

그래프 기반 자산선택의 분산효과 분석

Diversification Effects of Graph-Based Asset Selection

최인수(주저자)
Insu Choi(First Author)

가천대학교 경영대학 금융 빅데이터학부 조교수 Department of Finance and Big Data (ischoi@gachon.ac.kr)

본 연구는 네트워크 이론과 탐욕적 알고리즘을 결합한 자산선택 기법을 검토한다. 상관계수 행렬로부터 평면최대여과그래프(PMFG)를 구축하고, 그래프상 최단경로 거리를 활용한 최원선택(Farthest-First) 알고리즘으로 저상관 자산을 선별한다. 2014 - 2024년 미국 섹터 ETF 11종을 대상으로 표본의 이동 창 검증을 수행하고 6가지 벤치마크와 비교하였다. 핵심 기여는 자산선택과 비중결정을 분리하는 2단계 프레임워크(PMFG-MVO)의 유효성 실증에 있다. PMFG-FF는 본 설정에서 저상관 자산선택에 특화된 체계적 규칙으로 기능하며 전수조사에 근접한 준최적 성능을 보였다. 한편 상관관계 축소가 위험 지표 개선을 동반하지 않는 경향이 본 표본 하에서 관찰되었으며, 이는 실증적 관찰로 한정된다. PMFG-MVO는 저상관 유지와 위험 통제를 결합할 수 있음을 확인하였다. 본 연구는 제한적 유니버스에 기반한 탐색적 연구이며, 대규모 자산군에서의 재검증은 후속 과제로 남는다.

주제어: 평면최대여과그래프, 자산선택, 분산효과

This study examines an asset-selection method that combines network theory with a greedy algorithm. We construct a Planar Maximally Filtered Graph (PMFG) from the correlation matrix and select low-correlation assets using the Farthest-First (FF) algorithm based on graph-theoretic shortest-path distances. Using 11 U.S. sector ETFs over 2014 - 2024, we conduct rolling out-of-sample backtests and compare PMFG-FF against six benchmarks. The main contribution lies in the empirical validation of a two-stage framework (PMFG-MVO) that separates asset selection from weight determination. Within the present setting, PMFG-FF functions as a systematic rule specialized for low-correlation asset selection and exhibits near-optimal performance close to that obtained by exhaustive enumeration. Meanwhile, a tendency that correlation reduction is not accompanied by improvement in risk metrics was observed under the present sample, and this is confined to an empirical observation. We confirm that PMFG-MVO can combine low-correlation maintenance with risk control. This study is an exploratory investigation based on a limited universe, and revalidation on larger asset universes remains future work.

Keyword: Planar Maximally Filtered Graph, Asset Selection, Diversification

1. 서론

포트폴리오 구성에서 분산투자의 핵심은 자산 간 상관관계를 낮추는 데 있다. Markowitz(1952)의 평균-분산 모형이 이론적 토대를 제공한 이래, 상관관계가 낮은 자산들을 조합하면 동일한 기대수익에서 위험을 줄일 수 있다는 점은 널리 받아들여져 왔다. 그러나 실무에서는 거래비용, 관리 편의, 규제 등의 이유로 보유 종목 수에 제한을 두는 경우가 많고, 이른바 기수제약(cardinality constraint) 하에서 어떤 자산을 골라야 분산효과를 극대화할 수 있는지는 여전히 풀리지 않은 문제로 남아 있다.

기수제약 포트폴리오 최적화는 NP-hard 문제로 분류되어, 자산 수가 늘어나면 완전탐색이 사실상 불가능해진다(Chang et al., 2000). 이에 따라 유전 알고리즘, 타부 서치, 시뮬레이티드 어닐링 등 다양한 메타휴리스틱이 제안되었으나, 대부분 수익률이나 샤프비율 같은 성과지표를 목적함수로 삼는다. 그러나 분산효과의 원천인 상관관계 자체를 직접 겨냥한 접근은 상대적으로 드물다.

한편 금융 네트워크 분석 분야에서는 자산 간 상관관계를 그래프 구조로 변환하여 시장의 연결 특성을 파악하려는 시도가 이어져 왔다. Mantegna(1999)가 최소신장트리(MST)를 도입한 이후, Tumminello et al.(2005)은 평면최대여과그래프(PMFG)를 제안하여 MST보다 풍부한 연결 정보를 보존하면서도 잡음을 걸러내는 방법론을 제시하였다. 그러나 이러한 네트워크 분석 도구를 자산선택 단계에 직접 활용하여 분산효과를 개선하려는 시도는 드물다. 기존 연구는 주로 중심성 지표를 활용하거나(Peralta and Zareei, 2016), 군집화 결과를 기수제약에 통합하는 2단계 접근(Jiang et al., 2014)에 머물러 있다.

본 연구가 주목하는 선행연구의 공백은 다음과 같다. 첫째, 기수제약 최적화 연구의 상당수는 수익률 기반 목적함수에 치중해 왔으며, 상관관계 자체를 직접 목표로 삼는 접근은 상대적으로 제한적이다. 둘째, 네트워크 분석은 시장 구조 파악에는 널리 활용되어 왔으나, 그래프상 거리 정보를 자산선택 기준으로 직접 사용한 사례는 드물다. 셋째, 최근 제안된 위계적 위험균형(HRP; López de Prado, 2016)이나 최대 분산화(Maximum Diversification; Choueifaty and Coignard, 2008) 등 비전통적 포트폴리오 구축 방법론과 네트워크 기반 자산선택을 동일 조건에서 체계적으로 비교한 연구는 제한적이다. 본 연구는 이러한 공백에 주목하여 PMFG 위에서 최원선택(Farthest-First) 알고리즘을 적용하여 저상관 자산군을 선별하고, 6가지 벤치마크 및 1가지 변형(PMFG-MVO)과 체계적으로 비교하는 실증 분석을 수행한다.

특히 본 연구는 자산선택과 비중결정을 의도적으로 분리하여 분석한다. 이 분리는 본 연구의 핵심 기여인 PMFG-MVO 2단계 프레임워크의 출발점이다. 이론적으로, 포트폴리오 성과의 원천을 자산선택 효과와 비중배분 효과로 분해함으로써 각각의 기여도를 식별할 수 있다. 실무적으로, 비중 최적화를 수행하지 못하는 상황(예: 동일가중 제약이 있는 지수형 펀드, 규제상 비중 상한이 있는 연기금)에서도 자산선택만으로 분산효과를 확보할 수 있는지를 평가하는 것이 중요하다. 이를 위해 PMFG-FF로 자산을 선택한 뒤 동일가중을 부여하는 기본 설계에 더해, PMFG-FF 선택 후 최소분산 비중을 적용하는 2단계 변형(PMFG-MVO)을 추가 분석하여 자산선택과 비중결정의 상호작용을 검토하였다. 이 프레임워크는 PMFG-FF에 한정되지 않으며, 다양한 선택 규칙과 배분 규칙의 조합에 적용될 수 있는 범용적 연구 틀이다.

연구의 초점은 수익률이 아니라 분산효과 그 자체에 있다. 평균 상관계수, 분산화비율을 핵심 지표로 삼고, 샤프비율, 변동성, 최대낙폭, VaR, CVaR 등 위험-수익 지표도 종합 보고한다. 표본외(OOS) 검증, 전수조사 백분위 분석, Cohen's d 효과 크기, 거래비용 민감도, 자카드 유사도 기반 포트폴리오 안정성, 하위기간 강건성, 위기 국면 분석 등 다각적 검증을 통해 결과의 강건성을 점검한다.

본 논문의 구성은 다음과 같다. 제II장에서는 관련 선행연구를 검토하고, 제III장에서는 연구방법론을 설명한다. 제IV장에서는 실증분석 결과를 제시하며, 제V장에서 논의, 제VI장에서 결론을 제시한다.

II. 선행연구

2.1 기수제약 포트폴리오 최적화

포트폴리오에 포함할 자산 수를 제한하는 기수제약 문제는 Markowitz 모형의 실무적 확장으로 오랫동안 연구되어 왔다. Chang et al.(2000)은 NP-hard로 알려진 기수제약 평균-분산 문제를 혼합정수 이차계획(MIQP)으로 정식화하고, 유전 알고리즘, 시뮬레이티드 어닐링, 타부 서치 등 메타휴리스틱의 성능을 비교하였다. Woodside-Oriakhi et al.(2011)은 유전 알고리즘, 타부 서치, 시뮬레이티드 어닐링을 비교 분석하여 기수제약 효율적 프론티어 탐색의 벤치마크를 확장하였다. 이들 연구의 공통점은 목적함수가 주로 기대수익 극대화 또는 분산 최소화, 혹은 샤프비율 같은 위험조정수익률이라는 점이다. 상관관계 자체를 직접 목표로 삼기보다는, 최적화 과정에서 분산-공분산 행렬이 간접적으로 반영될 뿐이다.

2.2 금융 네트워크와 상관관계 분석

자산 간 상관관계를 그래프로 표현하려는 시도는 Mantegna(1999)의 최소신장트리(MST) 연구에서 본격화되었다. 상관계수를 거리로 변환한 뒤 MST를 구축하면, 시장의 계층적 구조가 드러나고 섹터별 군집화가 자연스럽게 나타난다. 그러나 MST는 $N-1$ 개의 간선만 남기므로 정보 손실이 크다. Tumminello et al.(2005)이 제안한 PMFG는 평면 그래프 조건을 만족하면서 $3N-6$ 개의 간선을 유지하여 MST보다 풍부한 연결 정보를 보존한다. Aste et al.(2010)은 2008-2009 신용경색 위기 기간의 상관구조 변화를 평면제약 그래프로 분석하였고, Pozzi et al.(2013)은 MST·PMFG의 주변부(peripheries) 자산에 투자하는 것이 분산효과 측면에서 우수함을 보였다. 최근 Choi and Kim(2025)은 섹터 기반 ETF에 대해 MST, PMFG, p-값 기반 네트워크 등 다양한 그래프 여과 기법을 적용하여 가격 기반 차이의 다면적 네트워크 구조를 분석하였으며, Choi et al.(2025)은 환율 자료에 전이 엔트로피 기반 비선형 인과 네트워크와 군집화를 결합하여 머신러닝 예측의 데이터 효율성을 개선하였다. 네트워크 분석을 포트폴리오 선택에 직접 활용한 연구로, Peralta and Zareei(2016)는 상관관계 기반 네트워크에서 자산의 중심성이 Markowitz 최적 비중과 음의 관계를 가짐을 이론적으로 규명하고 실증하였으며, Jiang et al.(2014)은 팩터모형 기반 군집화 결과를 기수제약 포트폴리오 선택에 통합하는 2단계 접근법을 시도하였다.

2.3 비전통적 포트폴리오 구축 방법론

최근 포트폴리오 이론에서는 전통적 MVO의 한계를 극복하기 위한 다양한 방법론이 제안되었다. López

de Prado(2016)의 위계적 위험균형(Hierarchical Risk Parity, HRP)은 상관관계 행렬로부터 덴드로그램을 구축한 뒤 군집 구조에 따라 비중을 재귀적으로 배분하는 방식으로, 공분산 행렬의 역행렬 계산이 불필요하여 추정 오차에 강건하다는 장점이 있다. HRP는 상관관계 행렬 기반 계층적 군집화(hierarchical clustering) 구조를 활용한다는 점에서 본 연구의 PMFG 기반 접근과 네트워크 활용이라는 공통분모를 갖지만, HRP는 비중결정에 초점을 맞추는 반면 본 연구는 자산선택에 초점을 맞춘다는 점에서 차별적이다.

Choueifaty and Coignard(2008)의 최대분산화(Maximum Diversification) 전략은 분산화비율(Diversification Ratio)을 직접 최대화하는 비중을 산출한다. 이는 상관관계 축소를 목적함수에 내재시킨다는 점에서 본 연구의 PMFG-FF와 유사한 철학을 공유하나, 자산선택이 아닌 비중 최적화를 통해 접근한다는 차이가 있다. 본 연구에서는 이들 방법론을 벤치마크로 설정하여, 네트워크 기반 자산선택의 상대적 위치를 다각적으로 평가한다.

국내 펀드 시장에서도 성과 결정요인과 효율성 평가에 관한 연구가 축적되어 왔다. 최현희와 김영준(2020)은 1999 - 2014년 결성된 375개 국내 벤처펀드를 대상으로 외부환경요인이 펀드 수익률에 미치는 영향을 실증 분석하였고, 권순학과 이상휘(2024)는 자료포락분석(DEA)을 활용하여 국내 ESG 주식형 펀드의 ESG 점수와 성과 간 효율성을 평가하였다. 송인욱·김용원·박영규(2021)는 코로나19 위기 국면에서 국내 주식형 펀드의 성과와 현금흐름을 분석하여 위기 시점에 펀드들이 시장 지수 대비 저조한 성과를 보였으며 강세장 구간에서 상대적 우위가 발현됨을 보고하였다. 한편 김민석·이도영·임우상·안태찬·최인수·김우창(2022)은 시스템 리스

크와 포트폴리오 이론의 관점에서 미국 ETF 시장에 암호화폐 지수가 신규 자산군으로 도입될 가능성을 분석하고, 샤프비율 최적화 결과를 근거로 기존 자산군과 유사한 역할을 수행할 수 있음을 확인하였다. 이들 연구가 펀드 단위 성과·위기 국면 분석과 ETF 시장 차원의 신규 자산 도입 가능성에 초점을 둔다면, 본 연구는 자산선택 단계에서 분산효과를 직접 겨냥하는 알고리즘적 접근을 제시한다는 점에서 차별된다.

2.4 분산효과 측정

분산효과를 수치화하는 방법으로는 여러 지표가 제안되어 왔다. 가장 직관적인 것은 포트폴리오 내 자산들 사이의 평균 상관계수이다. Choueifaty and Coignard(2008)가 제안한 분산화비율(Diversification Ratio)은 개별 자산 변동성의 가중평균을 포트폴리오 변동성으로 나눈 값으로, 1보다 클수록 분산효과가 존재함을 나타낸다. Statman(1987)은 분산투자의 한계효용이 체감함을 보여, 종목 수가 일정 수준을 넘으면 추가적인 분산효과가 미미해짐을 확인하였다. 이는 기수제약 상황에서 적은 수의 자산으로 얼마나 효율적으로 분산효과를 확보하느냐가 중요함을 시사한다.

기존 문헌을 종합하면, 기수제약 최적화 연구는 수익률 기반 목적함수에 집중해 왔고, 네트워크 분석은 시장 구조 파악에, 비전통적 방법론(HRP, 최대분산화)은 비중결정에 초점을 맞춰 왔다. 이 세 갈래를 결합하여 네트워크 기반 자산선택의 분산효과를 다중 벤치마크와 동일 조건에서 비교한 연구는 드물다.

III. 연구방법론

3.1 데이터

분석에는 미국 섹터 ETF 11종을 사용하였다. State Street Global Advisors의 Select Sector SPDR 시리즈로, S&P 500 지수를 구성하는 11개 GICS 섹터를 각각 추종한다. 분석 기간은 2014년 1월부터 2024년 12월까지 약 11년(132개월)이다. 일별 조정종가를 Yahoo Finance에서 수집하였으며, 로그수익률로 변환하였다. <표 1>은 분석 대상 ETF의 기초통계를 정리한 것이다.

3.2 상관계수 행렬과 PMFG 구축

N 개 자산의 수익률 시계열 r_{it} 로부터 Pearson 상관계수 행렬 $\rho = [\rho_{ij}]$ 를 산출한다. 상관계수를 유클리드 거리로 변환하기 위해 Mantegna(1999)의 거리 변환을 적용한다.

$$d_{ij} = \sqrt{2(1 - \rho_{ij})} \tag{1}$$

이 변환은 $\rho_{ij} = 1$ 이면 $d_{ij} = 0$, $\rho_{ij} = -1$ 이면 $d_{ij} = 2$, $\rho_{ij} = 0$ 이면 $d_{ij} = \sqrt{2}$ 가 되어 상관관계의 강도를 거리 공간에서 표현한다. 강건성 점검을 위해 Spearman 순위상관계수도 병행하였다. PMFG는 Tumminello et al.(2005)의 방법에 따라 구축한다. PMFG는 평면성 조건을 만족하면서 $3N - 6$ 개의 간선을 유지하는 여과 그래프로, $N = 11$ 인 경우 $3 \times 11 - 6 = 27$ 개의 간선을 갖는다. 이는 완전그래프 $\binom{11}{2} = 55$ 개 간선의 49%에 해당한다. $MST(N - 1 = 10$ 개 간선)보다 2.7배 많은 연결 정보를 보존하나, N 이 작아 여과 효과가 제한적일 수 있음을 감안해야 한다.

3.3 최원선택 알고리즘

PMFG 위에서 Dijkstra 알고리즘으로 모든 노드 쌍의 최단경로 거리 D_{ij} 를 계산한 뒤, Gonzalez (1985)의 최원선택 알고리즘을 적용한다. 절차는 다

<표 1> 분석 대상 섹터 ETF 기초통계

티커	섹터	연환산 수익률(%)	연환산 변동성(%)	샤프비율
XLF	금융	10.70	24.50	0.44
XLK	기술	19.25	26.51	0.73
XLV	헬스케어	9.07	17.60	0.52
XLI	산업재	10.78	21.98	0.49
XLX	임의소비재	11.77	24.31	0.48
XLP	필수소비재	9.26	15.92	0.58
XLE	에너지	6.52	33.60	0.19
XLU	유틸리티	9.50	21.34	0.45
XLB	소재	7.56	22.54	0.34
XLRE	부동산	7.20	23.14	0.31
XLC	커뮤니케이션	11.12	23.18	0.48

주: 2014.1 - 2024.12 전체 기간 기준. 샤프비율은 무위험이자율 0% 가정.

음과 같다.

[단계 1] 초기 자산 s_1 선택:

$$s_1 = \arg \max_{i,j} D_{ij} \quad (2)$$

[단계 2] t 번째 자산 선택 ($t = 2, \dots, k$):

$$s_t = \arg \max_{i \in S} \min_{j \in S} D_{ij} \quad (3)$$

여기서 $S = \{s_1, \dots, s_{t-1}\}$ 는 이미 선택된 자산 집합이다. 본 연구의 구현에서는 알고리즘의 안정성을 확보하기 위해 시드 선정 절차를 일부 보완하였다.

3.4 비교 방법

제안 방식의 분산효과를 다각적으로 평가하기 위해 6가지 벤치마크와 1가지 변형을 설정하였다. 비교군의 구성은 자산선택 효과와 비중결정 효과를 분리해 식별하고, 네트워크 기반 집근을 비전통적 포트폴리오 방법론과 동일 조건에서 대비하기 위함이다.

3.4.1 탐욕적 평균-분산 최적화 (Greedy MVO)

직전 12개월 데이터로 기대수익률 벡터 μ 와 공분산 행렬 Σ 를 추정한다. 이때, Σ 를 활용한 휴리스틱으로 자산을 선별한다. 최종적으로 선택된 k 개 자산에 대해 μ 에 의존하지 않는 최소분산(Global Minimum Variance) 비중을 비음 제약 하에 산출하여 부여한다.

3.4.2 평균-분산 자산선택 후 동일가중 (MVO-EW)

탐욕적 평균-분산 최적화와 동일한 절차로 자산을 선택하되, 비중은 동일가중($1/k$)을 부여한다. 이는

PMFG-FF와의 공정한 비교를 위한 것으로, 자산선택 효과만을 분리하여 평가할 수 있게 한다.

3.4.3 최소신장트리 기반 최원선택 (MST-FF)

PMFG 대신 MST를 구축한 뒤 동일한 최원선택 알고리즘을 적용한다. PMFG와 MST의 여과 수준 차이가 자산선택에 미치는 영향을 평가하기 위한 벤치마크이다. 비중은 동일가중을 부여한다.

3.4.4 위계적 위험균형 (HRP)

López de Prado(2016)의 위계적 군집화 아이디어에 기반한 변형이다. 상관관계 거리 행렬로부터 Ward 연결 덴드로그램을 구축한 뒤, 이를 k 개 군집으로 분할하고 각 군집에서 변동성이 가장 낮은 자산을 1개씩 선택하여 동일가중을 부여하였다. 이는 López de Prado(2016)의 채귀적 역분산 비중 배분과는 다른 변형으로, 자산선택 단계에서 군집 구조 활용 효과를 분리해 평가하기 위함이다.

3.4.5 최대분산화 (Maximum Diversification)

Choueifaty and Coignard(2008)의 분산화비율(Diversification Ratio) 개념을 참고한 자산선택 기준으로 활용하는 변형이다. 최종 비중은 동일가중을 부여하며, 분산화비율은 비중 산출이 아닌 자산선택 기준으로만 사용된다.

3.4.6 동일가중 (Equal-Weight)

모든 N 개 자산에 동일 비중 $1/N$ 을 부여한 포트폴리오이다. 기수제약이 없는 단순 분산투자의 기준선이다.

3.4.7 PMFG-MVO (2단계 변형)

PMFG-FF로 k 개 자산을 선택한 뒤, 선택된 자산들에 대해 제III장 4절 (1)의 최소분산 비중을 부여하는 2단계 접근법이다. 본 연구가 주목하는 변형으로, 자산선택(PMFG-FF)과 비중결정(최소분산 비중)의 결합이 저장관 유지와 위험 통제를 동시에 달성할 수 있는지를 검토한다.

3.5 표본의 검증과 재조정

과적합 위험을 통제하기 위해 표본내(in-sample)와 표본외(out-of-sample)를 분리한 이동 창 사후검증을 수행하였다. 매월 t 시점에서 직전 252거래일(약 12개월)을 표본내 기간으로 사용하여 상관계수 행렬 추정, PMFG 구축, 자산선택을 수행하고, 다음 달($t+1$) 수익률을 표본외 성과로 기록한다. 따라서 2014년은 초기 표본내 기간으로 사용되며, 실제 표본외 성과는 2015년 1월부터 2024년 12월까지 약 120개월이다.

3.6 성과 지표

분산효과와 위험-수익에 초점을 맞추어 다음 지표들을 산출한다. 평균 상관계수 $\bar{\rho}$ 는 선택된 k 개 자산의 쌍별 Pearson 상관계수 평균으로 정의한다. 연환산 변동성은 일별 수익률 표준편차에 $\sqrt{252}$ 를 곱하여 산출한다. 최대낙폭(MDD)은 누적수익률 곡선의 고점 대비 최대 하락폭으로, 누적수익 $C_t = \prod_{s=1}^t (1 + r_{p,s})$ 에 대해 $\min_t (C_t - \max_{sst} C_s) / \max_{sst} C_s$ 로 계산한다. VaR 5%와 CVaR 5%는 역사적 시뮬레이션 방식으로 산출하며, 각각 표본외 일별 수익률의 5%

분위수와 그 이하 평균의 음수이다. 샤프비율은 무위험이자율 r_f 를 0%로 가정하여 $(\mu_p - r_f) / \sigma_p$ 로 산출한다(여기서 μ_p 는 연환산 평균수익률, σ_p 는 연환산 변동성). 누적수익률은 $C_T = \prod_{s=1}^T (1 + r_{p,s}) - 1$ 로 정의한다.

3.7 통계적 검정과 효과 크기

방법 간 차이의 유의성은 Wilcoxon 부호순위검정(짜지어진 2-표본, 양측)으로 검정한다. 표본외 기간의 각 재조정 시점별 성과를 쌍으로 비교하며, 유의수준은 $\alpha = 0.05$ 이다. 실무적 유의성을 평가하기 위해 Cohen's d 효과 크기를 병행 보고한다.

$$d = \frac{X_1 - X_2}{s_p} \tag{4}$$

$$s_p = \sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}} \tag{5}$$

여기서 X_1, X_2 는 두 방법의 평균, s_1^2, s_2^2 는 분산, s_p 는 합동표준편차이다. Cohen(1988)의 기준에 따라 $|d| < 0.2$ 는 무시할 수 있는 효과, $0.2 \leq |d| < 0.5$ 는 작은 효과, $0.5 \leq |d| < 0.8$ 은 중간 효과, $|d| \geq 0.8$ 은 큰 효과로 해석한다. 한편 $N = 11$ 의 소규모 자산군에서는 조합 수가 $\binom{11}{k} \leq 462$ 로 제한적이므로, 모든 k 에 대해 전수조사를 수행하여 PMFG-FF 선택 조합이 전체 가능 조합 중 어느 백분위에 위치하는지를 확인하였다.

3.8 거래비용과 포트폴리오 안정성

월별 재조정에 수반되는 거래비용의 영향을 평가하기 위해, 편도 거래비용 $c = 0.5, 10, 20, 50$ basis points(bp)를 부과한 순 샤프비율을 산출하였다. 각 재조정 시점의 순수익률은 $r_{p,t}^{net} = r_{p,t} - c \cdot Turnover_t$ 로 계산한다. 포트폴리오 안정성은 자카드 유사도 $J(S_t, S_{t+1}) = |S_t \cap S_{t+1}| / |S_t \cup S_{t+1}|$ (S_t 는 시점 t 의 선택 자산 집합, $J=1$ 이면 완전 동일)와 회전율 $Turnover_t = \sum_i |w_{i,t} - w_{i,t-1}|$ 로 측정하였다.

1.232)를 크게 상회하며, 최대분산화(0.393)와 가장 유사한 상관계수를 보인다. 변동성에서는 평균-분산 최적화와 PMFG-MVO가 가장 낮고(둘 다 0.132), MDD에서는 MST-FF(-0.034)와 PMFG-MVO(-0.036)가 가장 양호하다. 주목할 점은 PMFG-MVO가 PMFG-FF와 동일한 자산을 선택하면서도(상관계수 0.414), 최소분산 비중 적용으로 변동성(0.132)과 MDD(-0.036)를 평균-분산 최적화 수준으로 개선하였다는 것이다. 반면 샤프비율 기준으로는 동일가중(1.48)·HRP(1.44)·최대분산화(1.43)·MVO-EW(1.38)가 PMFG-FF(1.30)·평균-분산 최적화(1.25)·PMFG-MVO(1.23)를 상회하여, PMFG-FF의 성과 위치가 종합 성과 기준 중위권임을 확인할 수 있다.

IV. 실증 결과 분석

4.1 표본의 성과 개요

〈표 2〉는 2015 - 2024년 표본의 기간의 전체 방법별 성과를 요약한 것이다. 모든 k 를 통합한 평균±표준편차이다.

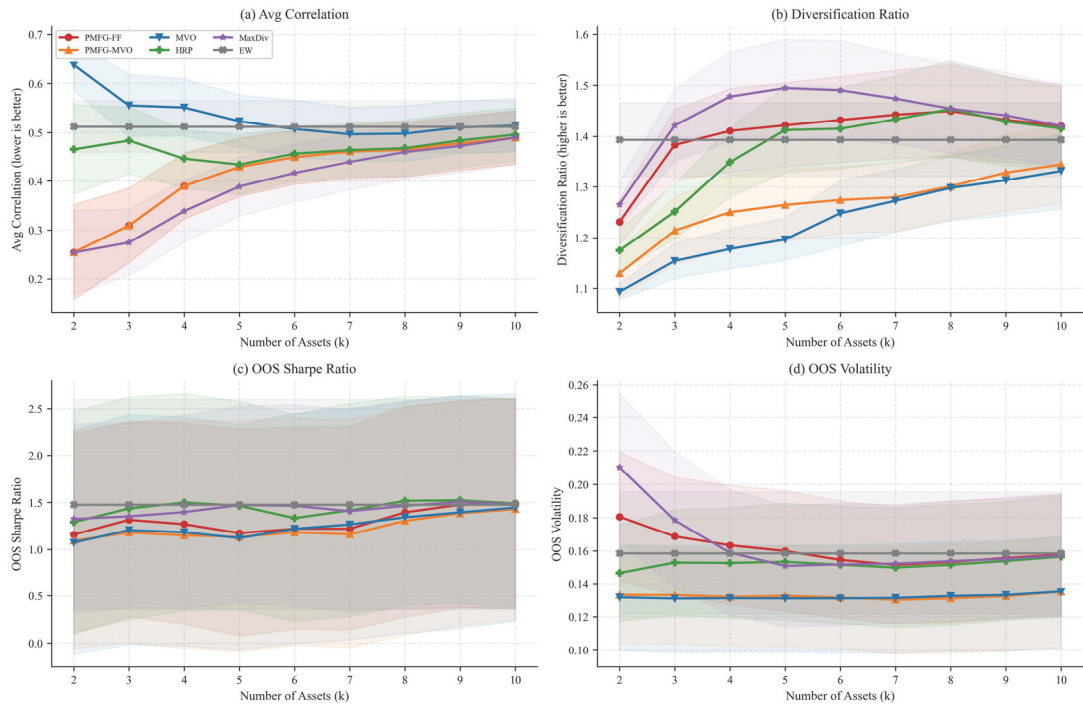
〈표 2〉에서 PMFG-FF는 평균 상관계수(0.414)와 분산화비율(1.403)에서 평균-분산 최적화(0.533,

4.1.1 k값별 표본의 성과

〈그림 1〉은 k 값별 주요 성과 지표를 7가지 방법과 함께 시각화한 것이다. 각 패널은 평균 상관계수, 분산화비율, 샤프비율, 변동성을 나타내며, 음영은 재조정 시점 간 변동을 반영한 평균±0.3σ 범위이다. 그림 1(a)에서 PMFG-FF(빨간 실선)는 모든 k 에서 탐색적 평균-분산 최적화(파란 삼각)보다 낮은 상관계수

〈표 2〉 표본의 성과 요약 (2015 - 2024, 전체 k 통합; PMFG-FF는 Pearson 기준)

방법	샤프	수익률	변동성	MDD	평균상관	DR	Var5%	CVar5%
PMFG-FF	1.30±3.60	0.009±0.053	0.161±0.121	-0.044±0.048	0.414±0.231	1.403±0.271	-0.015±0.013	-0.019±0.015
PMFG-MVO	1.23±3.98	0.007±0.042	0.132±0.104	-0.036±0.040	0.414±0.231	1.265±0.233	-0.012±0.011	-0.016±0.013
MVO	1.25±4.04	0.008±0.043	0.132±0.108	-0.037±0.042	0.533±0.191	1.232±0.197	-0.012±0.012	-0.016±0.014
MVO-EW	1.38±3.90	0.009±0.046	0.143±0.111	-0.040±0.043	0.533±0.191	1.309±0.230	-0.013±0.012	-0.017±0.014
MST-FF	1.27±3.75	0.010±0.040	0.134±0.093	-0.034±0.033	0.863±0.202	1.049±0.078	-0.011±0.009	-0.015±0.011
HRP	1.44±3.76	0.009±0.050	0.152±0.114	-0.041±0.045	0.466±0.211	1.371±0.270	-0.014±0.013	-0.018±0.014
MaxDiv	1.43±3.53	0.010±0.053	0.163±0.127	-0.044±0.051	0.393±0.224	1.438±0.284	-0.015±0.014	-0.019±0.016
EW	1.48±3.71	0.010±0.051	0.159±0.122	-0.043±0.047	0.512±0.176	1.393±0.241	-0.015±0.013	-0.018±0.015



〈그림 1〉 k값별 표본의 성과 지표

를 기록하였다. $k=2$ 에서 PMFG-FF의 상관계수는 약 0.26으로 평균-분산 최적화(0.64)의 절반 이하이다. 최대분산화(보라색 별)는 평균 상관계수에서 가장 낮은 수준을 보이며, PMFG-FF가 그에 근접한다. (b)에서 분산화비율은 최대분산화가 $k=4-7$ 구간에서 가장 높고, PMFG-FF가 그에 근접하여 두 번째 수준을 유지하다가 $k=8$ 이상에서 두 방법이 유사한 수준에 도달한다. (c) 샤프비율에서는 방법 간 차이가 크지 않으나, 동일가중(회색)이 안정적으로 높은 편이다. (d) 변동성에서는 평균-분산 최적화가 일관되게 가장 낮고, PMFG-FF는 소규모 k 에서 다소 높은 변동성을 보인다.

4.2 상관계수 감소 효과 분석

PMFG-FF는 평균-분산 최적화 대비 $k=2$ 에서 60.1%, $k=3$ 에서 44.3%의 상관계수 감소를 달성하였다. MST-FF 대비로는 모든 k 에서 43 - 71%의 감소를 보여, PMFG의 추가 간선 정보가 저상관 선택 기준에서 MST 대비 우위를 제공함을 확인하였다. HRP 대비로는 $k=2-4$ 에서 유의미한 감소(13 - 45%)가 나타났으나, $k \geq 5$ 에서는 차이가 1 - 2%로 축소되었다. 최대분산화는 분산화비율 최대화를 목적으로 함수로 삼으므로 PMFG-FF보다 낮은 상관계수를 달성하는 k 구간($k=3-9$)이 존재하나, 그 차이는 15% 이내이다.

4.2.1 전수조사 백분위 분석

N=11의 소규모 자산군에서는 가능한 조합 수가 $C(11,k) \leq 462$ 로 전수조사가 가능하다. <표 3>은 각 k에서 모든 조합의 평균 상관계수를 산출하고, PMFG-FF 선택 조합이 어느 백분위에 위치하는지를 정리한 것이다.

<표 3>과 <그림 2>에서 PMFG-FF는 모든 k에서 평균 88 - 96 백분위에 위치하며, k=2 (87.7)를 제외하면 90 백분위 이상을 안정적으로 달성하였다. 최적 대

비 값은 k가 커질수록 감소하여, k=8 이상에서는 0.01 미만이다. 이는 $O(kN)$ 시간복잡도의 탐욕적 알고리즘이 전수조사에 근접한 성능을 달성함을 보여준다. 다만 이 준최적 성능은 $C(11,k) \leq 462$ 의 제한된 조합 공간에서의 결과이며, 대규모 자산군에서도 유사한 준최적성이 유지되는지는 본 연구로 판단하기 어렵다.

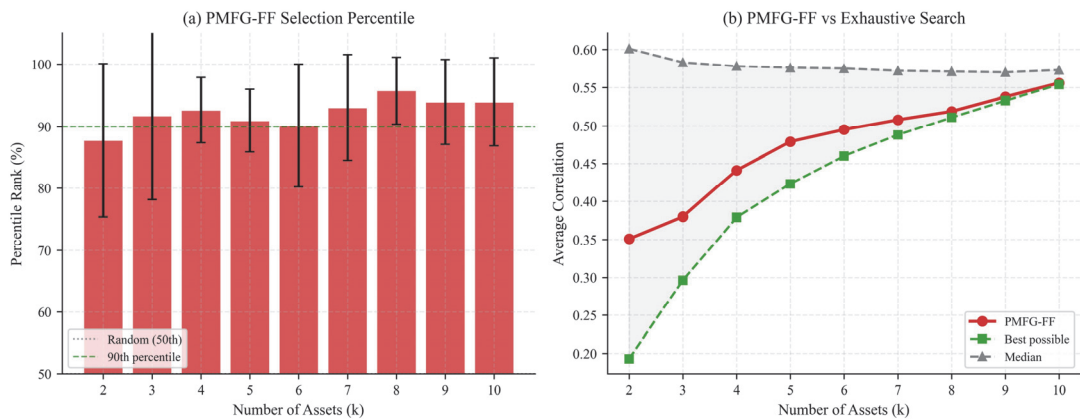
4.2.2 효과 크기 분석 (Cohen's d)

본 표본 규모에서는 통계적 검정력이 제한적이며 통

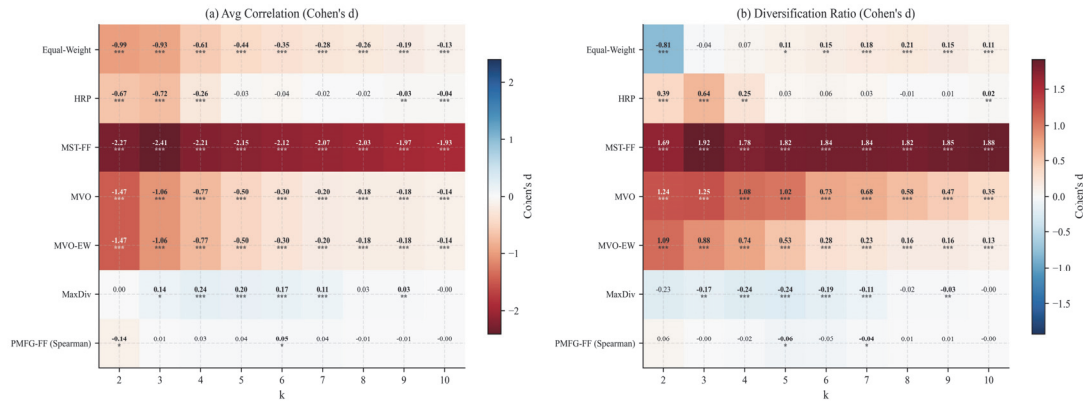
<표 3> 전수조사 백분위 분석

k	C(N,k)	PMFG-FF	최적	중앙값	백분위 평균	백분위 표준편차	최적대비 갭
2	55	0.351	0.193	0.601	87.7	12.4	0.158
3	165	0.380	0.296	0.583	91.7	13.6	0.083
4	330	0.441	0.379	0.578	92.6	5.2	0.062
5	462	0.479	0.423	0.576	90.9	5.0	0.056
6	462	0.495	0.460	0.575	90.1	9.9	0.035
7	330	0.508	0.488	0.572	93.0	8.5	0.021
8	165	0.519	0.511	0.571	95.8	5.4	0.009
9	55	0.538	0.533	0.570	93.9	6.8	0.005
10	11	0.556	0.554	0.573	93.9	7.1	0.002

주: 백분위는 낮은 상관계수를 높은 백분위로 기록. 최적=전수조사 중 최저 상관계수 조합.



<그림 2> 전수조사 백분위 및 최적 대비 비교



〈그림 3〉 Cohen's d 효과 크기 히트맵: (a) 평균 상관계수, (b) 분산화비율

계적 유의성만으로는 실무적 함의를 판단하기 어려우므로, Cohen's d 효과 크기를 산출하였다.

〈그림 3〉(a)에서 PMFG-FF 대 평균-분산 최적화의 Cohen's d는 $k=2$ 에서 -1.47 로 매우 큰 효과 ($|d| > 0.8$)를 보이며, $k=10$ 에서도 -0.14 로 무시할 수 있는 수준에 머문다. MST-FF 대비로는 모든 k 에서 $|d| > 1.9$ 로 매우 큰 효과가 나타나, PMFG가 MST보다 자산선택에서 뚜렷한 우위를 가짐을 확인하였다. (b) 분산화비율에서 PMFG-FF는 평균-분산 최적화 대비 $k=2-6$ 에서 Cohen's d $0.73-1.25$ 로 큰 효과를 보인다. 반면 최대분산화는 분산화비율에서 PMFG-FF보다 우위를 보이는데, 이는 최대분산화가 분산화비율을 직접 최대화하는 방법이므로 당연한 결과이다.


4.3 위험-수익 지표 분석

연도별 표본의 평균 샤프비율을 살펴보면 시장 국면에 따른 변동이 크다. 2019년과 2024년 강세장에서는 대부분의 방법이 평균 1.8 이상의 샤프비율을 기록한 반면, 2022년 하락장에서는 방법 간 차이가 축

소되었다. 전반적으로 샤프비율의 표본 분산이 커서 방법 간 통계적으로 유의한 차이는 관찰되지 않았다.

〈표 2〉의 위험 지표를 보면 변동성에서는 평균-분산 최적화와 PMFG-MVO가 0.132로 가장 낮고, MDD에서는 MST-FF(-0.034) · PMFG-MVO(-0.036)가, VaR · CVaR에서는 MST-FF · PMFG-MVO · 평균-분산 최적화가 양호한 수준을 보인다. PMFG-FF는 소규모 k 에서 위험이 다소 높으나 k 가 커질수록 수렴하며, PMFG-MVO는 평균-분산 최적화와 거의 동일한 위험 수준을 달성한다.

〈그림 4〉에서 PMFG-MVO는 동일가중과 HRP 대비 MDD, VaR, CVaR에서 모두 양의 Cohen's d를 보이며, 대부분의 셀에서 $p < 0.001$ 수준의 통계적 유의성이 확인된다. 평균-분산 최적화와의 비교에서는 대부분 $|d| < 0.05$ 로 차이가 미미하여, PMFG-FF의 자산선택 후 최소분산 비중을 적용하면 평균-분산 최적화 수준의 위험 통제가 가능함을 확인하였다. 이는 자산선택과 비중결정의 분리 프레임워크가 본 표본·설계 하에서 실무적으로 유효하게 작동할 수 있음을 시사한다.



〈그림 4〉 PMFG-MVO vs 벤치마크: 위험 지표 Cohen's d

4.4 거래비용 및 포트폴리오 안정성

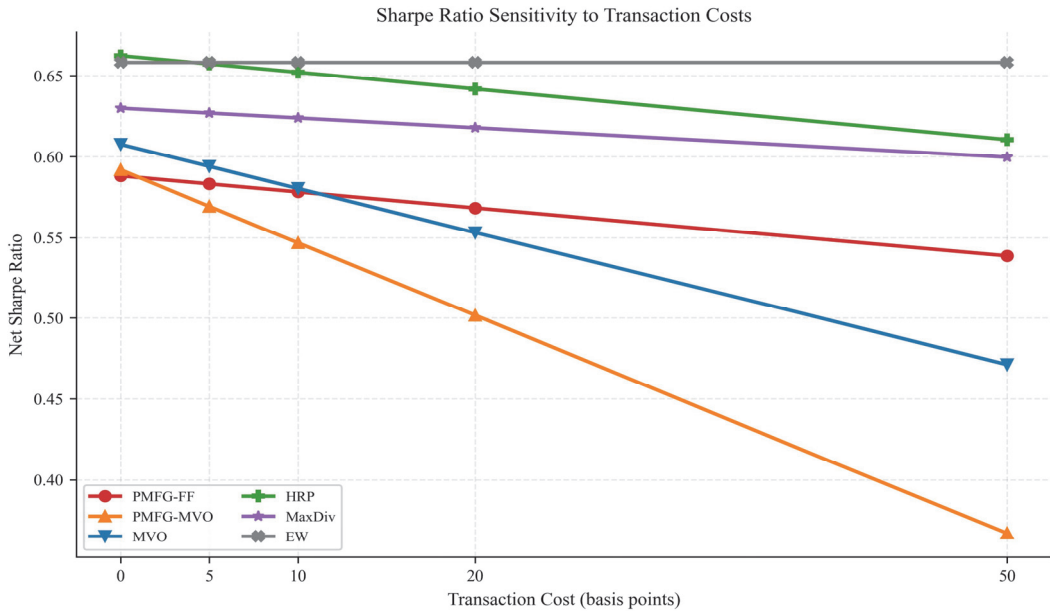
〈그림 5〉에서 PMFG-FF는 거래비용 0bp에서 50bp로 확대되어도 순 샤프비율이 0.588에서 0.539로 완만하게 하락하여 최적화 기반 방법(평균-분산 최적화, PMFG-MVO) 대비 낮은 민감도를 보인다. 그러나 단순 규칙 기반 방법(동일가중 0.658, HRP 0.611, 최대분산화 0.600)과 비교하면 50bp 시나리오에서의 순 샤프비율이 여전히 열위에 있다. 즉 “최적화 기반 방법 내에서의 상대적 안정성”은 확인되나, 전체 비교 대상을 고려한 “거래비용 환경에서의 압도적 우위”는 성립하지 않는다. PMFG-MVO는 비중 최적화로 인한 회전을 증가로 50bp에서 0.367까지 급락하여, 고비용 환경에서 2단계 접근법의 실무적 한계가 확인된다. 동일가중은 재조정이 거의 불필요하여 거래비용의 영향이 미미하다. 참고로 그림 5의 순 샤프비율은 거래비용을 차감한 월별 표본의 수익률 시계열에 $\times 12$, $\times \sqrt{12}$ 연환산을 적용하여 산출한 단일 값으로, 원도별 일간 샤프를 평균한 표 2의 샤프비율과는 산정 방식·단위가 달라 직접 비교 시 유의해야 한다.

4.4.1 포트폴리오 안정성

PMFG-FF의 자카드 유사도는 $k=3$ 에서 0.91, 전체 평균 약 0.88로, 연속 두 달의 선택 자산이 88% 이상 겹친다. 평균-분산 최적화(0.86 - 0.97)보다는 다소 낮으나, HRP(0.81 - 0.98) 및 MST-FF (0.80 - 0.83)와 유사한 수준이다. 회전율은 $k=4$ 에서 최대 0.145이나 $k \geq 8$ 에서 0.05 이하로 안정화된다. MST-FF는 $k \geq 3$ 에서 0.167의 일정한 회전율을 보이는 반면, PMFG-FF는 k 가 커질수록 회전율이 감소하는 패턴을 보인다.

4.5 강건성 분석

표본외 기간을 전반기(2015 - 2019)와 후반기(2020 - 2024)로 분리하여 비교하면, 평균 상관관계수에서 PMFG-FF는 두 기간 모두 평균-분산 최적화보다 낮은 위치를 유지하여 후반기에도 상관관계수 축소 효과가 일관된다. 분산화비율은 두 기간 모두 높은 수준을 유지하나 후반기에서 다소 감소하며, 샤프비율은 후반기에서 모든 방법이 하락하나 상대적 순위는 유지된다. 최대낙폭은 2020년 코로나 충격과 2022



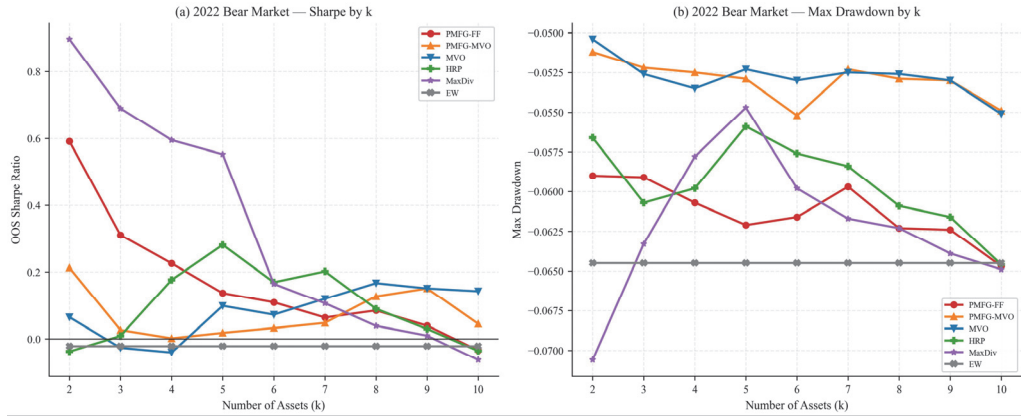
〈그림 5〉 거래비용 민감도: 순 샤프비율

년 하락장의 영향으로 후반기에서 심화된다. 전반기 대비 후반기 감쇠율을 보면 상관계수에서 PMFG-FF는 $k=2$ 에서 -33%로 감쇠가 가장 크고 $k \geq 6$ 에서는 -14% 수준으로 안정화되며, 평균-분산 최적화는 -8 - -12%로 상대적으로 작은 감쇠를 보인다. 변동성에서는 두 방법 모두 후반기에서 10 - 15% 증가하나 방법 간 차이는 크지 않다.

4.5.1 2022년 하락장 분석

송인옥·김용원·박영규(2021)는 위기 국면에서 펀드 성과가 시장 대비 저조하고 강세장에서 상대적 우위가 발현됨을 보고한 바 있다. 본 연구의 2022년 하락장 분석은 같은 맥락에서 자산선택 단계의 저상관 구성이 하락장 국면의 위험-수익 프로파일에 어떻게 작용하는지를 보여 준다.

〈그림 6〉은 2022년 하락장에서의 방법별 성과를 보여준다. (a) 샤프비율에서 PMFG-FF는 $k=2$ 에서 0.59로 최대분산화(0.89)에 이어 두 번째로 높은 성과를 보이며, 평균-분산 최적화·HRP 등 0 부근에 머무는 다른 방법보다 확연히 양호하다. $k \leq 4$ 구간에서 PMFG-FF의 저상관 선택이 하락장 방어에 기여한 것으로 해석된다. (b) 최대낙폭에서는 MST-FF가 $k \leq 4$ 에서 가장 얇은 낙폭을 보이며, 평균-분산 최적화·MVO-EW·PMFG-MVO도 그에 근접한다. PMFG-FF는 -0.059 - -0.065 범위로 동일가중과 비슷한 수준에 머문다. 하락장에서 PMFG-FF의 저상관 선택은 샤프비율 개선에는 기여하나, 최대낙폭 완화에는 제한적 효과를 보인다.



〈그림 6〉 2022년 하락장: (a) 샤프비율, (b) 최대낙폭

4.5.2 위험-수익 상충 관계

모든 방법과 k 값의 조합을 변동성-샤프비율 공간에서 분석하면, 평균-분산 최적화와 PMFG-MVO가 저변동성 영역에 군집하고, PMFG-FF와 최대분산화는 고변동성 영역에 위치하나 샤프비율은 유사한 수준이다. 이는 PMFG-FF가 변동성 축에서는 불리하나 수익률 축의 보상이 그 열위를 일부 상쇄함을 시사한다. 동일가중은 중앙에 위치하여 안정적 벤치마크 역할을 한다.

4.6 종합 순위

〈표 4〉에서 종합 순위 기준 동일가중, HRP, MST-FF가 공동 1위(4.4)이고, PMFG-FF는 5.6 - 6.1로 중위권에 해당한다. 이는 본 연구 설정에서 PMFG-FF가 “전반적으로 우수한 방법”이 아니라 “상관계수·분산화비율이라는 특정 목적에 특화된 규칙”임을 수치적으로 보여준다. 상관계수와 분산화비율만을 기준으로 하면 최대분산화(1위)와 PMFG-FF(2-3위)가 두드러지며, 위험 통제가 목적이면 평균-분산 최적화,

〈표 4〉 방법별 지표 순위 및 종합 순위

방법	샤프	수익률	변동성	MDD	상관	DR	CVaR	종합
EW	1	2	6	6	6	4	6	4.4
HRP	2	4	5	5	5	5	5	4.4
MST-FF	7	1	3	1	9	9	1	4.4
MaxDiv	3	3	9	8	1	1	9	4.9
MVO-EW	4	5	4	4	7.5	6	4	4.9
PMFG-MVO	9	9	2	2	2.5	7	3	4.9
MVO	8	8	1	3	7.5	8	2	5.4
PMFG-FF(S)	5	7	7	7	4	2	7	5.6
PMFG-FF(P)	6	6	8	9	2.5	3	8	6.1

주: 1=최우수. 종합순위는 7개 지표의 평균 순위. (P)=Pearson, (S)=Spearman.

PMFG-MVO, MST-FF가 우위이다. PMFG-MVO는 종합 4.9로 위험 지표(변동성·MDD·CVaR)에서는 상위권을 기록하나 수익성 지표(샤프·수익률)에서는 하위에 위치하여, 자산선택-비중결정 분리 프레임워크가 위험 통제에 특화된 결과를 산출함을 보여준다.

V. 논의

5.1 핵심 결과와 상관-위험 분리에 관한 해석

본 표본에서 PMFG-FF는 상관관계 축소 측면에서 비교적 일관된 결과를 보였다. 모든 k 에서 평균-분산 최적화 대비 낮은 상관계수를 기록하였고(Cohen's $d=1.47$ 에서 -0.14), 전수조사 상위 88-96 백분위에 위치하였다. 이는 PMFG의 그래프 거리 정보가 상관구조를 비교적 효과적으로 반영하며, 최원선택 알고리즘이 전수조사에 근접한 성능을 달성할 수 있음을 시사한다. 다만 이 성능은 제한된 조합 공간에서 관찰된 것으로, 대규모 자산군에서의 준최적성은 후속 검증을 필요로 한다.

한편 본 표본·설계 하에서 상관관계 축소가 위험 지표 개선을 자동으로 동반하지는 않는 경향이 관찰되었다. PMFG-FF는 상관계수와 분산화비율에서 평균-분산 최적화를 앞서지만, 변동성·MDD·VaR에서는 뒤진다. 이를 설명할 수 있는 한 가지 구조적 해석은 분산 분해에서 찾을 수 있다. 포트폴리오 분산은 개별 자산의 분산 기여분과 자산 간 공분산 기여분의 합으로 분해되는데, PMFG-FF는 그래프 거리 기반의 자산선택을 통해 공분산 기여분(자산 간 상관관계)을 줄이는 데 집중하는 반면, 개별 분산 기여분(자산

자체의 변동성)에 대해서는 직접적 통제력이 없다. 따라서 에너지(XLE, 변동성 33.6%)나 기술(XLK, 26.5%) 등 고변동성 섹터가 그래프상 “멀리” 위치하여 선택될 수 있고, 이는 공분산 축소의 이득을 상쇄할 수 있다. 반면 평균-분산 최적화는 공분산 행렬 전체를 활용하여 σ_p^2 를 직접 최소화하므로, 개별 변동성과 상관관계를 동시에 반영한다. 이 해석은 본 실증에 대한 사후적 설명이며, 다른 자산군에서의 재현성은 별도의 검증이 필요하다.

이 관찰은 본 연구 설정에서 분산효과(상관관계 축소)와 위험 감소가 항상 동치로 취급되지 않을 수 있음을 보여주며, 동시에 PMFG-MVO 2단계 접근법의 경험적 근거를 제공한다. 즉 PMFG-FF가 공분산의 비대각 성분(상관관계)에, 평균-분산 최적화가 대각 성분(개별 분산)과 비중 구조에 대응하는 상호보완적 역할 분담이 본 표본에서 작동할 수 있음을 시사한다.

5.2 연구의 한계와 후속 연구 방향

본 연구의 결과는 다음과 같은 본질적 한계 하에서 해석되어야 한다. 이러한 한계는 결과의 일반화 범위를 제약하는 설계 조건이자, 동시에 후속 연구의 진전 방향을 시사하는 지점이기도 하다.

첫째, 자산 수가 $N=11$ 에 그친다는 점이다. 이로 인해 PMFG의 간선 수가 27개로 완전그래프의 49% 수준에 머물러 여과 효과가 제한적으로만 작동하며, 기수제약 문제의 본질적 어려움 - 대규모 자산군에서의 NP-hard 결합 폭증 - 이 본 설정에서는 충분히 드러나지 않는다. $C(11,k) \leq 462$ 에 불과한 조합 공간에서는 휴리스틱의 확장성이 본격적으로 시험되지 않기 때문에, 본 연구의 결과는 “방법론의 일반적 유효성”을 입증한 것이 아니라 “소규모 섹터 유니버스에서의 탐색적 가능성 제시”에 한정해 해석하는 것이

적절하다. 다만 이 제한된 환경 덕분에 전수조사가 가능하였고, 그 결과 알고리즘의 절대적 성능을 상위 88 - 96 백분위 수준에서 직접 검증할 수 있었다는 점은 본 설계가 갖는 부수적 이점이라 할 수 있다.

둘째, 자산군이 미국 섹터 ETF로 단일하게 구성되었다는 점이다. 섹터 ETF는 그 자체로 내부적으로 분산된 상품이므로 개별 종목으로 구성된 포트폴리오와는 상관구조가 상이할 가능성이 크며, 따라서 본 연구의 결과를 개별 주식이나 다중 자산군 등 이질적 자산군으로 그대로 외삽하기에는 무리가 따른다.

셋째, 거래환경 모델링과 알고리즘의 근사성에서 비롯되는 한계이다. 거래비용 민감도 분석은 수행하였으나 슬리피지, 호가 스프레드, 시장 충격 등 시장미시구조 효과와 공매도 제약, 최소거래단위 등 실무적 제약은 반영하지 못하였다. 알고리즘 측면에서도 PMFG-FF는 2-근사 알고리즘이어서 전역 최적성이 보장되지 않고 전수조사 대비 일정한 최적 갭이 존재하는데, 이는 $O(kN)$ 의 시간복잡도라는 계산 효율성과의 불가피한 상충 관계로 이해할 수 있다.

넷째, 제V장 1절에서 제시한 구조적 설명이 추론적 성격을 갖는다는 점이다. 분산 분해에 기반한 해석은 본 표본에 정합적인 하나의 가능성일 뿐 일반 명제로 확장될 수 있는 것은 아니다. 다양한 자산군과 표본 구간에서의 재현성 검증과 엄밀한 이론적 유도가 뒷받침될 때 비로소 일반화가 시도될 수 있을 것이며, 본 연구는 해당 해석을 제안하는 데 그치고 그 입증은 후속 연구의 과제로 남긴다.

위 한계들을 출발점으로 후속 연구는 다음 방향으로 확장될 수 있다. 첫째, N 을 50 - 100 이상으로 확대한 대규모 검증을 통해 본 알고리즘이 대규모 자산군에서 갖는 실효성을 시험할 수 있다. 둘째, PMFG-MVO의 비중결정 방식을 전통 MVO(샤프 최대화), 최대분산화, 위험균형 등으로 다양화하여 2단계 접근

법에 적합한 조합을 탐색할 수 있다. 셋째, 네트워크 구조의 동적 변화를 활용한 시장 국면 판별과 이를 자산배분에 결합하는 연구로 발전시킬 수 있다. 넷째, 자산선택-비중결정 분리 프레임워크는 PMFG-FF에 한정되지 않으므로, 다양한 선택 규칙과 배분 규칙의 조합을 평가하는 범용적 연구 틀로 확장할 수 있다.

VI. 결론

본 연구는 11종 미국 섹터 ETF라는 제한적 유니버스를 대상으로, 네트워크 기반 자산선택과 비중결정 분리 프레임워크의 유효성을 탐색적으로 검토하였다. 상관계수 행렬로부터 PMFG를 구축하고 최단경로 거리 기반 최원선택 알고리즘으로 자산을 선별하는 PMFG-FF 방식을 6가지 벤치마크(평균-분산 최적화, MVO-EW, MST-FF, HRP, 최대분산화, 동일가중)와 체계적으로 비교하였다.

본 연구의 주된 실무적 공헌은 자산선택과 비중결정을 분리하는 2단계 프레임워크(PMFG-MVO)의 유효성을 본 표본에서 확인한 데 있다. PMFG-FF로 저장관 자산을 선택한 뒤 최소분산 비중을 적용하면, 저장관 유지(상관 0.414)와 평균-분산 최적화 수준의 위험 통제(변동성 0.132, MDD -0.036)를 동시에 달성할 수 있었다. PMFG-FF 자체는 저장관 자산선택이라는 특정 목적에 특화된 규칙으로, 전수조사 상위 88 - 96 백분위의 준최적 성과와 $O(kN)$ 시간복잡도의 계산 효율성이 확인되었다. 다만 <표 4> 종합 순위에서는 중위권(5.6 - 6.1)에 머무르며, 위험 통제와 종합 성과 측면에서는 동일가중·HRP·MST-FF에 열위이다. 본 방법의 가치는 “전반적 방법 우위”가 아니라 “저장관 선택이라는 조건부 우위”로 한정해

해석함이 적절하다.

본 연구는 $N=11$ 의 제한적 자산군을 대상으로 한 탐색적 연구이며, 결과의 일반화는 대규모 자산군에서의 재검증에 의존한다. 그럼에도 네트워크 분석 도구를 기수제약 자산선택에 적용하고, 다중 벤치마크와 동일 조건에서 비교하며, 선택과 배분을 분리하는 2단계 프레임워크를 제시한 점은 후속 대규모 실증 연구의 출발점이 될 수 있다.

참고문헌

- 권순학, 이상휘(2024), "ESG Rating이 주식형 펀드의 ESG 투자 효율성에 미치는 영향," *경영학연구*, 제53권 1호, pp.1-26.
- (Kwon, S. H. and Lee, S. W. (2024), "The Impact of ESG Rating on Investment Efficiency of Equity Funds," *Korea Management Review*, 53(1), pp.1-26.)
- 김민석, 이도영, 임우상, 안태찬, 최인수, 김우창(2022), "미국 ETF 시장의 암호화폐 지수 도입 가능성: 시스템 리스크와 포트폴리오 이론의 관점에서," *대한산업공학회지*, 제48권 5호, pp.509-518.
- (Kim, M., Lee, D., Yim, W., An, T., Choi, I., and Kim, W. C. (2022), "On the Possibility of Incorporating Cryptocurrency Index into the U.S. ETF Market: From the Perspective of Systemic Risk and Mean-Variance Portfolio Optimization," *Journal of the Korean Institute of Industrial Engineers*, 48(5), pp.509-518.)
- 송인욱, 김용원, 박영규(2021), "코로나19 위기 시 주식형 펀드의 성과와 현금흐름," *경영학연구*, 제50권 6호, pp.1621-1640.
- (Song, I., Kim, Y., and Park, Y. K. (2021), "The Equity Fund Performance and Flow during Covid-19 Crisis in Korea," *Korea Management Review*, 50(6), pp.1621-1640.)
- 최현희, 김영준(2020), "국내 벤처펀드의 성과결정요인에 대한 실증연구," *경영학연구*, 제49권 2호, pp.279-303.
- (Choi, H. and Kim, Y. (2020), " An Empirical Study on Performance Determinants of Korean Venture Funds," *Korea Management Review*, 49(2), pp.279-303.)
- Aste, T., Shaw, W., and Di Matteo, T.(2010), "Correlation structure and dynamics in volatile markets," *New Journal of Physics*, 12(8), 085009.
- Chang, T. J., Meade, N., Beasley, J. E., and Sharaiha, Y. M.(2000), "Heuristics for cardinality constrained portfolio optimisation," *Computers & Operations Research*, 27(13), pp.1271-1302.
- Choi, I., and Kim, W. C.(2025), "A multifaceted graph-wise network analysis of sector-based financial instruments' price-based discrepancies with diverse statistical interdependencies," *The North American Journal of Economics and Finance*, 75, 102316.
- Choi, I., Yun, W., and Kim, W. C.(2025), "Improving data efficiency for analyzing global exchange rate fluctuations based on nonlinear causal network-based clustering," *Annals of Operations Research*, 352(3), pp.745-780.
- Choueifaty, Y., and Coignard, Y.(2008), "Toward Maximum Diversification," *Journal of Portfolio Management*, 35(1), pp.40-51.
- Cohen, J.(1988), *Statistical Power Analysis for the Behavioral Sciences*, 2nd ed., Lawrence Erlbaum Associates, Hillsdale, NJ.
- Gonzalez, T. F.(1985), "Clustering to minimize the

- maximum intercluster distance," *Theoretical Computer Science*, 38, pp.293-306.
- Jiang, K., Li, D., Gao, J., and Yu, J. X.(2014), "Factor Model Based Clustering Approach for Cardinality Constrained Portfolio Selection," *IFAC Proceedings Volumes*, 47(3), pp.10713-10718.
- López de Prado, M.(2016), "Building Diversified Portfolios that Outperform Out of Sample," *Journal of Portfolio Management*, 42(4), pp.59-69.
- Mantegna, R. N.(1999), "Hierarchical structure in financial markets," *European Physical Journal B*, 11(1), pp.193-197.
- Markowitz, H.(1952), "Portfolio Selection," *Journal of Finance*, 7(1), pp.77-91.
- Peralta, G., and Zareei, A.(2016), "A network approach to portfolio selection," *Journal of Empirical Finance*, 38, pp.157-180.
- Pozzi, F., Di Matteo, T., and Aste, T.(2013), "Spread of risk across financial markets: better to invest in the peripheries," *Scientific Reports*, 3, 1665.
- Statman, M.(1987), "How Many Stocks Make a Diversified Portfolio?," *Journal of Financial and Quantitative Analysis*, 22(3), pp.353-363.
- Tumminello, M., Aste, T., Di Matteo, T., and Mantegna, R. N.(2005), "A tool for filtering information in complex systems," *Proceedings of the National Academy of Sciences*, 102(30), pp.10421-10426.
- Woodside-Oriakhi, M., Lucas, C., and Beasley, J. E.(2011), "Heuristic algorithms for the cardinality constrained efficient frontier," *European Journal of Operational Research*, 213(3), pp.538-550.

• 저자 최인수는 한국과학기술원에서 산업 및 시스템공학 박사 학위를 취득하였으며, 현재 가천대학교 경영대학 금융·빅데이터학부 조교수로 재직 중이다. 주요 연구 분야는 금융 데이터 사이언스, 비즈니스 애널리틱스, 데이터 기반 의사결정이다.