

AX 대전환

| AI 사피언스의 퀀트 리서치 재구성 |



Glossary

용어	정의
AI 및 기술 관련 용어	
생성형 AI (Generative AI)	텍스트, 이미지, 오디오, 동영상 등 새로운 콘텐츠를 생성하는 인공지능 모델
Agentic AI	스스로 목표를 설정하고, 계획을 수립하며, 도구를 활용해 자율적으로 행동하는 능동적 AI
LLM (Large Language Model)	대규모 언어 모델. 방대한 텍스트 데이터를 학습하여 언어를 이해하고 생성하는 AI 모델
트랜스포머 (Transformer)	2017년 구글이 발표한 AI 모델 구조로, 현대 생성형 AI의 기반 기술
RAG (Retrieval-Augmented Generation)	검색 증강 생성. 외부 지식을 검색하여 AI 응답의 정확성과 최신성을 높이는 기술
Multi-Agent 시스템	여러 개의 AI가 각각의 역할을 분담하여 협력하는 구조
Tool Use	AI가 외부 API, 데이터베이스, 계산기 등 다양한 도구를 직접 활용하는 능력
Self-Reflection	AI가 스스로의 결과물을 검토하고 오류를 수정하는 자기 성찰 기능
멀티모달 (Multi-modal)	텍스트, 이미지, 음성, 영상 등 여러 형태의 데이터를 동시에 처리하는 기술
딥러닝 모델 관련 용어	
RNN (Recurrent Neural Network)	순환 신경망. 시계열 데이터 처리에 특화된 딥러닝 모델
LSTM (Long Short-Term Memory)	장단기 메모리. RNN의 장기 의존성 문제를 해결한 모델
CNN (Convolutional Neural Network)	합성곱 신경망. 이미지 인식에 주로 사용되는 딥러닝 모델
GRU (Gated Recurrent Unit)	LSTM을 단순화한 순환 신경망 구조
BERT(Bidirectional Encoder Representations from Transformers)	구글의 양방향 인코더 기반 언어 모델로, 텍스트 이해에 특화
GPT (Generative Pre-trained Transformer)	OpenAI의 텍스트 생성에 특화된 대규모 언어 모델

용어	정의
----	----

금융 및 퀀트 관련 용어	
MPT (Modern Portfolio Theory)	마코위츠의 현대 포트폴리오 이론. 기대수익과 위험의 균형을 추구
VaR (Value at Risk)	특정 신뢰구간 내에서 발생 가능한 최대 손실 측정 지표
GARCH	시계열 데이터의 변동성을 예측하는 계량경제 모델
CAPM (Capital Asset Pricing Model)	자본자산 가격결정 모형. 시장 위험과 기대수익률의 관계를 설명
블랙-숄즈 모형	옵션 가격을 계산하는 대표적인 파생상품 가격결정 모델
로보어드바이저 (Robo-Advisor)	AI 기반 자동화된 투자 자문 서비스
Direct Indexing	개별 주식을 직접 보유하여 맞춤형 포트폴리오를 구성하는 투자 방식

IT 및 개발 관련 용어	
API (Application Programming Interface)	소프트웨어 간 데이터를 주고받을 수 있게 하는 인터페이스
GPU (Graphics Processing Unit)	그래픽 처리 장치. AI 학습에 필수적인 병렬 연산 처리 장치
NoCode 플랫폼	코딩 없이 애플리케이션을 개발할 수 있는 플랫폼
UI/UX	User Interface / User Experience. 사용자 인터페이스 및 사용자 경험
온프레미스 (On-premise)	자체 서버와 인프라를 구축하여 시스템을 운영하는 방식
엣지 (Edge)	클라우드가 아닌 기기 자체에서 데이터를 처리하는 방식
LoRA / QLoRA	AI 모델을 효율적으로 경량화하고 미세 조정하는 기법

Summary

AX 대전환

(AI사피엔스의 퀀트 리서치 재구성)

본 리포트는 생성형 AI에서 AgenticAI로의 진화 과정, 금융업에 미치는 영향 및 AI사피엔스로서 퀀트 리서치 영역에서의 구체적 적용 사례를 함께 다룬다

AI의 대전환기: 생성형 AI에서 Agentic AI로

- 2022년 11월 ChatGPT의 출시는 출시 2개월만에 월간 사용자 1억명을 돌파하며 인스타그램(30개월), 페이스북(54개월)을 압도하는 속도로 인공지능의 대중화를 이끌었다. 이는 인간이 컴퓨터 언어를 배우는 시대에서 컴퓨터가 인간의 언어를 배우는 시대로 근본적인 전환을 이끌어 냈다. 지금까지 생성형 AI는 사용자의 명시적인 프롬프트에 의존하는 ‘수동적’ 존재로, 복잡한 다단계 문제를 자율적으로 해결하는 능력은 제한적이었다. 이런 한계를 극복한 것이 Agentic AI라고 볼 수 있다.

DX에서 AX로

- 산업의 화두는 DX(Digital Transformation)에서 AX(AI Transformation)로 이동하고 있다. AX는 단순히 AI를 도구로 도입하는 변화가 아니라, 컴퓨트 인프라부터 모델·도구·애플리케이션에 이르는 새로운 산업 밸류체인이 형성되는 구조적 변화이다.
- AX의 본격화는 네 가지 동인의 동시 충족에 기반한다. 모델 측면에서 추론형 LLM과 멀티모달이 업무 수행 가능한 수준에 도달했고, 데이터 측면에서 사내·도메인 데이터의 정형화와 검색 인프라가 성숙했으며, 인프라 측면에서 Cloud, On-Prem, Hybrid 운영 환경이 정착했고, 도구 측면에서 Tool Use, Function Calling, MCP, CLI 등 외부 시스템 연결 표준이 자리잡았다. 이 네 가지가 동시에 충족된 시점이 AX의 출발선이며, 이후의 진행은 ‘보조 자동화 → 단일 작업 자동화 → 워크플로우 자동화 → 자율형 시스템’의 4단계로 전개된다.
- AX의 기술적 엔진은 Agentic AI이다. Agentic AI는 LLM을 두뇌로 두고 RAG, Tool Use, Memory, Planning, Reflection, Multi-Agent가 결합된 자율형 시스템이며, 단일 응답이 아닌 워크플로우 단위에서 작동한다. 본 리포트는 Part II와 IV에서 Agentic AI의 구조와 그 토대인 LLM·딥러닝 모델의 진화를 정리한다.

금융업의 AX

- 금융업의 AX는 프론트·미들·백오피스 전반에 걸쳐 확산되고 있다. 1 세대 Rule-based AI, 2 세대 머신러닝·딥러닝 기반 예측 모델을 거쳐 3 세대 생성형 AI·AI Agent 에 이른 흐름이 이제 4 세대 ‘Agentic AX 단계’로 이동하고 있다. 특히 퀀트 리서치는 데이터·업무 표준화 수준이 높고 산출물의 정형성·반복성이 강하다는 점에서 Agentic Workflow 와 자연스럽게 결합될 수 있다.

퀀트의 AI 활용 실무

- Part VI는 실무편으로, 퀀트 리서치작업에 활용할 수 있는 AX 도구(Claude Code, Codex, Grok Build, MCP 등)의 사용 사례를 정리하며 AX 시대의 분석가 도구 환경 변화를 보여주는 동시에, 실제 서비스에 활용될 daily report, weekly report, earning tracker, event_driven tracker 의 활용 방법도 설명한다.

결론

- 결론은, AX는 단일 도구가 아니라 새로운 산업 밸류체인이며, 향후 수년간 자본, 기술, 인력 배분구조를 재편할 거대 사이클이다. 금융 리서치 영역에서의 AX 적용은 데이터, 모델, 검증, 리포팅이 통합된 Agentic Workflow 로 진화할 가능성이 높으며 그 성패는 모델의 성능이 아닌, 데이터의 품질, 설계자의 insight, 검증체계, Human in the loop 구조의 설계 수준에 의해 결정될 것이다.

Contents

I. AX(AI Transformation)의 부상	8
DX에서 AX로: 디지털 전환에서 AI대전환으로	8
AX의 정의와 본질	11
AX의 4대 동인: 모델·데이터·인프라·도구	13
II. 생성형 AI에서 Agentic AI로	15
AI 패러다임의 전환	15
인공지능 3.0, Agentic AI	18
III. AX 밸류체인과 시장구조	25
5계층 밸류체인	25
IV. LLM과 딥러닝 모델의 진화	30
생성형 AI의 출발점은 트랜스포머 기반 NLP 연구	30
기존 딥러닝 모델의 역할: RNN, CNN, DNN, LSTM	32
Transformer와 기존 모델의 융합	35
퀀트 모델링에서 Hybrid Model이 갖는 의미	38
V. 금융업 AX와 Agentic 리서치	44
금융업 내 AI 도입 1세대~3세대 흐름	44
금융 산업 내 Digital Transformation → AI Transformation	46
해외 및 국내 사례	50
해외 금융권 생성형 AI 적용 대표 사례)	52
국내 금융권 생성형 AI 적용 대표 사례)	53
금융 산업이 AI시대에 준비해야 할 조건	54
VI. 퀀트 리서치의 재구성 (AX 활용 실무편)	56
Harnessing: 퀀트 리서치의 Agentic 설계 원리	56
데이터의 중요성: 금융업에서 가장 중요한 가치는 '신뢰'	57
DB 관리 방법론	61
프롬프트 설계: 자연어 질의의 원리	67
Agentic Quant Architecture	70
MCP의 개념과 적절한 사용 방법	73
Claude Code · Codex · Grok Build 비교	77
퀀트 리서치 Agentic 재구성 방법론	80
퀀트 리서치: 통합 적용 사례	83
VII. 결론	95
Agentic AI는 AX 전환의 실행 계층이 된다	95

I. AX(AI Transformation)의 부상

DX에서 AX로: 디지털 전환에서 AI대전환으로

DX 시대의 성과와 한계


인프라, 채널, 데이터의 변화 DX,
업무수행방식 자체를 바꾸는 AX

지난 10 여 년간 진행된 DX 는 대면, 수기 중심의 업무를 디지털 인터페이스로 전환하는 과정이었다. 기업은 비대면 채널을 정비하였고, 사내 시스템을 클라우드 환경으로 이전하였으며, 데이터를 표준화하여 활용 가능한 자산으로 축적하였다. 이 결과 운영 효율은 개선되었고, 데이터 기반의 의사결정 가능성이 크게 확대되었다.

그러나 DX 는 본질적으로 '인터페이스 전환'에 가까운 변화였다. 업무의 흐름과 의사결정 구조 자체는 기존과 크게 다르지 않았으며, 사람이 수행하던 판단, 데이터 집계, 보고서 작성 작업은 그대로 남아 있었다. 그 결과 DX 이후에도 반복적·정형적 작업의 비중이 의미 있게 축소되지 못한 사례가 다수 관찰된다.

또한 DX 는 데이터의 디지털화에는 성공했으나, 축적된 데이터를 활용한 의사결정 자동화로 충분히 연결되지 못한 경우가 많다. 보고서, 모니터링 화면의 수는 늘었으나, 그 결과를 활용한 후속 작업은 여전히 인력에 의존하는 구조가 일반적이다.

DX vs AX 글로벌 관심도 추이



자료: Google trend, 유진투자증권

DX 와 AX 의 변화 단위 비교

구분	DX(Digital Transformation)	AX (AI Transformation)
변화 대상	채널, 시스템, 데이터	업무흐름, 의사결정, 실행
핵심 목적	효율화/표준화 /가시화	자율화/예측화/지능화
변화 단위	기능/채널/데이터 (부분 최적화 중심)	업무흐름/판단/실행 (전사 관점으로 변화)
실행 방식	사람이 프로세스를 수행	AI가 판단·추천·자동처리 (사람은 설계, 감독)
성과 기준	처리속도, 운영비용	의사결정 시간, 자동화율, 성과창출(가치창출 중심 KPI)


자료: 유진투자증권

AX의 등장: AI가 업무 흐름 자체에 침투

AX는 이러한 DX의 한계를 넘어, AI가 '업무 흐름 자체'에 침투하는 단계의 변화로 정의된다. 단순히 AI 도구를 추가 도입하는 것이 아니라, 데이터 → 분석 → 판단 → 산출 → 배포로 이어지는 일련의 흐름을 AI를 전제로 재구성하는 작업이다. DX가 '데이터를 모으고 보여주는 변화'였다면, AX는 '데이터에 기반해 자동으로 판단·실행하는 변화'이다.


AX의 본격화는 2024년을 전후로 가시화되기 시작하였다. 추론형 LLM, 멀티모달 모델, Tool Use, Agent 프레임워크 등이 일정 수준 성숙하면서, 단순 응답이 아닌 업무 수행이 가능한 AI 시스템 구축이 현실화되었다.

AX의 업무 흐름 침투 구조



자료: 유진투자증권

DX→AX 산업 전환 타임라인



자료: 유진투자증권

DX와 AX의 구조적 차이

일부에서는 AX를 DX의 연장선으로 이해하기도 하지만, 필자는 AX를 DX와 구분되는 별도의 단계로 본다. DX가 '디지털 인프라를 갖추는 단계'였다면 AX는 '그 인프라 위에서 AI가 인간을 대신해 업무를 수행하는 단계'이다. 양자는 시간적으로 연속되어 있으나, 변화의 단위와 조직 운영에 미치는 영향은 본질적으로 다르다.

특히 AX는 단순 비용 절감이나 효율 개선이 아닌, '업무 산출량 단위의 확장'을 가져온다. AX 도입은 의사결정 구조에도 변화를 가져온다. 종전에는 인간이 데이터를 보고 판단하는 구조였다면 AX 환경에서는 AI가 1차 판단을 제시하고 인간이 검토·승인하는 구조가 일반화된다. 이는 의사결정 속도를 높이는 동시에, 의사결정의 일관성과 추적성을 향상시킨다

금융업에서 DX는 비교적 빠른 전진을 이루었다. 비대면 채널, 모바일 banking, 클라우드 인프라, 데이터 표준화 등이 일정 수준 정착되었다. 그러나 망분리 등 규제요인 및 개인정보보호 이슈로 AX 단계에서 금융업은 선두주자가 되지 못하고 있다. 규제 환경의 점진적 개선과 함께, 미들/백오피스부터 AX 도입이 본격화될 가능성이 높다. 특히 리서치, 리스크, 컴플라이언스 영역에서의 적용 사례가 빠르게 누적되고 있다.

AX는 모델 및 도구 자체의 우월성 보다는 데이터 흐름, 검증 체계, 리포팅 프로세스가 어떻게 연결되는지가 실제 가치에 가깝다. 본 리포트는 AX를 '퀀트 리서치'라는 구체적 영역에 적용해 본 사례를 통해, 추상적 개념이 아닌 실행 가능한 변화로서의 AX를 정리한다.

DX와 AX의 구조적 차이

구분	DX (Digital Transformation)	AX (AI Transformation)
변화의 단위	인터페이스·채널·인프라	업무 흐름·의사결정 구조
핵심 기술	모바일, 클라우드, 빅데이터	LLM, Agent, RAG, MCP
데이터의 역할	저장·조화·시각화	실행·판단·생성의 입력
인력의 역할	디지털 도구 사용자	워크플로우 설계자·감독자
주요 산출물	대시보드·보고서	자율형 워크플로우·자동 산출물
도입 단위	시스템 단위	업무 흐름 단위
거버넌스 초점	접근권·보안	모델·산출물·HITL 체계

자료: 유진투자증권

AX의 정의와 본질

AX의 세 가지 본질적 특성

1. Workflow 변화
2. 판단의 분업화
3. 산출물 자동화

AX는 다음의 세 가지 본질적 특성을 가진다. 첫째, '업무 흐름 단위의 변화'이다. 종전 자동화가 단일 작업 단위에서 진행되었다면, AX는 작업의 흐름 자체를 단위로 변화가 일어난다. 둘째, '판단의 분업화'이다. AI가 1차 판단을 제공하고 인간이 검토·승인하는 분업 구조가 표준화된다. 셋째, '산출물 단위의 자동화'이다. 결과 및 보고서가 자동 생성되며, 사람은 검수 및 해석에 집중한다.

AX 도입의 가장 흔한 실패 패턴 중 하나는 IT 부서의 단독 과제로 추진되는 경우이다. AX의 본질은 업무 흐름의 재설계이므로, 현업 부서의 주도하에 IT 부서의 지원이 결합되어야 한다. IT가 일방적으로 도구를 제공하는 구조에서는 실제 업무와의 정합성이 부족해질 가능성이 높다.

현업 주도형 AX 추진 구조에서는 각 부서가 자신의 업무 흐름을 분해하고, 자동화 가능 단위와 사람이 담당해야 할 단위를 정의한 후, 양자를 결합한 새로운 워크플로우를 설계해야 한다.

AX의 성공조건

1. Workflow 정의
2. 데이터의 DB화
3. 검증체계의 성숙

모든 AI도입이 AX는 아니다. 단순히 LLM을 사내 도구로 제공하거나, 챗봇을 채널에 추가하는 것만으로는 AX라고 보기 어렵다. AX의 성공 조건은 단순하다. 첫째, 업무 흐름이 명확히 정의되어 있어야 한다. 흐름이 모호한 영역에서는 자동화의 단위 자체가 정의되지 않는다. 둘째, 데이터가 정형화 되어야 한다. 데이터의 출처, 정의, 업데이트 주기 등이 명확해야 자동화 워크플로우가 안정적으로 작동한다. 셋째, 검증체계(Human-in-the-loop) 체계가 워크플로우 안에 포함되어야 한다. 자동화 산출물의 신뢰도는 결국 검증 체계의 성숙도에 의해 결정된다.

AX의 대표적 실패 패턴은 다음과 같다. 첫째, 도구 도입 후 활용으로 이어지지 않는 '도입 단계 정체'. 둘째, 자동화 산출물의 품질 관리체계 부재로 인한 '신뢰 저하'. 셋째, 거버넌스 부재에 따른 '책임 모호화'. 넷째, 현업과 IT의 단절에 따른 '업무 정합성 부족'.

이러한 실패 패턴은 모두 'AX를 도구 도입의 함으로 이해한 결과'이다. AX를 워크플로우 설계와 운영 모델 재정의의 관점에서 접근할 때, 이러한 실패 패턴은 상당 부분 회피 가능하다.

'AI 도구 도입'과 'AX'의 구분

구분	AI 도구 도입	AX
변화 단위	단일 기능·개별 작업 들 추가 중심	업무 흐름·판단·산출물 워크플로우 재설계
도입 방식	IT 주도 제공 챗봇·LLM 점점 확대	현업 주도 + IT 지원 자동화 단위와 검증체계 내재화
사람의 역할	사람이 대부분 수행 AI는 보조 도구 역할	AI 1차 수행·판단 사람은 검수·승인·예외 관리
성과 기준	사용률·접속수·PoC 도입 여부 중심	리드타임·자동화율·품질 운영성과 중심
대표 실패 패턴	도입 단계 정체 현업 정합성 부족	신뢰 저하·책임 모호화 거버넌스 없으면 확산 실패

자료: 유진투자증권

AX의 4대 동인: 모델·데이터·인프라·도구

모델: 추론형 LLM과 멀티모달의 성숙

모델: Fable, Gpt5.5 등
데이터: DB(PostgreSQL)
인프라: 클라우드, git 환경
도구: MCP, Notion, Slack

첫 번째 동인은 모델의 성숙이다. 단순 응답형 LLM이 아닌, 다단계 추론과 도구 호출이 가능한 추론형 LLM이 일반화되면서, 업무 수행에 실질적으로 활용 가능한 수준의 모델 기반이 마련되었다. 또한 텍스트, 이미지, 코드를 통합 처리하는 멀티모달 능력의 향상은 금융 도메인의 다양한 데이터 형식을 다룰 수 있는 기반을 제공한다.

모델 성능의 향상은 '업무 단위의 안정성'으로 평가되어야 한다. 다단계 작업에서 오류율, 도구 호출 정확성, 산출물 일관성 등이 실제 운영 환경에서의 모델 적합도를 결정한다.

데이터: 사내 데이터의 정형화와 검색 인프라 성숙

DX 단계에서 축적된 사내 데이터가 일정 수준 정형화되었고, 벡터 검색, 메타데이터 관리 등의 검색 인프라가 보편화되면서, RAG 기반 시스템 구축의 토대가 마련되었다. 이는 도메인 특화 AI 시스템 구축을 위한 핵심 기반이다.

데이터 동인의 핵심은 '양'이 아닌 '질과 구조'이다. 단순히 많은 데이터가 있는 것이 아니라, [데이터가 표준화/ 메타데이터화/ 검색 기능화](#)가 되어 있어야 AX 워크플로우에서 활용 가능하다. 따라서 AX 도입에는 데이터 거버넌스 준비가 선행되어야 한다.

인프라: Cloud-On-Prem-Hybrid 운영 환경의 정착

클라우드 LLM, 온프레미스 모델, 하이브리드 운영 모델 등 다양한 운영 옵션이 정착되면서, 보안·비용·성능 요건에 맞는 인프라 선택이 가능해졌다. 특히 금융권과 같이 규제 요건이 높은 산업에서는 온프레미스 또는 하이브리드 구조가 현실적 선택지로 자리잡고 있다.

또한 GPU/ NPU 등 AI 전용 인프라의 가격·가용성이 개선되면서, 대규모 모델의 사내 운영도 점차 현실화되고 있다. 인프라 측면의 성숙은 AX 도입의 비용 구조에도 직접적인 영향을 미친다.

도구: Tool Use·Function Calling·MCP의 표준화

LLM 이 외부 시스템을 호출할 수 있게 하는 Tool Use, Function Calling, MCP(Model Context Protocol) 등의 표준이 자리잡으면서, 모델과 업무 시스템의 통합이 표준화된 방식으로 가능해졌다. 이는 종전 '일회성 통합 코드' 방식 대비 확장성과 유지보수성이 크게 개선되었음을 의미한다.

특히 MCP의 등장은 AX의 핵심 변곡점 중 하나로 평가된다. USB가 디바이스 연결을 표준화한 것과 같이, MCP는 AI 시스템의 외부 통합을 표준화함으로써 도구 생태계의 빠른 확장을 가능하게 한다. 본 리포트 Part VI에서는 MCP의 활용 사례를 상세히 다룬다.

AX 4대 동인과 핵심 변화



자료: 유진투자증권

II. 생성형 AI 에서 Agentic AI 로

AI 패러다임의 전환


생성형 AI(Generative AI)의 등장과 확산

인간이 컴퓨터언어를 배우기 전,
컴퓨터가 인간의 언어를 배웠다.

생성형 AI란 텍스트, 오디오, 이미지 또는 동영상 형태의 새로운 콘텐츠를 생성하도록 설계된 인공지능 모델을 의미한다. 2022년 11월, ChatGPT의 등장은 인공지능(AI)을 기술 업계 내부의 연구 주제가 아니라, 전 세계 기업과 개인이 일상적으로 체감하는 혁신의 시작점으로 끌어올렸다. 불과 두 달만에 월간 사용자 수가 1억명을 돌파했는데, 인스타그램(30개월), 페이스북(54개월)보다 압도적으로 빠른 수치였다. 이는 인터넷과 스마트폰 초기 확산 속도를 월등히 능가했다.


생성형 AI(Generative AI)등장은 단순히 "더 정교한 AI"의 출현을 의미하지 않았다. 이는 **인류가 컴퓨터와 상호작용하는 방식을 근본적으로 바꾼 기술 패러다임의 전환으로 평가한다**. 과거의 인공지능이 특정 작업을 자동화하거나 분류/예측에 국한되었다면, 생성형 AI는 새로운 결과물을 창조한다. 텍스트, 이미지, 음성, 영상까지 기존에 사람이 만들어야 했던 창작물이 이제 알고리즘을 통해 대량 생산 가능해졌다.

GPT 검색어 트렌드



자료: Google trend, 유진투자증권

글로벌 MAU 1억명 달성까지 소요기간



자료: 유진투자증권

ChatGPT의 등장은 두가지 측면에서 기술 혁명이라 평가받는데,

첫번째는, 사용자 인터페이스(UI)의 혁명이다. 과거 App 기반 소프트웨어는 사용자가 메뉴와 버튼을 배워야 쓸 수 있었다. 하지만 생성형 AI는 자연어 대화를 통해 모든 기능에 접근할 수 있도록 했다. 즉 누구나 명령어나 복잡한 코딩어를 몰라도 “말하는 것만으로” 복잡한 업무 수행을 할 수 있게 되었다.

둘째, 생산성 민주화다. 생성형 AI는 전문가가 아니더라도 고품질의 산출물을 만들 수 있게 한다. 마케팅 담당자는 코드를 몰라도 캠페인 웹페이지를 제작할 수 있고, 학생은 데이터 분석 지식을 몰라도 통계보고서를 완성할 수 있다. 이로 인해 노동시장에서는 고급 기술과 단순 반복 작업 간의 경계가 무너지고 있으며, 기업들은 인력, 시간, 비용 측면에서 전례 없는 효율화를 경험하고 있다.


결국, 생성형 AI 등장의 가장 큰 변곡점은 “컴퓨터가 할 수 있는 일의 정의”를 확장했다는 것이다. 과거의 자동화가 사람이 만든 규칙을 기계가 따르는 Rule-based 방식이라면, 이제는 AI 스스로가 결과물을 창조하고 나아가 복잡한 문제 해결의 주체가 되고 있다. 이 기술 혁명은 단순히 새로운 도구의 출현이 아니라, **향후 인류가 지식, 창작, 의사결정의 방식을 근본적으로 다시 설계해야 하는 거대한 출발점이다.**

도입 초기에 시장의 관심은 모델 자체의 능력에 집중되었다. 모델이 얼마나 자연스러운 문장을 작성할 수 있는지, 얼마나 정확한 코드를 생성할 수 있는지가 평가의 주된 기준이었다. 이러한 흐름은 생성형 AI를 ‘텍스트를 잘 만드는 도구’로 인식하게 만들었으며, 업무에의 적용 방식 또한 단일 프롬프트(prompt) 기반의 일회성 응답 구조에 머무는 경우가 다수였다.

한편 이 시기에 함께 진행된 변화는 모델 외부의 인프라이다. 벡터 데이터베이스, 임베딩(embedding) 검색, API 통합, 워크플로우 자동화 도구가 빠르게 발전하면서, 모델을 둘러싼 ‘실행 환경’이 점차 풍부해졌다. 이러한 환경의 성숙은 모델을 단순한 텍스트 생성기에서 업무 시스템의 구성요소로 이동시키는 토대가 되었다.

그 결과 시장의 관심은 ‘모델의 크기’에서 ‘모델이 무엇과 연결되어 있는가’로 이동하기 시작하였다. 모델 자체의 파라미터 경쟁과 별개로, 모델이 데이터·도구·시스템과 어떻게 연결되어 실제 업무를 수행할 수 있는지가 더 중요한 평가 축이 되었다. 이러한 변화는 AI 산업의 패러다임이 단일 모델 중심에서 워크플로우 중심으로 전환되고 있음을 시사한다.

UI 혁명



자료: 유진투자증권

주요 생성형 AI 모델 비교

구분	Llama 4	GPT-5.5	Claude	Gemini 2.5
대표 라인업	Maverick / Scout 3.3 70B-8B 병렬	GPT-5.5 5.4 mini / nano	Fable 5 / Opus 4.8 Sonnet 5 / Haiku 4.5	2.5 Pro / Flash Flash-Lite 포함
입력·멀티모달	텍스트·이미지 입력	텍스트·이미지 입력	텍스트·이미지 입력	텍스트·이미지 중심
도구·에이전트	Tool calling OpenAI 호환 API	복잡 추론·코딩 소형 모델로 비용 최적화	장기 에이전트·기업 업무 코딩·엔터프라이즈 강점	Deep Research Computer Use 에이전트 계열 확장
배포 방식	Meta API + self-host 개방형·자체 운영 유리	OpenAI API 중심 주력은 폐쇄형 서비스	API + AWS·Bedrock Google Cloud·Foundry 제공	Gemini API Google 생태계 결합
주요 포지션	사내 구축·파인튜닝 벤더 종속 최소화	범용 플러그십 제품 탑재·고성능	장문·문서·기업 자동화 신뢰성 중시 업무 적합	멀티모달·검색 연계 음성·영상·에이전트 확장
공개 여부	개방형 / 자체 배포 가능	폐쇄형 주력	폐쇄형 주력	폐쇄형 주력

자료: 유진투자증권

인공지능 3.0, Agentic AI


생성형 AI의 한계와 Agentic 구조로의 확장

Prompt를 입력하지 않아도
일하는 AI, Agentic AI

생성형 AI는 텍스트, 코드, 이미지 등 새로운 콘텐츠를 생성하는 모델로 출발했다. 초기 생성형 AI의 활용 방식은 사용자가 자연어 프롬프트를 입력하면 모델이 이에 대응하는 결과물을 생성하는 prompt-based generation 구조에 가까웠다. 이 구조는 요약, 번역, 초안 작성, 코드 보조 등 일회성·단편적 업무에는 매우 효과적이었다. 그러나 금융, 데이터 분석, 리스크 점검처럼 외부 데이터 조회와 다단계 판단, 검증 절차가 필요한 업무에서는 한계가 분명했다.

그 한계는 크게 다섯 가지로 정리할 수 있다. 1) 초기 생성형 AI는 실시간 데이터, 사내 데이터베이스, 종목별 시계열 데이터 등 외부 자원에 직접 접근하기 어려웠다. 2) 계산기, 데이터 조회 API, 엔진, 파일 시스템 등 외부 도구를 안정적으로 호출하는 구조가 부족했다. 3) 대화 세션을 넘어서는 장기 메모리와 프로젝트 단위의 맥락 유지가 제한적이었다. 4) 복잡한 업무를 단계별로 분해하고 중간 결과를 검증하는 planning과 reflection 구조가 충분하지 않았다. 5) 산출물이 어떤 데이터와 판단 과정을 거쳐 만들어졌는지 추적하기 어려워 설명 가능성, 책임 소재 측면에서 제약이 있었다.

Prompt-based generation



자료: 유진투자증권

AI Agent의 등장: 단일 작업 자동화에서 목표 기반 실행으로

AI Agent는 LLM에 외부 도구 호출 기능, 단계별 계획 기능, 그리고 일정 수준의 상태 관리 기능을 결합한 구조를 의미한다. 사용자는 더 이상 한 줄의 프롬프트로 단일 응답을 받는 것이 아니라, 목표(goal)를 입력하고 Agent가 이를 달성하기 위해 필요한 단계와 도구를 스스로 선택·실행하도록 위임할 수 있게 된다.

대표적인 사례로는 코드 작성 Agent, 웹 검색 Agent, 데이터 분석 Agent 등이 있다. 이들은 공통적으로 (1) 목표 입력, (2) 단계 분해, (3) 도구 호출, (4) 결과 검토라는 순환 구조를 갖는다. 이러한 구조는 한 번의 응답에 머무르지 않고, '목표가 달성될 때까지 자체적으로 반복 수행'한다는 점에서 단순 챗봇과 명확히 구분된다.

Agent 구조의 초기 적용 사례는 단순 텍스트 자동화, 회의록 요약, 뉴스 분류 등의 영역에서 출발했다. 이후 RAG(Retrieval-Augmented Generation)와 결합되면서, 사내 매뉴얼·정책 문서·과거 리서치 자료를 참조하는 '참고형 Agent'가 등장하였다. 이는 정보 검색의 효율성을 크게 향상시켰으나, 여전히 단일 작업 단위에 그친다는 한계가 있었다.

참고형 Agent 예시




자료: 유진투자증권, 각사 로고 반영

다음 단계는 다단계 업무를 처리하는 '작업형 Agent'이다. 예를 들어 퀀트 리서치의 경우 '특정 종목군에 대한 팩터 분석 보고서를 작성하라'는 목표를 받았을 때, 데이터 조회 → 팩터 계산 → 결과 정리 → 시각화 → 코멘트 작성에 이르는 단계를 순차적으로 수행할 수 있어야 한다. 이러한 작업형 Agent의 구현 가능성은 도구 호출(Tool Use)과 작업 계획(Planning) 기능의 성숙도에 따라 좌우된다.

Agent 개념의 핵심은 '업무의 단위가 응답이 아닌 결과물'이라는 점이다. 단순 챗봇은 한 번의 응답을 단위로 동작하지만, Agent 는 '완성된 결과물'을 단위로 동작한다. 이는 업무 자동화의 관점에서 매우 중요한 변화로, 응답 품질 그 자체보다 결과물 품질과 검증 가능성이 핵심 평가 기준이 된다.

작업형 Agent 예시



자료: 유진투자증권, 각사 로고 반영


작업형 Agent 가 실제 업무 환경에서 작동하기 위해서는, Agent 가 호출할 도구와 데이터 소스를 연결하고 단계별 실행 흐름을 안정적으로 관리하는 별도의 기반 계층이 필요하다. 이러한 역할을 담당하는 것이 'Agent 구축 플랫폼'이다. 대표적으로 n8n 과 Make 는 다양한 외부 서비스와 API 를 노드 형태로 연결하여 다단계 워크플로우를 시각적으로 설계할 수 있게 하며, Dify 와 LangGraph 는 LLM 의 계획·도구 호출·상태 관리 로직을 코드 수준에서 구성하고 제어할 수 있는 프레임워크를 제공한다.

여기서 유의할 점은, 이들 플랫폼이 작업형 Agent 그 자체가 아니라 이를 조립하고 운영하는 인프라 계층에 해당한다는 것이다. 즉 앞서 언급한 팩터 분석 보고서 작성과 같은 작업형 Agent 는 이러한 플랫폼 위에서 도구 연결과 실행 순서가 정의됨으로써 비로소 구현된다. 플랫폼 계층의 성숙은 개별 Agent 의 도구 호출과 작업 계획 기능을 실제 업무 파이프라인으로 전환하는 접점이 되며, 나아가 다수의 Agent 를 하나의 흐름 안에서 연결·조율하는 Multi-Agent 구조의 기술적 토대를 형성한다.

복잡한 업무에서는 하나의 Agent 가 모든 작업을 수행하기보다는, 역할이 분리된 다수의 Agent 가 협업하는 구조가 효율적이다. 또한 결과의 신뢰성을 확보하기 위해서는 별도의 검증 단계가 시스템 안에 포함되어야 한다. 이러한 요구가 누적되면서 단일 Agent 구조는 Multi-Agent 구조 및 자기 검증 구조로 확장되었다.

요약하면 AI Agent 는 '단일 작업 자동화'에서 '목표 기반 실행'으로 AI 활용 방식을 이동시킨 핵심 개념이다. 그러나 실제 업무 환경에서는 단순한 Agent 구조를 넘어, 다수 Agent 가 협업하고 결과를 검증하는 보다 진화된 구조가 요구된다. 이를 통칭한 개념이 Agentic AI 이다.

Agent 구축 플랫폼 예시



자료: 유진투자증권, 각사 로고 반영

Agentic AI의 의미: 계획, 도구활용, 기억, 검증이 결합된 자율형 시스템

Agentic AI는 단일 Agent를 넘어, 계획(Planning), 도구 활용(Tool Use), 기억(Memory), 검증(Reflection), 다중 에이전트 협업(Multi-Agent)이 결합된 자율형 시스템을 가리킨다. 즉 AI Agent가 '하나의 행위 주체'라면, Agentic AI는 '여러 행위 주체와 보조 모듈이 조합된 시스템'으로 이해할 수 있다.

Agentic AI는 아래 여섯 가지 구조를 결합한 모델로 볼 수 있다.

① 목표 기반(goal-oriented)의 실행 구조. ② 다단계 계획과 단계별 실행. ③ 외부 도구데이터에 대한 접근 ④결과에 대한 자체 검증과 수정 ⑤ 필요시 다른 Agent와의 협업 ⑥ 누적적 맥락 관리

이 구조의 본질은 '응답형 AI'에서 '실행형 AI'로의 전환이다. 즉 사용자의 요청에 대한 단발성 응답이 아닌, 목표 달성까지의 일련의 업무 흐름을 수행하는 시스템으로서 동작한다. 이는 단순 도구를 넘어 업무 인프라의 일부로 통합될 수 있는 가능성을 시사한다.

다만 Agentic AI 역시 만능 도구는 아니다. Agent 간 협업이 복잡해질수록 오류 누적과 통제 어려움이 증가하며, 비용·지연·보안 측면의 부담도 커진다. 또한 모든 업무를 자동화하는 것이 최선의 선택이 아닐 수 있다는 점에서, 자동화 범위 설계와 Human-in-the-loop 구조의 설계가 더욱 중요해진다.

결국 Agentic AI 는 '응답 도구'가 아니라 '업무 시스템'이다. 이러한 관점에서 AI 도입을 단순 모델 선택의 문제가 아닌 워크플로우 설계의 문제로 보는 시각이 필요하다.

생성형 AI → AI Agent → Agentic AI


구분	생성형 AI	AI Agent	Agentic AI
기본 성격	응답형 AI	실행형 단일 주체	자율형 시스템
작동 방식	프롬프트에 대한 단발성 응답	목표를 받아 도구를 사용해 과업 수행	목표 달성을 위해 계획·실행·검증 협업을 반복
목표 지향성	낮음	중간	높음
계획 수립	거의 없음	단순 단계 수행	다단계 계획 및 재계획
도구 활용	제한적	가능	적극적·구조적 활용
기억 관리	대화 맥락 중심	세션 단위 맥락 유지	누적적 맥락·메모리 관리
검증·수정	사용자 재질문 의존	일부 가능	자체 검증·수정 루프 포함
협업 구조	없음	단일 Agent 중심	다중 Agent 협업 가능
산출 형태	답변·초안	작업 결과물	업무 흐름 완료 및 통합 결과
대표 한계	외부 실행 부족	복잡한 업무 확장 한계	비용·통제·보안·오류 누적 관리 필요

자료: 유진투자증권

Agentic AI의 핵심 구성요소

Agentic AI는 LLM을 중심으로 RAG, Tool Use, Memory, Planning, Reflection, Multi-modal 기능이 결합된 업무 수행 시스템이다. LLM은 사용자의 요청을 해석하고 계획·판단·검증을 담당하는 두뇌 역할을 하며, RAG는 외부 지식 검색을 통해 최신성과 도메인 정확성을 보완한다. Tool Use는 API, DB, 계산기, 파일 시스템 등을 호출해 실제 작업 수행을 가능하게 하고, Memory는 대화프로젝트·사용자 선호와 과거 리서치 맥락을 누적해 업무의 일관성을 높인다. Planning은 복잡한 업무를 단계별로 분해하고 조건에 따라 실행 흐름을 조정하며, Reflection은 산출물의 오류와 품질을 점검해 환각과 오류 누적을 줄인다.

Agentic AI 7대 구성요소 아키텍처



자료: 유진투자증권

III. AX 밸류체인과 시장구조

5 계층 밸류체인


Chip → Compute Infra → Foundation Model → Middleware/Tool → Application

AX 밸류체인에서 일반 사용자는
Application 단계만 사용

AX 밸류체인은 기술 스택의 순서를 따라 5 계층으로 구분된다. 최하단은 Chip(GPU·NPU·HBM 등 AI 전용 반도체), 그 위는 Compute Infra(데이터센터·전력·네트워크·클라우드), 그 위는 Foundation Model(범용 LLM), 그 위는 Middleware/Tool, 최상단은 Application(산업별·기능별 솔루션)이다. 이 구분은 산업 분석의 표준 프레임으로 자리잡고 있다.

5 계층 모델은 절대적 분류는 아니다. 일부 기업은 여러 레이어에 걸쳐 사업을 영위하며(예: 글로벌 빅테크), 레이어 간 경계는 점차 흐려지는 경향이 있다. 그럼에도 분석의 출발점으로 5 계층 모델은 유용한 분류 체계를 제공한다.

레이어별 경쟁 구도와 마진 구조



자료: 유진투자증권


자본 흐름의 단계적 이동

초기에는 GPU·데이터센터·전력 등 인프라 투자가 집중되지만, 시간이 지날수록 모델, 도구, 애플리케이션으로 가치 창출의 중심이 이동할 가능성이 높다. 따라서 AX 산업을 분석할 때는 단순히 AI 모델 성능만 볼 것이 아니라, 자본 흐름과 병목, 표준화, 생태계, 도메인 적용력을 함께 봐야 한다.

1) 컴퓨트 인프라 레이어: AX 사이클의 출발점


AX 사이클 초기의 자본은 컴퓨트 인프라 레이어에 집중된다. AI 모델 학습과 추론에는 대규모 연산 자원이 필요하며, 이를 뒷받침하는 핵심 요소가 GPU·NPU·HBM·첨단 패키징·데이터센터·전력 인프라이다. 특히 GPU는 현재 AI 학습과 추론의 표준 인프라로 자리 잡았고, HBM과 CoWoS 등 고성능 메모리·패키징 기술은 공급 병목이자 핵심 수혜 영역으로 부상했다. 이 영역은 소수 기업 중심의 과점 구조가 강해, 기술 우위와 공급 능력이 곧 가격 결정력과 마진 구조로 연결된다.

DRAM/NAND 가격 추이




자료: check, 유진투자증권

삼성전자/SK하이닉스 12MF EPS 추이



자료: Quantwise, 유진투자증권

삼성전자/SK하이닉스 시가총액 추이



자료: Quantwise, 유진투자증권

2) Foundation Model 레이어: 성능 경쟁에서 비용-생태계 경쟁으로

Foundation Model 은 대규모 데이터로 사전학습되어 다양한 작업에 활용 가능한 범용 모델을 의미한다. 텍스트 LLM, 멀티모달 모델, 코드 모델, 추론형 모델 등이 여기에 포함된다. 최근에는 단일 모델이 텍스트, 이미지, 코드, 음성, 추론 기능을 함께 포괄하는 방향으로 발전하고 있다.

모델 시장은 크게 세 그룹으로 나뉜다. 첫째, 자체 인프라와 생태계를 보유한 글로벌 빅테크 산하 모델, 둘째, 독립 모델 전문 기업, 셋째, 오픈 가중치 모델 기반 생태계이다. 초기에는 모델의 파라미터 규모와 벤치마크 성능이 경쟁의 핵심이었지만, 최근에는 상위 모델 간 성능 격차가 줄어들면서 차별화 기준이 바뀌고 있다. 이제 중요한 것은 단순 성능이 아니라 추론 능력, 도구 호출 안정성, 멀티모달 통합, 가격, 지연시간, 운영 효율, 생태계 연동성이다.

모델 레이어의 수익성은 아직 쉽지 않은 과제이다. 학습과 운영 비용은 막대하지만, 토큰 가격은 하락 압력을 받고 있으며 빅테크의 가격 경쟁도 심하다. 따라서 모델 전문 기업은 단순 API 매출만으로 지속 가능한 수익 구조를 만들기 어렵고, 생태계, 도구, 엔터프라이즈 통합, 도메인 특화 전략이 중요해진다. 분석가는 모델 기업을 평가할 때 벤치마크 성능만이 아니라 비용 구조, 토큰 가격, 도구 생태계, 도메인 적합성을 함께 봐야 한다.

빅테크의 AI 투자

기업	① 투자 발표/가이드라인	② 부지·인허가	③ 전력 확보/착공	④ GPU·서버·HBM 발주	⑤ 실제 가동	한 줄 판단
Microsoft		△		●	●	핵심 투자는 후반부, 일부 임대 프로젝트는 조정
Amazon				●	●	AWS 중심으로 실제 수요 연결성 높음
Alphabet			●	●	△	대규모 확충 중, 공급·전력·자본 부담 확대
Meta			●	●	△	미래 용량 확보 목적의 투자 확대
Oracle			△	●	●	대형 고객형 AI 인프라 수요가 계약·매출로 연결
Apple	●	△	△			AI 인프라 확대 초기, 규모는 제한적

자료: 유진투자증권

3) 미들웨어·도구 레이어: 모델과 애플리케이션을 잇는 인터페이스


미들웨어·도구 레이어는 Foundation Model 과 실제 애플리케이션 사이를 연결하는 핵심 계층이다. 모델은 범용적이고, 애플리케이션은 도메인 특화적이기 때문에 둘을 연결하는 Agent 프레임워크, Tool Use, Function Calling, MCP, Orchestration 도구가 필요하다. 이 레이어의 성숙도가 AX 확산 속도를 결정한다.

Agent 프레임워크는 LLM 을 실제 업무 수행 Agent 로 구성·운영하기 위한 플랫폼이다. 오픈소스와 상용 플랫폼이 혼재되어 있으며, 표준화의 방향이 시장 구조를 결정할 가능성이 높다. Tool Use 와 Function Calling 은 LLM 이 외부 API, DB, 계산 엔진, 파일 시스템 등을 호출하게 하는 표준 메커니즘이다. 이를 통해 LLM 은 단순 텍스트 생성기가 아니라 실제 업무 수행 시스템으로 확장된다.

MCP(Model Context Protocol)는 AI 시스템과 외부 시스템의 통합을 표준화하려는 흐름을 대표한다. USB 가 디바이스 연결을 표준화했듯, MCP 는 AI 가 다양한 도구와 데이터를 일관된 방식으로 연결할 수 있게 한다. 이는 도구의 추가·교체·결합을 쉽게 만들고, 미들웨어 생태계의 확장 속도를 높인다. 또한 다단계 Agent Workflow 를 정의·실행·모니터링하는 Orchestration 도구도 중요해지고 있다. 이는 기존 BPM·RPA 시장과 일부 중첩되며, 장기적으로 업무 자동화 시장의 재편으로 이어질 수 있다.

미들웨어 레이어의 수익 모델은 사용량 기반, 라이선스 기반, 오픈소스 코어와 상용 부가 서비스, 통합 플랫폼 모델 등으로 다양하다. 분석 관점에서는 표준화 수준과 생태계 규모가 핵심이다. 표준이 정착되면 시장은 소수 플랫폼 중심으로 통합될 가능성이 있다.

AI 미들웨어/ Agent Tool 생태계 맵



자료: 유진투자증권

4) 애플리케이션 레이어: 도메인 깊이와 고객 통합이 차별화

애플리케이션 레이어는 최종 사용자가 AX 의 가치를 체감하는 영역이다. 진입장벽은 상대적으로 낮지만, 지속 가능한 차별화는 쉽지 않다. AX 애플리케이션은 크게 수직 솔루션과 수평 솔루션으로 나뉜다. 수직 솔루션은 금융, 의료, 법률, 제조처럼 특정 산업에 특화된 솔루션이고, 수평 솔루션은 문서 작성, 코드 작성, 고객 응대, 데이터 분석처럼 산업을 가리지 않는 기능 중심 솔루션이다.

수직 솔루션의 경쟁력은 도메인 데이터, 규제 대응, 고객 시스템 통합, 운영 노하우에서 나온다. 단순히 LLM 을 붙이는 것만으로는 충분하지 않으며, 해당 산업의 업무 흐름과 데이터 구조를 깊이 이해해야 한다. 반면 수평 솔루션은 시장 규모가 크지만 진입장벽이 낮고 경쟁이 치열하다. 코딩 어시스턴트, 문서 생성, 고객 응대 챗봇, 데이터 분석 도구 등에서는 빅테크와 신생 AI 기업이 동시에 경쟁한다.

기존 SaaS 기업의 AI 기능 통합도 중요한 흐름이다. CRM, ERP, HR, 생산성 도구에 AI 기능이 내장되면서 사용자는 별도 AI 도구를 도입하지 않고도 AX 효과를 체감할 수 있다. 이는 신생 AI 애플리케이션에는 위협이지만, 기존 SaaS 기업에는 새로운 성장 동력이 될 수 있다. 한편 AI 네이티브 애플리케이션은 기존 업무를 단순 자동화하는 수준을 넘어, AI를 전제로 새로운 워크플로우 자체를 설계한다는 점에서 시장 재정의 가능성을 갖는다.

AX 애플리케이션 매트릭스



자료: 유진투자증권

IV. LLM 과 딥러닝 모델의 진화

생성형 AI의 출발점은 트랜스포머 기반 NLP 연구

자연어처리에서 시작된 트랜스포머 모델(딥러닝 모델)

NLP에서 시작된
LLM이 인간을 대신하기 시작

생성형 AI의 출발점은 자연어 처리(NLP, Natural Language Processing) 연구에서 비롯되었다. NLP는 인간의 언어(자연어)를 컴퓨터가 이해하고 해석하며, 나아가 생성할 수 있도록 만드는 인공지능 분야다. 즉, 언어의 의미(sentiment)와 문맥(context)을 기계가 이해하게 하여 사람처럼 언어를 다룰 수 있게 하는 것이

본래 컴퓨터는 구조화된 데이터 처리에는 강했지만, 사람의 언어처럼 모호하고 맥락이 중요한 정보를 다루는 데는 한계가 있었다. 이를 극복하기 위해 NLP 연구는 텍스트 분류, 기계 번역, 질의응답, 음성 인식, 요약 등 다양한 언어 과제를 중심으로 발전해왔다.

초기에는 통계적 접근과 단순한 기계학습 모델이 주를 이루었으나, 곧 RNN이나 LSTM 같은 순환 신경망, CNN 기반 모델이 텍스트 처리에 활용되면서 의미 있는 성과가 나오기 시작했다. 그러나 이들 모델은 긴 문맥을 처리하거나 병렬 연산을 수행하는 데 한계가 있었다. 이러한 문제를 근본적으로 해결한 것이 바로 트랜스포머(Transformer)다.

트랜스포머는 어텐션 메커니즘을 기반으로 문맥을 효율적으로 이해할 수 있는 딥러닝 모델로, 2017년 'Attention is All You Need' 논문을 통해 제시된 이후 NLP 연구의 주류를 완전히 바꿔놓았다. 트랜스포머는 기존 RNN·LSTM보다 더 긴 문맥을 안정적으로 학습할 수 있으며, 병렬 처리로 학습 속도와 효율성에서도 우월하다. 이후 GPT, BERT, T5 같은 거대 언어 모델(LLM)의 등장은 생성형 AI의 시대를 여는 결정적인 계기가 되었다.

즉, 오늘날 우리가 활용하는 생성형 AI는 단순히 기계가 언어를 흉내 내는 수준을 넘어, 트랜스포머 기반 NLP 연구의 축적된 성과 위에서 가능해진 것이다.

2010년대 후반 인공지능 트렌드

구분	주요 모델/사건	특징	의의
딥러닝 확산	ResNet (2015, Microsoft Research)	CNN-RNN/LSTM 기반 모델이 이미지·음성 인식 분야에서 압도적 성능 달성	자율주행·의료영상 등 산업 전반에서 딥러닝이 사실상 표준으로 자리 잡음
강화학습 붐	AlphaGo (2016), AlphaZero (2017), OpenAI Dota2, DeepMind StarCraft II	딥러닝 + 강화학습 결합 → 게임에서 인간을 능가	게임을 강화학습 혁신의 실험장으로 활용, 자율적 의사결정 AI 가능성 입증
NLP 혁신 (트랜스포머)	Transformer (2017), BERT (2018), GPT-2 (2019)	Attention 기반 구조, 사전학습 (Pre-training)+파인튜닝 확산	LLM(대규모 언어모델) 시대의 직접적 전조
GAN 열풍	GAN (Ian Goodfellow, 2014 → 2010년대 후반 확산)	이미지 합성, 딥페이크, 예술 창작	생성형 AI의 초기 형태, 창작 영역 확장 시도

자료: 유진투자증권

기존 딥러닝 모델의 역할: RNN, CNN, DNN, LSTM

Transformer의 등장에도 불구하고 기존 딥러닝 모델은 여전히 유효

금융 데이터는 기존
딥러닝 모델이 유효

금융 시계열은 자연어와 달리 표본 수가 제한적이고, 노이즈가 크며, 비정상성(non-stationarity)이 강하다. 이러한 특성은 대규모 학습을 전제로 한 Transformer 기반 모델의 강점이 항상 그대로 발휘되지 않을 수 있음을 시사한다.

오히려 적당한 복잡도의 전통 딥러닝 모델이 안정적 성능을 보이는 경우가 많다. 또한 해석 가능성, 학습 비용, 추론 속도 측면에서 전통 모델은 운영 환경에서의 장점을 갖는다. 즉 '최신 모델이 항상 더 우월한 것은 아니다'라는 점이 금융 시계열 모델링의 경험적 결론이다.

1) DNN: 비선형 관계 학습

DNN(Deep Neural Network)은 다층 퍼셉트론 구조로, 입력 변수 간 비선형 관계를 학습하는 데 적합한 모델이다. 종전의 선형 회귀나 로지스틱 회귀로는 포착하기 어려운 변수 간 상호작용을 일정 수준 모델링할 수 있다.

금융 데이터 분석에서는 가격·거래량·재무지표·매크로 변수 간의 비선형 관계를 다루는 데 활용된다. 다만 표본 수가 제한적인 금융 시계열의 특성상 모델이 쉽게 과적합(overfitting)되는 경향이 있어, 정규화(regularization)와 교차 검증의 설계가 중요하다.

2) CNN: 지역 패턴 인식

CNN(Convolutional Neural Network)은 본래 이미지 처리에 강점을 가진 모델이지만, 금융 데이터에서도 지역 패턴(local pattern) 인식에 활용된다. 예컨대 캔들 차트 이미지, 거래량 패턴, 주문 흐름 시퀀스 등에서 단기 패턴을 추출하는 데 적용될 수 있다.

일부 연구에서는 가격 시계열을 시간-가격 이미지로 변환하여 CNN을 적용하는 방식도 시도되어 왔다. 다만 이러한 접근은 데이터 변환 과정에서 정보 손실이 발생할 수 있어, 단독 사용보다는 다른 모델과의 결합 구조에서 의미를 갖는 경우가 많다.

3) RNN: 순차 데이터 처리

RNN 은 시간적 순서를 갖는 데이터 처리를 위해 설계된 모델이다. 가격, 거래량, 금리, 환율 등 시계열 데이터의 흐름을 모델링하는 데 활용되어 왔으며, 금융 도메인의 초기 딥러닝 적용 사례 다수에서 사용되었다.

다만 기본 RNN 은 장기 의존성 처리에 약점이 있어, 실무에서는 그 변형인 LSTM 또는 GRU 가 사용되는 경우가 일반적이다. 또한 표본 수가 제한적인 금융 시계열에서는 모델 복잡도가 높아질수록 학습 안정성이 떨어지는 경향이 있다.

4) LSTM/GRU: 장기 의존성 문제 보완

LSTM 과 GRU 는 RNN 의 장기 의존성 문제를 게이트(gate) 구조로 완화된 모델이다. 입력, 망각, 출력 게이트를 통해 어떤 정보를 기억하고 어떤 정보를 잊을지를 학습한다. 이는 시계열의 누적 효과를 일정 수준 모델링할 수 있게 한다.

금융 시계열에서 LSTM/GRU 는 가격 예측, 변동성 예측, 거시 변수와의 결합 분석 등에 활용되어 왔다. 다만 결과의 예측력은 모델 자체보다 데이터 전처리, 특징 설계, 학습 윈도우 설정 등 보조적 요소에 의해 좌우되는 경우가 많다.

금융 데이터 유형별 전통 딥러닝 모델 활용 예시

데이터 유형	주요 모델	활용 예시	유의사항
가격 시계열	LSTM, GRU, 1D-CNN	방향성 예측, 변동성 예측	비정상성, 과적합
거래량·수급	LSTM, Transformer-lite	이상 거래 탐지, 매집·분산 패턴	이상치 처리
금리·환율	DNN, LSTM, 통계모형 결합	커브 변화, 통화별 모멘텀	레짐 변화
변동성	GARCH+DNN, LSTM	옵션 변동성 예측, 리스크 관리	이벤트 충격
패턴/차트	2D-CNN	차트 이미지 분류, 형태 인식	정보 손실

자료: 유진투자증권

모델별 적합도

모델	핵심 강점	금융 데이터 적용 포인트	한계 / 유의점	실무 판단
DNN	비선형 관계 학습	가격, 거래량, 재무지표 등 매크로 변수 간 상호작용 포착	표본 수가 적으면 과적합 위험, 정규화, 교차검증 중요	정형 피쳐 기반 예측·분류에 유효
CNN	지역 패턴 인식	캔들 패턴 · 거래량 주문 시퀀스의 단기 패턴 추출	이미지/패턴 변환 과정의 정보 손실 가능, 단독보다는 결합형 구조에 적합	특정 패턴 탐지에는 유용하나 범용성은 제한
RNN	순차 데이터 흐름 처리	가격 · 금리 · 환율 거래량 등의 시간 순서 모델링	장기 의존성에 약함, 복잡도 상승 시 학습 안정성 저하	기초 시계열 구조 학습에는 의미 있으나 단독 주력은 제한적
LSTM/GRU	장기 의존성 보완	가격 예측 · 변동성 예측 거시 변수 결합 분석	성능은 모델보다 전처리, 특징설계, 학습 윈도우 설정에 크게 좌우	금융 시계열에서 가장 실용적인 전통 딥러닝 계열

자료: 유진투자증권

Transformer 와 기존 모델의 융합

금융 시계열 분석에서는 Hybrid Model 이 표준

금융 데이터는 기존
딥러닝 모델이 유효

Transformer 는 강력한 모델이지만, 모든 데이터-작업에서 우월한 것은 아니다. 특히 짧은 시퀀스의 단순 패턴 인식, 극단적인 저자원 환경, 정밀한 지역 패턴 인식 등에서는 기존 모델의 효율성이 더 높을 수 있다. 또한 학습추론 비용이 상대적으로 크다는 점도 운영 환경에서 고려해야 할 요소이다.

금융 시계열은 일반적으로 표본 수가 제한적이고 노이즈가 크다. 이러한 환경에서 대규모 Transformer 모델을 그대로 적용할 경우, 과적합과 학습 불안정의 위험이 동시에 발생할 수 있다. 가격, 거래량, 변동성 등은 모두 잡음 성분이 크며, 명확한 신호를 추출하기 어렵다. 또한 시장 구조 변화, 정책 변화, 거시 환경 변화 등으로 인해 비정상성이 강하다.

유효 표본 또한 제한적이다. 일별 가격 데이터를 사용하더라도, 의미 있는 패턴이 형성되는 기간은 수년~수십 년에 불과하며, 이는 모델 학습에 필요한 양에 비해 부족한 경우가 많다. 이러한 특성은 모델 복잡도의 무한정 확대를 제약한다.

지역적 패턴(Local Pattern)이란?

- 데이터 전체(global)이 아니라 일부 국소 영역(local region)에 나타나는 특징
- CNN(합성곱)은 작은 필터로 이미지를 훑으면서 이런 국소 패턴을 잘 파악하는 편, 이런 국소 정보가 쌓이면 점점 더 큰 특징까지 학습 가능

계산 효율(Computational Efficiency)이란?

- 모델이 연산을 얼마나 빨리, 적은 자원으로 할 수 있는지를 말함
- CNN 은 합성곱(convolution) 연산 덕분에 GPU/ 모바일 칩에서 매우 최적화되어 있으나, 트랜스포머의 어텐션(self-attention)은 모든 토큰(패치)끼리 관계를 계산하여 $O(n^2)$ 복잡도 이기 때문에 시퀀스가 길어질수록 계산 비용이 급격히 증가

1) CNN + Transformer: 지역 패턴과 장기 문맥의 결합

CNN 과 Transformer 의 결합은 지역 패턴 인식과 장기 문맥 이해를 동시에 수행할 수 있는 구조이다. CNN 이 단기 패턴을 추출하고, Transformer 가 그 패턴들 간의 장기적 관계를 학습하는 형태로 결합된다.

금융 시계열에서는 단기 가격 패턴이나 거래량 클러스터를 CNN으로 추출하고, 이러한 패턴들이 장기적으로 어떻게 누적·전파되는지를 Transformer 로 학습하는 구조가 시도될 수 있다. 다만 실증 결과는 데이터 정의와 윈도우 설정에 민감하다.

2) RNN/LSTM + Attention: 시계열 구조와 중요 구간 인식

RNN/LSTM 에 Attention 모듈을 결합하는 접근은, 시계열의 순차 구조를 유지하면서도 중요 구간에 대한 가중치를 명시적으로 학습할 수 있게 한다. 이는 예컨대 특정 이벤트 발생 시점 주변의 가격·거래량 흐름에 더 큰 가중치를 부여하는 형태로 활용 가능하다.

이러한 결합은 해석 가능성 측면에서도 장점을 가진다. 어떤 구간이 결과 예측에 기여했는지를 가중치를 통해 일정 수준 관찰할 수 있기 때문이다. 다만 이러한 해석은 보조적 수단이며, 인과 관계의 증거로 해석해서는 안 된다.

3) SSM, Mamba, RWKV 계열 모델의 부상

최근에는 Transformer 의 계산 복잡도 한계를 극복하기 위한 새로운 아키텍처들이 부상하고 있다. SSM(State Space Model) 계열의 Mamba, RNN 과 Transformer 의 장점을 결합한 RWKV 등이 대표적이다. 이들은 긴 시퀀스 처리에서 Transformer 대비 계산 효율의 장점을 보인다고 보고되고 있다

금융 시계열은 본질적으로 긴 시퀀스 처리가 잦은 분야이다. 일중 데이터, 호가 데이터, 시계열 누적 데이터 등은 그 길이가 매우 길 수 있으며, 이러한 영역에서는 새로운 아키텍처의 도입 가능성이 높다. 다만 실증 단계에서의 평가는 여전히 진행 중이며, 실무 적용은 신중한 검증이 필요하다.

SSM 이란?

SSM 은 제어이론의 상태공간 방정식을 시퀀스 모델에 적용해, 입력을 하나의 상태로 압축하며 긴 문맥을 선형에 가까운 계산량으로 처리하는 탈(脫)어텐션 아키텍처의 기반 개념

Mamba 란?

Mamba 는 이 SSM 에 입력에 따라 파라미터를 동적으로 바꾸는 '선택성'을 더해, 어텐션의 내용 기반 집중 능력을 구현하면서 Transformer 급 성능과 선형 확장성을 달성한 진화형

RWKV 란?

RWKV 는 학습은 Transformer 처럼 병렬로, 추론은 RNN 처럼 토큰당 일정한 비용으로 동작하도록 결합한 별도 계열이다.

셋 모두 어텐션의 제곱 복잡도($O(N^2)$) 한계를 넘어 긴 문맥을 저비용으로 처리하려는 시도라는 공통점을 갖는다.

퀀트 모델링에서 Hybrid Model 이 갖는 의미

기존 딥러닝 모델과 Transformer 결합한 모델 사용

매크로 국면 모델에
적용해본 RNN+ Transformer

앞서 언급했듯 짧은 시계열, 비정상성이 강한 금융 데이터 특성으로 인해, 퀀트 모델링에서는 단일 모델보다 Hybrid Model 이 보다 적합한 경우가 많다. 통계모형, 전통 머신러닝, 딥러닝, LLM 이 각자의 역할을 분담하는 구조가 점차 표준화 되고 있다.

예컨대 거시 변수 예측에는 통계모형과 DNN 을, 일중 패턴 인식에는 CNN·LSTM 을, 텍스트 데이터 분석에는 Transformer 기반 LLM 을 활용하는 식이다. Agentic AI 는 이러한 Hybrid 구조를 통합적으로 호출하고 관리하는 ‘오케스트레이터(orchestrator)’의 역할을 수행할 수 있다.

퀀트 모델 진화의 방향은 ‘단일 우월 모델’이 아닌 ‘적합 모델의 조합’이다. 이러한 흐름은 퀀트 모델 운영 방식 자체를 단일 모델 중심에서 시스템 중심으로 이동 시킨다.

Hybrid 모델로 만들어본 매크로 국면 모델

(비지도 학습으로 국면 정의)

기존에 Regime 자체를 먼저 정의(Labeling) 하는 방식은 라벨 정의가 불완전하면 오히려 overfit 위험이 있을 수 있고, Regime 에 정답이 존재하지 않기 때문에 모델이 스스로 군집을 찾는 것이 더 유연한 방식이다.

따라서 과거에 정의된 라벨(Regime 에 대한 정의)이 미래에는 통하지 않을 수 있음 → 학습된 임베딩은 구조 변화를 포착 가능한 구조이다.

라벨 없이 비지도 학습으로 데이터의 내재된 구조 및 패턴을 스스로 학습 한다면, 새로운 시장 국면이나 패턴을 발견 할 수 있다.

사후 해석(Post-labeling)을 통해 경제적 의미를 부여하고, 인간의 정의보다 더 자연스러운 국면 분류가 가능하다.

지도 학습 vs. 비지도학습

구분	지도학습	비지도학습
국면 정의 시점	학습 이전(pre-defined)	학습 이후(post-defined)
국면 라벨	사람 또는 경제지표 기준으로 미리정의	모델이 분포/패턴으로 자동 분리
모델의 역할	라벨을 맞추는 방향으로 학습	데이터 내 숨은 구조를 압축·표현
전환 탐지 방식	라벨 전환 확률 예측	분포 이동(embedding drift, clustering change) 탐지
필요 데이터	입력(X) + 정답(y: Regime label)	입력(X)만
해석 단계	예측 → 해석	클러스터 → 해석 (=사후 라벨링)

자료: 유진투자증권

최근 연구 트렌드

시기	주요 학술/산업 동향	채택 방법
2017~2020	LSTM, CNN 기반 시계열 예측 (추가/변동성)	완전 지도학습 중심 (price forecasting)
2020~2022	Transformer 계열 (Temporal Fusion Transformer, Informer 등)	지도학습 + 일부 attention 해석
2022~2023	Regime detection, Market state clustering 연구 급증	비지도(GMM, HMM, VAE, KMeans) 중심
2024~2026	Multi-modal + Representation Learning 확산	비지도/자지도(Self-supervised) 로 국면 임베딩, 이후 지도 fine-tuning

자료: 유진투자증권

매크로 국면 모델 설계 개요

모델 개요

- RWKV 딥러닝 모델 기반 비지도 학습 모델로, 시계열 데이터를 임베딩하여 시장의 매크로 국면(Regime)을 자동으로 탐지하고 전환점을 포착함
- 매크로 - 업종 - 팩터 스타일 수익률 시계열을 함께 학습해 국면별 패턴을 추출하고, 현재 시장의 위치와 구조적 변화 방향을 추정함
- 학습된 국면 구조를 통해 현재 Regime에서 유망할 업종, 팩터, 테마를 확률적으로 예측하는 다층 분석 프레임워크

모델 아키텍처 플로우



자료: 유진투자증권

매크로 국면 모델: Github 주소

https://github.com/eugene-quant-request/Macro_dynamic_model.git

Input Layer: Regime 분류(GMM)

(GMM(Gaussian Mixture Model)기반 Regime 분류 원리)


- GMM 모델은 금융 시계열의 “숨겨진 상태(hidden state)”를 찾는 가장 널리 쓰이는 비지도 모델
- 현재 찾고자 하는 hidden state는 Regime(국면)
- 금융 시장은 단일 패턴이 아닌 여러 개의 상태(State)가 존재하기 때문에 관측된 데이터는 하나의 정규분포로 설명할 수 없고, 여러 개의 정규분포의 혼합으로 설명하는 것이 더 바람직함 → Mixture Model
- GMM은 각 Regime의 평균 벡터, 국면의 공분산 행렬, 혼합 가중치(국면이 발생할 확률)를 학습해 클러스터링 진행

Regime	국면 분석	KOSPI 수준(1M) 수익률/변동성	KOSPI 수준(3M) 수익률/변동성	매크로 특징
R0	초기 회복 국면	1M 수익률: +1.40% 1M 변동성: 5.98	3M 수익률: +2.93% 3M 변동성: 9.14	소비/물가 안정, 제조·생산 반등 초기
R1	강한 경기확장 국면	1M 수익률: +3.15% 1M 변동성: 6.32	3M 수익률: +7.00% 3M 변동성: 6.85	경기지표 개선폭 높음, 제조업·수출 회복 뚜렷
R2	경기 둔화/위축국면	1M 수익률: -0.44% 1M 변동성: 7.27	3M 수익률: -2.01% 3M 변동성: 8.78	제조업 둔화, 수출 감소, PMIs 하락
R3	방어적 국면	1M 수익률: +0.46% 1M 변동성: 4.25	3M 수익률: +0.05% 3M 변동성: 5.95	물가 변동성·대외 리스크 확대

모델 성과 평가(In-sample)

국면별 최적 섹터를 전체기간으로 계산해 같은 기간에 적용

리밸런싱 주기(1M, 3M)에 따른 누적수익률



자료: Bloomberg(매크로 데이터), Quantwise(섹터데이터), 유진투자증권


In-Sample · 1M (n=271)	전략	KOSPI
CAGR	24.50%	12.30%
연율 수익률	24.20%	13.90%
연율 변동성	21.20%	21.70%
샤프	1.14	0.64
소르티노	1.87	1.04
누적 수익률	13742%	1266%
최대낙폭(MDD)	-39.90%	-43.10%
In-Sample · 3M (n=89)	전략	KOSPI
CAGR	23.20%	12.80%
연율 수익률	23.30%	14.10%
연율 변동성	21.60%	21.30%
샤프	1.08	0.66
소르티노	2.36	1.48
누적 수익률	9805%	1317%
최대낙폭(MDD)	-27.60%	-34.00%

In-sample [분석 리포트\(Tearsheet\) 보기](#)(클릭)

모델 성과 평가(Walk-Forward, 룩어헤드 제거)

매 시점 그 전까지 실현된 데이터만으로 섹터를 선택

리밸런싱 주기(1M, 3M)에 따른 누적수익률



자료: Bloomberg(매크로 데이터), Quantwise(섹터데이터), 유진투자증권

Walk-Forward · 1M (n=210)	전략	KOSPI
CAGR	9.00%	12.50%
연율 수익률	10.70%	13.90%
연율 변동성	20.20%	21.30%
샤프	0.53	0.65
소르티노	0.79	1.15
누적 수익률	352%	673%
최대낙폭(MDD)	-35.20%	-34.10%
Walk-Forward · 3M (n=70)	전략	KOSPI
CAGR	6.80%	12.50%
연율 수익률	7.90%	13.90%
연율 변동성	16.90%	21.90%
샤프	0.47	0.63
소르티노	0.75	1.2
누적 수익률	210%	659%
최대낙폭(MDD)	-35.40%	-33.60%

Out-sample [분석 리포트\(Tearsheet\) 보기](#)(클릭)

V. 금융업 AX와 Agentic 리서치

금융업 내 AI 도입 1 세대~3 세대 흐름

퀀트, 핀테크(로보어드바이저) 등에 머물렀던 1~2 세대


어려웠던 백테스팅,
(과거 데이터 분석)
이제는 AI가 다해준다.

3 세대: 퀀트의 대중화

금융산업에서 인공지능(AI)의 도입은 뚜렷한 세대적 변화를 거쳐 왔다. 초기에는 규칙 기반 시스템에 의존했으나, 이후 머신러닝과 딥러닝을 통한 데이터 기반 예측으로 확장되었으며, 최근에는 Agentic AI를 중심으로 한 자율형 의사결정 단계로 진화하고 있다.

금융 분야의 글로벌 생성형 AI 시장 규모는 2023년 8억 4,750만 달러에서 2024년에는 10억 달러를 넘어섰고 계속 증가하여 2033년에는 104억 330만 달러 규모에 이를 것으로 전망한다.¹⁾ Grand View Research., 2025, Generative AI In Financial Services Market Size Report, 2030

금융분야 생성형 AI 시장규모



자료: Grand View Research — Generative AI in Financial Services Market 2025, 유진투자증권

1 세대) 전통적 알고리즘(통계 모델)/Rule-based AI (1990~2010 년초)

1990 년대부터 2010 년대 초반까지 확산된 전통적 알고리즘 및 룰 기반 시스템이다. 이 시기의 AI 는 정형화된 데이터와 사람이 정의한 규칙에 따라 운용되었으며, 알고리즘 트레이딩, 신용평가, 리스크 관리 등 비교적 구조화된 업무에 집중되었다. 그러나 데이터 패턴 변화에 대한 적응력이 낮고, 비정형 데이터 활용이 제한적이라는 한계가 있었다.

2 세대) 머신러닝/딥러닝 기반 AI (2010 년대 중후반~2020 년대 초반)

2010 년대 중후반부터 2020 년대 초반까지 이어진 머신러닝·딥러닝 기반의 확산 기로, 금융업에 본격적으로 비정형 데이터를 다룰 수 있는 능력을 도입했다. 이 시기에는 뉴스와 소셜 데이터 분석을 통한 시장 심리(Sentiment) 측정, 개인화된 투자자문(Robo-Advisor), 이상거래 탐지(AML) 및 챗봇 기반 고객 응대 등 다양한 영역으로 활용이 확대하며 금융업무 전반의 효율화를 이끌었다. **예측 정확도는 크게 향상되었으나, 모델의 블랙박스 특성으로 인해 설명 가능성이 낮고, 전략적 의사결정보다는 개별 태스크 중심의 활용에 머물렀다.**

3 세대) Agentic AI 초기 도입기 (2023 년~현재)

2023 년 이후 급격히 주목받고 있는 Agentic AI 단계이다. 대규모 언어모델(LLM)을 기반으로 한 이 세대의 AI 는 도구 활용(Tool Use), 기억(Memory), 계획(Planning), 자기반성(Reflection) 기능을 결합하여 단순 예측을 넘어 목표 지향적 실행까지 가능케 한다. 금융업에서는 맞춤형 포트폴리오를 설계·운용하는 Direct Indexing, 규제 변화 추적 및 내부통제 자동화, 투자은행(IB)의 밸류에이션 및 딜 소싱 지원, 고객 맞춤형 PB(Personal Banker) 서비스 등으로 확장되고 있다. LLM 기반의 AI Agent 가 도입되고 있으며, 단순한 답변을 넘어 도구 실행, 데이터 검색, 다단계 의사결정까지 수행하며 리서치, 규제 모니터링, 고객 맞춤형 투자자문 등에서 활용 가능성이 확인되고 있다.

다만, 이러한 AI Agent 는 여전히 보조적, 준자율적 수준에 머물러 있으며, 완전한 의미의 Agentic AI(목표설정 - 계획 - 실행 - 피드백)는 파일럿으로 적용 중인 수준이다.

금융 산업 내 Digital Transformation → AI Transformation

프론트(Front)-미들(Middle)-백(Back) 오피스의 변화

어려웠던 백테스팅,
(과거 데이터 분석)
이제는 AI가 다해준다.

지난 10 여 년간 금융업의 화두는 디지털 트랜스포메이션이었다. 채널 디지털화, 비대면 거래, 클라우드 인프라 전환 등이 주요 의제였다. 이러한 디지털 인프라가 일정 수준 갖추어진 지금, 산업의 다음 단계 화두는 AI 트랜스포메이션, 즉 AX이다.

금융산업은 특히 생성형 AI 도입을 통해 가장 혁신적으로 변화할 수 있는 잠재력이 큰 산업이다. 프레시던스 리서치에 따르면 글로벌 금융시장에서 생성형 AI의 시장규모는 23년 약 12억 달러에서 2032년 약 112억 달러로 10배 가량 급성장할 것으로 전망된다. 맥킨지는 산업 중에서도 금융이 생성형 AI로 인해 가장 큰 기회를 얻을 것으로 보고 있다.

금융 내에서 본격적으로 디지털 트랜스포메이션이 부상했던 시기는 2015년 부터였다. 핀테크의 급부상 했으며, 글로벌 빅테크(구글, 애플, 텐센트, 알리페이)가 금융으로 진출했다. 국내에서는 2015년, 금융위원회에서 핀테크 육성 정책 발표가 있고 2년간 약 175개 핀테크사들이 출범했다. 2017년에는 카카오뱅크, 2019년 네이버파이낸셜, 2020년에는 토스증권, 2021년 토스뱅크가 잇따라 출범했다. 주로 챗봇 기반의 고객센터 기능과 RPA(Robotic Process Automation)로 백오피스 자동화가 있었다.

디지털 트랜스포메이션은 금융권에서 가장 적극적으로 이루어진 혁신 중 하나였다. 적극적이었던 배경에는 크게 3가지가 있다.



1) 비대면 채널 확대

- 모바일 뱅킹, 인터넷 뱅킹 확산으로 고객의 금융 접점이 오프라인에서 온라인, 모바일로 이동
- 은행 앱, 모바일 투자 플랫폼(증권사 MTS), 보험사 디지털 창구 등 “비대면 채널” 강화

2) 비용 효율성 압박

- 지점 운영비 절감, 인력 효율화 필요 → RPA(로봇 프로세스 자동화)·백오피스 자동화를 활발히 도입
- 예시) 단순 송금 및 계좌개설 → 비대면 인증, 비대면 계좌개설 변경

3) 핀테크와 경쟁 압력

- 토스, 카카오뱅크, 네이버파이낸셜 같은 신흥 금융플랫폼이 빠르게 성장 → 기존 금융 기관이 DT를 적극적으로 추진할 수 밖에 없음

이런 이유로 금융산업 내 DT(Digital Transformation)는 빠르게 추진되었으며 금융지주사마다 CDO(Chief Digital Officer)를 임명하며 “전략적, 선언적” 용어로 DT가 자주 언급되었다. 현재는 DT의 연장선상에서 AI Transformation이 추진되고 있다.

금융 산업 내 AI Transformation은 프론트(Front)-미들(Middle)-백(Back) 오피스 전반적으로 이루어지고 있는데, 프론트 오피스에서는 초 개인화된 고객 서비스와 AI 기반 PB가 등장하고 있으며, 미들 오피스에서는 리서치, 리스크 관리, 상품 설계에 AI Agent가 도입되고 있다. 즉, AI는 고객 경험 개선 - 리스크 관리 고도화 - 운영 효율화라는 세 축을 중심으로 금융 산업 전반을 변화시키고 있다.

1) Front Office: AI PB, 고객 상담, 초개인화 서비스

프론트 오피스에서의 AI 적용은 주로 고객 접점과 영업 지원에 집중된다. AI PB(Private Banker), 챗봇 기반 상담, 투자 성향 진단, 초개인화 추천 등이 대표적이다. 이 영역의 핵심은 '응대 품질'과 '개인화 수준'이며, AI는 양자 모두에 기여할 수 있다.

2) Middle Office: 리서치, 리스크 관리, 상품 설계

미들 오피스는 리서치, 리스크 관리, 상품 설계 등이 포함되며, 모두 데이터 분석과 문서 작성이 핵심 업무이다. Agentic AI의 워크플로우 자동화 특성이 가장 잘 발휘될 수 있는 영역이다.

리서치에서는 데이터 수집·분석·리포트 작성의 자동화가 진행되고 있다. 리스크 관리에서는 시나리오 분석, 익스포저 점검, 한도 모니터링의 자동화가 가능하다. 상품 설계에서는 시장 데이터 분석, 백테스트, 시뮬레이션을 결합한 의사결정 지원이 가능하다.

3) Back Office: 컴플라이언스, 내부통제, 문서 자동화

백 오피스에서의 AI 적용은 반복적·규정적 업무의 자동화에 집중된다. 컴플라이언스 점검, 내부 통제 보고, 정형 문서 작성, 거래 사후 점검 등이 대표적이다. 이 영역은 규정 준수의 일관성과 처리 속도 향상이 핵심 효과로 기대된다.

특히 정형 보고서, 규정 위반 점검, 내부 회의록 정리 등에서의 자동화는 비용 절감 효과가 명확하다. 다만 자동화 산출물의 정합성을 보장하기 위한 검증 절차가 필수적이며, 산출물에 대한 책임소재 정의가 함께 필요하다.

AI를 통한 금융산업 내 변화

		현시점 예상 생산성		High	Medium	Low
		Front Office (고객, 영업마케팅, 상품 등)		Middle Office (리스크, 컴플라이언스)		Back Office (계약관리, 심사, 운영 등)
		A) AI-Powered Customer Service (고객 경험 혁신)		B) AI-Powered Insight & Action (인사이트 및 실행)		C) AI-Powered Compliance (리스크 관리, 컴플라이언스 준수)
						D) AI-Powered Operational Efficiency (운영 최적화)
활용 사례	AI 챗봇, 가상비서	AI 기반 신용평가	이상거래탐지(FDS)		AI 기반 심사(대출, 언더라이팅 등)	
	AI 컨택 센터	AI 기반 상품 개발	자금세탁방지(AML)		AI 기반 디지털 결산	
	신원인식(얼굴, 음성)	AI 알고리즘 트레이딩	AI 기반 품질관리(불완전판매 등)		지능형 서류 관리(계약관리 등)	
	초개인화 서비스	지능형 예측	AI 기반 리스크 관리(운영/시장/신용)		합성 데이터	
동인 요소 / 기술	생성형, 대화형 AI	시장 동향, 투자 기회 분석	실시간 모니터링	리스크 관리 자동화	자동 신용 확인	예측 모델링
	추천 알고리즘	포트폴리오 리밸런싱	거래/행동 분석	컴플라이언스 준수 간소화	자동 대출/심사 승인	AI OCR
	거래완료	고객데이터 분석	올바른 고객 평가 강화	이벤트 식별, 이상 감지		고객 세그멘테이션
	고객여정분석	시장 변동성 예측				이벤트 식별, 이상 감지

자료: 유진투자증권

해외 및 국내 사례

미국은 생성형 AI 중심으로 3 세대, 국내는 2 세대 도입이 주류

망분리 이슈가
금융권의 AI 도입을 저해

해외 금융권에서는 이미 UBS, HSBC, Citi 등 주요 기관이 AI Agent 기반 시스템을 파일럿 또는 상용화하는 사례가 증가하고 있다. 반면 국내 금융기관은 아직 챗봇, AI 기반 소비 분석(데이터분석) 등 제한적인 2 세대 AI 활용에 머무르고 있으며, 완전한 AI Agent 도입은 규제, 내부통제, 책임소재 등의 이유로 매우 초기 단계에 그치고 있다.


글로벌 금융권은 이미 AI 를 광범위하게 도입해, 2025 년 기준 글로벌 은행의 약 92%가 최소 하나 이상의 핵심 업무에 AI 를 적용하고 있다. [ABA Banking Journal — Majority of financial institutions deploying generative AI \(2025\)](#)

반면 국내 금융권의 AI 활용률은 2024 년 기준 51% 수준(은행권은 38.1%)에 그쳐 여전히 격차가 있다. [대한상공회의소·KDI — 금융권 AI 활용현황과 정책개선과제 조사](#)

국내 금융사들이 뒤처진 데는 높은 수준의 보안 규제가 영향을 미쳤는데, 특히 정보 유출·해킹을 막기 위해 2014년부터 실시해 온 '망분리 규제'가 AI 활성화의 발목을 잡았다.

2024 년 8 월 금융당국은 '금융분야 망분리 개선 로드맵'을 통해 낡은 규제를 개선했고, 금융사의 생성형 AI 활용이 허용됐다. 이후 생성형 AI 활용이 활발해져, NH 투자증권은 2024 년 9 월 금융권 최초로 생성형 AI의 이미지 인식 기능을 활용한 차트 분석 서비스 '차분이'(GPT-4o 기반)를 출시했고, KB 증권은 'AI 금융코치' 등 생성형 AI 서비스 7 건을 금융위 혁신금융서비스로 지정받았다.

국내외 AI 도입률 격차




자료: 유진투자증권

국내: 대한상공회의소, 금융권 AI 활용현황과 정책개선과제 조사(2024)

해외: ABA Banking Journal — Majority of financial institutions deploying generative AI (2025)

금융사의 AI 활용 필요성과 활용도



자료: 유진투자증권, 대한상공회의소, 금융권 AI 활용현황과 정책개선과제 조사(2024)

해외 금융권 생성형 AI 적용 대표 사례)

AI 도구 사용은 보편적
Agentic AI로 나아가는 중

1) JPMorgan Chase - LLM Suite

- 사내 개발 전사 생성형 AI 플랫폼, 2024 년 여름 출시
- 8 개월 만에 23 만 명 이상 온보딩, 다중 모델 보안 환경
- 2025 년 기술투자 180 억 달러의 핵심 축

2) Goldman Sachs - AI Assistant

- 직원 약 1 만 명에 사내 AI 어시스턴트 배포
- 이메일·코드 작업 등 지원
- OpenAI·Google Gemini·Meta Llama 를 과업별로 활용

3) Morgan Stanley - AI Assistant

- OpenAI와 협업한 생성형 AI 어시스턴트
- 약 1.6 만 명 자산관리 어드바이저의 정보 접근 지원

4) Bank of America - Erica

- 고객용 가상비서 'Erica' 누적 32 억+ 상호작용, 2 천만 고객
- 직원용 Erica 사용률 90%이상, IT 문의 50% 이상 감소
- 약 20 만 직원 AI 도구 사용, 주 150 만 이상 프롬프트 사용

5) Citi Bank - AI Assistant

- 사내 지식비서 'Citi Assist', 문서분석 'Citi Stylus'
- Stylus Workspaces 에 에이전트형(agententic) AI 탑재
- 코딩비서 'Citi Squad' 22 만 건 자동 코드리뷰(2025 1 분기)

6) Wells Fargo - Fargo

- 'AI-first' 전략으로 전환
- Google 대화형 AI 기반 가상비서 'Fargo' 운영

7) HSBC - C-suite AI 직책

- 600 건 이상 AI 프로젝트를 전사 적용
- 직원 85%가 생성형 AI 도구에 접근
- 사기탐지·여신 등 50 개 프로세스 재설계 추진

8) UBS - 생성형 AI 도입

- 생성형·에이전트형 AI를 업무 전반에 도입
- 실제 배포에서 비용 절감(20~40%) 효과 보고

국내 금융권 생성형 AI 적용 대표 사례)

AI 도구의 회사 차원 도입
미비한 상황

1) 신한은행 - AI 투자메이트, AI ONE

- 은행권 최초 투자정보 제공 AI 'AI 투자메이트'를 SOL뱅크에 탑재
- 직원 업무비서 플랫폼 'AI ONE'에 40여 개 업무 지원 기능
- 캐릭터 '신한프렌즈' 제작에도 생성형 AI 활용

2) KB 국민은행 - KB Gen AI 포털- 리브 넥스트 AI 금융비서

- 그룹 공동 생성형 AI 플랫폼 'KB Gen AI 포털' 구축
- KB-GPT, KB AI Translator 등 사내 업무 효율화
- PB·RM 등 상담직원의 57%가 AI 활용

3) 하나은행 - 기업 하이챗봇 · 업무 자동화

- 자체 NLP 엔진 기반 기업고객 상담 챗봇
- 대출 계약서 분석·요약 체크리스트 자동 생성

4) 우리은행 - 우리 WON 뱅킹 AI 상담

- 앱 내 AI 상담 서비스로 상품 가입 권유
- 대출 상담까지 응대 영역 확대 추진

5) NH투자증권 - 차분이(차트분석 AI, 2024년 9월)

- 금융권 최초 생성형 AI 이미지 인식 기반 차트 분석
- 매매전략·가격패턴·거래량·기술적지표 해설, 지지·저항 안내

6) KB증권 - AI 금융코치 · AI 트레이딩코치 · WM Assistant

- 생성형 AI 서비스 7건이 금융위 혁신금융서비스로 지정 (2024.12)
- 맞춤형 투자 의사결정 지원 및 개인화 전략시뮬레이션
- 클라우드 통해 GPT-4 등 외부 모델을 내부망과 연계

7) 미래에셋증권 - AI 이슈체크

- 미국 증시 장중 $\pm 2\%$ 이상 변동 종목 자동 선별
- 공시·이벤트 발생 종목의 해외 뉴스 요약 제공

8) 삼성증권 - 삼성퀀트, 상담 어드바이저 지원

- '나만의 AI 추천', '삼성퀀트' 등 종목 리포트 제공
- 생성형 AI 기반 상담 어드바이저 지원 기능

금융 산업이 AI 시대에 준비해야 할 조건

AI 리터러시 인재 확보 & 기존 인력의 업스킬링 필수

AI 업스킬링 금융 산업의 AI 전환은 단순한 기술 도입을 넘어 조직 역량과 인적 자원의 구조적 변화를 요구한다. 특히 금융은 규제산업이자 신뢰가 핵심인 산업으로, 기술적 가능성이 곧바로 사업 적용으로 이어지지 않는다. 따라서 AI 시대에 금융사가 경쟁력을 유지하기 위해서는 ① AI 리터러시를 갖춘 신인재 확보, ② 기존 인력의 재교육 및 업스킬링이라는 두 가지 조건이 필수적이다.

우선, AI 리터러시를 갖춘 인재 확보가 필요하다. 금융업 특유의 규제, 리스크 관리, 상품 설계와 같은 전문적 맥락에서 AI 를 실제로 응용할 수 있으려면 데이터 과학·머신러닝 기술과 금융 도메인 지식이 융합된 인재가 요구된다. 단순히 모델을 구축하는 수준을 넘어, 금융 규제 준수, 설명가능성(XAI), 윤리적 책임까지 고려할 수 있는 '금융 특화 AI 전문가'가 확보되어야 한다. 글로벌 선진 금융사들은 이미 내부 AI 센터를 설립하고, 엔지니어와 금융 전문가가 협업하는 조직 문화를 조성하며, 학계·산업계와 연계한 인재 파이프라인을 적극적으로 확충하고 있다.

동시에, 기존 금융 인력의 업스킬링도 병행되어야 한다. 전통적 리서치 애널리스트, 리스크 매니저, 리테일 금융 상담 인력 등은 AI 도구를 업무에 적극 활용할 수 있어야 하며, 이를 위해 조직 차원의 교육 프로그램과 재훈련 체계가 필요하다. 단순 반복 업무를 대체하는 AI 자동화가 확대될수록, 인간 인력은 고부가가치 분석, 고객 신뢰 구축, 전략적 의사결정 지원에 집중하도록 역할이 재편될 것이다. 이를 가능하게 하기 위해서는 사내 직원들이 AI 툴을 이해하고, 결과를 해석하며, 필요한 경우 의사결정을 교정할 수 있는 역량을 길러야 한다.

결국, AI 시대 금융사의 경쟁력은 단순히 첨단 기술을 빠르게 도입하는 속도에 달려 있지 않다. AI 리터러시를 갖춘 신규 인재와 기존 인력의 업스킬링을 균형 있게 추진하는 인적 기반 전략이 뒷받침될 때, 금융 산업은 AI를 통해 고객 신뢰를 유지하면서도 효율성과 혁신을 동시에 달성할 수 있을 것이다.



VI. 퀀트 리서치의 재구성 (AX 활용 실무편)

Harnessing: 퀀트 리서치의 Agentic 설계 원리

Harnessing의 개념

AI 사피엔스
도구의 사용 능력이
핵심

‘Harness’는 본래 ‘마구를 채우다·동력을 끌어다 쓰다’의 의미로, 풍력·수력 등 자연의 원시 에너지를 특정 목적에 맞게 전환·활용하는 행위를 가리킨다. AI 맥락에서 Harnessing은 LLM과 Agent의 원시 능력을 그대로 사용하는 것이 아니라, 업무 목적에 부합하도록 범위를 정의하고, 출력 구조를 설계하며, 검증 체계를 결합하여 실질적 가치로 전환하는 설계 원리를 의미한다.

이 개념은 단순한 ‘활용(usage)’과 구분된다. 활용은 ‘있는 도구를 쓰는 것’이고, Harnessing은 ‘도구의 능력을 특정 방향으로 끌어내는 설계’이다. 동일한 LLM을 사용하더라도, Harnessing의 수준에 따라 산출물의 일관성·신뢰성·재현성이 본질적으로 달라진다. AX 시대의 분석가에게 Harnessing은 단순 도구 사용자에서 워크플로우 설계자로 진화하기 위한 핵심 개념이다.

Harnessing의 4가지 구성요소

차원	설계 대상	구체적 수단	AX 적용 예시
범위 (Scope)	모델이 다룰 작업, 데이터의 경계	시스템 프롬프트, 도구 권한, 컨텍스트 범위, 접근 가능한 데이터 소스 제한	특정 산업·기관·데이터 소스로 한정해 응답 범위 통제
구조 (Structure)	입력·출력의 형식과 스키마	JSON 스키마, 출력 템플릿, Few-shot 예시, 표준 보고서 포맷	분석 결과(output)를 표준 표·리포트 형식으로 강제
검증 (Verification)	산출물의 정합성 점검 기준	자동 체크, Reflection, Reviewer Agent, 규칙 기반 검토, Human-in-the-loop 승인	수치 일관성, 단위, 출처 명시, 논리 오류 여부 점검
맥락 (Context)	의사결정에 필요한 배경 정보	RAG, Memory, 도메인 지식 주입, 과거 결과물·정책 문서 연결	과거 리포트, 내부 정책, 시장 레짐 관련 데이터

자료: 유진투자증권

데이터의 중요성: 금융업에서 가장 중요한 가치는 '신뢰'

모든 것의 선행과제는
결국, 데이터

AX의 성패는 모델·도구가 아닌 '쓸 수 있는 데이터'에서 결정된다. '흩어진 데이터 + 생성형 AI = 여전히 못 꺼냄'이며, '정리된 DB + 생성형 AI = 누구나 셀프 분석'이다. 데이터 정리는 AX의 옵션이 아니라 선행과제이며, 분석가가 가장 먼저 인식하고 기여해야 하는 영역이다.

모든 AX의 선행 과제, 데이터

AX 도입의 가장 흔한 실패 패턴은 '모델·도구부터 도입'이다. Frontier LLM을 도입하고 Agent 프레임워크를 구축해도, 정작 모델이 '읽을 수 있는 데이터'가 정리되어 있지 않으면 시스템은 작동하지 않는다. 이는 마치 고성능 자동차에 휘발유가 없는 상태와 같다. AX의 동인 중 모델·인프라·도구는 외부에서 도입 가능하지만, '데이터'는 조직 내부에서 정리되어야 하며 이는 시간과 인력이 가장 많이 소요되는 영역이다.

본 리포트 Part I에서 정리한 AX의 4대 동인 중 '데이터'가 약한 고리일 경우, 다른 3개 동인이 아무리 갖춰져도 AX는 표면적 도입에 그친다. 즉 데이터 정리는 AX의 '기반 인프라'이며, 이것이 갖춰지지 않은 상태에서의 AI 도입은 비용만 늘리고 가치를 만들지 못한다. 분석가가 AX의 본질을 이해한다면, 모델·도구 논의보다 먼저 '우리 데이터는 쓸 수 있는 상태인가'를 물어야 한다.

금융권 데이터의 종류

구분	데이터 유형	주요 예시	AX 활용 관점
1	고객 데이터	고객 기본정보, 투자성향, 거래성향, 상담 이력, 민원 이력	고객 세분화, 개인화 추천, 상담 고도화, 이탈 예측
2	거래 데이터	매매내역, 입출금, 주문/체결, 카드 사용내역, 대출 실행 내역	이상거래 탐지, 수익성 분석, 행동 패턴 분석, 실시간 모니터링
3	계좌 데이터	예수금, 잔고, 포지션, 담보, 계좌 상태	리스크 관리, 자산현황 분석, 고객 맞춤 자산관리
4	상품 데이터	예금, 대출, 펀드, 보험, 파생상품, 랩어카운트 정보	상품 추천, 비교 설명, 조건 자동 응답, 판매 지원
5	리서치시장 데이터	주가, 금리, 환율, 원자재, 거시지표, 기업 실적, 컨센서스	리서치 자동화, 투자 아이디어 탐색, 요약분석, 시나리오 작성
6	재무회계 데이터	재무제표, 손익, 비용, 예산, 자금 흐름, 결산 자료	재무 분석, 이상치 탐지, 보고서 자동화, 예측 모델링
7	신용-리스크 데이터	신용등급, 연체정보, 부도확률, 익스포저, 스트레스 테스트 결과	신용평가, 여신심사, 포트폴리오 리스크 관리
8	컴플라이언스 데이터	AML, FDS, 내부통제 로그, 승인 이력, 감사 기록	이상행위 탐지, 규정 준수 모니터링, 사후 감사 대응
9	문서 데이터	리포트, 계약서, 약관, 투자설명서, 회의록, 이메일, 공문	문서 검색, 요약, 질의응답, 지식 추출, 내부 RAG 구축
10	상담-음성 데이터	콜센터 녹취, 상담 스크립트, 채팅 로그, VOC	상담 품질 분석, 불만 유형 분류, 응대 자동화, 세일즈 인사이트
11	운영 데이터	업무 처리 로그, 승인 프로세스, 처리 시간, 오류 이력	병목 분석, 업무 자동화, 운영 효율화, HPL 설계
12	외부 대체 데이터	뉴스, 공시, SNS, 웹 데이터, 위치/유통/산업 데이터	투자심리 분석, 이벤트 감지, 경쟁사 모니터링
13	지식-규정 데이터	사내 규정, 매뉴얼, 업무지침, 심사 기준, 투자 가이드라인	내부 지식검색, 정책 질의응답, 업무 보조 Agent
14	메타데이터	데이터 정의서, 컬럼 사전, 생성 주기, 소유 부서, 품질 정보	데이터 탐색성 향상, Agent의 정확한 조화-해석 지원

자료: 유진투자증권

흩어진 데이터 + AI 모델 = 쓸모 없음

대부분의 금융기관·기업에는 이미 방대한 데이터가 존재한다. 퀀트 리서치 환경만 보더라도 KRX·Quantwise·FnGuide·Bloomberg·Refinitiv 등 외부 데이터, 그리고 섹터별 담당 RA가 보유한 엑셀 파일, 내부 시스템의 거래·잔고 데이터 등 데이터의 양 자체는 부족하지 않다. 문제는 '양'이 아니라 '꺼낼 수 있는 형태'이다.

구체적으로 다음 세 가지 문제가 동시에 발생한다.

첫째, 데이터의 위치를 모름; 어떤 데이터가 어디에 있는지 파악부터 필요하다. 둘째, 담당자에게 의존; 매번 사람에게 파일을 요청하고 대기하는 구조이다. 셋째, 수작업 반복; 받은 파일을 직접 정리하고 차트를 그리는 데 20~40분이 소요된다. 이러한 상태에서는 생성형 AI를 추가해도 '꺼낼 대상' 자체가 정의되어 있지 않아 효과가 발생하지 않는다.

리서치 및 시장 데이터 source

데이터 source 유형	해외	국내	확보 가능한 데이터
공사·기업 제출자료	SEC EDGAR(무료)	DART, 거래소 공시(무료)	사업보고서, 10-K/10-Q, 실적자료
시세·시장데이터 플랫폼	Bloomberg, Factset, Refinitiv, Infomax(유료)	Quantwise, FnGuide, 증권사 HTS API(유료)	주가, 금리, 환율, 채권, 멀티애셋 시세, 기초 지표
재무·펀더멘털 데이터	Bloomberg(유료)	Quantwise, FnGuide(유료)	재무제표, 밸류에이션 배수, 세그먼트 데이터, 추정치
컨센서스·애널리스트 추정치	Bloomberg(유료)	Quantwise, FnGuide(유료)	매출/이익 컨센서스, 목표주가, 리비전 흐름
뉴스·실시간 이벤트	구글 뉴스 크롤링(무료)	네이버 뉴스 크롤링(무료)	속보, 기업 이벤트, 정책 뉴스, 산업 동향
거시경제 데이터		ECOS API(무료)	금리, 물가, 실업률, GDP, 통화·재정 지표
대체데이터	RavenPack, YipitData, Thinknum, Similarweb	Google, telegram 등	웹 트래픽, 소비 데이터, 뉴스 감성, 비정형 웹 데이터
내부 리서치 축적 데이터	과거 리포트, 모델 파일, 템플릿, 회의록, 내부 DB		하우스 뷰, 과거 추정, 커버리지 이력, 내부 논리

자료: 유진투자증권

DB 가 없다면, AI 도입 전 DB 구축부터

데이터 정리의 3 대축: DB 화, 카탈로그, Semantic Layer

데이터 정리는 세 가지 축으로 구성된다. 첫째, DB 화는 흩어진 엑셀·로컬 파일을 조회 가능한 데이터베이스로 통합하는 작업이다. 이는 분석가가 '파일을 찾는 시간'을 '질문을 만드는 시간'으로 전환하는 출발점이다. 둘째, 카탈로그(Data Catalog)는 어떤 데이터가 어디에 있고 누가 관리하며 어떤 형식인지를 체계적으로 정리한 메타데이터이다. RAG 검색의 대상이 되어 '환율 데이터 어디 있어?'와 같은 질문에 자동 응답할 수 있게 한다.

셋째, 용어 정의 통일(Semantic Layer)은 영업이익·PER·EPS 등 핵심 지표의 정의를 단일 출처로 고정하는 작업이다. 동일 지표가 파일·부서·시점에 따라 다르게 계산되면 리포트 간 수치 불일치가 발생하며, 이는 자동화의 신뢰성을 근본적으로 훼손한다. 이 3 축이 갖춰진 상태에서야 비로소 '자연어 한 문장 → 검증된 결과'의 워크플로우가 가능해진다

DB 구축 예시(Postgre SQL 사용)

Supabase SQL Table Indexing Example

primary key (id) create index idx_events_ticker on events(ticker) create index idx_events_sector_date on events(sector, event_date desc)

events | 12 columns x 6 rows

#	id	kind	ticker	name	sector	event_date	price	volume	status	created_at	updated_at	idx
1	191	action	013570	다와이	농림	2026-07-01	12.450	82,100	active	now0	now0	ticker
2	192	action	208400	베노티엘알	유상종자	2026-07-01	3.280	241,900	active	now0	now0	sector
3	193	action	263050	유틸렉스	상장폐지	2026-07-02	8.910	55,300	watch	now0	now0	date
4	194	action	010400	우진아이엔에스	가사주	2026-07-02	5.760	31,400	active	now0	now0	ticker
5	195	action	092230	KPX홀딩스	배달	2026-07-03	61.200	9,870	closed	now0	now0	compound

자료: 유진투자증권

DB 관리 방법론

DB 설계의 원칙: Discoverability, Consistency, Safety

데이터 관리에는
사람이 필요(HITL)
Human In The Loop

분석가가 SQL 없이도 자연어로 데이터를 조회할 수 있게 하는 DB 는 다음 3 대 요소로 설계된다. 첫째, 발견성(Discoverability) — 어떤 데이터가 있는지 찾을 수 있어야 한다(Data Catalog). 둘째, 일관성(Consistency) — 같은 지표가 항상 같은 값을 의미해야 한다(Semantic Layer). 셋째, 안전성(Safety) — 조회는 가능하되 수정·삭제·반출은 통제되어야 한다(Read-only DB + 권한 + 로그). 이 3 대 요소는 동시에 갖춰져야 의미가 있다.

이 설계는 자연어 질의 워크플로우의 전체 구조와 직결된다. '자연어 질문 → RAG 검색(카탈로그) → Semantic Layer(정의) → Text-to-SQL → MCP/DB 연결 → Read-only DB → 결과 검증'의 흐름에서, 각 단계는 위 3 대 요소의 구체적 구현이다. DB 관리는 단순 IT 작업이 아니라 이 워크플로우 전체의 토대를 설계하는 작업이다.

Data Catalog: 데이터의 위치·정의·제공처를 RAG 로 검색 가능하게

Data Catalog 는 '어떤 데이터가, 어디에, 어떤 형식으로, 누구의 관리 아래 있는가'를 체계적으로 정리한 메타데이터 저장소이다. 잘 설계된 Catalog 는 RAG 의 검색 대상이 되어, 분석가의 '환율 데이터 어디 있어?'와 같은 질문에 자동으로 응답한다. Catalog 의 핵심 구성요소는 다음과 같다. (a) 데이터셋의 명칭·설명, (b) 출처·제공처(KRX/Quantivise/Bloomberg 등), (c) 갱신 주기·기준일, (d) 컬럼 정의·단위, (e) 관리 담당자·권한 범위.

Catalog 가 없으면 '데이터를 찾는 데 30 분, 분석에 5 분'의 비효율이 발생한다. Catalog 가 RAG 와 결합되면 이 비율이 역전되어 '찾는 데 5 초, 분석에 집중'이 가능해진다. 이는 단순한 효율화가 아닌, 분석가의 시간 배분 자체를 바꾸는 변화이다.

Data Catalog 예시

데이터셋	제공처	분류	업데이트 주기	최종 업데이트	접근
 기업 연간 재무제표 대중 영업이익·순이익·재무비율	FnGuide	재무	분기	2024.12.31	가능
 실적 컨센서스 목표주가·EPS 추정치·투자리전	DataGuide	컨센서스	월	오늘 08:30	가능
 일별 추가-거래대금 시가총가·거래량·시가총액	KRX	시장·시세	일	오늘 16:00	가능
 거시경제 지표 (ECOS) 금리·환율·물가·통화량	한국은행	거시지표	일	오늘 09:00	가능
 전자공시 (DART) 종가·우시공시·물문·재무	금융감독원	공시	실시간	방금 전	가능
 글로벌 시세 (Refinitiv) 해외주식·원자재·채주	Refinitiv	글로벌	일	2024.12.30	요청 필요

자료: 유진투자증권


Semantic Layer: 영업이익/ PER/ EPS

Semantic Layer 는 핵심 지표의 '정의'를 시스템 차원에서 고정하는 계층이다. 예컨대 '영업이익'이 IFRS 기준인지 K-GAAP 기준인지, 'PER'이 잠정실적 기준인지 직전 12 개월 기준인지가 Semantic Layer 에서 단일하게 정의된다. 이 계층이 없으면 동일 지표가 파일·부서·시점에 따라 다르게 계산되고, 그 결과 '같은 회사의 PER 이 두 리포트에서 다른 값'이 되는 일관성 문제가 발생한다.

Semantic Layer 의 가치는 LLM 환경에서 극대화된다. LLM 이 자연어 질문을 SQL 로 변환할 때, '영업이익'이라는 단어가 어떤 컬럼·계산식에 매핑될지를 Semantic Layer 가 결정한다. 이 매핑이 단일하게 고정되어 있으면 동일 질문은 항상 동일 결과를 반환한다. 이는 '프롬프트의 자유도'에 따른 결과 변동을 차단하는 핵심 인프라이다.

Semantic Layer 예시

자연어 질문 → 지표 정의 고정 → SQL 매핑 → 일관된 결과



예시 해석: "PER"라는 같은 단어가 입력되더라도, Semantic Layer가 기준 시점·산식·컬럼 매핑을 고정해 보고서·부서·시점 간 수치 불일치를 방지

자료: 유진투자증권

권한 통제와 Read-only DB

금융권 환경에서 DB 관리의 핵심 안전 원칙은 다음과 같다. 첫째, Read-only DB 계정 AI Agent 가 사용하는 DB 계정은 SELECT 만 가능하도록 권한이 제한된다. 데이터의 변경·삭제는 원천적으로 차단된다. 둘째, 사용자별 테이블·컬럼 권한 및 직무·부서별로 접근 가능한 데이터 범위가 분리된다. 셋째, 고객·계좌 데이터의 범위 제외 망분리·개인정보 보호 등 규제 요건이 강한 데이터는 DB 화 대상에서 제외하여 범위 확대를 사전 차단한다.

DB 안전 통제 장치

통제 장치	주요 내용	기대 효과
Read-only DB 계정	AI Agent가 사용하는 DB 계정은 SELECT 권한만 보유하며, INSERT, UPDATE, DELETE 와 같은 변경 권한은 부여하지 않음	데이터 변경·삭제를 원천 차단하여 무결성 훼손 위험 방지
사용자별 권한 분리	사용자별로 조회 가능한 테이블과 컬럼 권한을 다르게 설정함	업무상 필요한 범위 내에서만 데이터 접근 허용
직무·부서별 접근 통제	직무와 부서에 따라 열람 가능한 데이터 범위를 구분함	최소권한 원칙 적용 및 내부 정보 노출 최소화
민감 정보 사전 제외	고객정보, 계좌정보, 개인정보 등 규제 민감 데이터는 DB 화 또는 AI 조회 대상 범위에서 제외함	규제 위반 가능성을 사전에 차단
규제 요건 반영	망분리, 개인정보보호, 내부통제 기준 등을 데이터 제공 범위 설계에 반영함	금융권 보안 및 컴플라이언스 요구사항 충족
결과 반환 통제	권한 정책을 통과한 승인 범위 내 데이터만 조회·반환함	안전한 조회 환경 유지 및 감사 가능성 확보

자료: 유진투자증권

실제 리서치센터 자연어 SQL 데모 페이지(클릭 시 접근 가능)

SQL 없이 묻는 리서치 데이터

무엇이 궁금하세요?

평소 말하듯 질문하면 표와 차트로 답합니다. 데이터 찾는 시간 **평균 32분 → 8초**

🔍 시가총액 상위 10개 종목

DRAM-NAND 가격 추이를 라인차트로 그려줘 | 코스피 지수-밸류에이션 추이 | 삼성전자 영업이익 추정치 추이 | 시가총액 상위 10개 종목 | 2026년 YTD 수익률 상위 10개

상세 차트보기 | **대문** | 포팅 | 반 물록 | 오픈

어떻게 이해했어요
 시가총액 상위 10개 종목을 시종-업종과 함께 보여줍니다. (단위: 조원)

10건 - 시가총액 상위

📄 Excel 다운로드

📊 표 1. 시가총액 상위 10개 종목

#	종목명	업종	시가총액(조원)
1	SK하이닉스	반도체	1,821.0
2	삼성전자	반도체	1,812.3
3	SK스퀘어	반도체	241.7
4	삼성전기	IT하드웨어	148.6
5	한미투자	자동차	104.6
6	삼성생명	보험	85.0

도표 1. 시가총액 비교

막대 라인 로그 이미지

(단위: 1,000)
 1,821 1,812
 242 148 106 85 84.7 73.8 61.7 58.9

저장된 쿼리

자주 쓰는 질문을 저장해 두고, 클릭 한 번으로 다시 실행하세요.

DRAM-NAND 가격 추이

"DRAM-NAND 가격 추이를 라인차트로 그려줘"

오늘 실행 - 82회

실행 편집

코스피 지수-밸류에이션

"코스피 지수-밸류에이션 추이"

어제 실행 - 34회

실행 편집

삼성전자 영업이익 추정치

"삼성전자 영업이익 추정치 추이"

3일 전 실행 - 21회

실행 편집

시가총액 상위 10

"시가총액 상위 10개 종목"

오늘 실행 - 63회

실행 편집

2026 YTD 수익률 상위 10

"2026년 YTD 수익률 상위 10개"

1주 전 실행 - 18회

실행 편집

조회 결과 화면에서
저장을 누르면 여기에 모입니다

다운로드 내역

조회 결과를 내려받은 파일 기록입니다. 동일 파일을 다시 받을 수 있어요.

🔍 파일명 검색

전체 형식 최근 30일

파일명	형식	다운로드 일시	크기	상태	
시가총액_상위10.xlsx	Excel	방금 전	12 KB	완료	다시 받기
DRAM_NAND_가격추이.csv	CSV	오늘 11:24	38 KB	완료	다시 받기
삼성전자_영업이익추정_차트.png	이미지	어제 17:02	—	완료	다시 받기
2026_YTD수익률_상위10.xlsx	Excel	어제 09:51	11 KB	완료	다시 받기
코스피_지수밸류에이션.csv	CSV	2일 전	96 KB	완료	다시 받기

데이터 코파일럿, 이렇게 씁니다

질문부터 차트까지 단 5단계. SQL이나 테이블 이름을 몰라도 평소 말하듯 질문하면 됩니다.

1

질문 입력

2

AI 의도 해석

3

SQL 자동 생성

4

결과 Excel

5

차트 자동 생성

1

질문 입력

상단 검색창에 평소 말하듯 질문을 적고 **조회**를 누릅니다. SQL이나 테이블 이름을 몰라도 됩니다.

Q

2024년 반도체 영업이익 상위 5개사

조회

?

팁 · 기간 · 대상 · 지표 · 정렬 기준 · 원하는 형태(표/차트)를 한 문장에 담을수록 결과가 정확해집니다.

2

AI 의도 해석

실행 전에 무엇을 **조회할지** 한 문장으로 확인시켜 줍니다. 의도가 다른면 바로 수정할 수 있습니다.

?

이렇게 이해했어요. / 2024년 반도체 업종에서 영업이익 상위 5개 기업

영업이익을 기준으로 바꿔줘

10개사로 늘려줘

?

팁 · "영업이익을 기준으로 바꿔줘", "10개사로 늘려줘"처럼 **조건을 구체해서** 반영할 수 있습니다.

3

SQL 자동 생성

AI는 **읽기 전용(SELECT)** 쿼리만 생성하며, 실행된 SQL을 인제른 필처 직접 검증할 수 있습니다.

SELECT company_name, operating_profit FROM financials WHERE sector = '반도체' AND year = 2024 ORDER BY operating_profit DESC LIMIT 5;

?

신뢰 포인트 · 리포트에 들어갈 수치이므로, 생성된 쿼리를 **할상 노출**에 애널리스트가 직접 검증할 수 있도록 설계했습니다.

4

결과 확인 · Excel 다운로드

필요한 컬럼이 자동 선택되어 표로 정리됩니다. 우측 상단 **Excel 다운로드**로 .xlsx 파일을 저장하세요.

기업명	영업이익(조원)	영업이익률
삼성전자	35.2	11.7%
SK하이닉스	23.5	35.5%

Excel 다운로드

5

차트 자동 생성

표와 동시에 차트가 만들어지고, **데이터 성격에 맞는 차트 유형**만 활성화됩니다.

순위 데이터 → 막대 · 표

시계열 데이터 → 라인 · 영역

권한 관리

사용자별 데이터 접근 권한입니다.

모든 조회는 기본 읽기 전용입니다

데이터 변경(추가·수정·삭제) 권한은 어떤 역할에도 부여되지 않습니다. 권한 밖 데이터셋은 조회 결과에서 자동 마스킹됩니다.

사용자	직책	역할	접근 가능 데이터	권한 수준
유진 유진 애널리스트 research@eugene.com	책임연구원	애널리스트	재무 컨센서스 시장 시세 거시	읽기 전용
김원 김원 퀀트 quant@eugene.com	수석연구원	퀀트	전체 데이터셋	읽기 전용
박매 박매 나지 pnm@eugene.com	운용역	운용역	시장 시세 컨센서스 글로벌	읽기 전용
이인 이인 번 intern@eugene.com	리서치 인턴	제한	재무 공시	읽기 전용

권한 변경은 리서치센터 데이터 관리자에게 요청하세요. 모든 조회 이력은 감사 로그에 기록됩니다.

프롬프트 설계: 자연어 질의의 원리

좋은 프롬프트가
똑똑한 AI를 키운다.

프롬프트는 흔히 'AI에게 말을 거는 입력'으로 단순화되지만, 실제로는 LLM의 출력을 '원하는 방향으로 끌어내는 설계 행위'이다. 동일한 질문이라도 프롬프트의 구조에 따라 결과의 깊이·형식·정확성이 본질적으로 달라진다. 본 Part VI에서 다룬 Harnessing의 '구조(Structure) 차원'이 곧 프롬프트 설계의 영역이다.

실무 환경에서 프롬프트를 단발 입력으로 사용하면 두 가지 문제가 발생한다. 첫째는 일관성 결여, 같은 분석가가 같은 작업을 매번 다르게 요청하여 결과가 흔들린다. 두번째 재현 불가, 좋은 결과를 만든 프롬프트가 기록되지 않아 다음에 다시 만들 수 없다. 이 두 문제는 프롬프트를 '템플릿화·자산화'함으로써 해결된다.

좋은 프롬프트의 4 요소

1. 의도



무엇을 수행할지 명확히 정의

2. 맥락



기간·대상·기준을 구체화

3. 구조



표·차트·컬럼·순서를 지정

4. 검증



출처·기준시점·검증 절차를 포함

자료: 유진투자증권

프롬프트 기법: Zero-shot · Few-shot · Chain-of-Thought

프롬프트 기법은 크게 세 유형으로 구분된다. Zero-shot 은 예시 없이 작업을 지시하는 방식이며, 단순·정형 작업에 적합하다. Few-shot 은 1~5 개의 예시를 함께 제공하여 출력 패턴을 학습시키는 방식이며, 출력 형식의 일관성이 중요한 작업에 적합하다. Chain-of-Thought(CoT)는 '단계별로 생각해 보라' 등의 지시로 다단계 추론을 유도하는 방식이며, 복잡 분석·검증 작업에 적합하다.

퀀트 리서치 환경에서 권장되는 조합은 다음과 같다. 데이터 조화·정형 표 생성에는 Few-shot 이 가장 안정적이다. 팩터 해석·시장 코멘트 작성에는 CoT 가 깊이를 더한다. 단순 분류·요약은 Zero-shot 으로 충분하다. 단일 기법만 고집하기보다, 작업 성격에 맞춰 조합하는 것이 효과적이다.

프롬프트 기법

 Role (역할) 어떤 역할과 관점으로 답할지 지정 전문가 관점 설정	 Context (맥락) 기간·대상·기준·배경을 구체화 세부 조건 및 환경 제공
 Task (작업) 수행할 작업과 산출 목적을 명확화 구체적 과업 정의	 Format (형식) 표·차트·컬럼·문체·순서를 고정 산출물 구조 및 스타일 지정
보조 기법 (Supporting Techniques)	
 Zero-shot: 추가 예시 없이 즉시 답변 유도	 Few-shot: 소수의 예시를 제공하여 답변 유도
 CoT (Chain-of-Thought): 사고 과정을 단계별로 유도	

자료: 유진투자증권

프롬프트 실패 패턴과 디버깅

프롬프트가 의도한 결과를 만들지 못하는 실패 패턴은 다음 다섯 가지로 정리된다.

- 1) 모호한 의도: 무엇을 원하는지 자체가 불명확.
- 2) 맥락의 부재: 기준·전제가 명시되지 않아 AI가 일반 응답으로 추정.
- 3) 출력 형식 미정의: 결과 형식이 매번 달라져 후속 작업이 어려움
- 4) 과도한 자유도: "알아서 좋은 분석해줘"식 지시로 결과 통제 불가
- 5) 검증 부재: 결과의 정확성을 확인할 기준이 없어 환각이 통과.

디버깅의 기본은 '4 요소 점검'이다. 의도·맥락·구조·검증 기준 중 어느 요소가 누락·약화되었는지를 식별하고 보완한다. 또한 '실패한 프롬프트와 그 원인'을 라이브러리에 함께 기록함으로써, 조직 차원의 프롬프트 역량이 축적된다. 프롬프트는 조직의 자산이며, 그 자산화의 출발점은 실패의 체계적 기록이다.

결론적으로 프롬프트 설계는 AX 시대 분석가의 핵심 역량이다. 모델·도구를 사용하는 AI 사피엔스의 능력이 평준화 되더라도, 같은 도구에서 더 좋은 결과를 만드는 차이가 곧 프롬프트 설계 역량에서 발생한다고 볼 수 있다.

프롬프트 실패 예시

실패 패턴	누락 요소	실패 프롬프트 (X)	개선 프롬프트 (O)
① 모호한 의도	의도	"반도체 좀 분석해줘"	"2024년 국내 반도체 5개사의 영업이익률 추이를 분석하고, 개선·악화 요인을 3줄로 요약해줘"
② 맥락의 부재	맥락	"이 종목 저평가야?"	"삼성전자 현재 PER-PBR을 최근 5년 밴드 및 SK하이닉스 대비로 비교해 저평가 여부를 판단해줘"
③ 출력 형식 미정의	구조	"실적 좀 정리해줘"	"중목명·매출·영업이익·YoY를 표로만 출력하고 부연 설명은 생략해줘"
④ 과도한 자유도	의도·구조	"알아서 좋은 포트폴리오 분석해줘"	"제시한 10개 종목만 대상으로 최근 3년 샵지수 상위 5개를 선정하고, 선정 이유를 각 1줄로 써줘"
⑤ 검증 부재	검증	"이 종목들로 리포트 써줘"	"각 수치 옆에 출처(데이터셋·기간)와 계산식을 함께 표기해 검증 가능하게 작성해줘"

자료: 유진투자증권

Agentic Quant Architecture

프롬프트 보다 중요한
Architecturing

앞서 살펴보았듯 금융업의 AX 는 프론트·미들·백오피스 전반에 걸쳐 확산되고 있다. 1 세대 Rule-based AI, 2 세대 머신러닝·딥러닝 기반 예측 모델을 거쳐 3 세대 생성형 AI·AI Agent 에 이른 흐름이 이제 4 세대 ‘Agentic AX 단계’로 이동하고 있다. 특히 퀀트 리서치는 데이터·업무 표준화 수준이 높고 산출물의 정형성·반복성이 강하다는 점에서 Agentic Workflow 와 자연스럽게 정합한다.

자율형 퀀트 리서치 시스템은 데이터·검증·팩터·백테스트·리스크·리포트·컴플라이언스 Agent 와 Human-in-the-loop 으로 구성된다. 각 Agent 는 명확한 역할과 권한을 가지며, 단계별 산출물은 표준 포맷으로 다음 Agent 에 전달된다.

Agentic Quant Architecture

Agent	역할	주요 도구	산출물	HTML 여부
Data	데이터 수집	DART, KRX, 뉴스 API	표준 데이터셋	예외 시
Validation	데이터 정합성 점검	스키마 검증, 통계 점검	검증 로그	예외 시
Factor	팩터 계산·평가	팩터 라이브러리	팩터 시계열	신규 채택 시
Backtest	전략 검증	백테스트 엔진	성과·민감도 결과	주요 전략 채택 시
Risk	리스크 모니터링	리스크 지표 라이브러리	리스크 리포트	임계치 도달 시
Report	리포트 작성	템플릿, 시각화 도구	리포트 초안	발간 전 필수
Compliance	규정 점검	정책 DB, 규정 룰	로그 점검	예외 시

자료: 유진투자증권

1) Data Agent: 가격, 재무, 공시, 뉴스 데이터 수집

Data Agent 는 가격, 거래량, 재무, 공시, 뉴스 등 다양한 데이터를 정해진 스케줄과 트리거에 따라 수집한다. 각 소스별로 별도의 도구 호출 정책을 가지며, 수집된 데이터는 표준 포맷으로 변환되어 후속 Agent 에 전달된다.

데이터 소스의 다양성과 갱신 빈도는 Data Agent 설계의 핵심 변수이다. 가격 데이터는 일간·일중, 재무 데이터는 분기, 공시는 비정기, 뉴스는 실시간 등 갱신 패턴이 다르며, 이를 통합 관리하는 구조가 필요하다.

2) Validation Agent: 결측치·이상치 등 데이터 검증

Validation Agent 는 수집된 데이터의 정합성을 점검하는 역할을 수행한다. 결측치, 이상치, 종목코드 변경, 단위 불일치, 시점 차이 등을 자동으로 점검하고, 문제 발견 시 사용자 또는 다른 Agent 에 알린다.

이 단계는 자동화 워크플로우의 가장 중요한 안전장치이다. 데이터 결함이 후속 Agent 에 전달될 경우, 모든 후속 결과가 왜곡될 수 있기 때문이다. 검증 로직은 정형 규칙과 통계적 이상 탐지가 결합된 형태로 설계된다.

3) Factor Agent: 팩터 계산과 성과 분석

Factor Agent 는 표준 팩터의 계산, 신규 팩터 후보의 평가, 팩터별 성과 분석을 수행한다. 가치·모멘텀·퀄리티·로우볼·사이즈 등 전통 팩터부터, 도메인 특화 팩터, 텍스트 기반 팩터까지 다양한 영역을 포괄할 수 있다.

Factor Agent 의 결과는 후속 Backtest Agent 와 Report Agent 에 전달된다. 결과 표준화와 메타데이터 관리가 중요하며, 각 팩터의 정의, 계산 방식, 데이터 원도우, 점검 일자 등이 함께 기록된다.

4) Backtest Agent: 전략 검증과 민감도 분석

Backtest Agent 는 팩터 또는 전략의 과거 성과를 시뮬레이션한다. 리밸런싱 주기, 거래비용, 유동성 제약, 벤치마크 설정 등의 옵션을 자동 적용할 수 있으며, 다양한 시나리오에서의 민감도 분석을 함께 수행한다.

또한 백테스트의 편향 점검을 워크플로우에 내장한다. 룩어헤드 편향, 생존 편향, 거래비용 과소 추정 등 흔한 오류 유형을 점검하는 체크리스트가 표준 작업의 일부로 수행된다.

5) Risk Agent: Drawdown, VaR, Exposure, Crowding 점검

Risk Agent 는 포트폴리오 또는 전략의 리스크 지표를 점검한다. 누적 손실, 최대 낙폭(MDD), VaR, 섹터팩터 익스포저, 군집(crowding) 지표 등이 주요 점검 대상이다. 한도 초과나 이상 패턴 발견 시 알림을 발송한다.

Risk Agent 는 다른 Agent 와 달리 '지속적 모니터링'이 핵심이다. 일회성 실행이 아닌, 정해진 주기와 트리거에 따라 반복적으로 작동하며, 임계치 도달 시 즉시 알림이 발생하도록 설계된다.

6) Report Agent: 차트, 표, 코멘트 자동 생성


Report Agent 는 앞 단계 Agent 들의 결과를 종합하여 리포트 초안을 작성한다. 차트와 표는 자동 생성되며, 코멘트는 템플릿과 LLM 생성 결과가 결합된 형태로 작성된다. 최종 발간 전에는 반드시 Human-in-the-loop 단계가 배치된다.

리포트 자동화의 핵심은 '템플릿의 표준화'와 '코멘트 가이드라인의 명확화'이다. 표준 양식과 톤 가이드가 잘 정의되어 있을수록 자동 생성 결과의 일관성이 높아진다.

7) Compliance Agent: 출처, 고지문, 내부통제 점검

Compliance Agent 는 산출물의 규정 준수 여부를 점검한다. 출처 표시, 위험 고지문 포함, 권유성 표현 점검, 내부 정책 부합 여부 등이 점검 대상이다. 이 단계는 자동화된 리포트가 외부로 배포되기 전 필수적으로 수행되어야 한다.

퀀트 리서치 7 개 Agent Workflow



자료: 유진투자증권

MCP의 개념과 적절한 사용 방법

MCP의 개념

MCP: MCP는 LLM 또는 AI Agent가 외부 시스템(파일·DB·API·메신저·사내 도구 등)과 통신할 때 사용하는 표준 프로토콜이다. 종전에는 도구별로 별도의 통합 코드를 작성해야 했다면, MCP는 'Agent ↔ MCP Client ↔ MCP Server ↔ 외부 시스템'의 표준 인터페이스를 통해 동일한 방식의 호출을 가능하게 한다. USB가 디바이스 연결을 표준화한 것과 유사한 의미로 평가된다.

MCP의 가치는 두 가지이다. 첫째, '인터페이스 표준화'로 도구의 추가·교체·결합이 용이해진다. 둘째, '책임의 분리'로 Agent는 외부 시스템의 세부 사양을 알 필요가 없고, 외부 시스템 변경은 MCP Server 수준에서 처리된다. 이는 운영·유지 보수 부담을 크게 경감한다.

MCP가 '만능'은 아니다

MCP의 부상 이후 '모든 도구 통합은 MCP로'라는 인식이 일부에서 형성되고 있으나, 실무 관점에서는 신중한 적용이 필요하다. MCP는 '반복 호출·재사용성이 높은 외부 시스템 연결'에 최적화된 도구이며, 모든 통합 시나리오에 적합한 것은 아니다. 일회성 작업, 단순 파일 처리, 내장 도구로 충분한 작업까지 MCP화하는 것은 오히려 복잡도만 증가시킬 수 있다.

MCP 예시

1 시장·기업 데이터    정형 재무·기업·공시 데이터를 표준 인터페이스로 연결  예: 실적, 밸류에이션, 컨센서스 조회	2 브로커리지·계좌·주문  계좌 정보, 포지션, 주문 실행을 안전한 규칙 아래 연결  예: 잔고 확인, 주문 생성·검증, 체결 상태 조회
3 리스크·신용 분석   신용도·리스크 데이터를 공통 방식으로 호출  예: 거래처 위험도 점검, 신용등급 조회	4 PE·딜 소싱  딜·투자·기업 관계 데이터를 워크플로우에 통합  예: 비교기업 탐색, 투자 라운드·M&A 이력 조회
5 회계·재무 시스템  회계 시스템을 에이전트와 분리된 인터페이스로 연결  예: 전표·청구·현금흐름 데이터 질의	6 대체데이터·웹 수집    웹 크롤링·검색 도구를 재사용 가능한 MCP 도구로 표준화  예: 웹페이지 수집, 경쟁사 정보 검색, 비정형 데이터 확보

자료: 유진투자증권

MCP 적용이 적합한 영역

구분	적용 대상	AX 적용 예시
사내 지식 문서 시스템 연동	문서관리시스템, 사내 위키, 정책 DB, 규정 문서	사내 규정 조회, 리서치 문서 검색, 내부 정책 Q&A
정형 데이터 DB 조회	SQL DB, 데이터 웨어하우스, 시계열 DB, CRM/ERP	매출 조회, 재고 확인, 퀀트 데이터 질의, 고객 이력 조회
외부 API 업무 시스템 호출	시장 데이터 API, 회계 시스템, 결제/정산 API, 티켓 시스템	시세 조회, 공시 수집, 회계 처리 요청, 티켓 생성
협업-메신저-업무 툴 연결	Slack, Teams, Gmail, Notion, Jira, Confluence	알림 발송, 회의록 저장, 이슈 등록, 문서 업데이트
멀티플 워크플로우 연결	여러 내부-외부 시스템을 순차 호출하는 업무 흐름	"자료 검색 → 분석 → 보고서 저장 → 메신저 공유" 자동화
권한-감사 추적 중요한 업무	승인 체계가 필요한 시스템, 접근 로그가 필요한 업무	컴플라이언스 조회, 승인형 워크플로우, 민감 데이터 접근 기록

자료: 유진투자증권

MCP 적용이 적합하지 않은 영역

구분	적용 대상	비효율적인 이유	예시
일회성 작업	한 번만 수행하는 임시 스크립트, 단발성 파일 변환	서버를 따로 만들고 관리하는 비용이 더 큼	단일 CSV 변환, 1 회성 데이터 추출
단순 파일 처리	로컬 파일 읽기-쓰기, 간단한 포맷 변환	내장 도구나 직접 처리만으로 충분한 경우가 많음	텍스트 정리, PDF 병합, 이미지 리사이즈
내장 도구로 충분한 작업	검색, 계산, 단순 브라우징, 기본 요약	MCP 없이도 기존 도구로 해결 가능	간단 계산, 웹페이지 요약, 단순 문서 정리
초단순-저복잡 호출	로직이 거의 없는 단일 API 연결	오히려 MCP 계층이 복잡도를 추가할 수 있음	단일 날씨 API 호출, 단일 환율 조회

자료: 유진투자증권

퀀트 리서치에서 MCP 적용 영역

퀀트 리서치 환경에서 MCP 적용이 가장 적합한 영역은 다음과 같다. (a) 정형 데이터 소스 연결(DART, KRX, 사내 DB), (b) 리포트 배포 채널(Slack, Telegram, 이메일), (c) 코드·버전 관리(GitHub), (d) 일정·작업 관리 시스템. 이들은 모두 반복적·다중 워크플로우에서 사용되며, 인터페이스가 비교적 안정적이라는 공통점을 갖는다.

반면 MCP 화가 적절하지 않은 영역은 일회성 데이터 가공, 단발성 시뮬레이션 등이다. 이러한 영역은 LLM 의 내장 도구(코드 실행, 파일 시스템 접근)로 처리하는 것이 더 효율적이다. MCP 적용은 '반복성·재사용성'의 임계점을 넘은 시점부터 고려하는 것이 권장된다.

퀀트 리서치 MCP Server 구성도



자료: 유진투자증권

Claude Code · Codex · Grok Build 비교

세 도구의 컨셉

바이브 코딩의 필수템

세 도구는 모두 LLM 기반의 코드·리서치 보조 도구이지만, 본질적 위치는 다음과 같이 구분된다. Claude Code 는 로컬 코드베이스와 직접 상호작용하는 '파일·터미널 통합형' Agent 이다. Codex 는 클라우드 환경에서 코드 작업을 실행하는 '백그라운드 작업형' Agent 이다. Grok Build 는 실시간 정보·SNS 데이터에 강점을 가진 '정보 수집·이벤트 모니터링형' Agent 이다. 세 도구는 동일 카테고리 내에서 '작업 환경'과 '데이터 강점'이 분화되어 있다.


Claude Code 는 사용자의 로컬 환경(터미널·IDE·파일 시스템)과 직접 결합한다. 사용자가 진행 중인 코드를 즉시 확인하고, 단계별 결과를 검토할 수 있다는 강점이 있다. 반면 Codex 는 클라우드 환경에서 격리된 컨테이너로 작업이 실행되어, 사용자가 비동기적으로 작업을 위임하고 결과를 회수하는 방식이다. Grok Build 는 클라우드 기반이며, X(구 트위터) 등 실시간 데이터에 직접 접근 가능한 데이터 환경이 특징이다.

Claude Code · Codex · Grok Build 비교

구분	Claude Code	Codex	Grok Build
핵심 포지션	로컬 개발환경에 붙는 에이전트형 코딩 도구	로컬 CLI/앱 + 클라우드 위임을 함께 씀	터미널 중심의 코딩 에이전트 + 계획/서브에이전트/MCP 확장
대표 실행 환경	터미널/IDE/깃허브, 개발자 기존 환경 활용	로컬 CLI/앱 + 클라우드 작업 환경 병행	터미널 TUI, 헤드리스 스크립트, ACP 연동
상호작용 방식	대화형으로 목표를 주고 단계적으로 수정·검증	로컬 대화형도 가능, 클라우드에 백그라운드/병렬 위임 강점	TUI 대화형 + Plan Mode + 병렬 subagent
가장 강한 영역	코드베이스 이해, 멀티파일 수정, 테스트 /CI 수정 반복	장시간 작업 위임, 병렬 처리, PR 생성, 작업 분리	복잡 프로젝트 계획, 서브에이전트 병렬화, MCP/플러그인 확장
인간 검토 포인트	기본적으로 파일 수정/명령 실행 전 승인 중심	결과 diff/PR 검토, 클라우드 작업 후 적용	Plan 승인, 단계별 코멘트, 병렬 결과 검토
보안/통제 관점	기존 로컬 환경 활용, 인간 승인 강조	클라우드 환경 제어 가능, 인터넷 접근 정책 설정 가능	샌드박스 실행·MCP 연결 등 확장성 높지만 설계 책임도 큼
비용 관점	Claude 요금제 포함 + API는 토큰 기반	ChatGPT 플랜 포함 + 추가 크레딧 + API 토큰 기반	구독형 접근 + API 사용 시 토큰 기반


자료: 유진투자증권

Claude Code 사용환경(Visual Studio – extension 설치가 편리함)




자료: 유진투자증권

Codex 사용환경(Claude 의 cowork 기능과 비슷)



자료: 유진투자증권

Grok Build 사용환경



자료: 유진투자증권

퀀트 리서치 Agentic 재구성 방법론

Agentic 리서치의 4 단계 프레임

Workflow 부터 정렬

1 단계 진단: 자신의 업무 흐름을 분해하고, 자동화 가능 단위와 사람이 담당할 단위를 구분한다.

2 단계 도구 선택: 위 작업별로 적합한 도구를 선택하거나 조합한다.

3 단계 워크플로우 설계: 작업을 연결한 워크플로우를 정의하고, 검증-HITL 지점을 배치한다.

4 단계 운영·개선: 데이터를 바탕으로 워크플로우와 도구 선택을 점진적으로 개선한다.

이 4 단계는 일회성 도입이 아닌 지속적 순환으로 작동한다. 새로운 도구의 등장, 업무 흐름의 변화, 운영 데이터의 누적이 다음 사이클의 진단·재설계로 이어진다.

1 단계: 업무 분해와 자동화 단위 식별

퀀트 업무는 일반적으로 '아이디어 → 데이터 → 모델 → 백테스트 → 리스크 점검 → 리포트 → 발간'의 단계로 구분된다. 각 단계는 다시 '반복적 정형 작업', '조건적 분석 작업', '판단·해석 작업'으로 분해된다. 자동화에 가장 적합한 영역은 '반복적 정형 작업'이며, '조건적 분석'은 부분 자동화, '판단·해석'은 인간의 영역으로 남는다.

분해 작업의 결과는 '업무 매핑 표'의 형태로 정리하는 것이 권장된다. 각 단위 작업의 빈도, 정형성, 데이터 의존도, 검증 난이도를 함께 기록함으로써, 후속 도구 선택의 기준을 마련한다.

2 단계: 단위 작업별 도구 선택 원칙

업무별 권장 도구

업무 단위	권장 도구	선택 이유
데이터 수집 (DART·KRX·뉴스)	Claude Code + MCP	코드 통합·반복 호출·표준 인터페이스
실시간 이벤트 모니터링	Grok Build (또는 실시간 검색 API)	SNS·뉴스 실시간 데이터
데이터 정제·표준화	Claude Code	로컬 환경·즉시 검증
팩터 계산·통계 분석	Claude Code (단순) / Codex (대규모)	작업 규모에 따른 분기
백테스트 (단일)	Claude Code	단계별 검증 가능
리스크 점검	Claude Code + 사내 리스크 시스템 MCP	표준 점검 자동화
리포트 초안 작성	Frontier LLM (직접 활용)	일회성 생성에 충분
리포트 시각화·정형 작성	Claude Code + 템플릿	일관성·재현성
슬라이드 정리 (외부 발표)	Gamma 등 SaaS	디자인·협업 강점
워크플로우 자동화 (비코드)	Make 등 SaaS	비코드 환경 친화성

자료: 유진투자증권

3 단계: 워크플로우 설계의 5 가지 원칙

워크플로우 설계의 핵심 원칙은 다음과 같다. 첫째, 모듈화 — 단위 작업을 독립적으로 정의하고, 입출력 스키마를 표준화한다. 둘째, 검증의 명시화 — 각 단위 작업의 결과 검증 기준을 사전에 정의한다. 셋째, HITL 지점의 배치 — 의사결정 중요도가 높은 지점에 인간 검토 단계를 명시적으로 둔다. 넷째, 로그·재현성 확보 — 모든 호출과 결과를 기록하여 재현 가능한 상태를 유지한다. 다섯째, 예외 처리의 표준화 — 실패·예외 상황에 대한 일관된 대응 정책을 정의한다.


4 단계: 운영·개선 사이클

운영 단계에서는 다음의 모니터링이 필요하다. (a) 자동화 산출물의 품질 지표(정합성·일관성), (b) 호출 비용·지연 시간, (c) 오류 발생률과 패턴, (d) HITL 통과·반려율, (e) 사용자(분석가) 피드백. 이 지표들을 정기적으로 점검하여 워크플로우와 도구 선택을 점진적으로 개선한다.

개선의 핵심은 '프롬프트 단위'가 아닌 '워크플로우 단위'의 관점이다. 단일 프롬프트 최적화가 아닌, 워크플로우 전체의 안정성·일관성 향상이 우선되어야 한다. 도구나 모델 교체 시에도 동일한 원칙이 적용된다.

활용 단계의 점진적 확장

AI 도구 활용은 한 번에 전면 도입하기보다 점진적 확장이 효과적이다. 권장 단계는 다음과 같다.



퀀트 리서치: 통합 적용 사례

Daily Earnings Surprise Tracker

- 1) Daily Earnings Surprise
- 2) Daily Event Driven
- 3) Daily, 실시간 Telegram bot
- 4) Weekly Theme Report

Daily Earnings Surprise Tracker 는 분기·반기 실적 발표 시즌에 일자별 어닝서프라이즈 종목을 정리·배포하는 시스템이다. 공시 수집 → 핵심 수치 추출 → 컨센서스 매칭 → 서프라이즈 계산 → 정리·시각화 → 배포의 흐름이 자동 수행된다.


이 시스템의 효율성은 실적 시즌의 '정보 압축'에 있다. 다수의 공시를 일관된 포맷으로 정리함으로써, 사용자가 핵심 종목에 집중할 수 있도록 한다. 자동화의 가치는 단순 시간 절약이 아니라 '판단의 효율성 향상'에 있다.

2. Earnings Surprise Tracker

PAGE 2 / 4

OP Surprise Ranking

So what — 고려아연 +42.1%, 샘씨엔에스 +29.1%가 상위, 조이시티 -90.7%는 최하위.



오늘 발표된 장정실적 요약

발표일	종목	업종	커버리지수	배출 SP	OP SP	NP SP	ESCR	ESPR	Pre-20D	판단 코멘트
05/06	고려아연	비철금속	5	+11.2%	+42.1%	-14.6%	+42.1	+42.1	-	OP 대폭 상위, 순이익은 하위
05/06	샘씨엔에스	반도체	2	+10.9%	+29.1%	-	+29.1	+29.1	-	OP 서프라이즈, 커버리지 확인 필요
05/06	심택	전자부품	6	+3.4%	+21.3%	+2914.8%	+21.3	+21.3	-	OP 상위, 순이익 기대효과 확인
05/06	조이시티	게임	2	+6.6%	-90.7%	-99.1%	-90.7	-90.7	-	OP/NP 소크, 부정적 하향 리스크
05/06	파라다이스	레저	8	-2.1%	-31.5%	-41.7%	-31.5	-31.5	-	OP 하위, 비용 부담 확인

SP = Surprise (컨센서스 대비) · ESCR = OP SP 기준 · ESPR = OP SP 기준, OP SP - Pre-20D · Pre-20D = 실적 발표 전 20거래일 수익률(산단형 척도).

OP Surprise 근거 (실적 vs 컨센서스)

Rk	종목	OP 실적	컨센서스	SP
1	고려아연	7,461억	5,252억	+42.1%
2	샘씨엔에스	77억	60억	+29.1%
3	심택	137억	113억	+21.3%
4	파라다이스	373억	544억	-31.5%
5	조이시티	3억	34억	-90.7%

Earnings Action & Signal 기준

종목	판단	대응
고려아연	OP 대폭 상위, NP 하위	Long
샘씨엔에스	OP 서프라이즈, 커버리지 확인	Long
조이시티	OP/NP 동반 소크	Avoid
파라다이스	OP 하위, 비용 부담	Avoid

Strong Positive(OP ≥ +20%) → Long Watch · Positive(≥ +10%) → Quality Watch · Neutral(-10 ~ +10%) → 제치 가능 · Negative(≤ -10%) → Avoid.

Daily Event Driven Tracker

Daily Event Driven Tracker는 인수합병, 정책 변화, 신규 사업 진출, 주요 계약 체결 등 이벤트형 정보를 모니터링·정리하는 시스템이다. 공시, 뉴스, SNS의 정보를 결합하여 유형별로 분류하고, 영향이 클 것으로 추정되는 종목을 사용자에게 알린다.

2. Event Driven Tracker

PAGE 2 / 3

Today's Event Calendar

당일 이벤트는 갑자 증선, KOSPI200, KOSDAQ150 종목만 Tracking 함.

일정	종목	이벤트 유형	이벤트 내용	예상 영향
07/06	이템	갑자	주요사항보고서(갑자결정)	권리락/신주인수권 조건 확인
07/06	정보	갑자	주요사항보고서(갑자결정)	권리락/신주인수권 조건 확인
07/06	SK스퀘어	유상증자	주요사항보고서(유상증자결정)(자 회사의 주요경영사항)	권리락/신주인수권 조건 확인
07/06	SK하이닉스	유상증자	주요사항보고서(유상증자결정)	권리락/신주인수권 조건 확인

주석: 코스피200, 코스닥150 종목만 Tracking 함.

Event Detail · 핵심 종목

권리이벤트는 신주배정기준일/권리락 등 조건 확정 전까지 Watch 유지.

이템

Watch

Event Type	갑자
Expected Flow	Neutral / Rights Offering Check
Key Check	갑자비율과 거래정지기간 확인: 주주 가치 훼손 및 변경상황 리스크 점검

정보

Watch

Event Type	갑자
Expected Flow	Neutral / Rights Offering Check
Key Check	갑자비율과 거래정지기간 확인: 주주 가치 훼손 및 변경 상황 리스크 점검

SK스퀘어

Watch

Event Type	유상증자
Expected Flow	Neutral / Rights Offering Check
Key Check	신주배정기준일/권리락일 확인: 확정 발행가 업데이트, 신주인수권 상장 시 본주-권리 차이 검토

SK하이닉스


Watch

Event Type	유상증자
Expected Flow	Neutral / Rights Offering Check
Key Check	신주배정기준일/권리락일 확인: 확정 발행가 업데이트: 신주인수권 상장 시 본주-권리 차이 검토

Weekly Theme Rotation Monitor

Weekly Theme Rotation Monitor는 시장 내 주도 테마의 변화 흐름을 주간 단위로 정리하는 시스템이다. 가격·거래량·뉴스·공시 데이터를 결합한 다차원 지표를 산출하고, 테마별 모멘텀의 변화를 추적한다.

이 시스템의 결과는 단순 '급등 테마 리스트'가 아니다. 테마별 모멘텀의 강도·지속 기간·확산 정도 등 다양한 차원의 평가가 포함되며, 사용자는 이러한 정보를 바탕으로 시장 구조의 변화에 대한 시각을 얻을 수 있다.




2. Weekly Theme League Table

Requested fields only: 테마랭크, 1W, 1M, 관련종목수, 상승종목 수, Top5 거래대금, Top5 상승률, Breadth(대장주집중도), 외국인+기관 수급, 대표 테마 ETF

테마랭크	테마	1W	1M	관련 종목수	상승 종목 수	Top5 거래대금	Top5 상승률	Breadth (대장주집중도)	외국인+ 기관 수급	대표 테마 ETF
01	비면치료제	+8.42%	+18.3%	14	12	1,840	+26.4%	32%	+278	
02	HBM	+7.91%	+14.2%	11	9	5,240	+21.8%	28%	+712	
03	휴먼노이드	+6.85%	+13.1%	10	8	950	+19.2%	34%	+119	
04	원전SMR	+6.32%	+11.4%	13	10	2,950	+16.5%	36%	+439	
05	K-뷰티	+5.74%	+12.5%	16	12	620	+14.8%	38%	+115	
06	조선-해양	+5.21%	+10.7%	12	9	1,840	+13.6%	41%	+316	
07	방산	+4.95%	+9.8%	15	11	2,670	+13.1%	39%	+388	
08	AI Agent	+4.42%	+8.2%	9	6	490	+11.3%	44%	+114	
09	전력기기송배전	+4.18%	+7.4%	10	7	950	+10.1%	43%	+182	
10	바이오시밀러	+3.87%	+4.1%	8	5	780	+8.3%	57%	+120	
11	스테이블코인	-2.18%	-0.8%	7	3	210	-1.2%	65%	+18	
12	신재생(태양광)	-2.84%	-6.8%	10	3	730	-4.1%	79%	-118	
13	K-콘텐츠	-3.12%	-4.6%	11	4	580	-2.1%	71%	-79	
14	연세관광	-3.45%	-5.1%	9	3	410	-3.4%	74%	-74	
15	2 차전지 소재	-5.22%	-10.8%	15	3	1,840	-6.5%	82%	-306	

Breadth(대장주집중도)는 테마 수익률이 대장주에 얼마나 집중되었는지를 나타내는 예시 지표로, 수치가 낮을수록 종목 확산도가 높고 수치가 높을수록 대장주 의존도가 높다고 해석.

3. Theme Life Cycle Monitor



Classification Rule Set

Leadership

Price ≥ 70 , Volume ≥ 70 , Breadth ≥ 75 , Flow 양호

Acceleration

Price ≥ 60 , Volume ≥ 55 , News/Event 지속, Risk 과도하지 않음

Emerging

News/Event ≥ 50 이나 Price/Flow 확산은 초기

Crowded

Price·News는 상위이나 Risk ≥ 45 또는 개인/공매도 증가

Cooling

Price ≤ 35 , Volume ≤ 35 , Breadth ≤ 40 , Flow 이탈

Reversal

Price 약세이나 EPS/Event 재유입, Risk 낮음

4. News Flow Tracker

Catalyst Score 상위 10개 테마. 카테고리별 점수와 한 줄 근거를 함께 표기.

News Flow Tracker

unit: msd 2020-03-31 / Catalyst Score 상위 10개 테마. 카테고리별 점수와 한 줄 근거를 함께 표기.

AI 반도체

-2.70%

정보·공급망

Catalyst Score: 31 / 33

- 실적발표 2 Q3 실적사 손익의 8년 연속 사상 최고라는(태양로열 발표)
- 정책 5 구글의 10년치 버블론에 '혁신' 노력 열을 때 나오는 부자'
- 주주/계약 1 (가정+신) 파지니스 후회하는 + 해외의 글기
- 공급망 5 "전문의 촉박" 개편이나...전은 잘 다를 수 영향
- 규제/재직 2 PC출시와 그보다 고공행진. 2분기 최대 50% 상승
- M&A 1 (D.S. 지평선지. 최대 4분기) 6.5 자립선가제 정치 생생 전 19년...차기...
- 재용출시 3 "스피드업" 성장 후 촉박...그때 정지하, 10배 오른 600만주

원전-SMR

-4.90%

공급망·정책

Catalyst Score: 30 / 33

- 실적발표 1 (원전의 ABC) 뉴스들 "대자본 불 하한 원 동진자" 8년 전에 최악의 양국...
- 정책 3 에너지 4000억 SMR 연구개발 예산 투입설이 확정
- 주주/계약 3 폭락으로 바뀐 계약분지. 일본 원전 정책이 재조나
- 공급망 5 폭락으로 바뀐 계약분지. 일본 원전 정책이 재조나
- 규제/재직 1 관주시 1-SMR 부지 공조 미비조사 작자 불려 호소
- M&A 1 강가을 "글로벌 시장제 14년 투자 오지...청년 일자리 30만 개 창출된다"
- 재용출시 2 삼중터프터론. 코스에 성장 위한 재비상선정서 재출

K-콘텐츠

-2.83%

이재·재용출시

Catalyst Score: 30 / 33

- 실적발표 1 BTS, 1분기 182억의 불었다...세계 1위 매출 기록
- 정책 1 (재조동화) 내 월급을 만든 자를 직접...사 칸리 논쟁 커진다
- 주주/계약 4 폭락한 수출 기업으로 올라선 흥업제와도 상반관계(재조동화) 보세상선...
- 공급망 5 (D.S. 지평선) 정정 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- 재용출시 5 (V.C. Pick) 재조동화 불었다...속한 "이분제(재조동화) 3000억에 투자...

조선-해상

-10.53%

수주·정책

Catalyst Score: 30 / 33

- 실적발표 1 농협연구소, 10년 매출액 내보 거진잡기 나섰나
- 정책 3 (가리) 화이 부흥시 역화전진전진스 원에 선도지리전
- 주주/계약 5 (B.S. 지평선) 속, "이분제 부상 선한" 비전인 연후한에 "대역으로 부...
- 공급망 1 해상로적 작공 시나...한계통-공급망 불고 다시 본다
- 규제/재직 2 (인사) 1 이회승 한계통과작가승용정(재조동화) 재직, 수종도론...
- M&A 1 재계 대표 부나세(사)한대 재직 장가선-선하 부하를 잡음은 못미칠...코...
- 재용출시 1 KCC, 세계 최대 조선해상 전지회 출자...정확한 선복도로 기술력 공개

휴먼노이드

-2.31%

재용출시·수주

Catalyst Score: 30 / 33

- 실적발표 1 과보나지 적화...티 루트, 순이익도 반했다
- 정책 1 감입회 생사 뒤 전 TV토론...정당논쟁 출중
- 주주/계약 2 (DPO) 6월 IPO 시장 불호...로온 수종계약 중 5년 불화
- 공급망 3 "전문의 촉박" 개편이나...전은 잘 다를 수 영향
- M&A 1 (단위) 정타지그를 (파지니스) 해설...로론스 행보다
- 재용출시 5 (영남)구생) 내가 나하를 들 수 영남제(2.순론은 보고 해운 하들라스

HBM

-13.06%

공급망·이

Catalyst Score: 30 / 33

- 실적발표 3 "결함유지" 열매 열매 불어등 컴퓨터는 지도자 (토렌트 소독기)
- 정책 1 "사 재장" 교열과 불분명한 재원...시험대 오른 한 지 인도제 불화
- 주주/계약 2 (가정+신) 파지니스 후회하는 + 해외의 글기
- 공급망 5 "전문의 촉박" 개편이나...전은 잘 다를 수 영향
- 규제/재직 2 (D.S. 지평선) 정정 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- M&A 1 김위원 종남도지사 후회 "부채 투자유치 논론은 왜곡"...장면 반박
- 재용출시 3 "나단 삼전니스 없다" 속하는 당선, 사는 정정 재용출시

반도체

-93.86%

수주

Catalyst Score: 30 / 33

- 실적발표 1 유연타 "촉박전원" 정정된 대선후이적, 후미나(42 대타)전타가 세 선...
- 정책 3 공공 F-16C, 2064년 공병부지 정정전타(이원호의 열리타(42)를
- 주주/계약 4 KODR 한 뒤(42)나...표 재조동화(재조동화) CMIS 수종계약 출중
- 공급망 5 중용화 불화 한 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- M&A 1 후 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- 재용출시 5 "나단 삼전니스 없다" 속하는 당선, 사는 정정 재용출시

Z차전지 소재

-1.68%

실적발표

Catalyst Score: 30 / 33

- 실적발표 4 크라이 디스자공회 불었다...열리타(42)를
- 정책 1 재조동화, 재조동화 조조 부상선 도입 5년...정정된 재조동화 불화
- 주주/계약 1 보스리, 반노제 과열 해스 주진 정정...공급가 "자랑가 열중 주종제 해"
- 공급망 5 정정, 재조동화 조조 부상선 도입 5년...정정된 재조동화 불화
- 규제/재직 4 F&I투자(42)를, 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- M&A 1 국전(정정)을, 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...

K-뷰티

-4.68%

수주

Catalyst Score: 30 / 33

- 실적발표 1 마루제(42)를, 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- 정책 2 중용화, 재조동화 조조 부상선 도입 5년...정정된 재조동화 불화
- 주주/계약 5 중용화, 재조동화 조조 부상선 도입 5년...정정된 재조동화 불화
- 공급망 1 4월 부상지적 수종 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- 규제/재직 2 수종(정정)을, 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- 재용출시 2 (K.재조동화)을, 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...

스태이플코인

-3.81%

M&A·이

Catalyst Score: 30 / 33

- 실적발표 2 KPO전 CEO 정정 열리타(42)를, 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- 주주/계약 1 재조동화(42)를, 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- M&A 5 가상자산 M&A 역행 시작된다...공급망 열리타(42)를, 재조동화 "영국부대 외국 기업" vs 요새로 "정정 시장 불노" 제...
- 재용출시 3 (DPO) 6월 IPO 시장 불호...로온 수종계약 중 5년 불화

5. Weekly Breadth & Flow Summary


Flow Summary

- ✓ Leadership는 HBM, 휴머노이드로 압축되며 가격·거래대금·확산도가 모두 우세.
- ✓ 비만치료제는 Catalyst는 가장 강하지만 개인 쓸림과 리스크 점수 상승으로 Crowded
- ✓ 원전·SMR, 방산, 조선·해양은 정책·수주 드라이버에 기반한 Acceleration 구간.
- ✓ 2차전지 셀/소재는 Cooling 테마로 수익률·수급·Breadth 모두 약세.

Breadth Summary


- ✓ Leadership는 HBM, 휴머노이드로 압축되며 가격·거래대금·확산도가 모두 우세.
- ✓ 비만치료제는 Catalyst는 가장 강하지만 개인 쓸림과 리스크 점수 상승으로 Crowded
- ✓ 원전·SMR, 방산, 조선·해양은 정책·수주 드라이버에 기반한 Acceleration 구간.
- ✓ 2차전지 셀/소재는 Cooling 테마로 수익률·수급·Breadth 모두 약세.

테마별 외국인+기관 수급



자료: Quantwise, 유진투자증권

테마별 Breadth & Diffusion




자료: Quantwise, 유진투자증권

6-1. Top Theme Deep Dive — HBM

HBM Leadership +7.91% / 1M +14.2%

- ✓ 대형주와 장비주가 동시에 강해 테마 확산 구조가 견조함.
- ✓ 외국인 수급이 가장 강한 테마로 패시브/액티브 양쪽 관심이 확인됨.
- ✓ 다음 주 체크포인트는 NVIDIA 실적과 공급망 코멘트.

기관, 외국인, 개인 주간 수급



자료: Quantwise, 유진투자증권

테마 지수 3개월간 추이




자료: Quantwise, 유진투자증권

Top5 종목의 Positioning



자료: Quantwise, 유진투자증권

Top5 종목을 거래대금 기여도



자료: Quantwise, 유진투자증권

Top5 종목 / 편입 사유

종목	편입 사유	1W
SK 하이닉스	HBM3E 12 단 글로벌 점유율 선도	+20%
삼성전자	HBM 인증/패키징 중설 기대	+12%
한미반도체	TC 분더 수주 모멘텀	+18%
리노공업	HBM 테스트 소켓 확장	+15%
이오테크닉스	레이저 어닐링 채택	+13%

자동 차트와 자동 코멘트

리포트 자동화의 핵심 구성 요소는 자동 차트와 자동 코멘트이다. 자동 차트는 표준 템플릿에 따라 데이터를 시각화하며, 색상·범례·레이블의 일관성을 유지한다. 자동 코멘트는 데이터 기반의 정형 문장 + LLM 기반의 보완 문장으로 구성된다.

다만 자동 코멘트는 '맥락 해석'의 한계를 가진다. 시장 상황·정책·이벤트 맥락의 반영이 충분하지 않을 수 있으며, 이 부분은 인간의 검수와 보완이 필요하다. 자동 코멘트는 '초안'으로 활용되며, 최종 코멘트는 인간의 보완을 거친다.


Telegram 자동 배포

완성된 리포트는 Telegram, Slack 등의 채널을 통해 배포된다. MCP 기반 환경에서는 배포 자체가 자동화 워크플로우의 일부로 포함되며, 채널별 포매팅이 표준화된다.


배포 과정에는 '검수 완료 확인'이 반드시 포함된다. 인간의 승인이 없는 상태에서는 외부 배포가 차단되며, 발간 이력은 별도의 로그로 기록된다. 이는 산출물의 추적성과 책임소재의 명확화에 기여한다.

1) 잠정실적 발표(실시간, Scaling 지표: ESCR 같이 제공)

Telegram 주소: t.me/arning_surprise_ssunny_bot



2) Corporate Action (Daily, 16 가지 주요 권리 Tracking)

Telegram 주소: t.me/arning_surprise_ssunny_bot

Human Review 후 발간 프로세스



HITL 개입 규칙

예외 발생: 1, 2, 5단계 · 주요 변경: 3단계 · 자동 생성: 4단계 · 필수 검수: 6단계 · 승인 후 자동 배포: 7단계

자동화 리포트의 한계와 운영 원칙

자동화 리포트는 효율성과 일관성 측면에서 큰 가치를 제공하지만, 다음의 한계를 함께 인식해야 한다. 첫째, 정형 분석에 강하고 비정형 통찰에 약하다. 둘째, 맥락 해석의 깊이가 인간 분석가 대비 제한적이다. 셋째, 새로운 유형의 이벤트나 데이터 패턴에 대한 적응에 시간이 필요하다.

이러한 한계를 보완하는 운영 원칙은 다음과 같다. 첫째, 자동화 리포트의 산출물은 '초안'으로 활용한다. 둘째, 인간 분석가는 코멘트와 해석에 집중한다. 셋째, 데이터·시스템 변경에 대한 회귀 점검을 정기적으로 수행한다. 넷째, 자동화 산출물에 대한 사용자 피드백을 시스템 개선에 반영한다.

요컨대 자동화 리포트는 인간 분석가의 산출물을 대신하는 것이 아니라, 인간이 더 깊은 통찰에 집중할 수 있도록 정형 작업을 흡수하는 인프라이다. 이러한 분업 구조의 정착이 자율형 리서치 시스템 도입의 핵심 성공 요소가 된다.

VII. 결론

Agentic AI 는 AX 전환의 실행 계층이 된다

향후 5 년간 AX 의 변화

AI 사피언스
도구의 사용 능력이
핵심

‘Harness’는 본래 ‘마구를 채우다·동력을 끌어다 쓰다’의 의미로, 풍력·수력 등 자연의 원시 에너지를 특정 목적에 맞게 전환·활용하는 행위를 가리킨다. AI 맥락에서 Harnessing 은 LLM 과 Agent 의 원시 능력을 그대로 사용하는 것이 아니라, 업무 목적에 부합하도록 범위를 정의하고, 출력 구조를 설계하며, 검증 체계를 결합하여 실질적 가치로 전환하는 설계 원리를 의미한다.

이 개념은 단순한 ‘활용(usage)’과 구분된다. 활용은 ‘있는 도구를 쓰는 것’이고, Harnessing 은 ‘도구의 능력을 특정 방향으로 끌어내는 설계’이다. 동일한 LLM 을 사용하더라도, Harnessing 의 수준에 따라 산출물의 일관성·신뢰성·재현성이 본질적으로 달라진다. AX 시대의 분석가에게 Harnessing 은 단순 도구 사용자에서 워크플로우 설계자로 진화하기 위한 핵심 개념이다.

결국 AX 의 본질은 “AI 를 도입하는 것”이 아니라, 기업의 업무 단위를 다시 설계하는 것이다. 과거에는 사람이 시스템을 사용해 업무를 수행했다면, 앞으로는 사람이 목표와 기준을 설정하고, Agent 가 시스템을 넘나들며 실행하며, 인간이 결과를 승인하고 책임지는 구조가 확산될 것이다. 이 변화는 일부 직무의 자동화를 넘어, 조직의 운영 속도, 의사결정 방식, 고객 경험, 비용 구조를 동시에 바꾸는 산업 전반의 구조적 전환으로 이어질 가능성이 높다.

따라서 Agentic AI 는 AX 시대의 핵심 실행 인프라로 볼 수 있다. 기업의 경쟁력은 더 이상 AI 모델 자체를 보유했는지에만 달려 있지 않다. 중요한 것은 AI 를 업무 프로세스 안에 얼마나 깊게 통합하고, 인간의 판단과 조직의 통제 체계 안에서 얼마나 안정적으로 운영할 수 있는가이다. 향후 AX 의 승자는 사람을 AI 로 단순 대체하는 기업이 아니라, 사람과 Agent 가 함께 일하는 방식을 가장 먼저 재설계하는 기업이 될 것이다.

Compliance Notice

당사는 자료 작성일 기준으로 지난 3개월 간 해당종목에 대해서 유가증권 발행에 참여한 적이 없습니다

당사는 본 자료 발간일을 기준으로 해당종목의 주식을 1% 이상 보유하고 있지 않습니다

당사는 동 자료를 기관투자가 또는 제 3자에게 사전 제공한 사실이 없습니다

조사분석담당자는 자료작성일 현재 동 종목과 관련하여 재산적 이해관계가 없습니다

동 자료에 게재된 내용들은 조사분석담당자 본인의 의견을 정확하게 반영하고 있으며, 외부의 부당한 압력이나 간섭 없이 작성되었음을 확인합니다

동 자료는 당사의 저작물로서 모든 저작권은 당사에게 있습니다

동 자료는 당사의 동의 없이 어떠한 경우에도 어떠한 형태로든 복제, 배포, 전송, 변형, 대여할 수 없습니다

동 자료에 수록된 내용은 당사 리서치센터가 신뢰할 만한 자료 및 정보로부터 얻어진 것이나, 당사는 그 정확성이나 완전성을 보장할 수 없습니다. 따라서 어떠한 경우에 동 자료는 고객의 주식투자의 결과에 대한 법적 책임소재에 대한 증빙자료로 사용될 수 없습니다