

卸売業における機械学習を用いた 不正リスクの評価

田中奎帆

慶応義塾大学経済学部 長倉大輔研究会 4年

2022年1月

概要

本稿では日本の上場企業について過去の不正会計をもとに、高い精度で不正リスクが評価できるモデルを作成することを目的とし、卸売業を対象として分析を行った。高い精度で不正リスクが評価できるモデルが作成できれば固有リスクの評価の精度が上がり、監査資源の割当に有用な情報となる。手法としては不正が起きやすい主な勘定科目として売上高・売上原価・営業債権・営業債務・棚卸資産・現金及び預金の6つを選定し、全ての組み合わせ15通りについて、2つの勘定科目の距離を相関とデータの位置関係による効果を考慮できるマハラノビス距離を計算した。計算したマハラノビス距離を特徴量として使用し、k-meanによるクラスタリングを行ったが、不正データを識別することが出来なかった。不正による金額の変動より会社ごとの勘定科目の傾向の違いの影響の方が大きいこと及び勘定科目の集計が難しいことが原因である。本稿では卸売業という括りで分析を行ったが、今後の改善点として範囲を競合他社等の狭い範囲に絞り、会社ごとの勘定科目の傾向の違いの影響をなるべく小さくすることが考えられる。

1. 序論

1.1 研究背景

監査基準委員会報告書 200 によれば、財務諸表監査の目的は財務諸表の適正性について意見を表明することであり、不正を発見することを直接的な目的とはしていない。しかし、東芝やオリンパスなどのディスクロージャー制度を揺るがすような不適切会計が発覚し、公認会計士による監査が有効に機能していないのではないかとの社会的な批判が強まった。近年、投資家の会計士に対する不正発見、摘発のニーズは高まっている。

このような投資家の期待に応えるべく、監査法人では監査の質を高めることに注力している。会計士協会の調査によれば、一社あたりの平均監査時間は年々増加している。その一方で、監査経験のある人を新規雇用することが難しいということから監査法人内では人手不足となっており、監査の質向上とともに効率化も求められている。

人員や時間等について制約を受けることから現在監査はリスク・アプローチに基づいて実施している。リスク・アプローチについて簡単に説明する。監査では監査人が財務諸表の重要な虚偽の表示を看過して、誤った意見を形成する可能性である監査リスクを合理的な水準まで低く抑えることが目的となる。監査リスクは仮に企業に内部統制が存在しなかった場合に重要な虚偽表示がなされるリスクである固有リスク、重要な虚偽表示が企業の内部統制によって防止されない可能性である統制リスク、企業の内部統制によって防止されなかった重要な虚偽表示について監査人が監査を実施しても発見されない可能性である発見リスクの3つの掛け算からなる。リスク・アプローチに基づく監査とは、監査人側で変化させることが出来ない固有リスク、統制リスクが高い事項、すなわち虚偽表示や不正が発生しやすい等のリスクが高い事項に重点的に監査資源（人員及び時間等）を充てることで、発見リスクを低く抑えるという考え方である。

固有リスクについて、現在は過去の監査人の経験から評価しているが、高い精度で不正検知が可能なモデルが作成できれば固有リスクの評価の精度が上がり、監査資源の割当に有用な情報となると考えられる。本稿では日本の上場企業について過去の不正会計をもとに、不正検知が可能なモデルを作成し、固有リスクの評価に資することを目的とする。次節で詳しく紹介するが先行研究では全ての上場企業に適用可能なモデルを作成しようとしている。しかし、業界によって財務諸表や損益計算書の特徴は異なり、また不正がおこりやすい勘定科目も異なると考えられる。本稿では過去の不正の傾向から特定の業界に絞り、特定の業界のみで適用可能な不正検知モデルを作成する

1.2 先行研究

公開財務情報を利用した機械学習による監査リスク分析手法に関する研究として細尾・倉橋(2020)がある。本研究では、監査リスクを評価する新たな方法として公開情報から得られる財務数値に、機械学習の手法等を適用することにより、会社の財務数値の中からリスクが高い可能性がある数値を少ないコストでかつ機械的に判別する方法を検討している。具体的には、研究対象のデータとして、多くの訂正報告書が提出されている東芝の財務データを採用し、暫定的に訂正対象となった財務数値をエラーデータ、訂正後ないし訂正なしの財務数値を正常なデータとして、実証研究を行っている。主要な勘定科目として、売上、売上原価、販管費、棚卸資産、営業債権、営業債務の6科目を分析対象として、各四半期の2つの勘定科目の組合せ15通りについてマハラノビス距離を算定し、教師なし学習による分析としてクラスタリングによる分析を行った結果、監査リスクを評価する手法として有用であると論じている。

公開情報を利用した機械学習の研究は他にも行われており、機械学習手法を用いた勘定科目レベルの異常検知の研究がある。宇宿・近藤・白木・眞田・須崎・宮川(2021)は、本邦上場企業5663社の2005年1月から2018年10月までの期間について、不正会計イベントを対象とした勘定科目レベルでの異常検知(不正検知)を行った。手法としては貸借対照表、損益計算書、キャッシュフロー計算書に含まれる合計399種類の科目情報を使い、スパースモデリング手法(graphical lasso)を用いた分析をすることで異常検知を試みている。スパースモデリング手法とは教師無し学習手法の一種であり、変数間の偏相関関係の推定を、次元圧縮を行いつつ実施するものである。結果として、実務的な観点から十分な検知精度を達成したほか、スパース化による検知精度の改善も図られていることが確認できたと論じている。

2. 本論

2.1 分析手法

不正には大きく分けて資産の流用によるものと粉飾決算によるものの2種類がある。日本公認会計士協会による2021年の上場会社等における会計不正の動向調査によれば、「一般的に、資産の流用による影響額よりも、粉飾決算による影響額の方が多額になる。そのため、上場会社等が適時開示基準にのっとって公表する数は、粉飾決算の方が多くなると考えられる。」とある。実際に2021年3月期においては、公表された会計不正のうち77.1%が粉飾決算となっている。本稿では粉飾決算の方が多額であること、また有価証券報告書データから分析をおこなうことから粉飾決算の不正を検知することを目的とする。

序論に記載した通り、本稿では特定の業界に絞ることで不正検知の精度をあげるという手法をとるため、どの業界に着目するかが問題となる。日本公認会計士協会による調査書の中では、業種別の会計不正についても調査しており、2017年3月期から2021年3月期において、会計不正の発覚の事実を公表した上場会社等159社の会計不正のうち、会計不正が行われた事業が判明しているものを業種別に分類している。この結果、「サービス業が22社（構成比13.8%）で最多であり、次いで卸売業が19社（構成比11.9%）、電気機器が18社（同11.3%）、情報・通信業が14社（同10.1%）」となっている。本稿では会計不正件数が比較的多く、また不正のパターンが比較的類似している卸売業に限定して不正検知モデルを作成する。

卸売業とは、メーカーと小売業の間に位置し、メーカーより商品を仕入れ、小売業へと商品を提供する業種である。メーカーが数百や数千を超える小売業者へ直接製品を卸すとすると、かなりの時間や手間・コストがかかるため、卸売業者が小売業者に代わりまとまった量で商品を仕入れ・保管し、必要な時に必要な量を小売業へ納品する。卸売業の会計不正では複数の取引先と結託して外部証憑を偽造し、架空仕入・架空売上を計上、それが常態化し循環取引に発展するケースが多いと考えられる。架空取引のため物の動きはないものの資金循環はされ、決済も通常通り行われるため発見が難しい一方、不正の関係者が多く損失額が多額になりやすいという特徴がある。特にリスクが高いのが直送取引である。直送取引とは仕入先であるメーカーから販売先の小売業者へ直接商品を送付してもらう取引のことである。直送取引では卸売業者の倉庫を介しないので物の動きが見えづらく、架空仕入・架空売上のリスクが高い。本稿ではこのような特徴を持つ卸売業について、勘定科目の変動からリスクを識別できないか検討していく。

分析する対象は決まったが、次にどのように分析するかについて述べる。細尾、倉橋(2020)による先行研究と同様に、不正リスクが高まっているのは①前年同期比等による残高の大幅な変動、②他の勘定科目との相関の変化、このいずれかあるいは両方があると考え、ユークリッドの距離に相関とデータの位置関係による効果を足し引きした距離概念であるマハ

ラノビス距離を金額の変動と相関の変化をまとめて扱うことができる変数として用いる。マハラノビス距離を特徴量として使用し、機械学習による分析を行う。

2.2 使用したデータ

日本の上場企業の開示情報、具体的には EDINET API を通じてダウンロードしたデータを用いる。EDINET API では開示情報である有価証券報告書をダウンロード出来るが、有価証券報告書が開示されるのは受理した日から5年を経過する日までである。そのため、使用したデータはダウンロード日の2022年1月9日から5年前までの期間において提出された有価証券報告書である。ダウンロードした有価証券報告書から分析で使用する勘定科目を抽出する。また、前節で述べたように本稿では卸売業に限定して分析を行う。卸売業の企業の選定にあたっては、SBI証券のスクリーニング機能を使用した。

作成したモデルの評価にあたっては使用した有価証券報告書データに不正があったか否かの情報が必要となる。有価証券報告書の虚偽記載で金融庁の課徴金勧告の対象となったもの及び不適切会計により第三者委員会の調査が行われ、訂正有価証券報告書が開示されたものを不正があったデータとする。このようなデータについては、訂正前のデータのみを不正があったデータとして使用する。

不正は起こる件数が少ないため、不正があったデータの数と不正が無かったデータの数に偏りが生じている。このように目的変数の分布に大きな偏りがあるデータのことを不均衡データといい、モデル評価を正答率で行うと全てのデータについて不正が無かったと判断するだけで精度が高いモデルであると言える。しかし、モデルの目的は不正リスクが高い項目を検知することであり、正答率が低くとも不正があったものについては全て不正があったと判断することが目的に敵う。よって、本稿のモデルはまず不正があったものは全て不正と判定でき、その上で正答率になるべく高いモデル（高い精度で不正がなかったものを不正がなかったと判断できるモデル）を作成することを目標とする。

上述の通り、不正があったデータの数は不正が無かったデータの数に比べて極端に少ないため、卸売業においてダウンロード期間（2017年1月10日～2022年1月9日）外で不正があったデータを追加している。以上より、不正があったデータ26個、不正が無かったデータ801個、合計で827個のデータを使用し分析を行った。

2.3 勘定科目の選定

分析手法の節で記載した通り、本稿ではマハラノビス距離を特徴量として使用する。マハラノビス距離は2つの勘定科目の距離を相関とデータの位置関係による効果を考慮して計算するものであり、距離が遠いほど異常の可能性が高くなるが、ここでどの勘定科目を選ぶかが問題となる。勘定科目は企業によって大きく異なり、また勘定科目を全て選ぶと計算量

が大きくなりすぎるためだ。勘定科目を選ぶ上ではどんな不正がありうるかを考える必要がある。

日本公認会計士協会による調査書の中では、粉飾決算について手口別にも調査しており、「2021年3月期においては、公表された粉飾決算のうち45.9%が売上の過大計上、18.9%が経費の繰延べ、同じく18.9%が架空仕入・原価操作、8.1%が在庫の過大計上」となっている。このことから発生件数の多い上記4つの不正に対応及び2.1の分析手法で述べたような卸売業の特徴に対応した上でマハラノビス距離を計算する勘定科目を選んでいく。勘定科目の選定理由については以下の図表2.1にまとめた。

図表 2.1 勘定科目の選定理由


特徴量名	説明
売上高	架空売上などで不正が一番起こりやすい勘定科目である 卸売業では外部の取引先と共謀して架空売上を計上する不正が多く、売上高の変動及び営業債権などの他の勘定科目との関係により不正リスクを識別する
売上原価	架空仕入・原価操作で不正が起こりやすい勘定科目である 架空売上を計上する場合、架空仕入によって利益率が調整されることが多いが、利益率が大きく変動している場合もあるため、売上高との関係で不正リスクを識別出来る可能性がある また、営業債務などとの関係で不正リスクを識別出来る可能性がある
営業債権	架空売上が計上されている場合、架空売上に係る営業債権について取引先からの入金が見られないことで売上高に比して営業債権が過大になるケースがある よって、売上高などとの関係で不正リスクを識別出来る可能性がある
営業債務	営業債務が増加していると取引先への支払いが滞っており資金繰りに窮している可能性があり、そのような場合には不正リスクが高まっている また、売上高・売上原価などとの関係で不正リスクを識別出来る可能性がある
棚卸資産	在庫の過大計上で不正が起こりやすい勘定科目である。計上している棚卸資産について実査等で実在性を確かめると、存在しないケースや不良在庫が大量に存在するケースがある 売上高などとの関係で不正リスクを識別出来る可能性がある
現金及び預金	現金及び預金が極端に少ないと金繰りに窮している可能性があり、そのような場合には不正リスクが高まっている また、営業債権が増加している一方、現金及び預金が減少している場合には営業債権の回収が出来ておらず、架空売上のリスクが高い よって、売上高・営業債権などとの関係で不正リスクを識別出来る可能性がある

2.4 卸売業全体のクラスタリングによる分析

前節で選定した6つの勘定科目から、2つの勘定科目の組み合わせ15通りについてマハラノビス距離を計算し、特徴量として用いる。不正があったデータの数は不正が無かったデ


ータの数に比べて極端に少ないため、教師なし学習の一つであるクラスタリングを用いる。計算したマハラノビス距離 15 個をそのまま特徴量として用いることも出来るが、その場合グラフで図示することが難しいため、マハラノビス距離 15 個について主成分分析による次元削減を行い 2 個の変数に減らす。次元削減の結果、一つ目の主成分で分散の 91%、二つ目の主成分で 4%を説明でき、合計 95%を二つの成分で説明している。一つ目の主成分 PC1 を y 軸、二つ目の主成分 PC2 を x 軸に取ったグラフが以下の図表 2.2 である。不正があったデータが橙色、不正が無かったデータが青色でプロットされている。

図表 2.2 卸売業全体のデータの分布



この図を見て分かる通り不正があったデータはある程度一部にまとまっているものの、他に平均から大きく外れているデータがあり、このデータについて分類を行っても不正があったデータは識別できないと考えられる。実際に k-mean によるクラスタリングを行うと、次ページの図表 2.3 のような結果となった。3つのクラスターに分類し、3色に色分けしている。図表を見て分かるように不正のあるデータは全て Cluster 0 に分類されてしまい、Cluster 1, 2 に分類されているデータは不正以外の原因で平均から外れているデータとなっている。Cluster 0 への分類数が一番多いため、Cluster 1, 2 に分類されているデータを平均から外れているデータとして不正データ、それ以外を不正が無かったデータと識別するのが妥当であるが、実際に不正があったデータ 26 個を全て不正が無かったと識別してしまう。

図表 2.3 卸売業全体の k-mean によるクラスタリング結果



このような結果になった原因として2つのことが考えられる。1つ目は会社ごとに勘定科目の傾向が大きく異なるということだ。本稿では卸売業に絞ることで比較的勘定科目の傾向が似ているデータを集めているが、それでも傾向が大きく異なっていた。一般的に卸売業は他の者から仕入れた商品を小売業者や他の卸売業者に販売する事業だが、スーパーで売られているような商品を販売する業者から太陽光発電施設を販売する業者までおり、これらの業者では有価証券報告書の傾向が異なる。また、主たる事業として卸売業を営んでいる会社でも別の事業、例えば不動産業も営んでいる会社もあった。別の事業も営んでいる場合には卸売業だけを営んでいる会社と比べて、傾向が大きく異なる。このように会社ごとの傾向による変動が不正による変動よりも影響が大きいため、不正データを識別できなかったと考えられる。

2つ目は勘定科目の集計が難しく、集計の問題で平均から外れているデータとなっている可能性があるということだ。例えば、勘定科目として営業債権を用いているが、集計時には売掛金という名前が入っている項目のみを自動で集計している。会社によっては売掛金及び受取手形という勘定科目で開示したり、売掛金と受取手形を分けて開示したりしており、このような集計方法では問題が生じる。また、主に電子記録債権で取引している会社もあり、このような場合電子記録債権の金額の方が大きいのが、営業債権として集計されず金額に歪みが出る。このように集計の歪みが不正による変動よりも影響が大きいため、不正データを識別できなかったと考えられる。

以上の2点より不正データを識別できなかったと考えられる。

3. まとめと課題

本稿では不正が起きやすい主な勘定科目として売上高・売上原価・営業債権・営業債務・棚卸資産・現金及び預金の 6 つを選定し、マハラノビス距離を計算して特徴量として使用し、k-mean によるクラスタリングを行ったが、不正データを識別することが出来なかった。前章で述べたように原因は 2 つある。1 つ目は不正による金額の変動より会社ごとの勘定科目の傾向の違いの影響の方が大きいことである。不正として例えば架空売上の計上がある。どれだけ架空売上が計上されるかということについて、売上の半分が架空売上であった事例もあるが、実際の売上を 1 割程度かさませる程度のことが多い。金額がいくらであっても架空売上はやってはいけないことであるが、機械学習で不正を識別するという観点からすると、このような不正による勘定科目の歪みは識別できないほど小さいという問題がある。一方、扱う商品が違うこと等による会社ごとの勘定科目の傾向の違いはとても大きく、前章の分析ではその違いでデータが分類されてしまった。今後の改善点として範囲を競合他社等の狭い範囲に絞り、会社ごとの勘定科目の傾向の違いの影響をなるべく小さくすることが考えられる。

不正データを識別することが出来なかった原因の 2 つ目は勘定科目の集計が難しいことである。前章で述べたように今回のデータの集計では集計が不十分であった。今後の改善点として集計する勘定科目をしっかりと定義することが必要である。例えば、今回は営業債権として売掛金という名前が入っている勘定科目を集計したが、営業債権を売掛金・受取手形・電子記録債権の名前が入っているもの、また実際に財務諸表を見て他に該当するものがないかを確認して集計するべきであった。この集計の問題として確認するのに手間がかかること及び正確に集計するコードを書くことが難しいことがあるが、正確に分類するためにはデータの正確性が必要であり、時間をかけて集計する必要がある。

以上が今後の課題と改善点であるが、上述の通り不正による勘定科目の歪みは識別できないほど小さいことも多く、今回の分析を通じて全ての不正を開示情報だけから機械学習で識別するのは不可能だと感じた。さらに、結論を導き出すまでの過程がブラックボックスとなっている機械学習の結果を用いて監査意見を表明することは難しいという問題もある。実務上は現在の監査基準に従って人の手で行われている監査と機械による不正リスクを識別できるモデルを上手く融合させることが大切になる。

参考文献

- 日本公認会計士協会, 「監査基準委員会報告書 200 財務諸表監査における総括的な目的」, 2019 年, https://jicpa.or.jp/specialized_field/2-24-200-2c-20190821a.pdf
- 日本公認会計士協会, 「監査実施状況調査 (2020 年度)」, 2020 年, https://jicpa.or.jp/specialized_field/files/0-0-0-2-20211209_1.pdf
- 細尾, 倉橋 (2020) 「公開財務情報を利用した機械学習による監査リスク分析手法に関する研究」, 経営課題に AI を! ビジネスインフォマティクス研究会 (第 15 回), http://sig-bi.jp/doc/15th_SIG-BI_2020/15th_SIG-BI_2020_paper_1.pdf
- 宇宿, 近藤, 白木, 眞田, 須崎, 宮川 (2021) 「機械学習手法を用いた勘定科目レベルの異常検知」, 独立行政法人経済産業研究所 デイスクッション・ペーパー, <https://www.rieti.go.jp/jp/publications/dp/21j049.pdf>
- 日本公認会計士協会, 「上場会社等における会計不正の動向 (2021 年版)」, 2021 年, https://jicpa.or.jp/specialized_field/files/2-3-5-2-20210729.pdf
- 金融庁, 「EDINET」, 2022 年, <https://disclosure.edinet-fsa.go.jp/EKW0EZ0015.html>
- SBI 証券, 2022 年, https://site1.sbisec.co.jp/ETGate/?_ControllID=WPLEThmR001Control&_PageID=DefaultPID&_DataStoreID=DSWPLEThmR001Control&_ActionID=DefaultAID&getFlg=on
- Sebastian Rachka, Vahid Mirjalili 著, 福島真太郎訳, 『第二版 Python 機械学習プログラミング』, 株式会社インプレス, 2019 年