

투자전략

알고리즘의 기술



▶ 투자전략 박승영 | park.seungyoung@hanwha.com | 3772-7679 ▶ 주식시황 김수연 | sooyeon.k@hanwha.com | 3772-7628

“ α 는 존재하다 발견되면 사라진다 ”

| Contents |

I. 핵심요약	03
II. 기계의 알파는 인간	04
III. 기계는 어떻게 생각하는가	06
IV. 알고리즘 트레이딩	10
미시구조 (HFT)	10
규칙기반 (Rule Based)	12
알파 (α)	14
V. 기계와 인간의 투자	18
VI. 알고리즘의 조건	21
VII. 알고리즘의 기술	25

I. 핵심 요약

기계의 알파는 인간	인간이 생각하는 방식은 휴리스틱이다. 같은 변수를 입력해도 다른 결과값이 나올 수 있다. 기계가 생각하는 방식이 알고리즘이다. 같은 변수를 입력하면 같은 결과값을 내놓는다.
기계는 어떻게 생각하는가	기계는 사람이 못하는 일은 할 수 없지만 사람이 할 수 있는 일 중 특정 분야에선 인간을 앞서 있다. 기계만의 장점이 알고리즘 트레이딩에 녹아들고 있다.
알고리즘 트레이딩	기계는 두 가지 방법으로 시장을 상대한다. 첫번째는 대결 구도를 1대1로 만드는 것이다. 미시구조로 통칭되는 이 방식은 고빈도 매매를 통해 수익을 낸다. 두번째는 규칙에 기반해 투자하는 것이다. 리스크 팩터들이 노출되며 투자전략이 개발됐고 CAPM이 반박되면서 초과 수익의 원천들이 알려지기 시작했다.
기계와 인간의 투자	재량 운용과 시스템 운용을 비교하면 기계와 인간의 차이가 드러난다. 기계는 수행할 수 있는 전략의 수가 많지 않다. 정성적인 판단을 요구하는 전략을 사용하지 못한다. 변동성을 제한하기 때문에 벌 때 많이 못 본다.
알고리즘의 조건	투자 알고리즘의 성패는 절차와 규칙을 어떻게 정하느냐에 달려있다. 데이터의 양보다 데이터의 의미에 집중해야 하고 데이터의 개량도 중요하다. 테스트 결과를 바꾸고 싶은 유혹에 빠지지 않아야 하며 모델은 수익성보다 안정성을 더 중요하게 평가해야 한다. 금융시장이 전산화되고 금융 파생상품들이 많아지면서 포트폴리오 운용에서 기계의 활용은 늘어날 수밖에 없다. 리스크 관리는 포트폴리오 변동성 제어다. 실측 변동성으로 관리하고 내재 변동성은 시그널로 활용한다.
알고리즘의 기술	기계가 돈을 버는 건 인간보다 똑똑해서가 아니라 인간과 달라서이다. 기계는 감정을 배제하고 잘 보이지 않는 기회를 포착하지만 기업에 대한 깊이 있는 통찰에서 인간을 앞설 순 없을 것이다. 인간과 기계의 영역은 앞으로 더 분화할 것이며 먹이사슬의 최상단은 기계를 다루는 인간의 차지가 될 것이다.

II. 기계의 알파는 인간

인간의 편향,
알고리즘 트레이딩의 시작점

“알파는 인간의 편향을 가진 행동. 완전히 합리적이지 않은 행동이 없어지지 않는 데에서 비롯된다.”

알고리즘 트레이딩 입문서는 초과 수익의 근원을 행동 경제학의 시각을 빌려 위와 같이 설명한다. AI(인공지능), 기계를 이용한 투자를 금융시장에 진입하게 해준 건 데이터 증가, 연산능력 향상 등 기술이지만 금융시장으로 끌어들이는 건 인간의 비합리성이라는 것이다.

즉, 기계의 알파는 인간이다.

인간이 생각하는 법
‘휴리스틱’

인간을 종(species)의 관점에서 연구하는 진화심리학은 인간의 사고방식을 휴리스틱(heuristic, 발견법)으로 특징짓는다. 휴리스틱은 오랜 기간 우리의 두뇌가 진화한 결과다.

인간의 뇌는 복잡한 문제를 맞닥뜨리면 과정을 단순하게 만들어서 인지 과부하를 막는다. 그렇게 도출된 해결책은 딱 들어맞는 정답은 아니지만 제한된 시간과 연산 능력의 제약을 감안하면 충분히 만족스러운 수준이다.

이렇게 ‘나름 최선을 다한’ 의사결정은 투자에서도 자주 보인다. 투자자들은 분석하고 결정할 때 종종 사고의 단축키(shortcut)를 누른다. 그래서 잘못된 결정을 내리기도 하는데, 정보의 제약, 정박 효과, 확증 편향 등이 정답 도출을 방해한다.

그래서 인간은 상황과 맥락에 맞는 결론을 내놓는다. 휴리스틱은 같은 변수를 입력해도 다른 결과값이 나올 수 있다.


기계가 생각하는 법
‘알고리즘’

알고리즘은 휴리스틱의 반대말이다. 사전적 의미는 ‘목표를 달성하기 위해 설계된 일련의 절차나 규칙’이다. 기계가 문제를 해결하는 방식이기도 하다. 감정을 배제한 채 지정된 규칙에 따라 절차를 반복하기 때문에 알고리즘은 같은 변수를 투입하면 같은 결과값을 내놓는다.

대신 기계를 생각하게 하려면 변수들을 입력해줘야 한다. 기계는 많은 변수들을 함수화해서 처리할 수 있어서 패턴을 잘 찾는다. 인간이 2차원 이상을 시각화하지 못해 두 개 이상의 변수를 다루는데 어려움을 느끼는 것과 대조된다.

다음 페이지 [그림1]은 AI의 행동 범주를 나타낸 것이다. 인간의 뇌를 닮은 신경망은 기계를 학습시키는 방법이고 학습을 마친 기계는 규칙에 기반해 행동한다.

[그림1] AI를 이루는 요소들



자료: 데이터시 겐고 '친절한 딥러닝 수학' 재인용, 한화투자증권 리서치센터

III. 기계는 어떻게 생각하는가

IBM 딥블루의 전략

기계는 사람이 못하는 일은 할 수 없지만 사람이 할 수 있는 일 중 특정 분야에선 인간을 앞서 있다. 그러면 투자는 기계가 앞서 있는 분야일까. 기계가 발전해 온 과정과 현재 위치를 추적하면 답에 가까워질 수 있다. 인간이 기계에 패배한 사건들은 극단적인 예시이지만 동시에 이정표다.

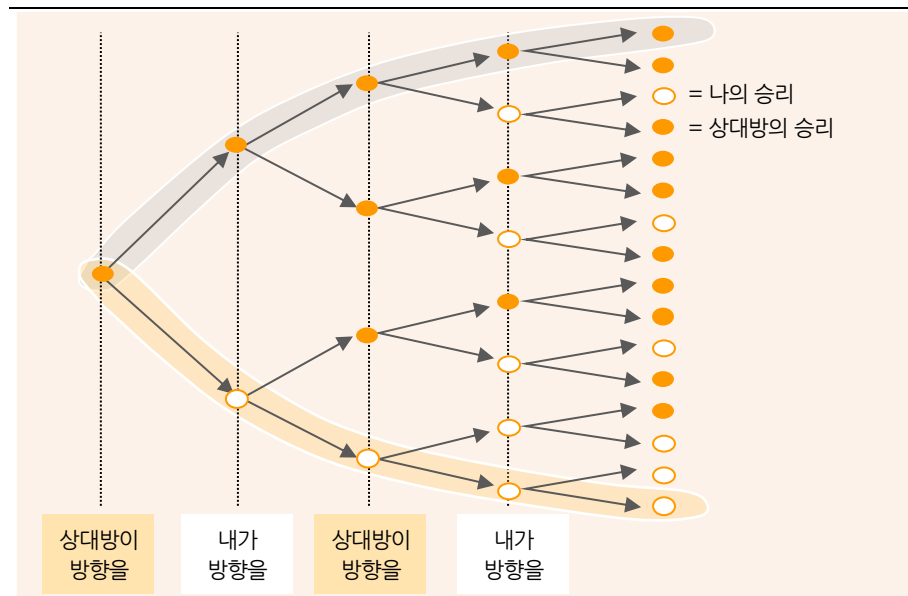
널리 알려진 인간의 첫 패배는 1997년 체스 그랜드 마스터 가리 가스파로프가 IBM의 인공지능 ‘딥블루(Deep Blue)’에 1승 3무 2패로 패배한 사건이다.

딥블루의 전략은 평가함수였다. 체스판 위에 올려져 있는 말들의 가치를 평가하는 것으로 자체특성과 위치특성으로 나뉜다. 자체특성은 가치가 높은 말과 낮은 말을 나누는 것이다. 퀸(Queen)에 나이트(Knight)보다 더 높은 가중치를 부여한다. 위치특성은 말들의 위치를 평가한다. 좋은 위치에 좋은 말이 있을수록 평가함수 값이 높아진다.

어떤 말을 어디로 움직일 것이냐로 평가함수 값을 추정할 수 있다. 딥블루는 트리 형식으로 경우의 수를 탐색했다. 앞으로의 수들을 계산해 보고 딥블루의 평가함수 값이 상대방의 값보다 높으면 그 수를 두게 했다.

딥블루는 ‘가지치기’를 수행해 최적을 경로를 찾았다. 딥블루가 꽤 좋은 경로 A를 발견하면 딥블루는 다른 경로 B도 검토한다. B를 검토하다가 상대에게 반격을 당해 패배하는 경우의 수를 발견하면 딥블루는 B의 검토를 중단한다. 상대방도 이 수를 찾아낼 것이라고 가정하기 때문이다. 이렇게 자신이 패배할 확률을 제거해 나가는 과정을 알파-베타 분기 가지치기라고 한다. [그림2]에선 맨 윗쪽 가지가 상대방이 승리하는 경로이므로 가지치기를 당한다. 맨 아랫쪽 가지는 딥블루가 승리하는 경로다. 딥블루는 다음 수로 맨 아래 경로를 선택하게 된다.

[그림2] 딥블루의 검색트리와 알파베타 가지치기



자료: 손 게리시 '기계는 어떻게 생각하는가' 재인용, 한화투자증권 리서치센터

IBM 왓슨의 전략

14년 뒤에 등장한 IBM의 또 다른 인공지능 ‘왓슨(Watson)’은 기계가 어떻게 데이터를 분류하는지를 보여줬다. 왓슨은 2011년 1월 IBM의 임시 스튜디오에서 인간 퀴즈 챔피언 켄 제닝스, 브래드 러터와 잡학 퀴즈쇼 ‘제퍼디’ 대결을 했다.

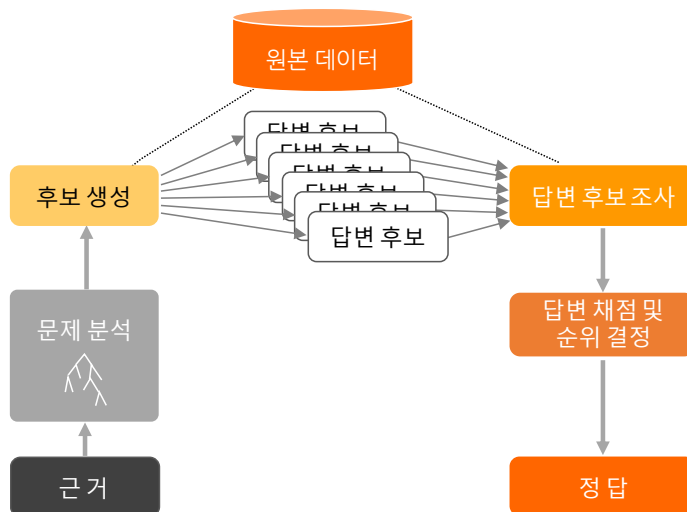
왓슨은 문제 분석에 구문분석(parse) 트리를 사용했다. 예를 들어 카테고리 ‘올림픽 상식’, 문제 : “차비치는 2008년 올림픽에서 이 사람을 거의 이겼지만 100분의 1초 차이로 패배했다”는 문제가 나왔을 때 왓슨은 ① (문제 유형 - 올림픽 상식) ② (초점 - 이 사람) ③ (답변 유형 - 인물) ④ (항목 - 밀로라드 차비치, 2008년 올림픽) ⑤ (관계 - 예게 패배하다) ⑥ (날짜 - 2008년)으로 분류했다.

왓슨 개발팀은 제퍼디 문제 정답의 95%가 위키피디아 항목의 제목에 포함돼 있다는 사실을 알아냈고 위키피디아를 정답 후보 생성 단계의 기초 자료로 활용했다. 위키피디아에서 ‘2008년 올림픽’, ‘차비치’를 검색하면 인물과 관련된 항목으로 라파엘 무노즈, 피터 판덴 호헨반트, 마이클 펠프스 등이 검색된다. 그러면 이들을 다시 위키피디아에서 검색한다. 마이클 펠프스에 대한 위키피디아에서 “그가 금메달을 땀다. 세르비아의 밀로라드 차비치를 100분의 1초 차이로 따돌렸다”는 문서를 발견할 수 있다.

이제 왓슨은 채점기 알고리즘에 후보들을 넣는다. 채점 레이어들은 마이클 펠프스와 관련된 정보가 문제의 분류기에 넣었을 때 얼마나 일치하는지를 채점하고 다른 정답 후보인 라파엘 무노즈나 판덴 호헨반트보다 점수가 높으면 마이클 펠프스를 정답이라고 판별한다.

인간은 주어진 단서들을 따라가면서 머릿속에 저장된 정답을 발견하고 출력하지만 기계는 후보들을 검토하고 증거에 기반해 확률을 추정해 정답을 선택한다. 기계의 접근법은 베이지안(Bayesian)이다.

[그림3] 왓슨의 구문분석 트리



자료: 손 계리시 '기계는 어떻게 생각하는가' 재인용, 한화투자증권 리서치센터

구글 알파고의 전략

구글의 바둑 알고리즘 ‘알파고(Alpha Go)’는 AI를 대중에게 성큼 다가서게 만들었다. 알파고는 생각하는 것처럼 보였고 결점이 없는 것 같았다.

바둑은 체스보다 어려운 게임이다. 무엇보다 경우의 수가 훨씬 많다. 체스 판은 가로 세로 8칸으로 총 64개의 칸이 있지만 바둑은 가로 세로 19칸으로 361개의 칸이 있다. 체스는 각각 말의 중요도가 달라서 평가함수를 사용하기 편하지만 바둑은 돌들의 가치가 모두 같다. 바둑의 평가함수는 돌들이 모여 있는 모양인 형세에 의존해야 한다.


알파고도 덩블루와 마찬가지로 현재 바둑판 상태에서 시작해 가상 대국들을 시뮬레이션 했다. 가상대국을 치르고 나면 알파고는 자신이 이겼는지 졌는지 알게 되고 승패 결과를 의사결정 트리의 상단으로 보냈다.

여기서부터가 중요하다. 알파고는 경우의 수를 가지치기 하기 위해 사람들이 뒀던 실제 기보(基譜)를 활용했다. 실제 프로 바둑 기사들이 둘 것 같은 수와 그렇지 않은 수를 구분해서 둘 것 같지 않은 수는 검색트리에서 제외했다.

기보를 학습한 뒤 알파고의 예측 신경망은 57%의 정확도를 나타냈다. 기보를 학습해 다음 수를 예측할 수 있게 됨으로써 알파고는 의사결정 시간을 줄일 수 있었다.

알파고 대 이세돌의 4국 78수, 끼움수는 알파고가 둘 확률이 1만분의 1 미만으로 계산한 수였다. 인간의 기보에는 없었던 수여서 신의 한수로 불리고 있다.

[그림4] 기계의 신경망



자료: 손 게리시 '기계는 어떻게 생각하는가' 재인용, 한화투자증권 리서치센터

대단하진 않지만
없었던 전략

인간 최강자를 이기며 세상을 놀라게 했던 기계들의 전략은 대단하지 않았다. 가능한 모든 경우의 수를 검토하고 패배하는 경로를 제거했고, 정답 후보들을 뽑아낸 뒤 증거들에 비춰 가장 확률 높은 후보를 정답으로 추측했다.

알고리즘이 지능을 갖췄다고 말하기는 어렵다. 다만 인간보다 더 뛰어난 부분이 있다는 점은 인정하지 않을 수 없다.

기계는 인간보다 더 많은 경우의 수를 검토할 수 있다. 그렇기 때문에 미래를 확률로 표현할 수 있다. 인간보다 더 많은 데이터도 수집할 수 있다. 그 많은 데이터를 분류하는 데에도 능숙하다.

이런 장점들이 알고리즘 트레이딩에 녹아들고 있다. 지금까지와는 다른 투자 기법이 만들어지는 중이다.

IV. 알고리즘 트레이딩

미시구조 (HFT)

미시구조를 이용하는 방법

주식 투자는 지금까지 살펴본 게임들과 다르다. 체스, 바둑은 1대1 대결이고 순서가 한 번씩 오고 간다. 주식 투자는 불특정 다수를 상대하고 순서가 정해져 있지 않다. 이런 불리한 조건에서 기계는 크게 두 가지 방법으로 시장을 상대한다.

첫번째는 대결 구도를 1대1로 만드는 것이다. 대상을 특정 개별종목, 주가지수로 좁히고 시간을 잘게 쪼개 반대편 거래 상대를 최소로 줄인다. 미시구조로 통칭되는 이 방식은 고빈도 매매(High Frequency Trading)를 통해 수익을 낸다.

2014년 미국에서 ‘플래시 보이즈 스캔들(Flash Boys Scandal)’이 있었다. ‘머니볼’의 소설가 마이클 루이스가 동명 소설에서 브로커들이 거래소들 간 호가를 조작해 이득을 취하고 있는 현상을 폭로했다.

미국은 한국과 달리 복수의 거래소를 허용하고 있어서 찰나의 순간에 거래소 간 가격 차이가 생길 수 있다. 고객의 주문을 받은 브로커가 더 낮은 가격부터 체결시켜야 한다는 규정을 악용했다.

예를 들어 한 브로커가 거래가 많지 않은 종목A를 1,000주 매수 주문을 받았을 때 거래소1에 99달러 100주 매도, 거래소2에 100달러 2,000주 매도가 있으면 거래소1에 먼저 주문을 내고 거래소2에 주문을 내야 한다. 이 주문을 미리 파악한 상대 브로커는 99달러에 100주가 체결된 직후 매도 호가를 101달러로 올려 이득을 취한다. 소설은 주문 속도를 높이기 위해 광케이블이 매립되는 장면으로 시작한다.

여의도 KT빌딩에 알고리즘 트레이더들이 모여있는 이유

한국엔 거래소가 하나여서 이런 차이거래는 불가능하다. 다만 더 빨리 주문을 내고 호가를 빨리 볼 수는 있다.

국내에서 현물 주문은 여의도 증권거래소로, 파생 주문은 부산 선물 거래소로 모인다. 여의도 증권거래소로 주문이 들어가기까지 두 개의 경로를 반드시 지나야 한다. 거래소로 들어가는 회선의 라우터는 여의도 전경련 빌딩 옆 KT 빌딩에 있다. 모든 주문은 우선 KT 빌딩(?)으로 모인다. 그리고 나서 거래소 옆 코스콤 전산실로 향하고 증권 거래소에 전달된다.

필자가 만난 상당수 알고리즘 트레이더들이 여의도 KT 빌딩에 입주해 있었다. 파생 프랩 트레이더 출신으로 알고리즘 트레이딩 회사 대표인 닉네임 ‘환’은 “여기 있다고 주문에서 이득을 볼 순 없다. 다만 시스템이 더 갖춰지면 시세가 더 잘 보일 수는 있을 것으로 기대하고 있다. 코스콤에 거래 시스템을 붙여놓은 모 증권사가 체결에 강점이 있는 것으로 알고 있다”고 귀띔했다.

한국에서도 대체 거래소에 대한 논의가 진행 중이다. 2년 후에 출범할 계획이 있다는 보도도 있었다. 국내에도 거래소가 늘어나면 미시구조를 다루는 알고리즘 트레이딩이 많아질 수 있다.

[그림5] 여의도 증권거래소에 주문이 전달되는 과정



자료: Google Earth, 한화투자증권 리서치센터

규칙기반 (Rule Based)


규칙에 기반한 투자	<p>두 번째는 규칙에 기반해 투자하는 것이다. 국내 대부분의 알고리즘 트레이더들이 이 방식을 사용하고 있으며 머신러닝을 운용에 적용하는 것도 이 범주에 들어간다.</p> <p>규칙에 기반한 트레이딩이 가능해지고 확대되고 있는 배경으로 세가지를 꼽을 수 있다. 1) 전자거래가 확산되며 자산, 지역이 통합됐다. 2) 연산 능력이 개선되고 데이터 관리가 쉬워지면서 통계적 방법이 개발됐다. 3) 리스크 팩터들이 노출되며 투자전략이 개발됐다.</p> <p>시장대비 초과 수익률이 베타 단일 요인에 근거한다는 아이디어가 반박되면서 초과 수익의 원천들이 알려지기 시작했다. 사이즈, 밸류, 모멘텀, 퀄리티 등이다.</p> <p>1세대 퀀트 애널리스트 닉네임 ‘퀀트’는 “CAPM이 맞으면 모든 차익거래 기회는 사라진다. 2000년 이전엔 주식시장과 채권시장이 분할돼 있어서 CAPM이 성립조차 하지 않았다. CAPM은 합리적이고 보수적인 시장참여자들이 동일한 기대를 갖는다고 가정하는데, 당시 시장 참여자들은 합리적이지도 기대가 동일하지도 않았다. 이렇게 CAPM의 가정이 맞지 않을 때 알파가 많아진다.”고 설명했다.</p>
한국 주식시장의 알파	<p>1991년 이후 5년 단위로 끊어 KOSPI 구성종목들의 베타와 알파 분포를 살펴보면 1991~95년부터 2011~15년까지는 베타 1, 알파 0으로부터 멀어졌다. 그러다 2016~20년에는 다시 베타 1, 알파 0쪽으로 수렴했다.</p> <p>외환위기 전까진 기업들이 돈을 벌지 못했고 국채 금리는 높은 한자릿수여서 시장 참가자들이 주식에 투자할 합리적 유인이 존재하지 않았다. 그러다 외환위기 이후 기업들이 돈을 벌기 시작하며 알파가 생겼고 2015년 이후엔 합리적인 시장 참가자들이 알파를 찾아내며 점차 사라졌을 것으로 추측한다.</p> <p>한국 주식시장에서 초과 수익의 원천은 투자와 수출이다. 시기별로 알파가 높은 업종과 종목을 살펴보면 1991~95년 통신, 1996~2000년 신규상장, 2001~05년 건설, 2006~10년 조선, 2011~15년 헬스케어, 2016~20년 인터넷이다. 투자를 늘렸지만 이익으로 전환하는데 실패한 기업들은 업종과 무관하게 마이너스 알파를 기록했다. 이런 주식시장의 특성을 반영해 모멘텀은 한국 주식시장에서 주요한 팩터로 작동해 왔다.</p>
알파의 등장과 소멸	<p>이를 계량적으로 보여주는 변수는 기업실적이다. 실적이 부상한 건 증권사 리서치센터가 기업실적을 분석하기 시작한 2000년 이후부터다. 지금은 실적이 주가에 어느 정도 영향을 미칠 지까지도 가늠할 수 있다. 이렇게 시장에 영향을 미치는 원인이 널리 알려지면 순수한 알파는 리스크 팩터가 된다.</p> <p>대형 자산운용사의 CIO인 닉네임 ‘센터장’은 “기업 재무제표가 가장 대표적인 알파 소스다. 2000년대 초반까지는 기업실적에 접근하는 것 자체가 어려웠다. 지금은 쉽게 찾아볼 수 있고 실적이 발표되면 알려지는 속도도 빠르다. 그래도 실적은 여전히 중요하다. 숫자가 아니라 숫자에 대한 해석이 알파가 됐다고 봐야 한다.”고 주장했다.</p>

[표1] 팩터와 작동 원리

팩터	작동 원리
모멘텀	투자자 행동, 자산효과, 시장 미시구조
가치	공정가치와 시장가격 간 차이 기회
규모	더 큰 변동성(high risk)에 대한 보상
퀄리티	이익 확실성에 대한 보상


자료: 한화투자증권 리서치센터

[그림6] 1990~2005년 KOSPI 구성종목 베타 분포




주: 60개월 월간 수익률 기준
자료: WISEfn, 한화투자증권 리서치센터

[그림7] 1990~2005년 KOSPI 구성종목 알파 분포




주: 60개월 월간 수익률 기준
자료: WISEfn, 한화투자증권 리서치센터

[그림8] 2006~20년 KOSPI 구성종목 베타 분포



주: 60개월 월간 수익률 기준
자료: WISEfn, 한화투자증권 리서치센터

[그림9] 2006~20년 KOSPI 구성종목 알파 분포



주: 60개월 월간 수익률 기준
자료: WISEfn, 한화투자증권 리서치센터

알파 (α)

알파의 등장 지난 20년 간 실적이 주가에 미치는 영향력이 점차 작아지는 과정을 다음 페이지 [그림 10]에 나타냈다. 2003년 이후 연도별로 1분기, 2분기, 3분기의 영업이익 추정치 변화를 조사했다. 4분기는 실적이 발표되기까지 기간이 길고 일회성 요인이 섞이는 경우가 많아 추정치가 주가에 미치는 영향이 약하다고 보고 제외했다.

실적 서프라이즈 포트폴리오는 해당 분기 3개월 동안 영업이익의 컨센서스 변화율 상위 25%로 구성했다. 주가 등락률은 다음 분기의 첫 45일을 측정했다.

실적 추정치 상향 포트폴리오는 당 분기 앞쪽 45일 동안 영업이익의 컨센서스 변화율 상위 25%로 구성했다. 주가 등락률은 당 분기 뒷쪽 45일을 측정했다.

서프라이즈 포트폴리오는 KOSPI와 KOSDAQ을 시가총액 가중 평균한 벤치마크를 2003년 1분기부터 2022년 3분기까지 81.4%p 아웃퍼폼했다. 관측한 60개 분기 중 아웃퍼폼한 분기는 35개로 승률은 58.3%였다. 누적 아웃퍼폼 비율을 누적 언더퍼폼 비율로 나눈 손익비는 2.18배였다.

추정치 상향 포트폴리오는 같은 기간 벤치마크를 52.9%p 아웃퍼폼했다. 승률은 61.6%로 더 높았지만 손익비는 1.22배로 더 낮았다.

알파의 소멸 서프라이즈 포트폴리오는 2015년 2분기까지 벤치마크를 아웃퍼폼했다. 이후부터 2019년 3분기까지는 벤치마크 수준이었고 2020년 1분기부터 다시 아웃퍼폼했는데, 그 폭은 이전보다 작았다.

실적 추정치 변화라는 팩터의 영향력이 점차 약해졌기 때문일 것이다. 그 증거를 추정치 상향 포트폴리오의 성과에서 찾을 수 있다.

실적 컨센서스의 영향력은 두 단계에 걸쳐 약해진 것으로 보인다. 첫 단계는 투자자들이 실적 추정치 변화가 초과 성과를 가져다 준다는 사실을 알아차리고 실적 추정치에 빨리 반응했던 2010년부터 2019년까지이다. 이 기간엔 실적 추정치가 상향되기 시작한 종목들을 실적 발표 이전에 매수하는 전략이 실적 발표 기간에 매수하는 전략보다 우월했다. 게다가 서프라이즈 포트폴리오의 초과 수익률이 사라지기 시작한 2015년 이후에도 추정치 상향 포트폴리오는 초과 수익률을 기록했다. 실적 추정치 상향 팩터의 영향력이 지속됐다는 증거다.

추정치 상향 포트폴리오는 2020년 1분기부터 벤치마크를 언더퍼폼하기 시작했다. 코로나 확산으로 실적 추정이 어려워지면서 분기가 끝날 때쯤에야 실적에 대한 정보가 알려졌을 수 있다. 더 큰 원인은 거시경제 상황과 이에 대응하는 정책 등 매크로 팩터들의 영향력이 실적보다 더 커졌기 때문이다.


이렇게 특정 팩터가 계속 초과 수익을 가져다 주지 않는다. 그리고 시장에 영향을 미치는 요인들의 가중치도 계속 달라진다. 매크로는 코로나 이전까진 경시되던 팩터였다.

알파의 활용 초과 수익의 원천을 발견하면 해당 팩터에 노출이 큰 종목들을 롱(long)하거나 비중을 높이고 노출이 적은 종목들을 숏(short)하거나 비중을 낮추는 방법으로 팩터를 드러낼 수 있다.

예를 들어 지금 국내 주식시장에 가장 영향이 큰 변수가 경기하강이라면 경기에 덜 민감한 퀄리티 팩터를 드러내 초과 수익을 기대할 수 있다. 국내 기업들 가운데 자산에서 현금 비중이 높은 종목들을 골라 비중을 높이고, 레버리지 비율이 높은 종목들을 골라 비중을 낮춰 트레이킹 에러를 만들 수 있다.

무엇이든 팩터가 될 수 있다. 재무제표를 가공한 비율부터 단기 기술적 지표까지를 포함한다. 단 이를 사용하는 투자자는 감수하고 있는 위험이 무엇인지 알고 있어야 한다.

[그림10] 실적 서프라이즈 포트와 실적 상향 포트의 초과 수익률




주: KOSPI, KOSDAQ 기업들 중 분기 영업이익 추정치가 존재하는 종목들 대상
 자료: WISEfn, 한화투자증권 리서치센터

예시: Rule Based Algorithm 설계

① 아이디어


주가 모멘텀이 떨어지는 일부 종목을 포트폴리오에서 제외한다. 전년에 수익률이 부진한 하위 20% 주식을 당해 포트폴리오에서 제거한다면 KOSPI보다 좋은 성과를 낼 가능성이 있을 것이다.



② 변수 설정

테스트에서 정할 변수는 리밸런싱의 빈도와 규모다. 리밸런싱을 월간으로 할지, 연간으로 할지, 성과 하위를 몇 %에서 끊는 것이 수익률을 극대화하는지 테스트한다.

백테스트와 표본외 테스트를 위해 기간을 나눈다. 1990년부터 2021년까지 32년에서 초반 90%인 1990~2018년은 백테스트 기간으로, 나머지 10%인 2019~2021년은 표본 외 테스트 기간으로 정한다.




③ 백테스트

③-㉠ 월간 리밸런싱

월간 리밸런싱으로 KOSPI를 가장 크게 아웃퍼폼한 것은 하위 32%를 제거한 포트폴리오다. 이 전략이 백테스트 기간에 KOSPI를 이긴 경험은 49.4%인데, 1990년 2월말부터 2018년 12월말까지 KOSPI를 66.5%p 아웃퍼폼했다. 시장을 이길 확률은 절반이 안 되지만 이길 때 크게 이긴다. 불안정해 보인다.

[월간 리밸런싱 KOSPI 아웃퍼폼 비율]




자료: WISEfn, 한화투자증권 리서치센터

③-㉡ 연간 리밸런싱

연간 리밸런싱에서 누적 수익률이 가장 높은 포트폴리오는 하위 27% 제거였다. 승률은 75%였고 1990년말 100p에서 2018년말 424p로 KOSPI 293p를 131%p 이겼다. 연수익률로 환산하면 5.30%였고 KOSPI를 1.38%p 아웃퍼폼했다. 너무 잦은 매매보다는 긴 팀의 매매가 변동성을 낮춰주는 효과를 냈다. 연간 리밸런싱이 월간보다 승률과 누적 수익률 모두 좋았다.

[연간 리밸런싱 상하위 포트폴리오 누적 성과]




자료: WISEfn, 한화투자증권 리서치센터

④ 표본 외 테스트

하위 27% 제거가 미래에도 성과가 있을 것인지 표본 외 테스트로 확인한다. 전년 주식수익률 하위 27% 주식을 당해 포트폴리오에서 제외하는 전략의 결과는 2019년과 2020년에는 KOSPI를 각각 1.3%p, 2.1%p 아웃퍼폼했고 2021년엔 2.3%p 언더퍼폼했다. 3년 누적 수익률은 46.6%로 KOSPI를 0.85%p 아웃퍼폼했다. 연수익률로 환산하면 KOSPI를 연 0.22%p 아웃퍼폼해 백테스트 기간보다 수익률 격차가 좁혀졌다.

[표본 외 테스트 성과]

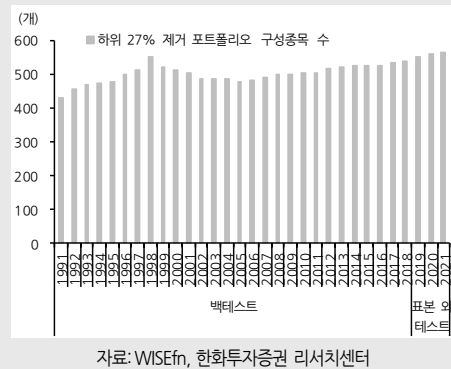


⑤ 운용에의 적용

채택한 룰을 실제 운용에 적용하려면 알고리즘과 실제 운용의 갭을 좁히고 운용상 발생할 수 있는 리스크를 관리할 수 있어야 한다.


저성과 주식을 편출하는 아이디어는 리스크 관리가 어렵지 않지만 상장주식 수가 많아지면서 포트폴리오에 편입되는 종목 수가 계속 늘어난다는 점이 부담이다.

[하위 27% 제거 포트폴리오 구성종목 수]




27%를 덜어내는 포트폴리오는 백테스트 기간 중 1990년대엔 평균 487개의 종목을 담았고 2000년대엔 505개의 종목을 담았지만 표본 외 테스트 기간인 2019년부터 2021년까지 평균 556개 종목을 담았다. 종목이 많아질수록 KOSPI에 대한 아웃퍼폼 정도는 떨어질 수 있다.

[KOSPI 상장]



합병이나 인적분할과 같은 이벤트를 어떻게 처리할지 결정해야 한다. 이 포트폴리오는 전년과 당해에 존속하는 기업들로 이뤄져 있기 때문에 기업이 소멸하는 경우는 고려하지 않았다. 세부적인 이벤트에 어떻게 반응할지 정하는 것이 전략을 촘촘하게 만들 수 있다.

[KOSPI 분할 이벤트]



V. 기계와 인간의 투자

기계가 수행할 수 있는 전략은 한정돼 있다

다음 페이지 [그림11,12]는 투자의 자유도가 높은 글로벌 헤지펀드들의 성과를 재량으로 운용되는 펀드들과 시스템으로 운용되는 펀드들로 나눠 비교한 것이다. 재량은 인간의 특성이, 시스템은 기계의 특성이 더 높을 것이다.

5년 기준 재량 헤지펀드의 수익률은 6.65%로 시스템 헤지펀드의 6.99%와 별 차이가 없었지만 5년 변동성은 재량 헤지펀드 9.40%, 시스템 헤지펀드 5.77%로 3.63%p나 벌어졌다. 같은 수익률을 올리는데 기계가 더 낮은 리스크를 감내하므로 투자의 세계에서 기계가 인간을 앞섰다고 생각할 수도 있지만 이 비교엔 몇 가지 맹점이 있다.

첫째, 기계가 수행할 수 있는 전략의 수가 많지 않다. [표2]는 시스템 헤지펀드들이 사용하는 전략들과 재량 헤지펀드들이 사용하는 전략들을 비교한 것이다. 지난 5년 동안 성과지표가 있는 전략으로 한정하면 시스템 헤지펀드의 전략은 6개이고 재량 헤지펀드의 전략은 11개로 배 가까이 차이가 난다.

또 재량으로만 운용되는 전략들은 절대 수익형이 많다. 원자재, 이벤트 드리븐, 채권, 특수 크레딧은 롱/숏, 상대적 가치와 비교하면 시장 노출도가 높은 전략들이다. 변동성이 클 수밖에 없다.


전략의 가짓수와 종류가 같다면 더 많은 변동성을 감내해야 더 높은 수익을 거둘 수 있다는 상식이 확인된다. [그림13,14]에 따르면 재량으로 운용되는 CTA의 변동성과 수익률이 시스템으로 운용되는 CTA에 비해 더 낮다.

둘째, 시스템 헤지펀드들은 이벤트 드리븐, 밸류 기반 등 정성적인 판단을 요구하는 전략을 사용하지 못한다. 이벤트 드리븐은 기업 인수합병, 유상증자, 신종자본증권 발행 등 기업 이벤트가 발생했을 때 특정 방향으로 포지션을 취해 수익을 낸다.

기대 수익률을 측정하는 것만큼이나 이벤트가 실제 성공적으로 종료될 가능성을 정성적으로 평가해야 한다. 가치 기반 투자 역시 사업모델, 주주구성 및 행동, CEO의 의사결정 등을 평가할 때 정성적인 평가가 수반된다.


셋째, 목표하는 변동성 대비 기대 수익 수준을 정하다 보니 별 때 많이 못 번다. 같은 매크로 전략을 수행해도 자유도가 높은 헤지펀드는 2014년 1월부터 2022년 10월까지 누적 32.6%의 수익을 올렸지만 전략을 CTA로 제한하면 누적 14.4%에 그쳤다. CTA는 헤지펀드의 전략 중 하나로 거래소에서 거래되는 규격화된 상품으로 투자 대상을 제한한다.

[그림11] 재량 운용, 규칙기반 운용과 수익률 비슷하지만




자료: preqin, 한화투자증권 리서치센터

[그림12] 리스크는 더 많이 감수




자료: preqin, 한화투자증권 리서치센터

[그림13] 투자 대상을 제한하면



자료: preqin, 한화투자증권 리서치센터

[그림14] 리스크와 수익률은 비례



자료: preqin, 한화투자증권 리서치센터


[표2] 헤지펀드 전략의 종류

(단위: %)

구분	헤지펀드 전략 분류	5년 연평균 수익률	5년 연평균 변동성	5년 위험조정 수익률
시스템	Credit Strategies	4.08	3.18	1.28
	Long Bias	4.05	13.32	0.30
	Long/Short Equity	5.32	5.33	1.00
	Macro Strategies	5.70	5.02	1.14
	Multi Strategy	4.70	4.07	1.15
	Relative Value Strategies	2.16	2.04	1.06
재량	Commodities	16.28	10.65	1.53
	Credit Strategies	3.48	5.66	0.61
	Equity Market Neutral	6.64	3.35	1.98
	Equity Strategies	6.53	12.18	0.54
	Event Driven Strategies	5.65	9.90	0.57
	Long Bias	5.74	15.81	0.36
	Long/Short Equity	6.81	9.57	0.71
	Macro Strategies	7.87	4.36	1.81
	Multi Strategy	5.49	7.13	0.77
	Relative Value Arbitrage	10.30	3.00	3.43
	Specialist Credit	2.51	8.61	0.29

자료: preqin, 한화투자증권 리서치센터

[그림15] 같은 매크로 전략이어도 운용 대상이 다르면 성과 달라



자료: Bloomberg, 한화투자증권 리서치센터

VI. 알고리즘의 조건

절차가 엄격해야 한다

투자를 위한 알고리즘의 성패는 절차와 규칙을 어떻게 정하느냐에 달려있다. [그림16]은 알고리즘 트레이딩의 설계도면이다.

1) 데이터를 가공하고 2) 예측을 위한 팩터들을 설정하고 3) 팩터가 드러나게 포트폴리오를 구성, 운용하고 4) 운용 결과를 모니터링하고 팩터들을 재조정하는 단계로 이뤄져 있다.

알고리즘 트레이딩 하우스에는 시스템 개발자, 리서치, 포트폴리오 운용역, 리스크 관리자 등이 있어서 각 단계를 담당한다. 리서치가 로직을 고안하면 개발자들이 시스템에 구현하고 운용역들이 감수 시행하면 리스크 관리자들이 모니터링한다.

헤지펀드 밀레니엄의 자회사 월드퀀트에서 리서치 컨설턴트로 일한 적이 있는 닉네임 '순두부'는 “월드퀀트엔 웹 시뮬레이션 시스템이 있어서 자신의 아이디어를 테스트해 볼 수 있다. 여기서 성과가 좋으면 리서치 컨설턴트가 되고 컨센서스 같은 더 고급 데이터를 쓸 수 있다. 로직을 만들고 백테스트, 표본 외 테스트를 거쳐 전략의 안정성을 검증하고 통과하면 트레이딩 전략으로 채택된다.”고 회상했다.

[그림16] 알고리즘 트레이딩 워크플로



자료: 스티븐 젠센 'Machine Learning for Trading' 재인용, 한화투자증권 리서치센터

데이터를 이해하고
입력해야 한다

알고리즘 트레이더들은 시스템을 개선하는데 많은 시간과 노력을 쏟고 있었다. 그들은 좋은 결과를 얻기 위해 좋은 변수들을 투입해야 한다는 점을 강조했다.

그들은 데이터를 많이 확보하는 것보다 데이터의 의미를 정확히 알고 쓰는 것에 더 집중해야 하고 비정형 데이터보다 정형 데이터, 특히 금융시장 데이터를 더 잘 다뤄야 한다는데 의견을 모았다.

국내 빅테크 자회사에서 퀀트 펀드를 운영하는 닉네임 ‘베이즈’는 “*모델을 만드는 건 데이터를 때려 넣어서 예측을 잘하게 될 때까지 하는게 아니다. 모델은 사람이 만드는 거고 데이터는 검증에 사용하는 것*”이라고 강조했다.

이 퀀트 펀드는 비정형 데이터를 쓰지 않고 있었는데, 베이즈는 “*블룸버그에 있는 매크로 데이터만으로도 좋은 모델을 만들 수 있다*”고 주장했다. 좋은 모델을 만들지 못하는 건 데이터가 없어서가 아니라 시장에 대한 인사이트와 아이디어가 없어서라는 설명이다.

국내 증권사에서 AI 사내 벤처를 이끌고 있는 닉네임 ‘SPEC’도 “*금융시장에 대한 이해 없이 데이터가 많다고 자랑하는 사람들은 상대하지 않는게 좋다. 금융 전문가가 기계를 다룰 줄 아는 것이 뛰어난 개발자가 금융을 적용시키는 것보다 더 좋은 결과물을 만들어내더라*”고 전했다.

데이터를 더 의미있게

데이터의 선별만큼 개량이 중요하다. 특히 금융시장 데이터는 시계열이 길지 않다는 특징이 있다. 100년이 넘는 미국 주식시장 데이터도 100년 중 위기 상황이 발생한 건 대공황과 금융위기 정도였다. 한국은 외환위기 정도를 꼽을 수 있다.

국내 대형 증권사에서 트레이딩 본부를 이끌고 있는 닉네임 ‘회계사’는 기계의 가장 큰 장점으로 유연성을 꼽으면서 “*기계가 미리 정해놓은 절차대로 움직인다고 해서 경직적이라고 생각할 수 있는데, 경험에 의존하는 인간보다 덜 경직적이다. 2022년 미국 금리가 상승할 때 사람은 3%에서 룱으로 전환했지만 기계는 그렇지 않았다.*”고 회고했다. 인간 경험의 시계열이 금융시장 데이터 시계열보다 짧다.

‘베이즈’는 외국 헤지펀드에서 일할 때 17세기 툴립 버블 시기의 매크로 데이터를 수집하는 걸 본 적이 있다. 더 긴 시계열의 정형 데이터를 더 갖는 건 알고리즘의 유연성을 높이는 강점이 될 수 있다.

백테스트 결과가 대단할 필요는 없다

예측을 위한 팩터들을 설정할 때 백테스트와 표본 외(out of sample) 테스트를 수행한다. 테스트 결과는 대체로 마음에 들지 않는다. 이때 변수를 조정하고 싶어지는데, 그 유혹에 빠지지 않는 것이 모델의 성패를 좌우한다.

백테스트 결과 엄청난 수익률을 올렸다는 주장을 어렵지 않게 볼 수 있다. 틀림 없이 과적합(overfitting)돼 있을 것이다. 과적합된 모델은 변수들이 백테스트를 수행한 기간에서만 설명력을 가진다.

과적합을 피하기 위해 표본 외 테스트를 수행하는데, 과거 10년을 백테스트 기간으로 설정했다면 10년 중 앞 9년의 백테스트 결과를 보고 그 변수들 그대로 10년 중 최근 1년을 대상으로 테스트하는 식이다. 과거 특정 구간에서의 수익률이 미래를 설명할 수 있는 지를 보기 위함이다.

테스트 결과는 누적 수익률보다 승률이나 손익비, 샤프 비율을 더 중요하게 봐야 한다. 모델의 수익성보다 안정성이 더 중요한 요소로 평가돼야 한다.

모델이 채택되는 승률의 한계점은 높지 않다. 필자는 55%를 넘어야 채택된다고 알고 있었지만 실제 채택되는 모델의 승률은 51~52%였고 50%도 있었다. 채택 여부에는 로직의 정성적 평가가 큰 부분을 차지했다.

‘베이즈’는 “개별 전략의 승률은 51%여도 된다. 상관계수가 낮은 전략들을 추가하면 승률을 높일 수 있기 때문이다. 30개 전략을 채택해서 쓰고 있는데, 전체의 승률을 53%까지 높일 수 있었다”고 말했다.

그는 “백테스트 결과 허들을 넘지 못한 모델은 파라미터를 조정하고 싶은 마음이 드는 게 당연한데, 바로 그때 버려야 한다. 그냥 버리기 아까워하는 그 마음이 오버피팅”이라고 조언했다.

운용에 기계의 접점은 늘어날 것이다

기계를 가장 많이 활용하는 단계는 포트폴리오 운용이다. 앞으로 더 늘어날 수밖에 없을 것이다. 금융시장이 전산화되고 금융 파생상품들이 많아지면서 기계의 접점이 확대되고 있기 때문이다. 거래 전략이 많고 복잡할수록 사람이 관리하기 어려워진다. 예를 들면 금융 파생상품은 만기가 돌아올 때마다 롤오버를 해야 하는 번거로움이 있다.

리스크 관리는 변동성 목표로

리스크 관리는 포트폴리오의 변동성 관리다. 실제로 시스템으로 운용되는 글로벌 헤지펀드들의 상당수가 목표 변동성을 제시하고 있다.

변동성을 제어하기 위한 방법들은 다양하다. 변동성에 따라 포지션 전체 규모를 조절하기도 하고, 보유 중인 자산들의 변동성이 각기 다르다면 변동성 작은 자산들을 더 많이 보유하는 리스크 패리티 전략을 사용하기도 한다.

이때 변동성은 실측치를 사용한다. 후행적이고 2020년처럼 시장이 급반등할 때 따라가지 못한다는 단점에도 불구하고 작년처럼 시장의 조정이 길어질 때에 효과를 볼 수 있다. 내재 변동성은 포트폴리오 운용에 적용하긴 어려워서 시그널로 활용된다.

블랙박스, 도전적인 분야 블랙박스는 알고리즘 트레이딩에서 도전적인 분야다. 모델의 작동 원리는 공개하지 않은 채 변수들을 투입하면 결과값이 도출되고 이에 따라 투자의사 결정이 내려진다. 모델의 로직을 사람이 짜면 퀀트, 기계가 짜면 알고리즘으로 분류하기도 한다.

블랙박스 모델은 로직을 보고 채택할 수 없기 때문에 테스트 결과에 전적으로 의존할 수밖에 없다. 이때 전략이 일반성을 확보했느냐가 채택의 기준이 되는데, 블랙박스의 백 테스트 값, 표본 외 테스트 값, 최근 시뮬레이션 값이 유사하면 모든 상황에 적용할 수 있다고 간주한다. 이런 모델은 미시구조를 다루고 있을 가능성이 높다.

그렇다 해도 과거의 성과가 미래의 성과를 담보하진 않는다. ‘순두부’는 블랙박스 모델을 동전 던지기에 비유했다. “동전을 던져서 10번 연속 앞면이 나올 확률은 1,024분의 1이다. 그러면 1,024개의 동전을 10번 던진다고 해보자. 그러면 한 개의 동전은 계속 앞면이 나올 것이다. 테스트 결과가 좋은 블랙박스 모델은 이 한 개의 동전과 같다.”고 설명했다.

인간과 기계의 협력 모델 운용에 직접 관여하지 않으면서 보조하는 알고리즘은 성장이 빠른 분야다.

하이프리퀀시 트레이더 닉네임 ‘호가창’은 “기계가 주연이 되기에 일러 보인다. 하지만 특정 역할을 주면 훌륭한 조력자는 될 수 있다. 운전 보조장치가 좋은 예시인데, 계속 앞을 보고 차선을 보는 건 기계가 더 잘한다. 사람은 갈림길에서 핸들만 틀면 목적지까지 힘을 덜 들이고 갈 수 있다.”고 말했다.

‘SPEC’도 “내일 주가를 맞히는 건 사람이 못하기 때문에 기계도 못한다. 하지만 주가 흐름이 비슷한 종목들을 분류하는 건 기계가 사람보다 잘한다. 테마주를 매매하는 사람이라면 기계의 도움을 받을 수 있을 것”이라고 주장했다.

시장을 모니터링하고 기회를 포착하는 도구로 쓸 때 기계는 활용도가 크다. 이는 기계와 인간의 현실적인 타협점이기도 하다.

Ⅶ. 알고리즘의 기술

기계와 인간의 장점은
겹치지 않는다

기계가 돈을 번다면 인간보다 똑똑해서가 아니라 인간과 달라서일 것이다. 기계는 감정을 배제하고 사람보다 더 많은 자산을 살피고 51% 승률의 기회를 포착한다. 포트폴리오의 리스크도 제한한다.

하지만 기업에 대한 깊이 있는 통찰에서 기계는 인간을 앞설 수 없을 것이다. 재무제표를 해석하고 기술력과 기업가 정신을 평가하는 일은 인간의 영역으로 남을 것이다. 먼 미래를 상상하는 것도 인간의 몫이다.

인간과 기계의 영역은 앞으로 더 분화할 것이다. 트레이딩은 기계의, 투자는 인간의 영역이 돼가고 있다. 먹이사슬의 최상단은 기계를 다루는 인간이 차지할 것이다.

[Compliance Notice]

자료는 투자자의 증권투자를 돕기 위해 당사 고객에 한하여 배포되는 자료로서 저작권이 당사에 있으며 불법 복제 및 배포를 금합니다. 이 자료에 수록된 내용은 당사 리서치센터가 신뢰할 만한 자료나 정보출처로부터 얻은 것이지만, 당사는 그 정확성이나 완전성을 보장할 수 없습니다. 따라서 이 자료는 어떠한 경우에도 고객의 증권투자 결과와 관련된 법적 책임소재에 대한 증빙으로 사용될 수 없습니다.