

연구보고서
2024-08

인공지능(AI) 발전의 고용효과

장지연 · 전병유 · 정준호 · 이철승 · 심지환 · 안성준

목 차

요 약	i
제1장 서 론	(장지연) 1
제1절 문제의식	1
제2절 인공지능은 어떤 기술인가?	3
1. 개 념	3
2. 인공지능이 할 수 있는 일	6
제3절 보고서의 구성	11
제2장 기존 연구 검토	(장지연) 12
제1절 기술 발전이 고용에 미치는 영향	12
1. 이론적 논의	12
2. 경험적 분석 : 고용 증감과 불평등	14
제2절 인공지능이 고용에 미치는 영향	17
1. 이번엔 다를까?	17
2. 고용에 미치는 영향	19
3. 불평등에 미치는 영향	23
제3절 측정 문제	25
1. 인공지능의 영향을 어떻게 측정할 것인가?	25
2. AI 노출도 척도와 측정 사례	27
3. AI 도입률 척도와 측정 사례	30
제3장 AI 노출도에 따른 고용과 임금 효과	(전병유) 33
제1절 문제 제기	33

제2절 직업별 AI 노출도(AIOE) 지표	35
제3절 AI 노출도와 고용	51
제4절 AI 노출도와 임금	58
제5절 소 결	60

제4장 기업의 AI 도입에 따른 고용과 임금 변화

..... (장지연 · 심지환)	63
제1절 연구 질문	63
제2절 기존 연구	65
1. 설문조사 방식	65
2. AI 특허출원	66
3. AI 숙련수요	67
제3절 분석 방법과 데이터	67
1. 기업의 AI 도입 여부 판정	67
2. 데이터 구축	73
제4절 고용과 임금의 변화	76
1. 어떤 기업이 AI를 도입할까?	76
2. AI를 도입하는 기업은 고용을 줄이는가?	80
3. AI 도입은 불평등을 심화하는가?	84
제5절 소 결	86

제5장 기업의 AI 개발 · 활용이 노동생산성에 미친 영향

..... (정준호)	88
제1절 들어가며	88
제2절 선행연구	89
제3절 실증 분석	95
1. 추정 모형과 방법	95
2. 자료와 변수	99

3. 추정 결과	109
제4절 소 결	119
 제6장 AI 압력과 기업 내부노동시장의 구조변동 : 인공지능과 자동화 노출도로 인한 이중화 경제의 심화 가능성 탐색연구 (이철승 · 안성준)	
제1절 들어가며	124
제2절 이론적 틀	125
1. 내부노동시장의 구성 요소	125
2. 내부노동시장의 직업과 임금 수준	126
3. 동아시아(및 독일) 기업에서의 기술 형성	128
4. 인공지능 기반 자동화 압력과 내부노동시장	129
제3절 자료 및 방법론	134
1. AI 노출도 측정	134
2. 내부노동시장 측정	135
3. 한계점	138
4. 모 델	139
제4절 회귀분석 결과	140
제5절 소 결	154
 제7장 결 론 (장지연)	
제1절 연구 결과	168
1. AI 노출도와 고용	168
2. AI 도입률과 고용	169
3. AI 도입과 생산성	170
4. AI 기술 발전과 내부노동시장	172
제2절 시사점	173
 참고문헌	
	174

표 목 차

〈표 2-1〉 AI 노출도와 도입률의 측정 단위와 측정 사례	26
〈표 3-1〉 직업의 업무환경 및 요구 교육 수준	39
〈표 3-2〉 직업의 사회적 능력	41
〈표 3-3〉 Acemoglu and Autor(2011)의 숙련 지표 작성 기준	43
〈표 3-4〉 주요 AI 노출도 관련 지표 종합	46
〈표 3-5〉 자동화(automation)와 증강(augmentation)	54
〈표 3-6〉 자동화와 증강 직업 예시	55
〈표 3-7〉 노동수요 함수 추정 결과	57
〈표 3-8〉 AI 지표의 임금효과 추정 결과	60
〈표 4-1〉 AI 관련 숙련명 목록	68
〈표 4-2〉 수집된 온라인 구인공고 데이터 전체 분량	74
〈표 4-3〉 숙련수요로 본 AI 도입 업체 수	75
〈표 4-4〉 고용보험 데이터 개요	75
〈표 4-5〉 분석 데이터 개요 : 사업체 단위	76
〈표 4-6〉 업종별 AI 도입률	77
〈표 4-7〉 사업체 규모별 AI 도입률	79
〈표 4-8〉 OLS 회귀분석 : 로그(신규채용 인원)	83
〈표 5-1〉 주요 변수의 정의	102
〈표 5-2〉 AI 개발 · 활용 기업 수와 비중 추이(2017~2022년)	106
〈표 5-3〉 분석에 이용된 주요 변수의 기술통계량	107
〈표 5-4〉 AI 개발 · 활용의 생산성 효과 : 횡단면 풀링 자료(N=64,492) ...	111
〈표 5-5〉 AI 개발 · 활용의 1단계 추정 결과 : 횡단면 풀링 자료	

(N=64,492)	112
〈표 5-6〉 AI 개발 · 활용의 생산성 효과(1) : 패널자료(N=44,157)	116
〈표 5-7〉 AI 개발 · 활용의 생산성 효과(2) : 패널자료(N=44,157)	117
〈표 6-1〉 기술 특정성과 노동조합의 교섭력에 따른 내부노동시장의 분류체계	130
〈표 6-2〉 주요 설명변수의 기술통계	137
〈표 6-3〉 주요 통제변수의 기술통계	138
〈표 6-4〉 로짓모델(with robust standard errors and cluster option) 추정치 : 인공지능 노출도와 성과지향 연공제(vs. 전통적 연공제) 임금 제도 유형과의 관계	142
〈표 6-5〉 OLS 모델(with robust standard errors and cluster option) 추정치 : 인공지능 노출도와 기업 복지제도와와의 관계	144
〈표 6-6〉 로짓모델(with robust standard errors and cluster option) 추정치 : 인공지능 노출도와 계단식 호봉표의 유무	146
〈표 6-7〉 순서 로짓모델(ordered logit model)(with robust standard errors and cluster option) 추정치 : 인공지능 노출도와 자동승진제도의 관계	148
〈표 6-8〉 AIOE의 기업 수준 상관관계 요인	150
〈표 6-9〉 OLS 모델(with robust standard errors and cluster option) 추정치 : 인공지능 노출도와 채용 결정의 관계	152

그림목차

[그림 1- 1] 퍼셉트론 개념도	4
[그림 1- 2] 딥러닝 개념도	4
[그림 2- 1] 일자리 창출과 소멸 예측(2023~2027년)	16
[그림 2- 2] 1940년과 2018년 미국의 산업별 일자리 규모	16
[그림 2- 3] Overall technical automation potential, comparison in midpoint scenarios(2023)	24
[그림 2- 4] ChatGPT 평가와 사람의 평가 비교	29
[그림 3- 1] AI 지표와 직업 숙련 특성들 간의 관계	48
[그림 3- 2] 기타 지표와 직업-숙련 특성들 간의 관계	49
[그림 3- 3] 대분류 직종별로 AI 지표 점수의 분포	50
[그림 3- 4] AI 지표 노출도별 고용 비중(대분류 직종 기준, 2023년)	52
[그림 3- 5] AI와 보완성 지표 기준의 직업별 고용 비중과 국제 비교	54
[그림 3- 6] GPT에 의한 증강 잠재력과 자동화 잠재력의 고용 비중, 2023년 「지역별 고용조사」	56
[그림 3- 7] GPT에 의한 자동화와 증강 잠재력 일자리 비율 국제비교	56
[그림 3- 8] GPT에 의한 증강 잠재력과 자동화 잠재력의 고용 비중	58
[그림 4- 1] 숙련분류체계 구성	74
[그림 4- 2] 구인공고와 고용보험 데이터 결합 방식	76
[그림 4- 3] 업종별 AI 도입률	78
[그림 4- 4] 사업체 규모별 AI 도입률	79
[그림 4- 5] AI 도입 여부별 사업체 AI 노출도	80
[그림 4-6a] 사업체 규모별 AI 도입 여부별 전년 대비 근로자 증가 인원	

(2023년)	81
[그림 4-6b] 사업체 규모별 AI 도입 여부별 전년 대비 근로자 증가율	
(2023년)	82
[그림 4-7a] 사업체 규모별 AI 도입 여부별 신규채용 인원(2021년)	82
[그림 4-7b] 사업체 규모별 AI 도입 여부별 신규채용 인원(2022년)	82
[그림 4-7c] 사업체 규모별 AI 도입 여부별 신규채용 인원(2023년)	83
[그림 4- 8] 사업체 규모별 AI 도입 여부별 신규입사자 1인당 월임금액	
(2023년)	84
[그림 4-9a] 사업체 규모별 AI 도입 여부별 전문·관리·사무직 채용 인원	
(2023년)	85
[그림 4-9b] 사업체 규모별 AI 도입 여부별 판매·서비스직 채용 인원	
(2023년)	86
[그림 4-9c] 사업체 규모별 AI 도입 여부별 생산·노무직 채용 인원	
(2023년)	86
 [그림 6- 1] 사업체패널 연공급 임금의 하위 분류	136
[그림 6- 2] 인공지능 노출도와 성과지향 연공제	141
[그림 6- 3] 인공지능 노출도와 1인당 복지후생비 지출의 상관관계	144
[그림 6- 4] 인공지능 노출도와 계단식 호봉표의 관계 : 사무직, 생산직 비교	146
[그림 6- 5] 인공지능 노출도와 자동승진제도의 관계 : 사무직, 생산직 비교	147
[그림 6- 6] 인공지능 노출도와 정규직 비율의 상관관계	149
[그림 6- 7] 산업별 인공지능 노출도 평균	151

요약

AI가 사람이 해 오던 일의 일부를 대신하거나 도와주는 세상은 이미 도래하였으며, 앞으로 이러한 추세는 지속될 것이다. 이러한 현상은 고용에 영향을 미칠 수밖에 없다. AI 기술의 발전이 완성되고 그 영향력이 노동시장에 모두 반영된 상태가 아니라는 점 또한 분명하다. 본 연구는 2024년 시점에서 AI 기술 발전이 고용에 어떤 영향을 미치고 있는지 분석한다.

1. AI 노출도와 고용

제3장에서는 AI 노출도(Exposure Rate)를 측정하고, 노출도에 따른 고용과 임금의 차이를 분석했다. 국내외 연구에서 소개된 여러 가지 노출도 측정 지표들을 서로 비교하면서 그 의미를 추적했다.

AI와 ChatGPT가 기술적인 측면에서는 고임금 일자리에 더 많은 영향을 줄 수 있지만, 직업의 책무성, 중요성, 사회적 의사소통까지를 고려한다면, AI와 ChatGPT는 오히려 저임금 일자리를 먼저 대체할 가능성이 높다고 판단된다. 자동화의 가능성도 관리 전문직보다는 판매직, 생산직, 단순직 등에서 높을 것으로 판단된다.

AI가 일자리에 미치는 영향을 단순히 '대체' 여부에만 주목하지 않고, 자동화(automation)와 증강(augmentation, 또는 보완)의 관점에서 살펴보았다. 직업은 여러 가지 과업(tasks)으로 구성되어 있고, AI가 하는 역할은 이 중에 특정한 과업을 대신하는 것이다. 직업을 구성하는 과업 중에서 일부 과업만을 AI가 대신한다면, 그 직업은 전체적으로 자동화되어 사라지는 것이 아니라 증강을 통해 생산성이 향상되는 경험을 하게 될 것이다.

우리나라 일자리의 9.8%는 AI 기술로 인한 자동화(automation)로 대체 가능성이 높은 것으로 나타났으며, 15.9%는 AI를 활용하여 생산성을 높이는 증강(augmentation) 잠재력이 있는 것으로 나타났다. 다른 나라와 비교하여 살펴볼 때, 증강과 자동화 잠재력 모두 상대적으로 높은 편이다. 사무직에서 자동화 잠재력이 높고, 전문직에서 증강 잠재력이 높게 나타났다.

2. AI 도입률과 고용

제4장에서는 기업의 AI 도입 여부에 따른 고용영향을 분석했다. 기업의 온라인 구인공고에 나타난 AI 관련 숙련수요를 보고 기업의 AI 기술 도입 여부를 판단했다. 어떤 회사가 AI 관련 숙련(skill)을 보유하고 있는 인력을 채용하려는 구인공고를 냈다면, 이 회사는 AI 기술을 도입한 것으로 본다는 조작적 정의를 사용하였다. 온라인 구인공고를 사업체별로 식별하고 고용보험DB 자료를 결합한 결과, 2023년 기준으로는 13만여 개의 사업체가 분석에 활용되었다.

전체 사업체의 약 4% 정도가 AI를 도입한 것으로 나타나서, 아직까지 AI가 기업에 폭넓게 적용되고 있다고 보기는 어렵다. 하지만 대기업 중에는 도입한 기업이 많다. 1,000인 이상 사업체의 41%, 300인 이상~1,000인 미만 사업체의 23%가 AI 기술을 도입한 것으로 보인다.

AI를 도입하는 기업은 고용을 줄일까? 기존 연구와 비슷하게 우리 분석에서도, 적어도 현재까지는 기업의 AI 도입이 고용을 줄이지는 않는 것으로 나타났다. 다만, 이러한 현상이 앞으로도 계속될 것인지는 지켜볼 필요가 있다. AI 기술이 확산하여 더 많은 기업이 AI를 도입하는 시기가 오면, 그때는 AI를 자동화 기술, 노동비용 절감 목적으로 사용하게 될 수 있다.

AI 도입 사업체와 미도입 사업체의 직종별 신규채용 인원을 살펴보았다. 인공지능이 인지적 숙련(cognitive skill)을 대신하기 때문에, 전문직, 관리직, 사무직의 과업을 대체할 것이라는 가설을 생각해 볼 수 있다. 분

석 결과는 이러한 가설을 지지하지 않았다. AI가 현실에서 관리 기능, 전문직의 과업, 사무직 과업을 본격적으로 대체하고 있는 단계에 들어가지는 않은 것으로 해석할 수 있다.

3. AI 도입과 생산성

제5장에서는 기업의 AI 도입이 생산성에 미치는 영향을 분석한다. 통계청이 제공하는 「기업활동조사」 데이터(2017~2022년)를 활용하여 다음과 같은 결과를 얻었다.

첫째, 횡단면 풀링 자료를 이용한 AI의 생산성 효과 분석은 IV 추정과 EP를 적용한 IV 회귀분석에서 정(+)의 AI의 생산성 효과가 관측되었다.

둘째, 2017~2022년 균형 패널을 구축하여 AI의 생산성 효과를 추정한 결과, 임의 효과 IV와 HTE 모형에서 정(+)의 AI의 생산성 효과가 관측되었다. 임의 효과 IV와 HTE 모형에서는 고정효과 모형과 달리 산업 더미와 같이 시간 불변 변수 추정이 가능하다. 이러한 점에서 산업에 따른 기업 간 차이나 이질성이 AI의 생산성 효과에 크게 영향을 미쳤다고 볼 수 있을 것이다.

셋째, 패널 모형에서 종속변수를 노동생산성 변화율로 하면, 이러한 AI의 노동생산성 변동 효과는 통계적으로 유의하게 확인되지 않는다. 이처럼 연도별 자료를 이용하면 노동생산성 변화율이 연도별로 심하게 변동할 수 있으므로 안정적인 통계 추정이 쉽지 않을 수가 있다. 따라서 수준과 변화율 변수 모두를 고려할 경우, AI의 노동생산성 효과는 일부 모형에서만 관측되는 것으로 결론 내린다.

AI는 초기 확산 단계에 있으므로 산업별로 기업별로 다양하게 이용되고 있지만, 상당한 편차가 있는 것으로 보인다. 이 분석의 추정 결과가 보여주는 바는 산업에 따른 기업 간 이질성이 AI의 생산성 효과에 크게 영향을 미치고 있다는 것이다.

4. AI 기술 발전과 내부노동시장

제6장에서는 「사업체패널자료」를 이용하고 노출도 측정을 기업 단위에 적용하여, AI 기술 발전의 압력이 기업의 내부노동시장 구조에 어떤 변화를 초래하는지 분석한다. 종사자의 직종 구성을 알 수 있다면, AI 노출도를 기업 단위에 적용할 수 있다. 이 척도는 기업의 인력 운용에 AI 기술 발전이 가하는 압력을 반영한다.

AI 및 자동화에 대한 노출이 큰 기업들은 연공형 임금체제와 같은 기존 내부노동시장 제도를 유지하는 데 어려움을 겪을까? 아니면, AI 및 자동화의 압력에 대처하기 위해 기존의 내부노동시장 제도를 더욱 강화하게 될까?

「사업체패널자료」 분석 결과, 한국 기업의 AI 노출도는 고숙련 정규직 노동자를 다수 고용하는 산업에서 더 높게 나타났다. 회귀분석 결과에 따르면, 우리나라 기업의 AI 노출도는 내부노동시장과 밀접한 관련이 있음을 알 수 있다. 이는 인과적 관계는 아니지만, 내부노동시장 메커니즘을 발전시킨 기업일수록 AI 노출도가 높은 시장 환경에 보다 적극적으로 적응할 유인이 있을 것으로 예상할 수 있다.

필자들은 AI 도입이 RBTC(기술이 노동을 대체하는 방향)보다는 SBTC(기술이 노동의 숙련도를 높이는 방향)를 통한 숙련 강화(reinstatement)를 가속화할 가능성이 높다고 본다. 즉, 대기업들이 AI에 대한 투자를 늘려 기업 특유의 역량을 육성하고, 이를 통해 정규직 직원의 특권이 더욱 강화될 수 있다. 이렇게 되면, AI에 기반한 생산성 혁명을 통해 대기업 정규직의 중소기업 종사자나 비정규직과의 격차는 더욱 벌어질 것이다.

5. 시사점

AI가 노동에 미치는 잠재적 영향을 기술적 측면으로만 볼 경우, 고임금-고숙련 노동에 더 많은 영향을 줄 것으로 예상되지만, 직업의 책무성, 중요성, 사회적 대인관계를 고려하면서 그 영향을 전망해 보면, 저임

금-저속련 노동에 더 큰 부정적인 영향을 미칠 수 있다. AI도 앞서 보아 온 기술 발전과 마찬가지로 숙련편향적인(SBTC) 형태의 결과를 초래할 수 있다는 시사점을 던진다.

그러나 AI의 발전은 아직 초기 단계에 있다. 향후 어떤 형태로 발전하느냐, 그리고 사회가 어떤 방식으로 AI를 수용하느냐에 따라 그 영향력은 크게 달라질 수 있다. 본 연구에서 검토한 결과는 이러한 기술 발전과 사회의 인식, 대응과 적응 방식에 따라서 달라질 수 있는 잠정적인 결과로 인식해야 한다.

AI 기술의 발전이 전체 고용의 총량을 감소시키는 상황을 상상할 수 있지만, 아직 그런 조짐은 보이지 않는다. 하지만 일부 직종은 AI로 인해 타격을 받을 것이다. 특히, 일부 직종은 AI 기술 덕분에 생산성 향상을 경험할 것이기 때문에 불평등은 심화할 것이다. 사라지는 일자리에 대한 대응, 불평등 심화에 대한 대응은 정책의 최우선 순위가 되어야 한다.

AI는 범용 기술(general purpose technology)이다. 영향 범위가 매우 넓다. 거의 모든 일자리에서 요구되는 역량이 변화하게 될 것이다. 교육과 직업훈련의 관점이 근본적으로 변화해야 하는 시점이다.

신기술이 등장하면 이것을 잘 활용할 수 있도록 직업능력 훈련이 함께 발전해야 한다. 과거, 포디즘의 대량생산체계가 등장했을 때 자동화가 인간을 완전히 대체한 것이 아니라, 수리와 유지 보수와 같은 다양한 업무가 창출되었으며, 이를 위해 노동자에게는 새로운 교육이 필요했다. AI 시대도 다르지 않다.

제 1 장 서 론

제1절 문제의식

인공지능 기술이 빠르게 발전하면서 우리의 일상생활은 물론 일자리에도 커다란 영향을 미치고 있다. 인공지능 기술은 산업구조, 노동과정, 일자리의 증감, 고용형태에서 변화를 초래할 것이며, 우리는 지금 인공지능이 초래하는 급격한 변화의 중심에 서 있다. 아직은 변화의 구체적인 내용이나 규모를 측정하기에 어려움이 있지만, 그럼에도 불구하고, AI로 인해 발생하는 변화의 과정을 기록할 필요가 있다.

일자리의 감소나 불평등에 미치는 영향은 경계하고 대응해야 할 사회적 과제다. AI가 그동안 사람이 해 오던 일의 일부를 대신하거나 도와주는 세상은 이미 도래하였으며, 앞으로 이러한 추세는 지속될 것이다. 다만, 그 결과가 고용의 감소인지는 아직 분명하지 않다. 뭔가 쓸모 있는 것을 만드는 데 드는 비용과 노력이 감소하면 관련 시장은 폭발적으로 성장하기 때문이다. 지금까지 인류는 여러 가지 기술 발전을 경험했지만, 그렇다고 오늘날 사람이 할 일이 없어진 것은 아니다. 다만, 불평등이 심화했다는 증거는 많다.

이번에는 다를까? 이번엔 다르다면, 그렇게 생각할 수 있는 근거는 다음

* 본 연구의 일부 내용은 이를 바탕으로 장지연(2024), 「인공지능이 불러온 새 바람, 일자리의 지형이 바뀐다」, 『미래정책 FOCUS』 가을호에 게재된 바 있다.

두 가지 정도가 핵심적일 것이다. 첫째, AI는 기존의 그 어떤 기술보다도 더 폭넓게 우리 일터의 저변에 스며든다. 손쉽게 활용할 수 있고, 의도하지 않아도 부지불식간에 AI 기술을 사용하게 된다. 둘째, AI는 인간의 인지기능과 닮아 있기 때문에 중간소득 내지 고소득 계층의 근로자가 더 큰 영향을 받을 가능성이 있다.

AI가 인간의 능력을 대체하는지 증강시키는지도 중요한 논점이다. 물론 일자리 규모의 절대적인 수준 측면에서 보자면 증강과 대체는 결국 같은 것이다. 절반의 직원이 담당하는 업무를 완전히 AI로 대체하든, AI를 활용하여 모든 직원의 생산성을 두 배로 늘리든 결국 같은 수의 사람이 일자리를 잃는다. 하지만 사회적 의미는 매우 다르며, 이런 일을 당하는 개인에게 그 의미는 완전히 다르다. ‘미래에는 AI가 사람을 대체하는 것이 아니라 AI를 활용하는 사람이 활용하지 않는 사람을 대체할 것이다’라는 말을 들어본 적 있다. 앞부분은 대체를, 뒷부분은 증강을 이야기하고 있다. 증강이나 대체냐는 결국 특정 일자리를 구성하는 직무가 얼마나 다양한가에 달려 있다. 인지적인 능력을 필요로 하는 일자리일지라도 한두 가지 단순한 직무로 구성되어 있는 일자리는 대체 가능성이 높다.

본 연구는 이와 같은 질문들을 가지고 인공지능 기술 발전이 고용구조에 어떤 영향을 미치는지 탐구한다. 고용구조에 미치는 영향은 일자리의 증감과 불평등에 미치는 영향으로 나누어 살펴본다.

본 연구의 특징은 인공지능 기술 발전 수준을 가늠하기 위해서 AI 노출도(Exposure Rate)와 AI 도입률(Adoption Rate) 개념을 구분하여 분석하는 데 있다. 기존 연구 중 상당수는 이 두 개념의 차이를 구분하지 않고 사용하거나, 혹은 구분하였더라도 명시적으로 언급하지 않은 경우가 많았다. 노출도는 아직 현실화되지 않은 가능성의 세계를 측정하는 데 비해, 도입률은 실제로 이루어진 액션을 측정한다. AI 노출도는 직종별로 측정하여, AI로 대체되기 쉬운 일자리의 특징과 규모를 추정한다. AI 도입률은 기업 단위로 측정하여 AI 도입률과 기업의 성과 간 관계를 분석한다. 이 두 개념은 각각 장단점이 있으며, 둘 다 쓸모가 있다. 도입률이 AI의 고용효과를 보기에 더 현실적인 것 같지만, 앞서 언급한 바와 같이 AI 기술이 모든 디바이스에 스며들기 때문에 개인은 자기도 모르게 부지불식간에 사용하게 된다는 점에서 노

출도의 의미가 더 클 수 있다.

다음 절에서는 AI가 도대체 어떤 기술인지 생각해 보는 시간을 갖는다. 어떤 기술인지를 알아야, 이것이 고용에 어떤 영향을 미칠지 예상해 볼 수 있기 때문이다.

제2절 인공지능은 어떤 기술인가?

1. 개념

인공지능은 ‘인간처럼 생각하는 기계’를 상상한 인간의 꿈이 담긴 용어다. ‘인공지능’이라는 단어는 1956년 존 매카시가 처음 사용했지만, 인간처럼 생각하는 기계를 꿈꾼 사람은 그 이전에도 많았다. 대표적으로 기억되는 사람은 앨런 튜링이다. 그가 활동하던 시대 영국에서는 ‘기계 지능(machine intelligence)’이라는 용어를 사용했다(김의중, 2016). 인공지능은 매우 오래된 용어이며 폭넓은 개념이다.

생각하는 기계가 만들어지려면 기계를 학습시켜야 한다. 머신러닝이다.¹⁾ 예를 들어, 컴퓨터에 손글씨를 인식하고 분류하는 태스크(T)를 부여하고, 미리 만들어진 데이터 세트로 학습한 경험을 통해(E), 일정한 확률 수준으로 손 글씨를 인식할 수 있는 성능(P)을 갖게 되면 ‘컴퓨터가 학습을 했다’라고 말할 수 있다(김의중, 2016). 컴퓨터를 학습시키기 위한 여러 가지 방법이 시도되었다. 오늘날 우리가 보고 있는 가장 성공적인 방법은 퍼셉트론에서²⁾ 출발해서 딥러닝으로 이어지는 신경 모형 패러다임이다.

딥러닝은 신경 모형 패러다임에 속하는 머신러닝의 하위 분야다. AI를 학


1) 머신러닝이라는 용어는 IBM의 인공지능 분야 연구원이었던 아서 사무엘의 논문에서 처음 등장했다. 여기서 머신(machine)이란 컴퓨터를 말한다.

2) 퍼셉트론은 1958년에 로젠블랫이 발표한 논문에 등장하는 아이디어이다. 여러 개의 입력을 받아서 하나의 출력을 내놓는다. 오늘날 딥러닝의 기초가 되는 기본 단위이다.


습시키기 위해 인간 두뇌 신경망을 모델로 만든 알고리즘이다. AI의 신경망은 소프트웨어 회로인데, 단순한 처리장치들을 여러 층으로 많이 연결해서 한 장치의 출력이 다른 장치의 입력이 되게 한다. 각각의 입력들에는 중요도(가중치)에 차이가 존재하는데, 신경망이 출력을 보고 각 입력의 중요도를 수정하게 만든다. 출력 결과와 정답 사이의 차이를 프로그램에 되먹임 해서 정답에 근접한 결과가 나올 때까지 중요도를 적절히 조정하는 식이다(뉴 사이언티스트 외, 2018). 이렇게 하면 컴퓨터가 데이터로부터 스스로 패턴을 찾아내고 판별하게 된다. 이것은 판별 규칙을 사람이 제시하는 규칙 기반 알고리즘과 구별되는 딥러닝 알고리즘의 핵심적인 특징이다.

오늘날 우리가 보고 있는 딥러닝의 성과는 세 가지 핵심적인 조건이 충족된 결과다. 첫째, 딥러닝 알고리즘 자체의 발전. 둘째, 인터넷 세상에 축적된 디지털 데이터 확보. 셋째, 대규모 데이터를 다룰 수 있는 컴퓨터 성능의 발

[그림 1-1] 퍼셉트론 개념도



[그림 1-2] 딥러닝 개념도



자료 : 심지환 강의노트(2023).

전. 이 중에서 둘째와 셋째 조건은 그 의미를 따로 되짚어 볼 필요가 없을 것 같다. 여기서는 딥러닝 알고리즘의 발전에 대해서만 잠시 돌아보자.

인공지능 발전의 최첨단에 서 있는 생성형 AI 시스템인 ‘대규모 언어 모델(LLM)’을 살펴보자.³⁾ LLM은 ‘트랜스포머(Transformer)’라는 특수한 인공신경망을 이용하여 방대한 양의 자연어 데이터를 학습한 모델이다. 수천 개 이상의 강력한 컴퓨터 프로세서를 동시에 이용해서 수 주에 걸쳐 학습하는 더욱 방대한 모델은 ‘파운데이션 모델(Foundation Models)’이라고 불린다.⁴⁾

LLM이 가능하기 위해서 두 가지 기술적인 초석이 필요했다. 하나는 단어 임베딩이고 다른 하나는 트랜스포머다.

임베딩은 단어를 숫자의 벡터로 변환하는 기술이다. 무턱대고 일대일 매칭을 하는 것이 아니라 다른 단어와의 관계를 반영하도록 숫자를 부여한다. 파운데이션 모델에서 특정 단어를 나타내는 임베딩은 보통 수백 개의 숫자로 이루어져 있다. 각각의 숫자는 해당 단어의 개념적 차원을 나타낸다. 간단하게 말하면, 임베딩은 컴퓨터가 읽을 수 있는 단어 사전이다(제리 카플란, 2024).

트랜스포머는 특수한 유형의 인공신경망이다.⁵⁾ 인공신경망에 대한 간단한 설명은 전술했으니⁶⁾, 트랜스포머가 어떤 의미에서 특수한지만 추가로 살펴보자. 언어는 맥락을 이해해야 하므로 일련의 시퀀스에서 앞서 나왔던 단어를 기억해야 한다. 순환신경망(Recurrent Neural Network : RNN) 모델로 이를 수행하고 있었는데, ‘되돌아볼 수’ 있는 입력 데이터의 범위가 제한적이라는 한계가 있었다. 트랜스포머의 첫 번째 혁신은 후속 처리에 도움이 될 정보를 선택적으로 보유할 수 있는 기능이다. 즉, 더 주의를 기울여야 할 요소를 네트워크 내에서 선택적으로 보유할 수 있게 했다. 트랜스포머의 또 다른 혁신은 입력 데이터의 여러 부분을 독립적으로 처리한 다음 효율적으

3) 몇 가지 간단한 묘사로 LLM을 설명할 수는 없다. 다만, 가장 기초적인 개념어를 짚고 넘어가는 수준으로 정리했다.

4) OpenAI의 ChatGPT, 구글의 제미니(Gemini), 앤스로픽의 클로드(Claude), 메타의 라마(Llama), 네이버의 하이퍼클로바X 등이 대표적인 파운데이션 모델이다.

5) 트랜스포머 모델은 구글 연구원 그룹이 발표한 “Attention is all you need” 논문에서 소개되었다.

6) LLM 이전에도 인공신경망은 여러 가지 분류와 예측 기능으로 널리 활용되었다.

로 결합해 결과를 산출하도록 설계되었다는 점이다. 동시에 여러 대의 컴퓨터에 연산을 분산시키는 것⁷⁾이 가능해졌다(제리 카플란, 2024).

재미있는 사실은 비언어적인 문제에도 LLM이 적용될 수 있다는 점이다. LLM은 이미지나 소리 등 비언어적인 유형의 데이터에서 파생된 토큰과 언어에서 파생된 토큰을 동시에 처리할 수 있다고 한다. 이미지를 보고 설명하거나, 설명에 따라 이미지를 생성할 수 있다는 것이다. 이처럼 텍스트, 이미지, 오디오, 비디오 등 다양한 형태로 주어지는 데이터 정보를 교차하면서 이해하고 표현하는 기술을 멀티모달(MultiModal)이라고 한다.

멀티모달 LLM에 도달한 인공지능은 사람의 말을 알아들을 뿐 아니라 이미지나 소리의 차이를 구별한다는 점에서 과거보다 훨씬 더 높은 수준의 ‘지능’을 가진 것으로 보인다. 물론, 우리가 이것을 ‘지능’이라고 부른다는 전제 하에서 그러하다.

2. 인공지능이 할 수 있는 일

인공지능 기술 발전이 고용에 영향을 미치는 양상은 이 기술로 어떤 일을 할 수 있느냐에 달려 있다. 인공지능을 분석형 인공지능(Analytical AI)과 생성형 인공지능(Generative AI)으로 구분하여 주요 기능과 응용 분야를 살펴보자.⁸⁾

분석형 인공지능은 기존 데이터를 분석하여 패턴을 식별하고, 이에 따라 예측 모델링이나 분류(또는 군집화) 기능을 하는 AI 시스템이다. 분석형 AI는 데이터를 기반으로 의사결정을 지원하고, 이 과정에서 효율성을 높인다. 분석형 인공지능이 유용하게 활용된 사례를 살펴보면 다음과 같다.

① 제조업 : 예측을 통한 유지 보수

제조업에서는 설비의 센서 데이터를 분석하여 기계의 상태를 실시간으로 모니터링하고, 고장 가능성을 예측하는 데 분석형 인공지능이 사용된다. 이러한 예측 유지보수 시스템을 통해 기계 고장으로 인한 생산 중단을 예방하

7) 이러한 연산을 위해 그래픽 처리 장치(GPU)가 사용되고 있다.

8) 이 부분 원고를 작성하는 데 ChatGPT와 클로드를 활용하였다.

고, 유지보수 비용을 절감할 수 있다. 제조 공정을 최적화하고, 효율성을 높이는 데 활용된다.

② 의료 분야: 질병 진단과 예측

의료 분야에서는 분석형 인공지능이 환자의 진단과 예후 예측에 크게 기여하고 있다. 예를 들어, IBM의 Watson은 수많은 의학 논문과 환자 데이터를 분석하여 암과 같은 질병의 진단을 돕는 역할을 한다. 환자의 증상, 병력, 유전자 정보를 바탕으로 가능한 진단 결과를 제시하고, 그에 따라 적절한 치료법을 추천한다. 분석형 AI는 환자의 데이터를 기반으로 질병 재발 가능성을 예측하거나 치료의 효과를 예측하는 데도 사용된다.

③ 금융 분야: 사기 탐지 및 리스크 관리

금융기관에서는 분석형 AI를 통해 거래 데이터를 실시간으로 분석하여 사기 행위를 탐지하고, 리스크를 관리하는 데 활용한다. 은행들은 고객의 거래 패턴을 분석하여 비정상적인 거래를 실시간으로 감지하고, 사기일 가능성이 높은 거래를 차단하기도 한다. 또한, AI는 금융시장의 다양한 데이터를 분석하여 주가 예측, 포트폴리오 관리, 시장 리스크 평가 등에 활용되며, 이를 통해 투자 전략을 최적화할 수 있다.

④ 마케팅 및 고객 관리: 고객 세분화 및 맞춤형 마케팅

마케팅 분야에서도 분석형 인공지능이 중요한 역할을 한다. 고객의 구매 이력, 웹사이트 방문 기록, 소셜 미디어 활동 등을 분석하여 고객을 세분화하고, 각 그룹에 맞춘 맞춤형 마케팅 전략을 수립할 수 있다. 예를 들어, 넷플릭스는 사용자들의 시청 기록을 분석하여 개인화된 추천 시스템을 구축하였고, 이를 통해 사용자 경험을 크게 향상시켰다. 이처럼 AI는 고객의 행동을 예측하고, 그에 맞춘 개인화된 서비스를 제공하는 데 중요한 역할을 한다.

⑤ 교통 관리: 교통 흐름 예측 및 최적화

교통 관리 분야에서도 분석형 AI가 유용하게 활용되고 있다. 예를 들어, 구글의 Waze와 같은 애플리케이션은 사용자들의 실시간 교통 데이터를 분석하여 교통체증을 예측하고, 최적의 경로를 제시한다. 도시의 교통관제시스템에서는 AI를 사용하여 교통 신호의 패턴을 조정하고, 교통 혼잡을 줄이

며, 응급 차량의 이동을 원활하게 한다.

⑥ 사이버 보안

네트워크 트래픽을 분석하여 잠재적인 사이버 공격을 식별하는 위협 탐지와 사용자 행동 패턴을 분석하여 비정상적인 활동을 감지하기도 한다.

⑦ 농업

토양 조건, 기후 데이터를 분석하여 최적의 작물 재배 조건을 결정하고, 작물의 질병 발생을 예측하여 선제적 대응을 가능하게 하기도 한다.

⑧ 에너지 관리

스마트 그리드 기술은 전력 소비 패턴을 분석하여 에너지 분배를 최적화한다. 날씨 데이터를 분석하여 태양광, 풍력 발전량을 예측한다.

생성형 인공지능은 주어진 데이터를 바탕으로 새로운 콘텐츠(텍스트, 이미지, 소리 등)를 생성하거나 기존 콘텐츠를 변형하는 기술이다. 이 기술은 언어 이해, 이미지 생성, 음악 작곡 등 다양한 창의적 작업에서 활용된다. 많은 경우 생성형 AI는 분석형 AI와 결합하여 작동하기 때문에 그 경계를 분명히 구분하기는 어려우나, 대체로 생성형 인공지능이 소개된 이후에 유용하게 활용된 사례를 살펴보면 다음과 같다.

① 고객 서비스 : AI 챗봇과 가상 비서

분석형 AI와 생성형 AI가 결합된 가장 성공적인 사례 중 하나는 고객 서비스 분야이다. AI 챗봇은 고객의 질문을 이해하고, 그에 대한 적절한 답변을 생성한다. 고객과의 과거 상호작용 데이터를 분석하여 그들이 필요로 하는 정보를 예측하고, 생성형 AI를 통해 자연스러운 대화를 생성한다.

② 의료 : AI 기반 맞춤형 치료

의료 분야에서도 분석형과 생성형 AI의 결합이 나타난다. 예를 들어, 분석형 AI는 환자의 유전자 정보, 병력, 생활습관 데이터를 분석하여 특정 질병에 대한 맞춤형 치료법을 추천한다. 그런 다음, 생성형 AI는 의사와 환자가 이해하기 쉬운 형식으로 복잡한 의료정보를 설명하거나, 맞춤형 식단이나 운동계획을 자동으로 생성할 수 있다. 이런 접근 방식은 환자 맞춤형 치료

를 가능하게 하며, 더 나은 의료서비스를 제공하는 데 기여한다.

③ 소프트웨어 개발

소프트웨어 개발 분야에서도 AI가 적극 활용되고 있다. 개발자의 코드 작성을 지원하며, 주석을 기반으로 전체 함수나 알고리즘을 제안한다. 코드 자동완성 기능을 제공하여 개발 생산성을 향상시킨다.

④ 교육

교육 분야도 분석형 AI와 생성형 AI의 결합으로 크게 변화하는 영역이다. 사용자의 학습 패턴을 분석하고 개인화된 언어 학습 콘텐츠를 생성한다. 학생의 학습 스타일과 진도를 분석하여 맞춤형 학습 경로를 생성한다.

⑤ 의료

의료와 제약 분야에서도 AI 활용이 활발하다. 신약 개발 과정에서 분자 구조를 분석하고 새로운 후보 물질을 생성하기도 하며, 의학 문헌을 분석하여 새로운 치료법 가설을 생성하기도 한다.

⑥ 금융

복잡한 재무 데이터와 금융 데이터를 분석하고 이해하기 쉬운 금융 보고서를 생성한다.

⑦ 법률

법률 분야는 비교적 의미가 명확한 용어를 사용하기 때문에 다른 분야에 비해 AI가 적극적으로 기여할 수 있는 분야이다. 법률 문서를 분석하고 관련 판례와 법규를 추천하기도 하고, 사용자를 위한 법적 문서를 생성하기도 한다.

⑧ 콘텐츠 제작 : 글쓰기, 이미지, 동영상 제작 등

LLM을 이용한 글쓰기는 널리 알려져 있다. 뉴스기사, 블로그 포스트, 마케팅 카피, 심지어 소설의 초안을 작성하는 데까지 사용된다.

디자인과 예술 분야에서는 이미지 생성과 보정에 이용된다. 생성형 인공지능은 사용자의 텍스트 입력을 바탕으로 독창적인 이미지를 생성한다. 예를 들어, 디자이너가 특정 주제를 설명하는 텍스트를 입력하면 AI는 그에 맞

는 이미지를 생성해 준다. 이는 광고, 마케팅, 브랜드 디자인에서 빠르게 시각 자료를 제작하는 데 매우 유용하다. AI를 이용해 이미지 보정이나 합성 작업을 더욱 정교하게 할 수 있는 기능이 도입되었다.

게임 개발 분야에서는 분석형과 생성형 인공지능이 결합된 사례가 많다. 절차적 콘텐츠 생성(Procedural Content Generation : PCG)이라는 기술을 통해, 게임 내의 맵, 캐릭터, 스토리라인을 자동으로 생성할 수 있다. 예를 들어, 'No Man's Sky'라는 게임은 우주를 탐험하는 게임으로, AI를 통해 약 1,800경 개의 서로 다른 행성과 생태계를 자동으로 생성했다. 이로 인해 플레이어는 무한에 가까운 다양한 환경을 탐험할 수 있다.

영화 등 엔터테인먼트 산업에서는 AI 기술이 시나리오 작성에서부터 영상 편집까지 폭넓게 시도되고 있다. 생성형 AI를 활용해 시나리오의 초안을 작성하거나, 영상 편집 과정에서 특정 효과를 자동으로 적용하는 작업에 사용된다.

지금까지 살펴본 사례를 넘어서서 인공지능이 노동자의 업무에 영향을 미치는 범위는 매우 넓다. 이는 인공지능이 자연어(Natural Language)로 인간과 소통할 수 있다는 데 기인한다. AI는 읽거나 듣고 이해하기, 말하기, 쓰기, 그리고 번역을 할 수 있다. 사람의 말을 알아듣는다는 것, 혹은 알아듣는 것처럼 대응한다는 것은 두 가지 측면에서 매우 커다란 의미이다. 첫째, 말하거나 쓸 수 있는 사람은 누구든지 이 기술을 이용할 수 있다. 누구든지 AI 기술을 이용하여 역량을 향상시키고 생산성을 높일 수 있다. 둘째, AI에 질문을 하고 무엇인가를 요청한다는 것은 달리 말하자면 집단지성의 도움을 받는다는 것과 같다. AI는 디지털 데이터로 전환된 과거 인간의 기록을 통해 학습하기 때문이다. 이 두 가지 의미가 고용에 미치는 간접적인 효과는 직업 경험(experience)에 따른 능력 차이가 줄어들고, 아마추어와 프로의 차이마저도 줄어들 수 있다는 점이다(제리 카플란, 2024).

그럼에도 불구하고, AI가 좀 더 잘하는 일이 있고, 하기 어려운 일이 구분되는 것은 분명하다. AI가 잘하는 일은 목표가 명확하고 객관적으로 잘 정의된 업무다. 벽에 페인트칠하기, CAT 스캔 판독, 선반 채우기, 잔디 깎기, 공장에서 부품 검사, 해외 여행객 여권 검사 같은 일이다. 보이는 대상 중에서 관심 가져야 할 대상을 식별하는 능력이 뛰어나다. AI가 잘 못하는 일은 사회적인

활동이나 상식적인 판단이 필요한 일이라고 볼 수 있다(제리 카플란, 2024).

제3절 보고서의 구성

본 보고서는 다음과 같이 구성된다.

제2장에서는 기존 연구를 검토한다. 일반적인 기술 발전이 고용에 미치는 영향에 관한 연구를 폭넓게 살펴보고, 인공지능이라는 특수한 기술의 발전에 초점을 맞춘 연구성과물에 대한 검토로 좁혀 들어간다. 특히 인공지능의 영향을 어떻게 측정할지는 본 보고서가 특별히 주안점을 두고 있는 주제이므로 별도로 검토한다.

제3장에서는 AI 노출도(Exposure Rate)를 측정하고, 노출도에 따른 고용과 임금의 차이를 분석한다. 국내외 연구에서 소개된 AI 노출도를 측정하는 방법은 여러 가지가 있다. 각각의 측정 지표들을 서로 비교하면서 그 의미를 추적한다.

제4장에서는 기업의 AI 도입 여부에 따른 고용영향을 분석한다. 기업의 AI 도입 여부는 해당 기업의 온라인 구인공고(Online Job Postings)에서 AI 관련 숙련인력을 구하는지를 살펴서 판단하고, 이 정보를 고용보험DB에 연결하여 분석한다.

제5장에서는 기업의 AI 도입이 생산성에 미치는 영향을 분석하는데, 통계청에서 제공하는 「기업활동조사」 데이터를 활용한다. 이 데이터에는 AI 도입 여부를 질문하는 문항이 포함되어 있으며, 기업의 생산성을 측정하는 지표들도 포함되어 있다.

제6장에서는 노출도 측정을 기업 단위에 적용하여, AI 기술 발전의 압력이 기업의 내부노동시장 구조에 어떤 변화를 초래하는지 분석한다. 종사자의 직종 구성을 알 수 있다면, AI 노출도를 기업 단위에 적용할 수 있다. 이 척도는 기업의 인력 운용에 AI 기술 발전이 가하는 압력을 반영한다. 기업은 이에 대응하여 제도를 변형하면서 적응해 나갈 것이다.

제7장은 요약과 결론이다.

제2장

기존 연구 검토

제1절 기술 발전이 고용에 미치는 영향

1. 이론적 논의

기술 발전이 고용에 미치는 영향은 오래된 연구 주제이고, 인공지능 기술의 영향은 그 연장선 위에 있다. 모든 생산요소의 한계생산성을 일률적으로 증가시키는 기술변화를 상상하기는 어렵다. 기술변화는 대체로 자본편향적이다. 우리는 역사적으로 자본이 자동화 기술을 들여와서 생산성을 증가시키는 것을 보아 왔다. 인공지능도 그런 사례의 하나일 것으로 예상하면서 그 결과를 지켜보고 있다.

자동화 기술이 고용에 미치는 영향은 다음과 같은 세 가지 기제를 통해서 실현된다(Furman and Seamans, 2019). 첫째, 자동화가 노동력을 직접적으로 대신하게 되는 대체 효과(Replacement Effect). 둘째, 자동화가 새로운 영역에서 일자리를 창출하는 효과(재배치 효과, Reinstatement Effect). 오프라인에서 백화점 판매직 일자리는 줄어들지만, 전자상거래 분야 콜센터 일자리가 새로 생기는 사례에서 볼 수 있다. 셋째, 자동화가 실질소득의 증가를 초래하여 경제 전반에 걸쳐 일자리가 증가할 수 있다(실질소득 효과, Real Income Effect). 가계소득이 증가하면 레스토랑과 여행 관련 종사자가

늘어나는 식이다.

기술이 일자리를 대체한다는 표현은 오해의 여지가 있다. 기술이 실제로 대신하는 것은 일자리 자체라기보다는 그 일자리를 구성하는 과업(task)이다(Task-based Framework; Autor, Levy and Murnane, 2003; Arntz et al. 2016). 신기술이 기존에 수행하던 업무에서 노동력을 대체하는 효과(대체 효과, Displacement Effect)와 자동화로 인해 비용 절감이 이루어지면서 그 외 업무에 대한 노동수요가 증가하는 효과(생산성 효과, Productivity Effect) 중에 어느 쪽이 더 클지가 핵심적인 질문이다(Acemoglu and Restrepo, 2018).

기술변화는 모든 부분에서 고르게 영향을 미치는 것이 아니라 특정 집단에 유리하게 혹은 불리하게 작용하여 결국 불평등을 초래할 수 있다. 크게 두 가지 가설이 널리 알려졌다. 첫째, 숙련편향적 기술변화(Skill-Biased Technological Change : SBTC) 가설. IT 기술이 주로 이 기술을 잘 활용할 수 있는 고숙련 노동자의 상대적 생산성을 높이고 저숙련 노동자 대비 상대적 노동수요를 증가시킨다는 주장이다(Katz and Murphy, 1992; Acemoglu, 2002; Acemoglu and Autor, 2011; Autor et al., 1998; Goldin and Katz, 2008; Katz and Autor, 1999). 이 이론은 일자리 양극화 현상을 설명하지 못한다는 한계가 지적되었다(Autor et al., 2006; Goos and Manning, 2007; Goos et al., 2009; Wright and Dwyer, 2003).

둘째, Routine-Biased Technological Change(RBTC) 가설. 자동화는 전체 직업이 아니라 각각의 업무에 대한 대체이며, 직업은 다양한 업무로 구성되어 있다는 과업기반 프레임워크에 기반을 두고 있다. 작업을 정형(routine)/비정형(non-routine)과 인지적(cognitive)/수동적(manual)으로 구분하고, ICT 기술이 정형화된 작업을 대체한다는 주장을 펼쳤다(Autor, Katz and Kearney, 2006; Autor and Dorn, 2013). 이 가설은 노동시장 양극화 현상을 설명하는데 도움이 된다.

Autor(2022)에 따르면, 기술 발전과 불평등의 관계에 대한 경제학적 사고는 다음과 같은 4단계를 거쳐 왔다. 첫 번째, 교육 경주 모델(The Education Race 또는 SBTC). 숙련수요곡선이 공급곡선보다 더 빠르게 우측으로 이동하면서 고숙련 노동자의 임금이 상승했다(Tinbergen, 1974; Goldin and Katz, 2010; Autor et al., 2020). 두 번째, 과업 양극화 모델(The Task-Polarization

Model 또는 RBTC). 컴퓨터는 정형화된(routine) 과업을 대체한다. 이 모델은 고임금 직업(비정형 인지 과업)과 저임금 직업(비정형 수동 과업)이 증가하고, 중간임금 직업(정형 과업)이 감소하게 된다고 설명한다(Autor et al., 2003; Acemoglu and Autor, 2011; Goos et al., 2014). 셋 번째, 자동화와 일자리 재창출 간 경주 모델(The Automation-Reinstatement Race). 자동화가 기존 일자리를 대체하는 반면, 새로운 기술은 인간의 전문성을 필요로 하는 새로운 과업을 만들어 낸다(Acemoglu and Restrepo, 2018, 2019; Autor et al., 2022). 어느 쪽이 빠른지가 문제다. 새로운 일자리는 저임금 서비스직과 고임금 전문직으로 양극화될 것으로 내다봤다. 과거에는 이 두 힘이 균형을 이루었지만 1990년대 이후에는 자동화의 힘이 우세하다는 분석도 내놓았다.

위와 같은 세 단계를 거쳐 네 번째이자 현 단계는 AI 불확실성 시대(The Era of AI Uncertainty)이다. AI가 어떤 과업을 수행할지 불확실하기 때문이다. AI는 명시적으로 프로그래밍되지 않은 과업도 수행할 수 있어서, ‘정형’과 ‘비정형’ 과업의 구분이 모호하다. 전문가가 수행하던 과업을 대체할 가능성도 제기되고 있다(Brynjolfsson et al., 2018; Felten et al., 2018; Webb, 2019).

2. 경험적 분석: 고용 증감과 불평등

컴퓨터를 이용한 자동화 기술로 인해 일자리가 사라질 위험을 경고한 가장 잘 알려진 연구는 Frey and Osborne(2013)이다. 한 직업에서 가장 많이 관여하는 업무를 기반으로 향후 자동화의 위험에 얼마나 노출되는지 평가했는데, 미국 내 고용의 47%가 컴퓨터화의 위험이 높은 것으로 분석되었다(Frey and Osborne, 2013). 동일한 방법론을 사용한 Brzeski and Burk(2015)는 독일 노동력의 59%가 자동화에 매우 취약할 수 있다고 분석했고, Pajarinen and Rouvinen(2014)은 핀란드 일자리의 35%가 고위험에 처해 있다고 주장했다(여영준 외, 2021, 재인용).

반면, 일자리가 사라질 위험이 크지 않다는 주장은 Arntz, Gregory and Zierahn(2016)에 의해 제기되었다. Frey and Osborne(2013)의 직종 기반

(occupation-based) 분석 방식이, 기술 발전의 일자리에 대한 부정적 영향을 과대 추정할 수밖에 없는 방법론이라고 비판하고 과업기반(task-based) 분석 방식을 적용하면, 미국의 대체 가능 고위험 일자리 비중이 9%에 그친다고 소개했다.


기술 발전이 고용에 미치는 영향에 대한 100여 편의 논문을 요약한 체계적 문헌리뷰(systematic literature review)에 따르면 대체로 노동 대체 효과가 노동 창출 효과에 의해 상쇄되는 것으로 나타난다(Filippi et al., 2023; Hötte et al., 2022). 기술적 실업에 대한 우려는 실증적 근거가 부족하다는 결론이다. 전체 논문의 67%는 대체 효과를 지지하고, 16%에서만 지지하지 않는다. 재배치 효과는 81%가 지지하고, 2.5%만 지지하지 않는다. 실질소득 효과는 70%가 지지한다. 다만, 국가에 따라 자동화 기술의 영향이 상이하 며, 이는 산업구조와 노동시장의 특성에 영향을 받기 때문이다.

부문별로도 차이가 나타나는데, 이는 불평등에 영향을 미칠 수 있음을 시사하는 것이다. 제조업에서는 고용을 감소시키지만, 서비스업에서는 고용을 증가시키는 경향이 발견된다. 저숙련/생산직/제조업 노동자들에게 부정적인 영향을 미친다는 사실은 많은 논문에서 일관성 있게 나타난다. ICT나, 로봇이나, 인공지능이나, 기술의 종류에 따라서도 다른 결과가 나타난다는 점도 주목할 만하다.

기술변화에 따른 일자리 증감을 직관적으로 이해할 수 있게 보여주는 두 가지 그래프를 살펴보고 마무리하자. 첫째, World Economic Forum의 ‘*The Future of Jobs Report*(2023)’에 따르면(그림 2-1), 향후 5년 동안 8,300백만 개의 일자리가 소멸되고 6,900만 개 일자리가 창출될 것으로 예상되었다. 순 일자리 감소는 1,400만 개로 전체 일자리의 2% 수준으로 크지 않다. 그러나, 전체 노동자의 23%는 일자리 변동을 경험하는 셈이다.

둘째, Autor의 연구에 따르면, 2018년에 미국에 있는 일자리의 60%는 1940년 이후에 생긴 직업이다(Autor et al., 2022). 기술 발전으로 인해 사라지는 일자리가 많더라도 새로 생기는 일자리가 있어서 일자리의 규모 자체는 줄어들지 않을 수 있다는 사실을 가시적으로 보여준다. 요컨대, 지금까지 기술 발전은 절대적인 수준에서 고용규모의 축소나 실업률의 증가를 초래했다고 보기 어렵다. 이제 질문은 AI 기술 발전도 마찬가지로 이어진다.


[그림 2-1] 일자리 창출과 소멸 예측(2023~2027년)



자료 : WEF(2023).

[그림 2-2] 1940년과 2018년 미국의 산업별 일자리 규모

Figure 2: Employment Counts by Broad Occupation in 1940 and 2018, Distinguishing Between Titles Present in 1940 Versus Those Added Subsequently



자료 : Autor et al.(2022).

기술 발전으로 인해 일자리 규모가 줄어들지는 않더라도 불균형한 영향으로 인해 불평등을 증가시킬 수 있다는 연구는 다수 발견된다. Acemoglu and Restrepo(2022a, 2022b)에 따르면, 1987~2016년 사이 미국 경제에서 자동화로 인한 대체효과가 크게 증가했으며, 새로운 과제 도입으로 인한 재

배치 효과는 감소했다. 이 기간 동안 발생한 숙련노동에 대한 상대적 수요 증가의 30%는 자동화로 인한 대체 효과로 설명되며, 임금구조 변화의 50~70% 역시 자동화로 인한 과업 대체 효과로 설명된다. 이러한 추세가 노동소득분배율 감소와 임금 정체의 주요 원인으로 작용했다는 것이다. 결국, 자동화는 주로 비숙련 노동이 수행하던 과제를 대체함으로써 숙련 프리미엄을 증가시킨다는 결론에 도달했다.

미국을 넘어 OECD 국가 전반에서도 비슷한 현상이 관찰된다(Lazear et al., 2023). 근로자 임금 격차는 증가했고, 90/50 비율 증가도 뚜렷하다. 생산성 또는 1인당 GDP의 증가는 임금 분포의 상단과 하단에 있는 근로자의 임금을 높이는 결과를 초래하는데, 그중에서도 상위 소득 계층의 근로자가 임금이 가장 많이 상승했다. 이러한 임금 인상을 설명하는 유력한 요인은 디지털 혁명의 숙련편향적 기술변화라고 저자들은 설명하고 있다.

제2절 인공지능이 고용에 미치는 영향

1. 이번엔 다를까?

과거의 경험을 단순화해 보자면, 기술 발전은 절대적인 수준에서 고용 규모를 줄이지는 않았다. 일자리가 줄어드는 분야가 있지만, 다른 한편에서는 늘어났기 때문이다. 하지만, 기술 발전은 불평등을 증가시키는 방향으로 작동해 왔다. 고숙련 노동자는 수혜집단이었고, 피해집단은 임금 수준으로 볼 때 중간 정도에 해당하며 정형화된 업무를 수행하던 제조업 노동자들이었다.

인공지능 기술 발전의 영향은 이와는 다를까? 위에 정리한 기술 발전의 고용효과를 염두에 둔다면, 이 질문은 두 가지 질문으로 나뉜다. 첫째, 인공지능 기술은 사람이 수행하던 과업을 대체함으로써 일자리를 줄일까? 둘째, 인공지능 기술은 불평등을 축소하는 방향으로 작동할까? 즉, 인공지능 기술 발전의 피해집단은 과거 기술 발전의 피해집단과 다를까?

이런 질문이 제기되는 이유는 인공지능 기술이 기존의 자동화 기술과는 다른 특성을 갖기 때문이다. 첫째, 인공지능의 영향 범위가 더 넓을 수 있다. 컴퓨터나 로봇도 자동화 기술이며 영향을 미치는 범위가 매우 넓다. 하지만 ‘인공지능 기술은 다르다’라고 하는 주장은 인공지능의 영향 범위가 더욱 넓다는 인식을 깔고 있다. 생성형 인공지능 기술이 나오기 이전의 분석형 인공지능은 기본적으로 예측 기술이자 분류 기술이라고 할 수 있고, 그 영향 범위가 컴퓨터나 로봇보다 넓을 것 같지 않다. 하지만 생성형 인공지능은 인간만이 가진 것으로 여겨지던 여러 가지 능력을 대신할 수 있을 것으로 보인다. 듣고 이해하고 말하고 쓰는 언어 능력을 보여주고 있을 뿐 아니라, 소리를 듣거나 이미지를 보고 상황을 파악하는 능력도 보여준다. 창작의 영역에서도 놀라운 결과물을 내고 있다. 생성형 인공지능이 할 수 있는 일이 인간의 능력에 근접하기 때문에, 인공지능의 고용효과가 더 광범위하지 않을까 짐작하게 된다.

둘째, 인공지능이 대체하는 직무는 전문직이나 관리직, 고숙련 직종에 더 많이 분포하고 있다는 주장이다. 과거 자동화 기술이 저임금 일자리나 정형화된 과업에 집중되어 있던 것과 비교된다. 인공지능을 분석형 인공지능과 최근에 등장한 생성형 인공지능으로 구분하여 살펴보자. 분석형 인공지능은 예측 비용을 크게 줄이는 기술(Agrawal et al., 2019)이므로 예측이 사용되는 모든 곳에서 작업, 직종 및 기업 운영 방식의 변형이 일어나게 되고, 특히 인공지능은 모니터링과 평가에 크게 도움이 되는 기술이므로 중간관리직의 역할을 대신할 것이라는 논의가 있다(데이비드 드 크리머, 2022). 생성형 인공지능은 문서의 정리와 이미지 창작에 이르기까지 다양한 용도로 활용 가능하다. 따라서 로봇의 영향을 상대적으로 적게 받았던 관리직과 전문직 등 화이트칼라 중상위층에서 AI의 노동 대체가 예상되고 있다(Eloundou, Manning, Mishkin and Rock, 2023).

인공지능 기술이 대체할 수 있는 과업이 과거 자동화 기술보다 광범위한지, 고임금 숙련 노동자의 과업을 대체하는 경향이 있는지 아직은 불확실하다. 현재는 가설 단계이며, 경험적으로 확인되어야 할 문제이다. 이런 문제의식을 반영하는 기존 연구를 검토해 보자.

2. 고용에 미치는 영향

가. 직업별 AI 노출도와 대체 가능성

어떤 일자리가 AI로 대체될까? 내 일자리는 안전할까? 이것은 AI 기술 발전의 시대를 맞이하여 사회적 관심이 집중된 질문이다. 이 질문을 학술적으로 정의하면 ‘AI 노출도(Exposure Rate)’라는 개념으로 정리된다. AI에 노출된 직종이란 AI가 대체할 가능성이 큰 직무로 구성된 일자리를 의미한다. 개별 직종에 대하여 다양한 방식으로 AI 노출도를 측정하여 부여하는데, 노출도가 높은 일자리는 고용이 줄어들 가능성이 높다는 의미로 해석될 수 있다.

AI 노출도를 측정하려는 몇 가지 중요한 시도들이 있었다. Webb(2019)은 AI 관련 특허의 제목과 초록에 등장하는 설명 및 직업 사전(O*NET)에서 개별 직업에서 하는 일을 묘사한 내용 사이에 일치하는 정도를 가지고 개별 직업의 AI 노출도를 측정했다. Felten et al.(2018)은 AI가 할 수 있게 된 기능을 O*NET이 제시하는 52가지 능력(abilities)과 연결하여 개별 직업이 AI에 영향받을 수 있는 가능성의 크기를 측정하였다. 하지만 이 두 연구에서는 AI 노출도를 직업 간에 상대적인 차이로 파악하였으며, 구체적으로 몇 %의 일자리가 영향을 받는다는 식의 결론을 내리지는 않았다.

Eloundou et al.(2023)은 대규모 언어 모델의 일종인 ChatGPT-4를 이용하여 개별 직종을 구성하는 직무(task)와 세부 작업 활동(detailed work activities)을 AI가 수행하면 작업시간을 단축시킬 수 있는지 조사하는 방법으로 AI 노출도를 측정했다. 이 연구에서는 LLM(대규모 언어 모델) 도입으로 인해, 미국 근로자의 약 80%는 최소한 10% 이상의 업무에 영향을 받게 되며, 약 19%의 근로자는 50% 이상의 업무가 영향을 받게 된다고 주장했다. Gmyrek et al.(2023)은 Eloundou et al.(2023)의 노출도 측정 방법을 이용하여 ILO에 가입한 여러 국가를 대상으로 생성형 인공지능(Generative AI) 기술, 특히 LLM 모델의 영향을 평가했다. 고용에 미치는 영향은 국가별 소득 수준에 따라 크게 다를 것으로 분석되었는데, 저소득 국가에서는 전체 고용의 0.4%만이 AI로 인한 자동화에 노출된 반면, 고소득 국가에서는 5.5%로 나타났다.

우리나라에서는 한지우·오삼일(2023)의 연구가 Webb(2020)의 AI 노출도를 한국표준직업분류 코드로 변환하여 적용하였다. 이 논문은 우리나라 전체 취업자의 12%에 해당하는 약 341만 명이 AI 기술에 의한 대체 가능성이 높은 일자리를 가지고 있다고 추정했다. 한편, 한요셉(2023)은 전문가 평가와 ChatGPT-4의 응답을 기초로 일자리의 기술적 자동화 가능성을 추산하였는데, 70% 이상의 업무 자동화가 가능한 일자리가 전체의 38.8%에 달하는 것으로 나타났다. 2030년에는 전체 일자리의 90%에서 직무의 90% 이상을 자동화할 수 있을 것으로 내다봤다. 기존 연구들에 비해 매우 높은 수준의 AI 노출도를 보고한 것으로 볼 수 있다.

AI 노출도는 자동화 가능성의 최대치라고 해석하는 것이 타당하다. 기술적으로는 사람이 하던 일을 AI가 할 수 있다고 할지라도 실제로 기업이 고용을 줄이고 AI 기술을 도입하는 결정을 하는 데에는 여러 가지 다른 고려 사항들이 등장하지 않을 수 없다. Acemoglu(2024)는 AI에 노출되는 과업 중에서 실제로 AI가 채택되어 대체될 가능성을 추정하였다. 미국 노동자들이 수행하는 과업의 약 20%가 AI에 노출되어 있지만, 이 중에서 향후 10년 이내에 채택 가능하고 수익성이 있는 과업의 비율은 23% 수준이라고 추정했다. 결국 4.6%에 해당하는 과업만이 AI의 영향을 받게 될 것으로 예측했다.

이상에서 살펴본 바와 같이, AI가 직무의 일부를 대신함으로써 과업 완수에 필요한 시간을 줄이고, 이로 인해 일부 직종에서는 일자리가 줄어들 수 있다고 결론 내리는 것은 타당해 보인다. 다만 그 규모가 어느 정도나 될 것인지가 관건인데, 기존 연구들이 제시한 수치들은 스펙트럼이 매우 크다. AI가 완성된 기술이라기보다는 아직은 빠르게 변화하고 있는 기술이기도 하고, 연구방법론의 개발도 더 필요할 것으로 보인다.

나. 기업의 AI 도입과 고용의 관계

AI 기술 발전이 고용을 감소시킬지 살펴보는 다른 방법은 AI 기술을 도입한 기업의 고용 변화를 분석하는 것이다. 몇몇 연구에서는 AI 기술과 고용 간에 음의 상관관계가 감지되었다. 그러나 기업의 AI 기술 도입 또는 관련 투자가 반드시 전체 일자리 수를 감소시킬 것으로 예상할 수는 없다. AI 기

술 도입은 기업의 매출을 증가시켜 고용 증가로 나타날 수도 있다. 문제는 'AI 기술을 도입한 기업'을 어떻게 식별할 것인가에 달려있는 것으로 보인다. 기업의 고용성과는 AI 도입 여부 또는 AI 투자를 측정하는 방법에 따라 다른 결론에 도달할 수 있다.

하나의 측정 방식은 기업의 직종별 구성을 AI 노출도를 기준으로 살펴보는 것이다. 기업의 종업원 구성에 있어서, AI 노출도가 큰 직종의 비중이 높다면 이들의 고용이 줄어들 것으로 예상하는 것은 자연스럽다. Acemoglu, Autor, Hazell and Restrepo(2022)의 연구가 이러한 분석 사례다. 저자들은 직업별 AI 노출도를 측정한 후 기업 단위로 환산하는 방법을 사용하여 AI가 고용에 미치는 영향을 계산하였다. 개별 기업의 온라인 구인공고에 올라오는 일자리를 직업별로 카운트해서 어떤 일자리가 새로 생기는지 파악하고, 그 일자리의 AI 노출도로 Felten의 노출도 지표와 Webb의 노출도 지표를 적용했다. 이 연구에서는 AI 노출이 높은 기업에서 non-AI 일자리와 전체 일자리의 고용이 감소하는 경향이 발견되었다. 이를 근거로 저자들은 AI가 생산성을 높여 고용을 증가시킬 수 있다는 기대에 대한 증가를 발견하지 못했다고 결론 내렸다. 이러한 결론은 저자들의 다른 연구(Acemoglu and Resprepo, 2020)에서 로봇 기술이 고용에 크고 강력한 부정적인 영향을 미쳤다는 분석과 함께 살펴볼 필요가 있다. AI는 로봇과는 다른 방식이지만 자동화 기술의 일종으로 볼 수 있고, 기업 수준에서는 고용을 줄일 가능성을 제기하는 것이다. 그러나 저자들은 이 기술의 영향이 아직 미국 노동시장 규모에 비해서 작기 때문에 노동시장 전체에 의미 있는 영향을 미치지 않는다고 보았다.

기업의 AI 기술 도입 여부를 측정하기 위해서 설문조사를 통해 직접적으로 물어보는 방식을 취할 수 있다. OECD 연구팀은 기업의 AI 도입 현황을 파악하기 위해서 제조업과 금융업 분야의 2,053개 기업을 대상으로 설문조사를 실시하였는데, AI를 도입한 후 고용을 줄였다고 응답한 사례가 보고되었다. AI 도입 후 새로운 작업이 창출되기도 하지만, 그보다는 반복적이고 위험한 작업을 자동화하는 경향이 명확하기 때문이다(Lane, Williams, and Broecke, 2023). 우리나라에서는 통계청의 「기업활동조사」 자료가 기업의 인공지능 도입 여부와 고용량을 모두 알려준다. 한요셉(2023)과 정소라·성낙일(2024)은 각각 이 데이터를 패널분석 하였는데, 두 논문에서 모두 AI를 도입한 기업과

도입하지 않은 기업 간에 고용규모 증가 수준의 차이를 발견하지 못했다.

기업의 AI 관련 투자를 특허출원 여부로 판단할 수도 있다. Alderucci et al.(2020)은 패널분석을 통해 AI 특허 출원 전후의 기업성장을 분석하였는데, AI 혁신 기업은 그렇지 않은 기업에 비해 고용 성장이 25% 빠른 것으로 분석되었다. 이것은 AI 투자가 기업의 생산성을 증가시켜 매출과 고용을 늘린다는 가설을 지지하는 것이어서 앞서 소개한 다른 연구 결과와 대비된다. 한편, Damoli et al.(2023)은 2000~2016년 기간 동안 AI 관련 특허를 출원한 전 세계 5,257개 기업을 분석했는데, 일관성 있는 고용효과를 발견하지는 못했다. AI 기술의 고용효과는 업종별로 달랐다. 특정 산업에서는 고용을 증가시키는 반면, 다른 산업에서는 고용을 감소시키는 것으로 나타났다.

Babina et al.(2020)은 기업의 AI 관련성을 구인공고에 나타난 숙련수요로 측정했다. AI 관련 숙련을 요구하는 구인공고를 많이 게시한 기업은 AI 투자가 큰 기업으로 본다는 가정이다. 이렇게 정의하고 분석한 결과, AI 투자가 큰 기업은 매출과 고용 모두에서 더 빠른 성장을 경험하는 것으로 나타났다. 이 연구에 따르면, 기업의 AI 기술 투자는 다음과 같은 기제를 통해서 기업의 성장과 고용 증가를 초래할 수 있다. 첫째, AI 기술은 예측과 관련된 비즈니스 프로세스를 효율화하여 예측 정확도와 리소스 할당을 개선시킴으로써 생산성을 향상시킨다(Productivity Channel). 둘째, 제품 제공 맞춤화와 온라인 광고의 타겟팅을 통해 AI 투자 기업은 가격을 차별화하고 시장 지배력을 확보할 수 있다(Market Power Channel). 셋째, AI는 가장 규모가 크고 가장 생산적인 기업에 사전 혜택을 주는 규모의 이점을 창출하기도 한다(Scale Advantages Channel).

기업의 AI 기술 도입률(Adoption Rate)을 어떻게 정의하는가에 따라 고용에 미치는 영향이 달리 나타나는 것으로 보인다. 기업의 AI 도입률을 구성원 직종의 AI 노출도의 합으로 간주하면 AI의 고용효과는 부정적으로 나타난다. 기업 대상 설문조사로 AI 도입 여부를 직접적으로 질문하는 방식을 취했을 때에는 고용효과는 중립적으로 나타나는 경향이 있다. 이런 척도와는 달리, 기업의 AI 특허출원이나 AI 관련 숙련수요로 AI 도입률을 측정하는 것은 기업의 보다 적극적인 AI 투자 행위를 측정하는 것일 수 있다. 이 경우에는 기업의 AI 투자가 고용 증가에 긍정적인 영향을 미치는 것으로 관찰되었다.

3. 불평등에 미치는 영향

AI가 불평등에 영향을 미치는 경로는 두 가지로 구별해 볼 수 있다. 첫째는 일자리 대체 경로이다. AI 기술이 어떤 일자리를 대체하느냐에 따라 불평등이 심화될 수도 있고, 심지어 완화될 수도 있다. 기존의 자동화 기술은 중간 임금 수준의 정형 과업을 대체함으로써 양극화를 초래했다고 알려져 있다. 이와 달리, AI가 중간관리자와 전문직 일자리, 고숙련·고임금 일자리를 대체하는 경향이 확인된다면 불평등 완화 효과를 나타낼 수 있다.

둘째 경로는 AI 숙련이나 기업의 AI 투자에 대한 보상 경로이다. AI와 직접적으로 관련되는 숙련에 대해서 높은 보상이 부여되거나 AI 투자에 적극적인 기업이 현저하게 높은 성과를 나타내게 된다면 이는 불평등 심화로 귀결될 가능성이 크다.

가. 일자리 대체 경로


AI가 가진 기술적 가능성은 전문직과 관리직의 높은 AI 노출도로 나타난다. 이것은 AI 기술 발전으로 인해 사라지는 일자리가 임금 분포에서 상위에 위치하는 일자리가 될 것임을 시사하는 것일까?

McKinsey and Company(2023)는 지식노동의 자동화가 시작되었다는 분석을 다각도로 제시했다. 의사결정이나 협업을 하는 과업은 당초에는 자동화 가능성이 낮았지만 인공지능을 활용하면 자동화 가능성이 상당히 증가한다고 주장했다. 또한, 학력 수준이 높을수록 인공지능으로 인한 자동화에 영향을 많이 받는 것으로 나타난다고 한다(그림 2-3).


Felten의 AI 노출도(Artificial Intelligence Occupation Exposure : AIOE)를 우리나라 데이터에 적용한 연구에서도 학력이 높은 직업일수록 AIOE 점수가 높게 나타났다(전병유 외, 2022). Webb의 AI 노출도를 적용한 연구에서도, 기존 기술(산업용 로봇 및 소프트웨어)과 달리 고소득·고학력 근로자가 AI에 더 많이 노출되어 있는데, 이는 AI가 비반복적·인지적(분석) 업무를 대체하는 경향이 크기 때문으로 해석했다(한지우·오삼일, 2023).

24 인공지능(AI) 발전의 고용효과

[그림 2-3] Overall technical automation potential, comparison in midpoint scenarios(2023)



자료 : McKinsey and Company(2023).



나. AI 숙련에 대한 보상 경로

AI 기술 발전은 AI 숙련과 non-AI 숙련에 대한 보상 격차를 확대시키거나, AI 기술 도입 기업과 미도입 기업 간 임금격차를 확대시킬 가능성이 있다.

Alekseeva et al.(2021)은 같은 기업 내 AI 숙련 일자리에 11% 임금 프리미엄이 주어지며, 같은 직종 내에서도 5%의 프리미엄을 제공한다고 분석하였다. AI의 일자리 대체 효과가 클 경우 AI 구인 비율이 높은 회사는 non-AI 일자리의 임금을 낮출 수 있다는 분석 결과도 도출했다. Alderucci et al.(2020)도 AI 기술 투자는 매출과 고용을 증가시키지만, 기업 내 임금격차도 증가시킨다는 사실을 보였다. Fossen and Sorgner(2019)도 기존 IT 기술과는 달리 AI 숙련은 개인의 직업안정성과 임금을 높이는 것으로 분석했다.

제3절 측정 문제

1. 인공지능의 영향을 어떻게 측정할 것인가?

인공지능 발전의 고용효과를 분석한 기존 연구들은 다양한 방식으로 인공지능의 영향을 측정했다. 우리는 이런 측정도구들이 내놓은 지표를 모두 ‘인공지능의 영향’이라고 부르지만, 이 지표들이 측정한 것이 모두 같은 개념인지는 의문이다. 인공지능의 고용효과를 분석한 각각의 연구들은 과연 무엇을 측정한 것인가? 이 절에서는 인공지능의 영향을 측정하는 척도에 집중하고자 한다.

‘인공지능이 발전하면 우리 일자리는 어떻게 될까?’라는 질문에 답하려면, 먼저 ‘인공지능의 발전’을 수치로 포착해야 한다. 기존 연구들에서는 인공지능 노출도(AI Exposure Rate)와 인공지능 도입률(AI Adoption Rate)의 두 가지 척도가 발견된다.

AI 노출도는 개별 직무(job, 또는 과업 task) 또는 직업(occupation)에 대

해서 측정하는데, 사람이 수행하던 이 직무를 AI가 얼마큼이나 대신 수행할 수 있는지를 반영하는 지표다. AI 도입률은 실제로 AI 기술을 채택하여 사용하고 있는 정도를 측정한다. AI 노출도가 아직은 가능성의 영역이라면, AI 도입률은 실제로 실현된 정도를 반영하는 지표다.

AI 노출도는 AI 기술 발전으로 인해 영향받는 직무를 양적으로 포착하는 개념이다. 기술이 발전하면 그로부터 영향을 받는 직무는 늘어난다. 사람이 그 직무를 더 짧은 시간에 해낼 수 있게 되거나, 더 좋은 결과물을 내놓을 수 있게 되거나, 아니면 그 직무를 전적으로 자동화하여 더 이상 사람이 수행하지 않게 될 수도 있다. AI 노출도는 이런 현상의 최대치를 측정하는 척도라고 볼 수 있다.

어떤 직무를 대신할 수 있을 만큼 AI 기술이 발전하더라도 바로 AI로 대체되는 것은 아니다. 여러 가지 이유로 인해 AI가 실제로 직무를 수행하는 정도, 즉 도입률은 노출도에 비해 적을 수밖에 없다. 가장 중요한 이유는 비용 효율성이다. 기업은 비용이 절감되는 경우에만 신기술을 채택한다. 노동자들이 신기술 사용을 거부하거나 제도적 제약이 있어도 신기술은 채택되기 어렵다. 신기술의 채택, 즉 AI 도입률은 중요한 개념이다.

AI의 영향을 개념화하는 방법뿐만 아니라 측정 단위도 중요하다. AI 노출도는 직무, 직업, 기업 등 다양한 단위에서 측정할 수 있다. 애초에는 직무 단위로 측정하더라도, 직업(=일자리)은 직무의 합이고, 기업이나 산업, 지역은 그 안에 포함되어 있는 일자리의 합으로 계산할 수 있으므로 결과적으로는 직업, 기업, 산업, 지역 단위로 측정할 수 있다. AI 기술의 도입률은 개념적으로는 직무 단위 혹은 직업 단위로 측정할 수 있지만, 도입 여부를 판단

〈표 2-1〉 AI 노출도와 도입률의 측정 단위와 측정 사례

		직무	직업	기업	산업/지역
노출도	Felten et al. (2018)				
	Webb (2020)				
	Eloundou et al. (2023)				
도입률	Svanberg et. al. (2024)				
	Babina et al. (2020)				
	Survey				

자료: 저자 작성.

하는 주체는 기업이기 때문에 기업 단위로 측정하는 것이 자연스럽다. 하지만, 직무 단위로 측정된 노출도에 실제로 채택될 확률 추정치를 곱해서 도입률을 측정한 사례도 있다.

2. AI 노출도 척도와 측정 사례

개별 직무 또는 직업에 대한 AI 노출도를 측정하는 방법으로 다음과 같은 세 가지가 가장 널리 알려져 있으며 흔히 이용된다. 첫째, AI 기술을 잘 아는 전문가를 활용하여, AI 기술을 직업사전(O*NET)이 소개하는 52가지 능력(abilities) 목록에 맵핑하여 개별 직업의 노출도를 측정한다(Felten, 2018). 둘째, AI 관련 특허출원 문서와 직업사전 문서에 등장하는 직무 설명 텍스트의 유사성을 근거로 직업의 AI 노출도를 측정한다(Webb, 2019). 셋째, 개별 직업에서 수행하는 과업(task)을 설명하는 텍스트를 LLM 모델에 제시하고 과업 수행 시간을 줄일 수 있는 정도를 질문하여 과업별 대체 가능성을 측정한다(Eloundou, 2023).

가. Felten의 AIOE

Felten은 직업별로 AI 노출도를 측정하는 척도(Artificial Intelligence Occupational Exposure : AIOE)를 처음 소개했고(Felten, 2018, Felten et al., 2019), 이후 AI 기술 발전 수준을 반영하여 수정했다(Felten et al., 2023). Electronic Frontier Foundation이 제공하는 'AI Progress Measurement dataset'에 등장하는 AI 응용 기술⁹⁾의 내용을 O*NET이 소개하는 52가지 인간 능력(abilities)¹⁰⁾과 연결한다. 이 매트릭스는 여러 명의 컴퓨터 전공 박사과정 학생들이 입력했다. 각 직업에서 필요로 하는 능력의 등장 비율과 중요성에 따라 가중치를 부여하여, AI 기술이 직업에 미치는 영향을 평가한다. 점수 자체의 가치는 임의적이지만 다양한 직업에 걸쳐서 상대적인 영향을 비교할 수 있다고 설명하고 있다.

9) 이미지 생성, 언어모델, 실시간 비디오 게임 등.

10) 구술 이해, 구술 표현, 귀납적 추론, 팔과 손의 안정성 등.

Felten et al.(2023)은 생성형 AI 노출도가 직업별로 어떻게 분포되어 있는지 살펴보았는데, 높은 연봉과 높은 교육 수준을 요구하는 직업이 더 많이 노출되어 있는 경향이 발견되었다. Georgieff and Hyee(2021)는 Felten의 AIOE 지표를 23개 OECD 국가의 직종별 고용구조 데이터에 적용하였다. 전반적으로 AI 노출도와 고용 증가 사이에는 명확한 관계를 발견하지 못하였으나, 컴퓨터 사용률이 높은 직종에서는 AI 노출도가 높으면 고용증가율이 높게 나타났다.

우리나라에서는 전병유 외(2022) 연구가 2019년 버전의 AIOE 연계표를 Felten으로부터 직접 받아서 우리나라 데이터에 적용했는데, 여기에서도 AIOE가 높을수록 고용이 증가하고 임금 프리미엄도 높은 것으로 나타났다.

한요셉(2023)은 Felten 방식을 채용하되, 지표를 곧바로 적용하지 않고 AI 노출도를 자체 측정했다. 한국고용정보원의 「재직자 조사」(2020)가 제공하는 44개 업무수행능력에 대해 전문가의 평가를 토대로 대체 가능성을 측정하고 이를 고용통계에 적용했다. 그 결과, 70% 이상의 업무 자동화가 가능한 일자리는 38.8%로 높게 나타났다. Felten의 AIOE를 그대로 적용한 연구와는 달리, 이 연구에서는 전문가와 고속련 직종의 자동화 가능성은 낮은 것으로 나타나고 저임금 직종의 자동화 가능성은 높게 나타났다.

나. Webb의 노출도

Webb(2019)은 미국 특허 데이터와 O*NET 직업 설명 데이터를 사용하여 AI 기술의 노출도를 측정했다. 특허출원 자료에서 제목과 초록에 등장하는 기능에 대한 설명과 O*NET의 직무 설명 사이의 일치 정도를 자연어처리 방법으로 식별하여 AI가 어떤 작업을 수행할 수 있는지 측정했다. 여기서 중복 수준이 높으면 이 직업은 AI에 더 많이 노출된 것으로 분류한다. Webb(2020)은 이 지수를 미국 일자리에 적용한 결과, 고학력·고임금 일자리가 상대적으로 AI에 더 많이 노출되어 있는 것으로 나타났다.

우리나라에서는 한지우·오삼일(2023)의 연구가 이 방법을 활용하였다. Webb(2019)이 미국 직업코드를 한국표준직업분류(KSCO, 소분류)와 매치시켜서 AI 노출지수를 구했다. 전체 취업자의 약 12%는 AI 기술에 의한 대


체 가능성이 높은 일자리에 있는 것으로 나타났다. Webb의 노출도 지수를 그대로 가지고 왔으므로, 우리나라에서도 고소득·고학력 노동자의 일자리가 AI에 더 많이 노출되어 있는 것으로 나타났다.

다. Eloundou의 노출도

Eloundou et al.(2023)은 OpenAI사의 ChatGPT-4 모델을 사용하여, O*NET이 직업의 하위 구성요소로 제시하는 특정 작업들을 수행함에 있어서 생성형 AI를 활용하면 소요시간이 줄어드는지 평가했다. LLM을 사용하면 특정 작업을 완료하는 데 걸리는 시간을 50% 이상 단축시킬 수 있는가? 소요시간을 절반으로 줄이지 못하거나 LLM을 사용하면 결과물의 품질이 저하되는지? LLM을 기반으로 추가 소프트웨어를 개발하면 소요시간을 50% 이상 절감할 수 있는지? 등등의 질문으로 평가했다. 이 질문을 O*NET에서 제공하는 1만 9,265개 직무(task description)와 2,087개의 세부작업활동(Detailed Work Activities : DWA)에 적용했다. 이 연구에서는 ChatGPT-4 활용이 타당한지 평가하기 위하여 사람의 평가도 동시에 진행하였으며, 두 결과가 상당히 유사했다고 보고하였다.

이 연구는 미국 노동자의 약 80%가 LLM 도입으로 인해 그들의 직무에 적어도 10% 이상의 영향을 받게 될 것이며, 약 19%의 노동자는 50% 이상의 영향을 받을 수 있다고 보고했다(Eloundou et al., 2023). Acemoglu(2024)는

[그림 2-4] ChatGPT 평가와 사람의 평가 비교



자료: Eloundou et al.(2023).

이 연구방법을 채용하여 미국 노동자의 과업의 20%가 AI에 노출되었다고 평가하였다.

Gmyrek et al.(2023)은 Eloundou의 AI 노출도 측정 방식을 ISCO에 명시된 직업별 세부 과업(tasks)에 적용하고 그 결과를 국제 비교에 활용하였다. 사무지원직이 가장 높은 노출도를 보였고, 전문가와 준전문가의 일부 직종도 노출도가 높았다. 관리자와 서비스직, 판매직의 노출도가 상대적으로 낮게 나타났다.

우리나라에서는 장지연(2024)이 이 방법을 우리나라 직업사전에 적용하였다. 한국고용정보원이 제공하는 「재직자 조사(KNOW)」의 직무 설명과 한국고용직업분류(KECO)의 직업별 직무 설명을 ChatGPT-4에 제시하고 AI 노출도 점수를 도출했다. 사무·금융직 일자리와 일부 연구·전문직 일자리에서 AI 노출도가 높았으며, 생산직도 장치 산업에서는 노출도가 높게 나타났다.

3. AI 도입률 척도와 측정 사례

새로운 기술이 등장하더라도 모든 기업이 이 기술을 도입해서 쓰는 것은 아니며 실제로 기술이 일터에서 사용되기까지는 시간이 걸린다. 최근으로 올수록 기술의 확산 속도가 빨라지는 경향은 있지만, 신기술 채택은 우리가 생각하는 것보다 느리게 진행된다. 증기기관은 널리 활용되는 데 30년 이상이 걸렸고, 비교적 속도가 빨랐다는 컴퓨터만 해도 10년 이상이 걸렸다(Lazear et al., 2023). AI가 일터에 도입되는 데에도 어느 정도 시간이 필요하다.

AI 도입률 또는 기업의 AI 도입 여부를 판단하는 방법으로 다음과 같은 몇 가지 시도들이 있었다. 첫째, 기술적 실현 가능성과 경제적 매력도까지 고려하여 작업(task) 수준의 대체 가능성을 측정하는 방법. 둘째, 기업 대상 설문조사(survey)를 통해 AI 도입 여부를 직접적으로 물어보는 방법. 셋째, 기업의 채용공고에서 AI 관련 숙련을 요구하는 공고가 발견되면 AI를 도입한 것으로 간주하는 방법.

가. Svanberg의 AI 도입 가능성 측정

단순히 AI 기술이 사람이 하던 작업을 수행할 수 있다고 할지라도 경제성이 낮다면 채택되지 않을 것이다. Svanberg et al.(2024)은 기존의 AI 노출도 측정이 실제로 AI가 도입될 가능성과는 거리가 있다는 점을 지적하며 기술적 구현 가능성과 경제성을 모두 고려하는 모델을 제안하였다. O*NET이 제공하는 정보를 활용해 414개 컴퓨터 비전과 관련되는 작업을 식별하고, 각 작업에 필요한 정확도, 소요비용 등을 설문조사로 파악한 후 AI 시스템을 구축하는 것과 사람이 수행할 때 들어가는 노동비용을 비교하여 경제성을 평가했다. 그 결과 미국 기업의 36%가 컴퓨터 비전에 노출된 작업을 보유하고 있으나 경제적으로 매력적인 작업의 비중은 전체의 8%에 불과하다고 보았다. AI로 인한 노동 대체 속도는 예상보다 느릴 것이며 컴퓨터 비전 자동화로 인해 줄어드는 일자리는 일부에 불과할 것으로 예측했다.

Acemoglu(2024)는 AI 노출 과업 중에서 실제로 AI가 채택될 가능성을 추정하는 Svanberg et al.(2024)의 방법론을 활용하였다. 향후 10년 이내에 AI가 채택될 가능성이 높은 수익성 있는 과업의 비율을 23%로 추정했다.

나. 기업 설문조사

기업의 AI 기술 도입 여부는 설문조사를 통해 파악할 수 있다. OECD는 오스트리아, 캐나다, 프랑스, 독일, 아일랜드, 영국, 미국 등 7개국 제조업과 금융업 분야 2,053개 기업을 대상으로 AI 도입 현황을 조사했다. AI의 정의를 제시하고, AI를 사용하고 있는지 질문하는 단순한 방식이다.

우리나라에서도 몇 가지 유사한 설문조사가 있다. 통계청의 「기업활동조사」에서는 다른 여러 가지 기술 도입 여부와 함께 AI 도입도 질문하고 있는데, 전 산업에서 AI 도입 기업의 비율은 3.09%로 조사되었다(한요셉, 2023). 한국개발연구원의 조사에서도 도입 기업의 비율은 3.6%로 나타났다(한요셉, 2023). 과학기술정보통신부의 「정보화통계조사」에서는 10인 이상 기업의 2.7%가 인공지능 기술을 도입하고 있으며, 250인 이상 대기업 중에서는 20%가 AI 기술을 사용하고 있었다. 한편, 정보통신정책연구원의 「인공지능

도입에 관한 기업실태조사」에서는 AI 기술 도입 비율이 14.7%로 높게 조사되었다(김경훈 외, 2021).

다. Babina의 AI 관련성 지수

Babina et al.(2020)은 개별 기업이 온라인에 게시하는 구인공고 중에서 AI 관련성이 높은 공고의 비율을 기업의 AI 관련성 지수로 보자고 제안했다. AI를 다루는 숙련(skill)을 가진 노동자를 채용하고자 하는 기업은 AI를 도입한 것으로 볼 수 있기 때문이다. 이 지수는 단순히 AI 기술 채택 여부를 측정하는 것을 넘어, 기업이 AI 기술을 얼마나 광범위하게 도입하고 있는지를 측정할 수 있게 해준다.

측정은 3단계로 이루어진다. 먼저 개별 숙련의 AI 관련도를 측정한다. 머신러닝, 자연어처리, 컴퓨터 비전을 세 가지 핵심 AI 관련 숙련으로 보고, 이 숙련과 동시에 등장하는 숙련을 AI 숙련이라고 본다.

$$AIShare_{f,t} = \frac{AI \text{ 숙련을 필요로 하는 } OJPs(\text{또는 일자리}) \text{의 수}_{f,t}}{\text{전체 } OJPs(\text{또는 일자리}) \text{의 수}_{f,t}}$$

두 번째 단계로 구인공고에서 요구하는 숙련의 AI 관련도의 평균값으로 각각의 구인공고(=일자리)의 AI 관련도를 측정한다. 이 값이 일정한 값 이상이면 이 일자리를 AI 관련 일자리로 본다.

$$\omega_j^{AllAI} = \frac{1}{N} \sum_{s=1}^N w_s^{AllAI}$$

세 번째 단계로 각 기업이 게시한 채용공고 중에서 AI 관련 일자리의 비율을 계산한다. 이렇게 계산한 기업의 AI 관련성 지수를 활용하여, Babina et al.(2020)은 어떤 기업이 인공지능 기술에 투자하는지 살펴볼 수 있었다.

제 3 장

AI 노출도에 따른 고용과 임금 효과

제1절 문제 제기

AI가 노동과 생산성 등에 미치는 영향을 분석하는 방법에는 두 가지 접근법이 있다(Gmyrek et al., 2023; Georgieff and Hyee, 2021). 첫 번째 접근은 앞 장에서 본 바와 같이 구인공고 데이터(OJPs)를 사용하여 AI 숙련(skill) 키워드를 도출하고 분석하는 접근이다. 이는 기업의 AI 숙련수요를 실시간으로 파악하는 데 적합하다. 다만, 채용이 많은 기업에서는 잘 작동하지만, AI 업무를 하도급하거나, AI 인력 수요를 자체 교육훈련으로 충당하거나, 온라인 플랫폼을 이용하지 않고 자사 홈페이지 등을 활용하는 기업들을 대표하지 못하는 문제가 있을 수 있다.

두 번째 접근 방식은 특정 직업을 구성하는 과업(task) 또는 숙련(skill)의 AI 관련성을 도출하고 직업 구성의 변화에 초점을 맞추는 접근이다. 이 방법의 장점은 직업 분류를 공식 노동시장 통계와 쉽게 연결할 수 있다는 점이다(Georgieff and Hyee 2021).

OJPs를 활용하여 도출된 AI 지표가 기업의 AI 인력 수요를 반영한다면, 두 번째 직업의 과업기반 접근법은 인간 노동이 AI에 어느 정도 노출되어 있는지, 즉, AI가 인간 노동을 대체할 것인가(자동화, automation), 아니면 인간 노동을 보완할 것인가(증강, augmentation)를 분석하는 데 더 적합한 지

표라고 할 수 있다.

이 장에서는 직업정보를 활용하여 직업별 AI 노출도(AI Occupational Exposure, 이하 AIOE)를 측정하고 이를 고용과 임금 통계에 연계하여 AI가 고용과 임금에 미치는 잠재적 가능성에 대해서 평가해 보고자 한다.

최근 AIOE를 측정하려는 다양한 시도가 나타나고 있다. 그런데 AI가 글로벌 빅테크 기업들의 테크노크라트(technocrat) 주도로 가능성의 경계를 허물면서 발전하고 있지만, Acemoglu and Restrepo(2020)의 “Wrong AI”나 Brynjolfsson et al.(2023)의 “Turing Trap”은 AI가 인간을 모방하는 방식에서 벗어나야 하고, 인간이 AI의 발전 방향에 대해서 통제 권한을 가져야 한다는 문제 제기를 하고 있다.

이는 AI가 기술적으로는 인간 노동을 대체할 수도 있지만, AI가 실제로 대체하느냐의 여부는 ‘인간’의 관점에서 평가되고 판단될 수 있다는 것이다. 완전한 자율주행자동차가 기술적으로는 가능할지라도 실제로 도입하느냐 여부는 책임성과 중대성 여부를 따져 인간과 사회가 최종적으로 판단하게 될 것이다. 의료 AI 기기가 병증에 대한 판독에 우수한 성과를 보인다고 할지라도 당분간 최종 판단은 의사가 하게 될 것이다. 즉, AI에 대한 사회적 수용성 정도에 따라서 AI에 의한 노동의 대체와 보완 가능성도 달라질 수 있다. 또한, 로봇이 인간 노동을 완전히 대체할 정도로 기술적 발전이 이루어진다고 하더라도, 그것이 경제적으로 기존 노동자의 임금보다 비싸다고 할 경우에는 쉽게 채택되지 않을 것이다.

최근 AIOE 측정 지표 연구는 이러한 측면까지 반영하는 방식으로 이루어지고 있다. AI의 파급효과를 단순히 기술적으로만 보지 않고, 그것이 사회적으로 수용 가능한 정도, 경제적으로 타당한 정도까지를 고려한 다양한 지표 개발이 이루어지고 있다. 제2절에서는 이러한 AIOE 지표 연구들에 기초하여 한국의 직업정보를 활용하여 다양한 AIOE 지표들을 도출하고 그것의 의미에 대해서 먼저 검토해 보고자 한다. 그리고 제3절에서는 이러한 지표들이 고용과 임금에 대해 가지는 잠재적 영향에 대해서 분석하고 평가해 보고자 한다.

제2절 직업별 AI 노출도(AIOE) 지표

가. AIOE에 대한 기존 연구

앞 장에서도 검토했듯이, AIOE 측정의 대표적 연구는 Felten et al.(2018, 2021)이다. 이들은 직업의 능력(ability) 변수와 AI 기술 특성 변수의 연관성을 기초로 하여 AI 노출도를 측정하였다.

다만, Felten et al.(2018, 2021)의 방법은 직업 특성이 AI와 관련성이 있다는 사실만을 보여줄 뿐, AI가 인간 노동에 어떤 영향을 줄지에 대해서는 불가지론적 입장을 취하고 있다. 즉, 직업의 AIOE 점수가 높다는 것이 이 직업이 AI에 의해 자동화될 가능성이 높은 것인지, AI가 이 직업을 보완할 것인지를 선형적으로 판단할 수 없다는 것이다. 경험적으로만 분석될 수 있다는 것이다.

또한, Felten et al.(2018, 2021)의 AIOE는 직업이 AIOE에 노출된 정도를 기술적으로만 측정한 것이다. 앞에서 언급했듯이, 인간, 사회, 경제가 AI를 어떻게 받아들이느냐는 반영하지 않고 있다.

이러한 측면을 반영하는 연구들이 ILO의 Gmyrek et al.(2023), IMF의 Pizzinelli et al.(2023), IAB의 Engberg(2024a, 2023b) 등이 있다.

IMF의 Pizzinelli et al.(2023)은 작업환경(work context)과 직업 숙련 수준(job zone, 교육과 숙련 수준)을 고려하여 AI가 인간 노동을 보완할 수 있는 사회적 가능성을 파악하고 이를 반영하는 “조정 AIOE(C-AIOE)” 지수를 생성하는 방법을 제시하였다. 작업환경에서 커뮤니케이션, 책임성, 의사결정 가능성, 외부 및 신체적 활동 정도, 자동화 가능성, 그리고 숙련 수준 등의 측면에서 AI가 직업의 과업을 대체하기 어렵고 보완해야 하는 사회적 맥락을 반영하는 방식이다. 예를 들어, 같은 AI 기술이 적용된다고 하더라도, 커뮤니케이션의 필요성(communication), 결과와 타인의 건강에 대한 책임성(responsibility), 외부활동 정도와 외부 사람과의 접촉 가능성(physical

condition), 의사결정의 중요성(criticality), 자동화의 어려운 정도(routine), 그리고 필요한 교육훈련 수준(skill) 등에 따라서, AI가 100% 채택되기보다는 기존 직업을 보완할 가능성이 높다고 보는 것이다. 이러한 6가지 범주를 미국 O*NET의 작업환경(work_context)과 직무영역(job zone) 변수들을 활용하여 파악하고, 이를 하나의 통합된 지표로 구성하였다.

Pizzinelli et al.(2023)은 이러한 범주를 선택한 근거도 제시하고 있다. 예를 들어, 커뮤니케이션의 경우, AI 도구가 계속 발전함에 따라 커뮤니케이션의 다양한 측면을 향상시킬 것은 의심할 여지가 없으나, 대면 상호작용의 미묘한 복잡성과 대중연설의 기술은 여전히 인간의 영역으로 남아 있을 것으로 본다. 사회적 규범은 전문적인 환경에서 이러한 정교한 인간 커뮤니케이션 기술을 보존하도록 지시할 수 있다는 것이다. 예를 들어, 배심원을 설득하기 위해 수사학을 사용하는 재판 변호사나 환자에게 진단을 설명하는 의사는 미묘한 이해, 공감, 적응력에 의존하는데, 이는 현재까지는 AI가 완벽하게 재현할 수 없다는 것이다. 또한 많은 상황에서 인간 상호작용은 성별이나 인종 등 개인적인 편견의 영향을 받는다. 이러한 경우, AI는 필수적인 대면 상호작용을 수행할 때 암묵적인 영향을 받지 않을 수 있는 편견을 완화하여 작업자를 보완할 수 있다.

한편, 독일 노동시장및직업연구소(Institut für Arbeitsmarkt und Berufsforschung : IAB)의 Engberg et al.(2023, 2024)은 AI가 인간의 사회적 측면을 대체하는 것이 어렵다는 점에 주목하여 사회적으로 조정된 AIOE 지표를 도출하고 있다. 직업의 능력이나 숙련 특성에서 사회적 측면을 반영하는 사회적 지각력, 설득력, 지시 등 6가지 유형의 사회적 능력을 지표로 만들고 AIOE를 사회적 능력 지표로 할인하는 지표(Social Adjusted AIOE)를 제시하였다.

이 지표는 직업 과업의 사회적 측면은 AI로 대체하기가 더 어렵다는 가정을 반영하는 것이다. 예를 들어, 가장 사회적인 직업인 성직자, 최고경영자, 상담심리학자 등의 경우, 당분간 많은 사람들이 영적 지도, 조직 리더십, 정신건강 상담과 같은 서비스를 위해 인간 대 인간의 상호작용을 계속 원할 것으로 보는 것이다(Engberg et al., 2023).

한편, ILO의 Gmyrek et al.(2023, 2024)은 직업정보를 활용하여 AI 중에서

도 생성형 사전훈련 트랜스포머(Generative Pre-Trained Transformer, 이하 GPT)에 노출된 정도(GPT Exposure)를 측정하였다.

특히, 이들은 직업의 다양한 과업들이 GPT에 노출되는 정도에서 차이가 있을 것이라는 점에 착안하여 GPT에 의해 자동화될 수 있는 직업과 증강될 수 있는 직업으로 분류하였다. 즉, 직업에서 AI에 노출된 과업들이 있다고 하더라도, 과업들의 AI 노출도 편차가 클 경우에는 자동화하기 어렵다고 보는 것이다. AIOE 점수가 높으면서 과업별 점수들의 표준편차가 작으면(즉, 직업 내 여러 과업들이 모두 비슷하게 AI와 관련성이 높으면) 자동화 가능성이 높고, AIOE 점수가 높지 않고 과업별 점수들의 표준편차가 크면(즉, 직업 내 특정 과업들은 AI 관련성이 높지만, 여타 과업들은 AI 관련성이 낮을 경우) 자동화 가능성이 낮은 것으로 판단했다. 예를 들어, 변호사의 경우, 판례 수집과 같은 일부 과업은 AI에 노출되어 있지만, 법정에서의 변론과 같은 다른 과업들은 AI에 의해 이루어질 수 없기 때문에 자동화 가능성은 낮고 증강 가능성을 높을 수 있다. 반면, 텔레마케터의 경우, 대부분의 과업들이 AI에 노출되어 있어 자동화 가능성이 높다고 볼 수 있다.

Svanberg et al.(2024)은 AI 노출도가 높다고 하더라도(직업들의 AI 관련성이 높다고 하더라도) 실제로 기업들이 AI를 도입하고 적용하는 것은 경제적 비용을 고려해서 이루어질 것이라는 점에 주목하고 있다. 설문조사를 통해 기업들이 경제적 비용을 고려한 채택 정도를 측정한 결과 AI 노출도 정도보다 훨씬 낮은 수준의 도입 가능성을 보고하고 있다. 경제적 측면까지 고려한다면, AI에 의한 대체 정도는 잠재적 가능성(기술적 가능성)보다 낮을 것으로 전망한다.

나. 한국의 AIOE 지표 도출

이 절에서는 앞에서 검토한 AIOE 도출에 관한 기존 연구들을 참고하여, AI의 사회적 수용 가능성을 반영하고 AI에 의한 자동화와 증강 잠재력까지를 나타낼 수 있는 AIOE 지표들을 한국의 데이터로 도출해 보고자 한다.

한국고용정보원은 지난 20여년간 한국의 직업 특성에 관한 정보들인 한국 재직자 직업 정보 조사를 꾸준히 실행하고 있다. 이 조사에서는 한국고

용직업분류 4자리 수준에서 451개 직업의 다양한 특성들에 대해서 조사하고 있다. 직업은 다양한 과업(tasks)의 집합이며, 과업을 수행하기 위해서는 능력(ability)과 숙련(skill)이 요구된다. 능력과 숙련을 갖추기 위해서는 지식(knowledge)이 필요하다. 우리나라에서도 한국고용정보원에서 직업별 과업들(tasks)뿐만 아니라 직업에서 요구되는 능력(ability), 지식, 취미, 작업환경 등을 중요성과 수준 측면에서 조사하고 있다.

본 연구는 이 조사 정보를 활용하여, 위에서 검토한 기존 AI 측정 지표들을 한국화하여 측정하고, 측정 지표별로 노동시장 효과를 비교 분석해 보고자 한다. 다만, 경제적 측면에서 AI 도입 가능성을 분석하는 Svanberg et al. (2024) 방식의 지표는 ‘설문조사’가 이루어져야 하기 때문에, 본 연구에서는 포함시키지 못하였다.

한편, 이러한 지표들 이외에, 일자리 양극화를 분석한 “정형-과업기반 기술 변화(Routine Based Technological Change, 이하 RBTC)” 이론의 대표적 연구인 Acemoglu et al.(2011)의 지표들도 한국직업정보 조사를 활용하여 한국화한 지표를 도출하여 보조 지표로 활용한다.

또한, 기술의 자동화 효과에 관한 대표적인 연구인 Frey and Osborne (2017)의 “컴퓨터에 의한 자동화” 측정 지표, 그리고, 특허의 기술 정보를 직업에 연계하여 분석한 Webb(2020)의 AI, 로봇, 소프트웨어 지표들도 한국의 직업코드와 연계하여 보조 지표로 활용한다.

1) AI 노출도(AIOE)

Felten et al.(2018, 2021)의 AIOE 지표 구축 방법에 대해서는 전병유 외(2022)에서 다음과 같이 설명되어 있다. Felten et al.(2019)은 전문가 평가보다는 AI의 기술 특성과 직업의 ‘능력(ability)’ 변수를 연계하는 방법으로 ‘직업의 인공지능 노출도(AI Occupational Exposure, 이하 AIOE)’를 측정하였다. 다만, 연계 점수는 전문가 조사로 만들어 냈다. 예를 들어, AI 응용 기술들은 이미지 인식, 이미지 생성, 텍스트 인식, 언어모델링, 번역, 음성 인식, 추상적 전략게임, 시각질문 응답 등이고, 이는 미국의 전자프론티어재단(the Electronic Frontier Foundation)에서 매년 업데이트하고 있다. 한편 직업의 능력 특성은 미국 BLS의 직업정보시스템인 O*NET에서 직업별로 52개

를 조사하고 있다. 예를 들어, 범주화, 창의력, 추리력, 수리력, 글쓰기, 기억력, 논리적 분석, 듣고 이해하기, 읽고 이해하기, 말하기, 반응 시간과 속도, 공간지각력, 선택적 집중력, 시력, 청력 등이 능력 변수이다. 이러한 AI 기술 특성과 직업의 능력 특성의 관련성 정도를 점수화하는 것이다. 결국, AIOE는 AI 응용기술들이 요구하는(또는 관련되는) 능력 점수들을 직업별로 합산하여 평균한 것으로, AI 관련 능력(ability)에 특화된 직업일수록 AIOE는 높아지게 된다. 자세한 방법론은 전병유 외(2022)를 참조할 수 있다. 전병유 외(2022)는 Felten et al.(2018, 2021)이 조사한 AI 기술 특성과 직업의 능력 특성 간의 연계 점수를 한국고용정보원의 「한국직업정보 재직자 조사」의 능력 변수들에 적용하여 한국형 AIOE 점수를 도출하였다. 다만, 미국의 경우 능력 변수를 52개 사용하였지만, 한국의 경우 「한국직업정보 재직자 조사」의 능력 변수는 15개에 불과하여, 몇몇 능력 변수들을 통합-조정하여 도출하였다. 52개 전체 변수들을 모두 포함하지 못했다는 한계가 있지만, Felten et al.(2018, 2021)의 AIOE와 한국의 AIOE 간 상관관계는 0.86 정도로 상당히 높은 것으로 나오고 있다.

2) AI 보완성 조정 AIOE(Adj_AIOE)

AI가 사람을 보완하는 정도를 나타내는 지표와 AIOE에서 이를 조정한 ‘보완성 조정 AIOE(Adj_AIOE)’는 앞에서 검토한 Pizzinelli et al.(2023) 방식에 따라서 도출하였다. AI가 인간노동을 보완해야 하는 가능성을 나타낸 변수들은 「2018년 한국직업정보 재직자 조사」에서 <표 3-1>과 같이 조사되어 있다.

<표 3-1> 직업의 업무환경 및 요구 교육 수준

업무 환경 및 지식 수준	설문 내용
건강 및 안전에 대한 책임	귀하는 함께 근무하는 사람의 건강 및 안전에 얼마나 책임이 있습니까?
결과에 대한 책임	귀하는 직장동료의 업무 성과와 결과에 얼마나 책임이 있습니까?

〈표 3-1〉의 계속

업무 환경 및 지식 수준	설문 내용
실수의 심각성	귀하가 업무를 수행하면서 실수를 한다면 그 결과는 얼마나 심각합니까?
이미지/평판/재정에 미치는 영향력	귀하가 업무를 수행하면서 의사결정하는 것이 다른 사람들이나 근무하는 회사의 이미지/평판/재정에 얼마나 자주 영향을 미칩니까?
의사결정 가능성	귀하는 업무를 수행하면서 관리자나 감독자(상사)의 개입 없이 의사결정 할 수 있는 재량이 있습니까?
사람들과 직접 접촉	귀하는 업무를 수행하면서 얼마나 자주 사람들과 얼굴을 맞대고 논의하십니까?
연설, 발표, 회의하기	귀하는 업무를 수행하면서 얼마나 자주 사람들 앞에서 공식적으로 연설(발표, 회의 등의 상황)을 하십니까?
실외 근무	귀하는 업무를 수행하면서 얼마나 자주 실외에서 근무하십니까?
다른 사람과 신체적 접촉	귀하는 업무를 수행하면서 다른 사람들과 신체적으로 얼마나 가까이에서 근무하십니까?
교육 수준	귀하의 업무를 수행하는 데 일반적으로 요구되는 교육 수준은 어느 정도라고 생각하십니까?

자료 : 한국고용정보원, 「2018년 한국직업정보 재직자 조사」.

이러한 변수들에 대한 중요도와 수준에 대한 조사 점수를 활용하여 AI의 잠재적 보완성(complimentarity potential) 지표를 도출하였다. 이 지표는 타인의 건강에 대한 책임 수준, 대면 상호작용의 중요성, 직업의 물리적 환경, 자격을 갖추기 위해 필요한 교육 수준 등 보다 광범위한 사회적 고려 사항들을 종합적으로 고려한다.

「2018년 한국직업정보 재직자 조사」에서는 이러한 변수들에 대해 5점 척도로 중요성과 수준에 대해서 조사하고 있다. 이 점수들을 합산하고 평균하여 잠재적 AI 보완성 지표 θ_i 를 도출하였다. 한편, 주어진 직업 i 에 대한 Adj_AIOE_i 는 Felten et al.(2018, 2021) 방식의 AIOE에서 잠재적 보완성 θ_i 의 상대적 값¹¹⁾을 뺀 값($\theta_i - \theta_{MIN}$)으로 도출한다. 즉, 아래 식 (1)의 오른쪽

11) Pizzinelli et al.(2023)은 잠재적 보완성(complimentarity potential)이 가장 낮은 직업의 점수(θ_{MIN})를 뺀 값으로 계산하였다. 여기서 θ_{MIN} 를 조정하여 보완한 측정값이 원래의 AIOE 지수로 상대적인 해석이 가능하도록 한 것이다. 즉, 식

두 번째 항은 잠재적 상보성이 가장 낮은 직종(θ_{MIN})에 대한 AIOE의 하향 조정을 나타낸다. 따라서, Adj_AIOE 지수 값이 클수록 잠재적 자동화 위험은 더 커진다고 볼 수 있다.

$$\text{Adj_AIOE}_i = \text{AIOE}_i * 1 - (\theta_i - \theta_{MIN}) \quad (3-1)$$

3) 사회적 능력을 할인한 AI 노출도(Socail_AIOE)

AI가 인간의 사회적 측면을 대체하는 것이 어렵다는 점을 반영하여 (Engberg et al., 2023, 2024), AIOE에서 직업의 사회적 능력 점수를 할인하는 방식으로 만들어진 지표가 ‘사회적 능력을 할인한 AI 노출도(Socail_AIOE)’이다.

직업의 능력이나 숙련 특성에서 사회적 측면을 반영하는 설문항은 「2020년 한국직업정보 재직자 조사」에 사람 파악, 행동조정, 설득, 협상, 가르치기, 서비스 지향 등의 항목으로 조사되고 있다. 이는 <표 3-2>에 제시되어 있다.

6가지 유형의 사회적 능력 변수들의 중요도와 수준 점수 값(s로 표시)을 합산하여 사회적 숙련 점수를 산정하고 이 점수를 가장 사회성이 높은 직업의 점수로 나누어 0과 1 사이의 점수를 부여하여 가장 사회성이 높은 직업에 비해 해당 직업이 얼마나 사회적인지를 나타낸다.

<표 3-2> 직업의 사회적 능력

사회적 능력	설문 내용
사람 파악	다른 사람의 반응을 파악하고 왜 그렇게 행동하는지 이해한다
행동 조정	다른 사람들의 행동에 맞추어 적절히 대응한다
설득	다른 사람들의 마음이나 행동을 변화시키기 위해 이해시키고 설득한다
협상	다른 사람과의 의견 차이를 좁혀 합의점을 찾는다
가르치기	함께 일하는 사람들에게 일하는 방법에 대해 알려준다
서비스 지향	동료나 고객들을 돕기 위해 적극적으로 노력한다

자료 : 한국고용정보원, 「2020년 한국직업정보 재직자 조사」.

(3-1)의 오른쪽 둘째 항은 잠재적 상보성이 가장 낮은 직종(θ_{MIN})에 대한 AIOE의 하향 조정을 나타낸다.

아래 식에서, i_{os} 는 직업 o 의 사회적 능력 변수 s 의 중요성 점수를 나타내고, l_{os} 는 직업 o 의 사회적 능력 변수 s 의 수준 점수를 나타낸다. 직업의 사회적 점수 s_o 는 0에서 1 사이의 값을 가지도록 조정된 것이며, 가장 사회성이 높은 직업의 경우 $s_o = 1$ 이다.

$$s_o = \frac{\sum_{(s=1)}^6 i_{(os)} \times l_{(os)}}{\max_{(o \in O)} (\sum_{(s=1)}^6 i_{(os)} \times l_{(os)})}$$

이러한 직업의 사회적 특성을 반영하여 할인한 Social AIOE는 아래 수식에 따라서 만들어진다. 여기서 δ 는 최종 노출 측정에서 사회적 기술에 얼마나 많은 가중치를 부여할지 결정하는 매개변수이다. 따라서 분모의 값은 사회성이 가장 낮은 직업에 의해 결정되며, 이 경우 s_o 가 가장 작으므로 $(1 - s_o + \delta)$ 가 가장 크다. 만약 δ 를 0으로 설정하면 가장 소셜한 직업은 AI 노출이 0인 것으로 모델링되며, δ 가 무한대가 되면 AI 노출에 영향을 미치지 않게 된다. Engberg et al.(2023)은 δ 를 2로 설정했는데, 이는 가장 사회적인 직업의 AI 노출 점수를 31% 감소시키는 효과가 있다.

$$Social\ AIOE = AIOE * \frac{(1 - s_o + \delta)}{\max_{(o \in O)} (1 - s_o + \delta)}$$

4) GPT 노출도(GPT Exposure)

앞에서 검토한 지표들은 대부분 실태조사를 기반으로 하여 AIOE를 측정하였다. 그런데 최근 생성형 AI의 발전으로 실태조사 대신 직접 생성형 AI에 AI 노출도를 직접 답해달라고 하는 방식의 연구들이 나타나고 있다. Gmyrek et al.(2023)을 포함한 최근 연구들(Eloundou et al., 2023; Eisfeldt et al., 2023)은 ChatGPT와 같은 대규모 언어 모델에 직업 과업들에 대해서 AIOE 점수를 부여해 달라고 직접 물어보는 방식을 취하고 있다. OpenAI의 Eloundou et al.(2023)이나 ILO의 Gmyrek et al.(2023) 등은 ChatGPT-4의 API 프롬프트를 활용하여 GPT 노출 점수를 도출하였다. Eloundou et al.(2023)에 따르면, 인간 전문가가 평가한 노출도 점수나 ChatGPT가 생성한 노출도 점수가

큰 차이가 없다는 것을 보여주고 있다.

본 연구에서도 동일한 방식으로 GPT Exposure 지표를 도출하였다. 여기에서 사용한 ChatGPT-4 프롬프트 예시는 다음과 같다.

{“role”: “system”, “content”: “당신은 기술 및 AI 전문가입니다. 주어진 과업에 대해 GPT 기술에 따른 잠재적인 자동화 점수를 제공합니다. 지침을 주의 깊게 따르세요.”},

{“role”: “user”, “content”: “이 과업을 보세요”: “+str(Tasks_GPT)+” “+”이 과업은 ISCO 코드: “+str(ISCO_08)+”와 관련이 있습니다. “+” 이 과업이 GPT 기술로 자동화될 수 있는 잠재적 점수를 제공하세요. “+” 점수는 0에서 1 사이여야 합니다. 한 줄에 점수를 제공하고 다음 줄에 점수 부여의 정당화를 제공하세요. 다른 논평은 제공하지 말고, 점수와 정당화만 제공하세요. “+” 각 작업에 대해 범위를 제공하지 말고 한 가지 점수만 제공하세요.}

5) 기타 보조 지표

Acemoglu and Autor(2011)는 RBTC 이론에 기초하여 일자리 양극화를 분석하였다. 이때 사용한 직업 숙련 지표는 정형 대 비정형(routine vs non-routine), 분석, 대인관계, 신체[cognitive(analytical)-cognitive(interpersonal)-manual]라는 두 가지 차원을 교차하여 범주화하였고, 오프쇼어링 가능한 정도를 측정하는 offshorability 지표도 생성하였다. 이러한 직업 숙련 범주를 Acemoglu and Autor(2011) 방식에 기초하여, 한국고용정보원의 「재직자 조사」를 활용하여 도출하였다. 이때 활용한 직업 숙련 지표들은 <표 3-3>과 같다.

<표 3-3> Acemoglu and Autor(2011)의 숙련 지표 작성 기준

		O*NET 지표	한국직업정보 재직자 조사 지표
NR_A	비정형 인지 : 분석적	데이터/정보 분석하기	귀하의 업무를 하기 위해 【정보, 자료 분석】 활동이 얼마나 중요합니까?
		창의적으로 사고하기	귀하의 업무를 하기 위해 【창조적 생각】 활동이 얼마나 중요합니까?
	Non-routine cognitive : Analytical	다른 사람을 위해 정보 해석하기	귀하의 업무를 하기 위해 【정보의 의미 해석】 활동이 얼마나 중요합니까?

〈표 3-3〉의 계속

		O*NET 지표	한국직업정보 재직자 조사 지표
NR_I	비정형 인지 : 대인 관계 Non- Routine Cognitive : Interpersonal	개인적 관계 수립 및 유지	귀하의 업무를 하기 위해 【대인관계 유지】 활동이 얼마나 중요합니까?
		부하 직원 지도, 지시 및 동기 부여	귀하의 업무를 하기 위해 【부하 직원들에게 업무 안내, 지시, 동기부여】 활동이 얼마나 중요합니까?
		다른 사람 코칭/개발하기	귀하의 업무를 하기 위해 【사람들에게 조언, 상담】 활동이 얼마나 중요합니까?
R_C	일상적 인지 : Routine Cognitive	동일한 작업 반복의 중요성	【반복적인 신체행동, 정신적 활동】 귀하의 업무를 수행하기 위하여 지속적이고 반복적 인 신체적 행동
		정확성 또는 정확성의 중요성	【정확성, 정밀성 유지】 귀하의 업무를 수행 하기 위하여 정확도나 정밀도를 유지하는 것 이 얼마나 중요합니까?
		구조화된 작업 대 구조화되지 않은 작업(역방향)	【의사결정 권한】 귀하는 업무를 수행하면서 해야 할 일, 일의 우선순위, 목표를 정할 수 있는 재량이 있습니까?
R_M	일상적 매뉴얼 : Routine Manual	장비의 속도에 따라 결정되는 속도	【장비 속도에 보조 맞추기】 귀하의 업무를 수행하기 위하여 장비 혹은 기계의 속도에 보조를 맞추는 것이 중요합니까?
		기계 및 공정 제어	귀하의 업무를 하기 위해 【기계장치 제어】 활동이 얼마나 중요합니까?
		반복적인 동작을 하는 데 시간 소비	
NR_M	비정형 수동 신체 작업 : Non- Routine Manual Physical	차량, 기계화 장치 또는 장비 작동	귀하의 업무를 하기 위해 【차량, 기계, 장비 작동】 활동이 얼마나 중요합니까?
		손을 사용하여 물체를 느끼고 통제함	【물, 도구, 조종 장치를 다루기 위해 손사용】 귀하는 업무 중 물건, 도구 혹은 조절 장치 를 얼마나 손으로 만지고 다루십니까?
		정교한 동작	귀하의 업무를 수행하려면 【정교한 동작】 능 력은 얼마나 중요합니까?
		공간 방향성 의향성	귀하의 업무를 수행하려면 【공간 지각력】 능 력은 얼마나 중요합니까?

〈표 3-3〉의 계속

Offshorability	오프쇼어링 가능성 Offshorability	O*NET 지표	한국직업정보 재직자 조사 지표
		대면 토론 (역방향)	【사람들과 직접 접촉】 귀하는 업무를 수행하면서 얼마나 자주 사람들과 얼굴을 맞대고 논의하십니까?
		다른 사람을 돕고 돌보기 (역방향)	귀하의 업무를 하기 위해 【사람들을 배려, 돌봄】 활동이 얼마나 중요하니까?
		대중을 위해 수행하거나 대중과 직접 협력(역방향)	귀하의 업무를 하기 위해 【업무상 사람들을 직접 응대】 활동이 얼마나 중요하니까?
		장비, 구조물 또는 자재 검사(역방향)	귀하의 업무를 하기 위해 【장비, 건축물, 자재 검사】 활동이 얼마나 중요하니까?
		물체 취급 및 이동(역방향)	귀하의 업무를 하기 위해 【물건 조종, 운반】 활동이 얼마나 중요하니까?
		기계장비 수리 및 유지보수 (역방향)	귀하의 업무를 하기 위해 【기계장비 유지 보수】 활동이 얼마나 중요하니까?
		전자 장비 수리 및 유지보수 (역방향)	귀하의 업무를 하기 위해 【전자장비 유지 보수】 활동이 얼마나 중요하니까?

자료: 저자 작성.

한편, 기술의 자동화 효과 연구로 많이 인용되는 Frey and Osborne(2017)은 직업에 대한 전문가 평가, O*NET 직업정보, 통계적 기법 등을 동원하여 컴퓨터에 의한 자동화 정도(computerization index)를 도출하였다. 직업 전문가들이 수기로 라벨링할 때 “이 직업의 업무가 빅데이터의 가용성에 따라 최첨단 컴퓨터 제어 장비로 수행될 수 있도록 과학적으로 구체화될 수 있는가?”라는 질문에 답하는 방식으로 이루어졌으며, O*NET 변수로는 신체적 숙련, 인지적 숙련, 사회적 숙련 측면에서, 컴퓨터화의 어려움 정도(computerization bottleneck)를 파악하였다. 본 연구에서는 Frey and Osborne(2017)에서 도출된 미국 직업분류(SOC)에 따른 점수를 한국의 표준직업분류(KSCO)와의 연계표를 활용하여 KSCO 직업별 컴퓨터화 점수(Computerization Index)를 도출하였다.

또한, Webb(2020)의 경우에도 특허에서 나타나는 기술 특성과 직업 특성의 연계 정보를 활용하여 AI 노출도, 로봇 노출도, 소프트웨어 노출도 등을

도출하였다. 본 연구에서도 보조적인 지표로 활용하고자 한다. 도출 방식은 Frey and Osborne(2017)의 컴퓨터화 지표와 마찬가지로 SOC-KSCO 연계 표를 활용하여 도출하였다.

한편, 앞 장에서 검토한 온라인 구인공고 자료에서 AI 관련 키워드가 2개 이상 있는 구인공고를 AI 관련 구인공고라고 하고 전체 구인공고에서 차지하는 비중을 직업별로 산정한 것을 AI 인력 비중(AI_intensity)으로 도출하였다.

위에서 검토한 지표들을 종합적으로 보여준 것이 <표 3-4>이다.

<표 3-4> 주요 AI 노출도 관련 지표 종합

변 수	설 명	방법론
AI Exposure (AIOE)	AI 응용기술을 능력(ability) 변수와 연계하여 AI Occupational Exposure Index를 직업별로 구축	Felten et al. (2018), (2021)
Adj_AIOE	직업의 책무성, 중요성 등을 반영하는 보완성 정도(AI_complement) 지표로 조정된 AIOE 지표	Pizzinelli et al. (2023), IMF
Social Discounted AIOE	사회적 숙련을 필요로 하는 정도를 측정하고, 이를 활용하여 기존 AIOE 점수를 할인하는 방식으로 구축	Engberg et al. (2023, 2024), IAB.
GPT Exposure	GPT-4를 활용하여, 직업의 과업(task)들이 GPT에 의해 자동화될 수 있는 정도를 측정	Gmyrek et al. (2023), ILO
Computerization Score	인지적, 신체적, 사회적 차원에서 컴퓨터에 의해 자동화될 가능성이 있는 정도를 직업별로 측정	Frey and Osborne (2017)
AI_Webb	특허정보와 직업정보의 연결을 통한 AI 노출도 지표 구축	Webb (2020)
Robot	특허정보와 직업정보의 연결을 통한 로봇 노출도 지표 구축	
Software	특허정보와 직업정보의 연결을 통한 소프트웨어 노출도 지표 구축	
Non-Routine Analytical	비정형-인지적(분석적) 숙련	Acemoglu and Autor (2011)
Non-Routine Interpersonal	비정형-인지적(대인관계) 숙련	
Non-Routine Manual	비정형-신체적 숙련	
Routine Analytical	정형-인지적(분석적) 숙련	
Routine Manual	정형-신체적 숙련	
AI Intensity	OJP에서 AI 관련 키워드가 2개 이상인 OJP를 AI-OJP로 정의하고, 전체 OJP 중에서 AI-OJP의 비중을 직업별로 계산	Green et al. (2023), OECD.

자료 : 저자 작성.

다. AI 지표들과 숙련 지표와의 관계

이 절에서는 먼저 AI 노출도 지표들이 Acemoglu and Autor(2011)에서 도출한 직업 숙련 지표들과 어떤 관계를 가지는지를 다음과 같은 간단한 회귀 분석을 통해 파악함으로써, AI 지표들의 특성을 확인해 보고자 한다. 여기서 직업 o 의 Skill은 Acemoglu and Autor(2011)의 지표들을 사용한다.

$$Exposure_o^{AI} = \alpha + \sum_S \beta_S Skill_o + \epsilon_o$$

AI Exposure는 인지적 숙련과 높은 상관관계를 가지는 것으로 보인다. 정형-인지적 숙련과도 (+)의 관계를 가지는 반면, 대인관계 숙련은 (-)의 관계를 가지는 것으로 보인다. 즉, AI는 직업 숙련이 인지적이냐-비인지적이냐와 관련이 높고, 정형이냐 비정형이냐와는 무관한 것으로 보인다. 즉, Acemoglu and Autor(2011)의 RBTC 가설은 AI 노출도에는 적용되기 어려운 것으로 보인다. 이는 GPT Exposure 지표에서도 동일하게 나타난다.

한편, AI_Compliment와 같은 AI 보완성 지표는 정형이냐 비정형이냐와 관련이 높다. 정형 숙련과는 (-)를 비정형 숙련과는 (+)를 나타낸다. 그 결과 ‘보완성 조정 AIOE’, Adj_AIOE는 정형 숙련과는 (+), 비정형 숙련과는 (-)를 나타낸다. 즉, 과업의 책무성, 중요성, 의사소통의 중요성 등을 반영하여 조정한 AI 노출도는 정형 인지(분석) 숙련과 높은 상관관계를 보여준다. 즉, 보완성 조정 AIOE라는 지표는 인지적 숙련이 필요하지만 직업의 중요성을 사회적으로 인정받지 못하는 직업에서는 조정된 AI 노출도가 높고 AI에 의해 자동화될 가능성이 높을 수 있다는 지표임을 시사한다. AI Exposure는 인지적 숙련과 높은 상관관계를 가지지만, ‘보완성 조정 AIOE’는 인지적 숙련 중에서 AI에 의해 대체 가능성이 높을 경우 점수가 높을 수 있다. 예를 들어, 단순 사무직이나 반복적인 작업을 하는 전문직 등은 AI에 의해 대체될 가능성이 높다고 할 수 있고, 보완성 조정 AIOE는 이러한 가능성을 포착하는 데 활용될 수 있다는 것이다.

또한, ‘보완성 조정 AIOE’는 대인관계 숙련과는 (-) 관계가 뚜렷하게 나타난다. AIOE도 대인관계 숙련과 (-)의 관계를 보이지만, ‘보완성 조정 AIOE’


가 AI는 대인관계 숙련을 대체하기 어렵다는 점을 더 강하게 반영하는 지표라고 할 수 있다.

반면, 사회적으로 조정된 AIOE, Social_AIOE의 경우에는 비정형 인지(분석) 숙련과 높은 상관관계를 나타내는 것으로 나온다. 이는 Socail_AIOE라는 지표는 비정형 분석 숙련을 가진 직업들도 AI 노출이 높고 AI에 의해 대체될 수 있다는 잠재적 가능성을 나타내는 지표로 해석해야 한다는 것을 의미한다. 이는 ‘Social_AIOE’는 직업의 사회적인 측면만을 조정했기 때문인 것으로 보인다.


한편, Frey and Osborne(2017)의 ‘컴퓨터에 의한 자동화 지표’는 ‘보완성 조정 AIOE’와 유사한 형태를 나타내고 있다. 즉, 정형이나 비정형이냐와 관련이 높다. 다만, ‘보완성 조정 AIOE’와 달리, ‘컴퓨터에 의한 자동화 지표’는 ‘정형-신체적 숙련’과도 (+)의 관계를 보인다. 인지적이든, 신체적이든 정형적인 업무와 높은 상관관계를 나타낸다. 즉, 이 지표는 정형적인 업무가 자동화될 가능성이 높다는 점을 보여주는 지표라고 할 수 있다.

Webb의 ‘로봇 노출도’는 당연히 신체적 숙련이나 아니냐와 밀접한 관련이 있다. Webb의 지표가 제조업 비중이 높게 반영되는 특허 자료를 활용한다는 특성을 반영하기 때문인 것으로 판단된다.

[그림 3-1] AI 지표와 직업 숙련 특성들 간의 관계




[그림 3-1]의 계속



자료 : 저자 작성.

[그림 3-2] 기타 지표와 직업-숙련 특성들 간의 관계




자료 : 저자 작성.

다음으로, 대분류 직종별로 AI 지표 점수의 분포를 검토해 보았다. 점수는 모두 표준화된 점수이다.

AIOE와 보완성 조정 AIOE(Adj_AIOE)를 비교해 보면, AIOE에 비해 Adj_AIOE는 관리, 전문, 사무직에서 낮고, 생산직에서 더 높으며, 판매 서비스직의 경우에도 높은 것으로 나타났다. 판매, 서비스, 생산, 단순 직업의 경우 직업의 중요성과 책무성이 떨어지기 때문일 것이다. 이 직업들의 경우 AI가 도입되면 상대적으로 대체되기 쉽다는 사정을 Adj_AIOE가 반영하는 것으로 해석해 볼 수 있다.

[그림 3-3] 대분류 직종별로 AI 지표 점수의 분포



자료: 저자 작성.

사회적 측면을 조정한 AIOE(Social_AIOE)와 비교해 보아도 비슷한 패턴을 보여준다. 다만, 판매직의 경우 더 낮아지는 것으로 나타났다. 예를 들어, 화장품 판매원과 같은 판매직의 경우 음식조리직과 같은 서비스직에 비해 사회적 접촉이 더 빈번하고 중요하기 때문인 것으로 보인다. 판매직의 경우 AI가 도입되더라도 사회적 접촉의 필요성 때문에 상대적으로 대체되기 어렵다는 점을 Social_AIOE는 반영하는 것으로 해석할 수 있다.

AI Exposure(AIOE)와 GPT Exposure를 비교해 보면, GPT Exposure의 경우, 사무직과 판매직이 관리직이나 전문직보다도 높은 점수를 나타내고 있으며, 서비스직이나 생산직에서는 GPT 노출도가 낮은 것으로 나타났다.

한편, 컴퓨터에 의한 자동화 정도는 사무직과 생산직에서 높은 노출도를 보이고 있는 반면, 로봇 노출도는 생산직에서 높은 노출도를 나타내고 있다.

이러한 지표 확인들에서 알 수 있듯이, 대체로 AI 관련 지표들이 상식적으로 그 의미가 타당하다고 판단된다.

제3절 AI 노출도와 고용

이 절에서는 한국의 전체 고용이 AI에 어느 정도 노출되어 있는지를 검토한다.


전체 451개 직업을 AI 지표 점수에 따라서, 상위 25% 직업은 높은 노출, 상위 25~50%는 중간노출, 나머지 50% 직업은 낮은 노출로 분류하고, 이를 통계청의 「지역별 고용조사」 2023년 데이터에 연계하여, 전체 고용에서 차지하는 비중을 대분류 직종별로 검토해 보았다.

AI Exposure 노출도 상위 25% 직업이 전체 고용에서도 대체로 24.8%를 차지하고 있다. GPT Exposure 노출도 상위 직업의 고용 비중은 30%를 넘는 것으로 나타났다. AI Exposure와 GPT Exposure를 비교해 보면, 두 지표 모두 전문직과 사무직에서 노출도 상위 직업의 비중이 높고, 차이점은 GPT Exposure의 경우 판매직에서 높은 고용 비중을 나타내고 있다.

한편, 보완성 조정 AIOE 지표로 볼 경우, 판매직과 조립원, 단순직 등

AIOE 지표에서 고노출 고용 비중이 낮았던 직종에서도 Adj_AIOE 고노출 고용 비중이 높은 것으로 나타났다. 반면, 사회성 조정 AIOE의 경우에 생산 직이나 단순직에서 고노출 고용 비중이 Adj_AIOE에서만 높은 높진 않았다.

[그림 3-4] AI 지표 노출도별 고용 비중(대분류 직종 기준, 2023년)



자료: 저자 작성.

컴퓨터 자동화 지표로 볼 경우, 사무직이 가장 큰 고용 비중을 차지하고 있고, 판매직, 단순직, 서비스직, 조립원 등이 컴퓨터 자동화에 노출될 가능성이 높은 고용 비중을 나타내고 있다. 로봇화 지표로 볼 경우, 생산직에서 높은 고용 비중을 나타낸다.

다음으로, 이러한 지표를 활용하여 AI가 노동을 자동화하거나 증강할 수 있는 고용 비중을 추정해 보고자 한다.


Pizzinelli et al.(2023)의 방법에 따라서, AIOE와 보완성 지수를 활용하여, AIOE와 보완성 지표가 모두 중간값 이상이면, High Exposure- High Complemetarity(HEHC), 두 변수 모두 중간값 이하이면, Low Exposure- Low Complemetarity(LELC), AIOE가 중간값 이상이고 보완성 지표가 중간값 이하이면, HELC이다. AIOE가 중간값 이하이고 보완성 지표가 중간값 이상이면 LEHC로 분류하였다. 여기서 HEHC면, 즉 AIOE 노출도가 높고 보완성도 높으면 증강 가능성이 높으며, HELC면, 즉 AIOE 노출도가 높고 보완성이 낮으면 자동화 가능성이 높은 것으로 볼 수 있다.

이 기준에 따라서 직종별 고용 구성을 분석한 것이 [그림 3-5]이다. 관리직의 경우, 증강 가능성이 높은 HEHC의 비중이 매우 높은 반면, 사무직과 판매직의 경우, 자동화 가능성이 높은 HELC의 고용 비중이 높다.

또한, Pizzinelli et al.(2023)의 분석 결과와 비교해서 국제 비교를 해보았다. 한국의 경우, HEHC 증강 잠재력 고용 비중이 24.5%, HELC 자동화 잠재력 고용 비중이 25.4% 정도로, 보완성을 고려할 때 한국이 AI에 노출되어 고용에 미칠 잠재적 영향은 여타 개도국에 비해서 높은 편이고, 미국에 비해서 약간 낮지만, 그래도 영국과 미국 등의 수준에 달하고 있다고 볼 수 있다. 한국의 직업별 고용 구성으로 볼 때, 제조업과 생산직의 비중이 높아서 LELC의 비중이 높기는 하지만, 전반적으로 AI의 노출도에 따른 증강과 자동화의 잠재력이 높은 국가라고 평가할 수 있다.

한편, Gmyrek et al.(2023)은 AIOE 점수가 높으면서, 과업별 점수들의 표준편차가 낮으면(즉, 직업 내 여러 과업들이 모두 비슷하게 AI와 관련성이 높으면) 자동화 가능성이 높고, AIOE 점수가 높지 않고 과업별 점수들의 표준편차가 높으면(즉, 직업 내 어떤 과업들은 AI 관련성이 높지만, 여타 과업들은 AI 관련성이 낮으면) 증강 가능성이 낮은 것으로 판단했다. 예들 들어,

[그림 3-5] AI와 보완성 지표 기준의 직업별 고용 비중과 국제 비교



자료 : Pizzinelli et al.(2023 : 20), 한국의 경우 저자가 작성.

변호사의 경우, 과업의 일부는 AI에 노출되어 있지만, 다른 과업들은 업무와 관련이 높지 않아 증강 가능성이 높다. 반면, 텔레마케터의 경우, 과업의 많은 부분이 AI에 노출되어 있어 자동화 가능성이 높다고 볼 수 있다.

Gmyrek et al.(2023)은 이러한 기준을 가지고 GPT에 의한 자동화(automation)과 증강(augmentation)을 구분하는 시도를 하고 있다. 직업 내 과업들의 AIOE의 평균이 크고 표준편차가 작은 직업일수록 자동화(대체)의 가능성이 높고, AIOE의 평균이 작고 표준편차가 큰 직업일수록 보완의 가능성이 크다고 보는 방식이다. 이러한 지표로 그는 국가별로 AI에 의해 자동화되는 일자리와 증강되는 일자리의 비중을 비교하였다(표 3-5 참고).

<표 3-5> 자동화(automation)와 증강(augmentation)

	낮은 AI 평균	높은 AI 평균
높은 AI 표준편차	증강 잠재력	알 수 없음
낮은 AI 표준편차	영향을 받지 않음	자동화 잠재력

〈표 3-6〉 자동화와 증강 직업 예시

	낮은 AI 평균	높은 AI 평균
높은 표준편차	(증강 잠재력) 변호사, 웹개발자, 도시교통전문가, 영업판매관리자, 전기전자공학시험원, 산업용로봇조작원, 약사 및 한약사	(알 수 없음) 제도사, 학습지교사, 상품중개인, 정보시스템운영자, 인사노사관련 전문가, 세무사, 회계사, 무역사무원, 은행사무원, 사회과학연구원, 해외영업원, 웹운영자, 보험금융상품개발자, 조사전문가
낮은 표준편차	(영향을 받지 않음) 철근공, 정육가공원, 환경미화원, 건설단순종사원, 재봉사, 치과의사, 조리사, 제화원, 소방관, 유치원교사, 물리치료사, 항공기정비원, 특수교육교사, 로봇공학기술자, 감독, 기업고위임원, 정부행정 관리자	(자동화 잠재력) 텔레마케터, 전산자료입력원, 여행사무원, 단말기판매원, 번역가, 통역가, 컴퓨터강사, 직업상담사, 비서, 아나운서 및 리포터


자료: 저자 작성.

ILO에서 조사한 직업별 GPT Exposure 점수를 그대로 한국 직업코드에 연계하여 분석할 경우, GPT에 노출될 때 증강 가능성이 있는 고용 비중은 15.9%, 자동화에 노출될 수 있는 고용 비중은 9.8% 정도로 나타났다.

[그림 3-6]에서 GPT에 의한 자동화와 증강 잠재력 일자리 비율을 여타 국가와 비교해 보면, 한국의 경우 GPT에 의한 증강과 자동화 잠재력 모두 비중이 상대적으로 높은 것으로 나타났다. GPT에 의해 증강 가능한 고용 비중은 세계 평균이 13.0%인데 한국의 경우 15.9%이고, 자동화 가능성이 있는 고용 비중은 세계 평균이 2.3%인데 한국은 9.8%에 달한다.


국제비교 연구를 한 Pizzinelli et al.(2023)과 Gmyrek et al.(2023)의 연구 결과와 한국의 자료를 가지고 추정해 본 결과, 한국의 직업구성으로 볼 때, 한국은 여타 국가들에 비해 AI 및 GPT 노출도, 자동화, 증강 잠재력이 미국, 영국 등에 비해서는 다소 낮지만, 세계 평균 이상의 수준은 나타내고 있다고 볼 수 있다.

[그림 3-6] GPT에 의한 증강 잠재력과 자동화 잠재력의 고용 비중, 2023년 「지역별 고용조사」



자료 : 통계청, 2023년 「지역별 고용조사」.

[그림 3-7] GPT에 의한 자동화와 증강 잠재력 일자리 비율 국제비교



자료 : Gmyrek et al.(2023 : 34), 한국의 경우 저자 추정.

AI 노출도가 사업체 고용에 미치는 효과를 추정해 보기 위해서 다음과 같은 노동수요 함수를 추정하였다.

$$L_{ft} = \beta + \beta_{AI_o} AI_{fat-1} + X_{ft-1} \beta_x + D_{ht} \beta_{ht} + D_{mt} \beta_{mt} + \varepsilon_{ft}$$

X는 사업체 수준의 변수들로 매출액, 매출액 대비 수출비중, 매출액 대비 외주비 비중, 외국인 지분율, 총자산 대비 유형고정자산 비중 등의 변수 등이다. D_{ht} 와 D_{mt} 는 산업-연도, 지역-연도 고정효과를 통제하기 위한 것이다. 자료는 고용보험DB를 사용하였고, 50인 이상의 사업체 기준으로 추출한 데이터들이다. 사업체 수준의 AI 지표는 직종별 AI 지수값을 부여한 다음 사업체별로 평균한 값이다.

AI 노출도 지표들의 회귀계수 값은 전반적으로 대체로 유의한 (-)값을 나타내고 있다. AI나 GPT에 노출된 종사자 비중이 높은 사업체일수록 고용 성과는 좋지 않은 것으로 판단된다. AI가 고용에 미치는 잠재적 영향은 전반적으로 부정적인 것으로 평가된다.

〈표 3-7〉 노동수요 함수 추정 결과


	AIOE	Adj_AIOE	Social_AIOE
상수항	3.1311*** (0.0501)	3.1442*** (0.0501)	3.1486*** (0.0501)
AI 지표들	-0.0484*** (0.0102)	-0.0231* (0.0127)	-0.0535*** (0.0127)
log(매출액)	0.1712*** (0.0047)	0.1699*** (0.0047)	0.1703*** (0.0046)
수출 비율	-0.0002 (0.0001)	-0.0002 (0.0001)	-0.0002 (0.0001)
외국자본 지분율	-0.0005* (0.0002)	-0.0005* (0.0002)	-0.0005* (0.0002)
외주비 비율	-0.0053 (0.0035)	-0.0051 (0.0035)	-0.0051 (0.0035)
이윤율	-0.0005*** (0.0002)	-0.0005*** (0.0002)	-0.0005*** (0.0002)
유형고정 자산비율	-0.0000 (0.0000)	0.0000 (0.0000)	0.0000 (0.0000)
R-square	0.0532	0.0524	0.0524
Obs	24,682	24,682	24,682

주 : 수출 비율, 외주비 비율, 유형고정자산 비율 등은 매출액 대비 비율임.
자료 : 저자 작성.

제4절 AI 노출도와 임금

한국고용정보원의 「한국직업정보 재직자 조사」에서는 직업 특성뿐만 아니라 임금 수준도 조사하고 있다. 2020년에 조사한 자료를 기초로 직업의 AI 지표 점수와 임금 간의 관계를 검토하였다.

[그림 3-8] GPT에 의한 증강 잠재력과 자동화 잠재력의 고용 비중



자료 : 한국고용정보원, 「한국직업정보 재직자 조사」, 2020년.

대체로 AI Exposure, GPT Exposure의 경우, 우상향의 (+)의 관계를 나타내는 반면, Adjusted AIOE, Social AIOE의 경우에는 우하향의 (-) 관계를 나타낸다. 컴퓨터 자동화, 로봇 노출도 지표들로 볼 경우, 중간이 불록한 역 U자 형의 양극화 형태를 나타낸다. 이른바 일자리 양극화를 나타내는 RBTC 가설에 부합하는 것으로 보인다.

AI나 GPT의 경우, AI 노출도나 GPT 노출도로만 볼 경우에는 고임금 일자리가 노출도가 높은 것으로 해석할 수 있지만, 보완성으로 조정된 AIOE나 사회적 능력으로 할인한 AIOE로 측정할 경우 이른바 숙련편향 기술변화(Skill-Biased Technological Change : SBTC) 가설이 적용될 수도 있다는 점을 보여준다.

AI 노출도가 임금에 미치는 영향을 추정하기 위해서 아래 두 가지의 임금함수를 추정해 보았다. 자료는 고용보험DB에서 2015년에서 2023년 데이터를 활용하였다. 고용보험DB는 직종 분류가 세 자리이기 때문에, 직종별 AI 노출도를 세 자리 수준에서 2023년 고용 비중을 가중값으로 하여 평균값을 구해서 결합하였다. 임금 추정 모델은 다음과 같다.

$$\ln(wage)_{iojt} = \beta' Exp_{ot} + \phi_t + \theta_o + \gamma' X + \lambda' Z_{jt} + \alpha_i + \mu_{J(i,t)} + \varepsilon_{iojt}$$

위 식에서 i 는 근로자, o 는 직업, j 는 사업체를 나타낸다. Exp_{ot} 은 t 시점에 o 직업에 근로자 i 의 AI 노출도 지표이다. X 는 성, 연령, 연령제곱, 근속 등의 개인 특성 지표이고, Z 는 사업체 규모(종업원 수), 지역, 산업 등 사업체 특성 지표이다.

고용보험DB는 사업체-근로자 동시 패널자료의 성격이 있기 때문에, 사업체 간 노동이동을 통제할 수 있는 Abowd, Kramarz, Margolis(1999) 모델(이하, AKM 모델)을 적용한다. 즉, 근로자와 사업장 모두에 대한 추가 고정효과를 통합하는 임금 회귀를 적용한다. 또한, 직종을 변경하는 경우도 반영해서 설명변수(same_occupation)에 포함한다.

임금함수 추정 결과를 보면, AI 노출도는 임금에 유의한 (+) 효과를 나타냈고 보완성 조정 AI 노출도는 임금에 유의한 (-) 효과를 나타냈다. 이는 앞에서 검토한 직종별 지표와 임금 사이의 관계에서 확인된 것이라 당연한 결과라고 할 수 있다.

〈표 3-8〉 AI 지표의 임금효과 추정 결과

	AI Exposure	Adj_AIOE	Social_ AIOE	GPT Exposure
회귀계수 값	0.0384*** (0.0030)	-0.0656*** (0.0027)	0.0548*** (0.0031)	-0.0185*** (0.0034)
R_square	0.6135	0.6161	0.6144	0.6108
Year fixed effects	yes	yes	yes	yes
Worker Controls	yes	yes	yes	yes
Establishment Controls	yes	yes	yes	yes
Worker fixed effects	yes	yes	yes	yes
Establishment fixed effects	yes	yes	yes	yes
3-digit occupation fixed effects	yes	yes	yes	yes
Same 3-digit occupation	yes	yes	yes	yes

자료: 저자 작성.

다만, GPT 노출도의 경우 임금에 유의한 (-) 효과를 나타냈다. 앞의 직종별로 임금과의 관계를 볼 때도, GPT 노출도는 역 U자 형에 가까웠다. GPT가 주로 단순 사무직이나 판매직 등 상대적으로 저임금 일자리 부분에서 더 높은 노출도를 나타냈기 때문인 것으로 판단된다. 앞에서 보았듯이, GPT Exposure는 '정형-인지(분석) 숙련'과도 매우 높은 상관관계를 나타냈었다는 점과도 관련이 있는 것으로 판단된다.

반면, 사회적 숙련 조정 AI 노출도는 임금에 유의한 (+) 효과를 나타냈다. 이는 앞에서 직업별로 볼 때 Social AIOE와 임금이 역의 상관관계를 보였다는 점에서 다소 의외의 결과이다. 이 부분도 Social AIOE가 임금 수준이 낮은 비정형-대인관계 숙련과 상대적으로 낮은 상관관계를 보이는 것과도 관련이 있는 것으로 보인다.

제5절 소 결

이 장에서는 AI와 GPT를 직업의 과업기반으로 측정할 수 있는 방법론에

대해서 검토해 보았다. 이른바 직업의 AI 노출도 지표를 다양한 방식으로 도출해 보았다.

AI가 기술적으로 인간 노동에 잠재적으로 영향을 미칠 수 있지만, 현실에서는 인간과 사회의 판단에 따라 AI의 적용이 달라질 수 있다. 직업의 사회적 책무성이나 중요도, 사회적 상호작용 등을 더 많이 필요로 하는 직업일수록, AI가 그 직업의 과업과 비슷한 일을 할 수 있을지라도, 인간과 사회는 AI에게 모든 것을 맡기지 않을 것이다.

이러한 점을 고려하여, 직업의 중요성, 책무성 등의 측면에서 AI가 인간 노동을 보완할 것이라는 점을 고려하여 보완성을 고려한 AI 노출도와 AI는 인간의 사회적 능력을 대체하기는 어렵다는 점을 고려하여, 사회적 능력을 할인한 AI 노출도 지표도 도출하여 같이 검토해 보았다.

분석 결과, AI와 GPT가 기술적인 측면에서는 고임금 일자리에 더 많은 영향을 줄 수 있지만, 직업의 책무성, 중요성, 사회적 의사소통까지를 고려한다면, AI와 GPT는 오히려 저임금 일자리를 먼저 대체할 가능성이 높다고 판단된다. 자동화의 가능성도 관리 전문직보다는 판매직, 생산직, 단순직 등에서 높을 것으로 판단된다.

한편, 국가 간 비교 결과를 보면, 한국의 경우, 전반적으로 AI에 의한 자동화와 증강 가능성 모두 세계 평균에 비해서는 높은 것으로 보인다.

AI의 잠재적 노출도는 전반적으로 고용에는 (-)로 임금에는 (+)로 나타나는 것으로 보인다. 다만, 임금에 미치는 영향은 지표별로 다소 엇갈리는 결과가 나왔다. AIOE는 임금에 (+) 효과를, 보완성 조정 AIOE, Adj_AIOE는 (-) 효과로 나왔다. 이 결과는 앞에서 검토한 직종별 지표와 임금 사이의 관계에서 확인된 것이라 당연한 결과라고 할 수 있다. 다만, GPT Exposure는 (-), Social_AIOE는 (+) 등으로 나타났다. GPT가 정형 인지(분석) 숙련을 가진 상대적 저임금의 판매직, 생산직 등과 상대적으로 높은 상관관계를 가진 것과 관련이 있고, Social_AIOE가 저임금의 비정형 대인관계 숙련 노동과의 관련이 낮기 때문인 것으로 보인다.

이 장의 분석 결과는, AI가 노동에 미치는 잠재적 영향을 기술적 측면으로만 볼 경우, AI가 고임금-고숙련 노동에 더 많은 영향을 줄 것으로 예상되지만, 직업의 책무성, 중요성, 사회적 대인관계를 고려하면, 반드시 AI가 고임

금-고숙련 노동에만 영향을 미치기보다는 저임금-저숙련 노동에 더 큰 영향을 미칠 수 있다는 점을 보여준다. AI도 기존 기술의 SBTC 형태의 결과를 초래할 수도 있다는 것이다.

그러나 이는 AI가 어떤 형태로 발전하느냐, 그리고 AI를 사회가 어떤 방식으로 수용하느냐에 따라 달라질 수 있다. 인간과 사회가 AI를 어떻게 받아들이느냐는 AI 기술의 발전에 따라서, 인간과 사회가 어떻게 적용하고 대응하느냐에 따라서 달라질 것이다. 오늘 이 장에서 검토한 결과는 이러한 기술 발전과 사회의 인식, 대응과 적응 방식의 변화에 따라서 달라질 수 있는 잠정적인 결과로 인식할 필요가 있다.

제 4 장

기업의 AI 도입에 따른 고용과 임금 변화

제1절 연구 질문

컴퓨터와 로봇 등 자동화 기술이 발전하면서 일자리 감소에 대한 우려는 끊임없이 제기되었다. 그러나 장기적이고 포괄적인 수준에서 기술 발전으로 인한 일자리 감소에 대한 우려는 기우였던 것으로 보인다. 하지만 일자리 감소가 부문별로 불균등하게 발생함으로써 불평등의 심화로 귀결되었다는 점에는 대체로 이견이 없다. 지금까지의 기술 발전은 고숙련 노동에 대한 높은 보상이나 중간 임금 수준의 정형 과업 대체를 통해서 불평등을 심화시켰다.

인공지능 기술은 다를까? 인공지능은 인간의 지적 능력을 모방하는 기계라는 점에서 그 영향이 이전보다 더 광범위할 수 있다. 이것은 AI 노출도(AI Exposure Rate)라는 개념으로 포착할 수 있다. 사람이 하던 여러 가지 작업에 대해서 AI를 활용하면 작업시간을 줄이거나 더 좋은 성과를 낼 수 있는 정도를 측정하는 개념이다. AI 기술에 노출된 정도가 큰 작업은 향후 AI가 수행하게 될 가능성이 크고, 이런 작업이 많은 분야에서는 일자리가 줄어들 것으로 예상된다.

노출도와는 구별되는 개념으로서 AI 도입률에 따른 고용효과를 검토할 필요가 있다. 노출도는 AI가 가진 기술적 가능성을 측정할 뿐이다. 경제성이

나 사회적·제도적 제약을 넘어서서 실제로 AI가 고용을 감소시킬지 여부는 검증해야 할 과제이다. Acemoglu(2024)는 인공지능의 거시경제 효과를 평가하였는데, 먼저 Eloundou et al.(2023)의 연구를 기반으로 미국의 전체 노동 과업의 약 20%가 AI에 노출되어 있다고 보았다. 그러나 AI에 노출된 과업이 모두 AI로 대체되는 것은 아니며 실제로 기업이 AI 기술을 채택할 가능성을 추정해야 한다고 주장한다. Svanberg et al.(2024)의 연구를 활용하여 AI에 노출된 과업 중에 실제로 채택 가능하고 수익성이 있는 과업의 비율은 23%로 추정하였다. 즉, 20% 중에서 다시 23% 과업만이 실제로 AI로 대체될 것으로 본 것이다.

본 연구를 진행해 온 2024년에 본격적으로 확산한 생성형 인공지능 기술은 기업의 인공지능 기술 ‘채택’이 과연 어떤 의미일지를 다시 생각하는 계기가 되었다. 인공지능 기술을 의도적으로 채택하지 않더라도 일터와 노동 과정에 ‘스며들고’ 있는 것은 아닐까? 기업이 사용하는 클라우드와 사무용 소프트웨어에 AI가 탑재되는 마당에 개별 기업이 AI 기술을 도입했는지를 질문하는 것이 큰 의미가 있을까? 이런 질문이 떠오르는 것은 자연스럽다.

그럼에도 불구하고, AI 기술을 적극적으로 채택하는 기업과 그렇지 않은 기업을 구별하여 AI 기술의 고용효과를 측정해 볼 수 있다고 생각한다. 이때 중요한 질문은 어떤 징표를 보고 기업이 AI 기술을 적극적으로 채택했는지 여부를 판단할 것인가이다. 이 문제는 다음 절에서 좀 더 상세히 다룬다. 이 장에서는 다음과 같은 연구 질문에 답하고자 한다.

- [1] AI 기술을 적극적으로 도입하는 기업이 그렇지 않은 기업에 비해 고용이 감소하는가? 이러한 분석으로 AI라는 새로운 기술이 기업에서 기존에 사람이 수행하던 일자리를 대체하는 방식으로 도입되고 있는지 알 수 있다.
- [2] 불평등에 미치는 영향 측면에서 AI는 기존의 자동화 기술과 다를까?
이 질문에 대해서는 다음 두 가지 경로를 검토한다.
 - [2-1] AI 기술은 불균등한 보상을 통해서 불평등을 심화시키는가? 즉, AI 도입 기업은 미도입 기업에 비해 높은 임금을 지급하는가?
 - [2-2] AI는 기존 자동화 기술과는 달리 중간관리직과 고숙련 직종의 과업을 대체하는가?

제2절 기존 연구

기업의 AI 기술 도입 여부 또는 AI 기술 관련 투자 수준을 측정하기 위한 시도는 다음과 같이 몇 가지 유형으로 구분해 볼 수 있다. 지금까지의 연구는 대체로 AI 도입 기업은 미도입 기업에 비해 고용이 증가하거나 적어도 감소하지는 않은 것으로 나타났다. AI 도입 여부를 측정하는 방식에 따른 분석 결과의 차이도 뚜렷하지 않다. 한편, 임금에 미치는 영향에 관한 연구는 비교적 적다. 축적된 데이터가 적은 것이 하나의 이유일 것이다.

1. 설문조사 방식

Acemoglu et al.(2022)은 미국의 2019년 「Annual Business Survey(US Census Bureau & National Center for Science and Engineering)」를 이용하여 기업의 첨단기술 채택 현황을 분석했는데, AI 채택 여부가 포함되었다. 「Annual Business Survey」는 미국 기업 전체를 대표할 수 있는 30만 개의 표본기업을 대상으로 매년 실시된다. 이 연구에 따르면, AI 기술 채택률은 비교적 낮게 나타났다. 2016~2018년 사이에 전체 기업 중에서 3.2%만이 AI 기술을 사용했다고 보고했다. 대기업일수록, 젊은 기업일수록, 높은 임금을 지불하는 기업일수록 AI를 도입할 가능성이 높은 것으로 나타났다. AI를 사용한 기업의 54%(고용 가중치 적용)는 노동 과정을 자동화하기 위한 목적으로 AI를 사용한다고 보고하였다. 그러나 다른 한편, AI를 사용하는 기업의 26%는 AI 사용으로 인하여 고용이 증가했다고 보고했다.

Calvino and Fontanelli(2023)는 OECD 11개국에서 기업 수준의 설문조사를 실시하여 AI 도입 여부와 고용, 매출 등을 조사했다. 대기업일수록, 젊은 기업일수록 AI 채택 비율이 높은 경향이 있으며, 산업별로는 정보통신기술(ICT) 분야에서 도입률이 높았다. AI를 도입한 기업은 그렇지 않은 기업에 비해 더 높은 고용 성장률을 보이는 것으로 나타났다. AI 투자가 곧바로 인

력감축으로 이어지기보다는 제품혁신과 제품 라인업 확장이 나타났으며 이로 인해 고용이 증가한 것으로 설명되었다.

우리나라에서도 이 방법을 사용한 논문들이 있다. 통계청이 2017년부터 매년 실시하여 발표하는 「기업활동조사」는 기업의 AI 도입 여부를 조사 항목에 포함하고 있다. 패널분석이 가능하다는 점, 생산성과 관련한 다양한 지표들이 측정되고 있다는 점이 강점이다. 다만, 기업의 고용을 측정하는 지표들은 다소 부족하다는 문제가 있다.

통계청 「기업활동조사」 자료를 분석한 한요셉(2023)의 연구에서는 AI 기술을 도입한 기업의 경우 AI 전문인력 채용으로 전체 고용 규모는 유지되지만 AI 인력을 제외한 고용 규모는 줄어든다는 결과를 보고하고 있다. 정소라·성낙일(2024)도 같은 자료를 활용하여 기업의 로봇과 인공지능 도입이 고용과 임금변화율에 미친 효과를 분석하였다. 로봇을 도입한 기업의 고용량 변화율은 미도입 기업에 비해 약 2% 낮아서 로봇의 노동 대체 효과가 확인되었다. 이에 비해, 인공지능은 고용량이나 실질임금 변화에 미치는 부정적인 영향이 있을 것으로 짐작되지만, 이는 통계적으로 검증되지 않는 수준이라고 보고하고 있다.

2. AI 특허출원

AI 관련 특허를 출원한 기업을 AI 기술을 도입한 기업으로 간주하는 방식이 있다. Alderucci et al.(2020)은 미국 특허청(USPTO)의 1990~2018년 특허데이터를 분석하여 AI 관련 특허를 식별해 내고, 이 특허를 출원한 기업을 Annual Survey of Manufactures(ASM), Census of Manufactures(CMF) 등 센서스국의 기업데이터와 연결하여 고용에 미치는 영향을 분석하였다. 이 연구에서는 AI 혁신 기업이 그렇지 않은 기업에 비해 고용 성장이 25% 빠른 것으로 분석되었고, 기업 내 임금 불평등은 증가하는 것으로 나타났다. 임금 불평등은 기업 내 90-10 임금비와 50-10 임금비로 측정하였다.

특허데이터를 이용한 또 다른 논문은 Damoli et al.(2021, 2023)이다. 이 논문은 유럽 특허청 PATSTAT 데이터베이스에서 2000년부터 2016년까지 AI 관련 특허를 출원한 적이 있는 전 세계 5,257개 기업을 찾아냈고, Bureau

Van Dijk's ORBIS 데이터베이스의 기업정보와 연결했다. AI 특허를 출원한 기업은 그렇지 않은 기업에 비해 더 높은 고용 증가율을 나타냈다.

3. AI 숙련수요

온라인 구인공고에 나타난 AI 관련 숙련수요를 보고 기업의 AI 기술 도입 여부를 판단하는 방법이 있다. 본 보고서의 연구가 채택한 방식이다. Babina et al.(2020)의 연구사례를 참고하였다.

Babina et al.(2020)은 미국의 lightcast(구 Burning Glass Technologies)사가 제공하는 1억 8,000만 개의 구인공고 데이터를 기업의 AI 도입 효과 분석에 사용했다. AI 관련 직무에 인력을 채용하려는 구인공고를 낸 기업은 AI 기술에 투자한 기업이라고 보는 것이다. 먼저, 각 구인공고에서 요구되는 모든 숙련수요의 AI 관련성을 평균 내어 해당 직무 수준의 AI 관련성을 측정한다. AI 관련성이 특정 기준치 이상인 구인공고는 AI 관련 직무로 분류된다. 구인공고를 기업단위로 집계한다. 각 기업에서 AI 숙련수요 비율을 계산하여 이를 기업의 AI 투자 수준으로 간주한다. 그런 다음, 이 데이터를 기업 데이터(Compustat)와 연결하였다. 이 연구에서는 주로 대기업일수록, 현금 보유량이 많고 연구개발 집중도가 높은 기업이 AI에 더 많이 투자하는 것으로 나타났으며, AI에 더 많이 투자한 기업은 매출과 고용이 모두 증가하는 것으로 나타났다.

제3절 분석 방법과 데이터

1. 기업의 AI 도입 여부 판정

기업이 AI 기술을 도입했는지 여부는 어떻게 알 수 있을까? 기업을 대상으로 설문조사를 실시하여 직접적으로 물어보는 것이 가장 손쉬운 방법이다. 통계청에서 해마다 실시하는 「기업활동조사」에는 AI 기술의 도입 여부

에 대한 질문 문항이 포함되어 있다. 그러나 이 조사자료에는 고용에 대한 정보가 비교적 간단하게만 포함되어 있어서, AI 도입의 고용효과를 분석하기에 부족한 점이 있다. 한국노동연구원의 「사업체패널조사」에서는 2024년도 조사 설문에 AI 도입과 관련된 여러 가지 질문을 포함시켰다. 이 조사가 완결되면 여러 가지 분석이 가능해질 것이다. 그러나 현재 시점에서는 아직 사용할 수 없는 데이터이다.

한 가지 대안적인 방법은 기업의 AI 숙련수요를 AI 기술 도입을 드러내는 지표로 간주하는 것이다. 기업이 온라인 구인사이트에 게재하는 채용공고 중에서 AI 숙련을 요구한다면, 이 기업은 AI 기술을 도입한 것으로 짐작할 수 있다. 이 장에서는 이 방법을 채택한다. 2021~2023년에 기업이 사람인과 잡코리아에 올린 채용공고를 분석하여 AI 도입 여부를 측정하였다. 한 번 AI 도입 기업으로 판정되면 그 이후 연도에도 AI 도입 기업으로 간주하였다.

AI 숙련으로 간주한 숙련 키워드는 <표 4-1>에 제시하였다. 이렇게 키워드를 선정하고 구인공고에 매칭하는 과정은 후술한다.

<표 4-1> AI 관련 숙련명 목록

MachineTranslation, 신경망기계번역, SpeechEnhancement, SpeechProcessing, SpeechRecognition, SpeechRecognitionSoftware, SpeechSynthesis, SpeechTechnology, SpeechoText, TexttoSpeech(TTS), VoiceAssistantTechnology, VoiceInteraction, VoiceTechnology, VoiceUserInterface, 3DReconstruction, AI, AIChatbot, AIKIBIT, AIOps(ArtificialIntelligenceForITOperations), AI데이터분석, AI도구, AI분석, AI역량검사, ANTLR, ActionRecognition, ActionsOnGoogle, ActivityRecognition, AdaBoost(AdaptiveBoosting), Adam최적화알고리즘, AdvancedDriverAssistanceSystems, AdvancedInteractiveMultidimensionalModelingSystem(AIMMS), AdvancedRobotics, AdversarialNetwork, AggregateFunctions, AgileMethodology, Algorithms, AmazonComprehend, AmazonLex, AmazonPolly, AmazonTextract, AmazonWebServices, AmbientIntelligence, Anaconda(Software), AntColonyOptimization, ApacheMADlib, ApacheMXNet, ApacheMahout, ApacheSINGA, ApacheSpark, Apertium, ApplicationsOfArtificialIntelligence, ApproximateStringMatching, ArtificialBeeColonyAlgorithm, ArtificialGeneralIntelligence, ArtificialIntelligence, ArtificialIntelligenceDevelopment,

〈표 4-1〉의 계속

ArtificialIntelligenceMarkupLanguage(AIML), ArtificialIntelligenceSystems,
 ArtificialNeuralNetworks, AssociationRuleLearning, AtScale(Software),
 Autoencoder, AutomatedMachineLearning, AutomaticSpeechRecognition(ASR),
 Automation, AutonomicComputing, AutonomousCruiseControlSystems,
 AutonomousSystem, AutonomousVehicles, AutoregressiveModel, Azkaban,
 AzureDatabricks,
 Backpropagation, Baidu, Bayes, BayesianLearning, BayesianNetworks,
 BeeColony, BigData, BipedRobot, BlindSignalSeparation, Boosting,
 BrainComputerInterface, Brownboost, BuildPipeline, BulkImport,
 BusinessIntelligence, C++(ProgrammingLanguage), Caffe, Caffe2,
 Canonicalization, CausalInference, Chainer(DeepLearningFramework),
 Chatbot, Chi-SquaredAutomaticInteractionDetection(CHAIID),
 Clarabridge(Software), ClassificationAndRegressionTree(CART), Classifier,
 ClusterAnalysis, CognitiveAutomation, CognitiveComputing,
 CognitiveModeling, CognitiveRobotics, CollaborativeFiltering,
 CollisionAvoidance, ComplexityTheory, ComputationalIntelligence,
 ComputationalLinguistics, ComputationalPathology, ComputerScience,
 ComputerVision, ConceptualDataModeling, ConfusionMatrix,
 ContextualImageClassification, ConvexOptimization,
 ConvolutionalNeuralNetworks, Cortana,
 Cross-IndustryStandardProcessforDataMining(CRISP-DM), Cudnn,
 Cyber-PhysicalSystems, Dask(Software), DataAnalysis, DataBlending,
 DataCapture(SQL), DataClassification, DataCleansing, DataConversion,
 DataCube, DataElement, DataEngineering, DataFusion, DataIngestion,
 DataIntelligence, DataLayers, DataManipulation, DataMining,
 DataMiningMethods, DataMonetization, DataPartitioning, DataPipeline,
 DataPreprocessing, DataReduction, DataScience, DataSelection,
 DatabaseProgrammersToolkits, Dbscan, DecisionModels,
 DecisionTreeLearning, DecisionTrees, DeepBeliefNetwork,
 DeepConvolutionalNeuralNetwork, DeepLearning, DeepNeuralNetwork,
 DeepSpeech, Deeplearning4j, DialogSystems, Dialogflow(GoogleService),
 DictionaryLearning, DigitalDecoupling, DimensionalityReduction,
 DirectedAcyclicGraph(DirectedGraphs), Disambiguation, Disguise.One,
 Distinguo, Dlib(C++Library), Embedding, EmergingTechnologies,
 EmotionRecognition, Encodings, EnsembleLearning, EnsembleMethods,
 EpicBridges, EvolutionaryAlgorithms, EvolutionaryComputation,
 EvolutionaryProgramming, ExpectationMaximizationAlgorithm, ExpertSystems,
 ExtremeMachineLearning, EyeTracking, FaceDetection,
 FacialExpressionRecognition, FacialRecognition,

〈표 4-1〉의 계속

FactorAnalysis, FactorizationMachine, FeatureEngineering, FeatureExtraction, FeatureLearning, FeatureSelection, FireflyAlgorithm, ForecastingManagement, FuzzyC-Means, FuzzyLogic, FuzzyNumber, FuzzySet, FuzzySystem, GAN, GaussianMixtureModel, GaussianProcess, General-PurposeComputingOnGraphicsProcessingUnits, GenerativeAdversarialNetwork, GeneticAlgorithm, GeneticProgramming, GestureRecognition, GoogleAutoML, GoogleCloudMLEngine, GoogleCloudMachineLearningPlatform, GoogleKubernetesEngine(GKE), GradientBoosting, GradientTreeBoosting, GraphAlgorithms, GraphicalModel, GravitationalSearchAlgorithm, Greenplum, Gremlin, GuidanceNavigationAndControlSystems, H2O(software), HandwritingRecognition, Hdinsight, HebbianLearning, HiddenMarkovModel, HierarchicalClustering, High-DimensionalData, High-DimensionalFeature, High-DimensionalInput, High-DimensionalModel, High-DimensionalSpace, High-DimensionalSystem, HortonworksSandbox, HuggingFaceTransformers, Human-RobotInteraction, HumanActionRecognition, HumanActivityRecognition, HumanAwareArtificialIntelligence, HumanReadable, HumanoidRobot, HyperparameterOptimization, Hypertable, IBMWatson, IPSoftAmelia, IndependentComponentAnalysis, IndustrialRobot, InferenceEngine, Informatics, InformaticsEngineering, InformationExtraction, InformationIntegration, InformationProcessing, InformationRetrieval, InformationSciences, Instance-BasedLearning, IntelligentAgent, IntelligentClassifier, IntelligentControl, IntelligentGeometricComputing, IntelligentInfrastructure, IntelligentSoftwareAgent, IntelligentSoftwareAssistant, IntelligentSystems, IntelligentVirtualAssistant, InteractiveKiosk, IntuitionisticFuzzySet, Ithink, Java(ProgrammingLanguage), Jupyter, JupyterNotebook, K-MeansClustering, KNN, Kaldi, Keras, Keras(NeuralNetworkLibrary), Kernel, KernelLearning, KernelMethods, Knowledge-BasedConfiguration, Knowledge-BasedSystems, KnowledgeDiscovery, KnowledgeGraph, Kubeflow, LIBSVM, LPBoost, LSTM, Lambda, LanguageIdentification, LatentDirichletAllocation, LatentSemanticAnalysis, LatentVariable, LearningAutomata, LeggedRobot, Lexalytics, LexicalAcquisition, LexicalSemantics, LightDetectionAndRanging(LiDAR), LightGBM, Logitboost, LongShort-TermDeepLearning, LongShort-TermMemory(LSTM), ML, MLOps(MachineLearningOperations), MLPACK(C++library), MLflow, ML프레임워크, MachineIntelligence, MachineLearning, MachineLearningAlgorithms, MachineVision, Madlib, Mahout, MapR(BigData), MapReduce, MarkovChain, MarkovChainMonteCarlo, Markovian, MatrixFactorization, MemeticAlgorithm, MetaLearning, Metadata, MicrosoftAzure, MicrosoftCognitiveToolkit(CNTK),

〈표 4-1〉의 계속

MicrosoftLuis, Mlpy, MoSes, ModularAudioRecognitionFramework(MARF),
 MonteCarloMethods, MotionAnalysis, MotionPlanning, Multi-AgentSystems,
 Multi-LabelClassification, Multi-LayerPerceptron,
 Multi-ObjectiveEvolutionaryAlgorithm, Multi-ObjectiveOptimization,
 Multi-SensorFusion, MultinomialNaïveBayes, ND4J(software),
 NLTK(NLPAnalysis), NaiveBayesClassifier, NaturalGradient, NaïveBayes,
 NearestNeighborAlgorithm, NeuralNetwork, NeuralTuringMachine,
 NeuromorphicComputing, Non-NegativeMatrixFactorization,
 NormalizationProcesses, ONNX, ObjectDetection, ObjectRecognition,
 ObjectTracking, ObjectiveFunction, OmniPage, Ontologies, OpenAIGym,
 OpenCV, OpenNLP, OpenNeuralNetworkExchange(ONNX), OpenTSDB,
 OpenVINO, Opensearch, OpticalCharacterRecognition(OCR), OracleBigData,
 PaddlePaddle, Pandas(PythonPackage), ParametricMethods,
 Part-of-SpeechTagging, ParticleSwarmOptimization, PathAnalysis,
 PathFinding, PatternMining, PatternRecognition, PedestrianDetection,
 Perceptron, PolicyGradientMethods, PoseEstimation, Predictionio,
 PredictiveAnalytics, PredictiveAnalyticsSoftware, PredictiveModeling, PyTorch,
 PyTorch(MachineLearningLibrary), Pybrain, Pyspark,
 Python(ProgrammingLanguage), QuadrupedRobot,
 QualitativeDataAnalysisSoftware, QuestionAnswering,
 R(ProgrammingLanguage), RStudio, RandomField, RandomForest,
 RandomForestAlgorithm, RandomForests, Rankboost, RapidMiner,
 RealTimeData, RealSense, ReasoningSystems, RecommendationEngine,
 RecommenderSystems, RecurrentNeuralNetwork(RNN),
 ReinforcementLearning, RelationalLearning,
 RelationalOnlineAnalyticalProcessing(ROLAP), RemoteSensing, Reshape2,
 ResourceDescriptionFramework(RDF), Rmarkdown, Robot, RobotFramework,
 RobotOperatingSystem, RobotOperatingSystems, RoboticAutomationSoftware,
 RoboticLiquidHandlingSystems, RoboticProgramming, RoboticSystems,
 RootFramework, RoughSet, Rule-BasedLearning, RuleLearning,
 SLAMAlgorithms(SimultaneousLocalizationAndMapping), Scalability,
 Scikit-learn, Scikit-learn(MachineLearningLibrary), ScreenReader,
 Self-OrganizingMap, Self-OrganizingStructure, Semi-SupervisedLearning,
 SensorDataFusion, SensorFusion, SentimentAnalysis, SentimentClassification,
 Seq2Seq, ServiceRobot, Servomotor, ShapeOptimization,
 ShortestPathProblem, SimultaneousLocalizationAndMapping,
 Single-LinkageClustering, SnowflakeSchema, SocialRobot, SoftComputing,
 SoftwareDevelopment, SoftwareEngineering, SortingAlgorithm, Spark,
 SparkCore, SparkDataframes, Sparkr, Splunk, Sqoop, StackedGeneralization,
 StarSchema, StatisticalLanguageAcquisition, StatisticalRelationalLearning,

〈표 4-1〉의 계속

StochasticGradient, StochasticGradientDescent, StreamProcessing, SupervisedLearning, SupportVectorMachine, SupportVectorMachines(SVM), SupportVectorRegression, SwarmIntelligence, SwarmOptimization, Syman, SyntaxNet, Takagi-SugenoFuzzySystems, TechnicalAnalysis, TemporalDifferenceLearning, TensorBoard, TensorFlow, TestData, TestDatasets, Theano(Software), ThirdNormalForm, Tidyverse, TimeSeriesAnalysisAndForecasting, TimeSeriesModeling, Torch(MachineLearning), TorchServe, TotalBoost, TrainingDatasets, TrajectoryPlanning, TrajectoryTracking, TransferLearning, Transformers, TrustRegionPolicyOptimization, TypeConversion, UniversalDatabase(UDb), UnmannedAerialSystems(UAS), UnmannedAerialVehicle, UnstructuredInformationManagementArchitecture(UIMA), UnsupervisedLearning, VariationalInference, VectorMachine, VirtualAgents, VirtualAssistant, VisualServoing, VowpalWabbit, Watson, WatsonConversation, WatsonStudio, WebMining, Weka, WheeledMobileRobot, Wit.ai, WordEmbedding, XGBoost, YOLO, 강화학습, 데이터사이언스, 딥러닝, 딥러닝모델평가, 딥러닝프레임워크, 랜덤포레스트, 머신러닝, 머신러닝기반CADD개발, 머신러닝및딥러닝알고리즘, 머신러닝파이프라인, 반감독학습, 부스팅, 수학, 신경망, 예측모델링, 오토인코더, 음성인식, 이미지분석, 인공지능, 텍서, 패턴인식, 합성곱신경망, GluonNLP, HuggingFace(NLPFramework), MXNet, NLP, NamedEntityRecognition, NaturalLanguageGeneration, NaturalLanguageProcessing, NaturalLanguageProcessingSystems, NaturalLanguageProgramming, NaturalLanguageToolkit(NLTK), NaturalLanguageToolkits, NaturalLanguageUnderstanding, NaturalLanguageUserInterface, NaturalProgramming, 다국어NLP, 자연어처리, HALCON, IMG, ImageAnalysis, ImageClassification, ImageMatching, ImageProcessing, ImageRecognition, ImageRetrieval, ImageSegmentation, OpenCV, OpenCV등2D이미지프로세싱개발, 객체검출, 광학문자인식, 머신비전, 문서인식, 얼굴인식, 영상인식, 이미지처리, 컴퓨터비전, 팔레트인식, 패턴인식, BERT, SemanticAnalysis, SemanticDrivenSubtractiveClusteringMethod(SDSCM), SemanticInterpretationForSpeechRecognition, SemanticParsing, SemanticSearch, SemanticWeb, TextExtraction, TextManipulation, TextMining, TextProcessing, Tokenization, Word2Vec, Word2VecModels, 구문분석, AI기획, AI바우처사업, AI서비스, AI시스템도입, AI프로젝트, AI플랫폼, AI활용, 상품추천, 자율주행, 자율주행로직개발, 챗봇, 추천시스템

자료 : 저자 작성.

2. 데이터 구축

가. AI 숙련수요 키워드 추출과 표준화

구인공고에 나타난 기업의 AI 숙련수요를 판단하기 위해서는 일차적으로 숙련의 내용을 분류해 내는 숙련분류체계가 필요하다. 이것은 달리 말하자면, 숙련의 내용을 표준화하여 인식하는 것이다. 연구진은 다음과 같은 과정으로 숙련분류체계(코드)를 구축하였다.

첫째, 구인공고에 등장하는 단어 중에서 ‘숙련(skill)’이라고 볼 수 있는 단어를 수집하였다. 수집된 구인공고 중에서 20만 건을 임의 표집하였으며, LLM 모델을¹²⁾ 이용하여 전체 텍스트 정보 중에서 숙련에 해당하는 단어를 추출하였다. 이렇게 해서 추출된 단어는 3만 3,800개이다.

둘째, LLM 모델을 이용하여 유사한 숙련 단어끼리 군집분석으로 묶었다. 먼저, 미국 Lightcast사의 범주를 참고하여 초벌 분류하고, 각각의 숙련 단어(skill term)에 대해서 정의(definition)를 생성하였다. 군집분석을 위해서는 단어를 숫자로 임베딩하여 거리를 계산해야 하는데,¹³⁾ 단어의 의미는 앞뒤 문맥 속에서 형성되기 때문에 단일한 단어만으로는 의미를 정확하게 확정할 수 없다. 그래서 먼저 GPT-3.5 Instruct 모델을 이용하여 위에서 추출된 3만 3,800건의 단어에 대해서 정의를 생성하고, 숙련 단어(term)와 정의(definition)를 모두 활용하였다. 유사한 단어를 통합하기 위해서 DBSCAN 방식으로 군집화하였다. 이 과정을 통해 ‘3톤 지게차 운전’, ‘3톤지게차운전’, ‘지게차운전능력’ 등의 단어가 모두 같은 단어로 통합되고, 같은 숙련코드가 부여된다.

셋째, 퍼지 매칭으로 대표 레이블을 지정했다. 이렇게 해서 최종적으로 만들어진 숙련분류체계는 다음과 같은 모양이다(그림 4-1). 이 분류체계에서 ‘인공지능’ 숙련에 해당하는 숙련명은 <표 4-1>에 제시하였다.

12) OpenAI사의 GPT-3.5 Instruct와 GPT-4o mini를 이용함.

13) 임베딩은 Sentence BERT Embedding을 활용함.

[그림 4-1] 숙련분류체계 구성

skill_code	category	subcategory	code1	code2	code3	기존 skill term list	fuzzy matching으로 얻은 대표 레이블
						keyword	representative keyword
AC0000000	건축및건설	건설	AC	000	0000	설계	설계
AC0000001	건축및건설	건설	AC	000	0001	설단	설단
AC0010000	건축및건설	건설	AC	001	0000	관리용역	관리용역
AC0010001	건축및건설	건설	AC	001	0001	건설재료시험	건설재료시험
AC0010002	건축및건설	건설	AC	001	0002	고소작업	고소작업
AC0010003	건축및건설	건설	AC	001	0003	내진성능평가	내진성능평가
AC0010004	건축및건설	건설	AC	001	0004	신조감독	신조감독
AC0010005	건축및건설	건설	AC	001	0005	하자조사	하자조사
AC0010006	건축및건설	건설	AC	001	0006	하자조정	하자조정
AC0010007	건축및건설	건설	AC	001	0007	하자처리	하자처리
AC0010008	건축및건설	건설	AC	001	0008	관리, 관리보조, 관리사업, 관리업무, 관리업무, 관리업무, 관리업무	관리업무
AC0010009	건축및건설	건설	AC	001	0009	건설안전관리자의, 건설현장안전감시단, 건설현장안전관리, 건설현장안전관리자, 건축관리, 건축법규관련현장안전관리	건설현장안전관리
AC0010010	건축및건설	건설	AC	001	0010	인테리어관리, 인테리어관리, 인테리어관리, 인테리어관리, 인테리어관리, 인테리어관리, 인테리어관리, 인테리어관리	인테리어관리
AC0010011	건축및건설	건설	AC	001	0011	현장관리, 현장관리, 현장관리, 현장관리, 현장관리, 현장관리, 현장관리, 현장관리	현장관리
AC0010012	건축및건설	건설	AC	001	0012	현장용접, 현장용접, 현장용접, 현장용접, 현장용접, 현장용접, 현장용접, 현장용접	현장용접
AC0020000	건축및건설	건설	AC	002	0000	관리	관리
AC0020001	건축및건설	건설	AC	002	0001	연장	연장
AC0020002	건축및건설	건설	AC	002	0002	관리공사, 관리공사, 관리공사, 관리공사, 관리공사, 관리공사, 관리공사, 관리공사	관리공사
AC0020003	건축및건설	건설	AC	002	0003	통합건설, 통합건설	통합건설
AC0020004	건축및건설	건설	AC	002	0004	현장PM, 현장공무, 현장공무, 현장공무, 현장공무, 현장공무, 현장공무, 현장공무	현장PM
AC0020005	건축및건설	건설	AC	002	0005	현장안전관리, 현장안전관리, 현장안전관리, 현장안전관리, 현장안전관리, 현장안전관리, 현장안전관리, 현장안전관리	현장안전관리
AC0030000	건축및건설	건설	AC	003	0000	공작	공작
AC0040000	건축및건설	건설	AC	004	0000	CM회사	CM회사
AC0040001	건축및건설	건설	AC	004	0001	ROLLTOROLL장비	ROLLTOROLL장비

최종 숙련 코드 대분류 코드, 하위분류 코드, 순번코드로 각각 나누어 열에 저장

자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

나. 구인공고 자료를 기업 단위 자료로 재구성

온라인 구인공고 사이트인 ‘사람인’과 ‘잡코리아’에 게시된 구인공고를 수집하였다. 각각의 구인공고에 대하여 위에 언급한 숙련분류체계의 숙련명(코드)을 부여하였다. 숙련분류체계의 대표 레이블에 딸린 하위 숙련 단어(skill term list)와 구인공고에 나타난 단어들의 유사도를 계산하는 방식을 사용하였다. 하나의 구인공고에는 여러 개의 숙련명이 부여될 수 있다.

수집된 데이터의 전체 분량은 약 650만 건이다(표 4-2 참조). 중복되는 구인공고는 정리하여 하나만 남겼다. 2021년까지는 사람인 자료만 수집되었으므로 그 이후 연도와 직접적으로 비교 가능하지 않다는 점을 밝힌다. 전체 수집 자료 중에서 사업체를 식별할 수 있는 건을 추려내면 약 절반 정도

〈표 4-2〉 수집된 온라인 구인공고 데이터 전체 분량

	수집 자료	사업체 식별 가능		사업체 수
	(건)	(건)	(%)	(개소)
2017~2021	1,222,686	652,843	53.4	118,582
2022	2,660,940	1,502,354	56.5	158,884
2023	2,605,050	1,203,353	46.2	152,904

주: 1) 사람인과 잡코리아에 모두 게시된 중복 사례는 하나만 남기고 삭제하였음.

2) 2021년까지는 사람인 사이트만 수집되었으며, 실제 데이터에는 2017년부터 2021년까지가 포함되어 있으므로 다른 해와 직접적으로 비교 가능하지 않음.

자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

〈표 4-3〉 숙련수요로 본 AI 도입 업체 수

	식별된 사업체	AI 도입 업체* (신규)	AI 도입 업체* (누적)
2021	118,582	3,077	3,077(2.59%)
2022	158,884	2,778	5,855(3.68%)
2023	152,904	2,679	8,534(5.58%)

주: 온라인 구인공고에 AI 관련 숙련수요를 올린 업체.

자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

로 줄어든다. 구인공고를 게시한 사업체의 수는 2022년에 약 15만 9,000개소, 2023년에는 15만 3,000개소 정도이다.

〈표 4-1〉에 제시한 숙련을 요구하는 구인공고를 낸 사업체의 수를 〈표 4-3〉에 제시했다. 이 사업체들을 인공지능 기술을 도입한 기업으로 본다. 한 번 AI 도입 업체로 판정된 사업체는 그 이후 연도에도 계속 AI 도입 업체로 보는 것이 타당할 것으로 판단하였다. 2022년 시점에는 구인공고를 한 건이라도 낸 사업체 중에서 약 3.9%가 AI 기술을 도입하였으며, 2023년 시점에는 5.9%가 AI 도입 기업인 것으로 볼 수 있다.

다. 고용보험DB와 연계

식별할 수 있는 사업체는 고용보험DB와 연결하여 고용 변화를 분석할 수 있다. 고용보험DB에 등록된 전체 사업장 수는 〈표 4-4〉와 같다. 고용보험의 행정적인 관리 단위는 사업장이다. 그러나 하나의 사업체는 복수의 사업장을 가질 수 있으므로, 이후 구인공고에서 식별한 사업체 정보를 결합하기 위해서는 고용보험 데이터도 사업자로 재구성하였다.


〈표 4-4〉 고용보험 데이터 개요

	전체 사업장 수	신규 채용 있는 사업장*
2021	2,511,690	454,212(18.1%)
2022	2,615,914	604,678(23.1%)
2023	2,579,905	852,315(33.0%)

주: 피보험자 이력 자료를 결합하여 얻은 정보.

자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-2] 구인공고와 고용보험 데이터 결합 방식



자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

〈표 4-5〉 분석 데이터 개요 : 사업체 단위

	사업체 수	AI 도입 사업체
2021	98,332	2,839(2.9%)
2022	127,575	4,985(3.9%)
2023	132,608	5,361(4.0%)

주: 구인공고 데이터에 고용보험DB 정보 결합. 건설업 제외, 이상치 제거.

자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

고용보험 자료로부터 매년 말 기준 근로자 수와 사업장의 업종을 알 수 있다. 여기에 고용보험 이력 자료를 결합하면, 각 연도의 신규채용 인원과 그 인원의 주요 특성, 즉 직종과 채용 당시 임금을 알 수 있다. 구인공고로부터 얻은 사업체 단위의 숙련수요 데이터에 고용보험 자료를 결합하여 분석 데이터를 완성하였다. 데이터 결합 방식은 [그림 4-2]에 제시하였으며, 그 결과물로 얻은 데이터의 개요는 〈표 4-5〉와 같다.

제4절 고용과 임금의 변화

1. 어떤 기업이 AI를 도입할까?

사업체의 업종별 AI 도입률을 살펴보면 〈표 4-6〉, [그림 4-3]과 같다. 정보통신과 금융, 일부 제조업, 전문서비스 부문에서 AI 도입 비율이 높게 나타난다.

정보통신업에서 AI 도입 비율이 높다는 것은 그대로 해석하여 정보통신업종에 속한 사업체가 AI 도입 비율이 높다고 보면 되지만, 좀 더 나아가 여기서 제작한 서비스가 B2B로 판매된다고 보면, 클라이언트 기업은 AI 생산/운영자를 채용하지 않고서도 실제로는 AI의 도움을 받으면서 기업 활동을 할 수 있다는 점도 염두에 둘 필요가 있다.

〈표 4-6〉 업종별 AI 도입률

(단위 : %)

업 종	~2021	2022	2023
정보통신	12.3	16.5	17.6
제조 2	3.5	4.6	6.1
금융	3.3	4.5	5.3
전문서비스	3.5	4.9	5.1
도소매	2.3	3.6	3.7
제조 1	1.3	2.1	2.5
부동산	0.4	0.3	2.2
그 외 서비스	1.7	2.3	2.0
음식숙박	1.6	2.1	2.0
사회간접	0.9	1.8	2.0
운수창고	0.7	1.2	1.7
농업	1.5	2.1	1.6
건설	1.1	1.3	1.2


주 : 1) 제조 1은 식음료, 섬유, 의복, 가구, 화학, 금속, 비금속; 제조 2는 전자, 컴퓨터, 의료, 전기, 기계.

2) ~2021은 2017~2021이므로 이후 연도와 직접 비교 불가함.

자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-3] 업종별 AI 도입률

(단위 : %)



자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

사업체 규모별로 AI 도입률을 살펴보면 <표 4-7>, [그림 4-4]와 같다. 소규모 사업체는 AI 도입률이 미미하지만, 대기업으로 갈수록 도입률은 증가하는데, 특히 최근 2년 사이에 급속히 증가하는 것을 볼 수 있다. 2023년 기준으로 볼 때 1000인 이상 사업체의 약 41%는 AI를 도입하고 있다. 300인 이상~1,000인 미만 사업체도 23%는 AI를 도입했다.

기업의 인공지능 기술 도입률이 아직 높지 않은 수준인 것으로 알려져 있는데, 구인공고에 나타난 숙련수요를 통해서 살펴보면 이 비율은 생각보다 높다. 특히 대기업에서는 더욱 그러하다. 이는 기업들이 본격적으로 인공지능 시스템을 도입하지는 않았더라도 AI 관련 숙련을 가지고 있는 인력을 채용하여 변화를 구상하고 있다는 의미로 해석할 수 있다.


<표 4-7> 사업체 규모별 AI 도입률

(단위: %)

	2021	2022	2023
1,000인 이상	24.2	36.6	41.0
1,000인 미만	14.9	19.7	23.0
300인 미만	7.0	9.9	12.1
50인 미만	2.2	3.1	3.0


자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-4] 사업체 규모별 AI 도입률



자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-5] AI 도입 여부별 사업체 AI 노출도



자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

인공지능 노출도가 높은 사업체가 AI를 도입하는 경향이 확인된다. 인공지능 노출도는 일자리에서 수행하는 과업(task) 단위로 측정되고 직종 단위로 합산된다. 즉, 일자리에 달린 지표이다. 따라서 사업체에 속한 근로자의 직종 구성을 살펴보면, 해당 사업체의 AI 노출도를 계산할 수 있다. 이렇게 계산한 사업체의 인공지능 노출도와 AI 도입 여부의 관계를 나타낸 것이 [그림 4-5]이다. 인공지능을 도입한 사업체는 도입하지 않은 사업체에 비해 AIOE 값이 뚜렷하게 크다. 정확하게는, 종사자의 직업이 AI 노출도가 큰 직업으로 구성된 회사일수록 AI를 도입할 가능성이 높은 것으로 해석할 수 있다. AI가 사람의 일을 대신할 수 있는 정도가 큰 일을 하고 있는 회사일수록 AI 도입 가능성이 높은 것은 어쩌면 당연한 현상이다.

2. AI를 도입하는 기업은 고용을 줄이는가?

인공지능도 일종의 자동화 기술이고 노동비용 절감 기술이라면, 인공지능을 도입하는 기업은 그렇지 않은 기업에 비해서 고용을 줄여나갈 가능성이 있다. 그러나 기존 연구들에서는 이러한 현상이 관찰되지 않았다. 이는 AI 기술이 확산되는 초기 단계이기 때문에 형편이 좋은 기업, 성장 가도에 있는 기업이 AI를 도입하기 때문에 그렇다는 설명이 가능했었다.


본 연구에서는 기업의 고용 증감을 세 가지 방법으로 측정했다. 전년 대비 근로자 증가 인원, 전년 대비 근로자 수 증가율, 신규채용 인원. 여기서 신규채용은 2024년 2월 시점에서 계속 근무 중인 인원만 계산했다.

AI 도입 사업체와 미도입 사업체를 구분하고, 사업체의 규모를 통제한 상태에서 전년 대비 종사자 수의 증감을 살펴보면, AI 도입 기업과 미도입 기업 간에 대체로 차이가 없으나, 1,000인 이상 규모의 사업체는 AI 도입 업체가 미도입 업체에 비해 근로자 수 증가가 뚜렷하다(그림 4-6). 신규채용 인원으로 살펴보아도 마찬가지다(그림 4-7). 규모와 업종을 통제하고, 도입/미도입 업체 간 신규채용 인원의 차이를 통계적으로 검증해 보기 위해서 OLS 회귀분석을 수행한 결과에서도 AI 도입 업체는 미도입 업체에 비해 신규채용 인원이 많다(표 4-8).

기존 연구와 비슷하게 우리 분석에서도, 적어도 현재까지는 기업의 AI 도입이 고용을 줄이지는 않는 것으로 볼 수 있다. 지금까지 기업은 새로운 서비스 기획이나 생산성 향상의 목적으로 AI를 도입하고 있다고 해석할 수 있다. 다만, 이러한 현상이 앞으로도 계속될 것인지는 지켜볼 필요가 있다. AI 기술이 확산하여 더 많은 기업이 AI를 도입하는 시기가 오면, 그때는 AI를 자동화 기술, 노동비용 절감 목적으로 사용하게 될지도 모른다.

[그림 4-6a] 사업체 규모별 AI 도입 여부별 전년 대비 근로자 증가 인원(2023년)


(단위 : 명)



자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-6b] 사업체 규모별 AI 도입 여부별 전년 대비 근로자 증가율(2023년)


(단위 : %)



자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-7a] 사업체 규모별 AI 도입 여부별 신규채용 인원(2021년)


(단위 : 명)



자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-7b] 사업체 규모별 AI 도입 여부별 신규채용 인원(2022년)


(단위 : 명)



자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-7c] 사업체 규모별 AI 도입 여부별 신규채용 인원(2023년)

(단위 : 명)



자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

〈표 4-8〉 OLS 회귀분석 : 로그(신규채용 인원)

	Coef.	Std.Err.
Intercept	4.703	0.019
AI_BIN[T.True]	0.430	0.010
SIZE_CD_LAST[T.1,000인 이상]	1.358	0.033
SIZE_CD_LAST[T.300인 미만]	-1.502	0.017
SIZE_CD_LAST[T.50인 미만]	-3.477	0.017
IND[T.금융]	-0.078	0.020
IND[T.농업]	0.138	0.042
IND[T.도소매]	-0.184	0.010
IND[T.부동산]	-0.224	0.018
IND[T.사회간접]	0.169	0.028
IND[T.사회서비스]	0.208	0.010
IND[T.운수창고]	0.068	0.015
IND[T.음식숙박]	0.139	0.012
IND[T.전문서비스]	0.094	0.011
IND[T.정보통신]	0.179	0.012
IND[T.제조 1]	0.202	0.011
IND[T.제조 2]	0.189	0.011
year[T.2022]	-0.030	0.005
year[T.2023]	0.015	0.005
No. Observations :	273701	
Df Model :	19	
R-squared :	0.410	
Log-Likelihood :	-3.8553e+05	
F-statistic :	1.001e+04	
Prob(F-statistic) :	0.00	

자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

3. AI 도입은 불평등을 심화하는가?

AI 도입이 불평등을 심화하는 기제로는 세 가지 경로를 생각해 볼 수 있다.

첫째, AI 도입 기업이 미도입 기업에 비해 노동자에게 높은 보상을 함으로써 불평등이 심화할 수 있다. 기업 간 지불 능력의 격차가 벌어지는 것을 의미한다.


둘째, AI 기술이 저숙련 또는 중숙련 노동자의 과업을 대체(replacement)한다면 불평등이 커질 수 있다. 특히, 중숙련 노동자를 대체한다면 양극화의 양상으로 나타난다.

셋째, AI 기술을 도입한 기업이 직종별로 불균등한 보상을 강화한다면 불평등이 커진다. AI 기술은 노동자의 숙련을 증강(augmentation)시키는 방식으로 기능할 수 있다. 즉, 일부 과업만을 대체하면서 해당 노동자의 생산성이 높아진다. 기업은 해당 노동자에게 높은 보상을 하게 되는데, 누가 여기에 해당하는지에 따라 불평등은 심화할 수도 있고 완화될 수도 있다. 누가 수혜자가 될 것인가가 문제다.

첫 번째 경로는 AI 도입 기업의 임금이 미도입 기업에 비해 높다는 가설을 의미한다. 우리가 분석에 활용한 데이터로는 기존 근로자의 임금을 알 수 없기 때문에 신규 입사자의 임금을 살펴보았다. [그림 4-8]에 나타난 바와 같

[그림 4-8] 사업체 규모별 AI 도입 여부별 신규 입사자 1인당 월임금액(2023년)

(단위: 원)




자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

이, 사업체 규모를 통제하고 보더라도 AI 도입 업체는 미도입 업체에 비해 신규 입사자의 임금이 높다. AI 도입 기업은 생산성이 높고 시장을 선도하는 기업이라고 볼 수 있고, 이들과 미도입 기업 간의 지불 능력 격차가 존재한다고 해석할 수 있다.

불평등 심화 기제의 두 번째 경로를 살펴보자. AI는 어떤 직종의 과업을 대체하는가? 즉, 어떤 직종의 일자리를 대체하는가? 엄밀한 분석을 통해 대답을 제시하기는 어렵지만, 여기서는 AI 도입 사업체와 미도입 사업체의 직종별 신규채용 인원을 살펴본다. 로봇 등 기존의 자동화 기술이 생산직 노동자의 과업을 대체하는 것으로 알려진 것과 달리, 인공지능은 전문직과 관리직, 사무직 노동자의 과업을 대체할 것이라는 예상이 있다. 그래서 ‘이번에는 다를까?’를 질문해 온 것이다.


분석 데이터는 이번에는 다르다는 가설을 지지하지는 않는 것으로 보인다. AI 도입 기업은 미도입 기업에 비해서 관리직과 전문직, 사무직의 신규 채용이 뚜렷하게 많은 것으로 보인다(그림 4-9). AI가 현실에서 관리기능, 전문직의 과업, 사무직 과업을 본격적으로 대체하고 있는 단계에 들어가지는 않은 것으로 해석할 수 있다.

[그림 4-9a] 사업체 규모별 AI 도입 여부별 전문·관리·사무직 채용 인원(2023년)




자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-9b] 사업체 규모별 AI 도입 여부별 판매·서비스직 채용 인원(2023년)



자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

[그림 4-9c] 사업체 규모별 AI 도입 여부별 생산·노무직 채용 인원(2023년)



자료 : 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 작성.

제5절 소 결

이 장에서는 AI 노출도와 구별되는 개념으로서 기업의 AI 도입률에 따른 고용효과를 검토했다. 노출도가 직종별로 계산되는 지표이고 AI가 개별 직무를 대신할 수 있는 정도를 측정하는 지표인 것에 비해, 도입률은 실제로 기업이 AI 기술을 활용하고 있는지 여부를 측정하는 지표이다.

본 연구에서는 온라인 구인공고에 나타난 AI 관련 숙련수요를 보고 기업의 AI 기술 도입 여부를 판단했다. 어떤 회사가 AI 관련 숙련(skill)을 보유하

고 있는 인력을 채용하려는 구인공고를 냈다면, 이 회사는 AI 기술을 도입한 것으로 본다는 조작적 정의를 사용하였다. 온라인 구인공고를 사업체별로 식별하고 고용보험DB 자료를 결합한 결과, 2023년 기준으로는 13만여 개의 사업체가 분석에 활용되었다.

전체 사업체의 약 4% 정도가 AI를 도입한 것으로 나타나서, 아직까지 AI가 기업에 폭넓게 적용되고 있다고 보기는 어렵다. 하지만 대기업 중에는 도입한 기업이 많다. 1,000인 이상 사업체의 41%, 300인 이상~1,000인 미만 사업체의 23%가 AI 기술을 도입한 것으로 보인다. 종사자의 AI 노출도와 기업의 AI 도입률은 정(+)의 상관관계가 있는 것으로 나타났다. AI가 사람의 일을 대신할 수 있는 정도가 큰 직종의 근로자로 구성된 회사일수록 AI 기술을 도입하는 경향이 높은 것은 당연한 현상이다.

AI를 도입하는 기업은 고용을 줄일까? 기존 연구와 비슷하게 우리 분석에서도, 적어도 현재까지는 기업의 AI 도입이 고용을 줄이지는 않는 것으로 나타났다. 다만, 이러한 현상이 앞으로도 계속될 것인지는 지켜볼 필요가 있다. AI 기술이 확산하여 더 많은 기업이 AI를 도입하는 시기가 오면, 그때는 AI를 자동화 기술, 노동비용 절감 목적으로 사용하게 될 수 있다.

AI 도입 사업체와 미도입 사업체의 직종별 신규채용 인원을 살펴보았다. 인공지능이 인지적 숙련(cognitive skill)을 대신하기 때문에, 전문직, 관리직, 사무직의 과업을 대체할 것이라는 가설을 생각해 볼 수 있다. 즉, AI를 도입한 기업은 미도입 기업에 비해서 관리직, 전문직, 사무직 신규채용이 적은지 살펴보았다. 분석 결과는 이러한 가설을 지지하지 않는다. AI가 현실에서 관리기능, 전문직의 과업, 사무직 과업을 본격적으로 대체하고 있는 단계에 들어가지는 않은 것으로 해석할 수 있다. 다만, 본 분석은 매우 간단한 기술통계를 살펴본 것이므로 이후 추가적인 연구가 필요하다.

제 5 장

기업의 AI 개발 · 활용이 노동생산성에 미친 영향

제1절 들어가며

생산성과 관련하여 일반적인 경제 이론은 기술 진보가 생산성과 정(+)의 관계가 있다고 예측한다. 그런데, 1970년대 이후 IT 혁신이 발생하는 산업 내에서도 생산성이 둔화하는 ‘생산성 역설’ 현상이 나타났다(Brynjolfsson & Hitt, 1993). Gordon(2018)에 따르면, 노동생산성이 이러한 생산성 둔화의 거의 절반을 차지한다. 하지만 AI 기술의 급격한 발전과 범용 기술로서 방대한 적용 가능성으로 인해 다시 생산성이 높아질 거라는 낙관론이 고개를 들고 있다. 예를 들면, AI는 예측력의 향상으로 불확실성을 줄여줄 수 있으며, 또한 자동화를 통해 기존 기술을 재조합하거나 새로운 혁신을 창출할 수가 있다는 것이다(Agrawal et al., 2019; Cockburn et al., 2019).

하지만 이러한 AI 기술의 급격한 발전에도 불구하고, 생산성 둔화는 여전히 반전되지 않고 있다. 이에 대해 Brynjolfsson et al.(2019)은 AI를 경제 전반에 활용 · 확산하기 위해서는 보완적인 제품 개발, 기업 구조조정, 근로자 숙련 제고 등이 필요하므로, 이에 따른 시차가 존재한다고 주장한다. Acemoglu (2024)는 AI 기술은 그 자체만으로 실현할 수 있지 않으며, AI와 관련한 새로운 업무를 수행할 수 있도록 근로자의 숙련 개발이 필요하다고 역설한다.

이처럼 AI에 대한 낙관론과 회의론이 교차하고 있으므로, AI의 경제적 효과, 특히 AI의 고용과 생산성 효과에 관한 실증 연구의 필요성이 커지고 있

다. 하지만 AI 기술 도입이 초기 단계이므로 이에 대한 기업 수준의 정밀한 조사자료가 많지가 않아 이것이 이 분야 연구의 장벽으로 작용하고 있다 (Seamans and Raj, 2018). 따라서 이에 관한 국내외 연구는 많지가 않다.

그런데 통계청의 「기업활동조사」 자료에 2017년부터 9개의 ‘4차 산업혁명’ 기술의 개발 · 활용에 관한 설문조사 문항이 들어가기 시작했다. AI는 이러한 ‘4차 산업혁명’ 관련 기술 중의 하나다. 따라서 특허나 구인공고 자료를 이용한 간접적인 측정 방식이 아니라 설문조사를 통한 직접적인 측정 방식으로 기업 수준에서 생산성이나 고용과 같은 AI의 경제적 효과를 분석할 수가 있다(송단비 외, 2021; 정소라 · 성낙일, 2024).

이러한 맥락에서 이 글은 2017~2022년 통계청의 인가용 「기업활동조사」 자료를 이용하여 전체 기업을 대상으로 AI 개발 · 활용의 생산성 효과를 추정하려는 것이다. 이를 위해 제2절에서는 AI의 생산성 효과에 관한 기존 국내외 문헌을 검토한다. 제3절에서는 추정 모형과 방법, 그리고 자료와 변수 등에 관한 기술이 이루어질 것이다. 마지막 제4절에서는 이제까지의 분석 결과를 요약하고 글을 맺는다.

제2절 선행연구

자본주의 시장경제에서 자본은 인간을 대체하여 노동생산성을 높이려는 줄기찬 노력을 해 왔다. Growiec(2022)는 이러한 자본에 의한 노동 대체를 네 단계로 구분한다. 첫 번째는 산업혁명 초기에 보듯이 기계화 진전에 따라 자본이 인간 육체노동을 대체하는 단계다. 두 번째는 로봇을 이용한 자동화의 진전에 따라 자본이 인간의 인지적 노동 일부를 소프트웨어로 대체하는 단계다. 이는 포디즘 이후 우리가 목도해 왔던 단계다. 세 번째는 주로 예측을 위한 기계학습의 활용을 통해 소프트웨어가 스스로 작업을 개선할 수 있게 됨으로써, 자본이 인지적 인간 노동을 대체하는 단계다. 현재 AI¹⁴⁾ 이용

14) AI는 컴퓨터 프로그램을 통해 자연어를 학습, 추론, 인지, 이해하는 능력을 포함하며, 이는 기계를 지능화함으로써 주변 환경을 인식, 분석, 대응하고 적절히 행

의 경제적 효과에 관한 논의가 바로 이 단계를 겨냥하고 있다. 마지막은 컴퓨터가 일반 지능을 갖게 되는 초지능 단계다. 이 단계에서는 컴퓨터가 모든 면에서 인간 지능을 능가할 수 있는데, 일부 학자는 이러한 단계가 그렇게 머지않은 시기에 도래할 것이라고 예상한다.

세 번째 단계를 대표하는 핵심 기술 AI는 범용 기술로 취급되면서 광범위한 산업 부문에서 빠르게 확산·활용되고 있다(Brynjolfsson et al., 2019; Agrawal et al., 2019). 범용 기술은 시간이 지남에 따라 생산성을 높일 수 있는 기존과는 다른 새롭고 보완적인 생산 방식을 가능케 한다는 점(Bresnahan et al., 2002; Cardona et al., 2013)에서 AI 기술에 관한 관심이 높아지고 있다. 따라서 기업이 AI 기술을 활용하면 새로운 사업 기회가 창출되고 생산성이 향상될 수 있을 것으로 기대되고 있다(Brynjolfsson and McAfee, 2014).

이러한 AI의 생산성 효과에 대해서는 크게 두 가지 견해가 있다. 첫 번째 견해는 AI는 기업의 생산함수에서 추가적인 무형 자본 또는 추가적인 투입 요소로 간주될 수 있으며, 범용 기술로서 AI는 기업의 생산성을 높일 수 있는 잠재력이 충분하다는 것이다(Brynjolfsson et al., 2019; Agrawal et al., 2019). 이는 AI가 기반 기술이므로 기업이 더 가치 있는 산출물을 생산할 수 있는 혁신 역량을 배가하는 추가 자본 또는 투입 요소라는 관점에서 있다. 따라서 이러한 기술을 응용함으로써 기업의 혁신 역량이 배가되고 생산성이 높아질 수 있는 방법에 대한 다양한 새로운 아이디어가 나올 수 있다(Aghion et al., 2019). AI는 주로 새로운 소프트웨어 알고리즘과 빅데이터 분석을 기반으로 하는 무형자산이므로 AI의 생산성 효과 분석은 무형자산의 생산성 효과 분석과 연관이 있다(Corrado et al., 2021).

반면에, IT와 같은 신기술의 생산성 효과에 대해 회의적인 견해가 있다. 대표적인 이가 Gordon(2018)으로, 그는 미국의 생산성 둔화는 오래갈 것이고, 현행 디지털과 AI 기술 혁신은 1920~1970년대 사이 미국에서 전기 및 내연기관과 같이 눈부신 생산성 향상을 일으킨 혁신보다 덜 파괴적이므로 이에 대한 지나친 낙관론을 경계해야 한다고 주장한다. Bloom et al. (2020)은 다양한 산업, 제품, 기업에서 R&D 생산성이 급격히 떨어지고 있으며, 아

이디어를 찾기가 점점 더 어려워지고 있다고 지적한다. Gries and Naudé (2018)는 AI는 근로자 소득과 노동소득 분배율을 떨어뜨려 소수만이 혁신의 대가를 보상받고 불평등을 심화시킴으로써 잠재적 성장 역량과 생산성이 저해될 수 있다고 주장한다.

이러한 견해에 대해 Brynjolfsson et al.(2021)은 AI의 생산성 효과는 AI 개발과 확산의 후기 단계에서만 나타날 것이라고 주장한다. 즉 시차를 두고서 AI의 생산성 효과는 관측될 수 있다는 것이다(Tambe et al., 2020). Nordhaus (2021)는 범용 기술의 초기 확산 단계에서는 생산성 효과가 과소평가될 수 있다는 ‘경제적 특이점’을 주장한다.

AI가 새로운 유형의 무형자본이라고 한다면, 이와 같은 신규 자본 투자는 일반적으로 중·장기적으로 노동생산성에 정(+)의 효과를 미칠 것으로 예상할 수 있다. 그렇지 않다면 어느 기업이 이러한 대규모 투자를 단행할 그럴듯한 이유를 찾기가 어렵기 때문이다. 하지만 단기적으로 신기술 확산이 초기에 더디고 조정 비용이 많이 들어 생산성에 정(+)의 효과를 기대하기가 힘들 수 있다. 이를 반영하듯이 2017~2021년 기존 연구를 검토한 Calvino and Fontanelli(2023)는 기업 차원에서 AI의 생산성 효과에 관한 증거가 명확하지 않다고 지적한다. 대신에 이들은 OECD 마이크로 자료 분석을 통해 AI 활용의 생산성 효과가 IT 기술과 디지털 인프라와 같은 보완 자산과 관련이 있다는 사실을 제시한다.

디지털 도구는 일반적으로 대량 데이터의 생성, 수집, 활용 등 다양한 기능을 수행하는데, 단독으로가 아니라 상호 보완적으로 작동한다. 예를 들면, 5G 모바일과 IoT 기술은 대량 데이터를 생성하며, Big data 기술은 이를 대규모로 수집할 수 있다. 클라우드 컴퓨팅은 이러한 자료를 처리·저장하는 효과적인 도구다. 기업이 Big data를 활용하여 알고리즘의 정확성을 훈련하고 개선할 때 AI는 가장 효과적이다(DeStefano et al., 2020). 또한, 로봇공학, CAD/CAM, 소프트웨어, 3D 프린터 등과 같이 제품의 생산성, 품질, 유연성에 영향을 미치는 디지털 기반 기술은 제조공정 내에서 상호 보완적인 역할을 수행한다(Goldfarb et al., 2020). 이처럼 기계장비, 자료수집, 첨단 소프트웨어 및 통신 간 결합은 생산공정에서 데이터와 무형자산 간 결합의 중요성을 시사한다(Haskel and Westlake, 2017).

전술한 바와 같이, AI 기술은 도입 초기 단계이기 때문에 기업의 AI 활용에 관한 자료의 가용성이 제한되어 있다. 따라서 AI의 생산성 효과에 관한 논의에서 엄격한 실증적 증거가 부족하다. AI의 생산성 효과 또는 고용 효과를 포함한 대부분의 경제적 효과에 관한 기존 연구는 주로 AI 이용보다는 AI 노출 또는 AI 기술 수요 측정치에 기반하고 있다. 즉, 특허데이터¹⁵⁾(Cockburn et al., 2019; Van Roy et al., 2020; Alderucci et al., 2020; Damoli et al., 2021)나 구인 광고와 같은 직무 관련 설명(Acemoglu et al., 2022; Babina et al., 2024)에 기반하여 AI 이용의 측정치를 개발하고 이를 실증 연구에 적용하고 있다.

Alderucci et al.(2020)은 1997~2016년 미국 기업의 마이크로데이터와 AI 관련 특허를 결합하여 AI의 경제적 효과를 평가한다. AI 특허출원 기업과 그렇지 않은 기업을 비교함으로써, 전자가 후자보다 매출, 고용 및 기업 내 소득 불평등 증가와 더 관련이 있음을 보고한다. Van Roy et al.(2020)은 2000~2016년 AI 특허를 출원한 유럽 기업의 경제적 성과를 분석했는데, 그 결과는 AI 특허출원 기업과 연간 매출 간 정(+)의 관계가 있다는 것이다.

전술한 바와 같이, AI는 여러 분야에 걸쳐 이용되는 범용 기술이다. 이를 반영하기 위해 특허 자료에 기반한 기존 연구는 핵심어 접근법(De Prato et al. 2019) 또는 AI 관련 기술 클래스의 사전 선택(Fujii and Managi, 2018), 아니면 두 접근법의 조합(Cockburn et al., 2019)을 활용한다. Alderucci et al.(2020)의 작업은 AI 관련 특허를 식별하기 위해 AI 머신러닝 기법을 이용한 선구적인 분석이다.

온라인 구직공고를 통해 기업의 AI 활용 수준에 대한 직접 측정치가 아니라 채용공고 기업의 업무를 기반으로 한 AI 노출도를 통해 기업의 노동수요를 분석한 Acemoglu et al.(2022)은 AI의 고용과 임금의 순효과는 현재로서는 너무 작아서 감지할 수 없다고 주장한다. Babina et al.(2024)은 기업의 AI 기술 투자에 대한 대리변수로 근로자 이력서 자료와 AI 기술 관련 구인

15) 특허 자료는 AI 기술의 이용과 확산을 추적하고 분석할 수 있다는 이점이 있다. 반면에 모든 AI 기술이 특허로 재현되지 않으며, 많은 기업이 제삼자가 발명한 AI 기술을 채택할 수 있으므로 생산성에 대한 AI의 잠재적 효과가 불완전하다는 한계가 있다. 또한, 특허가 혁신을 포착하는 데 갖는 한계가 있다. 가령, 기업이 발명을 비밀로 유지하기 위해 특허를 선호하지 않을 수도 있다.

공고 자료를 이용함으로써 AI 기술이 성장과 제품 혁신에 미치는 영향을 분석한다. 그들은 AI 투자 기업이 매출, 고용, 시장 가치 측면에서 더 많은 성장을 경험하고, 이는 주로 제품 혁신을 통해 나타난다는 분석 결과를 내놓고 있다. Bäck et al.(2022)은 핀란드 기업을 대상으로 AI 기술 관련 구인공고 자료를 이용하여 AI 도입이 생산성을 높이지만, 이는 대기업에 한정되며, AI 도입과 생산성 효과 간에 최소 3년 시차가 있다는 사실을 보여준다.

최근에는 기업의 AI 활용에 관한 설문조사 결과를 이용한 연구가 나타나고 있다(Cathles et al, 2020; Lee et al., 2022; Czarnitzki et al., 2023). 유럽 투자 은행의 투자 설문 조사(EIBIS)에서 EU 회원국과 미국을 대상으로 한 조사자료를 이용한 Cathles et al.(2020) 분석에 따르면, AI 기술 도입과 고용 증가 및 노동생산성 간에는 정(+)의 관계가 있다. 독일 기업을 대상으로 기업의 AI 활용에 대한 직접적인 측정치를 이용한 Czarnitzki et al.(2023)은 약 6,000개 기업 중 약 7%만이 AI 기술을 도입했으며, 기업 차원에서 AI 활용의 유의미한 생산성 효과가 있음을 보고한다. 즉, AI 활용과 기업생산성 간에 긍정적이고 유의미한 연관성이 있다는 이러한 분석 결과는 AI가 생산성을 높이는 기술이라는 개념과 조응한다.

이제까지 논의를 요약하면, 작업의 자동화, 예측의 정확성 향상으로 인한 불확실성 감소, 기존 혁신과 새로운 혁신 간 재조합을 통해 활용되는 AI 기술의 파괴적 성격이 생산성 향상에 기여할 것이라는 낙관론(Brynjolfsson et al., 2019; Agrawal et al., 2019; Cockburn et al., 2019)이 있기도 하지만, 불평등 증가(Gries and Naudé, 2018), 학습비용(Jones, 2009), 다른 범용 기술과 비교해 상대적으로 낮은 AI의 파괴적 성격(Gordon, 2018) 등으로 생산성 둔화가 지속될 것으로 예상하는 반론이 있다. 또한, AI의 확산은 초기 단계라 AI의 생산성 효과를 판단하는 것은 시기상조일 수가 있다(Brynjolfsson et al., 2021).

이러한 상반된 예상으로 AI의 생산성 효과에 관한 실증연구의 필요성이 증대되고 있지만, 자료 가용성의 한계로 이 분야의 연구에서 일종의 장벽으로 작용하고 있다(Seamans and Raj, 2018). 그럼에도 불구하고, 이에 관한 분석 결과가 아직은 그렇게 많지는 않지만, 대체로 AI 활용의 경제적 효과는 기업 수준에서 긍정적인 정(+)의 생산성 효과를 보여주고 있다(Cockburn et

al., 2019; Alderucci et al., 2020; Cathles et al., 2020; Czarnitzki et al., 2023). 반면에, 기업 차원에서 AI의 생산성 효과가 명확하지 않고, AI와 다른 기술 간의 보완성에 주목해야 한다는 논의도 있다(Calvino and Fontanelli, 2023).

국내 논의에서는 AI 기술과 경제성장 간 관계에 이론적이고 거시적인 논의보다는 AI의 경제적 효과, 특히 생산성과 고용효과를 실증적으로 분석하려는 논의가 대다수다. 특히 통계청의 「기업활동조사」 자료에 2017년부터 AI를 포함한 9개 4차 산업혁명 기술의 개발·활용에 관한 설문조사 항목이 들어가면서 이 정보를 이용한 여러 가지 실증 연구가 진행되고 있다.

예를 들면, 송단비 외(2021)는 2017~2019년 「기업활동조사」 자료를 이용하여 AI 활용이 제조기업의 생산성에 미치는 효과를 추정했는데, 복수 사업체 보유 기업에서 AI의 생산성 효과가 관찰된다고 보고한다. 정소라·성낙일(2024)은 2017~2021년 「기업활동조사」 자료를 이용하여 AI 활용의 노동 대체 효과가 300인 이상 대기업에서 명확하다는 것을 보여준다. 김성환 외(2019)는 4차 산업혁명 기술이 수출 성과에 미친 효과를 분석하고 있다. 박순찬(2019)과 이승민 외(2022)는 기업 차원에서 이러한 4차 산업혁명 기술의 생산성 효과를 추정하고 있다.

Cho et al.(2023)은 2017년 「기업활동조사」 자료를 이용하여 빅데이터, IoT, 클라우드 컴퓨팅, AI 등 대량 데이터를 생성, 촉진, 소비하는 기술 간에 상호 보완성이 존재하며, 이러한 기술은 3D 프린팅과 로봇공학 같은 혁신적 도구에도 중요한 역할을 한다는 것을 보여준다. Lee et al.(2022)은 2019년 첨단 벤처기업에 대한 설문조사를 이용하여 AI 도입 강도와 매출 성장 간 통계적으로 유의한 정(+)의 관계는 클라우드 컴퓨팅과 같은 보완 기술에 투자하고 내부 R&D 전략을 추구하는 기업에서, 특히 벤처에 특화된 R&D 전략을 추구하는 기업에서 더 강하게 나타난다는 분석 결과를 내놓고 있다.

제3절 실증 분석

1. 추정 모형과 방법

가. 추정 모형

기업 차원에서 생산성을 실증 분석하는 일반적인 방법은 생산함수를 추정하는 것이다. 이러한 생산함수는 산출물(Y)이 일련의 투입요소(X)와 연관되는 함수 형태로 나타낼 수 있다. 이 장의 실증 분석을 위해 기업 부가가치는 콥 더글라스(Cobb-Douglas) 유형의 생산함수에 의해 결정된다고 가정하는 선행연구(Damioli et al., 2019; Alderucci et al., 2020; Czarnitzki et al., 2023)를 따라 다음의 생산함수가 정의될 수 있다.

$$V_{it} = A_{it} C_{it}^{\alpha} L_{it}^{\beta} \quad (5-1)$$

여기서 V 는 부가가치, C 는 물리적 자본, L 은 노동이고, A 는 총요소생산성, i 는 기업, t 는 시간이다. 식 (5-1)이 산출물이 아니라 부가가치 측면에서 정의되므로 원자재와 재료와 같은 투입요소가 자본이나 노동과 같은 방식으로 식에 들어갈 필요는 없다.

식 (5-1)의 양변을 L 로 나누고, 자연로그를 취하고, $\alpha + \beta = 1$, 즉 물리적 자본과 노동에 대한 수익 불변을 가정하면, 식 (5-2)를 얻을 수 있다.

$$\ln \frac{V_{it}}{L_{it}} = \ln A_{it} + \alpha \ln \left[\frac{C_{it}}{L_{it}} \right] = \ln A_{it} + \alpha \ln \left[\frac{C_{it}}{L_{it}} \right] + \gamma A I_{it} \quad (5-2)$$

식 (5-2)에서 V/L 는 기업의 부가가치를 종업원으로 나눈 노동생산성을 의미한다. 이 측정치는 AI 개발 · 활용의 생산성 효과를 직관적으로 이해할 수 있게 한다. 또한, Brynjolfsson et al.(2019)이 언급한 바와 같이, 노동생산성은 총요소생산성과 달리 기업의 AI 도입과 연관된 다양한 측정 방식에 대

한 민감도가 낮아 AI 개발·활용에 대한 기업의 생산성 효과를 통계적으로 검증하는 데 용이하다. 그리고 이에 관한 선행연구(Damioli et al., 2019; Alderucci et al., 2020; Babina et al., 2020; Czarnitzki et al., 2023)도 노동생산성 변수를 이용하고 있으므로, 어느 정도 상호 비교가 가능할 수도 있다.

식 (5-2)에서 AI 는 기업의 AI 활용·개발을 나타내는 추가 변수다. 식 (5-2)는 기업의 생산성에 대한 IT 또는 혁신기술의 효과를 분석한 Brynjolfsson and Hitt(2003)가 사용한 추정식과 유사하다. 그들은 기업의 컴퓨터 자본 스톡을 추가 생산 투입요소로 설정하여 기업의 생산함수를 추정한 바 있다. AI 기술이 축적 가능하고 감가상각이 가능한 무형자산의 일종이며, 기업이 이를 활용하여 부가가치를 창출할 수 있다고 가정하면, 식 (5-2)를 이용하여 그것이 기업의 생산성에 미친 효과를 추정할 수 있다(Brynjolfsson et al., 2019).

그런데, 식 (5-2)에서 상수인 A 는 총요소생산성이며, 이는 관측된 투입요소로 인한 것이 아니라 생산함수를 통해 발생하는 전반적인 생산성 변화다. Czarnitzki et al.(2023)과 같이, 이를 $\ln A_{it} = \lambda_i + \delta X_{it} + \epsilon_{it}$ 로 나타내면, 식 (5-2)는 식 (5-3)과 같이 다시 쓸 수 있다. X_{it} 는 기업 특성을 나타내는 일련의 설명 변수이고, λ_i 는 기업별 시간 불변 생산성 항(term)¹⁶⁾이며, ϵ_{it} 는 비관측 확률 오차항이다.

$$\ln \frac{V_{it}}{L_{it}} = \lambda_i + \alpha \ln \left[\frac{C_{it}}{L_{it}} \right] + \gamma AI_{it} + \delta X_{it} + \epsilon_{it} \quad (5-3)$$

나. 추정 방법

이 절의 분석에서 식 (5-3)에 대한 기본 추정 모형은 횡단면 Pooled OLS다. 기업의 생산함수에 기본적인 투입요소인 자본과 노동 비율에다 AI 개발·

16) 콧-더글라스 생산함수를 이용한 기업의 생산성 추정 관련 문헌에서 λ_i 는 기업에는 알려져 있으나 연구자에게는 그렇지 않은 항이다. 기업은 이에 대한 지식을 토대로 투입요소를 최적으로 선택하므로 추정 과정에서 내생성 문제가 나타날 수 있다. 하지만 이 연구에서는 기존 다른 연구(Czarnitzki et al., 2023)처럼, 이러한 내생성 문제보다는 AI 변수의 내생성 문제에 더 집중할 것이다.

활용 여부를 나타내는 더미변수가 추가된다. 기본 추정 모형이 횡단면 Pooled OLS이므로, 모든 관측치에 대해 $\lambda_i = \lambda_0$ 라는 가정이 성립된다. 또한, 누락변수 편의와 비관측 이질성을 완화하기 위해 산업, 시간, 지역 더미, 혁신 활동 역량, 임금구조 인센티브, 고용형태, 기업지배구조, 외주화 전략, 수출기업 등과 같은 여러 통제변수(X)가 기업의 생산함수 추정식에 들어간다.

특히 AI 기술을 개발 · 활용하는 기업일수록 생산성이 높을 것이라는 내생성 문제를 해결하기 위해 AI 변수에 대한 도구변수를 활용하는 IV 추정(2SLS)을 한다. 하지만 「기업활동조사」를 이용한 기존 연구에서 제시된 바와 같이, 이 자료에서는 다양한 도구변수의 활용이 충분하지 않다(송단비 외, 2021; 정소라 · 성낙일, 2024).

Czarnitzki et al.(2023)을 따라 비관측 이질성으로 인한 잠재적 편이 가능성이 있으므로 처리 집단과 대조 집단 간 공변량의 불균형을 제거하기 위해 가중치를 할당하는 엔트로피 밸런싱(Entropy Balancing: EB)을 이용해 AI의 생산성 효과가 추가로 분석될 것이다. EB는 각 매칭변수의 세 가지 적률(평균, 표준편차, 왜곡도)을 처리집단(AI 개발 · 활용 기업)과 대조집단(AI 미개발 · 활용 기업) 간에 같게 하는 방법이다. 대조집단의 관측치에 가중치를 부여하면 이러한 대조집단에서 처리집단과 같은 적률(moment)이 생성될 수 있다(Hainmueller, 2012). 이에 따라 가중치가 적용된 대조집단이 처리집단과 유사한 공변량(covariate) 분포를 하게 된다.

EP는 활용 가능한 모든 대조집단의 관측치를 이용하므로 이상치 영향을 덜 받아 성향점수매칭법(propensity score matching)보다 유연하다는 장점이 있다. 이러한 가중치를 적용한 추정 결과는 기업의 AI 개발 · 활용이 생산성에 미치는 효과가 AI 개발 · 활용 기업과 그렇지 않은 기업 간 구조적 차이에 기인하지 않는다는 것을 의미한다.

EB를 통해 가중치를 생성하기 위해 식 (5-3)에 있는 일련의 공변량이 활용된다. 가중치를 생성하는 알고리즘이 대조집단의 가중치 조정을 중단하기 위해 충족해야 하는 균형 조건을 설정해야 한다. 이 경우 이상적으로는 처리집단과 가중치가 적용된 대조집단에서 공변량 분포의 세 개의 적률이 같아야 한다.¹⁷⁾ McMullin and Schonberger(2022)가 권고한 바와 같이, 현

재의 분석에서 이용된 자료가 단일 연도 자료가 아닌 복수 연도의 자료이므로, 복수 연도 횡단면 Pooled 자료를 하나로 설정하여 EB를 통해 가중치를 할당하는 것이 아니라, 개별 연도별로 가중치를 할당한다.

전술한 모든 관측치에 대해 $\lambda_i = \lambda_0$ 라는 가정을 완화하고 이질성을 통제하기 위해 2017~2022년 균형 패널자료를 구축한다. 정소라·성낙일(2024)과 같이 2017년 기준으로 2022년까지 주업종을 변경하지 않은 기업을 대상으로 균형 패널을 구축하므로 일부 기업이 분석에서 제외되는 잠재적인 표본 선택 편이가 발생할 수 있다.¹⁷⁾ 이러한 패널자료를 이용하여 패널 OLS와 IV 추정 모형을 통해 기업의 생산함수를 추정한다. 따라서 기업 생산함수의 추정식에서 λ_i 가 고려될 수 있다.

고정효과 모형은 시간 가변 변수의 효과를 분석하는 동시에 시간 불변 비관측 이질성으로 인한 누락변수의 편의를 고려하는 데 적합하다. 반면에 기업 간 차이가 종속변수에 어느 정도 영향을 미친다고 하면, 고정효과 모형보다 시간 불변 변수의 효과를 추정할 수 있는 임의효과모형이 더 적절하다. Hausman and Taylor(1981)는 시간 불변 변수를 포함하고 비관측 개별적 이질성을 통제하기 위해, 즉 고정효과와 임의효과를 혼합하는 추정 방법인 HTE(Hausman-Taylor Estimator)를 제안한다. 이는 추정모형에 포함된 설명변수를 활용하는 도구변수 추정을 통해 회귀변수와 오차항 간 상관관계가 존재할 수 있다는 임의효과의 문제점을 해결한다. 따라서 HTE는 고정효과와 달리 시간 불변 변수를 추정하기 위해 임의효과 추정을 이용할 수 있다.

AI 개발·활용 변수는 기업 생산성에 영향을 미치는 개별 기업의 특성과 연관성이 있지만, 후자는 관측되지 않으며, 단기간에 변하지 않는 시간 불변적일 가능성이 크다. 전술한 바와 같이, HTE 추정은 고정효과와 달리 시간 불변 변수를 추정할 수 있을 뿐만 아니라 기업 간 변동을 고려할 수 있다. 특

17) 여기서는 3이 아니라 2를 부여하였다. 3을 부여할 경우 두 집단 간 수렴이 이루어지지 않아 2를 선택한 것이다. 이는 세 적률 가운데 평균과 분산이라는 두 적률이 두 집단 간에 같다는 것을 의미한다.

18) 하지만 아래의 기술통계량에서 보는 바와 같이 두 자료의 분포에서 큰 차이가 없다.

히 AI 개발 · 활용 더미변수는 기업별로 연도별 변동이 거의 없으므로, 이 경우 기업 간 변동이 더욱더 고려될 필요가 있다. 또한, 추정식에 이용되는 설명변수 중에 정성적인 더미변수와 산업 더미변수가 시간 불변 변수이므로, HTE 추정이 적합할 수 있다(정소라 · 성낙일, 2024: 53).

2. 자료와 변수

가. 자료원

이 글의 분석에 활용되는 기본 자료는 2017~2022년 통계청의 인가용 「기업활동조사」이다. 이는 기업의 다양한 경영활동(경영실적, 다각화, 계열화, 성과보상 관리제도 등)을 포괄적으로 파악하여 각종 경제정책의 기초자료 및 기업의 경영전략과 산업구조 변화 등에 관한 연구 · 분석 자료를 제공하기 위해 2006년 이후 통계청이 매년 발간하는 통계자료다. 통계조사는 직접 방문 또는 온라인 기반 설문지를 통해 실시되며, 행정 데이터 및 기타 관련 정보로 보완된다.

이 자료는 산업분류상 전산업(O, T, U 제외)을 대상으로 하며, 매년 12월 31일 현재 회사법인 중 상용근로자가 50인 이상이면서 자본금이 3억 원 이상인 기업체를 조사대상으로 한다. 단, 도소매업 및 기타 서비스업은 상용근로자가 50인 미만이라도 자본금이 10억 원 이상이면 조사대상에 포함될 수 있다.

이 자료에서 포함된 조사 항목¹⁹⁾은 기업명, 대표자, 소재지, 기업의 창설 연도, 자본금(출자금) 등 일반 사항, 기업 내 조직 및 종사자 수, 재무구조(자산 · 부채 · 자본, 유 · 무형 자산 연간 증가), 경영실적(매출액, 영업비용, 당기순이익 등), 관계회사(자회사, 관련 회사, 모회사) 사항, 국내외 기업 간 거래(관계회사 비중), 사업의 외주비, 연구개발비, 지식재산권 보유, 기업의 경영 방향(국내외 외부위탁, 4차 산업혁명 관련 기술 개발 · 활용, 신규사업 진출, 주력사업 운영 변동, 전략적 제휴 여부, 성과보상 관리제도) 등이다.

19) 통계청의 마이크로데이터 인가용 자료에 조사 대상 모든 항목이 공개되는 것은 아니다.

나. AI 개발 · 활용 변수

통계청의 「기업활동조사」에서 ‘기업의 경영 방향’ 항목에 2017년부터 ‘4차 산업혁명 관련 기술 개발 · 활용’ 설문 조항이 추가되었는데, 4차 산업혁명 관련 기술은 사물인터넷, 클라우드, 빅데이터, 모바일, 인공지능, 블록체인, 3D 프린팅, 로봇공학, 가상증강현실 등 9개를 포함한다. 이 설문 조항은 4차 산업혁명 기술의 개발 · 활용, 활용 분야, 개발 방식 등을 아우른다(통계청, 2024).

이처럼 기업에 대한 직접 설문조사를 통해 AI 활용 여부를 측정할 경우 기업의 AI 활용 측정을 위해 관련 분야 특허 또는 구인광고의 관련 분야 숙련 비중을 통해 간접적인 방식으로 AI 활용을 측정했던 선행연구의 한계를 넘어서 설 수가 있다. 예를 들면, AI 관련 특허자료를 활용하면 특정 기업이 해당 기술의 구매 또는 외주화를 통해 활용된 사례는 배제된다. 따라서 AI 관련 특허는 AI 활용 그 자체보다 그 기술의 개발 정도를 측정하는 것으로 볼 수가 있다(Damioli et al., 2021; Alderucci et al., 2020).

구인광고의 AI 관련 숙련 요구 비중으로 AI 활용을 측정할 때도 이와 유사한 문제가 발생할 수 있다. 이 측정치는 AI에 대한 기업 인력 수요의 증감을 보여줄 수는 있으나, 이것이 어떤 수요인지를 분명히 드러내지 않으므로 기업의 실제 AI 활용이 명확히 확인될 수가 없다. 즉, 이것이 해당 기술 개발에 대한 수요인지, 이를 활용하기 위한 수요인지, 관련 기술 파악이나 도입 준비 과정에 나타난 수요인지를 확인할 수가 없다(Alekseeva et al., 2021; Babina et al., 2020).

통계청의 「기업활동조사」에서 설문 문항이 AI 개발과 활용 양자를 포함하고 있으므로 이를 명확히 구분하기가 어렵다. 기업에 따라 두 가지 활동은 상이할 수가 있다. 가령, AI 기술을 개발하여 타 기업에 관련 재화와 서비스를 판매하는 기업의 경우 두 가지 활동의 영역이 다를 수 있다(송단비 외, 2021). 「기업활동조사」를 활용한 기존 국내 연구에서 AI 개발 또는 활용 여부 모두를 기업이 AI 기술을 도입한 것으로 여긴다(송단비 외, 2021; 정소라 · 성낙일, 2024). 이 글의 분석도 마찬가지로 어느 기업이 AI 기술을 개발하거나 활용한 경우라면 그 기업은 AI 기술을 도입한 것으로 간주한다.

이 글의 분석에 이용되는 AI 변수는 기본적으로 더미변수다. 따라서 차분 모형에서는 시점 간 차이를 드러내지 못한다. 따라서 AI 변수에 대한 해석이 달라질 필요가 있다. 이는 자본스톡(stock)이라기보다는 AI에 대한 기업의 최근 투자를 반영한다. 대부분의 AI 도입 기업이 최근해야 이 기술을 개발하거나 활용했으므로 스톡보다 투자 가정이 더 현실적이라고 볼 수 있다 (Czarnitzki et al., 2023: 193).

다. 기타 변수

이 글의 분석에 이용되는 종속변수는 로그 1인당 실질 부가가치다. 부가가치는 「기업활동조사」의 조사 항목을 참조하여 영업이익, 대손상각비, 인건비, 세금과 공과, 감가상각비, 임대료 등의 합계로 정의된다. 명목 부가가치는 2020년 GDP 디플레이터를 이용하여 실질 부가가치로 전환한다. 종업원은 상용직, 임시·일용직, 기타직으로 구성되어 있는데, 특히 기타직 변동이 심하여 여기서 종업원은 상용직과 임시·일용직의 합계다. 따라서 1인당 실질 노동생산성은 실질 부가가치/(상용직+임시·일용직)으로 정의된다.

기업의 생산함수에서 주요 투입요소는 자연로그로 측정된 실질 자본과 노동비율이다. 기업의 유형자산과 종업원이 각각 자본과 노동을 대리하며, 따라서 로그 1인당 실질 유형자산이 자본과 노동비율을 대리한다. 이러한 투입과 산출 변수는 「기업활동조사」의 재무구조와 경영실적 항목에서 얻을 수 있다.

AI의 생산성 효과를 다른 기술 혁신의 잠재적 효과와 분리하기 위해, 식 (5-3)의 TFP를 나타내는 A는 추가적인 기업특수적인 변수(X)에 따라 변화할 필요가 있다. X는 일련의 설명변수로 이루어져 있다(표 5-1 참조).

첫째는 기업의 혁신 역량이다. R&D 활동을 수행하는 기업은 이러한 활동과 관련한 외부 지식을 습득함으로써 많은 기술 지식을 보유할 수 있다 (Brynjolfsson and Hitt, 2003). 이처럼 지식 기술을 보유한 기업은 다른 기업에 비해 TFP 수준이 높을 수 있다. R&D 지출액이 인가용 자료에서는 공개되지 않으므로, 여기서는 1인당 특허량으로 기업의 혁신 역량을 대리하는 변수로 사용한다.

〈표 5-1〉 주요 변수의 정의

변 수	정 의
ln(1인당 실질 부가가치)	로그 [실질 부가가치/종업원(상용직+임시·일용직)]
AI 개발·활용 여부	기업이 AI를 개발·활용한 경우 1, 그렇지 않으면 0인 더미변수
ln(실질 유형자산/종업원)	로그 (실질 유형자산/종업원)
수출기업 여부	기업이 수출 활동을 영위하면 1, 그렇지 않으면 0인 더미변수
외국기업 여부	외국인 지분율이 50% 이상이면 1, 그렇지 않으면 0인 더미변수
대기업 집단 여부	기업이 대기업 집단에 속하면 1, 그렇지 않으면 0인 더미변수
1인당 특허량 (임시·일용직/상용직)	특허출원/종업원 임시·일용직/상용직
외주 여부	기업이 외주화를 한 적이 있으면 1, 그렇지 않으면 0인 더미변수
전략적 제휴 여부	기업이 전략적 제휴를 한 적이 있으면 1, 그렇지 않으면 0인 더미변수
성과급/연봉제 도입 여부	기업이 성과급이나 연봉제를 도입하면 1, 그렇지 않으면 0인 더미변수
기업규모 더미	고용규모 100인 미만 1, 100인 이상~250인 미만 2, 250인 이상~300인 미만 3, 300인 이상~500인 미만 4, 500인 이상~1,000인 미만 5, 1,000인 이상 6인 더미변수 (기준변수는 100인 미만 기업)
산업 더미	산업 중분류 68개 산업 더미변수(기준변수는 농업)
연도 더미	2017~2022년 연도 더미변수(기준변수는 2017년)
광역시도 더미	17개 시·도 더미변수(기준변수는 서울)
AI 연관 기술 인프라 보유 여부	기업이 4차 산업혁명 기술 중 Big data, IoT, Cloud, 5G를 개발·활용하면 1, 그렇지 않으면 0인 더미변수
단순 산업 내 AI 개발·활용도	동종 산업 내 단순 AI 도입 비율
규모 가중 산업 내 AI 개발·활용도	동종 산업 내 기업규모(고용규모) 가중 AI 도입 비율

자료: 저자 작성.

둘째, 기업은 전략적 제휴를 통해 타 기업의 혁신과 기술 발전으로부터 경제적 이득을 얻을 수 있고, 타 기업과 상호작용을 통해 시너지 효과를 낼 수 있으므로, 다양한 전략적 제휴 활동을 수행한 적이 있으면 1, 아니면 0으로 하는 더미변수가 생성될 수 있다.

셋째는 수출기업 여부다. 수출기업은 더 많은 경쟁 압력을 받으므로 비효율성을 제거하거나, 신기술 또는 개선된 기술 이전과 확산을 통해 생산성을 높일 수 있다. 예를 들면, Aw and Hwang(1995)은 대만 전자기업을 대상으로 수출기업이 비수출 기업보다 생산성이 높다는 것을 보고하고 있다.

넷째, 기업의 지배구조다. 외국인 지분이 50%를 넘으면 1, 그 이하면 0으로 하는 외국기업 더미변수가 생성될 수가 있다. 외국인이 소유한 기업은 해외로부터의 지속적인 기술 이전과 확산을 통해 일반적으로 생산성과 기술 활용도가 높다(Griffith et al., 2002). 다국적 기업은 엄격한 생산 표준을 요구하고 유지하는 경우가 많으므로 기업 전체로 신기술이 쉽게 공유될 수 있다(Criscuolo and Timmis, 2017). 또한, 대기업 집단에 소속되면 1, 아니면 0으로 하는 대기업 집단 더미변수가 생성될 수 있다. 우리나라에서 대기업 집단에 소속되면 소위 ‘재벌의 그룹화 경제’의 이점을 통해 생산성 이득 효과가 기대될 수 있다(Chang, 1993).

다섯째, 고용형태가 기업의 생산성에 영향을 미칠 수 있다. 근로자의 이직이 줄어들거나 직업의 안정성이 높아지면 많은 경험이 있고 잘 훈련된 근로자가 확보되어 생산성이 높아질 수 있다. 여기서는 상용직 대비 임시·일용직 비율이 이를 대리하는 변수이다.

여섯째, 외주화이다. 기업 활동의 세계화로 핵심 역량에 집중하고 비핵심 자산을 외주화하는 관행이 일상화되고 있다. 내부의 비효율적인 조직이나 역량을 외주화함으로써 생산성이 제고될 수가 있다. 여기서는 외주화 경험 이 있으면 1, 아니면 0으로 하는 더미변수가 고려된다.

일곱째, 기업규모다. 대기업은 지식 기반 자본과 축적된 기술을 더 많이 보유하고 있을 가능성이 크므로 신기술을 더 쉽게 채택할 수 있다(Gibbs and Kraemer, 2004). 동시에 대기업은 일반적으로 상당한 양의 기존 자산과 관행으로 기업이 운영되는 경우가 많아 새로운 신기술인 AI를 수용하기가 어려울 수 있다(Iansiti and Lakhani, 2020). 반면에 중소기업은 유연적인

조직구조로 첨단기술을 채택할 가능성이 높을 수 있다. 이는 새로운 자본을 보유하거나(Baldwin and Rafiquzzaman, 1998), 혁신적인 위험을 감수할 의향이 더 높기 때문이다(Coad et al., 2016).

이처럼 규모 효과가 생산성에 미치는 효과가 지대할 수 있으므로 이를 대리하는 변수를 추정식에 포함한다. 기업규모를 종업원으로 대리할 경우 내생성 문제가 발생할 수 있으므로, 이를 완화하기 위해 기업규모를 종업원 기준으로 100인 미만, 100~250인 미만, 250~300인 미만, 300~500인 미만, 500~1,000인 미만, 1,000인 이상으로 구분하고, 이를 더미변수로 생성한다.

여덟째, 임금의 성과보상체제다. 성과급이나 직무급 도입과 같은 임금체제가 지연된 보상으로서 연공급과 대비하여 업무에 대한 강한 동기와 열정을 불러일으키는 인센티브로 작용하여 단기적으로 기업의 생산성을 높일 수 있다. 성과급이나 직무급을 도입한 기업은 1, 아니면 0으로 하는 더미변수를 생성하여 추정식에 포함한다.

마지막으로, 산업 더미와 지역 더미는 지금까지 설명한 구조적 변수로 아직 포착되지 않은 산업 부문과 지역에서 관측되지 않은 TFP 변동을 통제한다. 그리고 시간 더미는 거시경제적 변동을 통제한다. 산업 더미는 68개 중분류 수준, 지역 더미는 17개 광역시도 수준, 그리고 연도 더미는 2017~2022년 6년 수준에서 생성된다. 기준변수의 경우, 산업 더미는 농업, 광역시도 더미는 서울, 그리고 연도 더미는 2006년이다.

라. AI 개발 · 활용 변수의 내생성

고생산성 기업이 AI 개발 · 활용에 긍정적으로 나설 가능성 또는 저생산성 기업이 효율성 증대를 위해 AI 개발 · 활용을 추진할 가능성처럼 두 변수 간에 역인과(reverse causality) 가능성이 존재한다. 또한, 두 변수 모두에 영향을 미치는 비관측 누락 변수가 있을 수 있다. 예를 들면, AI 개발 · 활용은 기업의 광범위한 디지털화 노력 또는 기술 인프라의 일반적인 확장과 연관될 수 있으며, 이 경우 AI 개발 · 활용의 생산성 효과는 비관측 변수로 인한 것일 수가 있다(송단비 외, 2021; Czarnitzki et al., 2023). 이러한 이유로 AI 개발 · 활용과 생산성 간 잠재적인 내생성 문제로 식 (5-3)의 OLS 추정치가 편의될 수 있다.

이러한 문제에 대처하기 위해서는 AI 개발 · 활용 변수와 상관관계가 있어야 하지만, 비관측 생산성 충격과는 상관관계가 없어야 하는 도구변수가 필요하다. 「기업활동조사」를 이용한 기존 연구(송단비 외, 2021; 정소라 · 성낙일, 2024)를 참조하여 세 가지 도구변수가 추정에 활용된다. 이들 선행 연구에서 지적한 바와 같이, 「기업활동조사」에서 충분한 도구변수를 끄집어내는 것이 여간 어려운 일이 아니다.

첫째는 단순 산업 내 AI 개발 · 활용도이다. 이는 역인과 가능성을 줄이기 위한 것으로 동일 산업 내 타 기업의 AI 개발 · 활용도를 나타낸다. 다른 경쟁 기업의 AI 개발 · 활용도가 높을수록 동일 산업 내에서 신기술의 이전과 확산이 증대됨으로써 해당 기업은 AI 개발 · 활용을 긍정적으로 검토할 가능성이 있다. 이 도구변수는 AI 개발 · 활용과 연관성이 클 것으로 보이고, 간접 경로가 아닌 직접 경로를 통한 기업의 생산성 증대 효과는 낮을 것으로 기대된다(송단비 외, 2021).

둘째는 규모 가중 산업 내 AI 개발 · 활용도이다. 이는 단순 산업 내 AI 개발 · 활용도를 이용할 경우 현실과 다소 동떨어진 AI와 로봇의 개발 · 활용 비율이 나온다는 정소라 · 성낙일(2024)의 지적이 있다. 이를 수용하여 이 도구변수는 기업의 고용규모를 가중치로 이용해 계산한 것이다.

셋째는 AI 기술 연관 기술 인프라 보유 여부이다. 이는 AI 개발 · 활용과 생산성 변수 모두에 영향을 미칠 수 있는 제3의 누락 변수의 가능성을 통제하기 위한 것으로 더미변수다. Cho et al.(2023)은 「기업활동조사」에서 9가지 4차 산업혁명 관련 기술을 단독으로 이용하는 것보다 이들을 조합하여 활용하는 경향이 높다고 지적하고 있다. 예를 들면, 데이터 이용과 직접적 연관이 있는 AI 기술은 대량 정보를 생성하고 이를 저장하고 처리하는 5G, IoT, Big data 기술을 필요로 하며, Cloud 컴퓨팅은 정보를 보다 유연하게 저장하고 처리할 수 있게 하여 Big data, IoT, 5G 활용을 촉진한다. 따라서 이들 기술 간에는 상호보완성이 존재한다(DeStefano et al., 2020).

따라서 AI 기술과 상호보완성이 큰 Big data, IoT, Cloud, 5G 기술 보유 여부를 도구변수로 이용하면, AI 개발 · 활용 변수와 상관성이 높을 것으로 기대되며, 또한 이들 기술이 연관 기술의 인프라 기술이므로 간접 경로를 통해 기업의 생산성이 제고될 가능성이 클 것으로 보인다.

마. 기술통계량

2017~2022년 인가용 「기업활동조사」의 횡단면 풀링(pooled) 전체 관측치는 2017년 1만 2,578개, 2018년 1만 3,144개, 2019년 1만 3,255개, 2020년 1만 3,429개, 2021년 1만 3,448개, 2022년 1만 3,825개를 합쳐 7만 9,679개이다. 반면, 일부 이상치를 제외한 같은 기간 불균형 패널자료의 전체 관측치는 2017년 1만 2,242개, 2018년 1만 2,789개, 2019년 1만 2,899개, 2020년 1만 3,093개, 2021년 1만 3,102개, 2022년 1만 3,485개를 합쳐 7만 7,610개에 이른다. 전술한 바와 같이, 분석 기간에 주업종을 변경하지 않은 기업을 대상으로 균형 패널을 구성하면, 연도별 기업 수는 8,651개이고 전체 관측치는 5만 1,906개이다(표 5-2 참조).

〈표 5-2〉는 횡단면 풀링 전체 자료와 균형 패널자료를 통해서 본 AI 기술을 개발·활용하는 기업 수와 그 비중을 보여주고 있다. 횡단면 풀링 자료를 기준으로 AI 기술을 개발·활용하는 기업의 수는 2017년 173개에서 2022년 611개로 늘어났으며, 그 비중도 2017년 1.4%에서 2022년 4.4%로 늘어났다. 2017~2022년 기간 전체로는 평균적으로 3.2%의 기업이 AI 기술을 개발·활용하였다. 한편, 균형 패널자료를 기준으로 보더라도, AI 기술을 개발·활용하는 기업 비중이 2017년 1.7%에서 4.3%로 늘어났으며, 분석 기간의 평균은 3.4%이다. 따라서 AI 기술을 개발·활용하는 기업의 비중은 횡단면 풀링 자료와 균형 패널 간에 큰 차이는 없다.

〈표 5-2〉 AI 개발·활용 기업 수와 비중 추이(2017~2022년)

(단위 : %)

	2017	2018	2019	2020	2021	2022	전체
Pooled 자료(N=79,679)							
AI 개발·활용 기업	173 (1.4)	352 (2.7)	407 (3.1)	469 (3.5)	528 (3.9)	611 (4.4)	2,540 (3.2)
전체 기업	12,578	13,144	13,255	13,429	13,448	13,825	79,679
패널자료(N=51,906)							
AI 개발·활용 기업	145 (1.7)	264 (3.1)	312 (3.6)	329 (3.8)	362 (4.2)	369 (4.3)	1,781 (3.4)
전체 기업	8,651	8,651	8,651	8,651	8,651	8,651	51,906

자료 : 통계청, 「기업활동조사」.

2017~2022년 AI 기술을 개발 · 활용하는 기업 평균 비중이 3.2~3.4%라는 수치는 당연하게도 2017~2021년 「기업활동조사」의 균형 패널을 활용하여 분석 결과를 보고한 정소라 · 성낙일(2024)의 3.3%와 별다른 차이가 없다. Acemoglu(2024)는 2024년 2월 현재 미국에서는 약 5%의 기업 정도가 AI를 활용하고 있다고 언급하고 있다. 2019년 유럽연합의 「Community Innovation」 조사 중에 독일 기업 표본을 대상으로 AI의 생산성 효과를 분석한 Czarnitzki et al.(2023)은 AI 기술을 도입한 기업 비중이 약 7%에 달한다고 보고하고 있다. 따라서 2022년 기준 한국 기업의 4.3~4.3%라는 수치는 해외 기업의 그것보다는 다소 낮다고 볼 수 있을 것이다. 하지만 세계적으로 AI 기술을 도입한 기업 비중이 그렇게 높지 않다. 이를 통해 AI 기술 확산은 현재 초기 단계에 있다고 볼 수 있다.

〈표 5-3〉은 추정에 이용된 종속변수와 설명변수의 요약 통계를 보여주고 있다. 변수의 로그 전환이 가능하지 않거나, 관측치가 가용하지 않거나, 이상치가 있거나, 오류 가능성이 있어 보이는 관측치를 제거하여 실제로 횡단면 풀링 분석에 이용된 관측치는 6만 4,492개이고, 반면, 균형 패널의 그것은 4만 4,157개이다.

〈표 5-3〉 분석에 이용된 주요 변수의 기술통계량

	AI 개발 · 활용 기업		AI 미개발 · 활용 기업	
	평 균	표준편차	평 균	표준편차
Pooled Data(N=64,492)				
1인당 실질 부가가치	172.092	483.526	122.178	261.118
AI 개발 · 활용 여부	1	0	0	0
1인당 실질 유형자산	180.231	513.699	254.874	1,089.419
수출기업 여부	0.662	0.473	0.722	0.448
외국기업 여부	0.115	0.319	0.179	0.384
대기업 집단 여부	0.204	0.403	0.054	0.227
1인당 특허량	0.134	0.228	0.075	0.643
(임시 · 일용직/상용직)	0.062	0.231	0.138	1.353
외주 여부	0.684	0.465	0.598	0.490
전략적 제휴 여부	0.316	0.465	0.061	0.239
성과급/연봉제 도입 여부	0.968	0.177	0.818	0.385
기업규모 1 : 100인 미만	0.242	0.428	0.421	0.494
기업규모 2 : 100~250인 미만	0.283	0.450	0.319	0.466

〈표 5-3〉의 계속

	AI 개발·활용 기업		AI 미개발·활용 기업	
	평 균	표준편차	평 균	표준편차
기업규모 3 : 250~300인 미만	0.039	0.193	0.045	0.207
기업규모 4 : 300~500인 미만	0.107	0.310	0.077	0.266
기업규모 5 : 500~1,000인 미만	0.105	0.306	0.059	0.236
기업규모 6 : 1,000인 이상	0.225	0.418	0.080	0.271
AI 연관 기술 인프라 보유 여부	0.770	0.421	0.075	0.264
단순 산업 내 AI 개발·활용도	0.102	0.077	0.030	0.044
규모 가중 산업 내 AI 개발·활용도	0.268	0.189	0.118	0.150
Panel Data(N=44,157)				
1인당 실질 부가가치	201.523	506.561	126.468	228.843
AI 개발·활용 여부	1	0	0	0
1인당 실질 유형자산	214.546	591.471	246.017	774.008
수출기업 여부	0.688	0.463	0.735	0.441
외국기업 여부	0.117	0.322	0.165	0.372
대기업 집단 여부	0.214	0.411	0.061	0.238
1인당 특허량	0.123	0.209	0.068	0.260
(임시·일용직/상용직)	0.067	0.244	0.122	1.287
외주 여부	0.716	0.451	0.612	0.487
전략적 제휴 여부	0.322	0.467	0.064	0.245
성과급/연봉제 도입 여부	0.973	0.162	0.860	0.347
기업규모 1 : 100인 미만	0.159	0.366	0.355	0.479
기업규모 2 : 100~250인 미만	0.287	0.452	0.363	0.481
기업규모 3 : 250~300인 미만	0.040	0.196	0.055	0.228
기업규모 4 : 300~500인 미만	0.116	0.320	0.093	0.291
기업규모 5 : 500~1,000인 미만	0.120	0.325	0.071	0.256
기업규모 6 : 1,000인 이상	0.278	0.448	0.063	0.243
AI 연관 기술 인프라 보유 여부	0.786	0.410	0.083	0.276
단순 산업 내 AI 개발·활용도	0.099	0.076	0.028	0.043
규모 가중 산업 내 AI 개발·활용도	0.275	0.192	0.121	0.150

자료 : 통계청, 「기업활동조사」.

횡단면 풀링 자료의 주요 변수들을 보면, 1인당 실질 부가가치가 1억 7,200만 원이고, 그렇지 않은 기업의 그것은 1억 2,200만 원이므로, 전자의

노동생산성이 더 높고, 전자의 표준편차가 후자의 그것보다 작아서 전자보다 후자에서 기업별로 편차가 크고 다양하다는 것을 알 수가 있다. AI 개발 · 활용 기업의 1인당 실질 유형자산은 1억 8,00만 원이고, 반면 그렇지 않은 기업의 1인당 실질 유형자산은 2억 5,500만 원으로, 앞의 경우와 상반된다. AI 개발 · 활용 기업이 유형자산보다는 무형자산인 AI 기술 투자 등을 통해 노동생산성이 더 높은 것으로 추정된다.

〈표 5-3〉에서 터미변수의 평균값은 전체 대비 해당 변수에 속하는 해당 기업의 비중을 의미한다. 가령, 대기업 집단 여부 평균값이 AI 개발 · 활용 기업과 그렇지 않은 기업에 대해 각각 0.204와 0.054라는 것은 분석 기간 중 분석 대상 기업이 전체에서 차지하는 비중이 20.4%와 5.4%라는 것을 의미한다.

전반적으로 2017~2022년 분석 기간에 AI 개발 · 활용 기업은 그렇지 않은 기업에 대해 1인당 실질 부가가치, 1인당 특허량, 외주 여부, 대기업 집단 여부, 전략적 제휴 여부, 성과급/연봉제 도입 여부, 고용규모 300인 이상 여부, AI 연관 기술 인프라 보유 여부, 산업 내 AI 개발 · 활용도 비율이 더 높고, 반면에 상용직 대비 임시 · 일용직 비율이 더 낮다. 따라서 AI 개발 · 활용 기업은 대체로 대기업 집단에 속하는 대기업이고, 고용형태가 안정되어 있으며, 전략적 제휴나 외주화와 같은 다양한 경영전략을 구사하고, 성과급이나 연봉제를 도입하여 경쟁적인 보상 시스템이 작동하며, AI로 대표되는 무형자산 투자 비중이 높고, 결과적으로 노동생산성이 높다.

위에서 기술한 횡단면 풀링 자료에 대한 요약 통계량이 보여주는 바는 균형 패널자료에도 그대로 적용된다. 따라서 횡단면 풀링 자료와 균형 패널자료의 경우 분석에 활용된 변수들의 분포에서 큰 차이가 없다고 볼 수가 있을 것이다.

3. 추정 결과

가. 횡단면 풀링 자료

〈표 5-4〉는 전체 표본을 대상으로 횡단면 Pooled OLS와 IV 추정을 이용하여 기업의 생산함수를 회귀분석한 결과를 보여주고 있다. 〈표 5-4〉의 추

정 결과에서 종속변수는 로그 1인당 실질 부가가치다. 기본 추정·방식은 모형 1인 횡단면 Pooled OLS다. 앞서 언급한 바와 같이, AI 개발·활용 변수와 종속변수인 로그 1인당 실질 부가가치 간에 잠재적인 내생성 문제가 있으므로 이를 해결하고자 IV 추정을 한 것이 모형 2와 3이다. 한편, 공변량이 기업의 AI 개발·활용에 영향을 미칠 수 있다. 따라서 AI 개발·활용 기업과 그렇지 않은 기업 간에 같은 조건이 아닐 수 있다. 앞서 기술통계량에서 보듯이 AI 개발·활용 기업과 그렇지 않은 기업 간에 공변량 분포의 차이가 크다. 따라서 Czarnitzki et al.(2023)과 같이 EP를 적용하여 공변량 분포의 처리집단과 대조집단 간 균형(balance)을 맞추는, 즉 대조집단의 공변량 분포를 처리집단의 그것과 같게 보정할 필요가 있다. 모형 3은 EP를 통해 얻은 가중치를 이용해 회귀분석한 IV 추정치다. 세 모형은 횡단면 풀링 자료에 따른 이질성 문제를 통제하기 위해 기업별 클러스터 표준오차가 적용된 것이다.

주지하는 바와 같이, 이 분석에서 <표 5-4>에서 가장 주목해야 하는 회귀계수는 AI 개발·활용 더미변수다. 이 변수는 모형 1인 OLS 추정에서는 10% 수준에서 통계적으로 유의하지 않지만, 그 부호는 정(+)이다. 반면에, IV 추정(모형 2)과 EP를 적용한 가중 IV 추정(모형 3)에서는 그 변수는 10% 수준에서 통계적으로 유의하고, 그 부호는 정(+)이다. 즉, AI 개발·활용이 생산성에 미치는 효과는 어느 모형에서나 정(+)이지만, 10% 수준에서 통계적으로 유의한 것은 IV 추정을 한 모형 2와 모형 3이다. 모형 2와 모형 3에 따르면, AI 개발·활용 기업의 노동생산성이 각각 그렇지 않은 기업의 그것과 비교해 평균적으로 약 12.7%와 7.9%가 더 높다.

IV 추정을 이용한 모형 2의 계수 추정치가 다른 모형의 그것보다 훨씬 크다. 모형 3은 공변량 분포를 처리집단과 대조집단 간에 같게 보정함으로써 구조적 차이를 제거한 것이다. 이 경우 AI 개발·활용 기업이 그렇지 않은 기업보다 노동생산성이 약 7.9% 더 높고, 모형 2에 비교해 약 4.8%p 정도 줄어든다. 이는 약 도구변수(weak instrument)에 의한 것일 수도 있지만(정소라·성낙일, 2024: 56), IV 추정에서 이러한 분석 결과는 흔하며, Czarnitzki et al.(2023)의 그것과 유사하다.

IV 추정에 대한 검정 결과를 보면, 1단계 F 검정 결과, 귀무가설을 기각하고 F값도 10보다 커서 약 도구변수에 대한 우려는 없는 것으로 보인다(Staiger

and Stock, 1997). 또한, 도구변수 유효성에 대한 과대식별(Overidentification) Hansen J 검정도 귀무가설을 기각하지 않아 도구변수의 선정은 유효한 것으로 볼 수 있다(표 5-4 참조).

〈표 5-4〉 AI 개발 · 활용의 생산성 효과 : 횡단면 풀링 자료(N=64,492)

종속변수 : ln(1인당 실질 부가가치)	모형 1 : OLS	모형 2 : IV(2SLS)	모형 3 : IV+EP
AI 개발 · 활용 여부	0.011 (0.48)	0.127 (1.97)**	0.079 (1.97)**
ln(실질 유형자산/종업원)	0.134 (39.13)***	0.134 (39.03)***	0.155 (23.05)***
수출기업 여부	0.089 (9.53)***	0.088 (9.45)***	0.129 (5.40)***
외국기업 여부	0.284 (20.95)***	0.285 (20.97)***	0.328 (9.87)***
대기업 집단 여부	0.345 (15.51)***	0.341 (15.21)***	0.320 (12.96)***
1인당 특허량	0.017 (0.99)	0.016 (0.86)	-0.008 (-0.23)
(임시 · 일용직/상용직)	-0.029 (-4.07)***	-0.028 (-4.06)***	-0.100 (-2.89)***
외주 여부	0.008 (0.89)	0.007 (0.85)	0.039 (1.96)*
전략적 제휴 여부	0.020 (1.54)	0.010 (0.69)	0.054 (2.72)***
성과급/연봉제 도입 여부	0.141 (13.10)***	0.140 (13.09)***	0.208 (4.21)***
기업규모 더미	○		○
산업 더미	○	○	○
연도 더미	○	○	○
광역시도 더미	○	○	○
상수	3.138 (25.69)***	3.144 (25.82)***	2.456 (11.25)***
R2	0.337	0.336	0.430
Weak Instrument Test (Kleibergen-Paap rk Wald F값)	-	274.069***	770.178***
Overidentification Test (Hansen J 통계량)	-	0.15	0.30

주 : 1) 1만 6,172개 기업별 클러스터 표준오차를 적용한 것임.

2) *, **, ***는 각각 10%, 5%, 1% 수준에서 통계적으로 유의함을 나타내고, 괄호 안의 수치는 t값이며, EP는 Entropy Balancing의 약자임.
자료 : 통계청, 「기업활동조사」.

〈표 5-5〉 AI 개발·활용의 1단계 추정 결과 : 횡단면 풀링 자료(N=64,492)

종속변수: AI 개발·활용 여부	모형 2: IV(2SLS)	모형 3: IV+EP
ln(실질 유형자산/종업원)	0.001 (2.43)**	0.020 (6.68)***
수출기업 여부	0.005 (2.20)**	0.095 (7.91)***
외국기업 여부	-0.006 (-2.10)**	0.001 (0.05)
대기업 집단 여부	0.019 (2.83)***	-0.075 (-5.76)***
1인당 특허량	0.010 (1.71)*	-0.057 (-2.57)**
(임시·일용직/상용직)	-0.002 (-3.72)***	0.015 (1.37)
외주 여부	-0.002 (-0.93)	-0.021 (-2.19)**
전략적 제휴 여부	0.051 (8.84)***	-0.095 (-9.49)***
성과급/연봉제 도입 여부	-0.003 (-2.07)**	-0.055 (-2.68)***
AI 연관 기술 인프라 보유 여부	0.197 (26.97)***	0.512 (47.23)***
기업규모 가중 산업 내 AI 개발·활용도	0.014 (1.01)	0.270 (3.40)***
단순 산업 내 AI 개발· 활용도	0.815 (8.79)***	0.808 (2.82)***
기업규모 더미	○	○
산업 더미	○	○
연도 더미	○	○
광역시도 더미	○	○
상수	-0.026 (-3.10)***	-0.019 (-0.52)
R2	0.216	0.455

주: 1) 1만 6,172개 기업별 클러스터 표준오차를 적용한 것임.

2) *, **, ***는 각각 10%, 5%, 1% 수준에서 통계적으로 유의함을 나타내고, 괄호 안의 수치는 t값이며, EP는 Entropy Balancing의 약자임.

자료: 통계청, 「기업활동조사」.

IV 추정에서 1단계 분석 결과는 〈표 5-5〉에 나와 있다. 전반적으로 세 가지 도구변수는 모형 2와 모형 3에서 AI 개발·활용과 강한 상관관계가 있으며, 예상한 정(+)의 부호를 보여준다. 하지만 기업규모 가중 산업 내 AI 개발

· 활용도 도구변수는 5% 수준에서 모형 3에서는 유의하지만, 모형 2에서는 그렇지 않다.

여기서 추정한 AI의 생산성 효과를 국내외 선행연구와 직접 비교하는 것은 무리다. 왜냐하면, 상이한 산업과 기간을 대상으로 분석하고, 무엇보다 AI 활용에 대한 측정 단위가 상이하기 때문이다. 그런데, 송단비 외(2021: 83)는 2017~2019년 「기업활동조사」 자료를 풀링하여 제조업에 대한 AI 개발 · 활용의 생산성 효과를 추정했는데, 복수 사업체 보유 기업의 AI의 생산성 효과가 약 15%에 이른다고 보고한 바가 있다.

그런데 그들의 추정 결과는 이 분석의 추정치와 어느 정도 비교가 가능할 듯하다. 무엇보다 동일한 「기업활동조사」 자료를 이용하고 거의 유사한 도구변수를 써서 회귀분석을 했기 때문이다. 하지만 분석 시기와 산업이 상이하고 공변량이 상이하므로 전적으로 두 추정치를 직접 비교하기에는 무리가 따른다. 그들의 추정치 약 15%는 EP를 적용하지 않은 모형 2의 추정치인 약 12.7%와 비교하면 약간 높은 수준이다. 하지만 후자 추정치는 전체 기업을 대상으로 한 것이므로, 앞서 기술통계량에서 보면 대기업의 AI 개발 · 활용 비율이 높은 데다 대기업이 많은 제조업을 고려하면 거의 비슷한 수준의 AI의 생산성 효과가 나온 것으로 볼 수도 있다.

통제변수의 회귀계수를 대략 살펴보면 예상되는 결과가 나오고 있다. 기업 생산함수에서 기본 투입요소인 자본-노동 비율은 세 모형에서 생산성과 정(+)의 관계가 있다. 따라서 1인당 실질 유형자산액이 많으면 노동생산성은 높아진다. 이러한 노동생산성 확대도 가능하지만, 전술한 바와 같이, AI와 같은 무형자산도 노동생산성 향상에 기여할 수 있다. 물론 기업의 AI 투자가 초기 단계이므로 자본스톡이거보다는 투자로 보는 것이 더 적절할 것이다(Czarnitzki et al., 2023: 193).

기본 투입요소 이외의 통제변수 회귀계수를 보면, 세 모형 모두에서 수출 활동을 영위하는 기업이고, 해외 지분율이 50% 이상인 외국기업이며, 대기업 집단에 소속된 기업일수록 노동생산성이 높은 것으로 나타난다. 수출 활동을 통해 기업은 신기술을 도입하고 강한 경쟁 압력으로 비효율성을 제거함으로써 생산성을 높인다고 볼 수 있다. 해외 지분이 높은 외국기업은 해외 신기술 도입이 유리하고 다국적 기업 본사의 역외 경영 조직에 대한 모

니터링이 강해 생산성이 높아질 수 있다. 또한, 대기업 집단 소속 기업은 그룹화 경제의 이점, 즉 기존 축적된 자산과 인력의 공동 이용, 풍부한 자금과 재빠른 의사결정을 통한 자원 배분 등을 통해 생산성 제고 효과를 누릴 수 있다(표 5-4 참조).

상용직 대비 임시·일용직 비율로 대리되는 고용형태 변수도 세 모형 모두에서 노동생산성과 음(-)의 상관관계를 보여준다. 이는 상용직 고용의 안정성이 기업 내부에서 숙련 축적을 가능케 하고, 이는 다시 기업의 생산성 향상에 기여할 수 있다는 것을 시사한다. 성과급이나 연봉제 도입 여부와 같은 성과보상 인센티브는 세 모형 모두에서 노동생산성과 정(+)의 관계가 있다. 이는 연공급과 같은 지연된 보상체계보다는 성과 또는 직무 기반 보상체계가 기업의 단기적 생산성 제고에 기여할 수 있다는 것을 시사한다.

외주 여부와 전략적 제휴 여부 변수는 모형 3에서만 통계적으로 유의하고, 모형 1과 모형 2에서는 그렇지 않다. 또한, 1인당 특허 변수는 예상과는 달리 세 모형 모두에서 통계적으로 유의하지 않다.

나. 패널자료

앞서 횡단면 풀링 자료에 기반하여 종속변수로 로그 노동생산성 수준 변수를 이용하여 AI 개발·활용의 생산성 효과를 추정한 바가 있다. 이러한 횡단면 풀링 자료는 OLS 모형을 이용해 표준오차를 추정할 때 문제가 발생할 수 있다. 이는 무엇보다 추가되는 각 연도의 자료가 이전 연도와 독립적이지 않기 때문이다. 이 경우 연도 더미를 활용하여 이를 통제하고, 클러스터 표준오차의 적용을 통해 이러한 동일한 단위의 오차항 간 상관관계와 시간에 따른 이분산성 문제를 해결할 수 있다. 하지만 횡단면 풀링 자료에서는 모든 관측치에 대해 $\lambda_i = \lambda_0$ 라는 가정을 유지한다. 이러한 가정 대신에 식 (5-3)의 λ_i 를 유지하기 위해서는 횡단면 자료 대신에 패널자료를 이용해 이러한 이질성을 통제할 필요가 있다.

〈표 5-6〉과 〈표 5-7〉은 AI 개발·활용 더미를 주요 관심 변수로 설정한 전체 기업의 생산함수를 패널 OLS와 IV로 추정한 회귀분석 결과를 보여준다. 앞서 언급한 바와 같이, 2017~2022년 주업종을 변경하지 않은 기업을 대상

으로 한 균형 패널이다.

두 표에서 기본적인 OLS 고정효과와 임의효과 모형에 관한 추정 결과가 각각 모형 4와 모형 5다. AI 개발 · 활용 변수와 노동생산성 간 잠재적인 내생성 문제를 해결하기 위해 IV 고정효과와 임의효과에 관한 추정 결과가 각각 모형 6과 모형 7이다. 앞의 횡단면 풀링 자료 분석에서는 AI 연관 기술 인프라 보유 여부, 기업규모 가중 산업 내 AI 개발 · 활용도, 단순 산업 내 AI 개발 · 활용도 등 세 가지 도구변수가 이용되었는데, 기업규모 가중 산업 내 AI 개발 · 활용도 변수가 모형 2의 1단계 도수변수 추정에서 통계적으로 유의하지 않았다. 이를 고려하여 이 변수를 제외하여 패널 모형 추정에서는 두 개의 도구변수가 활용된다. 또한, 모형 8은 고정효과와 임의효과를 혼합한 HTE 추정치를 보여준다. 또한, EP를 적용한 모형 9~11은 이를 적용하지 않은 모형 6~8과 비교해 처리집단과 대조집단 간 공변량의 구조적 차이에 따른 AI 개발 · 활용의 생산성 효과에 관한 회귀계수 값의 변화를 보여준다.

OLS와 IV 임의 효과로 추정한 모형 5와 7, 그리고 HTE로 추정한 모형 8에서 AI 개발 · 활용의 정(+)의 생산성 효과가 10% 수준에서 통계적으로 유의하다. 따라서 AI 개발 · 활용이 노동생산성에 미치는 정(+)의 효과가 임의 효과를 어떻게든 고려하는 세 모형에서 유지되고 있다. 반면에, 고정효과 모형에서는 OLS와 IV 추정 모두 10% 수준에서 AI 개발 · 활용 변수가 통계적으로 유의하지 않다. 고정효과 모형에서는 산업 더미와 같은 시간 불변 설명변수가 추정에서 제외된다. 그런데 임의효과와 HTE 모형에서는 산업 더미 효과가 고려될 수 있는데, 산업에 따른 기업 간 차이 또는 이질성이 AI 개발 · 활용의 생산성 효과에 큰 영향을 미치는 것으로 볼 수가 있다.

10% 수준에서 AI 개발 · 활용 더미변수가 통계적으로 유의한 모형 5, 7, 8에서 그 변수의 한계 효과는 각각 2.7%, 13.4%, 4.1%이다. IV 임의 효과로 추정한 모형 7의 13.4%는 앞서 풀링 자료를 이용한 IV 추정한 모형 2의 12.7%보다 다소 높지만, 거의 유사한 수준이다.

IV 추정에 대한 검정 결과를 보면, 약 도구변수 우려에 대한 1단계 F 검정 결과는 귀무가설을 기각하고, F값도 10보다 크다(Staiger and Stock, 1997). 또한, 도구변수 적절성에 대한 과대식별 Hansen J 검정도 귀무가설을 기각

하지 않아 두 개의 도구변수 선정은 적절한 것으로 볼 수 있다(표 5-6, 표 5-7 참조).

〈표 5-6〉 AI 개발 · 활용의 생산성 효과(1) : 패널자료(N=44,157)

종속변수 : ln (1인당 실질 부가가치)	모형 4 : 고정 OLS	모형 5 : 임의 OLS	모형 6 : 고정 IV	모형 7 : 임의 IV
AI 개발 · 활용 여부	0.014 (0.87)	0.027 (1.74)*	0.051 (0.73)	0.134 (2.14)**
ln(실질 유형자산/종업원)	0.122 (15.97)***	0.130 (27.45)***	0.094 (14.09)***	0.126 (28.05)***
수출기업 여부	0.008 (1.10)	0.026 (3.63)***	0.011 (1.50)	0.033 (4.54)***
외국기업 여부	0.012 (1.14)	0.092 (9.57)***	0.012 (1.20)	0.098 (10.21)***
대기업 집단 여부	-0.014 (-0.42)	0.153 (6.31)***	0.001 (0.01)	0.202 (7.97)***
1인당 특허량	0.123 (1.50)	0.066 (2.07)**	0.065 (1.51)	0.051 (2.06)**
(임시 · 일용직/상용직)	-0.087 (-4.89)***	-0.067 (-3.75)***	-0.060 (-4.72)***	-0.059 (-3.58)***
외주 여부	0.001 (0.17)	0.007 (0.95)	0.003 (0.43)	0.010 (1.41)
전략적 제휴 여부	-0.002 (-0.16)	0.006 (0.64)	-0.002 (-0.15)	0.006 (0.62)
성과급/연봉제 도입 여부	0.020 (1.85)*	0.055 (5.61)***	0.024 (2.18)**	0.063 (6.52)***
기업규모 더미	○	○	○	○
산업 더미	×	○	×	○
연도 더미	○	○	○	○
광역 시도 더미	○	○	○	○
상수	4.000 (109.29)***	3.335 (23.38)***	4.337 (122.48)***	3.423 (23.27)***
R2	0.111	0.369	0.026	0.354
Weak Instrument Test	-	-	150.826***	189.247***
Overidentification Test	-	-	0.460	0.257

주 : 1) 8,630개 기업별 클러스터 표준오차를 적용한 것임.

2) *, **, ***는 각각 유의수준이 10%, 5%, 1% 수준에서 통계적으로 유의함을 나타내고, 괄호 안의 수치는 z값임.

자료 : 통계청, 「기업활동조사」.

〈표 5-7〉 AI 개발 · 활용의 생산성 효과(2) : 패널자료(N=44,157)

종속변수 : ln(1인당 실질 부가가치)	모형 8 : HTE	모형 9 : 고정 IV+EP	모형 10 : 임의 IV+EP	모형 11 : HTE+EP
AI 개발 · 활용 여부	0.041 (2.59)**	0.048 (0.97)	0.042 (2.69)**	0.028 (1.70)*
ln(실질 유형자산/종업원)	0.102 (15.27)***	0.110 (6.33)***	0.125 (27.30)***	0.135 (6.97)***
수출기업 여부	0.033 (4.51)***	0.018 (1.31)	0.031 (4.31)***	0.044 (3.11)***
외국기업 여부	0.072 (7.64)***	0.001 (0.03)	0.089 (9.36)***	0.035 (2.01)**
대기업 집단 여부	0.224 (7.84)***	-0.032 (-0.76)	0.193 (7.52)***	0.176 (4.03)***
1인당 특허량	0.077 (1.53)	0.026 (3.16)***	0.055 (2.01)**	0.026 (3.20)***
(임시 · 일용직/상용직)	-0.067 (-4.73)***	-0.053 (-3.33)***	-0.060 (-3.67)***	-0.064 (-3.42)***
외주 여부	0.007 (1.02)	0.001 (0.07)	0.010 (1.48)	0.007 (0.50)
전략적 제휴 여부	0.014 (1.45)	0.017 (1.10)	0.010 (1.04)	0.035 (2.46)**
성과급/연봉제 도입 여부	0.035 (3.30)***	0.038 (1.20)	0.060 (6.16)***	0.052 (1.66)*
기업규모 더미	○	○	○	○
산업 더미	○	×	○	○
연도 더미	○	○	○	○
광역 시도 더미	○	○	○	○
상수	-3.114 (-0.97)	-	3.440 (23.62)***	-1.979 (-0.47)
R2	-	0.114	-	-
Weak Instrument Test	-	165.600***	-	-
Overidentification Test	-	1.187	-	-

주 : 1) 8,630개 기업별 클러스터 표준오차를 적용한 것임.

2) *, **, ***는 각각 유의수준이 10%, 5%, 1% 수준에서 통계적으로 유의함을 나타내고, 괄호 안의 수치는 z값이고, EP는 Entropy Balancing의 약자임.
자료 : 통계청, 「기업활동조사」.

모형 7에서 보는 바와 같이, IV 회귀분석에서 추정된 AI 개발·활용 변수의 회귀계수는 그 변수에 대한 OLS와 HTE의 추정 결과와 비교해 높은 수준을 보여주고 있다. 이러한 결과는 부분적으로 IV 회귀분석이 통제할 수 없는 공변량의 이질성에 기인한 것으로 볼 수 있다. 모형 9~11은 EP를 적용하여 얻은 가중치를 활용하여 IV 회귀분석을 수행한 분석 결과를 보여준다. 전술한 바와 같이, 이는 AI 개발·활용 기업과 그렇지 않은 기업 간에 기업의 생산요소 투입과 기타 기업특성이 유사하도록 공변량 분포를 보정함으로써 가중 IV 회귀분석을 수행한 것이다.

EP를 적용해 각각 IV 임의효과와 HTE 모형으로 추정한 모형 10과 모형 11에서도, 동일한 추정 방식으로 한 모형 7과 모형 8의 분석 결과처럼, AI 활용·개발 변수는 여전히 정(+)이고 10% 수준에서 통계적으로 유의미한 회귀계수라는 추정 결과를 확인시켜 준다. 그러나 모형 7과 8에서 그 한계 효과가 각각 약 13.4%와 4.1%였으나 모형 10과 11에서는 각각 4.2%와 2.8%로 줄어든다. 이는 가령, 자본-노동 비율, 기업규모, 대기업 집단 여부, 1인당 특허량, 상용직 대비 임시직 비율 등과 같은 공변량의 구조적 차이가 AI를 개발·활용하는 기업인 처리집단과 그렇지 않은 대조집단 사이에 있다는 것을 시사한다.

이러한 추정 결과를 다른 국내외 연구와 직접 비교할 수는 없지만, 특허를 이용한 해외 연구와 간접 비교하면, 약 2.8~4.2%로 추정되는 정(+)의 생산성 효과는 그렇게 높지도 낮지도 않다. 예를 들면, 2000~2016년 사이에 AI 분야와 관련된 특허를 한 건 이상 출원한 전 세계 5,257개 기업 표본을 이용하여 분석한 Damoli et al.(2021)에 따르면, AI 특허출원이 근로자 1인당 매출액으로 측정한 노동생산성에 정(+)의 유의한 영향을 미치는 것으로 나타났다. 그들은 이러한 효과가 무시할 수 없는 수준, 즉 기업이 AI 분야에서 혁신 노력을 강화하여 AI 특허출원 건수를 두 배로 늘리면 노동생산성이 약 3% 증가한다고 제시한다. 또한, Alderucci et al.(2020)은 1997~2016년까지 미국에서 AI 관련 첫 발명을 한 기업의 근로자 1인당 매출액이 AI 특허를 출원하지 않은 유사 기업의 대조 집단과 비교해 평균 4.2% 정도 증가했다고 보고한다. 이러한 분석 결과를 참조하면 약 3~4% 정도 AI의 생산성 효과가 추정되고 있다. 따라서 이 분석에서 추정한 약 2.8~4.2%라는 AI의 생산성

효과는 직접 비교는 힘들지만, 해외 연구의 추정치와 비교해 그렇게 큰 차이가 없는 것으로 보인다.

정소라 · 성낙일(2024)이 제기한 것처럼, 종속변수를 노동생산성이라는 수준변수가 아니라 노동생산성 변화율로 하면 이러한 AI의 생산성 변동 효과는 어떻게 되는가? 이에 관한 추정 결과는 <부표 1>과 <부표 2>에 제시되어 있다. <부표 1>에서 모형 12~16은 산업, 지역, 연도 더미를 제외하고 종속과 설명 변수들을 차분 OLS와 IV 모형으로 추정한 것이다. IV 추정의 경우 도구변수는 AI 연관 기술 인프라 보유 여부와 단순 산업 내 AI 개발 · 활용도 변수가 이용되었다. 반면에 <부표 2>의 모형 17~21은 정소라 · 성낙일(2024)처럼 종속변수는 노동생산성 변동률이고, 설명변수는 수준변수이거나 더미변수이고, 추정 방법은 앞서와 같다.

<부표 1>과 <부표 2>의 추정 결과는 통계적으로 유의한 정(+)의 AI 개발 · 활용의 생산성 변동 효과를 보여주지 않는다. 어느 모형에서는 그 부호가 부(-)이기도 하고, 다른 모형에서는 정(+)인 부호가 있기는 하지만, 그렇다 하더라도 통계적으로 유의하지 않다. 이러한 결과는 정소라 · 성낙일(2024: 60)에서 제시된 바 있다. 그들에 따르면 <부표 2>와 같이 추가로 추정한 결과 AI의 노동생산성 변동 효과의 통계적 유의성이 없었다는 것이다.

제4절 소 결

이 글은 2017~2022년 통계청의 인가용 「기업활동조사」 자료에서 횡단면 풀링 자료와 균형 패널자료를 구축하여 전체 기업을 대상으로 AI의 생산성 효과를 추정하였다. 기존 연구에서 이러한 효과를 추정하기 위해 특허 자료나 구인공고 자료를 이용했던 데 반해, 여기서는 설문조사 문항을 이용함으로써 간접 방식이 아니라 직접 방식으로 AI의 생산성 효과를 추정하였다. AI 변수와 노동생산성 간 역인과와 누락 변수 편의로 인한 내생성 문제를 해결하기 위해 IV 추정이 이루어졌다. 또한, 비관측 이질성으로 인한 편의 가능성을 해결하기 위해 AI 활용 기업과 AI 비활용 기업 간 공변량 분포를 같게

하는 EP를 적용하였다. 이러한 분석으로부터 다음과 같은 몇 가지 분석 결과들이 도출되었다.

첫째, 횡단면 풀링 자료를 이용한 AI의 생산성 효과 분석은 IV 추정과 EP를 적용한 IV 회귀분석에서 10% 수준에서 통계적으로 유의한 정(+)의 AI의 생산성 효과가 관측되었다.

둘째, 2017~2022년 주업종을 변경하지 않은 전체 기업을 대상으로 균형 패널을 구축하여 AI의 생산성 효과를 추정한 결과, 임의효과 IV와 HTE 모형에서 10% 수준에서 통계적으로 유의한 정(+)의 AI의 생산성 효과가 관측되었다. 임의효과 IV와 HTE 모형에서는 고정효과 모형과 달리 산업 더미와 같이 시간 불변 변수 추정이 가능하다. 이러한 점에서 산업에 따른 기업 간 차이나 이질성이 AI의 생산성 효과에 크게 영향을 미쳤다고 볼 수가 있을 것이다.

셋째, 패널 모형에서 AI의 정(+)의 생산성 효과는 IV와 HTE 추정 모형에서 확인되지만, 이는 수준변수인 로그 1인당 실질 부가가치, 즉 노동생산성을 종속변수로 추정한 결과다. 하지만, 종속변수를 노동생산성 변화율로 하면, 이러한 AI의 노동생산성 변동 효과는 통계적으로 유의하게 확인되지 않는다. 이처럼 연도별 자료를 이용하면 노동생산성 변화율이 연도별로 심하게 변동할 수 있으므로 안정적인 통계 추정이 쉽지 않을 수가 있다. 이러한 요인이 이러한 추정 결과에 하나의 요인으로 작용했을 것으로 보인다. 따라서 수준과 변화율 변수 모두를 고려할 경우 AI의 노동생산성 효과는 일부 모형에서만 관측되었다.

AI는 초기 확산 단계에 있으므로 산업별로 기업별로 다양하게 이용되고 있지만, 상당한 편차가 있는 것으로 보인다. 이 분석의 추정 결과가 보여주는 바는 산업에 따른 기업 간 이질성이 AI의 생산성 효과에 크게 영향을 미치고 있다는 것이다. 주지하는 바와 같이, AI 기술은 범용 기술로 인식되어 다양한 분야에 적용되고 새로운 생산 방식을 열어 놓을 수가 있다. 그러한 점에서 AI 기술이 다양한 산업의 기업에 널리 확산·이용될 수 있도록 장려하는, 경제 전반의 생산성 제고를 도모하는 산업정책이나 인력정책이 필요할 것으로 보인다.

하지만, Acemoglu(2024)가 지적하고 있듯이, AI와 같은 신기술은 근로자

와 같이 갈 때 더 나은 업무 수행과 정교한 작업이 가능하고, 훨씬 더 생산성이 높아질 수 있다. 예를 들면, 포디즘의 대량생산체계에서 자동화가 인간을 완전히 대체한 것이 아니라, 수리와 유지 보수와 같은 다양한 업무가 창출되었으며, 이를 위해 근로자는 교육을 받았다. 마찬가지로 AI 시대에도 근로자가 새로운 업무를 수행할 수 있도록 체계적인 교육이 필요하다는 것이 Acemoglu(2024)의 주장이다.

이를 고려한다면 생산성 자체 제고에 매몰되는 산업정책이나 인력정책이 아니라, 다양한 업무를 수행할 수 있도록 기존 인력의 교육 · 훈련을 수반하는, 따라서 기업을 위해 AI의 과잉 신규 인력만을 배출하는 그러한 정책은 삼가야 할 것으로 보인다.

〈부표 5-1〉 AI 개발·활용의 생산성 변동 효과(1)(N=31,416)

종속변수 : △ln(1인당 실질 부가가치)	모형 12 : 고정 OLS	모형 13 : 임의 OLS	모형 14 : 고정 IV	모형 15 : 임의 IV	모형 16 : HTE
△ AI 개발·활용 여부	0.008 (0.53)	0.011 (0.75)	-0.037 (-0.53)	0.009 (0.81)	0.009 (0.57)
△ ln(실질 유형자산/중 업원)	0.133 (13.62)***	0.121 (14.70)***	0.133 (13.61)***	0.156 (13.06)***	0.133 (13.62)***
△ 수출기업 여부	0.020 (2.60)***	0.013 (1.88)*	0.020 (2.60)***	0.023 (2.71)***	0.020 (2.79)***
△ 외국기업 여부	0.013 (1.14)	0.012 (1.20)	0.013 (1.15)	0.024 (1.07)	0.012 (1.27)
△ 대기업 집단 여부	-0.036 (-1.01)	-0.017 (-0.54)	-0.037 (-1.03)	-0.010 (-0.28)	-0.021 (-0.65)
△ (1인당 특허량)	0.524 (4.00)***	0.262 (1.86)*	0.524 (4.00)***	0.262 (1.91)*	0.523 (3.99)***
△ (임시·일용직/상용직)	-0.064 (-5.58)***	-0.060 (-5.24)***	-0.064 (-5.58)***	-0.063 (-4.33)***	-0.064 (-5.57)***
△ 외주 여부	0.004 (0.51)	0.003 (0.43)	0.004 (0.56)	0.004 (0.43)	0.004 (0.47)
△ 전략적 제휴 여부	-0.001 (-0.08)	0.004 (0.40)	0.001 (0.10)	-0.002 (-0.16)	0.004 (0.39)
△ 성과급/연봉제 도입 여부	0.015 (1.19)	0.013 (1.17)	0.016 (1.21)	0.021 (1.48)	0.017 (1.28)
△ 기업규모 더미	○	○	○	○	○
산업 더미	×	○	×	○	○
연도 더미	○	○	○	○	○
광역시도 더미	○	○	○	○	○
상수	0.052 (3.32)***	0.051 (9.07)***	0.051 (3.30)***	0.011 (0.53)	0.015 (0.25)
R2	0.110	0.139	0.154	-	-
Weak Instrument Test	-	-	102.673** *	-	-
Overidentification Test	-	-	3.910**	-	-

주 : 1) 8,593개 기업별 클러스터 표준오차를 적용한 것임.

2) *, **, ***는 각각 유의수준이 10%, 5%, 1% 수준에서 통계적으로 유의함을 나타내고, 괄호 안의 수치는 z값임.

자료 : 통계청, 「기업활동조사」.

〈부표 5-2〉 AI 개발 · 활용의 생산성 변동 효과(2)(N=37,353)

종속변수 : $\Delta \ln$ (1인당 실질 부가가치)	모형 17 : 고정 OLS	모형 18 : 임의 OLS	모형 19 : 고정 IV	모형 20 : 임의 IV	모형 21 : HTE
AI 개발 · 활용 여부	0.021 (1.16)	0.015 (1.40)	0.045 (0.52)	0.042 (1.22)	0.042 (2.33)**
$\ln(\text{실질 유형자산/종업원})$	0.063 (8.43)***	0.009 (6.22)***	0.063 (8.43)***	0.009 (6.15)***	0.077 (10.52)***
수출기업 여부	0.045 (4.65)***	0.032 (5.25)***	0.045 (4.65)***	0.032 (5.19)***	0.064 (7.62)***
외국기업 여부	0.033 (1.24)	0.011 (1.71)*	0.033 (1.24)	0.011 (1.75)*	0.093 (7.68)***
대기업 집단 여부	0.072 (1.89)*	0.003 (0.34)	0.073 (1.90)**	0.002 (0.25)	0.160 (8.31)***
1인당 특허량	0.291 (2.90)***	0.033 (3.57)***	0.291 (2.90)***	0.033 (3.54)***	0.330 (2.83)***
임시 · 일용직/상용직)	-0.043 (-3.21)***	-0.017 (-1.73)*	-0.043 (-3.21)***	-0.017 (-1.73)*	-0.049 (-3.46)***
외주 여부	-0.005 (-0.56)	-0.003 (-0.52)	-0.006 (-0.58)	-0.003 (-0.55)	-0.001 (-0.11)
전략적 제휴 여부	0.004 (0.32)	0.001 (0.14)	0.003 (0.23)	-0.002 (-0.16)	0.031 (2.81)***
성과급/연봉제 도입 여부	-0.008 (-0.66)	0.002 (0.31)	-0.008 (-0.66)	0.002 (0.32)	0.003 (0.21)
기업규모 더미	○	○	○	○	○
산업 더미	×	○	×	○	○
연도 더미	○	○	○	○	○
광역시도 더미	○	○	○	○	○
상수	0.070 (1.71)*	-0.046 (-0.33)	0.070 (1.70)*	-0.044 (-0.32)	-0.287 (-1.53)
R2	0.007	0.019	0.007	0.019	-
Weak Instrument Test	-	-	115.575***	240.212***	-
Overidentification Test	-	-	13.154***	7.890***	-

주 : 1) 8,599개 기업별 클러스터 표준오차를 적용한 것임

2) *, **, ***는 각각 유의수준이 10%, 5%, 1% 수준에서 통계적으로 유의함을 나타내고, 괄호 안의 수치는 z값임.

자료 : 통계청, 「기업활동조사」.

제 6 장

AI 압력과 기업 내부노동시장의 구조변동 : 인공지능과 자동화 노출도로 인한 이중화 경제의 심화 가능성 탐색연구

제1절 들어가며

개발연대 이후 한국의 노동시장은 대기업과 중소기업으로 분절화됨으로써 전형적인 이중노동시장의 특징들을 띠어 왔다. 한국의 대기업들은 장기 고용과 연공임금제를 바탕으로 높은 임금, 높은 고용 경직성, 노동력의 기업 내부 전환과 배치 및 훈련과 같은 전형적인 내부노동시장의 요소들을 발전시켜 왔다. 이로 인해 대기업은 핵심 노동력의 높은 충성심을 끌어냄으로써 기업-특수적 숙련을 발전시킬 수 있었지만, 높은 임금비용으로 인해 비정규직의 증대와 아웃소싱/하청의 증대를 수반할 수밖에 없었다. 또한, 대기업의 핵심 노동력을 기반으로 한 내부노동시장의 발달은 중소기업과의 노동시장 분절과 임금 격차 확대를 동시에 수반하는 것이기도 했다.

본 연구의 주제는 자동화/인공지능의 진전과 확대가 기업 내부노동시장의 다양한 제도적 기제들에 미치는 충격을 분석하는 것이다. 자동화/인공지능의 일반화는 기업특수적 숙련에 대한 수요를 증대시킬 수도, 감소시킬 수도 있다. 우리는 산업이나 직종별로 이러한 수요의 변화를 탐지할 것이다. 수요가 증대되는 산업에서는 내부노동시장이 오히려 강화될 것이고, 수요가 감소하는 산업에서는 내부노동시장의 제도를 허물려는 시도들이 나타날 것이다.

인공지능(Artificial Intelligence)은 경제 성장을 촉진할 것으로 기대받고 있지만, 인간의 노동력을 대체할 수 있다는 우려도 널리 퍼지고 있다. 이러한 질문에 답하기 위해, 직종별로 인공지능에 의한 자동화 노출 크기를 측정하고 그에 따른 노동시장 영향을 살피는 다양한 경험 연구가 진행되어 왔다. 국내에서는 인공지능과 자동화 노출에 따른 직종별 임금, 고용효과에 대한 연구가 진행되었다(전병유 · 정준호 · 장지연, 2022). 그러나 인공지능과 자동화 노출에 따라 기업 수준에서 나타나는 임금, 고용효과에 대한 국내 경험 연구는 아직 미비한 편이며, 따라서 본 연구에서는 기업 수준에서의 AI 노출도를 계산하여 개별 기업들의 내부노동시장 제도들에 미치는 영향을 살피고자 한다.

제2절 이론적 틀

이 연구는 AI/전통적 자동화에 더 많이 노출된 기업들이 전통적인 내부노동시장 제도[예 : 연공서열에 따른 급여, 외부 시장과의 명확한 경계 설정, 많은 승진 계층에 따른 관대한 승진 제도, 승진 계층에 초점을 맞춘 급여 구조(개인화된 성과보다는), 그리고 승진 및 급여 구조와 연계된 내부 경쟁 구조]를 유지하는 데 어려움을 겪는지, 아니면 AI 기반 자동화가 내부노동시장 기제들을 강화하는 방향으로 발전할지 여부를 탐구한다.

AI/자동화가 기업 내 내부노동시장(ILM) 제도의 기능에 어떤 영향을 미치는지 탐구하기 위해서 먼저 내부노동시장의 구성 요소와 작동 메커니즘을 간단히 개괄할 필요가 있다. 기업은 어떤 상황에서, 왜 내부노동시장을 발달시키는가?

1. 내부노동시장의 구성 요소

기업의 내부노동시장(Internal Labor Markets : ILM)은 외부 시장의 수요와 공급이 기업의 기술 형성에 대한 필요에 덜 중요해지는 특정 조건하에서

나타나고 운영된다(Doeringer and Piore, 1971). 내부노동시장의 직원들은 “폐쇄된 고용구조에서 동기부여를 받는다”(Rosenfeld, 1992: 46). 기업의 성장 전략이 특정 기술 제공에 초점을 맞출 때(Becker, 1964), 기업은 장기적인 관점에서 직원들을 재교육할 동기가 더 커지는데, 이는 경쟁자들을 압도할 수 있는 기업 고유의 기술을 개발하는 데 상당한 시간이 걸리기 때문이다. 이러한 기업에서는 자원을 주로 사내 교육에 할당하는 경향이 있다. 일단 인적자원에 투자한 후에는 숙련된 직원들이 다른 경쟁 회사로 이직하는 것을 방지하려고 한다. 따라서 기업들은 이직을 막기 위한 기업 차원의 제도를 의도적으로 마련한다(Williamson, 1985).

내부노동시장은 기업 내에서 다음의 네 가지 제도적 장치로 구성된다. (1) 직원들이 하위 직급에서 시작하여 명확히 규정된 경력 사다리를 따라 인생 전반에 걸쳐 이동하도록 장려하는 이동구조 또는 직무사다리(Rosenbaum, 1984; Pfeffer and Cohen, 1984), (2) 장기적으로 기업 내에서 머물고자 하는 사람들에게 더 큰 인센티브를 제공하는 급여구조, 여기에는 종종 연공서열과 성과의 조합이 주요 평가 요소가 된다(Osterman, 1984), (3) 특정 기술에 대한 장기적인 투자를 보호하는 강력한 고용 보장(Hall and Soskice, 2001; Milgrom and Roberts, 1992), (4) 팀 내 및 팀 간의 잘 설계된 기술 교육/개발 시스템(Lazear, 1998). 궁극적으로 기업 차원의 내부노동시장(FILM)은 이러한 제도들이 고용주와 직원들이 기업 고유의 기술에 공동 투자하도록 돕고, 결국 “지식이나 기술의 점진적 발전”을 달성할 수 있게 해준다고 가정한다(Althauser and Kalleberg, 1981: 130).

2. 내부노동시장의 직업과 임금 수준

기업 내 경력사다리는 왜 존재하는가? 직업사다리와 직업 특성에 주로 초점을 맞춘 직업과 직업사회학자들(Rosenbaum, 1984; Althauser and Kalleberg, 1981)과는 달리, 많은 경제학자들은 내부노동시장(ILM)과 임금 간의 연계를 강조한다. 다시 말해, 직업과 임금의 매칭은 기업 내에서 효율적인 인센티브 메커니즘의 결과물이다. “계급에 기반한 임금은 인센티브 보상 체계와 동일한 효율적인 자원 배분을 유도한다.”(Lazear and Rosen, 1981: 841) 반복적

인 경쟁은 결국 기업 내에서 공유되는 공통 요인에서 비롯된 소득 변동을 제거할 것이다. 이러한 관점은 기업 내 고위 경영진이 왜 그렇게 높은 급여를 받는지를 설명한다. 기업은 단순히 높은 위치에 도달하기 위해 충분한 노력을 기울인 개인들에게 보상을 제공한다. 또한, 토너먼트의 후반 라운드에서 승리하는 것, 즉 더 높은 계급의 위치를 차지하는 것은 토너먼트의 초기 낮은 라운드에서 승리하는 것보다 더 큰 임금 인상을 부여한다(Rosen, 1986). 이 토너먼트 이론은 한국과 일본의 일부 대형 동아시아 기업에서 연공서열 제도의 존재로 가장 잘 설명된다.

그러나 초기의 위계구조(토너먼트) 설정에서의 승진과 불평등한 임금 보상 간의 연계를 연구한 이전 연구들과는 달리, 후속 연구들은 이러한 연계가 경험적 연구에서 기대만큼 현저하지 않음을 발견했다. 임금 격차는 토너먼트 이론의 메커니즘을 의문시할 만큼 충분히 크며, 심지어 인과관계도 복잡하다. 승진 전의 임금 상승률($t-1$)이 승진(t)을 결정하기 때문이며, 그 반대는 아니다(Baker and Holstrom, 1995). 오히려 현실은 어느 정도 능력을 가진 사람들이 높은 생산성 덕분에 높은 급여를 받고, 따라서 높은 생산성의 결과로 높은 위치를 차지한다는 것이다. 여기서 타고난 능력은 노동자의 고정된 속성이며, 대부분의 중요한 학습은 경력 초기 단계에서 발생하는 경향이 있다(Gibbons and Waldman, 2006). 동일 계층 내에서의 임금의 큰 변동 역시 이러한 시나리오를 지지한다(Baker and Holstrom, 1995).

Waldman(1984), Bernhardt(1995), Zaboynik and Bernhardt(2001)는 승진을 신호(signaling)로 간주하는데 이 시나리오에 기반하여 이론적 확장을 시도한다. 전통적인 토너먼트 이론이 승진을 노동자들의 노력을 유도하기 위한 인센티브 메커니즘(예: 상금)으로 보는 반면, 이 학자들은 승진을 외부 고용주들의 포획 시도를 막기 위해 필요한 과감한 임금 인상과 함께 내생적으로 발생하는 상금으로 본다. Bernhardt(1995)는 교육(학력)을 임금 변동을 창출하는 힘으로 보았지만, 고용주들이 노동자의 생산성을 직접 관찰하는 것(비대칭 학습)은 다른 고용주들이 존재하는 노동시장에서 승진(신호)과 임금 인상을 추진하는 더 명확한 동기라고 보았다. 경험적 연구는 실제로 이러한 시나리오(신호로서의 승진)를 승진과 임금 인상을 설명하는 가장 중요한 메커니즘 중 하나로 지지한다(DeVaro and Waldman, 2006).

균형계약이론(Harris and Holstrom, 1982)은 강력한 고용보장을 가진 전형적인 대기업에서 하향 임금 경직성이 존재하는 이유를 부분적으로 설명한다(Babecky et al., 2009). 하향 임금 경직성은 일정 정도 계약의 보험 역할을 한다. 노동자가 고용주에게 지불해야 하는 보험료(결과적으로 임금을 낮추는)는 나이가 들수록 감소하는데, 이는 고용주들이 더 적은 근무기간을 가진 고령 노동자들에게 임금 하한을 제공하는 비용에 대해 덜 걱정하게 되고, 고용주들의 정보가 더 정확해지기 때문이다(Harris and Holstrom, 1982: 330). 이 이론은 생산성이 나이에 따라 증가하지 않더라도 임금이 나이와 경험에 따라 오르는 초기 연구 결과를 설명하는 논리를 제공한다(Medoff and Abraham, 1981).

결국, 상기의 내부노동시장 이론에 대한 논의는 내부노동시장이 동북아시아에만 국한된 것이 아닌, 보편적으로 존재하는 기업의 임금결정이론 중 한 조류임을 알려준다. 하지만, 현실에서 내부노동시장을 가장 극단적인 형태로 발전시킨 기업 사례들은 일본과 한국에서 발견된다.

3. 동아시아(및 독일) 기업에서의 기술 형성

정치경제학자 그룹은 동아시아의 성장 이야기에서 기술 형성 문제를 조사해 왔다. 초기 일본 기업에서 20세기 초반에 프로토타입 기술 형성 과정을 찾을 수 있다. Taira Koji(1970)와 Gordon Andrew(1985)의 연구를 따르면, Thelen은 대기업에서 전통적인 도제식 견습 제도의 재활용을 강조했다. 이 시스템은 전통적인 오야카타-코카타(스승 - 견습생) 관계를 유지하며, 오야카타 장인은 사무라이 관리자로부터 하청업자로 고용되어 재량에 따라 견습생을 훈련시킬 책임이 있었다. 이 과정에서 19세기 말과 20세기 초의 일본 고용주들은 숙련된 장인, 오야카타의 극심한 부족을 겪었고, 따라서 다른 회사로부터 장인을 유인하려고 시도했다. 숙련된 장인이 경쟁 회사로 유출되는 것은 성장하는 기업에 큰 타격이었다. 따라서 장기적으로 기업 내에서 견습생을 훈련시키는 책임이 있는 장인을 유지하기 위해 고용주들은 내부노동시장의 구성 요소인 평생 고용과 연공서열 급여를 도입하기 시작했다. 따라서 일본 내부노동시장의 주요 구성 요소는 경쟁 회사의 장인 유출

시도에 대응하기 위한 고용주의 전략에서 발전했다.

내부노동시장은 일본(및 서유럽의 독일)에서 기업 고유의 기술 형성과도 밀접하게 공진화했다. 일본 고용주들은 직원들이 장기적으로 기업 고유의 기술에 투자하도록 설득하기 위해 고용보장을 보장해야 했다(Hall and Soskice, 2001). 이러한 보장이 없었다면, 노동자들은 현재 고용주로부터 해고될 경우 대체 고용주를 찾지 못할 위험을 감수해야 했다. 따라서 일본 고용주들은 직원들과 충성도 및 평생 고용보장을 교환했다. 내부노동시장은 고용주의 평생 고용 서약에서 비롯되었다고도 볼 수 있다.

1960년대 이후 임금과 처우에 관한 제도를 고민하던 대부분의 한국 대기업들 또한 이러한 일본의 내부노동시장과 연공급 관행을 받아들였다. 일본과 마찬가지로 소수의 숙련공들을 다른 기업에 빼앗기지 않고 사내에 묶어두기 위한 목적으로 안정된 고용을 기반으로 내부노동시장 기제들을 발달시켰다. 다만, 내부의 기술형성 전통이 박약했던 한국의 기업들은 내부노동시장과 연공급 체계를 나이에 따라 위계가 형성되는 전통적인 위계사회의 문화적 규준과 임금체계를 일치시킴으로써 조직의 안정성을 확보하기 위해 이러한 제도들을 받아들인 측면 또한 있었다.

내부노동시장과 연공급은 한국 대부분의 기업에서 관행처럼 정착되었지만, 그 발달 정도는 대기업일수록 더 두드러졌다. 대기업일수록 더 많은 내부노동시장 기제들을 발달시켰으며, 대기업일수록 연공급의 기울기는 더 가팔라졌다(정승국, 2021; 노용진 외, 2003; 이철승 외, 2020). 대기업일수록 내부노동시장을 통해 인력을 장기 고용하며 기업특수적 기술을 심화시킬 필요성이 더 컸고, 대기업일수록 숙련 인력의 타사로의 유출을 방지할 유인이 더 컸으며, 대기업일수록 이러한 필요성을 만족시킬 수 있는 지불능력이 더 컸기 때문이다. 결국, 이러한 내부노동시장과 연공급 기제는 대기업 대 중소기업으로 분절화된 한국의 이중노동시장의 주요한 내부 구성요소가 될 수밖에 없었다.

4. 인공지능 기반 자동화 압력과 내부노동시장

이 연구는 인공지능 기반 자동화의 압력이 이러한 내부노동시장 기제에

어떤 영향을 미치는지를 논의한다. AI 및 자동화가 기업 내 내부노동시장(ILM) 제도의 기능에 영향을 미치는가? 특히, AI 및 자동화에 대한 노출이 큰 기업들이 기존 내부노동시장 제도[예: 연공서열에 따른 임금체계, 외부 시장과의 명확한 경계, 다수의 승진 계층을 기반으로 한 승진시스템, 승진 계층에 중점을 둔 임금구조(개별 성과보다는), 승진 및 임금구조와 연계된 내부 경쟁 체계 등]를 유지하는 데 어려움을 겪는가? 아니면, 이들 기업들은 AI 및 그에 기반한 자동화의 압력에 대처하기 위해 기존의 내부노동시장 제도를 더욱 강화하는가?

Doeringer and Piore(1971)의 “기업특수적 기술(firm-specific skills) 형성의 필요성” 가정에 기반할 때, AI/자동화는 기업특수적 기술의 필요성을 증가시키거나 감소시킬 수 있다. 어느 쪽이든, 기업특수적 기술 형성의 필요성이 변화하면 내부노동시장 제도도 그에 따라 변화할 수 있다. 이와 관련, Grimshaw and Rubery(1998)는 기술 특정성과 노동조합의 교섭능력 조합에 따라 내부노동시장 유형을 다음과 같은 네 가지 타입으로 구분하였다.

〈표 6-1〉의 우측 하단 셀에 위치한 ‘안정적 계약’ 모델은 기업특수적 기술의 수요가 높고, 노동의 협상능력이 높은 경우이다. 노조와 회사 측이 상호 교섭에 기반하여 협조적으로 기업특수적 기술을 증진시키는 도요타 모델이 이러한 경우를 대표하며, 기술 축적과 노사 관계 두 측면에서 가장 이상적인 형태의 기술축적 모델이다. 하지만, 기업특수적 기술의 축적 필요는 높는데 전투주의적 노동조합의 힘이 너무 강한 경우, 노동자들은 과도한 기술축적

〈표 6-1〉 기술 특정성과 노동조합의 교섭력에 따른 내부노동시장의 분류체계

Bargaining Power of Labor	Skill Specificity	
	Low	High
Low	Day Labor's labor market	Employer's Opportunism (Samsung, until 2019)
High	Employee's Opportunism (Hyundai)	Mutual Seeking of Stable Contract (Toyota)

자료: Grimshaw and Rubery(1998).

요구를 거부할 수 있다. 이러한 상황에서 고용주는 기업특수적 기술의 축적을 ‘플로어 현장’에서 진행하기를 포기할 수도 있다. 한 예로, 1990년대 초 중반, 다능숙련공 체제에 기반한 도요타의 적기생산시스템(Just-in-Time, 이하 JIT)을 적극 도입하려는 회사 측의 노력에 대해, 현대자동차 노조는 노동자들에게 너무 과도한 부담을 지우는 체제라는 이유로 이를 거부하였다. 결국, 현대자동차는 노동조합의 반대에 밀려, 도요타 생산시스템의 직접적인 도입을 포기하고, 엔지니어 수준에서의 혁신과 현장의 자동화를 결합시킨 모듈 생산 방식을 도입하게 된다(Jo et al., 2023). 이러한 경우, 고용주는 기업특수적 기술 축적을 포기하고, 노동조합은 이 기회를 이용해 기술축적을 위한 투자는 거부하면서 임금상승은 계속해서 추구할 수 있게 된다. 도표의 좌측 하단 모델이 이러한 케이스이다. 이에 비해, 노조가 존재하지 않았던 삼성전자는 도요타의 적기생산시스템 및 품질관리시스템을 받아들여 사내 기술축적 역량을 극적으로 향상시킬 수 있었다. 우측 상단이 이에 해당하는데, 노동조합은 협상력이 낮고, 고용주는 전일적으로 자신들이 추구하는 기업특수적 기술을 추구하는 경우이다. 마지막으로, 일용 노동시장과 같이 극단적으로 고용주기가 짧은 노동시장에서는 노조가 만들어져 회사 측과 교섭을 벌일 유인도 없고, 회사 측의 기술축적에 대한 필요성도 없다. 이 경우, 내부노동시장은 전혀 발달할 필요가 없고, 고용주는 최단기 비숙련 노동자를 외부 파견업체를 통해 조달하며, 노동자들은 파견 업자들에 의해 관리되고 비조직화된 상태로 머물며 단기 계약을 전전하게 된다.

현대 모델이 한국 대기업의 노동시장을 대표하는 전형적인 모델이라고 가정한다면, 한국의 내부노동시장은 기술 형성을 수반하지 않는, 상위 계층과 임금을 향한 경쟁만이 존재하는 “노동의 무임승차 모델”에 가깝다고 할 수 있다. 다시 말해, 이는 기술 형성이 없는 내부노동시장이자, 강성 노조가 주도하는 내부노동시장이라고 할 수 있다(정승국, 2021).

AI의 노동시장 영향을 이론화 하는 대표적인 두 가설, 숙련편향 기술변동(Skill-Biased Technological Change) 가설과 루틴편향 기술변동(Routine-Biased Technological Change) 가설을 앞서 논의한 내부노동시장 유형에 적용시켜 보자. 먼저, 숙련편향 기술변동 가설은 숙련 노동에 대한 수요 곡선이 공급 곡선보다 더 빠르게 우측으로 이동하기 때문에, 기술 혁신은 주

로 고숙련 노동자의 임금을 인상시킨다(Goldin and Katz, 2010; Autor et al., 2020)고 가정한다. 이 경우, AI는 고숙련 노동자의 숙련과 임금을 동시에 상승시키는 역할을 하며, 고숙련 노동자와 나머지 노동자들 사이의 불평등을 강화시킨다. 반면, 루틴편향 기술변동 가설의 경우, 기술 혁신은 주로 반복적인 업무를 자동화하는 동시에 비반복적인 업무를 보완한다고 가정한다. 그 결과, 주로 반복적인 업무를 포함하는 중간층 일자리가 감소함에 따라 직업 양극화가 발생할 수 있다(Autor et al., 2003; Acemoglu and Autor, 2011; Goos et al., 2014).

ICT 기술의 변화는 RBTC 가설의 예측을 그대로 따르는 것은 아니다. 컴퓨터 기반 자동화는 주로 일자리 감소를 초래하는 대신, 생산성 향상과 새로운 일자리 창출로 이어졌다(Autor and Dorn, 2013; Arutz et al., 2016). AI 발전에 대한 비판적인 전망도 반드시 현실이 될 필요는 없다. 2018년 기준으로, 전체 일자리의 60%는 1940년 이후 새롭게 등장한 유형의 일자리였다(Autor, Salomons and Seegmiller, 2023).

또한 AI가 인간의 작업을 적극적으로 보완할 가능성도 있다(Agrawal et al., 2017). 생성 언어 모델을 사용하는 그룹과 사용하지 않는 그룹의 성과를 비교한 실험 연구에 따르면, 생성 언어 모델을 사용하는 그룹이 평균적으로 더 높은 생산성을 보였다(Dell'Acqua et al., 2023).

게다가 기업 차원에서의 AI와 자동화의 영향은 개인이나 산업 차원에서 관찰된 총체적인 영향과 다를 수 있다. 고도의 기술이 요구되는 고소득 직업을 제외하면, AI와 노동시장에 미치는 영향 간의 관계는 명확하지 않다(Acemoglu et al., 2020; 전병유 · 정준호 · 장지연, 2022). 그러나 기업 차원의 관찰에 따르면 AI 집약적인 직무로의 재편성과 비-AI 직무 채용 감소와 같은 인력 대체 효과가 나타나고 있다(Acemoglu et al., 2020).

그렇다면, 이러한 SBTC와 RBTC 기반 가설들을 노동조합의 교섭력과 기업특수적 기술 필요성이 상호작용하는 내부노동시장 기제에 적용시켜 보자. 먼저, AI 기반 자동화가 기존의 노동을 완전히 '대체'하는 방향으로 도입될 경우, 숙련공 중심의 노동조합은 이러한 압력에 강력하게 저항할 것이다. - 적어도 그들이 잘 조직화되어 있는 경우에만 - 하지만, AI 기반 자동화가 기존의 노동 숙련을 '강화'하는 방향으로 도입될 경우, 그것은 기존 숙련

공의 생산성을 향상시키면서 동시에 그들의 교섭력도 증대시킬 것이다. 실제, 필자가 인터뷰한 현대자동차 생산기술연구소의 임원은 “우리는 우리가 보유하고 있는 엔지니어들과 테크니션들이 AI를 스스로 학습해서 우리의 공정라인을 AI 기반으로 다시 깔도록 할 것이다.”라고 밝혔다. 이 경우, 현대자동차의 엔지니어와 개발자 그룹의 내부노동시장은 한층 더 강화될 것이다.

하지만, 기업특수적 기술 육성에 대한 필요성이 높지 않은 상황에서 AI에 의한 대체 압력이 증가하면, 내부노동시장은 어떻게 변화할까? 미숙련 노동자들은 이에 저항하겠지만(노동조합이 강력하게 조직화되어 있는 경우가 아니면), 숙련을 갖고 있지 못한 노동자들은 해고의 위협에 직접적으로 노출될 것이다. 반면, 미숙련 노동자들이(현대자동차 생산직 노동자들과 같이) 강력한 전투주의적 노동조합을 보유하고 있을 경우, AI 기반 자동화와 생산직 노동자들은 당분간은 공생할 가능성이 크다. 이 경우, 미숙련 노동자들과 그들의 노동조합은 AI를 자신들의 고용 유지를 위해 활용할 의사도 없기 때문에, 단기적으로는 노동자들의 고용과 AI-기반 자동화가 함께 유지되겠지만, 장기적으로 노동자들에 대한 해고 압력이 가중될 것이다.

마지막으로, AI의 ‘노출(exposure)’과 ‘전략(strategy)’을 구분할 필요가 있다. AI 노출이 높은 기업은 두 가지 전략 중 하나를 채택할 수 있다: 그것은 ‘대체(replacement)’ 또는 ‘새로운 기술의 내부화(internalization of new technology)’이다.

우리는 내부노동시장이 있으며 AI 노출이 높은 기업이 ‘대체’보다는 ‘새로운 기술의 내부화’ 전략을 선호할 수 있는 두 가지 이유를 제시한다. 첫째, 새로운 기술의 도입은 개인 수준에서의 기술 저하를 초래하는 것이 아니라 자동화 기술 자체와 관련된 새로운 기술을 요구한다. 전통적인 기술 저하 가설(Braverman, 1974)에 따르면, “자본이 새로운 기술과 기계를 도입하여 노동 과정의 지식과 계획에 대한 통제를 얻고 장인들의 지식과 경험을 구식으로 만들어 기술 저하를 초래한다.” 그러나 단순히 매뉴얼에 따라 일반 기계로 자동화하는 것만으로는 실제로 생산성이 감소할 수도 있다. 오히려 자동화 기술에는 새로운 기술이 필요하다. 제조업에서 자동화 기계를 최적의 성능으로 운영하기 위해서는 기본 설정만으로는 불가능하며, 기계를 효율적

으로 운영하기 위해 숙련된 작업자가 필요하다.²⁰⁾ 또한, AI 자동화 기술과 관련된 기술의 차이는 이미 분명해지고 있으며, 실험연구에 따르면 사전 훈련된 개인이 더 높은 성과를 내는 것으로 나타나고 있다(Dell'Acqua et al., 2023).

둘째, 실제 기업 환경에서 일반 목적의 대형 언어 모델(LLMs)을 적용하려면 회사 특화 데이터로 미세조정(fine-tuning)이 필요하다. LLMs는 무엇이든 배울 수 있는 다목적 도구처럼 보이지만, 실제로는 법률사무소나 병원과 같은 상업적 수준에서 사용하려면 회사 특화 데이터를 회사의 특정 분야 이윤 창출을 위해 '훈련'시키고 '조정'해야 한다. 보안상의 이유로 이 노하우는 내부화되어야 하며, 이는 기업들이 새로운 기술의 내부화 전략을 선호하도록 유도한다.

또한, 사회적 관계의 폐쇄성도 전문화 결정에 영향을 미칠 수 있다. 예를 들어, 전문직업(예 : 의사, 변호사)에서는 폐쇄된 사회적 관계가 AI의 범용화 보다는 내부화와 특성화를 유도하며 더 강력한 해자를 구축하는 방향으로 귀결될 수도 있다.

제3절 자료 및 방법론

1. AI 노출도 측정

본 연구는 가용 가능한 직업/산업 수준의 AI 노출도 지표를 활용하여 기업 수준의 내부노동시장 지표와의 상관성을 테스트함으로써 AI에 의한 압력이 기업의 내부노동시장 기제들을 강화 혹은 약화시키는지 여부를 논의한다.

한국표준직업분류를 기반으로 생성된 AI 직업 노출(AIOE)을 기업 수준 데이터에 적용하기 위해서는, 기업 수준의 AI 직업 노출도를 계산할 필요가 있

20) 이 논지는 본 논문(프로젝트)의 논평자인 노용진 교수가 제기한 것이다.

다. 그러나 기업 패널 데이터는 각 기업에 대한 세부 직업 분류를 제공하지 않고, 대신 관리자, 전문가(준전문가 포함), 사무직, 서비스업 종사자, 판매업 종사자, 단순노무직 등으로 간소화된 범주를 제공한다. 따라서 '한국표준 직업분류'를 기반으로 생성된 AIOE 값을 기업 패널 데이터의 간소화된 직업 비율에 매핑하여 기업 수준의 AI 직업 노출도를 계산해야 한다.

이 연구에서는 직업 수준에서 AI 직업 노출(AIOE)을 단순히 적용하는 대신, 산업-직업 셀의 대표값을 사용한다. 사업체패널 데이터는 68개의 산업과 7개의 직업을 포함하며, 총 476개의 산업-직업 셀을 생성한다. 산업-직업 셀의 대표값을 계산하기 위해 각 산업에 포함된 직업 목록을 추출한 후, 해당 직업들의 평균 AIOE를 계산하였다. 그다음, 이 산업-직업 셀 AIOE를 사용하여 개별 기업의 AI 노출을 산출하였다 (보다 자세한 측정 과정은 부록 1을 참조).

2. 내부노동시장 측정

내부노동시장 관련 연구들은(정승국, 2021) 다음과 같은 변수들을 내부노동시장의 지표로 사용해 왔다: 임금 프로파일의 경사도, 연공서열 임금체계의 형태, 내부 승진을 위한 기술 요건의 정도, 내부 직원의 고용안정성 수준, 승진 등급(수와 정도)과 이에 따른 임금 상승, 근속연수에 따른 자동 등급 상승의 정도, 복리후생 프로그램의 가짓수 혹은 회사에서 제공하는 추가 혜택의 범위. 이러한 다양한 지표들 중, 본 연구는 종속변수로 다음과 같은 변수들을 최종 선택하였다: 연공형 임금곡선의 형태(부류), 복리후생 프로그램의 규모 및 가짓수, 자동승진 시스템의 존재.


[그림 6-1]은 근속에 따른 연공급 형태 임금의 증가 유형을 그림으로 분류한 것이다. 본 연구는 이 형태들을 두 가지 단순화한 형태의 이항변수로 전환한다. 그림의 ②와 ⑥을 더 유연한, 혹은 더 강력한 근속 성과를 반영한 보상체제로 분류하고, 그림의 ① 일정한 증가율, ③ 증가율 감소, ④ 초기 증가 후 정체를 나타내는 연공형 임금 체계로 분류한다. ⑤ 초기 증가 후 감소(임금 피크제)와 ⑦ 증가율 정체(고정급)는 위의 두 분류 체계에 속하지 않으므로 분석에서 제외한다.

[그림 6-1] 사업체패널 연공급 임금의 하위 분류

CQ2109/CQ2209/CQ2309. ☒

05 07 09 11 13 15 17 19

귀 사업장의 {사무·전문직/생산직/서비스·판매직} 근로자의 연령 혹은 근무에 따른 임금 곡선은 아래의 그래프 중 어디에 가깝습니까? 아래의 그래프는 연령 혹은 근무이 올라갈 때 임금증가의 형태를 나타내는 것입니다.



자료: 저자 작성.

복리후생 프로그램의 규모 및 가짓수(정승국, 2021)는 다음과 같이 측정하였다. 먼저, 복지비 지출이 총매출액에서 차지하는 비율(서비스 및 판매 직종에서 높음)을 사용하였다. 이는 총복지비/총매출액으로 계산할 수 있는데, 매출액이 거대한 글로벌 대기업들은 복지에 돈을 많이 쓰고 있으면서도 총복지비 비중은 낮게 나타날 수 있다. 따라서, 직원 1인당 복지비(서비스 및 판매 직종에서 높음)나 비법정 복지 프로그램의 수를 따로 테스트한다.

또한, 사무/전문직, 생산직, 서비스/판매직 어느 직종에서든 임금표가 존재하면 1, 그렇지 않으면 0으로 코딩하여 이진 변수를 만들어 연공급 임금표 존재 여부에 관한 변수를 만들어 테스트한다.

〈표 6-2〉 주요 설명변수의 기술통계

변수명		N	Mean	SD	Min	Max
정규직 비율		8,526	0.90911	0.21609	0	1
종업원 1인당 복리후생비 지출(자연로그)		14,572	1.23380	1.059466	-7.0914	4.3341
매출 대비 복리후생비 지출 비율		15,485	0.02057	0.024513	0	0.3871
성과주의형 연공제 임금곡선	사무전문직	7,889	0.25339	0.43498	0	1
	생산직	4,573	0.21211	0.40885	0	1
	서비스직	2,829	0.24779	0.431806	0	1
호봉표 유무	사무전문직	7,889	0.42274	0.494026	0	1
	생산직	4,573	0.43166	0.495362	0	1
	서비스판매직	2,829	0.40473	0.490928	0	1
자동승진 직급단계 수	사무직	7,601	0.94461	1.701612	0	10
	생산직	4,075	0.71901	1.504475	0	8
	서비스직	2,296	0.78832	1.600262	0	10
신규 채용 비율	전 체	7,517	0.69541	0.34797	0	1
	정규직	7,073	0.68809	0.353207	0	1
정규직 채용 비율	신규	6,879	0.81968	0.336695	0	1
	경력	4,487	0.83315	0.32722	0	1
	전 체	12,653	0.81801	0.323788	0	1

자료: 저자 작성.

또한, 성과 평가 결과가 승진에 반영되지 않는 직종이 한 가지 이상 있는 경우, 해당 기업은 자동 승진 시스템을 보유한 것으로 간주하는 변수를 만들었다. 즉, 자동 승진 없는 경우는 0, 근속 연수만 충족되면 자동 승진되는 경우들은 총등급의 수를 기록함으로써 통합된 하나의 변수를 만들었다.

본 연구는 회귀분석에서 종속변수에 영향을 끼칠 수 있는 다음과 같은 변수들을 통제한다: 조사 연도(터미변수), 기업 연령, 수도권 소재 여부(터미변수), 외국인 직접투자 기업 여부(터미변수), 기업규모(회계기간 평균), 벤처기업 여부(창립 5년 이하, 터미변수), 노조 가입률, 시장 내 경쟁 압력, 시장 수요 특성, 제조업 여부(터미변수), 기계적 자동화 및 전산화 수준. 이 중에서 “기계적 자동화 및 전산화” 수준은 한국고용정보원에서 수행한 「재직자 조사」 설문 결과를 가져온 것이다.

〈표 6-3〉 주요 통제변수의 기술통계

변수명	N	Mean	SD	Min	Max
사업체 업력	15,485	25.44908	15.26164	1	118
외국인 직접투자기업	15,485	0.109719	0.31254	0	1
기업규모	15,485	1093.863	3995.869	1	95794
벤처기업 여부	15,485	0.033064	0.17881	0	1
노조가입률	15,367	19.5576	31.31207	0	100
시장 내 경쟁 압력	14,832	2.132821	0.878436	1	5
시장 수요 특성	14,776	2.908771	0.948238	1	5
제조업 여부	15,485	0.576816	0.49408	0	1
전산화 수준	11,524	2.24209	0.200817	1.651054	3.056432

자료: 저자 작성.

3. 한계점

본 연구는 세 가지 한계를 갖고 있다. 인공지능 노출도와 내부노동시장의 관계는 인과관계가 불분명하다. 내부노동시장이 이미 장착되어 있는 기업이 다수이기 때문에 인공지능 노출도가 높은 기업이 내부노동시장 제도를 채택하거나 증가시킨다고 보기에는 무리가 따른다. 오히려 내부노동시장을 장착하고 있는 기업들이 선제적으로 인공지능 관련 기술이나 자동화 시스템을 도입할 가능성도 있다. 따라서, 우리는 두 변수 간의 명시적인 인과관계의 방향을 설정하지 않는다. 현 데이터에서 어느 변수가 선행하는지 밝히기는 어렵기 때문에 우리는 이 내생성 문제를 부인하거나 제거하는 방향으로 연구를 설정하지 않는다.

첫 번째 문제와 관련이 있는 또 다른 문제는 내부노동시장을 갖고 있는 (대부분의 대규모 한국) 기업은 오랫동안 그러한 제도들을 유지해 왔기 때문에 이들은 시간에 따라 변화하지 않는다. 따라서 고정효과모델(fixed effects model)을 쓰기에 무리가 따른다. 본 연구는 랜덤효과모델(random effects model)과 유사하지만, 랜덤효과모델의 비현실적인 가정[corr(random error term, existing covarites)=0]을 우회하는 클러스터 옵션(cluster option)과 강

견표준편차(robust standard error)로 보완한 단순회귀분석을 써서 기업 간 평균 효과의 차이를 밝히고 확인하는 데 주력할 것이다.

마지막으로, 본 연구가 의도하는 인공지능이 내부노동시장 제도에 갖는 효과를 확인하기에는 아직 인공지능의 발전이 충분히 진행되지 않았다는 비판이 가능하다. 이를 인정함에도 불구하고, 본 연구는 인공지능 도입이 기업에 따라 매우 적극적으로 진행되고 있음을 고려하여, 기업의 인공지능 물결에 대한 초기 대응 양상을 확인하는 것을 목적으로 한다.

4. 모 델

우리는 웨이브별로 약 2,000에서 2,300개가량의 기업이 표본인 사업체패널 데이터를 2015년에서 2021년까지 격년으로 조사된 4개년도 데이터를 이용한다. 각 기업이 2회에서 4회 정도 조사되었기에 같은 케이스당 여러 웨이브들이 존재하는 패널 구조이다. 통상적으로 이러한 패널 데이터에는 고정효과모델(fixed effects models)이 사용되지만, 본 연구의 종속변수들인 내부노동시장 제도 변수들은 대부분 짧은 시간동안 변하지 않는다(time-invariant). 이러한 종속변수에 고정효과모델을 사용할 경우, 모든 케이스 간 변이는 고정효과(터미변수들)에 의해 통제되어 연구자의 관심을 제대로 반영하지 못하는 문제가 있다.

우리는 2,000여 개의 사업체 수준 클러스터를 사용하여 Huber-White의 이분산성 일관 표준오차(또는 견고한 표준오차)를 적용한 선형회귀(OLS)모델 혹은 로짓/순서형 로짓모델을 사용한다. 이 모델들에서는 다른 연도가 기업에 클러스터링되어 있으며, 각 기업 내에서 관측치가 상관관계를 가질 수 있지만, 기업 간에는 독립적일 것이라고 가정한다(Huber, 1967; White, 1980). 즉, 이 모델은 “같은 클러스터 내의 오차항 비대각 요소들이 0이 아닐 수 있다”는 것을 허용하면서도 “클러스터 간 관측치에는 상관관계가 없다”는 가정을 유지한다(Primo et al., 2007: 451).

이러한 예러항의 구조를 고려하기 위해 계층적 선형 모델링(HLM: Bryk and Raudenbush, 1992; Raudenbush and Bryk, 2002)(혹은 random effects model)을 사용할 수도 있지만, 우리는 다음 두 가지 이유로 Huber-White

추정치를 사용한다. 첫째, 우리는 각 수준의 공변량이 얼마나 설명하는지를 알고자 하는 것이 아니라, 주된 공변량의 점 추정치와 통계적 유의성을 적절히 지정된 오류 구조와 함께 알고자 한다. 둘째, Huber-White 추정치는 모든 수준에 대한 분포 가정을 요구하지 않으므로 이론과 데이터에 과도한 부담을 초래하지 않는다(Primo et al., 2007; Steenbergen and Jones, 2002 : 234). 다시 말해서, 우리가 사용하는 모델은 랜덤 에러항과 독립변수들의 상관관계가 없다는 랜덤효과모델의 비현실적인 가정(Halaby, 2004)을 유지하지 않아도 되지만, 표준편차는(robust standard errors를 통해) 보수적으로 추정하는, 보다 유연한 모델이다. 이 외에도 다수의 웨이브를 통제하는 시간 더미변수들(4개)과 지역 수준 변이를 통제하는 지역 더미변수들(38개)을 포함시킴으로써 가능한 한 지역 및 시간의 공유로 인해 발생하는 관측되지 않은 단위 내부의 상관성(intra-class correlations)을 통제할 것이다.

또한, 지나치게 규모가 작은 기업의 경우 내부노동시장 특성을 고려하기 어려우므로 30인 미만의 기업은 분석에서 제외하였다. 다만 30인 미만 기업의 포함 여부가 결과에 영향을 미치지 않는았다.

제4절 회귀분석 결과

〈표 6-4〉는 근속-임금 유형 중 (2)와 (6)을 나머지 유형에 대비시켜 이진 변수를 만든 후 AI 노출도와 회귀분석을 실시한 결과이다. (2)는 근속이 오래될수록 더 높은 임금을 책정함으로써 - 토너먼트 이론에서 예측하는 대로 - 더 높은 생산성을 발휘하는 사원에게 더 높은 보상을 함으로써, 직급사다리를 타고 올라가는 경쟁을 강화시키는 대표적인 내부노동시장 강화 기제이다. [그림 6-1]이 보여주듯이, 높은 인공지능 노출도는 성과지향형 연공급의 도입 가능성과 높은 확률로 연관되어 있다.


(6)은 근속이 오래될수록, 변동성을 늘림으로써, 더 높은 생산성을 발휘하는 사원에게는 더 높은 보상을, 더 낮은 생산성을 발휘하는 사원에게는 더 낮은 보상을 하여 직급사다리를 타고 올라가는 경쟁을 (2)보다 더욱 강화시

킨다. 높은 생산성에만 보상을 늘이는 것이 아니라, 낮은 생산성에 대해 벌(punishment)을 가하는 모델이기 때문이다. 특정 기업이 이 두가지 모델 중 하나를 채택할 경우, 전통적인 연공제 모델의 변형태들에 비해, 기업 내 내부노동시장을 강화하는 제도를 갖고 있다고 볼 수 있다.

모델 (1), (3), (5)를 볼 때, 사무직, 생산직, 서비스직 모두에서 높은 인공지능 노출도는 보다 강한 성과지향 연공제와 연동될 확률이 높다. 그 강도는 생산직에서 가장 높고 그다음 서비스직, 그다음 사무직 순이다. 하지만, 통계적 유의도는 사무직, 생산직, 서비스직 순으로 높았다.

여타 통제변수 결과는 기존의 이론 및 상식에 부합한다. 외국기업 사무직의 경우, 성과지향 연공급 제도를 채택할 확률이 높았다. 또한 사무직의 경우, 기업규모가 클수록 성과지향 연공급 제도를 채택할 확률이 높았다. 이 결과는 수출지향 글로벌 대기업일수록 연공급 기반 임금 위에 성과급을 함께 도입하는 경우가 많고, 이러한 성과급의 비율과 액수가 고연차 직원들에게 더 유리하게 지급되는 경우가 많다는 것을 의미한다.

[그림 6-2] 인공지능 노출도와 성과지향 연공제



자료: 저자 작성.

〈표 6-4〉 로짓모델(with robust standard errors and cluster option) 추정치: 인공
지능 노출도와 성과지향 연공제(vs. 전통적 연공제) 임금 제도 유형과의 관계

	(1) 사무직 성과지향 연공제	(2) 사무직 성과지향 연공제	(3) 생산직 성과지향 연공제	(4) 생산직 성과지향 연공제	(5) 서비스직 성과지향 연공제	(6) 서비스직 성과지향 연공제
AIOE	9.612*** (4.402)	8.188* (2.538)	15.15*** (3.780)	17.74*** (3.513)	9.173* (2.153)	14.38* (2.226)
업력	-0.00159 (-0.539)	0.00106 (0.309)	-0.00687 [†] (-1.673)	-0.00467 (-0.932)	-0.00669 (-1.370)	-0.00425 (-0.752)
외국인 직접투자	0.574*** (4.501)	0.636*** (4.068)	0.317 [†] (1.939)	0.255 (1.271)	0.521* (2.440)	0.512* (2.081)
기업규모	0.0000181 (1.642)	0.000037* (2.258)	-0.000009 (-0.691)	0.0000009 (0.0281)	0.0000103 (0.753)	0.0000225 (1.258)
벤처기업	0.00163 (0.00710)	-0.0153 (-0.0601)	-0.151 (-0.473)	-0.00257 (-0.00731)	-0.614 (-1.314)	-0.562 (-1.180)
노조조직률	-0.000277 (-0.190)	-0.00113 (-0.640)	0.00116 (0.570)	0.00326 (1.311)	-0.00352 (-1.401)	-0.00554 [†] (-1.888)
경쟁압력	-0.0147 (-0.302)	-0.0584 (-1.054)	-0.0395 (-0.628)	-0.0490 (-0.662)	-0.0239 (-0.296)	-0.0594 (-0.650)
제품수요	0.174*** (4.223)	0.180*** (3.781)	0.105 [†] (1.870)	0.0842 (1.273)	0.112 [†] (1.724)	0.119 (1.579)
제조업	-0.0794 (-0.853)	-0.0680 (-0.525)	-0.0914 (-0.601)	0.0187 (0.0909)	0.209 (1.422)	0.422 [†] (1.879)
자동화		0.331 (1.005)		0.0939 (0.162)		-0.515 (-0.977)
_cons	-7.792*** (-5.707)	-7.742*** (-4.715)	-10.76*** (-4.373)	-12.66*** (-4.466)	-7.372** (-2.796)	-9.481** (-2.873)
N	6455	4768	3923	2751	2392	1934
R2						

주: t statistics in parentheses.

[†]p<0.10, * p<0.05, ** p<0.01, *** p<0.001.

연도 더미와 지역 더미 추정치 결과는 생략함.

자료: 저자 작성.

서비스직의 경우, 노조조직율이 높을수록, 성과지향 연공급제를 채택할 확률이 낮아짐이 확인된다. 세계시장에 노출도가 높지 않은 국내 서비스 기


업들의 경우, 노동조합이 성과지향 연공급제에 대해 저항하는 경향이 있음을 보여준다.

마지막으로(전통적 의미의) 자동화가 성과지향 연공급에 미치는 영향이 대부분 통계적으로 무의미한 것은, 이 변수가 인공지능 노출도와 높은 긍정의 상관관계를 보이기 때문이다(부록 A 참조). 그러한 경향은 사무직에서 특히 두드러진다. 자동화 변수를 모델에 넣었을 때, 인공지능 노출도 계수가 눈에 띄게 줄어드는 데서 이를 확인할 수 있다. 생산직과 서비스직에서는 자동화 변수가 인공지능 노출도 변수에 별다른 영향을 끼치지 않는 것으로 보인다(서비스직의 경우, 인공지능 노출도 계수가 오히려 증가하였다).

〈표 6-5〉는 기업의 인공지능 노출도에 따라 더 강력한 복지제도를 갖고 있는지를 테스트한다. 모델 (1)과 (2)의 종속변수는 피고용인 1인당 복지지출 액수에 자연로그를 취해서 만든 것이다. 모델 (3)과 (4)는 복지제도의 가짓수 지표이다. 복지제도가 5가지이면 5, 10가지이면 10이라고 입력한 제도 개수의 단순 합산값이다. 〈표 6-1〉의 결과와 마찬가지로 인공지능 노출도는 복지지출의 관대함과 제도 개수의 관대함에 모두 긍정적으로 연관되어 있다. 이러한 관계는 [그림 6-2]에서 잘 나타난다. 대부분의 케이스들은 0과 0.5 사이에 집중적으로 분포되어 있고, 그보다 낮은 값과 높은 값의 인공지능 노출도에서 정의 관계의 분포는 덜 명확하다.

또한, 외국기업일수록, 대기업일수록, 그리고 노동조합의 조직률이 높을수록 1인당 복지지출이 더 높고, 복지제도의 가짓수가 많다는 점에서, 인공지능 노출도는 복지 관련 내부노동시장 기제들과 정의 관계를 갖고 있음을 알 수 있다. 다른 산업에 비해 제조업에 속한 기업들이 더 많은 가짓수의 복지제도를 운영하고 있다. 마지막으로, 전통적인 의미의 자동화는 1인당 복지 지출의 관대함과 부의 관계를 맺고 있다. 비록 전통적인 의미의 자동화가 인공지능 노출도와 상당히 높은 상관관계를 갖고 있지만($\text{corr}=0.498$), 자동화가 반드시 더 관대한 복지지출과 관련되지는 않음을 알 수 있다. 다른 주요 요인들이 통제되어 있기 때문에, 어떤 기업들의 경우 전통적 의미의 자동화는 인적자본에 대한 낮은 지출 경향과 관련이 있을 수 있다고 추정해 볼 만하다.

[그림 6-3] 인공지능 노출도와 1인당 복지후생비 지출의 상관관계



자료: 저자 작성.

〈표 6-5〉 OLS 모델(with robust standard errors and cluster option) 추정치 : 인공지능 노출도와 기업 복지제도와와의 관계

	(1) 종업원 1인당 복리후생비 (자연로그)	(2) 종업원 1인당 복리후생비 (자연로그)	(3) 복리후생제도 가짓수	(4) 복리후생제도 가짓수
AIOE	15.89*** (19.88)	15.54*** (14.22)	22.10*** (11.35)	21.71*** (7.785)
업력	0.00486*** (5.038)	0.00489*** (4.453)	0.0181*** (6.498)	0.0178*** (5.712)
외국인 직접투자	0.402*** (12.63)	0.345*** (9.109)	1.922*** (15.88)	1.952*** (13.42)
기업규모	0.0000128** (3.021)	0.0000196*** (5.027)	0.000119*** (6.357)	0.000168*** (7.487)
벤처기업	-0.165** (-2.659)	-0.196** (-2.735)	0.0320 (0.225)	-0.0529 (-0.347)

〈표 6-5〉의 계속

	(1) 종업원 1인당 복리후생비 (자연로그)	(2) 종업원 1인당 복리후생비 (자연로그)	(3) 복리후생제도 가짓수	(4) 복리후생제도 가짓수
노조조직률	0.00481*** (9.481)	0.00478*** (8.360)	0.0209*** (15.11)	0.0190*** (12.11)
경쟁압력	-0.0185 (-1.379)	-0.00991 (-0.632)	-0.00221 (-0.0599)	-0.0223 (-0.522)
제품수요	-0.0268* (-2.374)	-0.0297* (-2.298)	-0.175*** (-5.417)	-0.180*** (-4.953)
제조업	0.333*** (9.673)	0.323*** (7.403)	0.626*** (7.043)	0.670*** (5.876)
자동화		0.126 (1.135)		0.168 (0.595)
_cons	-8.745*** (-17.27)	-8.860*** (-15.38)	-7.307*** (-6.021)	-7.431*** (-5.228)
N	12682	9488	13460	10050
R2	0.168	0.173	0.253	0.262

주: t statistics in parentheses.

†p<0.10, * p<0.05, ** p<0.01, *** p<0.001.

연도 더미와 지역 더미 추정치 결과는 생략함.


자료: 저자 작성.

〈표 6-6〉은 기업의 인공지능 노출도와 기업이 호봉표를 갖고 있는지 여부를 테스트한다. 호봉표는 직급과 근속연수에 따라 호봉이 상승하는 정도를 명확히 규정하고 있는 표로 이를 명문화하고 있는 기업은 토너먼트 이론에 따라 사원들이 호봉표 계단을 오르기 위해 생산성 경쟁을 벌이도록 유도한다. 혹은 이러한 기업은 더 높은 생산성을 보이는 사원을 승진을 통해 보상하는 내부 경쟁 시스템을 제도화하고 있는 것으로 간주된다.

〈표 6-6〉의 결과는 사무직과 생산직의 경우, 인공지능 노출도가 높은 기업일수록 호봉표를 제도화하고 있을 가능성이 더 높음을 보여준다. 서비스직의 경우는 이러한 관계가 확인되지 않았다. 사무직의 경우 노동자들의 평균 연령이 높을수록, 생산직의 경우 노동조합 조직율이 높을수록, 사무직과 생산직 모두 기업규모가 클수록 이러한 호봉표를 제도화하고 있을 가능성이 높았다. 반면 전통적 자동화 정도가 높은 직군인지 여부는 호봉표의 제도화와 아무런 관련이 없었다.

〈표 6-6〉의 결과는, 〈표 6-1〉, 〈표 6-4〉와 마찬가지로, 인공지능 노출도는 내부노동시장 기제들의 발달과 양의 상관관계에 있음이 거듭 확인된다.

[그림 6-4] 인공지능 노출도와 계단식 호봉표의 관계 : 사무직, 생산직 비교



자료: 저자 작성.

〈표 6-6〉 로짓모델(with robust standard errors and cluster option) 추정치 : 인공지능 노출도와 계단식 호봉표의 유무

	(1) 사무직 계단식 호봉표 유무	(2) 사무직 계단식 호봉표 유무	(3) 생산직 계단식 호봉표 유무	(4) 생산직 계단식 호봉표 유무	(5) 서비스직 계단식 호봉표 유무	(6) 서비스직 계단식 호봉표 유무
AIOE	6.122** (2.981)	10.19*** (3.345)	13.12*** (3.628)	15.32*** (3.371)	1.688 (0.431)	6.527 (1.063)
업력	0.00657* (2.419)	0.00753* (2.411)	0.00383 (1.091)	0.00633 (1.557)	0.00446 (1.096)	0.00220 (0.488)
외국인 직접투자	0.0574 (0.470)	0.0240 (0.164)	0.295* (1.979)	0.292 ⁺ (1.668)	0.198 (0.982)	0.152 (0.652)
기업규모	0.000044** (3.165)	0.000044** (2.688)	0.0000832* (2.059)	0.0000873* (2.469)	0.0000269* (1.974)	0.0000221 (1.320)
벤처기업	0.0212 (0.109)	0.112 (0.516)	0.124 (0.472)	0.362 (1.122)	-0.0870 (-0.226)	-0.174 (-0.444)

〈표 6-6〉의 계속

	(1) 사무직 계단식 호봉표 유무	(2) 사무직 계단식 호봉표 유무	(3) 생산직 계단식 호봉표 유무	(4) 생산직 계단식 호봉표 유무	(5) 서비스직 계단식 호봉표 유무	(6) 서비스직 계단식 호봉표 유무
노조 조직률	0.00396** (2.929)	0.00323* (2.078)	0.00875*** (5.039)	0.0105*** (5.193)	0.00413 [†] (1.936)	0.00507* (2.189)
경쟁압력	-0.0226 (-0.529)	-0.0567 (-1.147)	-0.0788 (-1.407)	-0.110 (-1.640)	-0.0701 (-1.082)	-0.0854 (-1.200)
제품수요	-0.122** (-3.268)	-0.156*** (-3.664)	-0.117* (-2.443)	-0.166** (-2.899)	-0.151** (-2.617)	-0.194** (-2.994)
제조업	-0.0613 (-0.719)	0.00351 (0.0297)	0.257+ (1.732)	0.358+ (1.890)	-0.236 [†] (-1.812)	-0.172 (-0.840)
자동화		-0.422 (-1.402)		-0.158 (-0.312)		-0.280 (-0.566)
_cons	-3.639** (-2.857)	-5.069** (-3.282)	-8.051*** (-3.641)	-8.885*** (-3.497)	-0.921 (-0.382)	-2.946 (-0.941)
N	6455	4783	3925	2767	2399	1939
R2						


주: t statistics in parentheses.

[†]p<0.10, * p<0.05, ** p<0.01, *** p<0.001.

연도 더미와 지역 더미 추정치 결과는 생략함.

자료: 저자 작성.

[그림 6-5] 인공지능 노출도와 자동승진제도의 관계: 사무직, 생산직 비교



자료: 저자 작성.

〈표 6-7〉 순서 로짓모델(ordered logit model)(with robust standard errors and cluster option) 추정치 : 인공지능 노출도와 자동승진제도의 관계

	(1) 사무직 자동승진직급 단계 수	(2) 사무직 자동승진직급 단계 수	(3) 생산직 자동승진직급 단계 수	(4) 생산직 자동승진직급 단계 수	(5) 서비스직 자동승진직급 단계 수	(6) 서비스직 자동승진직급 단계 수
AIOE	7.965*** (3.610)	9.172** (2.847)	17.50*** (3.974)	18.04** (3.013)	3.760 (0.762)	-5.795 (-0.741)
업력	0.000298 (0.103)	0.00689* (2.146)	-0.00573 (-1.315)	-0.000264 (-0.0523)	-0.00926 [†] (-1.839)	-0.00519 (-0.950)
외국인 직접투자	-0.0467 (-0.340)	-0.145 (-0.869)	0.327 [†] (1.914)	0.211 (0.982)	0.0760 (0.308)	0.0517 (0.178)
기업규모	-0.000001 (-0.129)	0.000002 (0.121)	0.000011 (0.828)	0.000021 (0.561)	0.000008 (0.607)	-0.000001 (-0.0595)
벤처기업	0.0420 (0.200)	0.205 (0.839)	-0.159 (-0.518)	-0.0932 (-0.270)	-1.178 [†] (-1.928)	-1.027 [†] (-1.649)
노조 조직률	-0.00125 (-0.815)	-0.00226 (-1.263)	0.00457* (2.161)	0.00354 (1.349)	0.00158 (0.548)	0.000552 (0.176)
경쟁압력	0.0464 (0.974)	0.0624 (1.127)	0.0377 (0.561)	0.0136 (0.167)	0.0627 (0.765)	0.0101 (0.109)
제품수요	-0.0334 (-0.800)	-0.0685 (-1.415)	0.138* (2.351)	0.0854 (1.191)	0.0452 (0.615)	0.0157 (0.183)
제조업	0.252** (2.670)	0.364** (2.822)	-0.0344 (-0.193)	0.355 (1.426)	0.190 (1.110)	-0.131 (-0.463)
자동화		-0.369 (-1.149)		-0.568 (-0.889)		0.932 (1.385)
_cons	-5.875*** (-4.246)	-6.048*** (-3.637)	-12.23*** (-4.545)	-11.46*** (-3.616)	-3.698 (-1.227)	0.321 (0.0824)
N	6258	4630	3543	2467	2003	1599
R2						

주 : t statistics in parentheses.

[†]p<0.10, * p<0.05, ** p<0.01, *** p<0.001.

연도 더미와 지역 더미 추정치 결과는 생략함.


자료 : 저자 작성.

〈표 6-7〉은 기업의 인공지능 노출도와 기업이 자동승진제도를 갖고 있는지 여부와의 관계를 테스트한다. 〈표 6-7〉의 종속변수는 사무직, 생산직, 서비스직 각각의 근속연수 충족 시 자동승진되는 직급의 단계 수를 나타낸다. 0 값은 자동승진제도가 없는 경우를 나타낸다.²¹⁾

〈표 6-7〉의 결과는 인공지능 노출도가 높은 기업일수록 - 사무직과 생산직의 경우 - 자동승진제도를 사용하고 있을 가능성이 높음을 보여준다. 각 통제변수의 종속변수와의 관계는 〈표 6-6〉의 결과와 거의 일치한다.

사무직의 경우 노동자들의 평균 연령이 높을수록, 생산직의 경우 노동조합 조직율이 높을수록, 사무직과 생산직 모두 기업규모가 클수록 자동승진제도를 사용하고 있을 가능성이 높았다. 반면 전통적 자동화 정도가 높은 직군인지 여부는 자동승진제도의 사용과 아무런 관련이 없었다. 〈표 6-6〉의 결과 또한, 〈표 6-1〉, 〈표 6-4〉, 〈표 6-5〉와 동일하게, 인공지능 노출도는 내부노동시장 기제들의 발달과 양의 상관관계에 있음을 보여주고 있다.

[그림 6-6] 인공지능 노출도와 정규직 비율의 상관관계



자료: 저자 작성.

- 21) 이 경우 0과 1 이상 값의 관계가 근본적으로 다를 경우를 가정할 수 있다. 제로 값 증강(zero-inflation) 회귀 모델을 통해 두 관계를 따로 (하지만 독립적으로) 테스트한 결과 0과 1 이상 값의 관계와 1 이상 값들과의 관계는 근본적으로는 같은 방향성을 갖는 것으로 나타났다. 따라서, 본 연구에서는 이들을 한 모델 안에서 테스트해서 보고한다.

〈표 6-8〉 AIOE의 기업 수준 상관관계 요인

	(1) 사업체 AIOE	(2) 사업체 AIOE
정규직 비율	0.0184*** (12.07)	0.0198*** (13.67)
사업체 업력	0.0000938*** (4.051)	0.0000941*** (3.771)
외국인 직접투자	0.00281** (2.794)	0.00216* (1.974)
기업규모	-0.000000162 [†] (-1.947)	-0.000000212** (-2.672)
벤처기업	-0.00344* (-2.254)	-0.00278 [†] (-1.833)
노조조직률	-0.0000819*** (-7.026)	-0.0000661*** (-5.264)
경쟁노출	-0.000492 (-1.373)	-0.000489 (-1.153)
제품수요	-0.000626* (-2.059)	-0.0000379 (-0.106)
제조업	-0.00911*** (-11.34)	-0.00951*** (-11.12)
35세 미만 근로자 비율		0.000182*** (11.74)
_cons	0.600*** (321.7)	0.592*** (313.6)
N	6943	3617
R2	0.247	0.298

주: t statistics in parentheses.

[†]p<0.10, * p<0.05, ** p<0.01, *** p<0.001.

연도 더미와 지역 더미 추정치 결과는 생략함.


자료: 저자 작성.

〈표 6-8〉은 기업 수준에서 어떤 요인들이 AIOE와 상관되어 있는지를 탐구한다. 정규직 비율이 높을수록, 설립 후 오랜 시간이 지난 기업일수록 AIOE 노출도가 높았다. [그림 6-6]은 정규직 비율이 절반 이상인 기업에서 AIOE 노출도 또한 양의 값을 가짐을 보여준다. 정규직 비율이 절반 이상일

때, 90% 값에 가까울수록 신뢰구간이 급속히 좁아지고 있음을 볼 때, 정규직 비중이 높은 기업들에서 AIOE 노출도와 양의 관계가 더욱 강해짐을 알 수 있다. 앞의 AIOE 노출도와 내부노동시장과의 높은 상관성을 고려할 때, 인공지능의 도입은 고속련의 내부자 지위의 노동자들 중심으로 이루어질 가능성이 크다고 볼 수 있다.

반면, 노조조직율이 높을수록, 제조업에 속한 기업일수록 AIOE 노출도는 낮았다. AIOE 노출도가 사무직과 서비스직 중심으로 채택될 가능성이 높다는 것으로 해석할 수 있다. 또한, 강한 노동조합이 활동하고 있는 사업체에서 인공지능의 채택이 더 낮을 수 있음을 의미한다. 이는 기존의 내부자 지위를 향유해 온 대기업의 강성노조가 지배하는 제조업 사업장들의 경우 인공지능의 채택이 한동안 유예될 수 있음을 시사한다.

[그림 6-7] 산업별 인공지능 노출도 평균



자료: 저자 작성.

K : 금융 및 보험업
 O : 공공행정, 국방 및 사회보장 행정
 P : 교육 서비스업
 J : 정보통신업
 M : 전문, 과학 및 기술 서비스업
 Q : 보건업 및 사회복지 서비스업
 G : 도매 및 소매업
 D : 전기, 가스, 증기 및 공기 조절 공급업
 F : 건설업
 S : 협회 및 단체, 수리 및 기타 개인 서비스업
 L : 부동산업
 R : 예술, 스포츠 및 여가 관련 서비스업
 I : 숙박 및 음식점업
 C : 제조업
 H : 운수 및 창고업
 E : 수도, 하수 및 폐기물 처리, 원료 재생업
 N : 사업시설 관리, 사업 지원 및 임대 서비스업

〈표 6-9〉 OLS 모델(with robust standard errors and cluster option) 추정치 : 인공
지능 노출도와 채용 결정의 관계

	(1) 채용 근로자 중 신규 비율	(2) 정규직 채용 근로자 중 신규 비율	(3) 신규 채용 근로자 중 정규직 비율	(4) 경력 채용 근로자 중 정규직 비율	(5) 전체 채용 근로자 중 정규직 비율
AIOE	-1.910*** (-5.909)	-1.622*** (-4.729)	1.620*** (4.609)	1.367** (3.049)	0.847** (3.075)
업력	0.000933* (2.333)	0.00105* (2.459)	-0.000514 (-1.243)	-0.000602 (-1.160)	-0.000709* (-2.270)
외국인 직접투자	0.0462** (2.692)	0.0287 (1.479)	-0.0369+ (-1.934)	0.0262 (1.193)	-0.0353** (-2.698)
기업규모	0.00000843*** (4.925)	0.00000724*** (3.470)	-0.00000798** (-2.951)	-0.00000675 (-1.630)	-0.00000533*** (-3.026)
벤처기업	-0.00313 (-0.0981)	0.0152 (0.440)	-0.00781 (-0.245)	-0.0397 (-0.963)	-0.00145 (-0.0698)
노조조직률	0.000436* (2.215)	0.000407+ (1.931)	-0.000896*** (-4.051)	-0.000871** (-3.026)	-0.000630*** (-4.032)
경쟁압력	0.0213*** (3.305)	0.0170* (2.482)	0.0000263 (0.00374)	0.0145+ (1.821)	-0.00432 (-0.889)

〈표 6-9〉의 계속

	(1) 채용 근로자 중 신규 비율	(2) 정규직 채용 근로자 중 신규 비율	(3) 신규 채용 근로자 중 정규직 비율	(4) 경력 채용 근로자 중 정규직 비율	(5) 전체 채용 근로자 중 정규직 비율
제품수요	-0.0312*** (-5.643)	-0.0282*** (-4.887)	-0.0118* (-2.065)	-0.0159* (-2.293)	-0.00424 (-1.000)
제조업	-0.00384 (-0.294)	0.00948 (0.673)	0.151*** (10.61)	0.0942*** (5.621)	0.156*** (13.83)
자동화	1.770*** (8.893)	1.587*** (7.482)	-0.165 (-0.739)	-0.00179 (-0.00634)	0.278 (1.596)
N	6164	5806	5715	3706	10991
R2	0.091	0.074	0.094	0.060	0.087

주: t statistics in parentheses.

†p<0.10, * p<0.05, ** p<0.01, *** p<0.001.

자료: 저자 작성.

〈표 6-9〉는 기업의 AI 노출 수준이 채용 결정과 어떻게 관련되는지 살펴본다. AI 노출이 높을수록 신규채용은 적었다. (1)은 전체 채용 근로자 중에서 신규채용 근로자의 비율을, (2)는 정규직으로 채용된 근로자 중에서 신규 채용 근로자의 비율을 살펴본 것이다. 어느 쪽이든 신규채용 근로자의 비율은 AI 노출이 높을수록 낮아졌다. 한편, (3), (4), (5)는 채용 경로에 따른 정규직 근로자의 비율을 살펴본 것이다. 전반적으로 AI 노출이 높을수록 정규직으로 채용된 근로자의 비율은 높았다. AI 노출이 높은 기업에서 경력 채용보다는 신규채용 근로자일 경우 정규직으로 더 많이 채용했다. 종합하면, AI 노출이 높은 기업에서 신규채용 자체는 적지만 채용이 이루어지는 경우 정규직으로 채용할 가능성이 높다고 할 수 있다.

한편, 기업규모가 큰 기업일수록 신규채용 비율이 높았다. 반면 정규직으로 채용하는 비율은 기업규모가 큰 기업에서 더 낮게 나타났다. 노조조직률이 높은 기업에서 신규채용 자체는 많지만 새로운 정규직 채용은 낮은 경향성도 눈에 띈다. 또한, 제조업 기업일수록 정규직을 많이 채용했다.

제5절 소 결

사업체패널 분석 결과, 한국 기업의 AI 노출도는 고숙련 정규직 노동자를 다수 고용하는 산업에서 더 높게 나타난다. 또한, 회귀분석 결과로부터 한국 기업의 AI 노출도(AIOE)는 내부노동시장과 밀접한 관련이 있음을 알 수 있다. 이는 인과적 관계는 아니지만, 내부노동시장 메커니즘을 발전시킨 기업일수록 AI 노출도가 높은 시장 환경에 보다 적극적으로 적응할 유인이 있음을 추측할 수 있다. 내부노동시장 기제들 중 연공급이 보다 성과지향으로 적응된 기업들, 연공급 테이블이 존재하는 기업들, 복지 지출의 관대함과 정책의 세밀함이 높은 기업들, 마지막으로 자동승급제를 채택하고 있는 기업들이 높은 AI 노출도와 연관되어 있었다. 인공지능의 높은 노출도가 반드시 개별 기업이나 개인 수준에서 높은 인공지능 채택률을 의미하는 것은 아니다. 다만, 본 연구는 그럴 가능성이 구조적으로 높다고 결론 내린다.

다만, 이러한 적응이 새로운 기술과 역량을 내부화하는 방향으로 이어질지, 내부화된 노동력을 대체하는 방향으로 이어질지에 대해서는 보다 주의 깊은 분석이 필요하다.

우리의 판단으로는, 한국에서는 AI 도입이 RBTC(기술이 노동을 대체하는 방향)보다는 SBTC(기술이 노동의 숙련도를 높이는 방향)를 통한 숙련 강화(reinstatement)를 가속화할 가능성이 높다. 즉, 대기업들이 AI에 대한 투자를 늘려 기업 특유의 역량을 육성하고, 이를 통해 정규직 직원의 특권이 더욱 강화될 수 있다. 이 경우, 대기업 정규직이 AI에 기반한 생산성 혁명을 통해 나머지 (중소기업 종사자와 비정규직) 그룹과의 격차를 더욱 벌릴 가능성이 크다. 기존 내부노동시장 메커니즘의 발전과 함께, 고도화된 이중노동시장이 심화될 수 있으며, 이는 노동시장의 불평등을 가속화할 가능성이 크다.

〈부록 1〉 인공지능 직업 노출도의 조작적 정의와 특성

인공지능의 직업적 영향(Artificial Intelligence Occupational Exposure : AIOE)은 전자프론티어재단(Electronic Frontier Foundation)에서 각 AI 응용기술 영역의 발전 수준을 정량화한 “AI 응용기술들(AI-apps)”을 미국 O*NET 직업 정보에서 분류한 52개 능력(ability)과 연계하여 작성한 “AI기술-능력 연계표”에 따라 능력별 AI 노출도를 계산하고, 이를 각 직업의 모든 능력들에 대해 합산한 지표이다(Felten et al., 2019). 국내에서는 이 “AI 기술-능력 연계표”를 「한국직업정보 재직자 조사 2020」에서 개발한 15개의 능력 지표에 연계하여 한국고용직업분류(KECO) 코드 세 자리 기준 총 125개 직업의 인공지능 직업 노출도를 계산하였다(전병유 · 정준호 · 장지연, 2022).

인공지능 직업 노출도는 직종 수준에서 생성된 변수이므로, 사업체 수준 자료에서 인공지능 직업 노출도를 계산하려면 각 사업체에 재직 중인 근로자들의 직종별 인공지능 직업 노출도를 해당 직종의 구성비와 곱하여 사업체 전체의 인공지능 직업 노출도를 계산해야 한다. 기존 연구에서는 개별 사업체 i 가 고용한 직종 j 의 AI 노출도에 해당 직종의 구성비 s_{ij} 를 곱한 값을 합산하여 사업체별 인공지능 직업 노출도를 구하고 있다(Acemoglu, 2020; Eisefeldt, Schubert and Zhang, 2023).

$$AIOE_i = \sum_j (s_{ij} \times AIOE_j) \quad (1)$$

이 방법을 따라 사업체별 인공지능 직업 노출도를 집계하려면 한국고용직업분류 세 자리 코드를 연계용 키 변수로 이용하여 「사업체패널자료」에 125개 직업의 인공지능 직업 노출도 정보를 직접 병합하는 것이 이상적이다. 그러나 「사업체패널자료」에서는 개별 사업체에서 고용한 근로자의 상세한 직종 정보를 제공하지 않는다.

다만 「사업체패널자료」에서는 개별 사업체에서 고용한 직종별 근로자 수를 관리직, 전문직(기술직 포함), 사무직, 서비스직, 판매직, 생산직, 단순직 등 7개의 간소화한 직업 분류에 따라 제공하고 있다. 사업체 i 가 고용한 직종 j 의 구성비 s_{ij} 를 구하는 방법은 다음과 같다.

$$s_{ij} = \frac{L_{ij}}{L_i} \quad (2)$$

이때 L_i 는 기업 i 의 전체 고용, L_{ij} 는 기업 i 가 고용한 직종 j 의 고용을 나타낸다. 실제 「사업체패널자료」에서는 사업체의 직종구성비 s_{ij} 는 각 사업체 ID별로 각 직종의 근로자 수(epq3001, epq3002..., epq3007)를 전체 근로자 수(epq3008)로 나누어 계산하였다. 다음은 각 직종별 구성비의 평균이다. 사업체별로 구성비가 가장 높은 직종은 생산직이고, 사무직과 전문직 순으로 많은 것을 알 수 있다.

〈부표 1〉 직종별 구성비 평균

(단위 : %)

항 목	레이블	평 균
s_{i1}	관리직 구성비	10.99
s_{i2}	전문직 구성비	14.89
s_{i3}	사무직 구성비	20.59
s_{i4}	서비스직 구성비	8.05
s_{i5}	판매직 구성비	4.80
s_{i6}	생산직 구성비	29.65
s_{i7}	단순직 구성비	10.92

자료 : 저자 계산.

직종비를 알고 있는 7개 직종의 인공지능 직업 노출도 대표값을 이용하면 인공지능 직업 노출도 정보를 「사업체패널자료」에 연결할 수 있다. 이 경우 사업체 i 전체의 인공지능 직업 노출도는 다음과 같이 계산된다.

$$AIOE_i = \sum_{j=1}^7 (s_{ij} \times \overline{AIOE_j}) \quad (3)$$

이는 어떤 업종에서도 관리직, 전문직, 사무직, 서비스직, 생산직, 단순직의 인공지능 직업 노출도가 동일하다고 가정하는 것과 같다. (2)의 계산을 위해서 사업체별 직종구성비 s_{ij} 뿐 아니라 직종별 평균 인공지능 직업 노출도 ($\overline{AIOE_o}$)를 알아야 한다. 직종별 AIOE 평균값 $\overline{AIOE_j}$ 는 [부도 1]에서

처럼 소분류 직종 세 자리 수준에서 생성한 직종별 인공지능 직업 노출도 점수를 대분류 직종 한 자리 수준에서 집계하여 구할 수 있다.

[부도 1] 직종별 AI 노출도 원자료의 사업체패널 단순 병합 개요

직종 수준		→	사업체 수준		
직 종 별 AIOE	한국표준직업분류		근로자 직종 정보	직종 평균 AIOE	
	111 의원·고위 공무원 및 공공단체 임원 ... 139 기타 전문 서비스 관리자		관리직		
	211 생명 및 자연과학 관련 전문가 ... 288 문화·예술 관련 기획자 및 매니저		전문직 (기술직 포함)		
	311 행정 사무직 ... 399 고객 상담 및 기타 사무원		사무직		
	411 경찰·소방 및 교도 관련 종사자 ... 442 식음료 서비스 종사자		서비스직		
	510 영업 종사자 ... 532 방문 및 노점 판매 관련직		판매직		
	710 식품가공 관련 기능 종사자 ... 899 기타 기계 조작원		생산직		
	910 건설 및 광업 단순 종사자 ... 999 기타 서비스 관련 단순 종사자		단순직		
	〈직종별 AIOE 원자료〉		〈사업체패널〉		

자료: 저자 작성.

〈부표 2〉는 7개 직종의 AIOE 대표값을 구한 것이다. Felten의 방식에 따라 구한 AI 노출도는 인지 노동의 노출도가 높게 측정되는 경향이 있다. 평균 인공지능 직업 노출도가 가장 높은 직종은 사무직이고 관리직과 전문직, 판매직은 그다음으로 높게 나타났다. 반면 생산직과 서비스직, 단순직은 이론적 기대에 맞게 상대적으로 낮게 나타났다.

〈부표 2〉 AIOE의 직종별 대표값

직 종	AIOE
관리직	0.618367
전문직	0.621769
사무직	0.636765
서비스직	0.578409
판매직	0.617983
생산직	0.558010
단순직	0.564768

자료 : 저자 계산.

개별 사업체의 인공지능 직업 노출도를 구하기 위해 〈부표 2〉의 평균값을 (2)에 직접 대입하여 사업체패널에서 생성한 사업체별 직업구성비와 곱해주면 사업체패널의 전체 레코드 1만 5,485 건에 대해 사업체 AIOE를 구할 수 있다.

$$\forall i : AIOE_i = S_{i1} \times (0.618367) + S_{i2} \times (0.6212769) + S_{i3} \times (0.6367658) + S_{i4} \times (0.578409) + S_{i5} \times (0.6179838) + S_{i6} \times (0.5580104) + S_{i7} \times (0.564768)$$

그러나 본 연구에서는 몇 가지 이유에서 이러한 단순병합 방법을 보다 정교화하였다. 가장 큰 이유는 이 방법이 직종 내에서 나타나는 업종 간 차이를 무시하므로 값의 변이가 지나치게 감소하기 때문이다. 예를 들어 아래의 〈부표 3〉은 업종별 관리직의 AIOE 평균을 나타낸 것이다.

〈부표 3〉을 보면 같은 관리직 안에서도 업종마다 AIOE 값이 크게 차이난다는 사실을 알 수 있다. 업종마다 관리직의 AIOE 평균은 최소 0.585에서 최대 0.657까지 분포하는데, 단순병합 방법은 이를 0.618 단일값으로 평균화해서 사업체별 AIOE 노출도를 계산하므로 직종 내의 업종 간 차이를 충분히 반영하지 못한다. 「한국노동패널조사」에서 나타나는 관리직의 직업소분류 빈도를 업종별로 살펴보면 같은 직종 안에서도 업종별로 왜 이러한 차이가 나타나는지를 알 수 있다.

〈부표 3〉 업종별 관리직 인공지능 직업 노출도의 평균 분포

업 종	평균 AIOE
공공행정, 국방 및 사회보장 행정	0.657
우편 및 통신업	0.650
컴퓨터 프로그래밍, 시스템 통합 및 관리업	0.650
개인 및 소비용품 수리업	0.650
금융 및 보험관련 서비스업	0.648
금융업	0.648
보험 및 연금업	0.648
출판업	0.647
전문 서비스업	0.643
기타 전문, 과학 및 기술 서비스업	0.640
사업시설 관리 및 조경 서비스업	0.600
...	
전문직별 공사업	0.597
종합 건설업	0.594
화학물질 및 화학제품 제조업; 의약품 제외	0.594
기타 기계 및 장비 제조업	0.592
담배 제조업	0.591
인쇄 및 기록매체 복제업	0.591
비금속 광물 제품 제조업	0.591
1차 금속 제조업	0.591
기타 운송장비 제조업	0.591
수도사업	0.591
하수, 폐수 및 분뇨 처리업	0.585

자료 : 한국노동연구원, 「한국노동패널조사」.

〈부표 4〉를 보면 같은 관리직 대분류에 속하고 있더라도 업종마다 종사하고 있는 관리 직종의 직업 소분류 목록 구성은 무척 상이하다. 따라서 〈부표 4〉에서 확인되는 직종 내 업종 간 인공지능 직업 노출도 평균 차이는 주로 업종-대분류 직종 교차 셀에 포함되는 소분류 직업의 목록 구성 차이에 의해 나타난 것이라고 할 수 있다.

〈부표 4〉 업종별 관리직의 직업 소분류 빈도표

업 종	직업 소분류	빈도	AIOE
의복, 의복 액세서리 및 모피제품 제조업	121 행정 및 경영 지원 관리자	9	0.646
	141 건설, 전기 및 생산 관련 관리자	6	0.590
	151 판매 및 운송 관리자	13	0.633
	전 체	28	0.627
보험 및 연금업	112 기업 고위 임원	4	0.649
	121 행정 및 경영 지원 관리자	7	0.646
	132 보험 및 금융 관리자	52	0.648
	전 체	63	0.647
사업 시설 관리 및 조정 서비스업	139 기타 전문 서비스 관리자	6	0.639
	153 환경, 청소 및 경비 관련 관리자	15	0.584
	전 체	21	0.599
컴퓨터 프로그래밍, 시스템 통합 및 관리업	135 정보 통신 관련 관리자	8	0.649
	전 체	8	0.649

주: * 업종별 '총계' 항목은 소분류 직업의 표본 빈도를 반영하여 계산한 업종별 인공지능 직업 노출도의 평균임.

자료: 한국노동연구원, 「한국노동패널조사」.

아래에서는 이러한 업종별 소분류 직업 구성 차이를 반영하기 위한 방법을 검토한다. 앞서 확인한 것처럼 모든 업종에서 직종별 AIOE가 동일하다고 가정하면 동일 직종 내에서 나타나는 업종 간 차이가 제거됨에 따라 인공지능 직업 노출도 값의 변이가 사라지게 되는 한계가 있다. 이러한 정보 손실을 최소화하기 위해, 본 연구에서는 업종마다 대분류 직종의 집계된 평균(aggregate mean)을 각각 구하였다. 업종별로 각 직종의 AIOE 대표값인 $\overline{AIOE_{jk}}$ 를 계산한 뒤 「사업체패널자료」에서 각 사업체의 업종 및 직종별 근로자 수 정보에 연결하면 사업체의 AI 노출도를 다음과 같이 계산할 수 있다.

$$\forall i: AIOE_i = \sum_{j=1}^7 \sum_{k=1}^{68} (s_{ij} \times \overline{AIOE_{jk}}) \quad (4)$$

〈부표 5〉 컴퓨터 프로그래밍, 시스템 통합 및 관리업의 직종

직 종	직업 소분류
관리직	135 정보 통신 관련 관리자
전문직	221 컴퓨터 하드웨어 및 통신공학 전문가
전문직	222 컴퓨터 시스템 및 소프트웨어 전문가
전문직	223 데이터 및 네트워크 관련 전문가
전문직	224 정보 시스템 및 웹 운영자
전문직	274 감정·기술 영업 및 중개 관련 종사자
전문직	285 디자이너
사무직	312 경영 관련 사무원
사무직	313 회계 및 경리 사무원
사무직	399 고객 상담 및 기타 사무원
서비스직	431 운송 서비스 종사자
생산직	761 전기·전자기기 설치 및 수리원
생산직	771 정보 통신기기 설치 및 수리원

자료 : 한국노동연구원, 「한국노동패널조사」.

단, 인공지능 직업 노출도는 직종 수준에서 계산되는 자료이므로 「사업체 패널자료」의 업종 정보인 한국표준산업분류(KSIC)와 연계된 정보가 원자료에 존재하지 않는다. 따라서 본 연구에서는 산업-직업 교차셀의 인공지능 직업 노출도 대표값을 계산하기 위한 표본으로 「한국노동패널조사」를 이용하였다. 표본 데이터를 사용하는 가장 큰 이유는 업종별로 포함되는 소분류 직종들의 분포를 선형적으로 알 수 없기 때문이다.

예를 들어, 〈부표 5〉는 “컴퓨터 프로그래밍, 시스템 통합 및 관리업” 업종 안에 다양한 직종이 포함되어 있음을 보여준다. 이처럼 직업 소분류의 이름을 보고 직종의 업종 포함 여부를 결정하는 것은 지나치게 임의적일 우려가 있다.

따라서 본 연구에서는 업종별로 포함되는 소분류 직종들의 분포를 알기 위해 실제 표본의 분포를 활용하였다. 노동패널자료에서 업종마다 포함되는 직종들의 목록을 추출한 뒤, 해당 직종들의 AIOE 값 평균을 계산하였다. 예를 들어 참고 및 운송관련 서비스 업종에서의 AI 노출도는 아래 〈부표 6〉과 같이 계산된다.

〈부표 6〉 참고 및 운송관련 서비스업의 직종별 AIOE 값

대분류명	소분류명	AIOE	셀 평균
관리직	151 판매 및 운송 관리자	0.6333	0.6333
전문직	224 정보 시스템 및 웹 운영자 234 전기·전자공학 기술자 및 시험원 236 소방·방재 기술자 및 안전 관리원 238 항공기·선박 기관사 및 관제사 271 인사 및 경영 전문가 274 감정·기술 영업 및 중개 관련 종사자 285 디자이너	0.6296 0.6123 0.6170 0.6052 0.6417 0.6250 0.6158	0.6209
사무직	311 행정 사무원 312 경영 관련 사무원 313 회계 및 경리 사무원 314 비서 및 사무 보조원 330 법률 및 감사 사무 종사자 392 여행·안내 및 접수 사무원 399 고객 상담 및 기타 사무원	0.6400 0.6331 0.6435 0.6450 0.6502 0.6357 0.6375	0.6407
서비스직	412 경호 및 보안 관련 종사자 431 운송 서비스 종사자	0.5708 0.5883	0.5796
판매직	510 영업 종사자 521 매장 판매 종사자 531 통신 관련 판매직	0.6386 0.6112 0.6346	0.6281
생산직	743 용접원 752 운송장비 정비원 753 기계장비 설치 및 정비원 761 전기·전자기기 설치 및 수리원 762 전기공 771 정보 통신기기 설치 및 수리원 799 기타 기능 관련 종사자 862 전기 및 전자설비 조작용 873 자동차 운전원 874 물품 이동 장비 조작용 875 건설 및 채굴기계 운전원	0.5661 0.5752 0.5585 0.5784 0.5685 0.5831 0.5717 0.5771 0.5769 0.5656 0.5577	0.5708
단순직	921 하역 및 적재 단순 종사자 922 배달원 941 청소원 및 환경미화원 942 건물 관리원 및 검표원 953 판매 관련 단순 종사자 992 계기·자판기 및 주차 관리 종사자	0.5552 0.5631 0.5501 0.6103 0.5866 0.6027	0.5780

자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 계산.

이렇게 구한 참고 및 운송관련 서비스 업종의 AI 노출도를 사업체패널에서 해당 업종의 어떤 기업 f의 21년도 관측치에 대해 예시적으로 계산하면 아래와 같다.

참고 및 운송관련 서비스업 사업체 f의 AI 노출도

=참고 및 운송관련 서비스업 관리직 셀 평균×기업 f 관리직 직종구성비
+...+ 참고 및 운송관련 서비스업 단순직 셀 평균×기업 f의 단순직 직종
구성비

$$=0.6333 \times 0.0088594 + 0.6209 \times 0.0188261 + 0.5796 \times 0.1838317 + 0.5796 \times 0 + 0.6281 \times 0 + 0.5708 \times 0 + 0.5780 \times 0.7884828 = 0.579592$$

〈부표 7〉은 업종 68개와 대분류 직종 7개를 교차해 만든 476개 산업-직업 셀별 AIOE 대표값의 전체 목록이다. KSIC 산업 분류 가운데 농업, 임업, 어업, 석탄 원유 및 천연가스 광업, 비금속광물 광업, 광업 지원 서비스업 및 가구 내 고용활동은 「사업체패널조사」 자료에 포함되어 있지 않으므로 제외하였다. 붉게 표시한 셀은 ‘제조업’, ‘참고 및 운송업’ 등 대분류 업종의 평균으로 대체하였다.

〈부표 7〉 산업-직업 교차 셀 대표값 목록

코드	업종	관리직	전문직	사무직	서비스	판매직	생산직	단순직
10	식품 제조업	0.6120	0.6240	0.6379	0.5641	0.6155	0.5692	0.5702
11	음료 제조업	0.6333	0.6272	0.6383	0.5727	0.6386	0.5772	0.5623
12	담배 제조업	0.5908	0.6194	0.6331	0.5709	0.6386	0.5668	0.5594
13	섬유제품 제조업	0.6234	0.6209	0.6383	0.5641	0.6249	0.5659	0.5695
14	의복, 의복액세서리 및 모피제품 제조업	0.6234	0.6250	0.6380	0.5670	0.6281	0.5659	0.5594
15	가죽, 가방 및 신발 제조업	0.6120	0.6189	0.6414	0.5709	0.6249	0.5678	0.5659
16	목재 및 나무제품 제조업	0.6120	0.6220	0.6383	0.5709	0.6112	0.5691	0.5686
17	펄프, 종이 및 종이제품 제조업	0.6120	0.6244	0.6383	0.5708	0.6249	0.5728	0.5686
18	인쇄 및 기록매체 복제업	0.5908	0.6245	0.6397	0.5709	0.6386	0.5711	0.5632
19	코크스, 연탄 및 석유정제품 제조업	0.6120	0.6220	0.6383	0.5709	0.6305	0.5622	0.5566
20	화학물질 및 화학제품 제조업	0.6184	0.6253	0.6405	0.5641	0.6249	0.5702	0.5757
21	의료용 물질 및 의약품 제조업	0.6333	0.6233	0.6385	0.5709	0.6305	0.5738	0.5763
22	고무제품 및 플라스틱제품 제조업	0.6184	0.6234	0.6405	0.5674	0.6249	0.5693	0.5807

〈부표 7〉의 계속

코드	업 종	관리직	전문직	사무직	서비스	판매직	생산직	단순직
23	비금속 광물제품 제조업	0.5908	0.6189	0.6393	0.5670	0.6386	0.5619	0.5668
24	1차 금속 제조업	0.5908	0.6241	0.6405	0.5708	0.6386	0.5686	0.5675
25	금속가공제품 제조업	0.6120	0.6200	0.6393	0.5708	0.6249	0.5637	0.5674
26	전자부품, 컴퓨터, 영상, 음향 및 통신장비제조업	0.6184	0.6206	0.6405	0.5794	0.6386	0.5692	0.5650
27	의료, 정밀, 광학기기 및 시계 제조업	0.6120	0.6208	0.6405	0.5641	0.6386	0.5652	0.5738
28	전기장비 제조업	0.6120	0.6209	0.6380	0.5709	0.6249	0.5688	0.5743
29	기타 기계 및 장비 제조업	0.6184	0.6204	0.6405	0.5641	0.6386	0.5694	0.5675
30	자동차 및 트레일러 제조업	0.6264	0.6223	0.6380	0.5883	0.6386	0.5696	0.5661
31	기타 운송장비 제조업	0.5908	0.6185	0.6383	0.5883	0.6305	0.5643	0.5573
32	가구 제조업	0.6120	0.6185	0.6397	0.5709	0.6281	0.5631	0.5659
33	기타 제품 제조업	0.6120	0.6218	0.6380	0.5709	0.6366	0.5684	0.5686
34	산업용 기계 및 장비 수리업	0.6120	0.6220	0.6374	0.5641	0.6228	0.5655	0.5594
35	전기, 가스, 증기 및 공기조절 공급업	0.6184	0.6229	0.6391	0.5708	0.6386	0.5774	0.5799
36	수도사업	0.5908	0.6345	0.6393	0.5708	0.6386	0.5687	0.5877
37	하수, 폐수 및 분뇨 처리업	0.5847	0.6200	0.6365	0.5641	0.6386	0.5652	0.5501
38	폐기물 수집운반, 처리 및 원료재생업	0.6184	0.6222	0.6405	0.5641	0.6386	0.5647	0.5711
39	환경 정화 및 복원업	0.5878	0.6296	0.6389	0.5674	0.6386	0.5690	0.6027
41	종합 건설업	0.6287	0.6228	0.6408	0.5674	0.6386	0.5613	0.5728
42	전문직별 공사업	0.6184	0.6175	0.6391	0.5670	0.6281	0.5644	0.5561
45	자동차 및 부품 판매업	0.6333	0.6137	0.6389	0.5685	0.6281	0.5718	0.5756
46	도매 및 상품 중개업	0.6234	0.6225	0.6408	0.5670	0.6203	0.5664	0.5691
47	소매업; 자동차 제외	0.6333	0.6197	0.6403	0.5700	0.6203	0.5677	0.5743
49	육상 운송 및 파이프라인 운송업	0.6333	0.6215	0.6403	0.5864	0.6249	0.5712	0.5731
50	수상 운송업	0.6333	0.6174	0.6405	0.5848	0.6199	0.5663	0.5591
51	항공 운송업	0.6333	0.6052	0.6379	0.5883	0.6112	0.5752	0.5501
52	창고 및 운송관련 서비스업	0.6333	0.6235	0.6407	0.5796	0.6281	0.5708	0.5767
55	숙박업	0.6026	0.6160	0.6374	0.5800	0.6155	0.5596	0.5802
56	음식점 및 주점업	0.6026	0.6145	0.6397	0.5871	0.6155	0.5723	0.5744
58	출판업	0.6408	0.6229	0.6389	0.5708	0.6249	0.5807	0.5745
59	영상·오디오 기록물 제작 및 배급업	0.6371	0.6161	0.6393	0.5708	0.6112	0.5729	0.5802
60	방송업	0.6343	0.6218	0.6397	0.5708	0.6196	0.5646	0.5802
61	우편 및 통신업	0.6495	0.6221	0.6378	0.5708	0.6281	0.5733	0.5867
62	컴퓨터 프로그래밍, 시스템 통합 및 관리업	0.6495	0.6221	0.6380	0.5883	0.6346	0.5808	0.5824
63	정보서비스업	0.6495	0.6208	0.6397	0.5883	0.6346	0.5808	0.5824

〈부표 7〉의 계속


코드	업 종	관리직	전문직	사무직	서비스	판매직	생산직	단순직
64	금융업	0.6472	0.6238	0.6399	0.5708	0.6281	0.5494	0.5802
65	보험 및 연금업	0.6478	0.6277	0.6389	0.5861	0.6366	0.5711	0.5877
66	금융 및 보험관련 서비스업	0.6483	0.6328	0.6411	0.5884	0.6366	0.5619	0.5798
68	부동산업	0.6154	0.6236	0.6391	0.6082	0.6203	0.5650	0.5752
70	연구개발업	0.6353	0.6225	0.6407	0.5674	0.6333	0.5685	0.5700
71	전문서비스업	0.6430	0.6247	0.6403	0.5641	0.6281	0.5718	0.5666
72	건축 기술, 엔지니어링 및 기타 과학 기술 서비스업	0.6154	0.6217	0.6398	0.5708	0.6386	0.5689	0.5496
73	기타 전문, 과학 및 기술 서비스업	0.6399	0.6179	0.6408	0.5808	0.6333	0.5609	0.5496
74	사업시설 관리 및 조경 서비스업	0.6123	0.6180	0.6405	0.5870	0.6249	0.5661	0.5752
75	사업지원 서비스업	0.6198	0.6217	0.6387	0.5838	0.6203	0.5668	0.5719
76	임대업; 부동산 제외	0.6161	0.6198	0.6383	0.6033	0.6194	0.5687	0.5498
84	공공행정, 국방 및 사회보장 행정	0.6476	0.6195	0.6394	0.5868	0.6098	0.5634	0.5743
85	교육 서비스업	0.6343	0.6216	0.6397	0.5836	0.6177	0.5666	0.5726
86	보건업	0.6357	0.6227	0.6394	0.5775	0.6203	0.5671	0.5770
87	사회복지 서비스업	0.6303	0.6161	0.6391	0.5815	0.6112	0.5649	0.5768
90	창작, 예술 및 여가관련 서비스업	0.6343	0.6167	0.6391	0.5813	0.6170	0.5661	0.5669
91	스포츠 및 오락관련 서비스업	0.6026	0.6167	0.6389	0.5850	0.6229	0.5573	0.5713
94	협회 및 단체	0.6427	0.6266	0.6386	0.5838	0.6228	0.5725	0.5760
95	개인 및 소비용품 수리업	0.6495	0.6250	0.6389	0.5832	0.6249	0.5694	0.5738
96	기타 개인 서비스업	0.6026	0.6113	0.6391	0.5844	0.6281	0.5696	0.5719
99	국제 및 외국기관	0.6587	0.6401	0.6344	0.5838	0.6228	0.5676	0.5760

자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 계산.

〈부표 7〉의 대표값을 식 (4)에 대입하면 개별 사업체의 AI 노출도를 계산할 수 있다. 차이가 있지만 원자료의 분포를 비슷하게 재현하는 것이 확인된다.

이처럼 본 연구에서는 직종 대분류 수준에서 인공지능 직업 노출도를 단순 병합하지 않고, 업종과 직종을 교차한 476개 셀의 대표값을 이용함으로써 업종별 차이를 상세히 반영하였다. 이렇게 구한 사업체의 인공지능 직업 노출도 값은 개별 사업체의 직종별 고용인원에 따라 기업 수준에서 변이한다. 또한, 업종마다 관찰되는 실제 소분류 직종들의 평균적인 AI 노출도를 활용하였기 때문에 해당 업종에서 주로 나타나는 세부 직종들의 AI 노출도 수준을 대표하고 있다.

〈부표 8〉 사업체별 AIOE와 AIOE 원자료의 분포 비교



척도	N	Mean	SD	Min	Max
사업체 AIOE	15,280	0.60101	0.020372	0.565854	0.649509
AIOE 원자료	141	0.596586	0.032784	0.520050	0.671398

자료: 사람인과 잡코리아에 게시된 구인공고 데이터를 활용하여 저자 계산.

〈부록 2〉 상관관계 표

		AIOE	자동화	업력	외국인	기업 규모	벤처 기업	조직률	경쟁	수요	제조업							
AIOE 자동화 업력 외국인 기업규모 벤처기업 조직률 경쟁 수요 제조업	1																	
	0.4933	1																
	0.0436	0.0975	1															
	0.0233	0.1107	0.0831	1														
	0.0124	-0.0762	-0.0031	0.1935	1													
	-0.0064	-0.0304	-0.2696	-0.007	0.039	1												
	-0.1284	-0.0447	0.3179	0.1267	0.1032	-0.0625	1											
	-0.0472	0.0288	-0.0156	-0.0436	-0.056	-0.0007	0.117	1										
	-0.0652	-0.0156	0.1059	-0.0386	-0.0454	-0.0413	0.0629	-0.0098	1									
	-0.2358	0.3906	0.017	0.0845	-0.1177	-0.0342	-0.1105	0.0344	0.0515	1								
	AIOE	사무직 곡선	생산직 곡선	서비스 곡선	사무직 호봉	생산직 호봉	서비스 호봉	사무직 승진	생산직 승진	서비스 승진	복리후 생/인원	복리후 생/매출	정규직 비율	신규/ 전체	신규/ 정규	정규/ 신규	정규/ 경력	정규/ 전체
AIOE 사무직 곡선 생산직 곡선 서비스 곡선 사무직 호봉 생산직 호봉 서비스 호봉 사무직 승진 생산직 승진 서비스 승진 복리후 생/인원 복리후 생/매출 정규직 비율 신규/ 전체 신규/ 정규 정규/ 신규 정규/ 경력 정규/ 전체	1																	
	0.1294	1																
	0.1181	0.6926	1															
	0.1146	0.9036	0.7439	1														
	0.1208	0.0236	-0.0006	0.0281	1													
	0.1288	0.058	0.0342	0.0633	0.6686	1												
	0.0745	0.0276	0.0017	0.0389	0.8714	0.6783	1											
	-0.0343	0.0299	0.0215	-0.0039	0.1861	0.1282	0.1483	1										
	0.1342	0.0378	0.0332	0.0194	0.1723	0.1698	0.1417	0.6346	1									
	-0.009	0.0218	0.0194	-0.0151	0.1923	0.1602	0.1554	0.8245	0.6748	1								
	0.1887	0.1225	0.0836	0.1064	0.0217	0.0638	0.0401	0.0216	0.0508	-0.0139	1							
	0.0088	0.0343	0.0026	0.0158	0.083	0.049	0.0812	0.0352	0.026	0.0158	0.3672	1						
	0.0249	0.0282	0.0296	0.0334	-0.0731	-0.0449	-0.0909	0.0458	-0.0628	-0.0025	0.056	-0.0688	1					
	-0.1886	-0.1031	-0.0689	-0.0626	0.061	0.1033	0.0454	-0.0145	-0.0201	-0.0109	-0.1102	0.0124	-0.1497	1				
	-0.1746	-0.0791	-0.0616	-0.0416	0.048	0.0813	0.0273	-0.0215	-0.0419	-0.0415	-0.1093	-0.0259	0.0055	0.8825	1			
	-0.0452	-0.0043	0.0307	0.0014	-0.0381	-0.0978	-0.0625	0.0365	-0.0578	-0.0249	-0.048	-0.1151	0.5335	-0.1016	0.1912	1		
	-0.0126	0.0085	0.0682	0.0248	-0.0507	-0.0536	-0.0739	0.0867	0.015	0.0659	0.004	-0.0194	0.3959	0.0168	-0.1013	0.4426	1	
	-0.0248	-0.0017	0.0508	0.0167	-0.0646	-0.1254	-0.0986	0.0631	-0.036	0.0032	-0.0388	-0.112	0.5811	-0.1166	0.08	0.9135	0.6442	1

제 7 장

결 론

제1절 연구 결과

본 연구는 인공지능의 발전이 일자리 감소와 불평등에 미치는 영향을 탐구한다. AI가 사람이 해 오던 일의 일부를 대신하거나 도와주는 세상은 이미 도래하였으며, 앞으로 이러한 추세는 지속될 것이다. 이러한 현상은 고용에 영향을 미칠 수밖에 없다. AI 기술의 발전이 완성되고 그 영향력이 노동시장에도 모두 반영된 상태가 아니라는 점 또한 분명하다. 본 연구는 2024년 시점에서 AI 기술 발전이 고용에 어떤 영향을 미치고 있는지 분석하였다.

1. AI 노출도와 고용

제3장에서는 AI 노출도(Exposure Rate)를 측정하고, 노출도에 따른 고용과 임금의 차이를 분석했다. 국내외 연구에서 소개된 AI 노출도를 측정하는 방법은 여러 가지가 있다. 각각의 측정 지표들을 서로 비교하면서 그 의미를 추적했다.

AI가 기술적으로 인간 노동에 잠재적으로 영향을 미칠 수 있지만, 현실에서는 인간과 사회의 판단에 따라 AI의 적용이 달라질 수 있다. 직업의 사회적 책무성이나 중요도, 사회적 상호작용 등을 더 많이 필요로 하는 직업일

수록, AI가 그 직업의 과업과 비슷한 일을 할 수 있을지라도, 인간과 사회는 AI에 모든 것을 맡기지 않을 것이다. 이러한 점을 고려하여, 직업의 중요성, 책무성 등의 측면에서 AI가 인간 노동을 보완할 것이라는 점을 반영하여 조정된 AI 노출도(adjusted AI exposure rate)를 검토했다.

AI 기술은 인지적 숙련(cognitive skill)을 대체하는 경향이 있으므로 전문직이나 사무직 일자리에 고용이 줄어들 수 있다는 우려가 제기되어 왔다. 전형적인 AI 노출도는 이러한 우려를 뒷받침한다. 그러나 본 연구에서 추가적으로 측정한 ‘조정된 AI 노출도’는, 비일상적(non-routine) 인지적 숙련을 대표하는 전문직은 AI가 대체하기 어려운 반면, 일상적(routine) 인지적 숙련과 관련성이 높은 사무직은 AI 대체 가능성이 높은 것으로 나타났다.

AI와 GPT가 기술적인 측면에서는 고임금 일자리에 더 많은 영향을 줄 수 있지만, 직업의 책무성, 중요성, 사회적 의사소통까지를 고려한다면, AI와 GPT는 오히려 저임금 일자리를 먼저 대체할 가능성이 높다고 판단된다. 자동화의 가능성도 관리 전문직보다는 판매직, 생산직, 단순직 등에서 높을 것으로 판단된다.

AI가 일자리에 미치는 영향을 단순히 ‘대체’ 여부에만 주목하지 않고, 자동화(automation)와 증강(augmentation, 또는 보완)의 관점에서 살펴보았다. 직업은 여러 가지 과업(tasks)으로 구성되어 있고, AI가 하는 역할은 이 중에 특정한 과업을 대신하는 것이다. 직업을 구성하는 과업 중에서 일부 과업만을 AI가 대신한다면, 그 직업은 전체적으로 자동화되어 사라지는 것이 아니라 증강을 통해 생산성이 향상되는 경험을 하게 될 것이다.

우리나라 일자리의 9.8%는 AI 기술로 인한 자동화(automation)로 대체 가능성이 높은 것으로 나타났으며, 15.9%는 AI를 활용하여 생산성을 높이는 증강(augmentation) 잠재력이 있는 것으로 나타났다. 다른 나라와 비교하여 살펴볼 때, 증강과 자동화 잠재력 모두 상대적으로 높은 편이다. 사무직에서 자동화 잠재력이 높고, 전문직에서 증강 잠재력이 높게 나타났다.

2. AI 도입률과 고용

제4장에서는 기업의 AI 도입 여부에 따른 고용영향을 분석했다. 기업의

온라인 구인공고에 나타난 AI 관련 숙련수요를 보고 기업의 AI 기술 도입 여부를 판단했다. 어떤 회사가 AI 관련 숙련(skill)을 보유하고 있는 인력을 채용하려는 구인공고를 냈다면, 이 회사는 AI 기술을 도입한 것으로 본다는 조작적 정의를 사용하였다. 온라인 구인공고를 사업체별로 식별하고 고용보협DB 자료를 결합한 결과, 2023년 기준으로는 13만여 개의 사업체가 분석에 활용되었다.

전체 사업체의 약 4% 정도가 AI를 도입한 것으로 나타나서, 아직까지 AI가 기업에 폭넓게 적용되고 있다고 보기는 어렵다. 하지만 대기업 중에는 도입한 기업이 많다. 1,000인 이상 사업체의 41%, 300인 이상~1,000인 미만 사업체의 23%가 AI 기술을 도입한 것으로 보인다. 종사자의 AI 노출도와 기업의 AI 도입률은 정(+)의 상관관계가 있는 것으로 나타났다. AI가 사람의 일을 대신할 수 있는 정도가 큰 직종의 근로자로 구성된 회사일수록 AI 기술을 도입하는 경향이 높은 것은 당연한 현상이다.

AI를 도입하는 기업은 고용을 줄일까? 기존 연구와 비슷하게 우리 분석에서도, 적어도 현재까지는 기업의 AI 도입이 고용을 줄이지는 않는 것으로 나타났다. 다만, 이러한 현상이 앞으로도 계속될 것인지는 지켜볼 필요가 있다. AI 기술이 확산하여 더 많은 기업이 AI를 도입하는 시기가 오면, 그때는 AI를 자동화 기술, 노동비용 절감 목적으로 사용하게 될 수 있다.

AI 도입 사업체와 미도입 사업체의 직종별 신규채용 인원을 살펴보았다. 인공지능이 인지적 숙련(cognitive skill)을 대신하기 때문에, 전문직, 관리직, 사무직의 과업을 대체할 것이라는 가설을 생각해 볼 수 있다. 즉, AI를 도입한 기업은 미도입 기업에 비해서 관리직, 전문직, 사무직 신규채용이 적은지 살펴보았다. 분석 결과는 이러한 가설을 지지하지 않는다. AI가 현실에서 관리 기능, 전문직의 과업, 사무직 과업을 본격적으로 대체하고 있는 단계에 들어가지는 않은 것으로 해석할 수 있다.

3. AI 도입과 생산성

제5장에서는 기업의 AI 도입이 생산성에 미치는 영향을 분석했다.

AI가 생산성에 미치는 영향은 낙관론과 비관론이 교차한다. 작업의 자동

화, 예측의 정확성 향상으로 인한 불확실성 감소, 기존 혁신과 새로운 혁신 간 재조합을 통해 활용되는 AI 기술의 파괴적 성격이 생산성 향상에 기여할 것이라는 낙관론이 한편에 존재한다(Brynjolfsson et al., 2019; Agrawal et al., 2019; Cockburn et al., 2019). 다른 한편에는, 불평등 증가, 학습 비용, 다른 범용 기술과 비교해 상대적으로 낮은 AI의 파괴적 성격 등으로 생산성 둔화가 지속될 것으로 예상하는 비관론이 있다(Gries and Naudé, 2018; Jones, 2009; Gordon, 2018).

이 장에서는 통계청이 제공하는 「기업활동조사」 데이터(2017~2022년)를 활용한다. 이 데이터에는 AI 도입 여부를 질문하는 문항이 포함되어 있으며, 기업의 생산성을 측정하는 지표들도 포함되어 있다. 횡단면 풀링 자료와 균형 패널자료를 구축하여 분석하였으며, 다음과 같은 분석 결과를 도출하였다.

첫째, 횡단면 풀링 자료를 이용한 AI의 생산성 효과 분석은 IV 추정과 EP를 적용한 IV 회귀분석에서 정(+)의 AI의 생산성 효과가 관측되었다.

둘째, 2017~2022년 주업종을 변경하지 않은 전체 기업을 대상으로 균형 패널을 구축하여 AI의 생산성 효과를 추정한 결과, 임의 효과 IV와 HTE 모형에서 정(+)의 AI의 생산성 효과가 관측되었다. 임의 효과 IV와 HTE 모형에서는 고정효과 모형과 달리 산업 더미와 같이 시간 불변 변수 추정이 가능하다. 이러한 점에서 산업에 따른 기업 간 차이나 이질성이 AI의 생산성 효과에 크게 영향을 미쳤다고 볼 수가 있을 것이다.

셋째, 패널 모형에서 종속변수를 노동생산성 변화율로 하면, 이러한 AI의 노동생산성 변동 효과는 통계적으로 유의하게 확인되지 않는다. 이처럼 연도별 자료를 이용하면 노동생산성 변화율이 연도별로 심하게 변동할 수 있으므로 안정적인 통계 추정이 쉽지 않을 수가 있다. 따라서 수준과 변화율 변수 모두를 고려할 경우, AI의 노동생산성 효과는 일부 모형에서만 관측되는 것으로 결론 내린다.

AI는 초기 확산 단계에 있으므로 산업별로 기업별로 다양하게 이용되고 있지만, 상당한 편차가 있는 것으로 보인다. 이 분석의 추정 결과가 보여주는 바는 산업에 따른 기업 간 이질성이 AI의 생산성 효과에 크게 영향을 미치고 있다는 것이다.

4. AI 기술 발전과 내부노동시장

제6장에서는 「사업체패널자료」를 이용하고 노출도 측정을 기업 단위에 적용하여, AI 기술 발전의 압력이 기업의 내부노동시장 구조에 어떤 변화를 초래하는지 분석한다. 종사자의 직종 구성을 알 수 있다면, AI 노출도를 기업 단위에 적용할 수 있다. 이 척도는 기업의 인력 운용에 AI 기술 발전이 가하는 압력을 반영한다.

AI 및 자동화에 대한 노출이 큰 기업들은 연공형 임금체계와 같은 기존 내부노동시장 제도를 유지하는 데 어려움을 겪을까? 아니면, AI 및 자동화의 압력에 대처하기 위해 기존의 내부노동시장 제도를 더욱 강화하게 될까?

「사업체패널자료」 분석 결과, 한국 기업의 AI 노출도는 고숙련 정규직 노동자를 다수 고용하는 산업에서 더 높게 나타난다. 회귀분석 결과에 따르면, 우리나라 기업의 AI 노출도는 내부노동시장과 밀접한 관련이 있음을 알 수 있다. 이는 인과적 관계는 아니지만, 내부노동시장 메커니즘을 발전시킨 기업일수록 AI 노출도가 높은 시장 환경에 보다 적극적으로 적응할 유인이 있을 것으로 예상할 수 있다.

연공급이 보다 성과지향으로 적응된 기업들, 연공급 테이블이 존재하는 기업들, 복지 지출의 관대함과 정책의 세밀함이 높은 기업들, 자동승급제를 채택하고 있는 기업들이 높은 AI 노출도와 연관되어 있었다. 높은 인공지능 노출도가 반드시 높은 인공지능 채택률을 의미하는 것은 아니지만, 본 연구는 그럴 가능성이 높다고 본다.

필자들은 AI 도입이 RBTC(기술이 노동을 대체하는 방향)보다는 SBTC(기술이 노동의 숙련도를 높이는 방향)를 통한 숙련 강화(reinstatement)를 가속화할 가능성이 높다고 본다. 즉, 대기업들이 AI에 대한 투자를 늘려 기업 특유의 역량을 육성하고, 이를 통해 정규직 직원의 특권이 더욱 강화될 수 있다. 이렇게 되면, AI에 기반한 생산성 혁명을 통해 대기업 정규직과 중소기업 종사자 및 비정규직과의 격차는 더욱 벌어질 것이다.

제2절 시사점

AI가 노동에 미치는 잠재적 영향을 기술적 측면으로만 볼 경우, 고임금-고속런 노동에 더 많은 영향을 줄 것으로 예상되지만, 직업의 책무성, 중요성, 사회적 대인관계를 고려하면서 그 영향을 전망해 보면, 저임금-저속런 노동에 더 큰 부정적인 영향을 미칠 수 있다. AI도 앞서 보아온 기술 발전과 마찬가지로 숙련편향적인(SBTC) 형태의 결과를 초래할 수 있다는 시사점을 던진다.

그러나 AI의 발전은 아직 초기 단계에 있다. 향후 어떤 형태로 발전하느냐, 그리고 사회가 어떤 방식으로 AI를 수용하느냐에 따라 그 영향력은 크게 달라질 수 있다. 본 연구에서 검토한 결과는 이러한 기술 발전과 사회의 인식, 대응과 적응 방식에 따라서 달라질 수 있는 잠정적인 결과로 인식해야 한다.

AI 기술의 발전이 전체 고용의 총량을 감소시키는 상황을 상상할 수 있지만, 아직 그런 조짐은 보이지 않는다. 하지만 일부 직종은 AI로 인해 타격을 받을 것이다. 특히, 일부 직종은 AI 기술 덕분에 생산성 향상을 경험할 것이기 때문에 불평등은 심화할 것이다. 사라지는 일자리에 대한 대응, 불평등 심화에 대한 대응은 정책의 최우선 순위가 되어야 한다.

AI는 범용 기술(General Purpose Technology)이다. 영향 범위가 매우 넓다. 거의 모든 일자리에서 요구되는 역량이 변화하게 될 것이다. 교육과 직업훈련의 관점이 근본적으로 변화해야 하는 시점이다.

신기술이 등장하면 이것을 잘 활용할 수 있도록 직업능력 훈련이 함께 발전해야 한다. 과거, 포디즘의 대량생산체계가 등장했을 때 자동화가 인간을 완전히 대체한 것이 아니라, 수리와 유지 보수와 같은 다양한 업무가 창출되었으며, 이를 위해 노동자에게는 새로운 교육이 필요했다. AI 시대도 다르지 않다.

참고문헌

- 김경훈 · 최중범 · 한은영 · 윤성욱 · 안명욱 · 이영중... & 장지화(2021), 『AI 국가 경쟁력 확보를 위한 중장기 로드맵 구축 연구. 정책연구』, pp.1~288.
- 김성환 · 도연우 · 홍진근(2019), 「4차 산업혁명(4th Industrial Revolution)에 의한 기술 혁신 역량이 한국 기업의 수출 성과에 미치는 영향 : 기업 차원의 OFDI 중력 모형을 이용하여」, 『무역연구』 15 (4), pp.443~463.
- 김의중(2016), 『인공지능, 머신러닝, 딥러닝 입문』, 위키북스.
- 노용진 · 원인성(2003), 「내부노동시장의 성격과 비정규직 고용의 비율」, 『노동정책연구』 3 (2), pp.47~67.
- 뉴 사이언티스트 · 닉 보스트롬 · 넬로 크리스티아니니 · 존 그레이엄-커밍 · 피터 노빅 · 엔더스 샌드버그 · 토비 월시 지음. 김정민 역(2018), 『기계는 어떻게 생각하고 학습하는가』, 한빛미디어. New Scientist(2017), Machines that Think. New Scientist.
- 데이비드 드 크리머(2022), 『다음 팀장은 AI입니다』 박단비 역. 위즈덤하우스. David de Cremer(2020), Leadership by Algorithm. Harriman House Ltd.
- 박순찬(2019), 「4차 산업혁명 핵심 디지털 기술의 이용과 중소기업의 총요소 생산성」, 『중소기업정책연구』, 2019년 겨울호, pp.3~33.
- 송단비 · 조재한 · 최민철 · 김한훤(2021), 『기업의 인공지능 활용과 생산성 연구』. 연구보고서 2021-12. 산업연구원.
- 여영준 · 정성문 · 신기윤 · 정현민(2021), 「디지털전환 시대 기술진보 편향성과 거시경제적 효과 파급경로에 대한 고찰」, 『한국혁신학회지』 16 (4), pp.325~353.
- 이승민 · 신기윤 · 이정동(2022), 「기업의 4차 산업혁명 기술 도입과 생산성 간 관계 연구 : 절대적 수준과 상대적 위치」, 『한국혁신학회지』 17 (3),

- pp.251~279.
- 이철승·정준호·전병유(2020), 「세대·계급·위계 II : 기업 내 베이비 부머/386 세대의 높은 점유율은 비정규직 확대, 청년 고용 축소를 초래하는가?」, 『한국사회학』 54 (2), pp.1~58.
- 장지연(2024), 「직종별 AI 노출도」, 한국노동연구원. 『노동리뷰』 2024년 5월호.
- 전병유·정준호·장지연(2022), 「인공지능(AI)의 고용과 임금 효과」, 『경제연구』 40 (1), pp.133~156.
- 정소라·성낙일(2024), 「우리나라 기업의 자동화 기술 도입이 고용량과 임금에 미친 영향에 관한 실증 분석」, 『한국은행 경제연구원 경제분석』 30 (2).
- 정승국(2021), 「한국 내부노동시장의 성격과 비정규직 활용」, 『노동정책연구』 21 (4), pp.63~87.
- 제리 카플란(2024), 정미진 역, 『생성형 AI는 어떤 미래를 만드는가』, 한스미디어. Jerry Kaplan(2024), “Generative Artificial Intelligence : What Everyone Needs to Know”, Oxford University Press.
- 한요셉(2023), 「인공지능으로 인한 노동시장의 변화와 정책방향」, KDI 연구보고서.
- 한지우·오삼일(2023), 「AI와 노동시장 변화」, 『BOK 이슈노트』, 한국은행.
- Acemoglu, D.(2002), “Technical change, inequality, and the labor market”, *Journal of Economic Literature* 40 (1), pp.7~72.
- _____(2024), “The Simple Macroeconomics of AI”, National Bureau of Economic Research.
- Acemoglu, D., and D. H. Autor(2011). “Skills, tasks and technologies : Implications for employment and earnings”, In O., Ashenfelter & D. E. Card (ed.), *Handbook of Labor Economics*, Vol. 4B, Elsevier, pp.1043~1171.
- Acemoglu, D., and J. Loebbing(2022), “Automation and polarization”, National Bureau of Economic Research.

- Acemoglu, D. and P. Restrepo(2018), “Artificial intelligence, automation”, In *The economics of artificial intelligence : An agenda*, University of Chicago Press, pp.197~236.
- _____(2019), “The wrong kind of AI? Artificial intelligence and the future of labor demand” NBER Working Paper No. 25682.
- _____(2019), “Automation and new tasks : How technology displaces and reinstates labor” *Journal of Economic Perspectives* 33 (2), pp.3~30.
- _____(2020), “The wrong kind of AI? Artificial intelligence and the future of labour demand”, *Cambridge Journal of Regions, Economy and Society* 13 (1), pp.25~35.
- _____(2022a), “A task-based approach to inequality”, IFS Deaton Review of Inequalities.
- _____(2022b), “Tasks, automation, and the rise in US wage inequality” *Econometrica* 90 (5), pp.1973~2016.
- Acemoglu, D., D. Autor, J. Hazell and P. Restrepo(2022), “Artificial intelligence and jobs : Evidence from online vacancies”, *Journal of Labor Economics* 40 (S1), pp.S293~S340.
- Aghion, P., B. F. Jones, and C. I. Jones(2019), “Artificial intelligence and economic growth”, In A. Agrawal, J. Gans and A. Goldfarb (eds.). *The Economics of Artificial Intelligence : An Agenda*. Chicago : University of Chicago Press, pp.237~282 .
- Agrawal, A., J. Gans and A. Goldfarb(2017), What to expect from artificial intelligence.
- Agrawal, A., J. S. Gans and A. Goldfarb(2019), “Artificial intelligence : the ambiguous labor market impact of automating prediction”, *Journal of Economic Perspectives* 33 (2), pp.31~50.
- Agrawal, A., J. S. Gans and A. Goldfarb(2019), “Exploring the impact of artificial intelligence : Prediction versus judgment”, *Information Economics and Policy* 47, pp.1~6.
- Agrawal, A., J. S. Gans and A. Goldfarb(eds.)(2019), *The Economics of*

- Artificial Intelligence : An Agenda*. Chicago : University of Chicago Press.
- Alchian, A. Armen and Harold Demsetz(1972), "Production, Information Costs, and Economic Organization," *The American Economic Review* 62 (5), pp.777~795.
- Alderucci, D., L. Branstetter, E. Hovy, A. Runge and N. Zolas(2020), "Quantifying the impact of AI on productivity and labor demand : Evidence from US census microdata", *In Allied social science associations-ASSA 2020 annual meeting*.
- Alekseeva, L., J. Azar, M. Giné, S. Samila and B. Taska(2021), "The demand for AI skills in the labor market," *Labour economics* 71, 102002.
- Althausen, Robert P. and Arne L. Kalleberg(1981), "Firms, occupations, and the structure of labor markets : A conceptual analysis," *Sociological perspectives on labor markets* 8, pp.119~149.
- Arntz, M., T. Gregory and U. Zierahn(2016), "The risk of automation for jobs in OECD countries : A comparative analysis", OECD Social, Employment and Migration Working Paper No. 189, OECD Publishing
- Autor, D(2022), "The labor market impacts of technological change : From unbridled enthusiasm to qualified optimism to vast uncertainty", National Bureau of Economic Research.
- Autor, D. H. and D. Dorn(2013), "The growth of low-skilled service jobs and the polarization of the U.S. labor market", *American Economic Review* 103 (5), pp.1553~1597.
- Autor, D. H., F. Levy and R. J. Murnane(2003), "The skill content of recent technological change : An empirical exploration", *The Quarterly Journal of Economics* 118 (4), pp.1279~1333.
- Autor, D. H., L. F. Katz and A. B. Krueger(1998), "Computing inequality : Have computers changed the labor market?", *The Quarterly Journal of Economics* 13 (4), pp.1169~1213.
- Autor, D. H., L. F. Katz and M. S. Kearney(2006), "The polarization of the

- U.S. labor market”, *American Economic Review* 96 (2), pp.189~194.
- Autor, D., A. Salomons and B. Seegmiller(2023), Patenting with the stars: Where are technology leaders leading the labor market?.
- Autor, D., C. Chin, A. Salomons and B. Seegmiller(2022), “New frontiers : The origins and content of new work, 1940~2018”. *The Quarterly Journal of Economics*, qjae008.
- Autor, D., C. Goldin and L. F. Katz(2020), “Extending the Race between Education and Technology,” *In AEA Papers and Proceedings 110*, pp.347~351.
- Aw, B. and A. Hwang(1995), “Productivity and the Export Market : A Firm-level Analysis,” *Journal of Development Economics* 47, pp.315~332.
- Babecky, J., P. Du Caju, T. Kosma, M. Lawless, J. Messina, and T. Room(2009), “Downward nominal and real wage rigidity : Survey evidence from European firms”, *National Bank of Belgium Working Paper* 182, November 2009.
- Babina, T., A. Fedyk, A. He and J. Hodson(2024), “Artificial intelligence, firm growth and product innovation”, *Journal of Financial Economics* 151, 103745.
- Babina, T., A. Fedyk, A. X. He and J. Hodson(2020), “Artificial Intelligence, Firm Growth, and Industry Concentration”, *SSRN Scholarly Paper ID 3651052*, Social Science Research Network, Rochester, NY.
- Bäck, A., A. Hajikhani, A. Jäger, T. Schubert and A. Suominen(2022), “Return of the Solow-paradox in AI? : AI-adoption and firm productivity”, *Papers in Innovation Studies 2022/1*, Lund University.
- Baker, George, and Bengt Holmstrom(1995), “Internal labor markets : Too many theories, too few facts,” *The American Economic Review* 85 (2), pp.255~259.
- Baldwin, J. R. and M. Rafiquzzaman(1998), “The Determinants of the Adoption Lag for Advanced Manufacturing Technologies,” *Statistics Canada Working Paper*, 117.

- Becker, Gary S.(1964), *Human Capital : A Theoretical and Empirical Analysis, with Special Reference to Education*, Chicago : University of Chicago Press.
- Bernhardt, Dan(1995), "Strategic Promotion and Compensation," *The Review of Economic Studies*, pp.315~339.
- Bloom, N., C. I. Jones, J. Van Reenen, M. Webb(2020), "Are ideas getting harder to find?" *American Economic Review* 110 (4), pp.1104~1144.
- Braverman, H.(1974), *Labor and monopoly capital*, Monthly Review Press.
- Braverman, Harry(1998), *Labor and Monopoly Capital : The Degradation of Work in the Twentieth Century*, NYU Press, <http://www.jstor.org/stable/j.ctt9qfrkf>.
- Bresnahan, T. F., E. Brynjolfsson and L. M. Hitt(2002), "Information technology, workplace organization, and the demand for skilled labor : firm-level evidence," *Quarterly Journal of Economics* 117 (1), pp. 339~376.
- Brynjolfsson, E. and A. McAfee(2014), *The Second Machine Age : Work, Progress, and Prosperity in a Time of Brilliant Technologies*, New York : W. W. Norton & Company .
- Brynjolfsson, E. and L. Hitt(1993), Is information systems spending productive? New evidence and new results.
- Brynjolfsson, E. and L. M. Hitt(2003), "Computing productivity: firm-level evidence," *The Review of Economics and Statistics* 85 (4), pp.793~808.
- Brynjolfsson, E.(2023), "The turing trap : The promise & peril of human-like artificial intelligence", In *Augmented education in the global age*, pp.103~116.
- Brynjolfsson, E., D. Rock and C. Syverson(2019), "Artificial Intelligence and the Modern Productivity Paradox : A Clash of Expectations and

- Statistics,” In National Bureau of Economic Research (ed.), *The Economics of Artificial Intelligence : An Agenda*, pp.23~57.
- _____(2021), “The productivity J-Curve : how intangibles complement general purpose technologies,” *American Economic Journal : Macroeconomics* 13 (1), pp.333~372.
- Brynjolfsson, E., T. Mitchell and D. Rock(2018), “What can machines learn and what does it mean for occupations and the economy?”. *In AEA papers and proceedings* 108, pp.43~47.
- Brzeski, C. and I. Burk(2015), “Die Roboter kommen, Folgen der Automatisierung für den deutschen Arbeitsmarkt”, *INGDiBa Economic Research* 30.
- Calvino, F. and L. Fontanelli(2023), “A portrait of AI adopters across countries : Firm characteristics, assets’ complementarities and productivity,” OECD Science, Technology and Industry Working Papers, 2023/02.
- Cardona, M., T. Kretschmer and T. Strobel(2013), “ICT and productivity : conclusions from the empirical literature,” *Information. Economics and Policy* 25 (3), pp.109~125.
- Cathles, A., G. Nayar and D. Rückert(2020), “Digital Technologies and Firm performance : Evidence from Europe,” EIB Working Papers No. 2020/06. European Investment Bank, Luxembourg.
- Chang, Ha-Joon(1993), “The political economy of industrial policy in Korea,” *Cambridge Journal of Economics* 17 (2), pp.131~157.
- Cho, Jaehan Timothy DeStefano, Hanhin Kim, Inchul Kim and Jin Hyun Paik(2023), “What's driving the diffusion of next-generation digital technologies?”, *Technovation* 119, 102477.
- Coad, A., A. Segarra and M. Teruel(2016), “Innovation and firm growth : does firm age play a role?”, *Research. Policy* 45 (2), pp.387~400.
- Cockburn, I. M., R. Henderson and S. Stern(2019), “The impact of artificial intelligence on innovation : an exploratory analysis,” In A. Agrawal, J.

- Gans and A. Goldfarb (eds.), *The Economics of Artificial Intelligence : An Agenda*. Chicago : University of Chicago Press, pp.115~146.
- Corrado, C., J. Haskel and C. Jona-Lasinio(2021), "Artificial intelligence and productivity : an intangible assets approach," *Oxford Review of Economic Policy* 37 (3), pp.435~458.
- Criscuolo, C. and J. Timmis(2017), "The relationship between global value chains and productivity," *International Productivity Monitor* 32, pp. 61~83.
- Czarnitzki, D., G. P. Fernández and C. Rammer(2023), "Artificial intelligence and firm-level productivity," *Journal of Economic Behavior and Organization* 211, pp.188~205.
- Damioli, G., V. Van Roy and D. Vertesy(2021), "The impact of artificial intelligence on labor productivity", *Eurasian Business Review* 11, pp.1~25.
- Damioli, G., V. Van Roy, D. Vertesy and M. Vivarelli(2023), "AI technologies and employment : micro evidence from the supply side", *Applied Economics Letters* 30 (6), pp.816~821.
- De Prato, G., M. L. Cobo, S. Samoli, R. Righi, M. V. P. Baillet and M. Cardona(2019), The AI techno-economic segment analysis, Joint Research Centre(Seville site).
- Dell'Acqua, F., E. McFowland III, E. R. Mollick, H. Lifshitz-Assaf, K. Kellogg, S. Rajendran, L. Kraye, F. Candelon, and K. R. Lakhani(2023), "Navigating the Jagged Technological Frontier : Field Experimental Evidence of the Effects of AI on Knowledge Worker Productivity and Quality", *Harvard Business School Technology & Operations Mgt. Unit Working Paper* 24-013(September 15, 2023).
- DeStefano, T., R. Kneller and J. Timmis(2020), "Cloud Computing and Firm Growth," CESifo Working Paper No. 8306.
- DeVaro, Jed(2006), "Strategic promotion tournaments and worker performance," *Strategic Management Journal* 27 (8), pp.721~740.

- Doeringer, Peter B. and Michael J. Piore(1971), "Internal Labor Markets and Manpower Analysis", Armonk, NY : M. E. Sharpe.
- Eisfeldt, A. L., G. Schubert and M. B. Zhang(2023), Generative AI and firm values, National Bureau of Economic Research.
- Eloundou, T., S. Manning, P. Mishkin and D. Rock(2023), "Gpts are gpts : An early look at the labor market impact potential of large language models", arXiv preprint arXiv:2303.10130.
- Engberg, E.(2024a), Artificial intelligence, hiring and employment : Job postings evidence from Sweden, Working Paper.
- _____(2024b), AI unboxed and jobs : A novel measure and firm-level evidence from three countries, RF Berlin-CReAM Discussion Paper Series.
- Felten, E. W., M. Raj and R. Seamans(2018), "A method to link advances in artificial intelligence to occupational abilities", *In AEA Papers and Proceedings* 108, pp.54~57.
- Felten, E. W., M. Raj and R. Seamans(2019), *The occupational impact of artificial intelligence : Labor, skills, and polarization*, NYU Stern School of Business.
- _____(2021), "Occupational, industry, and geographic exposure to artificial intelligence : A novel dataset and its potential uses", *Strateg. Manag. J.* 42 (12), pp.2195~2217.
- _____(2023a), "Occupational Heterogeneity in Exposure to Generative AI".
- _____(2023b), "How will Language Modelers like Chat GPT Affect Occupations and Industries?".
- Filippi, E., M. Banno and S. Trento(2023), "Automation technologies and their impact on employment : A review, synthesis and future research agenda", *Technological Forecasting and Social Change* 191, 122448.
- Fossen, F. M. and A. Sorgner(2019), *New digital technologies and heterogeneous employment and wage dynamics in the United States : Evidence from individual-level data*.

- Frey, C. B. and M. A. Osborne(2013), "The future of employment" working paper. Oxpord Martin School, University of Oxford.
- _____(2017), "The future of employment : How susceptible are jobs to computerisation?", *Technological Forecasting and Social Change* 114, pp.254~280.
- Fujii, Hidemichi and Managi, Shunsuke(2018), "Trends and priority shifts in artificial intelligence technology invention : A global patent analysis," *Economic Analysis and Policy* 58, pp.60~69.
- Furman, J. and R. Seamans(2019), "AI and the Economy," *Innovation policy and the economy* 19 (1), pp.161~191.
- Georgieff, A. and R. Hyee(2021), "Artificial intelligence and employment : New cross-country evidence", OECD Social, Employment and Migration Working Papers 265, OECD Publishing, Paris.
- Gibbons, Robert and Michael Waldman(2006), "Enriching a theory of wage and promotion dynamics inside firms," *Journal of Labor Economics* 24 (1), pp.59~107.
- Gibbs, J. L. and K. L. Kraemer(2004), "A cross-country investigation of the determinants of scope of e-commerce use : an institutional approach," *Electrononic Market* 14 (2), pp.124~137.
- Gmyrek, P., J. Berg and D. Bescond(2023), "Generative AI and jobs : A global analysis of potential effects on job quantity and quality," ILO Working Paper 96.
- Gmyrek, Paweł, Hernan Winkler, and Santiago Garganta(2024), "Buffer or Bottleneck?", *World Bank Group, Policy Research Paper* 10863.
- Goldfarb, A., B. Taska and F. Teodoridis(2020), "Could Machine Learning Be a General Purpose Technology? : A Comparison of Emerging Technologies Using Data from Online Job Postings."
- Goldin, C., and L. F. Katz(2008), "The race between education and technology", Harvard University Press, Belknap.
- _____(2010), The career cost of family. In Sloan Conference on Workforce

- Flexibility. Washington, DC.
- Goos, M. and A. Manning(2007), “Lousy and lovely jobs : The rising polarization of work in Britain”, *The review of economics and statistics* 89 (1), pp.118~133.
- Goos, M., A. Manning and A. Salomons(2009), “Job polarization in Europe”, *American economic review* 99 (2), pp.58~63.
- _____(2014), “Explaining job polarization : Routine-biased technological change and offshoring”, *American Economic Review* 104 (8), pp. 2509~2526.
- Gordon, Andrew(1985), *The Evolution of Labor Relations in Japan : Heavy Industry, 1853~1955*, Havard Unive Press.
- Gordon, R. J.(2018), “Why has economic growth slowed when innovation appears to be accelerating?.” NBER Working Paper No. 24554.
- Green, A. and L. Lamby(2023), “The supply, demand and characteristics of the AI workforce across OECD countries”, OECD Social, Employment and Migration Working Papers, 287, OECD Publishing, Paris.
- Gries, Thomas and Naudé, Wim(2018), “Artificial intelligence, jobs, inequality and productivity: Does aggregate demand matter?.” MERIT Working Papers 2018-047.
- Griffith, R., S. Redding and H. Simpson(2002), “Productivity Convergence and Foreign Ownership at the Establishment Level,” CEPR Discussion Paper 3765.
- Grimshaw, D. and J. Rubery(1998), The Concentration of Women’s Employment and Relative Occupational Pay, In host publication.
- Growiec, J.(2022), *Accelerating Economic Growth : Lessons From 200,000 Years of Technological Progress and Human Development*, Brrlin: Springer.
- Hainmueller, J.(2012), “Entropy balancing for causal effects : a multivariate reweighting method to produce balanced samples in observational studies,” *Political Analysis* 20 (1), pp.25~46.

- Halaby, Charles N.(2004), "Panel models in sociological research : Theory into practice," *Annu. Rev. Sociol.* 30 (1), pp.507~544.
- Hall, Peter A., and David Soskice(2001), "An introduction to varieties of capitalism," *Debating varieties of capitalism : A reader*, pp.21~74.
- Harris, M. and B. Holmstrom(1982), "A Theory of Wage Dynamics," *Review of Economic Studies* 49, pp.315~333.
- Haskel, J. and S. Westlake(2017), *Capitalism Without Capital. The Rise of the Intangible Economy*, Princeton : Princeton University Press .
- Hausman, J. A. and W. E. Taylor(1981), "Panel Data and Unobservable Individual Effects," *Econometrica* 49 (6), pp.1377~1398.
- Hötte, K., T. Tarannum, V. Verendel and L. Bennett(2022), "Exploring Artificial Intelligence as a General Purpose Technology with Patent Data- A Systematic Comparison of Four Classification Approaches", *arXiv preprint*, arXiv:2204.10304.
- Huber, Peter J.(1967), "The behavior of maximum likelihood estimates under nonstandard conditions," *In Proceedings of the fifth Berkeley symposium on mathematical statistics and probability* 1 (1), pp.221~233.
- Iansiti, M. and K. R. Lakhani(2020), "Competing in the Age of AI : Strategy and Leadership when Algorithms and Networks Run the World." *Harvard Business Review*. January-February 2020. Harvard University.
- Jo, H. J., J. H. Jeong and C. Kim(2023), *Agile Against Lean*. Springer Books.
- Jones, B. F.(2009), "The burden of knowledge and the 'death of the renaissance man' : Is innovation getting harder?", *Review of Economic Studies* 7, pp.283~317.
- Katz, L. F. and K. M. Murphy(1992), "Changes in relative wages, 1963~1987 : Supply and demand factors," *The Quarterly Journal of Economics* 107 (1), pp.35~78.
- Katz, L. F., and D. H. Autor(1999), "Changes in the wage structure and

- earnings inequality”, In O., Ashenfelter & D. E. Card (ed.), *Handbook of Labor Economics* 3A, pp.1463~1555.
- Lane, M., M. Williams and S. Broecke(2023), “The impact of AI on the workplace : Main findings from the OECD AI surveys of employers and workers”, *OECD Social, Employment and Migration Working Papers* 288, OECD Publishing.
- Lazear, E. P. and Sherwin Rosen(1981), “Rank-order tournaments as optimum labor contracts,” *Journal of political Economy* 89 (5), pp.841~864.
- Lazear, E. P.(1998), *Personnel Economics for Managers*, New York : Wiley.
- Lazear, E. P., K. Shaw, G. Hayes and J. Jedras(2023), “Productivity and Wages : What Was the Productivity-Wage Link in the Digital Revolution of the Past, and What Might Occur in the AI Revolution of the Future?”, In *50th Celebratory Volume*(50), pp.191~253. Emerald Publishing Limited.
- Lee, Y. S., T. Kim, S. Choi and W. Kim(2022), “When does AI pay off? AI-adoption intensity, complementary investments, and R&D strategy.” *Technovation* 118, 102590.
- McKinsey and Company(2023) The economic potential of generative AI.
- McMullin, J. and Schonberger, B.(2022), “When good balance goes bad : A discussion of common pitfalls when using entropy balancing,” *Journal of Financial Reporting* 7 (1), pp.167~196.
- Medoff, James L., and Katharine G. Abraham(1981), “Are those paid more really more productive? The case of experience,” *Journal of Human resources*, pp.186~216.
- Milgrom, Paul, and John Roberts(1992), *Economics, Organization, and Management*, Englewood Cliffs, NJ : Prentice Hall.
- Nordhaus, W. D.(2021), “Are we approaching an economic singularity? Information technology and the future of economic growth,” *American Economic Journal : Macroeconomics* 13 (1), pp.299~332.
- OECD(2019), “Artificial Intelligence in Society”, Paris : OECD Publishing.

- Osterman, P. (ed.). (1984), "Internal Labor Markets: Theory and Change," *In Internal Labor Markets*, Edited by Paul Osterman, 3-39. Cambridge, MA : MIT Press.
- Pizzinelli, C., A. J. Panton, M. M. M. Tavares, M. Cazzaniga and L. Li(2023), "Labor market exposure to AI : Cross-country differences and distributional implications," International Monetary Fund.
- Primo DM, Jacobsmeier ML, Milyo J.(2007), "Estimating the Impact of State Policies and Institutions with Mixed-Level Data," *State Politics & Policy Quarterly* 7 (4), pp.446~459.
- Raudenbush, Stephen W.(2002), "Hierarchical linear models : Applications and data analysis methods," Advanced Quantitative Techniques in the Social Sciences Series/SAGE .
- Rosen, S.(1986), "Prizes and Incentives in Elimination Tournaments," *American Economic Review* 76, pp.701~715.
- Rosenbaum, James E.(1984), "Career Mobility in a Corporate Hierarchy," New York : Academic Press.
- Rosenfeld, Rachel A.(1992), "Job mobility and career processes," *Annual review of sociology* 18 (1), pp.39~61.
- Roy, V., D. Vertesy and G. Damioli(2020), "AI and robotics innovation," In K. F. Zimmermann (ed.). *Handbook of Labor, Human Resources and Population Economics*. Berlin : Springer, pp.1~35.
- Seamans, R. and M. Raj(2018), "AI, labor, productivity and the need for firm-level data", NBER Working paper 24239.
- Squicciarini, M., and H. Nachtigall(2021), "Demand for AI skills in jobs : Evidence from online job postings" OECD Science, Technology and Industry Working Papers 2021/03.
- Staiger, D. and J. Stock(1997), "Instrumental Variables Regression with Weak Instruments", *Econometrica* 65 (3), pp.557~586.
- Steenbergen, Marco R., Jones, Bradford S.(2002), "Modeling multilevel data structures," *Am. J. Polit. Sci.* 46 (1), pp.218~237.

- Svanberg, M., W. Li, M. Fleming, B. Goehring and N. Thompson(2024), "Beyond AI Exposure : Which Tasks are Cost-Effective to Automate with Computer Vision?", Available at SSRN 4700751.
- Taira, Koji(1970), *Economic development & the labor market in Japan*, Columbia University Press.
- Tambe, P., L. Hitt, D. Rock and E. Brynjolfsson(2020), "Digital Capital and Superstar Firms," NBER Working Paper No. 28285.
- Tinbergen, J.(1974), Substitution of graduate by other labour. *Kyklos* : international review for social sciences.
- Van Roy, V., D. Vertesy and G. Damolioli(2020), *AI and robotics innovation*, Springer International Publishing, pp.1~35.
- Waldman, Michael(1984), "Job assignments, signalling, and efficiency," *The RAND Journal of Economics* 15 (2), pp.255~267.
- Webb, M.(2019), "The impact of artificial intelligence on the labor market," Available at SSRN 3482150.
- WEF(2023), "Future of Jobs Report", World Economic Forum.
- White, Halbert(1980), "A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity," *Econometrica J. Econom. Soc.* 48, pp.817~838.
- Williamson, Oliver E.(1985), *The Economic Institutions of Capitalism*. New York, Free Press.
- Wright, E. O. and R. E. Dwyer(2003), "The patterns of job expansions in the USA : a comparison of the 1960s and 1990s", *Socio-Economic Review* 1 (3), pp.289~325.
- Zabojnik, Jan, and Dan Bernhardt(2001), "Corporate tournaments, human capital acquisition, and the firm Size-Wage relation," *The Review of Economic Studies* 68 (3), pp.693~716.

◆ 執筆陣

- 장지연(한국노동연구원 선임연구위원)
- 전병유(한신대학교 교수)
- 정준호(강원대학교 교수)
- 이철승(서강대학교 교수)
- 심지환(동양미래대학교 교수)
- 안성준(한신대학교 연구조교)

인공지능(AI) 발전의 고용효과

- | | |
|------------|--|
| ▪ 발행연월일 | 2024년 12월 26일 인쇄
2024년 12월 30일 발행 |
| ▪ 발 행 인 | 허 재 준 |
| ▪ 발 행 처 | 한국노동연구원
30147 세종특별자치시 시청대로 370
세종국책연구단지 경제정책동
☎ 대표 (044) 287-6081 Fax (044) 287-6089 |
| ▪ 조 판 · 인쇄 | 도서출판 창보 (02) 2272-6997 |
| ▪ 등 록 일 자 | 1988년 9월 13일 |
| ▪ 등 록 번 호 | 제2015-000013호 |

© 한국노동연구원 2024 정가 9,000원

ISBN 979-11-260-0746-2



한국노동연구원

30147 세종특별자치시 시청대로 370 경제정책동
TEL : 044-287-6083 <http://www.kli.re.kr>



9 791126 007462

ISBN 979-11-260-0746-2