

ニューラルネットワークを利用したポートフォリオセレクションモデル

3D-3

—実験結果と実務への適用可能性—

浜屋 敏* 宇梶 町子* 関 順二* 泉 寛幸** 佐藤 秀樹**

*¹富士通システム総研

**²富士通研究所

1. はじめに

証券市場の拡大とともに、証券投資のリスクを低減するために、さまざまな手法が開発され、実務への適用が検討されている。マルコビッツ¹⁾が考案した二次計画法(QP)を利用したモデルは、理論的に大変すぐれた性質をもっているが、実務へ適用するためには、現在のQPが持つ以下のような問題点を解決しなければならない。

- ①計算機の記憶領域を非常に多く使う。
- ②問題が大規模化すれば、処理時間が長くなる。
- ③整数条件など、実務的な制約条件に対応できない。

これらの問題点に対して、区分的に線形なリスクを用いたモデル²⁾などが考えられているが、われわれは、マルコビッツモデルの理論的な整合性を残したまま、従来のQPのアルゴリズムではなく、相互結合型ネットワークを利用して投資リスクを低減するモデルを開発した。実験結果から、本モデルは、大規模化の可能性やアルゴリズムの柔軟性などの点で従来のQPよりも優れていることがわかった。

ここでは、本モデルの実験結果を紹介し、さらに、実務への適用可能性を検討する。

2. 問題の定義とモデルの特徴

2-1. ポートフォリオ最適化問題

ポートフォリオとは、複数の証券を組み合わせたものを意味し、一般に、ポートフォリオを組めば、単独の証券に投資するよりもリスクが低減される。そして、「一定のリターンのもとで、リスクを最小化するようなポートフォリオを組むためには、各証券をどのような比率で組み合わせればよいか」という問題が、ポートフォリオ最適化問題として定義されている。

2-2. ニューラルネットワークの利用

本モデルで利用した相互結合型ネットワークは、以下のような特徴を持つ。これらの特徴によって、実務への適用がより現実的になったと思われる。

- ①各ノードを一つの証券(1銘柄)に対応させたため、比較的小規模のネットワークですむ。
- ②デジタルな2値モデルではなく、各銘柄の組み入れ比率まで表すことができる。

なお、本モデルの原理と構造の詳細については、われわれの他の論文³⁾を参照されたい。

3. 実験


3-1. 実験の方法

実験に使用したデータは、現実の株式市場の過去のデータに基づいて計算したものである。また、われわれは、全てのノードに等しい値を与えて初期状態とし、エネルギーが十分に小さなある一定の値以上減少しなくなったとき、ネットワークは収斂したものと判断した。

3-2. 実験結果

図1は、100銘柄を対象とした場合の、ネットワークの収斂状況を示したものである。各ノードの大きさは、対応する証券の組み入れ比率を表している。

図1. ネットワーク収斂状況(左:50回目, 右:収斂(242))



一方、図2は、50銘柄を対象とした場合の解の精度を表している。曲線はいわゆる「効率的フロンティア」であり、同一リタンのポートフォリオのなかで最もリスクの小さなものの集合を意味している。これは、Goldfarb-Idnani法によるQP(以下、QPという場合、主にこのG-I法を想定している)を利用して求めたものであり、真の最適解の集合であると考えて良い。一方、本モデルの解は図中◆で示されているが、解の誤差は非常に小さい。

図2. 本モデルの解の精度





図3は、パソコン上で80銘柄以下の少数銘柄を対象として実測した処理時間である。この図にあるような小規模問題では明らかにQPの方が速いが、この図からは、同時に、QPの処理時間が銘柄数の三乗に比例して増加するのに対して、本モデルは二乗にしか比例しないことがわかる。したがって、

Portfolio Optimization using Neural Networks
-experiment and application-
Satoshi Hamaya, Machiko Ukaji and Junji Seki: (*)
Hiroyuki Izumi and Hideki Sato: (**)
(*:Fujitsu Research Institute, **:Fujitsu Laboratories Ltd.)

大規模化した場合には、本モデルの方が速く処理できるはずである。

図3. 小規模問題の処理時間



4. 実務への適用と課題

4-1. 従来の実務上の問題点

一般的なQPは、特に大規模化に難点があるため、実務上は、まず何らかの属人的な基準で銘柄をスクリーニングし、処理可能な規模まで問題を縮小してから最適化を行うのが一般的である。したがって、そこで得られるポートフォリオは、あくまで部分的な意味で最適であるにすぎない。

以下では、実務上のこのような問題点を考慮にいれたうえで、本モデルの特長と課題を論じる。

4-2. 本モデルの特長

(1)大規模化の可能性

本モデルは、次の2点において従来のQPよりも大規模化が容易であると考えられる。

①必要とする記憶領域の大きさ

本モデルのアルゴリズムは比較的単純であり、計算機上で必要な記憶領域も少なくすむ。実験からも、パソコンでも少なくとも150銘柄の問題を処理することができるがわかっている(QPは、80銘柄以上は処理できない)。

②(大規模化した場合の)処理時間

図3に示した実験結果から、例えば、東証第一部で取引される全株式(1136銘柄)を対象にすると、本モデルの処理時間は、QPの40%程度に短縮されると推計できる。

(2)アルゴリズムの柔軟性

実務では、バンド制約や整数条件など、付加的な制約条件が追加されることが多い。QPに整数条件を追加することは困難だが、本モデルは、比較的簡単にさまざまな制約条件に対応できると考えられる。

また、QPが分散共分散行列の正定値対称性を必要とすることが多いのに対して、本モデルは対称行列であれば十分である。正定値の行列を作るためには銘柄数以上のサンプルが必要であるため、大規模問題でこの問題が表面化したとき、本モデルの柔軟性が大きな意味を持つことになる。

4-3. 本モデルの課題

(1)解の精度

一般に、ニューラル・ネットワークは局所的最小点に収斂してしまふ可能性があり、その解はあくまで近似解にすぎない

ことが多い。この問題を解決するためには、適当な初期状態の探索や模擬徐冷など、いくつかの手法が考えられており、本モデルにも適用可能である。

しかし、理論的にはともかく、実務上は、厳密な意味での「最適な」解でなくとも、「良い」解であれば十分利用できる場合が多い。特に、ポートフォリオ・セレクションの実務は、事前的な予測値を入力データとする場合が多いため、最適化の際のわずかな誤差は無視できるであろう。

(2)アルゴリズムのチューニング

本モデルで使用している評価関数は、問題の目的関数と制約条件式のそれぞれに適当な正の係数を掛け、それらを合計して一つにまとめたものである³⁾。したがって、まずこれらの係数を決定することが必要になるが、われわれは、今のところ、シミュレーションを繰り返して、試行錯誤によって経験的に良い値を定めているにすぎない。

われわれは現在225銘柄の問題まで解いているが、問題の大規模化とともに係数の決定が困難になり、スーパー・コンピュータを用いて処理しなければ、時間的に対応できなくなってしまう。すでに述べたように、一旦係数が決定されれば、その後の処理時間は特に問題ではないため、係数調整の効率を高めることが、本モデルの最大の課題であると思われる。

5. おわりに

ポートフォリオ・セレクションは、実務上の非線形最適化問題の中でも、最も規模の大きなものの一つである。われわれが開発したモデルは、一般のQPに比べて大規模化の可能性は高いものの、実務へ適用する際には、係数調整の時間を含めた全処理時間を短縮することが不可欠である。

われわれは、整数条件などの制約条件の追加とともに、より効率的なチューニング方法を現在検討中であるが、計算機技術の進歩は、処理速度を一気に高める可能性がある。例えば、ベクトル演算が可能なスーパー・コンピュータを利用すれば、処理時間と銘柄数の関係は線形になる。また、ニューロ・コンピュータのハードウェアが実用化されれば、さらに処理速度を上げることができるだろう。

効率的なチューニングの方法が確立されれば、すぐれたハードウェアのもとで、アルゴリズムの柔軟性などの長所を持つ本モデルの実務的な意義が大いに高まるものと思われる。

参考文献

- 1) Markowitz, H.: "Portfolio Selection", John Wiley & Sons, inc., 1959
- 2) Konno, H.: "Piecewise Linear Risk Function and Portfolio Optimization", IHSS 89-10, Inst. of Human and Social Sciences, Tokyo Inst. of Technology, January, 1989
- 3) 泉他: "ニューラルネットワークを利用したポートフォリオセレクションモデル(原理と構造)", 第39回情報処理学会全国大会予稿集, 掲載予定(1989)