

アンブレラ型ポートフォリオによる国際分散投資

Nakatsuma Seminar Team

指導教官:慶應義塾大学経済学部教授 中妻照雄

慶應義塾大学経済学部3年 余田大典

慶應義塾大学経済学部3年 渡邊直斗

慶應義塾大学経済学部3年 野田直希

目次

1. はじめに	2
1.1 目的	2
1.2 アンブレラ型ファンド	2
1.3 投資銘柄の決定	2
1.4 ポートフォリオ構築	3
1.5 効率的市場仮説	3
1.6 全体として用いる手法・ツール	3
2. 人工知能ファンドの構築	3
2.1 概要	3
2.2 用いるモデル	3
2.3 投資先市場の選定	5
2.4 セクターの決定	6
2.5 銘柄選択	7
2.6 接点ポートフォリオ	8
3. 時系列解析ファンドの構築	9
3.1 概要	9
3.2 選定方法	9
3.3 時系列解析	9
3.4 結果	11
3.5 接点ポートフォリオ	17
4. 定性グローバルファンドの構築	18
4.1 概要	18
4.2 選定方法	18
4.3 用いた情報・手法	18
4.4 結果	19
4.5 選定過程	19
4.6 接点ポートフォリオ	24
5. アンブレラ型ファンドの構築	25
5.1 平均分散アプローチ	25
5.2 1ファンド定理	25
5.3 ポートフォリオ構築の手順	25
5.4 結果	26
6. まとめと今後の課題	27
6.1 人工知能ファンド	27
6.2 時系列解析ファンド	27
6.3 定性グローバルファンド	27
6.4 リバランスについて	27
6.5 全体のまとめ	27
7. 参考文献	29

1 はじめに

1.1 目的

本ファンドの目的は、今回のコンテストのパフォーマンス測定期間である2カ月という短期において、高収益・低リスク運用を突き詰めて目指すことである。そのためには、視野や選択肢を広げることが不可欠であり、グローバルな市場での投資を行うことにする。

本ファンドの特徴としては、(1) 高い収益率を目指しながらも、徹底的なリスク管理を行ったことである。高度な金融工学の手法を用い、ポートフォリオ保全のためのリスク尺度について慎重に設定した。(2) 高い再現性を実現することができた点である。本ファンドは、確立された分析手法やフレームワークを用いることにより、あらゆる市場変化にも対応することのできる柔軟性を獲得した。

1.2 アンブレラ型ファンド

我々のチームでは、絶えず変化していくグローバル規模の市場変化に柔軟に対応していくためのフレームワークとしてアンブレラ型ファンド[1]を採用した。アンブレラ型とは複数の異なったアプローチにより作成されたサブファンドをまとめて一つの傘（アンブレラ）のもとで運用を行っていく方式であり、多様な分析手法を採用することが可能となっている。

次に各サブファンドの概要を説明する。まず、時系列解析ファンドでは、高度なデータ解析や数理モデルを駆使して価格予測を行う。定性グローバルファンドでは、GAMという独自のフレームワークを用い、マクロ経済学や国際情勢、財務分析や企業価値算定など多角的な分析を行う。そして、人工知能ファンドでは最新鋭の人工知能技術を駆使した新しい投資手法を提案する。

Table1: 各サブファンドの特徴

	AIファンド	時系列解析ファンド	定性ファンド
選定過程	トップダウンアプローチ	トップダウンアプローチ	ボトムアップアプローチ
手法	ERNN	ARIMAモデル	GAM
用いるデータ	財務データ、株価	株価	財務データ、情報端末
資産配分方法	1 ファンド定理を用いた平均分散アプローチ		

1.3 投資銘柄の決定

今回のコンテストでは、前提として先物やオプションなどで用いられる証拠金取引や空売り取引は認められていない。そのため、2カ月という短い期間で高いリターンを出すためには、投資銘柄の決定は重要なファクターとなってくる。我々はいくつかの投資先を慎重かつ徹底的に吟味した結果、株式市場が最も有効であるという結論に達した。理由としては、(1) 株式銘柄の多様性からポートフォリオ構築をする際のバランスが最もとりやすいこと、(2) 本コンテストのグローバル投資という特徴を最も活かしやすいということ、(3) 多様な分析を行っていく上でのデータやプラットフォームが整っていること、などから表で示した分析手法を最も効果的に使うことができると考えたからである。

また、インデックスファンドを用いることで株式だけでは補いきれないリスクマネジメントを可能にした。これにより、キャピタルゲインを積極的に狙う株式を用いたアクティブ運用+リスクマネジメントとしてのインデックスファンドを用いたパッシブ運用のハイブリッド運用によって、柔軟なポートフォリオ構築が可能となった。

1.4 ポートフォリオ構築

ポートフォリオの構築は平均分散アプローチと1ファンド定理を用いて行う。詳しくは5章で解説をする。

1.5 効率的市場仮説

効率的市場仮説 (Efficient-Market Hypothesis, EMH) とは、市場は情報的に常に完全であるという仮説である[1]。つまり、金融商品の価格は現時点で利用可能な全ての情報を織り込んでいるということである。この仮説は経済理論の前提として使われることが一般的であるが、それと同時にこの仮説に対する批判も多く存在する[2],[3],[4],[5]。本レポートでは、ポートフォリオの価値を向上させることが目標であるため、効率的市場仮説に否定的な立場をとる。

1.6 全体として用いる手法・ツール

1.6.1 トップダウンアプローチ

トップダウンアプローチとは、銘柄選択手法の一種であり、マクロ的な視点から経済動向などの分析によって、どのような国や地域の資産に配分するかを決定する。その後、その資産配分の枠の中で選択する業種を絞り、その業種の中で最終的に個別銘柄を絞っていく方法である[6]。本レポートでは、AIファンドと時系列解析ファンドにて用いる。

1.6.2 プログラミング

人工知能や時系列解析などの高度な定量分析を要するファンドや平均分散アプローチを用いたポートフォリオ構築では適宜プログラミングを行うことが必須となってくる。人口知能ファンドとポートフォリオ構築ではPythonを、時系列解析ではRをそれぞれ使用した。まずPythonを用いるメリットとしては、近年機械学習やフィンテックなどの分野で爆発的な流行を見せており、簡潔かつ短時間で高品質のコーディングをすることができることがあげられる。一方のRは統計解析などを行う際に高レベルの手法を扱うことができ、この分野のエキスパートに最も愛用されている言語である。

2 人工知能ファンドの構築

2.1 概要

本ファンドでは近年世間で話題となっている人工知能を用いたファイナンス分析によって銘柄の選択を行う。人工知能を用いた分析が既存の統計学的手法に対して高いパフォーマンスが期待できるという研究は数多く存在し、今も活発に研究が行われている分野である。特に市場のトレンドをヒストリカルデータを用いて予測しようとする研究は数多く存在している[8]。銘柄の選択方法には投資先市場→セクター→個別銘柄の順に選定を行うトップダウン方式を使用する。序章では今回用いる機械学習技術の説明を行い、2章で投資先国の決定、3章でセクターの決定、続く4章で銘柄の決定までを行う。

2.2 用いるモデル

投資先市場の選択にはEvolutionary Recurrent Neural Network(ERNN)を用いて行う。このモデルを説明するために、まずモデルの基礎となっている基本的な技術について説明を行っていく。

2.2.1 人工ニューラルネットワーク

人工ニューラルネットワーク (Artificial Neural Network, ANN) とは脳の神経系をモデルにして人工的につくられた学習知能の一種であり、近年話題となっている人工知能と呼ばれるものは、このモデルを応用したものである。まず、この学習モデルはいくつかの入力に対して適切な教師データを与えていくことにより学習を進める。学習を進めるごとに予測値と教師データとのずれを修正していき、正しくデータを予測させることを試みたアルゴリズムである。

2.2.2 深層ニューラルネットワーク

深層ニューラルネットワーク（Deep Neural Network, DNN）とは、それまでの入力層と出力層のみのANNに対して、隠れ層の数を増やすことによって、より複雑な系に対しての予測を可能としたものである。いわゆるディープラーニングと呼ばれる技術であり、昨今の人口知能のブームに火をつけたのがこのモデルである。

2.2.3 バックプロパケーション

従来は隠れ層が入力層と出力層の2層の場合にしか有効な最適化法は確立されていなかった。しかし、隠れ層を含めた深層ニューラルネットワークの最適化を可能にしたのがバックプロパケーション（Back Propagation, BP）という最適化法である[10]。今日、DNNの最も一般的な最適化手法となっているが、局所解に陥りやすいという欠点が挙げられる。

2.2.4 再帰型ニューラルネットワーク

Minkolovら[11]によって開発された再帰型ニューラルネットワーク(Recurrent Neural Network, RNN)は系列データを扱うためのニューラルネットワークである。ファイナンスの分野で用いられる時系列データに対して、このモデルを適用した研究は多く存在する（[8],[12],[13]など）。RNNにもいくつかの種類が存在するが、本ファンドでは、Elmanネットワーク[14]と呼ばれる構造のRNNを用いる。

Figure1: 再帰型ニューラルネットワークの構造



2.2.5 遺伝的アルゴリズム

遺伝的アルゴリズム(Genetic Algorithm, GA)とは、環境に対する高い適応度を持つ個体を優先的に選択し、交叉、突然変異などを繰り返すことによって最適解を得ようとするアルゴリズムである。多数の個体を用いて同時平行に解を探索することによって最適解を得ようとする多点探索型の解放が注目を集めており、広い探索空間を有する多峰性関数に対してより短時間に最適解を発見できる能力を有していることが知られている[15]。

2.2.6 Neuro Evolution

前述したように、ニューラルネットワークの最適化手法にはバックプロパケーションが用いられることが多い。しかし、この方法ではある種の目的関数に対して有効でないことや、局所的最適解に陥りやすいという問題も挙げられる。特に複雑でノイズ成分も多い金融データの場合では、このデメリットが有用なモデル選択をする上で大きな弊害になると考えられる。そこで私は、ニューラルネットワークの最適化を遺伝的アルゴリズムによって行うNeuroEvolution[16]という技術に着目した。NeuroEvolutionを用いることにより、ニューラルネットワークの構造をより自由な形で設計することが可能となった。

2.2.7 Evolutionary Recurrent Neural Network (ERNN)

NeuroEvolutionの考え方は一般的なニューラルネットワークだけでなく、再帰型ニューラルネットワークにも応用できる。遺伝的アルゴリズムのような進化的アルゴリズムとを用いた再帰型ニューラルネットワークをEvolutionary Recurrent Neural Network[9]と呼ぶ。

以下、ERNNという呼称を用いる。

2.2.8 活性化関数

ニューラルネットワークでは、各層に存在するノード(シナプス)の出力に活性化関数(activation function)と呼ばれる非線形関数を適用する。従来は、シグモイド関数(sigmoid function)や双曲正接関数(hyperbolic tangent function)が用いられることが多かったが、現在はReLU(Rectified Linear Unit)が最も良いとされている[17][18]。本ファンドでも、活性化関数にはReLUを用いる。

2.2.9 過学習

過学習 (Overfitting) とは、訓練データに対して過剰に適合したために、未知のテストデータに対しては正しく予測できない状態を指す。いかに過学習を起こすことなく、よりテスト誤差を小さくできるかがニューラルネットワークの学習の鍵となってくる[19]。

2.2.10 データの加工

用いるデータは全てBloombergから入手したものを使用する。ニューラルネットワークの性質上、データを学習データとして用いる際には正規化を行う。ここで正規化とは、データを[0,1]区間にエンコードすることを言う。また、欠損値の扱いについては前後の値から適切に補完することが必要となる。特に財務データで多かった欠損値は前後の関係から適宜補完を行った。

2.3 投資先市場の選定

投資先市場の決定は一般的に、それぞれの市場に代表されるインデックス（ベンチマーク）の期待収益を予想、分析することによって行われる。ここで注意したいのは、いわゆるGreedy法と呼ばれる最大の収益が予想される方策のみを採用するのではなく、いくつかの市場に分散投資することで市場リスクを軽減するという点である。今回は流動性の観点から先進国の株式市場を分析の対象とし、さらにその中でも代表的な10の市場を分析する。市場分析に使われるインデックスには、以下の10種類を選定した。

Table2: 分析に用いるインデックス

CAC40	フランス、ユーロネクスト・パリにおける株価指数
DAW	アメリカ、ダウ平均株価
DAX	ドイツ株価指数
FTSE100	イギリス、ロンドン証券取引所に上場する時価総額上位100銘柄
HSI	香港ハンセン株価指数
NASDAQ	ナスダック株価指数
Nikkei225	日経平均株価
S&P500	アメリカ、S&P500指数
SX5E	ユーロ・ストック50指数
TOPIX	日本、TOPIX指数

この代表的な10指数のヒストリカルデータをBloomberg端末より引用し、ERNNを用いて期待リターンの高い上位5市場に対して分析を進める。なお、ヒストリカルデータには日次のものを用い、過去5年分のデータを学習させる。

2.3.1 ERNNモデルの決定

ERNNモデルを用いる際に決定すべきパラメータの設定について説明していく。

まずニューラルネットワークの構造決定に関しては隠れ層の決定が重要となってくる。隠れ層の数が多すぎれば、モデルが複雑になりすぎるために過学習の問題を発生しかねない。また、隠れ層の数が少なすぎても、正しく学習できない結果となってしまう。適切な学習のために、テスト誤差が小さくなるようにパラメータを機械的に設定した結果、隠れ層10ユニットのネットワークに決定した。

遺伝的アルゴリズムの設計に関しては個体数、突然変異率、親の選択方式、交叉方法などを決定しなければならない。これらのパラメータについても深く吟味し、あらゆる値で実験、考察を試みた結果、個体数は100、世代上限は3000、突然変異の方式は摂動型、親の選択はランキング方式、交叉方法は一様交差を用いることに決定した。なお、それぞれのパラメータの種類や比較についてはここでは触れない。遺伝的アルゴリズムの設計に関する論文([20],[21]など)は多くあるのでそちらを参照してほしい。

2.3.2 結果

ERNNに予測させた9月1日までの上昇率上位5市場は以下の通りになった。

Table3: 期待上昇率上位5市場

	市場	期待上昇率
1位	NASDAQ	8.5%
2位	DAW	5.2%
3位	FTSE100	4.7%
4位	S&P500	4.5%
5位	DAX	2.4%

2.4 セクターの決定

次のフェーズとしてセクターの決定を行っていく。セクターの決定方法に対しても人工知能に決定させるという案があったが、リスク分散の考え方から、それぞれの市場の強みを活かすという点を重視し、各市場の上位1~2セクターを選定する。

2.4.1 結果

セクター選択は以下のようになった。

Table4: 各市場で選択されたセクター

市場	セクター1	セクター2
NASDAQ	一般消費財	テクノロジー
DAW	資本消費財	テクノロジー
FTSE100	金融	
S&P500	金融	ヘルスケア
DAX	ヘルスケア	資本消費財

2.5 銘柄選択

2.5.1 方法

現在の株価に今の財務が完全に反映されているのではなく、財務指標の変化から、企業の株価が左右されるという発想から、株価をその一期前までの時系列データによって説明するというモデルを考える。項目3で選定した各セクターから時価総額の大きい上位5銘柄を分析対象とする。理由としては流動性が高い、かつ比較的株価が安定している銘柄に絞って分析することにより効率的に分析を進めることができる。分析対象銘柄は以下の通りである。

Table5: 各セクターの分析対象銘柄（ティッカー表示）

市場	セクター	分析対象銘柄群
NASDAQ	一般消費財	COKE, CVCO, JJSF, MIDD, TSLA
	テクノロジー	AVGO, BIDU, MSTR, NTSE, ULTI
DAX	ヘルスケア	FME, BAYN, FRE, MRK
	資本消費財	VOW3, ADS, BMW, CONT, DAI
DAW	資本消費財	MMM, CAC, BA, UTC, CAT
	テクノロジー	AAPL, IBM, INTC, MSFT, V
S&P500	金融	BAC, BRK, C, JPM, WFC
	ヘルスケア	AMGN, JNJ, MRK, PEE, UNH
FTSE100	金融	RBS, HSBC, LLOY, BARC

2.5.2 ERNN構造

銘柄選択では、新たに財務データをネットワークに学習させる必要があるため、国選定で用いたRNNの構造を複雑にさせる必要がある。国選定の時と同様の方法でパラメータを設定し直し、隠れ層の数を10から50に増やすことでモデルのあてはまりが改善することが分かった。また、それに伴い世代上限を3000から5000まで増やした。

2.5.3 説明変数の決定

財務データを用いて将来の株価を予想させる試みは多くある。今回は、財務指標を8つのカテゴリに分けて、それらを一つずつ説明変数に組み込む手法をとった。8つのカテゴリは先行研究[22]を参考に収益率、資本収益率、投資収益率、レバレッジ、設備投資額、成長性、短期流動負債、リスクの8つを選択した。これらのカテゴリには複数の財務指標が当てはまるが、今回は以下の指標を用いた。財務データは四半期のものを2013年度から過去5年分を学習させた。

Table6: ERNNの学習に用いる財務データ

カテゴリ	財務指標	カテゴリ	財務指標
収益率	売上高利益率	投資	PER
資本収益率	税引前利益/総資産	成長性	売上高成長率
投資収益率	ROE	流動負債	流動比率
レバレッジ	DEレシオ	リスク	純利益/流動負債

2.5.4 結果

銘柄選択の結果は以下の通りになった。選択した銘柄は、その期待収益率から1社～2社選定を行った。

Table7: 各セクターで選択された銘柄

市場	セクター	銘柄 1	銘柄 2
NASDAQ	一般消費財	MIDD	TSLA
	テクノロジー	NTES	BIDU
DAX	ヘルスケア	FME	BAYN
	資本消費財	VOW3	
DAW	資本消費財	BA	CAT
	テクノロジー	V	
S&P500	金融	BRK	BAC
	ヘルスケア	UNH	
FTSE100	金融	RBS	HSBC

2.6 接点ポートフォリオ

AIファンドによって選定された15銘柄を用いて平均分散アプローチを行い接点ポートフォリオを算出する。安全資産にはシティ世界国債インデックスのETFを用い、その利回りをリスクフリーレートとして設定する。

Table8: 配分比率と接点ポートフォリオ

配分比率			
BA	0.064107639	MIDD	0.051923688
BAC	0	NTES	0.12355393
BAYN	0	RBS	0
BIDU	0	TSLA	0.117614714
BRK	0.024663097	UNH	0.328032922
CAT	0	V	0.290104031
FME	0	VOW3	0
HSBC	0		

接点ポートフォリオ	
リターン(%)	0.589749111
標準偏差	2.006553134

Figure2: AIファンドに対する平均分散アプローチ




Figure1の横軸と縦軸はそれぞれ週次で計測を行った。青い実線は最小分散フロンティアを、赤い実線は資本市場線を表している。今回は接点ポートフォリオをファンドのポートフォリオに選択するため、二つの実線が交わる点において配分比率を決定する。

3. 時系列解析ファンドの構築

3.1 概要

このファンドではランダムウォーク仮説がなりたっていないという仮定のもとに過去のデータから時系列分析を行い、推定された株価上昇率を基に銘柄を選定する。時系列解析にはARIMAモデルを使用する。ARIMAモデルを株価の予測に用いる事例は[23]の論文を参考にした。カントリーリスクをヘッジするために国の選定から行い、その後投資するセクターを決め、最後に銘柄の決定を行う。その際に国の選定および銘柄の選定に時系列解析を適用する。初めに銘柄の選択手法及び時系列解析の手順について説明し、最後に時系列モデルを適用した結果と選定された銘柄を示す。

3.2 選定方法

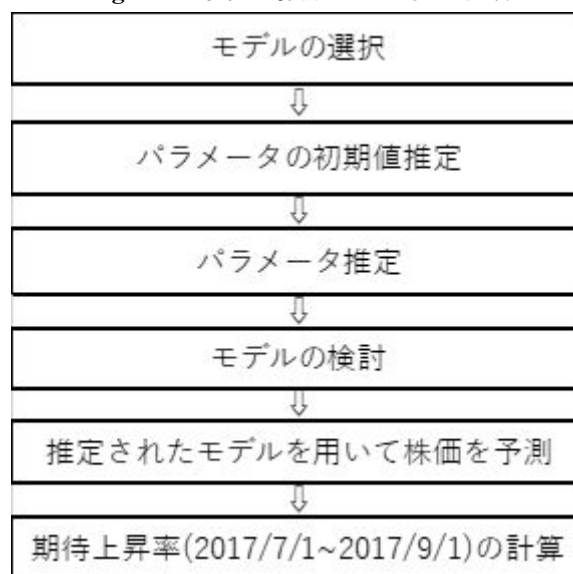
まず初めにBloomberg端末から世界の主要な株式の指数の5年間分の週次データを取り出し時系列解析を用いて予測を行ない、その中で上昇率が高い株価指数を上位3位まで選定する。次にその株価指数を構成する割合が高いセクターを2つ選び、そのセクターに属する企業の株価に対して時系列解析を行い将来の期待株価を予測する。推定された株価から期待上昇率(2017年7月1日～2017年9月1日)を計算し、各セクターで期待上昇率が高い上位3つの株式を採用する。最後に選定された株式を元に平均分散アプローチを適用し接点ポートフォリオを決定する。

3.3. 時系列解析

3.3.1 時系列解析の手順

時系列解析は一変量の時系列解析 (ARモデル、ARMAモデル、ARIMAモデル) と多変量モデルがあるが今回はARIMAモデルを使用した。予測の手順については次ページの図のように行った。

Figure3. 時系列解析による予測手順



3.3.2 定常性

時間や位置によって確率分布が変化しない性質を指す。定常性をもった時系列データは平均や分散も時間や位置によって変化しないためトレンドは存在せず、長期的に見れば平均に回帰する性質を持っている。

3.3.3 ARMAモデル

ARMAモデルは自己回帰(AR)モデルと移動平均(MA)モデルを組み合わせたモデルである。ARMAモデルは p, q のパラメータがあり、それぞれ自己回帰項の次数と移動平均項の次数を表している。階差のパラメータを持たないため分析対象となる時系列が定常性を持つことが前提である。

3.3.4 ARIMAモデル

ARMAモデルは定常な時系列過程を前提としてきたが、階差をとる事で非定常時系列に対して分析を行なえるようにしたモデルがARIMAモデルである。時系列において平均値が時間的に変動する現象(トレンド)は非常によく見られるものであり、株価の時系列データにはトレンドが頻繁に見られるためARMAモデルはそのままでは適用できない。そのため、今回はARIMAモデルを用いて時系列の階差をとり、平均値揺動を取り除いた上で予測を行う。

3.3.5 モデルの選択

ARIMAモデルを適用するかどうかの判定は、トレンドなどの平均値揺動が存在するかどうかによるものであり、第1階差、第2階差において、平均値揺動が解消されているかどうかを検討してモデルを決める。

3.3.6 パラメータの推定

ARIMAモデルは p, q, d のパラメータからなり、それぞれの時系列データに対して最適なパラメータを推定する必要がある。階差のパラメータ d に関しては各階差時系列において、時系列のプロット、自己相関関数の様子を見て判断する。ARMAモデルのパラメータ p, q はAIC(赤池情報量基準)を最小にする組み合わせを選択する。

3.3.7 モデルの検討

推定されたモデルをデータの予測に用いて良いのかを残差の検定と定常性の検定という2つの検定を用いて判断する。

3.3.7.1 残差の検定

モデルと実績値の残差がホワイトノイズとみなせるかどうかの検定を行なう。残差がランダムであると思えればそのモデルを採用し、そうでない場合は異なる2時点間に関係を持つ他の項が存在する事になるのでモデルの再検討を行う。残差の検定には代表的なものにLjung-Box検定があり、今回はRのBox.test関数を用いてLjung-Box検定を行った。

3.3.7.2 定常性の検定

ARIMAモデルの定常性の条件は特性方程式の解の絶対値が1より小さいことでありRのpolyroot関数を用いて検定を行なう。この検定を通して定常性の条件が満たされていない場合、モデルの再検討を行う。

3.4 結果

3.4.1 銘柄

時系列解析ファンドによって選定された銘柄は以下のようになった。

Table9: 時系列解析によって選定された銘柄

MSFT	マイクロソフト	FDX	フェデックス
700	テンセント・ホールディングス	V	ビザ
EXPD	エクスペディターズ	WU	ウエスタンユニオン・カンパニー
8382	中国銀行	AAC	AACテクノロジーズ・ホールディングス
FRE	フレニゼウス	CON	コンチネンタル
BMW	BMW	ADDYY	アディダス
BAYN	バイエル	1398	中国工商银行
MRK	メルク	2318	中国平安保険(集団)
ALK	アラスカ・エア・グループ	2388	中国銀行(香港)

3.4.2 選定の過程

次にこれらの銘柄を選定するまでにとった指数の選定の過程と銘柄の選定の過程を示す。時系列データのグラフに関しては赤い部分が観測されているデータで緑色の部分からが予測されたデータを示している。また上下にある灰色の線は推定された株価の期待値の95%信頼区間を示している。

3.4.2.1 指数の選定

Table10: 各インデックスの期待上昇率

銘柄	上昇率(2017/7/1~2017/9/1)
DAW	1.026713053
DAX	1.017120914
HIS	1.015622301
FTSE	1.014881354
CAC	0.984501342
TOPIX	0.948521835

時系列解析の結果、2017年7月1日から9月1日までの期待上昇率が高いDAW、DAX、HISを採用することにした。HISは他の指数と比べるとボラティリティが高いのが懸念材料だったが、中国株が世界の株式ととても低い相関関係にあることから、ポートフォリオの分散効果を高める目的で採用することに決定した。

Figure4: DAWの時系列予測




Figure5: DAXの時系列予測

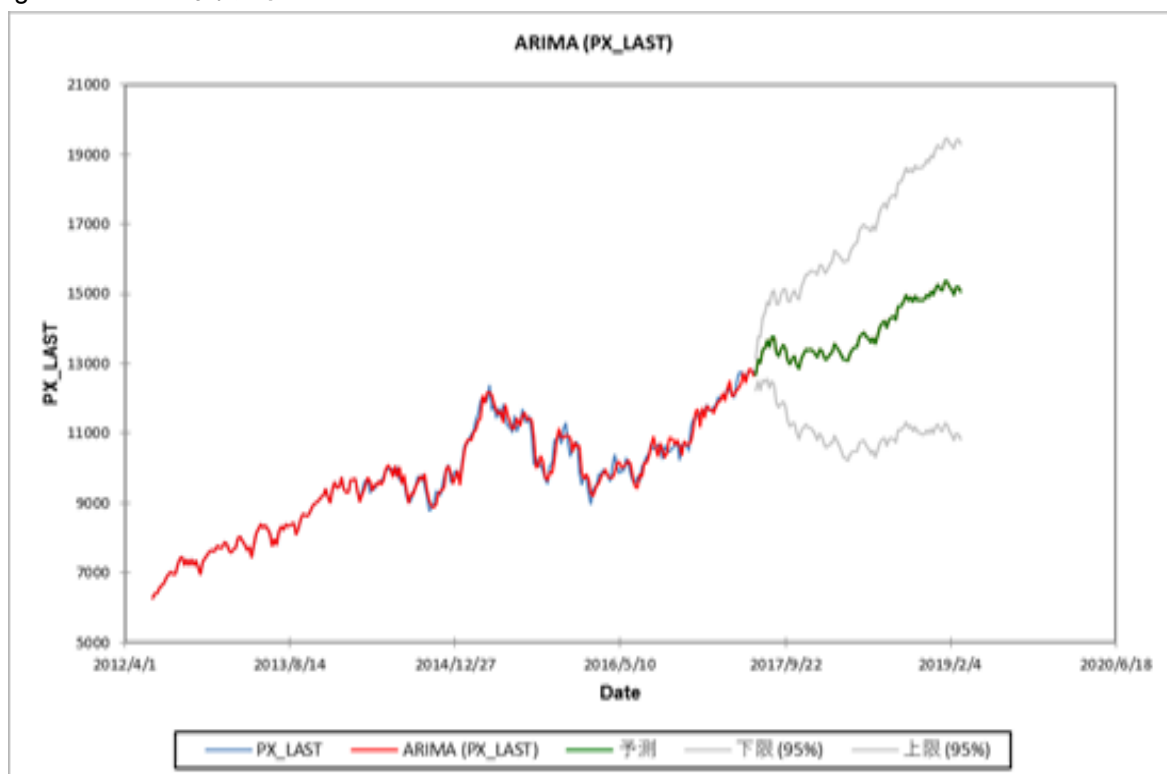
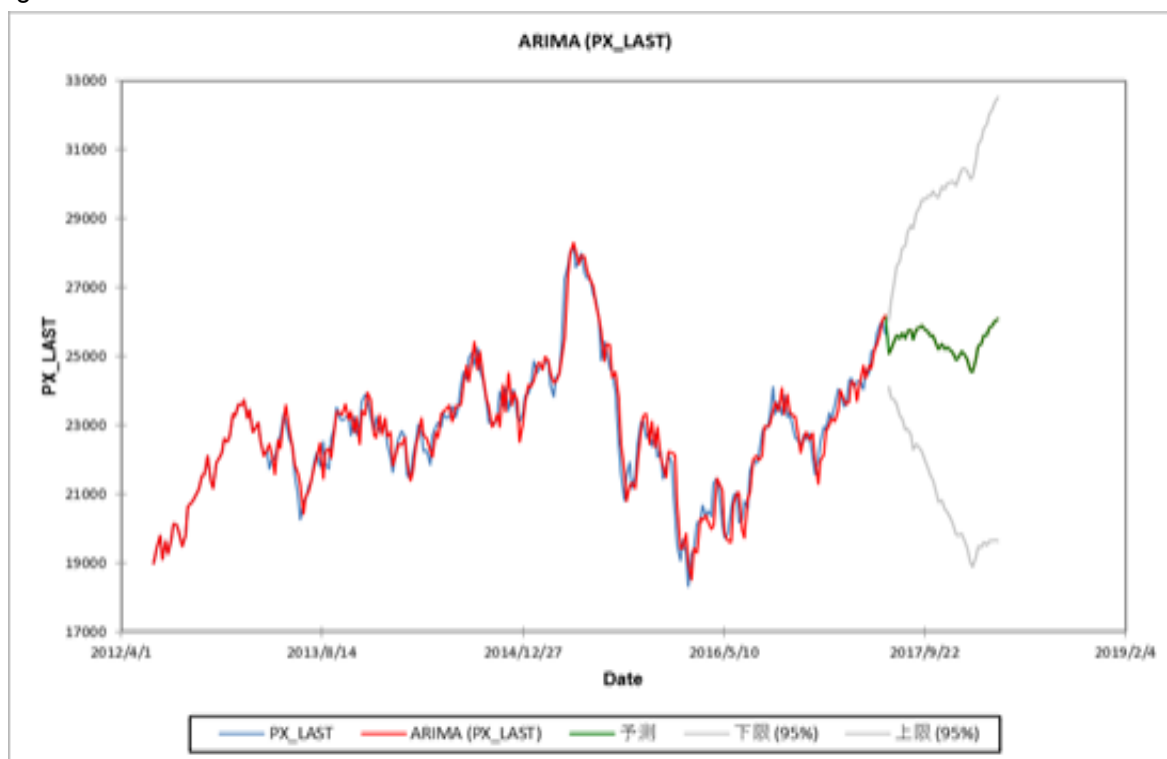


Figure6: HISの時系列予測



3.4.2.2 銘柄の選定

上記で決定した指数を元に投資するセクターを決め、銘柄の選定を行なった。選定された各銘柄の期待上昇率、予測グラフは次のようになった。選定された銘柄の時系列グラフを見てみると過去に大きな変化がなく安定的に上昇をしている企業が多く選定されていることがわかった。

Table11: DAW構成銘柄の期待上昇率と選定銘柄

情報技術		運輸	
銘柄	上昇率	銘柄	上昇率
マイクロソフト	1.070259	エクスプレッティーズ Int'lブワシントン	1.071873
ピザ	1.060924	フェデックス	1.031542
ウェスタンユニオン・カンパニー	1.030284	アラスカ・エア・グループ	1.030057
アカマイ・テクノロジーズ	0.964354	ユナイテッド・パーセル・サービス	1.000464
オラクル	0.955874	ノーフォーク・サザン	0.972571

Figure7: マイクロソフトの時系列予測




Figure8: エクスプレッティーズ Int'lブワシントンの時系列予測

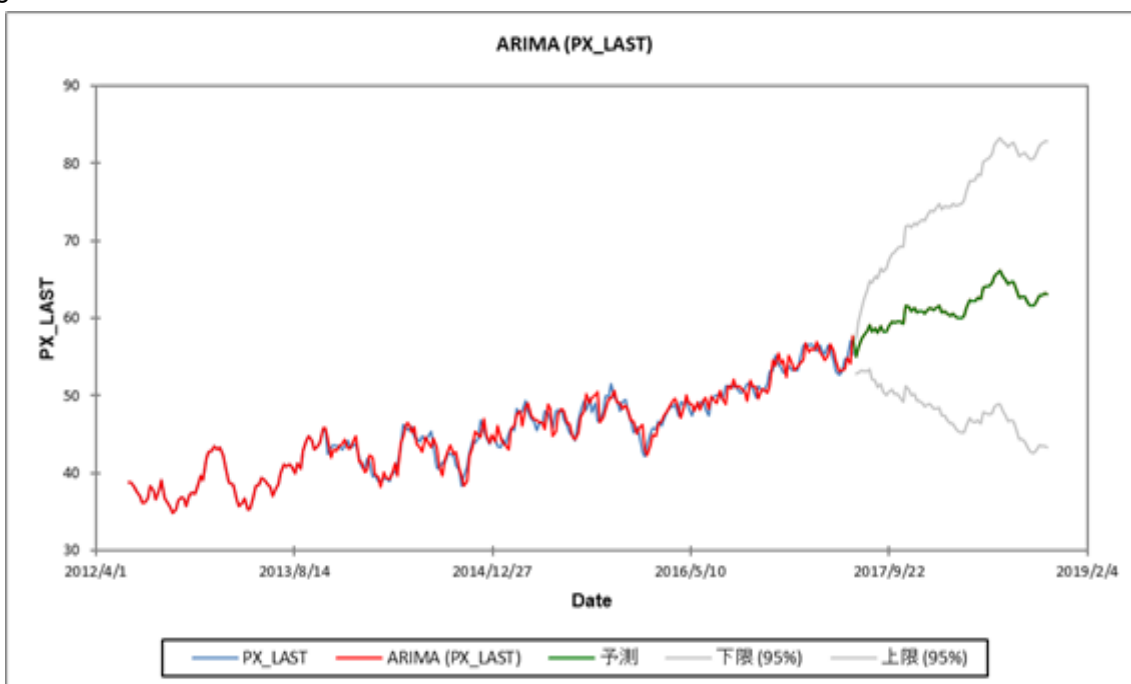


Table12: DAX構成銘柄の期待上昇率と選定銘柄

一般消費材・サービス		ヘルスケア	
銘柄	上昇率	銘柄	上昇率
BMW	1.090718	フレニゼウス	1.040653
コンチネンタル	1.082406	メルク	1.027732
アディダス	1.060738	バイエル	1.017559
プロジーベンザット1メディア	0.923595	フレニゼウス・メディカル・ケア	1.0158
フォルクスワーゲン	0.859324		

Figure9: BMWの時系列予測




Figure10: フレニゼウスの時系列予測

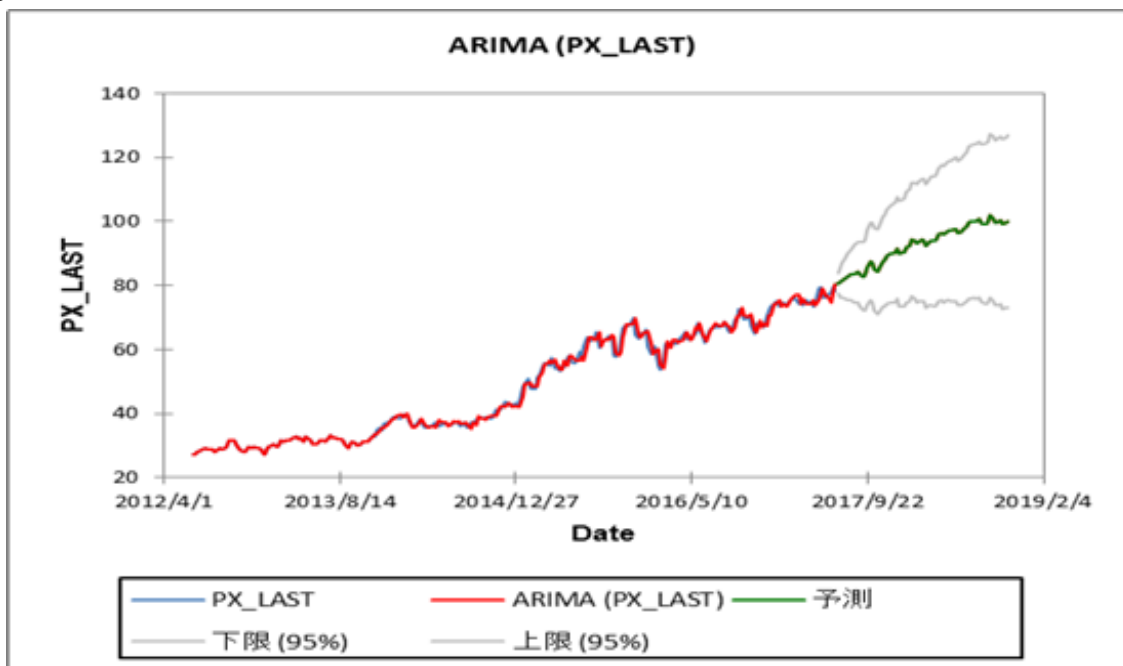


Table13: HIS構成銘柄の期待上昇率と選定銘柄

金融		情報技術	
銘柄	上昇率	銘柄	上昇率
中国銀行	1.087483	テンセント・ホールディングス	1.044817
中国工商銀行	1.083221	AACテクノロジーズ・ホールディングス	0.997561
中国平安銀行	1.078219	レノボ・グループ	0.877145
中國銀行(香港)	1.06222		
香港交易乃結算所	1.05026		

Figure11: 中国銀行の時系列予測





Figure12: テンセント・ホールディングスの時系列予測



3.5 接点ポートフォリオ

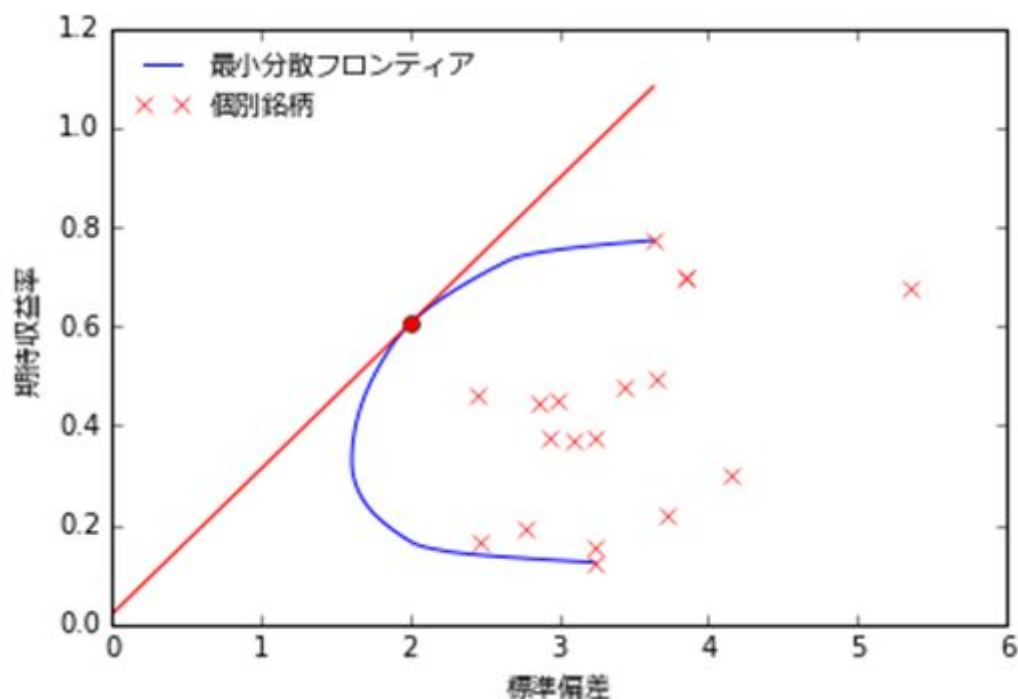
時系列解析によって選定された18銘柄を用いて平均分散アプローチを行い接点ポートフォリオを算出する。安全資産にはシティ世界国債インデックスのETFを用い、その利回りをリスクフリーレートとして設定する。

Table14: 配分比率と接点ポートフォリオ

配分比率			
MSFT	0	BAYN	0
700	0.28077	MRK	0.052246
EXPD	0	ALK	0.090381
8382	0	FDX	0
FRE	0.164201	V	0.222696
BMW	0	WU	0.090381
AAC	0.078252	1398	0
CON	0	2318	0
ADDYY	0.021074	2388	0

接点ポートフォリオ	
リターン(%)	0.605153
標準偏差	2.001458

Figure13: 時系列解析ファンドにおける平均分散アプローチ



4. 定性グローバルファンドの構築

4.1 概要

他の二つのファンドが高度な定量分析によって高精度の予測を実現している反面、本ファンドでは定性的な情報面からのアプローチを取り入れることにより、他の二つのファンドを補う形でより立体的なポートフォリオの構築を目指している。また、このファンドでは時系列など過去の株価情報は関係なく、真っ白の状態から未来を予想し市場予測を行う点でほか二つの異なることを強調しておく。その性質上、主観やバイアスが入りやすくなってしまいう危険性は孕んではいるが、様々な論拠から多角的に分析することにより、その危険性を回避できる客観的なアプローチを可能にしている。

4.2 選定方法

ここで銘柄選択までのプロセス方針を示す。他のファンドのような、国の選定→業種の選定→個別銘柄の選定という手順は踏まない。トレンドを踏まえてこれからグローバルで見て伸びることが予想される企業、短期の市場予測をニュース記事を基に定行的に行い、伸びると考えられる企業の二つの軸として個別銘柄を選択する。ここで留意すべき事実として他二つのファンドと異なり、国の選定が行われていないことがある。これは、選定の過程によっては選出企業が、数カ国に集中してしまうことで地政学的リスクの回避が難しくなる危険性を持つ。これを回避するため、国を意図的に分散させる。また、このファンドではある程度、選定過程に自由が利くため、売上高など規模の観点からも分散を行うことを試みたい。そこでこのファンドでは可能な限り、国と規模（大企業と中小企業など）を分散させることを条件として設定する。今回、私は定性分析における先行研究を探したが、性質上その数は少ない。そこで、論点がブレないように後述するGAMというフレームワークを作成し、それをもとに選定を行っていく。

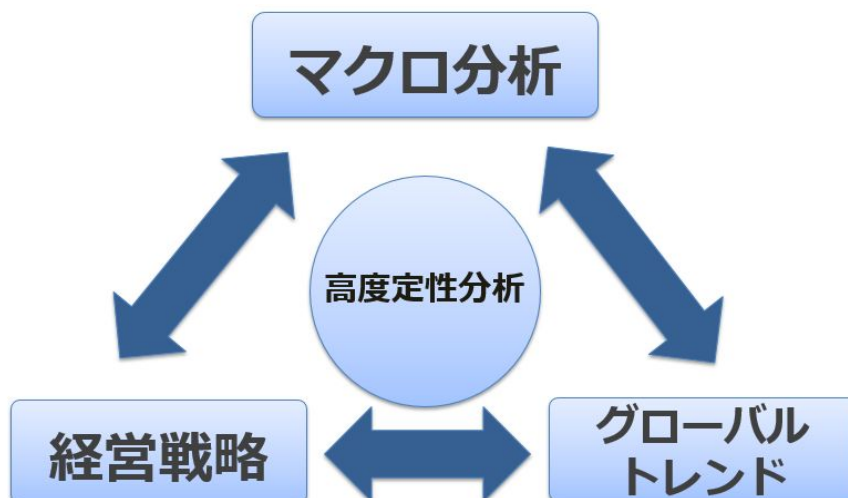
4.3 用いた情報・手法

定性分析において、一番重要になってくるのは情報である。先進国から新興国まで数十か国に存在する数千、数万という膨大な量の銘柄を確実にかつ迅速に分析をしなければならない。そのため Bloomberg端末のスクリーニング機能をフル活用することが必要不可欠となってくる。また、ニュースや銘柄情報などBloomberg端末を最も使う機会が多いことがこのファンドの特徴である。今回の分析においては情報に一定の信憑性確保するため、記事などの情報はBloombergと日本経済新聞からの情報のみを用いることにする。シェアなどの情報に関しては、信頼性のあるシンクタンクなどの情報を用いる。

4.3.1 Global Analytic Model

グローバルに活躍する企業に対して財務状況、経営戦略、グローバルトレンドの3つを主軸に高度な定性分析を行っていく。この手法はグローバルに移り変わる世界情勢に対して柔軟に対応するために作られたフレームワークであり、分析に一貫した客観性を持たせることを目指す。これをGlobal Analytic Model(GAM)と名付ける。

Figure14: Global Analytic Model



4.4 結果

先に結論を示すと、定性グローバルファンドによって選択された銘柄は以下になる。

- ・企業（所在国、業種）
- ・アジア・パシフィック・インベスタマ（インドネシア、繊維・繊維製品）
- ・エヌビディア（米国、IT・通信）
- ・キーエンス（日本、電気機器）
- ・シーメンス（ドイツ、製造を中心とした複合企業）
- ・ハイアール（中国、家電製品）
- ・ペイパル（米国、サービス）
- ・ポープ・アンド・タルボット（米国・カナダ、製紙）
- ・ユーロメディカ（ギリシャ、ヘルスケア・サービス）

4.5 選定過程


概要で示した二つの軸によるGAMによる選定だが、具体的に手順を表すと次のようになる。一つ目の軸は、グローバルなトレンドに沿った市場の分析を通じた業種の選定→シェア・利益率、経営戦略など定性分析で個別銘柄の選定。二つ目の軸は、ニュース記事などの情報から新興国、発展途上国をメインとして需要が見込まれる業種の選定→シェア・利益率、経営戦略など定性分析で個別銘柄の選定。便宜上、一つ目の軸による選定を選定法①、二つ目の軸による選定を選定法②と以下記述する。

4.5.1 選定法①におけるグローバルなトレンド

結論から述べると、我々は今回まとめると私たちはグローバルなトレンドとして、「人工知能」、「フィンテック」、「インダストリー4.0」の三つを主軸として考えた。

まずグローバルなトレンドについてまとめることにする。まず、頭に思い浮かぶのは、人工知能やAIなどのテクノロジーである。日本経済新聞の企業欄にはベンチャー企業、大手企業どちらもAIに関する記事が毎日のように掲載されている。Bloombergで検索をかけてもヒット件数が他と比べ圧倒的に多いことからやはりホットであることが分かる。GoogleやApple、IBMなど名だたるIT企業が注目することからグローバルなトレンドであると判断して問題ないだろう。市場規模についても多くのシンクタンクで大幅な伸びが予想されている。以下は富士キメラ総研による業種別のAIビジネスの国内市場の予測である。見てわかるように、2020年、30年まで爆発的な伸びを予測されている。特に金融部門における拡大は顕著で次に述べるフィンテックとも関連することが予想できる。

Figure15: AIビジネスの国内市場予測



(出典)富士キメラ総研「2016人工知能ビジネス総調査」

また、フィンテックもグローバルなトレンドである。日本では、金融庁が成長戦略にフィンテックの普及を促す新目標を加えるなど国家単位で注目されていることが分かる。日本のマーケットを見ても、ビットコイン関連の銘柄は値上がり上位に食い込むことが最近多く出来高も非常に多い。さらに、欧米はもちろんのこと、アブダビ・グローバル・マーケット（ADGM）が、17年5月に支援するフィンテック企業を選定することで中東・北アフリカで初のフィンテック特区を作る試みが行われるなど、グローバルに注目されていることが分かる。

RPA（Robotic Process Automation）もトレンドと考えられる。今まで多くのグローバル企業の工場としての役割を担ってきた中国だが、近年では人件費の高騰などにより「曲がり角の中国」の今が見えてきたという。結果、省力化のニーズが高まりロボット需要の急増にている。中国政府は「中国製造2025」という製造業を高度化するための計画を発表した。このような、工場自動化を先導するのは「インダストリー4.0」を提唱したドイツで、こちらも国を挙げて工場のデジタル化に取り組んでいる。日本においても、ファナックやオークラなどファクトリーオートメーションに強い企業が存在感を増してきている。


4.5.2 選定法①における個別銘柄の選定

まず、人工知能市場を考えていく。一口に人工知能市場と書いてはいるが、その内容は多岐にわたる。例えば、人工知能を用いた製造や、金融、情報通信の市場などが考えられ、それらすべてをまとめて人工知能市場としている。人工知能市場の拡大は間違いないと考えられるが、それは業界によって大小が分かれる。そこで、今回は確実性を重視し、人工知能のコアの部分の銘柄を選択することにした。人工知能を用いるのに必要な機材を製造する企業である。人工知能に必要なのは膨大なデータ量を処理するCPUやGPUである。なかでも、人工知能との相性が良いとされるGPUのシェアを見てみる。JPRによる調査結果によればPCに限ったGPUのシェアは、2016年時点で首位が40%を握るインテル、次いで35%のエヌビディア、そして3位に25%のAMDとなっている。さらに、人工知能の柱

ともいえるディープラーニングには、ほとんどのフレームワークがエヌビディアの出すソフトウェアに依存している。ここから、人工知能市場というトレンドに対しては「エヌビディア」を選定した。

次に、フィンテック市場について考えていく。ここも同様にフィンテックの中にも、多くの種類が存在する。代表的なのは、EC決済サービス、ロボアドバイザーなどの資金運用、クラウドファンディングなどだ。我々が注目したのは、EC決済サービスである。なぜなら、フィンテックの中でも、キャッシュレス化のトレンドは世界に共通し、拡大が予想されるフィンテックの柱ともいえるサービスだからだ。以下は、NRIによる日本のEC市場の推移と予測である。伸び悩みはなく、堅調な市場の拡大が予想されていることが分かる。アメリカや欧州などの統計・予測でも、日本と同様に市場規模の拡大が予想されている。

Figure16: 日本におけるEC市場の推移と予測

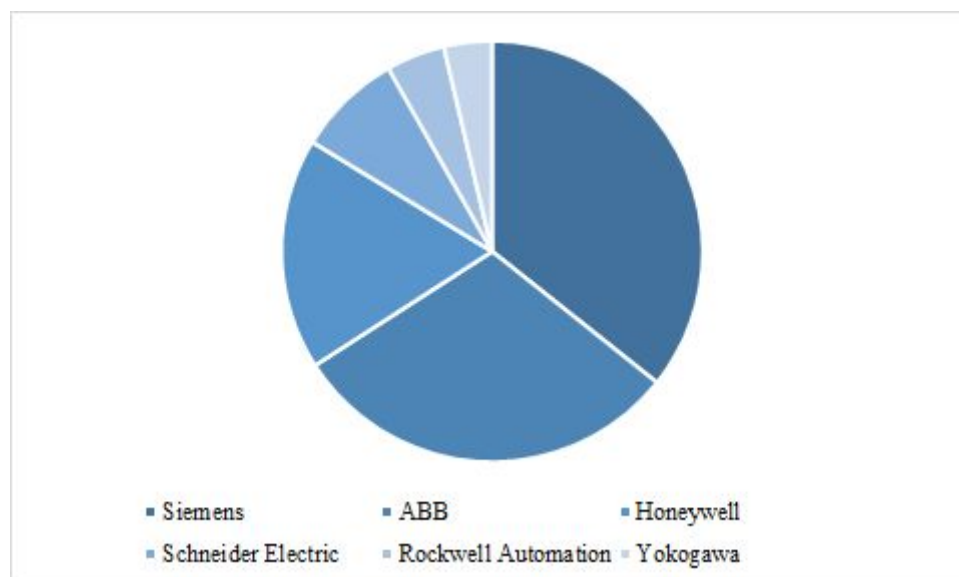


(出典)NRI

EC決済は非常に多くのフィンテック企業が参入をしているが、シェアで見るとペイパルが圧倒的である。Datanyzeによる統計では、ペイパルのシェアは81.4%を占めており、2位のストライプは4.1%と競争を大きく突き放している。ここから、「ペイパル」を選定した。

インダストリー4.0に代表される工場自動化の市場はどうだろうか。この市場も前述した先進国や人件費の高騰が問題化してきた中国での需要を根拠に、伸びが予想される。工場の自動化はFactory Automation (FA) と呼ばれ、産業ロボットやセンサーを用いて行われる。我々が注目したのは、FA全体のシェアとセンサーである。特に、センサーに注目した理由として、人工知能との相性がよくFA分野のみならず、自動運転などの技術にも利用されることが多く、安定した成長が予想されることがある。まず、FA全体のシェアであるが、シーメンスとABBが過半数と超えるシェアを握っている。少し古い次ページFigure17は、Frost & Sullivanが出した2015年度のFAのシェアである。これによれば、上位3社がほぼ寡占している状態だ。特にシーメンスとABBの首位2社の占めるところが非常に大きいことが分かる。

Figure17: 2015年におけるFAのシェア



(出典)Frost & Sullivan

シェアに加えて、ドイツ企業であるシーメンスはスイスのABBなど競合に比べて、インダストリー4.0を政府が掲げるなど国家レベルのプロジェクトになっている点で成長の確実性が高いといえる。これらの理由からシーメンスを選定した。また、センサーの企業は概要で条件に挙げた通り、国にバラつかせるために、日本に絞って検討した。日本には、キーエンス、ヒロセ電機など多くのセンサーを扱う企業が存在する。調査の結果、これらの中でも業界初が製品の70%などによる効率の良いビジネスモデルで圧倒的な営業利益率をコンスタントに出しているキーエンスが業界内で強みを持つことが分かった。結論として工場自動化の市場として、「シーメンス」と「キーエンス」を選定した。

4.5.3 選定法②におけるニュース記事による短期の市場予想

私が注目したのは、以下三つのニュース記事である。概要のとおり、Bloombergか日本経済新聞の情報のみを用いている。

一つ目は、調査会社富士経済が、白物家電主要5品目の世界での生産台数が2021年に16年比9・2%増の5億8693万台に達するとの見通しを発表したことだ。インドや東南アジアでの需要拡大により拡大が予想される。日本国内でも、2016年度の国内出荷額が前年度比3.6%増と2年連続でプラスとなった。デフレマインドの改善が今も議論される中でこの伸びは好調といえるだろう。ほかの先進国でも同様の動きがあり、白物家電市場はこれから安定的な伸びが予想される。

次に、注目したのは17年5月の北米産パルプの対日輸出価格が3カ月連続上昇したニュースだ。紙需要が堅調な中国で現地の製紙会社が在庫の積み増しに動いたことに加え、工場の定期修理で北米の供給水準が低下した結果対日輸出価格が押し上げられた。海外の製紙大手がインドネシアでパルプ工場を稼働させたが、生産が軌道に乗っていないことから、アジア全体でパルプの供給が不足しているようだ。ここから、短期的視点では、パルプ製品メーカーの収益向上が見込まれる。

インドネシアやインドなどの新興国が国家プロジェクトレベルで繊維製品や自動車などの輸出の拡大を狙っている。具体的には、インド政府は自動車部品や、工業用繊維の産業育成に力を入れている。税制優遇や外資誘致策で、規模を2014年の7368億ルピーから2018年3月までに1兆1600億ルピーへの拡大を目指す。また、インドネシアのジョコ大統領の経済顧問でもあるレンボン投資調整庁長官は、自国や日中韓など16カ国で交渉中の東アジア地域包括的経済連携（RCEP）について質の向上を訴える。米国の政権交代で、自国も参加を目指した環太平洋経済連携協定（TPP）の発効が難しいため、もう一つの多国間協定であるRCEPの実現を急ぐ考えである。RCEPの巨大市場をいかし自国製の自動車や繊維製品などの輸出を増やす予定だ。ここから、インドかインドネシアの市場に注目した。自動車は、非常に多くの競合が存在しており、アジアの需要はどこも狙っている。そこで、我々は繊維市場がより確実性が高いと判断した。まとめると、インドとインドネシアの繊維市場の伸びが予想される。

4.5.4 選定法②における個別銘柄の選定

白物家電市場など生活必需品の需要は新興国市場、特に中国やインド、インドネシアの需要が非常に大きい。この市場に強いのは、シェアでも首位の中国企業、ハイアールである。逆に、日本勢は例えば、ルームエアコンで温度の違う風を吹き分ける機能など付加価値の高い製品開発で中国勢との違いを見せるが新興国市場にはそこまで向かない。白物家電市場の拡大を牽引すると考えられているのは、冷蔵庫、洗濯機、家庭用エアコンの3分野である。ハイアールはこのうち冷蔵庫と洗濯機の2分野で首位を固め、家庭用エアコンでも3位につけている。2016年に米国企業ゼネラル・エレクトリックの家電部門を買収するなど、販売網を強化するハイアールの上位シェアは少なくとも短期では続くと考えられるため、「ハイアール」を選定した。

パルプ製品メーカーで伸びが予想される個別銘柄を探す。定性ファンドで選定する企業は残り2社だが、概要にあるように規模の観点での分散を行うため中小企業に絞って選定を行うことにする。北米産パルプを供給する企業を調べたところ、米国とカナダで、パルプと針葉樹製材を生産するポープ・アンド・タルボットという企業が見つかった。主要販売先は米国、カナダ、南米、欧州、日本、その他の環太平洋諸国である。そこで、「ポープ・アンド・タルボット」も選定した。

短期の市場予想とマクロ動向からインドかインドネシアの繊維市場に注目した。ここまですべてを条件にBloomberg端末によって企業を絞り込むと11社の企業がこれに当てはまった。我々がなかでも注目したのは、インドネシア国内で最大のポリエステル繊維生産企業で、自動車用の繊維も生産する「アジア・パシフィック・インベストマ」である。この企業も個別銘柄として選定した。

4.6 接点ポートフォリオ


定性ファンドによって選定された7銘柄を用いて平均分散アプローチを行い接点ポートフォリオを算出する。安全資産にはシティ世界国債インデックスのETFを用い、その利回りをリスクフリーレートとして設定する。

Table15: 配分比率と接点ポートフォリオ

配分比率			
CH600690	0.1258658	NVDA	0.51390505
PTBTQ	0	PYPL	0.08808171
JP6861	0.21040257	SIE	0
MYTX	0.06174487		

接点ポートフォリオ	
リターン(%)	1.455249
標準偏差	3.629482

Figure 18: 定性ファンドにおける平均分散アプローチ



5.アンブレラ型ファンドの構築

5.1 平均分散アプローチ

平均・分散アプローチとは、複数の投資対象の収益率の期待値と分散・共分散が与えられているときに投資家の効用を最大化する資産配分を決定する理論である。詳しくはマーコウィッツの[24]の論文を参考にした。平均分散アプローチではまず資産の期待値と共分散行列から最小分散ポートフォリオを算出し、その上で投資家の効用を最大化する集合である効率的フロンティアを描く。効率的フロンティアは以下のように導出した。まずポートフォリオの期待収益率の値を r とすると最小分散ポートフォリオは次のような二次計画問題を解くことで算出することが出来る。

$$\begin{aligned} & \text{minimize} && \frac{1}{2} {}^t y V y \\ & \text{subject to} && {}^t y \mu = r, \quad \sum_{i=1}^n y_i = 1, \quad y \geq 0 \\ & && (V: \text{分散共分散行列} \quad y: \text{配分比率} \quad \mu: \text{平均収益率}) \end{aligned}$$

今回はロングのみなので制約条件に $y \geq 0$ を追加した。この二次計画問題を解くことで最適ポートフォリオの配分比率を算出し、目標とする期待収益率の値を変動させることで効率的フロンティアを描く。

5.2.1 ファンド定理

投資対象に安全資産が含まれる場合の、リスク回避的投資家の投資プロセスは次のようになる。まず危険資産ポートフォリオから最も効率的なポートフォリオを選択する。この場合危険資産ポートフォリオで効率的なポートフォリオは接点ポートフォリオだけなので、投資家の選考にかかわらず一意に決まる。次に接点ポートフォリオと安全資産配分の投資比率を決定することで最適ポートフォリオを算出する。このように投資家の選好が接点ポートフォリオと安全資産との配分比率にしか影響を与えないという理論が1ファンド定理である[25]。

5.3 ポートフォリオ構築の手順

1ファンド定理に基づいて危険資産の接点ポートフォリオを求めることから始める。今回はアンブレラ型ファンドを採用していて複数のファンドが存在することから、各ファンドで接点ポートフォリオを算出し、その接点ポートフォリオで効率的フロンティアを作成するという手順をとる。安全資産にはシティ世界国債インデックスのETFを設定しその利回りをリスクフリーレートとして設定する。最後に、目標期待収益率を週次で0.875%として設定し安全資産と接点ポートフォリオの配分比率を算出することで最適ポートフォリオを決定した。

5.4結果

Figure19: アンブレラファンドの平均分散アプローチ




Table16: アンブレラファンドの配分比率

接点ポートフォリオ	
リターン	1.01696664
標準偏差	2.11149836

目標値	
リターン	0.875
標準偏差	1.810823979

配分比率	
安全資産	0.14239859
危険資産	0.85760141

ファンド配分比率	
時系列解析ファンド	0.275813651
AIファンド	0.430439907
定性ファンド	0.293746442

700	0.077440189
FRE	0.045288773
2018	0.021583072
ADDYY	0.005812392
MRK	0.0144102
ALK	0.024928183
V	0.061422659
WU	0.024928183
CH600690	0.036977263
JP6861	0.061805007
MYTX	0.018137335
NVDA	0.15095778
PYPL	0.025873688
BA	0.027594486
BRK	0.010615981
MIDD	0.022350027
NTES	0.053182542
TSLA	0.050626067
UNH	0.14119846
V	0.124872352
合計	1

6. まとめ

6.1 人工知能ファンド

トップダウンアプローチを用いたEvolutionary Recurrent Neural Networkによって銘柄選択を行った。このモデルはその性質上、膨大な量の計算資源と時間コストを要するため、いかに効率的にデータを取り扱うかが肝であった。今回の場合はあらかじめ、国や銘柄の選定に際し、あらかじめスクリーニングを行うことで問題を解決することができた。また、ヒストリカルデータや財務データを入手する際に、Bloomberg端末は非常に強力な武器となった。そして、改めて人工知能とビッグデータの相性の良さを実感することとなった。しかし、一方でニューラルネットワークの真価を発揮できなかったことは残念である。コンテスト後もBloomberg端末と人工知能の融合というテーマでファイナンス分析を続けていきたい。

6.2 時系列解析ファンド

今回は株価の時系列データのモデリングに一変量モデルであるARIMAモデルを使用した。ARIMAモデルのパラメータの推定、モデルの検定、そしてモデルを用いた将来の株価の予測をRを用いてプログラミングを行なった。いままで理論として学んでいたものを実際に手を動かしてプログラミングを組むことでこれまで気が付かなかった問題点や、改善点に気付くことができ、とても貴重な体験となった。取り組みの中で気づいた点としては、一変量モデルを使って予測を行うよりも、多変量モデルを用いることで為替やGDPなどのマクロ変数との関係性を考慮したモデリングをした方がより精度の高い予測ができるということだ。その際にはBloomberg端末を積極的に使っていくことが重要になってくるであろう。また問題点として、今回は銘柄選定や株価指数の選定を行う際に将来の株価を点推定してその上昇率の高さで銘柄や株価指数を決定したが、その際に過去のデータのボラティリティを考慮して選定を行うことが出来なかったことが挙げられる。例えば株価指数の選定の際に中国株はかなりボラティリティが高かったが結果的に選定されてしまった。株価の上昇率だけでなくボラティリティを考慮した選定方法をとる事で、より安定した選定ができるのではないかと考えた。

6.3 定性グローバルファンド

グローバルなトレンドと直近のニュース記事を用いたGAMによる短期市場予想によって銘柄を選択していった。他二つの定量的な分析を行うファンドと異なり、本ファンドは定性的な分析によるため、フレームワークなどの大まかな部分では先行する研究が存在したが、明確な手法の先行研究が存在せず、手法、モデルを考える部分から銘柄選択を行った。選定に取り組んだ中で、最も感じたことはBloomberg端末による恩恵が投資家にとって非常に大きなものであるということだ。国や業種を指定しての企業の絞り込みや、グローバルなニュースの閲覧など多くの作業がワンストップで利用することが可能で非常に分析がしやすかった。反省点として、個別銘柄に絞り込みを行う際により深い定性分析を行うべきだったことが挙げられる。これからの課題として、定性分析もテキストマイニングなどの人工知能を用いることで定量的に行い、今回のように人間に限られた時間と扱う情報量の中で選定した銘柄と、人工知能が非常に膨大な量のデータを解析し選定した銘柄の両方を出し比較してみることだ。

6.4 リバランスについて

我々は週次の目標リターンを0.875%と設定してポートフォリオを組んだ。現在、我々が組んだポートフォリオはその目標リターンを超えているためリバランスを行わないことに決定した。

6.5 全体のまとめ

今回はそれぞれが研究している分野を生かすために、アンブレラ型ファンドを採用してポートフォリオを組んだ。銘柄選定の際に様々なアプローチをとる事で、国や銘柄の特徴を多角的にとらえることが出来た点が私たちのポートフォリオの最大の特徴であった。またリターンのみこだわらず平均分散アプローチを用いてリスクを最大限減らすことにも重点を置いた。Bloomberg端末を使い、大量のデータから分析を行なうことは初めての体験であり、初めはそのデータの膨大さと機能の多さに戸惑うこともあったが、最終的にはデータの使い方や分析方法を深く学ぶことが出来たので非常に貴重な体験となった。今回のコンテストを通して私たちは大量のデータを正しく分析することの重要性に

気付くことができた。いままでは限られたデータでの分析しか行えなかったが、これから研究や論文に取り組む上でBloombergを使うことによって、これまでできなかった大量のデータを用いた分析を行なっていきたいと強く思うようになった。

7. 参考文献

- [1]D. L. L. Jerome, The Financial Times Guide to Investing in Funds: How to Select Investments, FT Press, 2012.
- [2]Fama, Eugene, Efficient Capital Markets: A Review of Theory and Empirical Work, The Journal of Finance 1970.
- [3]S. Basu Investment Performance of Common Stocks in Relation to Their Price-Earning Ratios: A Test of the Efficient Market Hypothesis, The Journal of Finance, 1997.
- [4]R. A. Haugen. Modern Investment Theory. Prentice-Hall, Inc., 1997.
- [5]E. F. Fama and K. R. French. Dividend yields and expected stock returns. Journal of Financial Economics, 22~3-26, 1988.
- [6]E. F. Fama and K. R. French. The cross-section of expected stock returns. Journal of Finance, 47:427-465, 1992.
- [7]P. A. Sabatier, Top-Down and Bottom-Up Approaches to Implementation Research: a Critical Analysis and Suggested Synthesis, Journal of public policy, 1986.
- [8]J. B. Helton, N. G. Polson, J.H. White, Deep learning for finance: deep portfolios, Electronic copy available at: <http://ssrn.com/abstract=2838013>, 2016.
- [9] Q.-L. Ma, Q.-L. Zheng, H. Peng, T.-W. Zhong, L.-Q. Xu, Chaotic time series prediction based on evolving recurrent neural networks, in: Machine Learning and Cybernetics, 2007 International Conference on, Vol. 6, 2007.
- [10]D. E. Rumhart and J. McClelland. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, MIT Press, 1986.
- [11]T. Mikolov, M. Karafiat, J. Cernocky, and S. Khudanpur. Recurrent neural network based language model. In Proc. Interspeech, 2010.
- [12] G. Zhang, M. Hu, Neural Network Forecasting of the British Pound/US Dollar Exchange Rate. Omega, Int. J. Mgmt Sci. Vol. 26, No. 4, 1998.
- [13]R. R. Trippi and E. Turban, A. N. Constructive learning and its application to currency exchange rate forecasting, Chicago: Probus Publishing Company, 1993.
- [14] J. L. Elman. Finding structure in time. Cognitive Science, vol 14, 1990.
- [15] Hitoshi IIMA, Yasuaki KUROE, Swarm Reinforcement Learning Algorithm Based on Exchanging Information among Agents, 計測自動制御学会論文集 vo42, 2006.
- [16]D. Floreano, P. Durr, C. Mattiussi, NeuroEvolution: from architecture to learning, Evolutionary Intelligence, 2008.
- [17]V. Nair and G. E. Hinton. Rectified linear units improve restricted boltzmann machines. In Proc. ICML, 2010.
- [18]X. Glorot, A. Bordes, and Y. Bengio. Deep sparse rectifier neural networks. In Proc. AISTAT, 2011.
- [19]岡谷貴之, 「深層学習」 p 29, 講談社, 2015.
- [20]J. H. Holland, Adaptation in Natural and Artificial Systems, Univ. of Michigan Press, 1975.
- [21]D. E. Goldberg, Genetic Algorithms in Search, Optimization, and Machine Learning, Addison-Wesley, 1989.
- [22]Alan Fan and Marimuthu Palaniswami, Stock Selection using Support Vector Machines, Department of EEE, University of Melbourne, VIC 3010, Australia, 2001.
- [23]B. Uma Devi, D. Sundar and Dr. P. AlliAn, Effective Time Series Analysis for Stock Trend Prediction Using ARIMA Model for Nifty Midcap-50, International Journal of Data Mining & Knowledge Management Process (IJDKP) Vol.3, No.1, January 2013.
- [24]H. M. Markowitz, Mean-Variance Analysis in Portfolio Choice and Capital Market, Basil Blackwell, 1987.
- [25]デービッド・G・ルーエンバーガー, 「金融工学入門」 第二版 p213, 日本経済新聞出版社, 2015.