



Title	バーゼル II導入における新格付手法としてのニューラル・ネットワーク法
Author(s)	勝田, 英紀; 田中, 克明
Citation	大阪大学経済学. 2008, 57(4), p. 32-45
Version Type	VoR
URL	<a href="https://doi.org/10.18910/18185">https://doi.org/10.18910/18185</a>
rights	
Note	

*The University of Osaka Institutional Knowledge Archive : OUKA*

<https://ir.library.osaka-u.ac.jp/>

The University of Osaka

## バーゼルⅡ導入における新格付手法としての ニューラル・ネットワーク法

勝田英紀・田中克明

### 要 約

バーゼルⅡが導入され、各金融機関は貸出先の格付を明確に行う必要が生じている。都市銀行においては既に内部格付手法を確立しているが、地方銀行や信用金庫等の中小金融機関では、独自で内部格付手法を確立することについては、対比できる安定した格付が存在しないため非常にむずかしいものとなっている。そこで外部の格付機関が公表する格付と同等の精度の格付を定義できれば、中小金融機関内の費用発生を最小限に抑えることが可能となると考える。そこで定量的データをもとにニューラル・ネットワーク法が有用な方法であるかどうかを分析する。対象とする格付機関は、格付投資情報センター（R&I）および日本格付研究所（JCR）、ムーディーズ・ジャパン（Moody's）およびスタンダードアンドプアーズ（S&P）の4格付機関の付与する格付の決定構造を類推し、これら4格付機関の公表している格付をニューラル・ネットワーク法により再現できるかどうかを検証する。

キーワード：バーゼルⅡ、格付機関、ニューラル・ネットワーク法、新格付手法

### 1. はじめに

2004年6月にはBIS（Bank for International Settlements：国際決済銀行）のバーゼル銀行監督委員会は、「自己資本の計測と基準に関する国際的統一化」にかかるバーゼル合意の全面的改訂に関して合意したと発表した（バーゼルⅡ合意）。ここでバーゼルⅡ合意<sup>1</sup>とは、間下（2004）によれば、BISのバーゼル委員会によって決定される、国際業務を展開する各国銀行の競争条件の衡平化および国際銀行システムの健全性、安定性の強化を目的として、国際的に銀行業務を展開する金融機関に対して、適用される自己資本比率規制とされており、その基本的な考え方は、金融機関が自ら有するリスクに見合った額だけの自己資本を確保することであると

されている。バーゼル合意に基づくバーゼルⅠは、1988年6月に公表され、経過措置期間を経て欧米では1992年12月期より、日本では、1993年3月期より実施されている。バーゼルⅠは、国際業務を行う金融機関に対して、金融機関が保有する個々の貸出・運用資産にその信用リスクに応じたリスク・ウェイトを掛けリスク・アセット額を算出し、自己資本を算出されたりスク・アセットで除することによって算出されるものである。国際業務を行う金融機関は、自己資本比率を8%以上に保つことが義務づけられたが、国際業務を行わない金融機関も、同比率を4%以上に保つことが義務づけられている。

バーゼルⅡの合意内容は、バーゼルⅠの施行後、多数の新規金融商品が市場に出回り、また金融機関の信用リスクの管理手法が高度化し、金融業界を取り巻く環境が大きく変化したため、健全性の基準として現状にあわなくなってきたことにある。そこでバーゼルⅠを見直

<sup>1</sup> 欧米ではバーゼル合意（Basel Capital Accord）と称されているが、日本ではBIS規制ないしBIS自己資本比率規制（基準）と称されている。

した。バーゼルⅡにおいて新たに合意された内容は、①リスクベースの最低自己資本比率、②同比率に関する監督上の検証、③情報開示を通じた市場規律の強化を骨子とするものであり、自己資本比率の算定に際し、新たにオペレーショナル・リスクもカバーすることとなったほか、信用リスクの分析において、銀行のリスク管理能力や業務内容に応じて、標準的手法に加えて手法のオプションとして内部格付手法（基礎的内部格付手法および先進的内部格付手法）が準備された。このバーゼルⅡの導入により、外部の格付機関の格付の評価および金融機関内での格付手法の確立が重要となる。バーゼルⅡは決算期の関係により欧米においては2006年末に導入され、我が国においては2007年3月期より導入された。この結果、社債を発行できる大企業のみでなく、今後資金調達を行おうとする企業全体に対しても格付の影響が増すことが考えられる。

外部格付機関である Moody's (Moody's Investors Service) や S&P (Standard & Poor's) などに関しては、種々の問題が持ち上がっている。2007年7月に発生したサブプライム問題の格付変更時期の問題や、その前の2001年12月に米国のエネルギー関連企業のエンロン社が破綻した際に、債券市場におけるエンロン社債券の取引価格はジャンク債のレベルまで急速に下落していくにとかかわらず、SECの公認格付機関<sup>2</sup>である Moody's (Moody's Investors Service) や S&P (Standard & Poor's) は、エンロン社が破産を申請する直前まで格付を投機的等級に下げなかった。同様に2002年7月に通信関連企業のワールドコムが破産申請を行う直前まで格付を下げなかったことで、信用リスク判

断に格付の変更がついて行けなかつたと市場からみなされた結果、格付機関に対する信頼は揺らぎ始めており、格付機関を見る目が厳しくなってきている。

格付は格付機関毎の情報商品であり、財務情報や経営指標等の定量データのみでなく、格付を取得しようとする企業より直接入手する定性データを加味し、格付機関毎の意見であるとそれぞれの格付機関から公式に表明されている。Kaplan & Urwitz (1979) がまとめた先行研究によれば、財務指標を定量データとした場合における格付の決定構造における説明力は60~80%程度であり、格付機関毎に異なる定性データに基づく判断の影響を明らかにすることはできない。我が国においても新美 (1995) によれば、定量データのみを分析した結果ではその説明力は約70%程度であり、残りの30%については、格付機関がどのように定性データを判断しているかは明らかにされていない。

「格付の決定構造」についての先行研究では、格付を従属変数として、発行企業の財務データあるいは財務指標を独立変数とする統計モデルを使って解析しているものが一般的であった。West (1970) あるいは、この領域における先行研究をまとめ OLS (最小二乗法) を用いて説明力を上げようとした前述の Kaplan and Urwitz (1979) がこの研究領域における先駆的な論文である。Kaplan and Urwitz のモデルは、Palepu, et. al. (1996) が検証したところ、1993年のデータを用いても、なお適合性を有していたと報告されている。

格付の決定構造の分析に財務データを用いた先行研究としては、前述の他に Altman (1968), West (1973) などがある。また Ederington (1985), Smith and Lawrence (1995), Nickell, Perraudeau and Varotto (2000) のように、順序プロビットあるいはロジット・モデルを適用して、格付け取得確率を推定するものから、倒産確率と格付け取得確率を同時に

<sup>2</sup> 現在米国 SEC による公認格付機関は、Moody's, S&P, Fitch Ratings, Dominion Bond Rating Service Limited (2003年) および A. M. Best (2005年) の5社である。日本の金融庁の公認格付機関は、格付投資情報センター (R&I), 日本格付研究所 (JCR), Moody's, S&P, Fitch Ratings の5社である。

推定するより複雑なモデルまで多数報告されている。また企業や銀行の信用リスク分析を試みたものとして Cyert and Thompson (1968), Carty and Fons (1993) などがあり、また銀行の抱える実際のデータを用いた分析として Del Angel et al. (1998), Barkman (1981), Betanourt (1999) などがある。さらにパネルデータを用いて分析したものに Blume, Lim and Mackinlay (1998) がある。

我が国における格付の決定構造の研究では、安川・椿 (1998) が、パネルデータを用いて、日本公社債研究所 (JBRI: 格付投資情報センター (R&I) の前身) の格付を分析し、格付の期間効果が少ないと、各企業の財務内容の悪化に追いついておらず、総じて格付のランクが高いことを見いだした。仁科 (2000) においては、S&P の格付を有する日米両国企業それぞれについて財務指標数値と格付との関係を回帰し、S&P は日米で同じ尺度で格付の付与を行っていないこと、日本企業はディスクロージャーの透明性の低さより格付の一貫性の低さ、ならびに高格付企業はやや過大評価され、低格付企業はやや過小評価されており、日本企業の格付は歪んでいることを見いだした。さらに安川 (2005) は、Moody's のデータを用いてパネルにより、格付の決定要因が同一の企業中においても期間によって変化していることを確認している。その他の研究として、新見 (1998) は、段階的判別分析により日系格付機関と米国系格付機関の決定要因の相違を分析している。さらに中山、森平 (1998) は、Ordered Probit Model により、JBRI と Moody's の格付の決定要因における相違を分析している。しかしながら定量データのみでは説明力が低く、定性データによると思われる部分については、未だに説明できていない。

各格付機関は、この定性データを加味して格付のランクを決めており、格付は個々の格付機関の意見であり、そのため各格付機関の

付与する格付のランクが異なるとの見解を出している。しかしながら格付は企業の信用リスクを図る尺度として銀行などの機関投資家を始めとする投資家に広く利用されており、また社債を発行する場合には必ず格付を取得しなければならないと義務づけられている。このように格付が公的に扱われているため、投資家が入手しきれない定性的情報が格付判断の重要な要素となっていることが問題である。さらに勝田 (2004) で示したように同一企業に対する格付に統計的有意差が生じていることは、格付を利用する投資家あるいは資金調達を行う企業に混乱を生じさせやすい。そこで定量的データのみを用いる分析により格付の決定構造が明確になれば、投資家にとってより一層判断がしやすいと考える。

我が国においては、大手の都市銀行においては既に内部格付手法を確立しているが、地方銀行や信用金庫等の中小金融機関では、独自で内部格付手法を確立することについては、対比できる安定した格付が存在しないため非常にむずかしいものとなっている。そこで外部の格付機関が公表する格付と同等の精度の格付を定義できれば、金融機関内での費用発生を最小限に抑えることが可能となると考える。そこでわれわれは内部格付手法に関して、外部の格付機関に頼らずに各金融機関が格付手法を確立するための新たな手法としてニューラル・ネットワーク法を提案する。

ニューラル・ネットワークを用いて格付を分析した先行研究としては、Dutta and Shekhar (1988) が S&P の格付を用いて分析を行ったが、格付企業数がわずか47社分であり、回帰分析との比較を行ったが、統計的に有意な差はなく、格付の決定構造の決定にニューラル・ネットワークが利用できるのではないかという、道を開いたのみである。次に Surkan and Singleton (1990) が、Moody's の格付を用いて分析をおこなった。彼らは、Moody's の格付の Aaa から

A3までの上から7ランクの格付を用いて、多重判別分析 (MDA; Multiple Discriminant Analysis)との比較を行い、ニューラル・ネットワークは多重判別分析より勝っていると結論づけた。さらに Maher and Sen (1997) は、Moody's の格付を用いて、分析をおこなった。彼らは、ニューラル・ネットワークがロジスティクス回帰よりもよりいっそうフィットすることを見いだしている。

先行研究と同様に、定量データである財務データを利用した分析により格付のランクが判明すれば、投資家にとって不明確な部分が無くなり、信頼度が高まると考える。一方社債を発行するあるいは銀行から借り入れを行い資金調達する企業にとって、格付の高低が社債のクーポン・レートあるいは借入金利の高低に影響を及ぼすため、少しでも高い格付の取得が必要となる。企業がどの格付機関に格付の付与を依頼するのが有利であるかを判断する場合に、格付機関毎の格付付与の特性を分析することに定量的データを利用して判断できれば、格付機関の選択が容易に行える。そこで定量的データをもとにニューラル・ネットワーク法を用いて分析する。ここで対象とする格付機関については、Fitch Ratings は日本では格付の件数が少ないため除外し、格付投資情報センター (R&I) および日本格付研究所 (JCR)、ムーディーズ・ジャパン (Moody's) およびスタンダード・アンド・プアーズ (S&P) の4格付機関の付与する格付の決定構造を類推し、これら4格付機関の公表している格付をニューラル・ネットワーク法により再現できるかどうかを検証する。

## 2. ニューラル・ネットワークによる分析

### 2.1. ニューラル・ネットワーク概説

ニューラル・ネットワークは、神経細胞の動作を模擬するものとして提案されたものである。細胞膜の内外には電位差があり、他の

ニューロンからの入力信号を受け取るとニューロンが興奮して内部の電位差が高まり、内部電位差が、ある「しきい値」以上になったときだけ他のニューロンに対して出力信号を出す。これをモデル化したものが、出力信号を出す、出さないを0と1の値をとる図1の「しきい値型ニューロンモデル」である。

いま  $n$  個のニューロンからの入力信号を受け取るとする。その強さを  $x_1, x_2, \dots, x_n$  とする。 $j$  番目の入力信号からの信号を受けて変化する電位の量をシナプス荷重と呼び  $w_i$  と表現しよう。 $n$  個の入力信号の荷重和が、あるしきい値  $\theta$  以上になれば興奮性シナプス結合、それ未満を抑制性シナプス結合と呼ばれている。入力信号の荷重和は次の式(1)で表現される。

$$u = \sum_{j=1}^n w_j x_j \quad (1)$$

興奮性シナプス結合のときにニューロンは出力  $y$  を出す。

$$y = f(u - \theta) = f\left(\sum_{j=1}^n w_j x_j - \theta\right) \quad (2)$$

$$= \begin{cases} 1 & u - \theta \geq 0 \text{ のとき} \\ 0 & u - \theta < 0 \text{ のとき} \end{cases}$$

このとき  $f(\cdot)$  をニューロンの出力関数 (output function) または活性化関数 (activation function) と呼ぶ。

1950年代の終わりから1960年にかけて、Rosenblatt はこのニューロンを層状に結合した

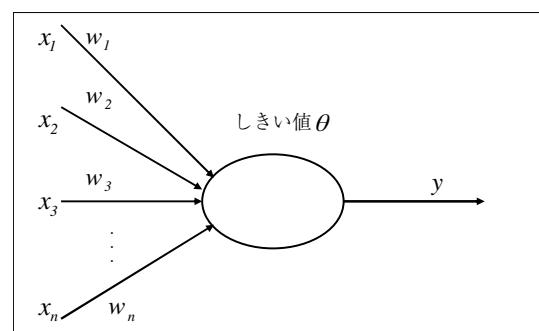


図1 しきい値型ニューロンモデル

パーセプトロンを開発した。パーセプトロンの考え方はその後の階層的パーセプトロンに大きな影響を与えた。彼らが提案したパーセプトロンモデル (Perceptron Model) は、S (Sensory) 層、A (Association) 層、R (Response) 層とよばれる3層からなる階層型ネットワークである。

図2に示されているように、R層には1個のユニットしかなく、各層のユニット間には結合のないフィードフォワードの3層の階層型ネットワークは、単純パーセプトロン (Simple Perceptron) とよばれている。単純パーセプトロンの1番目の層であるS層は、外部からの入力信号を神経信号に変換する入力層で、 $S_1, \dots, S_m$  の  $m$  個のユニットから構成されているその層の役割は単に外部からの情報を次のA層に伝達するのみである。2番目の層であるA層は、 $A_1, \dots, A_n$  の  $n$  個のユニットから構成される中間層である。このA層でのユニット  $A_j$  は、それぞれしきい値が  $\theta_j (j = 1, \dots, n)$  のしきい素子である。ここでS層のすべてのユニット  $S_i (i = 1, \dots, m)$  はA層のユニット  $A_j (j = 1, \dots, n)$  とランダムに結合しているが、 $S_i$  から  $A_j$  への結合荷重  $C_{ji} (i = 1, \dots, m, j = 1, \dots, n)$  はすべて固定されており変化しない。さらに、A層の各ユニット  $A_j$  のしきい値

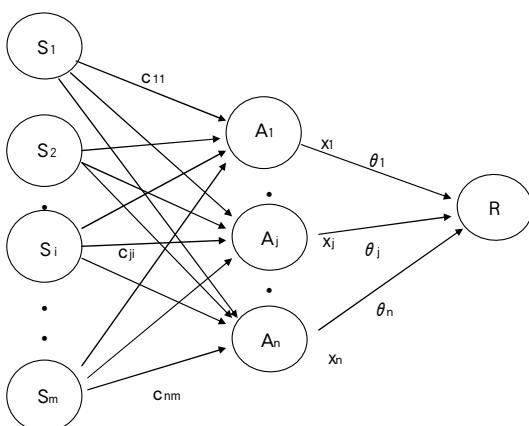


図2 単純パーセプトロン

$\theta_j (j = 1, \dots, n)$  も固定されている。3番目の層であるR層は、単純パーセプトロンではただ1個のユニットRからなる出力層であり、しきい値  $\theta$  のしきい素子である。このユニットRは、A層のすべてのユニット  $A_j (j = 1, \dots, n)$  と結合されているが、これらの結合荷重  $w_1, \dots, w_n$  とRのしきい値  $\theta$  は可変 (可塑性シナプス) である。各ユニット  $A_j (j = 1, \dots, n)$  の出力を  $x_1, \dots, x_n$  と書き表すと、A層のユニット  $A_j$  への入力はつぎのように書くことができる。

$$\sum_{i=1}^m c_{ji} s_i, j = 1, \dots, n \quad (3)$$

ここで、A層のユニット  $A_j$  はすべて、0か1のいずれかを出力とするしきい値素子であるので、出力  $x_j (j = 1, \dots, n)$  は次式で与えられる。

$$x_j = \begin{cases} 1, & \sum_{i=1}^m c_{ji} s_i - \theta_j \geq 0 \quad \text{のとき} \\ 0, & \sum_{i=1}^m c_{ji} s_i - \theta_j < 0 \quad \text{のとき} \end{cases} \quad (4)$$

同様に、R層のユニットRも、しきい値素子であるので、Rへの入力は次のように書くことができる。

$$\sum_{i=1}^m w_i x_i, j = 1, \dots, n \quad (5)$$

また、Rからの出力  $o$  は次式で与えられる。

$$o = \begin{cases} 1, & \sum_{i=1}^m w_i x_i - \theta \geq 0 \quad \text{のとき} \\ 0, & \sum_{i=1}^m w_i x_i - \theta < 0 \quad \text{のとき} \end{cases} \quad (6)$$

パーセプトロンではこのように正しい解を得るために重みとしきい値の学習をおこなうというものであった。しかしこの2値のパーセプトロンでは、表1の排他的論理和 (XOR) のような非常に単純な問題でさえも解くことができないことが判明して以来ニューラルネットワークブームが去った。

表1 排他的論理和

入力ベクトル	出力
0, 0	0
1, 0	1
0, 1	1
1, 1	0

## 2.2. 階層的パーセプトロンと誤差逆伝播法

Rumelhart, Hinton and Williams (1986) によって提案されたもので最も有名なものが階層的パーセプトロン (MLP) である。これは入力層と出力層の間に任意の中間層を設けたフィードフォワード型ネットワークで、教師あり学習 (supervised learning) の一つである。中間層を隠れ層という場合もある。

入力層のユニットは与えられた入力をそのまま出力するが、中間層と出力層の各ユニットはパーセプトロンで想定された0-1の階段型のしきい型ではなく準線形素子と呼ばれる非線形の出力関数が使われている。非線形で階段型に近い関数としていくつか考えられるがニューラルネットワークでは往々にして図3のようなロジスティック関数がよく採用されている。

$$f(x) = \frac{1}{1 + e^{-\beta x}} \quad (7)$$

ここで  $\beta$  は無限大の時には階段関数にな

る。通常  $\beta = 1$  と設定されることが多い。

また双曲線関数とくに双曲正接 (tanh) も使われることが多い。

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$

ある入力パターンが与えられたとき、それに対する出力パターンが目標出力 (target output) と一致するように、各ユニット間の結合加重を出力の方から順次修正していくという学習法で、誤差逆伝播法 (Error Back Propagation) といわれている。ニューラル・ネットワークの場合には「パターン」という語が使われるが、統計の分野ではオブザベーションという語が一般的である。

この誤差逆伝播法の考え方を要約すると次のようになる。

- (1) 学習を行うための入力パターンと対応する目標出力の組の集合を設定する。またこのとき各層間の結合荷重に適当な初期値を設定しておく。
- (2) 入力層、中間層、出力層の順に、各ユニットの入出力を計算する。すべてのユニットは1つ前の層からのみ入力を受け取り次の層へのみ出力を送り出す。このようなネットワークはフィードフォワード型ネットワークとよばれる。

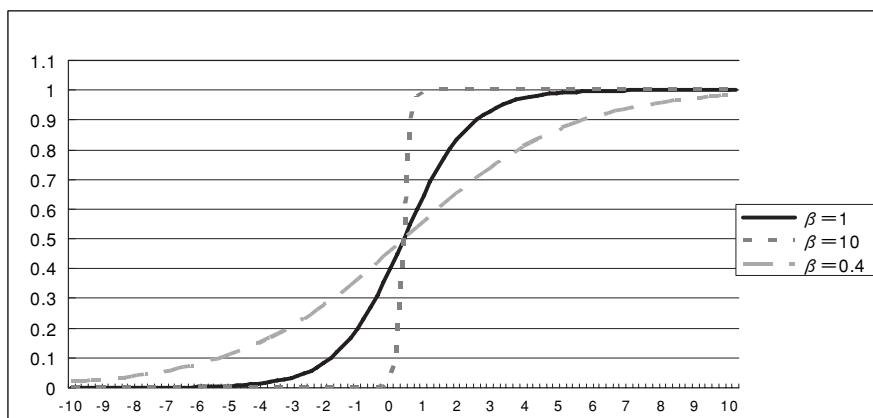


図3 ロジスティック関数

(3) 入力パターンに対する目標出力である教師信号と、上記の手続きで算出された出力との2乗誤差を計算する。この誤差を表現するのにギリシャ文字の $\delta$ 使ったことによりデルタ則と呼ばれることが多い。これはまたWidrow-Hoff学習則とも呼ばれている。

(4) この2乗誤差を最小化するように、出力層から入力層に向かって、ネットワークの各層間の結合荷重を修正する。この操作が誤差逆伝播法と呼ばれている理由である。結合荷重を修正するにあたり、誤差関数の勾配を使った最急降下法がよく使用されているが、学習の高速化を目指した準ニュートン法などの方法も開発されている。

この結合荷重を修正するときに、単調増加で微分可能な出力関数としてすでに触れたロジスティック関数を使うことで取り扱いが簡単になることに触れておくことにする。

(5) すべての入力パターンに対する2乗誤差が設定値以下になれば終了する。そうでなければ、(2)から(4)までの処理を繰り返す。

### 2.3. 本研究で使用したソフトウェアについて

ニューラル・ネットワークを計算する市販のソフトウェアは現在数多く存在する。われわれがソフトウェアを検討するとき考慮した点は次の4点である。

(1) 入力変数について、オリジナルのデータは当然のこととして、通常想定されるいくつかの変数変換、たとえば対数変換、逆数さらには2乗などを施した結果を入力変数として計算し、その中から最適な変数を採用してくれること。

(2) 各中間層のノードの数を増減させて最適なノードの数を決定してくれること。

(3) パーソナル・コンピュータを使用したときでも計算時間が想定の範囲内であること。

(4) 結果として算出される結合荷重が明示されることである。

数多くのソフトウェアを検討した結果、本論文ではNeuralWare社のPredictを採用した。このソフトは当初想定した上記4点を満たしていることが確認された。また表計算ソフトであるEXCELのアドインとして機能するのでデータハンドリングという観点から判断しても操作性が良いことも採用した理由の一つである。

### 2.4. 結合荷重の妥当性の検証

ニューラル・ネットワークを用いて算出された結合荷重は、算出に使用したデータセット（推定用データセット）にもっとも適合するよう求められたものである。結合荷重が推定用データセットにどの程度適合しているかを測定する尺度として、推定用データセットの入力変数に算出された結合荷重を適用して計算された、出力変数の理論値というべき値と、推定用データセットの出力変数の値との相関係数が考えられる。

結合加重を推定用データセットとは独立した他のデータセット（検証用データセット）に適用した場合に必ずしも良好な結果をもたらすことは保証できない。そのため推定用データセットで相関係数を算出したのと同様の手順で、検証用データセットの入力変数に推定用データセットで算出された結合荷重を使って、出力変数の理論値を算出し、検証用データセットの出力変数の値との相関係数を計算する。推定用データセットを使ったときの相関係数と検証用データセットを使ったときの相関係数を比較することによって、結合荷重の妥当性を検証できる。

### 3. データについて

日本で活動している格付機関は、日系のR&I, JCRおよび三国事務所の3機関と米系のMoody's, S&PおよびFitch Ratingsの3機関の合計6機関であるが、三国事務所<sup>3</sup>は、格付を

公開しておらず、また金融庁の指定も受けていないため、除外した。さらに金融庁公認の格付機関であるが、Fitch Ratings は日本での格付件数が少ないため除外し、R&I, JCR, Moody's および S&P の 4 格付機関を対象として、格付決定構造を比較検討する<sup>4</sup>。また、Jewell and Livingston (1999) 等の先行研究に倣い、各格付機関の格付を表 2 のごとく AAA 格(2)から D 格(1)までの 22 段階としている。ここで投資の基準として、投資適格は Moody's の場合 Baa 3 格(13)以上であり、R&I, JCR 及び S&P は BBB・格(13)以上である。12 未満は投機的等級とされている。

東京証券取引所に上場している企業のうち、4 格付機関が格付を付与している企業数は表 3 のとおりである。これらの企業のうち東京証券取引所に上場されている継続企業 (Going Concern) を対象として、日米の格付機関 Moody's, S&P, JCR, R&I の 4 格付機関が共通に格付を付与している企業を対象としている。共通企業の財務データを説明変数として使用する。4 格付機関の共通企業は 2005 年 4 月時点において、89 社であった。しかしながら、銀行、生・損保、証券会社等の金融機関の財務データは、製造業やサービス業等の一般企業とは根本的に異なるため、銀行等の金融機関 14 社を除く<sup>5</sup> 75 社を取り上げる。分析対象企業の財

務データは、2005 年 4 月時点の格付の判定基準となる 2004 年度の財務データとして「日経財務データ 連結決算 2004 年度」を使用した。

2005 年の 4 格付機関の共通企業の格付分布は図 4 のとおりであるが、S&P 以外の 3 格付機関の場合、投資適格の Baa 3 格あるいは BBB 格(13)以上がほとんどである。東京証券取引所に上場されている企業を対象としているので、日本の一流企業を対象とすれば、投資適格の企業が中心となるのが想定されるが、S&P の場合は、これらの企業においても 75 社中 20 社を投資適格以下の投機的等級に分類している。

表 2 格付記号 読替表

Score	R & I	JCR	Moody's	S & P
22	AAA	AAA	Aaa	AAA
21	AA+	AA+	Aa 1	AA+
20	AA	AA	Aa 2	AA
19	AA-	AA-	Aa 3	AA-
18	A+	A+	A 1	A+
17	A	A	A 2	A
16	A-	A-	A 3	A-
15	BBB+	BBB+	Baa 1	BBB+
14	BBB	BBB	Baa 2	BBB
13	BBB-	BBB-	Baa 3	BBB-
12	BB+	BB+	Ba 1	BB+
11	BB	BB	Ba 2	BB
10	BB-	BB-	Ba 3	BB-
9	B+	B+	B 1	B+
8	B	B	B 2	B
7	B-	B-	B 3	B-
6	CCC+	CCC+	Caa 1	CCC+
5	CCC	CCC	Caa 2	CCC
4	CCC-	CCC-	Caa 3	CCC-
3	CC	CC	Ca	CC
2	C	C	C	C
1	D	D	D	D

<sup>3</sup> 三国事務所は、事務所の会員でなければ格付データにアクセスできない。しかしながら、海外の投資家よりは高い評価を受けている。

<sup>4</sup> 発行体格付と長期債務格付の格付基準について、R&I は長期債務格付を公表しておらず、発行体格付しか公表していない。JCR は反対に発行体格付を公表しておらず、長期債務格付のみを公表している。S&P は発行体格付のみの公表となっている。Moody's は発行体格付と長期債務格付両方を公表しているが、両方の格付を付与している企業の格付で差が生じている企業は存在しなかった。そこで、この発行体格付と長期債務格付を同格のものと見なして分析を行った。

<sup>5</sup> 金融機関の財務諸表の形式および内容は他の一般事業会社と異なるため、定量データとして同一に取り扱うことが不可能であるため、分析対象企業から銀行、証券会社等の金融機関を除外している。

表3の平均格付からは、分布は、JCR, R&I, Moody's, S&Pの順に格付符号が下がるため、分布の形状に相似性を感じさせるが、実際の共通企業の格付の分布の形状からは、JCRとR&Iの分布の形状が近く、AAAに11社あるJCRの格付は、分布形状からもAA+から始まるR&Iの格付よりも約1 notch 高く推移している。4格付機関の共通企業の分布を見ているにもかか

わらず、日米の格付の間には、分布に相似性はみられない。

#### 4. 分析方法について

定量データについて、R&IやMoody's等の4格付機関は定量データとしてほぼ同じ財務指標を用いているので、今回、Moody'sの『グ

表3 4格付期間の格付総数と平均格付

各社 公表資料より作成

		1996年	1997年	1998年	1999年	2000年	2001年	2002年	2003年	2004年	2005年
Moody's	格付件数	219社	228社	236社	243社	247社	256社	270社	266社	251社	236社
	平均格付	15.12	15.08	14.99	14.35	14.34	14.40	14.34	14.21	14.46	15.37
S & P	格付件数	60社	98社	140社	174社	251社	269社	265社	266社	297社	296社
	平均格付	18.05	16.51	15.36	14.72	14.00	13.81	13.58	13.56	14.62	14.98
R & I	格付件数	422社	437社	735社	712社	718社	664社	630社	588社	550社	533社
	平均格付	16.67	16.80	16.14	15.55	15.37	15.57	15.57	15.73	15.92	16.10
JCR	格付件数	401社	444社	466社	490社	492社	496社	510社	501社	504社	509社
	平均格付	15.49	15.51	15.54	15.44	15.76	15.73	15.71	15.85	16.02	16.13

注：1 データはすべて各年4月末日の格付けによる

2 格付期間のデータはすべて格付機関毎の公表データに基づいている

3 平均格付については、ウィルコクソンの符号付順位和検定により前年の平均格付と比較している。

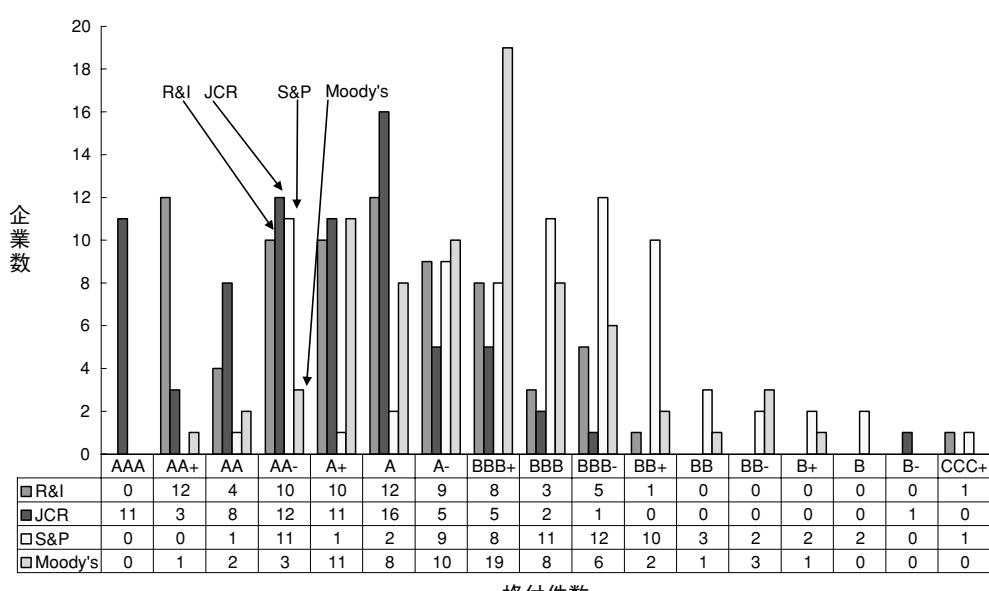


図4 4格付機関の共通企業の格付分布

ローバル格付』およびR&Iの格付で重視する主な財務指標収益性を重視する財務指標に倣い、収益性を重視する①キャッシュフローの増減、②フリーキャッシュフロー、③EBITDA、④ROA、⑤営業資産営業利益率(ROBA)、⑥インタレスト・カバレッジ(倍)、⑦純有利子負債構成比、⑧有利子負債キャッシュフロー・EBITEA(倍)、⑨財務レバレッジ(倍)、⑩有利子負債額、⑪純有利子負債額に加えて将来収益をもたらすであろうと考えられる試験研究費、さらに規模の大きさ並びに安定性の指標として売上高および総資産額を加えて検討した。これらの財務指標の算出方法については以下の表の通り。

上記のすべての指標を変数としてそのまま使用すると、相関高い変数が分析に悪影響を及ぼす可能性がある。そのため相関行列を計算し

て、相関係数が0.9以上の場合、どちらかの変数を代表として残し、もう一つの変数を削除した結果、以下の11変数に絞り込むことができた。使用する変数は、①キャッシュフローの増減、②フリーキャッシュフロー、③EBITDA、④ROA、⑤営業資産営業利益率(ROBA)、⑥インタレスト・カバレッジ(倍)、⑦純有利子負債構成比、⑧有利子負債キャッシュフロー・EBITEA(倍)⑨総資産額、⑩売上高、⑪研究開発費である。

ここで使用したNeuralWare社のPredictでは、入力変数に対して事前に想定したいくつかの変数を機械的に適用し、出力変数に適合する変数を探索する。変換の種類としては、log変換、logのlog変換、指数変換、指数の指数変換、平方根変換、2乗、逆数、平方根の逆数、2乗の逆数などが使用されている。

表4 適用財務指標の算出方法

財務指標	算出方法
① キャッシュフローの増減	キャッシュフロー期末残高一期首残高
② フリーキャッシュフロー	営業キャッシュフロー+投資キャッシュフロー
③ EBITDA	事業利益(営業利益+受取利息・配当金・有価証券利息)+減価償却費
④ ROA	事業利益÷使用総資本
⑤ 営業資産営業利益率(ROBA)	営業利益÷(受取手形・売掛金+棚卸資産合計-支払手形・買掛金+償却対象固定資産+敷金・差入保証金)
⑥ インタレスト・カバレッジ(倍)	(営業利益+受取利息・配当金・有価証券利息)÷支払利息・割引料
⑦ 純有利子負債構成比	(純有利子負債額-現預金)÷(自己資本+有利子負債-現預金)
⑧ 有利子負債キャッシュフロー・EBITEA(倍)	有利子負債額÷EBITDA
⑨ 総資産額	総資産額
⑩ 売上高	売上高
⑪ 研究開発費	研究開発費
⑫ 財務レバレッジ(倍)	(負債・少数株主持分・資本合計)2期合計÷資本合計2期合計
⑬ 有利子負債額	短期借入金+コマーシャルペーパー+1年以内返済の長期借入金+1年以内償還の社債・転換社債+従業員預かり金+社債・転換社債+長期借入金+受取手形割引高
⑭ 純有利子負債額	有利子負債額-(現金・預金+有価証券+営業貸付金・営業投資有価証券)

分析手順は、以下の通りである。

- (1) 推定用のデータのなか、あるいは検定用のデータのなかに特定の業界のデータが偏って分類されないように、一旦データをランダムに並べ替えた。
- (2) 格付の決定構造の推定用に全データの60件を振り分け、残りの15件を検証用に振り分けた。
- (3) ランダムに並び替えた結果先頭から60件を格付の決定構造の推定用に使用し、残りの15件を推定用で得られた結果をもとに決定構造の検証用に使用した。
- (4) さらに格付機関ごとに①から③の作業を5回反復し、その平均値を取った。

すでに結合荷重の妥当性の検証の項で示したように、推定用データセットの入力変数に算出された結合荷重を適用して計算した出力変数の理論値というべき値と、推定用データセットの出力変数の値との相関係数を計算し、ニューラル・ネットワークを使用したときの決定構造の精度を計算した。また推定用のデータで得られた構造を仮定して、検証用のデータに結合荷重を適用し、検証用の理論値を計算する。この結果と検証用データの出力値との相関係数を計算することにより、ニューラル・ネットワークの予測精度を計算することができる。

推定用のデータを使用した4格付機関の格付の決定構造の予測精度と検証用データへの適用可能性を示す予測精度をそれぞれの相関係数で示したものが図表9である。表中より、第1に4つの格付機関の格付を11個の財務変数のみを使用しただけで、予測精度はもっとも悪いMoody'sの場合ですら、0.95941の値を実現している。分析者の主観を入れずに、財務データの変換のみでこれだけの精度を挙げることができたことは、ニューラル・ネットワークのもつ能力であるといえるのではないかと思われる。

表5 相関係数による格付の決定構造の予測精度と適用精度

	推定用データによる格付の決定構造の予測精度	検証用データによる格付の決定構造の適用精度
R & I	0.97149	0.74234
JCR	0.97076	0.64103
Moody's	0.95941	0.68250
S & P	0.97224	0.80034

ただ検証用のデータを使った場合に0.64103から0.80034まで幅広く適用精度に大きい差が見られる。R&IおよびS&Pの適用精度はそれぞれ0.74234ならびに0.80034であり、実用に耐えると考えるが、JCRとMoody'sの適用精度は、0.64103ならびに0.65250と低い数値を示している。今後より詳細な検討を行い、JCRとMoody'sの適用精度の原因を検討する必要がある。決定構造の予測精度と検証用データによる適用精度に関しては、特にこのデータから傾向のようなものは、見いだし得なかった。

## 5.まとめと今後の課題

今回我々は新たな手法としてニューラル・ネットワークを用いて格付の決定構造を分析した。財務データを利用した分析により格付のランクが判明すれば、外部の格付機関に格付け与を依存せずに済むため、金融機関にとって経費の削減と審査時間の短縮を図ることが可能となる。一方社債を発行するあるいは借入れを行うとする企業にとって、格付の高低が社債のクーポン・レートあるいは借入金利の高低に影響を及ぼすため、少しでも高い格付の取得が必要となり、どの格付機関に格付の付与を依頼するかを定量的データにより判断できれば、格付機関の選択が容易に行うことができるようになる。

そこでニューラル・ネットワークを用いてR

&I, JCR, Moody's, S&P の 4 格付機関を比較検討した結果、ニューラル・ネットワークによる格付の決定構造の予測精度は、0.95以上の非常に高い精度を誇り、定量データを利用して格付の決定構造を見いだすことが可能となる。またこの決定構造の推定結果を利用した適用精度は、R&I および S&P の場合、それぞれ 0.74234 ならびに 0.80034 であり、実用に耐えると考えるが、JCR と Moody's の適用精度は、0.64103 ならびに 0.65250 と低い数値を示している。今後より詳細な検討を行い、JCR と Moody's の適用精度の低さの原因を検討する必要がある。決定構造の予測精度と検証用データによる適用精度に関しては、特にこのデータから傾向のよくなものは、見いだし得なかった。

今回の検証においては、4 格付機関比較を考えたため、共通して格付の付与を行っている企業を取り上げたため全数で 89 社しかなく、財務内容が異なる金融機関の 14 社を除くと全数で 75 社しかないため、今後はデータ数を増加させるため、格付機関毎の格付における格付の決定構造を検証することおよび格付機関毎に使用されている変数の細分分析、あるいは時系列に安定しているかどうかの検討が今後必要ではないかと考え、今後の課題としたい。

(近畿大学経営学部准教授)  
(摂南大学経営情報学部教授)

## 参考文献

- Altman, E. (1968) "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy," *Journal of Finance*, 23, pp.189–209.
- Barkman, A. I. (1981) "Testing The Markov Chain Approach on Accounts Receivable," *Management Accounting*, 62 (7), pp.48–50.
- Betancourt, L. (1999) "Using Markov Chain to Estimate Losses from a Portfolio of Mortgage," *Review of Quantitative Finance and Accounting*, 12, pp.303–318.
- BIS Homepage <http://www.bis.org/>
- Blume, M. E., F. Lim and A. C. McKinley (1998) "The Declining Credit Quality of U. S. Corporate Debt: Myth or Reality?" *Journal of Finance*, 53, pp.1389–1413.
- Carty, L. V. and J. S. Fons (1994) "Measuring Changes in Credit Quality," *Journal of Fixed Income June*, pp.27–41.
- Cyert, R. M. and G. L. Thompson (1968) "Selecting a Portfolio of Credit Risks by Markov Chains," *Journal of Business*, 41 (1), pp.39–46.
- Del A., F. Gabriela, J. M. Diez–Canedo and E. P. Gorbe (1998) "A Discrete Markov chain Model for Valuing Loan Portfolios: The case of Mexican Loan Sales," *Journal of Banking and Finance*, 22, pp.1457–1480.
- Dutta, S. and S. Shekhar (1988) "Bond rating: a non – conservative application of neural networks," *Proceedings of the IEEE International Conference Neural Networks*, pp.II 443–450.
- Ederington, L. (1985) "Classification Models and Bonds Ratings," *The Financial Review*, 20, pp.237–262.
- Jewell, J. and M. Livingston (1999) "A Comparison of Bond Ratings from Moody's S&P and Fitch," *Financial Markets, Institutions & Instruments*, 8, pp.1–45, 1999.
- Kaplan, R. S. and G. Urwitz (1979) "Statistical Models of Bond Ratings: Methodological Inquiry," *Journal of Business*, 52, pp.231–261.
- Maher, J. J. and T. K. Sen (1997) "Predicting Bond Ratings Using Neural Networks: A Comparison With Logistic Regression," *International Journal of Intelligent Systems in Accounting, Finance and Management*, 6, pp. 59–72.

- Nickell, P., W. Perraudin, and S. Varotto (2000) "Stability of Rating Transitions," *Journal of Banking and Finance*, 24, pp.203–227.
- Palepu, K. G., V. L. Burnard and P. M. Healy (1996) *Introduction to Business Analysis & Valuation*, Cincinnati: International Thomson Publishing.
- Rumelhart, D. E., G. E. Hinton and R. J. Williams, 1986, "Learning internal representations by error propagation," In D. E. Rumelhart and J. L. McClelland, editors, *Parallel Distributed Processing*, 1, MIT Press, Cambridge, MA
- Smith L. D. and E. C. Lawrence (1995) "Forecasting Losses on a Liquidating Long-Term Loan Portfolio," *Journal of Banking and Finance*, 19 (6), pp.959–985.
- Surkan, A. and Singleton, J (1990) "Neural network for bond rating improved by multiple hidden layers," *Proceedings of the IEEE International Conference Neural Networks*, pp. II 157–162.
- West, R. R. (1970) "an alternate Approach to Predicting Corporate Bond Ratings", *Journal of Accounting Research*, 7, pp.188–22.
- West, R. R. (1973) "Bond Rating, bond yields and financial regulation: some findings," *Journal of Law and Economics*, 16, pp.159–168.
- Zhang, G. P. (2004) *Neural Networks in Business Forecasting*, IRM Press
- 今井兼範 (1990) 『ニューラル・ネットワークリューション』共立出版.
- 格付投資情報センター (2001) 『格付け Q&A – 決まり方から使い方まで』日本経済新聞社
- 格付投資情報センターホームページ  
<http://www.r-i.co.jp/jpn/>
- 勝田英紀「市場からみた格付の評価」『経営財務研究』日本経営財務学会, 第23巻第1号, 2–18頁 (2004).
- 坂和正敏, 田中雅博 (1999) 『ニューロコンピューティング入門』, 森北出版.
- スタンダード&プアーズホームページ  
<http://www.standardandpoors.co.jp/>
- 中山めぐみ, 森平爽一郎 (1998) 「格付け選択確率の推定と信用リスク量」『JAFEE 1998夏季大会予稿集』, 210–225頁.
- 新美隆宏 (1995) 「機関投資家から見た格付利用方法とその展望」『証券アナリストジャーナル』, 95年6月号, 28–42頁.
- 仁科一彦 財務戦略研究会 (2000) 「格付と企業評価」『インベストメント』第53巻第4号 No. 320, 2–22頁.
- 日本格付研究所ホームページ  
<http://www.jcr.co.jp/homepageJ.htm>
- バーゼル情報ホームページ  
<http://www.tabilinks.com/basel/>
- 間下聰 (2004) 「新BIS規制の概要と中小企業金融への影響 – 内部格付手法の方が、中小企業向け貸出に有利となる見込み」『信金中金月報』第3巻第2号, 31–46頁.
- ムーディーズ・インベスタートーズ・サービス (1994) 『グローバル格付分析』金融財政事情研究会 ムーディーズホームページ  
<http://www.moodys.co.jp/ssl/>
- 武藤佳恭, 斎藤孝之 (2001) 『応用事例ハンドブック ニューラルコンピューティング』共立出版.
- 安川武彦, 椿広計 (1999) 「社債格付の決定要因に関する分析」『第67回日本統計学会講演報告集』, 238–239頁.
- 安川武彦 (2005) 「格付けの決定要因の時点による変化に関する分析」『経営財務研究』第24巻2号, 116–132頁.

## Neural Network Method as a New Corporate Rating Method for Basel II

Hideki Katsuda and Katsuaki Tanaka

### Abstract

As Basel II has been introduced, banks have to clearly classify their loan companies. Japanese city banks have already established their own internal rating methods but the small financial institutes such as local banks and shinkin banks and so on are hard put to establish their own internal rating methods because of a lack of comparable stable rating information. So, we think that small financial institutes become possible to minimize their rating cost if the definition of their own internal rating method is established with the same accuracy of the external existing rating agencies. So, we analyze the availability of the neural network method with using quantitative data. Firstly we speculate a decision structure of Rating and Investment Information, Inc. (R&I), Japan Credit Rating Agency, Ltd. (JCR), Moody's, Japan (Moody's) and Standard and Poor's (S&P), and validate the reproduction ability of neural network method against the ratings given by four rating agencies.

JEL Classification: G21, G28, G32

Key words: Basel II, Rating agencies, Neural Network method, New Corporate Rating method