기업이정신, 경영진 지원과 같은 비정형적이고 전략적인 내용이 포함되지 못하였다. 기업에서 비기술적인 영역이 강조되고 있는 만큼 새로운 변수를 활용한 연구가 진행될 필요가 있다. 마지막으로 분석 결과의 상이함을 해소하지 못하였다. 머신러닝 분석의 고질적인 문제인 분석과정의 블랙박스 영역은 현재까지 기술적으로 해소되지 못하고 있다. 다만, 최근 이것을 방법론적으로 해석하는 방법이 연구되고 있으므로 향후 연구에서는 블랙박스 영역의 해석방안이 마련될 필요가 있다(조보근 등, 2020).

참고문헌

김경민, 장하영, 장병탁, “불균형 데이터 처리를 위한 과표본화 기반 앙상블 학습 기법,” 정보과학회 컴퓨팅의 실제 논문지, 제20권, 제10호, 2014, pp. 549-554.

김주영, 유승경, “신경망모델(Neural Network Model)을 활용한 CSR 활동의 영향력 분석,” 경영학연구, 제49권, 제1호, 2020, pp. 51-74.

안경민, “통계적 매칭과 머신러닝 앙상블 기법

을 활용한 기업혁신 및 경영성과 예측 모형 개발,” 동국대학교 박사학위논문, 2021.

양울민, 장군, 김성훈, “R&D 활동과 기술혁신이 경영성과에 미치는 영향: 국내 제조업과 서비스업의 비교연구,” 대한경영학회지, 제30권, 제7호, 2017, pp. 1139-1157.

우종필, “구조방정식모델에서 다차원성 개념의 항목묶음 편향에 대한 연구,” 경영학연구, 제44권, 제4호, 2015, pp. 1131-1147.

이도명, 임성준, “활용적 혁신활동과 탐색적 혁신활동의 영향요인과 혁신성과 및 인지적 기업성과에 미치는 영향에 관한 연구,” 전략경영연구, 제15권, 제1호, 2012, pp. 1-31.

조가원, 조용래, 강희중, 김민재, “2018년 한국 기업혁신조사: 제조업 부문,” 조사연구, 2018, pp. 1-336.

조보근, 박경배, 하성호, “기계학습 알고리즘을 활용한 지역 별 아파트 실거래가격지수 예측모델 비교: LIME 해석력 검증,” 정보시스템연구, 제29권, 제3호, 2020, pp. 119-144.

최은영, “정부지원제도 및 내부 R&D 투자와 R&D 협력이 기술혁신성과에 미치는 영향,” 산업경제연구, 제28권, 제4호, 2015, pp. 1473-1492.

최진용, 김상유, “ICT 인프라와 투자 환경이 혁신에 미치는 영향: 세계혁신지수를 중심으로,” 정보시스템연구, 제29권, 제3호, 2020, pp. 159-178.

- 황정재, 김재영, 박재민, “빅데이터 분석방법을 활용한 제조업 혁신성과예측 방법에 대한 연구: 딥 러닝 알고리즘을 중심으로,” *기술혁신학회지*, 제21권, 제2호, 2018, pp.818-837.
- Adams, R., Bessant, J., and Phelps, R. “Innovation Management Measurement: A Review,” *International Journal of Management Reviews*, Vol. 8, No. 1, 2006, pp. 21-47.
- Armbruster, H., Bikfalvi, A., Kinkel, S., and Lay, G., “Organizational Innovation: The Challenge of Measuring Non-technical Innovation in Large-scale Surveys,” *Technovation*, Vol. 28, No. 10, 2008, pp. 644-657.
- Barrena-Martínez, J., Cricelli, L., Ferrándiz, E., Greco, M., and Grimaldi, M., “Joint Forces: Towards an Integration of Intellectual Capital Theory and the Open Innovation Paradigm,” *Journal of Business Research*, Vol. 112, 2020, pp. 261-270.
- Becheikh, N., Landry, R., and Amara, N., “Lessons from Innovation Empirical Studies in The Manufacturing Sector: A Systematic Review of the Literature from 1993-2003,” *Technovation*, Vol. 26, No. 5-6, 2006, pp. 644-664.
- Benner, M. J., and Tushman, M., “Process Management and Technological Innovation: A Longitudinal Study of the Photography and Paint Industries,” *Administrative Science Quarterly*, Vol. 47, No. 4, 2002, pp. 676-707.
- Berger, E. S., von Briel, F., Davidsson, P., and Kuckertz, A., “Digital or Not - The Future of Entrepreneurship and Innovation: Introduction to the Special Issue,” *Journal of Business Research*, Vol. 125, 2021, pp. 436-442.
- Breiman, L., “Random forests,” *Machine Learning*, Vol. 45, No. 1, 2001, pp. 5-32.
- Chen, T., and 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.
- Creamer, G., and Freund, Y., “Automated Trading with Boosting and Expert Weighting,” *Quantitative Finance*, Vol. 10, No. 4, 2010, pp. 401-420.
- Cooper, J. R., “A Multidimensional Approach to the Adoption of Innovation,” *Management Decision*, Vol. 36, No.8, 1998, pp. 493-502.
- Damanpour, F., and Aravind, D., “Managerial Innovation: Conceptions, Processes and Antecedents,” *Management and Organization Review*, Vol. 8, No. 2, 2011, pp. 423-454.
- Damanpour, F., and Evan, W. M., “Organizational Innovation and Performance: the Problem of

- “Organizational Lag,” *Administrative Science Quarterly*, Vol. 29, No. 3, 1984, pp. 392-409.
- Dewangan, V., and Godse, M., “Towards a Holistic Enterprise Innovation Performance Measurement System,” *Technovation*, Vol. 34, No. 9, 2014, pp. 536-545.
- Dewar, R. D., and Dutton, J. E., “The Adoption of Radical and Incremental Innovations: An Empirical Analysis,” *Management Science*, Vol. 32, No. 11, 1986, pp. 1422-1433.
- Dorogush, A. V., Ershov, V., and Gulin, A., “CatBoost: Gradient Boosting with Categorical Features Support,” *arXiv preprint arXiv:1810.11363*, 2018.
- Edison, H., Bin Ali, N., and Torkar, R. “Towards Innovation Measurement in the Software Industry,” *Journal of Systems and Software*, Vol. 86, No. 5, 2013, pp. 1390-1407.
- Ferreira, J., Coelho, A., and Moutinho, L., “Dynamic Capabilities, Creativity and Innovation Capability and Their Impact on Competitive Advantage and Firm Performance: The Moderating Role of Entrepreneurial Orientation,” *Technovation*, Vol. 92-93, 2020, pp. 1-18.
- Forés, B., and Camisón, C., “Does Incremental and Radical Innovation Performance Depend on Different Types of Knowledge Accumulation Capabilities and Organizational Size?,” *Journal of Business Research*, Vol. 69, No. 2, 2016, pp. 831-848.
- Frank, A. G., Cortimiglia, M. N., Ribeiro, J. L. D., and de Oliveira, L. S., “The Effect of Innovation Activities on Innovation Outputs in the Brazilian Industry: Market-Drientation vs. Technology-Acquisition Strategies,” *Research Policy*, Vol. 45, No. 3, 2016, pp. 577-592.
- Geldes, C., Felzensztein, C., and Palacios-Fenech, J., “Technological and Non-technological Innovations, Performance and Propensity to Innovate Across Industries: The Case of an Emerging Economy,” *Industrial Marketing Management*, Vol. 61, 2017, pp. 5-66.
- Hatzichronoglou, T., “Revision of the High-technology Sector and Product Classification,” *Technology and Industry Working Papers, OECD Science*, 1997.
- Ho, L. A., “Meditation, Learning, Organizational Innovation and Performance,” *Industrial Management & Data Systems*, Vol. 111, No. 1, 2011, pp. 113-131.
- ISO, “*ISO 56002: 2019 Innovation Management-Innovation Management System - Guidance*,” 2019.

- Jonash, R., and Sommerlatte, T., “The Innovation Premium: How Next Generation Companies Are Achieving Peak Performance and Profitability,” *Basic Books*, 2001.
- Kafetzopoulos, D., and Psomas, E., “The Impact of Innovation Capability on the Performance of Manufacturing Companies: The Greek Case,” *Journal of Manufacturing Technology Management*, Vol. 26, No. 1, 2015, pp. 104-132.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W and Liu, T.Y., “Lightgbm: A Highly Efficient Gradient Boosting Decision Tree,” *Advances in Neural Information Processing Systems*, Vol. 30, 2017, pp. 3146-3154.
- Kianto, A., Sáenz, J., and Aramburu, N., “Knowledge-based Human Resource Management Practices, Intellectual Capital and Innovation,” *Journal of Business Research*, Vol. 81, 2017, pp. 11-20.
- Knight, K. E., “A Descriptive Model of the Intra-Firm Innovation Process,” *The Journal of Business*, Vol. 40, No. 4, 1967, pp. 478-496.
- Lee, R., Lee, J. H. and Garrett, T. C. “Synergy Effects of Innovation on Firm Performance,” *Journal of Business Research*, Vol. 99, 2019, pp. 507-515.
- Natekin, A., and Knoll, A., “Gradient Boosting Machines, A Tutorial,” *Frontiers in Neurorobotics*, Vol. 7, No. 21, 2013, pp. 1-21.
- OECD, “*Oslo Manual: Guidelines for Collecting and Interpreting Innovation Data, 3rd Edition*,” OECD publishing, 2005, pp. 47-111.
- OECD, “*Oslo Manual 2018: Guidelines for Collecting, Reporting and Using Data on Innovation*,” OECD publishing, 2018.
- Rowley, J., Baregheh, A., and Sambrook, S., “Towards an Innovation-type Mapping Tool,” *Management Decision*, Vol. 49, No. 1, 2011, pp. 73-86.
- Saunila, M., “Innovation Capability in SMEs: A Systematic Review of the Literature,” *Journal of Innovation & Knowledge*, Vol. 5, No. 4, 2019, pp. 260-265.
- Schumpeter, J. A., “*The Theory of Economic Development*,” New York: Oxford University Press, 1934.
- Skare, M., and PORADA-ROCHON, M., “The Role of Innovation in Sustainable Growth: A Dynamic Panel Dstudy on Micro and Macro Levels 1990 - 2019,” *Technological Forecasting and Social Change*, Vol. 24, 2021, pp. 1-12.
- Siroky, D. S., “Navigating Random Forests and Related Advances in Algorithmic Modeling,” *Statistics Surveys*, Vol. 3, 2009, pp. 147-163.
- Teece, D. J.. “Business Models, Business

Strategy and Innovation,” *Long Range Planning*, Vol. 43, No. 2-3, 2010, pp. 172-194.

Thompson, V. A., “Bureaucracy and Innovation,” *Administrative Science Quarterly*, Vol. 10, No. 1, 1965, pp. 1-20.

Tidd, J., and Bessant, J., “Innovation Management Challenges: From Fads to Fundamentals,” *International Journal of Innovation Management*, Vol. 22, No. 5, 2018, pp. 1-14.

Utterback, J. M., “The Process of Technological Innovation within the Firm,” *Academy of Management Journal*, Vol. 14, No. 1, 1971, pp. 75-88.

Utterback, J. M., and Abernathy, W. J., “A Dynamic Model of Process and Product Innovation,” *Omega*, Vol. 3, No. 6, 1975, pp. 639-656.

Yam, R. C., Lo, W., Tang, E.P., and Lau, A.K., “Analysis of Sources of Innovation, Technological Innovation Capabilities, and Performance: An Empirical Study of Hong Kong Manufacturing Industries,” *Research Policy*, Vol. 40, No. 3, 2011, pp. 391-402.

Yang, L., and Shami, A., “On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice,” *Neurocomputing*, Vol. 415, 2020, pp. 295-316.

Zhou, B., Yang, C., Guo, H., and Hu, J., “A

Quasi-linear SVM Combined with Assembled SMOTE for Imbalanced Data Classification,” *In 2013 International Joint Conference on Neural Networks (IJCNN), IEEE*, 2013, pp. 1-7.

안 경 민 (An, Kyung Min)



동국대학교 경영학과와 동 대학원에서 석사와 박사학위를 취득하였다. 현재 동국대학교 글로벌융합연구소 전문연구원으로 재직하고 있다. 주요 관심 분야는 기술혁신, 조직성과, 머신러닝, 다기준의사결정 등이다.

이 영 찬 (Lee, Young Chan)



서강대학교에서 경영학사, 동 대학원에서 경영과학 전공으로 석사 및 박사학위를 취득하였으며, 현재 동국대학교 경주캠퍼스 경영학부 교수로 재직 중이다. 주요 연구 분야는 다기준의사결정, 데이터마이닝, 기업성과측정, 시스템 다이나믹스, 핀테크 등이다.

<Abstract>

Corporate Innovation and Business Performance Prediction Using Ensemble Learning

An, Kyung Min · Lee, Young Chan

Purpose

This study attempted to predict corporate innovation and business performance using ensemble learning.

Design/methodology/approach

The ensemble techniques uses weak learning to create robust learning, which combines several weak models to derive improved performance. In this study, XGboost, LightGBM, and Catboost were used among ensemble techniques. It was compared and evaluated with traditional machine learning methods.

Findings

The summary of the research results is as follows. First, the type of innovation is expanding from technical innovation to non-technical areas. Second, it was confirmed that LightGBM performed best for radical innovation prediction, and XGboost performed best for incremental innovation prediction. Third, Catboost performed best for firm performance prediction. Although there was no significant difference in predictive power between ensemble techniques, we found that comparative analysis was necessary to confirm better prediction performance.

Keyword: Ensemble Learning, LightGBM, XGboost, Catboost, Corporate Innovation, Business Performance

* 이 논문은 2021년 11월 23일 접수, 2021년 12월 10일 1차 심사, 2021년 12월 20일 게재 확정되었습니다.