철강 디지털 전환

가이드북

재료산업인적자원개발위원회
Material Industrial Skills Council

대표기관 한국철강협회

목 차

1. 서론
   - 1-1. 철강 산업 디지털 전환의 필요성 ---- 06
   - 1-2. 산업 환경 변화 및 정책 동향 ---- 08
   - 1-3. 교육 프로그램 개발의 필요성 ---- 10

2. 철강 산업의 디지털화 수준
   - 2-1. 제조 부문의 디지털화 수준 ---- 14
   - 2-2. 철강 산업의 디지털 기술 적용 사례 ---- 18
   - 2-3. 철강 산업의 디지털 기술 개발 방향 ---- 30

3. 디지털 전환을 위한 인공지능의 이해
   - 3-1. 인공지능 활용 대표적 모델의 종류 ---- 34
   - 3-2. 철강 산업 도메인 지식과 인공지능의 결합 ---- 40

4. 기술체계화 및 교육 프로그램 개발
   - 4-1. 철강 산업 디지털 기술교육 체계 ---- 44
   - 4-2. 교육과정 개발방법 ---- 48
   - 4-3. 수준별·직무별 교육과정 개발 가이드 ---- 52

5. 자격인증체계 및 국가직무능력표준
   - 5-1. 자격증 종류 소개 ---- 69
   - 5-2. NCS활용 자격 체계 구성 방안 ---- 77

6. 결론 ---- 84

참고 자료 ---- 86

비상업 목적으로 본 보고서에 있는 내용을 인용 또는 전재할 경우, 내용의 출처를 명시하면 자유롭게 인용하실 수 있으며, 보고서 내용에 대한 문의는 아래 연락처로 주시기 바랍니다.

<재료산업 인적자원개발위원회 사무국>
허지회 과장, jihie.her@ekosa.or.kr, 02-559-3566

표 목차

[표 1-1] 인공지능 AI기술의 업무 활용여부 ····· 8
[표 2-1] 인공지능(AI)기술 적용 필요성 인식 ····· 16
[표 2-2] 향후 3년내 인공지능(AI)기술 도입 계획 ····· 17
[표 4-1] 생산/조업 적용 예시 ····· 45
[표 4-2] 설비/정비 적용 예시 ····· 46
[표 4-3] 품질/안전 적용 예시 ····· 47
[표 4-4] 경영/지원 적용 예시 ····· 48
[표 4-5] 교육프로그램 설계안 ····· 53
[표 4-6] 설비/정비 직무 과정 개요 ····· 53
[표 4-7] 설비/정비 직무 요구분석 개요 ····· 53
[표 4-8] 설비/정비 직무 학습자 분석 개요 ····· 54
[표 4-9] 설비/정비 직무 수행자 분석 개요 ····· 54
[표 4-10] 설비/정비 직무 수행과제 분석 개요 ····· 54
[표 4-11] 설비/정비 학습목표 개요 ····· 55
[표 4-12] 설비/정비 커리큘럼 개요 ····· 55
[표 4-13] 설비/정비 평가도구 설계 ····· 56
[표 4-14] 설비/정비 교재 및 콘텐츠 개발 ····· 56
[표 4-15] 설비/정비 실습환경 구축 ····· 56
[표 4-16] 설비/정비 강사 가이드 개발 ····· 57
[표 4-17] 설비/정비 운영방식 ····· 57
[표 4-18] 설비/정비 파일럿 운영 계획 ····· 57
[표 4-19] 설비/정비 Kirkpatrick 4단계 평가 모델 적용 ····· 58
[표 4-20] 설비/정비 피드백/환류활동 예시 ····· 58
[표 4-21] 생산/조업 직무 교육과정 개요 ····· 58

[표 4-22] 생산/조업 직무 요구 분석 ····· 59
[표 4-23] 생산/조업 직무 학습자 분석 ····· 59
[표 4-24] 생산/조업 직무 환경 분석 ····· 59
[표 4-25] 생산/조업 직무 수행과제 분석 ····· 60
[표 4-26] 생산/조업 직무 커리큘럼 ····· 60
[표 4-27] 생산/조업 직무 강의계획서 예시 ····· 61
[표 4-28] 생산/조업 직무 평가 도구 설계 ····· 61
[표 4-29] 생산/조업 직무 교재 및 콘텐츠 개발 ····· 61
[표 4-30] 생산/조업 직무 실습 환경 구축 ····· 62
[표 4-31] 생산/조업 직무 강사가이드 개발 ····· 62
[표 4-32] 생산/조업 직무 운영 방식 ····· 62
[표 4-33] 생산/조업 직무 Kirkpatrick 4단계 평가 모델 적용 ····· 63
[표 4-34] 품질/안전 직무 교육과정 개요 ····· 63
[표 4-35] 품질/안전 직무 요구 분석 ····· 64
[표 4-36] 품질/안전 직무 학습자 분석 ····· 64
[표 4-37] 품질/안전 직무 환경 분석 ····· 64
[표 4-38] 품질/안전 직무 과제 분석 ····· 65
[표 4-39] 품질/안전 직무 커리큘럼 ····· 65
[표 4-40] 품질/안전 직무 세부 강의계획서 예시 ····· 66
[표 4-41] 품질/안전 직무 평가 도구 설계 ····· 66
[표 4-42] 품질/안전 직무 콘텐츠 개발 ····· 66
[표 4-43] 품질/안전 직무 실습환경 구축 ····· 67
[표 4-45] 품질/안전 직무 실행 단계 운영 방식 ····· 67
[표 4-46] 품질/안전 직무 Kirkpatrick 4단계 평가 모델 적용 ····· 68
[표 5-1] 자격증의 종류 ····· 69
[표 5-2] 인공지능모델링 NCS ····· 79

그림 목차

[그림 2-1] 생성형 AI 도입에 따른 산업별 연간 경제적 가치 창출 전망 15

[그림 2-2] AI 기술 필요성 인식 ····· 15

[그림 2-3] AI 기술 도입 계획 ····· 17

[그림 2-4] 딥러닝 기반의 AI 고로 제어 시스템 개념 ····· 19

[그림 2-5] POSCO의 연속 공정 특화 스마트 팩토리 플랫폼 ····· 20

[그림 2-6] Baowu Steel의 초광역 원격 제어 시스템 ····· 21

[그림 2-7] Nippon Steel의 전사 데이터 통합 구조도 ····· 22

[그림 2-8] 안전모 미착용 감지 ····· 25

[그림 2-9] 작업자 쓰러짐 감지 ····· 26

[그림 2-10] 영상 인식 로봇 ····· 29

[그림 2-11] 영상 인식 로봇(2) ····· 29

[그림 2-12] 크레인 자동 이송 AI ····· 30

[그림 3-1] 인공지능의 분류 ····· 34

[그림 4-1] 교수설계모형 ····· 48

1 서 론

1-1. 철강 산업 디지털 전환(DX)의 필요성

철강 산업의 디지털 전환 수준을 타 산업과 비교해보면, 해당 산업이 매우 독특한 위치를 점하고 있음을 확인할 수 있다. 보고서의 데이터를 기반으로 심층적으로 분석해보면, 철강업은 디지털 전환(DX: Digital Transformation)의 필요성과 중요성에 대한 인식 수준은 가장 높은 반면, 실제 전환 성과와 실행 수준은 가장 낮은 업종에 속하는 역설적 구조를 지니고 있다.

여기서 DX란 단순한 정보화나 자동화 수준을 넘어, 데이터·AI·디지털 기술을 활용하여 생산 방식, 의사결정 구조, 비즈니스 모델 전반을 근본적으로 재설계하는 변화 과정을 의미한다.

즉, 철강 산업은 디지털 기술이 향후 경쟁력 확보와 생존에 핵심적 요소라는 점을 충분히 인식하고 있음에도 불구하고, 이를 현장과 조직 전반에 실제로 구현할 수 있는 기반과 역량이 상대적으로 취약한 산업이라 할 수 있다. 이러한 점이 철강 디지털 전환의 핵심적 특징이자 구조적 한계로 작용하고 있다.

우선, 디지털 전환에 대한 인식 수준은 전 산업군 대비 최상위권에 속한다. 철강업 종사자들은 DX가 생산성 향상, 품질 안정화, 비용 절감, 그리고 글로벌 경쟁력 강화를 위한 핵심 수단임을 명확히 이해하고 있으며, 디지털 전환에 대한 인지도는 전체 산업 평균의 약 두 배 수준에 이르고 있다. 그러나 이러한 높은 인식이 곧바로 실질적인 실행력으로 연결되지는 않는다.

이는 노후 설비의 높은 비중, 고도로 복잡한 연속공정 중심의 제조 구조, 공정 중단이 어려운 운영 특성, 그리고 시스템 전면 개편 및 데이터 인프라 구축에 수반되는 막대한 비용과 위험 부담 등 철강 산업 고유의 구조적 제약에 기인한다. 그 결과, 디지털 전환의 필요성은 충분히 공감하고 있음에도 불구하고 실제 현장 적용과 성과 창출은 제한적인, 이른바 “인식은 높으나 실행은 낮은 디지털 전환 격차” 현상이 지속적으로 나타나고 있다.

데이터 활용 측면에서도 철강업은 디지털 전환을 가능하게 하는 기반 역량이 다른 제조업 대비 상당히 뒤처져 있다. 공정 데이터 자동 수집 비율은 6% 수준에

그치며, 전체 기업 중 절반 가까이가 데이터 품질관리에서 가장 낮은 단계에 머무르고 있다. 특히 철강 산업은 공정의 복잡성과 변수의 다양성이 매우 높은 산업으로, 충분히 수집되고 정제된 데이터 없이 고도화된 디지털 기술(AI, 자동제어, 품질 예측 등)을 적용하기 어렵다. 결국 철강업의 디지털 전환을 가로막는 핵심 병목은 기술의 부재가 아니라, 데이터를 기반으로 한 인프라의 미성숙에 있다.

AI 기술 활용 수준 역시 전 산업군 중 최저 수준이다. 실제 업무에 AI를 활용하는 철강 기업은 2%대에 불과하며, 이는 전체 업종 중 가장 낮다. AI를 도입하지 못하는 가장 큰 원인으로 내부 전문 인력 부족이 지목되며, 해당 비중은 68%로 전체 산업 중 가장 높은 수치를 기록한다. 철강업의 AI 적용에는 공정 이해와 데이터 분석 능력이 동시에 요구되기 때문에 일반적인 AI 인력만으로는 대응하기 어렵고, 이로 인해 적용 장벽이 더욱 높아진다. 따라서 철강업은 AI 활용도가 낮은 산업이 아니라, AI의 필요성이 크면서도 실제 적용 난이도 역시 높은 산업으로 평가할 수 있다.

한편, 디지털 기술이 국소적으로라도 적용된 영역에서는 탁월한 성과가 나타나고 있다. 업무 속도, 효율성, 프로세스 단순화 등 여러 지표에서 철강업은 전 업종 최고 수준의 개선 효과를 보이고 있다. 이는 철강업이 대규모 설비 기반의 에너지 집약적 산업으로서, 공정 최적화·자동제어·데이터 기반 의사결정이 도입될 경우 개선 효과가 비선형적으로 크게 발생하는 구조적 특성 때문으로 해석된다. 즉, 디지털 전환의 난이도는 높지만 그 효과는 매우 큰 산업이라는 점이 확인된다.

그럼에도 불구하고 실제 디지털 전환을 추진하는 철강 기업의 비중은 전체 평균의 절반 수준인 5%대에 머물고 있다. 이는 디지털 전환의 인식, 필요성, 효과 모두 높음에도 불구하고 이를 뒷받침할 실행 인프라(데이터 기반, 전문 인력, 조직 및 예산 구조, 리스크 관리 체계)가 충분히 구축되어 있지 않기 때문이다. 이러한 요인으로 인해 철강업은 “디지털 전환 잠재력이 가장 크고, 동시에 실제 추진은 가장 어려운 업종”이라는 평가가 가능하다.

종합하면, 철강 산업은 디지털 전환의 필요성을 명확히 인지하고 있으며 변화 의지 또한 강하지만, 데이터 인프라의 미성숙, 전문 인력의 부족, 공정 특성에 따른 높은 적용 난이도, 설비 중심의 산업 구조 등으로 인해 실제 디지털 전환 수준은 낮은 상태에 머물러 있다. 그러나 일단 디지털 기술이 적용될 경우 그 효과가 가장 크게 나타나는 산업이기 때문에, 향후 DX 투자가 본격화될 경우 전 산업군 중 가장 높은 효익을 창출할 잠재력을 지닌 분야라고 할 수 있다.

[표 1-1] 인공지능 AI기술의 업무 활용여부

특성별(1)	특성별(2)	2024	
		예	아니오
전체	소계	8.8	91.2
업종별	식음료 제조업	9.5	90.5
	섬유·의류 제조업	3.3	96.7
	석유·화학 제조업	6.3	93.7
	제약·의료기기 제조업	5.8	94.2
	고무·플라스틱 제품 제조업	9.1	90.9
	철강 제조업	2.3	97.7
	금속·비금속 제조업	4.5	95.5
	전자기기·전자부품 제조업	10.9	89.1
	기계 제조업	8.4	91.6
	자동차 및 자동차 부품 제조업	9.9	90.1
	전기장비 제조업	4.9	95.1
	선박 및 보트 건조업	7.2	92.8
	기타 제조업	9.7	90.3
	유통·물류	23.9	76.1
종사자규모별	5명 미만	4.7	95.3
	5~9명	6.2	93.8
	10~49명	15.0	85.0
	50~299명	26.2	73.8
	300명 이상	44.2	55.8

*출처 : 산업통상자원부 실태조사

1-2. 산업 환경 변화 및 정책 동향

국내 산업 전반은 디지털 기술의 발전과 시장·정책적 요구 변화에 직면하면서 구조적 전환을 요구받고 있다. 인공지능·빅데이터·클라우드 등 디지털 기반 기술은 산업 간 경계를 약화시키고 새로운 경쟁구조를 형성하고 있으며, 이러한 변화는 제조업을 중심으로 모든 산업 분야에 직접적인 영향을 미치고 있다.

산업 환경 변화를 살펴보면,

첫째, 시장 환경의 불확실성과 고객 요구 변화의 가속화가 두드러진다. 전반적으로 고객의 가격 민감도가 높고, 새로운 상품에 대한 수요가 크게 증가하고 있으며, 고객 기호 변화 폭도 확대되고 있다. 특히 철강업, 섬유/의류업 등 일부 업종에서는 시장 변동성 및 경쟁 강도를 기존보다 더 크게 체감하는 것으로 나타났다.

둘째, 기술 환경은 전 산업에서 급격한 변화 속도를 보이고 있다. 기업들은 필요한 기술이 빠르게 변화하며, 신규 기술 도입이 경영활동의 필수 요소로 자리잡았음을 공통적으로 인식하고 있다. 특히 디지털 기술의 발전 속도는 예측이 어렵고, 업종 간 기술 의존도가 심화되는 추세가 확인된다. 이러한 기술 변화는 기업 내부 시스템의 통합 및 자동화 수준 향상 요구로 이어지고 있다.

셋째, 경쟁 환경은 산업 디지털화 수준에 따라 차별적으로 강화되는 경향을 보인다. 대부분의 업종에서 경쟁 심화가 지속되며 가격 경쟁의 강도 역시 높게 나타난다. 특히 디지털 기술 도입도가 높거나 고객 접점 변화 속도가 큰 업종의 경우 경쟁 환경은 더욱 가속화되고 있다. 철강업·유통업 등은 경쟁 강도가 산업 평균보다 높은 것으로 나타났다.

정책 측면에서는, 산업계는 디지털 전환에 필요한 법·제도적 기반 마련과 정책 지원의 필요성을 명확히 인식하고 있으나 실제 지원 경험은 낮다. 다수 기업은 정책 지원을 필요로 함에도 불구하고 '어디서 지원받을 수 있는지 모름', '구체적 사업계획 수립 역량 부족' 등으로 인해 지원을 활용하지 못하는 실정이다.

디지털 전환 정책에 대한 수요는 '자금 지원 확대', '정보 제공 강화', '미래 전문인력 양성' 등 기본적 인프라 및 역량 확충 분야에 집중되고 있다.

아울러 기업은 데이터 협력·거래, AI 활용, 디지털 기술 도입 등에 있어 규제 및 지원 체계의 미비를 애로 요인으로 지적하고 있다. 특히 정부의 규제 환경과 관련하여, 디지털 혁신 과정에 일정 수준의 규제가 존재한다고 응답하는 비율이 높았으며, 이러한 규제는 기술 도입 및 산업 간 협력 활성화에 장애 요소로 작용하는 것으로 분석된다.

종합하면, 산업 환경은 시장·기술·경쟁 전 영역에서 빠르게 변화하고 있으며, 이에 대응하기 위한 체계적 디지털 전환 정책의 필요성이 지속적으로 증대되고 있다. 기업의 디지털 역량 격차가 확대되는 가운데, 정부 정책은 법·제도 정비, 자금 및 인력지원, 산업 데이터 생태계 구축 등 보다 구조적인 접근이 요구되고 있다.

1-3. 교육 프로그램 개발의 필요성

철강산업의 디지털 전환은 단순히 새로운 시스템을 도입하거나 일부 공정을 자동화하는 수준을 넘어, 고부하·고비용 구조라는 산업 특성 속에서 원가·품질·납기·ESG·안전을 동시에 향상시키기 위한 전사적 변화이다.

1-1에서 살펴본 것처럼 우리 철강산업 내부의 DX 수준은 아직 자동화·지능화·AI 활용 측면에서 제한적이며, 생산성·인력 구조 측면에서도 고령화, 숙련 단절, 수기 중심 데이터 관리 등 구조적 한계를 안고 있다. 1-2에서 정리한 글로벌 경쟁·시장·기술 환경 변화, 그리고 탄소 규제·ESG 강화, 디지털 전환을 선도하는 해외 철강사들의 전략을 고려하면, 이러한 격차를 줄이기 위해서는 설비·시스템 투자만으로는 충분하지 않으며, 디지털 전환을 실제로 기획·실행·확산할 수 있는 "사람과 조직 역량"을 체계적으로 키우는 것이 핵심 과제가 된다.

여기에 더해, 포스코 경영 연구원 이슈리포트 「글로벌 인재 위기, 현지 인력부족과 미스매치」에서 지적하듯이, 글로벌 인재 환경 자체가 구조적으로 악화되고 있는 점도 중요한 전제 조건이다. 전 세계적으로 숙련 인력 부족은 지난 10년간 빠르게 심화되어, 2013년에는 전 세계 고용주의 35%가 숙련 인재 확보에 어려움을 겪었으나 2024년에는 74%까지 급증하였다. 특히 헬스케어, 에너지·유틸리티, 정보기술 등 디지털 전환과 기후 대응이 가속되는 산업에서 인력난이 심각하며, 미국 제조·건설, 인도 IT 등 주요 산업·지역에서는 수백만 단위의 미충원 일자리가 발생할 것으로 예측되고 있다. 이 현상은 단순한 양적 인력 부족이 아니라, 산업·기술 변화 속도에 인력의 역량 전환이 따라가지 못하는 "질적 미스매치"라는 구조적 문제임을 보여준다.

OECD 국제 성인역량 조사(PIAAC) 결과에서도 나타나듯, 교육 수준은 높아졌지만 읽기·수리·문제해결 등 기본 역량은 제자리이거나 후퇴하고 있고, 한국을 포함한 주요국에서 스킬 과잉·스킬 부족·전공-직무 미스매치가 동시에 확대되고 있다. 맥킨지 등 글로벌 연구기관들은 앞으로의 인재상을 "디지털 역량과 고차원 인지·사회·감성 역량이 결합된 증강된 인재(Augmented Talent)", "특정 분야의 깊이와 다양한 분야 이해를 겸비한 T자형 인재"로 규정하고 있으며, 이런 인재를 확보하지 못하는 것이 기업 혁신의 핵심 제약 요인이라고 지적한다.

또한 지역별로 인재 위기 양상도 다르게 나타난다. 미국·유럽은 숙련 인력 경쟁이 가장 치열한 고비용·고위험 인재 시장이며, 일본·한국은 인구 감소와 고령화

에 따른 구조적 인력 부족, 중국・대만은 고학력 과잉과 직무 미스매치, 인도・동남아는 풍부한 인구에도 불구하고 실질 스킬 부족이라는 문제를 안고 있다.

이는 국내 시장의 한계를 넘어 미국, 인도, 동남아, 유럽 등으로 진출하는 우리 기업 입장에서 “필요한 인재를 외부에서 구매(Buying)하는 전략만으로는 더 이상 충분하지 않다”는 것을 의미한다. 포스코 경영연구원 리포트는 이에 대한 대응 방향으로, 외부 채용 중심에서 내부 육성(Building)과 현지 대학・교육기관・정부와의 파트너십(Partnering)을 통한 인력 생태계 구축으로의 전환을 제안하고 있다.

이러한 글로벌 인재 환경을 고려하면, 국내 철강산업의 디지털 전환 교육 프로그램은 단순히 “현재 인력의 디지털 이해도를 높이는 차원”을 넘어서,

(1) 국내외 사업장에서의 숙련 인력 부족・미스매치 리스크를 완화하고,

(2) 외부 채용 의존에서 벗어나 내부 인재 육성과 현지 인력 개발을 동시에 추진할 수 있는 기반을 만드는 역할을 수행해야 한다.

즉, DX 교육 프로그램은 철강업 특성에 맞는 디지털 역량 개발과 동시에 글로벌 인재 위기에 대한 기업 차원의 전략적 대응 수단으로 기능해야 한다.

이에 따라 교육 프로그램의 개발 목적은 다음과 같이 정리할 수 있다.

첫째, 철강산업 특성을 반영한 실질적 디지털 역량을 내재화하는 것이다.

고로・제강・압연・정정・물류 등 각 공정에서 생성되는 데이터를 이해하고, 이를 수집・정제・분석하여 조업・설비・품질・에너지 의사결정에 연결할 수 있는 능력을 키우는 것을 목표로 한다. 이를 통해 단순 IT 활용을 넘어, 현장과 디지털을 동시에 이해하는 실무 인력을 체계적으로 양성하고자 한다. 이는 외부에서 희귀한 ‘철강+디지털’ 복합 역량 인재를 비싼 비용으로 채용하는 대신, 내부 인력을 “증강된 인재(T자형 엔지니어)”로 전환시키는 전략적 의미를 가진다.

둘째, 디지털 전환 과제를 스스로 발굴・기획・추진할 수 있는 내부 추진 주체를 육성하는 것이다. 많은 기업이 DX 필요성은 인식하고 있으나, 구체적인 로드맵 수립과 사업성・효과 분석, 단계적 추진 전략에 어려움을 겪고 있다. 교육 프로그램은 데이터・AI・자동화・플랫폼 등 기술을 사업・공정 과제로 연결하고, PoC(Proof of Concept)–확산–내재화로 이어지는 추진 구조를 설계・관리할 수 있는 PM/PO 역량을 강화하는 데 목적을 둔다. 이는 글로벌 차원의 숙련 인력 부족으로 컨설턴트・외부 전문가에게 과도하게 의존하기보다는, 내부 DX 리더십을 구축하여 지속가능한 추진 체계를 만드는 기반이 된다.

셋째, 현장 숙련과 노하우, 안전 역량을 디지털 방식으로 전환·전수하는 기반을 마련하는 것이다. 고령 인력의 은퇴와 신규 인력 유입 감소로 인해 암묵지 형태의 조업·설비 노하우가 사라질 위험이 커지고, 중대재해에 대한 사회적 요구 수준도 높아지고 있다. 교육 프로그램을 통해 데이터·영상·센서 정보 등을 활용해 현장 지식을 구조화하고, 디지털 트윈·시뮬레이션·XR 등을 활용한 조업·안전 교육 모델을 설계할 수 있는 역량을 키움으로써, 인력·안전 리스크를 완화하는 "디지털 기반 학습·안전 체계"를 구축하고자 한다. 이는 숙련 인력의 절대적 부족과 고령화가 심화되는 일본·한국형 인력구조 문제에 대한 선제적 대응이기도 하다.

넷째, 에너지·탄소·환경 규제와 ESG 요구에 대응할 수 있는 데이터 기반 운영 역량을 확보하는 것이다. 에너지 다소비·탄소 다배출 산업인 철강에서 CBAM (Carbon Border Adjustment Mechanism) 등 글로벌 규제와 ESG 평가를 감당하기 위해서는 공정·설비·에너지·탄소 데이터를 계량적으로 이해하고, 이를 근거로 조업조건과 설비운영을 최적화할 수 있어야 한다. 본 교육은 에너지·탄소 데이터 관리의 기본 구조와 분석 방법, ESG 공시와 연계된 지표 체계를 이해하도록 하여, 환경·규제 대응력을 높이는 것을 지향한다. 동시에, 환경·에너지 관련 글로벌 전문 인력 부족이 심화되는 상황에서, 내부 인력을 통해 이러한 기능을 수행할 수 있도록 하는 "인재 구축(Building)" 전략의 핵심 수단이 된다.

다섯째, 디지털 기반 고객·비즈니스 모델 혁신을 준비하는 조직 역량을 기르는 것이다. 글로벌 OEM 고객들은 이제 가격·품질뿐 아니라 데이터 연계, 공급망 가시성, 공동 R&D, 저탄소·고효율 솔루션을 함께 제공할 수 있는 파트너를 선호하고 있다. 교육 프로그램은 철강제품과 공정 데이터를 기반으로 어떤 디지털 서비스와 솔루션이 고객 가치와 신규 수익을 창출할 수 있는지를 이해하고, 이를 기획할 수 있는 기초 역량을 확보하는 데 목적을 둔다. 이는 산업 간 경계가 허물어지고, 에너지·자동차·배터리·IT 등 다양한 산업이 동일한 디지털 인재를 놓고 경쟁하는 상황에서, 철강 내부 인력을 "고객 솔루션 기획 인재"로 전환시키는 전략적 수단이 된다.

여섯째, 전사적인 디지털 마인드셋과 협업 문화를 형성하는 것이다. 디지털 전환을 특정 부서나 프로젝트의 이슈가 아닌, 전 임직원의 공통 과제로 인식시키고, 공정·설비·품질·안전·ESG·영업 조직 간 협업을 자연스럽게 만들어 내는 것

이 중요하다. 교육 프로그램은 경영진에서부터 현장 리더·실무자에 이르기까지 각 계층별로 필요한 이해 수준과 역할을 명확히 하고, 데이터 기반 의사결정과 지속적 개선을 조직 문화로 정착시키는 것을 궁극적 목표로 삼는다. 더불어, 포스코경영 연구원 리포트에서 제시한 것처럼 외부 채용(Buying)에만 의존하지 않고, 내부 인재 육성(Building)과 현지 파트너십(Partnering)을 통해 글로벌 인력 생태계를 함께 만들어가는 장기 전략을 실행하기 위한 문화적·조직적 기반을 강화하는 데에도 그 목적이 있다.

2 철강 산업의 디지털화 수준

2-1. 제조 부문의 디지털화 수준

1 글로벌 AI 확산 및 시장 전망

1. 폭발적인 투자와 성장

(1) 기업 차원의 AI 활용 비율

(가) 시장 규모 확대 : IDC 등의 분석에 따르면, 글로벌 AI 시장은 단순한 파일럿 단계를 넘어 전 산업의 '지능형 혁신'을 주도하고 있다. 2027년까지 글로벌 AI 지출은 연평균 26.9% 성장하여 4,230억 달러 규모에 이를 것으로 전망 된다.

(나) 생성형 AI의 부상 : 특히 생성형 AI(Generative AI)는 연평균 59.2%의 폭발적인 성장세를 보이며, 2028년에는 전체 AI 지출의 32%를 차지할 것으로 예측된다. 이는 제조 현장에서도 보고서 자동화, 지식 검색, 공정 시뮬레이션 등 새로운 형태의 생산성 혁신을 예고한다.

(2) 경제적 파급효과

(가) 부가가치 창출 : 맥킨지앤드컴퍼니(McKinsey & Company, 이하 McKinsey)는 AI가 2030년까지 글로벌 경제에 연간 약 2.6조 ~ 4.4조 달러의 부가가치를 창출할 것으로 전망하며, 프라이스 워터하우스 쿠퍼스(PwC)는 전 세계 GDP에 최대 15.7조 달러를 추가할 수 있다고 분석했다.

(나) 제조업 임팩트 : 제조 분야에서 AI는 생산성, 품질, 에너지 효율 측면에서 10 ~ 20% 수준의 개선 잠재력을 보유한 것으로 평가 된다.

[그림 2-1] 생성형 AI 도입에 따른 산업별 연간 경제적 가치 창출 전망

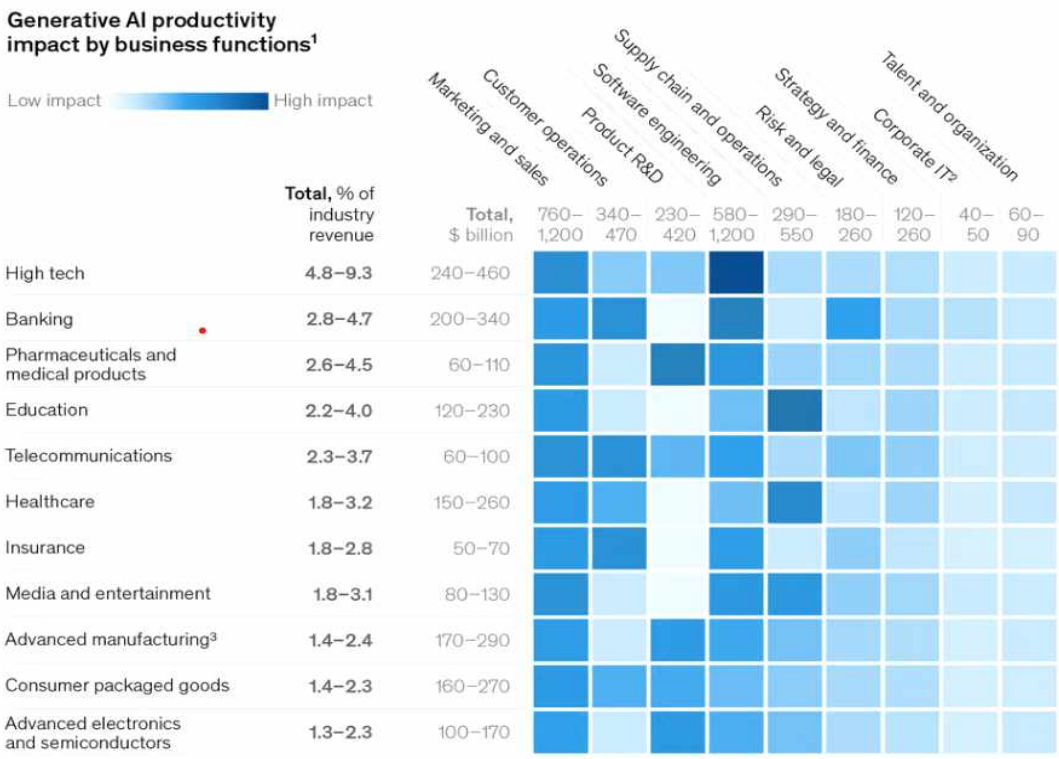

*출처 : McKinsey Global Institute

2 제조업 디지털 전환의 방향 (Industry 4.0)

1. 스마트팩토리의 진화

(1) 초연결과 지능화 : 제조업의 DX는 AI, IoT, 클라우드, 디지털 트윈이 결합된 4차 산업혁명형 스마트팩토리로 구체화되고 있다.

(2) 주요 적용 영역

(가) 예측정비(Predictive Maintenance) : 설비 데이터를 실시간 분석하여 고장을 사전 예측하고 돌발 정지를 방지한다.

(나) 공정 최적화 : 다변량 공정 데이터를 학습하여 최적의 조업 조건을 도출, 수율과 에너지를 동시에 개선한다.

(다) 품질 검사 : 컴퓨터 비전(Computer Vision) 기술로 미세 결함을 자동 검출하여 품질 신뢰도를 높인다.

3 국내 제조업·중소기업의 디지털·AI 성숙도 진단

1. 디지털 기술 수준의 양극화

(1) 성숙도 분포

(가) 기초 단계 집중 : 산업통상자원부 실태조사에 따르면, 국내 제조기업의 디지털 이해도는 여전히 1~2단계(입문·기초)에 머물러 있다. 특히 철강 및 금속 제조업의 경우 40~50%가 기초 단계이며, 고도화 단계인 4단계 이상은 3~4%에 불과하다.

[그림 2-2] 인공지능(AI)기술 필요성 인식

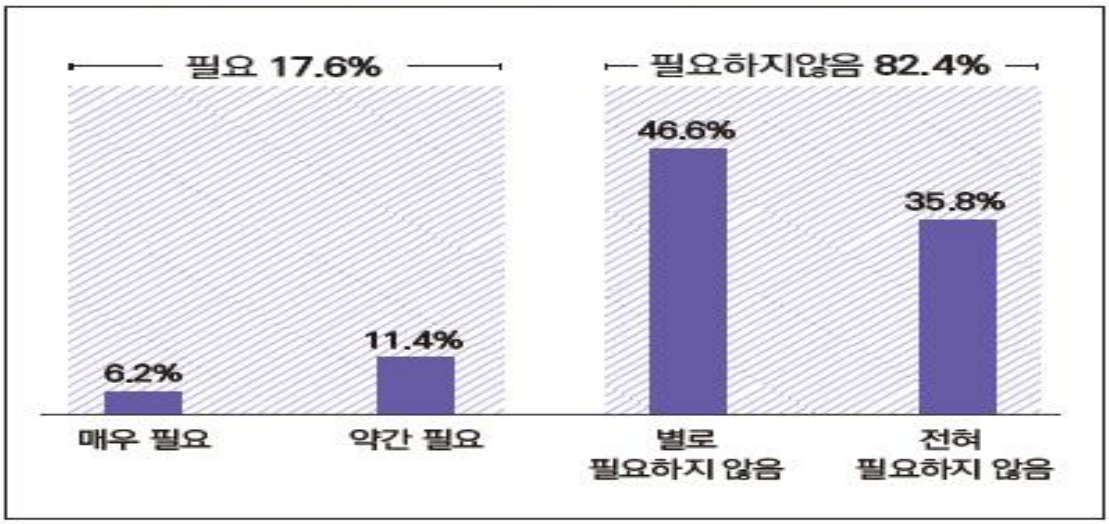

* 출처 : 2024 중소기업 기술통계조사 보고서

[표 2-1] 인공지능(AI)기술 적용 필요성 인식

(단위: %)

구분		매우 필요	약간 필요	별로 필요하지 않음	전혀 필요하지 않음
전체		6.2	11.4	46.6	35.8
규모별	소기업	5.9	11.4	46.9	35.9
	중기업	7.2	11.3	45.8	35.7
산업별	C	3.2	9.4	49.6	37.8
	F	0.6	8.6	43.1	47.7
	G	5.1	9.2	53.5	32.3
	J	28.8	21.8	26.2	23.2
	M	6.1	20.6	40.4	32.9

주) C: 제조업, F: 도매및소매업, J: 정보통신업, M: 전문,과학및기술서비스업

* 출처 : 2024 중소기업 기술통계조사 보고서

(나) AI 활용의 저조 : 실제 업무에 AI를 활용하는 국내 제조 기업 비율은 2.3% 수준으로, 금융이나 IT 서비스업 대비 현저히 낮은 수준이다. 이는 '철강 강국'이라는 하드웨어 위상과 대비되는 '소프트웨어 약세'를 보여준다.

[그림 2-3] 인공지능(AI)기술 도입 계획

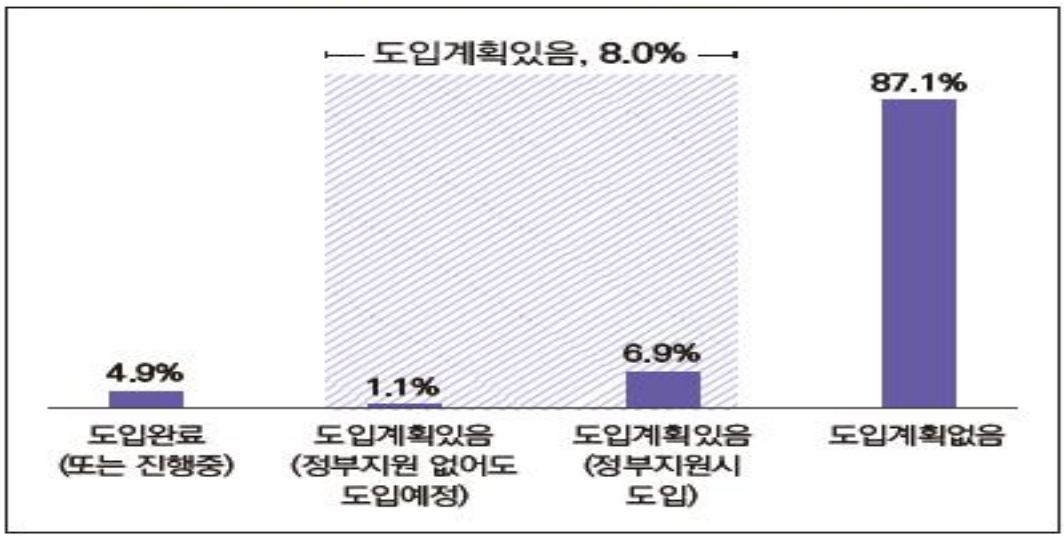

* 출처 : 2024 중소기업 기술통계조사 보고서

[표 2-2] 향후 3년내 인공지능(AI)기술 도입 계획

(단위: %)

구분		도입완료 (또는 진행중)	도입계획 있음		도입계획 없음
			정부지원 없이도 도입예정	정부지원 가능시 도입예정	
전체		4.9	1.1	6.9	87
규모별	소기업	4.4	1.1	6.4	88
	중기업	6.3	1.2	8.4	84
산업별	C	2.7	0.9	6.0	90
	F	0.1	0.1	5.2	94
	G	3.5	0.5	5.5	90
	J	23.5	4.0	13.3	59
	M	3.4	0.9	9.6	86

주) C: 제조업, F: 도매및소매업, J: 정보통신업, M: 전문,과학및기술서비스업

* 출처 : 2024 중소기업 기술통계조사 보고서

2. AI 도입의 장애 요인

(1) 현장의 애로사항

(가) **활용 방안 부재** : 기업의 52.7%는 “어디에 어떻게 AI를 써야 할지 모른다“는 점을 가장 큰 장벽으로 꼽았다.

(나) **인력 및 비용** : “내부 전문 인력 부족“(30.2%)과 “투자 비용 부담“(19.4%)이 그 뒤를 이었다. 이는 기술 자체의 부재보다는 ’활용 역량’의 부재가 더 큰 문제임을 시사하며, 실무 중심의 교육 가이드라인이 시급함을 역설한다.

2-2. 철강 산업의 디지털 기술 적용 사례

1 철강 산업의 특성

1. 공정 및 설비의 특수성

(1) 연속 공정과 블랙박스(Black Box)

(가) 설비 집약적 산업: 고로에서 압연까지 이어지는 공정은 거대한 설비가 밀집된 연속 공정으로, 특정 구간의 문제가 전체 생산 라인에 영향을 미친다.

(나) 불가시성: 고로 내부와 같이 2,300℃에 달하는 고온 환경은 센서 설치가 어렵고 내부 반응을 직접 관측할 수 없는 ’블랙박스’ 영역이다. 이러한 특성으로 인해 철강 산업은 오랫동안 조업자의 경험(암묵지)에 의존해 왔다.

2. 데이터 기반 전환의 당위성

(1) 암묵지의 형식지화

(가) **세대교체 대응** : 베이비부머 세대의 은퇴로 숙련 기술 전수가 단절될 위기에 처해 있다. DX는 숙련공의 노하우를 데이터로 정량화(형식지화)하여 시스템화하는 유일한 대안이다.

(나) **환경 및 안전 규제** : 탄소 배출 감축과 중대재해처벌법 대응을 위해서는 정밀한 에너지 제어와 위험 구역의 무인화가 필수적이며, 이는 AI와 로봇 기술 없이는 달성 불가능하다.

② 국내 철강사의 디지털 전환 동향

1. POSCO (포스코): AI 제철소의 표본

(1) AI 고로 (AI Blast Furnace)

(가) 개념: 포항 2고로에 적용된 AI 시스템은 수십 년간 축적된 조업 데이터와 실시간 센서 데이터를 딥러닝으로 학습하여, 고로 내부 상태를 예측하고 최적의 제어값(송풍량, 연료비 등)을 자동 제시한다.

(나) 성과: 이를 통해 일일 용선 생산량을 240톤 증대시켰으며, 연료비를 절감하고 조업 편차를 획기적으로 줄이는 데 성공했다.

[그림 2-4] 딥러닝 기반의 AI 고로 제어 시스템 개념도 및 데이터 처리 흐름

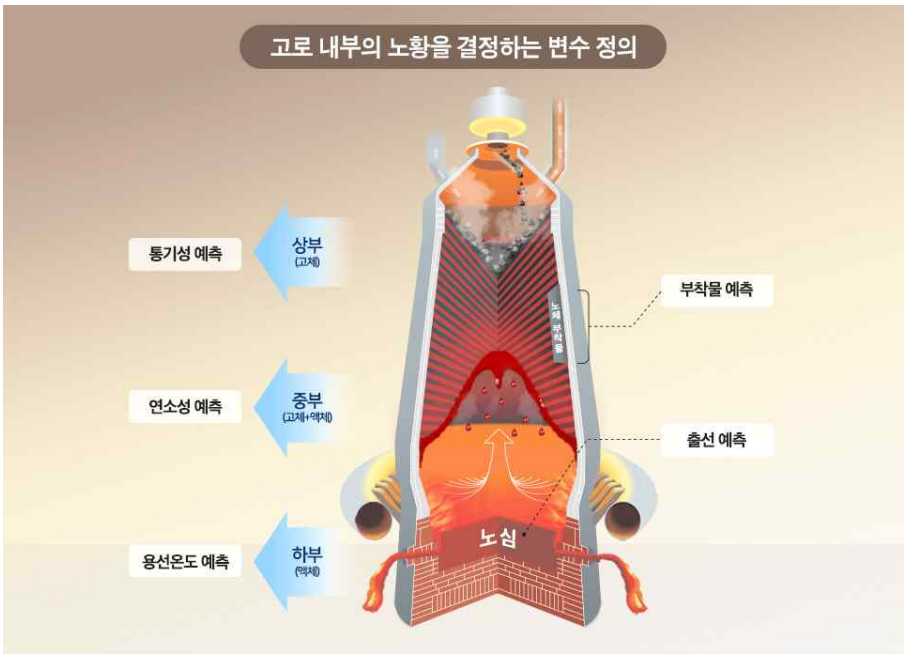

* 출처 : 포스코그룹뉴스룸

(2) PosFrame (포스프레임) 플랫폼

연속 공정 특화 : 세계 최초의 연속 제조 공정용 스마트팩토리 플랫폼으로, 공장 내 모든 데이터를 수집·정렬·저장하여 '불량 역추적'과 '공정 간 전후방 제어'를 가능하게 한다.

(3) 생성형 AI 도입

지식 자산화 : 사내 지식 검색 시스템에 생성형 AI를 도입하여 연구

논문, 정비 매뉴얼 등 방대한 기술 문서를 자연어로 검색하고 요약하는 기능을 제공, 연구원과 엔지니어의 업무 효율을 높이고 있다.

[그림 2-5] POSCO의 연속 공정 특화 스마트 팩토리 플랫폼 'PosFrame'의 6계층 구조

* 출처 : 포스코DX 홈페이지

2. 현대제철: 프로세스 혁신과 지능형 플랫폼

(1) HIP (Hyundai-steel Intelligence Platform)

(가) 생성형 AI 활용 : 보안이 강화된 프라이빗 클라우드 기반의 생성형 AI 플랫폼 'HIP'을 구축하여, 임직원들이 내부 문서를 안전하게 검색하고 인사이트를 도출할 수 있도록 지원한다.

(나) 제선 및 압연 : 제선 공정의 온도 예측 및 이상 감지, 압연 공정의 머신비전 기반 표면 결함 검사를 통해 불량률을 낮추고 조업 안정성을 확보하고 있다.

3. 동국제강: 공정별 특화 DX

(1) 점진적 AI 도입 사례

(가) 전기로 최적화 : 전기로(EAF) 중심의 공정 특성을 살려 스크랩 용해 효율을 높이는 AI 모델을 도입하고, 컬러 강판의 품질검사를 자동화했다.

(나) 강관 제조 혁신 : JCO 용접 공정에 레이저 센서와 AI를 결합하여 용접 품질을 실시간 모니터링하고, 생산 이력 추적 시스템을 고도화 했다

3 해외 철강사의 디지털 전환 및 AI 동향

1. Baowu Steel (바오우 강철, 중국): 등대 공장의 확산

(1) 대규모 자동화

(가) 다크 팩토리(Dark Factory) : 상하이 바오산 기지 등에서 조명 없이도 로봇과 AI가 24시간 가동되는 무인 공장을 운영 중이다. 크레인 운전, 품질 검사, 물류 이송이 완전 자동화 되었다.

(나) 조업실 통합 : 분산된 조업실을 수 킬로미터 떨어진 중앙 통제 센터로 통합하여, 현장 위험 요인으로부터 작업자를 분리하고 인당 생산성을 극대화했다.

[그림 2-6] Baowu Steel의 초광역 원격 제어 시스템 및 다크 팩토리 운영 개념도

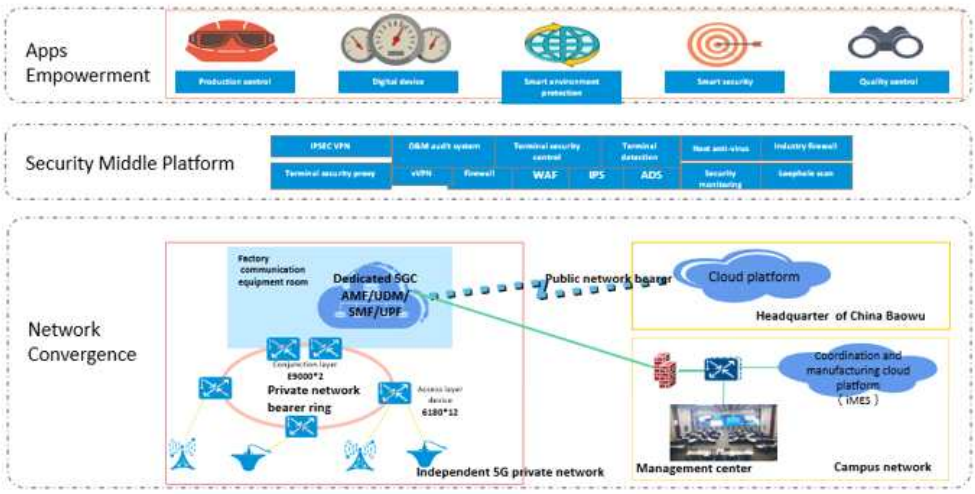

* 출처 : Baowu Resources

2. Nippon Steel (일본제철, 일본): 데이터 통합 플랫폼

(1) NS-DIGTM 및 NS-IoT

- **전사적 데이터 통합** : 각 제철소에 산재된 데이터를 통합 관리하는 'NS-Lib'와 AI 개발 플랫폼 'NS-DIG'를 구축하여 데이터 사일로(Silo)를 제거했다.

(2) 성과 : 이를 통해 베테랑의 노하우를 AI 모델로 대체하고, 영상 분석을 통한 설비 감시 자동화로 업무 부하를 줄였다.

[그림 2-7] Nippon Steel의 전사 데이터 통합 및 AI 분석 플랫폼 'NS-DIG' 구조도

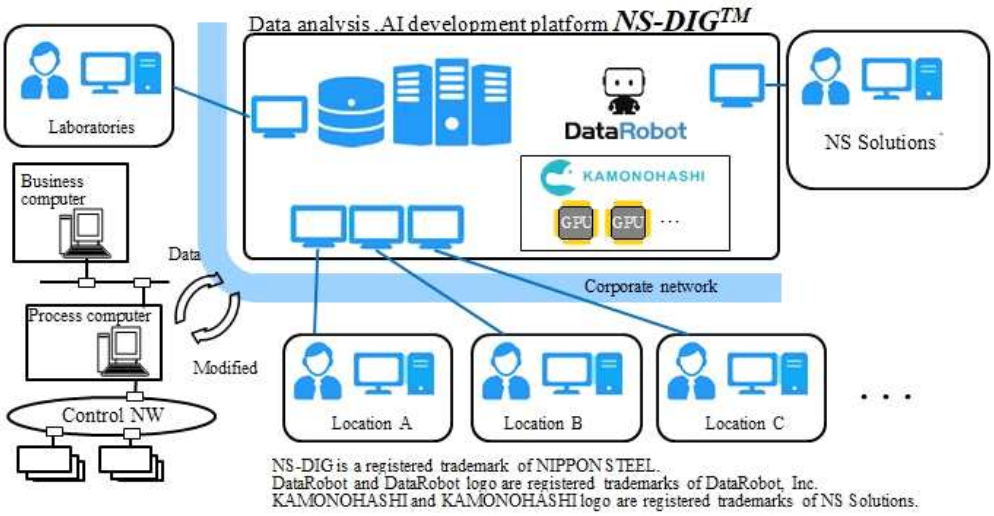

* 출처 : Nippon Steel DX Report

3. Tata Steel (타타 스틸, 인도): 가치 중심의 AI

(1) 칼링가나가르(Kalinganagar) 등대 공장

(가) 비즈니스 임팩트 : 기술 자체보다 '비즈니스 가치'에 집중하여, 과열 저감 모델 등 현장 엔지니어가 실제 사용하는 AI 솔루션을 개발했다. 그 결과 10억 달러 이상의 비용 절감 효과를 거둔 것으로 보고되었다.

④ 공정 제어 및 품질 고도화 사례

1. AI 기반 조업 최적화

(1) 도금량 정밀 제어 (POSCO 사례)

(가) 문제 : 자동차 강판의 도금량은 품질과 직결되나, 기존 수동 제어로는 편차를 줄이는 데 한계가 있었다.

(나) 해결 : AI가 수천 개의 변수를 분석하여 도금 부착량을 실시간 예측하고 제어하는 시스템을 구축했다.

(다) 효과 : 도금량 편차를 7g/㎡에서 0.5g/㎡로 획기적으로 줄여, 원가 절감과 품질 균일화를 동시에 달성했다.

(2) 전기로 전력 효율화

전기로 조업 시 스크랩 용해 패턴을 AI로 분석하여 전극봉 투입 깊이와 전력 공급 패턴을 최적화함으로써, 전력 소비를 줄이고 용해 시간을 단축한다.

2. 비전 AI 기반 품질 검사

(1) 표면 결함 자동 분류

(가) 기술 : 고해상도 카메라와 CNN(Convolutional Neural Network) 알고리즘을 활용하여 압연 강판의 스크래치, 덴트, 얼룩 등을 초고속으로 검출한다.

(나) 효과 : 작업자의 육안 검사 피로도를 제거하고, 미세 결함의 유출을 원천 차단하여 고객 클레임을 예방한다. 현대제철과 동국제강 등 다수 기업이 도입 중이다.

⑤ 설비 예지보전 및 안전·환경 관리 사례

1. 설비 예지보전 (Predictive Maintenance)

(1) CMS (Condition Monitoring System) 고도화

(가) 진동 및 전류 분석 : 모터, 압연 롤, 베어링 등 핵심 회전 설비에 IoT 센서를 부착하여 진동과 온도, 전류 파형을 수집한다. AI는 정상 패턴과 다른 미세한 징후를 감지하여 고장 발생 수주 전에 경보를 울린다.

(나) **가치** : 돌발 정지로 인한 막대한 생산 손실을 방지하고, 정기 보전(Time-based)에서 상태 기반 보전(Condition-based)으로 전환하여 유지보수 비용을 최적화한다

2. 스마트 안전 시스템

(1) 지능형 CCTV와 웨어러블

(가) **위험 감지** : AI CCTV가 지게차와 작업자의 충돌 위험, 안전모 미착용, 위험 구역 침입 등을 실시간으로 감지하여 경고 방송을 송출한다.

(나) **사각지대 해소** : 밀폐 공간 내 가스 농도 모니터링이나 고소 작업자의 상태를 웨어러블 기기로 체크하여 중대재해를 예방한다.

3. 환경 규제 대응 (CBAM)

(1) 탄소 배출량 모니터링

- 전과정 평가(LCA) : 원료 채굴부터 제품 출하까지 발생하는 탄소 배출량을 데이터 기반으로 산정하고 추적 관리한다. 이는 EU의 CBAM(탄소국경조정제도) 등 강화되는 글로벌 환경 규제에 대응하기 위한 필수 인프라가 되고 있다.

6 공급망 및 경영 지원 사례

1. 공급망 최적화 (SCM)

(1) 원료 가격 예측 및 재고 관리

(가) **시황 분석** : 철광석, 원료탄 등 원자재 가격 변동 추이를 AI로 예측하여 최적의 구매 시점을 결정한다.

(나) **물류 자동화** : 야드 내 크레인과 무인 운반차(AGV)의 동선을 최적화하여 물류 병목을 해소하고 리드타임을 단축한다.

2. 생성형 AI를 활용한 업무 혁신

(1) 도메인 특화 챗봇

(가) **활용** : 사내에 축적된 방대한 정비 매뉴얼, 표준 작업 절차서(SOP), 연구 보고서를 학습한 챗봇이 엔지니어의 질의에 즉답을 제공한다.

(나) **효과** : 정보 검색 시간을 획기적으로 줄이고, 신입 사원의 조기 전력화를 지원한다.

⑦ CCTV · 영상 기반 ‘위험행동 · 위험상황’ 실시간 감지

1. 보호구(PPE) 착용 여부 자동 인식 딥러닝 기반 영상 인식 모델

안전모 · 안전화 · 장갑 · 보안경 등의 착용 여부 고온부 · 위험구역 출입 시 방열복 · 특수 보호구 착용 여부를 자동으로 판별하고, 미착용 시 음성 · 경광등 · 모바일 알림을 보내는 사례가 보고되고 있다. 철강 · 건설 · 중공업을 아우르는 산업 안전 AI 솔루션 사례에서 반복적으로 등장하는 적용 방식이다.

[그림 2-8] 안전모 미착용 감지

* 출처 : www.seouland.com

2. 출입 금지 · 위험구역 침입 감지

용선 · 용강 운반구역, 크레인 작업 반경, 고소 작업 주변, 차량 통행로 등에는 통상 출입 제한이 설정되어 있는데, AI 영상 분석을 통해 사람이 출입 금지선(가상 펜스)을 넘을 경우 자동으로 감지해 알림을 주는 시스템이 운영되고 있다. 일부 사업장에서는 지게차 · 크레인와 작업자 간 거리를 실시간 계산해, 일정 거리 이내로 접근하면 경고하는 기능까지 도입하고 있다.

3. 이상 행동・쓰러짐 감지

협소 공간 작업, 고소 작업, 야간 작업과 같이 시야 확보가 어려운 환경에서는, 작업자가 쓰러지거나 움직임이 비정상적으로 감소할 경우 AI가 이를 이상 상황으로 인식하고 알람을 주는 기술도 확산되고 있다. 이는 중대재해뿐만 아니라, 열사병・질식 등 건강 이상 상황의 조기 인지에도 유용하다.

[그림 2-9] 작업자 쓰러짐 감지

* 출처 : www.seouland.com

⑧ 설비・공정 데이터를 활용한 ‘안전 리스크 예측’

설비 및 공정 데이터를 활용한 안전 리스크 예측이란, 생산 과정에서 축적되는 다양한 데이터를 기반으로 안전사고로 이어질 가능성이 있는 이상 상태를 사전에 탐지하고 선제적으로 대응하는 활동을 의미한다. 철강 산업과 관련된 AI 활용 사례를 살펴보면, 예측 유지보수, 에너지 최적화, 스마트 팩토리 구축과 같은 키워드가 주로 등장하며 ‘안전’이라는 용어가 전면에 부각되지는 않는다. 그러나 해당 사례들의 기술적 본질을 살펴보면, 이들 대부분은 궁극적으로 산업 안전 수준을 향상시키는 역할을 수행하고 있으며, 안전과의 연계성이 매우 높다.

특히 설비 고장이나 공정 이상은 생산성 저하에 그치지 않고, 고온·고압·

대형 설비가 밀집된 철강 공정의 특성상 중대 산업재해로 직결될 수 있다. 이러한 맥락에서 철강 산업의 AI 기반 디지털 전환은 단순한 효율 개선을 넘어, 안전 리스크를 사전에 제거하기 위한 예방 중심의 관리 체계로 확장되고 있다.

1. 예지보전(PdM)과 안전

예지보전(PdM, Predictive Maintenance)은 진동, 온도, 전류, 압력 등 설비 상태 데이터를 AI가 분석해 고장 징후를 사전에 감지하는 기술로, 가동률 향상이나 유지보수 비용 절감뿐만 아니라 설비 사고 예방을 위한 핵심 안전 기술로 기능한다. 베어링, 롤, 펌프, 팬, 가열로 등 주요 설비가 파손되거나 비정상 상태로 운전될 경우, 고온 물질의 누출, 비산, 화재, 폭발 등 중대 사고로 이어질 가능성이 크다.

따라서 예지보전은 설비의 수명을 관리하는 기술을 넘어, 위험 상태에 도달하기 이전 단계에서 이상 징후를 인지하고 개입함으로써 산업재해 발생 가능성을 구조적으로 낮추는 수단이라 할 수 있다. 이는 철강 산업에서 AI 기반 설비 데이터 분석이 생산성과 안전을 동시에 달성할 수 있는 대표적인 디지털 전환 사례임을 보여준다.

2. 공정 이상 상태와 안전사고의 연계 분석

고로・전로・전기로・연속주조・압연 등 주요 공정에서는 운전 조건이 곧 안전과 직결된다. 예를 들어, 용선・용강 레벨, 가스 압력, 온도, 냉각수 흐름, 롤 힘(압연력) 등의 이상은 설비 파손, 누수, 폭발, 파손 비산 등의 위험을 키운다. AI는 과거 사고・아차사고 데이터와 공정 데이터를 함께 학습하여, 특정 조건 조합이 나타날 때 “안전 리스크가 높은 상태”임을 판단할 수 있다.

장기적으로는,

(1) 어떤 조업 조건에서

(2) 어떤 설비 상태가 겹치면

(3) 어떤 유형의 사고가 잘 발생하는지

를 AI가 패턴으로 인식하고, 위험 상태에 접어들기 전에 운전 조건을 조정하거나 경보를 발생시키는 시스템으로 발전할 수 있다.

3. 가상 시뮬레이션(디지털 트윈) 기반 안전 검증

일부 스마트팩토리·디지털트윈 관련 자료에서는, 공정·설비를 가상 공간에 구현하고 AI로 시뮬레이션을 실행해 “위험 시나리오”를 미리 점검하는 시도가 언급된다. 예를 들어, 특정 설비 고장이 발생했을 때 용강이 어떻게 이동하고, 어느 구역이 위험해지는지를 가상으로 검증하고, 그에 맞는 대응 매뉴얼과 인터록(자동 정지·차단)을 설계하는 방식이다.

검색 결과에 구체적인 철강 디지털트윈+안전 사례가 상세히 기술되어 있지는 않지만, 전반적인 스마트 제조 문헌에서 디지털 트윈 + AI = 안전 시나리오 예측·검증 수단으로 자리 잡아가고 있다.

⑨ 고위험 작업을 대체하는 ‘원격·로봇 기반 안전 기술’

세 번째 축은 사람의 직접 투입이 위험한 작업을 로봇·원격 시스템으로 대체하고, AI가 그 로봇의 눈과 두뇌 역할을 하는 것이다. 검색 결과에는 철강·정유·석유화학·조선 등 중후장대 산업에서의 “AI 자동화 사례”를 묶어서 소개하는 자료들이 있는데, 여기서 공통적으로 강조되는 부분이 위험 작업의 로봇 대체다.

1. 고온·용강 주변 작업의 로봇화

용선·용강 샘플링, 슬래그 제거, 고온부 청소, 용탕 레벨 확인 등은 전통적으로 가장 위험한 작업으로 꼽힌다. 이 영역에서는 카메라·열화상 센서·레이저 센서 등이 부착된 특수 로봇이 용선·용강 주변 작업을 수행하고, AI가 영상·센서 데이터를 분석해 위치를 판단하고 작업 경로를 제어하는 형태가 확산되고 있다.

근본적인 안전 목표는 사람이 위험 구역에 들어가지 않게 하는 것이며, AI는 이를 위한 인지·판단·제어 기술로 기능하다

2. 고소·협소·밀폐공간 점검의 로봇·드론 활용

철강 공정에서는 굴뚝·덕트·탱크·피트 등 사람이 접근하기 어렵거나 위험한 공간이 많다. 이 경우 카메라·가스 센서가 장착된 드론이나 소형 주행 로봇을 투입하여 상태를 점검하고, AI가 영상·센서 데이터를 분석해 녹·균열·누수·가스 이상을 판별하는 사례가 늘고 있다. 이렇게 되면 작업자는 안전한 장소에서 모니터링과 판단을 수행하고, 위험 공간에는 로봇만 들어가게 된다.

[그림 2-10] 영상 인식 로봇

* 출처 : 포스코뉴스룸

[그림 2-11] 영상 인식 로봇

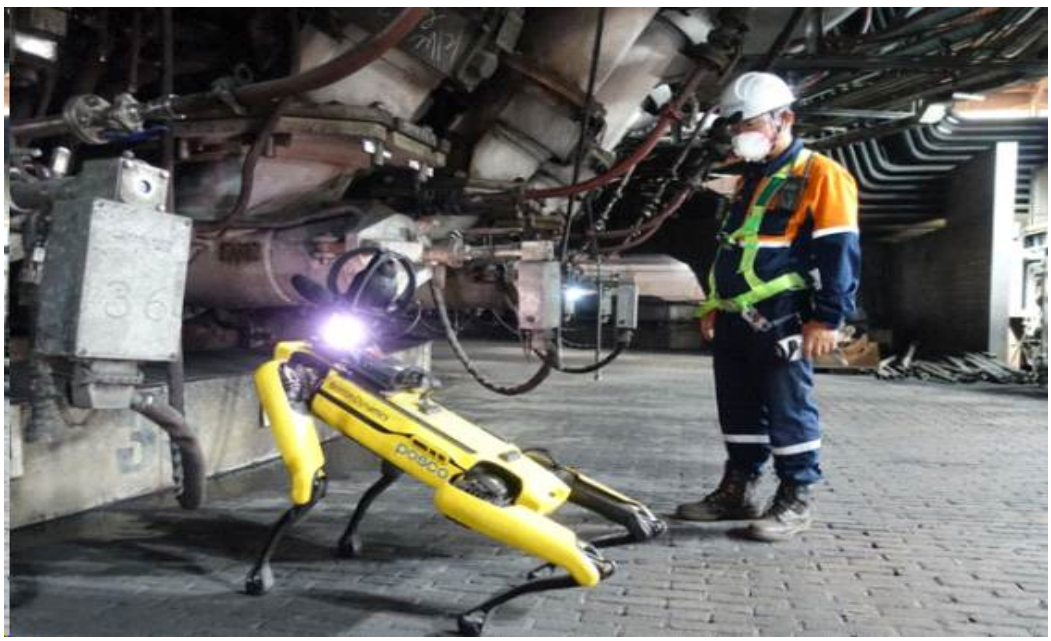

* 출처 : 포스코뉴스룸

3. 자율주행 물류장비와 인적 충돌 방지

크레인・지게차・야드 차량이 수시로 움직이는 철강 공장 내 물류 구역은, 인적 충돌 사고 위험이 높은 구역이다. 검색 결과에 나타난 스마트 물류・자율주행 사례들을 참고하면, AI 기반 자율주행・충돌 방지 시스템은 다음과 같은 방향으로 안전에 기여하고 있다.

(1) AI가 카메라·라이다·레이더 데이터로 사람과 장애물을 인식

(2) 사람과의 거리·속도 차를 계산해 충돌 위험을 판단

(3) 필요 시 자동 감속·정지 수행

(4) 일정 구역에서는 사람 접근 시 장비가 자동으로 운전 제한

이는 단순한 물류 효율 향상을 넘어, "사람과 장비가 같은 공간에서 안전하게 공존할 수 있는 환경" 조성에 핵심적이다.

[그림 2-12] 크레인 자동 이송 AI

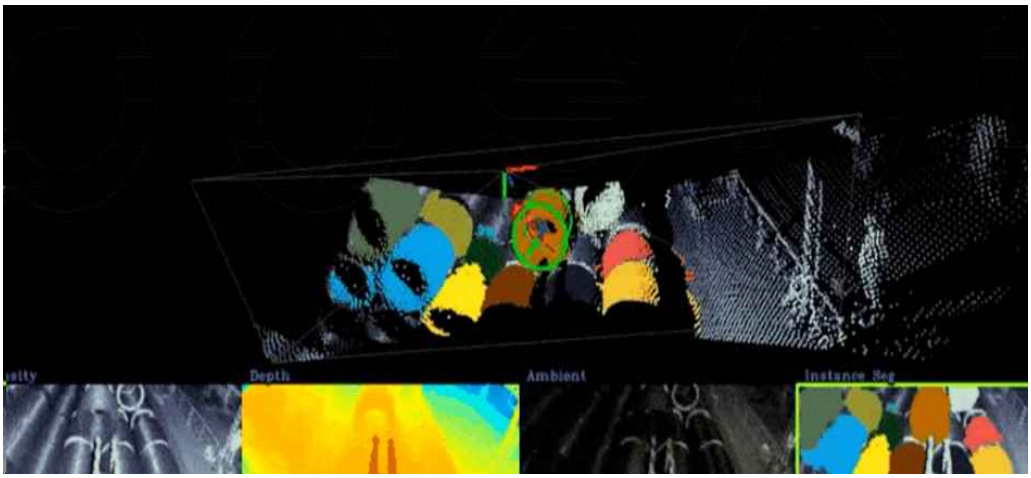

* 출처 : 포스코뉴스룸

2-3. 철강 산업의 디지털 기술 개발 방향

1 철강산업의 AI 개발 방향

"새로운 기술을 도입하는 것"을 넘어, 고위험·고에너지·고비용 구조를 가진 산업의 근본 체질을 바꾸는 데 초점이 맞춰져야 한다. 특히 글로벌 경쟁 심화, 탄소중립과 ESG 규제 강화, 숙련 인력 부족과 같은 구조적 변화 속에서, AI는 공정·설비·안전·물류·사무 전 영역을 아우르는 핵심 인프라로 자리 잡아가고 있다. 이에 따라 철강에서 AI 기술은 다음과 같은 방향으로 고도화될 필요가 있다.

1. 개별 공정 최적화에서 전 공정·전 가치사슬 최적화로의 확장이다. 지금까지 철강 공장에서의 AI 활용은 주로 고로·제강·압연과 같은 특정 공정에 한정된 품질 예측, 조업조건 추천, 에너지 사용 절감 등 "부분 최적화"에 머무르는

경우가 많았다. 그러나 원료 조달-제선-제강-압연-정정-물류-고객까지 이어지는 전체 가치사슬을 놓고 보면, 한 공정에서의 최적이 반드시 전체 관점에서의 최적이 되는 것은 아니다. 앞으로의 AI 개발은 각 공정의 센서·설비·품질·에너지 데이터를 통합 플랫폼에 집적하고, 이를 기반으로 생산량·납기·품질·원가·탄소배출을 동시에 고려하는 엔드 투 엔드(End-to-End) 최적화로 나아가야 한다. 예를 들어, 원료 성상 변화가 고로 운전과 제강 조업, 압연 스케줄과 최종 품질에 미치는 영향까지 AI가 함께 고려해, 공정 간 조합을 제안하고 납기·비용을 최소화하는 방향으로 계획을 자동 조정해야 한다.

2. 설비 상태 진단을 넘어 자율운전·무인화로 진화하는 방향이다. 현재 많은 철강사들이 도입하고 있는 AI 기반 예지보전(Predictive Maintenance)은 진동·온도·전류 등의 센서 데이터를 분석해 고장 가능성을 사전에 알리는 역할에 초점이 맞춰져 있다. 그러나 앞으로는 "고장 날 것 같다"는 알림을 주는 수준을 넘어, 설비 운전 조건을 스스로 조정하고, 보전 계획과 부품 교체 시점을 자동으로 최적화하는 '자율 설비 운영'으로 발전할 필요가 있다. 더 나아가, 크레인·운반차·야드 장비 등 물류 설비는 AI 기반 자율주행과 경로 최적화를 통해 사람 개입을 최소화하는 무인화 방향으로 나아가고 있다. 이런 흐름 속에서 철강의 AI 개발은 설비 데이터 분석 기술에 더해, 제어 로직과 결합된 폐루프(Closed-loop) 제어, 디지털 트윈 기반 가상 검증, 안전·인터록(Interlock)을 포함한 통합 운전 기술까지 포괄하는 방향으로 확장되어야 한다.

3. 품질 검사 자동화를 넘어 품질-공정 통합 제어로의 고도화이다. 표면 결함·치수·코팅 상태를 자동으로 검출하는 AI 비전 시스템은 이미 여러 공장에서 도입되거나 시험 적용되고 있다. 그러나 진정한 의미의 품질 경쟁력 강화를 위해서는, 검사 공정의 자동화에 그치지 않고 "검사 결과가 실시간으로 공정 조건에 피드백되는 구조"를 갖추는 것이 중요하다. AI 비전이 검출한 결함 패턴과 공정 데이터를 연계 분석하여, 어느 공정의 어떤 조건이 불량을 유발하고 있는지를 실시간으로 추적하고, 이를 기반으로 조업 조건을 자동 조정하거나 원인을 조기에 차단하는 방향으로 진화해야 한다. 또한 한 장의 코일, 한 개의 슬래브에 대한 품질 정보를 전 공정과 연결해, 고객별·제품별 최적 생산경로를 설계하고, 납품 이후 성능 데이터까지 연결하는 '데이터 기반 품질 생애주기 관리'로 이어져야 한다.

4. 안전 분야에서의 AI 활용을 "보조 도구"에서 "디지털 안전 플랫폼"으로 확

장하는 방향이다. 철강산업은 용선·용강, 고온·고압 설비, 중량물 취급 등 중대재해 위험이 상존하는 대표적인 고위험 산업이다. 이에 따라 앞으로의 AI 개발은 단순한 CCTV 관제 보조나 보호구 미착용 감지 수준을 넘어, 영상·센서·웨어러블 데이터를 통합 분석해 현장의 위험을 실시간으로 평가하고, 사고 가능성이 높은 작업·공정을 사전에 식별하는 수준으로 나아가야 한다. 예를 들어, 과거 사고·아차사고 데이터를 학습한 AI가 시간대·작업 종류·설비 상태·기상 조건을 종합해, "오늘 이 구역에서 이 작업은 위험도가 높다"고 경고하고, 인력 배치·작업 허가·안전감시자 운영을 조정하는 방식이다. 동시에, 고온·협소·중량물 작업은 로봇과 원격조작 시스템으로 대체해 "사람이 위험지역에 들어가지 않는" 구조를 만들어가는 것이 개념적인 목표가 될 것이다. AI는 이러한 로봇·원격 시스템의 눈과 두뇌 역할을 수행하면서 안전을 근본적으로 끌어올리는 핵심 기술이 된다.

5. 에너지·탄소·환경 영역에서의 '정량적 관리·최적화' 수단으로 AI를 활용하는 방향이다. 철강은 대표적인 에너지 다소비·탄소 다배출 산업이며, CBAM을 비롯한 글로벌 규제와 ESG 공시 요구가 강화되면서, 에너지·탄소 데이터를 정밀하게 관리하는 것이 생존의 문제가 되고 있다. 앞으로의 AI 개발은 공정별·설비별 에너지 소비와 탄소 배출을 실시간으로 추적·예측하고, 조업 조건·설비 운전·원료 배합을 최적화함으로써 에너지 효율을 높이고 탄소 배출을 줄이는 데 집중되어야 한다. 예컨대, 환원 공정에서 수소 비율·가스 유량·온도 조건을 AI가 조정해 환원 효율과 탄소 배출을 동시에 최적화하거나, 전기로·압연공정의 전력 피크를 회피해 전력 비용과 탄소 배출 계수를 함께 관리하는 방식이다. 이는 단순한 공정 효율 개선을 넘어, 규제 준수와 탄소 비용 최소화라는 재무적 과제와 직결된다.

6. 사무·지원 업무의 AI 전환을 통해 "AI 기반 경영·의사결정 체계"로 전환하는 방향이다. 생산 현장에서의 AI만큼이나 중요한 것이, 기획·영업·구매·물류·재무·ESG 등 사무 영역에서의 AI 활용이다. 수요·가격·환율·원료 시황·재고 데이터를 통합 분석해 생산·재고·물류 계획을 최적화하고, 계약서·규제 문서·기술자료를 AI가 요약·검토해 업무 속도를 높이는 것은 기본이다. 더 나아가, 경영진과 실무자들이 의사결정을 내릴 때, 각종 KPI·리스크·시나리오 분석 결과를 AI가 실시간으로 제시해 주는 "의사결정 보조 시스템"이 필요하다. 생성형 AI와 업무 시스템을 결합한 보고서·제안서·분석자료의 초안

을 자동 생성하고, 복잡한 데이터를 직관적인 언어와 시각화로 풀어주는 역할을 수행하게 될 것이다. 철강산업에서의 AI 개발은 생산·설비 중심의 기술만이 아니라, 이러한 백오피스·경영 의사결정 영역까지 포괄하는 방향으로 확장되어야 한다.

7. AI를 공장·시스템 차원을 넘어 사람과 조직 역량과 통합하는 방향이다. 결국 AI가 아무리 정교해도, 이를 기획하고, 데이터 인프라를 구축하며, 현장 적용과 확산을 추진하는 주체는 사람과 조직이다. 글로벌 차원에서 숙련 인력 부족과 디지털 인재 경쟁이 심화되는 상황을 고려하면, 철강산업의 AI 개발 방향은 “외부 솔루션 구매(Buying)” 중심에서 벗어나, 내부 인력의 재교육과 현장-데이터-AI를 이해하는 복합 인재 육성(Building), 대학·연구기관·스타트업과의 파트너십(Partnering)을 통해 인재 생태계를 구축하는 방향으로 나아가야 한다. 이를 위해서는 AI 모델 개발 그 자체뿐 아니라, 데이터 거버넌스, 표준화, 공정·설비 기반 도메인 지식과 AI 기술을 연결하는 교육 프로그램, 현장과 IT/DT 조직 간 협업 구조 설계까지 포함하는 ‘조직적 AI 역량’ 개발이 병행되어야 한다.

8. 철강에서의 AI 기술 개발은 “파일럿 프로젝트의 나열”을 넘어서, 전략적 로드맵과 아키텍처 관점에서 이루어져야 한다. 어느 공정·설비·업무부터 어떤 수준까지 자동화·지능화할 것인지에 대한 우선순위를 설정하고, 공통 데이터 플랫폼·분석 인프라·표준 모듈을 기반으로 재사용 가능한 AI 자산을 구축하는 것이 중요하다. 이를 통해 PoC-확산-내재화의 단계를 체계적으로 밟아가며, 공장 단위·전사 단위로 AI 활용도를 높여 나갈 때, 비로소 철강산업에서 AI는 일시적 유행이 아닌 경쟁우위의 핵심 기반으로 자리 잡게 될 것이다.

3 디지털 전환을 위한 인공지능의 이해

3-1. 인공지능 활용 대표적 모델의 종류

1 철강공정에서 Machine Learning 및 Deep Learning

철강 공장에서 인공지능 기반 기술과 설비기술(빅데이터)이 결합된다는 것은, 공장에서 일어나는 다양한 현상을 최대한 빠짐없이 데이터로 기록하고, 그 데이터를 바탕으로 설비 상태를 이해하며, 품질과 생산성을 예측하고, 조업과 설비 운전 방식을 점점 더 고도화해 가는 체계를 만든다는 의미이다. 이 과정의 중심에는 Machine Learning, Deep Learning, Vibe Coding(제미나이・GPT 등 AI 코딩 도구 활용), Computer Vision, Physical AI 같은 기술들이 있고, 이 기술들은 설비기술이 제공하는 데이터를 기반으로 서로 연계되어 작동한다.

[그림 3-1] 인공지능의 분류

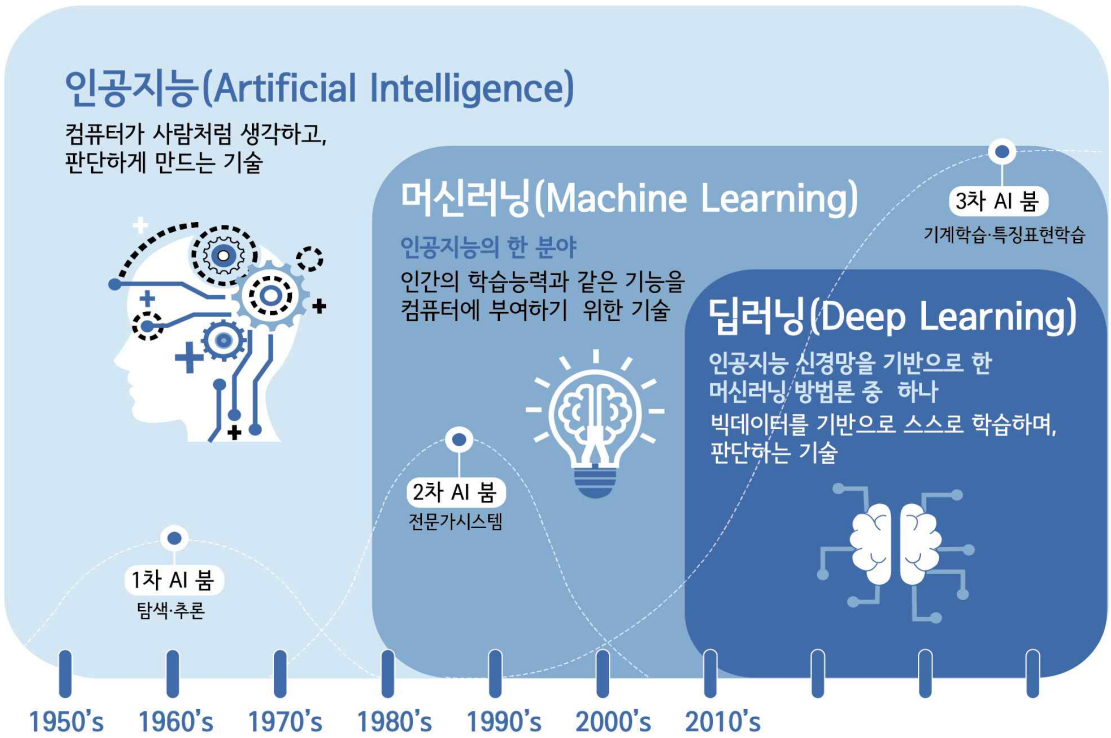

1. Machine Learning

공장에 축적된 데이터를 통해 규칙을 스스로 학습하는 기술이다. 과거에는 전문가가 “온도가 몇 도 이상이면 위험”, “전류가 일정 수준을 넘으면 이상”과 같은 기준을 경험과 이론에 따라 직접 정했다. 반면 머신러닝은 과거의 조업 조건, 설비 상태, 품질 결과, 고장 이력 등을 통째로 보면서, “이런 조건 조합에서는 양품이 잘 나왔고, 이런 패턴이 나타난 뒤 일정 시간 안에 고장이 났다”는 사실을 자동으로 찾아낸다. 예를 들어 가열로 온도, 압연 속도, 냉각 조건, 강종, 설비 진동, 모터 전류 같은 입력과, 그에 따른 제품 두께, 형상, 기계적 성질, 에너지 사용량, 고장 여부 같은 결과를 함께 학습한다. 이렇게 학습된 모델은 새로운 조업 계획이나 설비 조건이 들어왔을 때 “이 상태면 품질이 어느 정도일지”, “고장 위험이 얼마나 될지”, “에너지가 얼마나 들지”를 선제적으로 예측하는 데 활용된다. 결국 머신러닝은 설비기술(빅데이터)이 쌓아 둔 수많은 숫자들 속에서 사람이 일일이 찾아내기 어려운 규칙과 경향을 대신 정리해 주는 역할을 한다.

2. Deep Learning

같은 데이터 기반 기술이지만, 훨씬 복잡한 패턴을 여러 단계로 나누어 이해하도록 설계된 인공 신경망 기반 기술이다. 하나의 층에서는 단순한 특징만 보고, 그 위의 층들은 앞에서 뽑힌 정보를 조합해 더 복잡한 의미를 파악한다. 기술 발전 흐름을 보면, 딥러닝은 대략 CNN(합성곱 신경망) → LSTM 같은 순환 신경망 계열 → 트랜스포머(Transformer) 구조로 진화해 왔다.

(1) CNN(합성곱 신경망)

초기 딥러닝을 대표하는 CNN(합성곱 신경망)은 주로 이미지・영상을 처리하는 데 사용되었다. CNN은 이미지의 작은 영역을 일정한 패턴으로 훑으면서 에지(윤곽선), 모서리, 반복 무늬와 같은 기본적인 형태를 찾아내고, 여러 층을 지나면서 점점 더 복잡한 형태(결함 모양, 설비 부품 형태, 특정 구조물의 윤곽 등)를 인식할 수 있게 된다. 철강 현장에서는 제품 표면의 스크래치, 롤마크, 패치 같은 결함을 자동 검사하는 시스템에서 CNN이 핵심 역할을 한다. 카메라가 찍어 보내는 영상에서 CNN이 “정상 표면”과 “결함이 있는 표면”을 구분해내고, 필요하면 결함의 위치와 크기까지 표시해 준다.

(2) LSTM(순환 신경망)

그 다음 단계로 발전한 것이 LSTM 같은 순환 신경망 계열이다. LSTM은 시간에 따라 변하는 데이터, 즉 시계열 데이터를 잘 다루기 위해 만들어진 구조이다. 단순한 신경망은 현재 시점의 값만 보고 판단하기 쉽지만, LSTM은 과거 여러 시점의 정보를 일정 기간 동안 기억했다가, 현재 판단에 반영할 수 있다. 철강·설비 쪽에서는 모터 진동, 전류, 온도, 압력, 부하, 속도 등 여러 센서 값이 시간에 따라 변하는 패턴을 보고 "이 패턴이면 다음에 이상이 올 가능성이 크다", "이런 추세면 품질이 점점 나빠진다"와 같은 흐름을 학습하는 데 LSTM이 쓰인다. 예를 들어 베어링이 서서히 망가질 때 진동·온도 패턴이 어떻게 변하는지, 가열로 온도와 연료 사용량이 시간에 따라 어떻게 상호작용하는지와 같은 복합 시계열 문제에서 LSTM은 과거의 흐름을 기억하며 예측하는 강점을 보인다.

(3) Transformer

최근에는 트랜스포머(Transformer) 구조가 딥러닝의 중심으로 자리 잡고 있다. 원래는 문장·자연어 데이터를 다루기 위해 고안된 구조이지만, 시계열·영상·센서 데이터로 영역을 빠르게 확장하고 있다. 트랜스포머의 핵심은 "모든 시점·위치를 서로 비교하면서 중요한 부분에 더 집중하는 방식"이다. 과거의 RNN/LSTM 구조처럼 순차적으로 앞에서 뒤로만 기억을 전달하는 것이 아니라, 전체 데이터 구간을 한꺼번에 놓고 "어느 부분이 현재 판단에 특히 중요한지"를 스스로 판단해 가중치를 다르게 두는 식이다. 이 덕분에 긴 시계열에서도 앞·뒤 구간의 중요한 상관관계를 잘 잡아낼 수 있고, 여러 센서 채널 간의 복잡한 연관성을 한 번에 고려할 수 있다. 철강·설비 분야에서는 장기간 설비 상태 변화를 한꺼번에 보면서 이상 징후를 감지하거나, 공정 전체 구간의 조건 변화를 통합적으로 반영해 품질을 예측하는 데 트랜스포머 계열 모델이 점점 더 많이 활용되고 있다. 또한 GPT, 제미나이 같은 초거대 언어모델 자체가 트랜스포머 구조를 기반으로 만들어졌기 때문에, 코드 생성·자연어 분석·문서 요약 등에서도 동일한 원리가 적용되고 있다.

정리하면, CNN은 “공간 패턴(이미지・영상)”에 강한 기술로 영상 기반 검사와 시각 인식에 주로 쓰이고, LSTM과 같은 순환 신경망은 “시간에 따른 변화(시계열)”를 순차적으로 기억하며 예측하는 데 쓰이며, 트랜스포머는 “길고 복잡한 데이터의 전체 패턴을 한꺼번에 보고 중요한 부분에 집중하는” 방식으로 진화한 구조라고 볼 수 있다. 이 세 가지는 발전 순서상 CNN과 기초 신경망이 먼저 실용화되고, 이어서 LSTM 등 순환 신경망이 시계열에 적용되었고, 최근에는 트랜스포머가 시계열・텍스트・멀티모달 데이터 전반으로 확장되면서 딥러닝의 주류로 자리 잡았다고 이해할 수 있다. 철강 공장에서의 딥러닝 활용은 이 발전 흐름을 따라, 초기에는 주로 영상 기반 표면 검사(CNN)에서 출발해, 시계열 기반 예지보전(LSTM 등), 그리고 최근에는 공정 전체를 통합적으로 바라보는 고도 예측・최적화(트랜스포머 계열)로 넓어지고 있다.

3. Vibe Coding

Vibe Coding은 제미나이(Gemini)나 GPT 같은 대규모 언어모델(LLM)을 활용해 코딩 생산성을 높이는 방식에 초점을 맞춘 개념으로 이해할 수 있다. 철강・설비 분야에서 데이터 분석과 AI 모델링을 하려면, Python, SQL, Spark, 각종 라이브러리(pandas, scikit-learn, PyTorch, TensorFlow 등)를 활용해 데이터를 가공하고, 모델을 만들고, 시스템과 연계하는 코드를 상당히 많이 작성해야 한다. Vibe Coding이라는 이름 아래에서는 이런 개발 과정을 “사람과 AI 코딩 도구가 대화 형태로 함께 수행하는 방식”에 방점을 둔다.

실무에서는 엔지니어가 자연어로 “이 설비 데이터에서 지난 한 달간의 이상치를 탐지하는 코드를 만들어 달라”, “이 변수들을 사용해서 간단한 예측 모델을 만드는 예제를 보여 달라”, “이 에러 로그를 보고 어느 부분이 잘못됐는지 설명해 달라”와 같이 요구 사항을 적는다. 그러면 GPT나 제미나이 같은 AI 코딩 도구가 그에 맞는 코드 초안을 생성하고, 사용자는 이를 실제 환경에 맞게 실행・수정하면서 구체화해 나간다. 코드 구조를 이해하기 어렵거나, 반복적인 전처리 작업이 많을 때, “이 코드가 무슨 일을 하는지 요약해 달라”, “이 부분을 더 간결하게 리팩터링해 달라”라고 요청해 품질을 높이는 것도 가능하다. 이런 방식의 Vibe Coding을 활용하면 반복적・규칙적인 코딩 부담이 줄어

들고, 설비·공정에 대한 도메인 지식을 가진 엔지니어가 “어떤 데이터를 뽑을지, 어떤 모델이 현장에 맞을지, 어떤 지표가 실질적으로 의미가 있는지” 같은 본질적인 의사결정에 더 집중할 수 있게 된다. 즉, Vibe Coding은 제미나이·GPT 등 AI 코딩 도구를 파트너처럼 활용해, 설비 데이터 분석과 AI 적용을 빠르고 유연하게 구현하는 새로운 개발 방식이라고 볼 수 있다.

4. Computer Vision

Computer Vision은 카메라로 촬영한 영상과 이미지를 통해 제품, 설비, 작업 환경의 상태를 자동으로 인식하는 기술이다. 사람의 눈에는 제품 표면을 스쳐만 봐도 “정상이다”, “여긴 흠집이 있다”, “여기 이물이 묻어 있다”가 바로 들어오지만, 컴퓨터에게는 단지 픽셀 숫자의 집합일 뿐이다. 컴퓨터 비전 기술은 이 픽셀 데이터를 딥러닝(CNN, 최근에는 비전 트랜스포머 등)으로 반복 학습하면서 “결함이 있는 표면에는 이런 모양과 질감이 자주 나타난다”, “라벨에는 이렇게 생긴 문자 구조가 있다”, “작업자의 몸과 보호구는 대체로 이런 형태를 가진다”는 시각적 규칙을 습득한다. 철강 공장에서는 이를 이용해 제품 표면의 스크래치·롤마크·조각·패치 등 결함을 라인 속도에 맞추어 실시간으로 검출하고, 설비 외관의 균열·누유·부식·변형을 자동 점검하며, 코일·슬래브 라벨을 인식해 생산·품질 시스템과 자동 연동하는 등 다양한 형태로 활용한다. 또한 작업자가 헬멧, 보안경 등 보호구를 제대로 착용했는지, 위험 구역에 접근했는지, 차량과 사람의 동선이 충돌 위험을 가지는지 등을 모니터링하는 안전 시스템에도 활용된다. 이때 카메라 설치 위치와 각도, 조명, 라인 속도와의 동기화, 영상 데이터의 전송·저장 구조, 설비 제어 시스템과의 연동 방식 등은 모두 설비 기술의 영역이며, 컴퓨터 비전은 그 위에서 “영상 데이터를 의미 있는 상태 정보로 해석하는 역할”을 담당한다.

5. Physical AI

Physical AI는 물리적인 세계와 직접 맞닿은 인공지능을 의미하며, 철강 현장에서는 크게 두 가지 방향으로 나타난다. 첫 번째는 기존의 물리 모델과 AI를 결합해 더 정확하고 신뢰할 수 있는 예측 모델을 만드는 방식이고, 두 번째는 실제 설비·로봇·장비의 제어 단계에 AI를 적용해

움직임 자체를 지능화하는 방식이다. 가열로의 열 전달, 연주의 응고·수축, 압연 하중과 롤 변형, 열처리 후 조직과 강도 예측 등은 이미 다양한 이론 모델과 시뮬레이션 도구가 있다. 그러나 실제 공장에서는 원료 특성의 편차, 주변 환경 변화, 설비 노후화 등으로 인해 이론 모델과 실제 결과 간에 항상 일정한 차이가 발생한다. Physical AI는 이러한 상황에서 물리 모델이 전체적인 경향과 물리적 일관성을 담당하고, 인공지능이 실제 데이터와의 차이를 학습해 “어떤 상황에서 얼마나 보정해야 현실에 가까운지”를 계속 업데이트해 나간다. 이 방식은 데이터가 다소 적더라도 기본은 물리 모델이 잡아주고, AI는 세부적인 조정과 환경 변화 반영에 집중하기 때문에, 순수 데이터 기반 모델보다 안정적이고 엔지니어가 해석하기도 상대적으로 쉽다.

또 다른 측면에서 Physical AI는 자율주행 운반차(AGV·AMR), 스마트 크레인, 점검 드론, 검사 로봇, 작업용 로봇팔 등 실제 장비 제어에 적용된다. 예를 들어 자율주행 운반차는 공장 내부의 지도, 현재 위치, 주변 장애물, 작업 우선순위 등을 종합해 안전하면서도 효율적인 경로를 스스로 선택해 이동한다. 스마트 크레인은 훅의 흔들림, 코일이나 슬래브의 위치, 주변 설비·사람의 위치를 인식하고, 흔들림을 최소화하면서 목표 지점으로 정확히 이동하는 제어 전략을 자동으로 수행할 수 있다. 드론과 로봇은 사람이 접근하기 어려운 고위험·고소·밀폐 공간을 대신 점검하고, AI가 촬영 영상과 센서 데이터를 분석해 이상 여부를 판단한다. 이 모든 과정에서 Physical AI는 설비의 기계적 한계, 안전 규칙, 제어 시스템 구조를 반드시 지켜야 하며, 설비기술에서 정의한 각종 제약 조건 안에서만 최적의 행동을 찾도록 설계된다.

② 인공지능 적용 기술의 정리

이 다섯 가지 기술은 모두 설비기술(빅데이터)을 중심에 두고 서로 긴밀하게 연결되어 있다. 설비기술은 센서, 제어 시스템, 생산·품질·정비 시스템을 통해 공장에서 벌어지는 현상을 시간·설비·공정 단위로 정리해 기록하고, 이를 AI가 학습하기 좋은 형태로 제공하는 역할을 한다. 그렇게 준비된 데이터를 Machine Learning과 Deep Learning이 활용해 예측과 이상 탐지를 수행하고, CNN·LSTM·트랜스포머로 이어지는 딥러닝 기술 발전 흐름을 따라 점점 더 복잡한 패턴까지 찾아낸다. Vibe Coding은 제미나

이·GPT 같은 AI 기반 코딩 도구를 활용해 이러한 데이터 분석·모델링·시스템 연동 로직을 효율적으로 구현하고 유지하는 데 기여하며, Computer Vision은 영상 데이터를 통해 제품·설비·안전 상태를 자동으로 읽어낸다. Physical AI는 공정 물리 모델과 실제 설비 제어를 인공지능과 결합해, 공장의 움직임 자체를 똑똑하게 바꾸어 나간다. 결국 "인공지능 기반 기술 + 설비기술(빅데이터)"는 공장의 물리 세계를 디지털로 충실히 담고, 그 위에서 다양한 AI·코딩 기술이 함께 작동해 공정 운영, 설비 관리, 품질·안전 수준을 전반적으로 고도화하는 통합적인 시스템이라고 정리할 수 있다.

3-2. 철강 산업 도메인 지식과 인공지능의 결합

① 인공지능 기반 기술: 데이터를 통해 패턴을 학습하는 엔진

먼저 "인공지능 기반 기술"은 철강 공정·설비에서 발생하는 복잡한 데이터를 입력으로 받아,
그 안에 숨은 패턴을 스스로 찾아내고, 이를 바탕으로 예측·분류·최적화·판단을 수행하는 기술이다.

1. 철강 현장에서 주로 활용되는 인공지능 기술은 기능에 따라 다음과 같이 나눌 수 있다.

(1) 예측(Prediction)·회귀 모델

과거의 설비·공정 데이터를 바탕으로,
앞으로의 설비 상태, 품질 결과, 에너지 사용량 등을 수치로 예측하는 기술이다.
예를 들어, 현재 조업조건을 기준으로 "롤 힘, 출측 온도, 제품 특성이 향후 어떻게 변할지"를 예측하는 것이 여기에 해당한다.

(2) 분류(Classification)·판정 모델

데이터를 보고 "어떤 상태인지"를 구분하는 기술이다.
제품을 양품/불량으로 나누거나, 설비 상태를 정상/주의/위험으로 나누는 것, 이미지에서 표면 결함의 종류를 구분하는 것 등이 대표적인 활용이다.

(3) 이상 탐지(Anomaly Detection)

정상 패턴을 학습해 두고, 그 패턴에서 벗어난 특이한 상태를 찾아내는 기술이다.

일정 기간 동안의 진동·전류·온도 데이터를 보고 "지금은 평소와 다르다"는 것을 감지하는 것이 전형적인 사례다. 이는 고장·품질 불량·효율 저하의 전조를 포착하는 데 활용된다.

(4) 최적화·강화학습 기반 기술

주어진 제약(설비 한계, 품질 기준, 안전 기준 등) 안에서, 에너지·원가를 최소로 하면서 생산량과 품질을 최대화하는 운전 조건을 찾도록 학습시키는 기술이다. 다양한 조업조건을 시뮬레이션하고, 그중 가장 좋은 조합을 자동으로 찾아내는 방향으로 활용된다.

② 설비기술(빅데이터) : 공장 전체를 디지털로 표현하는 기반

"설비기술(빅데이터)"는 단순히 데이터 양이 많다는 의미를 넘어, 설비·공정·조업이 가진 물리적·기술적 특성이 데이터 형태로 정교하게 표현되어 있다는 뜻에 가깝다.

1. 철강 공장에서 설비기술이 빅데이터로 구현되는 모습은 다음과 같이 정리할 수 있다.

(1) 센서·설비 상태 데이터

고로, 전로, 연주기, 압연기, 모터, 펌프, 팬, 크레인 등에서 진동, 온도, 압력, 유량, 속도, 하중, 전류/전압 등의 값이 시간에 따라 연속적으로 발생한다. 이들은 대부분 시계열 데이터이며, 설비의 "심장 박동"과 같은 역할을 한다.

(2) 공정 운전·조업 데이터

조업자가 설정하는 온도·속도·가스 조성·유량·냉각 조건 같은 운전변수, 라인별 생산량, 가동률, 정지 시간, 에너지 사용량 등이 여기에 포함된다. 이는 "어떻게 운영했는가"를 설명해 주는 데이터다.

(3) 품질·결과 데이터

두께, 폭, 형상, 기계적 성질, 표면/내부 결함, 강종별 심사 결과 등 제품의 최종 성적표에 해당하는 데이터다. 조업·설비 상태와 연결하면, "어떤 조건에서 어떤 품질이 나왔는지"를 설명할 수 있게 된다.

(4) 정비・이력 데이터

설비 고장 기록, 정비 내용, 부품 교체 이력, 개조・개선 작업 내역 등은 설비의 “과거 병력”을 보여주는 데이터다. 이는 고장 패턴 분석과 수명 예측의 중요한 근거가 된다.

(5) 영상・이미지 및 비정형 데이터

CCTV 영상, 공정 모니터링 화면, 제품・설비 표면 이미지, 열화상 데이터,

그리고 검사 성적서, 작업일지, 점검 리포트 같은 텍스트 데이터도 설비기술의 일부로 볼 수 있다.

3 인공지능 기반 기술과 설비기술(빅데이터)의 결합 구조

이제 핵심은, 앞에서 설명한 인공지능 엔진과 설비기술(빅데이터)이 어떻게 결합되는지이다.

이 결합은 단일 단계가 아니라, 순차적이고 체계적인 흐름으로 진행된다.

1. 데이터 수집・통합 단계

현장에 설치된 센서와 설비 제어 장치(PLC, DCS), 생산・품질 시스템(MES, 품질 DB),

영상 시스템(CCTV, 검사 카메라) 등에서 데이터를 수집해 하나의 플랫폼으로 모은다.

이 과정에서 설비 태그, 설비 번호, 공정 위치, 시간 정보 등을 기준으로 서로 다른 데이터가 연결된다.

즉, “언제, 어느 설비에서, 어떤 조건으로, 어떤 제품이 생산되었는지”가 동시에 추적 가능해진다.

2. 전처리・가공 및 설비 지식의 반영

수집된 원시 데이터에는 노이즈, 결측값, 오류가 섞여 있다.

이를 걸러내고, 설비・조업 지식을 이용해 의미 있는 지표(파생 변수)를 만들어 낸다.

예를 들어, 단순 진동값 대신 특정 시간 구간의 평균・편차・피크, 주파수 성분 등을 추출하고, 온도・압력은 상승 속도나 안정화 시간처럼 설비 이해가 반영된 지표로 변환한다.

이 단계에서 설비기술이 AI 모델의 “언어”를 만들어 주는 셈이다.

3. 인공지능 모델 학습 단계

가공된 데이터를 이용해 예측・분류・이상 탐지・최적화 모델을 학습시킨다.

이때 단순히 통계적인 정확도만 볼 것이 아니라, 설비・공정 관점에서 모델이 제시하는 결과가 얼마나 설명 가능하고, 실제 조업・정비 의사결정에 활용 가능한지까지 함께 검토한다.

4. 운영・제어 시스템과의 연계 단계

학습된 모델은 모니터링 시스템, 알람 시스템, 혹은 일부 자동 제어 로직과 연계된다.

예를 들어, 압연기에서 코일의 비정상 거동을 영상으로 감지하면, 라인 속도를 줄이거나 정지 신호를 내보내는 식이다.

POSCO 포항제철소의 사례처럼, 영상 인식 AI가 라벨을 자동 판독하고, 압연 공정의 코일 이상을 감지해 조치를 돕는 것은 인공지능과 설비기술이 실제 공정 운영에 결합된 대표적인 모습이다.

5. 피드백・고도화 단계

현장에서 AI 모델의 예측이 정확했는지, 오차가 어디에서 발생했는지,

조업자와 설비 엔지니어가 사용하면서 느끼는 불편함이나 한계는 무엇인지가 다시 데이터로 축적된다. 이 피드백을 반영해 모델을 재학습하고, 필요한 경우 센서 위치・종류, 데이터 수집 주기를 조정하면서 인공지능과 설비기술이 함께 성숙해 나간다.

4 기술체계화 및 교육 프로그램 개발

4-1. 철강산업 디지털 기술교육 체계

1 기술 체계 수립 방향

철강산업 내 디지털 전환(DX)의 성공적 안착을 위해서는 일반적인 직무 교육과 차별화된, 현장 도메인 지식(Domain Knowledge)과 디지털 기술이 결합된 융합 교육이 필수적이다. 따라서 본 가이드라인은 '직무 특성(Vertical)'과 '역량 단계(Horizontal)'를 교차한 매트릭스 구조를 기반으로 기술 체계를 수립하였다. 특히 직무별로 다루는 데이터의 속성(시계열, 진동, 영상 등)과 당면 과제(생산성, 예지보전, 품질 등)를 구조화함으로써, 교육 대상의 정합성을 확보하고 현업 적용도와 실효성을 극대화하고자 한다.

2 직무 기반 디지털 기술 역량 매트릭스 (Job-Based Skill Matrix)

현장 직무를 크게 생산/조업, 설비/정비, 품질/안전, 경영/지원 4개의 축으로 분류하고, 역량 단계를 이해(Literacy), 활용(Application), 전문(Expert)의 3단계로 구조화하였으며, 각 직무에 따른 핵심기술과 교육과정 수립방향, 적용가능한 예시를 포함하였다.

1. 생산/조업 (Operation) - "생산량 Active제어를 위한 DX"

(1) **핵심 기술** : Machine Learning(회귀/분류), Reinforcement Learning (강화학습, 심화과정), Optimization (공정 최적화), Data Visualization (시각화)

(2) **교육 방향** : 숙련된 오퍼레이터의 암묵지(조업 노하우)를 데이터화하고, 변동하는 조업 환경(온도, 성분 등)에서 최적의 생산 조건을 AI를 통해 제안받거나 제어하는 기술역량향상

[표 4-1] 생산/조업 적용 예시

핵심 기술	적용 예시	상세 내용
Machine Learning	가열로 온도 최적 제어	투입되는 슬라브의 초기 온도 및 성분, 다음 공정의 목표 온도를 고려하여 연료 소모를 최소화하는 가열로 내부 온도 곡선 최적화
Reinforcement Learning	도금 부착량 최적 제어 AI	(용융) Airknife 압력, Strip 속도, 용탕 온도 또는 (전기) 전류 밀도, 용액 농도 등 복합 변수를 실시간으로 제어하여 목표 도금량을 정밀하게 준수하고 원재료 소모를 최소화하는 최적 제어 시스템 구현
Machine Learning	출선 성분 예측 모델	원료 배합, 장입 패턴, 코크스 반응성 등 조업 데이터를 기반으로 출선 직전의 용선 성분을 예측하여 즉각적인 공정 보정값 산출
Machine Learning/RL	전기로 전력 패턴 최적화	전기로의 전극 투입 시점, 전력 공급량, 산소 투입량을 RL로 학습하여 단위 시간당 에너지 비용은 최소화하고 생산량 목표는 달성하는 제어 전략 수립
Machine Learning	연속 주조 슬라브 표면 결함 발생 확률 예측	주조 속도, 몰드 온도, 용제 투입량 등의 변수 조합에서 표면 크랙 또는 내부 결함이 발생할 위험도를 예측하여 조업자에게 경고 및 조업 조건 제안
Reinforcement Learning	열연/냉연 압연기 최종 두께 정밀 제어	압연 중 발생하는 온도와 폭의 미세 변동을 감지하고, 압연 롤의 간격(Gap)과 장력(Tension)을 실시간으로 조정하여 제품의 두께 편차를 최소화

2. 설비/정비 (Maintenance) - “지속적인 설비 가동을 위한 DX”

(1) 핵심 기술: 진동 분석 (Vibration Analysis), 신호 처리 (Signal Processing), 시계열 분석 (Time-series Analysis)

(2) 교육 방향: 예방보전(PM, Preventive Maintenance), 사후보전(BM, Breakdown Maintenance), 수준을 넘어, 고장 시점을 예측하는 ‘예지보전(PdM, Predictive Maintenance)’ 역량 확보. 회전체(모터, 감속기)의 진동 주파수 스펙트럼(FFT) 분석 및 전류/온도 데이터의 시계열 패턴 분석을 통해 이상 징후를 조기 탐지

[표 4-2] 설비/정비 적용 예시

핵심 기술	적용 예시	상세 내용
진동 분석/시계열	압연기 롤 베어링 결함 진단	압연기(Rolling Mill)의 고하중 베어링에서 발생하는 궤도 손상, 볼 손상 등의 미세 결함 진동을 FFT 분석으로 조기 탐지
시계열 분석	유압 펌프/모터 잔존 수명(RUL) 예측	유압 시스템의 압력/온도/전류 시계열 패턴 분석을 통해 핵심 구동부의 남은 수명을 예측하고 정비 시점 최적화
진동 분석	설비 강건성 모니터링	대형 모터, 감속기, 팬/블로워 등 주요 회전체의 이상 진동 감지 및 고장 유형(미스얼라인먼트, 언밸런스 등) 분류
시계열 분석	연속공정에서 공정별 설비보전시점과 위치 실시간 예측	제선-제강-압연으로 이어지는 연속 공정에서 특정 설비의 부하/성능 데이터를 분석하여 연쇄적인 고장을 막기 위한 최적의 보전 구간 및 시간 예측
진동 분석/시계열	대형 밸브 및 댐퍼의 비정상 작동 진단	가스 또는 유체 제어에 사용되는 대형 밸브 및 댐퍼의 개폐 시 진동, 소음, 전류 패턴의 변화를 분석하여 미작동, 누설 등의 고장 예측
신호 처리/시계열	고로, 전로, 전기로 내화물 마모도 패턴 예측	Furnace 내부의 온도 분포 및 벽체 열전대 데이터의 시계열 패턴 변화를 분석하여 내화물의 침식 및 수명 종료 시점 예측

3. 품질/안전 (Quality & Safety) - “작업자의 눈을 대체하는 DX”

(1) 핵심 기술 : Computer Vision(CNN, Object Detection)

(2) 교육 방향 : 육안 검사에 의존하던 표면 결함 판정을 카메라와 AI로 자동화. CCTV 영상을 분석하여 작업자의 불안전 행동(방호벽 접근, 헬멧 미착용)을 실시간 탐지하는 AI활용 기술 역량 향상

[표 4-3] 품질/안전 적용 예시

핵심 기술	적용 예시	상세 내용
Computer Vision	코일 스크래치 자동 검출	고속으로 이동하는 제품 표면의 미세한 흠집, 찍힘, 스크래치 등을 실시간으로 검출하고 위치 및 심각도를 기록
Computer Vision	크레인 작업 반경 내 사람 인식	크레인, 지게차 등 중장비의 이동 경로 및 작업 반경 내 접근하는 작업자를 실시간으로 감지하여 충돌 위험을 예방
Computer Vision	용접 비드 결함 자동 판독 및 등급 분류	X-ray, CT 또는 3D 스캐너 이미지 분석을 통해 내부 기포, 슬래그 등 용접 결함을 미세하게 검출하고 국제 표준에 따라 등급 부여
Computer Vision	작업장 위험 구역 침입 실시간 경고 시스템	이동식 장비(지게차, 크레인) 주변의 설정된 안전 구역(Safety Zone) 침입 시 즉시 작업자에게 경고 송출 및 장비 가동 중단 요청
Computer Vision	장비 방호벽 개방 여부 및 안전 잠금장치 인식	기계 설비의 방호 장치가 제대로 닫혀 있는지, 또는 작업 중 안전 잠금장치가 해제되지 않았는지 실시간 모니터링

4. 경영/지원 (Management) - “과학적 의사결정을 위한 DX”

(1) **핵심 기술** : RPA(Robotic Process Automation), Forecasting(예측 분석), NLP(자연어 처리)

(2) **교육 방향** : 수작업 보고서 작성 및 반복되는 회의시간을 단축하고, 실시간 시장 데이터(원료비, 환율, 경쟁사동향 등)를 분석하여 구매/판매 시점과 적정 판매가격을 예측하는 AI활용 기술 역량 향상

[표 4-4] 경영/지원 적용 예시

핵심 기술	적용 예시	상세 내용
Forecasting	철스크랩 가격 예측 모델	원자재 시장 변동성 분석을 통한 최적 구매 시점 도출 및 비용 절감
NLP/RPA	챗봇 기반 사내 규정 검색 시스템	방대한 내부 문서(규정, 지침)에서 정확한 정보를 즉시 추출하여 보고서 작성 시간 단축 및 질의 응답 자동화
Forecasting	거시 경제 요소를 반영한 분기별 판매 수요 예측 모델	환율, 금리, 산업 동향 등 외부 데이터를 통합 분석하여 생산 계획 및 재고 수준 최적화
RPA	자동화된 공급업체 인보이스 처리 및 지급 결재 시스템	OCR 및 RPA를 활용하여 인보이스 데이터를 ERP에 자동 입력하고, 결재 라인에 따라 지급을 실행하여 수작업 오류 및 처리 시간 최소화
NLP/Forecasting	SNS 및 뉴스 데이터를 활용한 실시간 시장 동향 및 경쟁사 분석 시스템	비정형 텍스트 데이터의 감성 분석을 통해 제품 및 시장 변화에 대한 신속한 대응 전략 수립 지원
RPA/NLP	계약서 주요 조항 자동 추출 및 협상 리스크 분석 툴	법률 문서에서 핵심 의무 조항, 손해배상 규정 등을 자동 추출하여 계약 검토 및 협상 리스크 사전 예측
Forecasting	직원 퇴사율 및 핵심 인재 이탈 예측 모델 (HR)	근속 기간, 급여, 프로젝트 참여도 등 내부 데이터를 기반으로 인력 이탈 가능성을 예측하고 선제적 관리 방안 제시

4-2. 교육 프로그램 개발 방법

1 교수설계모형

본 가이드라인은 체계적인 교육 프로그램 개발을 위해 기업의 직무역량 향상을 위해 널리 활용되는 ADDIE(Analysis-Design-Development-Implementation-Evaluation) 모형을 철강산업 특수성에 맞춰 재해석하여 적용하였다.

[그림 4-1] 교수설계모형

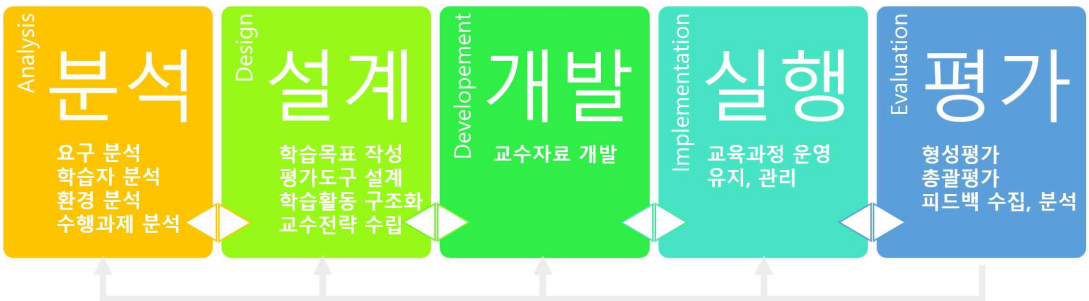

1. **분석 (Analysis)** : 현장의 고질적 문제(Pain Point) 도출 및 학습자 특성 분석을 목적으로 아래와 같은 사항을 고려하여 작성한다.

   (1) **현장 Pain Point 도출** : 생산량 감소, 고질적 품질 불량, 잦은 설비 Shut-down 등 현장의 정량적/정성적 문제점을 목록화하고 DX 솔루션 도입에 따른 우선순위 선정

   (2) **요구 역량 Gap 분석** : DX 전환을 위해 필요한 기술 역량(컴퓨팅 사고력, 데이터 분석, AI 모델 이해)과 현재 수준 간의 기술 격차(Skill Gap) 정밀 분석

   (3) **학습자 특성 분석** : 교대 근무자의 학습 가능 시간, 온라인/오프라인 선호도, 사전 지식 수준(IT Literacy) 등을 고려하여 학습 환경 설계 기초 자료 확보

   (4) **기술 환경 분석** : 학습에 활용할 데이터 수집 인프라 및 교육용 분석 환경(Python Jupyter Notebook 등) 점검

2. **설계 (Design)** : 학습 목표 및 블렌디드 러닝 구조 설계를 목적으로 아래와 같은 사항을 고려하여 작성한다.

   (1) **블렌디드 러닝 구조 설계** : 이론 교육(온라인/E-Learning), 기본 실습(가상 환경), 심화 적용(실제 공장 데이터 기반 문제 해결 프로젝트)을 유기적으로 통합하는 최적의 학습 경로 및 모듈별 시간 배분 구조화

   (2) **평가 계획 수립** : 각 모듈별 진단 평가, 형성 평가, 최종 수행 평가(Performance Assessment) 등 평가 방식 및 가중치를 사전에 결정하고, 평가 도구의 신뢰성 및 타당성 확보

   (3) **커리큘럼 연계성 확보** : 이해(기초)-활용(기본)-전문(심화) 과정 간의 학습 전후 모듈 간의 유기적인 연결을 통해 학습 효과 극대화

3. **개발 (Development)**

   교육의 현장감을 높이기 위해 실제 공장 데이터를 정제하여 실습용 데이터셋을 구축하고, 이에 기반한 교수 자료 및 가상 실습 환경을 개발한다.

   (1) **실습 데이터셋(Dataset) 구축** : 실제 공장 설비에서 수집된 정상/고장 데이터(진동, 온도, 압력 등 시계열 데이터)를 정보보안을 고려하여 전처리 후 교육용 데이터셋으로 개발

   * 데이터셋(dataset) : 인공지능(AI)이나 통계 분석, 머신러닝 모델 학습에

사용하기 위해 구조화된 형태로 수집·정리된 데이터의 집합

(2) 시뮬레이터/가상 환경 개발: 실제 장비를 대체하거나 위험 요소를 제거하고 반복 학습을 가능하게 하는 디지털 트윈 기반 시뮬레이터(Digital Twin Simulator) 또는 가상 실습 환경 구축

(3) 콘텐츠 제작: Micro-Learning을 위한 5~10분 내외의 영상 콘텐츠, 인터랙티브 퀴즈, 문제 해결형 워크북 등 학습 자료 제작

(4) 강사 역량 강화: SME(Subject Matter Expert, 사내 강사)를 위한 강사 가이드, 교수법 워크숍, 교육 자료 활용 방안 코칭

4. 실행 (Implementation)

직무 교육의 효과성을 극대화하기 위해, 현업 전문가(SME) 활용과 마이크로 러닝 도입을 통해 시간과 장소의 제약을 최소화하고 실무 적용력을 높이는 운영 전략을 수립한다.

(1) 사내 강사(SME) 활용 극대화 : 현업 전문가(SME)를 투입하여 이론과 현장 경험을 연계하는 생동감 있는 교육 운영 및 실습 지도 멘토링 제공.

(2) 마이크로 러닝 적용 운영 : 교대 근무자의 장소제약 없는 학습을 지원하기 위해 모바일 기반 숏폼형태의 짧고 집중적인 콘텐츠를 제공하여 접근성 및 효율성 제고.

(3) OJT 연계 : 교육 이수 후 현업 복귀 시, 배운 내용을 즉시 적용할 수 있도록 OJT(On-the-Job Training) 프로세스와 연계, 후속 멘토링 프로그램 운영.

(4) 학습 관리 시스템(LMS) 운영 : 진도율, 성취도, 평가 결과를 체계적으로 기록 및 관리하고, 학습자 맞춤형 피드백 제공.

5. 평가 (Evaluation)

Kirkpatrick 4단계 평가를 통한 현업 기여도 측정 및 피드백적용

(1) Kirkpatrick 4단계 평가

(가) 반응 (Reaction) : 학습 만족도, 강사 전문성, 교육 환경 등에 대한 설문조사 실시

(나) 학습 (Learning) : 지식 습득 정도(이론 시험) 및 실습 문제 해결 능력(실제 데이터 기반 문제 해결률) 측정.

(다) 행동 (Behavior) : 교육 이수 후 3~6개월 동안 현업에서 AX/DX 기술 활용 정도 및 문제 해결 방식 변화 모니터링

(라) 결과 (Results) : 교육 참여자의 현업 기여도(설비 가동률 향상, 불량률 감소, 에너지 비용 절감)를 정량적 지표(KPI)로 측정

(2) 교육 효과 측정 및 피드백/환류

Kirkpatrick 4단계 평가 결과를 정량·정성 지표로 분석하여, 각 과정의 강점과 개선 필요 영역을 도출하고, 이를 다음과 같은 항목별로 체계적으로 반영한다.

(가) 커리큘럼 측면 : 난이도 조정, 모듈 구성 재배치, 실습 비중 확대/축소 등 교육 내용 재설계

(나) 콘텐츠 측면 : 사례·데이터 최신화, 철강 현장 특화 예시 보강, 실습 자료 품질 개선

(다) 운영 측면 : 교육 시간·방식(온라인/오프라인, 교대근무 반영), 강사 구성 및 지원 체계 조정

4-3. 수준별·직무별 교육 프로그램 개발가이드

1 개요

앞서 수립한 기술 매트릭스 중 수준별·직무별로 3개 과정(Lv.1 정비, Lv.2 조업, Lv3 품질)에 대한 교육프로그램 설계안을 교육 과정 개발 예시로 작성하였다.

[표 4-5] 교육프로그램 설계안

구분	①생산/조업 (Operation)	②설비/정비 (Maintenance)	③품질/안전 (Quality & Safety)	④ 경영/지원 (Office/Support)
정의	고로/제강/압연 공정 제어 및 최적 생산	설비 상태 감시 및 예지보전	재질/표면 결함 제어 및 작업자 안전	SCM, 구매, 인사, 재무 등 데이터 기반 의사결정
Lv.1 (이해)	**[데이터 시각화]** - 공정 모니터링 대시보드 활용 - SCADA/MES 데이터 구조 이해	**[센서 기초]** - IoT 센서 종류 및 원리 이해 - 설비 데이터 수집 구조 파악	**[디지털 안전]** - 스마트 안전장구(웨어러블) 활용 - 품질 데이터 기초 통계	**[RPA/BI 기초]** - 엑셀/BI 도구를 활용한 데이터 시각화 - 단순 반복 업무 자동화(RPA)
Lv.2 (활용)	**[공정 최적화 기초]** - Big Data 기반 조업 인자 분석 - 최적 운전 패턴 도출 (ML)	**[Vibration Analysis/진동진단]** - 진동/전류 데이터 분석 - 이상 징후 탐지(Anomaly Detection)	**[Vision AI 활용]** - 표면 결함 이미지 분류 실습 - CCTV 기반 위험 행동 감지	**[수요/가격 예측]** - 원자재 가격 변동 예측 모델 - 재고 최적화 알고리즘 활용
Lv.3 (전문)	**[AI 제어/ 최적화]** - 데이터기반 공정 자동 제어 모델 개발 - AI 기반 조업 가이드 시스템 구축	**[예지보전(PdM) 모델링]** - 설비 잔존 수명(RUL) 예측 - 고장 유형 분류 딥러닝 모델	**[Deep Learning 심화]** - 비정형 영상 데이터 실시간 분석 - 지능형 품질 판정 시스템 개발	**[통합 경영 AI]** - 전사 데이터 통합 플랫폼 설계 - AI 기반 경영 시뮬레이션

② 교육과정 개발 예시

1. 설비/정비 직무 Lv.1 [센서 기초]

(1) 과정명 : 철강 설비 IoT 센서 기초 및 데이터 수집 구조 이해

(2) 과정 개요

[표 4-6] 설비/정비 직무 과정 개요

구분	내용
대상 직무	설비/정비 (Maintenance)
역량 수준	Lv.1 이해 (Literacy)
교육 목표	철강 설비에 적용되는 주요 IoT 센서의 종류·원리를 이해하고, 설비 데이터 수집 구조를 파악하여 현장 모니터링 시스템의 기본 개념을 습득한다.
교육 시간	총 16시간 (이론 10H + 실습 6H) / 2일 블렌디드러닝
선수 학습	해당 없음 (입문 과정)
후속 연계	Lv.2 [Vibration Analysis/진단] - 진동·전류 데이터 분석 과정

(3) 교육과정 설계

(가) 분석(Analysis) 단계 : 교육의 필요성을 명확히 하고, 학습자・환경・과제를 체계적으로 분석

1) 요구 분석 (Needs Analysis)

[표 4-7] 설비/정비 직무 요구분석 개요

분석 항목	세부 내용
현업 Pain Point	설비 고장 시 센서 데이터의 의미를 해석하지 못해 원인 파악 지연 신규 IoT 센서 도입 시 정비 인력의 이해 부족으로 활용도 저하 데이터가 수집되어도 "어디서, 무슨 데이터가, 어떻게" 들어오는지 모름
교육 목적	설비 데이터 기반 의사결정의 첫 단계로, 센서와 데이터 흐름에 대한 기본 소양 확보
핵심 과제	현장 모니터링 화면의 데이터 의미 해석 가능, 센서 이상 시 1차 진단 역량 확보

2) 학습자 분석 (Learner Analysis)

[표 4-8] 설비/정비 직무 학습자 분석 개요

분석 항목	세부 내용
대상	설비관리팀, 정비반, 전기계장 담당자 (신입~경력 3년 미만)
사전 지식	설비 운전 기초, 전기 기초 (OJT 수준), 디지털 역량 제한적
학습 동기	고령 숙련자 퇴직 대비, 스마트 설비 도입에 따른 역량 전환 필요성 인식
학습 제약/특성	교대 근무로 집체 교육 참여 어려움, IT 용어에 대한 심리적 거부감

3) 환경 분석 (Environment Analysis)

[표 4-9] 설비/정비 직무 환경 분석 개요

분석 항목	세부 내용
물리적 환경	사내 교육장 또는 현장 인근 회의실, PC 실습 가능 환경 필요
기술적 환경	실습용 IoT 센서 키트 또는 시뮬레이터, 웹 기반 대시보드 데모 환경
조직적 지원	교대 근무자 배려를 위한 분반 운영, 관리자 승인 필요

4) 수행과제 분석 (Task Analysis) : 학습 후 수행 가능해야 할 과제를 도출

[표 4-10] 설비/정비 직무 수행과제 분석 개요

과제 번호	수행 과제	필요 지식/기술
T1	주요 설비(모터, 펌프 등)에 부착된 센서 종류를 식별한다	센서 유형별 특징
T2	진동·온도·전류 센서의 측정 원리를 설명한다	물리량 측정 원리
T3	센서 → 게이트웨이 → 서버 데이터 흐름을 도식화한다	데이터 수집 아키텍처
T4	현장 모니터링 대시보드에서 이상 데이터를 식별한다	데이터 시각화 해석

(나) 설계(Design) 단계 : 분석 결과를 토대로 학습 목표, 커리큘럼, 평가방법을 설계

1) 학습 목표 수립

a. 최종 학습 목표

교육 수료 후, 학습자는 철강 설비에 적용되는 주요 IoT 센서(진동, 온도, 전류, 압력)의 측정 원리를 설명하고, 센서로부터 수집된 데이터가 모니터링 시스템에 표시되기까지의 흐름을 도식화할 수 있다.

[표 4-11] 설비/정비 직무 학습목표 개요

항목	내용
학습 목표	진동 센서(가속도계)의 물리적 측정 원리를 설명하고, 철강 설비에서의 적용 사례를 열거할 수 있다.
주요 내용	① 진동의 정의 (변위, 속도, 가속도) ② 압전소자(Piezoelectric) 원리 ③ MEMS 가속도계 구조 ④ 철강 현장 적용 예시: 모터 베어링, 감속기, 압연 롤
교수 방법	강의 (30분) + 센서 실물/영상 시연 (15분) + Q&A (15분)
교수 매체	PPT, 진동 센서 실물, 철강기업 적용 사례 영상
평가	모듈 종료 후 퀴즈 5문항 (예: "압전소자의 원리를 옳게 설명한 것은?")

b. 커리큘럼

[표 4-12] 설비/정비 직무 커리큘럼 개요

모듈명	세부 교육 내용	핵심 학습 목표	시간(H)	교수 방법
M1. IoT 센서 개론	1-1. 철강 설비와 디지털 전환 1-2. 센서의 정의와 분류 1-3. 현장 적용 센서 종류	설비 4대 핵심 센서 유형을 식별할 수 있다.	2H	이론 강의
M2. 센서 측정 원리	2-1. 진동 센서 원리 2-2. 온도 센서 원리 2-3. 전류 센서 원리 2-4. 압력 센서 원리	각 센서의 물리적 측정 원리를 설명할 수 있다.	4H	이론+시연
M3. 데이터 수집 구조	3-1. Edge Device & Gateway 3-2. 통신 프로토콜 및 DB 저장	데이터 수집 및 전송 흐름을 도식화할 수 있다.	4H	이론+실습
M4. 시각화 실습	4-1. 모니터링 대시보드 구성 4-2. [실습] 이상 데이터 식별	모니터링 화면에서 이상 패턴을 구분할 수 있다.	6H	실습 100%

3) 평가 도구 설계 (Assessment Design)

[표 4-13] 설비/정비 직무 평가도구 설계

평가 유형	평가 방법	평가 시점	배점
진단 평가	사전 설문 (디지털 역량 자가진단 10문항)	교육 전	-
형성 평가	모듈별 퀴즈 (객관식 5문항/모듈)	각 모듈 종료 시	40%
총괄 평가	실습 과제: 데이터 흐름도 작성 + 이상 징후 식별 보고서	교육 종료 시	60%

(다) 개발(Development) 단계 : 설계명세서를 바탕으로 실제교수자료와 실습환경 제작

1) 교재 및 콘텐츠 개발

[표 4-14] 설비/정비 직무 교재 및 콘텐츠 개발

자료 유형	상세 내용
교재 (매뉴얼)	「철강 설비 IoT 센서 기초」 책자형 교재
실습 워크북	모듈별 실습 시트, 데이터 흐름도 템플릿, 체크리스트 등
영상 콘텐츠	센서 설치 현장 영상 (10분), 데이터 흐름 애니메이션 (5분)

2) 실습 환경 구축

[표 4-15] 설비/정비 직무 실습 환경 구축

실습 도구	용도	비고
IoT 센서 키트	진동·온도·습도 센서 체험	아두이노 또는 산업용 미니 키트
웹 대시보드 데모	실제 철강 설비 데이터 시뮬레이션	Grafana 또는 자체 개발 시뮬레이터
Historical Data	정상/이상 패턴 비교 분석용	실제 공장 데이터 익명화 가공

3) 강사 가이드 개발

[표 4-16] 설비/정비 직무 강사 가이드 개발

항목	내용
강사 요건	설비 정비 경력 5년 이상 + IoT/데이터 분석 기초 역량 보유자
강의 가이드	차시별 시간 배분, 질의응답 예상 목록, 실습 진행 팁 포함

(라) 실행(Implementation) 단계 : 개발된 프로그램을 기업특성이 맞추어 효과적으로 운영하기 위한 전략을 수립

1) 운영 방식 (Blended Learning)

[표 4-17] 설비/정비 직무 운영방식

구분	운영 방식	시간	비고
사전 학습 (온라인)	M1, M2 이론 영상 + 퀴즈	4H	LMS 활용, 자기주도 학습
집체 교육 (오프라인)	M3, M4 실습	8H (1일)	실습 장비 활용
사후 학습 (온라인)	복습 퀴즈 + 현업 적용 과제	4H	4주 내 완료

2) 파일럿 운영 계획(필요시)

[표 4-18] 설비/정비 직무 파일럿 운영 계획

단계	활동	일정 (예시)
1차 파일럿	선발 인원 (10명) 대상 시범 운영	1주차
피드백 수집	설문조사 + 강사 소견서	1주차 말
콘텐츠 보완	난이도 조절, 실습 시간 재배분	2주차
본격 운영	전사 대상 순차 운영	3주차~

3) 교대 근무자 배려 운영 전략

- **마이크로 러닝** : 1개 모듈을 5~10분 단위 숏폼 콘텐츠로 분할 제공
- **반복 개설** : 동일 과정 월 2~3회 개설하여 교대조별 참여 기회 보장
- **현장 출장 교육** : 필요 시 각 공장별 교육장에서 집체 교육 진행

(마) 평가(Evaluation) 단계 : 교육의 효과성을 다층적으로 측정하고 개선점을 도출. 환류를 통한 지속적인 프로그램 내실 강화

1) Kirkpatrick 4단계 평가 모델 적용

[표 4-19] 설비/정비 직무 Kirkpatrick 4단계 평가 모델 적용

평가 수준	평가 내용	측정 방법	측정 시점
Level 1: 반응	교육 만족도, 강사 평가, 실습 환경 만족도	설문조사 (5점 척도)	교육 직후
Level 2: 학습	학습 목표 달성도 (지식 습득)	진단, 형성, 총괄평가	교육 전/후
Level 3: 행동	현업 적용도 (모니터링 화면 해석 가능 여부)	상사/동료 평가	교육 후 1개월
Level 4: 결과	센서 관련 문의/장애 대응 시간 단축	KPI 측정 (Before-After)	교육 후 3개월

2) 피드백/환류활동 예시

[표 4-20] 설비/정비 직무 피드백/환류활동 예시

개선 영역	Feedback 활동 예시
콘텐츠	어려운 용어 추가 해설, 실습 시나리오 현실화
운영	실습 시간 확대, 온라인 비중 조정

2. 생산/조업 직무 Lv.2 [공정 최적화 기초]

(1) 과정명 : 철강 공정 데이터 분석 및 머신러닝 기반 조업 최적화

(2) 교육과정 개요

[표 4-21] 생산/조업 직무 교육과정 개요

구분	내용
대상 직무	생산/조업 (Operation)
역량 수준	Lv.2 활용 (Application)
교육 목표	철강 조업 빅데이터를 분석하여 핵심 영향 인자(X)를 도출하고, 머신러닝 모델을 활용해 생산성 및 품질을 극대화할 수 있는 최적 운전 패턴(Y)을 제안한다.
교육 시간	총 24시간 (이론 8H + 실습/PBL 16H) / 3일 집체 또는 4주 블렌디드
선수 학습	Lv.1 데이터 리터러시 (기초 통계, 시각화 도구 활용 가능자)
후속 연계	Lv.3 [AI 제어/최적화] - 데이터 기반공정 자동 제어 모델 개발 과정

(3) 교육과정 설계

(가) 분석(Analysis) 단계 : 교육의 필요성을 명확히 하고, 학습자・환경・과제를 체계적으로 분석

1) 요구 분석 (Needs Analysis)

[표 4-22] 생산/조업 직무 요구 분석

분석 항목	세부 내용
현업 Pain Point	베테랑 작업자의 경험(감)에 의존하여 근무조별 품질/생산성 편차 발생 수많은 조업 인자(온도, 압력, 속도 등) 중 무엇이 불량의 주원인인지 파악 곤란 "데이터는 쌓여있는데 어떻게 써야 할지 모름"
교육 목적	경험 기반(Empirical) 조업에서 데이터 기반(Data-driven) 조업으로의 전환
핵심 과제	조업 인자 간 상관관계 규명, 품질 예측 모델 구현, 최적 Set-point 도출

2) 학습자 분석(Learner Analysis)

[표 4-23] 생산/조업 직무 학습자 분석

분석 항목	세부 내용
대상	공정 엔지니어, 조업 파트장, 품질 개선 담당자
사전 지식	공정 메커니즘(도메인 지식)은 전문가 수준이나, 코딩 및 통계적 분석 역량은 부족
학습 동기	데이터 기반 의사결정 역량 확보를 통한 공정 트러블 슈팅 능력 향상
학습 제약/특성	복잡한 수식보다는 “내 공정의 문제를 해결하는 방법“ 위주의 실용적 학습 선호

3) 환경분석(Environment Analysis)

[표 4-24] 생산/조업 직무 환경 분석

분석 항목	세부 내용
물리적 환경	실습용 PC 및 데이터 분석 소프트웨어(Python, BI 툴 등) 구동 환경 필요
데이터 환경	보안 심의가 완료된 과거 조업 이력 데이터(Historical Data) 확보 필수
조직적 지원	근무 시간 내 교육 참여 및 실습용 데이터 반출 승인

4) 수행과제 분석

[표 4-25] 생산/조업 직무 수행과제 분석

과제 번호	수행 과제	필요 기술/지식
T1	조업 데이터 전처리 (결측치, 이상치 처리)	Pandas, 데이터 정제
T2	[핵심] 조업 인자 영향도 분석(상관관계 분석)	Heatmap, Scatter, Correlation
T3	[핵심] 운전 패턴 도출(예측 모델링)	Regression, Decision Tree, Random Forest
T4	최적 조업 조건 설정	시뮬레이션, 최적화

(나) 설계(Design) 단계 : 분석 결과를 토대로 학습목표, 커리큘럼, 평가방법을 설계

1) 학습 목표 수립 (Performance Objectives)

최종 학습 목표: 학습자는 Python(또는 분석 툴)을 활용하여 과거 조업 데이터를 분석함으로써 품질에 영향을 미치는 핵심 인자 3가지 이상을 규명하고, 목표 품질 달성을 위한 최적의 운전 범위를 도출할 수 있다.

2) 커리큘럼 (Curriculum Structure)

[표 4-26] 생산/조업 직무 커리큘럼

모듈명	세부 교육 내용 (Topic)	핵심 학습 목표	시간 (H)	교수 방법
M1. 데이터 전처리	1-1. 철강 데이터 특성(시계열, 노이즈) 이해 1-2. 결측치/이상치 정제 기법 실습 1-3. 데이터 핸들링 (Pandas 활용)	수집된 Raw Data의 노이즈를 제거하고 분석 가능한 형태로 가공할 수 있다.	4H	강의 50% 실습 50%
M2. 인자 분석	2-1. 기초 통계 및 분포 확인 (EDA) 2-2. 상관관계 분석 (Correlation Analysis) 2-3. 변수 중요도(Feature Importance) 산출	통계적 근거와 시각화를 통해 품질에 영향을 미치는 핵심 인자를 도출할 수 있다.	6H	강의 30% 실습 70%
M3. 예측 모델링	3-1. 머신러닝 개요 (지도학습: 회귀 vs 분류) 3-2. 알고리즘 실습 (Linear Reg, Decision Tree) 3-3. 모델 성능 평가 (RMSE, Accuracy)	회귀 및 분류 알고리즘을 적용하여 신뢰할 수 있는 품질 예측 모델을 개발할 수 있다.	8H	강의 50% 실습 50%
M4. PBL	4-1. [프로젝트] 가열로/압연 공정 최적화 과제 4-2. 최적 운전 범위(Operating Window) 도출 4-3. 시뮬레이션 검증 및 결과 발표	학습한 모델을 활용해 불량률을 최소화하는 최적 운전 패턴을 제안할 수 있다.	6H	팀 프로젝트

[표 4-27] 생산/조업 직무 세부 강의계획서 예시

항목	내용
학습 목표	조업 인자 간의 상관관계를 히트맵(Heatmap)으로 시각화하고, 통계적 수치를 기반으로 품질에 영향을 미치는 핵심 변수를 선정할 수 있다.
주요 내용	① 피어슨 상관계수(Pearson Correlation Coefficient)의 개념 및 해석 ② 산점도(Scatter Plot) 행렬 및 히트맵 그리기 실습 ③ 다중공선성(Multicollinearity) 문제의 이해 ④ 철강 조업 데이터(온도-품질, 압력-두께) 상관성 분석 실습
교수 방법	이론 강의(30분) + Python 실습(50분) + 결과 해석 및 토의(40분)
교수 매체	강의 교안(PPT), Jupyter Notebook 실습 코드, 철강 조업 샘플 데이터셋(CSV)
평가	실습 결과물 평가 (제시된 데이터셋에서 상관계수 0.7 이상인 변수 쌍을 찾아내고 그 의미를 적절히 해석

3) 평가 도구 설계

[표 4-28] 생산/조업 직무 평가 도구 설계

평가 유형	평가 방법	평가 시점	배점
진단 평가	기초 통계 지식 사전 테스트	교육 전	-
수행 평가	팀 프로젝트 결과물 (분석 논리성, 모델 정확도, 개선안의 현실성)	교육 종료 시	80%
지식 평가	데이터 분석 이론 및 방법론 퀴즈	교육 중	20%

(다) 개발(Development) 단계 : 설계명세서를 바탕으로 실제교수자료와 실습 환경 제작

1) 교재 및 콘텐츠 개발

[표 4-29] 생산/조업 직무 교재 및 콘텐츠 개발

자료 유형	상세 내용
워크북	'따라하며 배우는 철강 데이터 분석' (코드 스니펫 및 No-Code 툴 매뉴얼 포함)
치트 시트	자주 쓰는 Pandas 명령어, Sklearn 모델링 코드 요약표
데이터셋	가열로 온도, 압연 하중 등 공정별 모의 데이터셋

2) 실습 환경 구축

[표 4-30] 생산/조업 직무 실습 환경 구축

실습 도구	용도	비고
분석 환경	데이터 전처리 및 모델링 실습	Jupyter Notebook 또는 사내 분석 플랫폼
시뮬레이터	최적화 결과 검증용 가상 공정 모델	Digital Twin 시뮬레이터 (필요 시)

3) 강사 가이드 개발

[표 4-31] 생산/조업 직무 강사 가이드 개발

항목	내용
강사 요건	제조 데이터 분석 전문가 및 사내 DX 담당자
운영 팁	코드 에러 해결보다는 분석 논리(Logic) 위주의 코칭 가이드 제공

(라) 실행(Implement) 단계 : 개발된 프로그램을 기업특성이 맞추어 효과적으로 운영하기 위한 전략을 수립

1) 운영방식(Problem-Based Learning)

[표 4-32] 생산/조업 직무 운영 방식

구분	운영 방식	비고
강의/실습 비율	강의(30%) : 실습(70%)	직접 데이터를 다루는 시간 극대화
협업 방식	2인 1조 페어 프로그래밍	도메인 전문가 + DX 인력 매칭
데이터 활용	익명처리 된 실제 데이터	본인 공장의 실제 데이터 분석 권장

2) 파일럿 운영 계획 (필요시) : 선도 공장 엔지니어를 대상으로 시범 운영 후, 우수 분석 사례(Best Practice)를 도출하여 전사 확산

(마) 평가(Evaluation) 단계 : 교육의 효과성을 다층적으로 측정하고 개선점을 도출. 환류를 통한 지속적인 프로그램 내실 강화

1) Kirkpatrick 4단계 평가 모델 적용

[표 4-33] 생산/조업 직무 Kirkpatrick 4단계 평가 모델 적용

평가 수준	평가 내용	측정 방법	측정 시점
Level 1: 반응	커리큘럼 만족도, 실습 도구 편의성	설문조사	교육 직후
Level 2: 학습	분석 프로세스 수행 능력, 모델 정확도	프로젝트 평가	교육 종료 시
Level 3: 행동	현업 데이터 분석 시도 및 활용 빈도	상사/본인 평가	3개월 후
Level 4: 결과	공정 산포 감소율, 불량률 개선 효과	KPI 측정	6개월 후

2) 피드백/환류활동 예시

a. 콘텐츠 : 공정별 특화 데이터셋 추가개발, 분석 코드 템플릿 보강

b. 운영 : 분석 툴 난이도 조절(No-code 툴 도입 검토)

3. 품질/안전 직무 Lv.3 [Deep Learning 심화]

(1) 과정명 : Vision AI 기반 지능형 품질 판정 및 스마트 안전 시스템 개발

(2) 교육과정 개요

[표 4-34] 품질/안전 직무 교육과정 개요

구분	내용
대상 직무	품질관리(QC), 안전환경, AI 연구/개발팀
역량 수준	Lv.3 전문 (Expert)
교육 목표	딥러닝(CNN, Object Detection) 기술을 활용하여 비정형 영상 데이터를 실시간으로 분석하고, 현장에 즉시 적용 가능한 '지능형 결함 탐지' 또는 '위험 상황 감지' 시스템을 구축한다.
교육 시간	총 40시간 (이론 12H + 프로젝트 28H) / 5일 집중 코스 또는 8주 프로젝트
선수 학습	Python 중급, 딥러닝중급(CNN)이해, Linux 기초 및 SW개발경험(권장)

(3) 교육과정 설계

(가) 분석 (Analysis) 단계 : 교육의 필요성을 명확히 하고, 학습자・환경・과제를 체계적으로 분석

1) 요구분석 (Needs Analysis)

[표 4-35] 질/안전 직무 요구분석

분석 항목	세부 내용
현업 Pain Point	(품질) 미세한 표면 크랙, 스크래치 등 비정형 결함은 룰(Rule) 기반 검사기로 검출 불가 (안전) CCTV가 수천 대 있으나 관제 인력 부족으로 사고 발생 시 사후 확인용으로만 전락 (공통) 육안 검사자의 피로도에 따라 판정 편차가 심하고, 위험 구역 접근이 어려움
교육 목적	인간의 시각 인지 능력을 대체/보완하는 AI 모델을 자체 개발 및 유지보수할 수 있는 역량 확보
핵심 과제	초고속 라인(분당 수백 미터) 대응을 위한 짧은 추론 시간(Latency)과높은 정확도 동시 달성 필요

2) 학습자 분석 (Learner Analysis)

[표 4-36] 질/안전 직무 학습자 분석

분석 항목	세부 내용
대상	사내 석/박사급 연구원, 현장 엔지니어 중 SW 역량 우수자
사전 지식	오픈소스 활용 능력은 있으나, 실제 공장 환경(조명, 노이즈)에 강건한 모델 설계 경험 부족
학습 동기	Vision AI 기술 내재화를 통한 무인화/지능화 시스템 자체 구축
학습 제약/특성	단순 실습이 아닌, 실제 배포(Deployment)와 최적화(Optimization) 기술 습득 희망

3) 환경 분석 (Environment Analysis)

[표 4-37] 질/안전 직무 환경 분석

분석 항목	세부 내용
H/W 환경	고성능 GPU 서버(V100/A100) 및 엣지 디바이스(Jetson 등) 실습 장비
S/W 환경	PyTorch/TensorFlow 프레임워크, 라벨링 툴(CVAT 등), Docker 배포 환경
조직적 지원	GPU 자원 할당 및 현장 영상 데이터 보안 반출 승인

4) 과제 분석 (Task Analysis)

[표 4-38] 질/안전 직무 과제 분석

과제 번호	수행 과제	필요 기술
T1	비정형 데이터(영상/이미지) 수집 및 라벨링자동화	Data Augmentation, Labeling T
T2	[핵심] 결함/객체 탐지 모델 설계 및 학습	CNN Architecture, Transfer Learning
T3	[심화] 실시간 처리를 위한 모델 경량화	Quantization, Pruning, TensorR
T4	시스템 통합 및 배포 (API 서버 구축)	Flask/FastAPI, Edge Device Porting

(나) 설계 (Design) 단계 : 분석 결과를 토대로 학습목표, 커리큘럼, 평가방법을 설계

1) 학습 목표 수립 (Performance Objectives)

학습자는 비정형 영상 데이터(표면 이미지 또는 CCTV)를 분석하여 결함이나 위험 요소를 95% 이상의 정확도로 탐지하는 딥러닝 모델을 개발하고, 이를 실시간 추론(30 FPS 이상)이 가능한 형태의 시스템으로 구현할 수 있다.

2) 커리큘럼

[표 4-39] 질/안전 직무 커리큘럼

모듈명	세부 교육 내용 (Topic)	학습 목표	시간(H)	교수 방법
M1. Vision Core	1-1. CNN 심화 (Backbone Network 이해) 1-2. Object Detection (YOLO series) 실습 1-3. Segmentation 기초 (U-Net)	문제 유형에 적합한 딥러닝 모델 구조를 선택하고 설계할 수 있다.	8H	강의 40% 실습 60%
M2. 데이터 전략	2-1. 불균형 데이터 처리 (Sampling, Loss fn) 2-2. Data Augmentation 심화 (CutMix, Mosaic) 2-3. Transfer Learning & Fine-tuning	데이터 부족 및 불균형 문제를 해결하기 위한 고도화된 학습 전략을 수립할 수 있다.	8H	실습 100%
M3. 최적화	3-1. 모델 경량화 (Pruning, Quantization) 3-2. 추론 가속화 (TensorRT, ONNX) 3-3. Edge Device(Jetson) 배포 실습	현장 장비에서 실시간 추론이 가능하도록 모델을 경량화하고 최적화할 수 있다.	8H	실습 100%
M4. PBL	4-1. [해커톤] 지능형 품질/안전 시스템 구축 4-2. 시스템 통합(입력-추론-알람) 및 데모 4-3. 성능 평가(mAP, FPS) 및 코드 리뷰	영상 수집부터 판정까지 자동화된 End-to-End 지능형 시스템을 구현할 수 있다.	16H	팀 프로젝트

[표 4-40] 질/안전 직무 세부 강의계획서 예시

항목	내용
학습 목표	1-Stage 객체 탐지 알고리즘(YOLO)의 작동 원리를 설명하고, 이를 활용하여 철강 표면 결함을 실시간으로 검출하는 모델을 구현할 수 있다.
주요 내용	① Object Detection 발전사 (R-CNN vs YOLO 비교) ② YOLO 아키텍처 심층 분석 (Grid Cell, Anchor Box, IOU) ③ Loss Function의 구성 (Localization Loss + Confidence Loss) ④ [실습] Pre-trained YOLO 모델 로딩 및 Custom Dataset 학습
교수 방법	심화 강의(40분) + 코드 리뷰 및 실습(60분) + 모델 성능 테스트(20분)
교수 매체	강의 교안(PPT), 실습용 GPU 서버 접속 환경, 표면 결함(NEU-DET) 이미지 데이터셋
평가	형성 평가 (IOU의 개념을 묻는 퀴즈 및 테스트 이미지에 대한 Bounding Box 검출 성공 여부 확인)

3) 평가 도구 설계

[표 4-41] 질/안전 직무 평가 도구 설계

평가 유형	평가 방법	평가 시점
정량 평가	모델 성능 지표 (mAP, Recall, FPS)	프로젝트 종료 시
정성 평가	시스템 완성도, UI 편의성, 현장 적용 가능성	데모 시연 시

(다) 개발 (Development) 단계 : 설계명세서를 바탕으로 실제교수자료와 실습 환경 제작

1) 교재 및 콘텐츠 개발

[표 4-42] 질/안전 직무 교재 및 콘텐츠 개발

자료 유형	상세 내용
기술 자료	최신 논문 리뷰 자료 및 SOTA 모델 코드 저장소(Repository)
환경 이미지	실습용 Docker 컨테이너 이미지 (환경 설정 시간 최소화)

2) 실습 환경 구축

[표 4-43] 질/안전 직무 실습 환경 구축

실습 도구	용도	비고
데이터셋	모델 학습용 비정형 데이터	철강 표면 결함(NEU-DET), 안전구 착용 데이터
GPU 서버	딥러닝 모델 고속 학습	팀별 클라우드 GPU 인스턴스 할당

3) 강사 가이드 개발

[표 4-44] 질/안전 직무 강사 가이드 개발

항목	내용
운영 방식	이론 강의보다는 프로젝트 멘토링(Code Review, 트러블 슈팅) 위주
피드백 가이드	모델 성능 미달 시 데이터 증강 및 하이퍼파라미터 튜닝 가이드 제공

(라) 실행 (Implementation) 단계 : 개발된 프로그램을 기업특성이 맞추어 효과적으로 운영하기 위한 전략을 수립

1) 운영 방식 (Project-Based Learnging)

[표 4-45] 질/안전 직무 운영 방식

구분	운영 방식	시간	비고
집중 교육	5일 집중 집체 코스	40H	업무 배제(Off-job) 필수
장기 프로젝트	주 1회 × 8주	8주	현업 병행 시 권장
해커톤	마지막 2일 무박 개발	16H	몰입도 극대화

2) 파일럿 운영 계획 (필요시) : 연구소 및 선도 공장 엔지니어를 우선 선발하여 PoC(개념 증명) 프로젝트와 연계 운영

(마) 평가 (Evaluation) 단계 : 교육의 효과성을 다층적으로 측정하고 개선점을 도출. 환류를 통한 지속적인 프로그램 내실 강화

1) Kirkpatrick 4단계 평가 모델 적용

[표 4-46] 질/안전 직무 Kirkpatrick 4단계 평가 모델 적용

평가 수준	평가 내용	측정 방법	측정 시점
Level 1: 반응	프로젝트 주제 적합성, 멘토링 만족도	설문조사	교육 직후
Level 2: 학습	모델 성능 지표(mAP, FPS) 달성 여부	정량 평가	교육 종료 시
Level 3: 행동	현업 복귀 후 Vision AI 활용 PoC 과제 발굴	과제 리스트업	3개월 후
Level 4: 결과	육안 검사 인력 효율화, 미검출 유출률 감소	KPI 측정	6개월 후

2) 피드백/환류활동 예시

a. 콘텐츠 : 최신 알고리즘 지속 업데이트

b. 운영 : 고성능 GPU 자원 확충 등 교육 환경 고도화

5 DX 자격인증체계 및 국가직무능력표준

5-1. 자격증 종류 소개

1 자격증의 종류

[표 5-1] 자격증의 종류

자격/과정명	난이도	주요대상	다루는 핵심 내용	실무·취업 측면 활용포인트
AI-900	초급	비전공자, 입문자	AI·ML·DL 개념, Azure AI 서비스, 책임있는 AI 개론	기초 개념·학습 의지 증명, 클라우드 AI 맛보기
ADsP	초중급	데이터 직무 준비생	데이터 이해·기획, 통계 기초, 기본 분석·모형 개념	데이터 직무 공통 언어, 이론 기초 증명
ADP (데이터분석 전문가)	고급	데이터 분석 실무 전문가	고급 통계·모형, 분석 방법론, 사례 분석, 실기 기반 문제 해결	시니어 분석가·컨설턴트급 역량 어필, 난이도 높은 자격
빅데이터 전문가	중고급	빅데이터·플랫폼 엔지니어	분산처리, 데이터 수집·저장·분석, 실기 기반 문제 해결	빅데이터 인프라·플랫폼 역량 증명, 엔지니어 포지션에 유리
TensorFlow	중급	개발 지망생	Python+TF 로 회귀·분류·CNN 등 실제 모델 구현·학습	포트폴리오용 실습 코드·모델, "개발형 인재" 어필
DCA	중고급	연구직·심화 학습자	딥러닝 이론, CNN·LSTM·Transformer 심화, 논문·연구 응용	연구 고급 개발 역량 어필, 심화 학습 동력
구글 ML Engineer	고급	실무 ML 엔지니어	ML 파이프라인, ML Ops, 배포·모니터링, Responsible AI	실무 시스템 구축 능력 증명, 시니어·전문가 포지션
SAS AI	중고급	분석 직무 실무자	SAS 기반 통계·ML·AI 모델링, 비즈니스 문제 해결	SAS 쓰는 조직에서 실무 적합성 어필

1. AI-900 (Azure AI Fundamentals)

AI-900은 인공지능을 처음 접하는 사람을 위한 입문용 개론 과정입니다. 수학과 코딩 부담은 거의 없고, 인공지능・머신러닝・딥러닝이 무엇인지, 서로 어떻게 다른지부터 시작한다.

또한 Microsoft Azure에서 제공하는 이미지・텍스트・음성 인식 같은 AI 서비스들을 개념 위주로 다룹니다. 실제로 모델을 코딩해서 만드는 것보다는, "클라우드에서 이런 AI 기능을 제공하고, 이런 식으로 비즈니스에 쓴다" 라는 사용 관점에 가깝습니다. AI 윤리, 편향, 공정성 같은

책임 있는 AI 개념도 소개한다.

비전공자가 “AI 이야기가 나와도 최소한은 이해하고 대화할 수 있는 수준”을 만드는 데 적합합니다. 자격증 자체만으로 취업이 확 달라지지는 않지만, 특히 비전공자에게는 기초 개념과 학습 의지를 보여 주는 증거가 될 수 있다.

2. ADsP (데이터분석 준전문가)

ADsP는 데이터 분야에 입문하는 사람들을 위한 데이터 분석 기초 이론 자격이다. 데이터 직무에서 공통으로 쓰는 개념과 용어, 기본 통계, 간단한 분석 기법을 폭넓게 다룬다.

데이터란 무엇인지, 어떤 유형이 있는지, 품질 문제(결측치・이상치)는 무엇인지부터 시작해, 분석 프로젝트를 어떻게 기획하고 추진하는지(문제 정의, KPI 설정, 분석 프로세스)를 배운다. 통계 부분에서는 평균・분산・상관계수 같은 기술통계, 가설검정과 같은 추론통계, 그리고 회귀분석・로지스틱 회귀・군집화・의사결정나무 같은 기본 분석 기법을 개념 위주로 익힌다.

시험은 필기 중심이라, SQL이나 Python 같은 실무 도구 활용 능력을 직접 보여 주지는 못하며 그렇지만 ADsP가 있으면 “데이터 분석의 기본 이론을 한 번은 체계적으로 공부했다”는 신뢰를 줄 수 있어, 데이터 직무 준비 초기 단계에서 기초 역량 증명용으로 많이 활용한다.

3. ADP (데이터분석 전문가)

ADP는 ADsP 위 단계로, 고급 통계・데이터 마이닝・분석 방법론을 폭넓고 깊게 다루는 자격이다. 난이도가 상당히 높고, 필기뿐 아니라 실기(케이스 분석)까지 있어 실무 감각도 요구 학습 범위는 다중회귀 및 모형 진단, 분산분석, 시계열 분석(ARIMA 등), 다변량 분석(주성분・판별・요인분석 등)처럼 고급 통계, 그리고 의사결정나무・랜덤포레스트・부스팅・군집분석・연관규칙 같은 데이터 마이닝 기법까지 포함한다. CRISP-DM 등 분석 프로젝트 방법론, 실제 산업 사례(마케팅・금융・제조・공공 등) 기반의 문제 해결 방식도 다룬다.

실기 시험에서는 주어진 상황과 데이터를 보고 어떤 분석 기법을 선택할지, 그 결과를 어떻게 해석하고 비즈니스 의사결정으로 연결할지를 서술해야 한다. 그래서 단순 이론 암기가 아니라 분석가로서의 사고력

도 평가 ADP 취득은 “데이터 분석을 깊이 있게 이해하고 있는 전문 인력”이라는 신호가 되며, 일부 공공·금융·컨설팅 분야에서는 우대 요인이 되기도 한다. 다만 여전히 코딩·툴 역량이나 실제 프로젝트 경험이 중요하기 때문에, ADP는 이론·방법론 측면에서의 강한 플러스 요인이라고 보는 것이 현실적이다.

4. 빅데이터 전문가

빅데이터 전문가는 통계·모델링보다는 대용량 데이터를 다루는 기술 인프라에 초점을 맞춘 자격/과정이다. Hadoop, Spark 같은 분산 처리 기술과, 데이터 수집·저장·처리·분석·시각화까지 전체 파이프라인을 이해하고 다루는 능력을 목표로 한다.

HDFS, YARN, MapReduce 같은 Hadoop 기본 구성요소와 Spark의 RDD·DataFrame·Spark SQL 개념을 익히고, 로그·이벤트 데이터를 대량으로 수집해 분산 환경에서 처리하는 방법을 배운다. Kafka 같은 스트리밍 수집 도구나 NoSQL 데이터베이스 개념, 배치/실시간 처리 구조도 함께 다룬다.

분석 측면에서는 Spark MLlib 같은 도구를 활용해 회귀·분류·군집 같은 기본 모델을 대용량 데이터에 적용하는 법을 배우고, 마지막으로 시각화 도구나 대시보드를 통해 결과를 서비스와 연결하는 프로젝트를 수행하는 경우가 많다.

이 과정은 데이터 분석가보다 데이터 엔지니어·플랫폼 엔지니어에 더 가깝다. 분산 환경에 대한 이해와 경험을 보여 줄 수 있어, 로그/이벤트 데이터가 많은 서비스·플랫폼·제조·IoT 분야 등에서 엔지니어 포지션을 노릴 때 강점이 된다.

5. TensorFlow 과정

TensorFlow 과정은 Python과 TensorFlow/Keras를 사용해 머신러닝·딥러닝 모델을 실제로 구현하는 실습 중심 과정이다.

기본적으로 텐서 개념, Keras로 신경망(Sequential/Functional API)을 정의하는 방법을 배우고, 손실 함수·옵티마이저·학습률 같은 학습 메커니즘을 이해한다. 이어서 회귀·분류용 신경망을 구현하고, 드롭아웃·정규화·Early stopping 등으로 과적합을 줄이는 방법을 실습 이미지 분야에서는 CNN을 사용해 손글씨·사물 이미지 분류 등을 구현하고, 사

전학습된 유명 네트워크를 가져와 전이학습도 경험하고 과정에 따라 RNN・LSTM/GRU를 이용한 시계열・텍스트 모델, 간단한 모델 배포(모델 저장, API 연동, TF Lite 등)까지 다루기도 한다.

이 과정의 가장 큰 장점은 실제 코드와 모델 산출물이다. 수료 후에 남는 노트북, 코드, 결과 리포트를 포트폴리오에 포함시킬 수 있어, 자격증 자체보다 "모델을 직접 만들어 봤다는 증거"로 활용하기 좋다.

6. DCA (딥러닝 심화 과정/자격)

DCA는 딥러닝을 심도 있게 공부하려는 사람을 위한 심화・연구형 과정이다. 예측 모델을 단순히 사용하는 수준을 넘어, 신경망 구조와 학습 원리를 수학・알고리즘 관점에서 이해하는 데 초점이 있다.

역전파 알고리즘, 손실 함수 설계, 최적화 기법(예: 다양한 gradient descent 변형, 정규화), 일반화 이론 등을 자세히 다루고, CNN・RNN・LSTM・GRU・Seq2Seq・Attention 등 대표 구조를 원리와 함께 학습한다. Transformer 기반 모델(self-attention, encoder/decoder)을 다루는 과정도 많으며 컴퓨터 비전・자연어 처리・시계열 등 여러 도메인에 걸친 응용 모델을 살펴보고, 최신 논문 구조를 리뷰하면서 연구 동향을 파악한다. 또한 하이퍼파라미터 튜닝과 실험 설계, 성능 비교, 결과 분석을 체계적으로 수행하도록 요구 한다.

이 과정은 일반적인 기업의 주니어 데이터 직무에 필수는 아니지만, 연구직・알고리즘 개발・고급 AI 프로젝트를 지향하는 사람에게는 좋은 발판이 된다. "딥러닝을 단순히 툴로 쓰는 사람"이 아니라, 구조를 이해하고 바꿔 볼 수 있는 수준으로 성장하고 싶을 때 적합하다.

7. 구글 ML Engineer (Google Cloud Professional ML Engineer 등)

구글 ML Engineer 자격은 머신러닝 시스템 전체 수명주기를 설계・운영할 수 있는 능력을 검증하는 고급 자격이다. 모델 하나를 잘 만드는 것에서 끝나지 않고, 데이터 수집부터 배포・모니터링까지 모두 포함한다.

비즈니스 문제를 분류・회귀・추천・시계열 등 ML 문제로 재정의하는 방법, 데이터 소스와 파이프라인(ETL/ELT, 배치/스트리밍)을 설계하는 방법을 다룬다. 알고리즘 선택 기준과 평가 지표 설계, 교차검증・성능 평가, 편향/분산 관리도 포함된다.

Vertex AI나 Kubeflow Pipelines 같은 도구를 사용해 모델 학습・평가・배포를 자동화된 파이프라인으로 구성하고, 모델 버전 관리와 재학습 자동화, A/B 테스트・Canary 배포 같은 운영 전략을 학습한다. 데이터/모델 드리프트 모니터링, 보안・권한 관리, 비용 최적화, Responsible AI까지 폭넓게 다룬다.

이 자격은 실제 클라우드 환경에서 ML을 운영하는 엔지니어에게 특히 의미가 있으며 신입보다는 1-2년 이상의 관련 경험이 있을 때 도전하는 경우가 많고, MLOps・ML Engineer 포지션을 노릴 때 역량을 잘 보여줄 수 있는 자격이다.

8. SAS AI

SAS AI는 SAS 플랫폼을 활용해 통계 분석과 머신러닝, 일부 딥러닝까지 수행하는 실무형 과정이다. 특히 금융・공공・통신처럼 SAS를 많이 쓰는 업계와 연관이 깊다.

SAS 언어(DATA/PROC step)를 이용해 데이터를 불러오고 가공하는 방법, SAS Enterprise Miner・Viya 같은 GUI 기반 도구로 분석 파이프라인을 구성하는 법을 배운다. 회귀・로지스틱 회귀・의사결정나무・랜덤포레스트・부스팅 등 다양한 모델을 SAS에서 구현하고, ROC・Lift 등 실무 지표로 성능을 평가한다.

과정에 따라 텍스트 마이닝(단어 빈도, 토픽 모델링, 감성 분석)과 간단한 신경망・딥러닝도 다루며, 고객 세분화・이탈 예측・신용평가・이상거래 탐지 같은 실제 업무 시나리오를 프로젝트 형태로 수행한다.

SAS를 사용하는 조직에서는 “툴을 바로 활용해 분석 프로젝트를 수행할 수 있는 사람”이라는 인상을 줄 수 있고, 프로젝트 결과 역시 포트폴리오로 활용 가능하다. 반대로, SAS를 거의 쓰지 않는 회사에서는 영향력이 상대적으로 작기 때문에 Python・SQL 역량과 함께 보여 주는 게 중요하다.

2 철강산업과 AI자격증의 연관성

1. 공정・품질 영역에서의 활용 (ADsP, ADP, TensorFlow, DCA 중심)

철강 공장은 압연, 열처리, 도금, 연주 등 다양한 공정이 연결된 거대한 시스템이다. 이 과정에서 두께, 온도, 압연력, 성분, 냉각 속도, 결함 개수와 같은 수많은 데이터가 생성된다. ADsP와 ADP는 이러한 공정・품

질 데이터를 이해하고 분석하는 데 필요한 통계와 분석 방법론을 제공하는 기반 역할을 한다.

ADsP 수준의 지식을 갖추게 되면, 공정 엔지니어나 품질 담당자가 “어떤 변수와 품질 지표 사이에 의미 있는 관계가 있는지”, “특정 조건에서 불량률이 올라가는지”를 통계 언어로 해석할 수 있게 된다. 예를 들어, 조업 조건이 바뀌었을 때 불량률이 유의하게 달라졌는지 가설검정을 해 보거나, 여러 공정 변수와 인장 강도 사이의 상관 관계를 살펴보는 활동이 가능해진다. 이 과정에서 ADsP에서 배우는 회귀분석, 기초통계, 분석 기획 개념이 실제 공정 개선 과제와 자연스럽게 연결된다.

ADP는 여기서 한 단계 더 나아가, 고급 통계와 데이터 마이닝 기법을 활용해 공정 최적화와 품질 예측을 진행할 수 있는 수준을 목표로 한다. 여러 공정 변수와 품질 지표를 동시에 고려하는 다중회귀, 공정 상태를 대표하는 지표를 뽑아내는 주성분분석, 시간에 따라 변화하는 데이터를 다루는 시계열 분석 등은 실제 철강 공정에 매우 자주 등장하는 문제 유형이다. 예를 들어, “이 조합의 공정 조건일 때 목표 강도와 연신율을 동시에 만족할 수 있는가?”를 분석하거나, “시간에 따라 설비 온도나 압력이 어떻게 변화하고, 그 패턴이 품질에 어떤 영향을 미치는가?”를 정량적으로 파악하는 데 ADP에서 다루는 내용이 직접적으로 쓰일 수 있다.

TensorFlow 과정과 DCA는 공정·품질 데이터를 가지고 예측 모델을 구축하거나 고급 패턴을 찾을 때 활용된다. 압연기, 가열로, 연속주조 설비 등에서 나오는 센서 데이터와 품질 데이터를 활용해, 특정 시간 이후에 설비가 이상 상태로 갈 가능성을 예측하는 예지보전 모델을 만들 수 있다. 이때 LSTM 같은 시계열 딥러닝 모델이나 1차원 CNN이 자주 사용된다. 또한 표면 결함 이미지를 활용해 결함 종류를 분류하거나, 미세 결함의 발생 가능성을 조기에 탐지하는 비전 모델을 구축할 수도 있다. TensorFlow 과정은 이러한 모델을 실제로 구현해 보는 실습 능력을 키워 주고, DCA는 CNN·Attention·Transformer와 같은 구조를 깊이 이해하여 보다 복잡한 문제에 대응할 수 있게 해 준다.

결국, 공정·품질 영역에서는 ADsP와 ADP가 데이터와 문제를 이해하는 “분석 언어와 기반 이론”을 제공하고, TensorFlow와 DCA가 실제 예측·분류·최적화 모델을 구현하는 “도구와 기술 스택”을 제공하는 구조라고 볼 수 있다.

2. 설비・플랫폼・스마트팩토리 영역에서의 활용(빅데이터 전문가, 구글 ML Engineer 중심)

철강 공장에는 수많은 설비와 센서가 존재하며, 이들로부터 발생하는 데이터의 양은 매우 크다. 압연기 진동 데이터, 모터 전류, 온도・압력 센서 정보, 설비 상태 로그, MES/PLC 로그 등은 모두 시간 축을 따라 계속 쌓이고 있다. 이처럼 데이터 규모가 크고 출처가 다양한 환경에서는, 단순히 엑셀이나 소규모 데이터 분석으로는 한계가 있다. 여기서 빅데이터 전문가 수준의 지식이 필요해진다.

빅데이터 전문가 과정에서 배우는 Hadoop, Spark, Kafka, 분산 저장・처리 구조는, 이러한 설비・공정 데이터를 안정적으로 수집하고 저장하며, 분석 가능한 형태로 가공하는 데 중요한 역할을 한다. 예를 들어, 가열로나 압연기의 센서 데이터를 실시간으로 수집해 중앙 시스템으로 보내고, Spark를 이용해 이상 징후를 빠르게 탐지하는 스트리밍 파이프라인을 구축하는 시나리오를 생각해 볼 수 있다. 또한 품질 시스템이나 MES에 저장된 생산 로그를 빅데이터 플랫폼과 연동해, 분석용 데이터 마트를 만드는 작업도 필수적이다. 이런 일을 잘 수행하려면 분산 시스템에 대한 이해와 데이터 파이프라인 설계 능력이 요구되며, 빅데이터 전문가 과정은 바로 이 영역에 초점을 맞춘다.

구글 ML Engineer 자격에서 다루는 MLOps 개념과 ML 시스템 운영 역량은, 이 빅데이터 인프라 위에 올라가는 AI 모델을 “서비스 형태로 안정적으로 운영”할 때 필요하다. 예지보전, 품질 예측, 수요 예측 같은 모델이 한 번 만들어지고 끝나는 것이 아니라, 정기적으로 재학습되고 공정 조건이나 데이터 분포가 바뀔 때마다 성능을 모니터링하며 개선되어야 한다면, 모델을 하나의 시스템처럼 관리해야 한다. 학습 데이터 추출, 모델 학습과 평가, 모델 배포, 성능 모니터링과 재학습 스케줄링까지 전 과정을 자동화하고, 문제 발생 시 롤백하거나 버전을 관리하는 구조가 필요하다.

철강 회사에서 이러한 역량을 갖춘다면, 예를 들어 “압연 라인별 설비 고장 예측 모델을 전 라인에 배포하고, 매달 새로운 데이터로 자동 재학습하는 시스템”을 설계할 수 있다. 또한 공장 단위의 전력 사용량 예측, 생산 계획 최적화 모델을 운영 시스템에 통합해 실제 의사결정에

활용하는 것도 가능해진다. 빅데이터 전문가 과정이 데이터 인프라에, 구글 ML Engineer가 그 위의 AI 운영에 각각 무게를 두고 있다면, 두 영역의 지식이 결합될 때 스마트팩토리·AI 공장이라는 목표에 가까워질 수 있다.

3. 영업·재무·경영 분석 영역에서의 활용(ADsP, ADP, SAS AI)

철강 산업에서는 공정과 설비뿐 아니라, 판재·형강 판매, 고객·원가·재고·물류 데이터도 매우 중요하다. 어떤 고객에게 어떤 제품을 어느 정도 수익성으로 판매하고 있는지, 어떤 산업군·지역에서 수요가 늘거나 줄고 있는지, 어떤 조합의 제품과 고객이 장기적으로 가치가 높은지 등의 질문은 영업·마케팅·재무·기획 부서가 늘 고민하는 부분이다.

ADsP와 ADP에서 배우는 데이터 분석 개념과 통계 기법은 이런 경영 데이터를 해석하는 데에도 그대로 적용된다. ADsP 수준의 지식만으로도 고객별 매출 분포를 분석하고, 군집화를 통해 고객을 여러 그룹으로 나누어 보는 작업 등을 시도할 수 있다. ADP 수준의 지식이 있다면, 고객 속성과 거래 이력을 활용해 거래 위험도나 이탈 가능성을 추정하는 로지스틱 회귀 모델을 설계하거나, 시계열 분석으로 특정 제품군의 수요 변화를 분석하는 등 보다 고급 분석을 수행할 수 있다.

SAS AI는 특히 금융·공공·통신뿐 아니라 대형 제조·서비스 기업에서도 많이 쓰이는 SAS 도구를 중심으로, 이러한 분석을 실무에 가깝게 수행하는 방법을 다룬다. SAS 환경에서 고객 세분화, 매출·마진 분석, 연체·부도 위험 예측 모델을 구축하고, 결과를 리포트나 대시보드 형태로 제공하는 일은 철강 영업·재무 쪽에서도 충분히 필요할 수 있다. SAS 기반의 분석 역량은 SAS를 사용하는 조직에서 곧바로 실무 프로젝트에 투입 가능한 능력을 의미하기 때문에, 해당 도구를 도입한 환경에서는 바로 활용될 수 있다.

4. 전략·기획·지원 부문에서의 활용(AI-900 중심)

전략·기획·지원 부서에서는 직접 모델을 만들기보다, “어떤 업무에 어떤 AI/데이터 기술을 도입할 수 있을지”를 고민하고, 사업 부서와 IT·데이터 조직, 외부 벤더를 연결하는 역할을 맡는 경우가 많다. 이때 AI-900과 같은 입문형 자격의 내용이 도움이 된다.

AI-900 수준의 지식을 갖추면, 인공지능·머신러닝·딥러닝의 큰 차이와

주요 용도를 이해하고, 컴퓨터 비전, 자연어 처리, 음성 인식 등 각 기술이 어떤 문제에 적합한지 파악할 수 있다. 이를 기반으로, 예를 들어 “표면 검사에 딥러닝 비전 모델을 도입하는 것”, “고객 문의·내부 문서에 자연어 처리 모델을 적용하는 것”, “생산 계획이나 수요 예측에 시계열 예측 모델을 활용하는 것”과 같은 아이디어를 구체화할 수 있다. 또한, 외부 컨설팅이나 솔루션 업체와 협의할 때, 기술적인 내용을 기본 수준에서 이해하고 질문할 수 있는 역량이 생긴다.

전략·기획 관점에서 보면, AI-900은 어떤 모델을 어떻게 코딩하는지 알려 주는 과정이라기보다는, 회사 내 다양한 도메인에 AI를 어디에, 어떤 수준으로 도입할 수 있을지를 판단하는 “기초 프레임”을 제공한다고 볼 수 있다.

5-2. NCS활용 자격 체계 구성 방안

1 NCS 3수준 자격 설계

NCS 3수준은 2수준에서 일정 기간(약 1~3년) 실제 업무를 수행한 후 도달하는 단계로서, 해당 분야의 기초이론과 일반지식을 활용하여 다소 복잡한 과업을 수행할 수 있는 수준을 의미한다. 이 단계의 인력은 아직 광범위한 권한과 책임을 갖는 것은 아니지만, 상위자의 구체적인 지시가 있어야만 움직이는 2수준과 달리, 제한된 권한 내에서 스스로 과제를 이해하고 처리할 수 있는 실무 초·중급자로 정의된다.

지식과 기술 측면에서 3수준은, 특정 분야의 심화된 전문지식까지는 아니더라도 업무 수행에 필수적인 기초이론과 일반지식을 이해하고 이를 실제 과업에 적용할 수 있는 상태를 전제로 한다. 예를 들어 인공지능모델링 직무의 경우, 통계와 기계학습, 데이터 전처리, 기본적인 프로그래밍 등에 대한 기초 개념을 알고, 인공지능 모델링의 전체 흐름(문제 정의-데이터 확보·전처리-특징 추출-모델 학습·선정-모델 활용 관리)을 개략적으로 설명할 수 있는 수준이 이에 해당한다. 다만 4·5수준처럼 이 지식을 바탕으로 새로운 방법을 설계하거나 고난도 문제를 독자적으로 해결하는 단계는 아니다.

과업 수행 역량 측면에서 3수준은 “다소 복잡한 과업”을 수행하는 수준으로 정의되며, 여기서 ‘다소 복잡하다’는 것은 완전히 절차화된 단순·

반복 작업을 넘어, 여러 단계가 연계되고 오류 발생 가능성이 존재하는 업무를 의미한다. 인공지능모델링을 예로 들면, 상위자가 설계해 놓은 데이터 수집·전처리 절차와 모델 학습 스크립트를 이해하고, 이를 기반으로 실제 데이터를 수집·정제하고, 기본적인 품질 검증을 수행하며, 정해진 알고리즘과 하이퍼파라미터 설정을 적용해 모델을 학습·평가하는 정도를 스스로 수행할 수 있는 단계라고 볼 수 있다. 이때 3수준 인력은 복잡한 알고리즘을 새로 설계하거나, 모델 구조를 창의적으로 바꾸기보다는, 이미 정의된 절차와 기준을 정확히 이해하고 재현하는 데 역할의 무게가 실린다.

책임과 권한의 측면에서 보면, 3수준은 “제한된 권한 내에서 과업을 수행하는 수준”으로 요약된다. 이는 독립적·포괄적인 권한이 부여되는 4·5수준과 달리, 업무 범위와 의사결정 권한이 명확히 정해져 있다는 뜻이다. 인공지능모델링 현장에서는, 예를 들어 데이터 품질에 문제가 발견되었을 때, 데이터 재수집이나 기본적인 정제 작업까지는 스스로 처리하되, 데이터 스키마 변경, 모델 구조 변경, 운영 정책 변경과 같이 영향 범위가 큰 결정은 선임·책임급(4·5수준)에게 보고하고 협의하는 역할 분담이 이루어진다. 즉, 이상 징후를 감지하고, 정해진 범위 내 조치를 취하며, 문제를 상위 수준으로 연결하는 “실무 실행자”의 역할이 3수준의 핵심이다.

경력 경로 측면에서 리포트는 3수준을 2수준(절차화되고 일상적인 과업을 수행하는 단계) 다음의 단계로 위치시킨다. 2수준에서 약 1~3년 동안 기본적인 업무를 숙달한 후, 3수준에 이르면 비슷한 분야의 업무를 보다 넓은 범위에서 다소 복잡한 형태로 처리할 수 있게 된다. 그 이후 3수준에서 다시 1~4년 정도 경험을 쌓으면, 일반적인 권한 내에서 복잡하고 다양한 과업을 수행하는 4수준으로 성장하는 경로를 전제하고 있다. 따라서 3수준은 “완전 초급”과 “독립적인 중급자” 사이, 즉 중간 단계의 실무자 레벨로 이해하는 것이 적절하다.

인공지능 분야에서 산업현장 직무능력수준 1수준을 NCS 능력단위 3수준에 대응시키고 있는데, 이는 인공지능서비스구현이나 인공지능학습데이터구축과 같은 입문 직군에서 일정 기간 실무를 경험한 인력이 인공지능모델링, 인공지능서비스기획, 인공지능플랫폼구축 등으로 성장해 가는 초입 단계에 3수준이 위치한다는 의미를 담고 있다. 다시 말해, 인공지능 관련 업무를 “혼자 설계하고 이끌어가는 전문가”라기보다는, 설계된 프레임 안에서 데이터를 다루고 모델을 실행·검증하며, 문제를 인지해 상위에 전달할 수 있는 실무 초·중급 인력의 기준이 바로 NCS 3수준이다.

[표 5-2] 인공지능모델링 NCS

구분	필수 능력단위 (인공지능 모델링)	주요 내용 (3수준 관점 요약)	이론 (시간)	실습 (시간)	소계 (시간)
1	인공지능 모델 문제 정의 2001070301	비즈니스/현장 문제를 데이터·모델 관점에서 이해하고, 목표·제약·성능지표(예: 정확도, 정밀도 등)를 기초 수준에서 정의	30	30	60
2	인공지능 모델 준비 2001070302	필요한 데이터·자원(컴퓨팅, SW도구 등)을 파악하고, 기본적인 프로젝트 계획·환경 구성을 수행	25	25	50
3	인공지능 데이터 확보 2001070303	내부/외부 데이터 원천 파악, 간단한 쿼리·파일 수집, API/크롤러 활용 기초 등으로 학습에 필요한 데이터 세트를 수집	30	40	70
4	인공지능 데이터 전처리 2001070304	결측치·이상치 처리, 스케일링·인코딩 등 기본 전처리 기법을 적용하고, 간단한 파이프라인을 구성	35	45	80
5	인공지능 데이터 특징 추출 2001070305	기초적인 피처 엔지니어링(파생 변수 생성, 로그변환 등), 도메인 지식을 반영한 주요 특징 도출	30	40	70
6	인공지능 데이터 품질 검증 2001070309	데이터 분포·편향·누락/오류 여부를 점검하고, 간단한 통계/시각화로 데이터 품질을 진단	25	35	60
7	인공지능 모델 학습 2001070306	지도/비지도 기본 알고리즘(예: 선형모델, 트리, k-means 등)을 사용해 모델을 학습시키고, 기본 하이퍼파라미터를 조정	40	60	100
8	인공지능 모델 선정 2001070307	여러 모델의 성능을 비교(정확도, F1 등)하고, 사업·운영상 제약(속도, 해석가능성 등)을 고려해 적절한 모델을 선택	20	30	50
9	인공지능 모델 활용 관리 2001070308	선정된 모델을 파일/서비스 형태로 배포·연동하고, 간단한 모니터링(성능 변화·로그 분석 등)과 개선 요구사항 접수·반영	25	35	60
합계			260	340	600

1. 본 교육과정은 인공지능모델링 직무를 수행하는 인력이 NCS 3수준에 적합한 능력을 갖추도록 설계된 600시간 과정으로, 인공지능 모델의 전 생애주기(문제 정의-준비-데이터-모델-운영)를 처음부터 끝까지 경험할 수 있도록 구성하였다.

2. 먼저, NCS 3수준의 정의를 전제로 교육 목표와 수준을 설정하였다. NCS 3수준은 “기초 이론과 일반지식을 이해하고, 주어진 절차와 기준에 따라 다소 복잡한 과업을 수행하되, 책임과 권한은 제한된 범위 내에서 행사하는 수준”으로 이해할 수 있다. 즉, 고도의 연구·설계나 전략 수립보다는, 이미 정해진 업무 프로세스와 지침 하에서 인공지능 관련 업무를 안정적으로 수행하고, 기본적인 문제를 인지하여 보고할 수 있는 실무형 인력을 양성하는 데 초점을 두었다. 이러한 정의에 따라, 교육 내용은 심화 이론보다는 기초 개념과 도구 활용, 표준 절차의 이해, 반복 실습에 비중을 두었으며, 이론 260시간, 실습 340시간으로 실습 중심의 편성을 채택하였다.

3. 교육과정의 설계는 인공지능 모델링 업무를 “문제 정의 → 모델 준비 → 데이터 확보 → 데이터 전처리 → 특징 추출 → 데이터 품질 검증 → 모델 학습 → 모델 선정 → 모델 활용 관리”라는 9개 능력단위로 나누고, 이를 모두 필수 능력단위로 설정한 뒤 600시간을 배분한 것이다. 이는 현업에서 인공지능 모델을 실제로 활용하려면 특정 단계만 이해하는 것으로는 부족하고, 전체 흐름을 한 번 이상 스스로 수행해 볼 수 있어야 한다는 관점을 반영한 것이다. 다만 NCS 3수준의 특성을 고려하여, 각 능력단위의 목표 수준은 ‘설계자·전문가 보조’에 가깝게 두고, 난이도가 높은 결정·설계 행위보다는 표준 절차에 따른 수행과 기초적인 판단·보고에 초점을 맞추었다.

4. 먼저 “인공지능 모델 문제 정의” 능력단위에는 60시간을 배정하였다. 이는 인공지능 프로젝트 실패의 주요 원인 중 하나가 애초의 문제 정의 오류라는 점을 고려한 것이다. 다만 3수준 인력에게 요구되는 수준은 경영·전략 차원의 추상적인 문제 정의가 아니라, 현장의 과제(불량률 감소, 설비 이상 감지 등)를 데이터와 모델 관점에서 이해하고, 입력·출력, 목표 성능지표(예: 정확도, 재현율)를 기초 수준에서 명확히 표현하는 것이다. 이론 교육을 통해 문제 정의의 개념과 사례를 학습하고, 실습을 통해 실제 사례를 인공지능 문제로 재구성해보는 활동을 균형 있게 배치하였다.

5. “인공지능 모델 준비”에는 50시간을 배정하였다. 이 단계는 데이터와 컴퓨팅 자원, 소프트웨어 도구를 파악하고, 개발 환경을 구성하며, 단기적인 수행 계획을 정리하는 과정이다. NCS 3수준 인력은 복잡한 인프라 아키텍처를 설계하기보다는, 이미 조직에서 정해놓은 환경과 도구를 이해하고, 지침에 따라 프로젝트를 준비할 수 있으면 충분하다. 이에 따라 라이브러리 설치, 기본 프로젝트 구조 설정, 버전 관리 도구의 기초 사용 등 실무에서 자주 발생하는 작업을 중심으로 구성하되, 전체 시간은 상대적으로 간결하게 책정하였다.

6. “인공지능 데이터 확보”에는 70시간을 배정하였다. 실무에서는 전체 프로젝트 시간 중 상당 부분이 데이터 수집과 확보에 소요되며, 제조·철강과 같이 시스템이 복잡한 환경에서는 각종 설비 데이터베이스, MES, LIMS, 로그 파일 등 다양한 원천을 이해하는 것이 중요하다. 3수준 인력에게는 복잡한 데이터 아키텍처 설계보다는, 간단한 SQL이나 파일 입·출력, API 활용 기초, 로그·CSV·엑셀 형식의 데이터를 다루는 능력이 요구된다. 따라서 다양한 데이터 원천에 접속하고 필요한 데이터를 추출해 보는 실습 비중을 높게 두었다.

7. “인공지능 데이터 전처리”는 80시간으로 전체 과정에서 상위 비중을 차지한다. 이는 실제 인공지능 프로젝트에서 전처리 작업이 시간과 성능에 모두 큰 영향을 미치기 때문이다. NCS 3수준 단계에서는 고급 통계 기법을 사용하는 것보다는 결측치 처리, 이상치 제거 혹은 대체, 스케일링, 원-핫 인코딩 등 기본적인 전처리 기법을 올바르게 적용하고, 간단한 전처리 파이프라인을 구성해 보는 수준을 목표로 한다. 이를 위해 다양한 형태의 예제 데이터를 반복적으로 다루는 실습을 강화하였다.

8. “인공지능 데이터 특징 추출” 능력단위에는 70시간을 배정하였다. 모델 성능 향상에 중요한 역할을 하는 단계이지만, 3수준 인력에게 고난도 피처 엔지니어링을 요구하기보다는, 파생 변수 생성(비율, 차이, 이동 평균 등), 로그·정규화 같은 기본 변환, 도메인 규칙을 반영한 단순한 특징 설계 능력을 목표로 삼았다. 제조·품질 데이터를 활용하는 경우 생산 조건과 품질 간 관계를 이해하고, 이를 변수로 표현해보는 실습을 통해 도메인 이해를 함께 높이도록 설계하였다.

9. “인공지능 데이터 품질 검증”에는 60시간을 배정하였다. 인공지능 모델의 신뢰성을 확보하기 위해서는 학습 데이터의 분포, 편향, 누락·오류 여부를 파악하는 것이 필수다. NCS 3수준 인력은 복잡한 통계 모델링까지는 아니더라도, 기본적인 통계치(평균, 분산 등)와 분포 그래프, 상관관계 분석을 통해 데이터 품질을 점검하고, 이상 징후를 상위 직무자에게 보고할 수 있어야 한다. 이에 따라 각종 시각화 도구와 통계 함수 사용을 중심으로 실습을 구성하였다.

10. “인공지능 모델 학습” 능력단위에는 100시간을 할당하여 전체 과정에서 가장 큰 비중을 두었다. 이는 인공지능모델링 직무의 핵심 역량이기도 하며, 다양한 알고리즘을 실제로 적용해보는 경험이 필요하기 때문이다. 다만 NCS 3수준에서는 최첨단 연구형 알고리즘까지 다루기보다는, 선형 회귀, 로지스틱 회귀, 결정트리, 랜덤포레스트, k-means 같은 기본 알고리즘의 개념과 활용법을 중심으로 한다. 이론 교육을 통해 알고리즘의 동작 원리, 장단점, 적용 조건을 이해하고, 실습을 통해 여러 데이터셋에 모델을 학습·평가해보면서 기초적인 하이퍼파라미터 조정 경험을 쌓도록 한다.

11. “인공지능 모델 선정”에는 50시간을 배정하였다. 이 단계에서 NCS 3수준 인력에게 요구되는 것은, 복잡한 최적화 의사결정을 단독으로 수행하는 것이 아니라, 여러 후보 모델의 성능 지표(정확도, F1-score 등)를 비교하고, 응답 속도, 해석 가능성, 운영 환경 제약 등을 고려하여 어떤 모델이 조직 상황에 더 적합한지 합리적으로 설명할 수 있는 수준이다. 이를 위해 다양한 모델 비교 실습과 평가 지표 해석 훈련을 포함했지만, 상위 기획·설계 수준의 판단은 상위 수준(4·5수준) 직무로 넘겨 시간 배분을 제한하였다.

12. 마지막으로 “인공지능 모델 활용 관리”에는 60시간을 배정하였다. 이는 배포·운영·모니터링 단계로, 최근 인공지능 프로젝트에서 점점 더 중요해지고 있는 영역이다. NCS 3수준 인력의 역할은 복잡한 MLOps 파이프라인 설계보다는, 파일이나 간단한 API 형태로 모델을 서비스에 연동하고, 주기적으로 성능 지표와 로그를 점검하여 이상을 발견하면 상위 직무자에게 알리는 수준이다. 실습에서는 간단한 배포 방식, 모니터링 대시보드 사용, 개선 요구사항 정리 및 커뮤니케이션을 다루도록 구성하였다.

13. 전체적으로 본 교육과정은 NCS 3수준의 정의에 맞게, 고급 연구·설계 역량보다는 “기초 이론 이해 + 표준 절차 수행 + 실무 도구 활용”에 초점을 두고 있다. 9개 능력단위를 모두 필수로 포함함으로써, 교육 수료자가 인공지능 모델링 프로젝트의 전 과정을 한 번 이상 스스로 수행해볼 수 있는 경험을 제공하고, 이후 상위 수준(4·5수준) 교육과정에서 고급 알고리즘, 대규모 데이터 처리, 고난도 모델링으로 확장할 수 있는 기초를 마련하도록 설계하였다. 이러한 구조는 인공지능 활용을 점차 확대하는 제조·철강 산업 현장에서, 초기 단계의 실무형 인력이 현장 데이터와 시스템을 이해하고 상위 전문가와 협업할 수 있는 기반을 제공하는 것을 목표로 한다.

7 결론

이 가이드라인은 철강산업의 디지털 전환을 뒷받침하기 위해, 공정·설비·품질·안전·경영 전 영역을 아우르는 AI·데이터 활용 방향과 이를 실행할 인재를 체계적으로 양성하기 위한 교육 체계를 제시했다. 고온·고압·연속공정이라는 산업 구조, 수기 중심 데이터 관리, 낮은 AI 활용률, 글로벌 가격·품질·납기 경쟁 심화, 탄소·ESG 규제, 숙련 인력 고령화와 안전 리스크 등 복합적인 환경 요인을 고려할 때, 철강산업의 DX는 더 이상 '선택적인 혁신 과제'가 아니라 생존과 직결된 구조적 과제라는 점이 분명해졌다.

문서 전반에서 제시한 방향은 크게 세 가지로 요약할 수 있다. 첫째, AI·데이터 기술의 활용 범위를 개별 공정·부분 최적화 수준에 머무르지 않고, 원료–제선–제강–압연–정정–물류–고객에 이르는 전체 가치사슬로 확장하는 것이다. 이를 위해 공정·설비·품질·에너지·탄소 데이터를 통합하는 플랫폼(예: PosFrame)과, 공장 특성을 반영한 AI 모델(조업 최적화, 예지보전, 비전 검사, 안전 모니터링, 에너지·탄소 최적화, SCM·경영 분석 등)을 연계해 End-to-End 최적화를 지향해야 함을 강조했다. 둘째, AI를 "보조 도구" 수준이 아니라 생산·설비·안전·사무 전 영역에서 작동하는 핵심 인프라로 자리잡게 하고, CCTV·웨어러블·로봇·자율주행 물류 등과 결합해 '사람이 위험한 곳에 들어가지 않는 공장'을 구현해야 한다는 점이다. 셋째, 어떤 기술을 도입하느냐보다 그 기술을 이해·기획·적용·확산할 수 있는 사람과 조직 역량을 구축하는 것이 궁극적인 성공 요인이라는 인식이다.

이러한 방향성 아래, 본 가이드라인은 직무(생산/조업, 설비/정비, 품질/안전, 경영/지원)와 역량 수준(이해–활용–전문)을 교차한 교육 매트릭스를 제시하고, 각 축에 대해 필요한 디지털 기술(머신러닝·딥러닝·비전·시계열·RPA·예측 분석 등)과 현장 적용 예시를 구조화했다. 더 나아가 ADDIE 모형을 기반으로 실제 교육 프로그램을 개발·운영하기 위한 절차(분석–설계–개발–실행–평가)를 정리하고, 센서 기초(설비/정비 Lv.1), 공정 최적화 기초(생산/조업 Lv.2), Vision AI 심화(품질/

안전 Lv.3) 등 구체 과정 설계안을 통해 현장에서 바로 활용 가능한 실습 중심 커리큘럼의 예시를 제시했다. 이는 교육이 단순 이론 전달을 넘어, 실제 공장 데이터를 활용한 문제 해결형 학습(PBL), PoC 연계, OJT 확산으로 이어져야 한다는 관점을 반영한 결과다.

또한, 국가직무능력표준(NCS)을 활용하여 인공지능모델링 직무에 대한 3수준(실무 초·중급자) 600시간 과정 설계안을 제시함으로써, 철강산업의 DX 인력 양성이 국가 수준의 직무 표준과 연계될 수 있는 토대를 마련했다. 인공지능 모델링의 전 과정을 9개 능력단위(문제 정의-모델 준비-데이터 확보-전처리-특징 추출-데이터 품질 검증-모델 학습-모델 선정-모델 활용 관리)로 구조화한 뒤, 이론 260시간·실습 340시간으로 구성한 이 과정은 “기초 이론 이해 + 표준 절차 수행 + 실무 도구 활용”에 초점을 맞춘 NCS 3수준의 특성을 충실히 반영하고 있다. 이는 향후 4·5수준으로의 확장을 위한 기반이자, 정부·공공 지원사업, 민간 교육기관과의 연계 가능성을 열어주는 설계이기도 하다.

결국 이 가이드라인이 제시하는 메시지는 분명하다. 철강산업의 디지털 전환은 더 이상 파일럿 프로젝트의 나열이나 일부 부서의 실험에 머물러서는 안 되며, 전사적 비전·전략, 공통 데이터·AI 아키텍처, 직무·수준별 교육 체계, NCS와 연계된 자격·역량 체계, 그리고 교육-현장 프로젝트-성과 평가-환류로 이어지는 구조적 메커니즘 속에서 추진되어야 한다는 것이다. 특히 “철강 도메인 깊이 + 디지털/AI 폭”을 겸비한 T자형 인재를 내부에서 체계적으로 육성하고, 이들을 중심으로 공장·사업장별 DX 셀과 전사 DX 거버넌스를 운영할 때, 고부하·고비용·고탄소·고위험 구조라는 전통적인 제약을 넘어서는 새로운 경쟁 우위를 확보할 수 있다.

본 가이드라인은 철강 디지털 전환 교육의 최종 완성본이라기보다, 산업과 기술, 인력 환경이 변화하는 과정에서 지속적으로 업데이트되어야 할 “기준선”에 가깝다. 향후 각 기업·공장이 이 기준선을 바탕으로 자사 상황에 맞는 세부 교육과정과 DX 추진 구조를 설계하고, 그 결과와 교훈을 다시 공유·반영함으로써, 철강산업 전반의 디지털 역량과 경쟁력이 함께 성장해 나가는 것이 본 가이드라인의 궁극적인 지향점이다.

참고자료

- 인공지능산업 실태 조사/과학기술정보통신부
- 2024년 산업 디지털 전환 실태조사(KOSIS)
- 2024 중소기업 기술통계조사 보고서
- McKinsey Global Institute(https://www.mckinsey.com/capabilities/tech-and-ai/our-insights/the-economic-potential-of-generative-ai-the-next-productivity-frontier)
- 포스코그룹뉴스룸(https://newsroom.posco.com/kr/)
- 포스코DX(https://www.poscodx.com/kor/solution/posFrame)
- Baowu Resources, ZTE(https://sdnfv.zte.com.cn/en/cases/Baowusteel-5G-Case)
- Nippon Steel DX Report(https://www.nipponsteel.com/en/news/20190425_200.html)

철강 디지털 전환 교육 가이드라인 개발진	
발행일	2025년 12월 26일
개발기관	한국철강협회(왕찬훈 실장) 한국철강협회(허지회 과장)
개발진	포스코 조규진 과장 포스코 인재창조원 장진영 교수 오성기공 박철호 차장 포항산업과학연구원 윤병준 과장 포항산업과학연구원 이만재 대리