

階層型ニューラルネットワークによる企業財務情報 分析：倒産分析と債券格付分析

李, 鋼浩

<https://doi.org/10.15017/3000048>

出版情報：経済論究. 82, pp.185-205, 1992-03-21. 九州大学大学院経済学会
バージョン：
権利関係：

階層型ニューラルネットワークによる 企業財務情報分析

——倒産分析と債券格付分析——

李 鋼 浩

1. ま え が き

企業が公表する各種の財務データや、これに関連して作成される第三者機関の財務分析の資料は、投資決定をはじめさまざまな意思決定に利用されている。これら資料の利用方法は多様であるが、その中でも現在までの資料を利用して、将来おこりうる事態を予測する分析は重要である。企業の財務データを解析してその企業の倒産を予測したり、債券の格付けするなどの作業は、形態は異なっているが、企業の管理部門、金融機関、信用調査機関などで行われている〔1〕。

このようなデータ予測の手法として、近年、ニューラルネットワーク (neural networks) による方法が提案されており成果を上げている。ニューラルネットワークは過去のデータをもとにして、システムが最適な認識機構を構成していく方法であり、学習 (learning) と呼ばれている。学習により得られたシステムは、解析するデータが標準的なケースより若干離れていても、学習したもとのデータと同様の処理を行ってくれる性質があり、データに含まれる個別的な特異性 (雑音とよんでいる) を吸収することができる。

本論文では、ニューラルネットワークを代表的な企業財務分析へ適用する場合の特性と問題点について整理している。ここで取り上げるニューラルネットワークによる企業財務情報の分析については、米国を中心として以前より多数の方法と応用例が示されており、現在においてもビジネスローン、債券の格付

け、企業財務診断などに重要な役割を果たしている〔2〕。しかし、金融機関などのレポートでは結果の概要しか示されていないため、どのような解析方法を取り、どこが問題であるかが不明である。また、実際にどのような効果を上げているかについてもあいまいである。このようなことから、本論文では、主に日本の企業に注目し、財務分析を行っている。

最初に階層型ニューラルネットワークにより企業財務データを用いた判別分析を取りあげ、企業倒産の予測モデルの構築と企業の発行する転換社債の格付け予測へと応用していく〔3〕〔4〕。なお、本論文では、ニューラルネットワークによる財務分析を単独のものとして取り扱っているが、従来の倒産分析や投資技法とニューラルネットワークとを組み合わせたエキスパートシステム（人工知能技術による自動判断システム）を構成することも可能である。これについては機会を改めて論じたい。

以下では、第2章において日本の企業財務データベースをどのように研究用データベースへと変換しているかについて整理し、一般に研究室レベルでデータベースを構成する場合について問題点を議論している。第3章においては階層型ニューラルネットワークによる学習の理論について整理するとともに、企業財務分析への応用方法についてまとめる。第4章では、本論文で行う財務分析手法と従来の手法との関連について整理し、分析の対象とする財務データの特性について説明し、実際に行ったニューラルネットワークによる学習と判別効率について結果の整理を行っている。

2. 企業財務データベースのコンピュータ処理環境

2.1 研究用財務データベースの構成

日本の企業財務に関する商用データベースとしては日本経済新聞社（日経）のデータが以前より整備されており、最近では種類も豊富になっている。ここでは論文に関連する企業財務データについてのみ、処理手順を整理しておく。財務データベースをコンピュータ処理すること自体は新しいことではないが、今後の分散処理の環境に関する問題点を指摘する必要がある。

図1には、今回の財務分析で行った解析手順をコンピュータシステムとの関連でまとめている。日経企業財務データは大蔵省印刷局発行の有価証券報告書をもとに、企業の現在までの活動を基本として統一的なフォーマットの貸借対照表、損益計算書を記載したものであり、使用した媒体は磁気テープである。現在では他の会社から CD-ROM によるデータも販売されている。九州大学経済学部ではデータベース構成の専用コンピュータとして1989年よりワークステーション（富士通A—80システム）を導入しており、今回もこのシステムを利用した。

よく知られているように、磁気テープの多くは汎用大型コンピュータシステム上において利用されることが多く、その記録形式もいわゆる IBM フォーマットとよばれる形式で、コード体系も EBCDIC である。これに対して、ワークステーションは UNIX オペレーティングシステムで動作し、コード系は ASCII である。その他、大型汎用コンピュータとワークステーションとのさまざまな相違に注意する必要がある。これらを含めてデータベース作成と利用手順は以下のようにまとめられる。

(1) 磁気テープフォーマット変換

IBMフォーマットで提供されている磁気テープデータを ASCII コードへと変換するために、九州大学大型計算機センターにおいて変換作業を行い、変換後の磁気テープはワークステーションA—80の磁気テープ読み取り装置にかけられるようにした。

(2) 索引データセットの作成

次に、A—80上の索引アクセスデータセットとして企業財務データを作成した。アクセスのキーとしては、決算の年次と月、企業コードである。企業コードについては日本経済新聞社独自の割当てであり、有価証券報告書の体系とは異なっている。また、決算の月が不明な場合でも検索できるように対応している。A—80システムの能力の関係で、磁気テープから直接読み込みながら索引データセットを構成することはできない。そのため、まず、磁気ディスク内の順次編成データセットとして作成し、次にこれを元にして上に述べたキーをもつ索引データセットとして作成した。このデータセットの格納形式については

省略するが、データが EBCDIC から ASCII へとコード変換されたとき 1 レコード長は 5075 バイトとなる。このレコードが一企業の単年度分のデータを構成し、これを繰り返している。

(3) データの検索と結果の格納

キーによる検索は連続して行えるようにしており、ある年度についての指定されたキーをもつ企業についての財務データを検索することができる。検索の結果は画面に生データとして表示されるとともに、あとでの処理に便利のように順データセット (A-80 上のファイル) として作成される。このデータセットはコンピュータ間の通信により汎用コンピュータ上のファイルへと転送することができる。

2.2 データベース構成上の問題点

このような手順により企業財務データを検索するシステムが作成できるが、実際には以下に述べるような問題点があり、特に磁気テープデータとして提供される場合には十分な注意が必要である。

(1) コード体系の違い

コンピュータによりコード体系が異なるため磁気テープデータを変換する必要がある。汎用コンピュータどうしの場合には IBM フォーマットが主流であり、ほとんど問題はないが、研究室などのワークステーションでは UNIX 系のオペレーティングシステムを用いている関係で ASCII コードであり、変換

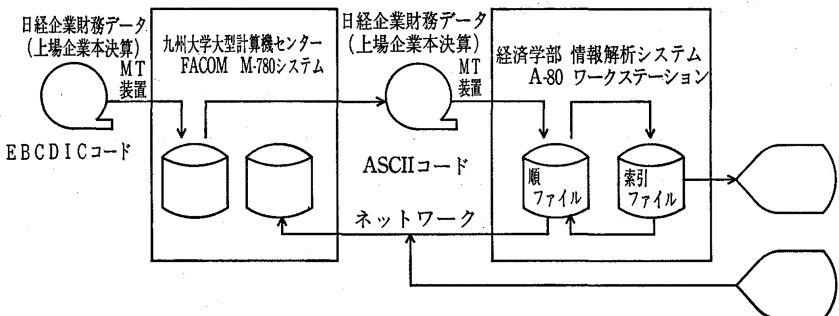


図1 研究室向け企業財務データベースの構成手順

ルーチンをもたない限り、変換作業をセンターにおいて行う必要がある。今回、かなり集中的に作業を行ったが、約2日を要している。

(2) 長大なレコード長

磁気テープに記録される経済データの多くは、多数の項目に関する時系列的なデータであるため、ひとまとまりのデータが記載されているレコードの長さが長大である。日経企業財務データの場合には3,000バイトであり、大学の計算機センターなど共同利用機関においては制限値を越えてしまうことがある。今回も特別に短時間だけ制限値を外してもらい、どうにか変換することができた。

(3) 膨大なデータ量

過去20年間にわたる日本企業財務データを格納している関係で、磁気テープとしては2～3本の量となり、索引ファイルとして作成した場合には300MB程度のスペースを食ってしまう。もちろん、共同利用の大型計算機センターなどへ格納した場合においても莫大なスペースと費用を要するので、単独のワークステーションで実現できていることを考えると改善されているであろう。

以上のように、ワークステーションなど従来とは異なる計算機システムを導入していくケースが増加することが予測されるので、最初からデータ変換機能を組み込んだシステム設計とすることや、汎用計算機とのデータのやりとりをネットワークにより整備しておいてデータ変換の労働を避ける構成が望ましい。

また、今回のデータベース構成とは直接関係ないが、UNIX系ワークステーションに使い勝手のよいテキストエディタを準備しておくことが不可欠である。現在、UNIX系ワークステーションのソフトウェアはPDS (Public Domain Software) を中心としてかなり充実される傾向にあるが、プログラミング言語の周辺の整備は進んでいない。これは早急に改善されるようではないので、エディタを充実することにより部分的にでも問題を解決することが必要である。

3. 階層型ニューラルネットワークによる企業財務分析

3.1 企業財務分析の方法

企業の財務分析については経営財務の分野でも歴史的にさまざまなアプローチが行われた分野であり、経営財務のみならず経営学一般にとっても重要な課題である。よく知られているビーバ〔1〕、レブ〔5〕やアルトマン〔6〕らの財務分析では、企業の財務分析を行うために判別関数を構成し、 z の値がゼロより大きいか、それともゼロ以下であるかにより企業経営の状態を判別しようとするものである。

$$z = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n \quad \dots\dots\dots(1)$$

判別関数に含まれる係数 a_i (判別係数) の最適化については統計解析の手法などが利用可能である。もちろん、式(1)のような判別関数だけではカバーできない情報があるので、分析の前提となる各種の条件が課せられることになる。これらは明確な形で定義づけはされていないが、最近の人工知能研究の用語によれば、一種のプロダクションルール (production rules) を記述したことになっている。もちろん、プロダクションルールとは言っても簡単なルールであり推論をすすめる道具として用意されているというよりは条件チェックのために利用され、その段数も 1～2 段という簡単なものである。

例えば倒産 3 年前からの財務データを収集しはじめ、配当性向や株価などと組み合わせた分析を行うことや、財務データに施される各種の粉飾を取り除く処理をどのように行うかなどは、式(1)のモデルだけでは記述できないので、組み合わせ論的な解析が必要となる。しかし、このような解析方法を比較することは簡単ではなく、また、問題はシステムの基本となっている判別関数(1)の構成方法に大きく依存していることに注目する必要がある。このようなことを考慮し、本論文では、式(1)に示される判別関数に相当するものをニューラルネットワークで構成した場合の能力を単純に比較することから、ニューラルネットワークによる効果分析を行うことにする。ニューラルネットワークを財務分析に応用する分野として有力なものは、各種の審査・判別業務であり、与えられ

た問題を変換すれば同様な問題へと集約されるであろう。

結論的にいえば、ニューラルネットワークは式(1)に示される判別関数を非線形関数（正確には区分線形関数）として構成する能力をもっているということであり、この関係を図2に示している。図2において、図2(a)は式(1)の線形判別関数を模式的に表したものである。図2(b)は少ない階層のニューラルネットワークにより線形関数により領域が分割されたことを意味し、図2(c)はニューラルネットワークの階層を増加した場合（構造は繰り返してであるがシステム構成要素の数が增加する）における領域分割を表し、非線形関数により、より適当な形で領域分割が行われている。図2(d)は、判別関数の形で示される判断だけではなく、企業の置かれている条件などの新たな情報が加わった場合にニューラルネットワークにより複数の連結していない領域へと分割できることを意味している。

図2に示すように、ニューラルネットワークにより実現できる判別関数はネットの階層を増加させるに従い、線形関数、区分線形関数、複数の領域へと分割する非線形関数への変化していき、経験的にいって、3～4層の階層構成により図2(d)の形態の構成が可能であることがわかっている。図2(d)に示された判別の領域は、従来の判別分析である式(1)を複数個組み合わせたのものであるともいえるが、ニューラルネットワークでは、更に図2(e)のような複雑な判別条件を付け加えることが可能となっている。

実際に従来の判別関数および簡単なルールの結合により企業財務の判別分析を行う場合には、判別関数(1)に含まれる係数 a_i と同時にルールに含まれるパラメータについても同時に最適化する必要がある。これは、一種の同時最適化の問題であり、数理的にもとり扱いにくい問題である。実際には、経営コンサ




図2 線形判別関数とニューラルネットワークの判別能力概要

ルタントなどが個別に値を調整しており、同時最適化とはなっていない。これに対してニューラルネットワークにより財務分析を行う場合には、数値的に表現された式であれば、それが判別関数であっても条件式であっても、同時にネットワークに含めることができる。

3.2 階層型ニューラルネットワークとバックプロパゲーション

人間の神経細胞の機能をコンピュータシミュレーションにより模擬して、さまざまな知識を実現しようとする試みは従来より続けられており、総称してコネクショニスト (connectionist) 法として分類されている。その中でパーセプトロン (perceptron) によるパターン認識実験に対してはかなりの理論的、実験的貢献がなされたが、ネットワークのパラメータを調整するための学習理論が確立されていなかったために実際的な応用にはいたらなかった。このパラメータ学習の問題を解決したものが階層型ニューラルネットワーク (階層構造をしたパーセプトロンの形式をとるので階層型パーセプトロンと呼ぶ場合もある) である。ニューラルネットワークの学習理論については、最終的なパラメータ値への収束が数学的に証明されており、極めて見通しのよいものとなっている〔7〕。この基礎理論に基づき、ニューラルネットワークに含まれる個々の神経細胞 (ここでは単にユニット: unit と呼ぶことにする) を記述するパラメータを最適化する方法も確立されており、望ましい出力に向けてシステムを調整する性質から、バックプロパゲーション (backpropagation: 逆伝播法) と呼ばれている。以下ではバックプロパゲーションによるパラメータ学習について簡単に整理する。

いま、図3に示すようにユニットの集合からなる層を N 層作り、 $n-1$ 番目の層に含まれる第 j 番目ユニットと、 n 番目の層に含まれる第 i 番目のユニットの間に、ある重みをもった回線により結合されているとする。この結合は第 $n-1$ 層から第 n 層へと一方向であり、上に述べた場合の結合する回線の重みを $w_{i,j}^{n,n-1}$ とする。第1層はニューラルネットワークへの送られる入力信号を受け付ける入力端子であり、最後の第 N 層はニューラルネットにより解析された出力信号を取り出す出力端子である。




図3 階層型ニューラルネットワークの動作原理

ニューラルネットワークを構成するユニットとしては、人間の神経細胞を模倣したモデルが考えられている。いま、第 $n-1$ 層の第 j 番目のユニットの出力信号を x_j^{n-1} とし、これが第 n 層の第 i 番目のユニットへの入力となっているので、入力信号は以下のように記述される。

$$u_i^n = \sum w_{i,j}^{n,n-1} x_j^{n-1} \dots\dots\dots(2)$$

この入力信号の和はそのままユニット i の出力信号となるのではなく、一定のしきい値 h_i を持った関数により制御されて出力とされる。

$$x_i^n = f(u_i^n - h_i^n) \dots\dots\dots(3)$$

ここで、関数 $f(\cdot)$ はユニットの動作を規定する特性であり、通常は数値計算上などを考慮して次のシグモイド関数が用いられる。

$$f(x) = 1 / \{1 + \exp(a - x)\} \dots\dots\dots(4)$$

ここで a はシグモイド関数に含まれるパラメータで適当に（ゼロでもよい）設定しておく。

ニューラルネットワークにおける学習とは、ネットワークへ特定の入力（第1層のユニットへの入力 x_i^1 ）を加えたときに、対応して望ましい出力信号（第 N 層の出力信号 x_i^N ）が得られるように、ネットワークのパラメータ $w_{i,j}^n$ ・

$n-1$ および h_i^n を調整していくことである。これを最適化問題として定式化した場合の収束理論については確立されており、層内のユニット数を連続にとり積分形として表現した場合の収束について理論的に証明されている。入力信号 x_i^L 、そのときに得られるべき出力信号 x_i^N との組はネットワークに対する教師信号と呼ばれる。教師信号の組を多数用意し、これらを繰り返しネットワークに与えることにより、学習により最適なパラメータ値が計算される。パラメータ学習については、教師信号と実際にニューラルネットワークの応答との差異が最少となる方向へパラメータを変化させていけばよい。数値的最適化に理論としてよく用いられる最小 2 乗法を適用すると、次に示されるバックプロパゲーションによる最適化の式が得られる。

出力層 N のユニット i から戻される学習信号は、出力層からの出力値 x_i^N と教師信号 d_i^N との差を使って次のようになる。

$$\delta_i^N = (d_i^N - x_i^N) f'(u_i^N) \dots\dots\dots(5)$$

第 n 層のユニット i から第 $n-1$ 層のユニットへ向かって戻される学習信号は

$$\delta_i^n = f'(u_i^n) \sum \delta_k^{n+1} w_{k,i}^{n+1,n} \dots\dots\dots(6)$$

以上の量を用いて、重みとしきい値との修正は次のようになる。

$$\begin{aligned} \Delta w_{i,j}^{n,n-1}(t) &= \eta \delta_i^n x_j^{n-1} + \alpha \Delta w_{i,j}^{n,n-1}(t-1) \\ w_{i,j}^{n,n-1}(t+1) &= w_{i,j}^{n,n-1}(t) + \Delta w_{i,j}^{n,n-1}(t) \dots\dots\dots(7) \\ \Delta h_i^n(t) &= \eta \delta_i^n + \alpha \Delta h_i(t-1) \\ h_{i,j}^n(t+1) &= h_{i,j}^n(t) + \Delta h_i^n(t) \dots\dots\dots(8) \end{aligned}$$

3.3 倒産企業の財務データ作成

一般に財務情報の診断分析では、分析の基礎となるデータによりあらかじめ分析システムを構成しておき、これに未知の分析対象は入力されたときに良好な判断が可能ないように分析システムのパラメータを調整することが行われる。ニューラルネットワークにおいてもこの間の事情は同じであり、教師信号を与えることにより学習を行い、未知データの分析へ対応する手順をとっている。

通常の判別分析とニューラルネットワークのシステムとが異なっている点は計算手順であり、判別分析では観測データから求まる連立方程式を解くことに

より一度で係数が決定されるのに対して、ニューラルネットワークシステムでは繰り返し最適化によりパラメータの値が調整される。従って、計算に要する時間が長くかかることと、教師信号を繰り返し与えてやる手順が必要になる点が問題として残されている。前者の計算時間については、分析システムをオンラインで構成するのではなく、いわゆるオフライン的に構成すれば十分であるので計算システムを工夫（例えば並列計算の特性を生かして並列コンピュータで処理をする）すれば部分的に解決できるが、後者については、単純に教師信号を繰り返し与えていたのでは、パラメータ最適化の過程で発散がおきたり、ループに入りこむことがある。

解析に用いたデータについて以下に示す。目的は企業財務データを観測することにより数年後の企業倒産を予測できるかどうかということであり、従来からも研究されてきた課題である。従来の解析手順とニューラルネットワークによる手順はそれほど大きく異なっているわけではないので、以下にまとめて示す。

(1) 倒産企業の調査

日本の企業財務データが記録されている範囲は1964年から現在までであり、この間、倒産した企業のデータは当然のことながら途中から記載されていない。倒産企業のリストを調査することも可能であるが、ある年から記載されていない企業を抽出することによりこれを識別する。その結果、1956年以降、148社の企業が倒産していることがわかった。

(2) ペアサンプルの抽出

倒産した企業に対して、同じ条件に置かれながら倒産しなかった企業を抽出し、これらに対比データとして確定する必要がある。判別分析では、倒産と非倒産、優良と不良などのグループ化が目的であり、片方のグループと同じ程度のサンプル数を他のグループについても確保する必要がある。ペアサンプルの抽出は倒産分析の精度に大きく影響することは当然であるが、ここでの目的は統計的手法による判別分析とニューラルネットワークの判別との能力を比較することにあるので、解析対象それ自体はあまり高精度のものでなくても良いであろうと考えた。従って、やや大雑把ではあるが、以下の規準でペアサンプル

を選択した。

まず、倒産した企業と同じ業種に属する企業であることが必要であり、その次に倒産発生時点で倒産企業と同じ程度の資本金を有していた企業をペアサンプルとして設定する。これが基本的な検索条件になる。もちろん、これだけではペアサンプルが設定できない場合があるので、いくつかの修正を行う。

(3) サンプル企業の財務データの作成

解析の対象となる企業の財務データを、倒産の1～3年前から検索し、これをA-80上のデータセットとして作成した。A-80上に作成するファイル形式は任意でかまわないので、ここではレコード長200バイトのファイルとしている。倒産分析には約4～5個の財務指標（財務データから得られる比率など）が用いられるので、ファイルに記録されたデータから、更にこれを計算する必要がある。この作業およびニューラルネットワークの計算過程の記述をA-80において行うことも可能であるが、エディタが十分ではないこと、判別分析を行うための統計パッケージが現時点では利用可能でないことなどを考慮し、このファイルを汎用コンピュータ FACOM M-780 上のファイルへと転送した。

(4) サンプル企業の財務指標の作成とニューラルネットワークプログラム

倒産分析の方法として、表1に示す2通りの指標を用いた。最初はアルトマ

表1. 倒産分析に利用された財務指標とその定義

(a) アルトマンの指標分析	
X_1 : 流動性尺度 = 運転資本 / 総資産 X_2 : 再投資利益尺度 = 留保利益 / 総資産 X_3 : 収益性尺度 = (利息 + 控除前利益) / 総資産 X_4 : レバレッジ尺度 = 持ち分時価 / 総負債 X_5 : 売上高生成能力 = 売上高 / 総資産	
(b) キャッシュフロー指標分析	
X_1 : 企業収益経常利益率 = 経常利益 / (売上高 + 営業外収益) X_2 : 自己資本比率 = (自己資本 + 引当金) / (負債 + 資本合計 + 手形割引) X_3 : 企業収益金融費用率 = (支払利息割引料 + 社債発行差益) / (売上高 + 営業外収益) X_4 : 流動比率 = (流動資産 + 受取手形割引高) / (流動負債 + 受取手形割引高)	

ンにより示された伝統的な分析方法に用いる指標であり、業種を問わず適用できる。アルトマンは論文で80%以上の判別効率を上げたと示している。しかし、この方法を直接日本の財務データに適用することには大きな問題があることが指摘された〔8〕。そこで、2番目の指標グループとして古川等により日本企業向けの開発された倒産分析の指標を用いることにする。簡単のために、以上の2つの方法を、それぞれアルトマンの指標分析、キャッシュフロー指標分析とよんでおく。

3.4 企業の転換社債の格付分析データの作成

本論文では、企業の倒産予測をニューラルネットワークにより行うと同時に、企業が発行する転換社債に対する格付アルゴリズムをどの程度ニューラルネットワークのよりシミュレーションできるかについても検討している。企業債券には債券価格とクーポンレートとが設定されるが、一般に企業の業績が順調であるときには高い債券価格と低いクーポンレートとなる。特に、転換社債を企業が発行する場合には債券の質についての評価が行われ、これを一般に格付 (rating) とよんでいる。格付は一般にこれを専門的に行う機関により実施され、米国では Moody 社、Standard & Poor 社が良くしられ、日本では日本債券格付研究所などが知られており、これら機関は定期的に企業の転換社債についての格付情報を公表している〔9〕～〔11〕。これらの情報は表現の方法には若干の差異はあるが、基本的には債券のランク付けであり、例えば最も優良な債券には AAA を、最悪と評価された債券には CCC を付与する。

このような格付にあたっての規準や処理手順については一般には公表されないもので、企業の財務データをどのように利用して判断がなされているかについては不明である。そのため定期的に発行される格付データを利用して社債購入の適否を決定する手順が取られる。しかし、投資関係者が格付のアルゴリズムを独自にもつことができれば、時間に関係なくいつでも自分で格付データを作成することができるし、時系列的な変化についても把握することができる。この目的にニューラルネットワークを応用することができる。その原理について図4に示している。

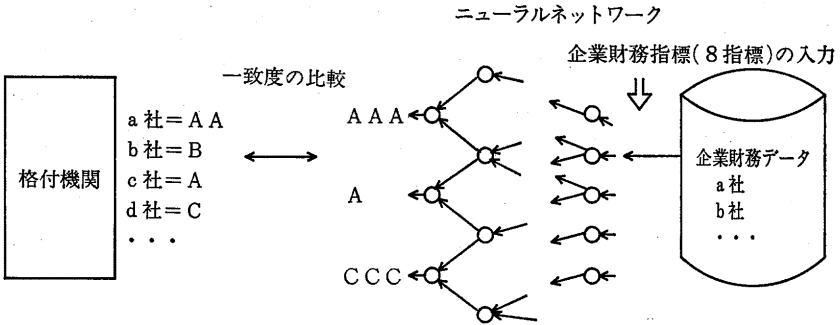


図4 債券格付予測分析のためのニューラルネットワークシステム

手順として、まず、格付機関による債券評価と、この債券を発行している企業の財務データ（有価証券報告書）のデータがコンピュータ上に作成されるとする。格付機関の債券評価については結論だけが公表されているので、これを学習信号としてニューラルネットワークのより債券格付のシステムを構成する。すなわち、格付機関はなんらかの判別関数を内部的に作成し、これに企業の財務データを当てはめて債券評価を行っているという仮定をたてるわけである。この判別関数は、倒産分析の場合と同様に線形関数である必要はなく、非線形性や条件付きの関数であってもかまわない。企業の財務データをニューラルネットワークに対する入力データとした場合に、出力信号として格付評価（教師信号）にできるだけ近い信号が出力されるようにニューラルネットワー

表2. 債券格付のための8財務指標

名 称	定 義
営 業 利 益 率	営業利益/売上高
経 常 利 益 率	経常利益/売上高
使用総資本事業利益率	営業利益+受取利息配当金/使用総資本
固 定 長 期 適 合 率	固定資産/自己資本+固定負債
自 己 資 本 比 率	自己資本/総資本
流 動 比 率	流動資産/流動負債
当 座 比 率	当座資産/流動負債
使用総資本回転率	売上高/使用総資本

注) 使用総資本=流動資産+固定資産+繰延資産+割引譲渡手形

クにおける学習を行う。

ニューラルネットワークへの入力となる企業の財務データとしてはさまざまな種類のものが可能であるが、ここでは企業の業績評価と同じような判断を行わせているといえるので、良く利用されている表2のような財務指標を利用している。ニューラルネットワークの出力としては、AAA から CCC までのすべてのレベルにそれぞれ1つの出力レベル（教師信号のレベル）を対応させることも可能であるが、ここでは最初の実験での確認を目的としているので、全体を2ないし3レベルへと集約した場合の解析を行っている。これらのレベルへの縮約については図4に示している。

4. 学習の過程と解析結果

4.1 学習の速度の特性

ここでは、まずニューラルネットワークの学習の特性について典型的なデータをもとにして議論しておく。倒産分析の場合、ニューラルネットワークの学習には倒産・非倒産の74ペアサンプルを用い、これらを繰り返し教師信号として与えた。学習は終了した時点で残り74ペアサンプルに対する判別実験を行った。判別分析については4.2で述べることとし、ここでは学習過程について述べる。

ネットワークのパラメータ値が最適値に近づくにつれて、教師信号とニューラルネットワークの出力信号との差が小さくなるので、これを最適化の尺度として用いることにする。図5には一組の教師データ（74個の倒産・非倒産企業のペアサンプル）をパラメータ計算の1回の繰り返しと考え、これを横軸にとった場合の教師信号とニューラルネットワークの出力信号との2乗誤差（74ペアサンプルの合計）として示している。

これより分かるように、階層構造の中間層を1層および2層にした場合では、学習の速度そのものはあまり変わらないことがわかる。これは大変都合のよい特性である。収束のスピードについても150回程度の繰り返し計算ですんでおり、例として報告されているデータと同様である。




図5 階層型ニューラルネットワークの学習過程

4.2 倒産分析の判別効率

以下では学習の終了したニューラルネットワークに対して、分析すべき企業の財務データを表1に従って入力した場合の結果について整理している。なお、ニューラルネットワークの能力を比較するために、同じデータを統計解析パッケージ ANALYST により判別分析した結果（線形判別関数による分析としている）も示している。まず、実験の方法についてまとめて示しておく。倒産分析そのものでは、企業の財務データに対する粉飾の問題や、いわゆる例外値（アウトライヤー）の問題があり単純ではないが、ここでは同じデータに対する2つの方法の性能比較であり、データに起因する問題は分析結果にはさほど反映されていないことが期待できる。

ニューラルネットワークの性能を比較する対象となる線形判別関数について

は、文献〔5〕〔8〕などに線形係数を示したものが公表されているし、日本の事例分析についての結果も示されている。しかし、ここでの分析では用いる財務指標は同じであるが、解析する企業サンプルは異なっているため、あらためて判別分析をやり直す方が適当である。判別分析のプログラムを作成することも可能であるが、ここでは簡単化と標準化の目的のために、コンピュータ処理の統計パッケージをそのまま利用することにした。統計パッケージとしては富士通㈱の ANALYST である。

統計パッケージにより線形判別関数と同時に、この判別関数を用いることにより、もとのデータがどの程度正しく判別できるか。つまり、本来倒産している企業の財務データを判別関数の入力として入れることにより、倒産と正しく判別される場合には正解であるが、非倒産と判別されれば正確な判別ではない。この場合の正しく判別される割合を判別効率とよぶ。ここで、用いているデータは判別関数を計算するために用いたデータであり、倒産するかどうか未知である企業のデータではないので、正確には実際的な判別の正しさを表現していないが、性能測定には便利である。

一方、ニューラルネットワークによる判別についても同様に正しく判別できるかどうかを定義することができる。いま、倒産した企業の財務データをニューラルネットワークの入力として加えた場合に、確かに倒産であるとの予測が出力として得られれば、正しい判別であるとする。逆の場合には誤判別である。判別効率も同様に定義できる。このように主として判別効率によりニューラルネットワークの性能を通常の線形計算と比較することができる。

(1) 判別効率

判別効率についての結果を表3に整理している。これを見てわかるように、アルトマンによる指標分析とキャッシュフロー指標分析とでは、一般的にキャッシュフロー指標分析が良好な特性を実現している。これは、もともとが日本企業の財務データに適合するように開発されていることを反映している。2つの解析システムの比較としては、全体的にニューラルネットワークによる解析の方が線形関数による判別よりも良好である。しかし、その差異は十分に大きいものではなく、改善の余地が残されている。判別関数の構成には定数をどの

表 3. 階層型ニューラルネットワークによる倒産分析の結果

(a) アルトマンによる指標分析				(b) キュッシュフロー指標分析			
(1) 線型判別関数 解析結果				(1) 線型判別関数 解析結果			
		倒産	非倒産			倒産	非倒産
属 性	倒産	64%	36%	属 性	倒産	60%	40%
	非倒産	26%	74%		非倒産	22%	78%
(2) ニューラルネットワーク(中間層1層) 解析結果				(2) ニューラルネットワーク(中間層1層) 解析結果			
		倒産	非倒産			倒産	非倒産
属 性	倒産	70%	30%	属 性	倒産	70%	30%
	非倒産	28%	72%		非倒産	26%	74%
(3) ニューラルネットワーク(中間層2層) 解析結果				(3) ニューラルネットワーク(中間層2層) 解析結果			
		倒産	非倒産			倒産	非倒産
属 性	倒産	78%	22%	属 性	倒産	81%	19%
	非倒産	42%	58%		非倒産	42%	58%

注) 属性とは企業が倒産か非倒産か的事实を表わし、解析結果とは指標を入力した場合の判定出力を表わす。表中の数字はこの判定出力の割合を%で示す。

ように設定するかの任意性が含まれているので、これを調整することにより、倒産、非倒産ともに同じ程度の判別効率となるようにすることが可能である。これに対してニューラルネットワークの場合には、判別特性そのものが学習により一意的に決定されてしまうので、定数による調整などはできない。

このようなことを考慮すると、ニューラルネットワークの特徴がいくつかあがり上がってくる。その1つは、倒産企業に対する解析精度の向上である。ニューラルネットワークの中間層が2層の場合には特にこれが顕著であり、倒産企業だけに分析を限定すると、78%の判別効率が得られている。従って、ニューラルネットワークによる非線形判別関数の構成に注目すれば、更に判別効率を向上させることができる。

(2) 階層の増加の影響

階層のうち中間層を増加させることにより判別効率が向上することが期待で

きるが、ここでの計算結果では逆の結果が得られている。また、倒産企業の検出の方には判別効率を上昇しているが、非倒産企業の判別は劣化している。これは、ニューラルネットワークの構成する非線形判別関数が倒産企業の側へと集中して詳細化されたことを意味している。

また、数値計算上の問題としては、中間層が1層の場合には収束に至る過程で2乗誤差は極めて小さくなったが、中間層が2層の場合にはシグイモイド関数において計算のケタあふれが生じる。これはもちろん、倍精度計算により部分的に克服できるが、同様の計算条件を前提とした場合には、中間層が2層の場合には数値的安定性が小さくなっている。

4.3 格付分析の判別効率

企業の発行する転換社債に対する格付をシミュレーションするニューラルネットワークの実験について結果をまとめた。最初の実験では格付のランクを2段階にしており、出力端子は1個で、この値が1かゼロか（実際にはアナログ値であり0.5を境とする）により2つのランクを区分している。2番目の実験ではランクを3段階に分け、出力端子は3個とし、それぞれの端子が1（実際にはアナログ値であり0.5以上）の場合にその端子に割当られたランクであるとの判断を行っている。格付のランクの取り方よりあきらかなように、2段階への区分のほうが3段階への区分よりも良好な判別効率を示すことが予測される。

判別効率については以下のようにまとめられる。結論的には、ニューラルネットワークによる分析と、その教師信号である格付機関によるランクとの一致度は70%程度であり、あまり良好とは言えないが、かなり簡単な手順により独自に格付システムを構成できることはメリットがある。この結果の一部について表4にまとめている。米国の論文の例では[12]、この効率が80%を越えているが、日本企業の財務データを用いた場合のことを考えると、表4の結果はほぼ妥当な結果であるといえる。この表ではニューラルネットワークの中間層を2層に増やした場合の結果は省略しているが、倒産分析の場合と同様に、結果の改善には至っていない。これは、米国における解析結果[12]とも一致して

いる。

なお、ニューラルネットワークによる倒産分析の場合と同様に、パラメータ学習における収束の問題や、中間層を増加した場合の計算上の問題点について述べる必要があるが、ほぼ同様の傾向にあることだけを明記して割愛する。

表 4. 転換社債格付の予測分析のためのカテゴリ化と実験結果

(1) 2段階へカテゴリ化した場合				(2) 3段階へカテゴリ化した場合				
		出力値 = 1		AAA		出力端子 1 = 1		
		出力値 = 0		AA, A, , , , , , CCC		AA, A, BBB		出力端子 2 = 1
				BB, B, CCC		出力端子 3 = 1		
解析結果				解析結果				
		AAA		それ以外				
属 性	AAA	75%	25%	クラス1	クラス2	クラス3		
	それ以外	23%	78%	クラス1	72%	15%	13%	
				クラス2	12%	68%	20%	
				クラス3	9%	24%	67%	

5. む す び

ニューラルネットワークによる経営情報の解析として、企業財務情報分析についてのべた。階層型ニューラルネットワークによる経営診断、特に判別関数で記述される倒産・非倒産、優良・不良分析については新しい分野ではないが、実際に適用する場合の問題点や、ニューラルネットワークの能力について検証することができた。階層型ニューラルネットワークの場合には、階層やユニット数を増大させることにより判別効率が上昇することが一般的に予測されるが、実際には学習プロセスでの計算上の問題や学習の偏りなどから、必ずしも向上するとは言えない。これは他の論文などでも言及されていることである。これらの問題点はありながら、階層型ニューラルネットワークは手軽に判別分析を行うシステムを構成できる有効な手段であると言える。

今後の課題としては、ニューラルネットワークによるパターンの情報処理機構を、ルールベースや知識ベースといった構文レベルの知識システムと結合

することがあげられる。例えば、企業の財務分析の場合には、経営者の特性や生産している商品など、質的なデータを解析する必要がある、どうしてもニューラルネットワークだけでは診断システムを構成することはできない。この解決策として、低レベルの認識にはニューラルネットワークを、更に上のレベルの認識にはプロダクションルールを用いる複合型エキスパートシステムが有効であろう。

参考文献

- [1] W. H. Beaver: "Financial Reporting: An Accounting Revolution," Prentice-Hall (1981) (邦訳: 伊藤邦雄訳「財務報告革命」, 白桃書房 (1986)).
- [2] R. A. Marose: "A financial neural-network applications," AI Expert, pp. 50-53 (May 1990).
- [3] 時永, 李: "ニューラルネットワークによる経営情報解析—倒産分析と時系列解析," 第3回日本経営学会研究発表大会, pp. 3-4 (1991).
- [4] S. Tokinaga: "Learning models in the neural networks in comparison to the learning classifier system with the genetic algorithm—applications in financial management," Proc. of the Second Symposium on Nonlinear Theory and its Applications (NOLTA), pp. 73-76 (1991).
- [5] B. Lev: "Financial Statement Analysis: A new Approach," Prentice-Hall (1974) (邦訳: 柴川, 寺田訳「現代財務諸表分析」, 東洋経済新報社 (1978)).
- [6] E. I. Altman: "Corporate Bankruptcy in America," Health Lexington Books (1971).
- [7] R. P. Lippmann: "An introduction to computing with neural nets," IEEE ASSP Magazine, pp. 4-22 (April 1987).
- [8] 古川浩一: 「財務分析の研究」, 同文館 (1988).
- [9] "Moody's Industrial Manual". Moody's Investors Services.
- [10] Standard and Poors: Standard and Poors' Industrial.
- [11] 「東証転換社債相場」, NIKKEI NEWSLETTER ON BOND & MONEY.
- [12] S. Dutta and S. Shekhar: "Bond rating: A non-conservative application of neural networks," discussion paper, Computer Science Division, University of California, Berkeley (1989).