JKSCI

한국컴퓨터정보학회논문지
Journal of The Korea Society of Computer and Information
Vol. 31 No. 11, pp. 437-444, November 2026
https://doi.org/10.9708/jksci.2026.31.11.437

Transmission of U.S. AI-Infrastructure Information to KOSPI and KOSDAQ

Insu Choi*

*Assistant Professor, Dept. of Finance and Big Data, Gachon University, Seongnam, Korea

[Abstract]

This study examines information transfer from U.S. AI-related assets to KOSPI and KOSDAQ using daily data from January 2024 to March 2026. Source returns are aligned to Korean market openings, and effective Rényi transfer entropy is evaluated with permutation tests and false discovery rate control. Ten of 17 channels into KOSPI and two of 19 into KOSDAQ are significant. After source returns are adjusted for same-day S&P 500 returns, no channel remains significant under transfer entropy, although heteroskedasticity-robust Granger tests detect predictive relationships mainly from semiconductor sources. For the 17 common sources, mean transfer is lower into KOSDAQ by 0.033 bits (95% bootstrap interval: −0.052 to −0.002). This difference is not statistically significant when KOSPI returns are residualized against Samsung Electronics and SK hynix returns. The lag profiles also differ, but do not directly measure price-adjustment speed. No out-of-sample tail-forecast improvement survives multiple-testing adjustment, and transfer entropy has low power in the reported simulations. The results therefore describe sample-specific predictive relationships rather than establish AI-specific transmission or a market-efficiency gap.

▸ **Key words**: Transfer entropy, Information transfer, AI infrastructure, KOSPI, KOSDAQ, Multiple testing

[요 약]

본 연구는 2024년 1월부터 2026년 3월까지 미국 AI 관련 자산과 KOSPI·KOSDAQ 간 정보 전이를 분석하였다. 원천 수익률을 한국 개장 시점에 맞추고 유효 레니 전이 엔트로피에 순열검정과 거짓발견율 통제를 적용하였다. KOSPI로 향하는 17개 경로 중 10개, KOSDAQ의 19개 경로 중 2개가 유의하였다. 원천 수익률에서 당일 S&P 500 수익률을 회귀로 조정한 뒤에는 전이 엔트로피 기준 유의한 경로가 없었으나, 이분산에 강건한 Granger 검정에서는 반도체 원천을 중심으로 예측 관계가 관찰되었다. 공통 원천 17개의 평균 전이량은 KOSDAQ에서 0.033비트 작았지만(95% 부트스트랩 신뢰구간 −0.052~−0.002), KOSPI 수익률을 삼성전자·SK하이닉스 수익률에 대해 잔차화하면 차이는 유의하지 않았다. 시차별 전이 양상도 달랐으나 이를 가격 반영 속도로 해석하기는 어렵다. 표본 외 꼬리사건 예측의 개선은 다중검정 보정 후 확인되지 않았고, 모의실험에서 전이 엔트로피의 검정력은 낮았다. 결과는 해당 표본의 예측 관계로 한정하며, AI 고유 정보의 전이나 시장 효율성 격차를 입증하지 않는다.

▸ **주제어**: 전이 엔트로피, 정보 전이, AI 인프라, KOSPI, KOSDAQ, 다중검정

• First Author: Insu Choi, Corresponding Author: Insu Choi
*Insu Choi (ischoi@gachon.ac.kr), Dept. of Finance and Big Data, Gachon University
• Received: 2026. 09. 28, Revised: 2026. 11. 02, Accepted: 2026. 11. 02.

Copyright © 2026 The Korea Society of Computer and Information
http://www.ksci.re.kr pISSN:1598-849X | eISSN:2383-9945
www.kci.go.kr

I. Introduction

미국 정규장은 한국 개장 전에 마감하므로 양국 시장의 일별 선후 관계를 분석할 때에는 정보의 이용 가능 시점을 구분해야 한다. 본 연구는 미국 AI 인프라 관련 자산과 한국 지수 사이의 정보 전이가 관찰되는지, 그리고 KOSPI와 KOSDAQ의 전이량과 시차별 양상이 다른지 살펴본다.

국제 주식시장 간 정보 전이는 수익률과 변동성의 선후 관계[1] 및 미국 수익률의 예측력[2]을 중심으로 연구되었다. 전이 엔트로피(transfer entropy)는 원천의 과거값이 대상의 조건부 분포에 더하는 정보를 측정하는 방법이다[3, 4, 5]. 다만 거래시간 정렬과 다중검정 보정이 결과에 영향을 줄 수 있으며, 두 국내 지수의 차이는 구성 종목과도 관련될 수 있다.

본 연구는 21개 일별 시계열에서 36개 방향성 경로를 구성하고, 한국 개장 시점에 맞춘 정보시점 정렬(information-time alignment), 유효 레니 전이 엔트로피(effective Rényi transfer entropy, ERTE)[6], 순열검정과 거짓발견율(false discovery rate, FDR) 통제를 적용한다. 시장 간 차이는 공통 원천을 기준으로 비교하고, 삼성전자·SK하이닉스 수익률에 대한 잔차화 후에도 유지되는지 확인한다. 표본 외 예측과 모의실험으로 결과의 해석 범위를 점검한다.

II. Preliminaries

1. Theoretical Background and Hypotheses

효율적 시장 가설[7]과 점진적 정보 확산 이론[8]은 시장 간 수익률의 선후 관계를 해석하는 배경을 제공한다. 산업 내 선도 기업과 후행 기업[9], 경제적으로 연결된 기업[10] 사이에서도 이러한 관계가 보고되었다. 그러나 일별 지수의 전이만으로 개장 이후의 가격 반영 지연을 식별할 수는 없다.

H1: 미국 AI 인프라 관련 원천의 과거 수익률은 한국 지수 수익률의 조건부 분포에 추가적인 정보를 제공한다.

H1b: AI 관련 원천 수익률을 당일 미국 시장 수익률에 대해 잔차화한 뒤에도 정보 전이가 관찰된다.

투자자 주의[11], 정보 접근성[12]과 유동성[13, 14]은 시장 간 차이의 가능한 설명이지만 본 연구에서는 직접 검정하지 않는다. 두 지수의 구성 종목도 다르므로 다음 가설은 현재의 지수 구성을 전제로 한다.

H2: 공통 원천을 기준으로 KOSDAQ은 KOSPI보다 (a) 평균 ERTE가 작고, (b) 양의 ERTE 합에서 장시차 값이 차지하는 비율이 크다.

2. Related Works

국제 주식시장 간 전이 연구는 수익률·변동성의 선후 관계[1]에서 분산분해 기반 연결성[15]과 주파수별 분석[16]으로 확장되었다. 한국 관련 연구는 미국 금융위기의 아시아 시장 전이[17], NASDAQ·KOSDAQ 및 양국 반도체 업종의 연계[18]를 다루었고, AI 관련 자산의 분산투자 효과도 분석되었다[19].

전이 엔트로피는 지수와 개별 종목[20], 국제 시장[4, 5], 산업 부문[21]의 정보 전이에 적용되었으며 추정 절차가 공개 소프트웨어로 제공된다[22]. Choi, Yun, and Kim[23]은 48개 통화의 전이 엔트로피 네트워크를 군집화하여 환율 변동 예측의 자료 효율성을 분석하였다. 본 연구는 이러한 네트워크 예측과 달리 두 한국 지수의 전이량과 시차별 양상 비교에 초점을 둔다.

Granger 인과검정(이하 Granger 검정)[24]과 비모수 확장[25]은 예측 관계를 검정한다. 가우스 변수에서 알려진 Granger 인과와 Shannon 전이 엔트로피의 동치[26]를 이산화된 레니 추정량에 그대로 적용할 수는 없다. 본 연구는 두꺼운 꼬리를 가진 수익률[27]을 고려하여 모의실험에서 두 검정의 기각률을 비교한다.

III. The Proposed Scheme

1. Data and Channel Design

자료는 Yahoo Finance의 수정 일별 OHLCV이며 조회 기간은 2024년 1월 2일부터 2026년 3월 15일까지이다. 원천은 미국 상장 AI 관련 대형주와 ETF, 시장 지수 및 거시 위험 변수로 구성된다(Table 1). 삼성전자와 SK하이닉스는 KOSPI 구성 종목과의 중복을 고려하여 KOSDAQ의 원천에만 포함하였다. 원천과 대상 지수의 방향성 쌍은 KOSPI 17개, KOSDAQ 19개로 총 36개이다. 거래량이 0이고 가격이 모두 같은 관측(KOSPI 1일, 미국 10년 국채금리 4일)은 변동성 계산에서 제외하였다.

www.kci.go.kr

Table 1. Series, groups and roles (daily data, Jan. 2, 2024 – Mar. 15, 2026)

Group	Series	Role
Target	KOSPI, KOSDAQ	Korean composite indices
U.S. Broad	SP500, NASDAQ	U.S. market indices
AI Compute	NVDA, AMD, AVGO	AI accelerators, custom chips, networking
AI Capex	MSFT, GOOGL, AMZN, META	Hyperscaler AI investment
Semi Supply	TSM, ASML, MU, SOXX	Foundry, lithography, memory, sector ETF
AI Software	IGV	Software sector ETF
Macro Risk	VIX, WTI, UST10Y	Volatility, oil price, 10-year yield
KR AI Megacap	SEC, SKH	Samsung Electronics, SK hynix

SEC and SKH are sources for KOSDAQ only. The main aligned panel contains 530 sessions from Jan. 5, 2024 to Mar. 13, 2026.

KOSPI와 KOSDAQ 로그수익률의 연율 변동성은 각각 25.8%와 28.5%, 초과첨도는 12.9와 18.3이며 Jarque–Bera 검정은 모두 정규성을 기각한다.

한국 세션 i의 개장 시각을 O_i라 하면 정보시점 정렬 수익률은 식 (1)과 같다.

$$\tilde{x}_i = \sum_{t:\ C_t^X \in (O_{i-1},\ O_i]} r_t^X \qquad (1)$$

여기서 C_t^X 는 원천 X의 t일 종가 시각, r_t^X는 그날의 로그수익률이다. 식 (1)은 직전 한국 개장 이후 현재 개장까지 관측된 원천 수익률을 합한다. 정보시점 패널은 530개 세션(2024년 1월 5일~2026년 3월 13일)이다. 비교 설계에서는 S&P 500, NASDAQ, NVIDIA, IGV, SOXX, KOSPI, WTI, VIX의 8개 시계열에 달력 정렬과 정보시점 정렬을 각각 적용하였다. 달력 정렬은 원천의 전일 수익률과 대상의 당일 수익률을 짝짓는다.

2. Effective Rényi Transfer Entropy

평균 순위에 따라 수익률을 B=5개 분위 구간으로 이산화하고, 대상과 원천의 상태를 각각 y_i , x_i 로 표기한다. 이력 길이는 k=l=1이다. 레니 전이 엔트로피는 식 (2)로 정의된다[6].

$$T_{X\to Y}^{(q)} = \frac{1}{1-q}\log_2 \frac{\sum_{y_i, y_{i+1}} \phi_q(y_i)\, p^q(y_{i+1}|y_i)}{\sum_{y_i, x_i, y_{i+1}} \phi_q(y_i, x_i)\, p^q(y_{i+1}|y_i, x_i)} \qquad (2)$$

여기서 $p(\cdot|\cdot)$ 는 조건부 확률이고, 에스코트 분포는 $\phi_q(z) = p(z)^q / \sum_{z'} p(z')^q$ 이다. 정보시점 패널에서 대상 수익률 y_{i+1}은 전일 종가에서 당일 종가까지의 로그수익률이며, 이에 대응하는 원천 상태는 같은 세션의 개장 전까지 관측된 $\tilde{x}_{i+1}$이다. q<1은 낮은 확률의 상태에 상대적으로 큰 가중치를 부여하지만, 분위 이산화에서 이를 수익률 꼬리의 직접적인 강조로 볼 수는 없다. 주 사양은 q=0.7이며 q∈{0.5, 0.9, 1.0}을 비교한다. q=1은 Shannon 전이 엔트로피에 해당하는 극한으로 해석한다. 유한표본 편의를 보정하기 위해 원천을 블록 단위로 섞은 대리자료 N개에서 계산한 평균을 뺀다[4].

$$\mathrm{ERTE} = \mathrm{T}_{\mathrm{X}\to\mathrm{Y}}^{(\mathrm{q})} - \frac{1}{\mathrm{N}}\sum_{\mathrm{n}=1}^{\mathrm{N}} \mathrm{T}_{\mathrm{X}^{(\mathrm{n})}\to\mathrm{Y}}^{(\mathrm{q})}, \qquad \mathrm{Z} = \frac{\mathrm{ERTE}}{\widehat{\sigma_{\mathrm{surr}}}} \qquad (3)$$

여기서 $X^{(n)}$은 n 번째 대리자료, $\widehat{\sigma_{\mathrm{surr}}}$는 대리자료 추정값의 표준편차이며 단위는 비트이다. 양의 ERTE는 대리자료 평균을 웃도는 추정값이며, 그 자체로 통계적 유의성을 뜻하지 않는다.

3. Inference and Validation Design

순열 p값은 (1+#{대리자료 추정값 ≥ 관측값})/(N+1)이며 N=1,000이다. 주 분석의 36개 경로를 하나의 검정군으로 묶어 Benjamini–Hochberg(BH) 방법[28]을 5% 수준에서 적용하고, 다중검정 보정 결과는 BH 보정 p값으로 표기하여 레니 모수 q와 구분한다. 비교 기준인 Granger 검정은 제약 모형의 AIC로 시차를 선택하고 HC3 공분산[29]을 사용한 Wald 검정으로 수행한다.

H1b에는 AI 관련 원천 12개 수익률을 당일 S&P 500 수익률에 회귀한 잔차를 사용한다. 이는 시장과의 선형 공변동을 조정한 분석이며 AI 고유 정보의 식별을 뜻하지 않는다. H2(a)는 공통 원천 17개에서 Δ_s = ERTE(s→KOSDAQ) − ERTE(s→KOSPI)를 계산하고, 두 패널을 같은 날짜 블록(길이 10세션)으로 재표본하는 이동블록 부트스트랩[30] 500회로 신뢰구간을 구한다. H2(b)는 원천 시차 d=1,…,5의 추정값 ERTE_d 로 정의한 장시차 비율 L을 비교한다.

$$L = \frac{\sum_{d=2}^{5} \max(\mathrm{ERTE}_d, 0)}{\sum_{d=1}^{5} \max(\mathrm{ERTE}_d, 0)} \qquad (4)$$

이는 양의 ERTE 합에서 d=2,…,5가 차지하는 비율이다. 분모가 양수일 때 정의되며, 서로 중복될 수 있는 시차별 정보를 합하므로 가격 반영 속도의 직접 측정치는 아니다. 두 시장의 차이는 Wilcoxon 부호순위 검정으로 비교한다. 구성 종목과의 공변동을 점검하기 위해 두 지수 수

www.kci.go.kr

익률을 당일 삼성전자·SK하이닉스 수익률에 대해 잔차화한 분석도 수행한다. 이 잔차는 두 종목을 실제로 제외하여 재구성한 지수가 아니다. 잔차화 계수는 전 표본에서 한 번 추정하였고, 부트스트랩은 잔차화된 패널의 날짜 블록을 재표본하되 이산화 경계는 고정하고 대리자료 보정은 반복마다 다시 계산하였다.

표본 외 예측은 대상 지수 수익률의 하위 20% 사건을 확장창으로 예측한다. 평가 세션 i(251~530번째)마다 이전 대상 수익률로 사건 임계값과 이산화 경계를 다시 추정하고, 원천 경계는 세션 i 개장 전까지의 값으로 추정한다. 학습 구간의 사건도 새 임계값으로 정의한다. 기준 모형은 직전 대상 상태, 비교 모형은 직전 대상 상태와 개장 전 원천 상태가 같은 학습 관측의 사건 빈도를 사용하며, 이는 식 (2)의 정보시점 구성과 같다. 두 빈도는 강도 2의 베타 사전분포로 학습 구간 사건율 쪽으로 축소한다. Brier 점수 차이는 Newey-West 분산(시차 5)을 사용한 Diebold-Mariano(DM) 검정[31]과 BH 보정으로 평가한다.

모의실험은 표본 크기 n=530, KOSPI 초과첨도에 맞춘 자유도 4.47의 t분포를 기준으로 500회 수행한다. N0~N2는 가우스, t, GARCH-t 귀무 과정이고, N3는 평균 연결 없이 분산만 연결된 과정이다. N3는 Granger 검정의 귀무 과정이지만 전이 엔트로피의 귀무 과정은 아니다. A1과 A2는 각각 선형 연결과 꼬리 연결의 대립 과정이다.

IV. Experimental Results

1. Comparison of Alignment Designs

Table 2는 달력 정렬과 대리자료 100개를 사용한 설계를 정보시점 정렬과 대리자료 1,000개를 사용한 설계와 비교한다. 후자에서는 KOSPI로 향하는 S&P 500, NASDAQ, SOXX, VIX의 전이가 56개 방향성 쌍에 대한 BH 보정 후 5% 수준에서 유의하였다. KOSPI의 순전이(받은 전이의 합에서 보낸 전이의 합을 뺀 값)는 0.434비트와 0.308비트로 후자에서 약 29% 작았다. 두 설계는 대리자료 수와 유의성 판정 방식도 다르므로 이 차이를 정렬 방식만의 효과로 해석하지 않는다.

Table 2. Transfer into KOSPI in the eight-series network (q=0.7)

Source	Calendar, N=100	Info-time, N=1,000	GC-HC3 p
SP500	0.100*** (5.64)	0.082** (5.07)	<0.001***
NASDAQ	0.066*** (4.15)	0.080** (4.80)	<0.001***
NVDA	0.039*** (2.36)	0.033* (2.00)	<0.001***
IGV	0.026* (1.54)	0.040* (2.45)	<0.001***
SOXX	0.069*** (4.33)	0.097** (5.84)	<0.001***
WTI	-0.017 (-0.98)	-0.007 (-0.43)	0.405
VIX	0.081*** (4.08)	0.098** (6.09)	<0.001***
Net ERTE of KOSPI	0.434	0.308	-

ERTE in bits; Z in parentheses. Calendar stars use one-sided normal p-values from Z; info-time stars use BH-adjusted p-values over 56 pairs. GC-HC3 uses information-time alignment. *** <0.01, ** <0.05, * <0.10. Significance symbols are not directly comparable across columns. Info-time values use the same 529 transitions and raw estimates as Fig. 1 and differ only by independent surrogate draws.

2. Information Transfer and Market Adjustment

주 분석에서는 KOSPI의 17개 경로 중 10개, KOSDAQ의 19개 경로 중 2개가 BH 보정 후 5% 수준에서 유의하였다(Fig. 1). KOSPI의 주요 전이량은 VIX 0.097, SOXX 0.096, ASML 0.093, AMD 0.089비트였다. KOSDAQ에서는 AMD(0.047)와 ASML(0.041)만 유의하였다. NVIDIA→KOSPI(0.032, 보정 전 p=0.033)는 BH 보정 후 유의하지 않았다. HC3 Granger 검정의 유의한 경로는 BH 보정 후 5% 수준에서 KOSPI 15개, KOSDAQ 14개였다. H1의 증거는 원천과 검정 방법에 따라 달랐다.

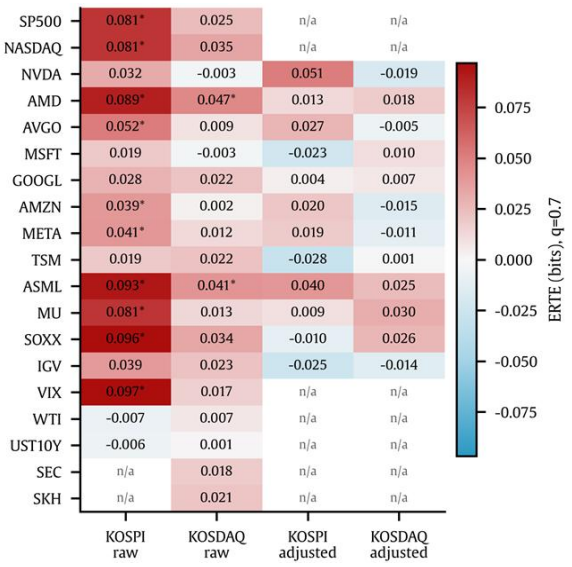


Fig. 1. ERTE in the main panel (bits, q=0.7). Adjusted columns use AI-related source returns residualized against same-day S&P 500 returns. Asterisks indicate BH significance at 5%; 36 raw channels and 24 adjusted channels are separate testing families.

www.kci.go.kr

시장 조정 원천의 24개 경로 중 ERTE가 유의한 경로는 없었고 최소 BH 보정 p값은 NVIDIA→KOSPI의 0.108(보정 전 p=0.005)이었다. 같은 잔차 원천에 대한 HC3 Granger 검정에서는 9개 경로가 유의하였으며 이 중 7개는 TSMC, ASML, Micron, SOXX에서 출발하였다. H1b는 ERTE에서 지지되지 않았으나 Granger 검정에서는 일부 예측 관계가 남았다. 시장 조정의 범위와 ERTE의 낮은 모의실험 검정력을 고려하면 이를 AI 고유 정보의 존재 또는 부재로 단정하기 어렵다.

3. Differences between KOSPI and KOSDAQ (H2)

공통 원천 17개의 평균 ERTE 차이는 −0.033비트였고 95% 부트스트랩 신뢰구간은 [−0.052, −0.002]였다(p=0.044; Fig. 2). 그룹별 평균 차이는 모두 음수였으나 각 신뢰구간은 0을 포함하였다. 원천별 구간에서는 VIX만 0을 포함하지 않았다. 전체 평균의 결과는 H2(a)와 일치하지만 원천별 차이로 일반화하기는 어렵다.

KOSPI 수익률을 삼성전자·SK하이닉스 수익률에 대해 잔차화한 뒤, KOSDAQ과 동일한 529개 세션(두 종목의 자료가 없는 2025년 9월 19일 제외)에서 비교한 평균 차이는 0.008비트(95% 신뢰구간 −0.015~0.039, p=0.40)로 유의하지 않았다. 두 지수를 모두 잔차화하면 차이는 0.001비트(p=0.93)였다. 이는 지수의 공변동 구조에 대한 민감도를 보여주며, 두 종목의 인과적 기여를 분리한 결과는 아니다.

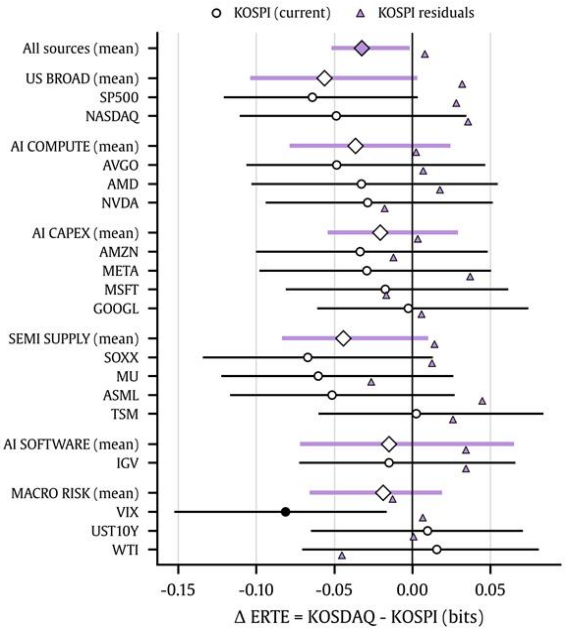


Fig. 2. ERTE differences (KOSDAQ minus KOSPI) and 95% bootstrap intervals. Filled markers exclude zero; diamonds show group or pooled means. Triangles show point estimates using KOSPI returns residualized against Samsung Electronics and SK hynix returns.

시차별 양상에서는 d=1의 ERTE 중앙값이 KOSPI 0.040, KOSDAQ 0.016비트였고, KOSDAQ은 d=3~5에서도 양의 중앙값을 보였다(Fig. 3). 장시차 비율 L의 중앙값은 각각 0.36과 0.66이며, 17개 원천 중 14개에서 KOSDAQ의 값이 컸다(Wilcoxon p=0.011). KOSPI 잔차의 d=1 중앙값은 0.007비트, L의 중앙값은 0.81이었고, L이 정의되는 16개 원천(TSMC는 모든 시차의 ERTE가 0 이하)에서 KOSDAQ의 중앙값 0.64와의 차이는 5% 수준에서 유의하지 않았다(p=0.083). 원천 간 의존성을 고려하면 Wilcoxon 결과는 탐색적으로 해석해야 하며, 이를 정보 흡수 속도나 시장 효율성의 차이로 볼 수는 없다.

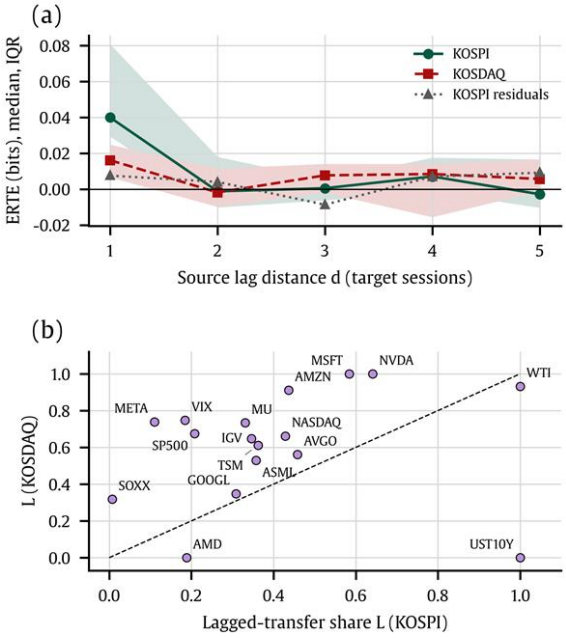


Fig. 3. (a) Median and interquartile range of ERTE by source lag d; the dotted line uses residualized KOSPI returns. (b) Lagged-transfer share L; points above the diagonal have larger values for KOSDAQ. This ratio is a descriptive lag-profile measure.

4. Robustness and Validation

표본 외 예측에서는 36개 경로 중 BH 보정 후 5% 수준에서 유의한 개선을 보인 경로가 없었다. 최대 개선은 AMD→KOSPI의 Brier 점수 13.5%(DM t=2.83, BH 보정 p=0.067)였고 개선율 중앙값은 KOSPI 2.5%, KOSDAQ −2.2%였다.

S&P 500→KOSPI의 Z는 대리자료 블록 길이 1~20에서 5.0~5.3이었다. 이산화 구간 B=10에서는 Z=1.69(순열 p=0.030)였고, k=l=2에서는 유의하지 않았다(p=0.84). 이 민감도 결과를 전체 36개 경로의 강건성으로 해석하지 않는다. 150세션 이동창의 S&P 500→KOSPI ERTE는 2025년 5월 이전 39개 창 평균 0.138, 이후 38개 창 평균

www.kci.go.kr

0.049비트로 시기에 따라 달랐다.

Table 3에서 N1과 N2의 HC3 및 ERTE 기각률은 0.042~0.052였고, VAR 전체 AIC로 시차를 선택한 Granger F검정은 두 과정 모두 0.078이었다. N3에서 동분산 F검정의 기각률은 0.128, HC3는 0.040이었다. N3는 전이 엔트로피의 귀무 과정이 아니므로 ERTE의 0.078을 검정 크기로 해석하지 않는다. A1과 A2에서는 HC3의 검정력이 각각 0.738과 0.926, ERTE는 0.136과 0.260이었다. 이 모의실험은 실증의 검정 간 차이와 일관되지만 그 원인을 확정하지는 않는다.

Table 3. Monte Carlo rejection rates at the 5% level (n=530, 500 replications)

DGP	GC-F (VAR-AIC)	GC-F	GC-HC3	ERTE
N0 Gaussian	0.050	0.036	0.038	0.038
N1 Student-t	0.078	0.054	0.052	0.048
N2 GARCH-t	0.078	0.048	0.048	0.042
N3 variance link	0.162	0.128	0.040	0.078
A1 linear link	0.788	0.746	0.738	0.136
A2 tail-only link	0.968	0.954	0.926	0.260

N0–N2 are null processes for all tests; N3 is a null for Granger tests only. A1 and A2 are alternatives. GC-F and GC-HC3 use lag selection from the restricted model; the first column uses VAR-AIC. Monte Carlo standard error at a rejection probability of 5% is approximately 0.01.

V. Conclusions

미국 AI 관련 자산과 한국 지수 간 정보 전이는 KOSPI에서 더 많이 관찰되었지만, 원천을 미국 시장 수익률에 대해 잔차화한 뒤의 결과는 ERTE와 Granger 검정에서 달랐다. 따라서 본 분석만으로 AI 고유 정보의 전이를 판단하기는 어렵다.

현재 지수에서 관찰된 평균 ERTE 차이는 KOSPI 수익률을 삼성전자·SK하이닉스 수익률에 대해 잔차화한 뒤에는 유의하지 않았다. 시차별 양상도 조정 여부에 따라 달랐다. 이 결과는 지수의 공변동 구조에 민감한 예측 관계이며, 시장 효율성이나 실제 정보 흡수 속도의 차이를 입증하지 않는다. 표본 외 예측 개선도 BH 보정 후 확인되지 않았으며, 모의실험에서 낮은 ERTE 검정력은 비유의 결과의 해석을 제한한다.

분석 범위는 2024~2026년의 일별 지수 자료에 한정된다. 후속 연구에서는 장중 자료로 개장 직후 가격 반응을 확인할 수 있다. 또한 다양한 분야에서 활용되는 미디어·댓글 텍스트의 담론과 감성 분석[32-34], 금융 텍스트에 대한 언어모형과 시장 맥락 활용[35-37]을 참고하여, 자연어처리로 뉴스·공시의 AI 관련 정보를 추출하고 가격 기반 전이와 비교할 수 있다.

REFERENCES

[1] Y. Hamao, R. W. Masulis, and V. Ng, "Correlations in Price Changes and Volatility across International Stock Markets," Review of Financial Studies, Vol. 3, No. 2, pp. 281-307, Apr. 1990. DOI: 10.1093/rfs/3.2.281

[2] D. E. Rapach, J. K. Strauss, and G. Zhou, "International Stock Return Predictability: What Is the Role of the United States?," Journal of Finance, Vol. 68, No. 4, pp. 1633-1662, Aug. 2013. DOI: 10.1111/jofi.12041

[3] T. Schreiber, "Measuring Information Transfer," Physical Review Letters, Vol. 85, No. 2, pp. 461-464, Jul. 2000. DOI: 10.1103/physrevlett.85.461

[4] R. Marschinski, and H. Kantz, "Analysing the information flow between financial time series," European Physical Journal B, Vol. 30, No. 2, pp. 275-281, Nov. 2002. DOI: 10.1140/epjb/e2002-00379-2

[5] T. Dimpfl, and F. J. Peter, "Using transfer entropy to measure information flows between financial markets," Studies in Nonlinear Dynamics and Econometrics, Vol. 17, No. 1, pp. 85-102, Jan. 2013. DOI: 10.1515/snde-2012-0044

[6] P. Jizba, H. Kleinert, and M. Shefaat, "Rényi's information transfer between financial time series," Physica A: Statistical Mechanics and its Applications, Vol. 391, No. 10, pp. 2971-2989, May 2012. DOI: 10.1016/j.physa.2011.12.064

[7] E. F. Fama, "Efficient Capital Markets: A Review of Theory and Empirical Work," Journal of Finance, Vol. 25, No. 2, pp. 383-417, May 1970. DOI: 10.2307/2325486

[8] H. Hong, and J. C. Stein, "A Unified Theory of Underreaction, Momentum Trading, and Overreaction in Asset Markets," Journal of Finance, Vol. 54, No. 6, pp. 2143-2184, Dec. 1999. DOI: 10.1111/0022-1082.00184

[9] K. Hou, "Industry Information Diffusion and the Lead-lag Effect in Stock Returns," Review of Financial Studies, Vol. 20, No. 4, pp. 1113-1138, Jul. 2007. DOI: 10.1093/revfin/hhm003

[10] L. Cohen, and A. Frazzini, "Economic Links and Predictable Returns," Journal of Finance, Vol. 63, No. 4, pp. 1977-2011, Aug. 2008. DOI: 10.1111/j.1540-6261.2008.01379.x

[11] B. M. Barber, and T. Odean, "All That Glitters: The Effect of Attention and News on the Buying Behavior of Individual and Institutional Investors," Review of Financial Studies, Vol. 21, No. 2, pp. 785-818, Apr. 2008. DOI: 10.1093/rfs/hhm079

[12] R. C. Merton, "A Simple Model of Capital Market Equilibrium with Incomplete Information," Journal of Finance, Vol. 42, No.

www.kci.go.kr

3, pp. 483-510, Jul. 1987. DOI: 10.1111/j.1540-6261.1987.tb04565.x

[13] A. S. Kyle, "Continuous Auctions and Insider Trading," Econometrica, Vol. 53, No. 6, pp. 1315-1335, Nov. 1985. DOI: 10.2307/1913210

[14] Y. Amihud, "Illiquidity and stock returns: cross-section and time-series effects," Journal of Financial Markets, Vol. 5, No. 1, pp. 31-56, Jan. 2002. DOI: 10.1016/s1386-4181(01)00024-6

[15] F. X. Diebold, and K. Yilmaz, "Better to give than to receive: Predictive directional measurement of volatility spillovers," International Journal of Forecasting, Vol. 28, No. 1, pp. 57-66, Jan. 2012. DOI: 10.1016/j.ijforecast.2011.02.006

[16] J. Baruník, and T. Křehlík, "Measuring the Frequency Dynamics of Financial Connectedness and Systemic Risk," Journal of Financial Econometrics, Vol. 16, No. 2, pp. 271-296, Mar. 2018. DOI: 10.1093/jjfinec/nby001

[17] B.-H. Kim, H. Kim, and B.-S. Lee, "Spillover effects of the U.S. financial crisis on financial markets in emerging Asian countries," International Review of Economics & Finance, Vol. 39, pp. 192-210, Sep. 2015. DOI: 10.1016/j.iref.2015.04.005

[18] B. N. Jeon, and B.-S. Jang, "The linkage between the US and Korean stock markets: the case of NASDAQ, KOSDAQ, and the semiconductor stocks," Research in International Business and Finance, Vol. 18, No. 3, pp. 319-340, Sep. 2004. DOI: 10.1016/j.ribaf.2004.04.006

[19] T. L. D. Huynh, E. Hille, and M. A. Nasir, "Diversification in the age of the 4th industrial revolution: The role of artificial intelligence, green bonds and cryptocurrencies," Technological Forecasting and Social Change, Vol. 159, 120188, Oct. 2020. DOI: 10.1016/j.techfore.2020.120188

[20] O. Kwon, and J.-S. Yang, "Information flow between composite stock index and individual stocks," Physica A: Statistical Mechanics and its Applications, Vol. 387, No. 12, pp. 2851-2856, May 2008. DOI: 10.1016/j.physa.2008.01.007

[21] P. Yue, Y. Fan, J. A. Batten, and W.-X. Zhou, "Information Transfer between Stock Market Sectors: A Comparison between the USA and China," Entropy, Vol. 22, No. 2, 194, Feb. 2020. DOI: 10.3390/e22020194

[22] S. Behrendt, T. Dimpfl, F. J. Peter, and D. J. Zimmermann, "RTransferEntropy — Quantifying information flow between different time series using effective transfer entropy," SoftwareX, Vol. 10, 100265, Jul. 2019. DOI: 10.1016/j.softx.2019.100265

[23] I. Choi, W. Yun, and W. C. Kim, "Improving data efficiency for analyzing global exchange rate fluctuations based on nonlinear causal network-based clustering," Annals of Operations Research, Vol. 352, No. 3, pp. 745-780, Sep. 2025. DOI: 10.1007/s10479-022-05101-8

[24] C. W. J. Granger, "Investigating Causal Relations by Econometric Models and Cross-spectral Methods," Econometrica, Vol. 37, No. 3, pp. 424-438, Aug. 1969. DOI: 10.2307/1912791

[25] C. Diks, and V. Panchenko, "A new statistic and practical guidelines for nonparametric Granger causality testing," Journal of Economic Dynamics and Control, Vol. 30, No. 9-10, pp. 1647-1669, Sep. 2006. DOI: 10.1016/j.jedc.2005.08.008

[26] L. Barnett, A. B. Barrett, and A. K. Seth, "Granger Causality and Transfer Entropy Are Equivalent for Gaussian Variables," Physical Review Letters, Vol. 103, No. 23, 238701, Dec. 2009. DOI: 10.1103/physrevlett.103.238701

[27] R. Cont, "Empirical properties of asset returns: stylized facts and statistical issues," Quantitative Finance, Vol. 1, No. 2, pp. 223-236, Feb. 2001. DOI: 10.1080/713665670

[28] Y. Benjamini, and Y. Hochberg, "Controlling the False Discovery Rate: A Practical and Powerful Approach to Multiple Testing," Journal of the Royal Statistical Society Series B: Statistical Methodology, Vol. 57, No. 1, pp. 289-300, Jan. 1995. DOI: 10.1111/j.2517-6161.1995.tb02031.x

[29] J. G. MacKinnon, and H. White, "Some heteroskedasticity-consistent covariance matrix estimators with improved finite sample properties," Journal of Econometrics, Vol. 29, No. 3, pp. 305-325, Sep. 1985. DOI: 10.1016/0304-4076(85)90158-7

[30] H. R. Künsch, "The Jackknife and the Bootstrap for General Stationary Observations," Annals of Statistics, Vol. 17, No. 3, pp. 1217-1241, Sep. 1989. DOI: 10.1214/aos/1176347265

[31] F. X. Diebold, and R. S. Mariano, "Comparing Predictive Accuracy," Journal of Business & Economic Statistics, Vol. 13, No. 3, pp. 253-263, Jul. 1995. DOI: 10.1080/07350015.1995.10524599

[32] I. Choi, "Déjà Vu in Iridescent Bloom: Bottom-Up Place Branding in the Complex Adaptive Reception of a RESCENE Member's Personal YouTube Channel," Systems, Vol. 14, No. 9, 1155, Sep. 2026. DOI: 10.3390/systems14091155

[33] P. C. Tetlock, "Giving Content to Investor Sentiment: The Role of Media in the Stock Market," Journal of Finance, Vol. 62, No. 3, pp. 1139-1168, Jun. 2007. DOI: 10.1111/j.1540-6261.2007.01232.x

[34] T. Loughran, and B. McDonald, "When Is a Liability Not a Liability? Textual Analysis, Dictionaries, and 10-Ks," Journal of Finance, Vol. 66, No. 1, pp. 35-65, Feb. 2011. DOI: 10.1111/j.1540-6261.2010.01625.x

[35] S. Lim, H. Ahn, T. Lee, G. Kim, S. Lim, and I. Choi, "Dynamic risk budgeting via large language models: A context-aware framework for adaptive portfolio allocation," Applied Intelligence, Vol. 56, No. 15, 454, Oct. 2026. DOI: 10.1007/s10489-026-07501-w

[36] A. H. Huang, H. Wang, and Y. Yang, "FinBERT: A Large Language Model for Extracting Information from Financial Text," Contemporary Accounting Research, Vol. 40, No. 2, pp. 806-841, May 2023. DOI: 10.1111/1911-3846.12832

[37] M. Gentzkow, B. Kelly, and M. Taddy, "Text as Data," Journal of Economic Literature, Vol. 57, No. 3, pp. 535-574, Sep. 2019. DOI: 10.1257/jel.20181020

www.kci.go.kr

Authors



Insu Choi received the Ph.D. degree in Industrial and Systems Engineering from the Korea Advanced Institute of Science and Technology (KAIST), Korea. He is currently an Assistant Professor in the Department of Finance and Big Data at Gachon University, Seongnam, Korea. His research interests include financial data science, business analytics, and data-driven decision making.

www.kci.go.kr