

電子金融工学の可能性

—金融データマイニングによる自動格付けを例に—

白川 浩

西川 武一郎

東京工業大学 理財工学研究センター

(株) 東芝 研究開発センター

shirakawa@craft.titech.ac.jp

takeichiro.nishikawa@toshiba.co.jp

1 はじめに

一般に、データマイニングとは、大量のデータを試行錯誤的に分析し、その中から意思決定に有益なある種の関係を抽出する知識発見行為を意味する。近年、金融機関においては、データウェアハウスを中心とした情報系システムが充実に伴い、リテール業務等における金融データマイニングの重要性が著しく増大している。

そこで本研究では、もっとも基本的なリテール業務である融資時の与信判断を効率的に行うための、対象企業の財務データ等による自動格付けについて考察する。具体的には、過去の融資実績データに基づいて、対象企業の融資時点の経営状態を表す財務データから格付けを行うルールを構成し、当該格付けの状態遷移確率の推定に基づいて、倒産リスクを客観的にかつ効率的に評価することを考える。一般に与信判断の現場では、人手による融資先の評価は依然として重要である。しかし自動格付けにより明らかに融資すべき企業と融資すべきでない企業を効率的に判別し、個別の人的与信判断という高価な意思決定をグレーゾーンの企業の格付け判定に集中して採用すれば、多くの融資案件の中から、収益性に見合う融資を効率的に選択することが可能となる。このような見地から、本稿では時系列モデルに基づく、融資時の倒産リスク評価モデルについて考察する。

2 格付モデルによるリスク分析

ここでは基本的に、企業の資金面からみた経営状態はある種の1次元指標に集約でき、この指標の時間的な変化が定常的なマルコフ過程、すなわち現在の状態が与えられれば、それ以降の状態変化は時点 t ならびにそれ以前の過去の状態とは独立に決定すると考える。また格付け状態集合は、順序づけられた離散的な数値の集合 $K = \{1, \dots, K\}$ により与えられ、数値が増すほど経営状態が悪い格付けを表し、状態 K は倒産状態を表すものとする。どのように格付け状態を判別するのは次節以降で議論する。本節では、格付け状態の1単位期間ごとの状態遷移、ならびに倒産する確率

をもとにしたリスク分析について考察する. 以降では, C_t により, ある企業の時点 t での格付け状態を表し, 格付け状態 i から j へ推移する状態遷移確率を p_{ij} とする. すなわち

$$p_{ij} = Pr\{C_{t+1} = j | C_t = i\}$$

また格付間の 1 単位時間あたりの状態遷移確率行列を, $\mathbf{P} = [p_{ij}]_{i,j \in \mathcal{K}}$ とする. 状態 K は倒産状態 (吸収状態) をあらわすので,

$$p_{Kj} = \begin{cases} 0, & j \in \{1, \dots, K-1\}, \\ 1, & j = K \end{cases}$$

このとき状態遷移確率のマルコフ性より, n 単位時間後の状態遷移確率 $\mathbf{P}^{(n)}$ は,

$$p_{ij}^{(n)} = \sum_{\ell_1 \in \mathcal{K}} \cdots \sum_{\ell_{n-1} \in \mathcal{K}} p_{i\ell_1} \cdots p_{\ell_{n-1}j}$$

により与えられる. また格付間の n 単位時間の状態遷移確率行列 $\mathbf{P}^{(n)} = [p_{ij}^{(n)}]_{i,j \in \mathcal{K}}$ は, \mathbf{P}^n となる. 定義により, 格付け状態 K は吸収状態なので, このマルコフ過程は明らかにエルゴード性を満たさない. そこで K を除いた格付け状態空間を $\mathcal{K}^- = \mathcal{K} \setminus \{K\}$ とし, その上に制限されたマルコフ過程を考える. このマルコフ過程の条件付きの状態遷移確率行列 $\mathbf{P}^- = [p_{ij}^-]_{i,j \in \mathcal{K}^-}$ は,

$$p_{ij}^- = \frac{p_{ij}}{\sum_{\ell \in \mathcal{K}^-} p_{i\ell}}$$

で与えられる. 以降では, この制約されたマルコフ過程が, 次の仮定を満足するものとする.

仮定 2.1 \mathbf{P}^- は, エルゴード性を満足する.

次に, 倒産リスクのある企業の融資の合理的な評価法について述べる. いま, 1 単位時間あたりの倒産リスクのない貸付に対する金利を r , 格付状態 i に対する融資期間 n に対する金利を $\phi_i^{(n)}$ とし, この貸付金利は, 倒産時点までは支払われると仮定する. このとき τ の確率分布は, $P\{\tau \leq t | C_0 = i\} = p_{iK}^{(t)}$ で与えられる. また倒産した場合の倒産時点 τ での貸付元本及び貸付金利に対する回収率を ξ ($\in [0, 1]$) とする. 一般に ξ は確率変数となるが, ここでは単純化のため, すべての倒産に対しある一定のパラメータ値をとるものとする. このとき, 時点 0 で格付状態 $C_0 = i$ から出発したもとの n 期間の融資 1 円に対する現在価値 $L_i^{(n)}$ は, 以下の確率変数により与えられる.

$$L_i^{(n)} = \sum_{1 \leq t \leq n} \frac{\phi_i^{(n)} 1\{\tau > t\}}{(1+r)^t} + \frac{\xi(1 + \phi_i^{(n)})}{(1+r)^\tau} 1\{\tau \leq n\} + \frac{1}{(1+r)^n} 1\{\tau > n\}.$$

以降では, 融資債権評価に用いる同値なリスク中立確率のもとの状態遷移確率行列 $\tilde{\mathbf{P}} = [\tilde{p}_{ij}]_{i,j \in \mathcal{K}}$ を, 一律に非倒産確率を減少させることにより構成する. すなわちリスク回避度 $\lambda \in [0, \infty)$ に対し,

$$\tilde{p}_{ij} = \begin{cases} \exp\{-\lambda\} p_{ij} + 1\{p_{iK} = 0\} (1 - \exp\{-\lambda\}) p_{ij}, & j \in \{1, \dots, K-1\}, \\ \exp\{-\lambda\} p_{iK} + 1\{p_{iK} > 0\} (1 - \exp\{-\lambda\}), & j = K \end{cases}$$

とおく、 $\lambda = 0$ の場合、リスク中立的な確率は自然確率を一致する。このとき $\phi_i^{(n)}$ は、リスク中立的な状態遷移確率 \tilde{P} のもとで $L_i^{(n)}$ の期待現在価値が 1 円となるよう決定するので、 $\tilde{E}[L_i^{(n)} | X_0 = i] = 1$ から、

$$\phi_i^{(n)} = \frac{1 - \frac{1}{(1+r)^n} - \frac{r\xi}{1+r} \sum_{1 \leq t \leq n} \frac{\tilde{p}_{iK}^{(t)}}{(1+r)^t} + \left(1 - \frac{\eta}{1+r}\right) \frac{\tilde{p}_{iK}^{(n)}}{(1+r)^n}}{1 - \frac{1}{(1+r)^n} - r \left(1 - \frac{r\xi}{1+r}\right) \sum_{1 \leq t \leq n} \frac{\tilde{p}_{iK}^{(t)}}{(1+r)^t} + \frac{r\xi}{1+r} \frac{\tilde{p}_{iK}^{(n)}}{(1+r)^n}}$$

となる。この結果、もし格付けの状態遷移確率 P が推定できれば、適当なリスク回避度 λ に対応した n 期間融資のリスクプレミアムが計算できる。

3 観測過程に基づく格付け状態の推定

次に、直接格付け状態が観測不能な場合に、ある格付け状態と相関関係のある確率過程に基づき、格付け状態を推定する方法を考える。いま、 m 次元確率ベクトル過程 $X_t = (X_{1,t}, \dots, X_{m,t})'$ が、 $C_t = K$ となる直後の時点まで観測可能であり、このベクトルの確率的変動が、各時点での格付け状態により変化するものとしよう。すなわち確率ベクトル X_t の平均回帰水準の状態集合が、 $\Theta = \{\theta_1, \dots, \theta_K\}$ により与えられ、時点 t での格付け状態 $C_t = i$ のとき、時点 t での平均回帰水準 $\mu_t = \theta_i$ とする。このとき、元々の格付け状態 $\{C_t\}$ は推移確率 P をもつマルコフ過程に従うので、平均回帰水準過程 $\{\mu_t\}$ も同じマルコフ過程に従う。さらに観測過程 X_t は、次の離散型の Orstein-Uhlenbeck 過程に従うものとする。

$$X_{t+1} - X_t = A(\mu_{t+1} - X_t) + \epsilon_{t+1}$$

但し $m \times m$ 行列 A は、 $\|I - A\| < 1$ を満足する正則な行列とし、イノベーション過程 ϵ_t は、格付け状態のマルコフ過程 C_t とは独立であり、かつ互いに独立で同一の正規分布 $N(\mathbf{0}, \Sigma)$ に従うものとする。このとき観測ベクトル X_t の、一時点前の観測ベクトル X_{t-1} 及び時点 t での格付け状態 C_t を所与としたもとの条件付き確率分布は、次の正規分布で与えられる。

$$X_t | X_{t-1}, C_t \sim N((I - A)X_{t-1} + A\theta_{C_t}, \Sigma) \quad (3.1)$$

過去の観測ベクトル過程 $\{X_u; 0 \leq u \leq t\}$ によって、 $C_{t-1} \in \mathcal{K}^-$ の条件下の格付け状態 C_t を推定したい。このとき $P_t^c = Pr\{\hat{C}_t = C_t\}$ を最大化する推定量 \hat{C}_t^* は、次式で与えられる。

定理 3.1

$$\hat{C}_t^* (\{X_u; 0 \leq u \leq t\}) |_{C_{t-1} \in \mathcal{K}^-} = \operatorname{argmax}_{i \in \mathcal{K}} \{\alpha_{t,i}(X_{t-1}) + \beta_i' X_t\},$$

$$\begin{aligned} \text{但し } \alpha_{t,i}(x) &= \ln Pr\{C_t = i | C_{t-1} \in \mathcal{K}^-\} + \ln Pr\{X_{t-1} = x | C_{t-1} \in \mathcal{K}^-, C_t = i\} \\ &\quad - \frac{1}{2} \theta_i' A' \Sigma^{-1} A \theta_i - \beta_i' (I - A)x, \end{aligned}$$

$$\beta_i = \Sigma^{-1} \mathbf{A} \theta_i \quad \square$$

系 3.1 仮定 2.1 のもとでは, 次の漸近的な収束性が成立する.

$$\lim_{t \rightarrow \infty} Pr\{\hat{C}_t^*(\{\mathbf{X}_u; 0 \leq u \leq t\})|_{C_{t-1} \in \mathcal{K}^-} \neq \hat{C}^*(\{\mathbf{X}_u; 0 \leq u \leq t\})|_{C_{t-1} \in \mathcal{K}^-}\} = 0,$$

$$\text{但し } \hat{C}^*(\{\mathbf{X}_u; 0 \leq u \leq t\})|_{C_{t-1} \in \mathcal{K}^-} = \operatorname{argmax}_{i \in \mathcal{K}} \{\alpha_i(\mathbf{X}_{t-1}) + \beta_i' \mathbf{X}_t\},$$

$$\begin{aligned} \alpha_i(\mathbf{x}) &= \lim_{t \rightarrow \infty} (\ln Pr\{C_t = i | C_{t-1} \in \mathcal{K}^-\} + \ln Pr\{\mathbf{X}_{t-1} = \mathbf{x} | C_{t-1} \in \mathcal{K}^-, C_t = i\}) \\ &\quad - \frac{1}{2} \theta_i' \mathbf{A}' \Sigma^{-1} \mathbf{A} \theta_i - \beta_i' (\mathbf{I} - \mathbf{A}) \mathbf{x} \quad \square \end{aligned}$$

この系の結果に基づいて, $\{\mathbf{X}_u; 0 \leq u \leq t\}, C_{t-1} \in \mathcal{K}^-$ なる情報から C_t を推定するには, $(\alpha_i(\cdot), \beta_i)_{i \in \mathcal{K}}$ をすべて予測する必要がある. そこで以降では, 格付け状態のクラスタリングを 1 次元尺度に帰着できる, ある特別な場合について考察する.

仮定 3.1

$$\alpha_i(\mathbf{x}) = \alpha_0(\mathbf{x}) + \alpha_i + \zeta_i \gamma_-' \mathbf{x}, \quad \alpha_1 \leq \alpha_2 \leq \dots \leq \alpha_K,$$

$$\theta_i = \theta_0 + \zeta_i \Delta \theta, \quad \zeta_1 \geq \zeta_2 \geq \dots \geq \zeta_K,$$

$$f(i) = \alpha_i, \quad g(i) = \zeta_i : \text{凸関数}$$

系 3.2 仮定 3.1 の下では, 漸近的に最適な状態推定法は

$$\hat{C}^*(\{\mathbf{X}_u; 0 \leq u \leq t\})|_{C_{t-1} \in \mathcal{K}^-} = j \Leftrightarrow v(\mathbf{X}_{t-1}, \mathbf{X}_t) = \gamma_+' \mathbf{X}_t - \gamma_-' \mathbf{X}_{t-1} \in [s_{j+1}, s_j]$$

となる. 但し $\gamma_+ = \Sigma^{-1} \mathbf{A} \Delta \theta$ であり, クラスタリングの閾値 $\{s_1, \dots, s_{K-1}\}$ は,

$$s_j = \begin{cases} -\infty, & \text{if } j = K, \\ \frac{\alpha_{j+1} - \alpha_j}{\zeta_j - \zeta_{j+1}}, & \text{if } j \in \mathcal{K}^-, \\ \infty, & \text{if } j = 0 \end{cases}$$

により与えられる. \square

この結果, 近似的に仮定 3.1 が成立する場合には, スコア値 $v(\mathbf{x}_{t-1}, \mathbf{x}_t) = \gamma_+' \mathbf{x}_t - \gamma_-' \mathbf{x}_{t-1}$ に対して 1 次元のクラスタリングを行えば, かなり良い推定が可能となる.

4 スコア関数及び状態遷移確率の推定

式 (3.1) より, 観測過程 $\{\mathbf{X}_u; 0 \leq u \leq t\}$ を所与としたもとの, 時点 t での格付け状態が $C_t = i$ である条件付確率 $h_{t,i}$ は,

$$h_{t,i}(\{\mathbf{X}_u; 0 \leq u \leq t\}) = \frac{\exp\{\alpha_{t,i}(\mathbf{X}_{t-1}) + \beta_i' \mathbf{X}_t\}}{\sum_{j \in \mathcal{K}} \exp\{\alpha_{t,j}(\mathbf{X}_{t-1}) + \beta_j' \mathbf{X}_t\}}$$

により与えられる。また $t \rightarrow \infty$ においては,

$$\lim_{t \rightarrow \infty} h_{t,i}(\{X_u; 0 \leq u \leq t\}) = h_i^*(\{X_u; 0 \leq u \leq t\}) = \frac{\exp\{\alpha_i(X_{t-1}) + \beta_i' X_t\}}{\sum_{j \in \mathcal{K}} \exp\{\alpha_j(X_{t-1}) + \beta_j' X_t\}}$$

が成立する。さらに仮定 3.1 の下では,

$$h_i^*(\{X_u; 0 \leq u \leq t\}) = \frac{\exp\{\alpha_i + v(X_{t-1}, X_t)\zeta_i\}}{\sum_{j \in \mathcal{K}} \exp\{\alpha_j + v(X_{t-1}, X_t)\zeta_j\}}$$

となり, 通常の多項ロジットモデルに帰着される。従って倒産確率の推定ができれば, スコア関数 v が推定でき, 未知の格付け状態へのクラスタリングの基準値が計算可能となる。

いまあるサンプルの観測過程の時系列データが与えられており, また 1 時点遅れで, 格付け状態 K に属しているか否かが判別できるとする。このとき口述する情報量基準を用いれば, 倒産確率の推定は可能である。さらに仮に格付け状態集合を $\mathcal{K} = \{1, \dots, K\}$ とおくと, 状態遷移確率 q_{ij} は

$$\hat{q}_{i,j} = \frac{\sum_{0 \leq t \leq T-1} 1\{\hat{C}_t = i \text{ かつ } \hat{C}_{t+1} = j\}}{\sum_{0 \leq t \leq T-1} 1\{\hat{C}_t = i\}}$$

により推定できる。ここで状態遷移確率行列 \hat{P} の安定性を考えると, 閾値については単純に $Pr\{\hat{C}_t = j | C_{t-1} \in \mathcal{K}^-\} = \frac{1}{K-1}$ となるように設定するのが望ましい。この格付け集合 \mathcal{K} は, 粒度が細かいほどより精緻な状態分類となるので, 格付けごとに正確な倒産リスクプレミアムを評価する観点からは, 詳細な粒度が望まれる。しかし一方で, 過度に粒度を高めると, 格付け状態集合 \mathcal{K} の閾値パラメータ数が増え, 結果として状態遷移確率行列 P の予測が不安定となる。このような観点から, 格付け状態集合 \mathcal{K} の最適な粒度を決定するには, 初期格付け状態 \hat{C}_0 に対応した n 期間融資の推定プレミアム金利 $\hat{\phi}_{\hat{C}_0}^{(n)}$ の割引融資実績の級内分散値

$$\min_{\mathcal{K}} \sum_{i \in \mathcal{K}^-} \sum_{1 \leq n \leq T} \tilde{E}[1\{\hat{C}_0 = i\} (L(\hat{\phi}_i^{(n)}) - \tilde{E}[L_i^{(n)} | \hat{C}_0 = i])^2]$$

を最小化するのが適切といえる。

5 最適な観測空間の設計

$Y = (Y_1, \dots, Y_n)'$ を, ある時点での格付け状態の確率分布 $\{\eta_j\}_{j \in \mathcal{K}}$ を定義する n 次元確率変数ベクトルとする。さらに真の格付け状態の確率分布を $\{h_j(Y)\}_{j \in \mathcal{K}}$, また予想される格付け状態のパラメトリックな確率分布のクラスを $\{h_j(Y; \eta)\}_{j \in \mathcal{K}}$, $\eta = (\eta_1, \dots, \eta_q)' \in \mathcal{A}$ とおく。一般に確率モデルの選択においては, 次の Kullback-Liebler の情報量を最小化することが望ましい。

$$\min_{\eta \in \mathcal{A}} \sum_{i \in \mathcal{K}} E \left[\log \left(\frac{h_i(Y)}{h_i(Y; \eta)} \right) h_i(Y) \right]$$

これは、次の最適化問題と同値である。

$$\max_{\eta \in \mathcal{A}} L(\eta) = \sum_{i \in \mathcal{K}} E[\log h_i(\mathbf{Y}; \eta) h_i(\mathbf{Y})]$$

ここで過去の倒産・非倒産のサンプルデータが $\{(\mathbf{y}_j, c_j); 1 \leq j \leq N\}$ により与えられると、 $L(\eta)$ のサンプル平均 $L_0(\eta)$ は

$$L_0(\eta) = \frac{1}{N} \sum_{1 \leq j \leq N} \sum_{i \in \mathcal{K}} \log h_i(\mathbf{y}_j; \eta) 1\{c_j = i\}$$

となる。このサンプル平均を最大にする推定量 $L_0(\hat{\eta})$ と望ましい基準を最大化した値 $L(\eta^*)$ には、次の関係が成立する。

定理 5.1

$$L(\eta^*) \approx L_0(\hat{\eta}) - \frac{1}{N} \text{trace}[\mathbf{J}(\hat{\eta})^{-1} \mathbf{I}(\hat{\eta})]$$

但し $\mathbf{I}(\eta)$, $\mathbf{J}(\eta)$ は、次式により定義される。

$$\begin{aligned} \mathbf{I}(\eta) &= \sum_{i \in \mathcal{K}} E \left[\frac{\partial}{\partial \eta} \log h_i(\mathbf{Y}; \eta) \frac{\partial}{\partial \eta'} \log h_i(\mathbf{Y}; \eta) h_i(\mathbf{Y}) \right], \\ \mathbf{J}(\eta) &= - \sum_{i \in \mathcal{K}} E \left[\frac{\partial^2}{\partial \eta \partial \eta'} \log h_i(\mathbf{Y}; \eta) h_i(\mathbf{Y}) \right] \end{aligned}$$

特に $h_i(\mathbf{Y}) = h_i(\mathbf{Y}; \eta^*)$, $i \in \mathcal{K}$, すなわち真の格付け状態分布が、あるパラメトリックな確率分布で記述できる場合には $\mathbf{I}(\eta) = \mathbf{J}(\eta)$ が成立し、 $L(\eta^*)$ は次式で近似できる。

$$L(\eta^*) \approx L_0(\hat{\eta}) - \frac{q}{N} \quad \square$$

この定理により倒産確率モデルの選択においては、 $L_0(\hat{\eta}) - \frac{1}{N} \text{trace}[\mathbf{J}(\hat{\eta})^{-1} \mathbf{I}(\hat{\eta})]$ をできるだけ大きくするパラメータ集合 η を選択することが重要となる。

6 中小企業の財務指標データに基づく倒産確率推定

ここでは、(株)東京商工リサーチの「TSR DATA BANK SERVICE MT&FD 99年版」に基づいて、1995年から1999年間の連続財務データを持つ非上場製造業企業1000社（うち181件は分析期間中の倒産企業）に対し倒産確率の推定を行った。対象企業を非上場会社とした理由は、その多くが中小企業であり、融資に伴う信用リスク計量化の重要性が高いことによる。ここで用いた財務指標は、標準的なZスコアモデルにおいて用いられる以下の5変数である。

$$Y_1 = \frac{\text{運転資本の増加}}{\text{総資産}}$$

流動負債増加額 (短期有利子負債増加分除く)

$$\begin{aligned}
 &= \frac{-\text{繰延資産増加額} - \text{流動資産増加額} - \text{手元流動性増加額}}{\text{現預金} + \text{流動資産計上有価証券} + \text{自己株式} + \text{親会社株式} + \text{利益準備金} + \text{その他余剰金}}, \\
 Y_2 &= \frac{\text{繰延資産増加額} + \text{流動資産増加額} + \text{手元流動性増加額}}{\text{総資産}}, \\
 Y_3 &= \frac{\text{税引前営業利益}}{\text{総資産}} = \frac{\text{税引前利益} + \text{支払利息割引料} + \text{社債利息}}{\text{総資産}}, \\
 Y_4 &= \frac{\text{自己資本市場価値}}{\text{負債価値}} = \frac{\text{発行済株式数} \times \text{株価}}{\text{負債価値}}, \\
 Y_5 &= \text{資本回転率} = \frac{\text{売上高}}{\text{総資産}}.
 \end{aligned}$$

これらの財務指標は、倒産確率推定の説明変数として実務的によく用いられている。本来データマイニングにおいては、これらの指標をどのように構成すれば、もっとも良い判別推定ができるのかに関心があるが、ここではその問題には深く立ち入らない(これについては、講演当日説明する)。以降では、これらの財務指標を所与として、格付け状態集合 $K = \{1, 2\}$ と見なしたもとの1年後の倒産・非倒産の予測性を実証分析により検証する。

図1及び図2は、上述の2つのアプローチに基づく内挿及び外挿による倒産予測の判別率を表したものである。(但し倒産の予測においては、 $h_2(\mathbf{y}) \geq \frac{1}{2} \Leftrightarrow$ 非倒産状態と判定した)。この結果内挿分析では当然の事ながらニューラルネットワークの適合性が高いものの、外挿分析では、ニューラルネットによる倒産予測が必ずしも優れていないことがわかる。一方線形スコア関数では、外挿分析においても、毎年安定したパフォーマンスを達成できる。これは、スコア関数の推定に必要なパラメータ数と、内挿分析において利用可能となる学習データ数との関係で、推定誤差の問題が予測性能に大きく影響することを示している。特に中小企業の財務データには、故意過失を問わず、かなりの誤りデータが含まれていると考えられ、これらの誤りデータに対してもニューラルネットにより学習を行った場合、その予測精度は大幅に低下する可能性がある。

次に線形スコア関数とニューラルネットによるノンパラメトリックスコア関数が、どの程度の予測期間について有効なのかを検討する。図3及び図4は、1995年の企業財務指標に基づいてそれぞれ2つのアプローチのスコア関数を計算し、1年後、2年後及び3年後の倒産予測を行ったものである。

いずれの場合にも、予測年数が長くなるにつれて判別率が減少していることがわかる。特に3年先の予測となると、線形スコア関数では判別率が50%を下回り、ノンパラメトリックなスコア関数でも60%程度しか達成できない。この結果、分析対象企業の標準的な財務指標情報しか用いない倒産予測モデルでは、共通リスク要因の変動が無視できる高々1年程度という短期間の倒産予測にしか有効でないと見えよう。また、ニューラルネットを利用したノンパラメトリックなスコア関数は、自由度の高さから、内挿分析に関してはかなり高い判別率を達成できるものの、外挿分析でも安定した予測力を実現するには、良質かつ十分な量の学習データを用意することが重要となる




図 1: 3 手法の内挿における比較




図 2: 3 手法の外挿における比較




図 3: 非線型判別の予測期間と判別率の関係




図 4: ニューラルネット判別の予測期間と判別率の関係

7 終わりに

本稿では信用リスクのスコア関数による自動格付けを、パラメトリックアプローチ (ロジットモデル) 並びにノンパラメトリックアプローチ (ニューラルネットワーク) により考察した。結果として財務指標情報に基づいて中小企業の倒産予測を行う場合、二次の非線型スコア関数による推定が有効であることを示した。一般に、中小企業の経営財務実態を把握するには、ここで用いた財務データ以外に、取引先や仕入先の信用データ、経営者の個人情報、マクロな経済環境データ等が有効であると考えられる。したがって予測精度の向上を実現するには、これらの付加的なデータに基づくスコア関数と財務データ中心のスコア関数をハイブリッドさせた複合的なスコア関数を考える必要がある。

参考文献

- [1] 上坂吉則, 尾関和彦 (1990), パターン認識と学習のアルゴリズム, 文一総合出版.
- [2] 木島正明, 小守林克哉 (1999), 信用リスク評価の数理モデル, 朝倉書店.
- [3] 白田佳子 (1998), 企業倒産予知情報の形成に関する研究, 東洋経済新聞社.
- [4] 豊田秀樹 (1996), 非線形多変量解析—ニューラルネットによるアプローチ—, 朝倉書店.
- [5] トーマツ (1993), 企業生命力 Z 値でみる検証・危ない会社, 週刊東洋経済.
- [6] 長尾裕一郎 (2000), ベイズアプローチによる信用リスクの計量化, 東京工業大学・修士論文.

[7] Altman.Edward.I(1968), Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy, Journal of Finance, 23(4), 589-609.

[8] ジョセフ・P・ビーガス (1997), ニューラル・ネットワークによるデータマイニング, 日経BP社.