

# 多層ニューラルネットワークと GA を用いた TOPIX 運用 AI

## “TOPIX trading AI” using Multi-layer Neural Networks and GA

石原 龍太

Ryota Ishihara

株式会社かんぽ生命保険 運用企画部

Investment Planning Department, JAPAN POST INSURANCE Co., Ltd.

**Abstract:** In This paper, we propose a construction method of an artificial intelligence for TOPIX trading. We apply a Multi-layer Neural Networks as a prediction method, and optimize to maximize the Information Ratio using GA. We also conduct a simulation using TOPIX market data from January 2014 to December 2016, showed the effectiveness of the proposed construction method from the information ratio level.

### 1 はじめに

現在、幅広い領域で注目を集めている人工知能(以下, AI)は、金融の世界にもブレークスルーをもたらすことが期待されている。本稿のテーマとする AI を用いた資産運用の研究とは、「過去に市場で発生した事象を学習し、適切な投資判断を行う AI」を構築し、資産運用に活用しようとする取り組みである。近年、米国のヘッジファンドが市場に影響を与える多種多量のデータ(ビッグデータ)を学習させた AI を資産運用に活用したり、国内の機関投資家が AI を用いて運用するファンドの組成を行う等、AI は資産運用の現場に広まってきている。

本稿のテーマに関するこれまでの研究成果を概観すると、絶対リターンを追求した運用を行う AI<sup>1</sup>の構築を目指したものが多い、というのが筆者の印象である(運用成果の表現が分かりやすい、というのも一因であろう)。一方、機関投資家の資産運用の現場では、リターンだけでなく、リスクにも配慮が求められることが一般的である。特に、株式のようなベンチマークとなる市場インデックスが存在する資産では、市場インデックスからの乖離をリスク、市場インデックスに対する超過収益をリターンとして捉え、リスク調整後リターン<sup>2</sup>を追求した運用がなさ

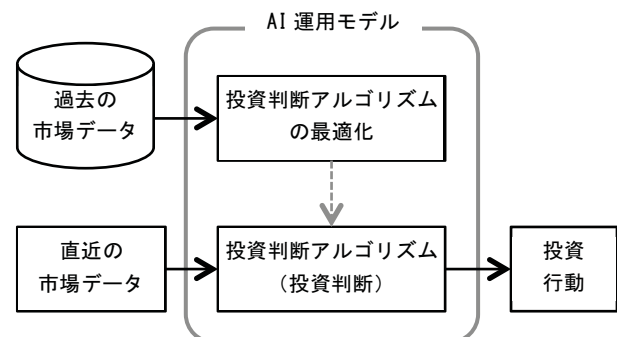
れることが多い。

そこで本稿では、東証株価指数(TOPIX)を運用対象資産として取り上げ、多層ニューラルネットワークと GA を用いて「リスク調整後リターンを追求した資産運用を行う AI(以下, AI 運用モデル)」の構築を試みる。

### 2 AI 運用モデルの構築

本稿で構築する AI 運用モデルの概念図を図 1 に示す。AI 運用モデルは、直近の市場データを知覚し、投資判断アルゴリズムで導出した投資判断から投資行動を決定するものとする。また、AI 運用モデルは過去の市場データを学習し、人間によるチューニングを必要とせず、自ら投資判断アルゴリズムを最適化することができるものとする。

図 1 AI 運用モデルの概念図



(出所) 筆者作成。以下同じ。

<sup>1</sup> 平林/伊庭(2008)の研究では収益額, 山口/坂井/田中(2003)の研究では資産残高の最大化を追求している。なお, 辻岡/山本(2011)の研究では, シャープレシオの最大化を追求する AI も提案している。

<sup>2</sup> 投資におけるリスクとリターンの両方を考慮して運用の巧拙を表す指標をリスク調整後リターンと呼ぶ。その代表的なものが, シャープレシオやインフ

オメーションレシオである。

## 2.1 AI 運用モデルの概要

### 2.1.1 運用コンセプト

AI 運用モデルは、市場環境に応じて機動的にリバランスを行い、リスク調整後リターンの最大化を目指すものとする。

### 2.1.2 投資対象資産

AI 運用モデルが投資する資産は、TOPIX と無リスク資産（収益率は常に 0% とする）の 2 種類とする。また、資産の売買（TOPIX と無リスク資産の交換）は当日終値で行うものとし、取引コスト（売買手数料等）は発生しないものとする。

### 2.1.3 資産アロケーション

AI 運用モデルは、機動的なリバランスにより資産価格の下落による損失を回避するため、市場環境に応じて日々保有資産の組入比率を変更（リバランス）するものとする。また、選択する保有資産の組入比率は「TOPIX100%, 無リスク資産 0%」又は「TOPIX0%, 無リスク資産 100%」のいずれかとする。

### 2.1.4 市場データ

AI 運用モデルが知覚する市場データ<sup>3</sup>は、表 1 で定義する TOPIX の日次の四本値と配当データ ( $t=1, \dots, T$ ) とする。ここで、 $t$  日の TOPIX の配当  $\text{TpxDIV}_t$  は以下のように定義<sup>4</sup>する。

$$\text{TpxDIV}_t = \left( \frac{t \text{ 日の TOPIX 配当込み指数}^5}{t-1 \text{ 日の TOPIX 配当込み指数}} - \frac{\text{TpxCL}_t}{\text{TpxCL}_{t-1}} \right) \times \text{TpxCL}_{t-1}$$

表 1 市場データ (TOPIX 四本値と配当)

日付	始値	高値	安値	終値	配当
T	$\text{TpxOP}_T$	$\text{TpxHI}_T$	$\text{TpxLO}_T$	$\text{TpxCL}_T$	$\text{TpxDIV}_T$
:	:	:	:	:	:
t	$\text{TpxOP}_t$	$\text{TpxHI}_t$	$\text{TpxLO}_t$	$\text{TpxCL}_t$	$\text{TpxDIV}_t$
:	:	:	:	:	:
1	$\text{TpxOP}_1$	$\text{TpxHI}_1$	$\text{TpxLO}_1$	$\text{TpxCL}_1$	$\text{TpxDIV}_1$

<sup>3</sup> 先行研究では「終値（一本値）」を知覚データに用いているものが多いが、筆者は適切な投資判断には情報の深さよりも厚みが重要であると考え、本稿では「TOPIX 四本値と配当」を用いる。

<sup>4</sup> 有効桁数は小数点第 2 位までとし、小数点第 3 位以下は切り捨てる。


<sup>5</sup> TOPIX 配当込み指数は、(株)東京証券取引所が終値のみを算出している指数である。

## 2.2 投資判断アルゴリズムの作成

AI 運用モデルの投資判断アルゴリズムは、入力層（1 層）、中間層（5 層）、出力層（1 層）の 7 層からなる多層ニューラルネットワーク<sup>6</sup>を用いて作成する。多層ニューラルネットワークとは、入力層と出力層の間に中間層をもつニューラルネットワークであり、さまざまな情報が混在する雑多なデータから、本質的な情報を抽出することに適した数理モデルとされる。

本稿で用いる多層ニューラルネットワークの構造を図 2 に示す。投資判断アルゴリズムは、入力層で市場データを知覚し、2 系（上昇系、下降系）の中間層と出力層で TOPIX の価格変動（上昇または下落）を予測し、当該予測に基づく投資判断を導出する。

図 2 多層ニューラルネットワークを用いた投資判断アルゴリズム



(注) 丸はニューロン、矢印はニューロン間の結合と処理の流れを示す。

### 2.2.1 入力層

入力層のニューロン  $y_{kt}^{\text{in}}$  は市場データを知覚し、表 2 で定義した出力値を中間層 1 のニューロンに受け渡す。ここで  $k$  を入力層を構成するニューロンの識別番号 ( $k=1, \dots, 7$ ) とする。

<sup>6</sup> ニューラルネットワークとは「人間の脳内の神経細胞（ニューロン）が、別の神経細胞から受け取った信号を次の神経細胞へと伝達していく流れの中で、様々な情報処理を行う仕組み」を模擬した数理モデルである。層（並列に並んだニューロンで形成されるユニット）の数が 3 桁以上となるような大規模な多層ニューラルネットワークはディープニューラルネットワークと呼ばれる。

表 2 入力層ニューロンの出力値

ニューロン	出力値
$y_{1t}^{in}$	$\log\{(TpxCL_t + TpxDIV_t)/TpxOP_{t-1}\}$
$y_{2t}^{in}$	$\log\{(TpxCL_t + TpxDIV_t)/TpxHI_{t-1}\}$
$y_{3t}^{in}$	$\log\{(TpxCL_t + TpxDIV_t)/TpxLO_{t-1}\}$
$y_{4t}^{in}$	$\log\{(TpxCL_t + TpxDIV_t)/TpxCL_{t-1}\}$
$y_{5t}^{in}$	$\log(TpxCL_t/TpxOP_t)$
$y_{6t}^{in}$	$\log(TpxCL_t/TpxHI_t)$
$y_{7t}^{in}$	$\log(TpxCL_t/TpxLO_t)$

### 2.2.2 中間層

中間層は、上昇系 (up) と下降系 (down) の並列構造をもつ 5 層構成とし、両系とも 1 つの層あたり 10 個のニューロンで構成する。

$\omega_{jkk}^{s-1(s)}$  を  $j$  系における  $s$  層のニューロン  $k$  と  $s-1$  層のニューロン  $k'$  の間の結合ウェイト ( $k'$  が 11 のものは定数項を意味する),  $f(x)$  を 0 または 1 の値をとるステップ関数 ( $x$  が 0 より大きい場合は 1, そうでなければ 0 を返す) としたとき, 中間層 1 のニューロン  $y_{jkt}^{mid1}$  の出力値は以下のように表現する。

$$y_{jkt}^{mid1} = f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

$$x = \omega_{j1k}^{in(mid1)} y_{1t}^{in} + \dots + \omega_{j7k}^{in(mid1)} y_{7t}^{in} + \omega_{j8k}^{in(mid1)} \times 5\%$$

また, 中間層 2~5 のニューロン  $y_{jkt}^{mid2}, y_{jkt}^{mid3}, y_{jkt}^{mid4}, y_{jkt}^{mid5}$  の出力値は以下のように表現する。

$$y_{jkt}^s = f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

$$x = \omega_{j1k}^{s-1(s)} y_{j1t}^{s-1} + \dots + \omega_{j10k}^{s-1(s)} y_{j10t}^{s-1} + \omega_{j11k}^{s-1(s)}$$

ここで  $j$  を系 ( $j=up, down$ ),  $s$  を層 ( $s=in, mid1, mid2, mid3, mid4, mid5$ ),  $s-1(s)$  を層間の結合 ( $s-1(s)=in(mid1), mid1(mid2), mid2(mid3), mid3(mid4), mid4(mid5)$ ),  $k$  を  $j$  系の  $s$  層を構成するニューロンの識別番号 ( $k=1, \dots, 10$ ) とする。  $j$  系の中間層  $s$  のニューロン  $y_{jkt}^s$  は, 出力値を  $j$  系の中間層  $s+1$  又は  $j$  系の出力層のニューロンに受け渡す。

### 2.2.3 出力層

出力層は、上昇系のニューロン  $z_{up t}$  と下降系のニューロン  $z_{down t}$  で構成する。  $\omega_{jki}^{mid5(out)}$  を  $j$  系における出力層のニューロンと中間層 5 のニューロン  $k'$  の間の結合ウェイト,  $y_{jkt}^{mid5}$  を中間層 5 のニューロン  $k'$  から受け取る値,  $f(x)$  を 0 または 1 の値をとるステップ関数としたとき, 出力層のニューロン  $z_{jt}$  の出力値は以下のように表現する。

$$z_{jt} = f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

$$x = \omega_{j1}^{mid5(out)} y_{j1t}^{mid5} + \dots + \omega_{j10}^{mid5(out)} y_{j10t}^{mid5} + \omega_{j11}^{mid5(out)}$$

出力層において,  $z_{up t}$  は TOPIX 上昇の兆候,  $z_{down t}$

は下落の兆候を検知するものとし,  $z_{up t}$  が “1” の場合, 投資判断アルゴリズムが TOPIX の上昇を予測し,  $z_{down t}$  が “1” の場合, 投資判断アルゴリズムが TOPIX の下落を予測していることを意味する。

## 2.3 投資行動の決定

AI 運用モデルは、多層ニューラルネットワークの上昇系のニューロン  $z_{up t}$  と下降系のニューロン  $z_{down t}$  の出力値から, 表 3 のとおり当日 (時点  $t$ ) の投資判断を行う。 AI 運用モデルは, この投資判断に基づき当日終値で売買を行う。 なお, 前日の保有資産の TOPIX 組入比率  $x_{t-1}$  が 100% の場合における “買い判断”,  $x_{t-1}$  が 0% の場合における “売り判断” については, 当日の売買を行わない ( $x_t = x_{t-1}$ ) もとする。

表 3 出力層ニューロンの出力値と投資判断

		上昇系 $z_{up t}$	
		0	1
投資 系 上 下 $z_{down t}$	0	現状維持 ( $x_t = x_{t-1}$ )	<b>買い判断</b> ( $x_t = 100\%$ )
	1	<b>売り判断</b> ( $x_t = 0\%$ )	現状維持 $x_t = x_{t-1}$

(注)  $x_t$  は時点  $t$  における AI 運用モデルの保有資産の TOPIX 組入比率とする。

## 3 投資判断アルゴリズムの最適化

AI 運用モデルの投資判断の巧拙は, 投資判断アルゴリズムのニューラルネットワークを構成するニューロン間の結合ウェイト  $\omega_{jkk}^{s-1(s)}$  の組み合わせ (以下, ネットワーク構造) によって決まる。つまり, 運用コンセプト (リスク調整後リターンの最大化) を具現化するためには, 適切なネットワーク構造を探索することが重要となる。

### 3.1 基本設定

#### 3.1.1 リターンの表現

本稿では, TOPIX の日次収益率  $Tpxr_t$  と Cash  $r_t$  を以下のように表現する。

$$Tpxr_t = \log\left(\frac{TpxCL_t + TpxDIV_t}{TpxCL_{t-1}}\right)$$

$$Cashr_t = 0\%$$

このとき, AI 運用モデルの日次収益率  $AIr_t$  は, TOPIX と無リスク資産の日次収益率を前日の組入比率で加重平均した値として, 以下のように表現され

る。

$$AIr_t = Tpxr_t x_{t-1} + Cashr_t(1 - x_{t-1})$$

また、N を m 月に含まれる日次データの件数としたとき、m 月における AI 運用モデルの月次収益率  $AIr_m$  と TOPIX の月次収益率  $Tpxr_m$  は以下のように表現される。

$$AIr_m = \sum_{t=1}^N AIr_t$$

$$Tpxr_m = \sum_{t=1}^N Tpxr_t$$

### 3.1.2 リスクの表現

本稿のリスク指標には、トラッキングエラーを用いる。AI 運用モデルのトラッキングエラー  $\sigma(e)_{AI}$  は以下のように表現する。

$$\sigma(e)_{AI} = \sqrt{\frac{\sum_{m=1}^M \{(AIr_m - Tpxr_m) - (\overline{AIr} - \overline{Tpxr})\}^2}{M - 1}}$$

$$\overline{AIr} = \frac{\sum_{m=1}^M AIr_m}{M}$$

$$\overline{Tpxr} = \frac{\sum_{m=1}^M Tpxr_m}{M}$$

ここで M を計測期間の月数とする。

### 3.1.3 リスク調整後リターン表現

本稿のリスク調整後リターンには、インフォメーションレシオ<sup>7</sup>を用いる。AI 運用モデルのインフォメーションレシオ  $IR_{AI}$  は以下のように表現する。

$$IR_{AI} = \frac{(\overline{AIr} - \overline{Tpxr}) \times 12}{\sigma(e)_{AI} \times \sqrt{12}}$$

## 3.2 投資判断アルゴリズムの最適化

本稿では、「学習」、「検証」の2ステップにより最適なネットワーク構造を探索し、AI 運用モデルの投資判断アルゴリズムを決定する。

### 3.2.1 学習

2002年1月～2011年12月の10年間を学習期間とし、当該期間の市場データをAI 運用モデルに学習させる。具体的には、当該期間のインフォメーションレシオを最大化する投資判断アルゴリズムのネットワーク構造を、遺伝的アルゴリズム<sup>8</sup>（以下、GA）を

<sup>7</sup> 本稿のインフォメーションレシオは、年率換算したリスクとリターンを用いて算出する。

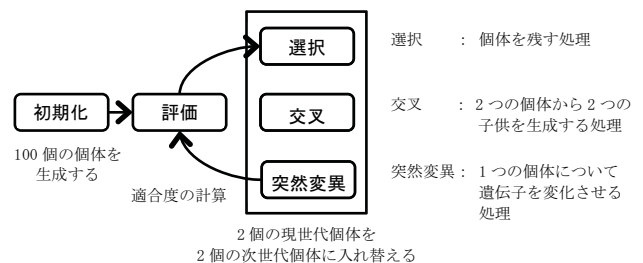
<sup>8</sup> 「生物が生存していくなかで、選択、交叉、突

用いて探索することで、AI 運用モデルに運用コンセプトを具現化する投資判断アルゴリズムを適応的に獲得させる。本稿における GA の操作は平林/伊庭(2008)を参考にした。

図3にGAの概念図を示す。GAの探索の流れとしては、まず異なる遺伝子型を持つ個体を多数生成させて初期個体とする。ここで、各個体は投資判断アルゴリズムのネットワーク構造を表す遺伝子型（遺伝子の集まり。各遺伝子の値は、ニューラルネットワークのニューロン間の結合ウェイト  $\omega_{jk}^{s-1(s)}$  を表す）として、図4のように定義される。各遺伝子の値は区間[-1, +1]の実数値とし、初期個体の遺伝子及び突然変異で置換する遺伝子の値は区間[-1, +1]の乱数で決定する。次に各個体について学習期間の売買シミュレーション<sup>9</sup>を行い、各個体の適合度を評価する。次に適合度の高い個体が生き残るような方法で選択を行い、一定数の個体に対して交叉や突然変異の処理（遺伝的操作）を行う。こうして作られた次世代についても適合度の評価を行い、以下同じ処理を繰り返す。

GAのパラメータは、適合度を学習期間のインフォメーションレシオ  $IR_{AI}$ 、初期個体数を100個体、遺伝的操作回数を500～10000回、選択の方法をエリート選択、交叉の方法を1点交叉、突然変異の方法を置換、突然変異率を3%とする。

図3 遺伝的アルゴリズムの概念図



(出所) 多田(2016) (筆者により一部修正)

図4 遺伝子型

$\omega_{j1k}^{in(mid1)}$	...	$\omega_{j1k}^{s-1(s)}$	...	$\omega_{j1k}^{mid5(out)}$	...
---------------------------	-----	-------------------------	-----	----------------------------	-----

然変異を繰り返しながら環境に適合していく仕組み」に基づく、数理モデルの最適化の手法を遺伝的アルゴリズムという。

<sup>9</sup> 各個体の保有資産の組入比率の初期値は、パフォーマンス計測期間の1営業日前の投資判断（買い：TOPIX100%，それ以外：TOPIX0%）により決定する。


### 3.2.2 検証

投資判断アルゴリズムが学習期間のデータに過剰適合（過学習）してしまうことを避けるため、学習期間の直後の2年間（2012年1月～2013年12月）を検証期間とし、当該期間のデータを用いて、学習ステップで最適化した個体の検証を行う。

具体的には、学習ステップのGAにおける遺伝的操作の回数が500, 1000, …, 10000回の各時点で適合度が最も高い個体を抽出し、抽出した各個体について検証期間のインフォメーションレシオを計測し、その水準から個体の過剰適合を判断する。

図5は、抽出した各個体の遺伝的操作回数と学習期間及び検証期間におけるインフォメーションレシオの関係を示す。図5より、遺伝的操作回数が5500回を超える辺りから検証期間のインフォメーションレシオが小さくなる傾向を示したため、遺伝的操作を6000回以上行った個体を過剰適合していると判断する。

図5 遺伝的操作回数とインフォメーションレシオ



### 3.2.3 投資判断アルゴリズムの決定

検証の結果、学習ステップでGAの遺伝的操作を5500回行った個体を、AI運用モデルの投資判断アルゴリズムに決定する。

## 4 実証分析

本稿で構築したAIの有効性を確認するため、検証期間の直後の3年間（2014年1月～2016年12月）を実証分析期間とし、当該期間の市場データを用いて売買シミュレーションを行う。

### 4.1 有効性の確認

表4に売買シミュレーションの結果を示す。表4より、実証分析期間におけるAI運用モデルのインフォメーションレシオは0.4946と、一般に良いとされる

目安<sup>10</sup>である0.5に近い値となった。これは、AI運用モデルが、運用コンセプトを具現化する投資判断アルゴリズムを適応的に獲得したことを示唆するものと考え、本稿で構築したAIが、実際の資産運用においても有効であるものと解釈する。

表4 売買シミュレーション結果（実証期間）

	収益率 (年率)	トラッキング エラー(年率)	インフォメーションレシオ
AI運用モデル	9.55%	4.96%	0.4946
TOPIX	7.10%	-	-

### 4.2 売買シミュレーション結果の考察

図6に実証分析期間におけるAI運用モデルとTOPIXの累積収益率の推移、図7に学習期間と実証分析期間における月次のTOPIX収益率とAI運用モデルの超過収益率の関係を示す。

図6 実証分析期間における累積収益率の推移





図7 TOPIX月次収益率とAI運用モデルの月次超過収益率（左：実証分析期間、右：学習期間）



(注) グラフ内の直線は回帰直線を表す。

<sup>10</sup> 一般に、インフォメーションレシオが0.5以上であればGood（良い）、1以上であればExcellent（優秀）、2以上であればExceptional（例外的）と言われる（三好(2007)）。但し、インフォメーションレシオの水準は測定するデータ数等によって変わってくるため、いくつ以上でどの程度優秀かを一概に言い表すことは難しい。

図 6 より、AI 運用モデルが TOPIX に比べて高い収益率を獲得していることがわかる。これは、AI 運用モデルが市場環境に応じた機動的なリバランスにより、TOPIX の下落による資産価格の減少を回避したことを示唆するものと考えられる。

また図 7 より、AI 運用モデルが高い超過収益率を獲得した月は、TOPIX が小幅に下落した月に集中しており、TOPIX が大幅に下落した月は超過収益率を相対的に獲得できていない(AI 運用モデルは TOPIX の大幅な下落の兆候を検知できない)という傾向が見られる。これは、AI 運用モデルの知覚データの数が少ないことやニューラルネットワークの階層が浅いことが一因ではないかと考える。

知覚データの拡大やニューラルネットワークの多層化等により、TOPIX が大幅に下落する局面における、AI の投資判断の精度を改善することが今後の課題である。

## 5 おわりに

本稿では、多層ニューラルネットワークで作成した投資判断アルゴリズムを GA で最適化する手法により「TOPIX に対するリスク調整後リターンを最大化する資産運用 AI」を構築した。また、インフォメーションレシオの水準から、構築した AI が実際の資産運用においても有効であることを示した。

なお、筆者としては現在のところ、資産運用の現場において AI が人間に置き換わるような劇的な変化が起こるとは考えていない。当面の間、既存の運用手法を AI で補完するような形(例えば、業種や個別銘柄の選択眼に長けたファンドマネージャーが、本稿で構築したような機動的なリバランスを行う AI を併用し、運用パフォーマンスを改善させるような方法)で、AI は資産運用の現場に広まっていくのではないかと考える。

最後に、本稿が資産運用の分野における AI に対する理解の広まりや活用の検討につながる一助となることを期待したい。

本稿の内容は、筆者個人に属するものであり、筆者の所属組織の公式見解を示すものではありません。また、本稿に含まれる誤りは全て筆者の責に帰するものです。

## 参考文献

- [1] 岡本訓幸, 野島哲, 岩田雄一郎, 鴻丸靖弘, 大塚征輝, “新潮流で広がるクオンツ運用のフロンティア”, 三菱 UFJ 信託資産運用情報 2016 年 6 月号, (2016)
- [2] 柏木亮二, “金融領域での人工知能の活用”, 金融 IT フォーカス 2015 年 11 月号, (2015)
- [3] 小牧昇平, 白山晋, “Deep Belief Network を用いた日経平均株価の予測に関する研究”, 第 12 回人工知能学会 金融情報学研究会 SIG-FIN-012-08, (2014)
- [4] 多田智史, “あたらしい人工知能の教科書”, 翔泳社, (2016)
- [5] 辻岡卓, 山本耕司, “取引戦略生成に適した評価指標の検討”, 第 7 回人工知能学会 ファイナンスにおける人工知能応用研究会 SIG-FIN-007-05, (2011)
- [6] 砺波元, “資産運用のパフォーマンス測定”, 金融財政事情研究会, (2000)
- [7] 平林明憲, 伊庭斉志, “遺伝的アルゴリズムによる外国為替取引手法の最適化”, 2008 年度人工知能学会全国大会(第 22 回) 論文集 3H1-2, (2008)
- [8] 堀江貞之, 金子久, 川橋仁美, 富永洋子, 浦壁厚郎, “日本の資産運用ビジネス 2016/2017”, 野村総合研究所, (2016)
- [9] 三好秀和, “ファンドマネジメントのすべて”, 東京書籍, (2007)
- [10] 山口和孝, 坂井修一, 田中英彦, “ニューラルネットと GA を用いた株式売買支援システム”, 情報処理学会第 65 回全国大会 講演論文集 2003(1), pp.215-216, (2003)