

Vibe Quant가 온다

:시계열 파운데이션 모델

- 모델 설계·학습 없이 추론만으로 하는 시계열 예측이 거시·금융 변수 예측에 진입
- BIS가 거시 데이터로 미세조정된 모델 공개 – 과거 패턴 기반 시나리오 예측 가능
- 현재 예측력은 과제특화 모델에 못 미쳐 – 보조 도구로서의 잠재력에 주목

시계열 예측도 GPT처럼: Time Series Foundation Model(TSFM)

시계열 파운데이션 모델(TSFM)의 가장 큰 강점은 사용하기 쉽다는 점이다. 이는 최근 대규모 언어모델(LLM)이 연 변화와 같은 맥락에 있다. 실제로 코딩 영역에서는 별도의 프로그래밍 지식 없이도 코드를 작성하는 Vibe Coding이 등장했고 사람이 직접 코드를 짜는 양은 크게 줄었다. 언어·이미지·단백질 구조 예측에서 확인된 성과를 바탕으로, 같은 모델 구조를 시계열 예측에 옮겨 온 것이 바로 TSFM이다. 채팅과 코딩에서 GPT·Claude·Gemini를 쓰듯, 모델의 설계와 학습은 제공하는 측에 맡기고 사용자는 관련 시계열 데이터를 입력하기만 하면 된다. 그러면 모델이 사전학습 단계에서 학습한 시계열 패턴을 바탕으로 예측치를 산출한다. 기존 퀀트가 수행하던 모델 설계와 학습 과정 없이 데이터만으로 일정 수준의 시계열 예측치를 얻는 이 접근을 본 보고서는 Vibe Quant로 칭한다.

BISTRO – 매크로 데이터에 특화된 시계열 파운데이션 모델

국제결제은행(BIS)은 2026년 3월 자체 거시 데이터로 미세조정된 BISTRO를 공개했다. 이미 공개돼 있던 시계열 파운데이션 모델 Moirai를 기반으로, 63개국 약 4,900개 거시 시계열로 다시 학습시킨 모델이다. 별도의 추가 학습 없이도 2021~2022년 미국 물가 상승을 실제에 가깝게 예측했고, 유가 같은 공변량(Covariate)의 경로를 함께 입력하면 그에 반응하는 물가 경로까지 제시했다. 분석가가 물가·실업률·성장률마다 메커니즘 모델을 따로 세우지 않아도 TSFM으로 예측할 수 있음을 보인 것이다. 본 보고서에서도 BIS의 방식을 따라 최근 유가 변동을 반영해 미국 소비자물가를 예측한 결과, 2026년 하반기까지 물가 상승 압력이 이어지는 것으로 나타났다. 다만 예측력은 국가별·지표별 편차가 컸다.

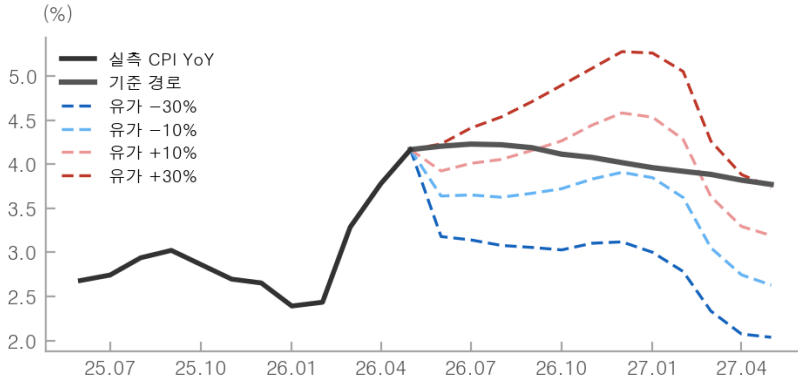
주식시장 적용 테스트 – 포트폴리오 수준에서 확인되는 예측력

오픈소스로 공개된 시계열 파운데이션 모델로는 Salesforce의 Moirai, Google의 TimesFM, Amazon의 Chronos 세 가지가 대표적이다. 이들로 국내 개별 주가와 팩터 포트폴리오를 예측해 본 결과, 개별 종목의 예측력은 낮았으나 팩터 포트폴리오에서는 일정 수준 이상의 예측력이 확인되는 경우가 있었다. 개별 종목의 변동은 그 종목 고유의 위험(Idiosyncratic Risk)이 차지하는 비중이 커서, 파운데이션 모델의 예측치를 개별 주가의 예측 지표로 쓰기는 어렵다. 그러나 고유 위험이 충분히 상쇄된 포트폴리오 수준에서는 보조 지표로 활용할 여지가 있다고 판단한다. 2026년 6월 23일까지의 팩터 수익률을 기준으로 한 현재 시점 예측에서는, 이익추정치 상황·대형주·단기 모멘텀 종목의 상대적 강세가 나타날 것으로 전망했다.

TSMF 예측 예시


시계열 파운데이션 모델(TSMF)로 산출한 거시 물가와 주식 팩터 전망의 예시이다. TSMF의 예측 방식과 예시 변수들에 대한 백테스팅 내용은 본문에 기재 하였다.

유가 충격 시나리오별 미국 물가 경로 (현재 WTI 대비)




자료: FRED, 대신증권 Research Center

TSMF를 활용한 어닝모멘텀 팩터 예측치



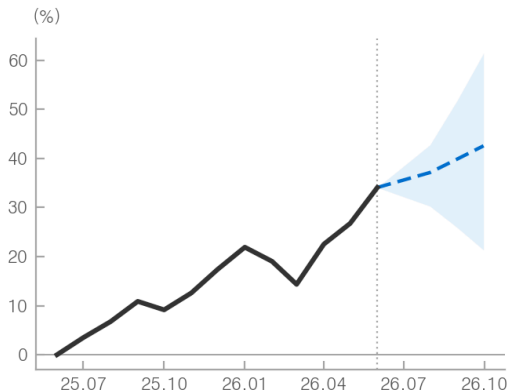
주: 1) 영업이익 추정치 상향 종목(봉) - 하향 종목(숫)으로 구성된 어닝모멘텀 팩터
2) 모델 MOIRAI 2.0
자료: 대신증권 Research Center

TSMF를 활용한 사이즈 팩터 예측치




주: 1) 시총 상위 대형주(봉) - 하위 소형주(숫)으로 구성된 사이즈 팩터
2) 모델 TimesFM
자료: 대신증권 Research Center

TSMF를 활용한 단기 모멘텀 팩터 예측치



주: 1) 직전 1개월 수익률 상위(봉) - 하위(숫)으로 구성된 단기 모멘텀 팩터
2) 모델 TimesFM
자료: 대신증권 Research Center

TSMF를 활용한 장기 모멘텀 팩터 예측치



주: 1) 직전 12개월 수익률 상위(봉) - 하위(숫)으로 구성된 장기 모멘텀 팩터
2) 모델 BISTRO
자료: 대신증권 Research Center

I. 시계열 파운데이션 모델의 성격과 이점

GPT를 쓰듯, 모델을 만들지 않고 데이터만 넣어 예측한다

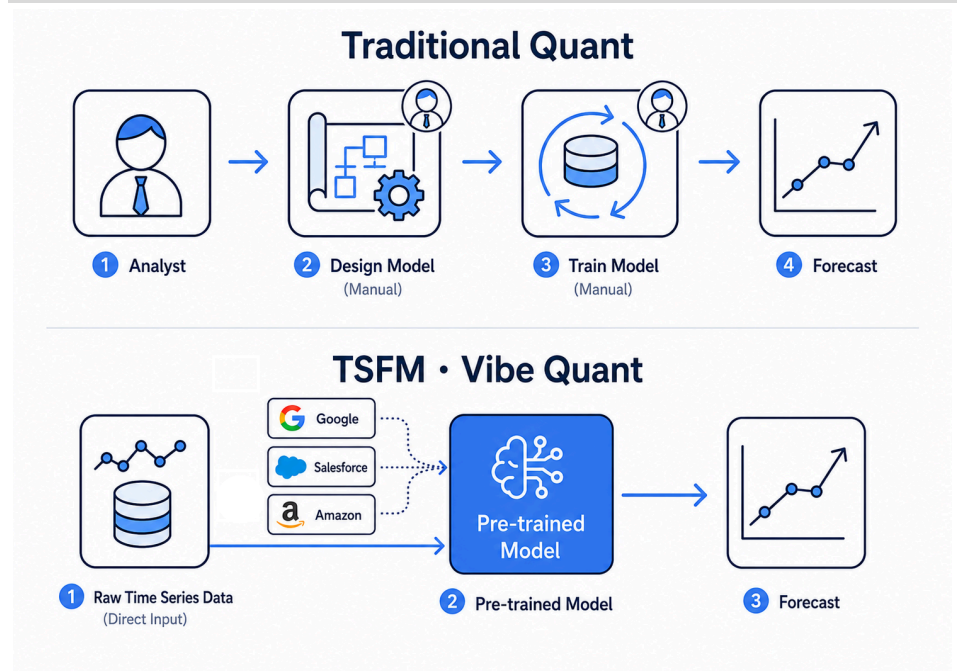
모형을 만들지 않고 데이터를 넣는다

우리가 GPT를 쓸 때, 모델 자체는 OpenAI가 설계하고 막대한 데이터로 학습시켜 만든 것이다. 사용자는 그 완성된 모델에 질문을 입력해 답을 받을 뿐, 직접 모델을 설계하거나 학습시키지 않는다. 시계열 예측에서도 같은 구도가 가능해지고 있다 - 모델은 만든 측에서 사전학습으로 완성해 두고, 사용자는 모델 구조를 짜거나 학습시키는 단계 없이 과거 시계열을 입력하면 곧바로 예측(추론)을 받는다. 본 보고서에서는 이 흐름을 **Vibe Quant**로 부른다.

전통적 방식과 견주면 차이가 분명하다. 기존에는 변수마다 모형을 구체화하고(주가 - 이자율, 이익추정치, 유동성, 상대수익률 등과 같은 관계 변수 및 메커니즘 설정) 표본으로 모수를 추정한 뒤에야 예측했다. 모델 구조와 변수 선택이 예측모형을 만드는 퀀트의 핵심 작업이었고, 대상이 바뀌면 처음부터 다시 해야 했다. 반면 파운데이션 모델은 한 번 사전학습된 가중치로 어떤 시계열이든 받아 다음 구간을 생성한다. 사용자는 모형을 고르거나 학습시키지 않고 그저 데이터를 입력한다. 이렇게 학습 단계 없이 입력만으로 예측하는 방식을 **zero-shot(제로샷)**이라 한다.

이러한 방식이 시도되고 있는 배경은 다음 세 가지로 이해할 수 있다. 첫째, 시계열을 일정 길이 구간(패치)으로 끊어 언어모델의 토큰처럼 다루는 표현 방식이 자리잡았다. 둘째, 수백억에서 수천억 개에 이르는 관측치로 사전학습할 데이터와 연산이 확보되었다. 셋째, 언어모델의 근간인 트랜스포머 디코더 스택이 시계열의 비선형 구조와 장기 의존성을 포착하는 데 효과적임이 반복 확인되었다. Google의 TimesFM이 2억 개 수준의 파라미터와 약 1,000억 개 관측치만으로 완전지도학습 모델에 근접하는 제로샷 성능을 달성한 것이 대표 근거다(Das et al., Google Research, 2024).

그림 1. 기존 퀀트와 파운데이션 모델의 예측 과정 비교



자료: 대신증권 Research Center


시나리오 예측은
상관의 재현이지
인과가 아니다

작동 원리 – 언어모델이 다음 단어를 예측하듯, 다음 시계열을 예측

작동 방식은 언어모델에 빗대면 이해하기 쉽다. 대규모 언어모델이 문장을 여러 단어로 끊어 읽고 다음 단어를 예측하듯, 시계열 파운데이션 모델(TSFM)은 과거 시계열을 일정 구간(이를테면 한 달치)씩 끊어 하나의 단어처럼 읽고 다음 구간을 이어 쓴다. TSFM만의 특징은 두 가지다. LLM 모델은 예측한 확률분포에서 표본 추출을 해 다음 단어를 뽑는다면 TSFM은 다음 값의 확률 분포 자체를 전달해 예측 불확실성에 대한 값을 반환한다, 같은 모델이 환율이든 물가든 어떤 시계열이라도 받아 같은 방식으로 다음을 이어 쓴다.


거시 분석에서 특히 중요한 기능이 조건부(시나리오) 예측이다. 일부 변수의 미래 경로를 분석가가 고정해 입력하면, 모델은 그 경로와 역사적 공동 움직임에 부합하도록 나머지 변수의 미래를 생성한다. “유가가 +9% 경로를 따른다면 물가는?”과 같은 질문에 답하는 방식이 이것이다. TSFM 중 일부 모델들(Chronos, TimesFM, BISTRO)은 미래의 공변량(Covariate)의 시나리오에 대한 예측값을 산출한다. 이를 통해 실제 유가가 물가에 미치는 경로에 대한 모델 설정과 학습 과정 없이도 합리적인 수준의 방향성을 그려볼 수 있다.

그림 2. 언어모델과 시계열 모델 비교



자료: 대신증권 Research Center

그림 3. 조건부(시나리오) 예측의 작동 방식



자료: 대신증권 Research Center

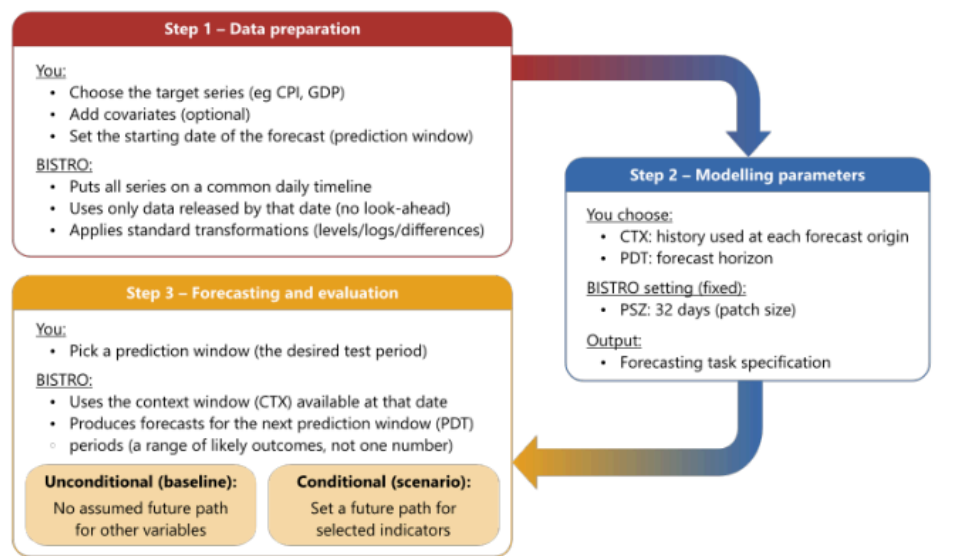
II. BIS BISTRO

매크로 변수 특화 시계열 파운데이션 모델

MOIRAI 기반 ·
63개국 거시
미세조정

BIS는 2026년 3월 BISTRO(BIS Time-series Regression Oracle)를 워킹페이퍼를 통해 공개했다. Salesforce의 MOIRAI를 기반으로, 63개국 4,925개 거시 시계열(1970~2024)로 미세조정된 모델이다. 일반적으로 거시경제 변수 각각에 대한 예측 모델을 설정하는 것이 일반적이지만, TSFM을 미세조정(파인튜닝) 할 때에는 거시경제 변수의 개별 메커니즘 구분 없이 모든 거시경제 변수를 일반적인 금융 시계열이라는 명목 하에 모델을 학습시키는 데 사용하였다. BIS는 이를 “거시 시계열을 위한 ChatGPT”로 표현했다. 국제결제은행(BIS) 같은 중앙은행 연합체가 매크로 예측에 시계열 파운데이션 모델을 적용하는 연구를 진행하고 있다는 점도 주목할 만한 흐름이다.

그림 4. BISTRO 사용 방식 - 데이터 입력부터 예측까지



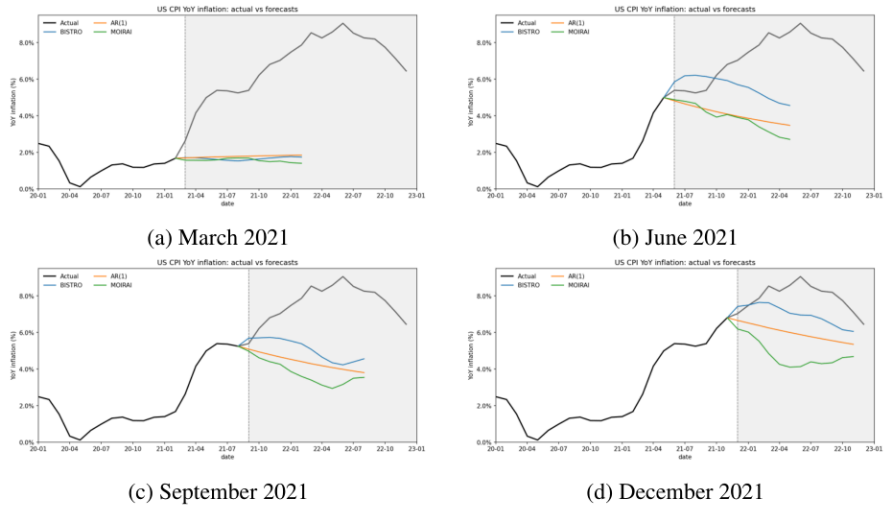
자료: BIS Working Paper No.1337(2026)

2021년 물가 급등 - 물가 상승 지속을 예측

6월 시점에서
지속적 물가 파동
예측

BIS는 2021년 3·6·9·12월 각 시점에서 미국 소비자물가를 예측시켰다(인플레이션 시계열만 입력한 단변량). 3월에는 BISTRO·MOIRAI·AR(1)(이전 값의 일정 비율이 다음 값에 영향을 준다고 가정하는 가장 단순한 모형) 모두 물가가 2% 목표표 수렴한다고 보았으나, 6월 시점에서 BISTRO만이 보다 지속적인 물가 상승 파동을 예측했다. AR(1)이 기계적으로 역사 평균으로 회귀하고 미세조정 전 MOIRAI가 더 빠른 하락을 시사한 것과 대비된다. 12월 시점에서 BISTRO는 높은 물가가 이어진다고 보아 실제 결과에 근접했다(BIS Quarterly Review, 2026).

그림 5. BIS 시연 – 2021년 미국 소비자물가 예측



자료: BIS Working Paper No.1337(2026)

단변량 예측 – AR(1) 단순 자기회귀 모델 대비 아웃퍼폼 하는 경향

미국 물가 12개월
오차가 AR(1)의
절반 수준

BIS는 모델을 서로 다른 경제 국면에서 시험했다 - 1995·2005·2015·2023년 이후를 각각 테스트 기간으로 빼어 두고, 나머지 기간으로만 학습해(미래정보 누출 차단) 한 시기에 과적합하지 않고 구조 변화에도 견디는지 보았다. 성적은 AR(1) 대비 오차 비율로 잰고, 이 값이 1보다 작으면 BISTRO가 더 정확하다는 뜻이다.

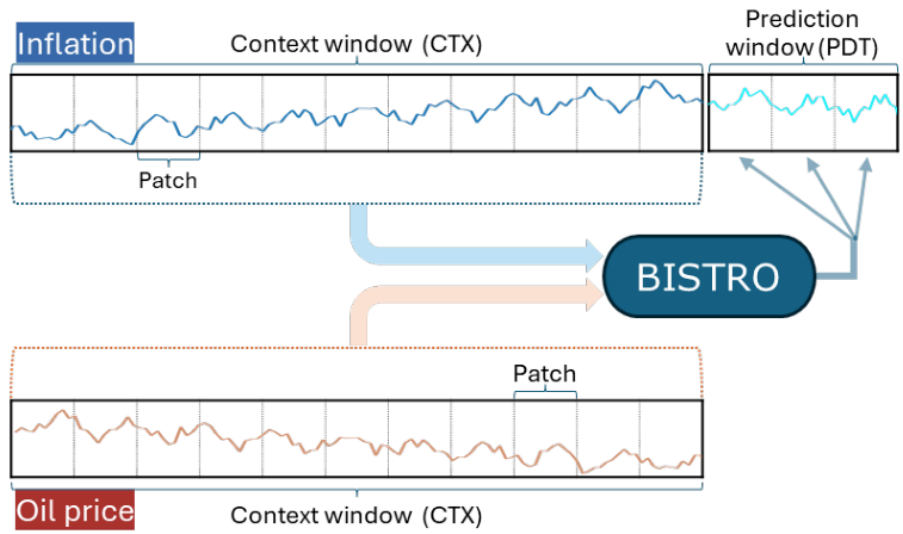
BISTRO는 물가·실업·성장에서 중기 예측까지 AR(1)을 앞섰고, 특히 미국 물가 12개월 예측에서는 오차가 AR(1)의 절반(0.481) 수준이었다. 그러나 한계도 뚜렷했다 - 12개월 장기의 실업·성장, 그리고 한 달짜리 단기 물가에서는 오히려 AR(1)에 뒤졌다. 장점과 약점이 예측 기간과 변수에 따라 갈린 셈이다.

시나리오 예측 – 유가의 비선형 영향을 포착, 통화정책은 맥락에 좌우

미세조정이
유가-물가 관계를
살려낸다

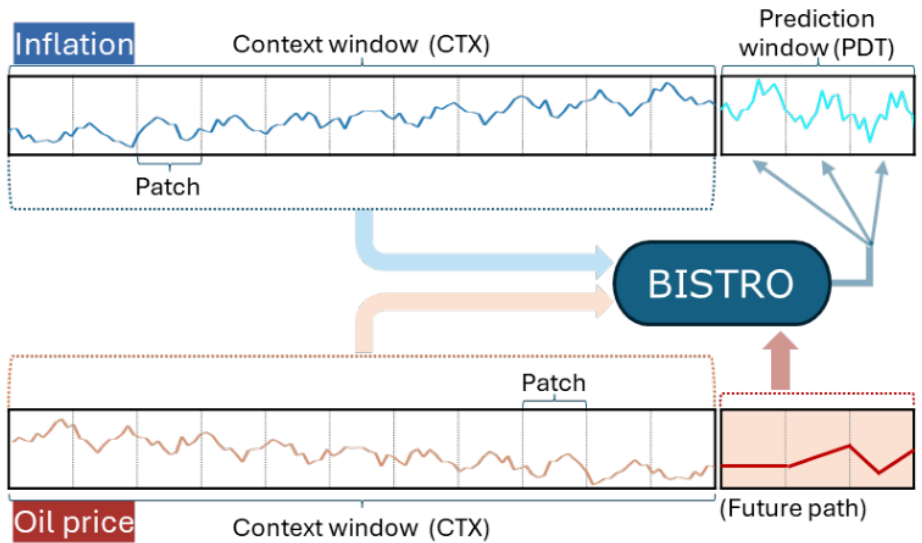
2023~2024년 구간에서 유가 경로를 -3%·+3%·+9% 세 가지로 고정한 조건부 예측에서, BISTRO는 유가 +9% 시 물가 편차가 최대 약 +0.6%p까지 비선형으로 확대되고 하방 충격의 영향은 비대칭적으로 작다는 반응을 포착했다. 반면 미세조정 전 MOIRAI는 네 시나리오에서 예측이 사실상 동일해(유가 가중치가 0에 가까움) 유가-물가 관계를 잡지 못했다 - 도메인 미세조정의 효과를 보여주는 핵심 대목이다. 반면 통화정책 추론은 맥락 창에 크게 좌우되었다. 물가 경로를 고정하고 정책금리를 예측시킬 때, 최근 12년만 맥락으로 주면 제로금리에 가까운 경로를, 37년(1986~2022)으로 넓히면 “높은 물가는 긴축을 부른다”는 관계를 추론했다 - 맥락 창 설계가 결과를 좌우한다는 점은 유연성이자 불안정성의 원천이다.

그림 6. BISTRO의 공변량 활용 - 유가를 함께 입력해 물가를 예측



자료: BIS Working Paper No.1337(2026)

그림 7. BISTRO의 시나리오 예측 - 유가 미래 경로를 고정해 물가를 예측



자료: BIS Working Paper No.1337(2026)

Ⅲ. 경제지표 - 단변량 물가 예측과 유가 시나리오

BIS의 방식을 따라 - 네 모델로 미국 물가를 예측

Chronos · TimesFM ·
Moirai · BISTRO를
두 기준선과 비교

BIS 워킹페이퍼의 방식을 따라, 미국 소비자물가(전년동기비)를 현재 시점 기준으로 예측한다. 비교 대상은 시계열 파운데이션 모델 네 가지다. Chronos(Amazon), TimesFM(Google), Moirai 2.0(Salesforce)은 각각 대형 기술기업이 공개한 범용 시계열 모델로, 이 가운데 Chronos와 TimesFM은 공변량(외생변수)을 함께 입력받을 수 있고 Moirai 2.0은 단변량만 지원한다. 여기에 BIS가 거시 데이터로 미세조정된 BISTRO를 함께 예측 모델로 테스트 하였다. 기준선으로는 직전 값을 그대로 예측값으로 산출하는 확률보행(Random Walk)과, 이전 값의 일정 비율이 다음 값에 이어진다고 보는 자기회귀 모형 AR(1) 두 가지를 둔다. 비교의 일관성을 위해 TSFM 모델마다 과거를 보는 길이(컨텍스트)는 120개 기간(10년)으로 고정하였다.

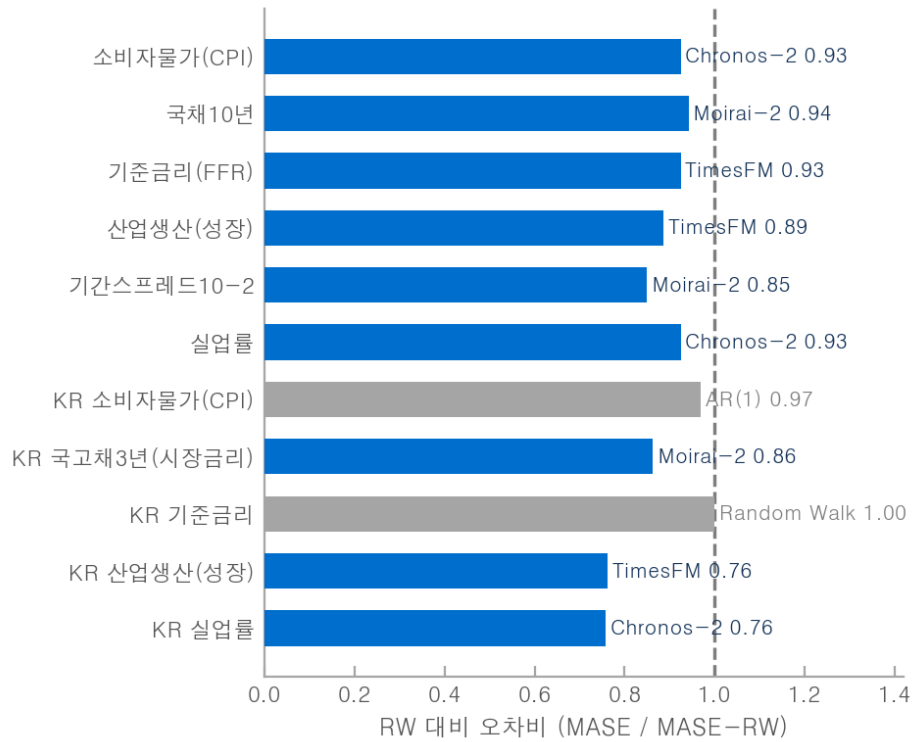
단변량 예측 - 대부분 확률보행(Random Walk) 대비 우위

컨텍스트 통일 시
거시 11개 중 9개
모델이 우위

먼저 외생변수 없이 과거 시계열만 입력하는 단변량 예측이다. 미국과 한국의 거시 11개 지표를 같은 방식으로 시험해 지표마다 오차가 가장 작은 모델을 추리면, 11개 중 9개에서 파운데이션 모델의 예측오차가 확률보행보다 작다(그림 8). 미국 소비자물가는 Chronos가, 금리·성장·실업은 Moirai와 TimesFM이 오차가 가장 작다. 단순 기준선의 오차가 더 작은 곳은 한국 소비자물가(AR(1))와 한국 기준금리(계단식으로 움직여 확률보행)뿐이다.

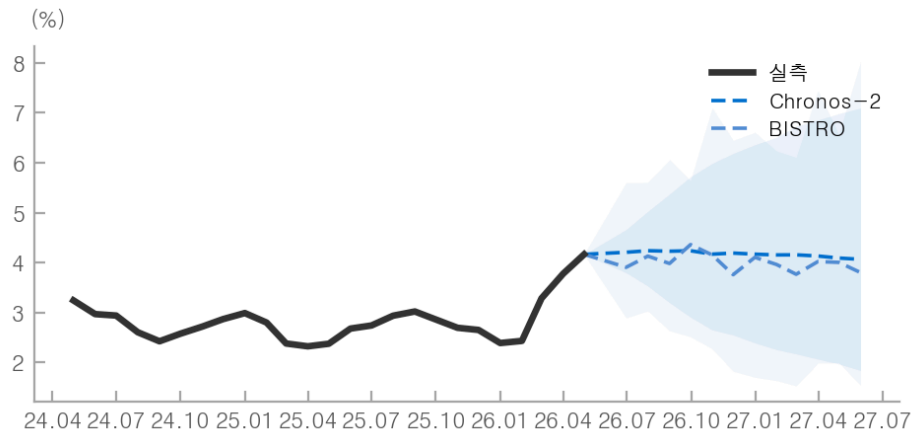
단변량 예측을 기준으로, 현재 시점에서 미국 물가의 향후 12개월을 내다보면, 미국 물가에서 예측오차가 가장 작았던 Chronos와 BISTRO 예측치는 2026년 5월 4.17%에서 각각 4.07%, 3.80%로 완만히 하락해, 물가가 4% 안팎에서 더디게 내려올 가능성을 시사한다(그림 9).

그림 8. 거시 지표별 최우수 모델 (컨텍스트 120개월)



자료: FRED, 대신증권 Research Center

그림 9. 미국 소비자물가 단변량 전망 - Chronos · BISTRO



자료: FRED, 대신증권 Research Center


공변량의 쓸모는
예측이 아니라
시나리오에 있다

유가 시나리오 - 경로를 가정해 물가 반응을 본다

단변량을 넘어, 유가 같은 외생변수의 미래 경로를 가정하고 물가를 예측하는 조건부 시나리오도 가능하다. 유가가 앞으로 어떤 경로를 따른다고 입력하면, 모델은 유가와 물가의 과거 공동 움직임에 따라 물가 경로를 산출한다. 현재 유가 수준 대비 -30%에서 +30%까지 움직여 보면 물가 예측 경로가 또렷이 갈린다 - 유가 하락 경로에서는 물가 예측치가 지속적으로 낮아지는 반면(현재 대비 -30%면 1년 뒤 2% 부근), 상승 경로에서는 단기적으로 높아졌다가 1년 뒤 기준 경로로 회귀한다(그림 10). 유가 충격에 대한 물가 반응이 비대칭적임을 보여준다.

두 가지는 특징적인 내용은 다음과 같다. 첫째, 이 시나리오 곡선은 반응이 안정적인 Chronos-TimesFM으로 산출하였다. 거시 데이터로 미세조정된 BISTRO는 미국 물가 도메인을 벗어난 시나리오에서 반응이 불안정해 제외했다. 둘째, 공변량을 넣는다고 예측 정확도 자체가 높아지는 것은 아니다. 미래의 외생변수 값을 실제로는 알 수 없어, 미래값을 누출 없이 정직하게 주면 개선 효과는 사실상 사라진다. 따라서 공변량의 쓸모는 “예측을 더 맞힌다”가 아니라 “특정 경로를 가정했을 때 결과가 어떻게 달라지는가”를 살피는 시나리오 도구에 있다.

그림 10. 유가 충격 시나리오별 미국 물가 경로 (현재 WTI 대비)



자료: FRED, 대신증권 Research Center

Ⅳ. 주식시장 - 개별 주가와 팩터·포트폴리오

주가 · 포트폴리오 - 개별은 예측이 어렵고, 모으면 예측력이 나타난다

개별 주가는
사실상 무작위 ·
모으면 구조가 보인다

이번 챕터에서는 분석 대상을 한국 주식(시총 상위 30 대형주)으로 옮긴다. 시계열 파운데이션 모델 네 가지(Chronos·MOIRAI 2.0·TimesFM·BISTRO)에 개별 종목·포트폴리오·팩터의 과거 수익률을 입력해 다음 달 수익률을 예측하게 한 뒤, 가장 단순한 두 기준선과 비교하였다.


몇 가지 용어부터 분명히 해 둔다. 여기서 수익률은 가격(레벨)이 아니라 월별 등락률(직전 대비 변화)이며, 이 선택이 결과를 좌우한다 - 같은 종목도 가격 그대로 넣으면 예측이 거의 불가능하지만 등락률로 넣으면 예측 가능성이 크게 달라진다. **포트폴리오**는 여러 종목을 같은 비중으로 묶은 바스켓의 월수익률을, **팩터**는 가치·모멘텀 같은 스타일별 룬셋 묶음의 수익률을 가리킨다. 예측이 잘 됐는지는 ‘과거 평균 수익률을 그대로 예측치로 두는 것’보다 얼마나 정확한지로 잰고(표본외 결정계수), 그 값이 0보다 크면 단순 기준보다 오차가 작은 것이다.

먼저 두 기준이 무엇인지부터 짚는다. **확률보행(Random Walk)**은 “내일도 오늘과 같다”고 보는, 생각할 수 있는 가장 단순한 예측이다. 수익률로 바꿔 말하면 “다음 달 수익률은 0”으로 두는 것 - 사실상 예측 없이 보유하는 것(매수보유)과 같다. **AR(1)**은 거기에 간단한 가정을 더해 “지난달 움직임이 이번 달에도 일부 이어진다”고 보는 모형이다. 둘 다 통계 지식이 거의 필요 없는 기초 기준선이다.

결과부터 보면(그림 11), **개별 종목**에서는 네 모델의 평균 예측력(표본외 R^2)이 -0.012로 0을 밑돈다. 풀어 말하면, 수천억 개의 데이터를 학습한 거대 모델조차 개별 종목을 다음 달 수익률은 “0으로 예측하는 것”보다도 잘 맞히지 못한다는 뜻이다. 이는 모델의 결함이 아니라 상장 회사 개별적인 등락에서 모델로 예측할 수 없는 범위가 크다는 것이다. 한 종목의 한달 등락은 그 회사 고유의 변동요인이 차지하는 비중이 크다.

그런데 **여러 종목을 모으면 예측력이 있다고 말 할 수 있는 수준이다**. 시총 상위 30 대형주를 동일가중한 포트폴리오에서는 예측력이 +0.064, 팩터에서는 +0.047로 양(+)으로 전환된다. 개별 종목 월수익률 예측이 통상 0 부근인 점을 감안하면, 이 표본외 결정계수는 의미 있는 수준이다. 종목을 합치면 제각각인 고유 등락은 서로 상쇄되고, 모델이 포착할 수 있는 **공통의 구조**만 남는 경향이 있기 때문으로 판단한다. 곧 이 모델들의 실질적 효용은 개별 종목 예측이 아니라, 분산된 묶음의 공통 성분을 포착하는 데 있다.

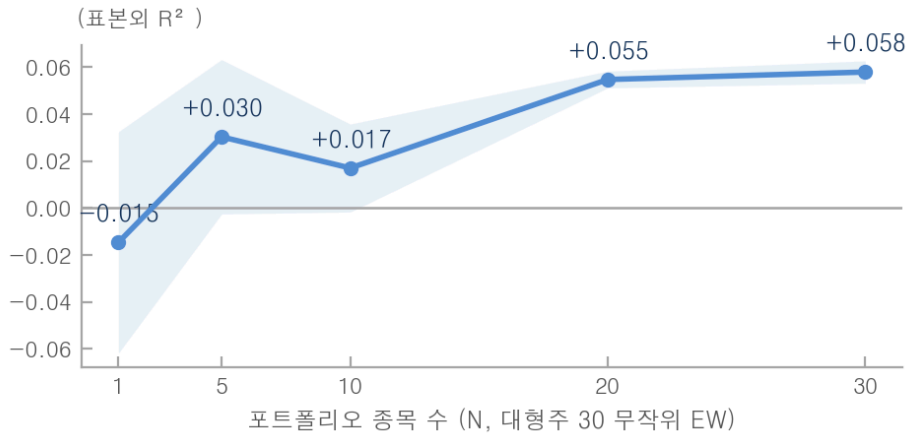
그림 11. 개별 · 포트폴리오 · 팩터의 예측력 (표본외 R²)



자료: 대신증권 Research Center

이 분산효과는 포트폴리오에 담은 종목 수를 늘려 가며 더 뚜렷이 드러난다(그림 12). 시총 상위 30 대형주에서 종목 수를 늘려 동일가중하면, 한 종목일 때 0을 밀돌던 예측력이 종목을 모을수록 양(+)으로 올라 종목 수 다섯에서 스물 사이에서 0.05 부근으로 포화한다. 개별 종목의 고유한 등락은 평균에서 지워지고, 여러 종목이 함께 움직이는 공통 성분만 남아 그 부분을 모델이 포착하기 때문이다.

그림 12. 개별주식 보다 포트폴리오 레벨에서 예측력 상승




자료: 대신증권 Research Center

사이즈 · 실적은 강
가격 모멘텀은
거의 0

어떤 묶음에서 예측력이 확인되는지 본다. 대표적인 일곱 개 팩터를 같은 방식으로 시험하면 예측력이 또렷한 차이를 보인다(그림 13). 영업이익의 추정치의 변화를 따르는 어닝모멘텀 +0.31과 종목 크기(사이즈) +0.28이 가장 높고, 밸류(E/P)와 단기 모멘텀(1개월)이 +0.13으로 그 뒤를 잇는다. 반대로 6개월·12개월 가격 모멘텀은 0 부근으로, 모델이 가장 못 맞히는 영역이다. 추세가 꾸준한 구조적 팩터에서는 패턴을 포착하나, 방향이 자주 바뀌는 가격 모멘텀에서는 단순 기준선보다 오차가 크다. 구조가 또렷한 곳에서만 예측력이 나타난다는 일관된 결과다.

그림 13. 대표 7개 팩터의 예측력



자료: 대신증권 Research Center

현재 시점 3개월 전망 – 추세가 또렷한 팩터에서 방향이 이어진다

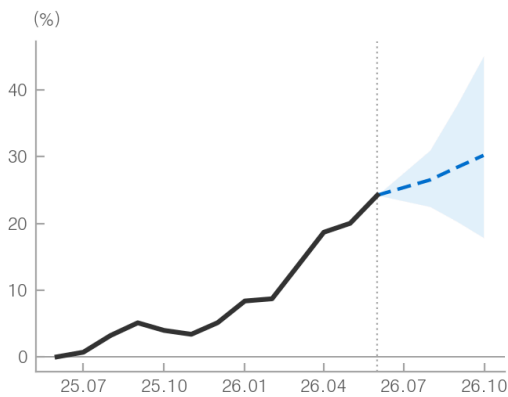
방향은 팩터마다
다르고
밴드는 넓다

앞 절에서 예측력을 살핀 팩터들 가운데 다섯(어닝모멘텀, 사이즈, 단기·장기 모멘텀, 벨류)에 대해, 현재 시점에서 향후 3개월의 룡숏 수익률을 같은 방식으로 예측한다. 각 팩터에는 표본외 결정계수가 가장 높았던 모델을 적용했고(모델명은 각 그림의 주2), 미래 공변량 없이 과거 월수익률만 입력하는 단변량 설정을 그대로 유지하였다. 그림 14~18은 각 팩터의 최근 12개월 누적수익률(실선)과 모델이 제시한 향후 3개월 중앙 경로(점선), 그리고 그 80% 구간(q10~q90, 음영)을 함께 보인다.

전망의 방향은 팩터마다 다르다. 종목 크기(사이즈)와 단기(1개월) 모멘텀·어닝모멘텀에서는 최근의 상승이 향후 3개월에도 이어지는 중앙 경로가, 벨류(B/P)에서는 직전까지의 약세와 달리 상승하는 경로가 나온다. 반대로 장기(12개월) 모멘텀에서는 그동안의 상승과 달리 하락하는 경로가 나온다. 다만 3개월 동안의 전진 폭 자체는 누적수익률 기준 대체로 한 자릿수 %포인트이고(장기 모멘텀만 -10% 포인트 안팎으로 크다), q10~q90 구간이 그 중앙 경로를 넓게 둘러싼다.


모델이 경제적 인과보다 최근의 통계적 추세를 반영할 가능성이 있고, 그렇다면 추세가 또렷한 팩터에서 방향이 더 분명하게 이어지고 방향이 자주 바뀌는 팩터에서 구간이 넓어지는 것으로 볼 수 있다.

그림 14. TSM을 활용한 어닝모멘텀 팩터 예측치




주: 1) 영업이익 추정치 상향 종목(퉁) - 하향 종목(숏)으로 구성된 어닝모멘텀 팩터
2) 모델 MOIRAI 2.0
자료: 대신증권 Research Center

그림 15. TSM을 활용한 사이즈 팩터 예측치




주: 1) 시총 상위 대형주(퉁) - 하위 소형주(숏)으로 구성된 사이즈 팩터
2) 모델 TimesFM
자료: 대신증권 Research Center

그림 16. TSFM을 활용한 단기 모멘텀 팩터 예측치



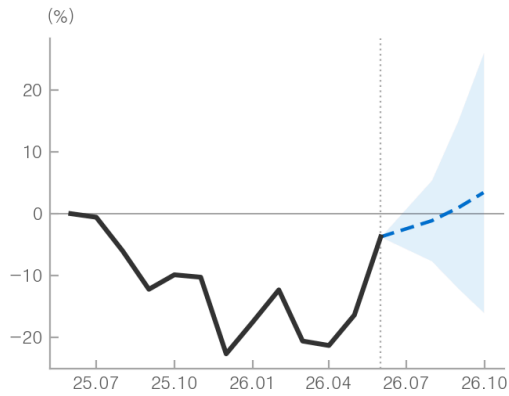
주: 1) 직전 1개월 수익률 상위(푼) - 하위(숏)으로 구성된 단기 모멘텀 팩터
 2) 모델 TimesFM
 자료: 대신증권 Research Center

그림 17. TSFM을 활용한 장기 모멘텀 팩터 예측치



주: 1) 직전 12개월 수익률 상위(푼) - 하위(숏)으로 구성된 장기 모멘텀 팩터
 2) 모델 BISTRO
 자료: 대신증권 Research Center

그림 18. TSFM을 활용한 밸류(B/P) 팩터 예측치



주: 1) 순자산 대비 주가가 낮은 종목(푼) - 높은 종목(숏)으로 구성된 밸류 팩터
 2) 모델 TimesFM
 자료: 대신증권 Research Center

V. 편리한 만큼 한계점을 인지할 필요

모델 핵심 설계방식에서 한계점 도출

설계의 차이를
알수록 활용처를
넓힐 수 있다

AI를 활용할 때에도, 대규모 언어모델(LLM)이 결국 언어의 맥락을 읽고 다음에 올 확률적으로 타당한 토큰을 산출한다는 점을 이해하면 에이전트 활용에서 맥락 설계나 하네스 엔지니어링의 필요를 알게 된다. 같은 맥락에서 시계열 파운데이션 모델도 기존 모델 설계 방식과 무엇이 다른지, 그 한계가 어디에 있는지 인식한다면 활용처를 적절하게 넓혀 갈 수 있을 것으로 판단한다.

기존의 시계열 예측에서, 고전적 계량경제학 모델은 변수 사이의 메커니즘을 모형에 담고, 기계학습(ML) 모델은 대상 변수의 동학에 중요하다고 판단되는 변수를 선별하고 가공하는 일이 핵심 작업이었다. 반면 시계열 파운데이션 모델은 특정 도메인에 속한 모든 시계열의 패턴을 일반적으로 학습한다. 물가·주가·성장률처럼 성질이 다른 경제 변수의 패턴을 한데 넣고 모델이 스스로 학습하도록 한 것이다. 기존 ML이 블랙박스라 지적받던 것보다 한층 더 큰 수준으로 일반화한 셈이며, 시계열을 적절히 입력하는 것 외에 달리 필요한 작업이 없다는 점은 편의성을 높이는 동시에 산출된 값의 타당성에 대한 의구심을 키우는 요인이기도 하다.

인과는 없고
과거의 동행을
반영할 뿐이다

BIS 워킹페이퍼가 지적했듯이 모델에는 인과적 메커니즘이 들어가 있지 않으며, 이는 ML 계열 모델에도 동일하게 적용되는 문제다. 따라서 현재로서는 산출된 수치를 직접 활용하기보다, 현실에서 나타나는 시계열의 일반적 패턴이 모델의 결과로 드러날 수 있다는 사실을 인지하는 편이 적절하다. 실제로 BISTRO에 정책금리를 조건으로 물가를 예측시키면 “금리를 올릴수록 물가가 높아지는” 양의 관계가 나오는데, 이는 모델이 통화정책의 전달 경로를 모른 채 “물가 급등기에 금리도 높았다”는 역사적 동행을 그대로 반영하기 때문이다. 정책 반응함수도, 구조적 충격의 식별도 없이 과거의 공동분포를 외삽하는 도구로 반사실 시나리오를 묻는 것은 위험하다.

그럼에도 TSFM 발전을 기대하는 이유

언어·이미지가 그랬듯
시계열에서도
발전 여지가 있다

그럼에도 시계열 파운데이션 모델의 발전 가능성은 낮지 않다. 기계학습(ML) 모델이 이미지 처리에서, 트랜스포머 구조가 언어와 이미지에서 뚜렷한 성과를 보였던 것처럼, 시계열 영역에서도 같은 흐름이 이어질 여지가 있다. 다양한 데이터로 사전학습된 트랜스포머 디코더 스택은 시계열의 비선형성과 장기 의존성을 포착하는데 유효하며, 빈도·계절성·변수의 성질·발표 지연 같은 시계열 고유의 구조를 더 충실히 반영하고 공변량과 인과 제약을 정직하게 통합하게 될 때 그 효용은 더 커질 수 있다. 어려운 모형을 설계하고 추정하는 과정을 추론 한 번으로 대신해 일정 수준의 예측 업무를 수행할 가능성이 있으며, 당분간은 과제특화 모형을 대체하기보다 보완하는 보조 도구로 자리매김하는 것이 합리적이다.

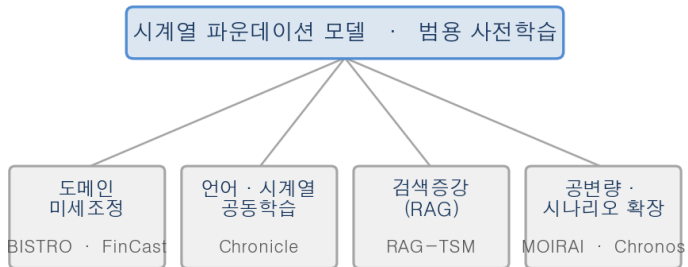
발전 방향 – 도메인 특화 · 언어 결합 · 검색증강

도메인 미세조정 ·
공동학습 · 검색증강 ·
시나리오 확장

최근 연구 페이퍼들의 TSFM 발전방향은 크게 네가지로 나눌 수 있었다. 첫째, **도메인 미세조정** - 범용 모델을 특정 도메인 데이터로 추가 학습한다(거시경제 변수의 BISTRO, 금융의 FinCast). 범용 사전학습이 부여한 일반 능력 위에 도메인 패턴을 얻는 방식으로, 순수 도메인 데이터만으로 처음부터 학습할 때보다 안정적이다. 혹은 비슷한 방향으로 특정 도메인 안의 시계열 데이터(예: 주식의 캔들 데이터, Kronos)만을 학습시키는 방식이다. 둘째, **언어·시계열 공동학습** - 텍스트와 시계열을 한 모델에서 함께 학습해(Chronicle), 추론 시 정성 정보와 정량 시계열을 결합한다. 셋째, **검색증강 시계열 모델** - 예측 시점에 유사 과거 구간을 검색해 맥락에 보강한다. 넷째, **공변량·시나리오 확장** - 외생변수와 조건부 경로를 다루는 능력이다.

한가지 주목할 부분은 시계열 파운데이션 모델에서는 파라미터 개수를 줄였을 때 효과가 크다는 일부 결론과, 공변량이 주는 정보의 양이 크지 않다는 결론이 일부 나타난다. MOIRAI 2.0은 “이득이 미미하다”는 판단으로 공변량 지원을 1.0에서 오히려 제거했고, Chronos도 원조 버전은 공변량을 받지 못한다. 더 근본적인 경계도 있다. 언어·이미지·영상에서는 모델을 키우고 연산을 늘릴수록 성능이 좋아진다는 규칙(스케일링 법칙)이 대체로 들어맞았지만, 성격이 제각각인 시계열을 한 모델에 너무 넓게 담을 때는 이 규칙이 그대로 통하지 않을 수 있다 - 실제로 MOIRAI 2.0에서는 오히려 더 작은 모델이 더 큰 모델보다 정확했다.

그림 19. 시계열 파운데이션 모델의 발전 방향



자료: 대신증권 Research Center

부록. 주요 모델과 특징

범용 모델에서 도메인 특화까지

MOIRAI는
BISTRO의 기반

Salesforce MOIRAI / MOIRAI 2.0 - 원조 MOIRAI(Woo et al., 2024)는 마스크 인코더 트랜스포머로, 변수 개수에 무관하게 처리하는 any-variate 어텐션과 혼합분포 확률출력, 다중 패치 크기를 특징으로 했다. BISTRO의 기반이기도 하다. MOIRAI 2.0(Liu et al., 2026)은 “Less is More”를 표방하며 마스크 인코더를 디코더 전용으로, 다중 패치를 단일 패치로, 혼합분포 손실을 단일 분위수 손실로 단순화했다. 그 결과 1.0-Large 대비 약 30배 작고 2배 빠르면서 더 높은 정확도를 달성했다. 다만 공변량·다변량 지원을 “이득이 미미하다”며 제거했고, 파라미터를 키우면 오히려 성능이 떨어져(Small 11.4M이 Large 305M보다 우수) 현 데이터 규모의 한계를 자인한다.

Amazon Chronos - 시계열을 평균 스케일링한 뒤 균등 양자화해 4,096개 어휘의 정수 토큰으로 바꾸고, T5 언어모델 구조에 그대로 태운다(20M~710M). 약 89만 개 시계열·840억 토큰으로 언어모델식 교차엔트로피로 학습하며, 추론 시 토큰 분포를 샘플링해 확률예측을 만든다. “시계열을 언어로 다룬다”는 발상이 핵심 기어다. 한계는 고정 어휘 탓에 강한 추세에서 예측 범위가 제약되고, 원조 버전은 공변량·다변량을 받지 못한다는 점이다(후속 Chronos-2에서 보강).

디코더 전용 ·
공동학습 ·
도메인 특화

Google TimesFM - 디코더 전용 트랜스포머에 패치 입력을 결합한 모델로, 입력 패치(32)보다 출력 패치(128)를 크게 잡아 장기 예측의 자기회귀 단계를 줄였다. 약 1,000억 개 관측치, 2억 파라미터(주력)로 사전학습해 완전지도학습 모델에 근접하는 제로샷 성능을 보였다. 본 보고서가 Vibe Quant의 실현 가능성을 뒷받침하는 대표 근거로 삼는 모델이다. 논문은 공변량 미지원, 확률예측 미완성, 계절성이 강한 도메인에서 계절형 ARIMA에 확실히 앞서지 못함을 한계로 밝힌다.

Chronicle - 324M 디코더 전용 백본을 텍스트와 시계열로 무작위 초기화부터 공동 사전학습한 첫 모델이다(Quinlan et al., 2026). 텍스트 토큰과 시계열 패치가 같은 어텐션 블록을 통과해, 추론 시 둘을 한 시퀀스에 섞어 텍스트 조건부 예측·설명을 수행한다. 언어 능력을 유지하면서 동결 임베딩만으로 분류에서 여타 파운데이션 모델을 앞섰으나, 학습 연산의 약 8%만 시계열에 배분한 절충으로 순수 예측 성능은 전용 모델에 못 미친다고 자인한다.

FinCast - 금융 시계열에 특화한 첫 파운데이션 모델로(Zhu et al., 2025), 1B 파라미터 디코더 전용 구조에 200억+ 관측치(주식·선물·외환·암호자산)를 학습했다. 토큰 단위 희소 전문가 혼합으로 레짐별 패턴을 분리하고, 학습형 주파수 임베딩으로 다해상도 비정상성에 대응한다. 제로샷에서 범용 모델 대비 평균 MSE 20%·MAE 10% 개선을 보고하나, 외생 공변량은 통합하지 않는다.

BIS BISTRO - II장에서 상술. MOIRAI 기반·63개국 거시 데이터 미세조정. 무조건부·조건부(시나리오) 예측을 모두 지원하며, 거시 변수에서 AR(1)을 일부 앞서는 한편 단기·장기·신흥국에서 한계를 보인다.

참고문헌

- Das, A., Kong, W., Sen, R., Zhou, Y. (2024). A Decoder-Only Foundation Model for Time-Series Forecasting. Google Research. arXiv:2310.10688.
- Woo, G., Liu, C. et al. (2024). Unified Training of Universal Time Series Forecasting Transformers (MOIRAI). Salesforce AI Research. arXiv:2402.02592.
- Liu, C., Aksu, T., Liu, J. et al. (2026). Moirai 2.0: When Less Is More for Time Series Forecasting. Salesforce AI Research. arXiv:2511.11698.
- Ansari, A. F., Stella, L., Turkmen, C. et al. (2024). Chronos: Learning the Language of Time Series. Amazon. TMLR. arXiv:2403.07815.
- Quinlan, P., Levasseur, J., Li, Q., Zhu, X. (2026). Chronicle: A Multimodal Foundation Model for Joint Language and Time Series Understanding. arXiv:2605.20268.
- Zhu, Z., Chen, H., Qu, Q., Chung, V. (2025). FinCast: A Foundation Model for Financial Time-Series. University of Sydney. CIKM '25. arXiv:2508.19609.
- Koyuncu, B., Kwon, B., Lombardi, M., Perez-Cruz, F., Shin, H. S. (2026). BISTRO: a general purpose oracle for macroeconomic time series. BIS Quarterly Review (2026.3); BIS Working Papers No.1337.

[Compliance Notice]

금융투자업규정 4-20조 1항5호사목에 따라 작성일 현재 사전고지와 관련한 사항이 없으며, 당사의 금융투자분석사는 자료작성일 현재 본 자료에 관련하여 재산적 이해관계가 없습니다. 당사는 동 자료에 언급된 종목과 계열회사의 관계가 없으며 당사의 금융투자분석사는 본 자료의 작성과 관련하여 외부 부당한 압력이나 간섭을 받지 않고 본인의 의견을 정확하게 반영하였습니다.

(담당자: 권순호)

본 자료는 투자자들의 투자판단에 참고가 되는 정보제공을 목적으로 배포되는 자료입니다. 본 자료에 수록된 내용은 당사 Research Center의 추정치로서 오차가 발생할 수 있으며 정확성이나 완벽성은 보장하지 않습니다. 본 자료를 이용하시는 분은 동 자료와 관련한 투자의 최종 결정은 자신의 판단으로 하시기 바랍니다.