

방법론 백서 No.3

계층적 리스크 패리티 (HRP)

Hierarchical Risk Parity — 머신러닝 기반 포트폴리오 최적화

발행일: 2025년 5월 · 개정: 2026년 9월

발행기관	Financial Planner — 포트폴리오 리스크 분석 시스템
분류	포트폴리오 최적화 방법론 기술 백서
대상 독자	금융 전문가, 자산운용 담당자, 퀀트 투자자
면책 공고	본 문서는 교육 목적으로 작성되었으며, 특정 투자를 권유하지 않습니다.

목차

1장	개요 및 혁신성
2장	3단계 알고리즘 상세
3장	HRP vs 기존 방법론 비교
4장	적합한 포트폴리오 유형
5장	주요 운용사 활용 현황
6장	한계와 실무 고려사항

참고문헌

1장. 개요 및 혁신성

HRP(Hierarchical Risk Parity)는 Marcos Lopez de Prado(2016)가 Journal of Portfolio Management에 발표한 혁신적인 포트폴리오 최적화 방법론입니다. 머신러닝의 계층적 클러스터링 기법을 금융 자산배분에 접목하여, 기존 MVO와 Risk Parity의 근본적 취약점인 공분산 행렬 역행렬 계산을 완전히 우회합니다.

핵심 혁신: 공분산 역행렬(Σ^{-1})을 계산하지 않습니다. 역행렬은 작은 추정 오류도 증폭시키는 수치적 불안정성의 원인입니다. HRP는 덴드로그램(계층 트리) 구조를 활용하여 이 문제를 우회하며, 종목 수가 많아질수록(30개 이상) MVO 대비 안정성 이점이 더욱 두드러집니다.

2장. 3단계 알고리즘 상세

단계 1: 계층적 트리 클러스터링 (Tree Clustering)

자산 간 상관관계 행렬(ρ)에서 거리 행렬(D)을 생성하고, 원 논문과 같은 단일 연결법(single linkage)으로 유사한 자산들을 계층적으로 군집화합니다. 상관관계가 높은 자산들은 같은 클러스터에, 낮은 자산들은 다른 클러스터에 배치됩니다.

$$d(i,j) = \text{sqrt}(0.5 \times (1 - \rho_{ij})) \text{ (거리 행렬 변환)}$$

단계 2: 준대각화 (Quasi-Diagonalization)

덴드로그램의 잎(leaf) 순서를 재정렬하여 유사한 자산들이 인접하도록 공분산 행렬을 준대각 형태로 변환합니다. 이를 통해 클러스터 내 vs. 클러스터 간 상관관계가 명확하게 구분됩니다.

$$\text{재정렬 후: } \Sigma_{\text{sorted}} \rightarrow \text{블록 대각 구조 근사}$$

단계 3: 재귀적 이분법 (Recursive Bisection)

덴드로그램을 위에서 아래로 이분(bisection)하며 비중을 배분합니다. 각 분기점에서 좌/우 묶음의 분산(묶음 안을 역분산 $1/\sigma^2$ 비중으로 섞었을 때의 분산)을 재서 분산이 작은 쪽에 더 많은 비중을 주고, 하위 묶음으로 재귀적으로 반복하여 최종 개별 자산 비중을 결정합니다.

$$\alpha = 1 - V_L / (V_L + V_R) \rightarrow \text{왼쪽 묶음 몫}, 1 - \alpha \rightarrow \text{오른쪽 묶음 몫}$$

3장. HRP vs 기존 방법론 비교

비교 기준	MVO	Risk Parity	HRP
공분산 역행렬 필요	필요 (불안정 위험)	필요 (수치적 해)	불필요 (트리 구조)
기대수익률 입력	필수	불필요	불필요
대형 포트폴리오 안정성	낮음 (차원의 저주)	보통	높음
클러스터 구조 반영	미반영	미반영	자동 반영
MDD (Lopez 2016)	기준	비교 가능	20%+ 낮음
Sharpe (Lopez 2016)	기준	비교 가능	15~31% 높음
구현 복잡도	중간	중간	중간~높음

백테스트 결과 (Lopez de Prado, 2016): S&P; 500 구성 종목 포트폴리오 대상 10년 Out-of-Sample 검증에서 HRP는 MVO 대비 Sharpe 비율 15~31% 향상, 최대낙폭(MDD) 평균 20% 이상 감소.

4장. 적합한 포트폴리오 유형

매우 적합한 경우

- 종목 수 20개 이상의 대형 포트폴리오 — MVO가 불안정해지는 구간에서 HRP가 빛납니다
- 공분산 행렬 추정 오류가 우려될 때 (짧은 데이터 기간, 비정상 시계열)
- 기대수익률 추정 없이 순수하게 리스크 기반으로 배분하고 싶을 때
- 동일 섹터 내 다수 종목 편입 — 클러스터링이 자연스럽게 섹터 집중을 방지
- 퀀트 팩터 포트폴리오, 로보어드바이저 기반 ETF 포트폴리오

주의가 필요한 경우

- 종목 수 3~5개 이하: 클러스터링 구조가 의미 없어 단순 역변동성과 차이 미미
- 특정 자산에 대한 강한 수익률 뷰가 있을 때 → BL + MVO 조합이 더 적합
- 목표 수익률이 명확히 정해진 경우 → 목표수익률 MVO 또는 LDI 전략 권장

5장. 주요 운용사 활용 현황

■ Man Group (Man AHL)

세계 최대 헤지펀드 중 하나인 Man AHL의 체계적 투자(Systematic Trading) 전략에 HRP 활용. 퀀트 업계에서 가장 선도적으로 도입한 기관.

■ Two Sigma

대규모 다자산 포트폴리오 구성 시 계층적 클러스터링 기반 자산배분 적용. 머신러닝 기반 투자 전략의 핵심 요소.

■ Citadel Securities

통계적 차익거래 및 마켓메이킹 포트폴리오 리스크 관리에 클러스터링 기반 배분 활용.

■ 국내 로보어드바이저

핀트(Fint), 파운트(Fount) 등 일부 국내 로보어드바이저 기업이 HRP를 핵심 배분 알고리즘으로 채택.

■ 학술/리서치 기관

Bloomberg Intelligence, MSCI 포트폴리오 분석 도구에 HRP 모듈 탑재. CFA Institute 교육 커리큘럼에 포함(2020 이후).

6장. 한계와 실무 고려사항

6.1 클러스터링 불안정성

클러스터 구조는 시장 체제(bull/bear/crisis)에 따라 달라질 수 있습니다. 단일 시점의 클러스터링 결과에 과도하게 의존하지 않도록 Rolling Window(3~6개월) 방식으로 클러스터를 주기적으로 갱신하는 것을 권장합니다.

6.2 수익률 최적화 부재

HRP는 공분산 구조만을 활용하며 기대수익률을 고려하지 않습니다. 따라서 특정 기대수익률 목표가 있거나 팩터 노출도를 조절해야 한다면, 목표수익률 MVO 또는 Black-Litterman 모델이 더 적합합니다.

6.3 연결법(Linkage) 선택의 영향

Ward's linkage, Single linkage, Complete linkage 등 다양한 클러스터링 방법이 있으며 결과에 영향을 줍니다. 본 시스템은 원 논문(López de Prado, 2016)과 같은 Single linkage를 씁니다 — 계산이 가볍고 논문과 같은 결과를 내지만, 가까운 종목을 하나씩 사슬처럼 이어 붙이는(chaining) 경향이 있어 묶음이 한쪽으로 길게 늘어질 수 있습니다. Ward's linkage는 묶음 안 분산을 최소화해 더 고른 묶음을 만드는 대안입니다.

참고문헌

- [1] Lopez de Prado, M. (2016). Building Diversified Portfolios that Outperform Out-of-Sample. Journal of Portfolio Management, 42(4).
- [2] De Prado, M.L. (2018). Advances in Financial Machine Learning. Wiley.
- [3] Lohre, H., Rother, C., & Schäfer, K.A. (2020). Hierarchical Risk Parity. SSRN Working Paper.
- [4] Raffinot, T. (2017). Hierarchical Clustering-Based Asset Allocation. Journal of Portfolio Management.