

FinTech×監査の現状： AIで見抜く不正会計

市原直通 新日本有限責任監査法人 公認会計士
首藤昭信 東京大学准教授

◆ Summary ◆

本稿の目的は会計監査において AI、とりわけ機械学習を活用することで不正会計の早期発見を効率的に行う可能性を議論することである。AI の活用の方性を取り扱う情報に応じて、公開情報を用いた不正会計の予測と非公開の被監査会社内部の情報を用いた不正会計の検知の2つに分類し、それぞれについて実務への適用を検討する。

《はじめに》

FinTech（フィンテック）の特徴は、金融サービスに機械学習やディープラーニングなどの AI 技術を中心とした先端技術を利用することで、既存のサービスの拡充を図る点にある（藤田，2017）。本稿では、会計監査に同様の技術を適用することの意義および可能性を、学術的な知見を参考にしながら検討する。具体的には、AI 技術、とりわけ機械学習が、監査プロセスにおける不正会計の早期発見を効率化する可能性を議論する。本稿の議論を通じて、会計や監査に特化した先端技術の応用となる AccounTech や AudiTech の可能性を探求してみよう。

I 監査における AI 活用の方向性

監査における不正会計の検出は、対象とする情報に応じて2つのアプローチに分類できる。1つは、公開情報を用いて不正会計の予測モデルを構築するアプローチである。財務諸表や株価情報といった公開情報を様々な企業・年度にわたり幅広く収集し、これらを用いて不正会計を予測するアプローチである。本稿ではこれを、マクロレベルのアプローチと呼ぶ。このアプローチでは、不正会計のパターンを識別するアルゴリズム、すなわち不正会計予測モデルの推計において AI が活用される。

もう1つのアプローチは、非公開の内部情報に注目する方法である。すなわち、被監査会社1社に焦点を当て、非公表の詳細な内部データを利用して、不正な取引や仕訳を発見するミクロレベルのアプローチとなる。もし、財務諸表数値として公表される前の段階で異常な取引や仕訳を検出できれば、被監査会社と監査人の双方にとって非常に有効なツールとなるであろう。

監査人は、クライアントの取引や仕訳に関する膨大な量のデータを取り扱うため、そのなかから異常な仕訳を抽出する作業は容易ではない。ここで異常な仕訳を検知する技術や、また勘定科目ごとの動きを他の科目との関連性から予測し異常な動きを把握する技術として AI が期待されている。

以下では、マクロレベルとミクロレベルに分けて、監査に関する不正会計検出の可能性を検討する。

II マクロレベルのアプローチ

1 不正会計予測モデルの概要

不正会計予測モデルでは、不正会計企業の財務諸表やその他の公開情報に潜む一定の傾向やパターンを機械的に識別し、これとどのくらい類似するのか、という視点で不正会計の発生リスクを算出する。予測モデル構築のポイントは、不正会計の発生を説明する要因

として、どのようなインプット要素に注目するかである。

会計学の領域では、経営者の会計的な裁量行動を分析する利益調整 (earnings management) という研究領域があり、この領域の研究成果が予測モデルに利用されることが多い (首藤, 2010)。利益調整は GAAP の範囲内の合法的な調整であるが、利益調整と不正会計の相関は高いという研究報告もあり、その研究成果が注目されている。

具体的には、①利益を調整した額、②利益調整の動機、または③利益調整を抑制するコーポレートガバナンス体制、といった要因がモデルのインプット要素として利用される (首藤・大城・宋, 2016)。

たとえば、経営者が利益を裁量的に調整した額として定義される会計発生高や裁量的発生高が高い企業は、不正会計を行っている可能性が高いと仮定される。また利益調整の動機としては、利益連動型報酬制度の存在、財務制限条項の抵触回避、または株価の維持などが確認されている。これらの動機に関連する変数も予測モデルに挿入される。さらに取締役会の属性や株式保有構造といったコーポレートガバナンスに関する変数も重要な要素となる。不正会計の有無を従属変数とし、上記のインプット要素を独立変数とする回帰モデルを設定し、予測モデルを構築する。

会計学の領域における代表的な先行研究としては、Beneish (1999) が提案する M スコアモデルや、Dechow *et al.* (2011) の F スコアモデルなどがよく知られている。また日本企業を対象とした不正会計予測モデルを提案した研究に、Song *et al.* (2016) がある。Song *et al.* (2016) では、F スコアモデルを

Profile

いちらは・なおと◇新日本有限責任監査法人 品質管理本部 不正リスク対策部 シニアマネージャー兼アシュアランス・イノベーション・ラボ 主任研究員。2002 年慶應義塾大学理工学部卒業。2016 年東京大学大学院経済学研究科修士課程修了 (経済学)。2003 年新日本監査法人 (現新日本有限責任監査法人) 入所。2016 年より会計学と機械学習を用いた不正会計予測モデルの構築・運用や監査業務における AI 活用に関する研究開発に従事。公認会計士、日本証券アナリスト協会検定会員。しゅとう・あきのぶ◇東京大学大学院経済学研究科 准教授。2002 年に関西大学大学院商学研究科博士後期課程単位取得。2011 年に神戸大学より博士 (経営学) の学位を取得。専修大学商学部、神戸大学経済経営研究所を経て 2015 年より現職。著書に『日本企業の利益調整』(中央経済社, 2010 年, 日本会計研究学会太田・黒澤賞)、論文に“The Effect of Institutional Factors on Discontinuities in Earnings Distribution: Public Versus Private Firms in Japan” *Journal of Accounting Auditing and Finance* 30 (2015) (共著) 等がある。

〔図表 1〕 先行研究で用いられている不正検出アルゴリズムの特徴

アルゴリズム	長 所	短 所
ロジット・モデル	実装が容易。 不正検出において実績がある。	複雑な不正パターンに対応が難しい。
ニューラルネットワーク	不正検出において実績がある。 他の分類問題で安定的な性能が示されている。	計算負荷が高い。 教師データへ過学習することがあるので、 新しい不正のパターンをサンプルに継続的に追加することが必要となる。
サポートベクトルマシン	非線形の分類問題（インプット要素の単純な足し算にならない）に対応が可能。 計算負荷が低い。	インプット要素がどう結果へつながっているのか解釈が難しい。
決定木・ランダムフォレスト	実装が容易。 理解が容易。 計算負荷が低い。	教師データへ過学習することがあるので、 新しい不正のパターンをサンプルに継続的に追加することが必要となる。
遺伝的アルゴリズム・プログラミング	実装が容易。 他の分類問題で安定的な性能が示されている。	計算負荷が高い。新しい不正のパターンへの対応が難しい。
テキストマイニング	大量のテキストデータが利用可能な際に有用。	他の分類アルゴリズムと組み合わせる必要がある。 テキストデータは数値データに比べ主観的要素が入るため、解釈が難しい。
ベイジアンネットワーク	他の分類問題で安定的な性能が示されている。 計算負荷が低い。	不正、適正な財務諸表の傾向やパターンの深い理解が必要となる。
ハイブリッド法	複数の検出アルゴリズムを総合することで 新しい不正のパターンにも対応しうる。	実績があまりない。

（出所）West and Bhattacharya（2015）の表2の一部を抜粋して加筆修正を行っている。

ベースに予測モデルの改善を行っており、高い検出力を有するモデルを提示している。

2 不正会計予測モデルにおける AI の活用

不正会計のパターンを識別するアルゴリズムに AI の様々な技術を利用することができる。West and Bhattacharya（2015）は、様々なアルゴリズムを用いた先行研究の比較を行っている。

図表 1 は、West and Bhattacharya（2015）に基づいて各不正検出アルゴリズムの特徴を要約したものである。前述の Beneish（1999）、Dechow *et al.*（2011）、または Song *et al.*（2016）といった会計学の先行研究では、シンプルな

ロジット・モデルを利用することが多い。実装が容易な点は実務上のメリットがあるが、複雑な不正パターンへの対応が難しい点が短所となる。

先行研究では、どのアルゴリズムの予測の正確度（accuracy）が高いのかについて比較検証が行われている（Kirkos *et al.*, 2007；Ravisankar *et al.*, 2011）。その結果をサーベイした West and Bhattacharya（2015）では、概して、単純なロジット・モデルよりもニューラルネットワーク、サポートベクトルマシン、決定木、遺伝的プログラミング、ベイジアンネットワークなどのほうが高い正確度を有することが示されている。近年話題に

なっているディープラーニングや勾配ブースティングなどの手法も含め、AIの代表例である機械学習を活用することでより精度の高い不正会計の予測が可能となると考えられる。

3 監査実務への応用

不正会計予測モデルが、監査実務において力を発揮するのは、スクリーニング・ツールとしての機能である。多数のクライアントを有する大規模な監査法人では、それぞれのクライアントの監査を担当する監査チームごとに適切に不正会計のリスクを識別し対応することが求められる。同モデルを利用すれば、監査法人の品質管理活動としてリスクの高い可能性のある企業を特定し監査チームにその対応を確認することができる。

さらに財務諸表にどういった傾向があったためにリスクが高いと予測されたのか、説明や注意喚起を行うことでリスクの識別や監査計画のための参考情報を提供することが可能となる。また上記の説明では、同モデルは公開情報に基づいて構築することを前提としていたが、監査法人が有するクライアントの内部情報を利用することができれば、モデルを精緻化することができるであろう。

III ミクロレベルのアプローチ

最近の監査実務では、売上や工事の総原価などの予測を行うために、取引明細などのデータから予測モデルを構築するといった取組みが徐々に始まっている（小川，2016）。また自然言語処理技術を用いた契約書などの文書の解析といった取組みも進んでいる。本稿では、機械学習を利用することで、仕訳デー

タから不正を検出する2つの試みを紹介する。

1つは、機械学習を利用して月次・日次ベースの勘定科目の動きを予測する方法である。実際の勘定科目の動きが期待値と大きく乖離した場合、不正や誤謬が疑われることになる。

今1つは、機械学習を利用して仕訳の異常検知を行う手法である。監査実務では、仕訳テストと呼ばれる、数十万から数億の仕訳を対象に不正や誤謬が含まれていないかの検証を行う作業がある。現状では、すべての仕訳を検証することはできないため、異常が疑われる一定の条件により抽出した仕訳のみの検証を行っている。ところが抽出条件は会社の状況や業種、監査人の経験などに基づいて設定され明確な異常の定義があるわけではない。そのため、偽陽性（空振り）や偽陰性（見逃し）なども多いと考えられ、より精度の高い抽出方法が望まれている。

1 機械学習を利用した勘定科目ごとの月次・日次推移予測

(1) スパースモデリングの利用の可能性

仕訳データがあれば、それを集計することで、各科目が月次・日次でいくら変動したのかわかる。また、科目ごとに今期の累計の変動額に前期末の残高を考慮することで、今期の月次・日次の残高がわかる。Dzeng (1994) や Kogan *et al.* (2014) といった先行研究では、勘定科目ごとの時系列の予測モデル、他の科目を予測に含めたベクトル自己回帰 (VAR) モデルや同時方程式モデル (SEM)、といった予測モデルの構築がなされている。

先行研究では、1つの科目の動きを予測するにあたって、その科目の過去の時系列データだけを用いるよりも、他の科目の動きも考

慮に入れたほうが精度がよくなると指摘されている (Dzeng, 1994)。この場合、同時点の他の科目の動きを考慮する同時方程式モデルが適切と考えられる一方で、単純にすべての科目をモデルに取り込めばいいというものでもない。1つひとつの科目の動きについて、他の科目のなかで関連性が高いものだけを用いてモデル化したい。

とりわけ実務においては数百、ときには数千にものぼる科目のなかからひと握りの関連性の高い科目を抽出する必要があるものの、この変数選択の作業は時間を要し、また判断を伴うため1科目ずつ監査現場で作り込むのは現実的ではない。それぞれの科目ごとに、関連がありそうな勘定科目だけを機械的に抽出して予測モデルを構築することが望ましい。

ディープラーニングは特徴量を自動的に抽出してくれると喧伝されるが、今回のケースでは使うことが難しい。というのも、数百という科目数(説明変数)に対して、過去数年程度のサンプル数ではディープラーニングで学習させるには不十分であり、与えたサンプルに完全に予測を合わせてしまう過学習などの問題が生じる。

スパースモデリングは、このような問題を解決する1つの方法として考えられる。「スパース(sparse)」とは「まばら、少数」という意味で、今回の状況でいえば科目ごとに説明力のある一部の変数のみを自動的に抽出する技術である。スパースモデリングの代表的な手法としてlasso(Least Absolute Shrinkage and Selection Operator)がよく用いられる。lassoは下式のように回帰モデルの損失関数に係数のL1ノルムに基づく正則化項を加えたものを最小化する係数を推定する方

法である。

$$\hat{\beta} = \arg \min_{\beta} \left(\sum_{i=1}^N (y_i - x_i \beta)^2 + \lambda \sum_{j=1}^p |\beta_j| \right)$$

ただし、 β_j は係数ベクトル β のj成分を表し、この絶対値をすべて足し合わせたものをL1ノルムと呼んでいる。最小二乗法に正則化項を足すだけで説明変数のうち一部の係数がゼロとなり変数の推定と変数選択を同時に行うことができるのである(廣瀬, 2016)。

(2) 監査実務への応用


lassoを用いれば、各科目ごとに関連がありそうな勘定科目だけを機械的に抽出し、予測モデルを構築することができる。勘定科目の変動額の予測にあたって他の科目の線形和としてモデルを表現することは理解がしやすい。たとえば、売掛金の変動額を従属変数としてlassoを用いて係数を推定すると、数百から数千にのぼる他の科目の変動額や期初残高のなかから売掛金と関連の高いものだけが機械的に抽出され、

$$\text{売掛金変動額} = \beta_0 + \beta_1 \text{買掛金変動額} + \beta_2 \text{月間売上} + \beta_3 \text{月間販売費} + \beta_4 \text{月初売掛金}$$

というような形で変数(勘定科目)が抽出されたとする。この推定結果から、こういった科目が売掛金と連動するか、またその度合などを理解することができる。これにより人間がこれまでに意識しておらず、踏み込んだ分析を行ってこなかった関連性が見つかるということも考えられる。

また、lassoを用いて科目ごとに月次・日次の変動額を予測することで、変動分析を精緻化することができる。たとえば、図表2の

〔図表2〕 lasso を用いて予測した売掛金の月次変動額



(注) 破線は lasso を用いて予測した売掛金の月次変動額、実線は売掛金の実際の月次変動額を示している。

ような形で売掛金の実際の月次変動額(実線)と lasso を用いて予測した月次変動額(破線)が推移していたとする。

科目間の関連性を大きく捉えてモデルが推定されるため、実際の変動額がモデルの予測値から乖離した場合には、売掛金に対して通常と異なる勘定科目が関連づけられたことが示唆される。単純に金額的に変動が大きい与否かで判断するよりも、他の勘定科目との関連性を考慮することで、イレギュラーな会計処理を抽出しやすくなる可能性がある。

2 機械学習を用いた仕訳の異常検知


(1) 仕訳のデータ化

機械学習のもう1つの活用例として、仕訳の異常検知の手法を検討しよう。機械学習を用いた異常検知自体は様々な研究がなされて

おり、クレジットカードの不正使用やシステム故障の検知などにおいてはすでに実用化が進んでいる。機械学習の適用にあたっては過去の事例と類似するものを抽出する教師あり学習と、与えられたデータの構造から異常なものを見つける教師なし学習があるが、本稿では過去の不正仕訳のデータベースの蓄積がなくとも適用可能な教師なし学習の手法を用いた仕訳の異常検知を紹介する。

著者たちの知る限りでは、仕訳データの異常検知を扱った会計学の学術的研究は存在しない。しかし、生命保険の不正な支払請求を分析対象としたものとして、Thihrungsri and Vasarhelyi (2011) がある。彼らは、支払請求の異常検知にクラスター分析(k-means法)を用いている。また保険会社や銀行の取引を対象にルールベースの異常検知を行って

〔図表3〕ベクトルとしての仕訳



いる研究も存在する (Kim and Vasarhelyi, 2012 ; Kim and Kogan, 2014)。

仕訳の異常検知を行うためには、①仕訳情報を機械学習が適用可能な形にデータ化し、②そのデータにフィットする異常検知の手法を探索する作業が必要になる。仕訳は複数の勘定科目から構成されるデータであるため、1つの仕訳を1つのデータとして表現する必要がある。

考えられる1つの方法は、仕訳をベクトルとして表現することである。あらかじめ用意した勘定科目の並びに従って、1つの仕訳で計上されている金額を並べ、その仕訳で用いられていない科目はゼロとすることでベクトルとして表わすことができる。たとえば、現金、売掛金、および売上の3科目しか用いない場合に、次のような仕訳が計上されたでしょう。

(現金)	100	(売上)	150
(売掛金)	50		

この場合仕訳は (100, 50, -150) というベ

クトルで表現できる。このベクトルに対して異常度を測定し、^{しきい}閾値を超える場合に異常として検知するのである。

仕訳の異常検知をイメージとして理解するために、現金、売掛金、および売上のベクトルを3次元でプロットしたのが図表3である。図表3では、複数の仕訳がプロットされているが、通常の売上の仕訳 (丸のマーク) が下の隅に固まっているのに対して、反対仕訳 (ひし形マーク) は売上・売掛金の符号が反対となるため、離れた位置にプロットされることが見て取れる。

また売上に対する現金・売掛金の計上の比率が異なる場合の仕訳 (ひし形マーク) も丸のマークから離れた位置にプロットされることがわかる。こういった他のパターンとは異なることから離れた位置にプロットされる仕訳を異常として識別するのである。

(2) 異常検知の手法

機械学習を用いた異常検知では、データの構造の把握に基づき異常度の定義を行い、こ

の異常度が閾値を超えるかどうかにより異常を判断することになる。データの構造をどう把握するかにより様々なアルゴリズムがあり、①統計的分布に基づく手法、②距離に基づく手法、または③密度に基づく手法がよく用いられている。以下では、仕訳データの異常検知に有効な手法を検討しよう。

統計的分布に基づく手法としてはホテリング理論がよく知られている。これは与えられたデータに基づき標本平均と標準偏差を計算し、観測値と標本平均の乖離を標準偏差で割ったもの（マハラノビス距離）の2乗を異常度とするものである。データの分布に正規分布を仮定しているため、分布が不規則で多数の類型が考えられる仕訳には当てはまりが悪いと考えられる。

こういった状況においては、距離に基づく手法がよく用いられる。代表的なものとしてk近傍法がよく知られており、これは観測値からk番目に近いデータまでの距離により異常度を測定するものである（kは1や2などの数値をあらかじめ決めておく）。外れ値は他のデータから乖離しているはずなので、k番目に近いデータとの距離が離れているものを異常とする。ただし仕訳データへの適用を考えた場合、データの密度が一樣ではないため、全域で妥当なkを決めるのは難しいという問題が生じる。

データの密度が一樣ではない場合に用いられる手法が密度に基づく手法であり、局所外れ値因子法（LOF法）がよく知られている。観測値から最も近いデータ（最近傍点）までの距離と、その最近傍点から最も近いデータまでの距離の比を見ることで、密度が近傍に比べて低くなるような点を異常と定義する方

法である（なお、観測値と最近傍点だけの比較ではなくk個の近傍点を用いた距離の比の平均という形に拡張できる）。したがって、仕訳をベクトルとして表現し、LOF法を利用して異常検知を行うことは1つの有効な方法と考えられる。

ただし、実際の運用の際には課題も存在する。監査実務において検討する科目数は、数百、数千にのぼるため、ベクトルの次元（羅列された数字の個数）が非常に多くなる。このような場合、データ間の距離が互いに等しくなることで異常検知が難しくなる、いわゆる「次元の呪い」と呼ばれる現象が発生する。そのため、高次元空間における異常検知手法や、次元を何らかの形で落としてから異常検知を行うといった工夫が必要となる。

(3) 監査実務への応用

これまで会計士が設定していた「異常な仕訳」の定義や抽出ルールを機械学習による異常検知により自動的に決定することで、今まで想定していなかったパターンの不正などを見つけられる可能性がある。もっとも、教師なし学習は過去の不正仕訳のデータベースの蓄積がなくとも適用が可能であるという利点がある一方で、アルゴリズムの妥当性の検証が機械的にできないという難点がある。実際に不正があった仕訳を対象に検証するといった作業を行い、アルゴリズムの改良や選択を行う必要があるだろう。

《おわりに》

本稿では、監査における機械学習を中心とするAI活用の取組みについて、不正会計の早期発見という観点から、実務への適用可能

性について検討した。監査における AI の活用は大きな可能性を秘めていることが期待される。すでに、実務ではマクロレベルの不正会計予測モデルを構築し、品質管理目的のスクリーニング・ツールとして活用が始まっている。本稿では、マクロレベルとミクロレベルの取組みを紹介したが、将来的にはデータベースの拡充や統一化によって、両アプローチを統合したシステムの開発も進むであろう。

ただし、ブラックボックスになりがちな AI 技術に依存しすぎることは注意が必要である。アルゴリズムが複雑になると、インプット要素に基づく結果の解釈が困難になり、なぜ不正会計の疑義が高いのか、ということを具体的な証拠に基づいて説明することが難しくなる。そのため、これまでの監査実務で得られてきた知見と組み合わせて、不正を見抜く力を高めることが最も重要な課題となる。

【参考文献】

- Beneish, M. D. (1999) "The detection of earnings manipulation," *Financial Analysts Journal*, Vol. 55, No. 5, pp. 24-36.
- Dechow, P. M., W. Ge, C. R. Larson, and R. G. Sloan (2011) "Predicting material accounting misstatements," *Contemporary Accounting Research*, Vol. 28, No. 1, pp. 17-82.
- Dzeng, S. C. (1994) "A comparison of analytical procedure expectation models using both aggregate and disaggregate data," *Auditing: A Journal of Practice & Theory*, Vol. 13, No. 2, pp. 1-24.
- Kim, Y. and M. A. Vasarhelyi (2012) "A model to detect potentially fraudulent/abnormal wires of an insurance company: An unsupervised rule-based approach," *Journal of Emerging Technologies in Accounting*, Vol. 9, No. 1, pp. 95-110.
- Kim, Y. and A. Kogan (2014) "Development of an anomaly detection model for a bank's transitory account system," *Journal of Information Systems*, Vol. 28, No. 1, pp. 145-165.
- Kirkos, E., C. Spathis, and Y. Manolopoulos (2007) "Data mining techniques for the detection of fraudulent financial statements," *Expert Systems with Applications*, Vol. 32, No. 4, pp. 995-1003.
- Kogan, A., M. G. Alles, M. A. Vasarhelyi, and J. Wu (2014) "Design and evaluation of a continuous data level auditing system," *Auditing: A Journal of Practice & Theory*, Vol. 33, No. 4, pp. 221-245.
- Ravisankar, P., V. Ravi, G. R. Rao, and I. Bose (2011) "Detection of financial statement fraud and feature selection using data mining techniques," *Decision Support Systems*, Vol. 50, No. 2, pp. 491-500.
- Song, M., N. Oshiro, and A. Shuto (2016) "Predicting accounting fraud: Evidence from Japan" *The Japanese Accounting Review*, Vol. 6, pp. 17-63.
- Thirungsri, S., and M. A. Vasarhelyi (2011) "Cluster analysis for anomaly detection in accounting data: An audit approach," *International Journal of Digital Accounting Research*, Vol. 11, pp. 69-84.
- West, J. and M. Bhattacharya (2015) "Intelligent financial fraud detection: A comprehensive review," *Computers & Security*, Vol. 57, pp. 47-66.
- 小川勤 (2016) 「監査業務:『試査』から再び『精査』の時代へ」『企業会計』第68巻第7号, 37-45頁。
- 首藤昭信 (2010) 『日本企業の利益調整』中央経済社。
- 首藤昭信・大城直人・宋明子 (2016) 「実証研究から読み解く不正会計予測の最新モデル」『企業会計』第68巻第6号, 66-74頁。
- 廣瀬慧 (2016) 「スパースモデリングとモデル選択」『電子情報通信学会誌』第99巻第5号, 392-399頁。
- 藤田勉 (2017) 「金融に革新が起こる! FinTechの基礎知識」『企業会計』第69巻第6号, 16-23頁。