

【研究論文】

AdaBoostを用いた実質破綻予測モデルの構築と財務指標選択

保坂 忠明 (東京理科大学)
 高田 悠太 (東京理科大学大学院(院生))
 大沼 宏 (東京理科大学)

倒産予測や経営破綻予測において重要なことは、財務指標の選択と予測モデルの構築である。多くの従来手法では、指標選択とモデル構築が別々に行われており、両者を含めた処理全体での識別精度の最適性が保証されない。本研究では、指標選択と予測モデルの構築を一貫した枠組みの中で行うことができるAdaBoostアルゴリズムを利用して実質破綻予測を行う。AdaBoostでは、逐次的に財務指標が選択されるが、選出される指標によって誤識別される学習サンプルの重みが後段では大きくなる。そのために相補的に働く指標の組み合わせが自然と選択される。150社ずつの実質破綻企業、継続企業の貸借対照表および損益計算書から生成することができるすべての財務比率を候補として、指標選択を行ったところ、1) 純資産合計÷資本金、2) その他有価証券評価差額金÷資本金、3) その他利益剰余金÷流動資産、4) 関係会社有価証券÷資本金、5) 支払利息÷負債合計、が選出された。AdaBoostでは、選出した財務指標を用いて予測モデルの構築まで扱うことができ、従来法との比較を通してその識別精度の高さが示された。

キーワード：実質破綻予測、倒産予測、AdaBoost、決定木、財務指標選択

I. はじめに

機関、個人を問わず投資家が証券取引において利益を生み出すためには、現在の経営状態から企業の行く末を正しく予測することが重要である。また、企業経営全般にとっても取引先の経営状況を予測することは重要となる。その代表的な取り組みの一つが、企業の倒産（経営破綻）の予測である。これらの予測に関しては、パターン認識や機械学習といった統計的解析を用いてこれまでに多くの研究が報告されてい

る。

倒産予測に関する研究の重要な構成要素は、分析に用いる財務指標の選択と予測モデルの構築である。従来の多くの倒産予測研究は、会計的な視点やそれまでの研究実績に基づいて財務指標をトップダウンに設定し、提案する予測モデルの精度評価に焦点を当てていた。これらの手法では、設定される財務指標が予測モデルの識別精度を高める点において最適なものであるとは限らない。一方で、財務指標の選択方法に焦点を当て、決定木などの統計的手法を用いる研究も報告されている。これらの研究の多くは、

選択された指標に対して後段で線形判別分析などの識別器（予測モデル）を適用する。したがって、指標選択と予測モデルの構築が別々のプロセスとなるため、処理全体として識別精度の最適性が保証されるわけではない。

以上の背景の下に本研究では、実質破綻予測を対象にして、財務指標の選出から予測モデルの構築までを単一の枠組みの中で扱うことを目的とする。そのために、機械学習の分野で指標選択（当該分野では特徴量選択と呼ばれる）の目的で使われることがあるAdaBoost (Adaptive Boosting, Freund [1997]) アルゴリズムを用いる。AdaBoostアルゴリズムは、逐次的に指標を選択するが、ある時点で選ばれた指標によって誤識別される学習サンプルの重みを次の繰り返しステップでは増加させる。この特徴のために、後段のステップでは先のステップにおいて選択された指標では識別できないという意味で「難しい」サンプルに対処できる指標が自然に選択される。さらに、選択された指標群の間の重みも与えられ、最終的な判別式（予測モデル）の構築までが単一の枠組みの中で扱われる。本研究では、選出される指標の質や導出される予測モデルの精度について、従来の決定木を用いた方法との比較を通して論じる。

II. 先行研究

多くの倒産予測や経営破綻に関する研究は、企業の財務情報に基づいている。そのさきがけは、Beaver [1967] の研究である。この研究における財務指標の選択基準は、1) 文献において頻繁に利用されていること、2) 先行研究において良好な結果を与えていること、3) キャッシュフローに基づいていること、であった。この基準の下で、解析者の主観や洞察を頼りに

トップダウン的に30個の財務比率が取り上げられ、その各々に対し倒産企業と継続企業を識別する能力が検証された。

複数の財務比率を同時に扱う倒産予測として、もっとも有名な研究の一つがAltman [1968] である。この研究では、破産申請をした製造企業33社と、規模が同程度の継続企業33社の財務情報が用いられている。財務指標の選択基準は、1) 流動性、収益性、レバレッジ、支払い能力、回転率のいずれかの観点により解釈ができること、2) 先行研究で利用されていること、3) 倒産予測という目的に適していること、であった。この研究においても、解析者の主観と洞察によりトップダウンに22個の財務指標が取り上げられ、それらの様々な組み合わせに対して線形判別分析に基づく検証が行われた。最終的には五個の財務指標を用いた倒産予測モデルが構築された。

その後には、財務指標選択に統計的アプローチを取り入れた研究が提案された。Edmister [1972] は、あらかじめ先行研究において使用されていた19個の財務指標に限定はしたものの、逐次変数選択法を用いて7個の指標を選出した。Sung [1999] は、決定木アルゴリズムを利用して、韓国企業の倒産予測に有効な財務指標を年代別に選出した。また、白田 [1999] は、これまでの研究での有効性や日本での企業評価の側面からの考察に基づき66個の財務指標を対象として、決定木アルゴリズムとステップワイズ法をそれぞれ個別に利用することで指標選択を行った。ステップワイズ法によって選択された上位4指標は、決定木アルゴリズムによっても識別精度の高い指標として選ばれるなど、両手法によって選出される指標の多くが重複する結果となった。

白田 [2003] は、分析の信頼性を高めるために、それまでの倒産予測研究では数十～数百程

度であったデータサンプル数を大幅に増大させた。この研究では、1,436社の倒産企業と3,435社の継続企業の財務情報が用いられている。白田〔1999〕において検討対象とされていた指標にキャッシュフローに関連する指標を加えた72個の財務指標が候補として取り上げられ、経済環境の変化に影響を受けやすい指標、会計学的適性に欠ける指標が排除されて42個の指標が残った。その上で、白田はCART (Classification and Regression Tree) と呼ばれる決定木アルゴリズムの一つを用いて、倒産予測に有効な財務指標として四つの比率を選出した。最終的には、それらの指標を用いた線形判別式が導出されている (SAF (Simple Analysis of Failure) 2002)。

一方で、財務指標の選択には重点を置かず、予測モデルの構築およびその精度評価に焦点を当てた研究も多い。それらの研究では、Altman〔1968〕や白田〔2003〕で用いられた線形判別分析ではなく、非線形の識別器が積極的に利用されて識別精度の向上が図られている。例えば、Ohlson〔1980〕ではロジスティック回帰モデルによる確率的な倒産予測、Altman〔1994〕ではニューラルネットワークを用いた倒産予測、Shin〔2005〕ではSupport Vector Machine (SVM; Vapnik〔1998〕)を用いた倒産予測がそれぞれ提案されている。本研究で用いるAdaBoostについてもAlfaro〔2008〕やRamakrishnan〔2015〕などにおいて倒産予測や経営破綻予測に用いられているが、財務指標は解析者によってトップダウンに指定され、AdaBoostは予測モデルの構築のみに使用されている。

倒産予測の研究では、選出される財務指標が予測モデルに適合するかどうか最終的な識別精度に大きく影響を与えると考える。したがって、単に先行研究における使用頻度が高いなどの理由で財務指標がトップダウン的に決定され

た場合には、十分な識別精度が達成されるという保証はない。また、Sung〔1999〕や白田〔2003〕のように決定木を援用して財務指標が選出される場合においても、後段で用いる予測モデルに適合する指標であるかどうかは、別途に評価されなければならない。これらのことから、財務指標の選出から予測モデルの構築までを一貫した枠組みの中で扱うことができるアルゴリズムを検討することには意義があると考えられる。

本研究では、以上の研究背景を踏まえて、Viola〔2004〕などの画像処理分野において指標選択 (特徴量選択) の目的で使われ顕著な実績を示したAdaBoostアルゴリズムに注目する。AdaBoostにより、実質破綻予測にとって有効な財務指標の選出と予測モデルの構築を単一の枠組みの中で行う。

Ⅲ. 研究方法

1. 対象となる財務データ

本研究の対象とする実質破綻企業は、2002年1月から2014年10月の期間に東証、大証、旧ナスダック・ジャパンスターダート、旧ヘラクレススタンダード、旧ヘラクレスグロース、旧ジャスダックのいずれかの市場で一般的に実質破綻とみなせる事由 (債務超過、銀行取引の停止、破綻・再生・更生手続き、合併を除く事業活動の停止) を理由として上場を廃止した会社とする。ただし、銀行等の金融機関や財務情報を入手することができない企業は除外する。結果として、この条件に当てはまり財務情報の入手が可能な企業の総数は150であった。

継続企業についても、実質破綻企業のサンプル数に合わせて150社分の財務情報を取得する。ただし、継続企業は実質破綻企業と比較して該当する会社が多く、そのため経営状況も多岐に

渡る。限定された150のサンプルの中に、経営破綻に近い状態の会社が継続企業として混入することで最終的に導出される予測モデルの精度が低下する可能性がある。そこで、本研究の対象とする継続企業は、公共社団法人日本証券アナリスト協会が提供している「証券アナリストによるディスクロージャー優良企業選定(平成26年度版)」から無作為に抽出する。

これらの実質破綻企業150社、継続企業150社の貸借対照表と損益計算書を日経NEEDS Financial QUESTより入手する。この際に、実質破綻企業の財務情報としては、上場廃止の直前期のデータを使用し、継続企業の財務情報としては、2014年10月時点における最新のデータを使用する。

本研究では、個々の企業の実質破綻を予測することに焦点をあてることとし、連結決算ではなく単独決算として報告された財務諸表を用いる。これは、連結子会社の業績が合算されることで、親会社単独としての業績が財務諸表から分かりにくくなることを回避するためである。なお、日経NEEDS Financial QUESTから入手できる単独決算の貸借対照表データは全部で187項目から構成されており、損益計算書データは全部で106項目から構成されている。本研究では、会計学的な考察による修正や補正を行わずに、これらの項目の数値を利用する。また、業種による区別、純粋持株会社といった特殊な企業形態などによる区別も行わずに、その条件の下で実質破綻を予測することを目的とする。

2. 欠損値の扱い

経営・財務データ分析において、欠損値の扱いは大きなテーマとして扱われることもあるが(Little [2002])、本研究では、以下の単純な手順にしたがって貸借対照表および損益計算書の項目ごとに、欠損値の除去および補完を行う：

- 1) 値が欠損しているサンプル(企業)の個数を数えて、全サンプル数(本研究では300である)に対する欠損率を求める。
- 2) 欠損率があらかじめ定めた値 l ($0 \leq l < 1$) を超える場合には、該当の項目全体を削除する。欠損率が l を超えない場合には、該当の項目における欠損値を0で置き換える。

手順2における0による置き換えの根拠は、本研究ではディスクロージャーが義務づけられている上場企業が対象であるため、真に情報が失われて欠損になっている場合は少ないと考えられ、むしろ欠損値が実際には0であるか、そもそも該当の財務項目が存在しないと考えられる場合の方が多くことである。これは日経NEEDS Financial QUESTから得られるデータの仕様とも言えるが、例えば、支払手形がない企業では該当項目が欠損となることや、サービス業に属する多くの会社では原材料の項目が欠損となる。

3. 財務比率候補の生成

欠損値補完処理によって生成される完全データを使って選出の対象となる財務指標の候補を生成する。本研究では、貸借対照表および損益計算書の中から任意の二項目を選び(両財務諸表から一項目ずつを選択する場合も含む)、それらの比率を求める。ただし、分子と分母を入れ替えることは本質的な識別力に影響を与えないため、いずれか一方のみを考える。また、一社でもデータ値が0になっている項目は、比率の分母になることがないように配慮する。

本研究では、会計的側面や先行研究での使用頻度などを考慮して財務比率を事前に絞り込むことは行わない。従来研究の中には、会計的な観点からの解釈が難しい指標をあらかじめ除外するものもある。しかし、仮にその指標を用いることで識別精度が向上するのであれば、む

しる積極的にその指標に対して考察がなされるべきであると考えている。また、白田〔2003〕では、大量の指標を人工的に生成することは、類似の意味をもつ多数の指標が作られるために慎重になるべきであるとされている。しかし、AdaBoostでは、以下で述べるように、先に選出された指標とは異なる質の指標が逐次的に選出されるように学習サンプルに再重み付けが施される。そのため、類似の意味をもつ複数の指標が存在しても、少なくとも識別精度に悪影響を及ぼすことはないと考えている。

4. 財務指標の選択と予測モデルの構築

生成される多数の財務比率の中から、用いる予測モデルにとって最適な指標の組み合わせを選択することは困難である。本研究では、財務指標の選択から予測モデルの構築までをAdaBoostという単一の枠組みの中で行うことで、この困難を克服する。ここでは、従来研究において、財務指標選択に利用されてきた決定木とともに、アルゴリズムについて述べる。

(1)決定木

決定木では、財務指標に対する閾値判別により識別対象である全300社の企業を次々と二つのグループに分割していく。使用する財務指標と閾値は、分割のたびに最適なものが選ばれる。分割操作を停止する条件としては、1) 生成されるグループに含まれる企業の属性（本研究では、実質破綻/継続）が単一になる、2) グループに含まれる企業数が一定数以下になる、3) あらかじめ定めた分割回数に達する、などが考えられる。

各分割操作において、注目する財務指標を決定する規準が必要となる。本研究では経済学で頻繁に用いられるジニ係数を利用する。ジニ係数はグループ内の属性の均一さを測っていると

解釈できる。あるグループを分割する際には、分割前のグループのジニ係数と、分割後に生成される二つのグループのジニ係数の平均値との差分を、もっとも大きくする財務指標および閾値を採用する。

すべての分割操作が終わると、一つの決定木が完成する。そして、決定木の中で分割に用いられた財務指標を抽出する。なお、機械学習の分野では、ジニ係数の減少への寄与が特に大きかったものに限定することもある。また、白田〔1999, 2003〕は、生成された決定木から機械的に財務指標を選出するのではなく、会計的解釈なども考慮している。決定木による指標選択の問題点としては、1) 学習に使うデータの組み合わせによって結果が大きく変化しやすい、2) 分割の停止条件によって結果が大きく変化しやすい、3) 相関の高い複数の指標が別々のグループの分割において選ばれやすい、などが挙げられる。

予測モデルの構築は、選出された財務指標を線形判別分析やSVMなどのパターン認識分野で知られる識別器の入力として用いることで実現する。本来であれば、指標選択の段階で予測モデルとして利用する識別器の最終的な予測精度が最適になるように指標を選択すべきである。しかし、指標の選択と予測モデルの構築が別途に行われる場合には、その最適化に対する配慮がなされていない可能性が高い。

なお、判別分析などを用いずに、求めた決定木をそのまま予測モデルとして使うこともできる。そのためには、属性が未知の新規データを決定木の分割ルールにあてはめて、最終的に到達するグループ（木の末端に対応）を求める。そして、決定木の学習時にその末端グループに含まれていた企業の属性を調べて、割合の大きい方に新規データを分類する。

(2)AdaBoost (Adaptive Boosting)

AdaBoostは本来、指標選択（機械学習分野では特徴量選択と呼ばれる）の目的で提案されたものではない。AdaBoostは、精度の高くない識別器（弱識別器と呼ばれる）をいくつか組み合わせることで全体として一つの精度の高い識別器（強識別器と呼ばれる）を生成するアンサンブル学習のアルゴリズムである（Freund [1997]）。本研究では、各財務指標の単純閾値判別を弱識別器とみなすことで、AdaBoostアルゴリズムによって財務指標選択を可能とする。

AdaBoostを用いた財務指標選択の手順を以下に示す：

- 1) 用意された学習データに含まれるすべてのサンプル（各企業データ）の重みを等しく設定する。
- 2) 財務指標ごとに、識別精度がもっとも高くなる最適な閾値を求める。なお、識別精度は、サンプルに対する重みを考慮した誤分類率により測る。
- 3) すべての財務指標の中でもっとも識別精度の高いものを採用する。その指標に対する重み付き誤分類率を ε ($0 \leq \varepsilon \leq 0.5$) としたとき、採用した財務指標の信頼度を

$$\alpha = \frac{1}{2} \log\left(\frac{1-\varepsilon}{\varepsilon}\right) \quad (1)$$

で定義する。ここで、信頼度 α は $\alpha \geq 0$ となる。

- 4) 手順3で採用された財務指標により正しく分類できるサンプルの重みに $\exp(-\alpha)$ (≤ 1) を乗じることでその値を減少させる。一方で、誤って分類されるサンプルの重みに $\exp(\alpha)$ (≥ 1) を乗じることでその値を増加させる。ただし、最終的に全サンプルの重みの和を1にするように、各指標の重みを規格化する。
- 5) 手順2-4をあらかじめ定めた回数 T だけ繰

り返すことで T 個の財務指標と閾値を得る。

AdaBoostでは、選択された財務指標によって識別が困難なサンプルの重みが大きくなり、後段のステップでは、そのような「難解な」サンプルの識別を可能とする財務指標が選出されやすくなる。しかし、正しく分類されたサンプルの重みが0になるわけではなく、一定の影響力は残っている。そのため、決定木と比較して少数のサンプルだけに強く依存した指標が選出されにくくなるという特長をAdaBoostは持っている。

上記の処理手順2-4を繰り返す際に、ある繰り返しステップで選択された財務指標によって誤識別されるサンプルの重みは、次のステップで大きくなる。そのため、それ以降の繰り返しステップにおいては、それらの誤識別されたサンプルを正しく識別する財務指標が選択されやすくなる。結果として、相補的な役割を果たす財務指標が逐次的に選択される傾向が強くなる。これはまた、複数の類似の財務指標が候補として存在していたとしても、そのうちの一つがある段階で選択されると、それに類似する財務指標は、それ以降の繰り返しステップでは選択されにくくなることを意味している。したがって、複数の類似の財務指標が候補として存在していても、そのこと自体は最終的な識別精度に悪影響を与えないと考える。

AdaBoostでは、指標の選択に留まらず、属性が未知の新規データに対する予測モデルの構築までが共通の枠組みに含まれている。まず、上記の手順により得られた T 個の財務指標と閾値をそれぞれ単独で使って新規データの識別を行う。各閾値判定の結果を $r_t \in \{+1, -1\}$ ($t = 1, 2, \dots, T$) で表す。ここで、 $r_t = +1$ は t 番目に選択された指標による識別結果が「継続」であることを表し、 $r_t = -1$ は識別結果が「実質破綻」であることを意味する。最終的な識別は、これ

らの T 個の判定結果を信頼度 $\alpha_t(t = 1, 2, \dots, T)$ で重み付けて多数決をとった

$$\text{sign}\left(\sum_{t=1}^T \alpha_t r_t\right), \quad (2)$$

ただし, $\text{sign}(x) = \begin{cases} +1 & (x \geq 0) \\ -1 & (x < 0) \end{cases}$

により行われる。

なお、上記のAdaBoostによる指標選択および予測モデルの構築の手順は、発見的な思い付きのアルゴリズムではない。Friedman[2001]は、上記の手順とは逆に、最終的な識別関数として式(2)の形を仮定したとき、この識別関数の判別誤りを指数関数の形で定式化した上で、その判別誤りを逐次的に（AdaBoostのステップごとに）最小化するという枠組みの中で、重みの更新式や信頼度の式を導出している。すなわち、指標選択から予測モデルの構築までが一つの枠組みの中に収まっており、予測精度が最適になるような指標が自然に選択される。この点が、両プロセスを別々に行う従来手法に対する利点となる。

5. Leave-one-out交差確認法による検証

本研究では、全300社のデータを財務指標選択のための学習用と、選択された指標の能力を測るための評価用に分割する。しかし、結果はデータの分割の仕方に大きく影響を受けるため、機械学習の分野では、交差確認と呼ばれる検証が行われる。交差確認とは、学習用データと評価用データを入れ替えて複数回の検証を行うことである。

本研究では、特にLeave-one-out交差確認法を用いる。Leave-one-out法では、1) 300社の企業データのうち、299社分を学習用データとして、決定木やAdaBoostにより、財務指標選択を行う、2) 残りの1社のデータを評価用データ、すなわち属性が未知の新規データと想定し

て実質破綻/継続の識別を行う、といった手順をとる。学習用データと評価用データの組み合わせを変えることで、全部で300通りのパターンを試し、評価用データに対して正しく識別がなされた割合を識別率として求める。

IV. 分析結果と考察

本節では、評価実験の結果について述べる。最初にLeave-one-out法によって求まる識別精度（予測モデルの精度）について定量的に検証し、その後、選択される財務比率や導出される予測モデルに対して考察を行う。

1. 識別精度の検証

本研究では、欠損率を制御するパラメータ l の値を0, 0.25, 0.5の三通りに変化させて評価を行う。これらの各場合において生成される財務比率の総数は、

$l=0$ の場合：136個

(貸借対照表10項目、損益計算書7項目が対象)

$l=0.25$ の場合：1,139個

(貸借対照表54項目、損益計算書22項目が対象)

$l=0.5$ の場合：1,666個

(貸借対照表78項目、損益計算書29項目が対象)

である。なお、参考として $l=0.25$ の場合に対してのみ、財務比率を構成する際の対象となる貸借対照表の54項目、および損益計算書の22項目を図表1に示す。


図表2に、提案手法による実質破綻企業/継続企業の識別精度を各 l の値について示す。横軸は予測モデルに取り入れる財務比率の数を表しており、これはAdaBoostにおける繰り返し回数 T に等しい。縦軸はLeave-one-out交差確認法によって求めた識別率であり、300回の評価において正しく判別がなされた割合である。

全体的な傾向として、財務比率の数が増える

図表1 財務比率を生成する際に対象となる財務項目 ($l=0.25$ の場合)

貸借対照表項目		損益計算書項目
流動資産	買掛金	売上高・営業収益
現金及び現金同等物	短期借入金・社債合計	売上原価・営業原価
受取手形・売掛金	1年内返済の借入金	売上総利益
売掛金	短期借入金	販売費及び一般管理費
棚卸資産	未払金・未払費用	営業利益
前払費用	未払金	営業外収益
その他流動資産	未払費用	受取利息・配当金
貸倒引当金	未払法人税等	受取利息・割引料・有価証券利息
固定資産	預り金	受取配当金
有形固定資産	その他流動負債	その他営業外収益
償却対象有形固定資産	固定負債	営業外費用
建物・構築物	長期借入金・社債・転換社債	支払利息
工具・器具及び備品	引当金合計	その他営業外費用
土地・その他非償却対象有形固定資産	その他固定負債	経常利益
無形固定資産	負債合計	特別利益
ソフトウェア	純資産合計	特別損失
その他無形固定資産	株主資本	税金等調整前当期純利益
投資・その他の資産合計	資本金	税金等調整前当期利益
投資有価証券・関係会社株式・出資金	資本剰余金	法人税等
投資有価証券	資本準備金	法人税・住民税及び事業税合計
関係会社有価証券	利益剰余金	法人税等調整額
長期貸付金	その他利益剰余金	当期利益
その他の投資・その他の資産	繰越利益剰余金	
貸倒引当金	自己株式	
資産合計	その他有価証券評価差額金	
流動負債	負債・純資産合計	
支払手形・買掛金	自己資本	

図表2 AdaBoostアルゴリズムによる実質破綻企業と継続企業の識別精度



につれて、識別精度は向上していくことが分かる。特に財務比率の数が5程度に達するまでは、識別率の上昇の程度が大きく、財務比率の数が20を超えると識別率はほぼ一定となる。欠損率を制御するパラメータ l の識別精度への影響では、いずれか一つの会社でも欠損している項目を除去することに対応している $l=0$ の場合の精度がもっとも低い。本研究の欠損値除去の方法では、本来は欠損ではなく値が0である財務項目までが除去されて、結果的に識別に有効な項目が失われる可能性がある。このことが、 $l=0$ の場合には顕著に現れたと考える。一方で、 $l=0.25$, $l=0.5$ の場合の識別精度の差は顕著ではない。これは、 $l=0.25$ の段階で、実質破綻の予測に有効な財務項目が除去されずにデータに含まれていることを示唆している。

図表3に決定木によって指標選択から予測モデルの構築までを行った場合の識別精度を比較として示す。ここでは、木の末端までの最大分割回数を3および4に設定した場合と分割回数に制限を設けない（すなわちグループ内の属性が単一になるまで分割を続ける）場合についての精度を示している。最大分割回数が3, 4の場合には、決定木の中で用いられる財務指標の数の最大値は、それぞれ7, 15となるが、提案手法において、それと同数の指標を用いた場合の精度を比較のために角括弧の中に示している。これより、多くの場合に提案手法の方が同等か高い精度を示していることが分かる。また、

最大分割数（抽出される財務比率の数に影響を与える）によって予測モデルの精度に大きな差異は生じていないことが分かる。

2. 選出される財務比率に対する考察

ここでは、欠損率を制御するパラメータ $l=0.25$ において、五個の財務指標を選出する場合（AdaBoostの繰り返し回数 $T=5$ に対応）について述べる。図表4にLeave-one-out交差確認法による総計300回の試行において、もっとも頻繁に選出される財務指標の組み合わせを示す。また、決定木において最大分割回数を4と設定して、ジニ係数の低減に強く寄与した順に五個の財務比率を選び出した場合に、もっとも頻繁に選出される組み合わせも併せて示している。

提案手法により選出された各財務比率の解釈について以下に述べる。補足として、図表5に本研究で用いた150社の実質破綻企業、および150社の継続企業における各財務比率の確率分布を示す。

(1)純資産合計 ÷ 資本金

この比率のみが、決定木アルゴリズムによっても同様に選出されており、単一の比率としては、（少なくとも本研究で用いたデータに対しては）もっとも識別精度の高い指標である。純資産の中に資本金が含まれるため、この指標は健全な財務状態の下では多くの場合に1を超えるものとする。しかし、実質破綻の前には経営

図表3 決定木アルゴリズムによって財務指標の選択および予測モデルの構築を行った場合の識別精度：決定木の中に現れる指標の最大数だけの財務指標を選出した場合の提案手法の識別率を角括弧内に示している。

	最大分割回数：3 (指標の最大数：7)	最大分割回数：4 (指標の最大数：15)	分割回数に制限なし
$l=0$	0.867 [0.830]	0.867 [0.863]	0.870
$l=0.25$	0.910 [0.937]	0.920 [0.940]	0.913
$l=0.5$	0.920 [0.947]	0.913 [0.957]	0.893

図表4 AdaBoostおよび決定木によって選出される頻度が高最も高い財務比率の組み合わせ ($I=0.25$ において、五個の財務比率を選出する場合):角括弧内の数字は本研究で用いた企業データにおける該当指標の平均値である (左側が実質破綻企業, 右側が継続企業)。

AdaBoost (提案手法)		決定木 (最大分割数:4)	
純資産合計	÷ 資本金 [0.42 / 9.25]	純資産合計	÷ 資本金 [0.42 / 9.25]
その他有価証券評価差額金	÷ 資本金 [0.0058 / 0.48]	1年内返済の借入金	÷ 投資・その他の資産合計 [8.22 / 0.20]
その他利益剰余金	÷ 流動資産 [-3.37 / 0.82]	負債・純資産合計	÷ 資本金 [12.80 / 17.32]
関係会社有価証券	÷ 資本金 [0.34 / 4.28]	その他有価証券評価差額金	÷ 自己資本 [0.0079 / 0.054]
支払利息	÷ 負債合計 [0.014 / 0.0043]	純資産合計	÷ 売上高・営業収益 [1.19 / 4.16]

状況が悪化して、純資産に含まれる利益剰余金が負になることが多いと想定され、この比率が1を下回ることもあると考える。図表5(a)からも上記の推察が支持されることが分かる。

(2)その他有価証券評価差額金 ÷ 資本金

その他有価証券には、売買目的以外の有価証券(ただし、子会社株式や関連会社株式は除く)が該当するが、日本では、その他有価証券の多くは、相互保有株式である。したがって、その他有価証券評価差額金は提携先の財務状況を反映していると考え。また、分母の資本金は、会社規模の影響を抑えるための規格化因子の役割を果たしていると考え。図表5(b)より、実質破綻企業では、この比率が小さくなるか、0になる(その他有価証券評価差額金の項目が欠損する場合も含む)傾向がある。その理由の可能性として考えられることは、

- ・両社の経営が相互に強く依存している場合に、提携先の経営状況の悪化が自社にも悪影響を与える
 - ・自社の経営の悪化に伴い、株式の相互保有の関係が解消される
- などである。また、株式の相互保有以外の場合も含めると、この比率は資本政策の巧拙を反映

した指標であると考えられることもできる。

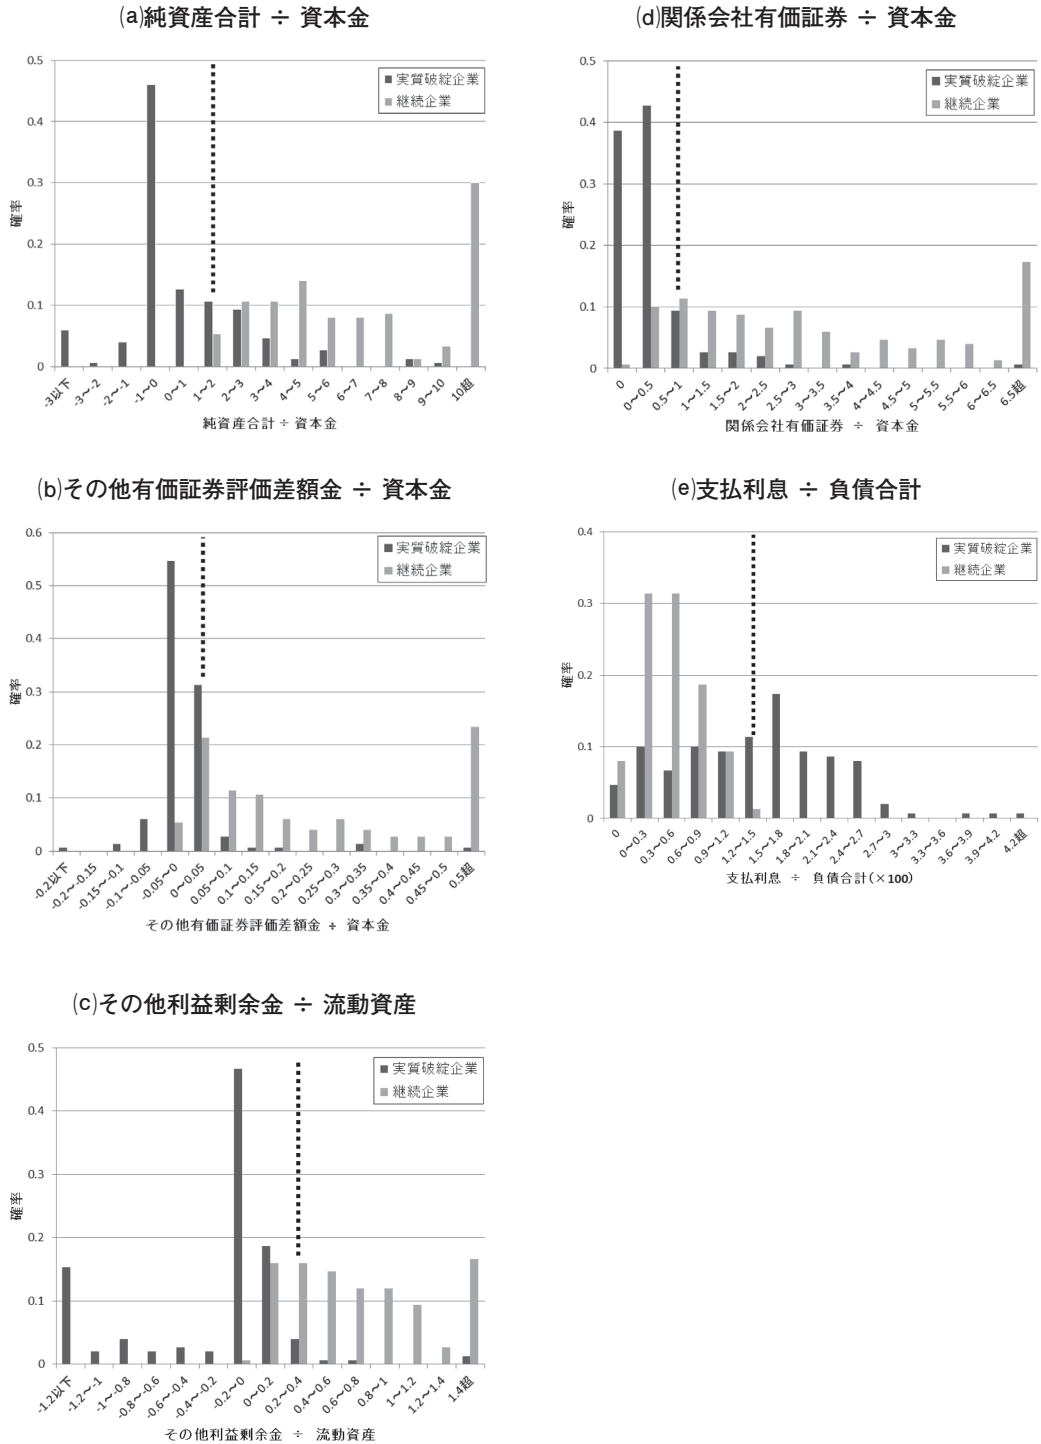
(3)その他利益剰余金 ÷ 流動資産

経営状況が悪化するにつれて、その他利益剰余金と流動資産はともに減少すると考えるが、減少の程度はその他利益剰余金の方が大きいと推察する。企業は経営活動のために流動資産を一定以上は保持する必要があるため、経営状況が悪化しても固定資産や有価証券の売却、さらなる借入などで流動資産を保つ動きをとることが自然である。結果として、事業が順調である状況と比較して、経営が悪化した状況では、分母の流動資産の減少に対して、分子のその他利益剰余金の減少の方が大きくなり、実質破綻企業と継続企業の間で比率の値に差異が生じるものとする。図表5(c)にもその傾向が顕著に現れている。

(4)関係会社有価証券 ÷ 資本金

関係会社有価証券は、子会社を経営的に支配する場合や関連会社に影響を与えることを目的として保有する有価証券である。分母の資本金は、会社規模の影響を抑えるための規格化因子の役割を果たしていると考えられる。業績悪化により経営が破綻する前に、これらの

図表5 提案手法により選出された財務比率の確率分布：本研究で用いる実質破綻企業150社，継続企業150社について求めた。図中の点線は，予測モデルの式(3)に現れる閾値が含まれている区間を示している。



有価証券は親会社や別の関連会社に売却されることが多いと想定すると、この比率が識別に有効であると理解できる。図表5(d)からも実質破綻企業の大部分について、この比率が小さくなっていることが分かる。

(5)支払利息 ÷ 負債合計

支払利息の主要な構成要素は、負債の利息である。経営状況の悪化に伴い、高利子の負債が増大する、支払いの滞納が発生する、といった事象が発生すると考える。その結果として、実質破綻企業においては、負債全体に占める利息の割合が大きくなるものと推察する。図表5(e)からも上記の推察が支持されることが分かる。

以上のように、提案手法により選出された五つの財務比率は、定性的にも実質破綻企業と継続企業を識別するために有効であることが分かる。なお、本研究では財務データとして貸借対照表および損益計算書を用いているが、選出する財務比率の数を五個に設定する場合には、そのうちの四つの財務比率について分子分母の両方が貸借対照表の項目であった。このことは、当期に限定した収益および費用を参照することよりも、これまでの業績の蓄積の反映である資産・負債・純資産を参照することの方が実質破綻予測にとっては有効であることを示唆していると考えられる。また、収益性よりも安全性の方が実質破綻予測にとっては有用であることを示唆しているとも言える。

提案手法においては、300回のLeave-one-out試行のうちの16回で、上記の五つの財務比率とは異なる組み合わせが選ばれていた。それらの16回の組み合わせの各々の中に、上記の五つの比率と異なるものがいくつ含まれているのかを調べた結果は以下の通りである：

1個：2回

2個：12回

3個：2回

4個：0回

5個：0回。

したがって、まったく異なる指標が選ばれているということではなく、選択される指標には一定の傾向があると言える。一方で、決定木の場合には、300回のLeave-one-out試行のうちの34回で、図表4（右列）に示した五つの財務比率とは異なる組み合わせが選ばれていた。また、それらの34回の組み合わせの各々の中に、最頻出の五つの比率と異なるものがいくつ含まれているのかを調べた結果は以下の通りである：

1個：6回

2個：6回

3個：9回

4個：1回

5個：12回。

Leave-one-out交差確認法を用いているため、試行ごとに学習用データは1サンプルずつしか変わらないにもかかわらず、五つの指標のすべてが異なるものに置き換わる場合が最も多い。これらの観点から、AdaBoostの方が決定木と比較して頑健な指標選択を実現しているものと考えられる。

3. 実質破綻の予測モデルの導出

AdaBoostにより選出された五つの財務比率を用いて予測モデルを導出する。AdaBoostアルゴリズムでは、その枠組みの中に指標選択から式(2)で表される予測モデル（判別式）の導出までが含まれている。上述したように、Leave-one-out交差確認法に基づく300回の試行のうち284回において、同一の五個の指標が選ばれているが、それらの284回の試行では、式(2)に含まれる各指標の信頼度 α_i や r_i を求めるために必要となる各指標の閾値はほぼ同じ値になった。

それらの値を利用して、本研究では、以下の実質破綻予測モデルを提案する：

$$f = 1.043 \operatorname{sign}(z_1 - 1.527) + 1.241 \operatorname{sign}(z_2 - 0.0334) + 0.957 \operatorname{sign}(z_3 - 0.268) + 0.816 \operatorname{sign}(z_4 - 0.745) - 0.747 \operatorname{sign}(z_5 - 0.0125) \quad (3)$$

- z_1 ：純資産合計 ÷ 資本金
- z_2 ：その他有価証券評価差額金 ÷ 資本金
- z_3 ：その他利益剰余金 ÷ 流動資産
- z_4 ：関係会社有価証券 ÷ 資本金
- z_5 ：支払利息 ÷ 負債合計。

式(3)に含まれる五つのsign関数は、各財務比率による閾値判別を表しており、式(2)における r_i に対応している。また、sign関数の中の定数は閾値であり、sign関数の係数（の絶対値）は各財務比率の信頼度 α_i に対応している。そして、関数値 f が正の値になる場合に対象企業は継続企業と判定され、負の値になる場合に実質破綻企業と判定される（最終的な判定が式(2)に現れるsign関数に対応している）。

式(3)の予測モデルは、複雑な印象を与えるかもしれないが、五つのsign関数が取りうる値はそれぞれ1または-1の二値なので、関数 f の取りうる値は32通りしかない。さらに、信頼度に対応する係数の値に注目すると、この予測モデルを次のように単純に表現することができる：

以下の五項目の内、対象企業が三項目以上を満たす場合には、その企業は継続企業と判定され、満たす項目が二項目以下の場合（すなわち、三項目以上を満たさない場合）には実質破綻企業と判定される。

[判定項目]

- 1) 純資産合計 ÷ 資本金 が1.527以上
- 2) その他有価証券評価差額金 ÷ 資本金 が0.0334以上
- 3) その他利益剰余金 ÷ 流動資産 が0.268

以上

4) 関係会社有価証券 ÷ 資本金 が0.745以上

5) 支払利息 ÷ 負債合計 が0.0125未満

したがって、各指標の信頼度は数値の上では0.747~1.241までの幅はあるものの、その差異は重要ではなく、実質破綻か継続かの識別は上記の五項目の検証によって行えばよいことになる。

上記の五つの項目を基に実質破綻に至る企業の行動とそれに伴う財務比率の変化を推察する。

1. 売上の減少等により資本に欠損が生じ始め、剰余金が減少する（比率 z_1 および比率 z_3 の減少）。
2. 財務状況の悪化に伴い、低金利での資金調達が困難となり、負債の支払いも滞る（比率 z_5 の上昇）。
3. 資本の減少がさらに進むと、元来は売買以外の目的で保有していた有価証券の売却が行われる（比率 z_2 および比率 z_4 の減少）。また、業務提携先との関係解消が発生する（比率 z_2 の減少）。

現実には、各事象がこの順序で発生するとは限らないこと、その他の要因が影響する可能性も十分にあることには注意を払う必要がある。

4. 線形判別分析, SVMによる予測モデルと の精度比較

決定木により財務指標選択を行う従来手法においては、後段として判別分析などの識別器を用いることが多い。そこで、**図表4**（右列）に示す決定木により得られた五つの指標を入力として、線形判別分析およびSupport Vector Machine (SVM) による予測モデルを構築し、提案手法による識別精度と比較する。これらの手法では、いずれも学習用データを用いて判別関数を導出する必要がある。そこで、ここでも

Leave-one-out交差確認法により評価を行う。また、SVMにおいては、識別精度に大きく影響を与えるパラメータがアルゴリズムに含まれるが、それらは最終的な識別率が最大になるように手動で調整する。

線形判別分析により予測モデルを構築した場合の識別率は0.860となり、AdaBoostを用いた提案手法（識別率0.940）の方が優位である。一方で、SVMにより予測モデルを構築した場合の識別率は0.957となり、AdaBoostを用いた提案手法と比較してSVMの方が数値の上では優位である。しかし、SVMには調整すべきパラメータが含まれている（この実験では、手作業により最適な値を探索している）のに対し、AdaBoostアルゴリズムにはそのようなパラメータが含まれていないといった実用上の利点がある。またSVMでは、複雑な非線形判別面を生成することができ（ただし、そのことが結果の解釈を難しくする）、新規データに対する識別にも適切に対応できるような工夫がされている。むしろ前節で述べたような単純な形で表現できる提案手法の予測モデルが、SVMと同程度の識別率を達成していることは、AdaBoostによる識別の有効性を示していると言える。

5. 外的妥当性の検証

Ⅲ-1節で述べたように、本研究では特定の年度におけるディスクロージャーが優良である継続企業をデータとして用いている。その条件の下で導出した式(3)の予測モデルの外的妥当性を検証する必要がある。そのために、日経NEEDS Financial Questより2015年10月時点で上場を継続している全3256社の企業の財務諸表を入手し、それらの企業に対して、式(3)を用いて識別を行ったところ、その識別率は0.835となった。学習データとは取得時点が異なること、様々な経営状況の継続企業が含まれていること

から、識別率が低下することは妥当であるが、それでも良好な識別精度を示していると考えられる。

V. おわりに

本研究では、企業の実質破綻予測において、AdaBoostアルゴリズムを用いることで財務指標の選択から予測モデルの構築までを一貫した枠組みの中で行い、その有効性を検証した。300社の企業の貸借対照表および損益計算書に含まれる任意の二項目から生成される比率を指標候補として、Leave-one-out交差確認法によって評価を行った。

提案手法により、五つの財務指標を選出する場合には、約95%の割合で、

純資産合計	÷	資本金
その他有価証券評価差額金	÷	資本金
その他利益剰余金	÷	流動資産
関係会社有価証券	÷	資本金
支払利息	÷	負債合計

の組み合わせが選択された。従来法で用いられてきた決定木による指標選択と比較して、提案手法は学習用データの組み合わせに対して頑健な指標選択を実現できることが示唆された。また、提案手法により五つの財務指標を選出して予測モデルを構築した場合の識別率は0.940となり、高い精度が示された。

本研究に対する問題点や改善の余地を基に今後の課題を以下に述べる。

第一に使用するデータの観点から今後の課題を考察する。本研究では、実質破綻企業については、該当企業の上場廃止の直前期における決算報告書のデータを用いている。しかし、より早い段階で実質破綻を予測することは有用である。そこで、上場廃止時点の二期以上前のデータを用いて検証を行うことが今後の課題として

挙げられる。併せて、複数年度の財務情報を同時に用いて精度の向上を図ることも課題である。また、データの信頼性を向上させるためには、1) 貸借対照表において期首と期末の平均値を用いる、2) 貸借対照表に計上されないオフバランスの項目を考慮する、3) 単独決算に特有の財務数値の歪みに補正を施す、4) その他の会計理論上の配慮を取り入れる、ことなどが必要であると考えられる。

第二に評価の方法の観点から今後の課題を考察する。本研究では、業種ごとの層別評価は行っていない。実際には、財務指標の傾向は業種ごとに大きく異なると考える。よって、業種ごとの評価を行うことで精度の改善やより有効な財務指標の発見につながることを期待できる。また、企業の業績は経済状況などの外部要因によって大きく影響を受けるため、特定の財務指標がすべての年代の実質破綻予測に対しても有効であるとは考えにくい。したがって、年代ごとの層別で分析を行うことも同様に新たな知見の発見につながると期待できる。

(参考文献)

- Alfaro, E., N. García, M. Gámez, D. Elizondo, "Bankruptcy Forecasting : An Empirical Comparison of AdaBoost and Neural Networks," *Decision Support Systems*, Vol. 45, 2008, pp. 110-122.
- Altman, E. I. "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy," *The Journal of Finance*, Vol. 23, No. 4, 1968, pp. 589-609.
- Altman, E. I., G. Marco, and F. Varetto, "Corporate Distress Diagnosis : Comparisons Using Linear Discriminant Analysis and Neural Networks (the Italian Experience)," *Journal of Banking & Finance*, Vol. 18, 1994, pp. 505-529.
- Beaver, W. H., "Financial Ratios as Predictors of Failure," *Journal of Accounting Research*, Vol. 4, 1967, pp. 71-111.
- Edmister, R. O., "An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction," *Journal of Financial and Quantitative Analysis*, Vol. 7, No. 2, 1972, pp. 1477-1493.
- Freund, Y., and R. E. Schapire, "A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting," *Journal of Computer and System Sciences*, Vol. 55, Issue 1, August 1997, pp. 119-139.
- Friedman, J. H., "Greedy Function Approximation : A Gradient Boosting Machine," *The Annals of Statistics*, Vol. 29, No. 5, 2001, pp. 1189-1232.
- Little, R. J. A., and D. B. Rubin, *Statistical Analysis with Missing Data*, Wiley-Interscience, 2002.
- Ohlson, J. A., "Financial Ratios and the Probabilistic Prediction of Bankruptcy," *Journal of Accounting Research*, Vol. 18, No. 1, 1980, pp. 109-131.
- Ramakrishnan, S., M. Mirzaei, and M. Bekri, "Corporate Default Prediction with AdaBoost and Bagging Classifiers," *Journal Teknologi (Sciences & Engineering)*, Vol. 73, No. 2, 2015, pp. 45-50.
- Shin, K., T. S. Lee, and H. Kim, "An Application of Support Vector Machines in Bankruptcy Prediction Model," *Expert Systems with Applications*, Vol. 28, Issue 1, 2005, pp. 127-135.
- Sung, T. K., N. Chang, and G. Lee, "Dynamics of Modeling in Data Mining : Interpretive Approach to Bankruptcy Prediction," *Journal of Management Information Systems*, Vol. 16, No. 1, 1999, pp. 63-85.
- Vapnik, V., *Statistical Learning Theory*, Wiley : New York, 1998.
- Viola, P., and M. Jones, "Robust Real-Time Face Detection," *International Journal of Computer Vision*, Vol. 57, Issue 2, 2004, pp. 137-154.
- 白田佳子『企業倒産予知情報の形成』中央経済社、1999。
- 白田佳子『企業倒産予知モデル』中央経済社、2003。
- (受付2015年12月14日、掲載承認2016年3月16日)