

AI로 성공하기

비즈니스에 AI를 활용하는 방법
핵심 요약

Veljko Krunic



MANNING

+



Microsoft Azure

AI로 성공하기

AI로 성공하기

비즈니스에 AI를 활용하는 방법

핵심 요약

VELJKO KRUNIC



MANNING
SHELTER ISLAND

간략 목차

- 2 ■ 비즈니스에서 AI를 활용하는 방법 1
- 3 ■ 첫 번째 AI 프로젝트 선택하기 28
- 6 ■ ML 파이프라인 분석하기 57
- 7 ■ AI 프로젝트 성공으로 이끌기 87

책 전문은 [이 링크](#)에서 볼 수 있습니다.

목차

저자 소개 x

2	비즈니스에서 AI를 활용하는 방법	1
2.1	AI에 대해 무엇을 알아야 하나요?	2
2.2	AI는 어떻게 사용되나요?	4
2.3	AI의 새로운 기능은 무엇인가요?	6
2.4	AI로 수익 창출하기	8
	의료 진단에 적용된 AI	9
	AI 수익화를 위한 일반 원칙	11
2.5	도메인 작업 찾기	13
	의사 결정 지원 시스템의 일부인 AI	14
	더 큰 제품의 일부로서의 AI	15
	AI를 사용하여 비즈니스 프로세스의 일부 자동화	17
	제품으로서의 AI	18
2.6	AI 기능 개요	20
2.7	유니콘 소개	22
	데이터 사이언스 유니콘	22
	데이터 엔지니어는 어떨까요?	23
	그렇다면 유니콘은 어디에 있을까요?	24
2.8	연습	25
	단답형 문제	26
	시나리오 기반 문제	26

3 첫 번째 AI 프로젝트 선택하기 28

- 3.1 젊은 AI 팀에 적합한 프로젝트 선택하기 29
성공의 모습 29 ▪ 실패의 모습 32
- 3.2 AI 프로젝트 우선순위 정하기 34
대응: AI가 답해야 할 비즈니스 질문 찾기 35
감지/분석: AI 방법 및 데이터 38 ▪ 비즈니스
지표로 AI 프로젝트 성공 측정하기 40 ▪ AI
프로젝트 난이도 추정하기 43
- 3.3 첫 번째 프로젝트와 첫 번째 연구 질문 44
연구 질문 정의 45 ▪ 실패하는 경우, 빨리 실패하는
편이 낫습니다 49
- 3.4 피해야 할 함정 49
비즈니스 팀과의 관계 구축 실패 50
이식 사용하기 50 ▪ 로켓 없이 문샷 시도하기 51
고급 도구를 사용하여 데이터의 바다 보기 52
CLUE 대신 직감 활용하기 53
- 3.5 연습 55

6 ML 파이프라인 분석하기 57

- 6.1 ML 파이프라인 분석에 관심을 가져야 하는 이유 58
- 6.2 자원 절약: CLUE 60의 E 부분 60
- 6.3 MinMax 분석: 올바른 ML 파이프라인을 보유하고 계신가요? 62
- 6.4 MinMax 분석 결과를 해석하는 방법 64
시나리오: 스마트 주차 미터기를 위한 ML 파이프라인 64
ML 파이프라인에 개선이 필요한 경우 어떻게 해야
할까요? 68 ▪ MinMax 분석 결과 해석을 위한 규칙 69
- 6.5 ML 파이프라인 분석 수행 방법 69
MinMax 분석의 Min 부분 수행하기 71 ▪ MinMax 분석의
Max 부분 수행하기 71 ▪ MinMax 분석의 추정치 및 안전
계수 74 ▪ 수익 곡선의 범주 76 ▪ 복잡한 수익 곡선
다루기 79
- 6.6 MinMax 분석에 대한 자주 묻는 질문 81
ML 파이프라인의 첫 번째 분석으로 MinMax를 사용해야
하나요? 82 ▪ 어떤 분석을 먼저 수행해야 하나요? Min인가요,
Max인가요? 82 ▪ 소규모 회사나 소규모 팀은 MinMax
분석을 건너뛰어야 하나요? 83 ▪ MinMax 분석이라는
용어를 사용하는 이유는 무엇인가요? 83
- 6.7 연습 84

7 AI 프로젝트 성공으로 이끌기 87

- 7.1 민감도 분석으로 ML 파이프라인 개선하기 88
 - 로컬 민감도 분석 수행하기 89* ▪ *글로벌 민감도 분석 92* ▪ *민감도 분석 결과 활용 예시 93*
- 7.2 CLUE를 완료했습니다 94
- 7.3 민감도 분석을 위한 고급 방법 97
 - 로컬 민감도 분석이 ML 파이프라인에 적합할까요? 98*
 - ML 파이프라인 단계 간의 상호 작용을 해결하는 방법 101* ▪ *실험 설계를 사용해야 하나요? 102*
 - 흔히 접할 수 있는 이의 제기 103* ▪ *데이터를 생성하는 단계를 분석하는 방법 106* ▪ *내 프로젝트에 어떤 유형의 민감도 분석이 적용되나요? 106*
- 7.4 시간이 지남에 따라 AI 프로젝트가 진화하는 방식 108
 - 시간은 비즈니스 결과에 영향을 미칩니다 108* ▪ *시간의 흐름에 따라 ML 파이프라인 개선하기 109* ▪ *타이밍 다이어그램: 시간에 따른 비즈니스 가치 변화 110*
- 7.5 AI 프로젝트 마무리하기 112
- 7.6 연습 114

책 전문은 [이 링크](#)에서 확인할 수 있습니다.

오늘 Azure AI를 사용하여 미션 크리티컬 결과를 도출하고 고객 경험을 개선하세요.

Azure AI는 성능과 안전을 위해 설계된 기업용 AI 솔루션을 제공합니다. 유연한 가격 옵션으로 클라우드, 하이브리드 또는 컨테이너에 인공 지능을 배포하세요. 머신러닝 모델을 사용자 맞춤화하거나 개발하고 데모 스튜디오에서 제품을 사용해 보세요. Azure AI를 활용하여 확장 가능하고 액세스 가능한 환경을 만드세요.

[Azure AI로 전략 계획 시작하기](#)

저자 소개



VELJKO KRUNIC은 데이터 과학, 빅데이터를 전문으로 하는 독립 컨설턴트이자 트레이너로, 고객이 실행 가능한 비즈니스 결과를 얻을 수 있도록 돕고 있습니다.

콜로라도대학교 볼더캠퍼스에서 컴퓨터 공학 박사 학위를 받았으며, 엔지니어링관리석사학위를 추가로 취득했습니다. 공학관리석사학위는 응용 통계, 전략 계획, 조직 효율성 향상을 위한 고급 통계 방법의 사용에 중점을 두었습니다. 그는 식스 시그마 마스터 블랙 벨트이기도 합니다.

Veljko는 엔터프라이즈 컴퓨팅, 데이터 과학, AI, 빅데이터 분야에서 포춘지 선정 10대 기업 중 5개(2019년 9월 기준), 다수의 포춘지 선정 500대 기업, 다수의 소규모 기업을 대상으로 컨설팅을 제공하거나 강의를 진행한 바 있습니다. 독립 컨설팅을 시작하기 전에는 Hortonworks의 전문 서비스 조직(PSO), VMware의 SpringSource 사업부, Red Hat의 JBoss 사업부에서 근무했습니다. 이러한 직책에서 그는 해당 PSO의 최고 고객을 위한 주요 프로젝트 담당 핵심 기술 컨설턴트로 일했습니다.

머리말

안녕하세요, 저는 Microsoft Azure의 데이터 및 AI 부문 기업 부사장인 Jessica Hawk입니다. 'AI로 성공하기: 비즈니스에서 AI를 활용하는 방법' 특별판을 다운로드해 주셔서 감사합니다. 이 책에서는 AI 컨설턴트이자 선구자인 Veljko Krunic이 실제 비즈니스 성과를 창출하는 비용 효율적이고 안정적인 AI 프로젝트를 계획하고 실행하기 위한 검증된 프로세스를 공유합니다. 이 책은 수십 개의 스타트업, 기존 기업, 포춘 500대 대기업과 함께 일한 그의 경험을 바탕으로, 데이터 과학자 및 개발자의 시간 투자 수익을 극대화하고 프로젝트가 순조롭게 진행되도록 효과성 지표를 구현하는 비결을 알려주는 실용적인 가이드입니다.

기술 또는 비즈니스 의사 결정권자는 조직에서 AI를 채택하고 구현하는 데 중요한 역할을 합니다. Microsoft가 제공하는 세계적 수준의 엔터프라이즈용 플랫폼인 Azure AI는 직원, 사용자, 고객의 경험을 개선하기 위해 다양한 방식으로 활용되고 있습니다. Teams의 음성 전사 및 캡션, PowerPoint의 콘텐츠 및 디자인 제작, Windows Hello의 생체 인식 감지 및 신원 확인, Xbox의 개인화된 추천, Edge 및 M365의 콘텐츠 읽기 및 쓰기 환경, Office의 텍스트 음성 변환 및 음성 텍스트 변환, Skype의 실시간 언어 번역, Outlook의 언어 감지 및 번역 등과 같은 기능들은 Microsoft 연구를 바탕으로 탄생했고 Microsoft의 여러 앱에서 대규모로 테스트된 바 있습니다. 엔터프라이즈 ChatGPT를 지원하는 새로운 Azure OpenAI 서비스도 기대됩니다.

Azure AI는 광범위한 데이터 과학 및 개발 기술 없이도 책임감 있게 구축된 AI 기능에 액세스할 수 있는 더 간단한 방법을 제공합니다. Azure AI를 사용하면 클라우드, 하이브리드 또는 컨테이너에 인공 지능을 배포하고 귀사의 비즈니스 요구 사항을 충족하는 다양한 사전 빌드 및 사용자 맞춤형 서비스에 액세스할 수 있습니다. 지난 몇 년 동안 Microsoft는 고객이 AI를 통해 어떻게 성공을 거둘

수 있었는지 여러 사례에서 확인할 수 있었고 고객사들이 수행했던 방식에서 영감을 받을 수 있었습니다. 몇 가지 주요 사례를 소개하면 다음과 같습니다.

- CarMax는 Azure OpenAI 서비스를 사용하여 자동차 조사 페이지의 텍스트 요약 생성을 간소화하여 고객에게 의미 있는 콘텐츠를 신속하게 제공하고 페이지의 검색 엔진 순위를 높였습니다. 이 회사의 초기 목표는 5,000개의 자동차 페이지에 대한 고객 리뷰 요약이었습니다. 기존 수작업 프로세스를 사용했다면 콘텐츠 생성에 약 11년이 걸렸을 것입니다. 그러나 OpenAI 서비스를 통해 CarMax는 단 몇 달 만에 목표를 달성했습니다.^[1]
- Fujitsu는 손으로 쓴 텍스트의 문자 인식률을 최대 99.9%까지 끌어올린 Azure Form Recognizer를 통합하여 클라우드 스캔 솔루션의 성능과 정확도를 개선했습니다.
- Ecolab은 디지털 지원을 위한 인텔리전트 가상 에이전트를 빌드하기 위해 Azure Bot Service, LUIS(언어 이해), Azure Cognitive Search, QnA Maker를 사용하여 현장에서의 통화량을 12% 감소시켰습니다.
- KPMG는 Azure Cognitive Services를 사용하여 컨택 센터 통화에서 규정 준수 위험을 식별하는 시간을 14주에서 2시간으로 단축했습니다.
- Volkswagen Group은 Azure Translator 및 Cognitive Services for Language를 사용하여 수동 검토 없이 1페이지 파일에서 1백만 자 책에 이르기까지 하루 평균 325개의 문서를 번역했습니다.
- 트위터는 Cognitive Services와 음성 텍스트 변환 서비스를 사용하여 스페이스에서 접근성을 위해 실시간 대화에 캡션을 달고 더 많은 오디언스에게 다가갔습니다.

최고 품질의 AI 솔루션을 제공하는 것 외에도 Azure AI는 신뢰성, 안정성, 접근성을 위해 최선을 다하고 있습니다. Microsoft는 데이터 프라이버시 및 보안의 중요성을 잘 알고 있으며, 제품과 서비스가 이러한 영역에서 최고 수준의 표준을 충족할 수 있도록 최선을 다하고 있습니다.

Krunic의 책을 읽은 후 Azure AI를 살펴보고 어떻게 미션 크리티컬한 결과를 달성하고 고객 경험을 개선하는 데 도움이 되는지 알아보세요. Microsoft에서는 귀사에서 전문가와 함께 AI 및 ML 전략을 계획하고 싶거나, Azure AI가 비즈니스에 어떤 도움을 줄 수 있는지 데모로 확인하고 싶거나, AI에 대해 팀을 교육하고 싶은 경우 시작하는 데 필요한 리소스를 제공하고 있습니다. aka.ms/azureai에서 Azure AI와 함께 여정을 시작하세요.

—데이터 및 AI 부문 부사장 JESSICA HAWK

책 전문은 [이 링크](#)에서 확인하실 수 있습니다.

비즈니스에서 AI를 활용하는 방법

이 장에서 다루는 내용

- 프로젝트 리더가 AI에 대해 알아야 할 사항
- AI를 사용하면 도움이 되는 비즈니스 문제 찾기
- 해결하려는 비즈니스 문제와 AI 기능 매칭하기
- 데이터 과학 팀이 보유한 기술과 AI 프로젝트에 필요한 기술 사이의 격차 찾기

AI에 대해 배우는 데 몇 년이 걸릴 수도 있지만, 이 분야는 빠르게 진화하기 때문에 완전히 숙련된 데이터 과학자라 할지라도 지속적이고 지속적인 학습에 상당한 시간을 할애해야 합니다. AI 관련 서적과 논문 시장은 AI에 대한 기술 정보에 의해 지배되고 있습니다. 지식이 너무 많아서 AI를 관리하기 위해 알아야 할 지식과 AI 시스템을 구축하는 엔지니어가 갖춰야 할 지식¹<2>을 구분하기가 어렵습니다.

이 장에서는 AI 프로젝트를 이끌기 위해 이해해야 하는 AI와 ML의 측면에 대해 설명합니다. 또한 AI를 적용하기 적합한 비즈니스 문제를 찾는 방법을 알려줍니다. AI 기능을 이미 알고 있는 비즈니스 조치와 연결하여 AI 인사이트를 실행 가능한 것으로 만드는 방법에 대한 예제를 제공합니다.^[1]

저는 이 장과 그 이후의 장에 제시된 예제를 다양한 비즈니스 영역에서 선택했습니다. 예제 중 일부는 여러분에게 익숙하지 않은 비즈니스 영역에서 나온 것일 수도 있습니다. 이는 AI를 성공적으로 적용하기 위한 주요 기술 중 하나인 처음 접하는 비즈니스 상황에 맞게 AI 기능을 적용하는 연습을 할 수 있는 좋은 기회일 것입니다.

2.1 AI에 대해 무엇을 알아야 하나요?

AI 프로젝트는 비즈니스, 컴퓨터 과학, 수학, 통계, 머신러닝이 결합된 매우 복잡한 작업입니다. 이 섹션에서는 AI에 대한 기술적 지식이 AI 프로젝트를 관리하는 데 필요한 기본 지식이 아닌 이유를 설명합니다. 귀하가 만약 분석적 배경이 없는 AI 프로젝트 리더라면, 최상의 결정을 내리기 위해 이러한 개념을 모두 파악해야 한다고 느끼는 것도 이해할 수 있습니다.

상황이 더 나쁠 수도 있습니다. 데이터 과학자가 여러분이 잘 모르는 개념에 대해 이야기할 뿐만 아니라, 그 개념이 여러분이 *알고 있어야 할 것 같지만* 완전히 기억하지 못하는 것일 수도 있습니다. 그들이 사용하는 전문 용어는 종종 통계 용어에 뿌리를 두거나 관련되어 있습니다. MBA 프로그램 중에 통계학 수업을 한두 번 들었을지 모르지만, 다루는 모든 주제에 특별히 주의를 기울이지 않았을 수도 있습니다. 하지만, 걱정할 필요 없습니다. 프로젝트 성공을 위한 가장 중요한 의사 결정에는 통계나 AI 알고리즘에 대한 광범위한 지식이 필요하지도 않고, 반드시 도움이 되지도 않습니다.

AI 프로젝트를 관리하기 위해 알아야 할 것은 다른 프로젝트와 마찬가지로 프로젝트의 방향과 성공을 제대로 이해하고 모니터링할 수 있는 메트릭과 프로세스를 정의하는 방법입니다. 이를 이해하고 나면 AI 프로젝트 관리는 이전에 감독했던 프로젝트를 실행하는 것과 비슷합니다.

AI 프로젝트 관리는 관리 과학의 또 다른 적용입니다.

잘 알려진 영역의 비유를 들어 설명하자면, 만약 여러분이 공장을 관리한다면, 공장을 운영하기 위해 감독자만큼 유능한 노동자가 될 필요는 없을 것이라고 생각하실 것입니다. 실제로 공장을 성공적으로 경영하는 경영진 중 상당수가 원격 근무에 능숙하지 않다고 해도 과언이 아닙니다.

IT 프로젝트에도 동일한 원칙이 적용됩니다. 데이터베이스 관리자(DBA)뿐만 아니라 데이터베이스를 정말 잘 알아야 할까요? 데이터베이스 프로젝트를 관리하기 위해 DBA가 되어야 한다고 생각하시나요?^a 데이터베이스 프로젝트의 비즈니스

^a AI는 공장이 아니라고 주장하는 사람이 있을 수 있지만, 그렇다고 해서 데이터베이스 프로젝트도 아닙니다. 경영진이 DBA가 되지 않고도 데이터베이스 프로젝트를 관리하는 방법을 배웠습니다. 전문직으로서의 경영은 조직과 프로젝트를 운영하기 위한 몇 가지 보편적인 원칙에 기반하며, 이러한 지식은 AI에도 적용됩니다.

(계속)

및 아키텍처 측면과 RDBMS 시스템을 유지 관리하는 데 필요한 기술을 분리하여 데이터베이스 프로젝트를 관리합니다.

공장 관리자가 공장의 작동 원리를 알면 도움이 되는 것처럼, 프로젝트 리더가 AI에 대한 기술적 지식을 가지고 있다고 해서 도움이 되는 것은 아닙니다. 하지만 공장 관리자가 공장을 관리하는 방법을 알고 적극적으로 관리하는 것을 대신하여 공장장의 업무에 세부적인 부분에 집중할 수는 없습니다. 마찬가지로, 인공지능 프로젝트 리더는 경영 고려사항에 집중해야 합니다.

그러나 AI 프로젝트를 관리할 때는 AI가 내부적으로 어떻게 작동하는지에 대한 세부 사항에 집중해야 한다고 생각하는 반면, 공장이나 데이터베이스 프로젝트를 관리할 때는 세부 사항에 집중할 필요가 없다고 생각하는 경우가 종종 있습니다. 이는 인공지능이 다른 분야와 다르기 때문이라기보다는 인공지능이 훨씬 젊은 분야이기 때문입니다. 공장의 경우, 경영 이론을 개발할 충분한 시간이 있었기 때문에 경영 지식이 제조에 대한 도메인 수준의 지식과 동일하지 않다는 것을 이해할 수 있었습니다. 시간이 더 많았기 때문에 공장을 운영하는 데 필요한 기술과 제품을 만드는 데 필요한 기술을 구분할 수 있는 방법과 시스템을 구축할 수 있었습니다. 이 책의 목표는 AI를 사용하여 동일한 작업을 수행할 수 있도록 돕는 것입니다.

^b 예, 좋은 데이터 과학자를 찾는 것은 어렵고, 현재로서는 드뭅니다. 오늘날 데이터 과학자 중 일부는 감독과 비교되는 것에 반대할 수도 있습니다. 하지만 초기 철도가 건설될 당시, 철도 교대 감독이 혼란 직종이었다고 생각하시나요? 아니면 데이터베이스가 도입되었을 때 DBA 스킴렛이 일반적이었다고 생각하시나요? 인공지능이 젊은 직업이라는 말은 바로 이런 의미입니다.

경영진의 의사 결정과 관련된 대부분의 AI 개념은 비즈니스 용어로 비즈니스맨에게 설명할 수 있습니다. 이상적으로는 데이터 과학자가 이를 수행할 수 있어야 합니다. 만약 그렇게 할 수 없다면, 프로젝트 팀에 AI와 비즈니스 모두에 전문성을 갖춘 인력을 보강하여 커뮤니케이션을 지원해야 합니다.

참고 비즈니스 의사 결정을 위해 분석을 더 잘 이해해야 한다고 느끼는 경우, 이는 지식 부족이 아니라 커뮤니케이션 문제입니다.

AI 프로젝트를 관리하기 위해 알아야 할 것은 AI 개념을 비즈니스와 연관시키는 방법입니다. 즉, 다음 질문에 답할 수 있어야 합니다.

- AI는 무엇을 할 수 있으며, 이를 비즈니스에 어떻게 활용할 수 있는가?
- 어떤 유형의 AI 프로젝트부터 시작해야 하는가?
- AI가 비즈니스를 얼마나 성공적으로 지원하는지 어떻게 측정할 수 있는가?
- AI 프로젝트는 어떻게 관리해야 하는가?
- 어떤 리소스가 부족하며, 이를 가장 잘 할당하려면 어떻게 해야 하는가?

이 책의 나머지 부분에서는 이미 보유하고 있는 관리 기술을 최소한의 수정만으로 AI 프로젝트를 실행하는 데 적용할 수 있는 방식으로 데이터 과학 프로젝트를 구성하는 방법을 보여 줍니다.

2.2 AI는 어떻게 사용되나요?

적절한 비즈니스 행동을 수행할 때 수익을 창출합니다. 이를 통해 사용 중인 시스템에서 AI가 어떤 역할을 하는지, 즉 어떤 조치를 취해야 하는지 알려줍니다. 이 섹션에서는 AI가 어떻게 그렇게 하는지에 대해 설명합니다.

AI, ML, 데이터 과학은 새로운 것으로 인식되고 있지만, 비즈니스 성공에 있어 이들이 수행하는 역할은 새로운 것이 아닙니다. 역사적으로 돈을 벌기 위해 어떤 형태로든 데이터 분석을 사용해 온 직업은 꽤 많습니다. 보험 계리사와 쿼트 애널리스트가 그 예입니다. 통계적 방법을 프로세스 엔지니어링 및 품질 개선 과학에 적용하는 전문가들도 비즈니스 결과를 개선하기 위해 데이터 분석을 사용해 온 오랜 역사를 가지고 있습니다. AI는 분석과 비즈니스의 관계 방식을 바꾸지 않으며, 단지 분석을 수행하는 방법과 분석의 역량 (및 비용)을 변화시킬 뿐입니다. 현재 (그리고 미래) 비즈니스에 AI를 적용하는 방식과 비즈니스에서 데이터 분석을 전통적으로 사용하는 방식 사이에는 상당한 유사점이 있습니다.

비즈니스 문제에 AI를 적용할 기회를 식별하는 방법을 이해하려면 먼저 비즈니스 문제에 AI를 성공적으로 적용하기 위해서는 높은 수준에서 어떻게 바라봐야 하는지 이해해야 합니다. 데이터가 추가 조치를 알리기 위해 사용되는 모든 문제에는 해당 프로세스를 설명하는 공통 패턴이 있습니다. 우리는 데이터를 수집하고, 분석하고, 그에 대응합니다. 이것은 단순히 오래된 제어 루프이며, 이 루프의 요소를 이해하는 것이 중요합니다. AI는 이 루프의 분석 부분에 새로운 기능을 추가할 뿐입니다. 그림 2.1은 이러한 요소가 상호 작용하는 방식을 보여줍니다.

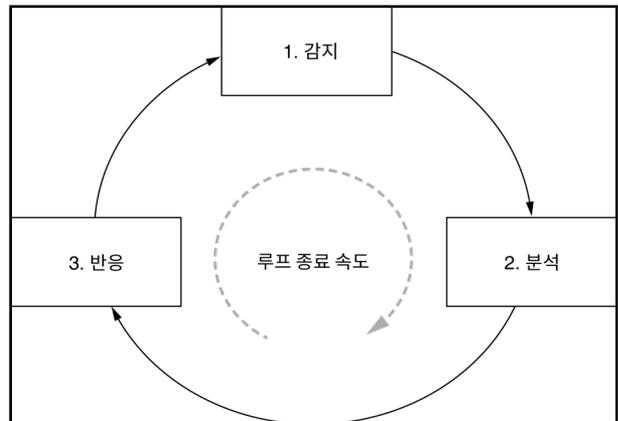


그림 2.1 감지/분석/반응 루프입니다. 성공적인 분석 프로젝트에는 이 루프의 세 가지 요소가 모두 포함되어야 합니다.

그림 2.1의 요소는 다음과 같습니다.

- 감지 —루프의 센서 부분은 분석이 찾는 데이터를 얻는 곳입니다. 빅 데이터 이전 시대의 대부분의 엔터프라이즈 시스템에서는 데이터가 서로 다른 데이터베이스에 있었습니다. 빅데이터 시스템의 경우, 데이터 레이크에 데이터를 저장하는 것이 일반적입니다.

- **분석**—그것은 이제 데이터 세트에 AI를 적용하는 박스입니다. AI를 사용하기 전에는 더 간단한 알고리즘(예: PID 컨트롤러[34])이나 사람의 개입(예: 은행의 경우 수동 대출 승인)을 사용했습니다. 분석을 돕기 위한 AI의 도입은 최근의 발전으로 인식되지만, AI 연구는 1956년에 시작된 것이 아닙니다[35]. 우리는 수십 년 동안 컴퓨터 시스템을 사용하여 분석을 수행해 왔습니다. 새로운 점은 오늘날 최신 AI 기술을 통해 컴퓨터화된 분석이 훨씬 더 강력해졌다는 것입니다!
- **반응**—반응자/이펙터는 실제 세계에서 행동을 담당하는 부분으로, 반응은 사람이나 기계가 수행할 수 있습니다. 수동 반응의 예로는 분석 결과에 따라 관리 결정을 내리는 많은 의사 결정 지원 시나리오가 있습니다. 자동 반응의 예로는 로봇 시스템, 스마트 온도계[36,37], 자동화된 차량[38] 등이 있습니다.

루프를 닫는 속도는 어떤 사건이 발생하는 순간과 반응이 수행되는 시간 사이의 시간입니다. 루프를 닫는 속도가 얼마나 중요한지는 도메인에 따라 다릅니다. 고빈도 트레이딩 시스템에서는 최대한 빠른 속도로 루프를 완료해야 할 필요가 있을 수 있습니다. 다른 상황(예: 고고학 연구의 맥락에서 데이터 분석을 수행하는 경우)에서는 타이밍 요구 사항이 훨씬 더 완화될 수 있습니다. 자율주행 차량의 경우 인공지능 분석에 정해진 시간보다 *더 오래 걸리지 않도록* 해야 할 수도 있습니다.

참고 루프를 닫는 속도도 시스템으로 데이터를 수집하는 빈도에 따라 달라집니다. 때때로 데이터를 주기적으로 시스템에 수집하는 것이 허용되는 경우도 있습니다. 다른 경우에는 데이터가 시스템에 도착하는 즉시 실시간으로 분석해야 합니다. (이를 *스트리밍 분석*이라고 합니다.)

감지/분석/반응 루프를 적용할 때 중요한 고려 사항은 *누가 또는 무엇이 반응하는가*에 대한 질문입니다. 자동화된 방식으로 시스템 자체가 될 수도 있습니다. (그것이 바로 자율 주행 자동차[38]가 하는 일입니다.) 또는 분석 결과에 따라 사람일 수도 있습니다. 오늘날 데이터 과학을 사용하는 기업에서는 후자의 경우가 훨씬 더 일반적입니다.

감지/분석/반응 루프는 광범위하게 적용 가능합니다.

감지/분석/반응 루프는 다양한 규모에 걸쳐 적용 가능합니다. Nest[36]나 ecobee[37]와 같은 스마트 온도계의 경우처럼 단일 기기, 비즈니스 프로세스, 여러 부서, 기업 전체, 스마트 시티 또는 더 넓은 지역에 적용될 수 있습니다. 감지/분석/반응 패턴 루프는 앞으로 재난 구호나 전염병 추적 및 예방과 같은 시스템에서 사회 전체 차원에 적용될 것이라고 생각합니다.

감지/분석/반응 패턴은 빅데이터와 데이터 과학의 영역에만 국한되지 않습니다. 이 패턴은 개발 및 조직 프로세스 영역에도 적용됩니다. 관리 과학에서 정의하고 사용하는 다양한 형태의 제어 루프에 대해 알고 계실 것입니다. 이러한 루프의 예로는 PDCA [39,40], OODA [41,42], CRISP-DM [43]과 같은 개념이 있으며,

이는 이 패턴과 공통점이 있고 더 정교하게 발전된 형태입니다. 감지/분석/반응 패턴은 생물학에도 적용됩니다(예: 문어와 다른 동물의 행동 방식 [44]). 일부 영역에서는 루프의 반응 부분을 이펙터라고 부르기도 합니다 [45].

모든 비즈니스 프로세스의 자동화는 감지/분석/반응 루프의 적용일 뿐입니다. AI를 사용하면 이전에는 자동화된 반응이 불가능했던 일부 문제 영역에 해당 루프를 적용할 수 있습니다.

자동화된 데이터 분석은 최근에 개발된 기술인가요?

복잡하고 컴퓨터화된 분석을 사용하여 완전히 자동화되고 신속한 감지/분석/반응 루프를 사용하는 것조차 새로운 것은 아닙니다. 특히 알고리즘 트레이딩과 결합된 자본 시장은 이러한 패턴을 대규모로 구현합니다. 사물인터넷[46]과 로봇공학이 더욱 발전함에 따라 이러한 대규모의 완전 자동화된 폐쇄형 제어 루프는 물리적 세계에서 훨씬 더 널리 퍼질 것입니다.

2.3 AI의 새로운 기능은 무엇인가요?

AI의 발전으로 새로운 분석 기능이 추가되어 감지/분석/반응 루프의 적용 범위가 넓어졌습니다. 이 섹션에서는 이러한 새로운 기능에 대해 설명합니다.

AI와 빅데이터의 새로운 점은 자동화된 분석이 더 저렴하고, 더 빠르고, 더 좋아졌으며, (빅데이터 시스템을 사용하여) 훨씬 더 큰 데이터 세트에서 작동할 수 있게 되었다는 점입니다. 과거에는 사람의 개입이 필요했던 분석이 이제 이미지 및 음성 인식과 같은 영역에서 컴퓨터로 가능해졌습니다. 이 새로운 AI 기반 기능 덕분에, 이전에는 경제적으로 적용하기 어려웠던 전체 감지/분석/반응 루프를 이러한 상황에서 실행할 수 있게 되었습니다.

자동화를 실현하는 AI의 예

다음은 AI의 도입으로 이전에는 사람이 수행해야 했던 작업을 자동화할 수 있게 된 몇 가지 예입니다.

- **한 언어에서 다른 언어로 자동 번역**—언어 번역은 새로운 것이 아니며 인류가 태초부터 해온 일입니다. 새로운 것은 인공지능이 이제 자동 번역이 가능한 수준에 도달했고, 이에 따라 번역 웹 서비스가 실용화되었다는 것입니다.^a
- **자율 주행 자동차**—우리는 지난 250여 년 동안 어떤 형태로든 자동차를

^a 실제 번역 시스템의 실제 제어 루프는 일반적으로 최소 두 개의 제어 루프가 존재해야 한다는 점에 유의하세요. 한 루프는 한 언어에서 다른 언어로 번역하고, 다른 루프는 이 서비스를 위해 수익을 창출합니다. 두 번째 루프는 필요한 번역에 대한 정보를 수집하고, 이를 분석하고, 번역 서비스 제공업체에 수익을 창출하는 작업을 수행함으로써 작동할 수도 있습니다.

(계속)

사용해 왔으며, 항상 인간 운전자가 필요했습니다.^b AI의 새로운 점은 인간 운전자가 필요 없는 자동차를 만들 수 있을지도 모른다는 점입니다.

- **안절환 진단 능력**—우리 모두는 안과 의사와 검안사를 위해 멀리서 글자를 읽고 명령에 따라 밝은 빛을 응시해 본 적이 있습니다. 새로운 것은 간단한 망막 이미지에서 당뇨병성 망막증을 감지하는 AI의 능력입니다[49].
- **웹에 게시된 댓글을 읽는 능력**—웹 사이트의 댓글 섹션에 있는 자료를 충분히 읽으면 사람들이 특정 주제에 대해 열광적인지 회의적인지 추측할 수 있습니다. 이제 인공지능도 할 수 있습니다. AI는 사람보다 훨씬 더 많은 수의 댓글을 더 빠르고 저렴하게 읽을 수 있으며, 청중이 주로 열광적인지 회의적인지 여부를 알려줍니다. 우리는 이 기능을 **감정 분석**이라고 부릅니다.^c
- **제품 추천**—우리 각자에게는 우리가 좋아할 만한 책, 영화, 제품을 추천하는 친구가 있습니다. 예를 들어 Amazon 웹 사이트에서 AI가 이러한 작업을 수행하는 것을 **추천 엔진**이라고 합니다.

역사적으로 데이터 세트의 크기가 작을 때는 사람이 AI가 수행하는 것과 동일한 분석을 수행할 수 있었습니다. 어떤 경우에는 동일한 데이터세트를 가지고 인간이 할 수 있는 것보다 AI가 더 못하는 경우도 있습니다. 하지만 장기적으로 볼 때 AI는 더 경제적이며, 인간이 보기에는 너무 큰 데이터 집합에서도 작동할 수 있습니다.

^b 바퀴가 달린 최초의 자체 추진 차량은 1769년에 발명되었고[47], 최초의 가솔린 자동차는 1870년에 등장했습니다[48].

^c 글을 쓰는 시점에서 AI는 인간만큼 웹 콘텐츠를 잘 읽지 못하며, 텍스트의 냉소주의와 미묘한 메시지로 어려움을 겪고 있으며—메시지의 기본 논조조차 놓치는 경우가 많습니다. 그러나 "지난 3개월 동안 제품에 대한 감정이 개선되었습니까?"라는 질문에 답하기 위한 목적이라면 인공지능은 충분합니다. 인공지능은 충분히 훌륭하며 여러분이나 저보다 훨씬 저렴하게 답변을 제공할 수 있습니다.

AI의 새롭거나 달라지지 않은 점은 분석만으로는 여전히 수익을 창출할 수 없다는 점입니다. 앞서 예로 든 사용 사례 중 어느 것에서도 수익을 창출하는 방법에 대해 이야기하지 않았습니다. 이러한 사용 사례 중 일부는 수익을 창출하는 것이 매우 간단하지만(예: 인간보다 더 잘 운전하는 자율 주행 차량), 다른 사용 사례에서는 AI로 수익을 창출하는 방법이 명확하지 않을 수 있습니다.

빈약한 비즈니스 사례에는 AI가 도움이 되지 않습니다.

인공지능 기반 분석이 아무리 뛰어나더라도 **수익을 창출할 수 없는 경우도 있습니다**. 교통 표지판 제조업체가 교통 표지판의 여론에 대한 감정 분석을하기로 결정했다고 가정해 봅시다. 이 제조업체는 이 분석으로 손해를 볼 가능성이 높습니다. 운전자들의 감정이 교통 표지판 공급업체 선택에 실질적인 영향을 미친다는 것이 명확하지 않습니다(또는 표지판에 대한 감정은 표지판의 위치가 아니라 공급업체의 선택에 의해 결정될 것입니다).

분석을 수행하면 해당 분석에 대한 비용이 발생합니다. 분석 결과에 따라 대응할 때 수익이 발생할 수 있습니다. 분석 결과를 얻은 후 취할 수 있는 비즈니스 조치가 없다면 분석은 항상 손실입니다.

2.4 AI로 수익 창출하기

AI를 통해 감지/분석/반응 루프를 통해 분석을 개선할 수 있다면, AI로 어떻게 수익을 창출할 수 있을까요? AI를 통해 감지/분석/반응 루프를 적용할 수 있는 상황을 찾아서 해당 루프를 사용하여 가능한 비즈니스 작업 중 하나를 자동화할 수 있습니다. 이 섹션에서는 그 방법을 설명합니다. 그림 2.2는 AI로 수익을 창출하는 일반적인 프로세스를 보여줍니다.

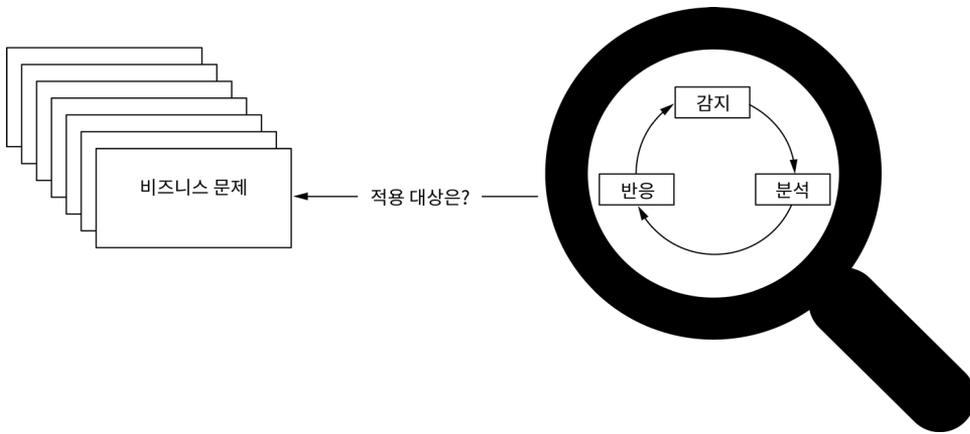


그림 2.2 AI로 수익을 창출하는 것은 감지/분석/반응 루프를 적용할 수 있는 비즈니스 문제를 찾아내는 데 기반합니다.

AI의 기능 덕분에 이 제어 루프를 새로운 컨텍스트에 적용할 수 있습니다. 하지만 감지/분석/반응 루프를 성공적으로 적용하려면 루프의 모든 구성 요소가 기술적으로 가능한지 확인해야 합니다.

- 감지 측면에서는 AI 지원 분석에 필요한 데이터를 수집할 수 있는 기능이 있어야 합니다. 3장에서는 선택한 AI 방법에 적합한 데이터를 수집했는지 확인하는 방법을 다룹니다.
- 분석 측면에서는 사용 가능한 AI 기술로 가능한 범위 내에 머물러 있는지 확인해야 합니다.
- 반응 측면에서는 분석 결과를 비즈니스에서 실제로 구현할 수 있는 작업 중 하나와 연결해야 합니다. 수행할 수 있는 가능한 비즈니스 액션의 목록을 만들고 "이 비즈니스 액션을 더 잘 알려줄 수 있는 AI 분석이 있습니까?"라고 질문합니다.

감지/분석/반응 루프가 비즈니스 문제에 적용 가능하다는 것을 알게 되면, AI를 사용하여 해당 비즈니스 문제를 해결할 수 있는 능력이 있다는 것을 알게 됩니다. 예제부터 시작하겠습니다.

2.4.1 의료 진단에 적용된 AI

대형 병원의 소프트웨어 개발팀에 소속되어 있다고 가정해 보겠습니다. 팀의 목표는 병원의 임상 및 진단 절차에 AI를 적용하는 것입니다. 이 섹션에서는 AI가 도움이 될 수 있는 사용 사례를 찾는 방법을 보여줍니다.

이 예제를 작고 관리하기 쉽게 유지하기 위해 안과 검사를 받는 환자라는 단일 진단 워크플로에 집중하겠습니다. 환자의 망막 이미지를 촬영하여 질병이 있는지 확인합니다. 이 절차가 그림 2.3에 표시된 단계로 구성되어 있다고 가정합니다.¹

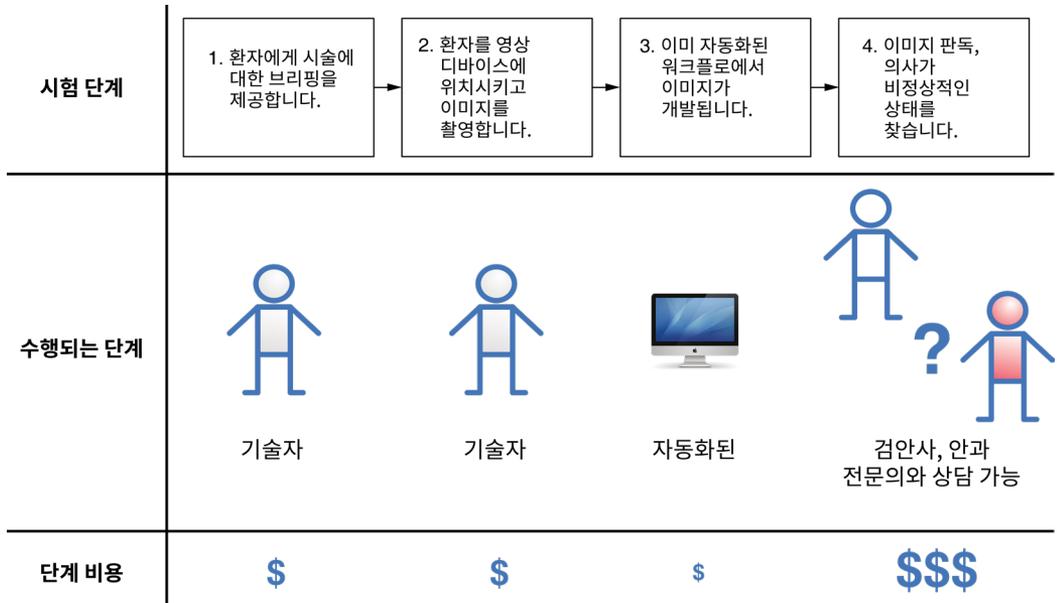


그림 2.3 일상적인 검안 검사의 워크플로. 이 워크플로의 일부를 자동화하기 위해 AI를 적용하겠습니다.

그림 2.3에 표시된 워크플로는 다음 단계로 구성됩니다.

- 1 환자에게 시술에 대한 브리핑을 제공합니다. 이 단계는 검안사의 개입을 최소화하여 기술자가 수행할 수 있습니다.
- 2 환자를 영상 장치에 위치시키고 이미지를 촬영합니다. 이 단계도 기술자가 수행합니다.

¹ 실제 검안/안과 검사는 더 복잡하지만 여기서는 설명을 위해 단순화했습니다.

- 3 이미 자동화된 워크플로에서 이미지가 개발됩니다.
- 4 검안사가 이미지를 판독하여 비정상적인 상태를 찾습니다. 필요한 경우 추가 의사와 상담합니다.

이제 인공지능이 도움을 줄 수 있는 곳을 찾습니다. 이 워크플로에서는 환자와의 두 번의 상호작용과 안구 이미지의 최종 판독이라는 세 가지 단계에 AI를 적용할 수 있습니다.

어떤 분석을 할 것인지 생각하면서 시작하지 마세요!

"어떤 분석을 수행할 수 있을까?"라고 질문하는 것으로 시작하지 않는 이유를 설명하기 위해 AI가 어떤 작업을 수행할 수 있다는 것을 알고 분석부터 시작하는 시나리오를 구성해 보겠습니다.

여러분은 Apple Siri[50]와 같은 음성 비서를 알고 있고, 음성 인식이 점점 더 좋아지고 있다는 것을 알고 있을 것입니다. 음성 어시스턴트/음성 인식 기능을 챗봇과 결합하여 환자에게 기계가 브리핑을 할 수 있도록 하면 어떨까요? 이 멋진 기술과 함께 일할 수 있는 훌륭한 데이터 과학 팀이 있다는 것은 행운입니다. 인공지능을 잘 활용하고 있는 것 같지 않나요? 빠른 프로토타입을 만들어 봅시다!

안타깝게도 이런 프로토타입에 투자하는 시간은 낭비입니다. 기술자를 대체하는 것은 가치가 제한적입니다—기술자가 환자에게 브리핑하는 데 소비하는 시간은 상대적으로 적습니다. 더 중요한 것은 여러 언어, 장애, 연령, 기계와의 상호작용에 대한 편안함 등 다양한 환자 집단에 서비스를 제공한다는 점입니다. 인간 기술자는 이러한 인구를 잘 다룰 수 있지만, 오늘날의 AI는 그렇지 않습니다. 일부 인구 집단이 음성 어시스턴트와 대화하는 데 익숙하지 않다는 것 외에는 다른 이유가 없다면 말이죠.

흥미로운 기술을 기반으로 한 아이디어입니다. 이 사용 사례는 본질적으로 흥미롭고 공상과학 소설에서나 나올 법한 이야기입니다—많은 공상과학 소설에는 환자가 AI 의사와 대화하는 장면이 등장합니다. 문제는 통제할 수 없는 요인으로 인해 처음부터 수익성이 없는 비즈니스 활동에 AI를 적용하려 했다는 것입니다.

이것이 일반적인 함정입니다. 비즈니스 환경에서 AI로 작업하는 모든 사람은 좋은 비즈니스 사례가 있다고 주장하지만, 비즈니스 사례는 나중에 고려해야 할 사항인 경우가 많으며, 프로젝트에 대한 팀의 초기 흥분은 흥미로운 AI 기술로 작업할 수 있는 기회에 기인합니다.

최악의 경우 프로젝트의 기술적 부분이 성공하더라도 처음부터 수익을 창출하는 것이 불가능할 수도 있습니다. 좋은 AI 구현이 부실한 비즈니스 사례를 구제할 수는 없습니다.

체계적인 접근 방식을 사용하여 검안 시험에 AI를 더 잘 적용합니다. 먼저 수행할 수 있는 도메인 작업을 열거한 다음, 해당 작업에 감지/분석/반응 루프를 적용할 수 있는지 확인합니다.

팁 "실행 가능한 도메인 액션은 무엇인가?"라는 질문으로 시작하세요. 수행할 수 있는 도메인 액션의 수는 제한되어 있으므로 소수의 사용 사례만 고려해야 합니다.

이 워크플로에서는 기술자가 환자와 상호 작용하고 안과 의사/검안사가 안구 이미지를 판독하여 안과 질환의 유무를 확인하는 두 가지 상호 작용이 있습니다. 환자와의 상호 작용은 초기 브리핑과 좋은 이미지를 촬영할 수 있도록 환자를 영상 장치에 위치시키는 것으로 구성되며, 브리핑을 자동화할 수 없는 이유를 잠시 전에 살펴보았습니다. 환자 위치는 어떻게 잡을까요? 그러려면 로봇 공학 전문 지식이 필요한데, 경영진은 로봇 공학 회사가 아니라 소프트웨어 개발 회사라고 단호하게 말합니다. 귀사의 경우 환자와 직접 상호 작용하는 영역에서는 어떤 조치도 실행할 수 없습니다.

이미지를 해석하는 것은 어떻습니까? 특정 안질환에 대한 이미지 해석은 복잡하고 경우에 따라 검안사가 중요한 상태를 놓칠 수 있다는 것이 밝혀졌습니다. 또한 전문적인 해석은 비용이 많이 들기 때문에 안과 질환 진단에 도움이 되는 대체 시스템을 만들 수 있다면 병원에서 비용을 절감할 수 있을 것입니다. 이 사용 사례는 더 조사해 볼 가치가 있습니다.

데이터 과학 팀의 추가 연구에 따르면 컴퓨터 비전을 의료 진단에 적용하는 데 상당한 진전이 있었다고 합니다. Google 팀은 중등도 및 중증 당뇨망막병증 사례를 진단할 수 있는 AI를 개발했습니다[49]. 과거 검안 검사에서 얻은 데이터가 충분하여 해당 데이터로 AI를 훈련시킬 수 있습니다. 이 사용 사례에서 감지/분석/반응 루프를 적용하려면 감지 부분만 다루면 됩니다. 이미 환자의 망막 이미지가 있고, 그 이미지를 AI 시스템으로 전송하면 됩니다.

2.4.2 AI 수익화를 위한 일반 원칙

이전 예제에서는 하나의 비즈니스 시나리오에서 AI를 사용할 수 있는 기회를 찾는 방법을 보여드렸습니다. 이 섹션에서는 이 예제에서 추출할 수 있는 일반적인 원칙을 보여줍니다. 그림 2.4는 AI를 적용하기 위한 이러한 원칙을 보여줍니다.

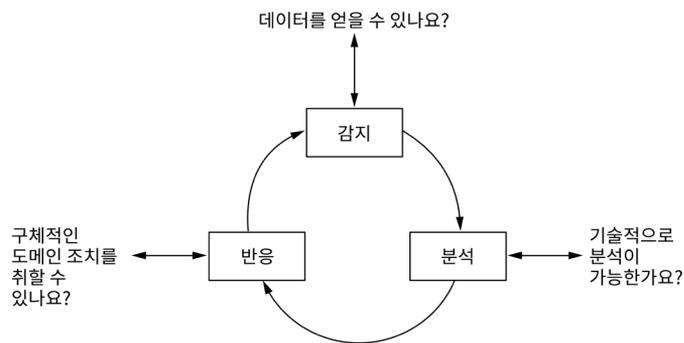


그림 2.4 비즈니스 문제에 AI를 적용하기 위한 일반적인 원칙입니다. 기본 아이디어는 감지/분석/반응 루프의 모든 부분을 구현할 수 있도록 하는 것입니다.

그림 2.4에 표시된 접근 방식은 감지/분석/반응 루프의 각 부분을 다룹니다.

- **감지**—필요한 데이터를 수집할 수 있나요? 해당 데이터를 수집하는 데 비용이 얼마나 드나요?
- **분석**—이상적인 상황에서 AI가 해당 분석을 수행할 수 있나요, 아니면 AI로 유사한 작업을 성공한 적이 있나요? AI가 그런 능력을 가지고 있다는 것은 잘 알려져 있나요? 귀사의 팀은 이러한 AI 방법을 적용하는 데 전문성을 갖추고 있는가? 적용하는 것이 얼마나 어려운가요?
- **반응**—AI에게 가치 있고 가능한 도메인 액션을 찾아보세요. 그 행동의 경제적 가치는 얼마인가요? 이 정보를 통해 해당 작업을 AI로 자동화하는 것이 경제적으로 실행 가능한지 판단할 수 있습니다.

3장과 4장에서는 비즈니스 메트릭을 사용하여 경제적 측면과 감지/분석/반응 루프의 적용을 다루는 방법에 대해 설명합니다. 당분간은 루프의 반응 및 분석 부분을 다루는 방법에 집중하겠습니다. 다음 두 가지 질문에 답해야 합니다.

- 1 AI의 혜택을 받을 수 있는 도메인 작업을 찾는 데 도움이 되는 비즈니스에 대한 체계적인 사고 방식이 있나요?
- 2 AI의 높은 수준의 기능은 무엇인가요?

이 두 가지 질문에 대한 답을 알고 나면 섹션 2.4.1에 표시된 것과 같은 분석을 수행하여 AI의 실행 가능한 사용 사례를 찾을 수 있습니다.

AI로 돈을 버는 것은 AI가 인간보다 똑똑하다는 것에 기반하지 않습니다.

이 장 (및 1장)의 사례는 AI로 성공을 거두려면 특정 알고리즘이나 기술보다 AI와 비즈니스를 연결하는 것이 훨씬 더 중요한 이유를 보여줍니다. AI는 초인적인 지능을 제공하는 것이 아니라 이미지 인식과 같은 제한된 영역에서 인간과 같은 능력을 가지고 있습니다. 또한 이러한 기능을 경제적으로 적용하고 인간보다 더 큰 데이터 세트로 작동할 수 있습니다. 하지만 AI의 기능이 비즈니스 개선으로 어떻게 연결되는지 파악해야 합니다.

AI는 대규모 데이터 세트를 처리할 수 있기 때문에 때때로 인간의 지능을 뛰어넘는 인사이트를 발견할 수 있습니다. 그러나 복잡한 영역에서 작동할 때 AI는 여전히 인간보다 뒤처집니다. AI는 스스로 돈을 버는 방법을 알아내지 못합니다.

Peter Drucker는 일을 제대로 하는 것보다 옳은 일을 하는 것이 더 중요하다고 믿었습니다.^a AI의 역할은 더 나은 분석을 할 수 있도록 돕는 것이며, 일을 제대로 하는 데 도움을 줄 수 있지만, AI가 올바른 문제에 적용되도록 하는 것은 사람만이 가능합니다.

^a "비즈니스 효율성을 위한 관리"[4] 기사에서 발췌: "근본적으로 효과성과 효율성 사이의 혼동은 옳은 일을 하는 것과 옳은 일을 하는 것 사이에서 있습니다. 전혀 하지 말아야 할 일을 매우 효율적으로 하는 것만큼 쓸모없는 일은 없을 것입니다."

2.5 도메인 작업 찾기

이제 AI를 적용하는 것이 단순히 어떤 도메인 액션에 감지/분석/반응 루프를 적용하는 문제라는 것을 이해했다면, 다음 질문은 어떻게 체계적으로 취할 수 있는 도메인 액션을 찾을 수 있는지에 대한 것입니다. 이 섹션에서는 이를 찾는 방법을 보여줍니다.

비즈니스에서 AI가 수행할 수 있는 높은 수준의 역할은 제한되어 있습니다. 그림 2.5는 이러한 역할을 보여줍니다.

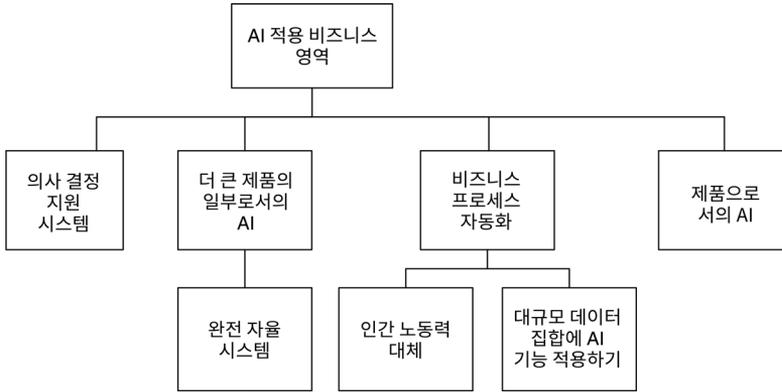


그림 2.5 AI 분류는 비즈니스에서 수행하는 상위 수준의 역할을 기반으로 합니다. 이 분류법을 사용하여 AI로 지원할 수 있는 비즈니스 조치를 도출할 수 있습니다.

다음 중 일부로 AI를 사용할 수 있습니다.

- **의사 결정 지원 시스템**—AI는 조직의 직원이나 관리자가 더 나은 결정을 내릴 수 있도록 도와줍니다. 이러한 시스템의 용도는 경영진이 조직 전체에 영향을 미치는 의사 결정을 내리는 데 도움을 주는 것부터 일선 직원의 일상 업무를 지원하는 것까지 다양합니다.
- **더 큰 제품**—AI는 더 큰 제품의 일부일 수 있습니다. 이러한 제품에는 AI가 가능하게 할 수 있지만 순수한 AI 기능이 아닌 기능이 있습니다. 예를 들어 Roomba[51]와 같은 집 청소 로봇이나 ecobee[37], Nest[36]와 같은 스마트 온도 조절기를 들 수 있습니다. 완전 자율 시스템의 경우, 사람이 개입할 필요 없이 AI가 시스템 운영을 안내하고 결정을 내립니다.
- **비즈니스 프로세스 자동화** —AI가 비즈니스 프로세스의 일부 단계를 자동화합니다. 때로는 인간의 노동력을 대체하기 위해, 때로는 인간이 처리할 수 없을 정도로 큰 데이터 세트를 처리하기 위해 수행됩니다.
- **제품으로서의 AI** — AI 도구를 상품으로 패키징하여 다른 조직에 판매할 수 있습니다. 예를 들어 교통 표지판의 이미지를 인식할 수 있는 AI 제품을 자율 주행 차량 제조업체에 판매할 수 있습니다.

이 섹션의 나머지 부분에서는 이러한 각 항목에 대해 설명합니다.

2.5.1 의사 결정 지원 시스템의 일부인 AI

오늘날 기업에서 데이터 과학을 사용하는 가장 일반적인 시나리오 중 하나는 AI가 의사 결정 지원 시스템으로 사용되는 시나리오입니다. 이 섹션에서는 이러한 시스템의 일부로 AI를 사용하여 도메인 작업을 찾는 방법을 보여줍니다.

의사결정 지원 시스템의 일부로 AI를 사용하는 것은 도메인 액션을 도출하기 위한 가장 쉬운 시나리오입니다. 어떤 의사 결정 지원 시스템에서든 사용자는 이미 결정해야 하는 옵션에 집중하고 있습니다. 의사 결정 지원 시스템의 일부로 AI를 사용할 때는 의사 결정을 지원하는 사용자(또는 관리 팀)를 고려해야 합니다. 그런 다음 그들이 내릴 수 있는 결정의 스펙트럼을 열거합니다. 마지막으로 스스로에게 이런 질문을 던져보세요: "이 가능한 옵션 중에서 선택하려면 어떤 정보가 필요한가?" 그런 다음 해당 정보를 제공하는 것을 중심으로 프로젝트를 구성합니다.

경영진을 돕는 AI

대규모 제조 운영을 지원한다고 가정해 보겠습니다. 이 사업장에는 매일 수천 개의 부품을 배송하는 여러 대형 공급업체가 있습니다. 공급업체의 구성 요소 중 일정 비율에 결함이 있는 경우 조직이 제조 공정에서 문제 해결에 많은 시간을 할애해야 한다는 점이 비용 측면에서 큰 우려 사항입니다. 이러한 문제 해결은 비용이 많이 듭니다. 더 큰 문제는 제조업체 자체의 최종 제품 품질이 저하될 수 있다는 점입니다.

개별 공급업체가 비즈니스의 큰 부분을 차지하지만, 이 분야는 소수의 대형 공급업체가 지배하고 있으며 공급업체가 제품의 품질을 개선하도록 강제할 수 있는 능력은 제한적입니다. AI가 제조 운영의 관리 팀에 어떤 도움을 줄 수 있습니까?

경영팀이 구현할 수 있는 옵션과 실행 가능한 옵션을 열거하는 것부터 시작하세요. 조직은 개별 공급업체에 대한 영향력이 거의 없기 때문에 조직이 취할 수 있는 유일한 실행 가능한 비즈니스 조치는 공급업체를 변경하는 것입니다.

공급업체를 변경하려면 어떤 질문에 답해야 합니까? 여기서는 한 가지 가능한 답변에 집중합니다.

이상적으로는 공급업체의 품질이 악화되기 전에 선제적으로 공급업체를 교체하고 싶습니다—그러나 그때는 이미 제조 운영에서 비용이 발생했을 때입니다. 공급업체와 계속 거래할 경우 어떤 비용이 발생할지 모르기 때문에 공급업체와의 관계를 종료하기로 결정하기가 어렵습니다. 이상적으로는 공급업체의 품질 추세가 어디로 향하고 있는지에 따라 선제적으로 대응하고 싶습니다. 품질 추세가 개선되고 있는 공급업체와 거래를 끊고 싶지 않을 것입니다. 또한 추세가 하락하고 있는 공급업체를 바꾸기 위해 기다리기를 원하지 않습니다.

경영진의 대응을 바탕으로, 이제 AI를 사용하여 품질에 대한 과거 추세를 분석하고 미래 품질 추세를 예측할 수 있다면 경영에 유용한 시스템을 갖출 수 있다는 것을 알게 되었습니다. 의사결정 지원 시스템의 일부로 AI를 활용한 사례입니다.

이 예는 또한 다른 사람에게 효과가 있었던 AI 솔루션을 적용하는 것보다 자신의 비즈니스 사례에 맞게 AI를 맞춤화하는 것이 더 나은 이유를 설명합니다. 귀사가 해당 공급업체의 훨씬 더 큰 고객이라면 단순히 공급업체를 바꾸는 대신 관리 팀이

(계속)

관계 조건을 협상할 수 있을 것입니다. 이러한 관계 조정의 예로는 공급업체의 경영진에게 문제를 에스컬레이션하거나 결함이 있는 부품에 대한 금전적 보상을 요청하는 것 등이 있습니다.

귀사의 조직보다 훨씬 큰 공급업체의 고객에게는 이러한 조치가 실행 가능한 조치일 수 있지만, 귀사의 조직에는 실행 가능한 조치가 아닙니다. 훨씬 더 큰 조직에 맞춰진 일반적인 AI 솔루션은 기업이 취할 수 없는 조치에 초점을 맞출 수 있습니다.

이 시나리오의 마지막 질문입니다: 많은 부서가 있는 대규모 조직이라고 가정할 때, 의사 결정 지원 시스템에서 비즈니스 작업을 지원하도록 요청하는 세부 수준은 어느 정도여야 할까요? 분석을 수행하는 팀의 책임 및 실행 범위 내에 있는 옵션을 고려해야 합니다.

경고 수행 가능한 조치를 찾기 위해 적절한 수준의 조직을 선택하는 것이 중요합니다. 취할 수 있다고 생각되는 20개 이상의 서로 다른 옵션을 열거하는 목록으로 완료하면 분석을 수행한 세분화 수준이 잘못되었습니다.

의사 결정 지원 시스템의 일부로 AI를 사용하는 것에 대해 논의할 때 너무 깊이 파고드는 것은 위험합니다. 고위 관리자로 구성된 팀을 위한 의사 결정 지원 시스템의 일부로 AI를 적용하는 경우, 조직에서 일하는 개별 작업자가 취할 수 있는 조치가 아니라 고위 관리자가 취하는 조치를 분석해야 합니다. 인턴이 첫날에 할 수 있는 행동을 분석하지 마세요.

팁 의사결정권자가 고위급 관리자일 필요는 없습니다. 영업 인력에게 접근해야 할 고객을 추천하고 각 고객에 대한 추가 정보가 포함된 대시보드를 표시하는 AI를 상상해 보세요. 하지만 최종 선택은 개별 영업 전문가에게 맡겨져 있습니다. 이러한 AI가 바로 의사 결정 지원 시스템입니다.

2.5.2 더 큰 제품의 일부로서의 AI

또 다른 일반적인 상황은 AI 기능이 더 큰 제품의 일부일 때 발생합니다. 이 상황의 주요 특징은 최종 고객이 AI 자체를 구매하는 것이 아니라 AI를 사용하지 않으면 더 큰 제품에 포함되지 않는 일부 기능에 대한 비용을 지불한다는 것입니다. 이 섹션에서는 더 큰 제품의 맥락에서 AI를 사용하는 방법을 보여줍니다.

제품 자체의 일부인 AI는 이미 매우 중요합니다. 스마트 스피커(Amazon Alexa [52], Google Home [53,54], Apple HomePod [55])에서부터 자율 주행 차량 [38]에 이르는 다양한 제품이 그 예입니다. AI를 제품 차별화를 위한 방법으로 생각할 수도 있지만, 일반적으로 고객에게 가치 제안을 가능하게 하는 **조력자**로 생각하는 것이 더 낫습니다.

팁 AI를 사용한다는 이유만으로 제품을 구매하는 사람은 거의 없습니다. 핵심 질문은 "제품이 고객에게 어떤 가치를 제공하는가?"입니다.

"우리는 AI를 사용합니다"라고 말하는 것이 마케팅/모금 기법으로 통하던 시기가 있었을지 모르지만, 이제 그런 시대는 끝났습니다. 시간이 지남에 따라 AI는 오늘날 자동차에서 엔진이 하는 것과 같은 역할을 자율주행 제품에서 수행하게 될 것입니다. 그러나 대부분의 자동차 구매자는 특정 엔진이 아니라 자동차를 A 지점에서 B 지점으로 이동시키는 능력에 관심이 있습니다.

제품의 일부인 AI

인간과 함께 작동하는 AI 제품의 예로는 보안 시스템의 일부로 AI 기반 장치를 사용하는 홈 보안 회사가 있습니다. 이러한 시스템이 취할 수 있는 관련 조치는 무엇인가요? 우선, 침입자가 있다고 판단되면 경보를 울릴 수 있습니다.

다양한 비용 및 책임상의 이유로 관리자는 경보를 울리거나 경찰에 신고하는 최종 조치를 항상 모니터링 센터의 숙련된 실시간 운영자가 시작하도록 요구할 것입니다. 또한 관리자는 자산을 모니터링하기 위해 몇 명의 운영자를 배정할지 결정할 수 있습니다. 한 사람이 여러 보안 자산을 모니터링할 수 있다면 이 사업은 훨씬 더 수익성이 높을 것입니다.

이러한 시스템에서 AI를 활용하여 모니터링 센터에 배치된 운영자를 도울 수 있습니다. AI가 얼굴을 인식할 수 있다면 집에 거주하는 가족이 아닌 사람이 집에 있을 때 경보를 울릴 수도 있습니다. 그러면 AI가 이를 운영자에게 알려 확인이 이루어질 수 있도록 하고, 필요한 경우 운영자가 경보를 울릴 수 있습니다.

AI가 더 큰 제품의 일부로 작동하는 경우, 해당 제품은 물리적 세계 내 어딘가에서 작동합니다. 고객은 제품이 AI를 사용한다는 사실이 아니라 제품에 탑재된 일부 기능에 대해 비용을 지불하는 것이므로 제품의 기능부터 시작해야 합니다. 시스템이 수행할 수 있는 잠재적 작업은 무엇인가요? 가능한 조치의 집합을 알고 나면 다음 질문은 "시스템이 각 조치를 언제 수행해야 하는가?"입니다.

참고 AI가 더 큰 제품의 일부인 경우, 제품 자체가 완전히 자율적이거나 일부 기능은 자동으로 수행하고 다른 작업은 인간에게 의존하는 하이브리드 제품이 될 수 있습니다.

완전 자율 제품 내 AI

완전 자율 시스템의 예로는 Roomba[51]와 같은 진공 청소 로봇을 들 수 있습니다. 이 경우 진공 청소기는 방 전체를 청소해야 합니다. 관련 도메인 작업은 "어디로 가야 하고, 어떤 영역을 피해야 하는가?"입니다.

AI를 사용하여 해당 환경에서 디바이스에 내비게이션 기능을 제공할 수 있습니다. 이러한 AI는 정교한 내비게이션 시스템부터 비교적 간단한 조작까지 다양할 수

(계속)

있다는 점에 유의하세요. 로봇 청소기는 AI를 사용하여 방의 레이아웃을 학습하고 레이아웃의 변화를 인식할 수 있습니다. 또한 방에 대한 정교한 매핑을 더 큰 배터리와 교환하여 시간이 많이 걸리는 시행착오 방식을 사용하여 장애물을 피할 수 있습니다.

더 큰 배터리는 AI 알고리즘의 선택보다 전체 시스템이 더 중요하다는 것을 보여주는 또 다른 예입니다. 몇 년 전만 해도 AI 내비게이션을 크게 개선하는 데 많은 시간과 비용을 투자하는 것보다 더 큰 배터리를 추가하여 실행 시간을 늘리는 것이 더 간단하고 저렴했습니다.

완전 자율 제품의 경우, 제품이 취할 수 있는 조치뿐만 아니라 일부 조치와 결과는 바람직하지도 허용되지도 않는다는 점도 고려해야 합니다. Roomba와 같은 값비싼 로봇 청소기가 계단에서 추락하는 것을 보고 싶지는 않을 것입니다.

제품의 기능은 어떻게 발전할까요?

더 큰 제품의 일부로 AI를 사용할 때는 초기 제품에 추가할 기능뿐만 아니라 나중에 추가할 제품 기능의 전체 로드맵을 고려하는 것이 중요합니다.

제품은 고객에게 배송되는 물리적 시스템인 경우가 많습니다. 예를 들어, AI 기반 자율주행 차량[38]의 경우 차량 자체를 배송합니다. 차량이 배송되면 소프트웨어 업데이트로 추가 기능이 추가될 수 있습니다. 하지만 차량과 함께 제공되는 센서와 이펙터(엔진, 브레이크, 조향 장치, 경적, 신호등, 헤드라이트 등)에 갇혀 있습니다. 물리적 시스템을 고객/사용자에게 배포한 후에는 설계 당시에는 상상하지 못했던 새로운 작업을 수행할 수 있는 용량을 추가하는 것이 불가능하거나 비용이 많이 드는 경우가 많습니다. 미래에 어떤 자율주행차가 등장하든, 일부 기능은 자동차 제조 시점에 고정되어 나중에 변경하기 어려울 것입니다.

2.5.3 AI를 사용하여 비즈니스 프로세스의 일부 자동화

업계와 대중 언론 모두에서 점점 더 많은 관심을 받고 있는 AI의 용도 중 하나는 이전에 사람이 필요했던 작업을 수행하는 데 AI를 사용하는 것입니다. 이 섹션에서는 기존 비즈니스 프로세스를 최적화하기 위해 AI를 적용하는 방법을 보여줍니다.

워크플로의 일부를 자동화하는 AI

어떤 시설에 CCTV 카메라와 보안 요원을 배치하여 모니터링하고 있다고 가정해 봅시다. 경비원들이 화면을 보는 것이 업무의 일부라고 가정해 봅시다. AI는 비디오 스트림을 모니터링하고 비정상적인 상황을 강조 표시하여 보안 요원의 워크플로에서 이 부분을 보다 효율적으로 만드는 데 사용될 수 있습니다.

AI를 사용하여 비즈니스 프로세스의 일부를 자동화하려는 경우, 먼저 해당 프로세스를 스케치한 다음 "AI를 사용하여 이 단계 중 더 효율적으로 만들거나 제거할 수 있는 단계가 있는가?"라고 질문합니다. 이는 AI를 사용하여 일대일 업무 대체를 수행하는 것으로, 사람이 수행하던 작업을 이제 AI가 수행합니다.

인간과 AI의 역량이 다르기 때문에 사람이 하던 작업을 AI로 일대일로 대체하는 것은 복잡하고 비용이 많이 듭니다. 대부분의 워크플로에서 몇 가지 작업은 필수적이며, 작업에서 가장 많은 시간이 소요되는 기능은 자동화할 수 있어도 자동화하기 어렵습니다!

실제로는 기존 프로세스의 단계에 AI를 적용하는 것뿐만 아니라 비즈니스 프로세스를 재설계해야 하는 경우가 많습니다. 리엔지니어링은 현재 기술로 자동화하기 쉬운 작업을 워크플로우의 별도 단계로 분리해야 합니다. 그런 다음 AI에게는 쉽지만 사람에게서는 시간이 많이 걸리거나 오류가 많이 발생하는 프로세스 부분에만 AI를 할당합니다.

AI로 새로운 일자리 창출

자동화를 위한 AI의 사용은 논란의 여지가 있는 주제입니다. AI가 특정 작업을 수행할 때 인간을 대체하고 그 작업이 해당 작업의 주요 목적이라면, 그 직업은 이제 위험에 처할 수 있습니다.

일 자리를 없앨 때 고려해야 할 상당한 비용이 있습니다. 가장 중요한 것은 일자리가 사라지는 사람들이 치러야 할 비용입니다. 금전적인 비용뿐만 아니라 대중과 남은 직원들의 선의에 대한 비용도 있습니다. 프로세스 자동화에 대해 이야기할 때 인간의 관점을 염두에 두어야 하며, 이 시나리오는 종종 제로섬 게임이라는 점을 이해하는 것이 중요합니다.

인공지능에 대해 생각할 때 일 자리를 인공지능으로 대체하는 시나리오로만 한정한다면 실제로는 기회를 놓치고 있는 것입니다. AI는 이전에는 불가능하거나 경제성이 없던 새로운 비즈니스를 창출할 수 있게 해줍니다. 이 시나리오는 AI 시스템을 구축하고 지원하는 일자리뿐만 아니라 그러한 비즈니스에 수반되는 다른 모든 일자리까지 새로운 일 자리를 창출합니다.

예를 들어, 주인이 외근 중일 때 AI를 사용하여 반려동물의 행동을 모니터링하는 것을 생각해 보세요. 현재로서는 아무도 이 작업을 수행하지 않고 있습니다. 왜냐하면 이러한 모니터링은 사람이 수행해야 하는 경우 서비스로서 경제적으로 실행 가능하지 않기 때문입니다. 반려동물의 행동을 모니터링하고 반려동물을 즐겁게 해줄 수 있는 AI를 사용하려면 AI가 처리할 수 없는 드문 상황(예: 반려동물에게 의학적 문제가 있는 것으로 보이는 상황)을 처리할 수 있는 사람이 필요합니다. 이러한 AI는 반려동물을 모니터링하는 사람들에게 일 자리를 창출합니다. 이러한 일 자리는 100% 사람이 직접 처리해야 할 때는 경제적으로 전혀 실현 가능하지 않았습니다. 대부분의 모니터링은 AI가 처리하고 예외적인 작업은 사람이 처리하면 이러한 일 자리가 실현 가능해집니다.

2.5.4 제품으로서의 AI

다양한 비즈니스 상황과 다양한 고객에게 적용 가능하다고 생각되는 AI 솔루션 또는 AI를 지원하는 인프라 솔루션을 보유하고 있는 경우가 있습니다. 이러한 경우, 이러한 AI 솔루션은 그 자체로 가치가 있으며 독립형 제품으로 패키징되어 판매될 수

있습니다. 이 섹션에서는 AI 솔루션을 완전한 제품으로 판매하고자 할 때 적용되는 몇 가지 특별한 고려 사항에 대해 설명합니다.

개발할 수 있는 AI 기능에 대해 기꺼이 비용을 지불할 의향이 있는 고객이 있을 때 완전한 제품이 됩니다. 다양한 분석 제품(예: SAS [56] 또는 IBM의 SPSS [57])을 제공하는 기업은 오랜 역사를 가지고 있으며, AI 기반 제품은 복잡한 분석 기능을 고객이 사용할 수 있는 형식으로 패키징하는 이러한 전통의 연장선상에 있다고 볼 수 있습니다.

팁 제품을 판매하고 있습니다. 핵심 질문은 이 제품을 구매할 의향이 있는 고객을 찾을 수 있는지 여부입니다. 판매 주기와 관련하여 제품 자체가 AI를 기반으로 한다는 사실은 다른 모든 판매 고려사항에 부차적인 것입니다.

하지만 AI를 기반으로 제품을 만들 때는 반드시 고려해야 할 사항이 있습니다. AI에 대한 지식과 관련하여 조직과 팀의 역량을 정확하게 평가해야 합니다. 전례 없는 AI 솔루션을 개발하는 것과 알려진 AI 기능을 새롭고 구체적인 맥락에 적용하는 것에는 큰 차이가 있습니다.

새로운 AI 솔루션과 기능을 개발하는 것은 해당 분야에 대한 상당한 사전 전문 지식이 필요한 다른 차원의 게임입니다. AI를 제품으로 판매할 때는 제품의 초기 버전을 제공할 수 있는 능력뿐만 아니라 경쟁 제품을 능가하는 혁신 능력도 평가해야 합니다.

경고 AI 연구 전문가로 구성된 팀이 없다면 기존 AI 기능을 새로운 맥락에 적용하는 데 집중하세요. 아직 아무도 입증하지 않은 새로운 AI 기능을 개발해야 하는 AI 제품은 예측이 어렵고 개발하기 어렵고 위험하므로 피하세요.

반면에 일반적인 AI 기능을 이해하고 있다면 새로운 분야의 제품에 해당 기능을 적용하는 데 따르는 위험이 훨씬 적습니다. 예를 들어, AI는 이미지의 맥락을 인식하는데 매우 능숙해지고 있는 것으로 알려져 있는데, 이는 일반적인 능력입니다. 이러한 기능을 특정 분야에 적용할 수 있다면 실용적인 제품을 만들 수 있을 것입니다. 한 가지 예로 공장 라인의 결함을 인식할 수 있는 소프트웨어를 들 수 있습니다. 누구에게 판매할 것인지 알고 있다면 이는 매우 귀중한 제품이 될 수 있습니다.

AI 제품이 광범위하게 적용 가능한가요?

어떤 AI 제품은 (분명히) 광범위하게 적용할 수 있는 일반적인 프레임워크이지만, 어떤 제품은 한 가지 문제 범주에 한정되어 있습니다.

귀사의 AI가 한 범주의 문제를 해결하는 경우, AI 솔루션을 사용하여 새로운 비즈니스 활동을 실현할 수 있는 여러 사례를 찾을 수 있다면 하나의 제품으로 독립할 수 있습니다. 대신 새로운 비즈니스 액션을 만들어내는 AI의 사례를 단 하나만 찾을 수 있다면, 더 큰 제품의 일부가 되는 AI의 사례로 생각하는 것이 좋습니다.

인공지능이 어떤 새로운 비즈니스 액션을 실현할 수 있는지 알아내려고 할 때 2.5.1, 2.5.2, 2.5.3 섹션의 기술을 적용하게 될 것입니다. 단, 자신의 비즈니스에 적용하는 것이 아니라 잠재 고객의 비즈니스에 적용하게 됩니다.

2.6 AI 기능 개요

2.5장에서는 적절한 AI 기능과 결합할 수 있는 비즈니스 질문을 찾는 방법을 설명했습니다. 이 섹션에서는 "내 비즈니스 문제를 해결할 수 있는 광범위한 AI 기능 영역이 있는가?"라는 질문에 답하는 데 도움이 되는 AI 기능의 분류 체계를 제시합니다. 그림 2.6은 이러한 AI 방법의 분류법을 제시합니다.

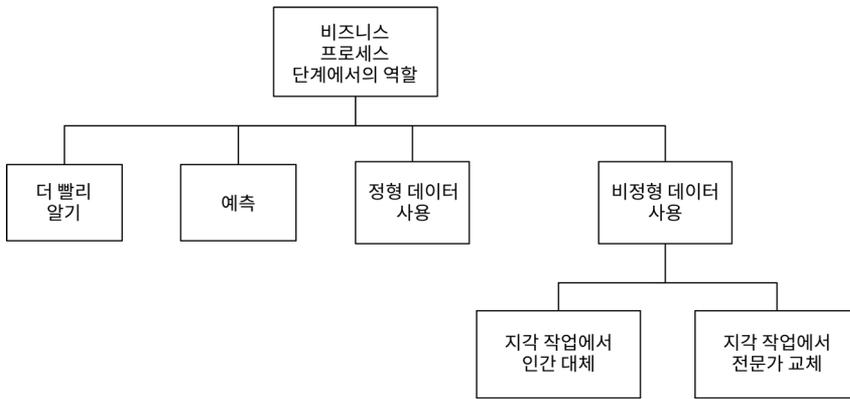


그림 2.6 AI 기능에 따른 분류법. 이 프레임워크는 광범위한 AI 기능 영역을 그룹화하여 해결하려는 비즈니스 문제에 적용 가능한지 빠르게 확인할 수 있습니다.

이 분류법은 원래 Bill Schmarzo의 저서[58,59]에서 제시된 분류법을 수정한 것으로, 지각 작업에서 AI의 사용을 강조하기 위해 "비정형 데이터 사용" 범주를 확장했습니다. 이 분류법의 주요 목표는 AI 전문가와 비즈니스 전문가 간의 토론을 안내하는 것입니다. 이 분류법의 카테고리는 다음과 같습니다.

- **더 빠르게 결과를 파악하세요.** 여기서 AI는 결과를 더 빨리 발견하도록 도와주며, 이는 많은 시나리오에서 비즈니스 가치가 있습니다[58,59]. 자동차 제조 공장을 운영하면서 공장의 한 구역에서 생산된 부품으로 자동차를 조립하고 있다고 가정해 봅시다. 어떤 자동차 부품이 만들어지자마자 결함이 있다는 것을 알게 된다면, 그 부품을 즉시 폐기하고 자동차에 장착하지 않을 수 있습니다. 이미 부품을 자동차에 장착하여 고객에게 배송한 후에 부품에 결함이 있다는 사실을 알게 되는 것보다 훨씬 낫습니다.
- **현재의 추세를 바탕으로 미래에 발생할 어떤 사건을 예측합니다.** 이 기법은 2.5.1절에서 과거 추세를 기반으로 공급업체의 미래 품질을 예측할 때 사용되었습니다.

- **구조화된 데이터를 사용합니다.** 특히 대량의 데이터가 있는 경우, 이미 보유하고 있는 관계형 데이터베이스 중 하나에서 원하는 답을 찾을 수 있는 경우가 있습니다[58,59]. 이미 표 형식의 데이터에 잘 작동하는 AI 방법도 있습니다.²
- **구조화되지 않은 데이터를 사용합니다.** AI 방법은 텍스트, 이미지, 비디오 및 오디오와 같은 대량의 비정형 데이터를 처리하고 이해하는 데에도 도움이 될 수 있습니다[58,59]. 이 경우 AI 메서드를 사용하여 이미지, 비디오 또는 오디오 녹음의 컨텍스트를 인식할 수 있습니다.
- **지각 작업에서 사람을 대체합니다.** 이 비정형 데이터 사용의 하위 범주는 최근 몇 년 동안 AI가 이미지 인식과 같은 많은 간단한 인식 작업에서 인간의 능력과 일치하거나 심지어 능가했다는 사실에 근거합니다[62,63]. 이 범주의 AI는 인간이 쉽고 본능적으로 수행하는 간단한 지각 작업을 수행할 수 있는 능력을 갖춘 것으로 생각할 수 있습니다. 이러한 작업의 예로 사진 이미지에서 물체를 인식하는 것을 들 수 있습니다.
- **지각 작업에서 전문가를 대체합니다.** 이 하위 범주의 AI 능력은 구조화되지 않은 데이터도 이해하지만, 여기서는 높은 수준의 인간 전문가가 필요한 지각 작업을 AI가 수행합니다. 이러한 전문가는 수년간의 훈련을 통해 본능이 된 기술을 사용합니다. 예를 들어 AI를 사용하여 의료 영상을 해석하는 것입니다. 최근 몇 년 동안 AI는 경우에 따라 인간 전문가에 필적하는 수준의 의료 이미지 해석 능력을 보여주었습니다[64,65].

이제 2.5절에 제시된 비즈니스 문제에 적용할 수 있는 AI 솔루션을 어떻게 찾았는지 살펴보았습니다. 모든 예제에서는 실행 가능한 비즈니스 문제를 찾은 다음 취할 수 있는 도메인 조치를 찾는 것부터 시작합니다. "이 비즈니스 문제에 그림 2.6에 표시된 6가지 범주의 AI 기능 중 하나를 적용할 수 있을까요?"라는 질문을 던집니다.

모든 개별 AI 방법을 열거할 수 있습니까?

이 책을 포함하여 한 권의 책에 AI의 모든 기능을 설명할 수 있는 방법은 없습니다. AI는 빠르게 발전하는 분야이며, 새로운 방법과 애플리케이션의 개발로 AI 기능은 매일 변화하고 있습니다. 개별 AI 방법의 세부 사항에 관심이 있다면 숙련된 데이터 과학자나 컨설턴트가 AI의 최신 기능에 대한 세부 사항을 안내해줄 필요가 있습니다.

이 섹션에 제시된 분류법은 AI 전문 지식을 대신할 수는 없지만, 비즈니스 전문가와 AI 전문가 간의 논의를 체계적으로 구성하기 위한 방법입니다.

² 그런 방법의 예로는 *그래디언트 부스팅 (gradient boosting)*이 있습니다. 이 방법의 기술적 세부 사항에 관심이 있으시면 위키피디아[60]와 캐글 (Kaggle) 웹사이트[61]의 토론을 참조하세요.

비즈니스 사용자가 이해하기 쉬운 방식으로 일반적인 용어와 개념을 제공합니다. AI 전문가라면 이 장에 제시된 분류법을 비즈니스 질문에 적용 가능한지 확인해야 하는 메서드 및 알고리즘 클래스에 대한 간단한 체크리스트로 사용할 수 있습니다.

2.7 유니콘 소개

이 장에서는 어떤 비즈니스 문제가 AI 기술의 혜택을 받을 수 있는지 판단하는 방법을 살펴봤는데, 귀사의 특정 개발팀이 방금 제안한 솔루션을 구현하는 데 필요한 지식을 갖추고 있나요? 이 섹션은 이 질문에 답하는 데 도움이 됩니다.

인공지능 프로젝트에 사용하는 기술은 아직 새롭고 드물며, 데이터 과학자와 데이터 엔지니어가 갖춰야 할 기술 집합에 대해 업계에서 여전히 어느 정도 혼란이 있습니다. 이러한 기술의 희소성 때문에 이러한 전문가는 *유니콘*이라는 농담도 있습니다. 이 섹션에서는 흔히 유니콘에게 *귀속되는* 기술에 대해 설명하는 것으로 시작하겠습니다. 그런 다음 왜 대부분의 현실 세계 팀들이 이 모든 기술을 보유하지 못하는지 설명하겠습니다. 마지막으로, 여러분이 진행 중인 특정 AI 프로젝트에 필요한 모든 기술을 팀에 보유하도록 하는 방법을 보여드리겠습니다.

2.7.1 데이터 사이언스 유니콘

데이터 과학은 많은 기술을 포괄하는 포괄적인 용어로 간주될 수 있습니다. 2013년에 실시된 설문조사에 따르면 데이터 과학의 일부인 22개의 다른 영역이 나열되어 있습니다[66]. 이러한 영역의 예로는 통계, 운영 연구, 베이지안 통계, 프로그래밍 등의 주제가 포함됩니다. 더 발전합니다! 오늘날에는 확실히 중요하다고 여겨지는 새로운 영역(예: 딥 러닝)이 등장했습니다.

참고 분명히 데이터 과학 유니콘은 이러한 각 분야에서 세계적 수준의 전문가여야 합니다. 아니요, 이 분야들은 개별적으로 매우 복잡한 분야입니다. 우수 대학의 많은 저명한 교수들은 그 중 한 분야의 전문가가 되기 위해 자신의 모든 시간과 노력을 투자합니다. 아마도 전 세계에서 모든 분야에서 전문성(앞서 언급한 교수들의 실력과 비슷한 수준으로 정의됨)을 갖춘 사람은 없을 것입니다. 그런 유니콘이 존재한다고 해도, 어떤 AI 프로젝트가 유니콘을 위한 예산을 확보할 수 있을까요?

데이터 과학에는 왜 이렇게 다양한 스킬셋이 포함될까요? 실제 문제마다 각기 다른 기술이 도움이 되기 때문입니다. 가능한 모든 데이터 세트에서 다른 모든 방법을 능가하는 단일 ML 방법은 없습니다.³ 이러한 각 방법은 AI 커뮤니티가 실제적이고 실용적인 문제를 해결했을 때 일부 방법이 다른 방법보다 더 잘 작동했기 때문에 등장했습니다. 수년이 지난 후, 우리는 다양한 분야의 여러 방법을 조합하여 사용합니다.

³ 이것은 공짜 점심 정리는 없다[67]라고도 합니다.

유니콘을 키우는 방법

선도적인 데이터 과학자들은 오늘날 알고 있는 모든 방법을 배우는 것에서 시작했을까요? 뛰어난 데이터 과학자가 되려면 먼저 유명한 데이터 과학자의 스킬셋을 모방하는 스킬셋을 구축해야 할까요? 아니요. 뛰어난 데이터 과학자 두 사람의 기술은 일치하지 않는 경우가 많습니다. 뛰어난 데이터 과학자라도 한 사람은 다른 한 사람이 익숙하지 않은 한 가지 이상의 영역에 전문성을 가지고 있다는 것은 사실상 보장됩니다.

유능한 데이터 과학자의 스킬셋은 특정 유형의 AI 방법의 이점을 활용하는 문제를 해결하면서 습득하는 경우가 많습니다. 특정 인공지능 방법을 배워야만 했습니다. 그것들은 그들이 일하는 영역에서 구체적인 문제를 해결하는 데 필요했기 때문입니다. 새로운 프로젝트를 수행할 때마다 새로운 기술을 습득해야 했고, 때로는 이전에는 핵심 전문 영역에 포함되지 않았던 새로운 영역에서 새로운 기술을 습득해야 했습니다. 예를 들어, 2011년에는 전 세계적으로 기업이나 학계에서 오늘날 딥 러닝으로 알려진 분야를 연구하는 사람이 거의 없었습니다.

유니콘이 되고 싶다면 해결할 가치가 있는 문제를 해결하세요. 그 과정에서 강력한 기술을 습득할 수 있습니다.

관리자는 팀에 데이터 과학자를 채용할 때 두 가지를 고려해야 합니다. 초기 AI 프로젝트에서 사용할 가능성이 높은 핵심 영역에 대한 기술을 갖춘 지원자를 찾아야 하지만, 새로운 기술을 배울 수 있는 능력이 입증된 지원자도 필요합니다. 그 과정에서 데이터 과학자는 많은 새로운 방법을 배워야 할 가능성이 높습니다. 선임 데이터 과학 팀원을 채용할 때, 한 가지 AI 방법론에 대한 강력한 배경 지식을 갖춘 사람만 찾지 마세요. 선임 데이터 과학자는 다양한 방법을 사용하여 구체적인 문제를 해결한 이력이 있어야 합니다.

팁 데이터 과학은 팀 스포츠입니다. 데이터 과학의 모든 지식을 완벽하게 다루려면 팀 전체가 필요하므로 상호 보완적인 기술을 가진 팀을 구성해야 합니다.

초기 데이터 과학 팀을 어떻게 구성해야 할까요? 팀은 비즈니스 문제를 이해할 수 있는 충분한 비즈니스 전문 지식과 초기 분석을 수행하고 AI로 문제를 해결할 수 있는지 판단할 수 있는 AI 방법에 대한 충분한 숙련도가 모두 필요합니다. 완전한 AI 솔루션을 제공하는 과정에서 팀은 몇 가지 새로운 기술을 배워야 한다는 점을 명심하세요.

2.7.2 데이터 엔지니어는 어떨까요?

AI에 대해 논의할 때, 우리는 종종 단일 머신에 맞지 않을 정도로 큰 데이터 집합을 관리하기 위해 빅 데이터 프레임워크가 필요한 경우에 대해 이야기합니다. 데이터 과학자는 빅 데이터 프레임워크 사용에 능숙하지만, 프레임워크의 세부 사항에 대한 전문가인 경우는 드뭅니다. 따라서 빅 데이터 프레임워크 자체의 사용에 중점을 둔 전문가가 필요합니다. 우리는 이들을 *데이터 엔지니어*라고 부릅니다.

빅데이터는 데이터 과학과 마찬가지로 넓은 영역입니다. 빅 데이터 분야에서 가장 인기 있는 제품인 Apache Hadoop 프레임워크[15]를 예로 들어 보겠습니다. 몇 년

전만 해도 주요 Hadoop 공급업체 중 한 곳의 배포판은 23개의 개별 구성 요소로 구성되어 있었는데, 각 구성 요소는 별도의 책 한 권을 쓸 수 있을 만큼 방대했습니다 [68].

데이터 엔지니어링의 범주에 속하는 지식은 단일 빅 데이터 프레임워크보다 훨씬 더 큼니다. 데이터 엔지니어는 온프레미스 환경과 클라우드 환경 모두에서 작업할 수 있어야 하는 경우가 많습니다. Amazon AWS[11], Microsoft Azure[13], Google Cloud Platform[12]과 같은 클라우드 서비스에는 서로 다른 플랫폼이 있으며, 플랫폼 간에 상당한 차이가 있습니다. 즉, 고용하는 데이터 엔지니어는 빅데이터 프레임워크에 대한 전문 기술 외에도 선택한 클라우드 플랫폼에 대한 기술도 갖춰야 할 수 있습니다.

데이터 과학자에게 적용되는 것과 동일한 한계가 데이터 엔지니어에게도 적용됩니다. 데이터 엔지니어도 인간이며 모든 것을 알 수는 없습니다. 데이터 엔지니어는 주요 빅 데이터 프레임워크의 몇 가지 구성 요소에 대한 전문가라는 특징이 있습니다.

2.7.3 그렇다면 유니콘은 어디에 있을까요?

이런 말씀 드리기 싫지만, 데이터 과학과 데이터 엔지니어링의 일부인 방법, 제품, 기술 각각에 대해 강력한 전문성을 가진 사람을 한 명도 찾이란 거의 불가능합니다. 기껏해야 개별 데이터 과학 및 데이터 엔지니어링 주제에 대한 경험이 풍부하고, 자신이 전문가가 아닌 분야의 전문가와 이야기할 수 있을 정도로 다른 관련 주제에 대해 잘 알고 있는 선배 몇 명을 찾을 수 있을 것입니다.

최근 몇 년 동안 대학에서 데이터 과학 및 데이터 엔지니어링 주제에 대한 프로그램과 학위를 제공하기 시작했지만, 더 나은 교육을 통해 이 문제를 해결할 수 있을 것 같지는 않습니다. 지식의 영역이 너무 넓기 때문에 이러한 교육 기관이 학생들에게 무엇을 가르칠 수 있는지에 대한 현실적인 기대치를 가져야 합니다.

경고 프로젝트 리더는 팀이 보유한 스킬셋과 프로젝트에 필요한 스킬셋을 구분해야 합니다. 기술 격차를 파악하고 해소해야 합니다. 선임 데이터 과학자와 설계자가 해당 분야의 모든 것을 알고 있다고 가정하지 말고, 그들에게 모든 것을 알고 있어야 한다는 기대를 강요하지 마세요. 그러한 기대는 사람들이 기술 격차를 인정할 가능성을 낮출 뿐입니다.

프로젝트 리더는 팀 내에서 지식의 격차가 어디에 있는지 알아야 합니다. 팀에 아직 갖추지 못한 기술이 필요한 AI 프로젝트를 시범 운영하려면 이러한 지식 격차를 줄여야 합니다. 갭 분석을 적용함으로써 *이를 수행합니다*[69]. 팀이 현재 보유하고 있는 스킬셋과 필요한 스킬셋 간의 격차 분석의 예는 그림 2.7.11에 나와 있습니다.

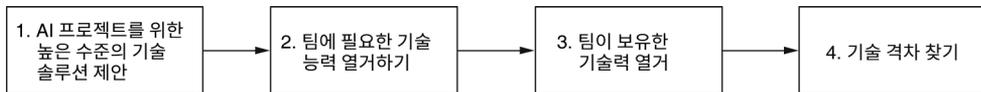


그림 2.7 팀이 보유한 스킬과 필요한 스킬 간의 격차 분석. 이 분석을 통해 부족한 기술을 어떻게 해결할 것인지에 대한 계획을 세울 수 있습니다.

다음 단계를 적용하여 격차 분석을 수행합니다.

- 1 먼저 기술 팀과 협력하여 높은 수준의 기술 솔루션을 스케치하고, 이 기술 솔루션에 소요되는 시간을 구현 가능성과 일치시킵니다. 프로젝트를 고려하는 단계라면 솔루션은 높은 수준의 것이어야 합니다. 곧 프로젝트를 시작할 계획이라면 초기 기술 솔루션에 상당한 세부 사항이 필요합니다.
- 2 솔루션을 기반으로, 프로젝트가 식별된 사용 사례를 해결하는 데 필요할 것으로 예상되는 기술적 기술의 목록을 작성합니다. 이 기술 요약은 해결하려는 비즈니스 문제를 잘 알고 있고 문제 해결을 위한 높은 수준의 기술적 접근 방식을 신속하게 식별할 수 있는 충분한 기술 전문 지식을 갖춘 사람이 작성해야 합니다.
- 3 팀원들은 이미 어떤 기술을 보유하고 있나요? 팀원들의 스킬셋에 대해 물어보고 이 분야에서는 가정을 피하세요. AI와 데이터 엔지니어링은 고도의 기술 분야이므로 근거 없는 가정을 하기 쉽습니다.
- 4 필요한 스킬셋과 현재 스킬셋 사이에 차이가 있는지 확인합니다. 이러한 격차는 팀의 프로젝트 난이도를 추정하는 데 유용합니다. 이 목록을 보관하세요. 이 비즈니스 질문을 다루는 프로젝트를 진행하기로 결정했다면, 그 격차를 어떻게 좁힐지 계획을 세워야 합니다. (팀원 교육, 새로운 팀원 채용 또는 컨설턴트 고용을 통해 지식 격차를 해소합니다.)

격차 분석은 항상 현재 상황을 기반으로 수행된다는 것을 이해합니다. AI 프로젝트를 가능성으로만 생각하고 있다면 기술 솔루션의 개요만 가지고 대략적인 수준에서 격차 분석을 수행해야 합니다. 진행 중인 프로젝트의 경우 시작점으로 훨씬 더 자세한 솔루션이 필요합니다. 즉, 프로젝트 수명 주기 동안 일반적으로 갭 분석을 여러 번 수행하게 됩니다.

질문하는 방법에 유의

기술 능력의 격차에 대해 질문하는 것은 기술 담당자에게 개인적으로 전문 지식이 없는 영역을 인정하도록 요구하는 것입니다. 잘못 처리하면 지뢰로 간주될 수 있습니다. 팀원들이 기술적 능력이 부족하다는 것을 쉽게 인정할 수 있는 분위기를 조성하는 것이 리더의 역할입니다.

이러한 분위기를 조성하기 위해 선호하는 기법 중 하나는 팀원들이 이런 문제에 대해 이야기할 수 있도록 팀원들 간에 신뢰를 구축하는 것입니다. 다른 유용한 기법으로는 비공개로 기술을 요청하거나, 익명으로 설문조사를 작성하거나, 신뢰할 수 있는 중개자에게 팀원들과 함께 해당 주제에 접근하도록 요청하는 것 등이 있습니다.

2.8 연습

이 책의 목표는 프로젝트를 실행할 때 사용할 수 있는 실용적인 기술을 개발하는 데 도움을 주는 것입니다. 이를 돕기 위해 이 섹션의 연습 문제에서는 이 장에서 배운 기술을 새로운 비즈니스 시나리오에 적용해 보도록 합니다.

2.8.1 단답형 문제

다음 질문에 대한 간단한 답변을 입력하세요.

질문 1: 기업에서 실패한 프로젝트에 대해 생각해 보세요. 그 프로젝트에 AI 기반 구성 요소도 있었다면 똑같은 방식으로 실패했을까요?

질문 2: 개인적으로 데이터 과학 및 데이터 엔지니어링에 대한 지식이 충분하여 팀이 보유한 기술 역량과 이 프로젝트에 필요한 기술 간의 격차를 이해할 수 있나요?

질문 3: 팀원들이 자신의 기술력의 한계를 편안하게 인정할 수 있을 만큼 팀원들과 좋은 관계를 유지하고 있나요?

2.8.2 시나리오 기반 질문

설명된 시나리오에 따라 다음 문제에 답하세요.

질문 1: 감지/분석/반응 루프를 적용하는 데 있어 중요한 기술 중 하나는 패턴의 반응 부분을 누가 실행할 것인지 파악하는 것입니다. 다음 시나리오의 경우 이 질문에 답하세요: 누가 또는 무엇이 작업을 수행하고 감지/분석/반응 루프의 반응 부분을 수행하나요?

- **시나리오 1:** 자동화된 자동차를 만들고 있으며, 여러분이 사용하는 AI는 모든 조건에서 완전 자율 주행(소위 레벨 5 자율성[38]으로, 운전자가 제어할 수 있는 것이 없는 상태)을 가능하게 할 것입니다.
- **시나리오 2:** 고객에게 상품을 제안하는 추천 엔진을 작성하고 있습니다.
- **시나리오 3:** 집의 온도를 조절하는 스마트 온도 조절기를 제어하는 AI 프로그램을 작성 중입니다.

질문 2: AI를 사용하여 새로운 직업을 만듭니다. 조직에서 아직 제공하지 않는 새로운 서비스를 제공할 수 있는 AI 기능의 예를 찾아보세요. (이 연습의 해결책으로 간주되려면, 해당 직무가 AI를 구축하는 소프트웨어 개발 팀과 전혀 관련이 없는 직무여야 하며, 해당 직무에 고용된 사람이 해당 팀과 만날 가능성이 낮아야 합니다.)

질문 3: 의료 시설(대형 병원의 방사선과를 예로 들어 보겠습니다)에서 AI 알고리즘을 사용한다고 가정해 보세요. 운 좋게도 이미지 분류 분야에서 최고의 AI 전문가가 팀에 합류하여 AI 측면을 담당하고 있습니다. 그 전문가가 의료 이미지를 정상 또는 비정상적으로 분류하는 AI 알고리즘을 개발할 수 있을 것이라고 확신하지만, 그 전문가는 이전에 의료 환경에서 일한 적이 없습니다. 의료 분야에 적용할 수 있는 작동하는 AI 제품을 개발하기 위해 해결해야 할 다른 고려 사항은 무엇인가요?

질문 4: 병원 환경의 앞선 예제를 해당 산업의 분류 문제에 적용하세요. 의료 산업과 비교하여 귀하의 산업에 존재하는 새로운 고려 사항은 무엇인가요?

질문 5: 인간의 역할을 대체했지만 인간만큼 좋은 경험을 제공하지 못하는 인공지능의 예를 제시하세요.

질문 6: 귀사가 보안 카메라 제조업체이고, 사진에서 사람을 감지할 수 있는 AI 알고리즘을 개발했다고 가정해보겠습니다. 귀사의 비즈니스에서 AI의 역할에 대한 분류와 관련하여, 이 AI 사용을 어떻게 분류하시겠습니까?

질문 7: 귀사가 보험 회사이고, 사고 현장의 정지 이미지를 기반으로 사고로 인해 손상된 자동차의 어느 부분이 손상되었는지 인식할 수 있는 AI 프로그램을 개발했다고 가정해보겠습니다. 이 프로그램이 보험 손해사정사를 대체할 수 있나요?

요약

- AI 프로젝트를 관리한다고 해서 AI 알고리즘의 세부 사항에 대한 전문 지식이 필요한 것은 아닙니다. 대신 AI 프로젝트의 이점을 비즈니스 측면에서 설명하는 방법을 알아야 합니다. 어떤 비즈니스 문제를 해결하고자 하는가? AI가 제공하는 비즈니스 혜택은 무엇인가요? 그 혜택은 어떻게 측정되나요?
- 체계적인 프로세스를 통해 취할 수 있는 비즈니스 조치와 AI의 혜택을 받을 수 있는 조치를 발견할 수 있습니다. 그림 2.5에 설명된 분류법을 조직에 적용하세요.
- AI 역량은 더 빨리 파악하고, 예측하고, 정형 및 비정형 데이터를 처리하고, 지각 작업을 수행할 수 있는 능력에 기반합니다.
- AI는 구체적인 비즈니스 행동에 대한 정보를 제공하는 분석을 수행하여 비즈니스에 도움을 줄 수 있습니다. AI는 감지/분석/반응 루프를 적용할 수 있을 때 기회가 발생하며, 분석 부분은 AI 역량을 기반으로 하고 리액트 부분은 구체적인 비즈니스 조치를 기반으로 합니다.
- 개인이 AI, 데이터 과학 및 데이터 엔지니어링의 모든 주제에 대해 전문가가 될 수는 없습니다. 프로젝트 리더는 팀이 보유한 지식과 역량에 대한 관련 격차를 파악하고 이를 해소해야 합니다.

첫 번째 AI 프로젝트 선택하기

이 장에서 다루는 내용

- 조직의 AI 역량에 맞는 AI 프로젝트 선택하기
- AI 프로젝트 우선 순위 지정 및 먼저 실행할 AI 프로젝트 선택하기
- 비즈니스 문제와 관련된 연구 질문 공식화하기
- AI 프로젝트를 선택할 때 피해야 할 함정과 그러한 프로젝트의 모범 사례

지속 가능한 분석 조직을 개발하려면 복잡한 기술적 과제를 수반하는 AI 프로젝트부터 시작해서는 안 됩니다. 대신, 명확하고 실행 가능한 결과를 신속하게 제공할 수 있는 초기 프로젝트를 선택해야 합니다. 전체 프로세스는 성공에 이르는 시간을 최적화하도록 구성해야 합니다.

이 장에서는 첫 번째 AI 프로젝트를 선택하는 방법을 설명합니다. 또한 AI 프로젝트에서 사용하는 연구 질문이 해결해야 할 비즈니스 문제를 올바르게 반영하고 있는지 확인하는 방법을 알려줍니다. 마지막으로, 젊은 AI 팀이 빠질 수 있는 일반적인 함정 목록을 제시합니다.

3.1 젊은 AI 팀에 적합한 프로젝트 선택하기

장기적인 목표는 AI 관련 프로젝트를 성공적으로 수행하여 모기업의 성공을 도울 수 있는 AI 팀을 구축하는 것이라고 가정해 보겠습니다. 이를 달성하기 위해서는 성공적인 AI 팀이 어떤 여정을 거쳐야 하는지 이해해야 합니다. 이 섹션에서는 그 여정을 설명합니다.

팁 일회성 AI 프로젝트를 진행하려는 경우 기성 솔루션을 구입하거나 외부 파트너와 계약하는 것이 더 나을 수 있습니다.

리더로서 내려야 할 가장 중요한 결정 중 하나는 팀이 수행해야 하는 초기 AI 프로젝트의 우선순위를 어떻게 정할 것인가 하는 것입니다. 이러한 결정을 내리기 전에 먼저 그 영향을 이해해야 합니다. AI 팀이 어떻게 성공하거나 실패하는지 이해하려면 먼저 성공과 실패가 어떻게 다른지 이해해야 합니다.

3.1.1 성공의 모습

레오 톨스토이는 *안나 카레니나*에 이렇게 썼습니다[70].

행복한 가정은 모두 비슷하지만 불행한 가정은 각자의 방식으로 불행합니다.

유사하게, 모든 성공적인 인공지능 팀은 비슷합니다. 인공지능 팀은 전문성(그리고 아마도 인원)이 성장하고 있으며 점점 더 복잡한 문제를 해결하고 있습니다. 실패한 AI 프로젝트는 여러 가지 오류(그 중 상당수는 3.4절에 설명되어 있음)로 인해 발생하며, 이러한 오류로 인해 전체 AI 팀이 무너질 수 있습니다. 이 섹션에서는 빠르게 제공하면서도 비즈니스에 중요한 가치를 제공하는 프로젝트부터 시작해야 하는 이유를 설명합니다.

조직에서 AI 작업을 시작하는 경우 (또는 기존 분석 조직에 속해 있더라도) 세 가지 힘에 영향을 받습니다.

- 1 **풍부한 기회**—귀하는 과거에는 비즈니스와 산업에 존재하지 않았던 기술(AI 및 빅데이터)로 운영되고 있으며, 조직이 보유한 많은 데이터 세트에 이를 최초로 적용하고 있습니다.
- 2 **제한된 시간과 리소스**—분석에 투입할 수 있는 리소스가 제한되어 있으며, 고려 중인 AI 프로젝트를 실행할 자격을 갖춘 인력이 충분하지 않을 가능성이 있습니다.
- 3 **성공은 당신을 더 강하게 만든다**—비즈니스에 돈을 벌면 시간이 지남에 따라 분석 리소스가 늘어날 것입니다. 경영진은 가치 제공 실적이 우수한 팀에 투자합니다. 추가 데이터 과학자는 성공 이력이 있는 프로젝트에 참여하기를 원할 것입니다. 쉬운 문제를 먼저 해결하면 더 큰 문제를 해결하는 데 필요한 리소스를 확보할 수 있습니다.

이런 환경에서 어떻게 성공할 수 있을까요? 얼마나 어려운지 상관없이 큰 성공(예: 상당한 금전적 가치를 제공하는 프로젝트)에 먼저 집중하는 것이 합리적일까요? 분명히 그렇지 않습니다. 오늘 어려운 일이 내일은 쉬워질 것이므로, 금전적 가치가 크고 빠르게 납품할 수 있는 프로젝트부터 시작하세요.

팁 핵심은 초기 프로젝트를 빠르게 처리하여 빠르게 배울 수 있도록 하는 것입니다. 귀사는 회사에서 처음으로 데이터와 비즈니스 문제에 AI를 적용했으며, AI로 성공할 수 있는 기회는 많습니다. 솔직히 이러한 환경에서 쉽게 성공할 수 없다면 AI는 비즈니스에 도움이 될 수 없습니다.

다른 비유를 들어보겠습니다. 기회와 관련하여 팀이 처한 위치는 풍부한 사냥터를 발견한 사냥꾼과 비슷할 것입니다. 돈을 벌 수 있는 기회가 동물이고 여러분이 선사시대 사냥꾼이라면, 사냥감이 풍부한 환경에서 활동하게 될 것입니다(그림 3.1 참조).

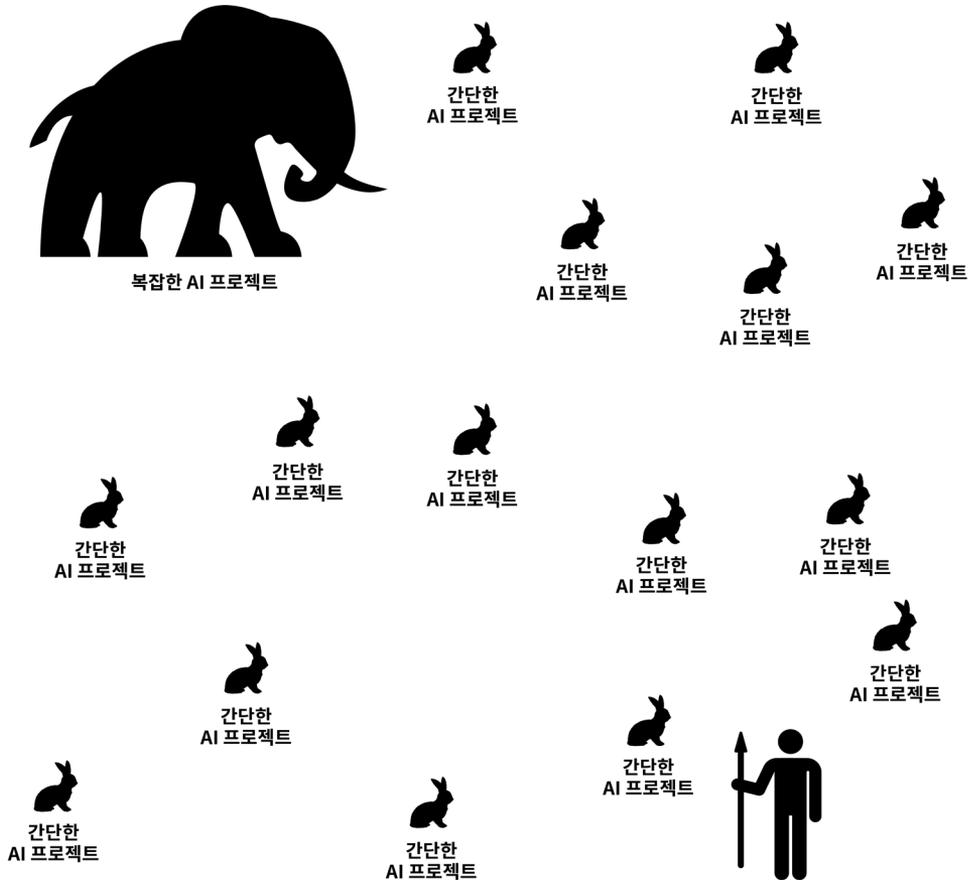


그림 3.1 귀하는 풍요로운 사냥터에 있습니다—많은 토끼와 커다란 매머드가 눈에 들어옵니다. 어떤 동물을 먼저 잡아야 할까요?

성공적인 분석 조직을 구축하는 것은 사냥꾼으로서 생존하고 번영하는 것과 비슷합니다. 이제 스스로에게 "만약 귀하가 사냥꾼이라면 먼저 가장 큰 동물을 노리겠습니까?"라고 질문해 보세요.

만약 귀하가 다음 세대에 유전자를 성공적으로 전달한 길고 뛰어난 조상의 혈통의 끝에 있다는 것 외에는 다른 이유가 없다면, 아마도 대답은 '아니오'일 것입니다. 그들은 생존을 위한 상식과 기술을 가지고 있었습니다. 매머드를 먼저 쫓는다고 해서 성공할 수 있는 사냥 기술이 처음부터 있는 것은 아닙니다! 만약 귀하가 저와 같이 평범한 사람이라면 매머드가 돌아섰을 때쯤에는 매머드를 포기하고 멀리 도망쳐 평생 채식주의자로 살았을 가능성이 높습니다. 하지만 토끼와 같이 작은 대상이라면 저와 같이 평범한 사람도 토끼를 올가미로 잡는 데 성공할 수 있다고 믿습니다. 모든 성공적인 사냥꾼은 토끼를 잡을 수 있어야 합니다(그림 3.2 참조).

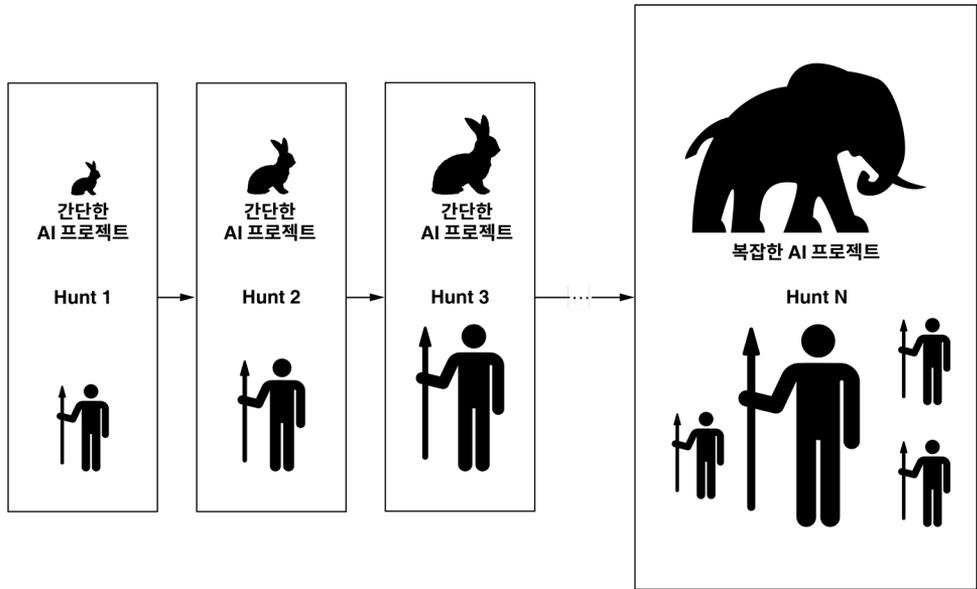


그림 3.2 쉬운 프로젝트부터 시작하세요. 이러한 프로젝트에서 성공하면 회사 내에서 기술과 평판이 향상되어 나중에 더 어려운 사냥에 도전할 수 있습니다.

사업적 가치가 높다고 인식되더라도 기술적으로 어렵고 오랜 시간이 걸리는 프로젝트부터 시작하고 싶지는 않을 것입니다. 팀이 사냥꾼이라고 가정하면 앞에서 살려온 토끼가 더 쉬운 프로젝트에 해당합니다.

팁 귀하가 좋은 사냥꾼으로 알려지면, 다른 부족원들도 매머드 사냥을 기꺼이 도와줄 것입니다. 인공지능 팀이 학습하고 경영진에게 좋은 평판을 얻으면, 더 많은 자원을 얻을 수 있습니다.^[1] 바로 이때가 어려운 인공지능 프로젝트에 도전할 때입니다.

간단하게 시작하여 차근차근 구축하세요: 예시

중장비를 제작하는 어떤 대형 엔지니어링 회사가 AI 활용에 관심이 있었습니다. 초기 프로젝트는 비교적 간단했고, 사용된 AI 기술은 거의 모든 머신러닝(ML) 입문 교재에서 볼 수 있는 것들이었습니다. 분석은 장비에서 발생하는 문제를 기본적으로 클러스터링하고 기본적인 추세를 예측하는 것으로 구성되었습니다. 그러나 장비 고장에 대한 데이터의 양이 방대했기 때문에 이러한 유형의 분석은 이 회사에서 제조하는 전체 장비 라인에 대해 수동으로 수행할 수 있는 것이 아니었습니다. 비즈니스 사례의 세부 사항은 해당 작업에만 국한된 것이었지만, 수익화 사례는 간단하고 직관적이었습니다. 고위 경영진은 해당 프로젝트를 시작하는 것이 좋은 생각이라는 데 동의하고 AI의 조언에 따라 비즈니스 조치를 취하는 데 동의했습니다. 분석에 따라 취해야 할 비즈니스 조치는 향후 장비 유지보수를 위한 리소스 할당을 변경하는 것이었습니다.

소규모 팀이 프로젝트의 기술적 측면을 빠르게 완료했습니다. 관리자가 결과를 즉시 적용하도록 설득하는 것은 간단했습니다. 강력한 비즈니스 사례 덕분에 AI 팀 리더는 대규모 조직에서 흔히 겪는 많은 조직적 제약과 관료적 장애물을 헤쳐나갈 수 있었습니다. (그리고 AI 팀은 다음번에는 이러한 장애물을 피하는 방법을 배웠습니다.)

이 솔루션은 AI 팀에 높은 가시성을 제공하고 경영진과 훌륭한 관계를 구축했습니다. 이제 AI 팀은 필요한 모든 리소스에 액세스할 수 있게 되어 새로운 인력을 채용하고 더 어려운 프로젝트를 수행할 수 있게 되었습니다. 그럼에도 불구하고 다음에 선정된 프로젝트는 기술적으로 비교적 간단하면서도 비즈니스에 큰 영향을 미치는 프로젝트였습니다. 이러한 선순환을 통해 AI 팀은 더 높은 평가를 받고 더 많은 리소스에 액세스할 수 있게 됩니다. 상상할 수 있듯이, 오늘날 이 팀은 훨씬 더 큰 규모로 성장하여 업계에서 가장 복잡한 AI 프로젝트를 진행하고 있습니다.

3.1.2 실패의 모습

대규모 실패를 방지하려면 무엇을 피해야 할까요? 네, 개별 소규모 AI 프로젝트가 실패할 수 있는 방법은 여러 가지가 있지만, 전체 AI 팀이 실패하는 일반적인 방법은 단 한 가지뿐입니다. 팀 전체의 실패는 AI 팀이 하나의 AI 프로젝트에 모든 것을 걸고 그 프로젝트가 실패할 때 발생합니다.

이전의 사냥꾼에 대한 비유를 확장해 보겠습니다. 사냥꾼은 어떻게 실패할까요? 결국 성공한 사냥꾼은 먹을 것이 있지만 실패한 사냥꾼은 먹을 것이 없습니다. 사냥감이 풍부한 환경에서 실패한 사냥꾼은 왜 굶주릴까요?

사냥감이 풍부한 환경에서는 가장 큰 동물을 사냥하는 데 실패했다고 해서 굶지 않습니다. 가장 큰 동물을 쫓느라 너무 많은 시간을 보내서 쉽게 저녁을 먹을 수 있는 작은 동물을 간과했기 때문에 굶습니다. 큰 동물을 사냥할 때는 작은 동물에 대한 기술을 연마하고 배가 부를 때입니다.

참고 AI 작업을 막 시작하면 가장 크고 어려운 기회를 잡을 수 있는 충분한 규모의 팀을 구성하는 데 어려움을 겪을 것입니다. '큰 기회부터 잡자'라는 위험한 접근 방식은 팀을 파괴할 수 있는 위험한 베팅이 될 수 있습니다.

기술적으로 어려운 프로젝트부터 시작하기로 선택하는 것은 비록 그것이 더 높은 가치를 지녔다고 하더라도 위험합니다. 프로젝트가 복잡하면 분석 팀에 다른 중요한 프로젝트를 실행하기에 충분한 리소스가 없을 수 있습니다. 모든 계란이 한 바구니에 있습니다.

의료 진단은 어려운 문제입니다.

귀하가 인공지능에 관심이 있는 병원 팀의 일원으로, 종양학과에서 인공지능을 사용하여 초대형 **혁신 프로젝트**를 시도한다고 가정해 봅시다. 귀하는 종양학과를 위한 의사 결정 지원 시스템을 구축하기 위해 대규모 프로젝트 팀을 구성할 것입니다. 하지만 암은 복잡한 질병이며, 병원에서는 임상 지침 내에서 의사가 최종 결정권을 갖습니다.

지금 귀하는 수백만 달러의 투자가 필요한 복잡한 프로젝트를 진행 중이고, 지나치게 광범위한 문제를 해결하려고 노력하고 있습니다. 또한 최종 사용자(종양 전문의)와 점진적으로 신뢰를 구축하지 않았기 때문에 AI 시스템의 결과에 대해 회의적입니다. 더 나쁜 것은 그들이 회의적인 측면이 옳다는 것입니다! 다른 문제에 대해 작업한 초기 시스템 프로토타입은 좋지 않은 결과를 제공했습니다. 이미 수백만 달러를 투자한 프로젝트를 두 배로 줄이는 것 외에는 대안이 없는 악순환의 고리에 갇혀 있습니다.

팀이 더 간단한 문제에 집중하고 의사들과 좋은 관계를 먼저 구축했다면 훨씬 더 좋은 결과를 얻을 수 있었을 것입니다. 우선, 암은 하나의 질병이 아니라 여러 질병의 집합체입니다. 최근 의료 영상에서 인공지능의 활용이 크게 발전하여[64], 예를 들어 심장 부정맥을 잘 진단할 수 있게 되었습니다. 일부 심장 전문의와 좋은 관계를 구축한 후 나중에 더 어려운 프로젝트에 도전해보는 것은 어떨까요? 심장내과 과장이 다른 과의 동료들에게 여러분의 전문성을 기꺼이 추천해 준다면 성공 가능성은 더욱 높아질 것입니다.

그림 3.3 은 팀의 초기 역량에 비해 너무 어려운 프로젝트를 맡았을 때 어떤 일이 일어날 수 있는지 보여줍니다.

어떤 때는 복잡한 프로젝트부터 시작하면 운이 좋을 수도 있습니다. 프로젝트를 성공적으로 수행하면 경영진의 신뢰를 오래 유지할 수 있고, 그 성공은 나중에 더 큰



그림 3.3 첫 번째 사냥에서 매머드를 궁지에 몰아넣었습니다. 이제 어떻게 할 건가요?

프로젝트를 수행할 때 도움이 될 수 있습니다. 하지만 그런 종류의 지원에 베풀하는 것이 현명한 선택일까요, 아니면 가장 귀중한 자원(팀의 시간)을 한 번의 큰 시도로 낭비하는 큰 위험일까요? 또한, 이러한 유형의 성공은 향후 성과에 대한 기대치를 높인다는 점도 기억하세요. 첫 번째 프로젝트가 성공하더라도 이제 또 다른 크고 위험한 프로젝트를 찾아야 합니다. 운이 다할때까지 얼마나 걸릴까요?

데이터 과학 팀을 운영할 때 진짜 위험은 복잡한 프로젝트를 맡아서 잘못된 방향으로 너무 오래 지속하고, 부족한 리소스를 독점하고, 노력에 대한 성과를 보여주지 못하는 것입니다. 그 과정에서 상당한 비용이 발생합니다. 또한 경영진은 빠르게 결과를 내지 못하는 값비싼 프로젝트를 계속 지원해야 하는 입장에 처하게 됩니다. 만약 경영진이 프로젝트를 중단하는 것이 합리적이라고 판단한다면 어떻게 해야 할까요?

경고 의사결정 지원 시스템으로 사용될 AI 프로젝트를 구축할 때, 비즈니스 조직은 AI 기반 분석 결과를 *구현하는 방법을 배우기* 위해 시간이 필요합니다. 프로젝트의 기술적 부분이 완료되기 전에 경영진이 긴장하면 프로젝트는 도착하자마자 죽습니다.

3.2AI 프로젝트 우선순위 정하기

올바른 첫 AI 프로젝트를 어떻게 선택하나요? 단순함: 비즈니스 관점에서 실행 가능하고, 가치가 있으며, 단순해야 합니다. 즉, 각 프로젝트는 비즈니스에 실행 가능한 결과를 제공할 수 있어야 합니다. 비즈니스적으로 중요한 가치를 가져야 하며, 제공 난이도를 예측할 수 있어야 합니다. 이 섹션에서는 해당 조건을 충족하는 프로젝트 목록을 만드는 방법을 보여 줍니다. 그림 3.4는 프로젝트 목록을 만드는 데 사용해야 하는 프로세스를 설명합니다.

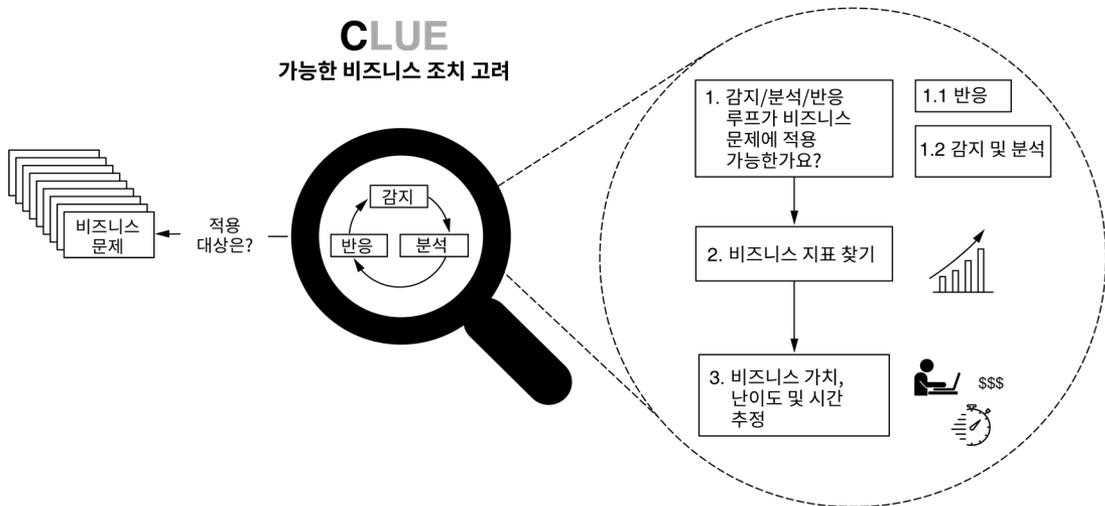


그림 3.4 CLUE의 C 부분을 사용하면 실행 가능한 AI 프로젝트의 목록을 만들고 복잡성을 추정할 수 있습니다.

그림 3.4는 이러한 요소를 보여줍니다.

- 1 팀이 담당하는 모든 비즈니스 영역을 살펴보는 것부터 시작합니다.
- 2 감지/분석/ 반응 루프에서 AI를 적용하고 모든 요소를 커버할 수 있는 영역은 어디인가요? (이 단계에 대한 좋은 참고 자료는 2장의 그림 2.4입니다.)
 - 반응에서 취할 수 있는 액션을 찾아서 시작하세요. (자세한 내용은 3.2.1절을 참조하세요.)
 - 그런 다음 루프의 감지 및 분석 측면을 다룰 수 있는지 확인합니다. (자세한 내용은 3.2.2절을 참조하세요.)
- 3 AI 프로젝트가 비즈니스 목표를 달성하는 데 얼마나 도움이 되는지 측정하는 데 사용할 비즈니스 지표를 결정합니다. (자세한 내용은 3.2.3절을 참조하세요.)
- 4 주어진 AI 프로젝트의 비즈니스 가치를 추정합니다.
- 5 이 비즈니스 사례의 구현 난이도와 구현에 걸리는 시간을 추정합니다(섹션 3.2.4).

귀사의 조직이나 비즈니스를 잘 모르기 때문에 AI 프로젝트의 비즈니스 가치(4 단계)를 스스로 추정할 수 있다고 가정하겠습니다. 이 섹션의 나머지 부분에서는 이 워크플로의 다른 단계를 구현하는 방법을 보여드립니다.

3.2.1 대응: AI가 답해야 할 비즈니스 질문 찾기

2장을 읽으셨다면 비즈니스에서 AI가 수행하는 역할에 기반한 AI 분류법을 이미 알고 계실 것입니다. 이 분류법을 사용하면 대응 루프에서 사용할 수 있는 비즈니스 액션을 도출하는 좋은 방법입니다. 이 섹션에서는 그 분류법을 적용하는 방법을 보여드립니다.

제거 프로세스를 사용해 감지/분석/반응 루프에서 적절한 반응 부분을 찾습니다. 먼저 비즈니스의 모든 영역을 살펴봅니다. 그런 다음 높은 수준의 AI 분류법을 적용하여(2장의 그림 2.5에 설명된 대로) 어떤 영역이 AI의 혜택을 받을 수 있는지 결정합니다. 그림 3.5는 이 분류법을 사용하여 루프의 반응 부분을 다루는 도메인 액션을 발견하기 위한 논의를 촉진하는 방법을 보여줍니다.

그림 3.5는 기존의 비즈니스 관련 AI 분류법을 적용하여 AI가 답변해야 하는 비즈니스 문제를 찾기 위해 고안된 질문을 던집니다. 어떻게 사용할 수 있는지 예시를 보여드리겠습니다.

명목상 독립적이지만 더 큰 프랜차이즈의 일부인 소매업체와 협력하고 있다고 가정해 보겠습니다. 프로세스를 변경하려면 프랜차이즈 소유주의 승인이 필요하며, 매장 경영진은 AI가 수익을 개선할 수 있다는 것을 보여주기 전까지는 이를 요청하지 않을 것입니다. 결과적으로 소매업체의 경영진은 아직 비즈니스 프로세스를 변경하거나 자동화할 의향이 없지만 *제품 믹스*(매장에 어떤 유형의 제품이 몇 개 있는지)를 변경할 수 있습니다.

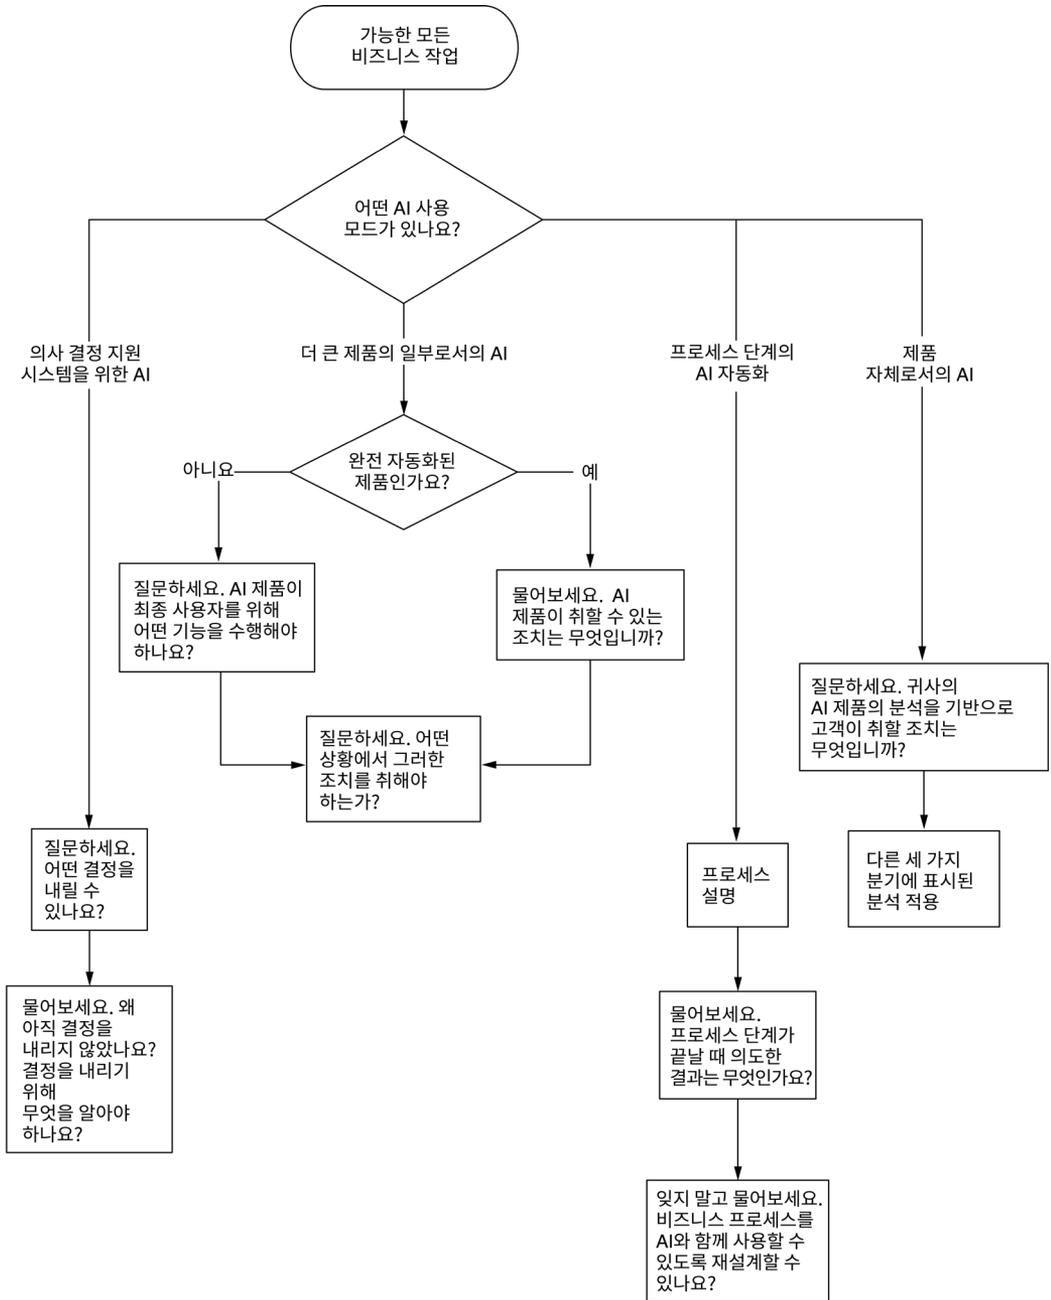


그림 3.5 감지/분석/반응 루프의 반응 부분: AI가 반응할 수 있는 비즈니스 문제 찾기. 비즈니스에서 AI가 수행하는 역할을 파악한 후에는 여기에 제공된 질문을 하세요.

팁 AI 기반 솔루션에 대한 경영진의 회의론은 현실 세계에서 종종 해결해야 하는 문제입니다. 기술자들은 AI 기능을 당연한 것으로 받아들이는 경우가 많지만, 비즈니스맨들은 회의적일 수 있습니다. 더 크고 효과적인 AI 프로젝트를 채택하려면 먼저 이들의 신뢰를 얻어야 합니다. 소매업체 경영진의 입장이 되어보세요. 프랜차이즈 소유주에게 가서 "프랜차이즈의 모든 매장에 영향을 미치는 프로세스를 바꿀 수 있을까요?"라고 물어본다면 어떻게 생각하시나요? 제 매장에서 AI라는 것을 시도해보고 싶은데 어떻게 될지 모르겠습니다."

이 예제에서 AI를 사용할 수 있는 유일한 방법은 매장 관리 자체에 도움을 주는 것입니다. 이것은 분명히 의사 결정 지원 시스템을 만드는 예입니다. 의사 결정 지원 시스템을 위한 지점 AI의 그림 3.5를 보세요. 이 지점에 적용할 수 있는 질문은 경영진이 어떤 결정을 내릴 수 있으며 왜 아직 결정을 내리지 못했을까요? 이 지점에서 경영진이 지금 당장 할 수 있는 일은 제품 구색을 변경하는 것뿐이며, 다른 제품을 다른 선반에 배치할 수 있다는 사실을 알게 됩니다. 이것이 감지/분석/반응 루프의 반응 부분입니다.

"과거 매출을 기준으로 내 스토어에서 가장 수익성이 높은 제품 믹스는 무엇인가요?"라는 비즈니스 질문에 대한 답변입니다. 이제 루프의 감지/분석 부분으로 이동할 수 있습니다.

첫 번째 비즈니스 문제를 발견하자마자 멈추지 마세요.

진행하기 전에 이 소매점에서 AI를 사용할 수 있는 다른 옵션이 있는지 살펴봅시다. 그림 3.5를 다시 보세요. AI를 더 큰 제품 지점의 일부로 사용할 수 있는 방법이 있을까요? 글썄요, 이미 매장에 비디오 감시 시스템이 있습니다. 그 영상 감시 시스템을 AI와 함께 사용할 수 있나요? 관리자가 매장의 상품 구색을 최적화하고자 한다면, 영상 감시와 결합된 AI의 어떤 기능을 관리자가 수행할 수 있나요? 실행 가능한 추가 비즈니스 질문을 찾아보세요:

- 고객이 제품을 살펴보고 자리를 떠났습니까? 해당 제품이 경쟁사 제품보다 더 비싼가요?
- 고객이 품절된 제품을 찾았나요? (고객이 해당 제품이 진열된 영역으로 다가갔다가 제품이 없는 것을 확인하고 매장을 떠났습니다.)

인공지능을 사용하여 이러한 질문에 답할 수 있다면 제품 믹스 최적화에 도움이 될 수 있는 실행 가능한 사용 사례를 발견했을 수 있습니다. 그림 3.5를 사용할 때 비즈니스의 각 영역에서 여러 사용 사례를 생성할 수 있다는 점을 기억하세요.

그러나 비디오 스트림 분석에 AI를 사용하는 데 너무 많은 시간을 소비하기 전에, 이는 해결하기 쉬운 문제가 아니며 이러한 AI 프로젝트를 구현하는 데 시간이 걸린다는 점을 염두에 두어야 합니다.

프로토타입을 시작하기 전에 소매업체 경영진에게 발견한 사용 사례에 대해 어떻게 생각하는지 물어보기로 결정합니다. 물어봐 주셔서 감사합니다! 경영진이 매장에서 AI를 사용하는 것에 대한 법적 및 홍보 측면에 대해 걱정하고 있다고 말합니다. 비디오 분석에 관심이 없습니다. 성공하더라도 사용하지도 않을 AI 솔루션을 구현하는 데 드는 비용을 절감했습니다.

3.2.2 감지/분석: AI 방법 및 데이터

루프의 반응 부분을 설정했다면 어떤 AI 알고리즘을 사용할지 결정하고 이를 사용하기에 충분한 데이터가 있는지 확인해야 합니다. 이 섹션에서는 AI 메서드와 데이터 사이의 관계에 대해 설명합니다.

이 영역은 AI에 능숙하지 않은 경우 광범위한 AI 및 ML 알고리즘에 능통한 전문가의 도움이 필요한 분야입니다. AI 분야는 너무 방대하고 빠르게 변화하기 때문에 한 권의 책으로 그 전문가를 대체할 만큼 충분히 배울 수 없습니다. 그래도 2장의 그림 2.6에 제시된 분류법은 논의의 틀을 잡고 해결하려는 비즈니스 질문에 적용할 수 있는 높은 수준의 AI 기능을 상기시키는 데 유용할 수 있습니다.

사용할 AI 방법의 유형을 파악한 후에는 그림 3.6과 같이 해당 방법과 데이터 간의 관계를 파악해야 합니다.

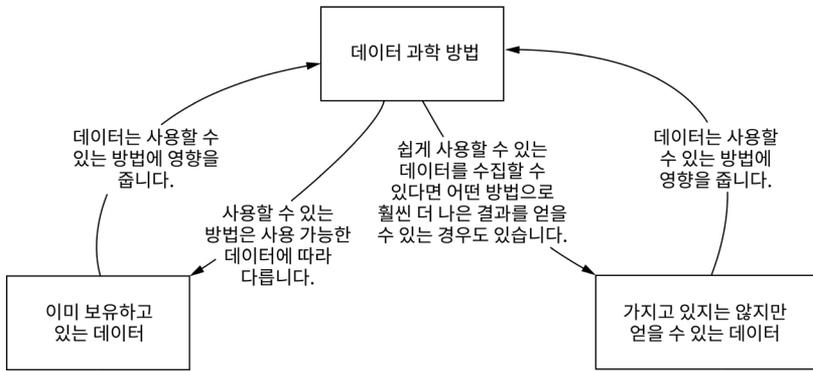


그림 3.6 데이터 과학 방법과 데이터는 서로 연결되어 있으며 서로 영향을 미칩니다.

훈련에 필요한 데이터를 어디서 구할 수 있는지 묻지 않고 방법을 논의해서는 안 됩니다.

사용하려는 데이터와 AI 방법을 항상 함께 고려해야 합니다. 데이터를 팀에서 보유하고 있는 데이터와 팀에서 수집할 수 있는 데이터로 나눌 수 있습니다.

팁 수집할 수 있는 데이터는 조직 어딘가에 있는 데이터뿐만 아니라 팀에서 즉시 사용할 수 없는 데이터도 포함합니다. 조직 외부의 소스에서 수집할 수 있는 데이터 또는 비즈니스 파트너로부터 구매할 수 있는 데이터일 수도 있습니다. 이러한 데이터에 액세스하려면 종종 협상과 서명이 필요한 계약이 필요합니다.

데이터 수집 시 고려 사항

데이터 수집에는 많은 함정이 있으므로 신중하게 관리해야 합니다. 최소한 다음과 같은 질문을 하세요.

- 선택한 ML 알고리즘이 이 데이터를 학습하려면 무엇이 필요한가? 어떤 데이터 형식이 필요한가요? 이 알고리즘을 학습시키는 데 필요한 데이터의 양은 얼마인가요? 어떤 품질인가요?
- 어떤 소스가 이 데이터를 제공하나요?
- 데이터 집합의 소유자는 누구인가요?
- 이 데이터 집합을 획득하는 데 드는 비용은 얼마인가요? 해당 데이터 집합을 획득하는 데 얼마나 걸리나요? 해당 데이터에 액세스하기 위해 협상(또는 법적 계약 체결)이 필요한가요?
- 이 데이터 집합은 프로덕션 시스템에서 얻을 수 있는 데이터 형식과 얼마나 밀접하게 일치하나요? 학습 데이터를 사용하기 전에 사전 처리가 필요하며 데이터에 레이블을 지정해야 하나요?
- 데이터 집합을 저장하려면 얼마나 큰 규모의 데이터 인프라가 필요한가요?
- 초기 데이터 집합이 구축된 후 새로운 데이터를 수집하려면 어떻게 해야 하나요?
- 조직에 일부 데이터가 있지만 팀이 데이터에 액세스할 수 없는 경우가 있나요? 조직이 이미 가지고 있는 데이터 중 일부에 액세스할 수 없는 경우가 종종 있습니다. 윤리, 규정 또는 회사 개인정보 보호정책의 이유로 데이터가 기밀로 유지될 수 있습니다.
- 법적 및 윤리적 고려 사항(저작권, 개인정보 보호정책, 기대치 등)은 무엇인가요? 데이터를 수집할 때는 항상 윤리, 조직 정책, 규정(GDPR[71] 및 HIPAA[72,73]를 예로 들 수 있음)을 고려해야 합니다.

이 체크리스트를 살펴보면 경우에 따라 ML 알고리즘에 필요한 데이터를 쉽게 수집할 수 있다는 것을 알 수 있습니다. 다른 경우에는 데이터를 사용할 수 없거나 너무 비싸서 수집할 수 없는 경우도 있습니다.

이전 섹션에 제시된 소매업의 예에서 데이터 과학자는 판매 추세를 예측하는 데 한 가지 ML 방법을 사용하고 제품 믹스를 최적화하는 데 다른 방법을 사용할 수 있다고 확신합니다. 이러한 알고리즘과 방법의 이름은 크게 의미가 없으며, ARIMA, LSTM, 운영 연구와 같은 용어가 나타날 수 있습니다. 이러한 방법에는 과거 판매에 대한 데이터가 필요합니다. 이러한 데이터는 조직 내부에서 사용할 수 있으며 프로젝트에서 즉시 액세스할 수 있습니다. 이제 감지/분석/반응 루프의 모든 요소를 포괄하는 사용 사례를 확인하셨으며, 이는 AI 프로젝트에서 실행 가능한 사용 사례입니다.

음식을 인식하는 AI

데이터와 사용된 알고리즘 간의 관계를 보여주는 또 다른 예는 AI를 사용하여 음식의 이미지 인식을 수행하는 경우입니다. 식품 가공 공장이나 내부에 카메라가 있고 AI를 사용하여 오븐에 넣은 음식을 자동으로 인식하는 스마트 인터넷 연결 오븐[74]을 예로 들 수 있습니다.

이러한 오븐을 만들려면 이미지를 인식할 수 있는 AI 알고리즘(이 글을 쓰는 시점에서는 일반적으로 컨볼루션 신경망의 한 형태)을 사용해야 하며, 이러한 AI 방법을 학습할 데이터가 필요합니다. 이 데이터는 다양한 종류의 음식 사진으로 구성되어 있습니다.

프로젝트를 시작할 때는 사내에 음식 사진이 많지 않을 것입니다. 하지만 데이터를 수집할 수 있는 외부 소스가 있을 수 있습니다. 이러한 소스에는 음식 사진이 있는 웹사이트나 오븐 사용자가 요리하는 음식 사진 등이 있습니다. 이러한 소스에서 음식 사진을 수집할 때 고려해야 할 추가 고려 사항이 있는데, 이는 보유하고 있지는 않지만 잠재적으로 수집할 수 있는 데이터에 일반적입니다. 저작권 및 개인정보 보호법을 준수하는지 확인해야 합니다.

데이터 수집의 또 다른 흥미로운 측면은 수집한 데이터 중 일부가 AI 학습에 이상적인 데이터와 미묘하게 다를 수 있다는 점입니다. 오븐에 있는 카메라의 위치와 유형에 따라 오븐이 촬영하는 음식 사진은 일반적으로 웹에서 볼 수 있는 접시 위의 음식 사진과 약간 다르게 보입니다. 또한 오븐은 기름기가 많은 장소이므로 유리에 묻은 기름이 오븐에 있는 음식의 이미지에 영향을 줄 수 있습니다. 웹에 있는 음식 사진은 기름기가 많은 렌즈를 통해 촬영되지 않습니다!

비즈니스 질문 중 일부가 최고의 데이터 과학자에게 알려지지 않은 AI 기술을 통해 도움을 받을 수 있었다면 어떻게 되었을까요? 찾을 수 있는 최고의 AI 전문가가 해당 AI 기술에 대해 잘 알지 못한다면, 해당 기술을 사용할 수 있을 만큼 강력한 팀을 구성할 수 없을 가능성이 높으므로 고려 대상에서 제외하세요.

빅 데이터와 스몰 데이터 중 무엇을 선택해야 할까요?

빅데이터는 마인드셋이 크며, 대부분의 AI 대화는 빅 데이터 세트의 맥락에서 발생합니다. 수백만 명이 촬영한 1인당 수백 장의 사진을 고해상도로 저장하려면 대용량 스토리지가 반드시 필요합니다.

하지만 빅데이터는 AI 알고리즘이 사용할 수 있는 데이터 유형 중 하나일 뿐이므로 빅데이터와 소규모 데이터로만 생각해서는 안 됩니다. 대신 *의사결정에 필요한 모든 데이터*에 대해 생각해 보세요. 때로는 빅 데이터 집합이 필요하지 않거나 구할 수 없는 경우도 있습니다. 예를 들어, 분기별 결과는 분기마다 한 번씩 나옵니다. 약물 연구에서는 수백만 명의 환자를 모집할 수 없습니다. 자동차 사고는 흔하지만 (다행히도) 연간 수조 단위로 측정되지는 않습니다.

일부 데이터 집합은 작을 수 있지만 중요한 결과에 대한 정보를 담고 있습니다. 또한 수집하는 데 비용이 많이 들 수도 있습니다. 런던의 Lloyd's와 같은 재보험 시장을 생각해 보세요. 클레임이 수억 건 단위로 측정되는 경우, 데이터 집합은 (희망적으로) 작지만 중요하고 수집하는 데 비용이 많이 듭니다.

3.2.3 비즈니스 메트릭으로 AI 프로젝트 성공 측정하기

특정 사용 사례에 대해 감지/분석/반응 루프의 모든 부분을 다루고 있는지 확인함으로써 해당 사례가 기술적으로 가능하고 실행 가능한지 검증할 수 있습니다.

하지만 이것이 수익에 어떤 영향을 미치는지 어떻게 알 수 있을까요? 이 섹션에서는 비즈니스 도메인 메트릭을 사용하여 AI 프로젝트의 결과를 측정해야 하는 이유를 설명합니다.

AI는 메트릭을 기반으로 하지만 비즈니스 목표를 달성하기 위해 AI를 사용해야 합니다. 이 목표는 비즈니스 메트릭으로 표시되어야 합니다. 비즈니스 지표는 비즈니스 개선에 사용될 때 질문에 대한 답변이 얼마나 가치 있는지를 나타내야 합니다. 측정된 메트릭은 "수익이 10% 개선됨"과 같이 정확한 단일 수치일 필요는 없습니다. "수익이 8%에서 12% 사이로 개선되었습니다"와 같이 추정치일 수도 있습니다.

경고 비즈니스 지표는 모든 AI 프로젝트에 대해 정의되어야 합니다. AI 방법은 하드 데이터로만 작동한다는 점에서 본질적으로 정량적 방법입니다. 프로젝트의 결과를 측정하는 데 사용할 수 있는 비즈니스 지표를 먼저 정의할 수 없다면 AI를 사용하지 마세요.

적절한 비즈니스 지표를 선택할 수 있는 능력은 결코 사소한 것이 아닌 비즈니스 기술입니다. 하지만 좋은 소식은 조직에서 메트릭을 올바르게 사용하고 있다면, AI를 적용하려는 영역에서 이미 비즈니스 결과를 측정하는 비즈니스 메트릭이 이미 정의되어 있을 것입니다. 이 지표는 또한 AI가 비즈니스를 얼마나 개선했는지를 측정해야 합니다.

가능한 비즈니스 지표의 예

주의할 점은, 올바른 비즈니스 지표는 항상 조직에 맞는 것이지, 다른 사람에게 효과가 있었다고 해서 다른 사람에게서 가져오는 것이 아니라는 것입니다. 다음 메트릭은 이 규칙의 예외가 아니라 일부 조직에서 효과가 있을 수 있는 예시입니다.

- 여러 공급업체 중에서 선택할 때 가능한 지표 중 하나는 제품에 해당 공급업체의 부품을 사용하는 데 드는 **총 비용일 수 있습니다**. 이는 해당 부품의 사용으로 인해 발생하는 기타 관련 비용을 포함하므로 해당 부품의 **가격과는 다릅니다**. 여기에는 해당 부품이 고장났을 때 제품의 지원 또는 수리 비용이 포함됩니다.
- 새 책을 몇 권 인쇄할지 논의하는 도서 출판사의 경우, 한 가지 좋은 지표는 **실제 책 판매로 인한 예상 수익입니다**. 여기에는 인쇄된 책의 누적 비용, 서점이나 기타 보관 시설에 책을 보관하는 누적 비용, 책을 판매할 것으로 예상되는 일정과 가격, 자본 비용 등의 요소가 포함되므로 판매된 책 한 권당 수익과는 다릅니다.
- 3.2.1절의 예에서와 같이 제품 믹스를 최적화하는 소매업체라고 가정해 보겠습니다. 해당 소매업체에 대한 올바른 비즈니스 지표 중 하나는 **얼마나 순이익의 변화가 제품 구성의 모든 품목과 관련이 있는가입니다**. 순이익은 혼합에 포함된 개별 품목의 판매량뿐만 아니라 혼합 변경 비용, 보관, 운송 및 각 개별 소매업체에 특정한 기타 많은 비용에 의해 영향을 받습니다.

좋은 비즈니스 지표는 조직의 요구와 측정하고자 하는 구체적인 비즈니스 결과에 맞게 맞춤화되어야 합니다.

이 책에서 좋은 조직 메트릭을 구축하기 위한 모든 모범 사례를 제공할 수는 없으며, 그 자체로 하나의 책이 될 것입니다(비즈니스 메트릭에 대한 주제는 루프티그와 오울렛의 책 [1]과 리스의 책 [28]에서 다루고 있습니다). 하지만 좋은 비즈니스 지표는 조직에 구체적이고, 정량화되고, 측정 가능하며, 원하는 결과와 관련이 있고, 의도하지 않은 결과를 초래하지 않아야 한다는 점을 지적하고 싶습니다.

팁 조직에서 비즈니스 지표를 사용하고 있지만, 측정하는 내용이 잘못되어 비즈니스 운영에 도움이 되지 않는다고 의심되는 경우가 있습니다. 이러한 상황이라면, AI 프로젝트를 시작하기 전에 메트릭을 수정하고 이 고정 메트릭을 사용하여 AI 프로젝트의 최종 결과를 측정하세요. 그렇지 않으면 잘못된 비즈니스 결과를 도출하도록 AI를 최적화할 수 있습니다.

AI 프로젝트의 비즈니스 기여도를 측정하는 데 사용할 수 있는 비즈니스 메트릭을 선택했다면 임계값을 정의할 수 있습니다. 이 **임계값**은 프로젝트가 가치가 있으려면 AI가 지시한 작업이 달성해야 하는 최소값을 나타냅니다. 예를 들어, 사용하기로 선택한 비즈니스 지표가 '수익 증가'인 경우, 임계값은 AI 프로젝트가 가치가 있으려면 수익이 연간 최소 2백만 달러 증가해야 한다는 것일 수 있습니다.

소매업체 예제의 임계값

임계값은 조직의 비용 및 수익 구조에 따라 달라지므로 항상 조직별로 다릅니다. 비즈니스 팀으로부터 임계값을 얻어야 합니다. 다음은 섹션 3.2.1.에 제시된 소매업체 예제에 대한 목표를 얻는 예입니다.

여러분은: AI 프로젝트를 통해 **순이익**이 1% 증가한다면, 제품 믹스를 변경하시겠습니까?

소매업체 관리자: 제품 믹스를 변경할 의향은 있지만, 새로운 공급업체와 계약하는 데는 비용이 많이 듭니다. 공급업체와 계약할 때 금전적 비용뿐만 아니라 관리자의 주의와 계약에 필요한 시간 등 비용을 고려해야 합니다. 우리의 지표는 얼마나 많은 신규 공급업체와 계약해야 하는지를 고려해야 합니다. 구체적으로, 신규 공급업체 한 곳과 계약하는 것을 정당화하려면 내 **순이익**이 0.3% 증가해야 합니다. 따라서 전반적으로 제품 믹스를 변경하는 데 1%면 충분하다고 말할 수 없습니다—새 공급업체 3곳과 계약해야 하는 경우에는 충분하지만 20곳과 계약해야 하는 경우에는 그렇지 않습니다.

이 예에서는 **순이익**이 지표이고 각 신규 공급업체의 0.3%가 임계값입니다.

프로젝트에 사용할 메트릭을 찾았으므로 이제 해당 메트릭을 사용하여 AI 프로젝트의 결과를 측정할 수 있는지 확인해야 합니다. AI 전문가에게 비즈니스 메트릭을 제시하고 해당 메트릭을 사용하여 AI 프로젝트의 결과를 보고할 수 있는지 확인하도록 요청하세요. AI 전문가가 해당 비즈니스 지표와 AI 프로젝트에서

사용하려는 기술 평가 지표 중 하나(예: RMSE)와의 연결을 설정해야 합니다.

팁 비즈니스 지표는 달성하고자 하는 비즈니스 결과를 정확하게 측정하고, 기술 전문가가 해당 비즈니스 지표를 사용하여 기술 진행 상황을 보고하는 방법을 알고 있을 때 AI 프로젝트에 적합합니다.

적용 가능한 비즈니스 메트릭을 찾을 수 없다면 어떻게 해야 하나요?

AI 프로젝트를 측정해야 하는 비즈니스 지표를 쉽게 인식할 수 없다면 큰 위험 신호가 됩니다. 달성하고자 하는 비즈니스 결과를 정량화할 수 없다면, 자신과 동료들에게 "애초에 AI 프로젝트를 시작해야 하는가?"라는 질문을 던져야 합니다.

비즈니스 지표를 정의할 수 없다면 AI 프로젝트의 값 임계값도 정의할 수 없습니다. 임계값이 없으면 프로젝트의 결과가 비즈니스에 사용할 수 있을 만큼 충분한지 알 수 없습니다. 비즈니스 지표와 임계값이 없으면 AI 프로젝트의 비즈니스 가치를 추정할 방법도 없고, 비용 효율성이 있는지 알 수도 없습니다. 어떤 경우든 좋은 비즈니스 지표가 없으면 AI 프로젝트 관리는 직감에 의한 일련의 의사 결정으로 변질될 것입니다.

AI 프로젝트에 대한 비즈니스 지표를 선택할 수 없다는 것은 비즈니스 지표가 제대로 구축되지 않았다는 신호일 수 있으며, 비즈니스에 가치를 제공할 수는 있지만 측정할 수 없는 상황을 초래할 수 있습니다. 또한 비즈니스 가치를 전혀 제공할 수 없음을 나타낼 수도 있습니다. 또는 AI 프로젝트가 핵심 비즈니스와 너무 단절되어 있어 비즈니스에서 결과를 어떻게 처리해야 할지 모른다는 것을 나타낼 수도 있습니다. 그러한 프로젝트는 위험합니다.

명확한 비즈니스 가치가 있지만 경영진이 이를 무형적이고 측정할 수 없는 것으로 인식하는 경우도 있습니다. 무형의 예로는 직원 사기나 브랜드 가치를 들 수 있습니다. 이는 경영진이 무형 자산을 단일 숫자 대신 *범위*를 사용하여 측정할 수 있다는 사실을 모르는 경우에 발생합니다. 비즈니스에서 범위를 사용하여 소위 무형의 양을 측정하는 모범 사례에 대한 많은 예는 허바드의 저서 [75]를 참조하세요.

3.2.4 AI 프로젝트 난이도 추정하기

이제 고려 중인 AI 프로젝트가 기술적으로 가능하다는 것을 확인했으며, 비즈니스에 미치는 영향과 비즈니스 가치를 측정할 수 있는 방법이 생겼습니다. AI 프로젝트가 실행 가능한지 결정하려면 비용, 구현 난이도, 소요 시간을 알아야 합니다. 이 섹션에서는 이러한 비용을 추정할 때 고려해야 할 사항을 자세히 설명합니다.

난이도를 추정하려면 AI 프로젝트에 사용될 기술 솔루션의 개요를 스케치해야 합니다. 데이터 과학 및 데이터 엔지니어링 팀 대표와 소프트웨어 아키텍트가 함께 이 개요를 작성해야 합니다. 목표는 솔루션의 개략적인 개요를 제공하여 가능한 여러 AI 프로젝트를 비교할 수 있도록 하는 것입니다.

이 개요가 완성되면 이 개요를 사용하여 프로젝트의 난이도, 비용, 소요 시간을 예측합니다. 이는 여러 AI 프로젝트 옵션을 비교하기 위한 대략적인 추정치입니다.

AI 프로젝트 난이도 추정 시 고려 사항

AI 프로젝트 난이도를 추정할 때는 다음 사항을 고려해야 합니다.

- 필요한 데이터를 수집하는 데 필요한 시간을 고려하세요.
- 데이터 규모에 필요한 인프라를 갖추고 있나요? 빅 데이터 프레임워크가 필요한가요?
- 대규모 데이터 집합을 사용하는 경우, 데이터를 처리하고 AI 알고리즘을 학습시키는 데 필요한 시간을 고려해야 합니다.
- 팀이 사용 사례를 다루는 데 필요한 모든 기술을 갖추고 있나요? 스킬 세트에 부족한 부분이 있다면 무엇인가요? (2장에서 조연한 대로, 팀 리더는 팀 내 지식 격차를 알고 있어야 합니다.)
- 프로젝트가 기술적으로도 가능한가요? 제안된 AI 방법을 팀이 구축할 수 있다고 확신할 수 있을 만큼 충분히 이해하고 있나요, 아니면 프로젝트가 가능하다고 가정할 정도로만 해당 AI 분야를 알고 있나요?

AI 프로젝트의 세부 사항을 설명할 수 있으면 조직에서 익숙한 추정 방법론을 사용하여 다른 소프트웨어 프로젝트를 추정할 수 있습니다.

팁 사람은 추정에 특히 능숙하지 않으며[75], 솔루션의 스케치만 보고 추산하는 경우 더 나쁘고, 잘 모르는 기술 영역에서 추산해야 하는 경우 더욱 나쁘다는 점을 기억하세요. 어쩔 수 없이 매우 대충 추정하게 됩니다. 이 견적은 다양한 AI 프로젝트 옵션을 비교하기 위한 것일 뿐이며, 이 견적에 근거하여 경영진에게 확고한 약속을 해서는 안 됩니다.

이 시점에서는 실행 가능하고 실행 가능한 AI 프로젝트 목록을 작성하는 데 필요한 모든 정보를 확보한 상태입니다. 제안된 프로젝트가 실행 가능하고 기술적으로 가능한지 판단하는 방법을 알고 있습니다. AI 프로젝트의 비즈니스 가치를 측정하는 방법을 알고 있으며 비용, 난이도 및 기간을 대략적으로 추정할 수 있습니다. 이제 실행할 첫 번째 AI 프로젝트를 선택할 차례입니다. 다음 섹션에서는 첫 번째 AI 프로젝트를 실행하기 위한 선택 및 준비 과정을 안내합니다.

3.3 첫 번째 프로젝트와 첫 번째 연구 질문

섹션 설명한 것처럼, 비즈니스 조직의 장기적인 자산이 될 AI 팀을 구축하는 것이 목표라면 초기 프로젝트는 간단하고 빠르게 제공해야 합니다. 따라서 실행할 첫 번째 AI 프로젝트를 선택하는 기준은 간단합니다. 빠르게 전달할 수 있고 비즈니스 가치가 큰 프로젝트를 선택하면 됩니다. 해당 프로젝트를 선택했다면 다음을 수행해야 합니다.

- 프로젝트가 답할 연구 질문을 정의합니다(섹션 3.3.1).
- 프로젝트가 실패할 경우 빠르게 실패하도록 프로젝트를 구성합니다(섹션 3.3.2).

이 섹션의 나머지 부분에서는 연구 질문을 정의하는 방법을 보여주고 빠르게 실패한다는 것이 무엇을 의미하는지 설명합니다.

3.3.1 연구 질문 정의하기

첫 번째 AI 프로젝트를 선택했습니다. 해당 프로젝트에는 해답이 필요한 명확한 비즈니스 질문이 있으며, 그 질문은 비즈니스 의사 결정권자가 이해할 수 있는 형식으로 작성되었습니다. 이제 그 질문을 AI가 이해할 수 있는 형식, 즉 "연구 질문"으로 변환해야 합니다. 이 섹션에서는 연구 질문이 비즈니스 질문과 일치하는지 확인하는 방법을 보여줍니다.

제조업체의 연구 질문이 "제품의 품질에 따라 A 공급업체와 거래해야 하는가, 아니면 B 공급업체와 거래해야 하는가?"라고 가정해 보겠습니다. 이 질문에 답하려면 인공지능이 필요하지만, 인공지능은 **공급업체의 개념이 무엇을 의미하는지 모른다**는 문제가 있습니다.

AI는 비즈니스 개념을 이해하지 못합니다

AI 기능에 익숙하지 않은 사람들은 종종 AI가 인간의 능력을 벗어난 새로운 비즈니스 반응을 찾아낼 수 있다고 착각합니다. 현재 수준의 AI로는 거의 불가능합니다.

소매업체를 분석하여 수익을 개선할 수 있는 방법을 찾아낼 수 있는 AI 알고리즘은 존재하지 않습니다. 그 이유는 AI가 **소매업체, 제품, 이익**이라는 단어가 무엇을 의미하는지 모르기 때문입니다. 인공지능은 공급업체가 무엇인지도 모르고, 한 공급업체가 다른 공급업체보다 나은 이유도 모릅니다. 그건 비즈니스 개념입니다. 또한 AI는 매장 내 감시 영상을 분석하는 데 AI를 사용하는 것과 관련하여 윤리적, 홍보 및 법적 고려 사항이 있을 수 있다는 사실도 이해하지 못합니다.

비즈니스 개념은 사람이 이해할 수 있지만, 해당 개념과 관련된 데이터는 AI/ML 알고리즘이 예상하는 형식으로 패키징되어야 합니다. 이것이 바로 데이터 과학 팀이 해야 할 일입니다. 이를 위해서는 먼저 연구 질문을 공식화해야 합니다. 연구 질문은 비즈니스 질문을 AI가 이해할 수 있는 형태로 번역한 것으로 볼 수 있습니다.

기술 영역의 계약 언어

AI 메서드는 기술 영역에서 작동합니다. 해당 영역에서 사용되는 언어는 본질적으로 계약 언어이며, "X 형식의 입력을 제시하면 Y 답변을 제공할 것을 보장합니다"와 같은 형식입니다. 이러한 계약은 종종 복잡하기 때문에 해당 분야의 전문가가 정확한 의미는 물론, 그 말의 모든 함의를 제대로 이해해야 합니다.

몇 가지 구체적인 예를 통해 이러한 계약 언어를 설명해 보겠습니다.

- 전적인 통계 방법을 기반으로 하는 AI는 가설 테스트 언어를 사용합니다. " $p = 0.05$?에서 공급업체 A와 공급업체 B의 부품 샘플 간에 통계적으로 유의미한 차이가 있는가?"입니다.
- 이미지 인식을 기반으로 하는 AI는 ML 언어로 "이것이 귀하의 부품 사진이라면, 귀하가 불량으로 분류한 부품 클래스와 다른 클래스에 비해 훨씬 더 유사하다는 것을 95%의 신뢰도로 알려드릴 수 있습니다"라고 표현할 수 있습니다.

또한 AI는 전반적으로 부품을 클래스 간에 정확하게 분류하는 정확도가 98%에 달한다고 말할 수 있습니다.

- 출판 업계에서 첫 번째 배치가 3개월 만에 판매된 경우 두 번째 배치에서 얼마나 많은 실제 책을 인쇄해야 하는지 예측하는 데 사용되는 AI는 시계열 모델을 기반으로 할 수 있습니다. 사용되는 모델에 따라 한 가지 연구 질문은 "이전 3개월의 판매량을 기준으로 다음 3개월의 도서 판매량을 95% 신뢰 구간으로 예측하라"가 될 수 있습니다.

데이터 과학자가 아니라면 지금 이 질문이 머릿속을 맴돌고 있을 것입니다. 이 문장이라도 대체 무슨 뜻일까요? 괴짜처럼 들리나요? 그렇기 때문이죠! AI 메서드는 비즈니스 사용자가 아닌 컴퓨터와 데이터 과학자가 이해할 수 있도록 추상적인 형식으로 정의되어 있습니다. 비즈니스 문제를 해결하려면 이를 *AI 언어*로 번역해야 합니다. ML이 공식화, 최적화, 평가의 조합이라고 말할 때 문제의 *공식화*가 의미하는 바가 바로 이것입니다. 그림 3.7은 이 과정을 보여줍니다.

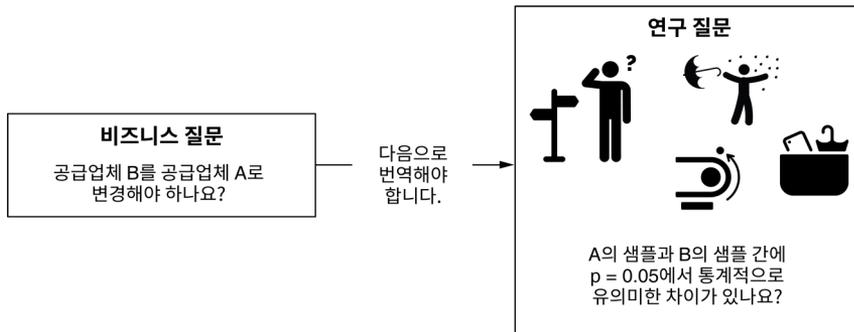


그림 3.7 비즈니스 질문을 연구 질문으로 변환하는 과정. 인공지능은 비즈니스 개념을 이해하지 못합니다. 통계에 익숙하지 않은 경우 연구 질문 구성이 이해하기 어려울 수 있습니다.

AI 전문가의 역할은 적절한 연구 질문을 선택하고 비즈니스 질문과의 관계를 손상시키지 않으면서 AI 방법이 답할 수 있는 형식으로 변환하는 것입니다.

경고 비즈니스 팀과 데이터 과학 팀이 긴밀하게 소통하지 않으면 프로젝트가 잘못되는 경우가 많습니다. 비즈니스 질문이 잘못된 연구 질문으로 잘못 번역되어 묻지도 않은 질문에 대한 답을 얻게 될 수 있습니다. 그 답을 사용하여 잘못된 비즈니스 조치를 취하면 문제는 더욱 복잡해집니다.

번역은 비즈니스 영역과 AI 영역에 대한 이해를 모두 공유해야 하는 매우 복잡한 작업이라는 점을 이해하는 것이 중요합니다. 이 번역은 간단하지 않습니다. 가능한

모든 비즈니스 행동을 평가하는 번역을 고안하는 것은 거의 불가능합니다. 비즈니스 질문과 연구 질문이 일치하지 않는 것을 방지하는 것은 비즈니스 리더의 역할입니다.

잘못 정렬된 비즈니스 질문과 연구 질문

다음은 비즈니스 리더나 데이터 과학자가 직접 이야기하지 않는 한 파악하기 어려운 방식으로 비즈니스 질문과 연구 질문이 어떻게 잘못 정렬될 수 있는지에 대한 예입니다.

비즈니스 리더: 분석을 마쳤을 때 제공할 수 있는 답변 한 가지를 예로 들어주세요.

데이터 과학자: 공급업체 A가 공급업체 B보다 실제로 더 나은 것이 아니라면 우리가 얻은 결과를 얻을 확률은 5%에 불과하다고 추론할 수 있는 충분한 통계적 증거가 있습니다.

비즈니스 리더: 그럼 공급업체 A가 공급업체 B보다 낫다는 말씀이신가요? 지금부터 3개월 뒤에는 좋은 공급업체가 필요한 큰 프로젝트가 있을 것으로 예상됩니다. 공급업체 B를 공급업체 A로 교체할 계획입니다. 공급업체 A의 주문을 100배로 늘릴 것입니다. 분석이 이러한 비즈니스 결정을 뒷받침하기에 충분하나요?

데이터 과학자: 우리가 알고 있는 것은 우리가 테스트한 샘플에서 A가 B보다 더 우수할 가능성이 높았다는 것입니다. . . .

비즈니스 리더 [혼자 생각 중]: *이것은 흥미롭군요. 기술 전문 용어는 무엇을 의미하나요? 이것은 단순한 예, 아니오 문제가 아닙니다. 더 깊이 파헤쳐 봅시다.*
. . . .

비즈니스 리더: 잠깐만요. 방금 말씀드린 것과 어떻게 다른가요? 우리가 간섭할 충분한 증거가 있다고 보고할 상황의 예를 들어주세요. . . 공급자 B를 삭제하는 것은 여전히 잘못된 것입니다.

데이터 과학자: 음. . . 우리는 충분한 통계적 증거를 갖고 있습니다. . 음... 추론, 우리는 지난 주에 주어진 샘플만을 다룹니다. 3개월 후에도 여전히 그럴 것이라고 말할 수는 없습니다. 또한 테스트한 샘플 크기의 100배에 달하는 주문이 들어올 경우 공급업체 A가 동일한 수준의 품질을 제공할 수 있다고 말할 수 없습니다.

비즈니스 리더: 알겠습니다. 공급업체 A와 B의 개선 추세를 고려하는 것이 중요하다면 어떻게 해야 하나요? 현재 추세가 계속된다면 3개월 후에 어떤 일이 일어날지 알고 싶습니다. 공급업체 A가 3개월 내에 납품할 부품 10,000개를 주문하려고 합니다. 분석이 이러한 조치를 뒷받침하나요?

데이터 과학자: 아니요, 그렇지 않습니다. 다른 유형의 분석을 수행해야 합니다. . . .

AI 프로젝트의 비즈니스 리더를 위한 모범 사례

'잘못 조율된 비즈니스 및 연구 질문' 사이드바에는 비즈니스 리더와 데이터 과학자가 완전히 다른 질문에 대해 이야기하고 있어 끔찍하게 잘못될 수 있었던 프로젝트의 예가 나와 있습니다. 하지만 그 대화가 일어나기 전까지는 같은 것에 대해 이야기하고 있지 않다는 것을 알아차리지 못할 것입니다. 다음은 AI 프로젝트를 시작하는 비즈니스 리더를 위한 모범 사례를 제공합니다.

- 이해하지 못하는 고도의 기술적인 연구 질문을 제안하는 문서에 절대 서명하지 마세요. 대신 데이터 과학자와 회의를 요청하세요. 이상적으로는 비즈니스와

AI 모두에 대한 배경 지식이 풍부한 사람이 이 회의를 진행해야 합니다. 조직에 이러한 인력이 없다면 컨설턴트의 도움을 받아야 합니다.

- 데이터 과학자에게 제안된 연구 질문이 도출할 수 있는 몇 가지 가능한 답변을 제공하도록 요청하세요.
- 시나리오 분석을 실행합니다(이전 예제에서와 같이). 연구 질문에 대한 답을 가지고 그 답을 통해 무엇을 알 수 있다고 생각하는지 설명하세요. 그런 다음, 모든 가정을 설명하면서 정확한 비즈니스 의사 결정을 내릴 수 있도록 서술하세요.
- 데이터 과학자가 제공한 답을 해석하는 방법을 항상 반복합니다. 간단하고 비기술적인 용어를 사용합니다.
- 어떤 것을 잘못 이해했더라도 바보처럼 보일까 봐 걱정하지 마세요. 이 단계에서 오해의 소지를 찾아내면 나중에 엄청난 비용을 절약할 수 있습니다. 이 단계에서 오해의 소지를 찾아내면 나중에 엄청난 비용을 절약할 수 있습니다.
- 상대의 답변을 바탕으로 취하고자 하는 비즈니스 조치를 명확하게 설명하세요. 해당 비즈니스 조치가 합리적인지 물어보세요.
- 데이터 과학자가 귀하가 계획한 비즈니스 조치에 대해 단순한 예 또는 아니오 이외의 다른 답변으로 응답하는 경우, 분석 결과만을 근거로 어떤 상황에서 그러한 비즈니스 조치를 취하는 것이 잘못된 것인지 조사합니다.
- AI 전문가와 함께 연구 질문을 더 깊이 탐구하는 것을 두려워하지 마세요. 연구 질문이 의미하는 바에 대한 세부 사항에 대해 교육을 받고, 마찬가지로 데이터 과학자에게 비즈니스에 대한 세부 사항에 대해 교육하세요.
- 비즈니스 질문과 연구 질문 사이의 매핑이 결코 완벽할 수 없음을 이해합니다. 연구 질문은 비즈니스 문제의 모든 측면을 정확하게 포착하는 경우가 거의 없습니다. 질문은 "그 측면들이 귀하에게 중요한가?"입니다.
- 고도로 기술적인 용어를 사용하여 비즈니스 문제를 논의하는 것을 주의하세요. 모든 회의 참가자가 공유하지 않는 용어는 기술과 비즈니스 간의 불일치를 숨기는 훌륭한 수단입니다. 연구 질문과 비즈니스 문제가 일치하는지 확인하기 위해 충분한 논의를 거치지 않는다면, 사실상 중요한 비즈니스 세부 사항을 기술 팀에 맡기는 것과 같습니다.
- 중요한 세부 사항을 명확히 하기 위해 비즈니스 전문가가 기술 팀에 항상 자문을 구할 수 있도록 하세요. 비즈니스 문제의 사양이 모호할 때 기술 팀이 최적의 비즈니스 결정을 내릴 것이라고 기대하는 것은 현실적이지 않습니다.

경고 연구 질문에 대한 시나리오 분석을 항상 수행합니다. *인공지능 팀이 작업을 시작하기 전에* 말이지요. 잘못된 연구 질문을 던질 경우 프로젝트가 성공할 확률은 거의 제로입니다.

연구 질문을 정의할 때 마지막으로 기억해야 할 점은 비즈니스 질문 간의 대응은 "하나의 비즈니스 질문당 하나의 연구 질문"이 아니라는 것입니다. 하나의 비즈니스 질문을 다루기 위해 여러 개의 연구 질문이 필요할 수도 있습니다. 하나의 연구 질문으로 여러 비즈니스 질문에 답할 수 있는 것도 가능합니다(실제로는 드물지만).

3.3.2 실패한다면, 빨리 실패하는 편이 낫습니다.

귀하는 이 첫 번째 인공지능 프로젝트가 쉬운 프로젝트가 될 것이라는 가정 하에 프로젝트를 시작하고 있습니다. 하지만 예상은 대략적이었고, 막상 프로젝트를 시작하면 처음에 계산한 것보다 더 어려운 프로젝트가 될 가능성이 높습니다. 이 섹션에서는 초기 AI 프로젝트를 어떻게 관리해야 하는지 설명하여 프로젝트가 예상치 못하게 어려울 경우 이를 즉시 파악할 수 있도록 합니다.

팁 프로젝트 전달 프로세스를 최적화하여 성공률을 높여야 합니다. 풍부한 사냥터에서 사냥할 때는 더 많이 사냥할수록 더 많이 잡을 수 있습니다. 인공지능 작업 초기에는 초기에는 쉬워 보이지만 자세히 살펴보면 어려운 프로젝트에 계속 매달려서는 안 됩니다. 대신 초기에 중단하고 남은 프로젝트 시간을 더 쉬운 프로젝트를 시작하는 데 사용하세요.

프로젝트는 빠른 프로토타입을 구축하는 개념 증명으로 시작해야 합니다. 이 프로토타입은 네 가지 용도로 사용됩니다.

- 1 엔지니어링 팀이 프로젝트를 제공하는 데 필요한 기술 전문 지식을 보유하고 있음을 보여줍니다.
- 2 식별한 감지/분석/반응 루프에서 분석하는 구체적인 AI 구현을 제공합니다. 이제 루프의 반응 부분을 테스트할 수 있습니다(예: 필요한 비즈니스 액션을 구현하는 것이 얼마나 어려운지 테스트할 수 있습니다).
- 3 프로토타입을 분석하여 제안한 시스템 솔루션이 더 많은 데이터 또는 다른 ML 알고리즘에 노출되었을 때 어떻게 작동하는지 확인할 수 있습니다. 이 책의 6장과 7장에서는 이 분석이 어떻게 수행되는지 보여줍니다.
- 4 프로토타입은 AI 프로젝트를 구현하는 것이 얼마나 어려운지 보여줍니다. 난이도가 예상보다 훨씬 높다면 금방 알 수 있을 것입니다.

이러한 과정을 여러 번 겪은 숙련된 팀이 있기 전까지는 구현하는 데 많은 시간이 걸리는 프로젝트에 매달리지 마세요. 사냥꾼은 사냥감을 한 마리도 잡지 못해서 굶는 것이 아니라 너무 오랫동안 한 마리만 잡으려고 해서 굶게 됩니다.

팁 프로젝트가 예상보다 어렵다면 잠시 멈추고 더 쉬운 프로젝트를 선택하세요. *지옥의 문을 우연히 발견했다면 뒤돌아서서 도망치세요!*

3.4 피해야 할 함정

AI 프로젝트를 실행할 때 피해야 할 몇 가지 일반적인 함정이 있으며, 가장 중요한 함정 중 일부는 다음과 같습니다.

- 감지/분석/반응 루프의 반응 부분을 소유한 조직 액터와 소통하지 않거나, 더 나쁜 경우 AI 프로젝트가 잘 진행 중일 때까지 그들과 전혀 협력하지 않습니다.
- 다른 프로젝트나 조직에서 사용 사례 (및 메트릭)를 이식하기
- 헤드라인을 장식할 만한 유행에 민감한 AI 프로젝트를 실행하기

- 지속 가능한 이점을 줄 수 있는 도구, 어떤 도구든 구입할 수 있다고 믿는 것
- 데이터에 무작위로 분석을 던지면 결과가 나올 것이라고 기대하는 경우
- 분석 결과 대신 '직감'에 따라 실행할 프로젝트를 선택하는 경우

이 섹션에서는 이러한 각각의 함정에 대해 자세히 설명합니다.

3.4.1 비즈니스 팀과의 관계 구축 실패

의사결정 지원 시스템으로 AI를 사용할 때는 단순히 좋은 분석을 제공하는 것만으로는 충분하지 않으며, AI 기반 분석이 권장하는 구체적인 비즈니스 액션을 잘 실행해야 합니다. 즉, 경영진은 분석 결과와 비즈니스 조치 사이의 연결 고리에 집중해야 합니다. 이 섹션에서는 AI 팀이 AI 분석을 기반으로 비즈니스 조치를 취할 조직 내 부서와 좋은 관계를 구축해야 하는 이유를 강조합니다.

팁 분석은 자동차의 속도계와 같습니다. 속도계가 너무 빨리 가고 있다고 알려주면 운전자는 차의 속도를 줄여야 합니다. 프로젝트/조직에서 운전자에 해당하는 사람은 누구인가요?

비전문가는 분석 결과를 잘못 해석할 수 있습니다. 비전문가는 분석의 한계와 분석의 기본 가정이 위반되는 경우를 이해하지 못하는 것이 전형적인 문제입니다. 이러한 문제의 예는 3.3.1절에 연구 질문과 비즈니스 질문이 잘못 정렬된 경우로 나와 있습니다.

저는 개인적으로 여러 조직에서 분석 보고서를 별도의 비즈니스 팀에 넘기는 것을 목격했습니다. 이러한 비즈니스 팀은 데이터 과학자의 의견 없이 비즈니스 조치를 취했습니다. 이것은 항상 실수입니다.

팁 분석 결과에 대응하는 방법을 논의하는 모든 그룹에는 항상 분석 전문 지식이 있어야 합니다. 비즈니스 팀이 분석 결과와 처방을 완전하고 정확하게 이해할 수 있도록 해야 합니다. 분석 결과는 의도된 비즈니스 조치에 비추어 유효해야 합니다.

분석 프로젝트의 리더라면 결과를 전달한다고 해서 업무가 끝난 것이 아닙니다. 분석가의 처방이 성공적으로 실행될 때 당신의 임무는 완료되며, 분석을 실행할 부서와 좋은 업무 관계를 구축해야 합니다. 분석에서 특정 비즈니스 조치를 처방했다면, 여러분이 도와야 할 필요성을 과소평가하지 말고 그 처방을 실행에 옮겨야 합니다.

3.4.2 이식 사용

사람들은 종종 자신을 둘러싼 사람과 조직에서 효과가 있었던 것을 모방하고 싶은 유혹을 받습니다. 결과적으로 *이식 프로젝트*라고 부르는 것을 볼 수 있습니다. 여기서 한 기업이 AI 팀을 구성하기로 결정하고 다른 조직에서 비슷한 프로젝트를 수행했다고 들었던 AI 프로젝트에 착수합니다. 이 섹션에서는 이식이 왜 나쁜 생각인지 설명합니다.

이식 프로젝트의 예는 많습니다. "우리만의 추천 엔진을 만들자" 또는 "고객 피드백에 대한 감성 분석을 해보자"와 같은 프로젝트를 예로 들 수 있습니다. 이러한 프로젝트는 비즈니스 맥락에서 의미가 있는 경우도 있지만, 다른 사람에게서 들었지만 자신의 비즈니스 맥락에서 분석하지 않은 평범한 사용 사례인 경우가 너무 많습니다.

참고 왓지 사람들은 비즈니스 이식이 아닌 실제 이식에 대해 생각할 때 더 많은 상식을 가지고 있습니다. 이웃에게 신장이식이 잘 되었다고 해서 신장이식을 받지 않을 텐데, 왜 사업에서 다르게 행동해야 하나요?

다른 사람에게 효과가 좋았던 프로젝트를 무턱대고 적용하는 대신, 수많은 가능한 AI 프로젝트 중 하나라고 생각하세요. 이 장에 제시된 분석적 접근 방식을 사용하여 어떤 AI 프로젝트를 먼저 시작해야 하는지 결정하세요.

3.4.3 로켓 없이 문샷 (moonshots) 시도하기

세계 최대 기술 기업 중 상당수가 데이터 활용을 통해 돈을 벌었습니다. Google, Microsoft, Baidu와 같은 기업들은 핵심적으로 AI에 크게 의존하여 성공을 거두고 있습니다. 이들은 상당한 연구 역량을 보유하고 있으며 중요한 AI 발전의 흐름을 놓치지 않으려는 기득권을 가지고 있습니다. 이 섹션에서는 조직이 이러한 기업을 맹목적으로 따라가서는 안 되는 이유를 설명합니다.

귀하가 CEO라고 상상해 보세요.

귀하가 연 매출 300억 달러 규모의 회사를 운영하고 있고, AI와 관련된 사업을 하고 있다고 가정해 보겠습니다. 한 걸음 더 나아가 향후 10년 내에 누군가가 강력한 인간 수준의 인공지능—인공지능(AGI)[76]에 근접한 것을 발명할 확률이 1%라고 가정해 봅시다. AGI를 찾는 데 실패하더라도 자율주행 자동차[38]가 위로 상품으로 주어질 수 있습니다. 마지막으로, 경쟁자들이 인공지능에 막대한 투자를 하고 있다는 것을 알고 있습니다.

인공지능에 상당한 돈을 투자하고 뛰어난 연구원을 고용하여 인공지능 지식의 경계를 발전시키시겠습니까? 아니면 AI에 투자하지 않고 다음과 같은 위험을 감수하시겠습니까?

- 귀사의 경쟁업체가 AGI 또는 자율주행차 기술을 개발합니다. 귀사는 더 나은 위치에 있을 수 있었지만 시도조차 하지 못했습니다.
- 귀사의 실수는 앞으로 수년 동안 모든 비즈니스 스쿨에서 가르쳐질 것입니다.

"귀하가 CEO라고 상상해 보세요"라는 사이드바의 논리는 구글, 바이두, Microsoft와 같은 기업에도 적용되지만, 많은 기업이 이러한 기업의 행동에 대한 근거를 이해하지 못한 채 모방하는 안타까운 경향이 있습니다. 네, 대기업들은 AI를 통해 상당한 수익을

창출하고 있습니다. 그들은 또한 AI 연구에 많은 투자를 하고 있습니다. 그들의 AI 연구 노력을 모방하기 전에 "내가 같은 업종에 종사하고 있는가?"라고 자문해 보세요.

귀사가 강력한 AI/AGI[76]에 중요한 무언가를 발명한다면, 이를 수익화할 수 있는 방법을 알고 있습니까? 귀사가 대형 오프라인 소매업체라고 가정할 때, 그 발견을 최대한 활용할 수 있습니까? 아마도 아닐 것입니다. 소매업체의 비즈니스는 Google의 비즈니스와 다릅니다.

거의 확실하게, 귀사가 구체적인 비즈니스 문제를 해결하는 데 AI 기술을 사용한다면 더 많은 혜택을 누릴 수 있을 것입니다. 즉, 가장 똑똑한 연구원들로 채워진 팀과 새로운 AI 지식 습득을 지향하는 프로세스 대신, 조직에는 *기존 AI 기술로 비즈니스 영역에서 수익을 창출하는 방법을 알고 있는 사람들이 필요합니다.*

성공을 어떻게 활용할지 먼저 이해하지 않고 당신보다 더 부유한 조직을 모방해서는 안 됩니다. 대부분의 조직에서 성공의 길은 AI 지식의 경계를 넓히는 데 있는 것이 아니라, *AI 결과를 비즈니스에 어떻게 연결할 수 있는지를 아는 데 있습니다.* 연구가 아닌 애플리케이션에 집중하는 데이터 과학 팀이 필요합니다. 그렇다고 똑똑한 박사를 고용해서는 안 된다는 뜻이 아니라, AI 팀의 리더는 주로 돈을 버는 일에 AI를 적용하는 전문가여야 한다는 뜻입니다.

3.4.4 고급 도구를 사용하여 데이터의 바다를 바라보는 것입니다.

또 다른 일반적인 함정은 AI 또는 빅 데이터 도구를 구입하면 데이터를 살펴보고 인사이트를 찾은 다음 찾은 인사이트를 수익화할 수 있다고 믿는 것입니다. AI를 도입하는 일부 조직은 초기 AI 노력의 주안점을 올바른 도구를 찾는 데 두어야 한다는 태도를 취하기도 합니다. 이 섹션에서는 이것이 왜 피해야 할 함정인지 설명합니다.

팁 수익화가 사소한 것이라면 수익화가 어떻게 일어나는지 설명하는 것도 사소합니다. 즉시 사용 가능한 도구를 구매 시점부터 해당 도구를 사용하여 조직이 수익을 창출하는 엔드포인트까지 적용하는 방법의 세세한 부분까지 완전히 이해할 때까지 공급업체에 자세한 질문을 하세요.

대부분의 비즈니스 업종에서 AI로 수익을 창출하는 것은 전혀 사소한 일이 아닙니다. 많은 도구가 이를 달성하는 데 도움이 될 수 있지만, 이러한 도구가 수익화 문제를 해결할 수 있는 것은 아닙니다. 설치와 실행만으로 수익을 창출할 수 있는 도구가 있다고 하더라도, 이는 상품화된 사용 사례일 뿐입니다. 젠장, 누군가 이미 그렇게 하는 제품을 가지고 있습니다!

팁 비즈니스의 초기 초점은 구체적인 비즈니스 가치를 제공하는 AI 프로젝트를 찾는 데 맞춰야 합니다. 도구는 이러한 프로젝트를 가능하게 합니다.

영업사원이 "대규모 데이터 레이크를 구축하고 데이터 과학자를 투입하라"고 조언할 수도 있습니다. 빅 데이터 집합에 대한 분석만이 제공할 수 있는 예상치 못한 인사이트의 예를 들었을 수도 있습니다. 그러나 이러한 상황은 드물고 예측할 수 없습니다. 이빨 요정 (tooth fairy)만 믿지 마세요. 감지/분석/반응 루프의 분석 부분부터 시작하지 마세요. 프레임워크에서는 항상 반응 부분부터 시작하세요.

경고데이터 깊숙한 곳에 특별한 무언가가 숨어 있을 가능성은 항상 존재합니다. 적절한 분석을 통해 예상치 못한 비즈니스 아이디어를 얻을 수 있고, 이를 통해 엄청난 돈을 벌 수 있습니다. *가능하긴 하지만, 확실히 보장된 것은 아니고 예측 가능한 것도 아니며, 그리고 주요 전략으로 채택해야 할 만큼 충분한 가능성이 있는지에 대한 큰 의문이 있습니다.* 더 나쁜 것은, 당신이 잡으려는 수익성 높은 참다람어가 오히려 심해의 끈적끈적한 괴물로 밝혀질 수도 있다는 것입니다. 낚시 탐험을 떠나는 대신, 예측 가능한 성공을 위해 초기 인공지능 프로젝트를 조직하세요.

3.4.5 단서 대신 직감을 활용하기

AI 프로젝트 실행에 대한 결정은 종종 팀을 흥분시키는 기술적 아이디어에 지나지 않는 우연한 방식으로 이루어집니다. 기반 기술을 경험해보고 싶어서 AI 프로젝트를 실행하는 것은 스포츠카를 사는 것과 같은 기술입니다. 이 섹션에서는 직감을 따르는 것이 왜 좋지 않은 비즈니스 결과를 초래할 수 있는지 설명합니다.

소매 고객의 행동에 대한 비디오 분석

3.2.1절의 소매업체로 돌아가서 제품 믹스를 최적화하고 있다고 가정해 보겠습니다. 판매 동향 예측에 기반한 접근 방식과 고객 행동에 대한 비디오 인식에 기반한 접근 방식 두 가지가 제안되었습니다.

데이터 과학자 모자를 쓴다면 고객 행동에 대한 비디오 인식이 기술적으로 더 흥미로운 프로젝트라는 것을 인정해야 할 것 같습니다. 이 프로젝트는 오늘날 많은 기술 팀을 흥분시킬 것입니다. 매출 예측은 오래된 시계열 분석 방법을 사용할 수 있지만, 이 프로젝트는 최첨단 AI 동영상 인식 기능을 사용합니다.

때때로 이러한 기술적 매력만으로도 팀이 프로토타입을 만들기로 결정할 수 있는데, 제 안의 데이터 과학자는 이러한 충동을 확실히 이해합니다. 그러나 이것은 프로젝트 선택에 대한 전형적인 '직감' 또는 '오, 반짝반짝!' 접근 방식입니다.

이 예에서 왜 이것이 실수인지 알아보려면 3.2.1절에서 일어난 일을 기억해 보세요. 경영진과 이야기를 나누다 보면, 고객 행동에 대한 비디오 분석으로 인한 법적 및 홍보적 파급 효과에 대해 귀사의 비즈니스 입장에서는 불편해한다는 사실을 알게 될 수 있습니다. 귀하의 노력이 기술적으로는 성공적이었다고 해도 채택되지 않을 가능성이 높습니다. 프로토타입을 제작하기 전에 비즈니스 리더와 제안에 대해 이야기하는 데 시간이 오래 걸리지 않습니다.

또한 어떻게든 경영진을 설득하여 AI 프로토타입을 계속 구축할 수 있도록 허용하더라도 성공을 측정하기 위한 비즈니스 지표를 정의하지 못했습니다. 이제 프로젝트 관리에 문제가 생겼습니다. 프로젝트가 진행 중이고 초기 성공을 거두었다고 가정해 보겠습니다. 출시하기에 충분한지 어떻게 알 수 있을까요? 고객 행동을 얼마나 정확하게 인식해야 하나요? 인식 실수가 발생할 수 있으며, 발생한다면 어떤 상황에서 발생하나요? 어떤 실수가 가장 큰 피해를 주나요?

직관에 의존하여 어떤 AI 프로젝트를 먼저 실행할지 선택하는 것에 대해 극도로 회의적이어야 합니다. 3.2장에서는 어떤 프로젝트를 실행하는 것이 가장 좋은지 올바르게 결정하는 데 필요한 단계를 설명했습니다. 첫 번째 프로젝트를 선택할 때 직감이 정답을 제공하기에는 고려해야 할 요소가 너무 많습니다. 프로젝트가 실행 가능한지, 기술적으로 가능한지, 비즈니스 가치가 있는지 확인해야 합니다. 제안된 기술 솔루션의 개요와 난이도뿐만 아니라 비용도 알아야 합니다. 제안된 AI 프로젝트의 모든 속성을 1~2분 동안 문제에 대해 생각하는 것만으로 평가할 수 있는 가능성은 거의 없습니다.

팁 무엇보다도, 모두가 잘 참석하고 중요한 회사 회의에서 모두가 즉시 "좋은 아이디어인 것 같다!"라고 외치는 상황을 경계해야 합니다. 이러한 사회적 상황은 사람들이 그룹 합의를 반증하는 데 필요한 신중한 분석을 수행하도록 장려하는 데 도움이 되지 않습니다. 요컨대, 집단 사고를 조심하세요.

하지만 우리는 MVP 접근법을 사용하고 있습니다!

일부 팀은 소프트웨어 프로젝트를 개발할 때 애자일 방식을 사용하거나 린 스타트업(Lean Startup)[28] 방법론을 사용합니다. 린 스타트업 방법론에서는 프로젝트를 고객에게 피드백을 받을 수 있는 작은 작업 덩어리로 나누도록 권장합니다. 이 작업의 덩어리를 *최소 실행 가능한 제품(MVP)*이라고 합니다. 린 스타트업 방법론의 일부는 MVP가 고객이 원하는 것이 아니라고 판단되면 다른 것을 시도할 수 있다는 것입니다—소위 *피벗*이라고 합니다.

일부에서는 MVP를 구축하고 있기 때문에 초기 AI 아이디어를 빠르게 선택하여 고객에게 보여주고 고객의 반응을 확인해야 한다고 주장할 것입니다. *그러지 마세요!*

MVP를 사용하면 실제 제품에 많은 이점이 있으며, CLUE는 린스타트업 전략과 잘 결합할 수 있습니다. 하지만 MVP만으로는 CLUE가 해결하고자 하는 것과 같은 문제를 해결할 수 없습니다.

- 직감에 따라 MVP를 선택하는 경우, 비즈니스가 분석 솔루션을 채택할 의향과 능력이 있는지 알기 전에 프로젝트를 시작한 것입니다.
- MVP가 잘못된 길을 가고 있다는 것을 더 빨리 보여줄 수는 있지만, 처음부터 잘못된 길을 가고 있는 것입니다.
- 감으로 할 수 있는 분석에 대해 생각했다면(감지/분석/반응 루프에서 반응 부분부터 시작하는 대신), *분석 플랫폼*을 하고 있는 것입니다. 귀하는 귀하가 하는 분석이 귀하의 비즈니스가 어떻게든 구현할 수 있는 결과로 나타나길 바라며 기도하고 있습니다.

MVP는 AI 프로젝트를 선택하고 실행하는 데 직감 접근 방식을 홍보하는 유효한 변명이 아닙니다. MVP는 잘못된 길을 가고 있다는 것을 알아내는 데 드는 비용을 줄여주지만, 이는 실패의 대가를 줄이는 것에 불과합니다. 피벗 능력이 있다고 해서 무작위적인 AI 아이디어로 우연히 실행 가능한 무언가를 발견하길 바라며 프로젝트를 마구잡이로 실행할 수 있는 변명은 아닙니다.

CLUE 접근 방식은 MVP 및 린 스타트업과 통합될 수 있으며 호환됩니다. CLUE 분석의 C 부분은 첫 번째 AI 프로젝트를 선택하는 것이며, 이러한 프로젝트는—직감이 아닌 분석에 기반한 MVP가 될 수 있습니다.

오늘날 AI 프로젝트 실패의 가장 큰 원인은 기술적인 문제일 수 있습니다. 하지만 기술적으로 성공한 프로젝트 중에도 비용을 지불한 기업에서조차 사용하지 않는 프로젝트가 너무 많습니다. 이러한 AI 프로젝트는 애초에 시작하지 말았어야 했고, 대개 그 가치에 대한 직감이 잘못되었기 때문에 시작되었습니다.

3.5 연습

다음 질문은 각각 구체적인 비즈니스 시나리오를 제시한 다음 해당 시나리오에 대한 후속 질문을 던집니다. 다음 질문에 답해 주세요.

질문 1: 출판 업계에서 일하고 있는데 인쇄본, 전자책, 오디오북을 동시에 출시하는 것이 더 좋은지 아니면 차례로 출시하는 것이 더 좋은지 궁금하다고 가정해 보겠습니다. 또한 인쇄된 책이 먼저 출시되도록 배송이 단계적으로 이루어질 경우 다른 형식의 책을 출시하기까지 얼마나 기다려야 하나요? 이 설정 내에서 다음 질문에 답하세요. "어떤 비즈니스 지표를 사용해야 하나요?"

질문 2: 귀하가 비즈니스 리더라면 비즈니스 질문과 이를 측정할 적절한 지표를 정의하세요. 조직에 직접 적용할 수 없는 몇 가지 가상 시나리오(예: 자선 활동과 관련된 시나리오)에 대해 생각해 보세요. 비영리 단체를 운영하면서 취할 수 있는 조치에 대해 생각해 보세요. 3장에서 소개한 기법을 사용하여 첫 번째 가상의 비즈니스 질문과 성공을 측정하는 데 사용할 지표를 선택합니다.

질문 3: 이전 연습에서 비즈니스 질문을 파악했다면, 선임 AI 전문가와 함께 점심을 먹으며 다음과 같이 이야기해 보세요. 연구 질문을 어떻게 공식화할지 물어보세요. 3장에 설명된 프로세스를 사용하여 답변이 취하려는 비즈니스 조치를 뒷받침하는지 여부를 확인합니다. 그리고 점심을 먹는 동안 그러한 연구 질문에 답할 수 있는 데이터 세트를 어떻게 찾을 수 있을지에 대해 이야기하세요. 그 데이터 집합을 구할 수 있다고 생각하시나요?

요약

- 새로운 비즈니스에 도입된 인공지능은 풍부한 사냥터에 속합니다. 모든 자원을 묶어두고 실패하면 파멸하는 어려운 프로젝트부터 쫓아가지 마세요. 대신 비즈니스 가치가 크고 빠르게 완료할 수 있는 간단한 프로젝트부터 시작하세요.
- CLUE를 사용하여 AI 프로젝트를 선택하고 정리하세요. CLUE(그림 3.4)의 C 부분을 사용하면 구현할 수 있는 실행 가능한 AI 프로젝트 목록을 작성하고 프로젝트의 규모와 가치를 추정할 수 있습니다.
- AI가 답해야 하는 비즈니스 질문은 연구 질문을 정의하여 기술적 형식으로 변환해야 합니다. 번역이 잘못되면 비즈니스 결과를 망칠 수 있습니다. 프로젝트를 시작하기 전에 시나리오 기반 테스트를 통해 연구 질문을 점검하세요.

- 비즈니스 메트릭을 사용하여 AI 프로젝트의 진행 상황을 측정하세요. 비즈니스 지표는 프로젝트와 조직에 맞게 사용자 정의해야 합니다. 성공을 측정할 비즈니스 지표가 없다면 AI 프로젝트를 시작하지 마세요.
- 실패할 경우 빨리 실패할 수 있도록 AI 프로젝트를 구성하세요.
- 개념 증명부터 시작하세요. 프로젝트가 생각보다 어렵다면 프로젝트를 중단하고 대신 더 쉬운 프로젝트를 진행하세요. 목표는 *다음 성공까지 걸리는 시간을 최적화하는 것입니다.*
- AI 프로젝트를 실행할 때 피해야 할 일반적인 함정이 있습니다. 관련 비즈니스 리더와의 관계 구축 실패, 사용 사례 이식, '문샷' 프로젝트를 채택했지만 로켓을 놓친 경우, 무작위 도구(또는 무작위 분석)에 너무 많은 희망을 거는 경우, 직감을 CLUE로 대체하는 경우 등이 이에 해당합니다.

ML 파이프라인 분석하기

이 장에서 다루는 내용

- 골화되기 전에 올바른 ML 파이프라인을 보유하고 있는지 판단하기
- AI 프로젝트에서 리소스 절약하기
- ML 파이프라인에서 MinMax 분석 수행하기
- MinMax 분석 결과 해석하기

ML 프로젝트의 비즈니스 목표를 달성할 수 없는 잘못된고 부적절한 ML 파이프라인을 보유하지 않도록 하는 것이 중요합니다. ML 파이프라인에 대한 가장 중요한 비즈니스 질문은 "이 파이프라인이 비즈니스 측면에서 얼마나 잘 작동하는가?"입니다. 이 장에서는 ML 파이프라인을 분석하고 이 질문에 대한 답을 얻는 방법을 보여줍니다.

비즈니스 측면에서 ML 파이프라인이 얼마나 잘 작동하는지 알고 나면, 이를 분석하여 비즈니스 목표를 달성할 수 있는지 판단할 수 있습니다. 분석 이름

MinMax 분석을 해야 합니다.¹ 프로젝트 초기에 MinMax 분석을 수행할 수 있으며, 각각 다른 질문에 답하는 두 부분으로 구성됩니다.

- *MinMax 분석의 Min 부분* —내일 AI 프로젝트를 출시하는 데 여러분의 삶이 달려 있다면, 가장 간단한 ML 파이프라인 구현은 얼마나 잘 수행될까요? 그러한 구현이 비즈니스 목표를 달성할 수 있나요?
- *MinMax 분석의 최대 부분*—현재 파이프라인의 구조로 얻을 수 있는 최상의 결과는 무엇인가요? 파이프라인의 각 단계에서 가능한 최상의 구현을 위해 노력하기 전에 해당 구현이 비즈니스 목표를 달성할 수 있나요?

실무자로서 우리는 이러한 질문에 대한 답을 기술적인 지표(예: 정확도 99.9543%)가 아닌 비즈니스 측면에서 찾아야 합니다.

6.1장에서는 ML 파이프라인 분석에 관심을 가져야 하는 이유를 알아보고, 6.2장에서는 ML 파이프라인에 투입되는 리소스를 절약하는 방법을, 6.3장에서는 비즈니스 문제를 해결할 수 있는 올바른 파이프라인을 보유하고 있는지 판단하기 위해 MinMax 분석을 사용하는 방법을 살펴봅니다. 6.4장에서는 MinMax 분석 결과를 해석하는 방법을, 6.5장에서는 MinMax 분석을 수행하는 방법을 설명합니다. 마지막으로 6.6장에서는 MinMax 분석에 대한 자주 묻는 질문을 소개합니다.

6.1 ML 파이프라인 분석에 관심을 가져야 하는 이유

이제 AI 시스템은 부분의 합보다 전체가 더 중요하며, ML 파이프라인은 시스템의 동작을 결정하는 주요 소프트웨어 아티팩트 중 하나라는 것을 알고 계실 것입니다. ML 파이프라인은 빠르게 고착화되며, 잘못된 ML 파이프라인을 고착화하도록 허용하는 것은 비용이 많이 드는. 그렇기 때문에 ML 파이프라인 관리는 데이터 중심으로 이루어져야 합니다. ML 파이프라인을 분석하면 데이터를 얻을 수 있습니다.

모든 프로젝트 관리 의사 결정은 시간 제약 하에서 이루어집니다(그림 6.1 참조). 프로젝트가 진행 중일 때는 매일 비용과 기회가 모두 발생하며, 비용을 계산할 때는 무언가를 변경하는 데 드는 비용과 현재 과정을 유지하는 데 드는 비용 등 모든 비용을 고려해야 합니다.

경고 무행동은 현재 코스를 유지하기로 한 결정이며 때로는 잘못된 행동을 취하는 것만큼 위험할 수 있습니다.

프로젝트에서 사용하는 ML 파이프라인의 형태는 프로젝트 관리 및 소프트웨어 아키텍처에서 가장 중요한 결정 중 하나입니다. 잘못된 ML 파이프라인을 선택하면 여러분과 여러분의 지갑이 알게 될 것입니다. 하지만 그때는 이미 너무 늦습니다. 프로젝트 초기에 ML 파이프라인을 분석하면 올바른 파이프라인을 사용하고 있다는 확신을 가질 수 있습니다. 비즈니스 및 업계에서 팀에 유용하려면 이러한 분석이 다음을 수행해야 합니다.

- 수행 방법을 쉽게 배울 수 있어야 합니다.
- 저렴한 비용으로 수행
 - 직관적으로 해석할 수 있는 결과 제공

¹ 게임 이론[114]의 미니맥스 알고리즘에 익숙하다면 미니맥스 분석과 미니맥스 알고리즘을 혼동하지 말아야 하는데, 완전히 다른 개념입니다.

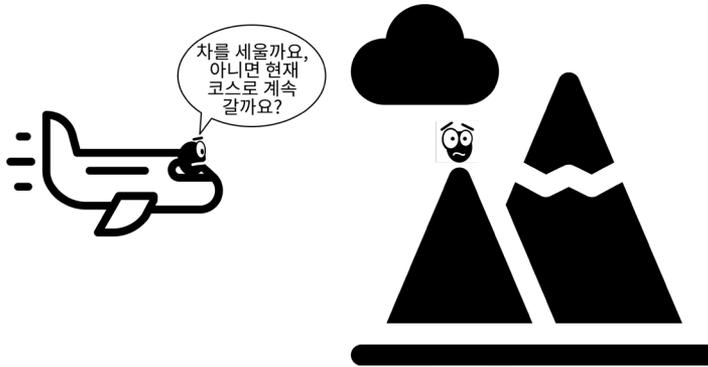


그림 6.1 프로젝트 관리 의사 결정은 시간 제약 하에 이루어집니다. 일부 프로젝트는 이 그림의 비행기와 같아서 추락하기 전에 항로를 수정해야 합니다. 아무것도 하지 않는 것은 때때로 잘못된 행동을 취하는 것만큼이나 위험할 수 있습니다.

- 반환하는 정보에서 합리적인 수준의 신뢰도를 제공해야 합니다.

이 장에서는 이 네 가지 요건을 충족하는 분석 방법을 보여드리겠습니다. 다음 장에서는 또 다른 방법을 소개합니다. 리더는 팀에게 어떤 유형의 분석을 수행하도록 요청하고 분석 결과를 해석하는 방법을 배워야 합니다.

팁 분석을 수행하려면 *저렴해야 합니다*. 분석 비용(질문하는 데 드는 비용)과 답을 아는 것의 가치 사이의 균형을 맞춰야 합니다. 이 균형은 D. W. 허바드[75]가 *완벽한 정보의 기대값*[79]이라고 부르는 것입니다.

머신러닝 파이프라인을 분석하는 것은 각 AI 프로젝트와 각 프로젝트에 대해 고려하는 각 머신러닝 파이프라인에 대해 반복적으로 수행해야 하는 작업입니다. 기술을 잘 모르는 독자라도 지금 시간을 투자하여 분석이 어떻게 작동하는지 이해하세요. 이렇게 이해하면 현재 진행 중인 AI 프로젝트뿐 아니라 앞으로 진행할 프로젝트에서도 최선의 결정을 내리는 데 도움이 됩니다. 8장에서는 여러분이 배우게 될 방법들이 단순히 ML 파이프라인을 분석하는 것보다 훨씬 더 광범위하게 적용된다는 것을 보여드리겠습니다.

주식 시장과의 유사점

시간적 제약과 제한적이고 불완전한 정보로 의사결정을 내리는 또 다른 분야가 있습니다. 그 분야는 바로 투자입니다.

세계 최대 헤지펀드를 만든 레이 달리오가 불확실한 상황에서 의사결정을 내리는 방법에 대해 어떤 이야기를 하는지 들어보겠습니다[29].

*'수정구슬 곁에 사는 사람은 갈아놓은 유리를 먹을 운명이다'*라는 말은 제가 그 시절에 많이 인용했던 말입니다. 1979년에서 1982년 사이에 저는 가장 중요한 것은 미래를 아는 것이 아니라는 것을 깨닫기 위해

(계속)

충분히 많은 잔을 마셨습니다.—그것은 각 시점에 이용 가능한 정보에 적절히 대응하는 방법을 아는 것이었습니다.”

조직을 위한 AI 역량을 구축할 때 많은 의사결정을 내리게 됩니다. 목표는 확률의 균형을 유리하게 기울이는 것입니다.

6.2 자원 절약: CLUE의 E 부분

사용 중인 ML 파이프라인이 장기적으로 사용하기에 적합한 파이프라인인지 어떻게 알 수 있나요? 현재 사용 중인 ML 파이프라인을 계속 사용해야 할까요, 아니면 노후화되기 전에 다른 파이프라인으로 교체해야 할까요? 파이프라인의 어느 부분을 먼저 개선해야 할까요? 데이터를 기반으로 이러한 결정을 내려야 하며, 이 섹션에서는 이러한 질문에 답할 수 있는 도구에 대한 개요를 제공합니다. 이러한 도구는 다음과 같습니다.

- *MinMax 분석* —비즈니스 목표를 달성하는 데 적합한 ML 파이프라인을 보유하고 있는가?라는 질문에 답합니다.
- *민감도 분석* —"ML 파이프라인의 한 단계 구현을 수정하면 비즈니스 결과가 얼마나 달라질까요?"라는 질문에 대한 답변

이 장에서는 MinMax 분석에 집중하고, 7장에서는 민감도 분석에 대해 설명합니다. 이 두 가지 분석을 함께 사용하면 개발 리소스를 올바른 ML 파이프라인과 해당 파이프라인의 올바른 단계에 할당할 수 있습니다.

ML 파이프라인에 집중하는 것이 프로젝트의 논리적인 다음 단계입니다. 지금까지 CLUE 프로세스의 *고려*(사용 가능한 비즈니스 조치), *연결*(연구 질문 및 비즈니스 문제), *이해*(비즈니스 맥락에서의 기술적 답변) 부분을 적용했습니다. 이 프로세스의 이러한 부분을 수행하면 다음을 보장할 수 있습니다.

- 귀사의 AI 프로젝트가 비즈니스에 실질적으로 영향을 미칠 수 있습니다. 프로젝트에서 감지/분석/반응 루프를 문제에 적용할 수 있는 방법이 있고, 반응 부분이 가능하다는 것을 알고 있습니다. 3장에서는 CLUE의 C 부분을 설명하여 이 내용을 다루었습니다.
- 귀사의 AI 프로젝트는 사용하려는 ML 파이프라인을 정의합니다.

인공지능 프로젝트를 구축하는 동안 부족한 자원을 *경제화*하는 것이 여전히 필요합니다. CLUE의 E 부분을 경제화하려면 비즈니스 문제 해결을 위해 합리적인 ML 파이프라인을 사용하고 있는지 확인해야 합니다. 또한 ML 파이프라인에서 개선해야 할 최적의 단계가 무엇인지 결정해야 합니다.

MinMax 분석은 "내가 올바른 파이프라인을 보유하고 있는가?"라는 질문에 대한 답을 제공합니다. 현재 ML 파이프라인에서 기대할 수 있는 최상의 비즈니스 결과가 무엇인지 알려줍니다. 현재 만들고 있는 ML 파이프라인이 비즈니스 목표를 지원할 수 있는 파이프라인인지 알려주며, ML 파이프라인이 골화되기 전에 이를 알려줍니다.

비즈니스 문제를 완전히 해결하는 ML 파이프라인을 이미 보유하고 있지 않다면, 개선이 필요할 가능성이 높습니다. 리소스는 한정되어 있으며, 최적의 프로젝트 결과를 얻으려면 리소스를 최적으로 할당해야 합니다. 민감도 분석 [115-117]은 투자 수익을 극대화하기 위해 다음에 어떤 단계의 ML 파이프라인에 투자해야 하는지에 대한 질문에 대한 답을 제공합니다. 그림 6.2는 프로젝트를 MinMax 및 민감도 분석과 통합하는 방법을 보여줍니다.

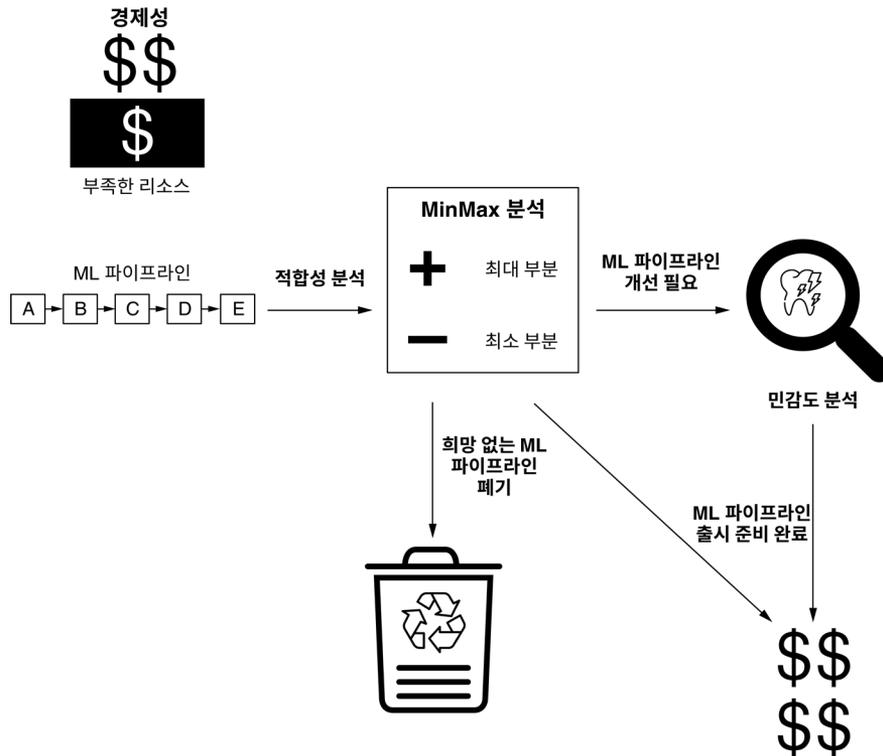


그림 6.2 CLUE 프로세스의 이코노마이즈 부분입니다. MinMax 및 민감도 분석을 통해 비즈니스 실행 가능한 ML 파이프라인의 적절한 부분에 노력을 적용할 수 있습니다.

그림 6.2는 먼저 MinMax 분석을 적용하여 ML 파이프라인이 이미 실행 가능한 비즈니스 결과를 생성하고 있는지 확인합니다. 그렇지 않다면 파이프라인을 더 개선해야 할 필요가 있을까요? 아니면 본질적으로 그러한 결과를 생성할 수 없는 것일까요?

파이프라인이 절망적이라면, 그 파이프라인을 폐기하고 다른 파이프라인(또는 다른 AI 프로젝트를)을 시도합니다. 일단 해결하기 위해 적절한 ML 파이프라인을 사용하고 있다는 것을 알게 되면

비즈니스 문제를 해결하는 데 적절한 ML 파이프라인을 사용하고 있다고 판단되면 민감도 분석을 사용하여 비즈니스 결과에 만족할 때까지 파이프라인을 반복적으로 개선합니다.

그림 6.2의 모든 이전 단계에서는 데이터 과학, 데이터 엔지니어링 및 비즈니스 팀의 긴밀한 협력이 필요합니다. 파이프라인 분석 작업을 수행하는 팀은 처음에 세 영역의 대표자로 구성되어야 합니다. 목표는 비즈니스 메트릭과 기술 메트릭 간의 연결에 대한 공통된 이해가 나타나는 지점에 도달하는 것입니다. ML 파이프라인을 관리하는 팀은 관리 및 엔지니어링 리더(데이터 과학자 및 데이터 엔지니어 포함)로 구성되어야 합니다. 이 팀을 구성하는 목표는 데이터 과학 파이프라인의 기술적 특성을 지속적으로 공유하고 이러한 특성에 따라 리소스를 배포하도록 안내하는 것입니다.

팁 ML 파이프라인을 분석하고 개선하는 이러한 접근 방식은 반드시 반복적으로 이루어져야 합니다. 개념 증명(POC)이 아직 진행 중일 때 분석의 초기 반복을 수행할 수 있습니다. 애자일[118,119] 또는 반복적 소프트웨어 개발 방법론을 사용하는 경우, 분석 작업을 프로젝트의 첫 번째 반복의 일부로 간주할 수 있습니다.

6.3 MinMax 분석: 올바른 ML 파이프라인을 보유하고 계신가요?

모든 ML 파이프라인에서 항상 수행해야 하는 기본 분석인 MinMax 분석은 "주어진 구조의 ML 파이프라인이 달성할 수 있는 최상의 결과와 최악의 결과는 무엇인가?"라는 질문에 대한 답을 제공합니다. 이 섹션에서는 MinMax 분석에 대한 개요를 제공합니다.

참고 용어 *MinMax 분석을 사용하지만* 이러한 유형의 분석을 *최우수 사례/최악 사례 분석*이라고도 한다는 것을 알고 있습니다. 섹션 6.6.4에서 이 용어에 대해 자세히 설명합니다.

MinMax 분석은 파이프라인의 수명 초기 단계에서 달성할 수 있는 예상 결과 범위를 보여줍니다. "이 ML 파이프라인을 계속 사용해야 하는가?"라는 질문에 대해 분석은 "예", "아니오" 또는 "아마도"로 대답합니다. 올바른 ML 파이프라인을 보유하고 있다는 것을 알면 잘못된 ML 파이프라인을 구축하는 데 많은 시간과 비용을 소비하지 않아도 됩니다.

정의 MinMax 분석은 ML 파이프라인이 이미 비즈니스 목표를 달성하고 있는지, 목표를 달성하기 위해 개선이 필요한지, 아니면 목표를 달성할 수 없는지 판단하는 분석 유형입니다.

MinMax는 ML 파이프라인의 구조를 살펴보고 비즈니스 실행 가능성을 평가하며, 분석된 ML 파이프라인의 경우 Min 파트에서 질문에 대한 답을 제공합니다: "내가 만들 수 있는 가장 간단한 구현을 출시하면 비즈니스 결과는 어떻게 될까?"라는 질문에 답합니다. 최대 부분은 이 질문에 대한 답변입니다: "최상의 구현으로 얻을 수 있는 비즈니스 결과는 무엇인가?"라는 질문에 답합니다.

팁 무언가를 시도하기 전에 항상 "내가 성공할 경우 얻을 수 있는 최선은 무엇이며, 이를 알면 시도해 볼 가치가 있는가?"라고 질문하는 것이 좋습니다. MinMax 분석의 Max 부분은 이 질문에 대한 답을 제공합니다.

최소 최대 분석을 수행하려면 ML 파이프라인 구조와 수익 곡선이 필요합니다. 수익 곡선을 사용하면 기술 메트릭을 비즈니스와 연관시키는 방법인 비즈니스 메트릭이 생깁니다. 임계값(도달해야 하는 비즈니스 메트릭의 최소 수준)도 있습니다. 그림 6.3은 최소 최대 분석의 개요를 보여줍니다.

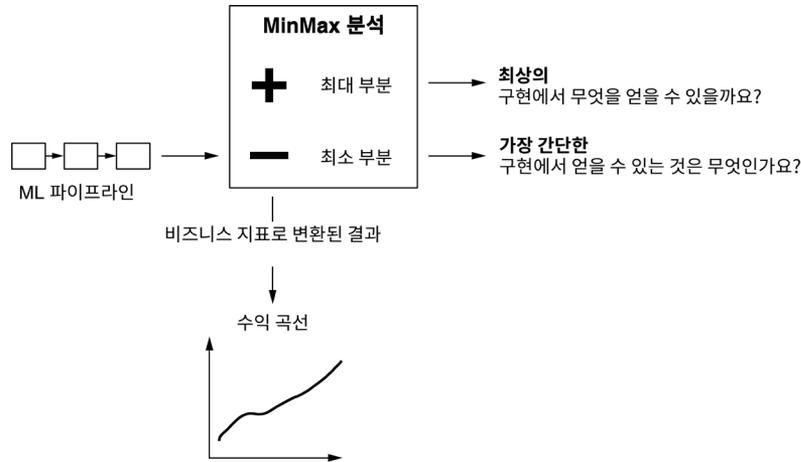


그림 6.3 MinMax 분석은 최소 부분(-)과 최대 부분(+)으로 구성됩니다. 수익 곡선을 사용하여 기술 지표를 예상 비즈니스 결과로 변환합니다. 이 분석의 결과에 따라 ML 파이프라인의 실행 가능성이 결정됩니다.

높은 수준에서 MinMax 분석은 다음과 같이 구성됩니다.

- 1 해결하려는 문제에 대해 ML 파이프라인이 얼마나 잘 수행되는지 측정합니다. 기술 메트릭을 사용하여 ML 파이프라인을 측정합니다.
- 2 ML 파이프라인의 산출물을 비즈니스 용어로 표현합니다. 수익 곡선을 사용하여 측정된 결과가 비즈니스 측면에서 어떤 의미인지에 대한 이해(CLUE의 U)를.
- 3 앞의 두 단계를 Max 부분에 대해 한 번, Min 부분에 대해 한 번씩 두 번 더 반복합니다. Max 부분은 ML 파이프라인의 모든 단계에서 가능한 최상의 구현을 사용합니다. Min 부분은 모든 단계에서 가장 간단한 구현을 사용합니다.

분석을 수행한 후에는 비즈니스 측면에서 가장 간단한 ML 파이프라인이 무엇을 달성할 수 있는지 알 수 있습니다. 또한 현재 ML 파이프라인의 최상의 구현이 무엇을 달성할 수 있는지 이해할 수 있습니다. 최선의 방법으로는 비즈니스를 실행하기에 충분하지 않다면, ML 파이프라인을 폐기해야 할 때라는 것을 알게 됩니다.

다음 섹션에서는 최소값 분석을 수행하는 방법을 보여줍니다. 먼저 이 분석에 사용할 수 있는 예제 ML 파이프라인을 소개한 다음 결과를 해석하는 방법을 보여드리겠습니다.

6.4 MinMax 분석 결과를 해석하는 방법

MinMax 분석은 "현재 ML 파이프라인을 계속 개발할 가치가 있는가?"라는 질문에 대한 답을 제공합니다. 따라서 모든 팀 리더는 MinMax 분석 결과를 해석하는 방법을 알고 있어야 합니다. 이 분석을 수행하는 것은 분석을 직접 수행하거나 세부 사항을 더 잘 이해하려는 일부 독자들만 관심을 가질 수 있습니다. 따라서 먼저 MinMax 분석 결과를 해석하는 방법을 보여드리고, 이후 섹션에서 분석을 수행하는 방법을 배우게 될 것입니다.

이 섹션에서는 먼저 실제 비즈니스 문제를 해결하는 ML 파이프라인의 구체적인 시나리오를 제공합니다. 그런 다음 이 시나리오에서 ML 파이프라인을 계속 개발해야 하는지 여부에 대한 구체적인 결정을 내리도록 요청합니다. 이러한 예는 분석 결과가 ML 파이프라인이 비즈니스 문제를 해결하는 데 적절하거나 부적절할 뿐만 아니라 비즈니스 문제를 해결하기 전에 개선해야 할 필요성을 알려줄 수 있음을 강조합니다. 마지막으로, MinMax 분석을 해석하는 예제를 보고 나면 MinMax를 수행하기 위한 규칙을 요약하여 제공합니다.

세부 사항 이해하기

귀사의 기술이 비즈니스 문제를 해결할 수 있는지 결정하는 것은 본질적으로 여러 분야에 걸친 문제입니다. 재정적 영향과 비즈니스 및 도메인 규칙을 고려하지 않고는 비즈니스에서 의사 결정을 내릴 수 없으므로 비즈니스 문제의 세부 사항을 이해해야 합니다. 먼저 기술 솔루션에 대한 기본적인 이해가 필요합니다. 그런 다음 해당 솔루션이 수익성이 있는지 결정해야 합니다.

결과적으로 MinMax 분석에 대한 현실적인 시나리오는 이 책의 다른 시나리오보다 조금 더 복잡할 것입니다. AI 프로젝트에서 막대한 비용을 절감하는 가장 쉬운 방법은 잘못된 ML 파이프라인을 막대한 비용이 들기 전에 포기하는 것이므로, 분석의 세부 사항을 이해하기 위해 노력할 가치가 있습니다.

6.4.1 시나리오: 스마트 주차 미터기를 위한 ML 파이프라인

해결해야 하는 비즈니스 문제의 모든 세부 사항과 시스템이 내리는 다양한 의사 결정의 재무적 영향이 포함된 구체적인 비즈니스 시나리오에 대해 이야기해 보겠습니다. 먼저 문제의 비즈니스 측면을 설명한 다음 문제를 해결하는 ML 파이프라인의 윤곽을 보여드리겠습니다.

귀사는 스마트 주차 미터기를 만듭니다. 주차 미터기에는 번호판 사진을 찍는 데 사용할 수 있는 카메라가 있습니다. 고객은 도시입니다. 이 주차 미터기에 대한 많은 계획과 가능성이 있지만, 당분간은 누군가 방문을 초과하면 자동 과태료를 부과합니다.

시에서는 주로 과태료 수입이 아닌 주차 규정 준수에 관심이 있습니다. 이 시나리오에서는 시에서 미터기의 초기 설치 비용을 지불하고 연간 초과 체류 횟수가 50회 미만인 미터기에 대해 연간 보너스를 제공하기로 합의했습니다. 보너스는 그 자체로 충분히 크므로 귀사는 이 포상금이 스마트 주차 미터기와 관련된 시의 유일한 수입원이 되는 것에 만족할 수 있습니다.

스마트 주차 미터기의 경제성을 고려할 때, 귀사는 과태료 부과 건당 3달러의 수익을 얻고, 잘못된 과태료를 부과할 때마다 20달러를 시 당국에 지불해야 합니다. 스마트 주차 미터기 사업이 회사에 실용적이라면 연간 \$100(미터당) 또는 시로부터 보너스를 받는 것이 바람직합니다. 현재 가장 좋은 추정치는 각 주차 구역에 대해 연간 최소 300건의 초과 체류가 발생하며, 모든 과태료가 올바르게 부과될 경우 미터당 최대 수익은 \$900입니다.

참고 1장에서 학습했듯이, 인공지능 기술의 도입으로 인해 추측의 현실이 바뀔 수 있는 경우 과거 데이터를 미래 데이터로 추정하지 않도록 주의해야 합니다. 과태료를 부과하기 시작한 후에도 같은 수의 초과 체류가 계속 발생하나요? 아니면 주차 초과가 즉시 사라질까요?

안전한 편을 위해 초과 숙박 횟수가 줄어든 것이라고 가정하기로 결정합니다. 연간 300회를 사용하는 대신 연간 최소 51회의 초과 숙박이 있을 것이라고 가정합니다. 초과 숙박이 50건 이하인 경우 도시에서 헤지하므로 연간 51건의 초과 숙박이 최악의 시나리오입니다. 그림 6.4는 사용할 간단한 ML 파이프라인을 보여줍니다.

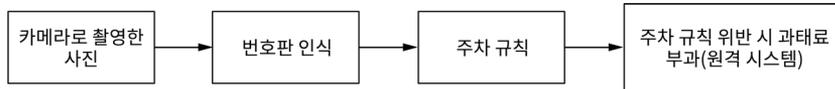


그림 6.4 번호판 사진을 찍고, 주차가 합법적인지 확인하고, 합법적이지 않은 경우 과태료를 부과하는 자동 주차 미터기를 위한 간단한 ML 파이프라인입니다. 이 장의 예제에서는 이 파이프라인을 분석에 사용합니다.

그림 6.4에 표시된 ML 파이프라인은 카메라와 이미지 인식을 사용합니다. 그러나 현실 세계의 실제 물리적 디바이스로 작업하기 때문에 몇 가지 복잡한 문제가 있습니다.

- 카메라 이미지의 품질은 시간대와 날씨에 따라 달라집니다. (태양, 빛, 비에 의한 반사가 모두 요인입니다.)
- 범칙금은 셀룰러 네트워크를 사용하여 발행되므로 주차 미터기에는 셀룰러 모뎀이 있습니다. 이 예에서는 파이프라인의 발권 단계가 항상 완벽하게 작동한다고 가정합니다.²

² 실제로는 통신 오류나 발권 시스템 문제로 인해 일부 발권이 실패할 수 있습니다. 이 예제를 단순화하기 위해 이러한 문제는 무시하겠습니다.

주차 규칙은 처음에 설명한 것보다 조금 더 복잡합니다. 실제로 그림 6.4에 표시된 ML 파이프라인에 이러한 주차 규칙을 지원하기 위한 규칙 엔진이 필요할 정도로 복잡합니다.

참고 이 장에서는 MinMax 분석의 기본 사례를 다루고 있는데, 기본 사례에서는 수익 곡선이 기술 지표의 값이 높을수록 비즈니스 지표의 값이 항상 높아지는 구조라고 가정해도 안전합니다. 섹션 6.5.5에서는 이 가정이 충족되지 않는 경우 수행해야 할 작업을 보여줍니다.³

어떤 경우에는 분석의 최소 또는 최대 부분만을 기반으로 의사 결정을 내릴 수 있습니다. 다른 경우에는 결정을 내리기 전에 분석의 Min 및 Max 부분을 모두 검토해야 합니다.

참고 MinMax 분석의 가상 결과 집합을 보기 전에 주차 미터기가 수익을 내기 위해 필요한 임계값은 각 미터기에서 연간 100달러 이상이어야 실용적이라는 점을 기억하세요. 이 기준은 최악의 초과 숙박 사례인 연간 51회의 초과 숙박이 발생한다고 가정했을 때 시에서 지급하는 보너스를 받을 수 있을 만큼 적은 횟수가 *아니라*는 가정에 근거한 것입니다. (뉴욕시는 50건 이하의 위반에 대해 비용을 지불합니다.)

이 예제의 첫 번째 시나리오에서는 가장 간단한 측정기를 구성하고 변호판의 비디오 인식을 가장 간단하게 구현하면 97%의 인용이 정확하다는 것을 알 수 있습니다. 안타깝게도 3%는 틀릴 것입니다. 수익 곡선을 기반으로 데이터 과학자가 MinMax 분석의 Min 부분을 완료했으며 미터당 예상 수익이 연간 \$117.81(연간 51건의 불법 주차 과태료에 대해)이라는 것을 발견했다고 말합니다. 임계값이 연간 100달러에 불과했기 때문에 ML 파이프라인을 실행할 수 있으며, AI 시스템이 "있는 그대로" 형태의 파이프라인에서 수익을 창출할 수 있다는 것을 알 수 있습니다. 현재 보유하고 있는 ML 파이프라인이 이미 비즈니스 목표를 지원하기에 충분하기 때문에 MinMax의 Max 부분에 대해 걱정할 필요가 없습니다.

릴리스할 것인가, 말 것인가?

MinMax 분석의 Min 부분에서 현재 ML 파이프라인이 이미 임계값을 초과하는 값을 생성하고 있는 것으로 나타나면 제품을 릴리스하도록 선택할 수 있습니다. 또는 다양한 비즈니스상의 이유로 제품을 릴리스하지 않기로 결정할 수 있습니다. 이제 더 많은 분석이 필요할 수 있는 비즈니스 결정입니다.

또 다른 고려 사항으로, 주차 미터기에는 비즈니스 결정을 복잡하게 만들 수 있는 부분이 있습니다. 예를 들어, 미터기를 한 번 배치하면 카메라를 쉽게 교체할 수 없습니다. 그러나 이미 최고의 카메라를 보유하고 있고 미터기의 소프트웨어를 원격으로 업데이트할 수 있다면 미터기를 기존 소프트웨어 시스템으로 취급할 수 있습니다. 이 경우 즉시 출시하고 필요한 경우 향후 더 나은 비전 인식 시스템을 구축해야 합니다.

³ 청중의 데이터 과학자 - 수익 곡선은 단조롭지만, 기술 지표와 비즈니스 지표 사이의 관계가 반드시 선형일 필요는 없습니다.

이제 다른 시나리오를 살펴봅시다. 누군가 주차 미터기 자체에 카메라를 설치하는 대신(번호판에서 불과 몇 인치 떨어진 곳에 설치) 주차장 근처 건물 옥상에 있는 보안 카메라를 재사용하여 주차된 모든 차량을 관찰하기로 결정했다고 가정해 보겠습니다. 이러한 시스템을 사용하면 카메라가 장착된 새로운 물리적 주차 미터기 장치를 설치할 필요도 없습니다.

시에서는 카메라가 달린 주차 미터기를 새로 설치하는 데 드는 비용을 절약할 수 있기 때문에 이 아이디어가 마음에 든다면 이 시스템을 사용할 것을 의무화했습니다. 과태료 비용 및 \$100 값 임계값과 같은 다른 모든 매개 변수는 동일하게 유지됩니다. 회사는 이러한 조건 하에서 여전히 시와 거래하기를 원한다고 결정합니다.

그런 다음 옥상에 있는 기존 보안 카메라에서 이미지를 연습니다. 카메라가 몇 초에 한 번씩만 흐릿하고 왜곡된 이미지를 찍는다는 것이 밝혀졌습니다. 보안 시스템용 어안 렌즈 카메라입니다. 주차장의 시야에 영향을 미치는 장애물도 있으며, 이제 카메라의 이미지를 매핑하여 어떤 차량이 어떤 주차 공간에 있는지 확인해야 합니다.

엔지니어링 팀에 의견을 물어봅니다. 팀이 다시 MinMax 분석을 수행합니다. 이번에는 어려운 기술적 문제에 직면해 있으며, 현재 ML 파이프라인의 최상의 구현으로도 이 문제를 해결할 수 있을지 궁금해합니다.

팀은 먼저 MinMax 분석의 Max 부분을 수행합니다. 분석 결과, 현재 가지고 있는 이미지로 시스템이 89%의 올바른 인용과 11%의 잘못된 인용을 내리는 것으로 나타났습니다. 연간 51회의 오버스테이가 발생하면 미터당 수익은 연간 \$23.97입니다. ML 파이프라인이 작동하지 않습니다.

패닉 타임! 엔지니어링에서 다른 ML 파이프라인을 구축할 수 있나요? 시도해 보지만 기존 보안 카메라의 이미지를 사용하면 비즈니스적으로 실용적이지 않습니다. 더 나은 사진을 얻을 수 없다면 실행 가능한 AI 프로젝트가 아닙니다.

팁 이런 경우 프로젝트를 취소하는 것이 전혀 나쁘지 않습니다. 이 예는 프로젝트 초기에 MinMax 분석을 수행해야 하는 이유를 정확히 보여줍니다. 예산(시간과 비용)의 3%를 사용했는데 효과가 없다는 것을 증명할 수 있을 때와 예산의 105%를 사용했는데 아무 소용이 없다는 것을 깨달았을 때 중 언제 상사와 프로젝트 취소에 대해 이야기하고 싶으신가요? 실패할 운명이라면 빨리 실패하고 더 생산적인 일을 시작하세요.

상사는 합리적이며 옥상에 설치된 보안 카메라의 이미지를 사용하려는 아이디어가 시작도 하기 싫은 일이라는 것을 이해합니다. 상사가 전화를 걸고 좋은 소식을 가지고 돌아옵니다! 대신 주차장 주변에 설치된 훨씬 더 좋은 카메라를 사용할 수 있게 될 것입니다. 여러 대의 카메라가 장애물에 대해 걱정할 필요가 없도록 배치됩니다. 팀에 동일한 ML 파이프라인을 사용하되 더 나은 카메라를 사용한다는 가정 하에 MinMax 분석을 반복해 달라고 요청합니다.

이번 MinMax의 Max 부분은 이러한 시스템에서 가능한 최고가 98%의 정확한 인용이며 2%가 틀렸다는 것을 보여줍니다. 연간 51회의 오버스테이가 발생하면 미터당 수익은 연간 \$129.54가 됩니다. (최대 부분은 ML 파이프라인의 최상의 구현에 해당하는 결과를 제공한다는 점을 기억하세요.) 그러나 구축할 수 있는 가장 간단한 파이프라인을

분석하는 Min 부분에서는 정확한 인용이 91%에 불과하여 연간 47.43달러의 수익이 발생합니다. 가장 간단한 ML 파이프라인 구현은 작동하지 않지만 개선할 수는 있습니다.

프로젝트는 계속 진행해야 하지만 ML 파이프라인을 개선하는 것이 얼마나 어려울지 의문입니다. 다음에 논의하겠습니다.

6.4.2 ML 파이프라인에 개선이 필요한 경우 어떻게 해야 할까요?

MinMax 분석 결과는 종종 ML 파이프라인의 비즈니스 가치에 대한 결정적인 정보를 제공합니다. 이전 섹션에서 Min 분석 결과 파이프라인이 이미 실행 가능한 비즈니스 결과를 제공하고 있음을 보여주는 예를 보았습니다. 또한 ML 파이프라인이 비즈니스 목표를 달성하기에 부적절한 예도 보았습니다. 그러나 때로는 결과가 결정적이지 않을 수 있습니다. 즉, 비즈니스 목표를 달성하기 위해 ML 파이프라인을 개선해야 합니다.

이 섹션에서는 이러한 상황의 마지막에 대해 설명합니다. 그림 6.5는 ML 파이프라인에 개선이 필요한 경우에 MinMax 분석을 적용하는 개요를 보여줍니다.

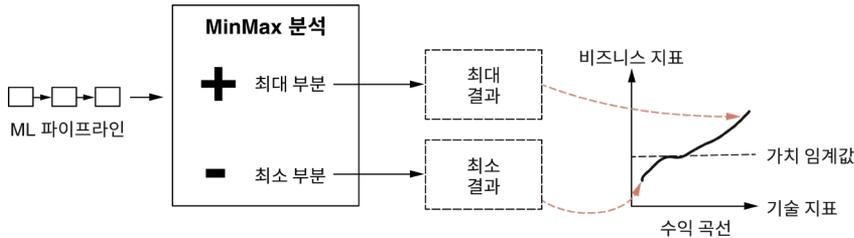


그림 6.5 여기서 최소 분석은 값 임계값에 도달하지 못하지만 최대 분석은 임계값을 초과합니다. 이 파이프라인을 비즈니스에 적합하도록 충분히 개선할 수 있습니다.

그림 6.5에서 분석 결과는 현재 사용 중인 ML 파이프라인의 경우 최소 구현이 충분하지 않지만, 최대 분석은 현재 ML 파이프라인의 구조를 개선하여 비즈니스에 적합한 결과를 제공할 수 있음을 보여줍니다. 이 상황에서는 ML 파이프라인이 최대 분석은 통과하고 최소 분석은 실패했다고 말할 수 있습니다.

최소한의 노력으로 수익을 창출하는 ML 파이프라인은 좋은 것입니다. 각 단계에서 가능한 최고의 기술을 사용해도 수익을 창출하지 못하는 ML 파이프라인은 조기에 포기하는 것이 좋습니다. 하지만 그 중간에서 최대값은 충분히 좋은데 최소값이 그렇지 않다면 어떻게 될까요? AI 제품을 출시하기 전에 ML 파이프라인을 개선해야 하므로 민감도 분석을 수행해야 합니다(7장에서 자세히 설명함).

6.4.3 MinMax 분석 결과 해석 규칙

이전 섹션에서는 MinMax 분석 결과를 해석하는 방법을 배웠습니다. 이러한 결정을 내리는 방법을 요약하면 MinMax 분석 결과를 해석하기 위한 일련의 규칙을 만들 수 있습니다. 이 섹션에서는 이러한 규칙을 요약합니다. 먼저 몇 가지 용어에 대해 합의해 봅시다.

- 최소한의 ML 파이프라인 구현이 이미 수익 곡선의 값 임계값을 초과하는 비즈니스 가치를 가지고 있다면 MinMax 분석의 최소 부분이 **합격**이라고 할 수 있습니다. 최소한의 ML 파이프라인이 비즈니스적으로 실행 가능합니다.
- 최소한의 ML 파이프라인 구현이 이미 수익 곡선의 값 임계값을 초과하는 비즈니스 가치를 가지고 있다면 MinMax 분석의 최대 부분이 **합격**이라고 할 수 있습니다. 현재 ML 파이프라인의 최상의 구현이 비즈니스적으로 실행 가능할 것입니다.

최소 및 최대 분석 결과의 다른 조합은 비즈니스적으로 다른 의미를 갖습니다. 표 6.1에는 최소값과 최대값 분석의 가능한 결과와 비즈니스 영향이 요약되어 있습니다.

표 6.1 MinMax 분석의 가능한 결과 요약. 각 결과는 비즈니스에 직접적인 영향을 미칩니다.

최소 결과/최대 결과	최대 통과	최대 실패
	ML 파이프라인이 비즈니스적으로 실행 가능합니다.	이 조합은 불가능합니다.
	ML 파이프라인이 비즈니스적으로 실행 가능하려면 개선이 필요합니다.	현재 ML 파이프라인은 비즈니스 문제 해결에 적합하지 않습니다.

6.5 ML 파이프라인 분석 수행 방법

이제 MinMax 분석 결과를 **해석**하는 방법을 알았으니, 이제 분석을 수행하는 방법에 대해 이야기해 보겠습니다. 이전 섹션에서 MinMax 분석의 결과인 숫자는 어떻게 얻었나요? ML 파이프라인을 분석하여 얻었습니다. 이 섹션에서는 이러한 분석을 수행하는 방법을 보여줍니다.

참고 엔지니어링 배경 지식이 없는 관리자라면 MinMax 분석에 대한 나머지 설명을 훑어보면서 팀이 분석 중에 수행할 작업에 대한 기본적인 이해를 얻을 수 있습니다. 엔지니어링 배경을 가진 관리자라면 이 분석을 이해하거나 수행할 수 있어야 합니다.

ML 파이프라인 분석의 첫 번째 단계는 모든 전제 조건이 갖추어져 있는지 확인하는 것입니다. 제안한 ML 파이프라인의 논리적 다이어그램이 필요합니다. 또한 프로젝트에서 사용하는 기술 및 비즈니스 메트릭과 수익 곡선도 필요합니다.

데이터를 실행하여 ML 파이프라인을 분석한 다음 수익 곡선을 사용하여 비즈니스 측면에서 결과를 측정합니다. 분석의 일반적인 프로세스(그림 6.6)는 MinMax 분석의 최소 및 최대 부분 모두에 동일하게 적용되며, ML 파이프라인의 민감도 분석에도 적용됩니다.

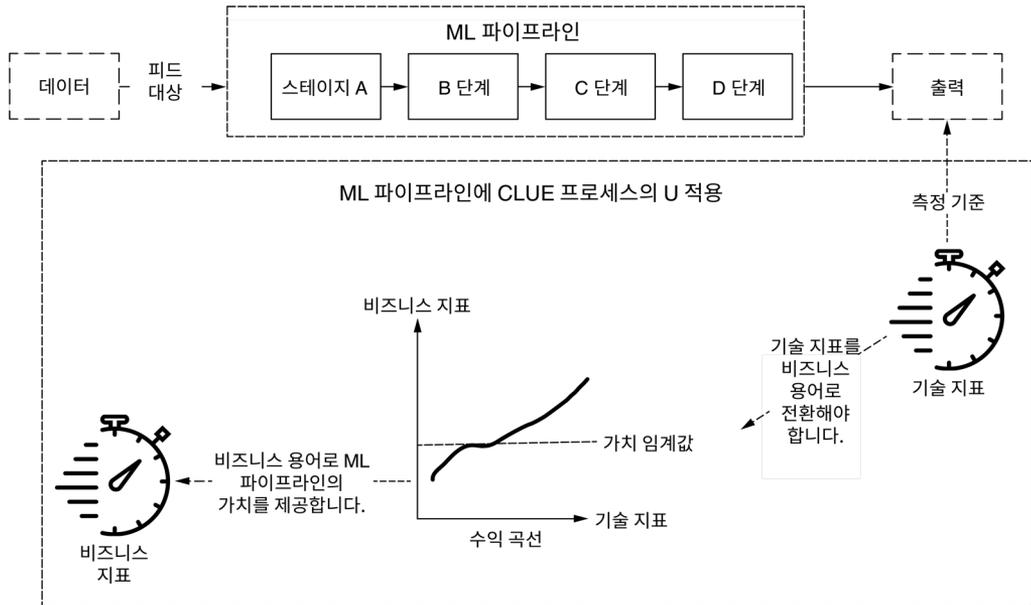


그림 6.6 ML 파이프라인 분석. 이 분석은 현재 ML 파이프라인이 비즈니스를 위해 무엇을 달성할 수 있는지 알려줍니다. MinMax 분석의 최소 및 최대 부분 모두 동일한 프로세스를 사용합니다.

그림 6.6에 표시된 분석은 비즈니스 측면에서 ML 파이프라인의 결과를 측정합니다. 이는 현재 ML 파이프라인으로 실제 데이터를 처리하고 기술 메트릭을 사용하여 결과를 측정한 다음 해당 값을 비즈니스 메트릭으로 변환하는 방식으로 수행됩니다. 이 분석에 대해 생각할 수 있는 또 다른 방법은 실제 데이터를 ML 파이프라인에 공급한 다음 결과를 측정하기 위해 CLUE 프로세스의 일부를 이해하는 방법을 적용하는 것입니다.

그림 6.6의 동일한 프로세스가 MinMax 분석의 Min 및 Max 부분 모두에 적용됩니다. 달라지는 것은 ML 파이프라인을 분석하는 방법이 아니라 ML 파이프라인 단계의 구현입니다.

이제 ML 파이프라인을 분석하는 전반적인 프로세스를 이해했으니 실제 분석을 수행하는 방법을 살펴보겠습니다. 6.5.1절에서는 MinMax 분석의 Min 부분을 수행하는 방법을, 6.5.2절에서는 Max 부분을 수행하는 방법을 설명합니다. 6.5.3절에서는 MinMax 분석을 수행하는 동안 추세 추정 및 안전 계수를 고려하는 방법에 대해 설명합니다. 섹션 6.5.4에서는 다양한 유형을 소개합니다.

다양한 유형의 수익 곡선을 소개합니다. 마지막으로 6.5.5절에서는 복잡한 형태의 수익 곡선에 최소 최대 분석을 적용하는 방법을 보여줍니다.

6.5.1 MinMax 분석의 최소 부분 수행하기

분석의 Min 부분을 수행하려면 먼저 가장 간단한 ML 파이프라인 구현을 구성해야 합니다. 실제 데이터로 테스트할 수 있는 ML 파이프라인 구현을 구축하는 것이 목표입니다.

MinMax 분석의 Min 부분을 위해 ML 파이프라인을 준비하는 데 얼마나 많은 노력을 기울여야 하나요? 전체 프로젝트 규모에 비해 노력은 미미해야 합니다. 일반적으로 프로젝트 규모에 관계없이 몇 명의 인력이 몇 주 정도 소요되며, 전체 프로젝트 예산의 5%를 넘지 않아야 합니다. 소규모 회사라면 한 사람이 며칠 안에 할 수 있는 것이 최선일 수 있습니다.

덕트 테이프를 자유롭게 사용하는 것이 핵심입니다. 빠르게 구축할 수 있는 파이프라인 구현을 사용하세요. 상용 기성품(COTS) 제품이 도움이 될 수 있다면 이를 사용하세요. 파이프라인의 어느 단계에서든 필요한 기능을 구현하기 위해 다른 사람의 제품을 사용할 수 있는지 자문해 보세요. 필요한 최소한의 노력으로 시스템을 작동시켜 해당 시스템을 통해 어떤 비즈니스 결과를 얻을 수 있는지 확인합니다.

분석이 완료되면 6.4장에서 배운 기법을 적용하고 분석 결과를 해석할 차례입니다. 이미 비즈니스 메트릭의 임계값을 초과하는 결과를 제공하는 ML 파이프라인이 있다면, 파이프라인을 그대로 비즈니스에 사용할 수 있습니다.

참고 아무리 간단한 ML 파이프라인이라도 구축하는 데 필요한 노력의 양이 많으면 어떻게 될까요? 간단한 구현 없이는 분석의 최소값 부분을 수행할 수 없습니다. 따라서 최소 분석의 결과는 0—*현재* 구현된 ML 파이프라인의 비즈니스 가치는 0입니다. 개선하지 않으면 아무것도 얻지 못합니다.

6.5.2 MinMax 분석의 Max 부분 수행하기

현재 가지고 있는 것이 출시하기에 충분하지 않다면, 비즈니스 실행이 가능하기 전에 AI 시스템을 개선해야 합니다. 이제 MinMax 분석의 최대 부분을 수행하여 ML 파이프라인이 비즈니스 목표를 달성할 수 있을 만큼 충분히 개선할 수 있는지 판단할 때입니다. 이 섹션에서는 분석의 이 부분을 수행하는 방법을 보여줍니다.

MinMax 분석의 Max 부분에서는 주어진 구조를 가진 ML 파이프라인의 경우 파이프라인 전체에 대해 가능한 최상의 결과는 모든 단계가 가능한 최상의 구현을 갖는 결과라는 개념이 적용됩니다. 그림 6.6에 표시된 ML 파이프라인의 단계 B를 보세요. 스테이지에 이미지가 주어지고 이미지의 숫자를 시각적으로 인식하는 작업을 처리한다고 가정합니다. Max 분석의 경우, 다른 사람이 숫자를 인식하는 데 달성한 최상의 결과가 무엇인지 살펴보고 이를 B 단계가 상당한 노력을 기울일 경우 달성할 수 있는 최상의 결과의 프록시로 사용합니다.

지금까지 최고는 합리적인 기대치의 상한선입니다.

논의를 위해 ML 파이프라인의 특정 단계(B 단계라고 함)에서 지금까지 누구나 얻은 최상의 결과가 99.22%의 정확도라고 가정해 봅시다. 이 단계를 사용하여 ML 파이프라인을 구축했는데, MinMax 분석의 Max 부분을 수행했을 때 ML 파이프라인이 비즈니스에 적합하지 않다는 것을 알게 되었다고 가정해 보겠습니다. 하지만 B 단계의 정확도를 0.5%만 개선할 수 있다면(정확도 99.72%까지) 비즈니스적으로 실행 가능한 ML 파이프라인을 갖게 될 것입니다. 귀사의 팀이 99.72%의 정확도를 달성할 수 있다고 가정해야 할까요?

업계의 대부분의 팀에서 지금까지 AI 분야에서 발표된 최고의 결과보다 개선할 수 있다고 장담하는 것은 위험합니다. 즉, 모든 단계에서 알려진 최상의 구현을 사용하는데도 만족할 만한 비즈니스 결과를 얻지 못하는 ML 파이프라인은 그 구조상 비즈니스 문제 해결에 부적합합니다. 이러한 ML 파이프라인은 MinMax 분석의 Max 부분에 실패했습니다. 최소한의 실행 가능한 제품이라도 얻기 위해 과거 최고의 결과를 뛰어넘어야 한다면, 그러한 ML 파이프라인을 포기할 때가 훨씬 지났습니다.

분석의 최대값 부분은 새로운 비즈니스나 제품을 구축하는 초기 단계에서 특히 중요합니다. 이 단계에서는 프로젝트와 파이프라인의 총 비용을 추정하고 있는데, 간과하고 있는 비용이 있을 수 있습니다. 총 비용이 과소 추정되었을 수 있는데도 ML 파이프라인이 최소 최대 분석의 최대 부분을 통과하지 못한다면, 해당 ML 파이프라인은 실행 가능한 AI 제품을 지원할 수 없는 것이 분명합니다.

ML 파이프라인의 Max 분석에서 가장 중요한 질문은 "해당 단계에서 가능한 최상의 결과를 얻기 위한 합리적인 프록시는 무엇일까?"입니다. 좋은 프록시를 찾는 몇 가지 방법을 살펴보겠습니다.

최소값 분석의 최대값 부분은 경쟁 벤치마킹에 뿌리를 두고 있습니다[1,120]. 경쟁 벤치마킹이란 비슷한 문제를 가진 프록시를 찾고 그들이 얼마나 잘 해결했는지를 측정하는 것을 의미합니다. 다음은 프록시로 사용할 수 있는 몇 가지 소스를 더 자세히 조사할 것입니다.

- 해결하려는 문제와 유사한 문제에 대해 지금까지 비즈니스, 산업 또는 학계에서 달성한 최고의 결과물입니다.
- AI가 수행해야 하는 작업을 수행하는 사람

학계나 업계에서 귀사가 당면한 문제와 같은 문제에 대처하여 얻은 최상의 결과는 무엇일까요?

귀사가 당면한 과제와 똑같은 과제에 대해 학계나 업계에서 가장 잘 발표된 결과는 무엇인가요? 귀사가 찾고자 하는 것은 귀사가 가진 문제와 동일한 문제를 가진 조직이 얼마나 이를 잘 해결했는지 여부일 것입니다.

업계를 살펴볼 때는 구매할 수 있는 COTS 제품뿐만 아니라 다른 회사(직접적인 경쟁자가 아니더라도)가 직면한 문제를 해결할 때 달성할 수 있었던 최고가 무엇인지도 살펴봐야 합니다. 학술 논문을 살펴볼 때는 가장 잘 발표된 결과를 살펴보는 것입니다. 두 경우 모두, 핵심은 다른 사람이 문제를 해결할 때 달성한 최고가 무엇인지 가능한 한 당신과 비슷하게 보이는 것을 찾으려는 것입니다.

팁 파이프라인의 특정 단계에서 COTS 제품을 고려하고 있다면, 공급업체에 귀하와 같은 문제에 대해 해당 제품을 사용하여 달성한 최상의 결과가 무엇인지 물어보세요. 귀하와 같은 비즈니스 사례에 대해 실질적인 비즈니스 가치를 제공한다고 확신하는 공급업체는 이러한 질문을 차별화할 수 있는 기회로 인식해야 합니다.

학계나 업계를 대리인으로 삼는다는 생각은 세계 최고의 전문가가 어떤 작업에 대해 80% 이상의 정확도를 달성하지 못했다면, 80%보다 더 잘할 수 없다고 가정하는 것이 합리적이라는 것입니다.

어떤 프록시를 선택해야 하는지에 대해서는 일반적으로 학술 논문보다는 업계에서 검증된 문제와 더 유사한 프록시를 사용하는 것이 더 낫습니다. 반면에, 귀사가 처한 상황과 정확히 유사한 상황을 설명하는 학술 논문이 관련성이 낮은 문제에 대한 업계 사용보다 더 나은 프록시가 될 수 있습니다.

귀사의 상황은 얼마나 비슷한가요?

대용량으로 사용하기로 선택한 문제가 자신의 상황과 유사한지 신중하게 확인해야 합니다. 프록시는 밀접한 관련이 있어야 하며, 광고된 결과가 어떤 조건에서 달성되었는지 이해해야 합니다. 학술 논문의 저자가 도입했을 수 있는 단순화에 특히 주의를 기울이세요.

B. Hu 등은 시계열 분류에 관한 논문에서 예를 제시합니다[121].가속도계 데이터를 사용하여 배우의 동작과 제스처를 인식할 수 있습니다.여기서 문제는 한 동작이 시작되고 다른 동작이 끝나는 시점을 어떻게 알 수 있는가 하는 것입니다. 특정 학술 커뮤니티의 답변은 기술적으로 *사전 세분화*로 알려진 것을 사용한다는 것이었습니다.

그 커뮤니티는 제스처가 언제 시작되고 멈추는지를 이미 알고 있는 상태에서 제스처를 분류하는 데 관심이 있었습니다. 이는 배우가 큐에 따라 제스처를 수행하도록 요청받았기 때문에 알 수 있었습니다. *더 정확한 사전 세분화를 위해 일부 배우들은 메트로놈을 사용하기도 했습니다*

한 가지 문제는 메트로놈의 도움으로 가속도계 데이터가 사전 분할된 경우 제스처를 인식하는 것이 스마트 워치(예: 애플 워치)에서 오는 가속도계 데이터를 이해하는 것보다 훨씬 쉽다는 것입니다. 이전 커뮤니티의 결과를 스마트 워치 가속도계로 가능한 것에 대한 프록시로 사용했다면, 왜 그 학계가 달성할 수 있었던 것에 근접한 제스처 인식 정확도를 얻지 못했는지 궁금해하지 않을 것입니다.

최대 분석 중에 팀이 발표한 절대적으로 가장 좋은 결과를 놓친다면 어떻게 해야 하나요? 예를 들어, 그 결과가 모호한 과학 논문에 실렸다면요? 팀이 발견한 Max는 여전히 조직의 Max로 간주되며, Max는 모호한 논문이 존재한다고 해서 영향을 받지 않습니다. Max 분석 중에 찾고 있는 것은 인류에게 알려진 절대적인 최대값이 아닙니다. 실제 팀이 파이프라인의 주어진 단계를 구현하려고 할 때 얻을 수 있는 실용적이거나 산업적인 Max를 찾고 있는 것입니다. 팀이 모르는 논문의 알고리즘을 구현할 수 없습니다.

사람이 문제를 얼마나 잘 해결할 수 있을까요?

문제와 비슷한 예가 전혀 없다면 어떻게 해야 할까요? 이전에 아무도 귀사가 당면한 문제와 동일한 문제를 해결하지 못했다면, 인간보다 더 잘할 수 있는 인공지능 제품을 만들 수 있다고 가정하는 것은 위험합니다. 대신 데이터의 작은 하위 집합이 주어졌을 때 사람이 무엇을 할 수 있는지 살펴보세요. 그 사람을 프록시로 사용하세요.

사람을 데려다가 파이프라인의 단계가 보는 것과 동일한 데이터를 보여주세요. 이 사람에게 파이프라인 단계의 역할을 수행하도록 한 다음, 사람이 수행하는 단계가 달성하는 결과를 측정하세요. 이것이 인공지능 알고리즘이 할 수 있는 최대치에 대한 추정치입니다.

참고 일부 작업에서 *인간보다 더 나은* 효과를 얻을 수 있을지는 모르지만, 이 글을 쓰는 시점에서 이러한 상황은 드물고, 종종 뉴스 가치가 있으며, 달성하더라도 이미 세계 최고의 AI 연구자들로 구성된 팀에 의해 만들어지는 것이 보통입니다. AI 알고리즘의 결과가 사람이 달성할 수 있는 결과보다 더 나쁠 때가 훨씬 더 흔합니다.

6.5.3 MinMax 분석의 추정치 및 안전 계수

MinMax 분석의 최대 부분의 특성은 ML 파이프라인의 모든 단계에서 가능한 최상의 구현이 이루어질 경우 달성할 수 있는 것을 추정하는 것으로, 이 섹션에서는 달성할 수 있는 것을 추정할 때 자주 나타나는 질문을 다룹니다. 예를 들면 다음과 같습니다.

- MinMax 분석을 수행 중이고 프로젝트가 18개월 후에 출시될 예정이라면 하드웨어 또는 AI 알고리즘의 개선 추세를 고려해야 하나요?
- MinMax 분석 중에 전문가 의견을 어떻게 사용해야 하나요?
- 결과에 안전 계수를 추가해야 하나요?

MinMax 분석에서 추세 추정치 사용하기

때때로 개선 추세를 보고 프로젝트를 배포할 시점에 그러한 추세가 지속되면 어떤 의미가 있는지 추정할 수 있습니다. 예를 들어, 데이터 저장 비용이 감소하고 있고 프로젝트가 2년 후에 출시될 경우 데이터 저장 비용의 감소를 고려하여 현재보다 더 많은 데이터를 저장할 수 있을 것이라는 결론을 내릴 수 있습니다.

인공지능 알고리즘의 개선에 트렌드를 적용할 수도 있습니다. 어떤 경우에는 AI 알고리즘이 개선되고 있다는 분명한 추세가 있을 수 있습니다. 예를 들어, 현재 AI는 이미지와 비디오 스트림의 인식 능력이 향상되고 있으며, 그 속도가 매우 빠릅니다. 특히 최대값 분석 결과가 도달하고자 하는 비즈니스 생존 가능성 임계값과 근소한 차이로 실패할 경우 추세 추정을 시도하고 싶은 유혹에 빠질 수 있습니다. 예를 들어, 96%의 정확도가 필요한데 현재 최고는 95.5%이지만 2년 후에는 96%가 될 것으로 예상합니다.

저는 초기 AI 노력의 추세를 예측하는 것을 좋아하지 않으며, 대부분의 고객에게 그렇게 시도하지 말라고 말합니다. 특정 분야의 트렌드를 성공적으로 예측하려면 해당 분야의 초기 노력을 시작할 때보다 더 많은 전문 지식이 필요합니다. 기술

지식뿐만 아니라 조직이 새로운 AI 기술을 얼마나 잘 흡수할 수 있는지에 대한 지식도 필요합니다. 마지막으로, 트렌드가 유의미하려면 일반적으로 첫 번째 AI 프로젝트보다 더 오래 걸릴 정도로 프로젝트가 충분히 길어야 합니다.

전문가 의견에 기반한 추정치

파이프라인의 일부 단계에서 얻을 수 있는 최대 결과의 예상치를 전문가에게 문의하는 것이 좋습니다. 이러한 전문가는 컨설턴트나 학자 등이 될 수 있습니다. 또한 파이프라인의 특정 단계에서 가능한 최상의 결과가 무엇인지뿐만 아니라 이를 달성하는 방법도 알려줄 수 있습니다.

전문가 의견의 또 다른 장점은 현재 최선의 결과가 무엇일 뿐만 아니라 특정 연구 분야의 트렌드가 무엇인지 알려줄 만큼 해당 분야를 잘 알고 있다는 것입니다. 이미지 인식 커뮤니티와 같이 기능이 빠르게 향상되고 있는 분야인가요? 팀이 이러한 결과를 달성하기 위해 얼마나 많은 훈련이 필요한가요?

전문가의 조언을 상황에 맞게 활용하도록 주의하세요. 전문가가 단일 질문에 대해 개별적으로 답변했으며, 귀하의 특정 상황을 잘 이해하고 있나요?

전문가는 비용이 많이 들고 바쁘기 때문에 팀이 구성한 간단한 질문을 통해 비용을 절약하고 싶은 유혹이 있습니다. 문제는 이제 팀이 전문가보다 전문성이 떨어지는 영역에서 질문과 답변의 맥락을 모두 처리해야 한다는 점입니다.

이러한 상황에서 얻은 답변은 공인된 전문가가 제공한 것이기 때문에 정답이라고 믿을 가능성이 높기 때문에 잘못된 안정감을 줄 수도 있습니다. 그러나 (비전문가에 의해 수행되는) 맥락화 부분은 문제의 본질적인 부분이 될 수 있습니다. 올바른 질문을 하는 것은 어려운 일이며, 전문가를 전문가로 만드는 많은 요소 중 하나는 어떤 질문을 해야 하는지 알고 있다는 점입니다.

비즈니스 문제 해결을 위한 연구 질문을 공식화할 때 3장에서 질문의 맥락화 문제에 직면한 적이 있습니다. 3장에서 경영진과 데이터 과학자가 대화를 나누어야 했던 것처럼, (올바르게 던진) 질문이 여러분의 요구 사항을 반영하는지 확인하기 위해 전문가와 대화해야 합니다.

전문가의 조언에 돈을 아끼는 것은 '현명하고도 어리석은' 접근 방식이라고 생각합니다. 전문가가 맥락에 맞는 답변을 제공할 수 있도록 전문가와 충분한 시간을 갖고 직면한 문제를 설명하는 데 필요한 예산을 책정합니다. 적합한 전문가를 찾았다면 몇 시간 안에 비즈니스 상황의 세부 사항을 설명할 수 있습니다.

마지막으로, 전문가로부터 얻은 답변의 형태가 어떤 것인지 잘 이해해야 합니다. 사실인가요, 상황에 대한 전문가 의견인가요, 아니면 그냥 추정치인가요? 제가 초기 AI 프로젝트에 대한 트렌드 추정치를 좋아하지 않는다는 것은 이미 알고 계시겠지만, 추정치가 해당 분야의 기술 전문가라고 해서 제 의견이 크게 달라지지 않습니다.

경고 견적을 받는 경우, 대부분의 사람들(그리고 대부분의 전문가들)이 특별히 정확한 견적가는 아니라는 점에 유의하세요. 대부분의 사람들이 추정을 잘못한다는 데이터, 인간이 추정을 잘못하는 이유에 대한 토론, 그리고 사람들이 더 정확해질 수 있는 방법에 대해서는 D. W. 허바드의 책 [75]을 읽어볼 가치가 있습니다.

분석하는 동안 안전 계수를 추가해야 하나요?

때때로 학문적 결과를 산업 환경에서 완전히 복제할 수 없는 경우가 있습니다. 또한 같은 작업을 수행하는 사람이 할 수 있는 것과 비슷한 수준의 결과를 도출하는 AI 솔루션을 개발할 수 있을지에 대해 회의적일 수도 있습니다.

이러한 상황에서는 "우리는 공개된 최고 결과의 50%만 달성할 수 있다고 가정합니다."와 같은 안전 계수를 도입하는 것이 좋습니다. 물론 이 안전 계수가 무엇인지, 즉 왜 80%가 아닌 50%를 안전 계수로 선택했는지는 명확하지 않습니다. 안전 계수는 불확실성이 어디에서 오는지, 얼마나 불확실성이 있는지 설명할 수 있을 정도로 문제를 잘 이해하고 있을 때 사용하는 것이 좋습니다. 그러나 불확실성이 어느 정도인지 모를 때 안전 계수는 추측에 불과합니다.

경고 반올림 숫자(예: 2, 3, 10 또는 50%)인 안전 계수가 발생할 때 주의하세요. 문제에 대한 기술적 분석의 결과라고 보기에는 너무 의심스러운 정도로 동글게 보이며, 해당 숫자는 추측일 수 있습니다.

6.5.4 수익 곡선의 범주

지금까지 제시된 수익 곡선 분석의 예에서는 수익 곡선이 단조롭다고 가정했습니다. 즉, 기술적 지표가 증가하면 비즈니스 지표(예: 수익)도 증가한다고 가정했습니다. 이것이 가장 일반적인 실제 상황이지만, 이 섹션에서는 수익 곡선과 기술 지표가 더 복잡한 관계를 가질 때 어떻게 해야 하는지 보여드리겠습니다.

참고 이 섹션은 일반 독자와 수학에 관심이 있는 독자 모두에게 흥미로울 것입니다. 광범위한 독자를 위해 일상적인 용어를 사용하여 몇 가지 개념을 더 간단하게 설명하겠습니다. 수학에 관심이 있는 독자들은 이미 제가 설명하는 기본 개념과 모퉁이 사례를 알고 있으며, 기본적인 수학적 엄밀성을 직접 추가할 수 있으니 인내심을 가져 주시기 바랍니다.

수익 곡선은 다양한 모양을 가질 수 있습니다. 우리는 특히 그림 6.7의 네 가지 범주에 관심이 있습니다. 그림 6.7에 표시된 수익 곡선의 범주에 대해 논의해 보겠습니다.

- 선형 수익 곡선에서 비즈니스 지표와 기술 지표 사이의 관계는 직선입니다.
- 단조로운 수익 곡선에서는 기술 지표가 증가하면 비즈니스 지표도 증가합니다. 그러나 기술 지표와 비즈니스 지표 사이의 관계를 설명하는 함수는 직선이 아니며, 수익 곡선은 다양한 형태를 취할 수 있습니다. 모든 선형 수익 곡선은 단조로운 곡선이지만 그 반대는 아닙니다.
- 다음으로 더 복잡한 수익 곡선은 비단조 수익 곡선입니다. 이 곡선에는 기술 지표가 증가할 때 비즈니스 지표가 증가하는 세그먼트와 기술 지표가 증가할 때 비즈니스 지표가 감소하는 다른 세그먼트가 있습니다. 그래프(c)는 실제로 발생할 수 있는 비단조 곡선의 한 유형을 보여줍니다.

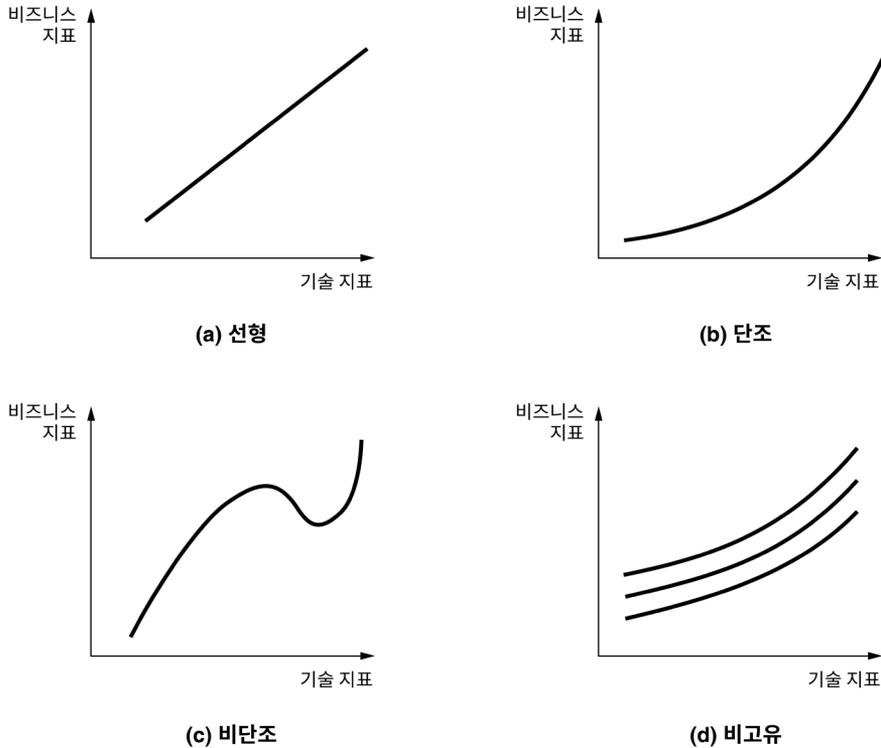


그림 6.7 다양한 유형의 수익 곡선. 선형 및 단조 수익 곡선은 비단조 수익 곡선보다 최적화 하기가 더 간단합니다. 고유하지 않은 수익 곡선은 피하세요.

- 마지막 예는 고유하지 않은(모호한) 수익 곡선으로, 주어진 기술 지표와 수익 사이에 고유한 관계가 없습니다. 이러한 유형의 수익 곡선은 기술 지표가 중요한 비즈니스 고려 사항을 측정하지 못할 때 발생합니다.

귀하는 프로젝트의 수익 곡선 모양을 알고 있습니다.⁴ 다음에 표시된 종류의 수익 곡선을 언제 접하게 될지 몇 가지 구체적인 예를 들어 보겠습니다. 그림 6.7:

- 기술 지표와 비즈니스 지표 사이에 단순하고 직접적인 관계가 존재할 때 선형 수익 곡선(그래프 (a))을 자주 접하게 됩니다. 예를 들어, 선형 수익 곡선은 "우리의 연간 비용은 $\$100,000$ * RMSE 공식을 사용하여 주어진다" 형식의 규칙이 있을 때 발생합니다.

⁴ 수익 곡선을 실험적으로 도출할 수 있는 경우도 있지만, 이는 고급 기술 주제이므로 이 책에서 다루기에는 대상 독자층과 지면 관계상 실용적이지 않습니다. 수익 곡선의 실험적 도출과 관련된 기술 주제에는 실험 설계, 반응 표면 분석, 베이지안 최적화가 포함됩니다.

- 어떤 가치를 예측할 때 단조로운(그러나 비선형적인) 수익 곡선을 만날 수 있으며, 예측이 정확할수록 그 가치는 더 높아집니다. 그래프 (b)는 기술 지표와 비즈니스 지표 간의 기하급수적 관계를 보여 주며, 예측 정확도가 조금만 증가해도 수익이 크게 증가합니다. 금융 시장에서는 이러한 상황에 자주 직면하게 됩니다.⁵
- 비단조 곡선의 또 다른 예는 로봇 공학으로, 수익 곡선은 그래프(c)에 표시된 곡선처럼 보입니다. 로봇 공학에는 *불편한 골짜기*라는 개념이 있습니다 [122]. 첫 번째 로봇은 인형과 같은 얼굴을 가진 로봇이고, 두 번째 로봇은 인간과 비슷한 얼굴 특징(및 얼굴 움직임)을 가지고 있지만 완벽한 팩시밀리는 아니라고 가정합니다. 우리는 더 정교한 얼굴 모델링을 가진 두 번째 로봇이 더 인기가 있을 것이라고 생각하는 경향이 있지만, 그 반대일 수도 있습니다[122]. 어떤 사람들은 두 번째 로봇에 대해 본능적이고 부정적인 반응을 보입니다.
- 비단조 곡선의 또 다른 예는 인간의 면밀한 감독이 필요한 자동화 시스템입니다. AI를 사용하여 의심스러운 활동을 강조하는 보안 시스템을 생각해 봅시다. 또 다른 예는 작업자가 자동화된 기계와 로봇을 감독하는 경우입니다. 비행기와 같은 운송 시스템도 같은 현상의 대상이 될 수 있습니다[123].
법적 또는 실용적인 이유로 사람이 시스템을 감독하는 데 전념해야 하는 경우 (그리고 상당한 시간 동안 지루해하는 경우) 그래프 (c)와 유사한 모양을 볼 수 있습니다. 불완전한 인공지능이 가끔 오류를 범할 때(하지만 여전히 오류를 범할 때) 인공지능과 인간의 결합 시스템은 인공지능이 더 자주 오류를 범할 때보다 *더 나쁜* 성과를 낼 것입니다. 그 이유는 AI 시스템의 성능이 아니라 작업을 감독하는 인간의 성능에 있습니다. 인간은 지루하고 부주의한 경향이 있으므로 문제가 발생했을 때 문제를 해결하는 속도가 느릴 수 있습니다. 또는 AI 시스템의 오류에 대응하는 방법에 대한 연습이 부족할 수도 있습니다.
- 단조롭지 않은 수익 곡선의 또 다른 예는 비즈니스 지표가 수익인 일부 상황입니다. 때로는 기술 지표에서 더 높은 값에 도달하는 데 비용이 많이 들고 추가 자본 지출이 필요할 수 있습니다. 기술 지표를 더 개선하려면 값비싼 추가 데이터 소스에 대한 액세스 권한을 구매해야 한다고 가정해 보겠습니다. 이로 인해 수익 곡선에 '하락'이 발생하여 값비싼 추가 데이터를 구매한 후에야 기술 지표의 추가 개선이 가능해지며, 따라서 해당 시점의 수익이 감소합니다.

일반적으로 단조로운 수익 곡선은 다루기가 더 간단하며, 선택의 여지가 있다면 단조로운 수익 곡선을 선호해야 합니다. 두 가지 *동등하게* 좋은 기술 지표/비즈니스 지표 조합을 선택할 수 있고, 그 중 하나는 단조롭고 다른 하나는 그렇지 않은 경우, 단조로운 조합을 선택합니다.

⁵ 지수 관계의 이유는 큰 개선이 어렵거나 심지어 불가능하다고 여겨질 수 있기 때문일 수 있습니다. 경쟁으로 인해 개선이 가능하다는 것을 보여주면 경쟁자들이 따라잡으려 할 것이고, 곡선의 모양이 빠르게 바뀔 수 있습니다. 7장에서는 시간에 따라 변화하는 수익 곡선으로 운영하는 방법을 보여줍니다.

경고 중요한 비즈니스 고려 사항과 관련이 없는 기술적 지표만을 근거로 비즈니스 의사 결정을 내리지 마세요! 그렇지 않으면 비즈니스 결과를 최적화하는 것이 아니라 숫자(기술적 지표)를 최대화하기로 결정하게 됩니다.

초기 AI 프로젝트나 AI 팀이 아직 경험을 쌓는 단계에서는 수익 곡선이 단순한 사용 사례를 선호해야 합니다. 이는 기술적 이유(단조로운 수익 곡선이 분석하기 더 간단함)와 비즈니스 이유 모두에 해당합니다.

참고 복잡한 수익 곡선은 수익화가 간단하지 않은 AI의 비즈니스 사례가 약하다는 것을 나타낼 수 있습니다. 그러나 수익 곡선을 자세히 분석할 가치가 있을 정도로 강력한 비즈니스 사례를 나타내는 것일 수도 있습니다. 또는 "이 특정 비즈니스 지표와 기술 지표 사이의 관계가 바로 이런 것이구나"와 같이 단순히 기술적인 우연일 수도 있습니다. 저는 어떤 선입견을 가지고 시작하지는 않지만, 단조롭지 않은 수익 곡선을 보면 항상 "왜 수익 곡선이 이런 모양일까?"라고 자문합니다.

때로는 선택의 여지가 없을 때도 있습니다. 자신에게 맞는 유일한 기술적 지표/비즈니스 지표 조합이 비단조적일 수도 있기 때문입니다. 다음 섹션에 소개된 기법은 데이터 과학 팀이 이러한 상황을 해결하는 데 도움이 될 것입니다.

6.5.5 복잡한 수익 곡선 다루기

이제 좀 더 복잡한 수익 곡선을 구성하는 데 필요한 세부 사항에 대해 이야기하겠습니다. 이 섹션에서는 단조롭지 않고 고유하지 않은 수익 곡선을 다루는 기술적 측면에 대해 설명합니다.

참고 이 섹션에서는 독자가 자연어 처리(NLP)의 맥락에서 혼동 행렬과 F-스코어에 이미 익숙하다고 가정합니다. 자세한 내용은 Leon Derczynski의 논문[124]에서 확인할 수 있습니다.

먼저 고유하지 않은 수익 곡선을 인식하는 방법을 살펴봅시다. 고유하지 않은 수익 곡선은 비즈니스 지표와 사용 중인 기술 지표 사이에 고유한 수학적 관계가 존재하지 않을 때 발생합니다. 법률 분야의 예로는 전자증거개시, 호사가 문서를 검토하는 데 드는 비용을 절감하기 위해 AI를 사용하는 경우를 들 수 있습니다. AI를 사용하여 대량의 문서를 확인할 수 있습니다. AI 시스템이 소송과 관련이 없는 텍스트를 신뢰성 있게 플래그를 지정할 수 있다면, 변호사는 시간을 크게 절약하고 소송 당사자는 비용을 절감할 수 있습니다.

지금 로펌에서 일하고 있다고 가정해 보겠습니다. 비즈니스 질문은 "소송의 증거개시 단계에서 AI가 절약할 수 있는 최대 금액을 추정할 수 있습니까?"입니다.⁶ 전자증거개시에서 절감되는 비용은 AI가 "소송과 관련이 없는 문서"로 정확하게 분류하는 문서(진정한 네거티브)의 비율에 비례합니다.

문서를 분석하는 AI 시스템은 더 광범위한 자연어 처리 분야의 일부입니다. NLP 커뮤니티에서 일반적으로 사용하는 지표 중 하나는 F-점수 (score)입니다

⁶ 이 예제를 간단하고 핵심을 파악하기 위해 이 문제만 신경 쓰는 것으로 가정하고 AI가 법적인 실수를 할 때 발생하는 비용은 무시해 보겠습니다. 물론 이 첫 번째 질문에서 충분한 비용 절감 효과가 나타나고 법률 회사가 이 AI 시스템을 검토하기로 결정하면 추가 비즈니스 질문을 할 것입니다.

[124]. 안타깝게도 우리의 비즈니스 사례에서는 F-점수가 실제 네거티브를 설명하지 못합니다! 실제 네거티브의 수가 매우 다양한 두 개의 서로 다른 AI 시스템이 동일한 F-점수를 가질 수 있습니다! 우리의 비즈니스 사례에서 이는 F-점수와 AI가 제공할 수 있는 절감액 사이에 고유한 관계가 없다는 것을 의미합니다. 같은 F-점수라도 변호사 시간을 10% 절약할 수도 있고 80% 절약할 수도 있습니다! 이 F-점수를 사용하여 '비용 절감 F-점수' 수익 곡선을 만들 수 없습니다. F-점수를 사용하여 이 시스템의 다른 특성을 측정할 수는 있지만, 비즈니스 지표가 비용 절감인 수익 곡선에는 좋은 기술 지표가 아닙니다.

참고 그렇다면 왜 사람들은 F-점수를 사용하나요? F 점수는 정보 검색의 많은 영역에서 의미가 있지만, *특정 비즈니스 사례에서는 그렇지 않습니다.* F-점수는 자연어 처리[124]의 맥락에서 자주 사용되므로, 어떤 *기술 매트릭*을 사용할지 논의하는 경우 합리적인 출발점이 될 수 있습니다. 특정 기술 지표가 널리 사용된다고 해서 자동으로 수익 곡선에 유용한 지표가 되는 것은 아닙니다.

이제 단조롭지 않은 수익 곡선을 살펴보겠습니다. 비단조 수익 곡선에 대한 MinMax 분석은 단조 곡선에 대한 분석과 다르게 수행해야 합니다. 곡선이 비단조 곡선인 경우 수행해야 하는 MinMax 분석 접근 방식은 그림 6.8에 나와 있습니다.

MinMax 분석에서 *Min*이라는 용어는 비즈니스 메트릭의 최소값이 아니라 ML 파이프라인의 최소 구성(모든 단계에 단순하고 최소한의 구현이 있음)을 의미한다는 점을 기억하세요. ML 파이프라인을 통해 얻을 수 있는 비즈니스 지표의 가치를 최대한 활용하고 싶을 것입니다! 따라서 수행 할 때

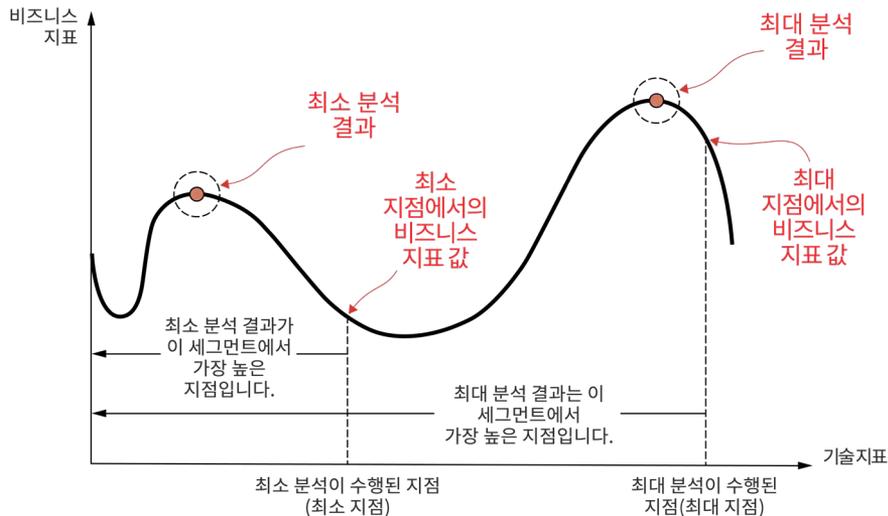


그림 6.8 비단조 수익 곡선에 대한 MinMax 분석. Min 분석 결과는 세그먼트 [0, 최소 지점]에서 비즈니스 지표의 최댓값입니다. Max 분석 결과는 세그먼트 [0, 최대 포인트]에서 비즈니스 지표의 최고 값입니다.

그림 6.8의 MinMax분석에서, Min 분석 결과는 전체 구간에서 가장 좋은 값[0, Min Point] 커브의 시작과 Min 분석을 수행한 지점 사이의 값입니다. 전체 구간[0, 최대점]에 대해 MinMax 분석의 Max 부분을 수행할 때도 비슷한 논리가 적용됩니다.

전체 MinMax 분석에 익숙해지면 비단조 수익 곡선에 대한 MinMax 분석도 어렵지 않게 수행할 수 있습니다. 하지만 단조로운 수익 곡선으로 작업하는 것보다 노동 집약적입니다! 비단조 수익 곡선이 있는 프로젝트에는 일반적으로 특별한 고려 사항이 있기 때문에 MinMax 분석으로 작업이 끝나지 않습니다. 예를 들어, 수익 곡선이 그림 6.7의 (c)와 같은 모양이라면 관리자가 지루해져서 부주의해질 수 있는데, 이러한 지루함을 어떻게 해결할 수 있을까요?

머리로 하는 수학이 통하지 않을 때

수익 곡선의 복잡한 사다리를 올라갈수록 관계를 이해하기가 더 어려워집니다. 수익 곡선의 단순한 비선형성은 이미 정신적 수학을 비실용적으로 만듭니다. 곡선이 비단조적일 때는 훨씬 더 나쁩니다!

잘 정의된 수익 곡선을 제시하지 못하면 팀의 회의 참가자가 기술적 지표가 비즈니스 측면에서 무엇을 의미하는지 파악하기 위해 정신적 수학을 수행해야 합니다! 비선형적이고 단조롭지 않은 수익 곡선에 필요한 정신적 수학을 '부수적인 활동'으로 수행하면서 동시에 대부분의 회의의 중심 주제에 집중할 수 없다는 것을 알고 있습니다. 이런 상황에 처한 많은 사람이 정신적 계산을 아예 건너뛰고 "그냥 기술적 지표만 개선하자"는 식으로 안주할 것 같습니다. 그러면 기술 지표와 비즈니스 지표 사이의 관계에서 비선형성은 무시되거나 기껏해야 *근사치로 처리됩니다*.

즉, 수익 곡선을 구성하는 데 실패하고 비단조로운 수익 곡선을 갖는 모든 AI 프로젝트는 잘못된 것을 위해 최적화하고 있다는 뜻입니다! 기술 지표의 정확한 최적화가 비용이 많이 드는 작업인데 근사치를 사용했다면 특히 불행한 일입니다!

대학 1학년 때 근사치 연속에 대한 농담을 들은 적이 있습니다. 농담은 이런 것이었습니다: "공학은 마이크로미터 나사 게이지를 사용하여 측정된 다음 분필로 자를 위치를 표시하고 마지막으로 도끼를 사용하여 표시된 지점을 자르는 것입니다!"라는 농담이었습니다.

6.6 MinMax 분석에 대해 자주 묻는 질문

MinMax 분석 수행의 기본 사항을 이해했다면, 해당 분석 수행에 대한 몇 가지 실용적인 질문을 해결해야 합니다. 이 섹션에서는 다음과 같은 일반적인 질문에 대한 답변을 제공합니다.

- 더 복잡한 분석이 더 정확한 결과를 제공할 수 있는데 MinMax를 ML 파이프라인의 첫 번째 분석으로 사용해야 하나요?
- MinMax 분석의 Min 또는 Max 부분을 먼저 수행해야 하나요?
- MinMax 분석은 대기업만 할 수 있는 분석인가요?
- MinMax 분석이라는 용어를 사용하는 이유는 무엇인가요? 최상의 사례 / 최악의 사례 분석이라고 부르지 않는 이유는 무엇인가요?

6.6.1 ML 파이프라인의 첫 번째 분석은 MinMax가 되어야 할까요?

ML 파이프라인의 첫 번째 분석으로 MinMax를 사용해야 하는지에 대한 질문부터 시작하겠습니다. 시스템 엔지니어링 및 산업 공정 제어 분야에 익숙하다면 ML 파이프라인을 분석할 때 적합한 몇 가지 분석 유형에 대해 잘 알고 있을 것입니다. 그렇다면 더 복잡한 분석이 더 정확한 결과를 제공할 수 있는데 왜 MinMax 분석을 사용해야 할까요?

7장에서 몇 가지 대체 가능한 ML 파이프라인 분석 유형에 대해 설명하겠습니다. 여기에 설명된 대로 이러한 분석 유형은 MinMax보다 더 강력할 수 있습니다. 하지만 MinMax는 배우기 쉽고, 수행 비용이 저렴하며, 파이프라인의 적합성에 대한 합리적인 추정치를 제공합니다. 분석의 복잡성과 결과의 정확성 사이의 좋은 절충안입니다.

경고 분석 결과가 아무리 정확하더라도 학습이 지나치게 복잡하고 구현하는데 비용이 많이 든다면 ML 파이프라인 분석을 수행할 필요가 없습니다. 미래를 완벽하게 예측하는 분석은 미래가 이미 도래하기 전에 그 결과를 사용할 수 있을 때만 가치가 있습니다.

6.6.2 어떤 분석을 먼저 수행해야 하나요? Min 인가요, Max 인가요?

MinMax 분석을 수행해야 하는 순서에 대해 이야기해 보겠습니다. MinMax 분석의 Min 또는 Max 부분을 먼저 예약하나요? 이 두 부분은 독립적이므로 분석의 유효성을 위해 Min과 Max 부분의 순서는 크게 중요하지 않습니다. MinMax를 구현할 때 그림 6.9에 표시된 프로세스를 사용하여 Min과 Max 부분의 난이도, 예상 결과에 대한 사전 의견과 같은 요소를 고려합니다.

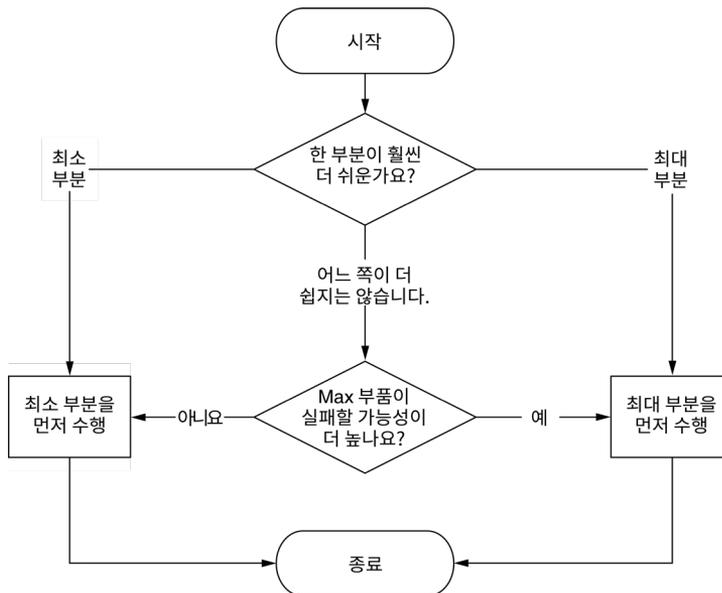


그림 6.9 ML 파이프라인에서 MinMax 분석을 수행해야 하는 순서입니다. 결정적인 답을 제공할 수 있는 분석 부분을 먼저 수행합니다.

Min과 Max 부분 각각은 그 자체로 올바른 파이프라인을 사용하고 있는지 여부를 결정할 수 있습니다. MinMax 분석의 어느 한 부분의 결론은 다른 부분을 수행할 필요가 없도록 도와줍니다. Max 분석이 쉽게 수행되고 실패하면 Min 분석을 수행할 필요가 없습니다. 그림 6.9는 결정적인 결과를 제공하는 분석의 보다 간단한 구성 요소부터 시작하도록 MinMax 분석의 일부를 예약하는 방법을 보여줍니다.

6.6.3 소규모 회사나 소규모 팀은 MinMax 분석을 건너뛰어야 하나요?

또 다른 질문은 "소규모 기업은 AI 알고리즘과 ML 파이프라인 자체에 대한 작업을 통해 프로세스 오버헤드를 최소화한 다음, 이를 제공했을 때 어떤 일이 발생하는지 확인해야 하지 않을까요?"입니다. 예, ML 파이프라인 분석을 건너뛰는 것이 좋습니다. .. 올바른 ML 파이프라인에서 작업하고 있다고 확신할 수 있다면! 문제는 MinMax(또는 이에 상응하는) 분석이 없는 경우, 올바른 ML 파이프라인에서 작업하고 있는지 확신할 수 없다는 것입니다. 소규모 회사와 팀일수록 실수로부터 복구할 수 있는 자금과 리소스가 적기 때문에, 소규모 팀에게는 *MinMax 분석이 더욱 중요합니다.*

AI 프로젝트를 위한 ML 파이프라인을 구축할 때는 본질적으로 상당한 위험을 내포하고 있으며 모범 사례가 아직 등장하고 있는 새로운 영역에서 작업하는 것이며, 첫 번째 시도에서 올바른 ML 파이프라인을 직관적으로 구축할 수 있을 만큼 충분한 AI 프로젝트를 수행한 사람은 거의 없으며, 많은 문제에서 작동하지 않는 ML 파이프라인의 수가 작동하는 ML 파이프라인의 수를 압도하고 있습니다.

그렇다면 올바른 ML 파이프라인을 사용하고 있는지 어떻게 알 수 있을까요? 위험을 감수할 수 있지만, 잘못하면 많은 노력을 기울인 결함이 있는 ML 파이프라인이 이제 골화되어 버릴 수 있습니다.

팁 적절한 ML 파이프라인을 보유하고 있는지 파악하는 것은 소규모 기업의 맥락에서 더욱 중요합니다! 적절한 MinMax 분석은 AI 프로젝트에서 가장 중요한 기술 단계이며, 이를 건너뛰는 것은 프로세스를 간소화하는 것이 아니라 위험을 감수하는 것입니다.

민감도 분석에도 비슷한 논리가 적용됩니다. 어떤 파이프라인 단계를 개선해야 하는지 어떻게 알 수 있을까요? 모든 규모의 기업에서 민감도 분석을 사용하는 것이 중요합니다. 다음 장에서는 이에 대해 자세히 설명합니다.

6.6.4 왜 MinMax 분석이라는 용어를 사용하나요?

비즈니스 및 업계에서 MinMax 분석을 지칭하는 용어는 여러 가지가 사용됩니다. 최적 사례/최악 사례 분석이라고도 합니다. 이러한 용어는 ML 업계에서 자주 듣게 됩니다.⁷ 그러나 업계에서 일하면서 모범 사례/최악 사례 용어가 문제가 되는 이유는 모범 사례를 어느 관점(비즈니스 또는 엔지니어링)에서 측정해야 하는지 불분명한 경우가 많기 때문입니다.

⁷ 최우수 사례/ML 알고리즘의 맥락에서 최악의 경우 사용의 예로서, ML 알고리즘의 최적 사례 결과는 [112]에서 논의됩니다.

이 장에서 분석한 ML 파이프라인을 살펴봅니다. 비즈니스 관점에서 가장 좋은 사례는 무엇인가요? ML 파이프라인을 가장 간단하게 기술적으로 구현하면 비즈니스 문제를 해결할 수 있습니다. 이것이 바로 MinMax 파이프라인의 Min 부분에 사용한 ML 파이프라인입니다. 그러나 엔지니어링 관점에서 보면 Min 결과가 최악의 경우라고 주장할 수 있습니다. 저는 정확히 그렇게 주장하는 엔지니어와 통계학자를 많이 알고 있습니다. 현재 보유하고 있는 ML 파이프라인은 오늘 제품을 출시할 경우 제품의 AI가 얼마나 잘 작동할 수 있는지에 대한 최저한계(최악의 경우)를 설정합니다.

이 모든 논의는 일부 엔지니어에게 큰 관심사이며, 그만한 이유가 있습니다. 부정확한 용어는 업계에서 발생하는 많은 문제의 근본 원인입니다. 이 주장에 공감하지만 실용적인 관점에서 저는 MinMax 분석이라는 용어를 선호합니다.

6.7 연습

다음 연습문제는 이 장에서 소개한 개념을 더 잘 이해하는 데 도움이 됩니다. MinMax 분석의 결과는 그 특성상 해석이 간단합니다. ML 파이프라인을 분석하는 것은 기술 및 비즈니스 기술이므로 비즈니스 전문가와 엔지니어로 구성된 팀을 구성하여 이러한 연습을 함께 수행해야 할 때입니다. 이 장의 모든 연습에서는 그림 6.10에 제시된 ML 파이프라인을 사용합니다.



그림 6.10 ML 파이프라인의 예입니다. 이 장의 연습에 이 파이프라인을 사용하겠습니다.

또한 표 6.1의 앞부분에 제공된 정보를 참조해야 합니다(여기서는 편의를 위해 표 6.2로 반복).

표 6.2 MinMax 분석의 가능한 결과 요약

Min 결과/Max 결과	Max 통과	Max 실패
	ML 파이프라인이 비즈니스적으로 실행 가능합니다.	이 조합은 불가능합니다.
	ML 파이프라인이 비즈니스적으로 실행 가능하려면 개선이 필요합니다.	현재 ML 파이프라인은 비즈니스 문제 해결에 적합하지 않습니다.

다음 질문에 답하세요.

질문 1 : 표 6.2에서 MinMax의 Min 부분은 통과했지만 Max 부분이 실패한 상황에 대한 지침이 없는데, 왜 그런지 설명하세요.

질문 2: 그림 6.10의 ML 파이프라인의 경우, 프로젝트가 사업성을 갖게 되는 값 임계값이 100만 달러라고 가정합니다. MinMax 분석 결과가 다음과 같을 경우 파이프라인을 추구할 가치가 있는지 결정합니다.

- **시나리오 1:** Min 부분은 230만 달러이고 Max 부분은 2300만 달러입니다.
- **시나리오 2:** Min 부분은 50만 달러, Max 부분은 100만 달러입니다.
- **시나리오 3:** Min 부분은 50만 달러이고, Max 부분은 200만 달러입니다.
- **시나리오 4:** Min 부분은 110만 달러, Max 부분은 900만 달러입니다.
- **시나리오 5:** Min 부분은 50만 달러, Max 부분은 90만 달러입니다.

질문 3: 데이터 과학자 또는 기술 관리자인 경우, 선택한 기술 문제를 가지고 이에 대한 ML 파이프라인을 구성하세요. 그 문제에 대해 MinMax 분석의 Max 부분을 수행합니다.

질문 4: 데이터 과학자 또는 기술 관리자인 경우, 6.4.1절에 제시된 예제를 보고 해당 절에 설명된 대로 MinMax 분석을 수행하세요. 해당 섹션에 주어진 달러 금액의 출처를 파악합니다. 힌트: 분류기의 혼동 행렬에서 수익 곡선을 만들었습니다.

질문 5: 6.5.5절에 설명된 전자증거개시 절차 중 소송 비용 절감의 맥락에서 AI의 사용을 어떻게 분류하겠습니까? 섹션 2.5에 소개된 AI 사용 분류법을 사용합니다. 그림 2.5에 표시되어 있으며, 여기서는 그림 6.11로 복제하여 해당 섹션에서 논의된 분류법을 요약합니다.

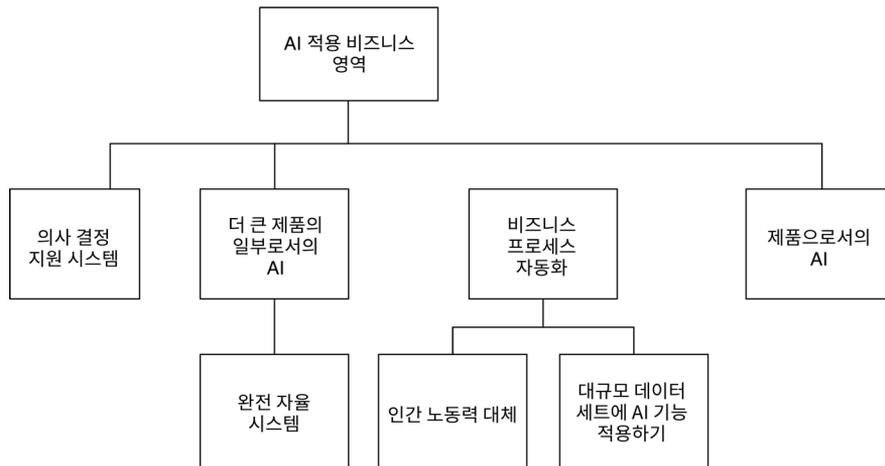


그림 6.11 AI 분류는 비즈니스에서 수행하는 상위 수준의 역할을 기반으로 합니다. 이 분류법을 사용하여 AI로 지원할 수 있는 비즈니스 조치를 도출하는 데 도움을 받을 수 있습니다. (이 그림은 그림 2.5의 반복입니다.)

요약

- 프로젝트 관리는 대개 시간 제약이 있는 상황에서 현재 가지고 있는 정보를 바탕으로 최선의 결정을 내리는 것입니다. ML 파이프라인의 비즈니스 가치를 조기에 파악하려면 MinMax 분석을 사용하여 분석해야 합니다.
- 프로젝트에서 리소스를 경제적으로 할당하려면 올바른 ML 파이프라인을 사용하고 있는지 파악한 다음 필요에 따라 해당 ML 파이프라인의 올바른 단계를 개선해야 합니다. 전자는 MinMax 분석을 통해, 후자는 민감도 분석을 통해 수행됩니다. 이것은 CLUE 프로세스의 *경제화* 부분입니다.
- MinMax 분석을 통해 ML 파이프라인이 이미 비즈니스 목표를 달성하고 있는지, 목표를 달성하기 위해 개선이 필요한지, 아니면 목표를 달성할 수 없는지 판단할 수 있습니다.
- MinMax 분석은 AI 프로젝트에서 "실패할 거면 빨리 실패하는 편이 낫습니다!" 는 정책을 구현하는 데 도움이 됩니다.

AI 프로젝트를 성공 으로 이끄는 가이드

이 장에서 다루는 내용

- ML 파이프라인에서 민감도 분석 수행하기
- 고급 민감도 분석 방법 평가하기
- 파이프라인에서 시간의 영향 고려하기
- '실패할거면 빨리 실패하는 편이 낫습니다'라는 정책을 구현하는 프로젝트 구성하기

이 장에서는 다음과 같은 질문에 답합니다. "ML 파이프라인에 개선이 필요한 경우 어떻게 해야 하며, ML 파이프라인의 올바른 단계를 개선하고 있는지 어떻게 알 수 있나요?" 이러한 문제는 거의 항상 이미 시장에 출시된 AI 제품에서 발생하며, 여러분의 목표는 AI 제품의 사용자 경험을 지속적으로 개선하는 것입니다.

비즈니스 목표를 달성하기 위해 현재 ML 파이프라인을 개선해야 하는 경우, AI 프로젝트의 초기 개발 단계에서도 동일한 질문이 발생합니다. 기술적으로 이러한 상황은 MinMax 분석의 Min 부분이 실패하고 Max 부분이 통과할 때 발생합니다. (섹션 6.4.3에서 이러한 시나리오에 대한 자세한 내용을 설명합니다.)

이 장에서는 ML 파이프라인을 개선하는 방법을 보여드리겠습니다. 핵심은

ML 파이프라인의 어느 단계에 개선 노력을 집중해야 하는지 정확하게 결정하여 리소스를 절약하는 것입니다. CLUE 프로세스의 *경제화* 부분에서는 리소스를 가장 잘 활용하는 방법을 다룹니다.

- 7.1장에서는 민감도 분석을 통해 ML 파이프라인의 어느 단계에서 개선이 필요한지 알아보는 방법을 살펴봅니다.
- 섹션 7.2에서는 CLUE 프로세스의 여정을 마무리합니다.
- 7.3장에서는 민감도 분석을 수행하는 고급 방법과 이를 사용해야 하는 시점에 대해 설명합니다.
- 7.4장에서는 AI 프로젝트 출시 이후 ML 파이프라인의 성장과 유지 관리를 관리하는 방법을 설명합니다.
- 섹션 7.5에서는 승자 프로젝트를 강화하고 패자 프로젝트를 차단하여 일련의 AI 프로젝트와 현재 프로젝트의 균형을 맞추는 방법을 설명합니다.

7.1 민감도 분석으로 ML 파이프라인 개선하기

ML 파이프라인의 결과를 개선해야 한다는 것을 알고 있다면, 파이프라인의 어느 부분을 업그레이드해야 하는지 궁금해집니다. 오류가 적은 더 깨끗한 데이터 또는 더 나은 AI 알고리즘이 필요한가요? 리소스가 제한되어 있으므로 "ML 파이프라인의 모든 것을 동시에 개선하고 어떤 일이 일어나는지 보자"라고 말할 수는 없습니다. 개선할 ML 파이프라인의 단계를 선택해야 합니다. 이 섹션에서는 다음에 개선할 ML 파이프라인의 가장 적합한 단계를 찾는 과정을 안내하는 도구를 소개합니다. 이 도구를 *민감도 분석*이라고 합니다.

정의 *민감도 분석*은 ML 파이프라인의 단일 단계를 개선하면 파이프라인 전체의 결과가 어떻게 개선되는지 보여줍니다. 민감도 분석은 먼저 업그레이드해야 하는 ML 파이프라인의 단계를 안내합니다.

민감도 분석의 핵심은 비즈니스 질문에 대한 답변입니다. "최대 성과를 거두기 위해 ML 파이프라인의 어느 단계에 투자해야 할까?"라는 질문에 대한 해답입니다. 이 질문에 대한 답을 알면 파이프라인 개선에 투입되는 리소스를 절약할 수 있습니다.

예를 살펴보겠습니다. 그림 7.1의 파이프라인이 있고 파이프라인의 결과(E 단계의 출력)를 개선하고 싶다고 가정해 보겠습니다.

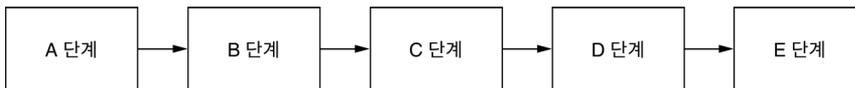


그림 7.1 ML 파이프라인의 예입니다. 이 파이프라인을 민감도 분석의 기본 예시로 사용합니다. (독자의 편의를 위해 그림 6.10을 반복합니다.)

실제로 "파이프라인의 각 단계를 개선하면 어떤 결과가 나올까요?"라고 질문하는 것입니다. 예를 들어, A 단계가 1% 개선되면 전체 파이프라인의 개선 효과는 얼마인가요? 그런 다음 B, C, D 및 E 단계에 대해 동일한 질문을 합니다. 민감도 분석은 이러한 질문에 답하는 데 사용하는 도구이며, 직관과 직감을 데이터 기반 접근 방식으로 대체할 수 있게 해줍니다.

팁 민감도 분석은 ML 파이프라인에서 한 단계를 개발하는 데 필요한 비즈니스 가치를 제공합니다. 모든 단계에 대한 민감도 분석을 통해 각 단계가 개선될 때 비즈니스가 얼마나 전반적으로 개선되는지에 따라 파이프라인의 단계 순위를 매길 수 있습니다.

민감도 분석 결과를 기반으로 ML 파이프라인의 단계에 우선 순위를 지정하고 개선에 필요한 작업의 백로그를 만들 수 있습니다. 백로그가 생성되면 일반적으로 사용하는 프로젝트 관리 방법론을 사용하여 나머지 프로젝트를 관리할 수 있습니다. 민감도 분석을 사용하면 ML 파이프라인 개선 문제를 일상적으로 내리는 관리 의사 결정과 유사한 의사 결정으로 전환할 수 있습니다. 이 접근 방식은 환경이 애자일인지 여부에 관계없이 적용됩니다. ML 파이프라인의 한 단계를 업그레이드하는 데 드는 비용과 시간, 비즈니스 이점을 균형 있게 고려합니다.

참고 다음 섹션인 7.1.1과 7.1.2는 엔지니어링 배경을 가진 독자를 위해 작성되었으므로 간단한 미적분학 수준의 개념이 먼저 소개됩니다. 팀에서 민감도 분석을 수행하는 방법에 대한 아이디어만 얻고자 하는 경우 해당 섹션의 세부 사항을 건너뛰어도 됩니다.

다음 섹션에서는 민감도 분석을 수행하는 방법에 대한 두 가지 고급 방법을 소개합니다.

- 섹션 7.1.1에서는 로컬 민감도 분석을 다룹니다. 팀은 ML 파이프라인의 한 단계에서 점진적인 개선만 가능할 것으로 예상되는 경우 로컬 민감도 분석을 사용해야 합니다.
- 섹션 7.1.2에서는 글로벌 민감도 분석을 다룹니다. ML 파이프라인의 한 단계에서 광범위한 개선이 가능할 것으로 예상되는 경우 팀은 글로벌 민감도 분석을 사용해야 합니다.
- 섹션 7.1.3에서는 민감도 분석 결과를 해석하는 예제를 제시합니다.

다음에 개선할 파이프라인 단계를 결정하는 관리자는 주로 민감도 분석 결과(섹션 7.1.3에 설명되어 있음)를 해석하는 데 관심이 있으며, 수행되는 분석 유형은 부차적인 관심사입니다. 그러나 민감도 분석을 수행하는 기술 전문가는 로컬 또는 글로벌 분석 중 올바른 분석 형식을 선택하는 방법을 알아야 합니다.

7.1.1 로컬 민감도 분석 수행하기

로컬 민감도 분석은 질문에 대한 답을 제공합니다: "현재 ML 파이프라인의 한 단계를 조금만 개선하면 비즈니스 결과는 어떻게 될까?"라는 질문에 답합니다. 이러한 유형의 민감도 분석은 특정 단계에서 점진적으로 작은 개선만 가능할 것으로 예상되는 경우에 적합합니다. 예를 들어, 사용자가 (또는 더 넓은 커뮤니티가) 이미 파이프라인의 특정 단계를 개선하는 데 많은 노력을 기울여 해당 단계의 결과를 크게 개선할 수 있는 시기가 지났다고 생각하는 경우를 들 수 있습니다.

예를 들어, 그림 7.1의 ML 파이프라인을 개선하고 싶고 개선 시 파이프라인의 어떤 단계가 해당 파이프라인의 전체 성능을 가장 잘 이끌어낼 수 있는지 찾고자 한다고 가정해 보겠습니다. 이를 위해 ML 파이프라인의 모든 단계에 민감도 분석을 적용합니다.

참고 단일 단계에 대한 민감도 분석은 ML 파이프라인의 특정 단계를 실제로 개선(가능한 모든 결과에 대해)하는 것보다 훨씬 더 빠르게 수행할 수 있습니다. 따라서 민감도 분석을 다음 단계에서 개선할 파이프라인의 단계에 대한 지침으로 사용할 수 있습니다.

그림 7.1의 B 단계를 분석해 보겠습니다. B 단계에서 입력을 두 가지 범주로 분류한다고 가정합니다. 입력을 올바른 카테고리로 분류하는 B 단계의 능력을 측정하기 위한 기술적 지표가 분류 정확도라고 가정해 봅시다. 또한 현재 B 단계에서 분류 정확도가 $x\%$ 라고 가정합니다. 그림 7.2는 이 민감도 분석 방법을 보여줍니다.

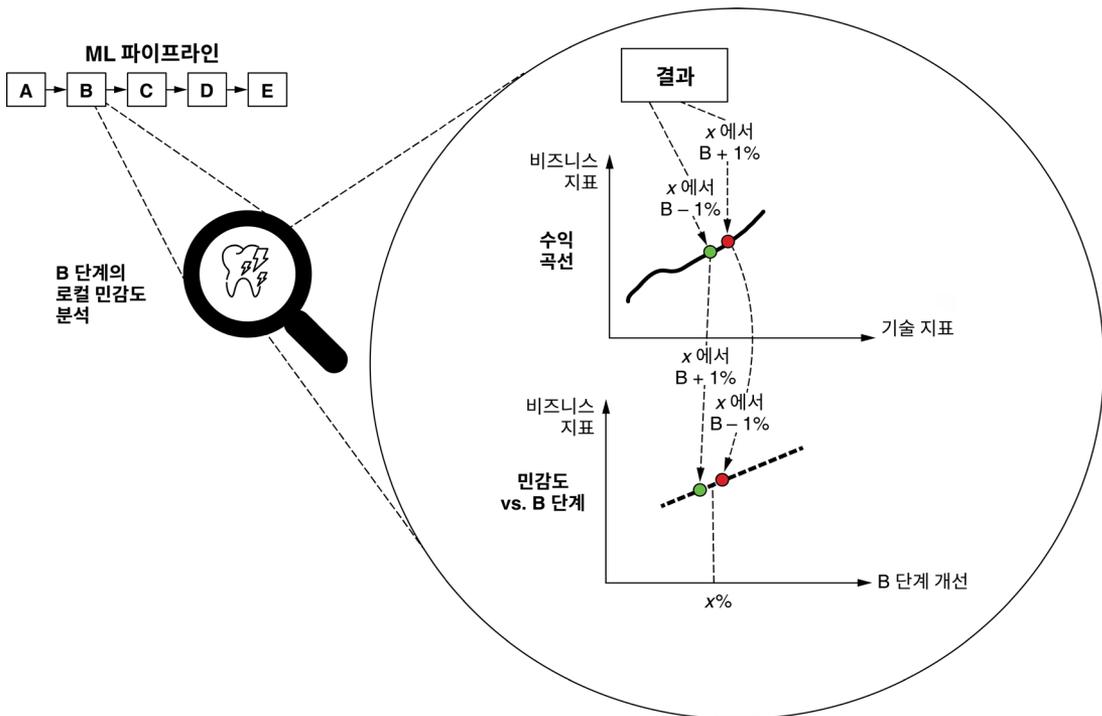


그림 7.2 로컬 민감도 분석. B 단계의 응답이 약간 개선된 경우 이 분석에서는 ML 파이프라인의 선형 응답을 가정합니다. B 단계에서 0.5%의 이득이 파이프라인의 결과를 1% 개선하는 경우, B 단계에서 1% 이득이 발생하면 전체 ML 파이프라인에서 2% 개선이 발생합니다.

B 단계의 분류 정확도를 $x\%$ 부근에서 변경하면 파이프라인의 마지막 단계(E 단계)의 출력은 어떻게 됩니까? $x - 1\%$ 와 $x + 1\%$ 에서는 어떻게 되나요? 단계 B의 결과 개선을 시뮬레이션하여 국소 민감도 분석을 수행합니다.

분류기의 정확도가 $x\%$ 인 지점 근처에서 이러한 유형의 민감도 분석을 로컬로 수행합니다. B 단계의 출력을 $x - 1\%$ 및 $x + 1\%$ 의 정확도를 갖도록 변경하면 전체 파이프라인의 결과를 얻은 다음 B 단계의 변경이 ML 파이프라인의 출력에 미치는 영향을 측정할 수 있습니다. 수익 곡선을 사용하여 기술 메트릭을 비즈니스 메트릭으로 변환하고 마지막으로 B 단계의 변경 사항과 전체 파이프라인의 비즈니스 결과 간의 관계를 플롯합니다.

경고 이익 곡선과 민감도 대 단계 곡선은 완전히 다른 두 곡선입니다. 전자는 전체 ML 파이프라인을 측정하는 기술 지표가 변경될 때 비즈니스 지표가 어떻게 변화하는지 보여줍니다. 후자는 개별 단계의 개선에 따라 비즈니스 지표가 어떻게 변화하는지를 보여줍니다.

1% 더 나빠지는 (또는 더 좋아지는) 방법

1% 더 나쁜 출력을 얻으려면 분류기를 그대로 가져와서 난수 생성기를 통해 분류기의 출력을 실행합니다. 난수 생성기는 분류기의 총 정확도를 1% 낮추도록 조정해야 합니다. 정확도를 1% 높이려면 사람을 사용하여 결과를 검토하고 수정할 수 있습니다.

현재 생산할 수 있는 것보다 더 나은 결과를 얻을 수 있는 상용 기성 제품 또는 서비스를 사용할 수도 있습니다.^a 이러한 COTS 제품 또는 서비스가 ML 파이프라인의 프로덕션 버전에서 영구적인 역할을 수행할 필요는 없습니다. 분석의 목적상 비용, 성능 또는 파이프라인과 COTS 제품을 통합하는 데 따르는 복잡성 등의 이유로 ML 파이프라인의 프로덕션 버전에 COTS 제품을 통합할 수 없는 경우 상관없습니다. COTS 제품은 일회성 정확도 1% 증가를 얻을 수 있는 실험에만 유용하면 됩니다.

^a 인하우스 솔루션 구축에 상당한 리소스를 투자하기 전에 항상 상업적 환경을 조사해야 합니다. 따라서 이러한 COTS 솔루션이 무엇인지 이미 알고 있어야 합니다.

로컬 민감도 분석을 수행할 때 $x\%$ 부근에서 전체 ML 파이프라인의 응답이 선형이라고 가정합니다. B 단계에서 1%의 변화가 ML 파이프라인의 출력에 1%의 변화를 일으키는 경우, B 단계에서 2%의 변화는 출력에 2%의 변화를 일으킬 것입니다. 민감도 분석에 대한 이 접근 방식을 사용하면, B 단계의 분류 결과 값이 $x\%$ 인 근처에서 전체 ML 파이프라인의 출력의 동작을 이해할 수 있습니다.

민감도 분석에 대한 이 접근 방식은 민감도 분석 결과의 개선이 점진적으로 이루어질 것으로 예상하고 1%의 성능 향상은 중요하지 않을 것으로 예상하는 경우에 가장 적합합니다.

참고 이 상황의 전형적인 예는 개선하려는 파이프라인 단계가 일부 AI 알고리즘의 구현인 경우입니다. 팀에서 한동안 해당 단계를 개선하기 위해 노력했을 수도 있습니다. 여기서는 메트릭을 조금만 개선해도 어려움을 겪을 수 있다고 가정합니다.

로컬 민감도 분석을 설명하기 위해 방금 사용한 예제에서 1%의 지표 개선에 마법 같은 것은 없습니다. 반드시 1% 개선을 사용할 필요는 없으며 0.1%, 1.5%, 2% 또는 다른 백분율을 사용할 수도 있습니다. 중요한 것은 스테이지에서 가능한 총 개선의 일부인 백분율 증가를 사용해야 한다는 것입니다. 예를 들어, 잠재적 이득이 0.1%로 제한되어 있다면 0.05%의 증분을 사용할 수 있습니다.

7.1.2 글로벌 민감도 분석

종종 ML 파이프라인의 특정 단계에 대한 작은 개선에 국한될 것이라고 믿을 이유가 없습니다. 한 단계를 30% 또는 60%까지 개선할 수 있을까요? 글로벌 민감도 분석은 단일 단계의 급격한 개선에 대해 ML 파이프라인이 어떻게 반응하는지 이해하는 데 도움이 됩니다.

파이프라인의 한 단계에서 잠재적인 극적인 개선의 원천이 되는 한 가지 예는 해당 단계의 구현이 아직 없지만 완전히 다른 결과를 제공할 수 있는 여러 가지 가능한 단계 구현이 있다는 것을 알고 있는 경우입니다. 또 다른 예는 데이터 정리를 수행하는 파이프라인 단계를 개선하는 경우입니다. 적어도 이론적으로는 이러한 단계에 충분한 노력을 기울인다면 데이터를 완전히 정리할 수 있습니다.

참고 실제로는 높은 데이터 품질을 감당하고 달성할 수 있는 데에는 한계가 있습니다. 하지만 입력 데이터의 품질을 얼마나 향상시킬 수 있는지는 상당한 수준으로 제어할 수 있습니다.

한 단계의 결과를 크게 개선할 수 있는 경우, 넓은 범위에 걸친 ML 파이프라인의 반응을 살펴봐야 하므로 로컬 민감도 분석은 적절하지 않습니다. 대신 테스트 지점 간 간격을 두고 사용 가능한 전체 범위의 값을 테스트해야 합니다. 그림 7.3은 민감도 분석에 대한 이러한 접근 방식을 보여줍니다.

글로벌 민감도 분석은 로컬 민감도 분석과 유사하게 수행되지만, 두 지점($x - 1\%$ 및 $x + 1\%$)에서 분석을 수행하는 대신 스테이지가 생성할 수 있는 값의 범위에서 분석을 수행합니다. 이 접근 방식을 사용하면 ML 파이프라인의 단일 단계의 변경 사항과 ML 파이프라인 전체의 출력 간의 비선형 관계를 더 잘 수용할 수 있습니다. 단점은 더 많은 포인트를 분석하기 때문에 민감도 분석에 더 많은 작업을 투입해야 한다는 것입니다. 그렇다면 얼마나 많은 포인트를 (그리고 어떤 간격으로) 사용해야 할까요?

간격은 현재 성능 수준과 가능하다고 생각하는 최대 성능 수준(또는 100%에 도달할 수 없다고 의심할 이유가 없는 경우 100%)을 비교하는 데서 비롯됩니다. 분석을 수행하는 데 필요한 포인트 수에 관해서는 테스트 포인트당 분석을 수행하는 데 필요한 노력의 양에 따라 결정됩니다. 최소 3개의 포인트로 시작하여 사용 가능한 시간 내에 수용 가능한 만큼의 포인트를 사용하는 것이 좋습니다.

파이프라인의 모든 단계에 대한 민감도 분석을 완료하면 파이프라인의 개별

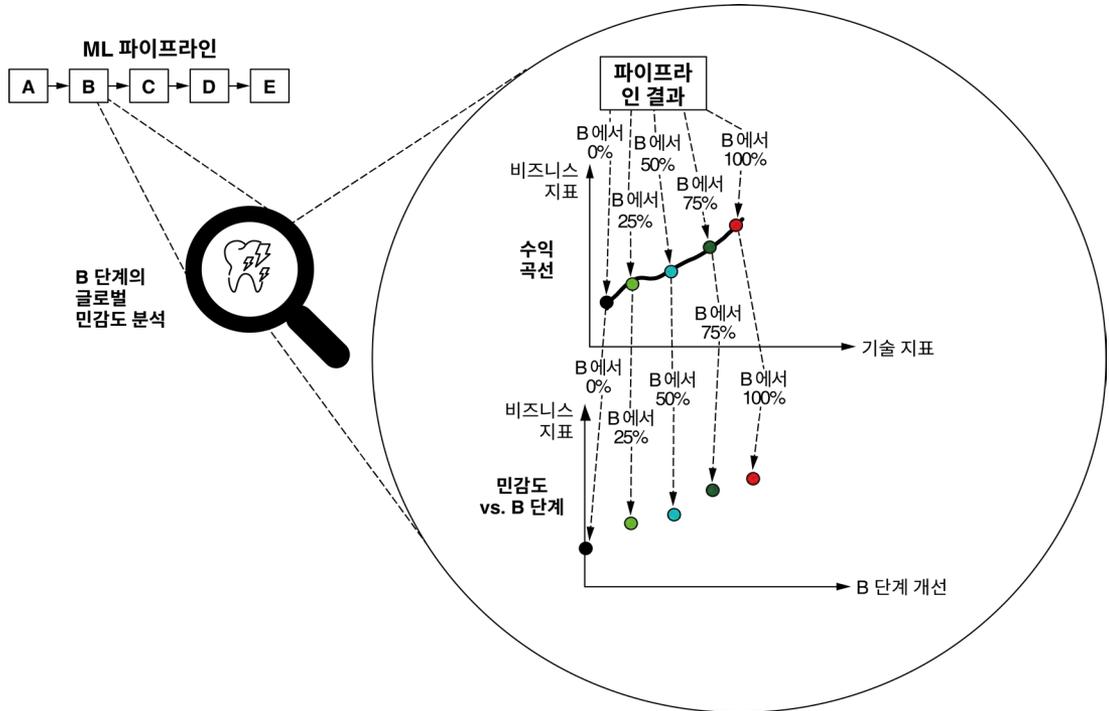


그림 7.3 글로벌 민감도 분석은 광범위한 값을 사용합니다. 파이프라인의 일부 단계에서 약간의 개선만 가능하다고 믿을 이유가 없는 경우 (즉, 대폭적인 개선이 가능하다고 믿는 경우) 글로벌 민감도 분석을 수행합니다.

단계에서 변경 사항이 비즈니스 가치에 어떤 영향을 미칠 수 있는지에 대한 데이터를 갖게 됩니다. 이 데이터는 '경험과 직관'을 기반으로 ML 파이프라인의 결과를 개선하는 사람들에 비해 엄청난 이점을 제공합니다.

7.1.3 민감도 분석 결과 활용 예시

그림 7.1의 ML 파이프라인이 있고 MinMax 분석 결과 비즈니스 목표에 도달하기 위해 더 개선해야 하는 것으로 나타났다고 가정해 보겠습니다. 파이프라인의 각 단계를 개선하는 데 걸리는 시간(그리고 각 단계를 얼마나 개선할 수 있는지)에 대한 개발 팀의 추정치가 있습니다. 각 단계를 개선하는 데 몇 주 동안 팀의 과반수를 차지할 정도로 상당한 시간이 소요될 것입니다. 제품을 빨리 출시하고 싶기 때문에 성과가 합당한 개선 사항만 구현하려고 합니다.

비즈니스 지표가 단위당 수익(달러)이고 값 임계값에 도달하려면 단위당 3달러의 개선이 필요하다고 가정해 보겠습니다. 또한 민감도 분석에서 다음과 같은 결과가 있다고 가정합니다.

- 1 단계 A와 B를 크게 개선할 수 있습니다. 다양한 개선 사항을 시뮬레이션하는 것은 간단했습니다. 그러나 글로벌 민감도 분석을 수행한 결과, 이 두 단계 중 어느 단계도 파이프라인의 결과에 큰 영향을 미치지 않았습니다.
- 2 C 단계는 약 1~2%만 개선할 수 있습니다. 엔지니어가 한 지점에서 민감도 분석을 수행하는 데 한 시간이 걸립니다. 분석 결과, 로컬 민감도 분석에 따라 C 단계가 1% 개선될 때마다 전체 ML 파이프라인이 단위당 \$10/%씩 개선됩니다.
- 3 D 단계도 1~2% 정도만 개선할 수 있으며, 전체 팀이 한 지점에서 분석을 수행하는 데 이틀이 걸립니다. 두 지점의 로컬 민감도 분석 결과 이 단계에서 1% 개선에 대한 민감도는 \$.05/단위/%인 것으로 나타났습니다. D 단계 개선의 난이도는 C 단계 개선의 난이도와 비슷합니다.
- 4 E 단계는 현재 수준 이상으로 전혀 개선할 수 없습니다. (알림만 제공합니다.)

이 예에서는 C 단계를 개선하기로 선택합니다. 민감도가 높고 D 단계와 마찬가지로 업그레이드가 쉬워 보이기 때문입니다. 가장 중요한 것은 C 단계에서 합리적이고 달성 가능한 수준으로 개선하면 비즈니스 목표에 도달할 수 있다고 생각하기 때문입니다.

7.2 CLUE를 완료했습니다

6.2절에서 배운 것처럼, MinMax 분석과 민감도 분석의 조합은 부족한 자원을 *경제화*하는 방법이며, 이는 CLUE의 최종 E입니다. MinMax 분석은 올바른 ML 파이프라인에서 작업하고 있음을 알려줍니다. 민감도 분석은 해당 파이프라인의 올바른 단계에서 작업하는 데 도움이 됩니다.

팁 데이터 과학자라면 여기서 반복적인 것을 발견했을 것입니다. 데이터 과학을 사용하여 ML 파이프라인이 어떻게 작동할지 예측하는 것처럼 MinMax 및 민감도 분석에 대해 생각할 수 있습니다.

CLUE는 통합된 프로세스이며, 각 단계는 이전 단계에 따라 달라집니다. 그림 7.4는 CLUE의 종속성을 보여줍니다.

CLUE의 *경제화* 부분은 *이해하기* 부분을 사용합니다(그림 4.4와 같이 수익 곡선 형태). *이해* 부분은 비즈니스 및 기술 지표가 *연결*되어야 합니다.. 마지막으로, 올바른 비즈니스 문제에 대해 작업했는데, 이 부분이 바로 CLUE의 *고려하기* 부분입니다.

참고 CLUE 프로세스의 최종 목표는 나중에 후회하는 일을 줄이는 것입니다. CLUE는 비즈니스와 기술을 연계하는 방식으로 AI 프로젝트를 구성합니다. CLUE는 잘못된 비즈니스 문제를 해결하거나 예상한 비즈니스 결과를 제공하지 못하는 기술 솔루션을 쫓는 등 예측 가능한 낭비를 방지합니다.

CLUE

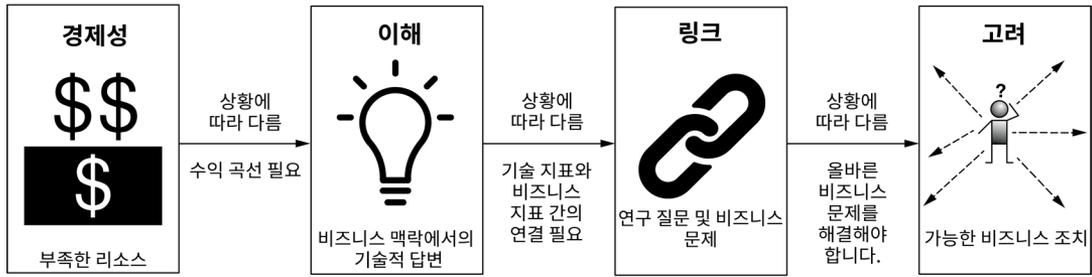


그림 7.4 CLUE의 후속 단계 사이의 중속성—이전 단계의 올바른 구현에 따라 달라집니다. CLUE를 따르면 올바른 비즈니스 문제를 해결하고, 해당 문제를 해결하는 데 적합한 ML 파이프라인을 선택하며, 항상 파이프라인의 올바른 단계를 개선하기 위해 노력할 수 있습니다.

프로젝트의 모든 단계에서 CLUE는 수집 비용이 저렴하면서도 ML 파이프라인에서 가능한 기술적 결과에 대한 예측력을 갖춘 정보를 기반으로 정보에 입각한 의사 결정에 집중할 수 있도록 도와줍니다. "이 ML 파이프라인이 수용 가능한 비즈니스 결과를 제공할 가능성은 얼마나 될까?"와 같은 질문에 답할 수 있습니다.

참고 CLUE는 현재 사용 가능하거나 빠르게 수집하기 쉬운 최상의 정보를 기반으로 의사 결정을 내릴 수 있도록 도와줍니다.

CLUE가 아닌 다른 프로세스를 사용하기로 선택하더라도 그러한 프로세스는 올바른 비즈니스 문제를 해결하고, 비즈니스 측면에서 결과를 이해하며, 보유한 정보(직감이 아닌)를 기반으로 리소스를 절약해야 하는 등 CLUE와 동일한 문제를 해결해야 합니다. 이러한 고려 사항 중 어느 하나라도 해결하지 못하면 프로젝트 결과에 위험을 감수하는 것입니다.

데이터가 없으면 인간의 감이 대신합니다!

데이터를 사용하여 ML 파이프라인의 개발을 관리하지 않는다는 것은 직감이나 특정 작업을 옹호하는 팀 내 인물을 얼마나 신뢰하는지에 따라 개발을 처리하고 있다는 것을 의미합니다.

전체 ML 파이프라인을 이해하는 팀원은 소수에 불과하지만, 대부분의 팀원은 자신이 개인적으로 작업하는 파이프라인의 일부분만 폭넓게 이해하는 것이 일반적이라는 점을 기억하세요. 팀원들은 이해하지 못하는 부분보다는 자신이 이해하는 부분을 개선하는 방법에 대해 조언하는 것이 더 편한 것이 인간의 본성입니다.

기술적 전문 지식이 부족한 영역에서 기술 제안을 판단하는 것은 관리자가 해결해야 할 최악의 상황입니다. 팀원들은 자신의 의견을 옹호하면서 리더십, 성실성, 성숙도, 설득력 및 전문성의 자질을 제시할 것입니다. 이러한 자질은 진심입니다. 또한 ML

(계속)

파이프라인에서 어떤 부분을 개선하는 것이 가장 생산적인지와도 전혀 무관합니다. 사람에게 대한 이해에 기반한 의사 결정은 잘못된 방향으로 나아갈 수 있습니다.

ML 파이프라인의 신들은 유머 감각이 있습니다. ML 파이프라인에서 가장 생산성이 높은 단계를 팀에서 가장 설득력이 떨어지는 구성원에게 할당하는 경우가 많습니다. 그러면 그 신들은 기꺼이 그 결과를 받아들일 것입니다.

CLUE와 같은 프로세스를 사용하는 요점은 AI 알고리즘과 AI 시스템에 대한 세부적인 지식의 필요성을 비즈니스 측면에서 기술적 결정을 이해할 수 있는 일련의 메트릭으로 대체하는 것입니다. 2장의 공장 관리자의 예를 기억하시나요? 교대 근무자만큼 공장을 잘 다루지는 못했지만 공장을 운영하는 방법을 알고 있던 관리자가 있었나요? 그 관리자는 데이터와 관리 노하우를 사용하여 공장을 운영했습니다.

여러분도 CLUE가 제공하는 데이터와 관리 기술을 활용하여 AI 프로젝트를 운영할 수 있습니다. CLUE를 적용하면 관리자에게 기술 지식이 기술적 논쟁을 판단하는 유일한 도구인 경우 필요한 수준의 AI 및 데이터 엔지니어링에 대한 복잡한 세부 사항을 학습하도록 요청하는 것보다 더 확장 가능한 접근 방식을 제공합니다.

관리자도 사람입니다

반대하는 사람들은 어떤 일이 있어도 AI 프로젝트를 이끌기 위해서는 AI에 대한 깊은 이해가 필요하다고 말할 수 있습니다. 특히 그 AI 기술이 리더십 기술을 희생한다면 더욱 그렇습니다.

또한 그런 반대론자들의 말이 맞다면 비즈니스와 산업의 많은 영역에서 광범위한 AI 혁명이 일어나지 않았을 것입니다. AI를 이해하는 박사 학위 수준에 빠르게 도달할 수 있는 능력, 시간, 끈기, 집중력을 (그리고 그보다 덜 필요한 다른 자질들을) 갖춘 사람들이 충분히 있다고 생각하시나요? 네, 그런 사람들은 좋은 리더가 되는 방법도 배웠을 겁니다. 하지만 AI도 빠르게 발전하고 있기 때문에 이를 따라잡기 위해서는 광범위하고 지속적인 기술 교육이 필요합니다. 그런 사람들이 그 모든 것을 배우고 나면 필요한 일을 할 시간을 어디서 구할 수 있을까요?

소수의 사람에게만 요구되는 자질을 조합하여 "관리자에게 AI의 세부 사항을 가르치자"는 방식은 확장성이 없습니다. 게다가 이러한 관리자는 최고의 기술 기업뿐만 아니라 향후 몇 년 내에 AI를 적용해야 하는 모든 분야에서 필요합니다.

AI 혁명을 이르기 위해 필요한 만큼 많은 리더에게 AI의 세부 사항을 가르칠 수 있을 거라고 기대하는 것은 현실적이지 않다고 생각합니다. 상당한 AI 전문 지식이 필요하지 않은 AI 프로젝트를 이끌 방법을 찾지 못하면 성공적인 AI 프로젝트가 많지 않을 것입니다.

직관력이 뛰어나고 경험의 기회가 거의 없었던 새로운 영역의 프로젝트를 진행하는 관리자가 있을 수 있습니다(현재 대부분의 AI 프로젝트의 경우처럼). 그런 관리자가 얼마나 많은지 여러분이 추측해 보시죠. 하지만 직관적인 감각이 없는 사람들에게는 CLUE와 같은 프로세스를 기반으로 프로젝트를 관리하는 것이 직감만으로 관리하는 것보다 관리와 소프트웨어 아키텍처 책임을 더 잘 수행할 수 있게 해준다고 말하고 싶습니다.

7.3 민감도 분석을 위한 고급 방법

앞서 소개한 파이프라인 분석 방법은 빠르게 수행할 수 있으며 파이프라인이 장기적으로 사용하기에 적합한지 조기에 파악하는 데 도움이 될 수 있습니다. CLUE와 AI를 처음 사용할 때는 섹션 7.1에 설명된 민감도 분석 방법을 사용하는 것이 좋습니다. 그러나 민감도 분석에 능숙해지면 민감도 분석을 수행하는 더 정밀한 (그러나 훨씬 더 복잡한) 방법에 관심이 생길 수 있습니다. 이 섹션에서는 이러한 방법에 대해 설명합니다.

앞으로의 복잡한 주제

이 섹션에서는 성공적으로 적용하려면 상당한 프로세스 엔지니어링 경험이 필요한 고급 방법에 대해 설명합니다. 이미 프로세스 엔지니어링에 대한 배경 지식이 있는 고급 독자 또는 이미 CLUE를 구현하고 더 잘 활용하고자 하는 팀을 대상으로 합니다.

고급 방법이 필요할 수 있는 상황을 인식하고, 이러한 방법을 충분히 이해하여 전문가에게 어떤 도움을 요청해야 하는지 알 수 있도록 가르치는 것이 목표입니다.

섹션 7.3.2 및 7.3.3은 이 책에서 AI 도구, 기술 및 인프라에 상당한 투자를 한 대기업에만 해당되는 부분이라고 생각합니다. 이 섹션에서 설명하는 많은 주제를 적용하려면 프로세스 엔지니어링 분야의 전문가가 필요하며, 이러한 전문 지식을 한 장이나 한 권의 책에서 배울 수 있는 방법은 없습니다.

이러한 전문가를 고용할 예산이 없는 경우, 혼자서 이러한 작업을 수행하는 방법을 배울 수 있는 몇 가지 참고 자료도 포함되어 있습니다. 이러한 참고 자료를 최대한 활용하려면 엔지니어링 배경 지식과 인내심이 필요합니다.

초기 ML 파이프라인을 개발하고 많은 시간과 비용을 투자한 후에는 해당 파이프라인을 개선할 수 있는 방법을 분석하는 데 더 많은 시간을 할애할 수 있습니다. 이 단계에서는 고급 분석 방법이 유용합니다. 특정 시나리오에서 이러한 방법은 수행된 분석의 복잡성을 증가시키는 대가를 치르더라도 더 나은 분석 결과를 제공할 수 있습니다. 이 섹션의 나머지 부분에 대한 로드맵은 다음과 같습니다.

- 7.3.1절에서는 비선형성의 존재를 감지하는 방법을 보여줍니다.
- 섹션 7.3.2에서는 ML 파이프라인의 상호 작용에 대해 설명합니다.

- 섹션 7.3.3에서는 상호작용을 발견하고 해결할 수 있지만 성공적으로 적용하려면 상당한 프로세스 엔지니어링 지식이 필요한 기술인 실험 설계의 개념을 소개합니다.
- 섹션 7.3.4에서는 민감도 분석을 수행할 때 발생할 수 있는 일반적인 비평을 다룹니다.
- 섹션 7.3.5에서는 데이터 품질을 개선하여 ML 파이프라인을 개선하기 위한 모범 사례에 대해 설명합니다.
- 섹션 7.3.6에서는 ML 파이프라인에 대한 민감도 분석 분야의 최근 발전된 몇 가지 적용 가능성에 대해 설명합니다.

민감도 분석에는 비선형성[125, 126]과 파이프라인 단계 간의 상호 작용이라는 두 가지 중요한 오류 원인이 있습니다. 비선형성이 발생하면 로컬 민감도 분석 결과에 오류가 발생할 수 있습니다. 상호 작용을 만나면 파이프라인의 두 단계를 변경할 때 한 번에 하나씩 변경하는 것보다 함께 변경하면 상당히 다른 동작이 발생할 수 있습니다. 각 소스를 간략하게 살펴봅시다.

7.3.1 로컬 민감도 분석이 귀사의 ML 파이프라인에 적합하나요?

7.1.1절에 설명된 국소 민감도 분석은 단일 단계의 변화에 대한 전체 ML 파이프라인의 반응이 선형이라고 가정합니다. 즉, B 단계에서 0.5%의 변화가 전체 파이프라인에서 1%의 개선을 가져온다면, B 단계에서 1%의 개선이 ML 파이프라인에서 2%의 개선을 가져올 수 있습니다. 파이프라인 응답의 선형성에 대한 가정이 위반되면 민감도 분석 결과에 오류가 발생합니다. 이 섹션에서는 선형성 가정이 깨지는 시점을 감지하는 방법을 설명합니다. 이 경우 로컬 민감도 분석은 적절하지 않으므로 글로벌 민감도 분석으로 대체해야 합니다.

비공식적으로 비선형 반응은 수익 곡선의 출력이 선형 반응일 때보다 더 빠르게 (또는 더 느리게) 변할 수 있음을 의미합니다. 그림 7.5는 시스템의 수익 곡선이 비선형 (초선형 또는 볼록형) 방식으로 증가하는 상황을 보여 주며, 파이프라인의 단일 단계의 성능이 주어진 비율만큼 증가하면 수익 곡선의 응답도 해당 비율만큼 증가합니다.

응답의 볼록성이 중요한 이유는 무엇입니까? 그림 7.5에서 볼 수 있듯이 볼록한 응답이 있는 경우 분석을 수행하는 지점에서 멀어질수록 오차가 커지기 때문입니다. 극단적인 경우 오차가 너무 커서 분석 결과가 무효화될 수도 있습니다. ML 파이프라인의 해당 단계에서 개선하면 상당한 수익을 얻을 수 있는 기회를 놓칠 수도 있습니다. 이처럼 확률은 낮지만 영향력이 큰 이벤트를 비즈니스 업계에서는 흔히 **검은 백조**[127]라고 부릅니다.¹ 그러므로 중요한 성과를 놓칠 때 비선형성이 중요합니다. 그림 7.6은 국부 민감도 분석이 볼록성을 놓치는 상황을 보여줍니다.

¹ 유럽에서는 누군가가 검은 백조를 볼 수 있을 만큼 멀리 여행하기 전까지는 오랫동안 모든 백조는 흰색이라고 믿었습니다. 한 마리의 검은 백조는 드물기는 하지만 이 가설을 불식시키는 데 큰 영향을 미쳤습니다.

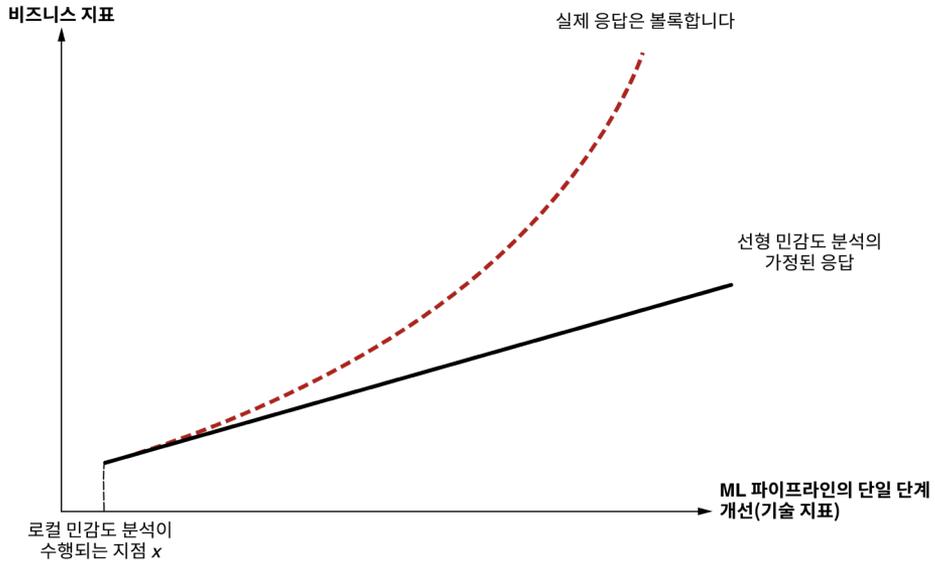


그림 7.5 ML 파이프라인 응답의 볼록성. 분석이 수행된 지점에서 멀어질수록 분석의 오류가 더 커집니다. 로컬 민감도 분석이 수행된 지점에서 멀리 떨어진 곳에서는 절대 추정하지 마세요.

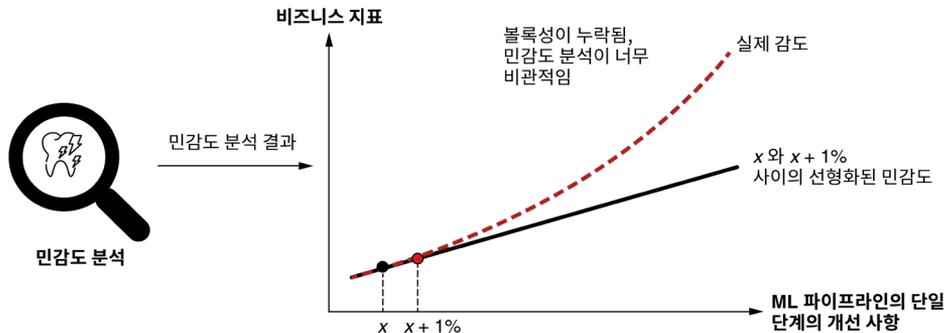


그림 7.6 볼록성이 존재하는 민감도 분석. 두 점, x 와 $x + 1\%$ 에서만 수행된 국소 민감도 분석은 두 점 사이에 항상 선을 그릴 수 있기 때문에 볼록성을 놓쳤습니다.

비선형 응답이 있을 수 있음을 보여주기 위해 사용할 수 있는 휴리스틱 기법이 있으며, 특히 비선형성으로 인해 결과가 크게 왜곡될 가능성이 있는 상황에 적합합니다. 한 가지 휴리스틱은 국소 민감도 분석을 세 지점에서 전역 민감도 분석으로 대체하고 다음을 확인하는 것으로 구성됩니다.

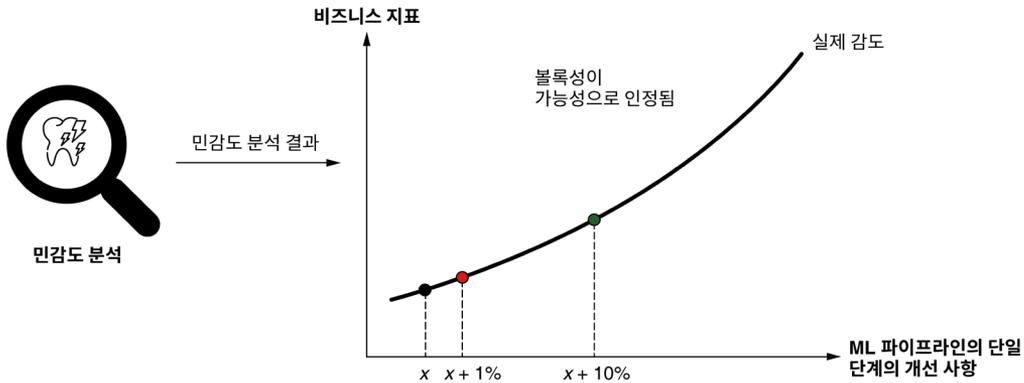


그림 7.7 볼록성이 있는 경우의 글로벌 민감도 분석. 분석의 복잡성이 증가하는 대가로, 글로벌 민감도 분석은 응답의 비선형성을 감지할 수 있습니다.

응답이 선형인지 또는 볼록성/오목함의 징후가 있는지 여부. 이 기법에 대한 자세한 내용은 Taleb 외 [126]에서 설명합니다. 그림 7.7은 이 휴리스틱의 적용을 보여줍니다. 공교롭게도 모든 전역 민감도 분석은 비선형 응답을 감지하기 위해 동일한 기법 (Taleb 외. 논문 [126]에 설명되어 있음)을 적용할 수 있습니다.

선형 민감도 분석에서 발생할 수 있는 오류가 ML 파이프라인에 얼마나 중요하며, 선형 민감도 분석이 볼록성을 놓칠 수 있다는 사실이 항상 글로벌 민감도 분석을 수행해야 한다는 것을 의미하나요? 저는 실용적인 관점을 취하며 모든 프로젝트 관리 결정은 시간 제약 하에서 이루어져야 한다는 점을 기억합니다. 로컬 민감도 분석과 글로벌 민감도 분석의 주요 차이점은 전자는 수행하는 데 두 점(예: x 및 $x + 1\%$)이 필요한 반면, 글로벌 민감도 분석(및 Taleb 등의 논문[126]에 설명된 휴리스틱 접근 방식)은 최소 세 점이 필요하다는 것입니다.

팁 하나 이상의 데이터 포인트에서 민감도 분석을 수행하는 것이 저렴하고 간단하다는 것을 알고 있다면, 저는 항상 전역 민감도 분석을 수행합니다. 비용이 많이 드는 경우(예: 분석을 수행하기 위해 사람을 대리로 사용해야 하는 경우), 적절한 경우 로컬 민감도 분석을 사용하여 두 지점에서만 수행합니다.

추가 데이터 포인트에서 ML 파이프라인의 민감도 분석이 비용이 많이 드는 경우, 볼록성에 대해 걱정하는 유일한 상황은 나머지 파이프라인을 분석한 후에도 명확한 승자가 없는 경우입니다. 하지만 이런 경우에는 민감도 분석 결과는 비슷하지만 볼록한 반응을 보이지 않는 스테이지보다 먼저 볼록한 스테이지의 개선 일정을 잡습니다. 그러면 (아마도) 검은 백조가 나에게 유리하게 작용할 수 있는 기회가 생깁니다.

참고 비선형성을 프로젝트의 위험 요소로 생각해서는 안 됩니다. 불록성은 단계의 민감도가 선형일 때보다 비즈니스 목표를 달성하는 것이 더 쉽다는 것을 의미합니다. 민감도 분석 중 오목함 누락의 영향은 제한적입니다. 프로젝트는 "실패할거라면 빨리 실패하는 편이 낫습니다"라는 정책이 구현되도록 구성되어야 합니다. 따라서 스테이지가 예상보다 느리게 개선되는 경우 이를 조기에 발견하고 해당 스테이지 작업을 중단합니다.

7.3.2 ML 파이프라인 단계 간의 상호 작용을 해결하는 방법

때때로 두 가지를 동시에 변경하는 결과는 하나씩 변경하는 것과는 매우 다릅니다. 두 변수 사이에 상호작용이 있을 때 이런 일이 발생합니다. 이 섹션에서는 상호작용의 예와 ML 파이프라인 분석의 맥락에서 상호작용을 처리하는 방법에 대한 조언을 제공합니다.

상호작용의 한 가지 예로 노트북을 구입할 때 노트북의 무게와 프로세서의 속도를 모두 고려하는 경우를 들 수 있습니다. 다른 모든 것이 동일하다면 더 가벼운 노트북이 항상 더 좋습니다. 다른 모든 것이 동일하다면 더 빠른 프로세서가 항상 더 좋습니다. 그러나 작고 가벼운 노트북에 빠른 프로세서를 장착하면 프로세서를 적절히 식힐 수 있는 공간이 충분하지 않기 때문에 프로세서가 과열될 수 있습니다. 작지만 강력한 노트북을 만드는 것도 비용이 많이 듭니다. 따라서 강력한 프로세서가 탑재된 작은 노트북은 만들 가치가 (또는 구매할 가치가) 없을 수도 있습니다.

상호 작용의 효과는 무엇인가요?

상호 작용이 있는 경우, 한 번에 하나의 변수만 변경하는 분석(예: ML 파이프라인의 단일 단계의 출력)은 유효하지 않을 수 있습니다. 또한, 통계학자 및 데이터 과학자들은 상호작용의 존재가 최소값 및 민감도 분석의 결과에 영향을 미친다고 지적합니다.

그렇습니다만, 이것이 팀이 수행할 수 있는 분석과 어떤 관련이 있을까요? 팀이 상호 작용 분석을 수행하는 방법을 알고 있는 경우에만 상호 작용 분석을 수행할 수 있습니다. 상호작용이 존재하더라도 이를 찾는 방법을 모른다면, 상호작용의 위험을 (그리고 MinMax 및 민감도 분석에 미치는 영향을) 감수해야 합니다.

상호작용에 얼마나 신경을 쓸 것인지는 팀에 따라 다르다는 것이 제 조언입니다. 조직에 프로세스 엔지니어링에 대한 상당한 지식이 있고 여러 지점에서 ML 파이프라인의 동작을 신속하게 분석할 수 있는 능력이 있다면 상호작용 분석을 수행해 보라고 조언하고 싶습니다. 실제로, 이는 일반적으로 ML 파이프라인의 작은 변경으로 막대한 재정적 보상을 얻을 수 있는 프로젝트를 진행하는 대기업의 자금력이 풍부한 팀을 의미합니다.

AI 및 민감도 분석을 막 시작하는 팀이라면 처음에는 상호작용에 대해 걱정하지 말고 한 번에 한 가지 요소만 변경했을 때 ML 파이프라인에서 어떤 일이 일어나는지에 집중하라고 조언합니다. ASQ의 두 가지 식스 시그마 리소스[21,22]는 프로세스에 대한 몇 가지 시작점과 상호작용을 감지하기 위한 실험 설계에 좋은 경험을 가진 사람들의 프로필을 제공하며, 이를 통해 실험 설계에 대한 더 광범위한 주제를 다룹니다([24]).

7.3.3 실험 설계를 사용해야 하나요?

실험 설계(DOE)[24]는 수십 년 동안 프로세스 엔지니어링 분야에서 물리적 물체 제조와 같은 프로세스의 품질, 비용 및 효율성을 개선하기 위해 성공적으로 사용되어 온 방법론입니다. 수백만 달러의 비용이 드는 공장 라인이 있다면, 그 라인이 최적으로 운영되고 있는지 알고 싶을 것입니다. DOE는 실험을 수행하고 그 결과를 통해 공장 라인을 개선할 수 있는 방법을 제시합니다. 이 섹션에서는 DOE에 대해 소개하고 언제 DOE를 AI 프로젝트에 적용할 수 있는지 알려드립니다.

역사적으로 소프트웨어 개발에는 DOE가 많이 사용되지 않았습니다. 그 이유 중 하나는 DOE가 소프트웨어 엔지니어에게 익숙하지 않은 복잡한 주제이기 때문입니다. 더 중요한 것은 소프트웨어 측면에서 DOE 대신 "그냥 해보고 무슨 일이 일어나는지 보자"는 식의 유사 실험을 구현하는 데 드는 비용이 적었다는 점입니다. 예를 들어, 데이터베이스가 어떻게 반응하는지 확인하기 위해 구성 매개변수를 변경하는 것이 쉬웠습니다.

참고 유사 실험에는 많은 약점이 있습니다. 예를 들어, 상호 작용을 놓칠 수 있습니다. 또한 백그라운드 프로세스에 민감하여 백그라운드 프로세스가 불편한 시간에 실행되면 유사 실험 결과에 영향을 미칠 수 있습니다. 유사 실험과 달리 DOE 방법론에 따라 수행된 적절한 실험은 상호 작용 및 백그라운드 프로세스가 있는 경우에도 정답을 제공합니다.

최근 인공지능 프로젝트에서 '그냥 무언가를 시도하는 것'에 드는 비용이 크게 증가했습니다. 대기업의 대규모 프로젝트에서 수백 대의 머신을 사용하여 복잡한 AI 알고리즘을 훈련하는 경우도 드물지 않습니다[128]. 이러한 시스템을 운영하는 데는 많은 비용이 들며, 하드웨어 인프라의 가격이 공장 운영 비용과 비슷해지기 시작하면서 공장을 운영하는 데 사용되는 방법이 소프트웨어 엔지니어에게도 적용될 수 있습니다.

DOE는 유사 실험에 비해 많은 이점을 제공합니다. DOE를 사용하면 비용이 많이 드는 ML 파이프라인 개발을 더 잘 관리할 수 있습니다.

프로젝트에 DOE를 사용해야 하나요? 대부분의 AI 프로젝트에서 DOE는 제대로 구현하기가 복잡하고 전문 교육을 받은 전문가가 있어야 제대로 구현할 수 있기 때문에 권장하지 않습니다. 실험 비용 및 해당 전문가가 너무 비싸서 오늘날 평균적인 AI 프로젝트에서 이 접근 방식을 정당화하기 어렵습니다. 또한, ML 파이프라인을 체계적으로 관리해본 적이 없다면 이 책에서 제시하는 방법을 통해 큰 진전을 이룰 수 있을 것입니다.

참고 프로세스 엔지니어링 분야가 발전해온 역사를 살펴보면, 이 분야 역시 단순한 실험에서 시작하여 나중에 DOE 이론과 지식을 구축했습니다.

하지만 대규모 AI 작업을 운영하고 있고 팀, 하드웨어, 인프라에 대한 자본 투자가 공장 운영 비용과 맞먹는다면, 그리고 ML 파이프라인 관리와 관련하여 내리는 모든 결정의 결과가 그에 상응하는 높은 위험을 수반한다면, 저는 그 권고를 뒤집고

싶습니다. 대신 AI와 프로세스 엔지니어링을 모두 알고 있는 전문가와 협력하는 것이 좋다고 조언합니다. 이러한 전문가는 고객의 시스템에 무엇이 적합한지 사례별로 조언해 줄 수 있습니다. 이미 시스템 운영에 많은 비용을 지출하고 있으므로 실험을 적절하게 설계해야 합니다.

7.3.4 한 가지 일반적인 반대 의견

이 섹션에서는 여러분이 직면할 수 있는 비판과 그 비판이 왜 옳은지, 그리고 ML 파이프라인 분석의 실제 사용 사례와 대부분 관련이 없는지에 대해 설명합니다. 민감도 분석이 유용하지만 최상의 결과는 아닌 결과를 나타내는 예제를 구성할 수 있다는 비판이 있습니다.

예를 살펴보겠습니다. 5개의 지점에서 전역 민감도 분석을 수행했는데 상호작용으로 인해 그림 7.8의 민감도 곡선이 비정상적인 상황이 발생했다고 가정해 보겠습니다.

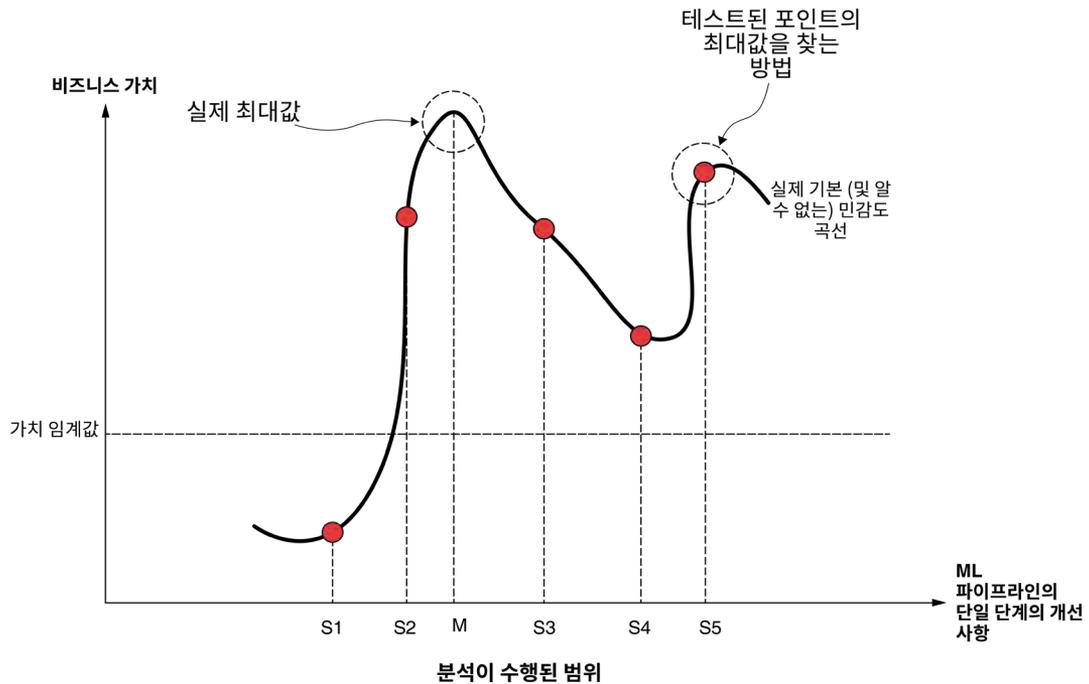


그림 7.8 위치 S1-S5에서 민감도 분석이 수행되었지만 지점 M에서 실제 최대값이 누락되었습니다. 값 임계값을 초과하므로 여전히 수익을 내고 있으므로 상관없습니다. 몇 개의 지점에 대해서만 수행된 값싼 분석으로는 이 문제를 피할 수 없습니다.

그림 7.8에서는 S1-S5의 5개 지점에서 분석을 수행했습니다. 가장 좋은 결과는 살펴본 5개 지점 중 최대값(S5)입니다. 그러나 기본 함수의 절대 최대값인 위치 M은 아닙니다.

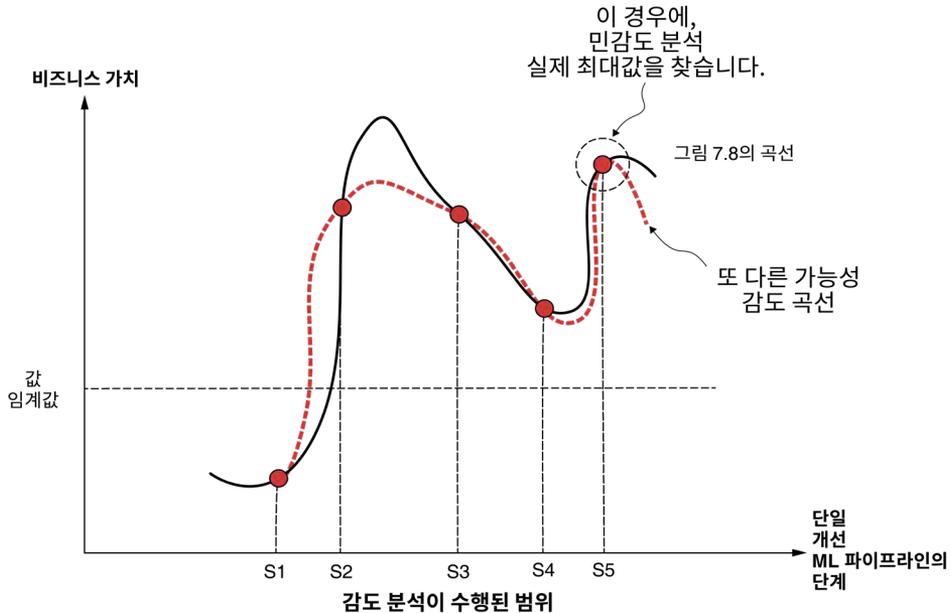


그림 7.9 기저 곡선이 그림 7.8과 반대로 이 그림에 주어진 모양을 갖는 경우 민감도 분석은 실제 최대값을 찾습니다. 기저 곡선의 모양을 알 수 없으므로 해당 곡선의 최대값이 무엇인지는 중요하지 않습니다. 중요한 것은 값 임계값을 초과했다는 것입니다.

앞의 예가 설득력 있어 보이지만 다시 생각해 보세요. 실제로 그림 7.8의 실제 기본 감도 곡선으로 표시된 '진실'에 접근할 수 있나요? 아니, 그렇지 않습니다! 실제 감도는 알 수 없고 프로젝트에서 사용할 수 없으며, 포인트 S1-S5의 감도 분석 결과만 가지고 있습니다. 기본 감도 곡선은 숨겨져 있으며 그림 7.9.1의 곡선일 수 있습니다.

많은 반례를 만들 수 있지만, 여기에는 한 가지 공통점이 있습니다: 제가 언급한 비판은 여러분이 이미 그림 7.8의 곡선의 전체 모양을 알고 있다고 가정합니다! 실제로는 기본 감도 곡선에 접근할 수 없습니다. 만약 그렇다면 애초에 어떤 단계에 투자해야 할지 고민하지 않고 민감도 곡선만 보고 판단할 것입니다.

이제 이 섹션의 원래 이의 제기의 근거가 된 수학적 이론과 실제 프로젝트 관리의 차이점에 대해 알아보겠습니다. 이 제기된 이의 제기는 어떻게 해야 하는지에 대한 실제적인 조언이 없는 이론적인 이의 제기입니다. 비판자는 기본 곡선의 최대값을 찾을 수 있는 몇 가지 방법을 지적할 수 있지만, 자세한 내용을 물어보면 그러한 방법을 사용하려면 많은 지점에서 민감도 분석을 수행해야 한다는 것을 알게 될 것입니다. 분석하는 지점의 수는 분석 비용을 결정하는 요인이므로 이러한 방법은 종종 너무 비싸서 ML 파이프라인에서 개선 결정을 안내하는 데 실용적이지 않습니다.

실무자에게는 솔루션이 필요하며, 이 경우 해답은 이미 문제를 잘 알고 있다는 것을 인식하는 것입니다. "그럼, 당신이 인생에서 벌 수 있는 최대 금액은 얼마입니까?" 라고 묻는 것과 같은 문제입니다. 글썄요, 만약 당신이 적절한 사람들을 소개받았다면 오늘날 구글보다 더 번창한 회사를 설립했을지도 모르지만, 당신은 결코 알 수 없을 것입니다. 여러분은 이 질문에 답할 수 있는 인생의 '소득 민감도' 곡선을 모릅니다.

참고 인생에서 자신이 벌 수 있는 만큼의 돈을 벌었는지 알 수 없습니다. 귀하가 아는 유일한 것은 귀하가 편안하게 살기에 충분한 돈을 벌었는지 아닌지입니다.

인생과 마찬가지로 프로젝트에서도 "곡선의 최대값이 얼마인가?"가 문제가 아닙니다. 여러분은 풍부한 사냥터(섹션 3.1.1)에 와 있으며, 투자한 AI 프로젝트가 수익성이 있는지 확인하고 싶다는 점을 기억하세요. 또한 투자 결정을 내려야 할 때 *이용 가능한 최상의 정보를 바탕으로 결정해야 합니다*. 민감도 분석에서 최대값을 찾지 못했지만 여전히 수익성 있는 파이프라인을 구축할 수 있다면, 이를 비즈니스의 성공이라고 합니다.

참고 민감도 분석이 수익성 있는 영역을 너무 많이 놓쳐서 개선할 수 없을 정도로 막아버리는 ML 파이프라인을 만나는 것은 *드문 일*입니다.² 그런 일이 발생하는 ML 파이프라인이 수익성으로 쉽게 연결되는 것은 더더욱 드문 일입니다. 그런 희귀한 파이프라인은 쉽게 사냥할 수 있는 토끼가 아니며, 여러분은 풍부한 사냥터에 있는 것입니다. 다른 것을 시도해 보세요.

민감도 분석은 현재 이용 가능한 정보를 최대화하여 다음 행동이 수익성이 있는지 여부를 판단할 수 있게 해줍니다. 이것이 성공적인 AI 프로젝트를 실행하는 데 필요한 전부입니다.

비지도 학습은 어떤가요?

민감도 분석(및 MinMax 분석)은 지도 학습에만 적용 가능한지 질문할 수 있습니다. 답은 비지도 학습에도 수익 곡선을 구성할 수 있기 때문에 모든 유형의 AI와 관련이 있다는 것입니다.

귀사의 제품이 데이터를 분석하고 이 데이터로부터 클러스터를 생성한다고 가정합니다. 그 후, 클러스터는 인간에게 제시되고, 인간은 상당한 시간 제약 하에서 내려야 하는 의사 결정에 대한 입력 중 하나로 클러스터를 사용합니다. 예를 들어 복잡한 교통 시스템에서 AI를 사용하여 결함 유형을 클러스터링하는 시스템을 들 수 있습니다.

이러한 상황에서는 더 많은 클러스터를 제시할수록 (그리고 각 클러스터에서 공통점을 파악하기가 더 어려워질수록) 시스템이 사용자에게 제공하는 가치는 줄어듭니다. 분명히 시스템의 출력과 사용자에 대한 가치 사이에는 관계가 있습니다. 실제 사용자의 도움을 받아 실험을 수행하여 사용자에게 대한 가치를 결정해야 할 수도 있습니다. 그 실험의 결과는 수익 곡선의 형태로 설명할 수 있습니다.

² 이러한 상황은 분석 중인 ML 파이프라인의 한 단계뿐만 아니라 여러 단계에서 동시에 발생해야 합니다.

7.3.5 데이터를 생성하는 단계를 분석하는 방법

파이프라인의 일부 단계는 데이터를 다루는 작업일 가능성이 높으며, 사용하는 모든 AI 알고리즘은 데이터를 입력으로 사용합니다. 일반적으로 이러한 입력 데이터의 품질을 개선할 수 있습니다. 이 섹션에서는 데이터 개선이 ML 파이프라인에 미치는 영향을 분석하는 방법에 대한 조연을 제공합니다.

글로벌 민감도 분석 또는 MinMax 분석의 Max 부분을 수행할 때 목표는 가능한 최상의 데이터를 얻는 것이어야 합니다. 여기서 최상의 데이터란 더 큰 데이터 집합, 더 잘 타겟팅된 데이터, 더 깨끗한 데이터 집합 등 모든 차원을 아우르는 것입니다.

참고 카메라와 같은 AI 기반 물리적 디바이스를 구축하는 경우, 더 좋은 것은 더 우수한 센서를 탑재하는 것을 의미할 수 있습니다. 흐릿한 사진에 문제가 있다면 더 나은 카메라를 구할 수 있을까요? 장애물에 문제가 있는 경우 더 많은 카메라를 구할 수 있나요?

더 나은 데이터가 더 나은 AI 알고리즘을 이길 수 있는 경우가 종종 있으므로[129], 더 깨끗한 데이터가 있는지 확인하는 것은 필수적입니다.

모든 데이터를 어떻게 정리하나요?

빅 데이터 영역에서 때때로 발생하는 문제: 데이터 양이 상당할 경우 데이터를 정리하는 것이 어떤 영향을 미치는지 어떻게 측정할 수 있을까요? 사람에게 1PB를 수동으로 정리하라고 할 수는 없습니다! 게다가 1PB의 데이터를 정리하는 프로젝트를 시작할 수는 있지만, 답을 얻을 때까지는 이미 많은 시간과 비용을 들였을 것이므로 그 정보의 경제적 가치는 낮습니다.

다행히도 간단한 해결책이 있습니다. 파이프라인의 두 단계를 하나로 축소하는 것입니다. 파이프라인의 한 단계에서 이미지 데이터를 수집하고 다른 단계에서 딥러닝을 기반으로 한 객체 인식을 해당 이미지에 적용한다고 가정해 보겠습니다. "완벽하게 깨끗한 이미지 데이터가 있다면 이 딥러닝 네트워크 아키텍처를 적용하면 어떤 결과가 나올까?"라는 질문에 답하기는 매우 어렵습니다. 따라서 수집 단계를 개선하는 것은 매우 어렵습니다.

하지만 "데이터와 알고리즘을 함께 살펴보면 이미지 인식으로 얻을 수 있는 최상의 결과는 무엇일까?"라는 질문에 답하는 것은 훨씬 더 간단합니다. 어떤 데이터 집합에서 지금까지 달성한 최고의 비전 인식 결과를 살펴보면 됩니다. ML 파이프라인의 두 단계(데이터 수집과 인식)를 하나로 통합하여 복잡한 질문을 간단한 질문으로 바꿉니다.

7.3.6 내 프로젝트에는 어떤 유형의 민감도 분석이 적용되나요?

민감도 분석은 복잡한 주제이며 컴퓨터 과학 커뮤니티에서 활발히 연구되고 있는 분야입니다(예: *글로벌 민감도 분석: 입문*[117]). 더 나은 민감도 분석을 수행하는 데 도움이 될 수 있는 최신 연구에 관심이 있을 것입니다. 이 섹션에서는 프로젝트에 대한 적용 가능성을 결정하기 위해 사용해야 하는 기준을 제시합니다.

민감도 분석에 대한 연구를 접할 때 가장 중요한 질문은 "이 방법을 적용하려면 얼마나 많은 작업이 필요할까?"입니다. 프로젝트의 전체 규모에 비해 구현하기 쉬운 방법만이 ML 파이프라인의 프로젝트 관리에 실질적인 가치가 있습니다.

팁 분석이 너무 복잡해서 분석을 수행하는 데 ML 파이프라인을 구축하는 것만큼 많은 비용이 든다면, 그냥 파이프라인을 구축한 후 어떤 일이 일어나는지 보는 것이 좋습니다.

ML 파이프라인 분석에서 비용의 가장 큰 원인은 분석을 수행해야 하는 지점의 수입니다. 따라서 수천 개의 포인트를 분석해야 하는 글로벌 민감도 분석 기법은 섹션 7.1.1[1]에 설명된 방법보다 (특히 프로세스 엔지니어링 경험이 부족한 AI 팀의 경우) 적용 가능성이 훨씬 낮습니다.

편리한 트릭

데이터나 결과를 더 좋게 만드는 것은 어려울 수 있지만, 데이터에 오류를 도입하여 더 나쁘게 만드는 것은 종종 간단합니다. 요령은 ML 파이프라인의 단계 결과를 1% 더 좋게 만들고 x 및 $x + 1\%$ 지점에서 분석하는 대신, 결과를 1% 더 나쁘게 만들고 $x - 1\%$ 및 $x\%$ 지점에서 분석하는 것입니다. 이 트릭을 사용하는 경우, 스테이지의 출력이 약간 개선될 때와 출력이 약간 감소할 때 파이프라인의 동작이 비슷하다고 가정합니다.

33%, 66%, 100% 지점에서 글로벌 민감도 분석을 수행한다고 가정합니다. 100%에서 분석을 완료하면 해당 단계의 출력 데이터를 의도적으로 손상시켜 33% 및 66% 지점에서 분석을 수행할 수 있습니다.

지역 민감도 분석에도 동일한 수법이 적용됩니다. 예를 들어, 파이프라인에서 이미 95% 정확도의 단계 결과를 생성하고 있는 경우 95% 및 96% 지점에서 민감도 분석을 수행하지 마세요. 대신 94%와 95%에서 수행하세요. 현재 단계의 출력에 오류를 도입하는 것이 개선하는 것보다 훨씬 쉽습니다.

이 같은 방법을 사용하여 수천 개의 지점에서 평가해야 하는 민감도 분석 방법을 단일 지점(최상위 지점)에 대한 결과를 구성한 다음 해당 결과를 저하시켜 다른 지점을 시뮬레이션할 때 ML 파이프라인의 분석에 적용할 수 있습니다.

그러나 이 사이드바에 제시된 기법에는 미묘한 차이와 함정이 있어 빠지기 쉽다는 점에 유의하시기 바랍니다. 출력에 발생하는 오류는 단순한 무작위 오류가 아닙니다. ML 파이프라인에서 실제 단계를 구현할 때 발생하는 오류와 유사한 통계적 특성을 가져야 합니다. 이 함정을 피하려면 전문가가 필요합니다.

민감도 분석, 프로세스 엔지니어링, 통계 분포 분석에 상당한 경험이 있는 인력을 확보하기 전에는 이 기법을 시도해서는 안 된다는 것이 제 조언입니다.

7.4 시간이 지남에 따라 AI 프로젝트가 진화하는 방식

지금까지 소개한 MinMax와 민감도 분석 기술은 빠르게 구현할 수 있는 AI 프로젝트에 초점을 맞췄습니다. 다른 모든 것이 동일하다면 실제 고객에게 빠르게 전달할 수 있는 프로젝트를 선호해야 하며[28], 특히 초기 AI 프로젝트의 경우 더욱 그러합니다. 그러나 일단 제공된 AI 프로젝트는 시장에 오랫동안 남아있을 수 있습니다. 또한, 때로는 AI 프로젝트가 새로운 영역을 개척하고 있어 시장에 출시하는 데 오랜 시간이 걸리는 경우도 있습니다. 이 섹션에서는 장기적인 AI 프로젝트를 이끌 때 지금까지 제시된 방법을 어떻게 수정해야 하는지 설명합니다.

7.4.1절에서는 시간이 프로젝트에 미치는 영향에 대해 설명합니다. 섹션 7.4.2는 긴 프로젝트에서 시간의 영향을 고려하기 위해 CLUE의 이해 부분을 수정하는 방법을 보여줍니다. 7.4.3절에서는 시간에 따른 프로젝트의 비즈니스 가치 변화를 다이어그램으로 작성하는 방법을 보여줍니다.

7.4.1 시간은 비즈니스 결과에 영향을 미칩니다.

프로젝트를 관리할 때 우리는 종종 성공을 위해 실행해야 하는 일련의 단계에 집중합니다. 우리는 시간을 프로젝트 마감일이라는 형태로 생각하고, 마감일을 엔지니어링의 책임으로 생각합니다. 이 섹션에서는 프로젝트에 영향을 미치는 엔지니어링 및 관리 결정을 함께 고려할 수 있도록 시간에 대한 다른 사고 방식을 보여줍니다.

많은 프로젝트에서 시간은 마감일이라는 사후 고려 사항이 되고, 경영진과 엔지니어링 팀은 마감일을 협상합니다. 일단 마감일이 정해지면 마감일은 프로젝트 관리자와 엔지니어링의 문제가 됩니다. 그 결과 시간이 결과물의 가치에 미치는 영향과 AI 프로젝트의 기술 관리가 분리됩니다. 엔지니어링은 마감일을 놓치지 않는 데 집중합니다. 경영진은 마감일을 놓칠 경우 비상 계획을 세우는 데 집중하고, 때때로 새로운 기능에 대한 요청으로 엔지니어링을 놀라게 할 수 있습니다. 기술적 의사 결정을 비즈니스 결과와 통합하는 대신, 팀 간의 관계가 노골적으로 적대적이지는 않더라도 분리되어 있습니다.

시간 차원을 다루는 더 좋은 방법은 관리 및 최적화하는 지표에 프로젝트 완료 시간을 직접 포함하는 것입니다. 프로젝트를 완료하는 데 필요한 시간이 중요하다면, 적어도 어느 정도의 범위에서 얼마나 중요한지 정량화할 수 있어야 합니다. 시간이 프로젝트에 미치는 영향을 정량화하면 수익 곡선에 시간을 통합할 수 있습니다.

팁 정확하게 정량화할 수 없는 경우 추정치를 사용합니다. 비즈니스에서 '무형 자산'을 정량화하는 방법은 D. W. 허바드의 저서 [75]를 참고하세요.

프로젝트의 가치(그리고 프로젝트가 충족해야 하는 값 임계값)는 시간이 지남에 따라 변합니다. 예를 들어, 인터넷을 색인하고 검색할 수 있는 인공지능은 1998년(Google 이전)에 엄청난 비즈니스 가치를 가졌습니다. 오늘날 이러한 AI의 가치는 훨씬 작아졌습니다. 따라서 프로젝트의 수익 곡선과 값 임계값은 모두 시간이 지남에 따라 진화합니다.

이러한 변화는 수년 동안 시장에 출시될 수 있는 성공적인 AI 프로젝트와 같이 더 긴 기간에 대해 이야기할 때 중요해집니다.

프로젝트에 다양한 납기일이 있는 경우 프로젝트 전체 기간에 대해 단일 수익 곡선을 사용해서는 안 됩니다. 다양한 시점의 비즈니스 가치 변화를 반영하는 여러 수익 곡선이 있어야 합니다. 그림 7.10은 2년간 실행되는 프로젝트에 대한 수익 곡선 집합을 보여줍니다.

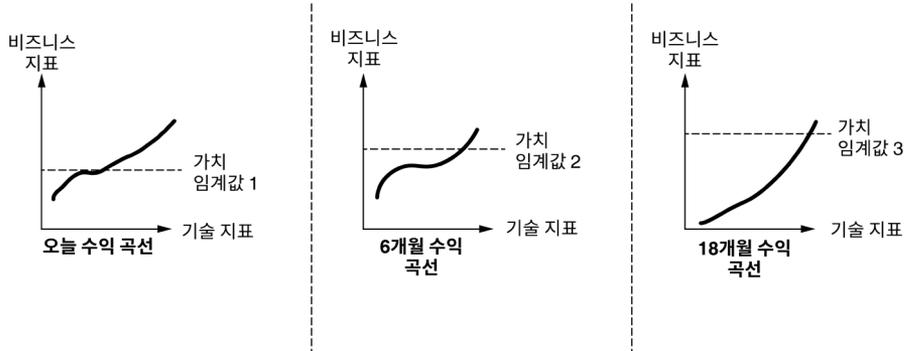


그림 7.10 장기 실행 AI 프로젝트의 수익 곡선 집합입니다. 수익 곡선의 모양과 특히 값 임계값은 시간에 따라 변화합니다.

시간을 염두에 두고 ML 파이프라인을 관리해야 합니다. "6월 1일 이전에 완료되면 정확도 x 는 $\$y$ 의 가치가 있고, 그 이후에 완료되면 $\$z$ 의 가치가 있다"와 같이 간단한 접근 방식도 수익 곡선에 적용하면 시간 차원을 빠르게 처리할 수 있습니다.

경고 기한은 기껏해야 시간을 설명하는 불완전한 방법일 뿐입니다. 애자일 프로세스 자체만으로는 이러한 마감일의 역학 관계를 해결하지 못하며, 엔지니어링 팀과 비즈니스 팀 간에 보다 일반적인 체크포인트를 시행할 뿐입니다. 애자일 프로젝트에서도 선택한 ML 파이프라인의 장기적인 영향에 의도적으로 집중해야 합니다.

7.4.2 시간이 지남에 따라 ML 파이프라인 개선하기

어느 시점에는 훨씬 더 긴 AI 프로젝트를 다루게 될 것입니다. 이러한 프로젝트는 장기간 지속될 수 있으며, 섹션 7.4.1에서 볼 수 있듯이 시간이 지남에 따라 수익 곡선이 바뀔 수 있습니다.

경고 장기 프로젝트에서는 일반적으로 시간이 지남에 따라 지연에 따른 기회 비용을 고려하여 수익 곡선이 변화합니다. 프로젝트의 비즈니스 가치를 평가할 때 이러한 변화를 고려해야 합니다.

이러한 변화를 고려하기 위해, 전달 파이프라인의 한 단계에서 개선 사항을 제공하는 데 걸리는 시간을 예측한 다음, 개선 사항이 AI 프로젝트가 출시되는 시점 (현재가 아닌)에 갖게 될 가치를 반영하는 적절한 수익 곡선을 사용합니다. 그림 7.11은 이 프로세스를 설명합니다.

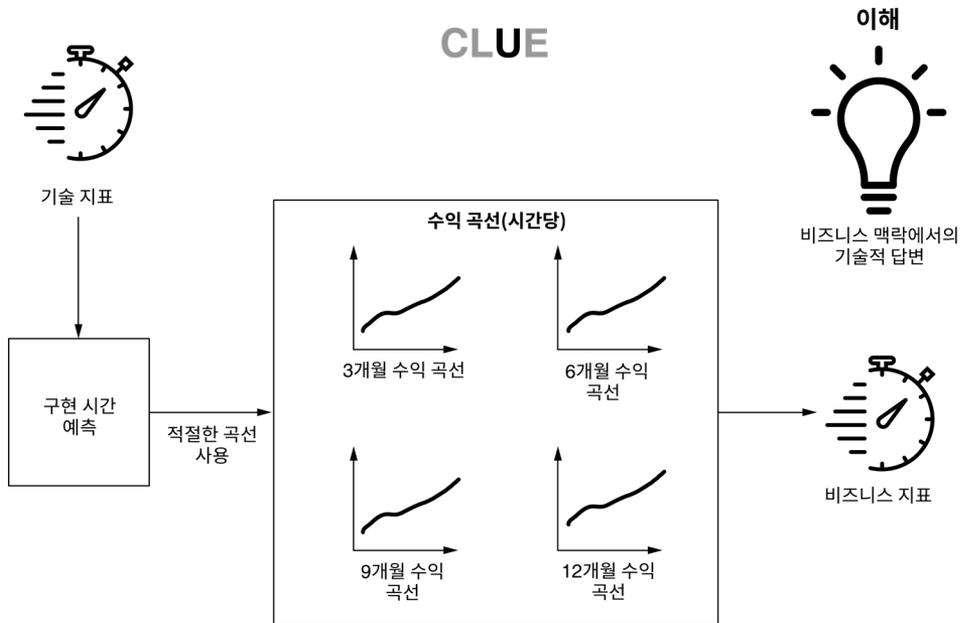


그림 7.11 긴 납기 시간을 고려하기 위해 CLUE의 이해의 일부를 수정했습니다. 프로젝트 가치는 납품에 걸리는 시간에 따라 달라집니다. 개선의 가치를 계산하려면 소프트웨어 출시 시점에 해당하는 수익 곡선을 사용해야 합니다.

시간이 수익 곡선에 미치는 영향을 고려하면 파이프라인에서 개선 사항의 스케줄링이 간단해집니다. 가능한 한 빨리 값 임계값에 도달하고 프로젝트가 진행됨에 따라 값 임계값 이상을 유지할 수 있는 순서로 ML 파이프라인의 단계를 개선하도록 예약합니다.

참고 ML 파이프라인에서 단계의 개선 가치가 시간에 따라 변하는 것처럼 값 임계값도 변합니다. 예를 들어, 값 임계값은 처음 6개월 동안 단위당 5달러가 될 수 있으며, 이후에는 단위당 4달러로 감소할 수 있습니다. 일정을 수립할 때 값 임계값의 변화를 고려하는 것을 잊지 마세요.

7.4.3 타이밍 다이어그램: 시간이 지남에 따라 비즈니스 가치가 변화하는 방식

장기 프로젝트의 경우, 프로젝트의 비즈니스 가치도 시간이 지남에 따라 변화합니다. 시간 경과에 따른 비즈니스 가치의 변화를 *타이밍 다이어그램*의 도움으로 나타낼 수 있습니다. 이 섹션에서는 이러한 다이어그램을 구성하는 예제를 제공합니다.

이 예에서는 값 임계값이 최종 사용자에게 대한 AI 제품의 가치를 기반으로 하며 최종 사용자가 단위당 창출하는 수익으로 표현된다고 가정합니다. 또한 표준 솔루션을 구축하는 회사의 평생 가치가 높을 것으로 예상되는 빠르게 확장하는

시장을 포착하려고 한다고 가정합니다. 따라서 기업의 목표는 시장 입지입니다. 귀사의 목표는 가능한 한 빨리 실행 가능한 제품을 출시하고 향후 24개월 동안 수익에 대해 걱정하지 않고 지속적으로 실행 가능한 제품을 유지하는 것입니다. 기업 경영진은 제품이 표준으로 자리 잡으면 나중에 수익이 발생할 것으로 기대합니다.

시간에 따른 값 임계값의 변화가 표 7.1에 나와 있는 시나리오를 살펴봅시다. 그림 7.11에 표시된 프로세스를 적용하여 해당 정보를 추출할 수 있습니다.

표 7.1 최종 사용자를 위한 단계 개선 값

단계 이름	오늘의 개선 가치	6개월 후 개선 가치	12개월 후 개선 가치	단계 개선을 완료하는 데 필요한 시간
A	\$7	\$4	\$3	2개월
B	\$30	\$27	\$21	11개월
C	\$14	\$10	\$7	3개월
D	\$10	\$8	\$6	6개월

파이프라인 단계를 개선하는 데 필요한 값과 시간은 표 7.2에 나와 있습니다. 그림 7.12의 해당 수익 곡선에서 값 임계값을 읽어 값 임계값 변경을 구성할 수 있습니다.

표 7.2 고객에 대한 단위의 값 임계값입니다. 고객이 제품을 구매하려면 값 임계값을 초과해야 합니다.

현재 값 임계값	6개월 후의 값 임계값	12개월 후의 값 임계값
단위당 \$5	단위당 \$14	단위당 \$15

그림 7.12는 ML 파이프라인이 최종 사용자에게 제공할 것으로 예상되는 값의 타이밍 다이어그램을 보여줍니다. ML 파이프라인의 비즈니스 가치가 변하는 이유는 ML 파이프라인 단계의 개선과 시간의 경과라는 두 가지 이유가 있습니다. 2, 5, 11, 23개월에 파이프라인 효용이 증가하는 것은 A, C, D, B 단계의 개선이 완료되었기 때문이며, 6개월과 12개월에 감소하는 것은 시간이 지남에 따라 파이프라인 단계의 개선에 대한 비즈니스 가치가 감소하기 때문입니다.

타이밍 다이어그램을 사용하면 미래의 모든 시점에서 ML 파이프라인의 가치에 대해 예상되는 것을 결정할 수 있습니다. 이 정보는 장기 실행 프로젝트가 있는 경우 파이프라인 단계를 어떤 순서로 개선해야 하는지에 대한 질문에 답하는 데 도움이 됩니다.

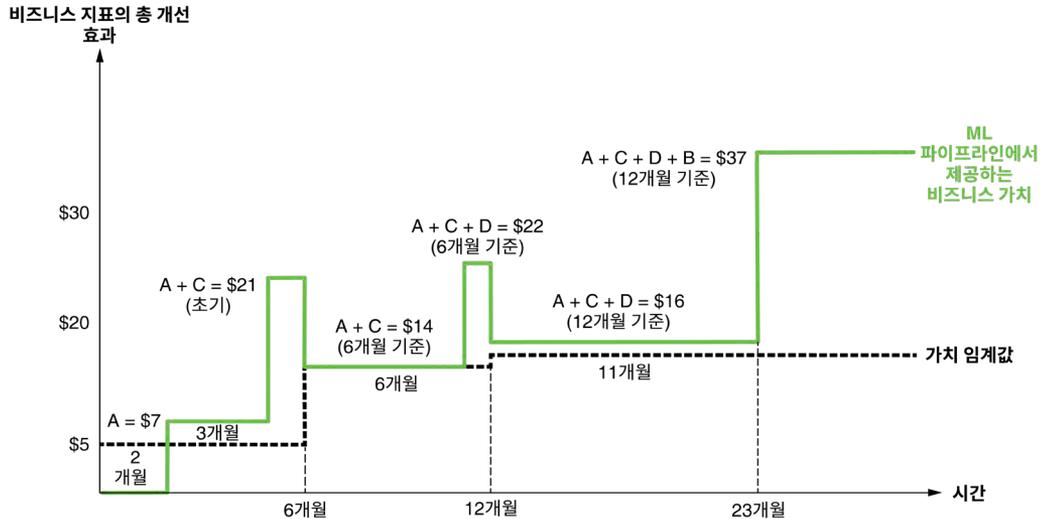


그림 7.12 표 7.1과 7.2에 주어진 시간 매개 변수를 고려하여 ML 파이프라인을 개선합니다. ML 파이프라인 단계의 개선 순서는 먼저 A 단계, C 단계, D 단계, 마지막으로 B 단계가 되어야 하며, 이 순서를 따르면 단 2개월 만에 실행 가능한 제품을 출시할 수 있습니다.

기법은 연구 질문에 가장 적합한 ML 파이프라인을 선택하는 프로젝트 초기 단계와 프로젝트에서 현재 ML 파이프라인을 대체할 새로운 ML 파이프라인 개발을 관리해야 할 때 모두 유용합니다. 후자의 경우, 그림 7.12와 같은 다이어그램을 사용하여 기존 ML 파이프라인에서 수행하려는 점진적 개선 사항을 관리하는 방법을 알려주고 새 파이프라인이 기존 파이프라인의 작업을 대신할 수 있을 것으로 예상할 수 있는 시점을 예측할 수 있습니다.

7.5 AI 프로젝트 마무리하기

프로젝트를 관리하려면 일부 기능을 구현하는 데 걸리는 시간, 일부 AI 알고리즘을 적용하는 데 얼마나 복잡할지, 구현이 얼마나 많은 비즈니스 가치를 제공할지 등 많은 예측이 필요합니다. 때로는 모든 일이 예상하고 계획한 대로 진행되기도 합니다. 때로는 현실이 우리의 바람을 따르지 않아서 예상대로 되지 않을 때도 있습니다. 이 섹션에서는 문제가 처음에 생각했던 것보다 훨씬 더 복잡해졌을 때 어떻게 해야 하는지 설명합니다.

오늘날 초기 AI 프로젝트를 실행하고 있다면, 여러분의 팀은 회사에서 비즈니스 문제를 해결하기 위해 강력한 AI 기술을 사용하는 최초의 팀이 될 가능성이 높습니다. 이는 또한 프로젝트가 완료하기 어려운 것으로 판명될 경우, 당시의 지식에 비추어 복잡성에 대한 초기 추정치가 정확하더라도 현재 학습한 내용을 바탕으로 수정해야 한다는 것을 의미합니다. 구현하기 어려운 프로젝트를 계속 진행하지 말고 일시 중지하고 더 간단한 프로젝트를 시도해야 합니다.

초기 인공지능 프로젝트에서는 풍부한 사냥터에서 사냥꾼처럼 생각해야 합니다 (3.1.1절) - 매머드를 쫓는 데 시간을 낭비하지 말고 토끼를 잡아야 합니다. 한참을 사냥하다가 쫓고 있는 동물이 토끼로 위장을 잘하는 매머드라는 것을 알아차렸다면, 추격을 포기하고 토끼를 찾아야 합니다.

실패할 거라면 빨리 실패하는 편이 낫습니다.

프로젝트 관리 접근 방식은 빨리 실패하는 쪽으로 치우쳐야 합니다. 너무 일찍 포기하여 잠재적인 해결책을 놓칠 가능성을 받아들이는 대신, 결국에는 효과가 없는 일에 오랫동안 매달리는 상황을 피할 수 있다면 그 대가를 감수해야 합니다.

AI 이니셔티브가 실패하는 주된 이유는 문제가 있는 프로젝트를 너무 오랫동안 지속해서 결국에는 아무것도 보여주지 못하기 때문이라는 점을 기억하세요(3.1.1 섹션).

어려운 문제가 발생하면 플러그를 뽑기 전에 항상 *시간 상자* AI 프로젝트를 얼마나 오래 진행하도록 허용할지 고려해야 합니다. 연구 질문이 처음 예상했던 것보다 구현하기가 훨씬 더 어려운 것으로 판명되면 답을 찾기 위해 끈질기게 추적해서는 안 됩니다. 대신 현재 프로젝트를 일시 중지하고 보다 간단한 연구 질문으로 작업을 시작하세요.

이 방법을 사용하면 잠재적으로 기능적인 솔루션으로 이어질 수 있는 프로젝트를 보류하는 대신(그러나 아무것도 보여주지 못한 채 상당한 시간 낭비로 끝날 수도 있음) 더 간단한 프로젝트를 먼저 시도할 수 있습니다. 하지만 이 기법을 사용할 때는 연구 질문을 보류할 때 무엇을 찾았는지 이해하는 것이 중요합니다. *연구 질문을 보류하기로 결정했는데, 해당 연구 질문을 더 이상 추구할 비즈니스 가치가 없다는 것을 발견하지 못했습니다.*

안타깝게도 조직은 종종 연구 프로젝트의 결과를 '예/아니오', '효과가 있다/없다'와 같은 이분법적 범주로 분류하는 습관이 있습니다. 타임박스 접근법을 올바르게 사용하려면 연구 질문에 대한 초기 분석에 세 가지 가능한 결과가 있다는 것을 이해해야 합니다.

- 1 *예*—이 접근 방식은 더 추구할 가치가 있습니다. 많은 자원을 투입해야 합니다.
- 2 *아니요*—이 접근법은 잘못된 접근법이라고 확신할 만큼 충분히 시도해 보았으므로 효과가 없을 것으로 예상됩니다. 추가 리소스를 투입하지 마세요.
- 3 *아마도*—초기 조사에 투입한 시간으로는 이 접근법이 효과가 있다는 것을 증명할 수 없었습니다. 그러나 우리는 더 열심히 노력해도 효과가 없다는 것을 알 정도로 충분히 오래 조사하지 않았습니다. 나중에 더 많은 돈과 시간이 생기면 이 문제를 다시 살펴봐야 합니다.

참고 결과를 예/아니오/아마의 3상태 논리 형식으로 보고하고 추적하는 것이 중요합니다. "아니오"로 답한 질문은 다시 열지 않지만 "아마도"로 답한 질문은 나중에 다시 시작할 수 있기 때문입니다. 이 구분을 정확하게 해야만 "어려운 프로젝트는 기꺼이 일찍 포기한다"는 접근 방식이 제대로 작동합니다.

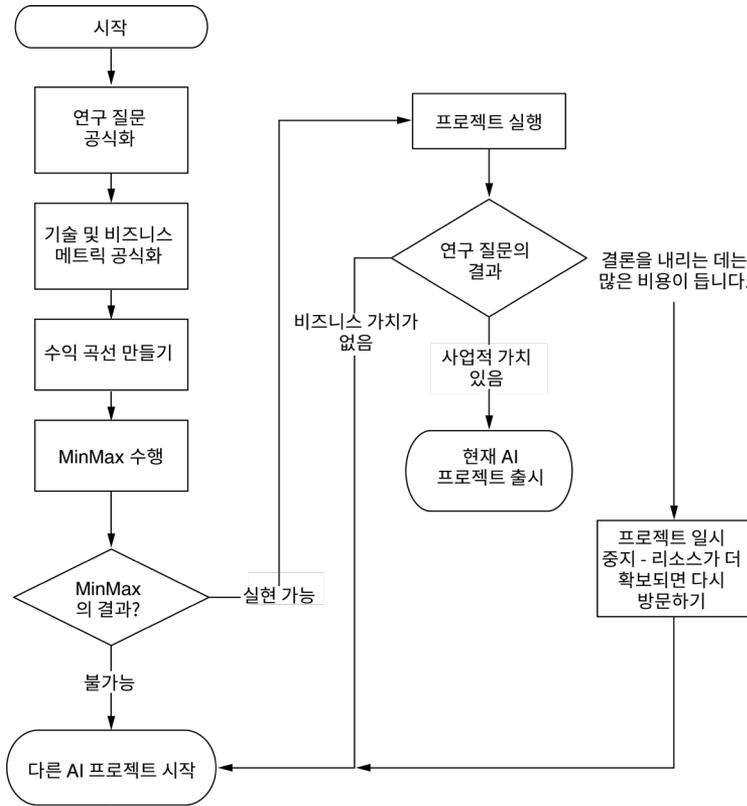


그림 7.13 어려운 프로젝트를 보류할 수 있는 능력을 갖춘 AI 프로젝트 실행합니다. 이 접근 방식을 사용하면 예상보다 어려운 것으로 판명된 프로젝트에서 신속하게 손실을 줄이고 대신 더 간단한 프로젝트를 시도할 수 있습니다.

나중에 더 많은 리소스를 확보하여 개선하고자 하는 성공적인 솔루션이 있을 때, 몇 가지 가능성을 다시 살펴볼 가치가 있다고 판단할 수도 있습니다. 그림 7.13은 이 세 가지 상태(예/아니요/아마도)의 결과 분류를 사용하여 프로젝트를 실행하는 프로세스를 요약한 것입니다.

7.6 연습

이 연습의 문제는 그림 6.10(및 그림 7.1)을 재현한 그림 7.14의 ML 파이프라인을 참조합니다.

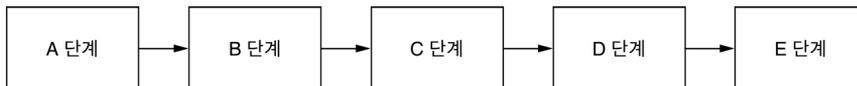


그림 7.14 ML 파이프라인의 예입니다. 이 파이프라인의 민감도 분석을 수행합니다. (이것은 독자의 편의를 위해 그림 6.10을 반복한 것입니다.)

질문 1: 이 질문은 그림 7.14의 파이프 라인에 대한 민감도 분석 결과를 제공합니다. 비즈니스 메트릭이 수익이고 값 임계값이 연간 2백만 달러라고 가정합니다. MinMax 분석의 결과는 최소 부분이 연간 190만 달러이고 최대 부분이 연간 300만 달러입니다. 민감도 분석을 수행하기로 결정했습니다. 민감도 분석을 수행해야 하는 이유는 무엇인가요? 한동안 모든 단계를 작업했는데 어떤 단계도 개선하기가 점점 더 어려워지는 지점에 도달했습니다. 민감도 분석 결과가 다음과 같을 경우 파이프라인의 어느 단계에 투자해야 하는지 결정하세요.

- A 단계는 1% 개선하는 데 6개월이 필요합니다. A 단계를 개선하면 ML 파이프라인의 전체 개선 효과는 \$10,000/%입니다.
- B 단계는 1% 개선하는 데 2개월이 필요합니다. B 단계를 개선하면 ML 파이프라인의 전체 개선 효과는 \$200 K/%입니다.
- C 단계는 1% 개선하려면 1년이 필요합니다. C 단계를 개선하면 ML 파이프라인의 전체 개선 효과는 \$800 K/%입니다.
- ML 파이프라인은 D 및 E 단계를 개선해도 눈에 띄는 결과 개선이 나타나지 않습니다. 실제로 이러한 상황은 언제 발생하나요?

질문 2: 이 질문은 그림 7.14의 파이프라인에 대한 민감도 분석 결과를 제공합니다. 비즈니스 메트릭이 수익이고 값 임계값이 연간 2백만 달러라고 가정합니다. MinMax 분석의 결과는 최소 부분이 연간 190만 달러이고 최대 부분이 연간 300만 달러입니다. 민감도 분석을 수행하기로 결정했습니다. 프로토타입을 만들거나 데이터 정리를 시도하지 않았습니다. 민감도 분석 결과가 다음과 같을 경우 파이프라인의 어느 단계에 투자해야 하는지 결정하세요.

- 단계 A에서 2% 개선하려면 3개월이 필요합니다. A 단계를 개선하면 ML 파이프라인의 전반적인 개선 효과는 \$200 K/%입니다.
- B 단계를 1% 개선하려면 2개월이 필요합니다. B 단계를 개선하면 ML 파이프라인의 전체 개선 효과는 \$100 K/%입니다.
- C 단계는 1% 개선하려면 1년이 필요합니다. C 단계를 개선하면 ML 파이프라인의 전체 개선 효과는 \$800 K/%입니다.
- ML 파이프라인은 D 및 E 단계를 개선해도 눈에 띄는 결과 개선이 나타나지 않습니다.

질문 3: 귀하의 AI 프로젝트는 차량의 소리를 모니터링하는 IoT 센서를 설치하여 어떤 종류의 음색 변화가 차량의 기계적 문제를 나타낼 수 있는지 알아낼 수 있는지 조사하고 있습니다. 150대의 차량에 센서를 설치하고 한 달 동안 기다렸습니다. 단 한 대의 차량에서만 기계적 문제가 발생했습니다. 한 달간의 조사 끝에 데이터 과학자가 수집된 데이터로는 차량의 고장을 예측할 수 없으며, 고장 난 차량 한 대만으로는 데이터 세트가 불충분하다고 말합니다. 이는 차량 파손을 예측할 수 있는 AI를 만들 수 없다는 의미인가요?

질문 4: 두 개의 ML 파이프라인이 있다고 가정해 보겠습니다. 비즈니스 지표는 매출입니다. 값 임계값은 연간 1,000만 달러로 일정합니다. 두 개의 ML 파이프라인에서 작업할 수 있는 두 개의 병렬 팀이 있습니다. 파이프라인 1은 연간 2천만 달러, 파이프라인 2는 연간 3천만 달러를 제공합니다. 파이프라인을 개발하는 데 드는 팀의 비용이 AI 프로젝트에서 기대되는 평생 수익에 비해 적습니다. 조직은 파이프라인 1을 4개월 안에, 파이프라인 2를 1년 안에 구현할 수 있습니다. 두 파이프라인 중 어떤 파이프라인을 언제 출시해야 하는지 결정합니다. 또한 이 두 파이프라인을 보여주는 타이밍 다이어그램을 그립니다.

요약

- 민감도 분석은 "ML 파이프라인의 어느 단계에 투자해야 하는가?"라는 질문에 대한 답을 제공합니다. 민감도 분석에는 로컬 민감도 분석과 글로벌 민감도 분석의 두 가지 형태가 있습니다.
- 로컬 민감도 분석은 ML 파이프라인의 한 단계를 조금만 개선할 수 있다고 판단될 때 적용할 수 있습니다.
- 파이프라인의 한 단계를 크게 개선할 수 있다고 생각되면 글로벌 민감도 분석을 수행해야 합니다.
- CLUE는 AI 프로젝트 관리의 중요한 고려 사항을 다루는 통합 프로세스입니다. CLUE 프로세스의 각 부분은 CLUE의 이전 섹션에 따라 달라지므로 *C*, *L*, *U*, 및 *E*를 순서대로 수행해야 합니다. 데이터를 기반으로 정보에 입각한 의사 결정을 내리려면 CLUE와 같은 프로세스가 필요합니다.
- 장기 프로젝트에서는 솔루션의 비즈니스 가치가 시간에 따라 변하기 때문에 여러 시점의 가치를 고려하기 위해 여러 수익 곡선을 구성해야 합니다. 타이밍 다이어그램을 사용하여 ML 파이프라인의 비즈니스 가치가 시간에 따라 어떻게 변화하는지 시각화할 수 있습니다.
- 연구 질문에 대한 답은 예/아니오로 제한되지 않습니다. "현재로서는 질문에 답하는 데 투입할 수 있는 리소스가 부족하여 알 수 없음"이 될 수도 있습니다. 이러한 프로젝트는 보류하고 나중에 다시 검토하는 것을 두려워하지 마세요.