

Ⅲ. 운용전략소개

1. 자산 배분 및 위험 대응

• Strategy & Asset Allocation (SAA) Team

개요

SAA팀은 KSIF에서 운용하는 총 자산을 무위험자산과 각 전략 별 투자 금액으로 배분하는 업무를 담당하고 있다. 또한 전략의 수익률을 스타일에 기반한 수익률과 종목 선택에 기반한 수익률로 나누어 분석하는 성과평가를 실시하고 있다. 마지막으로 유니버설 포트폴리오(Universal Portfolio)의 알고리즘으로 구한 최적 자산 비율을 추종하는 전략을 사용하여 투자하고 있다.

전략적 자산배분(SAA : Strategic Asset Allocation)

SAA팀에서는 Top-down 방식으로 Passive 전략과 Non-Passive 전략의 비중을 먼저 나눈 후, 각 팀의 운용 전략 별로 투자할 비중을 결정한다. 전략적 자산배분의 특성상 장기적인 관점에서 자산배분이 이루어져야 하나 다양한 투자전략을 연구하고 실제 시장에서 활용해보는 목적을 가진 KSIF의 특성상 매 분기마다 자산배분이 이루어지고 있다.

2017년까지 실시했던 자산배분 전략에서는 위험자산과 무위험자산의 비중을 먼저 결정한 뒤 전략 별 비중을 결정해왔다. 이때 마코위츠의 평균-분산 모델(Mean-Variance Optimization)¹⁾과 효용 함수를 통해서 위험자산과 무위험자산의 투자 비중을 결정했으며, 이후에 각 전략 별 투자 비중을 블랙-리터만 모델(Black-Litterman Model)²⁾을 토대로 산출하였다.

그러나 KSIF 운용 특성에 따른 여러 가지 제약 조건(Passive 전략의 20% 고정 비중 및 각 전략 별 최소 10%, 최대 30% 비중 제한 등) 하에서 현금 비중이 음수로 나와 추가적인 차입이 필요한 경우 혹은 각 전략들의 비중이 최소치나 최대치에 치중하는 구석 해(Corner solution)가 발생하는 경우가 많았다. 이에 따른 해결책으로 목표 변동성을 기반으로 자산 배분을 진행하는 변동성 조정 전략(Target Volatility Strategy)³⁾을 도입하였다.

변동성 조정 전략은 포트폴리오의 변동성을 일정한 수준으로 유지하는 것을 목적으로 하고 있다. 참고

1) Markowitz, H., 1952, Portfolio selection, *Journal of Finance*, 7(1), 77-91.

2) Black, F. & Litterman, R., 1992, Global portfolio optimization, *Financial Analysts Journal*, 29-43.

3) Perchet, R., de Carvalho, R. L., Heckel, T., & Moulin, P., 2016, Predicting the success of volatility targeting strategies: Application to equities and other asset classes, *Journal of Alternative Investments*, 18(3), 21-38.

논문(Perchet et al., 2016)에서는 일간 리밸런싱을 통해 위험자산과 무위험자산에 투자하는 비중을 조정하며, 투자자의 성향에 따라 안정적인 포트폴리오를 원하면 낮은 목표 변동성(Target Volatility)을, 공격적인 포트폴리오를 원하면 높은 목표 변동성을 설정할 것을 제안한다. SAA팀에서는 이를 토대로 KSIF에 적용할 수 있는 전략을 고안하여 자산배분을 실시하였다. 이때 각 팀의 전략으로 구성된 포트폴리오를 하나의 특정 자산으로 간주하였다. 즉, KSIF가 총 6개의 Non-Passive 위험자산으로 구성된 포트폴리오를 운영한다고 보았다. 또한 자산배분의 주기는 분기로 설정하였다.

Step 1. GARCH Model (Generalized Autoregressive Conditional Heteroskedasticity Model)

다음 분기의 포트폴리오 변동성을 예측하기 위하여 과거 1년 동안의 KSIF 수익률 데이터와 GARCH(1,1) 모델을 이용한다.

$$\begin{aligned} r_t &= \mu + \epsilon_t \\ \epsilon_t &= \sigma_t e_t \\ \sigma_t^2 &= \omega + \alpha \epsilon_{t-1}^2 + \beta \sigma_{t-1}^2 \end{aligned}$$

Step 2. Risk Parity

$$\begin{aligned} \sigma_p &= \sqrt{w' \Omega w} \\ MRC_i &= \frac{\partial \sigma_p}{\partial w_i} \\ RC_i &= w_i \times \frac{\partial \sigma_p}{\partial w_i} \end{aligned}$$

where Ω : Covariance Matrix

첫 번째 식은 포트폴리오의 역사적 변동성을, 두 번째 식은 각 자산의 한계 위험 기여도(Marginal Risk Contribution, MRC)를 의미한다. 또한 MRC에 각 자산의 비중을 곱하게 되면 위험 기여도(Risk Contribution, RC)를 얻을 수 있다. Risk Parity의 목적은 모든 자산의 위험 기여도를 동일하게 해주는 것이다. 이를 통해 아래의 목적함수를 도출하고, 최적화를 통해 Risk Parity를 만족하는 자산의 비중을 구한다.

$$\arg \min_w \sum_{i=1}^N \left[\frac{\sqrt{w' \Omega w}}{N} - RC_i \right]^2$$

Step 3. 최적 목표 변동성 도출

Step 1에서 구한 예측 변동성을 σ_{Target} 으로 설정하고, 허용오차범위 λ 를 통해 최적 변동성의 범위를 σ_L 와 σ_U 로 제한한다. 이때 λ 가 너무 작은 값을 가진다면 최적화가 잘 진행되지 않는 문제가 발생하여 2%로 설정하였다.

$$\begin{aligned}\sigma_L &= \sigma_{Target} \times (1 - \lambda) \\ \sigma_U &= \sigma_{Target} \times (1 + \lambda) \\ \sigma_L &< \sigma_{Optimized} < \sigma_U\end{aligned}$$

또한 전략의 비중 합이 $w'1 \leq 1$ 를 만족하도록 제약식으로 두어, 현금을 $1 - w'1$ 만큼의 비중으로 배분했다. 추가적으로 배분 금액이 특정 전략에 집중되지 않고 고르게 배분될 수 있도록 Non-Passive 내에서 각 전략 별 비중의 범위를 10%에서 30%로 제한하였다. 따라서 다음과 같은 최종 식을 통해 최적 변동성과 자산 비중을 계산한다.


$$\arg \min_w \sum_{i=1}^N \left[\frac{\sqrt{w' \Omega w}}{N} - RC_i \right]^2$$

$$\begin{aligned}Subject\ to\ \sigma_L &< \sigma_{Optimized} = \sqrt{w' \Omega w} < \sigma_U \\ w'1 &\leq 1 \\ 0.1 &\leq w_i \leq 0.3\end{aligned}$$

Step 4. 최종 목표 변동성 도출

위에서 구한 최적 목표 변동성을 기준으로 $\pm 0.5\%$ 의 범위 내에서 목표 변동성을 0.1% 단위로 조정하며, 이에 따른 자산 비중들을 구한다. 예를 들어 최적 목표 변동성이 10%라면, 변동성의 값을 9.5%부터 10.5%까지 0.1%씩 늘려가며 각각의 경우에서 도출되는 자산 비중을 구한다. 마지막으로, 앞서 계산한 목표 변동성에 따른 전략 비중들 가운데 포트폴리오 수익률을 최대로 하는 전략 비중을 구한다. 이때의 목표 변동성을 최종 목표 변동성으로 설정하고, 이를 KSIF의 자산배분에 사용한다.

[그림 1] Target Volatility Process



변동성 조정 전략을 사용한 결과, 2018년 4분기의 목표 변동성은 8.2%이고 실제 자산 배분 비중은 [표 1]과 같다.

[표 1] 2018년 4분기 실제 자산 배분 비중

Asset Class			Amount	Weight
Total			₩1,093,653,474	100%
Passive(LMI팀)			218,730,695	20%
Non-Passive			874,922,779	80%
	LMI팀	SES	103,819,539	11.87%
	SGI팀	ESG	98,981,029	11.31%
		Opt,EP	87,492,278	10.00%
	QVI팀	SFI	88,424,182	10.11%
	SAA팀	UP	87,492,278	10.00%
	DAR팀	EMP	132,225,093	15.11%
	Cash		276,488,381	31.60%

성과 평가


SAA팀에서는 자산배분 외에도 KSIF에서 운용하고 있는 전략들에 대한 분기 별의 성과평가를 실시하고 있다. 성과평가의 지표로는 누적 수익률, 추적 오차, Sharpe Ratio, MDD 등을 사용하고 있으며, 전략들 간의 상관관계를 계산하여 KSIF 포트폴리오의 분산투자 효과를 판단하고 있다. 또한 Sharpe (1992)⁴⁾가 제안한 Return Based Style Analysis(이하 RBSA)를 사용하여 각 전략들의 투자 수익률을 해당 전략의 스타일과 매니저의 종목 선택 역량으로 분리하여 설명하고 있다. 구체적으로 RBSA는 펀드의 과거 수익률을 분석하여 그 포트폴리오 스타일(Style)을 Fama-French 3 Factor Model의 자산군 조합으로 나타내는 모형이고 다음 식과 같이 나타낼 수 있다.

$$\tilde{R}_i = [b_{i1}\tilde{F}_1 + b_{i2}\tilde{F}_2 + \dots + b_{in}\tilde{F}_n] + \tilde{e}_i$$

\tilde{R}_i 는 포트폴리오의 수익률을, \tilde{F}_n 과 b_{in} 은 각각 n번째 자산군(스타일 포트폴리오)의 수익률과 그 자산이 포트폴리오에 영향을 미치는 민감도를 의미하고, \tilde{e}_i 는 자산군으로 표현할 수 없는 오차항이다. 따라서 대괄호 안의 항들의 합은 스타일 성과부분이고, \tilde{e}_i 는 스타일로는 설명할 수 없는 종목 선택의 성과부분이다. [그림 2]는 실제 KSIF에서 운용하는 전략들에 대해 RBSA를 적용한 결과이다.

4) Sharpe, W. F., 1992, Asset allocation: Management style and performance measurement, *Journal of Portfolio Management*, 18(2), 7-19.

[그림 2] KSIF 각 팀별 스타일 분석



마지막으로 [그림 3]는 RBSA의 예시로써 KSIF에서 운용하고 있는 전략에 대한 2018년도 3분기의 스타일 분석을 나타낸 것이다. 벤치마크의 수익률과 스타일 포트폴리오의 수익률 차이로부터 해당 전략의 스타일에 의한 성과를, 스타일 포트폴리오의 수익률과 실제 포트폴리오의 수익률 차이로부터 포트폴리오 종목 선정에 의한 성과를 구하였다.

[그림 3] RBSA를 통한 성과평가 예시



Universal Portfolio(UP) 전략

SAA팀은 Thomas M. Cover(1991)⁵⁾의 논문을 토대로 Universal Portfolio(이하 UP) 전략을 구현하여 투자해 오고 있다. UP 전략의 장점은 사후적으로 최적 수익률의 포트폴리오 비중을 추종한다는 점이다. 따라서 장기 시계열일수록, 종목의 변동성이 클수록, 그리고 자산 비중을 리밸런싱 하는 빈도가 높을수록 UP 전략의 효과는

5) Cover, T. M., 1991, Universal portfolio, *Mathematical Finance*, 1(1), 1-29.

극대화된다. 하지만 리밸런싱 빈도가 높을수록 거래비용이 증가하는 문제점이 있기 때문에, SAA팀은 주간 단위로 리밸런싱하고 있다.

2015년에는 2개의 개별 종목으로 운용하였고, 2016년에는 위험분산을 목적으로 종목 수를 10개로 확장하여 운용하였다. 하지만 10개의 종목으로 UP를 운용한 결과 주간 단위로 비중 변화가 뚜렷하게 일어나지 않는다는 단점이 발생하여, 2017년부터 4개의 개별 종목(이하 UP4)으로 변경하여 운용하고 있다. 2017년의 UP4 운용에서 특정 주식(셀트리온)의 비이상적인 주가 변화로 인하여 포트폴리오의 수익률에서 전략의 실효성을 분석하는 것이 어려워졌다. 이에 따라 운용기간을 1년으로 정하고 새롭게 종목을 선정하였다. 2018년 UP4의 종목 변경을 위한 기준은 다음과 같다.

(Step 1. 높은 시가총액) FnGuide에서 제공하는 10개의 섹터 별로, 2017.04.01을 기준으로 시가총액 상위 다섯 종목을 선정하였다. (총 50 종목)

(Step 2. 높은 변동성) 각 섹터 별로 Step 1에서 선정된 다섯 종목 중, 2016.04.01~2017.03.31 1년간 변동성을 기준으로 상위 세 종목을 선정하였다. (총 30 종목)

(Step 3. 높은 총자산 대비 영업이익, 총자산 대비 영업이익) Step 2에서 선정된 30개의 종목 중, 2016.04.01.~2017.03.31의 기간 동안 총자산 대비 영업이익(ROE)이 높은 4개의 종목과 총자산 대비 영업이익(ROA)이 높은 4개의 종목이 일치하였다. 해당되는 4개의 종목으로 포트폴리오를 구성한 뒤, 2017.04.01~2018.03.31 1년 동안의 백테스팅을 시행한 뒤 UP4 변경 종목으로 최종 결정하였다.

위의 과정을 통해 최종적으로 선정된 종목은 'LG생활건강, 롯데케미칼, 메디톡스, S-OIL'이다. UP4 전략의 시장 대비 수익률과 리밸런싱 효과를 확인하기 위해 네 종목의 섹터 지수 동일 비중(이하 Sector EW)과 동일 비중 포트폴리오(이하 UP4 EW)를 벤치마크로 한다. Sector EW와의 비교를 통해 시장 대비 수익률을 확인하고, UP4 EW와의 비교로 UP 전략의 핵심인 리밸런싱 효과를 확인하고 있다.

2. 자산운용전략

• Large-cap & Market-based Investing (LMI) Team

개요

LMI팀은 KOSPI 상장 기업에 대한 기초 분석을 바탕으로 중대형주 투자를 중심으로 한다. 현재 운용중인 Enhanced index 전략은 전반적인 시장을 추종하는 성격이 강하고, Conservative Factor Strategy는 Low volatility 필터에 Momentum, Net payout yield factor를 도입하여 안정성이 높은 전략이라는 공통점이 있다. 실행 예정인 Dynamic ETF Momentum 전략은 Market state를 활용하는 전략으로 산업 모멘텀을 보완하여 Enhanced index 전략의 완성도를 높일 수 있다. LMI팀은 전략 실행에 있어서는 주관을 배제한 정략적인 접근과 기계적인 운용을 지향한다.

Enhanced Index 전략

1. Passive 전략: KOSPI200 추종

Passive 전략은 기본적으로 Mutual Fund Separation Theorem을 기반으로 안정적으로 시장수익률을 추종하기 위해 KOSPI200 지수를 완전 복제하는 것을 목표로 한다. KOSPI200 지수는 KOSPI 구성 종목 중 시가총액 상위 200개 종목으로 구성되어 있으며, 단순 시가총액이 아닌 유동주식수로 조정된 시가총액을 이용한다. 유동주식수는 최대주주 및 특수관계인의 지분, 자사주, 정부 및 정부투자기관의 투자 이외 목적 지분 등을 제외하여 계산된다. 구성 종목 변경은 정기변경과 특별변경으로 나누어지고, 정기변경은 매년 6월이며, KOSPI200 주가지수 선물의 최종거래일이 속하는 주의 다음 주 첫 영업 일에 이루어진다. 특별변경은 신규 상장, 기업분할 인수합병 등의 사건이 있을 때 발생한다.

LMI팀에서는 2018년 7월 이후 KOSPI 시가총액 상위 50개 종목을 이용하여 KOSPI 200을 추종하고 있다. 이는 KOSPI200의 구성 종목 중 시가총액 상위 50개의 종목이 전체 비중의 80% 이상을 차지한다는 점, KOSPI50과 KOSPI200의 상관관계가 높다는 점 (0.98), 그리고 추적오차가 크지 않다는 점(오차제곱합 기준 0.4%) 등을 고려해 보았을 때 200개 종목을 통한 완전 복제의 실효성이 적다는 판단 아래 진행되었다. 월별 리밸런싱에는 버퍼룰(Buffer Rule)을 적용하여, 기존 포트폴리오에 있는 종목이 시가총액 55위 이내일 경우 그대로 보유하고, 55위 밖으로 떨어지는 경우에만 포트폴리오에서 해당 종목을 제거하고 새로운 종목을 추가하고 있다.

2. SES (Sector ETF Strategy)

LMI팀에서는 중대형주를 중심으로 한 모멘텀 투자에 대해 지속적으로 연구하였고, 기존 연구와 같이 한국에서도 산업별 지수의 모멘텀 효과가 개별 주식들의 모멘텀 효과보다 강하다는 사실을 확인하였다.⁶⁾ 따라서 섹터 ETF를 활용하여 투자하는 것이 개별 종목으로 지수를 구성하는 것 보다 좋은 성과를 보일 것이라 판단하여, 섹터 ETF로

유니버스를 구성한 Sector ETF Strategy(SES)을 테스트하고 실행하였다. 모멘텀을 활용한 구체적인 섹터 ETF 투자 전략은 다음과 같다.

먼저 유니버스 내의 6개월간의 ETF별 평균 모멘텀 점수를 각각 구한다. 평균 모멘텀 점수는 1, 2, 3, 4, 5, 6개월 모멘텀 점수를 평균한 수치로, 꾸준한 상승 모멘텀을 가지는 종목의 모멘텀 효과가 더 강하다는 것을 보인 Da et al. (2014)의 연구를⁷⁾ 참고하여 사용하였다.⁸⁾ 다음으로 추세성과 횡보성을 판단하기 위해 각각의 지수에 대해 기술적 지표로 쓰이는 KAMA Ratio를 도입하였다.⁹⁾ 섹터 지수가 횡보할 경우 모멘텀 효과가 약하며, 이 때 KAMA ratio를 활용하면 모멘텀의 강도를 측정할 수 있다. 그리고 앞서 구한 개별 종목의 평균 모멘텀 점수와 KAMA ratio의 곱을 SES Score라 정의하면, SES Score가 높은 종목은 강한 상승 모멘텀을 가지고 있다고 판단할 수 있다. 최종적으로 SES Score 기준 상위 4종목을 뽑은 후, SES Score를 기준으로 비중을 계산하여 포트폴리오를 구성한다. 다만 횡보장과 같이 전반적으로 모멘텀 효과가 약한 시기에는 전략에 손실이 발생할 수 있으므로 손실을 방어하기 위한 장치가 필요하다. 산업 전반의 모멘텀 효과는 포트폴리오를 구성하는 4종목의 SES Score 합으로 추정할 수 있으므로, SES Score 합이 일정 기준을 넘지 못할 경우 KOSPI200 ETF를 기존 포트폴리오에 탄력적으로 편입하여 최대손실(Max Drawdown)을 방어한다. [그림 1], [표 1]은 본 전략의 백테스팅 결과이며, KOSPI200에 투자하지 않는 경우(SES only)보다 하락장 방어를 위해 KOSPI200을 도입한 경우(SES with KOSPI200)의 성과가 개선된 것을 확인할 수 있다.

[그림 1] SES 전략의 누적수익률 (기간: 2013.01~2018.09)




- 6) Moskowitz and Grinblatt (1999)는 모멘텀 수익을 분해하여 산업 모멘텀 효과가 강하다는 사실을 확인했다. (참고 문헌: Moskowitz, T. J., & Grinblatt, M., 1999, Do industries explain momentum? *Journal of Finance*, 54(4), 1249-1290.)
- 7) Da, Z., Gurun, U. G., & Warachka, M., 2014, Frog in the pan: Continuous information and momentum, *Review of Financial Studies*, 27(7), 2171-2218.
- 8) 평균 모멘텀 점수 = $\frac{1}{6} \sum_{i=1}^6 Score_i$ where $Score_i = \begin{cases} 1 & \text{if } Price_i < Price_0 \\ 0 & \text{otherwise} \end{cases}$ for $i = 1, 2, \dots, 6$.
- 9) $KAMA \text{ Ratio (Efficiency Ratio)} = \frac{|Price_6 - Price_1|}{|Price_6 - Price_5| + |Price_5 - Price_4| + \dots + |Price_2 - Price_1|}$

LMI팀은 2018년 10월부터 KOSPI 시가총액 상위 50개 종목으로 구성된 기존의 Passive portfolio에 SES를 더한 Enhanced Index 전략 (EI-SES)을 운용하고 있다. 전체 Enhanced Index에서 SES가 차지하는 비중은 20% 내외이며, SES전략 내에서의 KOSPI200 ETF의 비중은 유동적으로 변한다. Enhanced Index에서 Passive (KOSPI50 및 KOSPI200 ETF)가 80% 이상의 비중을 가짐에 따라, LMI팀의 Enhanced Index 전략은 Passive의 성격을 잃지 않는 선에서 적정 추적오차를 유지하며, 추가적인 Alpha를 추구한다. [표 1], [그림 2]는 기존 Passive 전략 (Passive with 50)과 비교할 때 Enhanced Index SES (EI-SES) 전략이 Alpha를 성공적으로 실현하고 있음을 나타낸다.

[표 1] EI-SES 백테스팅 결과 (기간: 2013.01~2018.09)

	Total Return	CAGR	Max Drawdown	Annualized Sharpe Ratio	Calmar Ratio
SES only	12.48%	2.07%	-30.63%	0.15	0.07
SES with KOSPI200	50.10%	7.34%	-16.79%	0.49	0.44
EI-SES	20.06%	3.24%	-19.65%	0.29	0.16
Passive with Top50	12.79%	2.12%	-24.71%	0.23	0.09
KOSPI200	11.65%	1.94%	-18.73%	0.24	0.1

[그림 2] EI-SES 포트폴리오 누적수익률 (기간: 2013.01~2018.09)



추후에는 현재 운용 중인 모멘텀 기반 SES 전략에 Market state를 반영하고자 한다. 산업 지수는 거시경제상황에 영향을 받는다는 사실이 알려져 있으므로, Market state를 예측하여 산업별 비중을 조정하면 추가적인 수익을 얻을 수 있을 것으로 기대된다.

Conservative Factor 전략

Conservative Factor 전략에서는 전체 투자 종목 유니버스를 변동성(Volatility) 필터링을 통하여 변동성이 낮은 N개의 자산으로 추려낸 후, Net Payout Yield (NPY)와 가격 모멘텀(Price Momentum)을 동시에 2차 필터로 사용하여 추려낸 상위 n개의 자산에 투자한다. Blitz and van Vliet (2018)¹⁰⁾은 Conservative Formula를 통해 구성된 포트폴리오의 성과지표가 Fama-French의 팩터 조합 전략 즉, Size, Value, Quality, Momentum 전략 또는 이들을

혼합한 전략에 비해 높은 것을 보였다. Conservative Factor 전략은 이러한 팩터들을 효과적으로 조합하여 초과수익을 추구한다. 또한 Conservative Factor 전략은 Long-only 전략이기 때문에 공매도 제한에서 자유로우며, 리밸런싱을 자주 하지 않고도 높은 수익을 창출한다는 장점이 있다.

Boudoukh et al. (2007)¹¹⁾에 따르면 배당과 배당률은 미래 주가를 예측하는데 중요한 역할을 한다. Net Payout은 기업으로부터 투자자로의 현금흐름을 뜻하며, 이는 배당뿐만 아니라 자사주재매입과 유상증자 등을 포함한다. LMI팀에서는 수정평균발행주식수에 평균발행 주식 수를 나눈 주식조정계수누적에 유동주식수를 곱한 수정유동주식수 증감으로 유상증자와 자사주재매입을 근사하고자 하였으나, 실제 자사주재매입과 유상증자의 발생 수에 비해 수정유동주식수의 변화가 자주 발생하는 것을 확인하고, 근사치에 많은 노이즈가 있다고 판단하였다. 따라서, NPY를 대신하여 단순 배당수익률(Dividend Yield)을 사용하여 백테스팅을 진행하였고, 이에 따라 결과의 경향성이 강화되는 것을 확인하였다. 1차 필터로 사용한 변동성 지표 역시 대표적인 수익률 팩터로써 많은 논문에서 낮은 변동성을 갖는 주식들이 미래에도 낮은 변동성을 가지면서 양(+)의 수익률을 낸다고 밝힌 바 있다. 모멘텀 지표 역시 널리 사용되는 수익률 팩터로써 가장 기본적인 12개월 모멘텀 지표를 배당수익률과 함께 2차 필터로 사용하였다.

매 분기마다 다음의 과정을 통해 포트폴리오를 구성한다. 먼저 변동성지표를 이용해 낮은 변동성을 갖는 200개 주식들을 추려낸다. 그리고 200개의 주식들을 대상으로 모멘텀과 배당수익률이 높은 순서대로 순위를 매긴 뒤, 두 지표의 평균 등수를 기준으로 상위 20개 종목에 투자한다. [표 2]는 위의 방법으로 구성한 Conservative Factor Strategy (CFS) 포트폴리오와 개별 팩터 포트폴리오에 대한 백테스팅 결과로, 수익률과 리스크 측면에서 CFS 포트폴리오가 개별 팩터 포트폴리오보다 우월한 것을 확인할 수 있다. 개별 팩터 포트폴리오와 비교하여 CFS 포트폴리오는 높은 Total Return과 CAGR, 낮은 최대손실(Max Drawdown)과 변동성(Daily Vol)을 가진다. 특히 CFS 전략은 변동성이 큰 모멘텀 지표를 포함함에도 불구하고, 안정적인 수익률을 보인다는 장점이 있다. 그 결과

	High NPY				Low NPY			
High momentum								
	Conservative							
Low momentum								
					Low Volatility			

10) Blitz, D., & van Vliet, P., 2018, The conservative formula: Quantitative investing made easy, *Journal of Portfolio Management*, 44(7), 24-38.

11) Boudoukh, J., Michaely, R., Richardson, M., & Roberts, M. R., 2007, On the importance of measuring payout yield: Implications for empirical asset pricing, *Journal of Finance*, 62(2), 877-915.

수익률과 리스크를 동시에 고려하는 Sharpe Ratio와 Calmar Ratio 기준으로 CFS 포트폴리오의 성과가 다른 포트폴리오들을 상회하는 것으로 나타난다.

[표 2] Conservative Factor 전략 팩터 포트폴리오 수익률 (기간: 2013.01~2018.08)

Top 20	Total Return	CAGR	Daily Sharpe	Calmar Ratio	Daily Vol (ann.)	Max Drawdown
Volatility	102.32%	13.38%	1.36	0.85	9.83%	-15.82%
Momentum	134.99%	16.44%	0.65	0.42	31.58%	-38.80%
Div. Yield	139.24%	16.81%	1.32	1.12	12.69%	-15.02%
CFS	141.36%	17.00%	1.42	1.5	11.86%	-11.36%
KOSPI200	8.14%	1.40%	0.18	0.07	12.47%	-18.73%

• SRI and Growth Investing (SGI) Team

개요

SGI팀은 성장주(Growth Stocks) 투자를 기초로 하여 사회적 가치를 창출할 수 있는 기업에 투자하는 ESG InBest 전략 전략을 운용 중이다.

ESG InBest 전략

코피아난(Kofi Annan) 전 UN 사무총장의 제창으로 2006년 제정된 유엔 책임투자 원칙은 투자 의사 결정시 기존의 재무적 분석에 더해 비재무적인 환경, 사회, 그리고 지배구조 이슈를 고려할 것을 천명하고 있다. 이 원칙은 사회책임투자의 개념과 결부되어, 현재 세계유수의 기업들과 기관들이 적극적으로 활용하고 있다.


ESG 지표는 환경(Environment, 이하 E), 사회(Social, 이하 S), 지배구조(Governance, 이하 G) 세 가지 영역에서 기업의 우수성을 측정하는 지표이다. ESG InBest 전략은 기업의 지속가능성을 대변하는 ESG 지표에 재무적 요소를 함께 고려하여, 모범적인 기업에 투자하는 사회책임투자를 실천하면서도 수익성을 목표로 하는 전략이다. 기업의 지속 가능성에 대한 지표로, 본 전략에서는 한국기업지배구조원(Korea Corporate Governance Service, 이하 KCGS)에서 발표하는 데이터를 사용하였다.

기존 ESG InBest 전략은 E, S, G 각 영역 등급과 ESG 통합 등급 모두 B 이하의 등급을 받은 기업을 제외하는 네거티브 스크리닝(Negative Screening)을 통해 투자 유니버스를 구성하였다. 이 후 다양한 재무 비율에 대해 Linearity Filter를 사용하여, 수익에 긍정적으로 영향을 준 재무 비율을 필터로서 사용하였다. 마지막으로 E, S, G 각 영역 등급과 ESG 통합 등급 중에서 수익성과 유의한 관계가 있는 요소만을 선택하여, 상위 30 종목에 투자하였다. 이와 같은 전략으로 1년 간 운용한 결과 다음과 같은 한계점들을 발견했다. 따라서 현 SGI팀은 기존 전략을 개선한 ESG InBest 전략을 개발하여 이를 실행하고자 한다.

1. 산업별 스코어링을 적용한 새로운 ESG 벤치마크 설정

기존 ESG 투자 유니버스는 각 회사의 산업별 특성을 고려하지 않았다. 하지만 금융회사가 E(Environment) 영역에서 A등급을 받는 것과, 정유회사와 같이 환경에 직접적인 영향을 주는 회사가 E 영역에서 A등급을 받는 것은 상대적으로 차이가 있으므로, 1차적으로 기업마다 산업별 특성을 반영하여 ESG 등급을 점수화 했다. 점수화는 Kim and Li(2014)¹²⁾에 근거하여 해당 기업의 ESG 점수를 그 기업이 속한 산업의 최고 점수와 최저 점수의 차이로 나눔으로써 정규화 했다. 산업의 구분은 FnGuide에서 제공하는 10개의 산업 대분류¹³⁾를 사용하였다. 이를 통해 계산된 ESG 점수를 바탕으로, 각 산업별로 상위 50% 기업들을 추출하여 ESG 유니버스로 구성하였다. 개선 전략의 초창기 투자 유니버스 구성 방식은 각 산업 마다 똑같이 ESG 점수 상위 30위의 기업들을 뽑는 것이었다. 하지만 종목 수가 30개 이하인 산업에서는 ESG 점수와 관계 없이 모든 종목이 선정되므로, 유니버스의 산업별 종목 선정 분포가 실제 시장의 산업별 종목 분포와 달라지는 문제가 생긴다. 그 차이를 좁히기 위해 산업별 ESG 점수 상위 50%의 기업을 선택하는 것으로 기준을 개선하였다.¹⁴⁾ [그림 1]은 수정된 ESG 벤치마크와 기존 벤치마크의 투자 성과 차이를 보여준다. 그 결과 새로 개선한 ESG 벤치마크가 투자 수익률 측면에서 기존의 벤치마크를 상회하는 것을 알 수 있다.

[그림 1] 새로운 ESG 벤치마크 및 기존 벤치마크 성과 비교



12) Kim, Li, & Li, 2014, Corporate social responsibility and stock price crash risk, *Journal of Banking and Finance*, 43, 1–13.

13) 의료, 금융, 산업재, 경기소비재, 필수소비재, IT, 소재, 유틸리티, 에너지, 통신서비스

14) 2017년 기준으로 KCGS는 총 733개의 기업을 평가하였고, 그 중 398개의 기업이 ESG InBest 투자 유니버스에 포함되었다.

2. EST Momentum 적용

MSCI(Morgan Stanley Capital International)의 리포트¹⁵⁾에 따르면 ESG 등급이 증가해온 기업에 가중치를 주어 투자하는 경우 포트폴리오의 수익률이 유의미하게 상승하였다. 이를 한국 시장에 적용하기 위해, 우선 자체적으로 계산한 ESG 점수가 전년도 대비 감소한 기업들을 제외하는 ESG Increasing 필터를 적용하였다.

[표 1]은 ESG Increasing 필터 적용 후 ESG 점수가 증가하거나 동일한 종목으로 포트폴리오를 구성한 경우(UP & Equal)와 필터로 걸러진 ESG 점수가 하락한 종목으로 포트폴리오를 구성한 경우(Down)의 성과를 보여준다. 백테스팅 결과 ESG 점수가 전년 대비 하락한 종목으로 구성된 포트폴리오의 수익률이 하회하는 것을 알 수 있다. 따라서 ESG Increasing 필터는 수익성 향상에 기여하면서도, ESG 등급에서 발전을 이룬 회사에 가중치를 두고 투자하는 사회책임투자로서 본 전략의 가치를 높일 수 있다고 판단하여 적용하였다.

[표 1] ESG Momentum 백테스팅 결과 통계치

2012-08-01 ~ 2018-08-01	UP & EQUAL	DOWN
연간수익률	10.18%	7.85%
누적수익률	72.52%	50.32%
최저연간수익률	-2.09%	-6.81%
최고연간수익률	47.85%	24.31%
MDD	-33.30%	-36.89%
Sharpe Ratio	1.80	1.47
Information Ratio	1.10	0.67
Standard Deviation	0.25	0.22

3. 재무 필터를 통한 최종 포트폴리오 구축


개선하는 전략의 목적은 ESG로 대표되는 기업의 비재무적 성과를 반영함과 동시에 최적의 투자성과를 강조하는 선관주의 의무(Fiduciary Duty)를 최우선시 하는 것이다. 이를 위해 수익성 지표로 GP/A(Gross Profit / Total Asset)와 회계적 수익률 지표인 ROA(Return on Asset) 증가율을 이용하였다.

Novy-Marx(2013)¹⁶⁾에 따르면 GP/A는 수익을 예측하는데 있어서 Book-to-Market을 대체할 수 있을 만큼 유의하다. GP/A는 매출총이익을 자산의 총계로 나눈 지표로서 해당 산업의 마진율을 알아볼 수 있는 간단한 방법이다. 그는 자신의 논문에서 GP/A가 가장 회계조작 측면에서 '깨끗한' 수익성 지표라 주장한다. 종합적으로, GP/A와 ROA의 증가분을 재무 필터로 추가하여 최종 ESG InBest 전략 백테스팅 한 결과가 [그림 2]와 [표 2]에 요약되어 있다. 현 SGI팀은 본 전략을 통해 투자 성과와 사회적 가치창출을 동시에 추구하고자 한다.

15) Zolt n Nagy, Altaf Kassam, Linda-Eling Lee, 2015, Can ESG add alpha? *MSCI ESG Research Inc.*

16) Novy - Marx, R., 2013, The other side of value: The gross profitability premium, *Journal of Financial Economics*, 108(1), 1 - 28.

[그림 2] ESG InBest 백테스팅 결과 그래프



[표 2] ESG InBest 백테스팅 결과 통계치

2012-08-01 ~ 2018-08-01	개선된 ESG InBest	유니버스
연간수익률	37.97%	9.39%
누적수익률	512%	65.91%
최저연간수익률	5.7%	-2.21%
최고연간수익률	91.37%	24.65%
MDD	-23.75%	-34.22%
Sharpe Ratio	1.34	1.81
Information Ratio	1.30	1.05
Standard Deviation	1.67	0.23

• Quantitative Value Investing (QVI) Team

개요

QVI팀은 KOSPI, KOSDAQ 중소형주 투자를 중심으로 한다. 현재 운용중인 SFI(Style Factor Investing) 전략은, Fama-French(2015)¹⁷⁾, Novy-Marx (2013)¹⁸⁾, Piotroski (2000)¹⁹⁾ 등의 학술적 연구 및, Benjamin Graham²⁰⁾과 Joel Greenblatt²¹⁾ 등 저서를 참고하여 이를 한국 주식시장에 적용하고 실증 분석한 후, 추가적으로 개선한

17) Fama, E. F., & French, K. R., 2015, A five-factor asset pricing model, *Journal of Financial Economics*, 116(1), 1-22.

18) Novy-Marx, R., 2013, The other side of value: The gross profitability premium, *Journal of Financial Economics*, 108(1), 1-28.

19) Piotroski, J. D., 2000, Value Investing: The use of historical financial statement information to separate winners from losers, *Journal of Accounting Research*, 1-41.

20) Graham, B., 1949, *The intelligent Investor*, (Harper and Row)

팩터(Factor) 기반 전략이다. 본 팀은 각 팩터의 분위별 수익률, Spearman Correlation(Rank IC), Information Ratio를 분석하여 사용할 팩터를 선정한 후, 이를 통해 개별 주식들의 점수를 산출한다. 최종적으로, 산출된 결과에서 높은 점수를 받은 개별주식들을 추출하여 구성된 동일가중 포트폴리오를 운용 중이다. 실행 예정인 Factor Machine Learning 전략은, 인위적인 filter의 조합을 통한 overfitting의 위험을 줄이고 방대한 재무데이터를 처리하기 위해 개발중인 전략이다.

SFI 전략(Style Factor Investing strategy)

본 전략은 한국 주식시장의 특성을 반영하기 위해, 일반적인 재무 팩터 이외에도 외국인 지분율, 공매도 잔고비율 등과 같은 팩터들에 대해서도 기간별로 검증하여 Scoring 혹은 Filtering 조건으로 사용한다. (표 1 참고) 검증을 거쳐 최종적으로 산출된 팩터는 유의미한 팩터 구간에 대한 Binary Scoring을 통해 점수를 부여하고 이를 모두 합산하여 계산된 Total Score 상위 종목부터 KOSPI, KOSDAQ 각각 15종목씩 투자한다. 동점자는 팩터 중 가장 유의미했던 매출총이익/총자산이 높은 순서로 매수하였다.

$$\text{For } x \leq \text{Factor}_i \leq y \quad , \quad \begin{array}{ll} \text{If True} & \text{Score}(\text{Factor}_i) = 1 \\ \text{False} & \text{Score}(\text{Factor}_i) = 0 \end{array}$$

$$(\text{Weight of Factor}_i = W_i)$$

$$\text{Total Score of Asset}_i = \sum W_i \times \text{Score}(\text{Factor}_i) + \text{Rank}(\text{GP}/A_i)$$

$$\text{Portfolio} = \text{Equal weight}(\text{KOSDAQ Total Score Top 15} + \text{KOSPI Total Score Top 15})$$

- 유니버스 선정

투자 유니버스 선정 기준은 다음과 같다.

- 코스피 & 코스닥 상장
- 시가총액 500억 원 이상, 8000억 원 이하
- 종가 1000원 이상
- 금융 섹터, SPAC, 지주사, 거래정지 종목, 관리종목 제외

21) Greenblatt, J., 2007, The little book that still beats the market, (John Wiley and Sons, Inc.)

[표 1] 사용 팩터 별 최상위/하위 10% 기하평균 수익률 및 Rank IC (2011. 6. 1 ~ 2018. 7. 31)


KOSPI	Low	High	Rank IC	KOSDAQ	Low	High	Rank IC
부채비율	10.76%	-3.43%	-0.0554	부채비율	15.75%	0.30%	-0.0327
유동비율	3.63%	10.06%	0.0399	유동비율	3.95%	16.32%	0.0303
시총/영업현금흐름*	14.46%	5.24%	-0.0368	시총/영업현금흐름*	13.60%	10.27%	-0.0361
시총/장부가치*	11.09%	2.01%	-0.0571	시총/장부가치*	14.35%	0.35%	-0.0576
시총/매출총이익*	18.03%	2.40%	-0.0539	시총/매출총이익*	22.90%	4.05%	-0.0606
시총/영업이익/*	16.17%	8.92%	-0.0341	시총/영업이익/*	15.39%	3.11%	-0.0575
분기순이익/장부가치	-6.56%	13.78%	0.0520	분기순이익/장부가치	-1.58%	16.48%	0.0521
투자자본순이익률	0.71%	13.49%	0.0336	투자자본순이익률	5.72%	10.25%	0.0425
ROA YoY	1.08%	9.62%	0.0242	매출총이익/총자산	-2.45%	15.20%	0.0355
매출총이익/총자산	-4.84%	21.42%	0.0493				
Momentum 1M*	4.71%	12.45%	-0.0661				
외국인지분율	8.49%	12.52%	0.0301				
SFI Score	-4.73%	21.50%	0.0782	SFI Score	-3.67%	25.86%	0.0650

(*: 양수의 데이터만 사용하여 10분위를 계산)

Rank, IC는 종목별 팩터와 사후수익률 간의 rank correlation, 절대값이 높을수록 전략 성과가 뛰어남

- SFI 백테스트 결과 및 통계치 (2012.05.01 ~ 2018.08.31.)

[그림 1] SFI 전략 백테스트 결과 (KOSPI)




[표 2] SFI 전략 백테스트 통계치 (KOSPI)

	누적 수익률(%)	CAGR(%)	Sharpe Ratio(Year)	KOSPI 대비 Win Ratio (%)	MID BM 대비 Win Ratio (%)	Skewness
KOSDAQ	117	2.5	0.09	—	—	-0.37
MID BM*	136	4.86	0.13	—	—	-0.12
SFI	371	29.43	1.61	59.21	59.21	0.19

(*: KOSPI, KOSDAQ 중형주 지수 일간 수익률의 평균 지수)

[그림 2] SFI 전략 백테스트 결과 (KOSDAQ)



[표 3] SFI 전략 백테스트 통계치 (KOSDAQ)

	누적 수익률(%)	CAGR(%)	Sharpe Ratio(Year)	KOSDAQ 대비 Win Ratio (%)	MID BM 대비 Win Ratio (%)	Skewness
KOSDAQ	171	8.68	0.18	—	—	0.19
MID BM*	136	4.86	0.13	—	—	-0.12
SFI	460	32.97	1.8	64.47	67.11	0.02

(*: KOSPI, KOSDAQ 중형주 지수 일간 수익률의 평균 지수)

FML(Factor Machine Learning)

FML은 투자 팩터의 ‘선정’과 ‘조합’ 방식에 있어 계량 모델의 장점을 극대화한 머신러닝(Machine Learning) 알고리즘을 적극 활용하여 가장 유망한 주식들을 찾아 포트폴리오를 구성하여 운용하는 전략이다.

– 자료 및 방법론

Deep learning에 필요한 데이터는 KSIF Library를 활용하여 구성하였다. 학습에 사용한 Factor는 6개 섹터 (Value, Profit, Growth, Momentum, Safety, Liquidity)에서 아래와 같은 총 25개의 Factor를 사용하였다.

[표 4] FML 전략에 사용된 Factor

Value	순이익/시총, 장부가치/시총, 매출액/시총, 영업현금흐름/시총, EBIT/시총, 매출총이익/시총
Profit	ROA, ROE, QROA, QROE, 매출총이익/총자산, 매출총이익/매출, ROIC
Growth	ROA QoQ, 매출 QoQ, 매출총이익 QoQ
Momentum	Momentum 6months, Momentum 12months
Safety	Beta, Volatility, Liquidity Ratio, Equity Ratio, Debt Ratio
Liquidity	외국인지분율, 공매도 비율

T+1 시점까지의 수익률을 예측하기 위해 과거 1년간의 팩터들을 사용하였다. 예를 들어, 2018년 1월 한 달간의 수익률을 예측을 하다면, 2017년 1월부터 2018년 1월까지 총 13시점에서 관측되는 25가지 팩터를 사용하였다.

Training set은 과거의 120개월이다. 예를 들어, 2018년 1월의 수익률을 예측하기 위해 2008년 1월부터 2017년 12월까지의 수익률과 팩터들에 대해 학습한다.

[그림 3] 학습 데이터 입력 방법

Training: 120 sets			Prediction: 1 set
May 2001	...	April 2011	May 2011

Training: 120 sets			Prediction: 1 set
June 2001	...	May 2011	June 2011

...

Training: 120 sets			Prediction: 1 set
August 2008	...	July 2018	August 2018

– Performance Measures (성능 지표)

FML의 성능을 측정하기 위해서, 예측수익률과 실제 사후수익률간의 Rank IC(Spearman Correlation)와 MSE (Mean Squared Errors)를 사용하였다. 또한, 분위 별 동일 비중 포트폴리오를 구성하여 백테스트를 진행하였다.

– Parameter 선정

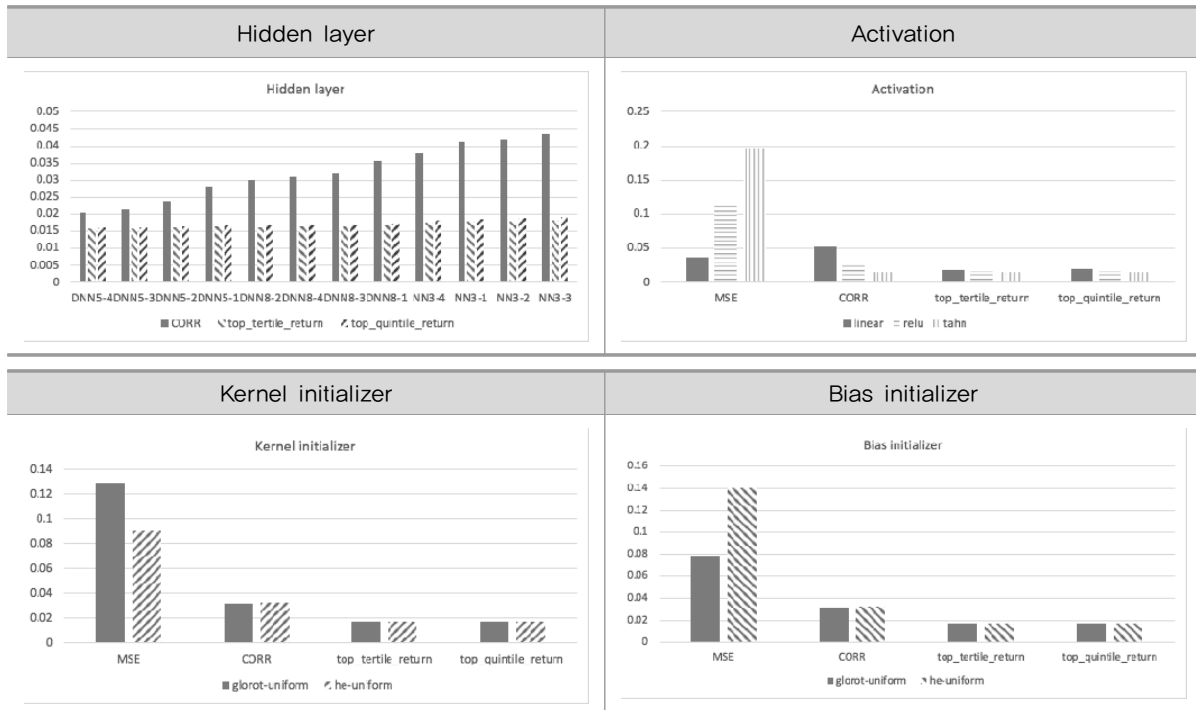
신경망 모델은 어떤 파라미터를 사용하느냐에 따라 모델의 성능이 다르다. 한국 주식시장에서 어떤 파라미터가 수익률 예측에 적합한지 확인하기 위해 DNN(Deep Neural Networks)와 NN(Neural Networks)의 은닉망의 형태(number of layers & hidden layers), activation, initializer, bias regularizer를 조절하여 성능을 확인하였다. 모든 신경망 모델은 fully-connected feedforward neural networks이며, 총 144개의 모델에 대해 백테스트를 진행하였다.

[표 5] Architectures of neural networks


Parameters	Options			Cases
Activation	Linear	ReLU	tanh	3
Bias Initializer	glorot_uniform	he_uniform		2
Kernel Initializer	glorot_uniform	He_uniform		2
Hidden Layer	NN3_1,2,3,4	DNN5_1,2,3,4	DNN8_1,2,3,4	12
				144 Cases

– FML 백테스트 결과 (2012. 6. 1 ~ 2018. 7. 31)

[표 6] 파라미터 별 백테스트 결과



[표 7] Best CAGR 을 보인 모형의 백테스트 결과



Activation: Linear, Bias initializer: he_uniform, Kernel Initializer: glorot_uniform, Hidden Layer: NN3_3

• Derivatives & Absolute Return (DAR) Team

개요

D.A.R(Derivatives and Absolute Return)팀은 주식을 제외한 국내 상장지수펀드(ETF), 선물(Futures)에 투자하는 것을 기본방향으로 한다. D.A.R팀은 첫째로 초과수익의 원천으로 알려진 다양한 팩터의 조합 및 비중조정전략을 이용한 Smart Beta ETF Managed Portfolio(EMP) 전략을 통해 지속적이고 안정적인 수익을 목표로 하였고 둘째로는 System trading과 초 단위 data를 이용한 Futures pairs trading 전략을 통해 기존 KSIF 펀드와의 상관관계가 낮은 포트폴리오를 구축하여 학생투자펀드의 안정적 운용을 도모하였다.

Smart Beta ETF Managed Portfolio[EMP] Strategy

본 전략은 액티브 투자의 장점을 취한 패시브 투자전략으로 초과수익의 원천으로 알려진 다양한 팩터(Momentum, Value, Growth, Low Vol, High Dividend)를 계량적인 방법론으로 구현하고 전통적인 패시브펀드와 다르게 다양한 팩터의 조합 및 비중조정전략을 이용하여 기존 스마트베타 펀드를 변형 및 확장한 전략이다.

1. 소개

최근 들어 한국뿐만 아니라 전 세계적으로 ETF 시장의 성장세가 가파르다. 스마트베타 ETF 상품은 기대 수익률과 위험관리 측면에서 높은 효용성을 자랑한다. 스마트베타 Factor 간에는 상관관계가 높지 않아 다양한 스마트베타 factor ETF로 포트폴리오 구성 시 분산투자 효과를 누릴 수 있다.

본 전략은 액티브 투자의 장점을 취하여 다양하게 확장한 패시브 투자전략으로 초과수익의 원천으로 알려진 다양한 Factor를 계량적인 방법론으로 구현한 전략이다. EMP의 투자 유니버스로는 우선 중장기적으로 시장 대비 초과수익 획득에 기여하는 스마트베타 Factor ETF를 포함한다. 두 번째로 중·소형주에 일부 편중되는 위험을 줄이기 위해 대형주 ETF인 KODEX 200 ETF를 추가적으로 배분한다. 세 번째로 추가수익 추구를 위해 Leverage, Inverse ETF를 활용하였다.

2. Universe (Factor ETF) 선정

현재 국내시장에 상장된 5개 Factor에 해당하는 ETF를 대상으로, 단일 Factor ETF 여부 및 유동성 등을 기준으로 각 Factor별 ETF를 선정하였다.

[표 1] 각 Factor별 ETF 유니버스

Factor	종 목
Momentum	TIGER 모멘텀(147970), KODEX 모멘텀 플러스(244620), KINDEX 스마트 모멘텀(272220)
Value	KB 셀렉트 밸류(234310), KODEX 밸류 플러스(244670), KINEX 스마트 밸류(272230)
Quality	KODEX 퀄리티 플러스(244660)
Low Vol	TIGER 로우볼(174350), KODEX 최소변동성(279540)
High Div	KB KQ고배당(270800), KODEX 고배당(279530)
기타	KODEX 200(069500), KODEX 레버리지(122630), KODEX 인버스(114800)

3. 방법론

– 스마트베타 Portfolio 후보군 구성

스마트베타 Factor ETF 간에는 상관관계가 낮은 속성으로 인해 다양한 Factor ETF로 포트폴리오를 구성 시 분산투자 효과를 누릴 수 있다. 따라서 5개의 Factor ETF가 모두 포함되도록 각 Factor별 1개의 ETF를 선정하여 총 36개의 모든 경우의 수(Model 1의 경우) 포트폴리오를 스마트베타 Portfolio 후보군으로 구성한다.

– 포트폴리오 내 자산 비중 결정 방법

스마트베타 Portfolio 후보군이 구성되면 Elastic asset allocation을 통해 각 포트폴리오 내 자산 비중을 결정한다. Elastic asset allocation은 모멘텀, 변동성, 상관성이 혼합된 전략으로 모멘텀 전략의 장점을 누리면서 변동성을 최소화하고 급락장에서 급격한 상관관계 증가에 의한 추가 손실을 최소화할 수 있게 해준다.

각 Model별 공통으로 들어가는 자산 배분 비중 계산 순서는 아래와 같다. Model별 세부 자산 비중의 경우, 먼저 전체 포트폴리오 자산 개수에서 “평균 모멘텀 값 > 1”인 자산 개수의 비중을 Factor ETF에 투자한다. 그 외의 비중은 Model을 세분화하여 추가적으로 배분한다.

[표 2] 자산배분 비중 계산 순서(Model 공통 적용)

순서	내 용
1단계	포트폴리오 구성 ETF 12개월 평균 모멘텀 – 마지막 월 증가 평균 / 12개월 전체 증가 평균
2단계	구성 ETF의 변동성 계산 (1개월 수익률의 최근 12개월 표준편차)
3단계	전체 동일 비중 포트폴리오와의 상관계수 계산 – 매월 증가 기준 ETF 수익률과 동일 비중 포트폴리오 수익률 간의 상관계수
4단계	(1-상관계수) / 변동성 비율에 따라 Factor ETF의 투자 비중을 조절

- Model 세분화

앞서 설명한 스마트베타 Portfolio 후보군과 자산 비중 결정방법을 기본으로 하여 Model을 세분화한다. 구체적인 Model 설명은 [표 2]와 같고, Factor 외 투자 비중을 어떻게 결정하는 지에 따라 두 가지로 분류된다. 첫 번째 분류 (Model 1~3)기준은 스마트베타 Portfolio 후보 군에 중·소형주 편중 위험관리를 위하여 대형주 관련 ETF를 추가하는 것이다. 두 번째 (Model 4~5)는 스마트베타 Portfolio 후보군에 추가 수익 추구를 위해 Leverage ETF와 Inverse ETF를 추가하는 방법이다. 각 방법에 따라 세분화된 내용은 아래 표에 설명되어 있다.

[표 3] EMP 모델별 포트폴리오 경우의 수(총 1,188개)

(1) 대형주 ETF 비중: 1 – Factor ETF 투자 비중인 모형

모델	내 용	Cap (5 / 10 / 15 / 20 / 25 / 30%)	초과비중	Case
Model 1	KODEX 200 ETF를 추가	X	KODEX 200	36
Model 2	KODEX 200 ETF에 투자 비중 Cap 설정	O	Factor ETF	$6 \times 36 = 216$
Model 3	초과비중을 Leverage ETF 혹은 Inverse ETF에 배분	O	KODEX Leverage KODEX Inverse	$6 \times 36 \times 2 = 432$

(2) Leverage / Inverse 비중: 1 – Factor ETF 투자 비중인 모형

모델	내 용	Cap (5 / 10 / 15 / 20 / 25 / 30%)	초과비중	Case
Model 4	Leverage ETF와 Inverse ETF를 추가	X	KODEX Leverage KODEX Inverse	$36 \times 2 = 72$
Model 5	Leverage ETF와 Inverse ETF에 투자 비중 Cap 설정	O	Factor ETF	$6 \times 36 \times 2 = 432$


4. Backtesting 결과

Backtesting에 사용된 Data는 2012년 9월 1일부터 2018년 9월 30일까지의 Factor ETF Price 및 Benchmark Index (BM Index)로부터 추정된 Price Data이다. 유니버스에 포함되는 스마트베타 ETF의 경우 최근 1년 내에 상장된 ETF들의 비중이 높기 때문에 장기간 백테스팅을 위한 최소 2년 이상의 Data 확보가 어렵다. 따라서 상장된 ETF의 기준이 되는 BM index의 과거 수익률을 기반으로 가격을 역 추정하여 가격데이터를 확보하였다. 가격 역추정 작업에 앞서 각 ETF별 추적오차를 분석하여 BM index의 수익률을 ETF Price 대응으로 사용가능한지에 대한 여부를 확인하였다. 그 결과 데이터가 부족한 ETF들의 tracking error가 유의미하게 큰 차이를 보이지 않았으며, 따라서 백테스팅에 필요한 ETF의 상장 이전 가격 데이터를 BM index의 수익률로 추정하여 확보하였다.

앞서 설명한 전략으로 다음과 같은 조건하에서 백테스팅을 진행하였다.

- 사용 자료: 6년 (2012. 10. 01 ~ 2018. 9. 30), ETF 상장 이전의 자료는 Index자료로 대체
- 리밸런싱 주기: 4주
- 비교 지수: KOSPI

[그림 1] 백테스팅 결과(누적수익률 그래프)



[표 4] 백테스팅 결과 통계치

	총 누적수익률	연 평균수익률	연 샤프비율
SmartBeta EMP	112.77%	16.30%	1.352
KOSPI(BenchMark)	17.33%	3.24%	0.289

5. Model 최적화 검증

Model 세분화를 통해 확장된 총 1,188개의 스마트베타 portfolio 후보군 중 수익률이 가장 좋은 포트폴리오를 Best Portfolio로 선정하여 리밸런싱을 진행하지만 최종적으로 선정된 Best Portfolio가 실제 투자기간에 선정되지 않은 나머지 1,187개의 포트폴리오에 비해 항상 좋은 성과를 내는 것은 아니다. 장기간의 백테스팅에서 최종적으로 선정된 포트폴리오가 실제 투자기간에서도 지속적으로 좋은 성과를 낸다면 Model이 안정적이라고 할 수 있다. 따라서 Model 검증을 위해 최종적으로 선정된 Best Portfolio가 선정되지 않은 포트폴리오들에 비해 좋은 성과를 내는지 확인하였다. 그 결과 장기간의 백테스팅에서 최종적으로 선정된 포트폴리오가 실제 투자기간 수익률은 상위 10.1%, 반대로 실제 투자기간에서 가장 좋은 수익률을 보인 포트폴리오의 전 기간 수익률은 상위 9.8%인 것을 확인하였다. 이 결과를 토대로 전략의 Model이 안정적인 것을 확인하였다.

Futures pairs trading strategy using system trading & high frequency data

본 전략은 일정한 상관관계를 갖는 만기가 다른 두 해외 선물 계약을 대상으로 초 단위 데이터를 활용하여 스프레드가 통계적으로 유의미한 범위를 이탈했을 때 상대적으로 높은 수익률이 예상되는 계약을 매수, 낮은 수익률이 예상되는 계약을 매도하는 차익거래전략이다.

1. 소개

D.A.R팀은 해외 선물시장에서의 페어트레이딩 전략을 확장하여, 초 단위 데이터를 통한 투자 범위의 확장과 운용스타일의 다변화를 시도하였다. 또한, 페어트레이딩 전략은 대상이 되는 자산 간의 가격 움직임이 높은 상관관계를 가지되 그 스프레드는 적당히 변동성을 가질수록 더 좋은 성과를 기대할 수 있기 때문에 본 전략에서는 근월물-차월물간의 페어를 이용하여 페어트레이딩을 진행하였다. 이외에도 기존의 페어트레이딩 전략과 달리 pair selection과 trading의 분리, loss cut 기준 강화전략 등을 통해 다양한 가능성을 확인하였다.

2. 자료

종목 유니버스 구성을 위해 총 6개 종목의 해외 선물을 선정하였으며, 종목 선정 기준은 레버리지(계약단위* 가격조정계수) 2000이하이다. 이 6개의 종목 Pool은 국내에서 증권사를 통해 실제 거래가 가능한 종목들이다. 데이터 기간은 2017년 7월 24일 AM 6:40:31부터 2018년 8월 7일 PM 3:43까지로 농산물(Soybean, Soybean oil, Soybean Meal, Rough Rice, Oats) 5종목, 축산물(Lean Hog) 1종목 등 6개 자산에 대해서 해당 기간의 모든 월물의 초 단위 데이터를 사용하였다. 해당 기간 초 단위 데이터는 블룸버그에서 제공하는 데이터를 사용하였다.

3. 방법론

기존의 페어트레이딩 전략들과 달리 본 전략은 Pairs Selection과 Pairs Trading의 2단계로 분리하여 진행하였다. 실제 system trading시 블룸버그와 데이터 계약이 체결되어 있지 않은 상태에서 초 단위 데이터를 실시간으로 블룸버그 단말기로부터 받아와서 트레이딩을 하는 것이 현실적으로 불가능하기 때문에 백테스팅 단계에서부터 pairs selection과 Trading을 분리하여 진행하였다. 또한, pairs를 미리 선택하여 트레이딩 단계에 진입해도 전략이 유의한지를 확인하였다. 구체적으로 selection period는 7일, trading period는 8시간으로 설정하였으며, 거래 시간대는 해외상품선물이 가장 활발하게 거래 되는 오후 20시부터 오전 04시까지로 설정하였다.

구체적인 pairs selection과 pairs trading methodology는 다음과 같다.

- 선형회귀 분석 (regression)

OLS(Ordinary Least Square) Method를 통해 서로 다른 두 월물 간의 선형 관계를 통하여 계산되는 잔차를 도출한다.

- Co-integration & Correlation

1) Co-integration

첫 번째 회귀 분석에서 계산된 잔차의 시계열이 정상적(stationary) 과정임을 확인하기 위해 co-integration test를 진행한다. 이 test를 진행하는 이유는 서로 다른 두 월물이 불안정적인 시계열을 가질 경우 회귀분석만

사용하게 되면 두 월물이 실제로 아무런 관계가 없음에도 불구하고 두 월물간의 관계를 오해하거나 예측 값을 잘못 추정할 우려가 있기 때문이다. co-integration test는 ADF test(Augmented Dickey-Fuller test)를 통해 일반적으로 많이 사용하는 95% 신뢰도 하에서 검증한다.

2) Correlation

페어트레이딩 전략은 대상이 되는 자산 간의 가격 움직임이 높은 상관관계를 가지되 그 스프레드는 적당히 변동성을 가질수록 더 좋은 성과를 기대할 수 있다. 일반적으로 선물(Futures)의 변동성이 크고 근월물과 차월물이 높은 상관관계를 보인다는 특성을 고려하여 correlation test를 통해 0.8 이상의 높은 상관관계를 가지는 월물들을 골라낸다. 이와 같은 과정들을 통해 실제 trading에 사용될 pair들을 선정하며, trading period인 8시간동안 미리 선정된 pair로 trading을 진행한다.

- Pairs Trading

1) open / close signal

페어트레이딩 전략으로 좋은 성과를 내기 위해서는 진입과 청산의 시점 및 조건이 매우 중요하다. 본 전략은 기존의 페어 트레이딩 전략과 달리 초 단위 데이터의 이점을 최대한 활용하여 스프레드가 균형 점에서 얼마나 이탈해 있는지 그 위치를 비교적 정확하게 잡아내어 진입, 청산조건을 세분화하였다.

구체적으로 pairs selection 단계에서 정한 pair들로 trading period에 진입하기 위한 신호는 다음과 같이 세분화할 수 있다.

- open / close signal : 1 / mean
: 전일 잔차가 1 ~ 2 사이에 있고, trading period동안 균형점 방향으로 회귀하면서 1 기준선을 히트 하는 경우
- open / close signal : 2 / mean
: 전일 잔차가 2 ~ 3 사이에 있고, trading period동안 균형점 방향으로 회귀하면서 2 기준선을 히트하는 경우

월물들의 잔차를 분석한 결과 어느 정도의 모멘텀 효과가 있는 것으로 파악되었기 때문에 더 정확한 신호를 받기 위하여 두 경우 모두 잔차가 mean reverting 하려는 추세에 있을 때를 진입 신호로, 진입 뒤 균형점(mean)으로 회귀할 때를 청산신호로 설정하였다.

기존 전략들과 달리 초 단위 데이터를 활용하면 trading period 내에 상당히 많은 수의 진입신호를 받게 되지만 거래비용을 고려하게 되면 이익보다는 손실로 끝나는 pair들이 많다. 따라서 전략의 성과를 높이기 위해서는 진입신호를 받은 수많은 pair들 중에 실제로 이익이 날 만한 pair를 선별하는 작업이 필요하다.

2) 거래비용 및 mean reverting speed를 고려한 profitable pair 선정

NH선물 HTS에서 제공하는 거래비용 자료(매수 혹은 매도 1계약당 \$8)를 참고하여 1개의 pair를 매도 및

매수하는데 투입되는 거래비용을 1계약당 \$32로 설정하고 진입신호를 받은 수많은 Pair들 중 거래비용을 초과하여 이익을 낼 수 있는 profitable pair를 선별한다. 거래비용을 고려한 profitable pair 선별 알고리즘은 진입신호 기준에 따라 다르게 적용된다.

가. 거래 비용을 고려한 profitable pair 선정

- open / close signal : 1σ / mean

: 진입 신호가 1σ 인 경우 거래비용(\$32)을 고려하여 $1\sigma \geq \$32$ 인 pair를 profitable pair로 선별하고 \$32를 초과하지 않는 pair들은 진입신호기준 정수배를 통해 거래비용을 초과하여 이익을 낼 수 있게끔 진입 신호를 엄격하게 적용한다.

- open / close signal : 2σ / mean

: 진입 신호가 2σ 인 경우 거래비용(\$32)을 고려하여 $2\sigma \geq \$64$ 인 pair를 profitable pair로 선별하고 \$64를 초과하지 않는 pair들은 진입신호기준 정수배를 통해 거래비용을 초과하여 이익을 낼 수 있게끔 진입 신호를 엄격하게 적용한다.

나. Mean reverting speed를 고려한 profitable pair 선정

스프레드가 균형점으로 빠르게 회귀하려는 성향을 가진 pair는 trading period내에 가장 먼저 청산신호를 받을 가능성이 있다. 따라서 거래비용을 고려하여 profitable pair를 선별한 뒤에도 여러 개의 profitable pair가 있다면 mean reverting speed를 고려하여 최종적으로 하나의 pair를 선택한 뒤 매매를 진행한다. 거래는 최종적으로 선정된 1개의 pair만 가지고 진행을 하며 선정된 pair가 청산된 후 trading period 내에 위 과정을 반복한다.

- Loss cut 기준 설정

최종적으로 선정된 profitable pair가 진입 신호에 따라 진입한 후, 예상과 달리 스프레드가 불리한 방향으로 발산하는 경우 선물거래의 특성상 막대한 손실을 볼 가능성이 있다. 따라서 좋은 성과를 낼 수 있는 profitable pair를 선별하는 것만큼 중요한 것은 큰 손실을 막기 위한 안전장치인 loss cut 기준을 정교하게 만드는 것이다. 본 전략은 기존의 페어트레이딩 전략과 달리 loss cut기준이 세분화되어 있다.

1) 추세 이탈 기준 (σ 기준)

Pair가 진입 신호를 받아 진입한 이후에 진입 당시의 스프레드 값을 기준으로 이보다 불리한 방향으로 1σ 만큼 더 발산하면 loss cut한다. 예를 들어 open signal이 1σ 이면 2σ 가 loss cut 기준이 되고, 2σ 이면 3σ 가 loss cut 기준이 된다.

2) 거래 시간 제약 기준

Trading period (20:00~04:00)가 종료되는 시점에서는 손익상황에 관계없이 포지션을 청산한다.

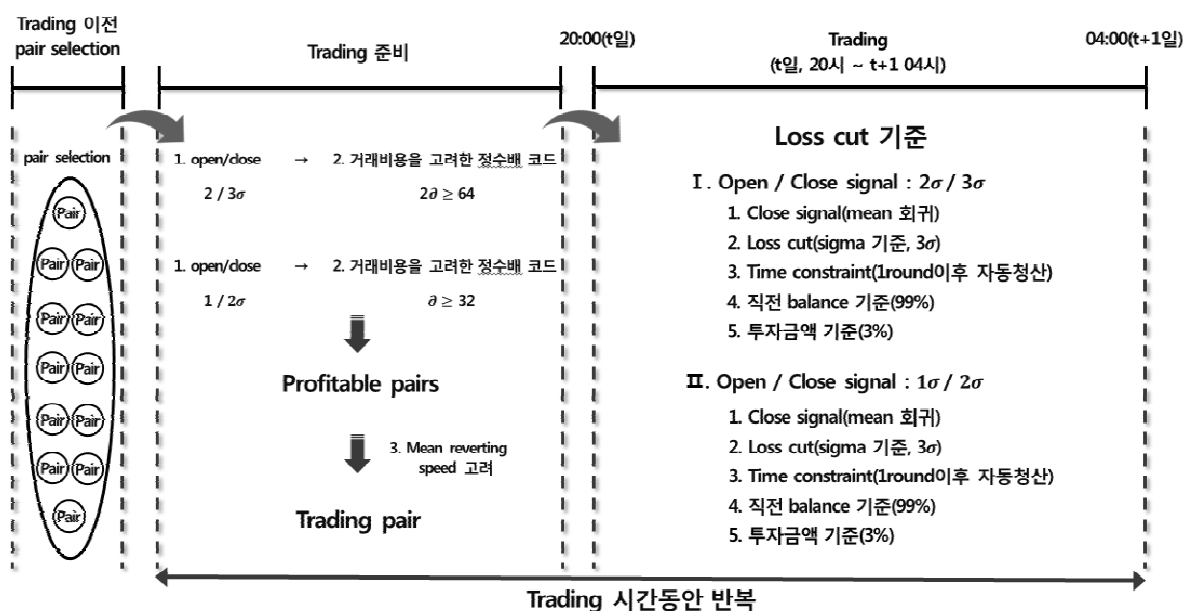
3) 거래 직전 밸런스 기준

Pair가 진입 신호에 따라 진입한 후에 스프레드가 진입 시와 반대의 양상이 나타나면 손실이 누적되는데 σ 기준 loss cut만으로는 막대한 손실을 방지하기 어렵다. 따라서 예상치 못한 큰 손실을 막기 위해 σ 기준 loss cut과 함께 추가적인 안전장치가 필요하다. 거래 직전 밸런스 99% 기준을 함께 활용하면 발생 가능한 최대 손실을 제한하는 장점이 있다.

4) 초기 투자금액 기준

투자금액 기준 3% loss cut기준이 필요한 이유는 선물거래는 그 특성상 변동성이 매우 크기 때문에 많은 거래를 통해 이익을 냈더라도 단 한 번의 거래로 큰 손실을 볼 수 있으며 앞선 기준들로는 큰 손실을 방지하기에 충분하지 않다. 따라서 일단 스프레드가 불리한 방향으로 발산하기 시작하면 trading period 내에 이익을 낼 가능성이 크지 않기 때문에 투자금액 기준 3%로 한 번의 거래에서 최대 발생 가능한 손실을 초기 투자금액의 3%로 제한한다. 일련의 Trading 과정을 요약하면 다음과 같다.

[그림 2] Trading 과정 요약도



4. Backtesting 결과

- 결과

앞서 설명한 전략으로 다음과 같은 조건하에서 백테스팅을 진행하였다.

1. Data: 초 단위 데이터(2017/07/24 AM 6:40:31 ~ 2018/08/07 PM 3:43) [블룸버그 데이터]
2. Futures Universe: lean hog, soybean, soybean oil, soybean meal, rough rice, oats
3. Formation period (7일) / Trading period (8시간)
4. 거래비용: 매수 혹은 매도 1 계약당 \$8
5. 초기 증거금 대비 10%씩 투자
6. Initial balance: \$100,000

먼저 전략 백테스팅 결과를 살펴보면 2017년 7월부터 2018년 8월까지의 총 누적 수익률은 378.38%를 기록하였다. 결과에서 주목할 점은 백테스팅 기간 동안 안정적인 수익을 내고 있다는 것이다. 이 결과는 전략의 핵심 알고리즘인 거래비용을 고려한 profitable pair 선정, loss cut 기준의 정교화가 실제 백테스팅에서도 효과를 발휘한다는 것을 보여준다.

[표 5] 거래비용을 고려한 백테스팅 결과

max profit	\$ 4,777	max loss	- \$ 4,420
mean profit	\$ 1,010	mean loss	- \$ 583
total balance	\$ 478,385		
총 누적 수익률	378.38%		

- Slippage problem

선물 매매 시 시장가주문(market order)을 넣었을 때 주문을 넣은 시점의 가격으로 체결되지 않고 불리한 가격으로 체결되는 것을 슬리피지(slippage)라고 한다. 선물 System trading의 경우 슬리피지 문제가 전략의 실행 가능성을 좌지우지하며 전체 수익의 50% 이상을 결정한다. 또한 본 전략은 해외상품선물을 대상으로 근월물-차월물간의 페어를 이용하였고, 선물의 특성상 원월물로 갈수록 유동성이 급격하게 하락하기 때문에 슬리피지 문제에 훨씬 더 취약하다. 1번 백테스팅 결과는 슬리피지를 '0'으로 가정해서 슬리피지 자체를 무시했기 때문에 전략 수익률이 과대평가 되었을 가능성이 있다. 따라서 보다 정확하게 성과를 측정하여 전략을 평가하기 위해 슬리피지 비용을 고려하여 다시 한 번 백테스팅을 진행하였다.

선물의 경우 상품별, 만기별 유동성이 천차만별이며 초 단위 호가데이터를 구할 수 없기 때문에 상품별 만기에 따른 일 평균 bid-ask spread를 확인하여 슬리피지 비용을 추정했다. 슬리피지 비용 추정시 사용한 일 평균 bid - ask spread는 9.19%이며 거래비용(슬리피지 비용 포함)을 고려한 백테스팅 결과는 다음과 같다.

[표 6] 거래비용(슬리피지 비용 포함)을 고려한 백테스팅 결과

max profit	\$ 4,504	max loss	- \$ 4,715
mean profit	\$ 939	mean loss	- \$ 573
total balance	\$ 317,152		
총 누적 수익률	217.15%		

5. System Trading

Trading period는 해외선물거래가 가장 활발히 일어나는 20:00 ~ 04:00으로 설정하였다. 시간대가 한국 기준으로 밤 ~ 새벽이기 때문에 현실적으로 trading signal을 투자자가 직접 받아 매매를 하는 것에는 한계가 있다고 판단하여 trading signal을 자동으로 받아 매매를 하는 시스템을 구축하였다. 매매 시스템은 NH선물 API를 사용하였다. NH선물 API를 사용하면 HTS서버와 데이터를 주고받을 수 있고 주문/체결 등의 매매 기능을 사용할 수 있게 된다. VBA로 구축된 매매시스템은 선물의 현재가, 거래량을 실시간으로 받아와서 Python으로 구축된 pair trading 서버로 데이터를 보내준다. 데이터를 받은 pair trading 서버는 데이터를 바탕으로 trading signal을 계산하고 open signal이 잡히면 매매시스템으로 주문을 전송한다. 주문 전송 후에도 실시간으로 현재가와 거래량 데이터를 받아서 pair trading 서버로 데이터를 보내고 서버는 loss cut signal을 계산하여 loss cut signal이 잡히면 매매시스템으로 매도 주문을 전송한다.

3. 기술 지원팀 소개

• Technical Support Team


탄생 배경

1. 반복적인 작업

Quant 투자를 모토로 하고, 백테스팅에 근거한 투자를 추구하는 KSIF에서 가장 중요한 작업은 데이터 수집, 백테스팅, 각종 통계 검증이다. 이러한 기초작업들은 새로운 전략 구상에 비해 단순하고 반복적이지만, 이 작업에서 실수가 있으면 전략 백테스팅 결과에 오류가 발생하며, 새로운 전략 수립의 근거가 부실해 진다. 15기 펠로우들 중 일부가 자발적으로 KSIF 라이브러리 프로젝트를 시작하게 된 것도, 바로 이 기초작업이 중요하다고 생각하기 때문이다.

우리는 반복적인 작업을 극복하기 위해, 필요한 코드를 한 곳에 모아 함께 사용할 수 있는 라이브러리를 만들기로 하였다. 이렇게 반복적인 작업을 한 곳으로 모으게 되면 우선 코드의 양이 줄어든다는 장점이 있다. 작성해야하는 코드의 양이 줄어들면, 전략을 검증하는 데 드는 시간 역시 줄어들고, 이는 곧 전략을 구상하는데 더 많은 시간을 할애하여 더 나은 전략을 수립할 수 있다.

[그림 1] KSIF Library 사용 전 후 프로그래밍 효율성



2. 실수

KSIF에는 실력이 출중한 많은 펠로우들이 있음에도 불구하고, 사실상 다른 팀의 코드를 볼 기회가 없다. 그렇다 보니 상호 검증을 할 수 있는 기회가 적고, 팀 내에서 소수의 사람이 코드를 작성하고 검증하게 된다. 그 결과 실수를 사전에 발견할 수 있는 확률이 상대적으로 낮다. 특히 데이터를 다루는 경우, 실수가 발생하더라도 검증하기 어렵고,

따라서 한 번 데이터터를 잘못 설정하게 되면, 이를 기반으로 수립된 전략은 치명적인 결함을 가지게 된다.

Technical Support Team(이하 Tech 팀)은 집단 지성을 이용하여, 이러한 실수를 극복하고자 한다. 이를 위해 Tech 팀원들은 각자의 팀 회의와 별도로, 정기적으로 Tech 팀 회의를 가지며 서로의 코드를 리뷰한다. 단순히 오류를 없애는 것을 넘어, 코드의 가독성을 높이고 효율적인 코드를 만들기 위해 서로가 가진 지식을 나누고 함께 공부한다. 이를 통해 각 팀의 코드에 확신을 가지고 전략을 연구할 수 있다.

3. 전략 유실

KSIF의 펠로우들은 일 년 간 활동하며, 각 팀은 한 학기에 2~3명의 신입 펠로우를 받는다. 그리고 6개월 뒤 신입 펠로우들은 또 새로운 신입 펠로우를 맞이하고, 기존 펠로우의 도움 없이 스스로 팀을 이끌어 나간다. 6개월 안에 기존의 전략을 100% 이해할 수 있으면 다행이지만, 예기치 않게 팀원이 탈퇴하거나 교육이 잘 이뤄지지 않을 경우, 기존 전략이 유실되고 코드는 남아있지만 유지보수를 할 수 없는 일이 발생한다.

Tech 팀은 서로의 작업 과정을 이슈 추적 시스템과 공개 사용 설명서를 통해 공유하고 결과물을 문서화하고 있다. 신입 펠로우는 이를 통해 과거에 선임 펠로우들이 이슈를 어떻게 해결했는지 배울 수 있다. 또한 튜토리얼과 예제를 통해 라이브러리의 사용법을 익힐 수 있도록 도움을 준다.

KSIF Library 소개

1. 간편한 설치

KSIF 라이브러리는 파이썬 라이브러리 공유 시스템인 PyPI에 등록이 되어 있기 때문에, 터미널에서 `$ pip install ksif` 만으로 필요한 코드가 모두 다운로드 된다. 코드의 수정이나 새로운 기능 추가가 있을 경우에도 PyPI를 통해 배포되며, 이 경우에는 `$ pip install -U ksif` 로 라이브러리를 업데이트할 수 있다.

2. 공통 데이터셋 제공

KSIF에서는 주로 FnGuide에서 제공하는 DataGuide를 이용하여 데이터터를 확보하고 있다. DataGuide의 경우 엑셀을 통해 다운로드하는 형태로, 소량의 데이터터를 받을 때는 유용하지만 모든 주식의 데이터와 같은 대량의 데이터터를 받을 때는 수 시간이 소요된다. 따라서 각 팀별로 리밸런싱을 진행하기 위해서는, 팀마다 따로 많은 시간을 들여 데이터터를 받아야 한다. KSIF 라이브러리는 담당자가 미리 방대한 데이터터를 KSIF 라이브러리의 파일 저장소에 미리 저장해 둬으로써, 코드를 돌리면 빠른 시간 안에 웹에서 데이터터를 받을 수 있게 구성되었다. 한 번 받은 데이터터는 컴퓨터에 저장되어 그 다음부터는 더 빠르게 데이터터를 사용할 수 있으며, 처음 사용하는 데이터터의 경우 1분, 이미 사용했던 데이터터의 경우 6초 만에 데이터터를 읽어 사용할 수 있다. 따라서 사용자는 데이터터를 받기 위해 별도로 홈페이지에 접속하거나 데이터터의 유무를 인식하지 않음으로써 시간을 절약할 수 있다.

3. 프로그래밍 모듈

– 전략 Back-Testing 모듈

KSIF 라이브러리를 사용하여 만들어진 포트폴리오는 한 번의 함수 호출로 수익률 뿐 아니라 active return, 정보비율과 같은 여러 지표를 제공한다. 백테스팅 코드는 벡터 연산을 적극적으로 사용하였기 때문에, 10년 이상 백테스트를 하더라도 2~3초 이내에 계산하고 결과를 출력할 수 있다. 향후에는 백테스팅 결과를 HTML 또는 PDF 형태의 보고서로 저장할 수 있도록 확장할 예정이다.

– 시각화 기능

KSIF 라이브러리는 전략 Back-Test 결과를 보고할 때 사용 되는 포트폴리오 누적 수익률 차트와 10분위 누적 그래프, 10분위 바 차트를 제공한다. 이를 통해 반복적이고, 많은 시간이 소요되는 시각화 과정을 줄일 수 있다.

예제

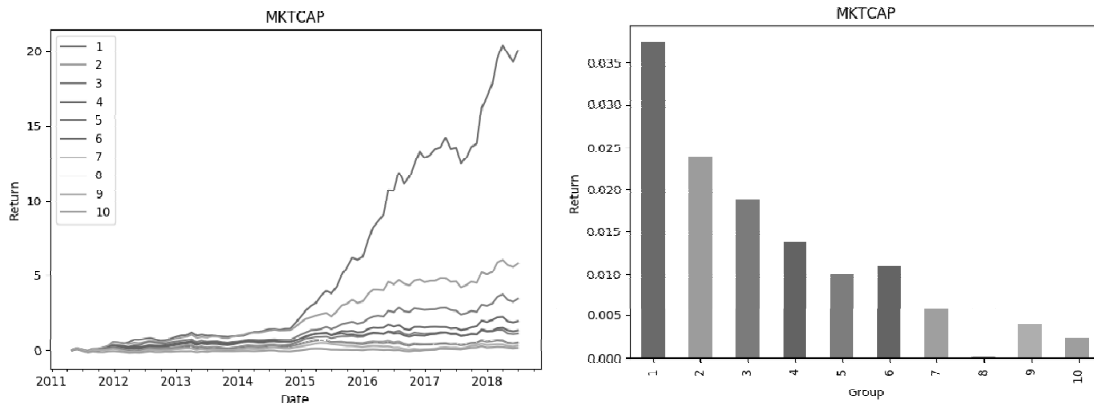
Tech 팀은 파이썬 프로그래밍을 통해 백테스팅 및 시각화에 필요한 module을 개발하여 공유하고 있고, 아래 예제처럼 KSIF 펠로우는 누구나 쉽고 빠르게 활용할 수 있다.

– 예제 1. 시가총액 기준 10분위 포트폴리오 수익률 비교하기

[그림 2] 예제 1. 파이썬 코드

```
1 from ksif import Portfolio
2 from ksif.core.columns import *
3
4 pf = Portfolio() # Portfolio 클래스 생성
5 universe = pf.loc[pf[DATE] >= '2011-05-31', :] # 2011년 5월 31일 이후
6 universe.quantile_distribution_ratio(factor=MKTCAP,
7                                     show_plot=True, # 누적 수익률 선형 함수 출력
8                                     show_bar_chart=True) # 월평균 수익률 바 차트 출력
```


[그림 3] 예제 1. 출력 결과



– 예제 2. KOSPI 시가총액 상위 30개 종목으로 동일가중 포트폴리오 구축하기

[그림 4] 예제 2. 파이썬 코드

```

1  from ksif import Portfolio
2  from ksif.core.columns import *
3
4  pf = Portfolio()
5  universe = pf.loc[pf[EXCHANGE] == '유가증권시장', :] # KOSPI 종목만 선택
6
7  # 시가총액 기준 상위 1등부터 30등
8  universe = universe.periodic_rank(min_rank=1, max_rank=30, factor=MKTCAP)
9
10 # 누적 수익률 그래프(기본 벤치마크 KOSPI)
11 universe.show_plot(title='KOSPI 시가총액 상위 30종목 동일 비중')
12 print(universe.outcome()) # 성과 지표
13
14 # Outcome:
15 # {
16 #   'total_return': 4.389634825319122,
17 #   'active_return': 0.022153266613092665,
18 #   'active_risk': 0.06330222781148329,
19 #   'information_ratio': 0.10102483660281546
20 # }
21

```

[그림 5] 예제 2. 출력 결과

