

機械学習を用いた自動入金消込による会計業務支援

Automatic Bank Reconciliation Using Machine Learning

加藤 直^{*1}

Nao Kato

馬場 雪乃^{*1}

Yukino Baba

鹿島 久嗣^{*1}

Hisashi Kashima

横路 隆^{*2}

Ryu Yokoji

^{*1}京都大学大学院 情報学研究科 知能情報学専攻

Department of Intelligence Science and Technology, Graduate School of Informatics, Kyoto University

^{*2}free株式会社

free K.K.

All companies need to conduct accounting work to understand the financial condition. Since the accounting operation does not directly contribute to the business revenue, there is a motivation to let the accounting works take as little time as possible. Particularly in recent years, accounting data has been accumulated due to the spread of cloud accounting services, and automation of accounting work by machine learning is becoming feasible. There is a type of accounting work called *reconciliation*, a work of matching invoice data and payment data. In this research, we try to improve the efficiency of reconciliation by predicting invoice data to be matched against each payment data by machine learning. We confirm that the precision of the prediction by the proposed classifiers are superior to the accuracy of a method without using machine learning, and we show the usefulness of accounting work support by prediction using machine learning.

1. はじめに

多くの企業は、内部で経営状況を把握し社外のステークホルダーに報告するため、経理・会計業務を行う。経理・会計業務は、取引先毎に請求書の回収状況を正確に把握し、リスク管理を行うという点でも経営に不可欠な作業である。企業は日々大量の金銭取引を行うため、経理・会計業務の作業量は膨大である。一方で、経理作業は専門家の知識と経験に裏打ちされた単純作業という側面が強く、自動化による経理・会計業務の効率化が期待できる。特に近年ではクラウド会計サービスの普及により種々の会計データが民間企業に蓄積され活用できるようになったことで、機械学習による会計業務の自動化が現実味を帯びてきている。

会計業務の1つに入金消込処理がある。入金消込処理とは、企業の請求書とその請求書に対応する入金データをマッチングさせ、売掛金の回収が請求通りに成されているか確認し入金の内訳管理を行う作業である。請求書や入金データは数が非常に多く手作業では労力がかかるために作業の自動化が望まれる。しかし、締切日と大幅に異なる日付に振り込まれる可能性、振込手数料や分割払いにより金額のズレが発生する可能性、大量の同一金額の請求書と入金データをマッチングさせる可能性が存在し、入金がどの請求書に紐づく入金なのか一意に識別できる仕組みが一般的にないために単純な処理による自動化は難しい。銀行による入金照合サービスも存在するが、利用料金が必要であり利用者は限られる。

本研究では機械学習を用いた会計業務支援の実現可能性を検証するために入金消込処理の自動化を図る。そのために、ある1つの請求書データと入金データについてそのペアがマッチングするか予測する問題と、それぞれのデータペアのマッチング予測を元に全ての請求書データ及び入金データのマッチング組み合わせを予測する問題の2つの問題を定義する。前者の問題を解決する手法としてナイーブベイズ分類器を用いる手法とサポートベクターマシン(SVM)分類器を用いる手法を提案し、機械学習を用いない単純な手法と比較しその有効性を検証

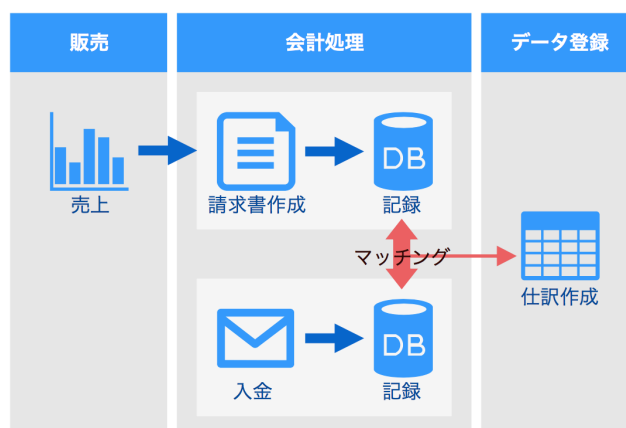


図1: 入金消込処理の概略図

する。また後者の問題を解決する手法として、異なる入金データが同一の請求書データを選択しないように全体のマッチング候補を決定する方法を提案する。各入金データに対して独立に最もマッチング確率の高い請求書データをマッチング対象として予測する手法と比較する。

実験ではクラウド会計サービスで作成された実データを匿名化し使用した。実際の請求書データ及び入金データでは複数の請求書データに対して複数の入金データがマッチングするデータが存在するが、本研究では1つの請求書データに対して1つの入金データのみがマッチングするもの限定して実験を行なった。どちらの問題においても、機械学習を用いない単純な手法の精度と比べて提案した分類器による予測の精度が優れていることを確認し、入金消込処理の支援に対する機械学習の有用性について確認する。

会計データに対して機械学習による予測を用いている既存研究の多くは、企業の経営情報からの破産予測 [Odom 90] を対象にしている。本研究により、会計データに対する業務支援の新たな可能性を示唆する。

連絡先: 加藤 直, 京都大学大学院 情報学研究科 知能情報学専攻, knao.aq@ml.ist.i.kyoto-u.ac.jp

2. 問題設定

本研究では入金消込処理問題の解決を実現する手段として、ある1つの入金データと1つの請求書データについてそのデータペアがマッチングするかどうか予測する(単体マッチング予測)問題と、各データペアのマッチング予測を元に全体のマッチング組み合わせを予測する(全体マッチング予測)問題の2つの手順による解決方法を提案する。

2.1 単体マッチング予測

単体マッチング予測問題は、入力として請求書データと入金データが与えられた際に2つのデータがマッチングするかどうか予測する予測器を学習することで解決する。単体マッチング予測問題は、以下に述べる教師付き学習問題として定式化される。請求書データ集合 \mathcal{X} と入金データ集合 \mathcal{Y} が与えられているとする。請求書データ $x_i \in \mathcal{X}$ は、 $x_i = (a_i, p_i, d_i)$ で表されるとする。 a_i は請求金額、 p_i は発行日、 d_i は締切日である。入金データ $y_j \in \mathcal{Y}$ は、 $y_j = (a_j, p_j)$ で表されるとする。 a_j は支払い金額、 p_j は支払日である。我々の目標は、 \mathcal{X}, \mathcal{Y} を用いて、マッチングを予測する分類器 $f: \mathcal{X} \times \mathcal{Y} \rightarrow \{0, 1\}$ を学習することである。

2.2 全体マッチング予測

マッチング未知の請求書データ集合 \mathcal{X}^* と入金データ集合 \mathcal{Y}^* が与えられているとする。分類器 f により、 $x_i \in \mathcal{X}^*$ と $y_j \in \mathcal{Y}^*$ のマッチング度 q_{ij} が与えられるとする。全体マッチング問題は、これらの入力データが与えられたときに、全体のマッチング集合 \mathcal{M} を予測する問題である。ただし m_{ij} は0または1の値をとり、値が1であれば $x_i \in \mathcal{X}^*$ と $y_j \in \mathcal{Y}^*$ がマッチングすることを表す。また、各入金データ y_j がそれぞれ1件の請求書データのみとマッチングするという条件の下で予測する。すなわち、 $\sum_j m_{ij} = 1$ の条件の下で予測する。

3. 予測手法

2章にて定義した2つの問題を解決する予測手法をそれぞれ提案する。

3.1 単体マッチング予測の手法

請求書データと入金データのマッチングの予測には、それぞれの日付や金額よりも日付差や金額差が有効だと考えた。そこで我々は、請求書データ x_i と入金データ y_j のペア (x_i, y_j) の特徴ベクトル $z_{ij} = (p_j - p_i, d_i - p_j, a_i - a_j)$ を設計し、分類器の学習に用いる。分類器はナイーブベイズを用いた分類器とSVMを用いた分類器の2種類を用意する。なお比較手法として、金額差が0に近いものをマッチング対象と予測する手法(金額選択法)を用意する。

3.2 全体マッチング予測の手法

ナイーブベイズによる分類器及びSVMによる分類器によって得られた結果を元にデータ全体のマッチング組み合わせを予測する方法について述べる。

3.2.1 独立マッチング組み合わせ

全体のマッチング組み合わせを予測する最も簡単な手法として、各入金データに対して独立に、マッチングする確率が最も高い請求書データをマッチング対象として予測する手法を考える。本論文ではこの手法を独立マッチング組み合わせと呼ぶ。

3.2.2 割当マッチング組み合わせ

全体のマッチング組み合わせを予測する際に異なる入金データが同一の請求書データをマッチング対象と予測した場合、本

問題は全ての入金データと請求書データが1対1に対応しているため、必ず一方は正しくない予測である。そこで異なる入金データが同一の請求書データを選択しないようにマッチング候補を選択する方法を考える。これは一般に割り当て問題(Assignment Problem)として定義される。これは、2つのデータ集合 \mathcal{X}, \mathcal{Y} ($|\mathcal{X}| = |\mathcal{Y}|$) が与えられ、 $x_i \in \mathcal{X}, y_j \in \mathcal{Y}$ なる2つのデータペア (x_i, y_j) の全組み合わせについてコスト c_{ij} が設定されている際に、コストの合計が最小(または最大)になるように各々の x_i について対応する y_j を選択する問題である。本論文ではこの手法を割当マッチング組み合わせと呼ぶ。割り当て問題は最小費用流問題(Minimum Cost Flow Problem)へと帰着させて解くことが可能である[Burkard 2012]。

4. 評価実験

本実験ではデータセットのうち、1つの請求書に対して1つの入金データのみがマッチングする1対1型データを取り扱う。実際の利用シナリオに即したマッチング予測方法を2つ用意し、それぞれについて2種類の評価指標を用いて評価する。

4.1 データセット

本研究で扱うデータセットについて説明する。なお本データセットはクラウド会計ソフト freee で蓄積された10社分、21,122件の請求書・入金データを匿名化して実験に用いる。

● 請求書データ

企業では他社との契約が成立した際に依頼内容に基づいて請求書を発行する。その際に請求書データが作成され、企業のデータベースに格納される。請求書データには契約に関する情報が不足なく記載されている。各請求書データについて、本問題で用いる発行日、締切日、金額のほかに、以下の情報が提供されている。

- 請求書 ID ... 請求書データを一意に特定する。
- マッチング ID ... 入金データの中で同一の ID を持つデータとマッチングする。
- 取引先 ID ... 請求書を発行した先の会社を一意に特定する。

● 入金データ

請求を受けた取引会社が請求書に基づいて入金した際に作成される。入金データは銀行の振込情報をもとに自動で作成されることが多い。入金データには該当する振込の情報が不足なく記載されている。各入金データについて、本問題で用いる支払日、金額のほかに、以下の情報が提供されている。

- 入金 ID ... 入金データを一意に特定する。
- マッチング ID ... 請求書データの中で同一の ID を持つデータとマッチングする。
- 会社 ID ... 入金元の会社を一意に特定する。(取引先 ID と対応する)

4.2 表記揺れ問題

取引先 ID と会社 ID の一致性について、本来のデータセットではこれらの特徴量は ID ではなく会社名の文字列として保持されている。そのため誤入力や通称による表記揺れ問題が発生し、2つの文字列を簡単に一意に結びつけることはできない。表記揺れ問題については広く研究されているが[Bilenko 03, Ohtake 04]、本研究では単純化のためこれらの問題は解決されているもの

表 1: 単体マッチング予測の精度 (任意数マッチング)

分類器	正解率	適合率	再現率
ナイーブベイズ法	0.9690	0.7600	0.9100
SVM 法	0.9141	0.4885	0.9681
金額選択法	0.7331	0.2300	0.9580

と仮定し実験する。よってマッチングするかどうか予測する際には取引先 ID と会社 ID が一致するもののみを調べることとなる。

4.3 単体マッチング予測

本節では単体マッチング予測問題に対する予測方法と評価指標、及び実験結果・分析について述べる。

4.3.1 予測方法

実際に入金消込処理の作業を行う際に予測器を活用する方法として、マッチング済みでない全ての請求書データ群と入金データ群に対して予測器により全てのマッチングを一度に予測する方法と、各入金データについてそれとマッチングする請求書データを選択する際に予測器による予測結果を利用することで作業効率の向上を図る方法の 2 通りが考えられる。そこで、マッチングする確率が一定以上であるデータペアを無条件にマッチングするペアであると予測する (任意数マッチング) 方法と、各入金データに対してマッチングする確率が最大の請求書データ 1 件をマッチング候補と予測する (固定数マッチング) 方法の 2 つの予測方法により実験を行い、それぞれについて評価を行う。

4.3.2 評価指標

2 つの予測方法についてまず、すべてのテストデータに対する予測精度 (正解率、適合率、再現率) を算出することにより分類器の性能を比較する。次に各入金データに対してそれとマッチングする請求書データをマッチング候補に含む割合 (マッチングする請求書データをマッチング候補に含む入金データの数 / 入金データの数) を算出することにより分類器の性能を比較する。以降この割合を請求書含有率と呼ぶ。請求書含有率は、各入金データについてそれとマッチングする請求書データを選択する際に予測器による予測結果を利用することで作業効率の向上を図る、といった活用を行うとどの程度の効率化が見られるか検討するための指標である。

4.3.3 実験結果

それぞれの分類器について 2 つの予測方法により実験を行った結果を記す。まず初めに、任意数マッチングを行った際の予測精度を算出した結果について、提案した手法が共に金額選択法より予測精度が高く、及び正解率や適合率の面においてナイーブベイズ分類器の予測精度が高い結果となった (表 1)。

次にそれぞれの分類器について任意数マッチングを行った際の請求書含有率を算出した結果、及びある 1 つの入金データに対してそれとマッチングすると予測した請求書データの平均候補数について、請求書含有率は分類器により顕著な差は見られなかったが、平均候補数についてはナイーブベイズが最も少ない結果となった (表 2)。提案した予測器が精度を低下させることなくより少ない予測候補に絞れている。

固定数マッチングを行った場合の予測精度について、閾値以上のマッチング確率を持つ全てのデータペアを正例と予測するよりも、予測した正例数と負例数の比を実際の比に合わせる方が、正解率、適合率の面で精度が高くなる結果となった (表

表 2: 単体マッチング予測の請求書含有率

分類器	請求書含有率	平均候補数
ナイーブベイズ法	0.9100	1.1973
SVM 法	0.9681	1.9818
金額選択法	0.9580	4.1644

表 3: 単体マッチング予測の精度 (固定数マッチング)

分類器	正解率	適合率	再現率
ナイーブベイズ法	0.9845	0.9089	0.9089
SVM 法	0.9879	0.9267	0.9267
金額選択法	0.9531	0.7150	0.7150

3)。データペアの全組み合わせが負例に偏ることが原因であると考えられる。

また、固定数マッチングでマッチング候補を n 件とした場合の請求書含有率の推移について、提案した 2 つの手法ともに金額選択法と比べて高い精度で正例を予測できている (図 2)。

4.4 全体マッチング予測

本節では全体マッチング予測問題に対する予測方法と評価指標、及び実験結果・分析について述べる。

4.4.1 予測方法

全体マッチング予測問題については、マッチング済みでない全ての請求書データ群と入金データ群に対して予測器により全てのマッチングを一度に予測する活用方法のみを考える。予測方法として各入金データに対して請求書データ 1 件をマッチング候補と予測する方法をとる。請求書データの選択方法については、独立マッチング組み合わせによる方法と割当マッチング組み合わせによる方法をとる。

4.4.2 評価指標

全体マッチング予測問題では、全ての入金データのうちマッチング対象を正しく予測できた割合 (= 請求書含有率) について評価する。

4.4.3 実験結果

それぞれの分類器について全体マッチング予測を行った際の請求書含有率について、SVM 法と割当マッチング組み合わせによる予測が最も高い請求書含有率を示した (表 4)。割当マッチング組み合わせについては SVM 法では請求書含有率が向上したが、ナイーブベイズ法と金額選択法についてはわずかに精度が下がる結果となった。金額選択法についてはマッチングする確率として使用した値 (= 金額差) の大きさと本来のマッチング確率の大きさの相関性が高くないことが原因である。

4.5 分析

任意数マッチングについて、比較手法である金額選択法と比べて本研究にて用いたナイーブベイズ法・SVM 法の精度の方が高い結果となった。また SVM 法によるマッチング予測の正解率が 0.9141 であるのに対してナイーブベイズ法によるマッチング予測の正解率が 0.9690 と、SVM 法と比べてナイーブベイズ法の精度の方が高い結果となった。この結果より、特徴量として用いた日付差・締切日差・金額差の特徴間の相関性の高さよりも、各特徴量の分布の偏りのほうがマッチングを判別する特徴として重要であると考えられる。請求書含有率についてはナイーブベイズ法と比べて SVM 法の方がやや高くなった




図 2: マッチング確率上位 n 件の請求書データをマッチング候補とする場合の請求書含有率

表 4: 全体マッチング予測の請求書含有率

分類器	請求書含有率	
	独立マッチング	割当マッチング
ナイーブベイズ法	0.9027	0.8652
SVM 法	0.9267	0.9617
金額選択法	0.7151	0.7102

が、SVM 法はナイーブベイズ法よりも平均候補数が多く、一概に SVM 法の方が優れているとは言えない。

固定数マッチングにおいてはナイーブベイズ法と比べて SVM 法の精度の方が高くなった。このことから SVM 法では、ある入金データに対して各請求書データとマッチングするかどうか予測した際に、正例を含む全ての請求書データについてマッチング確率が閾値以下となる入金データが多くみられると考えられる。また、SVM 法においては割当マッチング組み合わせを用いた方が請求書含有率が高くなったが、ナイーブベイズ法と金額選択法では割当マッチング組み合わせを使用すると独立マッチング組み合わせと比べて請求書含有率が下がる結果となった。割当マッチング組み合わせの有意性については更なる実験を実施する必要がある。

結論として、入金消込処理を行う際にナイーブベイズ法を用いて各入金データについてマッチングする請求書データの候補を提示することで、平均 1.1973 件の請求書データを提示し、その中に 91.00% の確率で正しい請求書データを含むことができた。また、SVM 法と割当マッチング組み合わせを適用して全体のマッチングを予測することで 96.17% のデータを正しくマッチングさせることができた。どちらの問題においても金額差の最も近いものをマッチング対象であると予測する場合の精度と比べて提案した分類器による予測の精度が優れていることが確認でき、機械学習を用いた予測による会計業務支援の有用性が示された。

5. おわりに

本研究では会計業務の 1 つである入金消込処理に対して機械学習を用いた手法によるマッチング予測方法を提案することにより、機械学習による会計業務自動化の実現可能性の検証に

取り組んだ。入金消込処理問題では複数の請求書データと複数の入金データがマッチングする可能性が存在しているが、まず問題の単純化として 1 つの請求書データに対して 1 つの入金データが 1 対 1 に対応しているデータ群のみを扱い、マッチング対象を予測する分類器を 2 つ提案し実験を行った。実験では金額差の最も近いものをマッチング対象であると予測する場合と比べて、提案した分類器による予測の方が精度が優れていることを確認した。実際の予測について SVM 分類器と割当マッチング組み合わせを用いて 1 対 1 データ全体のマッチングを予測した場合に全体の 96.17% を正しく予測できることを示した。またナイーブベイズ分類器を用いてある入金データに対しそれとマッチングすると予測される請求書データ候補を予測することで、平均 1.1973 件のデータをマッチング候補として予測することで、91.00% の確率で予測したデータ内に正しい候補を含むことができることを示した。金額差の最も近いものをマッチング対象であると予測する場合の精度と比べて提案した分類器による予測の精度が優れていることが確認でき、機械学習を用いた予測による会計業務支援の有用性が示された。

また、今後考えられる研究課題としてあげられる課題は以下の通りである。実際の入金消込処理においては 1 対 1 データのみを扱うわけではないので、全体データに対する予測精度を向上させる必要がある。また取引会社名等の情報は ID でなく文字列で登録されていることが多くそこでは表記揺れの問題を解決しなければならない。会計データは会社毎に特徴が異なる可能性もあり、新しい会社に対して入金消込処理のマッチング予測を行う際にはその会社の会計データを元に学習を行う方がよいと思われる。そのためオンライン学習や定期的なバッチ学習により新しい会計情報を逐次学習しながら予測を行うアルゴリズムの実装が望まれる。

参考文献

- [Odom 90] Odom, M. D. and Sharda, R.: A neural network model for bankruptcy prediction, Proceedings of the International Joint Conference on Neural Networks, pp. 163–168 (1990).
- [Bilenko 03] Bilenko, M. and Mooney, R. J.: Adaptive duplicate detection using learnable string similarity measures, Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, pp. 39–48 (2003).
- [Singla 06] Singla, P. and Domingos, P.: Entity resolution with markov logic, Proceedings of the Sixth International Conference on Data Mining, pp. 572–582 (2006).
- [Burkard 2012] Burkard, R., Dell’Amico, M. and Martello, S.: Assignment problems: revised reprint, SIAM (2012).
- [Ohtake 04] Ohtake, K., Sekiguchi, Y. and Yamamoto, K.: Detecting transliterated orthographic variants via two similarity metrics, Proceedings of the Twentieth International Conference on Computational Linguistics, Association for Computational Linguistics, pp. 709–715 (2004).