

金融リテラシー調査からどのような金融
トラブルとの遭遇を予測できるか

鈴木 明宏
高橋 広雅
竹本 亨

Research Group of Economics and Management
No. 2024-E01
2024.3

Discussion Paper Series



**Faculty of Humanities and Social Sciences
Yamagata University
Yamagata, Japan**

金融リテラシー調査からどのような金融 トラブルとの遭遇を予測できるか

鈴木 明宏 (山形大学人文社会科学部)

高橋 広雅 (広島市立大学国際学部)

竹本 亨 (日本大学法学部)

1. はじめに

本稿ではまず、金融広報中央委員会の「金融リテラシー調査 (2016 年、2019 年、2022 年)」の個票データを使用して、金融リテラシーや行動バイアスおよび金融トラブルに遭ったかどうかに関する質問項目から金融トラブルの遭いやすさを予測するモデルを構築する。次に、我々はどのような金融トラブルにあったかについて独自にアンケート調査を行っている。金融リテラシー調査では金融トラブルの種類に関する質問項目は存在しない。そこで、我々は金融リテラシー調査の項目に加えて、遭遇したトラブルの種類も尋ねるアンケート (以降、「独自アンケート」と呼ぶ) を実施した。本稿ではこれらのデータを用いて、金融トラブルの種類別に上述のモデルの予測精度を評価する。このようにトラブルの種類を尋ねることで、金融リテラシー調査データから構築した予測モデルが、どのようなトラブルであれば遭遇することを予測できているのかを明らかにできる。

現在の日本では高齢化の進展による社会保障財政の膨張もあり、NISA や iDeCo など個人による資産形成が推奨されている。その結果、資産選択における自己責任が重くなり、国民の金融リテラシー向上に政府が取り組む必要があると考えられるようになった(春井, 2007)。一方で『消費生活年報 2021』によると、国民生活センターに寄せられた金融・保険に関する相談は 5 万 6 千件もあり、金融トラブルに遭遇する人が多いという現状がある。このような状況を改善するためには、金融トラブルに遭遇しやすい人の個人属性を明らかにすることで、その人たちに対する注意喚起を行うなどトラブルを未然に防止することが有効であろう。

金融トラブルと個人属性の関係について論じた研究として、家森・上山 (2018a)、家森・上山 (2018b)、鈴木・高橋・竹本 (2018)、鄭 (2021) がある。家森・上山 (2018a) は独自にアンケート調査を行い、金融リテラシーや個人特性と金融トラブルの経験との関係を調査している。また、家森・上山 (2018b) は同じアンケート調査を元に金融教育の経験と金融行動との関係を調査しており、その分析の中で金融教育の経験と金融トラブルの経験

との関係を調査している。鈴木・高橋・竹本 (2018) は 2016 年の金融リテラシー調査を用いて個人属性、特に行動バイアスと金融トラブル経験や金融行動との関連を調査した。鄭 (2021) は同じ金融リテラシー調査を用いているが、対象を学生と無職を除く 18~34 歳の 2,609 人に限定して金融トラブルに遭遇する人の要因を分析している。鄭 (2021) が分析対象を若年層に限定している理由は、金融トラブルを経験した時期と金融リテラシー調査への回答時点を近づけることで、金融リテラシーとトラブル遭遇の関係を明確にするためである。

このように、金融トラブルに遭遇する人の個人属性が明らかとなってきたため、予測システムの構築が可能となった。そこで本稿では、金融リテラシー調査を利用して金融トラブルに遭遇する可能性の高い人を予測するモデルを構築する。さらに、独自アンケートデータにその予測モデルを適用することによって、金融トラブル別に予測精度を明らかにする。それによって、金融リテラシー調査の設問項目から予測できる金融トラブルの種類がどのようなものかわかる。

金融リテラシー調査データは 3 年分で、計 8 万件もある。このような大量のデータから通常とは異なるデータ（ここでは金融トラブル経験者）を見つけることは「異常検知」と呼ばれる。近年、異常検知には機械学習の手法が用いられることが多く、本稿でもこの手法を用いて予測モデルを構築する。

本稿の以下の構成は、次の通りである。第 2 節では本稿で用いられるデータについて説明する。第 3 節では本稿での分析方法とその中で用いられる機械学習の手法について説明する。第 4 節では得られたモデルによって独自アンケートデータから得られる予測がどのような金融トラブルで予測精度が高いのかを考察する。そして、第 5 節で本稿の分析から得られる含意と今後の課題について述べる。

2. データ

2.1. 金融リテラシー調査

「金融リテラシー調査」は金融広報中央委員会により、日本人の金融リテラシーを調査する目的で行われる調査であり、これまで 2016 年、2019 年、2022 年の計 3 回実施されている。金融リテラシー調査のデータはインターネットによるアンケート調査で収集されており、そのサンプル数は 80,000 (2016 年が 25,000、2019 年が 25,000、2022 年が 30,000) と大規模な調査となっている。

この調査でも使われている「金融リテラシー」とは、お金や金融商品についての知識・判断力を指すもので、金融庁金融研究センターにより開催された金融経済教育研究会が「金融経済教育研究会報告書」の中で「生活スキルとして最低限身に付けるべき金融リテラシー」として示している。その内容は報告書を元に金融経済教育推進会議により作

成された「金融リテラシー・マップ」にまとめられているが、「家計管理」「生活設計」「金融知識及び金融経済事情の理解と適切な金融商品の利用選択」「外部の知見の適切な活用」の4分野に分かれている。

金融リテラシー調査には金融リテラシーに直接関連する設問 25 問以外にも、金融教育に対する考え方や、金融取引の状況、所得、保有資産、行動バイアス¹、学歴や居住地などの個人特性など、設問数は大問で 52 (2022 年の場合) ある。

特に、本稿との関係で重要な設問として「あなたは、振り込み詐欺や多重債務などの金融トラブルを経験したことがありますか。」という、金融トラブルの遭遇経験を尋ねたものが存在する。この設問は「はい」か「いいえ」の二択となっており、「はい」と回答した人を本稿では金融トラブルに遭遇した人と定義する。

2.2. 独自アンケート

上記のように、金融リテラシー調査は金融トラブルの遭遇経験を尋ねているが、金融トラブルの詳細は不明である。そこで、本稿の目的のために、我々は金融リテラシー調査の設問に加えて、金融トラブルの遭遇経験がある人に対しトラブルの詳細を尋ねる独自アンケートを実施した。追加設問の内容については、金融広報中央委員会 (2002)、増田 (2011)、家森・上山 (2018)を参考に作成した。実際に追加した設問は以下の通りである。

1. フィッシング詐欺 (偽のサイトに誘導されるなどしてクレジットカードやキャッシュカード等の金融口座に関する情報を盗まれる詐欺) の被害にあったことがある。
2. クレジットカードの支払いが遅れ、強制退会 (解約) されたことがある。
3. すでにあるローンの支払いに充てるため、他の金融機関から借り入れることを繰り返したことがある。
4. 他人の保証人または連帯保証人になり、返済が困難なほどの負担を強いられた経験がある。
5. 自分の収入では返済が困難なほどの借り入れをしたことがある。
6. 保険や投資信託といった金融商品の特徴 (例えば、元本割れのリスクがある、など) について、十分な説明がないまま、あるいは十分理解できないまま、これを購入したことがある。
7. 「必ず上がります」とか「絶対に〇〇になる」と断定することや、そう思わせる

¹ 金融リテラシー調査で問われている金融行動における行動バイアスは、将来のことより現在の関心事を (過剰に) 重視してしまう心理を表す近視眼バイアス、他人が購入したものを欲しくなる心理を表す横並びバイアス、損失拡大時に損切りできず大穴に賭けてしまう心理を表す損失回避バイアス、の 3 つである。行動バイアスが金融リテラシーに与える影響について分析した文献に鈴木・高橋・竹本(2020)がある。

ような表現を使って、金融商品の購入（取引）を勧誘され、その商品を購入したことがある。

8. 海外の海老養殖への投資といった架空または虚偽の投資話でお金をだまし取られたことがある。
9. 振り込め詐欺の被害に遭ったことがある。
10. マルチ商法やねずみ講の被害に遭ったことがある。

独自アンケートは2023年7月5日～10日に（株）インテージのWebアンケートにより行われた。金融リテラシー調査と同様に15～79歳の日本全国の男女を対象としている。有効回答数は472、回収率は1.9%である。金融トラブルに遭遇した経験がある人と無い人をほぼ同数ずつ集めるように依頼したが、実際には「あり」222人、「なし」250人である。

3. 予測モデル構築

3.1. 概略

本稿では、金融リテラシー調査を利用して金融トラブルに遭遇した経験の有無を予測するモデルを構築し、独自アンケートデータにそのモデルを適用する。これによって、独自アンケートにおいて金融トラブルに遭遇すると予測される人々が具体的にどのような金融トラブルに遭遇しているかがわかる。つまり、金融リテラシー調査から得られる予測がどのようなトラブルに対して有効であるのかを知ることが可能となる。

金融リテラシー調査のサンプル数は3年分で計8万件ある。暮らしの中で金融トラブルに遭遇したことがある人はそれほど多くはない。実際、金融リテラシー調査の中で金融トラブルに遭遇した経験のある人の割合は、全体の6.6%である。このように大量のデータから通常とは異なるデータを見つけることは「異常検知」と呼ばれる。

近年、異常検知には機械学習の手法が用いられることが多い²。本稿で取り扱うデータは「正解」（ここでは、金融トラブルに遭遇した経験があるかどうか）のあるデータなので、分析には「教師あり学習³」（正解が変数として含まれているデータを用いる学習のこと）と呼ばれる手法が用いられる。また、金融トラブルに遭遇した経験は2値（「経験あり」と「経験なし」）であるから、このような問題は「分類」問題と呼ばれる⁴。

本稿の分析の概略は以下の通りである。

² 例えば、井出・杉山（2015）を参照。

³ 機械学習において出てくる基本的な用語や手法については、例えば Hastie, Tibshirani, and Friedman（2014）を参照。

⁴ 一般には、被説明変数が離散的な値を取る場合に分類問題と言われる。一方、連続的な値を取る場合には「回帰」問題と言われる。ただし、この区別は必ずしも厳密なものではなく、以下で出てくるロジスティック回帰はどちらの扱いも可能である。

- (1) 3年分の金融リテラシー調査データを「訓練データ（モデルを構築するためのデータ）」と「テストデータ（モデルの未知データに対する予測性能を見るためのデータ）」に分割する。ここでは訓練データを8割、テストデータを2にランダムに分割する。ただし、金融トラブルを経験したサンプルがどちらにも分割前と同じ割合で入るようにしておく。
- (2) （複数の手法について）訓練データを用いて、予測性能が高くなるようモデルのパラメータを設定（「チューニング」と言われる）することで、「手法毎の最適なモデル」を得る。
- (3) (2)で得られた手法毎の最適なモデルをテストデータで評価し、テストデータに対する予測性能が最も高い手法（最適なモデル）を選択する。
- (4) 独自アンケートデータに対し、(3)で得られた最適なモデルを用いて金融トラブルの予測を行う。

3.2. 本稿で用いる機械学習の手法⁵

機械学習の手法として本稿では、Lassoを用いたロジスティック回帰（以降、「Lasso (Logit)」と略す）、Ridgeを用いたロジスティック回帰（以降、「Ridge (Logit)」と略す）、Random Forest、Support Vector Machines（以降、「SVM」と略す）の4つを扱う（ただし、後で述べるように、本稿の分析において主に用いられる手法はLasso (Logit)、Ridge (Logit)の2つである）。

LassoとRidgeは係数の大きさに罰則を入れた、つまり、傾きがあまり大きくなならないように制約条件を入れた回帰モデルである。2つの違いは傾きのノルムが異なることにある。LassoはL1ノルム

$$\|a\|_1 = \sum_{i=1}^n |a_i|$$

を、RidgeはL2ノルム

$$\|a\|_2 = \sqrt{\sum_{i=1}^n (a_i)^2}$$

を制約に用いる。ここで、 a は係数のベクトルである。

Random Forestとは、決定木⁶を複数作成して、それらの予測の多数決を取って予測する手法である。

⁵ 本稿で扱う機械学習の手法については例えば、Hastie, et.al. (2014)を参照。

⁶ 例えば、スパムメールの判定するとき、「ある怪しげなサイトへのリンクが記述されていればスパム、書かれていなければ正常なメール」というように、いくつかの条件を枝のように記述する手法を決定木 (decision tree) という。

SVM とは n 個の特徴（ここでは、性別、居住地、所得など）が存在するときに、 n 次元空間にサンプルをプロットし、それらを 2 つの領域（ここでは、1 つの領域には「金融トラブルを経験した」サンプルが所属し、もう一方には「経験していない」サンプルだけが属する）に分離するような超平面（2 次元なら直線、3 次元なら平面の一般化した概念）や曲面を探す手法である。

3.3. 混同行列

分類問題において予測の正確さを見るためのツールとして「混同行列（confusion matrix）」がある。混同行列とは実際の値と予測がどのようになっているかを並べたもので、表 1 のように表される。

		実際の値	
		Positive (1)	Negative (0)
予測	Positive (1)	True Positive (TP)	False Positive (FP)
	Negative (0)	False Negative (FN)	True Negative (TN)

表 1 : 混同行列

本稿の場合、例えば表 1 の左上の位置にある「True Positive (TP)」には、実際に金融トラブルを経験し、かつ金融トラブルに遭遇するとモデルが予測するサンプル数が入る。以降、True Positive は TP と、False Positive は FP と、False Negative は FN と、True Negative は TN とそれぞれ略す。

3.4. 標準的なチューニング基準の問題点

多くの文献や統計ソフトの標準ではモデル選択の基準として、「正解率（Accuracy）」が用いられる。正解率は以下で定義される。

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN}$$

つまり、正解率は全体としてどれだけ予測が的中するかの割合を表す。

しかしながら、本稿のデータでの予測において、この基準を用いてモデルを選択することには問題がある。正解率を基準とした場合、上で述べた 4 つの手法に関して得られたモデルの正解率は表 2 のようになる。

手法\指標	正解率	再現率
Lasso (Logit)	0.9346	0.0548

Ridge (Logit)	0.9349	0.0480
Random Forest	0.9382	0.0150
SVM	0.9343	0.0367

表 2：訓練データにおける各手法の正解率と適合率

我々の目的はトラブルに巻き込まれそうな人々に注意喚起することであるから、実際に金融トラブルを経験した人々についてはできるだけ予測モデルで検出できるようにしたい。つまり、可能性の低い人を **Positive** と予測する間違いが起こることを多少犠牲にしても、可能性の高い人を **Negative** と予測する間違いを減らす必要がある。そのための指標は「再現率 (Recall)」と呼ばれる。再現率の定義は以下で与えられる。

$$Recall = \frac{TP}{TP + FN}$$

表 2 から明らかなように、いずれの手法も再現率の値はかなり小さいことがわかる。

以上から、上記で得られるモデルはいずれも本稿の目的にとって有用ではなかった。これはそもそも金融トラブルを経験する人が少数であることが原因である。このようなデータでは「経験したことがない」と予測すればほぼ正解となるので、正解率は高くなる。もちろん、そのような予測は金融トラブルを経験した人をあぶり出すことが出来ない。

3.5. 本稿で用いるモデルの選択基準

しかしながら、ロジスティック回帰のように出力が連続的な場合には以下のように予測を改善する余地がある。ロジスティック回帰の結果から混同行列を得るときにはある閾値以上なら 1、それ以外なら 0 という処理をするが、多くの場合その閾値は 0.5 である。同じモデルでも閾値を下げることでより多くのサンプルについて 1 と判定することが可能である。

それでは、どのように閾値を設定すべきだろうか？Zumel and Mount (2020) 7.2.3 節によれば、閾値を決定する基準としては上で挙げた再現率と「適合率 (Precision)」の 2 つが高いものにすべきと述べられている。適合率の定義は以下で与えられる。

$$Precision = \frac{TP}{TP + FP}$$

この 2 つを同時に見る指標の一つに「F1 スコア (F1-score, F measure)」が挙げられる⁷。F1 スコアは以下で定義される。

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}}$$

F1 スコアは適合率と再現率の調和平均であることがわかる。

⁷ F1 スコアやその派生については、Hand and Christen (2018) を参照。

以降では、モデル選択と閾値の決定に F1 スコアを用いることにする。

3.6. 閾値の最適化

ここでは F1 スコアが訓練データにおいて最大となるようにモデルと閾値を選択した結果を示す。閾値の変更は、ロジスティック回帰のように結果が確率で得られるモデルにしか適用できない⁸。そのため、以下では **Lasso (Logit)** と **Ridge (Logit)** について閾値を変更した場合の結果を示す。得られた結果は表 3・表 4 の通りである。表 2 と比較して再現率が改善していることがわかる。

Lasso (Logit)			Ridge (Logit)		
予測\実際	1	0	予測\実際	1	0
1	1674	4135	1	1677	4143
0	2576	55615	0	2573	55607

表 3：訓練データでの混同行列

基準値\手法	Lasso	Ridge
適合率	0.2882	0.2881
再現率	0.3939	0.3946
F1 スコア	0.3328	0.3331
閾値	0.149	0.144
正解率	0.8951	0.8951

表 4：訓練データでの結果

Lasso (Logit) と Ridge (Logit) それぞれについて、最適なモデルにテストデータを適用すると表 5 のような混同行列が得られる。

Lasso (Logit)			Ridge (Logit)		
予測\実際	1	0	予測\実際	1	0
1	412	1131	1	405	1133
0	653	13804	0	660	13802

表 5：テストデータでの混同行列

⁸ 他の手法についてもこの作業は不可能ではない（例えば、SVM は離散値（ここでは 0 か 1）を出力するが、Platt (1999) は SVM の出力を使ってシグモイド関数を学習することで確率を出力させる方法を提示している）が、本稿では扱わない。

それぞれの手法における各指標は表 6 の通りである。F1 スコアを比較すると、わずかに Lasso (Logit) の方が高いことがわかる。この結果から、Lasso (Logit) モデルが予測モデルとして選ばれた。

基準値\手法	Lasso (Logit)	Ridge (Logit)
適合率	0.2670	0.2633
再現率	0.3869	0.3803
F1 スコア	0.3160	0.3112
正解率	0.9334	0.9340

表 6：テストデータでの結果

4. トラブル別予測の検証

上記で選ばれた Lasso (Logit) モデルに、独自アンケートデータを適用する。表 7 は独自アンケートでの混同行列を、表 8 はその結果を表す。正解率を除いて、表 8 の各指標は表 6 (テストデータでの結果) のそれよりも高くなっている。その理由として、独自アンケートデータでは金融トラブルに遭遇した経験のある人とそうでない人の割合がほぼ半々であることが挙げられる。一方、正解率は表 8 の方が低いが、実際に遭遇した経験のないの方が予測は当たりやすく、独自アンケートデータはテストデータよりも経験のないサンプルが圧倒的に少ないためと考えられる。

予測\実際	1	0
1	94	15
0	128	235

表 7：独自アンケートデータでの混同行列

基準値\手法	Lasso
適合率	0.8624
再現率	0.4234
F1 スコア	0.5680
正解率	0.697

表 8：独自アンケートデータでの結果

金融トラブルの種類ごとに、トラブル遭遇の経験を正しく予測できた割合が表9である。「総数」はそのトラブルに遭遇した経験のある人の数を、「正解」はそのうち予測モデルがトラブルに遭遇したと予測した人の数を、「不正解」は同じく遭遇しなかったと予測した人の数を、「正答率」は正解の数が総数に占める割合をそれぞれ表す。なお、この設問は複数回答可であるから、総数の合計はトラブルに遭遇した人数よりも多い。

トラブルの種類	総数	正解	不正解	正答率
1. フィッシング詐欺（偽のサイトに誘導されるなどしてクレジットカードやキャッシュカード等の金融口座に関する情報を盗まれる詐欺）の被害にあったことがある。	74	29	45	39%
2. クレジットカードの支払いが遅れ、強制退会（解約）されたことがある。	48	33	15	69%
3. すでにあるローンの支払いに充てるため、他の金融機関から借り入れることを繰り返したことがある。	60	42	18	70%
4. 他人の保証人または連帯保証人になり、返済が困難なほどの負担を強いられた経験がある。	26	18	8	69%
5. 自分の収入では返済が困難なほどの借り入れをしたことがある。	49	35	14	71%
6. 保険や投資信託といった金融商品の特徴（例えば、元本割れのリスクがある、など）について、十分な説明がないまま、あるいは十分理解できないまま、これを購入したことがある。	38	18	20	47%
7. 「必ず上がります」とか「絶対に○○になる」と断定することや、そう思わせるような表現を使って、金融商品の購入（取引）を勧誘され、その商品を購入したことがある。	38	15	23	39%
8. 海外の海老養殖への投資といった架空または虚偽の投資話でお金をだまし取られたことがある。	19	14	5	74%
9. 振り込め詐欺の被害に遭ったことがある。	23	13	10	57%
10. マルチ商法やねずみ講の被害に遭ったことがある。	36	18	18	50%

表9：トラブル別の予測精度

この結果を見ると、トラブル 2~4 と 8 が高い正答率となっている。2~4 は借金に関するトラブル、あるいは計画性のなさに起因するトラブルと言える。このように金融リテラシーの低さが要因の一つと考えられる金融トラブルについては、本予測モデルは高い予測精度を持っている。一方、トラブル 1 のフィッシング詐欺をはじめとしたそれ以外のトラブルには「騙される」という共通点があり、これらについてはトラブル 8 を除いて低い予測精度となった。

5. 終わりに

本稿では、金融リテラシー調査の設問項目から金融トラブルに遭遇する可能性の高い人を検出するモデルを構築した。そして、フィッシング詐欺など金融トラブルの種類を追加して尋ねた独自アンケートのデータから、金融トラブルの種類別に予測精度を検証した。その結果、「クレジットカードの支払い遅れ」や過度の借入れなど、借金に関するトラブル、あるいは計画性のなさに起因するトラブルの予測精度が高いことが分かった。また、「海外の海老養殖への投資といった架空または虚偽の投資話でお金をだまし取られたことがある。」といったトラブルの予測精度も高かった。しかし、フィッシング詐欺などこれと似たトラブルの予測精度は必ずしも高くなかった。このような結果となった理由については今後の課題としたい。

筆者らの研究の最終的な目標は、金融トラブルに遭遇しやすい人をアンケートから見つけ、トラブルに遭遇しないよう意識を高めてもらうことである。そのためには、適合率よりも再現率を高める必要がある。今回用いた基準である F1 スコアは適合率と再現率を同等に重視した基準である。今後の研究では、再現率をより重視した基準で分析を行う必要がある。

本稿では、ロジスティック回帰に **Lasso** と **Ridge** を適用した手法について、閾値を操作することで予測を改善したが、**SVM** など他の手法についても工夫すれば結果が改善する可能性がある。また、本稿で取り扱った被説明変数の 0 と 1 の割合がアンバランスなデータは異常検知ではよくあることだろう。その取扱いについては閾値の操作以外の方法も考えられる。例えば、0 を取るサンプルの除外、1 を取るサンプルをリサンプリングして増やすといった方法が考えられる。そのような手法の改善についても今後の課題である。

最後に、金融リテラシー調査の設問項目から本稿が構築した予測モデルでは、フィッシング詐欺のような「騙される」ことによる金融トラブルに遭遇した経験を予測できていない。これは、「騙される」可能性の高い個人属性をあぶりだす設問項目が金融リテラシー調査に欠けているためではないかと考えられる。金融トラブルの防止に金融リテラシー調査がさらに貢献するためには、そのような設問項目の追加が望まれる。

参考文献

- ・家森信善・上山仁恵, 「生活者の金融リテラシーと金融トラブルー2016年・金融リテラシーと金融トラブルに関する調査をもとに」, 『生活経済学研究』 47, 1-18, 2018a.
- ・家森信善・上山仁恵, 「学校での金融経済教育の経験が金融リテラシーや金融行動に与える影響」, 『ファイナンシャル・プランニング研究』 17, 52-71, 2018b.
- ・井出剛・杉山将, 『異常検知と変化検知』, 講談社, 2015.
- ・金融広報中央委員会「金融に関する消費者アンケート調査ーどのような知識・情報を希望するか」, 『財形：財形貯蓄と資産活用の総合情報誌』 31(2), 9-11, 2002.
- ・鈴木明宏・高橋広雅・竹本亨, 「金融教育と行動バイアスが金融行動と金融トラブルへの巻き込まれやすさを与える影響:金融リテラシー調査データを利用した分析」, 『山形大学紀要(社会科学)』 第49巻第1号, 1-13, 2018.
- ・鈴木明宏・高橋広雅・竹本亨, 「学歴・金融教育・行動バイアスが金融リテラシーに与える影響:「金融リテラシー調査(2016年)」を利用した分析」, 『山形大学大学院社会文化システム研究科紀要』 第17号, 53-68, 2020.
- ・鄭美沙, 「若年層のリスク性資産購入経験と金融トラブル経験に関する実証分析」, 『生活経済学研究』 54, 45-58, 2021.
- ・春井久志(2007)「金融自由化・少子高齢化社会における金融リテラシー教育ーイギリスの事例を中心に」『消費者金融サービス研究会年報』 8, 67--81.
- ・増田純一, 「「金融教育」の混迷化現象に関する一考察: 公民科単元「金融」を事例として」, 『専修大学社会科学研究所月報』 571, 2-17, 2011.
- ・Hand, D., and P. Christen, “A note on using the F-measure for evaluating record linkage algorithms,” *Statistics and Computing* 28, 539–547, 2018.
- ・Hastie, T, R. Tibshirani, and J. Friedman, 『統計的学習の基礎ーデータマイニング・推論・予測』, 共立出版, 2014.
- ・Platt, J. C., “Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods,” *Advances in large margin classifiers* 10(3), 61-74, 1999.
- ・Zumel, N. and J. Mount, *Practical Data Science with R*, Manning Publications, 2020.