日本における新型コロナウイルスの地方債市場へのインパクトとリスク管理に関する考察

丹波　靖博 *，　原口　健太郎**，　大石　桂一***

１．はじめに

日本の公募地方債市場の取引金額は，発行市場年間約７兆円，流通市場約 12 兆円に上り，米国に次ぎ世界第２位の取引規模を誇る。また公募地方債市場は金融機関の投資対象や地方財政の資金源として重要な役割を果たしてきた。近年，地方公共団体に公会計の統一的な基準が導入されたことなどにより発行体の情報開示が改善され，インフラストラクチャー整備が徐々に進展してきたことに加え，国債のマイナスイールドが継続する環境下でプラスのイールドを維持する地方債は，金融機関が国債よりも高い収益性を確保可能な地方債への投資を拡大していることから，地方債は国債の代替財としての役割も大きく，その重要性は益々向上している。このように，地方債は地方財政運営に重要な役割を果たすことはもちろん，投資対象としての意義も大きい。

我が国の地方債市場の健全な発展のためには，市場参加者にとっての市場の透明性や効率性を高めることが不可欠である。そのためには，十分で正確な情報のもと投資家がリスク評価を行ったうえで，各自のリスク選好に従い投資できる環境構築が必要となる。しかし，地方債市場に関する既存研究は限定されているのが現状であり，実務におけるリスク管理体制に関する知見も不十分であるのが現実である。このように研究が進展してこなかった理由として，第１に，地方債が非政府保証債であるにもかかわらず事実上国債と同リスクであるとする「暗黙の政府保証論」の存在が挙げられる。「暗黙の政府保証論」の存在により，地方公共団体間の信用リスク差（スプレッド差）の存在自体が疑問視されてきたことから，地方債市場自体がファイナンス領域においてはほとんど分析対象とされてこなかった。他方，「暗黙の政府保証論」により日本国政府も地方債は原則として当初の約定通り支払われるものであることを公式に表明している一方で，主に財政学分野の複数の先行研究では，発行体間の有意な金利差の存在を指摘している。もしも上記金利差が信用リスクに起因するとしたら，暗黙の政府保証論の不完全性が示唆され，学術上はもちろん，投資意思決定やリスク管理の観点から実務的にも重要な知見となるが，上記に関して学界・実務界での合意はこれまで得られていない。第２に，流動性データの取得が困難なことなどのデータ面での制約が挙げられる。米国においては，地方債市場の売買高データの入手が可能で，売買高データをもとに様々な流動性リスクに関する研究が行われているが，日本において地方債の売買

* 西南学院大学経済学部教授　**西南学院大学商学部准教授　***九州大学経済学研究院教授

データを入手することは現状非常に困難であるため,流動性リスクに関する分析が困難な状況にある。第３に,地方債銘柄の格付の取得率が非常に低い上に,付与されている格付も基本的には同一であることが挙げられる。この点は,前述の「暗黙の政府保証論」の存在とも関係するが,どの地方公共団体の信用リスクも同程度であるという考え方も一部存在し,そのため付与される格付も同一になるという現状がある。一方,自治体間においては,財務状況の良し悪しにはかなりの差があるのが現状であり,投資家としては真の信用リスクが見えにくくなっている現状があると思われる。第４に,近年,地方債金利が著しく低い水準で推移していることから,モデル構築において目的変数の差が小さいため信用リスクのモデル構築による評価が困難であることが挙げられる。これらの課題の中でも，リスク評価に関する合意の未形成は特に重要であると考える。このように，実務的にも重要かつ巨大な市場に関する研究蓄積が乏しいことは大きな問題であると考える。本報告は，とりわけ，近年市場に大きなインパクトを与えた可能性がある新型コロナウイルス感染症の影響を調査することで，信用リスク分析の観点から地方債市場に関する学術的知見を獲得することを目的とする。

２．先行研究レビューと本研究の概要

２－１．先行研究レビュー

地方債市場に関する学術分野は,会計学,財政学,ファイナンスの 3 つの領域で研究が行われている。まず,会計学の分野では,公会計の財務諸表や地方債の格付け,地方債金利情報との関連性などが,複式簿記や発生主義に基づく会計情報を用いた研究によって進展している。一方,財政学分野では,地方債市場に対する財政情報の影響などが研究されている,また,ファイナンス分野では社債を中心とする債券市場の信用リスク評価に関する研究が行われている。本研究では,地方債のスプレッドを対象にしたスプレッド推定モデル構築による分析を進めるが,本稿の主題に関連の深いものを対象にレビューを行う。

地方債市場の研究は米国で進展しており多くの研究が見られる。米国の地方債研究の例として,財務健全性とリスクプレミアムの関係性について債務額とイールドの関係を示した Goldstein,and Woglom（1995）,説明変数の一つに流動性リスクプレミアムを用いてイールド推定を行った Wang,Wu,and Zhang（2008）などの研究が挙げられる。また,リスク要因をデフォルトと流動性に区分して分析した Schwert（2017）,金融機関も投資の際に必ず参照する格付を対象にして,財務指標により格付け推定とスプレッド推定を行った Capeci（1991）,説明変数に格付けを用い地方債のスプレッド推定を行った Liu and Thakor（1984）等の研究が挙げられる。その他の関連研究では,地方債の流動性と価格ボラティリティとの間に正の関係を示した Downing and Zhang（2004）,地方債のトレーディングコストを推定することにより価格の透明性の欠如の問題を指摘した Harris and Piwowar（2006）や,財政状況が悪い自治体であるにもか

かわらず,発行している地方債スプレッドの水準は同格の地方公共団体と同程度の水準である地方公共団体も存在するという矛盾を指摘したNovy-Marx and Rauh（2011a, 2011b）などの研究も見られる。

これに対し,日本での地方債研究は,これまで主に財政学分野で行われてきた。例えば，石田・中里（2019）では,わが国の地方公共団体の複数の既存指標が対国債スプレッドに対して有意な影響を与えることや,既存指標の内容の悪化は他の地方公共団体のスプレッド水準にも負の影響を与えるというスピルオーバーリスクについても明らかにした。また，田中（2012）,中里（2008）,Hattori and Miyake（2015）では,重回帰分析を用いて総務省が公表している「実質公債費比率」や「将来負担比率」等の財政関連指標（既存指標）と対国債スプレッドの有意な関係性を示した。三宅（2017）では,既存指標に加え,流動性指標として売買参考統計値最高値と最低値の差を説明変数に取り入れることで,地方債のスプレッド推定に関する分析を行っている。その他に,前述の既存指標・流動性指標にマクロ指標である有効求人倍率も説明変数として追加しモデル構築を行った石川（2007）の研究も見られる。一方，井潟・三宅（2007）では,国が暗黙のうちに地方公共団体の債務を保証しており,地方債と国債が事実上同リスクと見なされるわが国における,「暗黙の政府保証論」の存在が言及されている。さらに，既存指標に公会計情報を追加し,格付けや地方債スプレッドとの関連性を分析した一連の研究（Haraguchi and Oishi（2019),原口・丹波（2021）,原口・丹波（2022））が挙げられる。上述の複数の課題の存在は確認できるものの,わが国においては地方債の信用リスクの先行研究の事例は限定的であるのが実情である。特に,ファンナンスの観点から信用リスク分析に焦点をあてた研究はほとんど見られない。さらに上記で挙げた分析は，すべて伝統的な統計的手法であるOLS等に基づくものである。これらの先行研究に対し，日本の地方債の特殊性や課題を対象とし,ファンナンスの観点から機械学習モデルを適用して地方債スプレッド推定モデルを構築した研究として丹波・原口(2023a)が挙げられる。

２－２．本研究の目的と分析方針

本研究は，地方債の金利差がいかなる要因に基づくものなのかを明らかにするための信用リスク分析を行ったうえで，当該結果を金融機関等に提示し広く共有することで，学術上・実務上の新たな知見提供を通じて，これまで格付けのみで評価される傾向のあった地方債投資に関し,投資家視点からの透明性向上を図り，ひいては市場の透明性向上と活性化を目指すものである。

本研究では,学術的にはこれまで乏しかった地方債の信用リスク分析の知見が蓄積されることを目的とし,日本の地方債市場を対象として地方債への投資行動について分析する。特に,本研究では市場への影響が大きいと見込まれる新型コロナウイルス感染症の地方債市場への影響に注目して分析を行う。

前述のとおり,信用リスク分析におけるスプレッド推定モデル構築に関して,現在の地方債市場のスプレッドが低水準である課題がある。このような低水準のスプレッド下で分析を進めるためには,高精度のスプレッド推定モデルの構築が不可欠となるが,従来の重回帰モデルでは精度上の限界が生じるため,より高精度の手法を検討する必要がある。近年,コンピュータで膨大な計算を行うことで柔軟かつ高精度の説明力を確保できるAI（人工知能）モデルが,コンピュータの計算速度の向上により進化している。機械学習モデルという呼称は,そのうちのいくつかの計算手法を指し,機械学習モデルには多くの種類が存在する。そのため，モデルの適用にあたっては様々な手法や前提条件について検討を行い，最適な機械学習モデルを選定する作業が重要となる。

本研究の分析内容は以下のとおりである。まずは,新型コロナウイルス発生前後のそれぞれの期間において,いくつかの機械学習によりスプレッド推定モデルを構築し,説明力の高いモデルの選定を行う。また,特徴量として重要な財政・市場指標などの特定を行う。その際，特徴量の数を減らしていき,決定係数の水準を維持できる最少の特徴量を特定する。これにより,日本の地方公共団体が発行する地方債の金利（価格）差を構成する主要な要素が何かを明らかにする。次に,近年注目されている「説明可能なAI（eXplainable AI: XAI)」の技術を活用し,更に詳細な地方公共団体間のスプレッド差の要因とコロナ前後の各特徴量と目的変数の関係性の変化について考察を行う。これにより，新型コロナウイルス感染症が地方債への投資行動の変化に対してどのような影響を与えたかの分析を行う。さらに,金利の決定要因や投資家の投資行動の変化を踏まえ,コロナ禍での地方債投資におけるリスク管理方法について考察を行う。

３．分析データ

本研究のモデル構築の際の使用データにおいて,説明変数については,これまでの先行研究でも影響が指摘されている「実質公債費比率」「将来負担比率」などの既存指標や総務省公表資料である地方公共団体の財政状況評価資料として一般的に用いられる「地方財政状況調査関係資料（決算統計)」データを使用する。さらに,本稿では近年整備され一般に使用が可能となった複式簿記・発生主義に基づく公会計情報も説明変数候補に加える。わが国の地方公共団体は,これまで単式簿記・現金主義に基づく会計制度により運営されてきた。近年になってようやく,総務省が2015年に示した「統一的基準」に基づき,多くの地方公共団体が複式簿記・発生主義に基づく公会計情報を今日では,表しており,広く利用できるようになった。2019年現在では,本運用も軌道に乗りほとんどの地方公共団体は統一的基準モデルに基づき公会計財務諸表を公表しており,2019年3月31日時点で,1,788の地方公共団体のうち1,695団体が統一的基準による公会計財務諸表の作成を完了している。作成モデルの統一化は,統一的基準の導入により大きく進展し,公会計財務諸表の自治体間の比較可能性を向上させた。また,総務省がこれらのデータを「統一的な基準による財務書類に関する情報」（総務省データベース）としてホームページに掲載したことにより,だれも

がデータにアクセスできるようになり,公会計情報の自治体間の比較分析などは導入前と比べて著しく改善された。本稿でも分析の対象としている地方債市場のこれらの公会計情報に対する評価は,信用リスク分析の観点からはもちろん,会計学上も重要な論点となり得るため,モデルに追加している。また,新しく入手可能となった情報を取り入れることにより,信用リスク分析における説明力やモデル精度を向上できることが期待される。

本分析ではセカンダリーマーケットを分析対象とし,金利情報の取得のために債券分析データベース・ソフトウェア「イールドブック」を使用し 2019 年 4 月 15 日から 2019 年 5 月 31 日までの期間及び 2020 年 4 月 1 日から 2020 年 5 月 29 日までの期間を分析対象とする。また,データ取得が可能な地方債銘柄を対象とし,本分析期間における日次ベースの地方債イールドデータを使用する。ここで 4 月から 5 月のデータを使用しているのは,4 月から 5 月は地方自治法に定められている地方公共団体のいかなる財務指標も新規公表しない期間である出納整理期間にあたるため,決算公表時期がまちまちである各地方公共団体の情報開示がスプレッドに対して与える影響を排除でき,年度ベースで公平に評価できると考えることによる。

社債等の研究においては,イールド水準が市場環境に大きく左右されるため,無リスクと考えられる国債を基準とした対国債スプレッドを目的変数に用いることが一般的である。しかし,2016 年から実施されている日本銀行のマイナス金利政策により,本稿の分析対象としている 2019 年 4 月以降においても,主に残存年限 10 年以下の年限で国債金利はマイナスの値を取ることが通常の状態となっている。一方,地方債のイールドは国債のように日本銀行の買い入れが期待できず非常に低水準のプラス値をとるため,対国債スプレッドはその大部分が国債金利のマイナス幅の部分が占めてしまう。このため,対国債スプレッドを目的変数とした場合,地方債イールドの変動よりもむしろ国債イールドの変動の影響を大きく受けてしまうので,地方債の信用リスク分析のモデル構築を行う際には目的変数として有効に機能しない可能性がある。この状況を鑑み,本稿では,地方債の中で最もリスク水準が低いと見込まれる地方債の 1 つである東京都債をベンチマークとし,各銘柄と東京都債とのスプレッド（対東京都債スプレッド）を目的変数として採用する。対東京都債スプレッドは,東京都債をスプライン補間してイールドカーブを計算し,任意の残存年限の東京都債の金利情報を導出して計算する。モデル構築の試行に使用する説明変数は,地方公共団体の公会計情報,主要財政指標,決算統計などの各種指標,地方債市場データ,個々の地方債銘柄の属性データなど合計 45 変数である。スプレッド推定モデルに使用した目的変数と説明変数として試行した変数一覧は表 1 のとおりである。

【表１ 目的変数と試行した説明変数一覧】

#	変数	内容
0	TokyoYield	対東京都債イールド(目的変数)
#	変数	内容
1	population	人口
2	YRSTOMAT	銘柄の残存年限
3	ISSAMT	銘柄の当初発行高対数
4	RepMem	市場価格報告者数
5	AveRating	格付け
6	zaisei	財政力指数
7	keijo	経常収支比率
8	jissitsu	実質公債比率
9	syourai	将来負担比率
10	ebbalance	臨時財政対策債期末残高
11	assets	資産合計
12	liabilities	一人あたり負債合計
13	retirement	一人あたり退職手当引当金額
14	infra	固定資産等形成分
15	netassets	純資産合計
16	revenue	財源
17	NAR	純資産比率
18	rNAR	修正純資産比率
19	perasset	住民一人当たり資産額.万円
20	revasset	歳入額対資産比率.年.
21	depasset	有形固定資産減価償却率
22	future	将来世代負担比率

#	変数	内容
23	percost	住民一人当たり行政コスト.万円
24	perliabilities	住民一人当たり負債額.万円
25	balance	基礎的財政収支.百万円
26	benefit	受益者負担比率
27	popToukei	一人あたり決算統計上の地方債残高
28	popdiftoukei	一人あたり公会計財務諸表上の負債と決算統計上の地方債との差
29	popresidual	一人あたり公会計財務諸表上の負債（退職手当引当金以外）と決算統計上の地方債との差
30	popretirement	一人あたり退職手当引当金
31	sd	スプレッド標準偏差
32	lgcode	自治体コード番号
33	prefdummy	県ダミー
34	COUP	クーポン
35	MATDATE	満期日
36	MOODY.IR.	Moody's格付け
37	S.P.IR.	S&P格付け
38	R.IQ	R&I格付け
39	ebissue	期中発行額
40	rasu	ラスパイレス指数
41	bond_toukei	差引現在高
42	JointGov	共同発行債フラグ
43	PRICEDT	価格評価日
44	ISSUEDATE	発行日
45	Difference	売買参考統計値上の取引価格の最大と最小の差

*11~30は公会計指標

試行した説明変数には,流動性リスクを表す指標もいくつか含まれている。前述した通り,我が国の地方債市場では取引高データが入手できないという課題がある。市場の状況にもよるが,流動性リスクのリスク全体に対する寄与度は小さくない可能性もあるため,上記表１には流動性リスクを表す変数としていくつかの変数を試行している。具体的には,同一取引日における各団体のイールド取引値データの最高値と最低値の差,日本証券業協会に取引値データを提出した証券会社数,スプレッドデータから計算される標準偏差の３つの変数を試行している。モデル構築においては,モデルにおける説明力を確認しながら最終的な変数の採択を検討することとする。スプレッドの標準偏差は 2019 年と 2020 年の各年について,各地方公共団体の年限が 0.5 年刻み(0 年超 0.5 年以下,0.5 年超 1 年以下,以下同様)の範囲に入るデータの標準偏差を算出することにより算出する。区分内のサンプル数が 10 未満のデータは計 430 サンプル存在するが,サンプル数が小さい場合には標準偏差値の信頼性が低下するため,データユニバースから削除する。分析対象としている４月及び５月は,財務指標が新規公表されない期間であるため,スプレッドの標準偏差が大きいということは,ファンダメンタルズ以外の流動性や市場要因により取引スプレッドが変動している可能

性がある。一般的に,ファイナンスにおいてはスプレッドの標準偏差が大きい銘柄は流動性リスクが高く, 標準偏差が小さい銘柄は流動性リスクが低いと考えられる。このため,スプレッドの標準偏差は流動性リスクの代替変数として解釈することができる可能性がある。

必要となる情報を全て入手可能であった 49 地方公共団体に係る 143,020 銘柄（2019 年：57,135 銘柄, 2020 年：85,885 銘柄）の地方債データに関し,機械学習への適用の際は 8 割を学習データとし,学習データ 114,416 銘柄,テストデータ 28,604 銘柄とする（表２）。

【表２ 分析サンプル数】

自治体名	年限0	年限	年限	年限	年限	年限	年限	総計
	0	5	10	15	20	25	30	
北海道	961	3018	1003	575	335	67		5959
札幌市	351	1014	702	312	156		39	2574
宮城県	146	699	268					1113
仙台市	39	201		26	99			365
秋田県		106	201					307
福島県	103	523	200					826
茨城県	106	279	162					547
栃木県	39	328	198					565
群馬県	72	668	497	335	134			1706
埼玉県	754	3307	1899	681	456	480	335	7912
千葉県	172	1260	648	307	140			2527
千葉市	184	810	579					1573
東京都	1138	4997	2801	938	603	374	162	11013
神奈川県	848	3464	1781	1089	430			7612
横浜市	553	3135	1480	984	516			6668
川崎市	396	974	961	798	363	335	134	3961
相模原市	39	402	134					575
新潟県	117	660	350	39	78			1244
福井県	46	280	140	140	56	28	28	718
山梨県	115	363	164					642
長野県	39	201						240
岐阜県	106	344	164					614
静岡県	1032	3882	2430	644	603	335	152	9078
静岡市	36	176	103					315
愛知県	1259	4468	3001	752	521	335	134	10470

自治体名	年限0	年限	年限	年限	年限	年限	年限	総計
	0	5	10	15	20	25	30	
名古屋市	158	878	560	224	219	112	28	2179
滋賀県	39	328	200					567
京都府	699	2416	1642	369	134	67	39	5366
京都市	448	1745	909	318	214			3634
大阪府	1677	5794	2557	430	162			10620
大阪市	688	2121	1834	502	341	240	134	5860
兵庫県	626	2359	2129	1244	603	67	39	7067
神戸市	386	1141	871	508	430	268	252	3856
奈良県	39	200						239
島根県	72	333		106	134	240	28	913
岡山県	106	670	402					1178
岡山市	67	335	201					603
広島県	533	2253	1339	371	304	67		4867
広島市	444	974	402	45	301			2166
徳島県	39	192	115					346
高知県		233	200					433
福岡県	542	2293	1764	1110	500	296	212	6717
北九州市	195	507	558	253	39			1552
福岡市	565	1566	738	427	520		39	3855
長崎県		224	56					280
熊本県	138	272	97					507
熊本市		300	200					500
大分県	56	197	98					351
鹿児島県	74	166						240
総計	16242	63056	36738	13527	8391	3311	1755	143020

４．スプレッド推定モデルの構築

４－１．スプレッド推定モデルの構築と説明力の比較

新型コロナウイルス発生前後の 2019 年と 2020 年のそれぞれの期間において,複数の機械学習モデルを適用し,スプレッド推定モデルを構築する。XAI では特徴量の数が多くなると分析が複雑になるため,本稿では決定係数によりモデルの説明力の判定を行い,モデルの説明力が大幅に低下しないことを確認しながら最少の重要な特徴量の特定を行う。その結果,モデル構築において最終的に残った特徴量は,残存年限,実質公債費比率,クーポン金利の３変数であった（表３）。これら特徴量による説明力を比較すると,2019 年で１番説明力の高いモデルは,rf（Random Forest Regressor）で,説明力は約 97.52%（表４）,2020 年で１番説明力の高いモデルは,et(Extra Trees Regressor)で決定係数は約 94.09%であり, ２番目に説明力の高いモデルは rf で決定係数は約 93.67%（表５）であることが確認できる。2020 年の rf と et の説明力の差は僅かであるが,特徴量の数や組み合わせを変えた場合にほとんどのケースで最も説明力の高いモデ

ルは rf であることが確認できるため,本稿では rf モデルを両年に対し採用して議論を進める。また,テストデータでの決定係数も同程度（2019 年：約 97.75%,2020 年：約 95.15%）の水準であり高い説明力が確認された。Random Forest Regressor のパラメータ設定は表６の通りである。

【表３　モデルに採用した変数リスト】

変数	定義
TokyoSpread	各銘柄の対東京債スプレッド (目的変数)
YRSTOMAT	各銘柄の残存年限
jissitsu	各自治体の実質公債比率
COUP	各銘柄のクーポン金利

【表４　2019 年モデルの説明力比較】

	Model	MAE	MSE	RMSE	R2	RMSLE	MAPE	TT (Sec)
rf	Random Forest Regressor	0.0010	0.0000	0.0013	0.9752	0.0013	0.8180	0.6900
et	Extra Trees Regressor	0.0010	0.0000	0.0013	0.9746	0.0013	0.8724	0.5100
knn	K Neighbors Regressor	0.0011	0.0000	0.0015	0.9692	0.0014	0.9271	0.0110
dt	Decision Tree Regressor	0.0011	0.0000	0.0016	0.9635	0.0015	0.9213	0.0180
lightgbm	Light Gradient Boosting Machine	0.0014	0.0000	0.0019	0.9472	0.0019	1.1024	0.0320
gbr	Gradient Boosting Regressor	0.0019	0.0000	0.0028	0.8942	0.0026	1.4165	0.2600
ada	AdaBoost Regressor	0.0034	0.0000	0.0044	0.7255	0.0041	3.7239	0.1250
lar	Least Angle Regression	0.0045	0.0000	0.0068	0.3562	0.0060	3.8513	0.0050
br	Bayesian Ridge	0.0045	0.0000	0.0068	0.3562	0.0060	3.8509	0.0050
ridge	Ridge Regression	0.0045	0.0000	0.0068	0.3562	0.0060	3.8513	0.0050
lr	Linear Regression	0.0045	0.0000	0.0068	0.3562	0.0060	3.8513	0.0050
huber	Huber Regressor	0.0043	0.0000	0.0069	0.3307	0.0061	3.4487	0.0360
omp	Orthogonal Matching Pursuit	0.0051	0.0001	0.0077	0.1786	0.0068	5.2191	0.0050
lasso	Lasso Regression	0.0063	0.0001	0.0085	-0.0002	0.0079	6.6778	0.0050
en	Elastic Net	0.0063	0.0001	0.0085	-0.0002	0.0079	6.6778	0.0040
llar	Lasso Least Angle Regression	0.0063	0.0001	0.0085	-0.0002	0.0079	6.6778	0.0050
dummy	Dummy Regressor	0.0063	0.0001	0.0085	-0.0002	0.0079	6.6778	0.0040
par	Passive Aggressive Regressor	0.0088	0.0001	0.0119	-0.9811	0.0118	1.0000	0.0050

【表５　2020 年モデルの説明力比較】

	Model	MAE	MSE	RMSE	R2	RMSLE	MAPE	TT (Sec)
et	Extra Trees Regressor	0.0013	0.0000	0.0018	0.9409	0.0017	3.5709	0.8320
rf	Random Forest Regressor	0.0013	0.0000	0.0018	0.9367	0.0017	3.4057	1.0790
knn	K Neighbors Regressor	0.0014	0.0000	0.0020	0.9224	0.0019	3.7113	0.0140
dt	Decision Tree Regressor	0.0015	0.0000	0.0022	0.9118	0.0020	3.6453	0.0250
lightgbm	Light Gradient Boosting Machine	0.0021	0.0000	0.0028	0.8547	0.0026	6.4070	0.0470
gbr	Gradient Boosting Regressor	0.0027	0.0000	0.0041	0.6870	0.0038	6.7265	0.4790
ada	AdaBoost Regressor	0.0042	0.0000	0.0054	0.4497	0.0049	8.1867	0.2820
lar	Least Angle Regression	0.0045	0.0001	0.0071	0.0614	0.0064	9.2102	0.0050
br	Bayesian Ridge	0.0045	0.0001	0.0071	0.0614	0.0064	9.2074	0.0050
ridge	Ridge Regression	0.0045	0.0001	0.0071	0.0614	0.0064	9.2073	0.1990
lr	Linear Regression	0.0045	0.0001	0.0071	0.0614	0.0064	9.2073	0.0140
omp	Orthogonal Matching Pursuit	0.0045	0.0001	0.0071	0.0604	0.0065	9.4147	0.0050
huber	Huber Regressor	0.0044	0.0001	0.0071	0.0543	0.0065	8.0649	0.0560
lasso	Lasso Regression	0.0048	0.0001	0.0073	-0.0002	0.0066	9.9997	0.2620
en	Elastic Net	0.0048	0.0001	0.0073	-0.0002	0.0066	9.9997	0.0050
llar	Lasso Least Angle Regression	0.0048	0.0001	0.0073	-0.0002	0.0066	9.9996	0.0050
dummy	Dummy Regressor	0.0048	0.0001	0.0073	-0.0002	0.0066	9.9997	0.0050
par	Passive Aggressive Regressor	0.0347	0.0014	0.0377	-25.8569	0.0362	58.0525	0.0070

【表６ Random Forest Regressor のパラメータ設定】

パラメーター	設定	内容
n_estimators	100	バギングに用いる決定木の個数
criterion	mse	決定木のデータを分割する指標
max_features	auto	最適な分割のための特徴量数。auto は特徴量数のルート個
max_depth	None	決定木の深さの最大値
min_samples_split	2	ノード分割のための必要な最小サンプルサイズ
min_samples_leaf	1	葉を構成するのに必要な最小限のサンプル数
min_weight_fraction_leaf	0	葉における重みの総和の最小加重率
max_leaf_nodes	None	生成される決定木における最大の葉の数
min_impurity_split	None	決定木成長における停止の閾値
bootstrap	TRUE	ブートストラップサンプリングの実行
oob_score	FALSE	各ブートストラップサンプリングでサンプリングされなかったデータの利用
n_jobs	1	フィットおよび予測の際に用いるスレッドの数
random_state	123	乱数シード
verbose	0	モデル構築過程のメッセージ有無
warm_start	FALSE	既にフィットしたモデルへの学習の追加

４－２．ランダムフォレストモデルの概要

上記の分析で最も R2 が高かった rf（Random Forest Regressor）について概要を説明する。機械学習モデルは，所定の方程式によるモデルとして用いることなく，コンピュータがデータから反復的に学習し，そこに潜むパターンを見つけ出す手法である。一般的に，サンプル数が増加するにつれて適応的にその性能を改善することが可能であ

る。機械学習モデルにはさまざまなタイプのモデルが存在するが,そのうちの一つに決定木分析がある。Random Forest は決定木分析の手法の１つで,目的変数に影響する説明変数（特徴量）により樹木状のモデルを作成する分析方法である(APPENDIX)。決定木分析は,予測,判別,分類などを目的として使われる機械学習の手法のひとつであり,決定木分析の１つである Random forest は,回帰問題と分類問題のどちらにも用いることができる。分類問題を解くには,決定木により学習データを条件分岐によってグループを分割していく。例えば,ある１つのサンプルを考えた場合,決定木により分類された結果所属グループが決まるが, Random Forest Regressor の場合には,条件分岐によって分割されたグループの複数の木における平均値を取ることで推測値を算出する。このように Random forest は決定木モデルを複数利用することで,決定木単体よりも予測精度の向上を図る事ができる。このようなモデルを複数利用する手法をアンサンブル学習とよび,個々に別々の学習器として学習させた結果を多数決により融合させる事により,予測能力を向上させる学習方法である。決定木単体の性能は必ずしも高くないが,複数の決定木を用いることで,精度の高いモデルを作成できるという利点を生かした手法である。多数決で結果を決定する方法は,さまざまな多くの人に答えやアドバイスを聞いて総合的に物事を判断し,より良い結果を得るという一般社会でも行われている方法に似ている。機械学習においても同じような考えのもと,複数のモデルを作り多数決をとることで,より適切な結果を得ることが期待できる。

決定木の構築の枝分かれにおいては,学習データを分割する際に損失を定義し,どのようにデータを分割すれば最適かを学習していく。決定木では,同じ種類のデータを塊として分類することが目的となるので,一般的にデータの乱雑さを表す不純度が小さくなるようにデータを分割していく。分類されたグループに同一のラベル（区分データ）が多く存在する時に不純度は小さくなり,分類されたグループに異なるラベルが多く存在すると不純度が大きくなる。不純度を表す具体的な指標としては様々なものが存在するが,代表的な指標としてジニ係数が挙げられる。具体的な手順は,全ての特徴量と分割候補について不純度を計算し,様々な分割の中で不純度が最も減る分割を選択し,さらに次のグループに分割していくことを繰り返していく。Random forest では,重要度の高い特徴量は不純度を大きく減らすことが期待でき,重要度の小さな特徴量は不純度を減らすことができない特徴量を表す。このように,予測結果に対する重要度を特徴量ごとに計算し,不要な特徴量を排除していくことができる。

しかし,上記のような手順で同一のデータを使って同一の学習方法で決定木を作成すると,出力結果も同じになってしまう。そのため,決定木の１つ１つが多様性を持つことが重要となり,Random forest では,ブートストラップ法と特徴量のランダム抽出により, それぞれの決定木に与えるデータを分割結果ができるだけ多様性を持つように学習させていく。ブートストラップ法とは,学習データから内容の異なる複数の学習データを生成する手法であり,１つの学習データから何度もランダムに復元抽出を行うこ

とによりデータを増やしつつ,データに多様性をもたらすことが可能となる。他方の,特徴量のランダム抽出では,特徴量のうち１部の特徴量だけをランダムに用いて学習させていく。Random forest では,ブートストラップ法によりサンプルをランダムに復元抽出すると同時に,決定木のノード分割時に特徴量を都度選択して学習を行うことにより,結果の多様性を持たせている。

他方,機械学習で分析する際に,モデルの構造を把握しにくいという大きな課題がある。つまり,伝統的な回帰モデルなどと比較した場合,なぜそのような結果や推定になっているのかという理解が難しいという課題がある。特に,金融機関などの実務においては,中身が見えないモデルや根拠が分からないモデルから得られた結果の利用は困難である場合が多い。機械学習モデルで評価を行う場合,いかにモデルの内容を把握し,可能であれば因果関係を解釈できるかという点が非常に重要となる。この課題の解決には，今後の研究展開や実務への適用にあたって，XAI の活用が有用である可能性がある。

５．XAI の各手法の概要

一般的に,機械学習モデルは線形回帰などの手法に比べ非線形な関係性も表現できるため,説明力の高いモデル構築が可能である場合が多いが,モデルの解釈が困難である点が分析の目的によっては大きな課題となることもある。特に金融の分野では,モデルの説明責任が問われるケースも多く,機械学習の分析においてモデルの解釈を行うことは分析の内容をブラックボックス化させないという観点から重要な場合が多い。

近年,機械学習におけるモデルの解釈可能性ついて,多くの研究が急速に進められている。XAI の近年の手法をまとめた良書として森下(2021)が挙げられ,機械学習モデルの解釈可能性を向上させるための様々な手法を取り上げ解説している。機械学習の複雑なブラックボックスモデルの挙動を理解するために,Permutation Feature Importance（以下 PFI と呼ぶ）,Partial Dependence（以下 PD と呼ぶ）,Individual Conditional Expectation（以下 ICE と呼ぶ）,SHapley Additive exPlanations（以下 SHAP と呼ぶ）などの手法を紹介し,それぞれの手法の観点について解説を行っている。モデルの解釈性を観点別に分解すると,①目的変数との関係性における特徴量の重要度の定量化,②特徴量と予測値の平均的な関係性の把握,③平均的な関係だけでは捉えきれないインスタンスごとの特徴量と予測値との関係性の把握,④モデルが目的変数に対して行った予測に対する理由の解明,などの観点が挙げられる。機械学習モデルにおける XAI についての観点,手法,技術の具体的適用などについては丹波・原口(2023b)を参照されたい。

５－１．特徴量の重要度

上記４つの解釈性の観点のうち，特徴量の重要度の定量化を行うために,各特徴量の目的変数に対する重要度を予測誤差の増加分で定量的に判断する Permutation

Feature Importance（PFI）を用いる。PFI では,ある特定の特徴量の値をシャッフルし,その特徴量が使えない状態にして,目的変数に対する説明力の変化を計量化する。ある特徴量をシャッフルした場合に予測誤差が大きく増加すれば,モデルがその特徴量を重視していると考えることができ,もし予測誤差が変化しないなら,その特徴量は重要でないと判断できる。各特徴量に対して,全ての特徴量の情報が使える場合と各特徴量の情報を使わない場合との予測誤差を計算し比較を行い各特徴量の重要度を測定する。PFI の利点として,適用するモデルに対する制限がないこと,手法が直感的で理解しやすいことなどが挙げられる。一方,PFI の注意点として,特徴量の相関が高い場合には予測誤差を計測することができない場合があること,特徴量と目的変数の因果関係として解釈するには危険を伴うことなどが挙げられる。

５－２．特徴量と予測値の平均的な関係

Partial Dependence（PD）は他の特徴量を固定してある特徴量の水準だけを変化させ,各インスタンスの予測値を平均して可視化する方法である。前述の PFI では,特徴量の重要度は計量可能だが,特徴量の値と目的変数の正負の方向性の関係は調べることができない。PD により,ある特徴量の値と目的変数の値の平均的な正負の関係を知ることができる。PD の利点として,非モデル依存であること, 他の特徴量の影響も考慮に入れて各特徴量のモデル予測値への影響を確認できることなどが挙げられる。一方,PD の注意点として, 特徴量と目的変数の因果関係として解釈するには危険を伴うこと,インスタンスごとの特徴量と目的変数の細かい関係性はわからないことなどが挙げられる。

５－３．インスタンスごとの特徴量と予測値との関係

PD は特徴量と目的変数の平均的な関係を調べる手法で,インスタンスごとの詳細な関係を知ることはできないという課題がある。Individual Conditional Expectation（ICE）では,インスタンスごとに他の特徴量を固定した状態で,ある特徴量の水準を変化させ,特徴量と予測値の関係を確認する方法である。これにより,インスタンスごとの異質性を把握しモデルの振る舞いをより深く解釈することが可能となる。ICE の利点として,各インスタンスに対して各特徴量と目的変数の関係性を確認できること,モデル非依存であること, 特徴量の交互作用をとらえられる可能性があることなどが挙げられる。ICE の注意点として, 特徴量と目的変数の因果関係として解釈するには危険を伴うこと,値が安定しない傾向があること,特徴量の実績値の近傍で解釈する必要があることなどが挙げられる。

５－４．目的変数に対して行った予測の理由

各インスタンスの予測値に対して具体的な解釈が可能となる手法に SHapley Additive exPlanations（SHAP）がある。ICE ではモデルが予測値を出した理由を知ることができないが,SHAP では,各特徴量の値の増減が目的変数に与える影響や特徴量の貢献度を可視化することができる。また,SHAP では特徴量の平均的な重要度を数値で評価することも可能である。SHAP の利点は,貢献度の分解において理論上の望ましい性質を持っていること,SHAP はミクロ的な解釈とマクロ的な解釈のどちらにも用いることができることなどが挙げられる。SHAP の注意点として，ICE のように各特徴量に対する予測値の変化については分からないこと,計算負荷が高いこと,理論面の難易度が他の手法に比べると高いことなどが挙げられる。

協力ゲーム理論における複数プレイヤーの協力によって得られた利得を各プレイヤーに公正に分配するための評価手法の一つであるシャープレイ値（Shapley Value）はよく知られた手法であるが，SHAP はシャープレイ値を機械学習に応用した手法である。シャープレイ値の計算には,ある特徴量の値の増減が目的変数に与える影響を考慮するため,データ項目数が大きくなるに従い膨大なデータの組み合わせを考える必要があり,計算量が膨大になるというデメリットが存在する。特に,機械学習モデルの構築においては,データサンプル数のみならず,データ項目数も膨大になることが多く，シャープレイ値を機械学習モデルにそのまま適用するには困難が伴う。このような背景があり,SHAP では,計算量の軽減のため,シャープレイ値の計算負荷を小さくしながら近似的に計算できるよう工夫している。特に，Lundberg et al.(2020)が Nature Machine Intelligence に発表されて以降，SHAP は自然科学のみならず社会科学の分野においても XAI の分野において有効なツールの１つとして利用され始めている。

６．XAI の算出結果と考察

本章では，５章で紹介した XAI の各種手法についての分析をデータに適用し,モデルの解釈性の観点から分析結果の考察を行う。

６－１．特徴量の重要度

PFI の結果（図１,図２）を見ると,2019 年,2020 年とも残存年限,実質公債費比率,クーポンの順で重要度が高いことがわかる。2019 年と比較して,2020 年では実質公債費比率,クーポンの水準は小さな変動であるのに対し,残存年限の重要度の値が小さくなり,残存年限と実質公債費比率,クーポンの重要度の差が小さくなっていることがわかる。このことから 2019 年と比較して,2020 年では残存年限に対する投資行動に変化があったものと推測される。

■ PFI による特徴量の重要度の結果

【図１　2019 年 PFI】

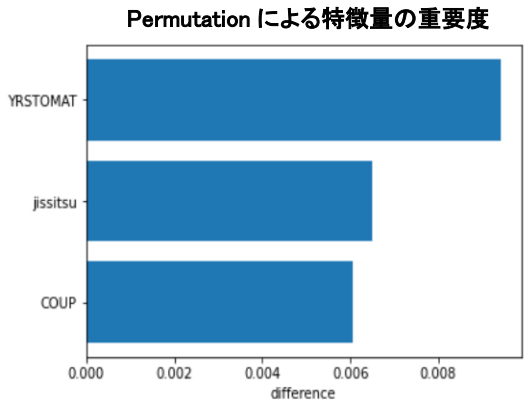

【図２　2020 年 PFI】

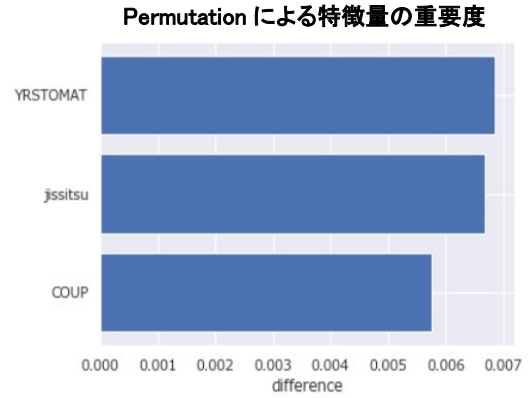

次に別の方法で特徴量の重要度の変化を確認してみる。SHAP 平均値の結果（図３，図４）をみると，特徴量の重要度は 2019 年では残存年限，実質公債費比率，クーポンの順，2020 年では実質公債費比率，残存年限，クーポンの順で高いことがわかり，2020 年では実質公債費比率の重要度が残存年限を逆転して最も高くなっている。図３の見方は，適用した全データから計算される対東京都債スプレッドの変動分 0.84bp（3 つの特徴量の合計値）のうち，残存年限（YRSTOMAT）の貢献分は 0.45bp であることを示す。実質公債費比率の SHAP 値の水準を見ると 2019 年の値（0.45）に対し 2020 年の値（0.23）が大幅に低下していることがわかる。一方，実質公債費比率の水準は 0.27 から 0.31 に若干増加，クーポンは 0.12 から 0.11 とほぼ横ばいである。この結果から，新型コロナウイルス発生前の 2019 年では残存年限が大きくなるほどスプレッドが大きくなるという一般的な傾向が確認されるが，コロナ発生後の 2020 年ではその関係性が小さくなったことが確認される。また，実質公債費比率のスプレッドへの貢献度が若干上

昇したことがわかる。これらの点は，「PFI による特徴量の重要度の結果」とほぼ同様の結果である。

■ SHAP による特徴量の重要度の結果

【図３　2019 年 SHAP の平均値】

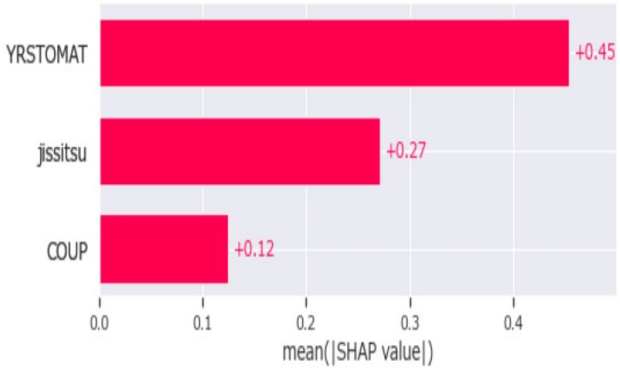

【図４　2020 年 SHAP の平均値】

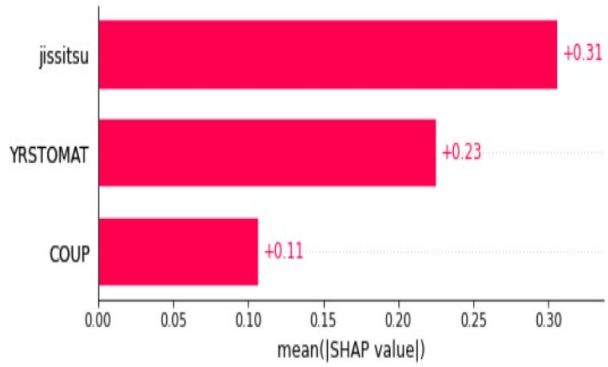

６－２．特徴量と予測値の平均的な関係（PD）とインスタンスごとの関係（ICE）

図５，図６は実質公債費比率と予測スプレッド値の平均的な関係である PD を表している。図５の 2019 年に対し，図６の 2020 年では，実質公債費比率が比較的高い 15 以上の領域で PD の水準がやや低下していることがわかる。これは実質公債費比率が比較的高い 15 以上の領域で地方債が平均的には買われたことを示している。

【図５　2019 年実質公債費比率 PD】

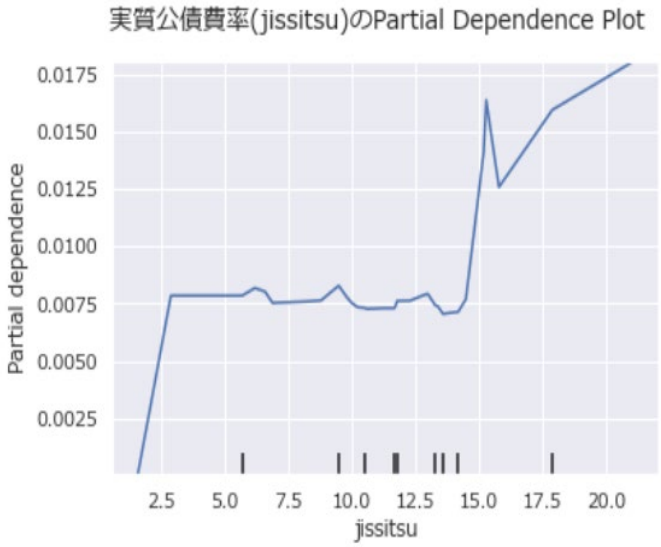

【図６　2020 年実質公債費比率 PD】

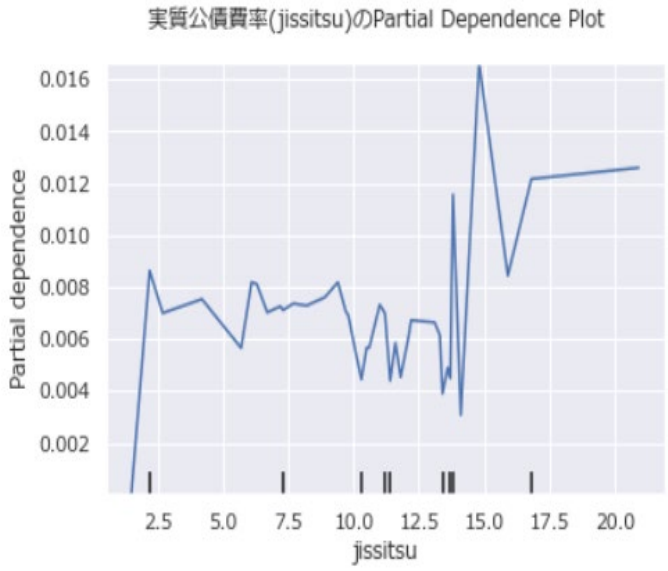

インスタンスごとの関係である ICE（図７,図８）を確認すると，図７の 2019 年では実質公債費比率が高い 15 以上の領域で PD の値が 0.03 程度のものが多く見られるのに対し,2020 年では概ね 0.02 以下となっていることがわかる。これは,新型コロナウイルスの発生によるリスク回避から,やや高めの実質公債費率の自治体であっても安全資産としての地方債へ資金が流れてきた可能性がある。この結果は図５,図６の PD の結果と整合的である。

【図７　2019 年実質公債費比率 ICE】

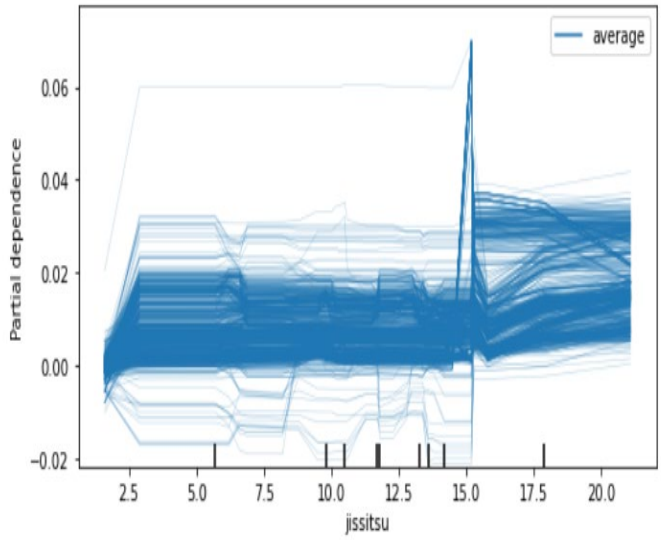

【図８　2020 年実質公債費比率 ICE】

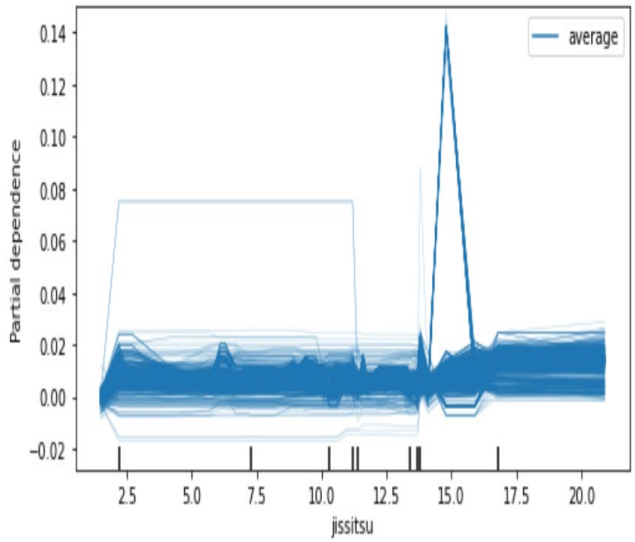

残存年限と予測スプレッド値の平均的な関係（図９, 図 10）をみると, 2019 年（図９）と 2020 年（図 10）で PD の形状が大きく変わっていることがわかる。2019 年対比で 2020 年では, 残存年限３年程度の PD が上昇しており短期債の中には売られた銘柄がある一方, 残存年限 10 年から 17.5 年程度の PD が下落しており長期債の中には買われた銘柄があることがわかる。この結果は図１から図４の結果と整合的であり, 地方債の年限に対して投資行動の変化が大きかったことがわかる。

【図 9　2019 年残存年限 PD】

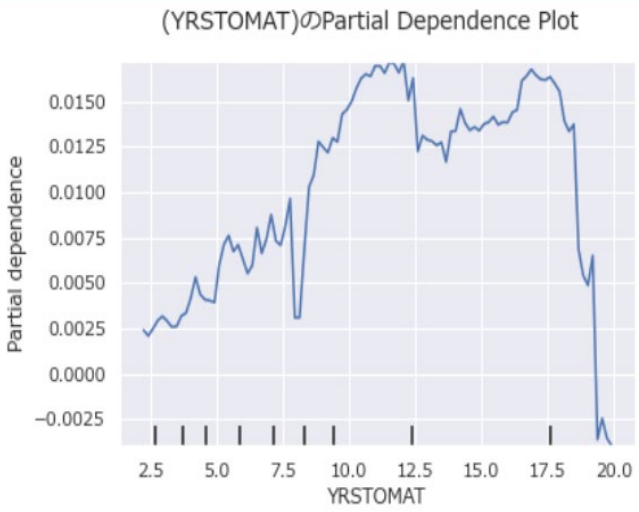

【図 10　2020 年残存年限 PD】

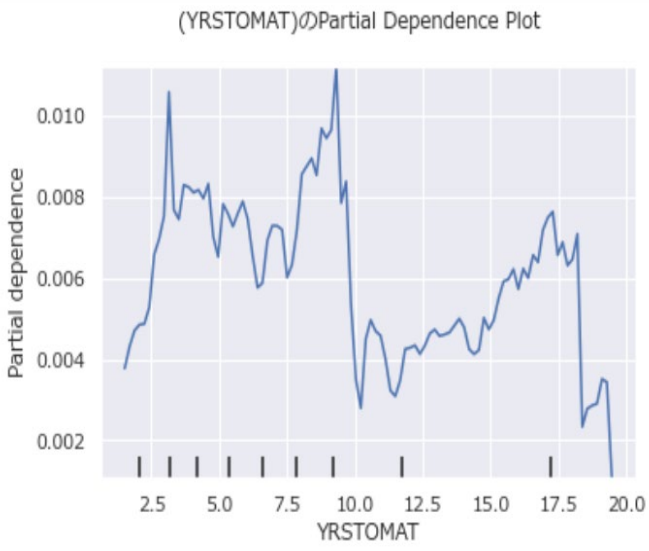

ICE の結果（図 11, 図 12）からは, 2019 年（図 11）においては PD が 0.02 を超えているものも一定数見られるが, 2020 年（図 12）ではおおむね 0.02 を下回っており，2020 年には中長期債が全体的に買われていたことが確認できる。

【図 11　2019 年残存年限 ICE】

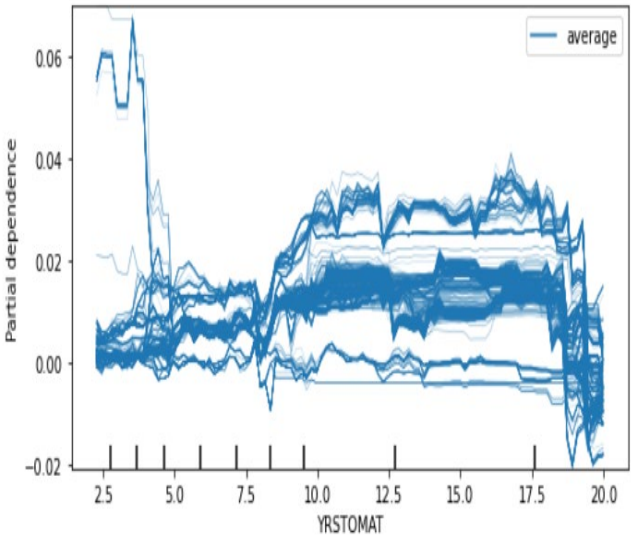

【図 12　2020 年残存年限 ICE】

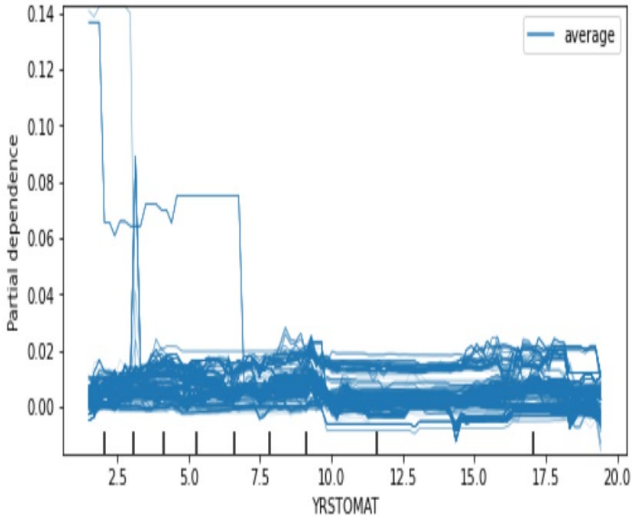

６－３．目的変数に対して行った予測の理由

SHAP 値の分布の出力結果である図 13 において, 横軸が目的変数への寄与度の大きさ, 縦軸が特徴量の貢献度の順位を示す。赤は各特徴量が正の値, 青が負の値を表す。例えば, jisshitsu は jissitsu の値が小さくなる青色が横軸のマイナスの領域に多く見られるため, 目的変数への寄与度が小さく（左側）なり, jissitsu の値が大きく（赤）なるほど目的変数へ寄与度が大きく（右側）なる。つまり, jissitsu は目的変数と正の相関があることがわかる。また, 縦軸の特徴量の序列は残存年限, 実質公債費率, クーポンの順番なので, 特徴量の貢献度の順位がこの順番に高いことがわかる。

【図 13　2019 年 SHAP 分布】

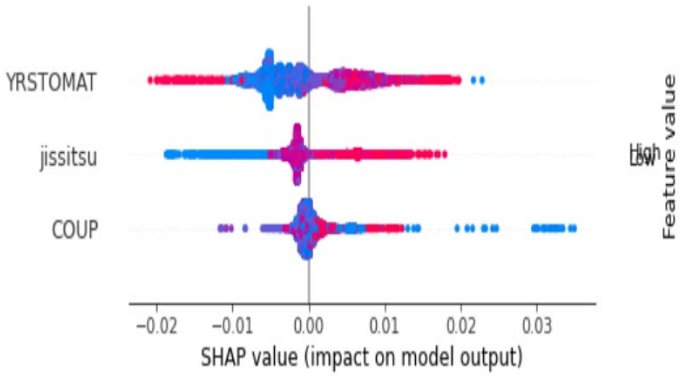

※図 13～図 20 のカラー版についてはネット掲載論文（ゆうちょ財団「ゆうちょ資産研究（論文集）」）を参照のこと。

【図 14　2020 年 SHAP 分布】

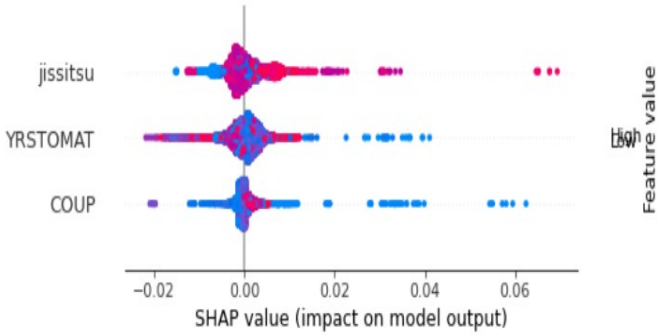

図 13 を見ると，2019 年で説明力の高い特徴量は，残存年限，実質公債費率，クーポンの順であり，各特徴量とも概ね正負の関係性は理論上整合的となっていることが確認される。次に，図 13 と図 14 を比較すると，残存年限の SHAP の分布が 2019 年と 2020 年では大きく変化していることがわかる。2019 年においては一部の中長期債（左端の赤）に SHAP 値が小さいものが見られる点を除き，残存年限とスプレッドの関係は，左側が青で右側が赤い正の関係だった。2020 年にはその関係が大きく崩れ，もはや正の関係性が見られない。つまり，上記でも見たように一部の短期債が売られ一部の中長期債が買われたため，正の関係性が崩れ残存年限のスプレッドへの説明力が低下したことが推測される。他方，2020 年において一部の銘柄で実質公債費比率が高い銘柄（赤）やクーポンが低い銘柄（青）で SHAP 値が大きくなっていることがわかる。これは，一部の実質公債費比率が比較的高い銘柄やクーポンが小さい短期債銘柄が売られスプレッドが高まったものと推測される。

【図 15 2019 年実質公債費比率と残存年限】

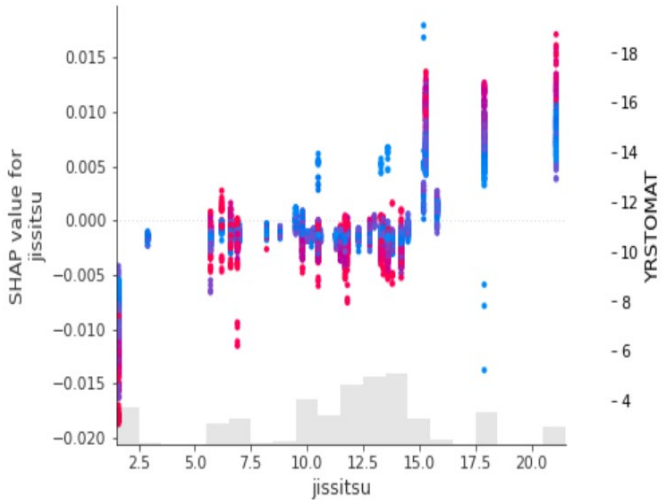

【図 16 2020 年実質公債費比率と残存年限】

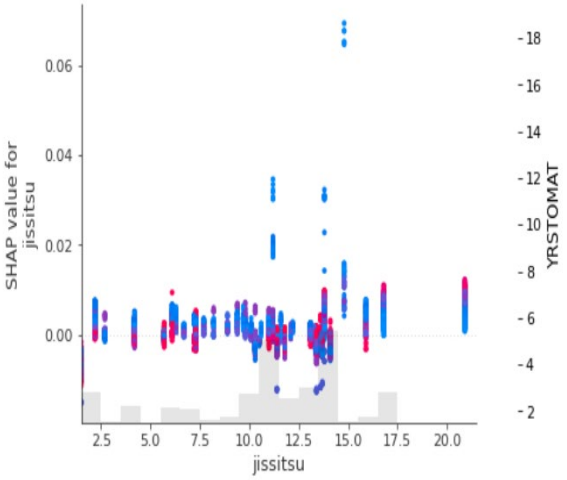

次に，２つの特徴量を対象とした SHAP 値の分布を確認する。図 15 の点の色は右軸の残存年限（YRSTOMAT）の値の水準を表しており赤は高く，青は低いことを表す。横軸は実質公債費率（jissitsu）の水準を表し，縦軸は SHAP 値の水準を表す。図 15 を見ると 2019 年には SHAP 値は約 0.02 以下の範囲にあったが，2020 年には取りうる値の範囲の上限が大きくなり，約 0.07 以下の範囲と大幅に SHAP 値の範囲が上昇している銘柄が見られる（図 16）。特に，図 16 の横軸の実質公債費比率が 10 から 15 の中程度の実質公債費比率の短期債銘柄（青色）においていくつかの青い点が高い値に飛んでおりスプレッドの上昇が大きいものが見られることがわかる。また，図 16 の薄いグレーの棒グラフを見ると実質公債費比率が 10 から 15 程度で高い値を示していることから，この範囲が多くの地方債銘柄の実質公債費比率のボリュームゾーンであり，平均的な信用リスクの自治体の短期債では売られたものがあることがわかる。

【図 17 2019 年残存年限と実質公債費比率】

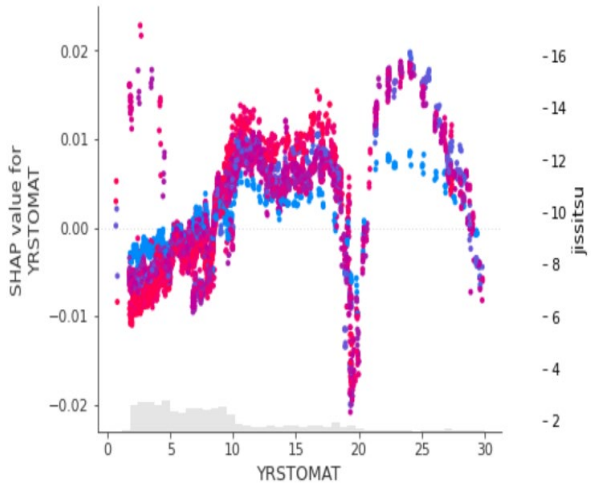

【図 18 2020 年残存年限と実質公債費比率】

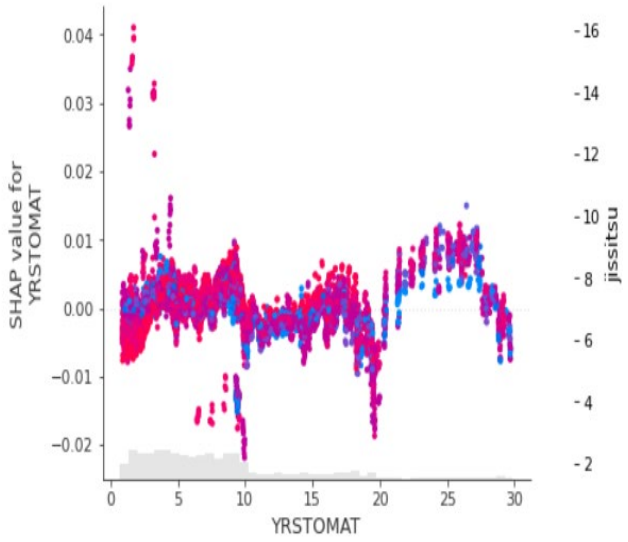

残存年限（YRSTOMAT）と実質公債費率（jissitsu）の２変量の横軸と縦軸を入れ替えた図 17 を見ると 2019 年には SHAP 値は 0.02 超以下の範囲であったが,2020 年には 0.04 超以下と大幅に SHAP 値の範囲が上昇している銘柄が見られる（図 18）。特に，図 18 において,残存年限が 5 年以下の短期債で実質公債費比率が高めの銘柄（赤色）においてスプレッドが上昇し売られたものがあることがわかる。

【図 19 2019 年クーポンと残存年限】

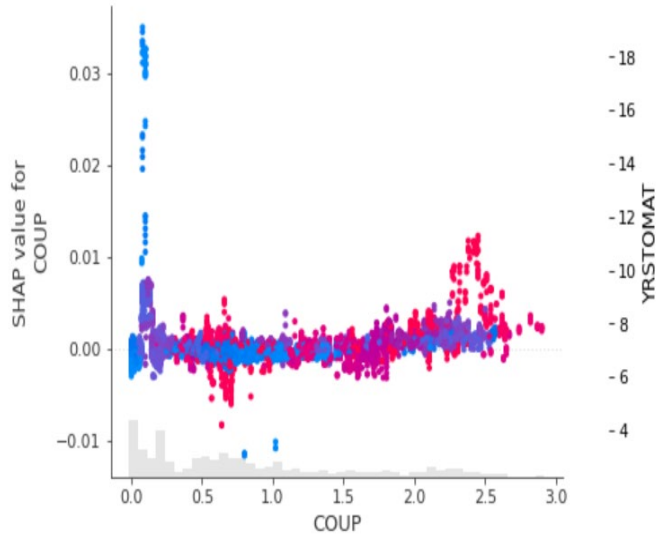

【図 20 2020 年クーポンと残存年限】

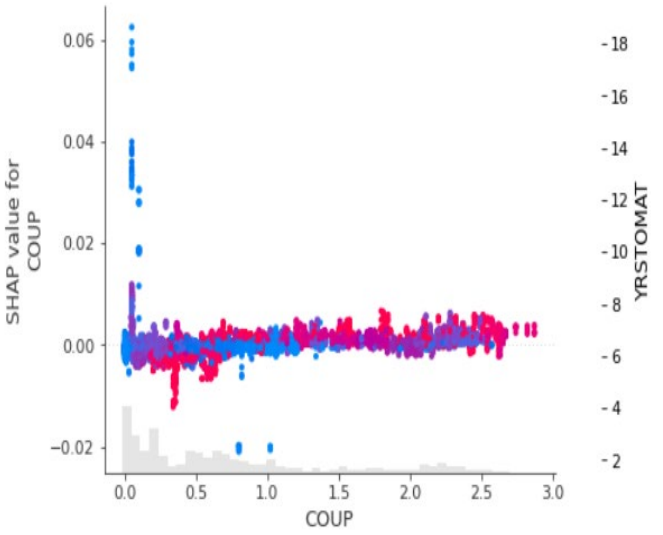

図 19 を見ると 2019 年には SHAP は 0.03 超以下の範囲であったが, 2020 年には 0.06 超以下と大幅に SHAP 値の範囲が上昇している銘柄が見られる（図 20）。特に, クーポンが 0 近辺と非常に小さい短期債銘柄（青色）においてスプレッドの上昇が大きいものが見られ, 2020 年に売られた銘柄があることがわかる。

7．まとめ

新型コロナウイルス発生前後のそれぞれの期間において, 機械学習によりスプレッド推定モデルを構築した。説明力の高いモデルは Random Forest Regressor であることが確認でき, 選択された説明変数は残存年限, 実質公債費率, クーポン金利であった。「説明可能な AI（XAI）」を活用し, 地方公共団体間のスプレッド差の要因と新型コロナウイル

ス発生前後の要因の変化について考察を行うと,新型コロナウイルス発生後の 2020 年では 2019 年に比べ,残存年限との関係性が小さくなったことがわかる。短期債の中には売られたものがある一方,中長期債は全体的に買われていたことによる影響と推測される。新型コロナウイルスの発生によるリスク回避から,やや高めの実質公債費率の自治体であっても安全資産としての地方債へ資金が流れてきたと推測される一方,実質公債費比率が平均的で残存年限が 5 年以下の短期債銘柄の中には売られた銘柄があると推測される。このように新型コロナウイルス禍においては,安全資産としての地方債投資への投資増加と短期的な不確実性からの回避による短期債から中長期債への投資対象への転換が見られたことがわかる。これらの結果から,新型コロナウイルス禍における地方債投資家の投資行動の詳細な変化を確認できたことは大きな成果である。この結果により,投資家がどのようなリスク変数に注目し,投資行動を変化させているかを理解することがある程度可能となった。これらの結果を利用して,経済的イベントが発生した際のリスクを考慮した投資方法が考えられる。具体的には,新型コロナウイルス時には,市場に与える短期的な先行きの不透明感から短期債の中には売られ,中長期債は全体的に買われていた,特にやや高めの実質公債費率の自治体であっても地方債へ資金が流れてきたため,現在の経済環境下での地方債への投資は一般的には安全であると言えるだろう。しかし, 5 年以下の短期債銘柄の中には売られた銘柄があったため,特に短期地方債については銘柄選択に非常に注意を要すると言える。このように新型コロナウイルス禍においては,安全資産としての地方債投資への投資増加と短期的な不確実性からの回避による短期債から中長期債への投資対象への転換が見られた。再び新型コロナウイルスの拡大が見られる場合は,同様の投資行動の変化が発生する可能性も高く,今後のリスク管理の知見となるものと考えられる。

今後の課題として,XAI のその他の手法の適用と解釈を試みる。また,上記の分析で投資行動の変化がある程度把握できたものもあるが,実際にどの地方公共団体のどのような属性の銘柄が多く売られ（または買われ）たかという問題がある。その把握のためには今回の手法だけでは限界はあると考えられるが,個別のデータを分析していくなど,別のアプローチも併用して分析を行う必要があると考える。今回のような新型コロナウイルス発生という大きなイベントに対して,売り買いの多かった具体的な銘柄の特定まで行うことができれば,実務上も有意義な情報となり得ると考える。また,経済的に大きなインパクトを与える新型コロナウイルス以外のイベントに対して,同様の投資行動の変化が見られるかについては, 今後他の経済イベントについても同様の分析と検証を行う必要がある。他の経済イベントにおいても投資行動の変化が確認できれば,次に起こりうる大きな経済イベントに対しても類似の経済イベントや経済状況に対し,ある程度の地方債への影響が予想することができる可能性もあり,今後のリスク管理において大きな知見となるだろう。

さらに,このような知見を前提にし,よりよい地方債市場を目指すためにはいくつかのアプローチが考えられる。一つ目の観点は,ファイナンスからのアプローチである。

現在の地方債市場においては「暗黙の政府保証」の存在により,本邦の地方債市場の透明性には課題があると考えられる。地方債市場に何らかの信用リスクイベントが発生した際,日本政府の対応に不確実性がある場合には,投資家はそれをリスクとみなし,追加のスプレッドを要求することになる可能性が大きい。地方債に対して政府保証を行うのか,行わないのか,またその際のルールを社会全体で議論し制度化していくことが重要であると考える。その際には,欧米における地方債市場のルール,現状把握と課題の分析が参考になるであろう。また,政府保証を行わない場合は,地方公共団体間の競争を段階的に徐々に促していく必要があると考える。二つ目の観点は会計学からのアプローチである。会計学においては,財務・会計情報の意思決定有用性や公開タイミングのルール化などの有効性の検証とそれらの制度設計が重要となる。三つ目の観点は,財政学からのアプローチである。市場原理により地方公共団体間の健全化と競争を促すためには中央集権的な財源構造を徐々に分権化していく必要があると考える。この点に関しては,財政学の専門家とも議論をすすめていく必要があると考えている。

参考文献

井潟 正彦, 三宅 裕樹 (2007)「わが国地方債市場のインフラ整備の現状と展望」『資本市場クォータリー』第 11 巻第 2 号, 31～45 頁。

石川 達哉 (2007)「市場公募地方債の流通利回りと信用リスク」『ニッセイ基礎研究所・経済調査レポート』No.2007-01。

石田三成,中里透 (2019)「地方債の信用リスクとスピルオーバー」『地方債の経済分析』有斐閣。

大坪直樹他 (2021)『XAI(説明可能な AI)--そのとき人工知能はどう考えたのか?』リックテレコム。

総務省 (2020)「統一的な基準による財務書類の作成状況等に関する調査 (令和 2 年 3 月 31 日時点)」総務省公表資料 (令和 2 年 8 月 9 日)。

中里透 (2008)「財政収支と債券市場－市場公募地方債を対象とした分析」『日本経済研究』第 58 号,1～16 頁。

田中宏樹 (2012)「地方債をめぐる地方公共団体間信用連関－市場公募債パネルデータを用いた実証分析」『証券経済研究』第 78 号,69～79 頁。

原口健太郎,丹波靖博 (2021)「わが国における公会計と地方債市場に関する分野横断的研究の展開可能性」『商学論集 (西南学院大学)』第 67 巻第 3・4 合併号,169～199 頁。

原口健太郎, 丹波靖博 (2022)「わが国の統一的な基準に基づく公会計財務諸表が有する増分情報と地方債スプレッドとの関連性分析」『会計プログレス』近刊。(査読採択済み) 。

丹波靖博, 原口健太郎 (2023a)「機械学習を用いたわが国における地方債のスプレッド

推定モデルの構築」『JAFEE ジャーナル』近刊。（査読採択済み）。
丹波靖博，原口健太郎(2023b)「説明可能なAI(XAI)による機械学習モデルの特性分析」第 57 巻第 1・2・3・4 合併号, 29～44 頁。
三宅　裕樹（2017）「わが国地方債市場における信用リスク ： 起債自由化改革・夕張ショックが与えた影響（植田和弘教授記念號）」『京都大学経済学会経済論叢』191(2), 161-178 頁。
森下光之助（2021）『機械学習を解釈する技術～予測力と説明力を両立する実践テクニック』技術評論社。
Capeci,J. (1991) Credit Risk,Credit Ratings,and Municipal Bond Yields: A Panel Study, *National Tax Journal*, 44 (4), pp.41-56.
Downing, C. and F. Zhang (2004). Trading Activity and Price Volatility in the Municipal Bond Market, *The Journal of Finance*,59 (2), pp.899-931.
Goldsterin,M. and G. Woglom. (1991) Market-Based Fiscal Discipline in Monetary Unions: Evidence from the U.S. Municipal Bond Market, *IMF Working Paper*, WP/91/89.
Hattori, T. and H. Miyake (2015) Empirical Analysis of Yield Determinants in Japan's Municipal Bond Market: Does Credit Risk Premium Exist? *MPRA Paper 67127,* University Library of Munich, Germany.
Haraguchi,K. and K. Oishi (2019) The International Differences in the Relationship between Public Financial Reports and Bond Markets: A Comparison between Japanese Local Governments and U.S. States, *Discussion Paper Series (Kyushu University)*, No. 2019-5, pp.1-17.
Harris, L. E. and M. S. Piwowar. (2006) Secondary Trading Cost in the Municipal Bond Market, *The Journal of Finance*,61 (3), pp.1361-1397.
Liu,P. and A. V. Thakor (1984) Interest Yields,Credit Ratings,and Economic Characteristics of State Bonds: An Empirical Analysis, *Journal of Money, Credit and Banking*,16 (3), pp.344-351.
Lundberg, S.M. G. Erion, H. Chen, A. DeGrave, J. M Prutkin, B. Nair, R. Katz, J. Himmelfarb, N. Bansal,and S. Lee (2020) Explainable ai for trees: From local explanations to global understanding, *Nature Machine Learning*, 2, pp.56-67.
Novy-Marx, R. and D. R. Joshua (2011a) The crisis in local government pensions in the United States, in Robert Litan and Richard Herring, eds.: *Growing Old: Paying for Retirement and Institutional Money Management after the Financial Crisis* (Brookings Institution, Washington, DC).
Novy-Marx, R. and D. R. Joshua (2011b) Public pension promises: How big are they and what are they worth? *The Journal of Finance*,66 (4), pp.1211–1249.
Schwert,M. (2017) Municipal Bond Liquidity and Default Risk, *The Journal of Finance*,72 (4), pp.1683–1722.

Wang,J. C. Wu,and F. X. Zhang. (2008) Liquidity, Default, Taxes, and Yields on Municipal Bonds, *Journal of Banking & Finance*,32 (6), pp.1133-1149.

URL

ロンドン証券取引所 FTSE Russell グループ「The Yield Book Inc」
https://www.yieldbook.com/m/products/yield-book/index-jpn.shtml
ゆうちょ財団「ゆうちょ資産研究（論文集）」
https://www.yu-cho-f.jp/ar_center/research_aid/ronbunkensaku.html

謝辞

本研究は一般財団法人ゆうちょ財団の 2022 年度研究助成，および科学研究費補助金（JSPS KAKENHI Grant Number JP19K23214, JP20K02058, JP21K13412），日本経済研究センター研究奨励金の交付を受けて行ったものである。また，ロンドン証券取引所・FTSE グループ The Yield Book Inc. には，債券分析ソフトイールドブックを通じて効率的な分析ツールと貴重なデータを提供いただいた。この場を借りて御礼申し上げたい。

APPENDIX
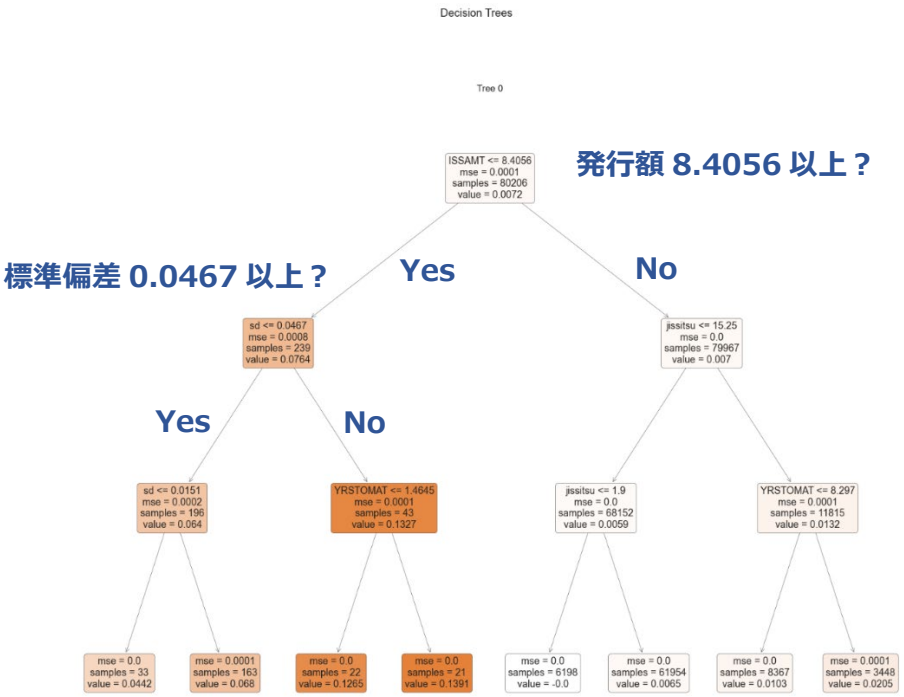
【図　決定木分析の例】