



HUB-FS Working Paper Series

FS-2024-J-002

企業の炭素排出量と信用リスクの関係について

関 俊哉

First version: 2024年2月27日

All the papers in this Discussion Paper Series are presented in the draft form. The papers are not intended to circulate to many and unspecified persons. For that reason any paper can not be reproduced or redistributed without the authors' written consent.

企業の炭素排出量と信用リスクの関係について*

関 俊哉

概 要

本研究では、2012年度から2021年度の国内上場企業を対象として、移行リスクが相対的に高い企業は、移行リスクが低い企業と比べて、信用リスクが高いかの分析を行った。具体的には、企業の移行リスクを表す指標として温室効果ガス (GHG) 排出量、CO₂ 排出量およびそれらを売上高で除した炭素強度を採用し、企業の信用リスクを表す指標として、Merton (1974) に基づくデフォルト距離を採用した上で、線形回帰分析を中心に検証を行っている。結果としては、炭素強度とデフォルト距離に負の関係があること、つまり、単位売上高当たりの炭素排出量がより多い場合、デフォルト距離が小さく、信用リスクが高くなる関係にあること、その関係は高排出セクターにおいてより顕著になることがわかった。この結果は、有賀ほか (2021) を参考にした Double Machine Learning 等で欠落変数バイアス等の対処をした場合においても変わらなかった。このことから、気候変動リスクは、金融機関の経営管理上重要なリスクとされている信用リスクと関連性があるリスクドライバーとして、投資家や金融機関において管理すべきリスクであり、その管理は、金融システム全体に対するリスクを制御する一助になると考える。

* 本研究は、JSPS 科研費 JP23K04285 の助成を受けて実施されたものである。また、本研究にあたり、多くの有益なコメントをいただいた、一橋大学大学院 経営管理研究科 中川 秀敏 教授に深謝したい。なお、本研究の内容や意見は著者個人に属し、所属機関の公式見解を示すものではない。

1 はじめに

環境・社会・ガバナンス (ESG) への意識の高まりとともに、気候変動リスクへの対応が喫緊の課題であり、気候変動の進行に伴う物理的リスクや政策の推進や技術等の進展に関連した移行リスクが、金融機関の健全性や金融システムの安定性に対するリスクに波及するという認識が広がっている。

気候変動リスクのうち、移行リスクは、石炭火力発電から再生可能エネルギーへの移行や電気自動車利用推進等による脱炭素社会へ産業構造全般が移行することなどに伴うリスクのことであり、金融機関において経営管理上重要なリスクとなる信用リスクにも影響を及ぼす可能性がある。Kabir (2021) で指摘されているように、例えば、ある企業の炭素排出量が多い場合、炭素税の導入や、再生可能エネルギーや電気自動車に対する優遇措置等の法規制の変化により、税負担や座礁資産化に起因する資産償却といった財務的打撃が大きくなり、結果として、その企業の倒産確率の上昇を通じて信用リスクが高くなる可能性がある。また、炭素排出量の多い企業は、低炭素社会への移行に適応できていない企業とみなされ、レピュテーションリスクを高めてしまう可能性があり、それが市場シェアの損失ひいては企業の倒産確率を高めてしまうおそれがある。

そうした中、炭素排出量と信用リスクの研究が海外を中心に進んでおり、Capasso et al. (2020) や Safullah et al. (2021) , Carbone et al. (2021) 等で、炭素排出量と信用リスクの関係性についての分析が行われている。国内においては、海外と比較して信用リスクに焦点をあてて検証しているものは少ないが、Okimoto and Takaoka (2022) では、信用リスクを表す指標としてクレジット・デフォルト・スワップ (CDS) と炭素排出量の関係について、検証を行っている。本研究では、これらの先行研究を参考にしつつ、「日本国内を対象として、炭素排出量もしくは企業の炭素効率を示す炭素強度が大きい企業、すなわち、移行リスクが相対的に高い企業は、移行リスクが低い企業と比べて、信用リスクが高いか」という仮説の検証を行う。つまり、「日本国内を対象にしたとき、GHG 排出量、CO₂ 排出量もしくは炭素強度と Merton (1974) に基づくデフォルト距離は有意に負の関係にあるか」ということを統計的に確認する。なお、ここでの炭素強度は、炭素排出量を売上高で除した経済的炭素強度のことを指す。Bolton and Kacperczyk (2021) が指摘するように、売上高当たりの炭素排出量と炭素排出量の絶対値では結果が異なる可能性があるため、いずれについても分析を行う。また、本研究での炭素排出は、CO₂ に限定されるものではなく、メタン (CH₄) や一酸化二窒素 (N₂O) まで含んだ温室効果ガス (GHG) を対象として分析を行う。

本研究の分析は、まず、Capasso et al. (2020) 等を参考にしつつ、現時点で炭素排出量のデータを取得できる国内上場先を対象に、Merton (1974) に基づくデフォルト距離を目的変数、GHG 排出量、CO₂ 排出量もしくは炭素強度を説明変数、企業の財務情報等をコントロール変数としたパネルデータ分析を行う。なお、Carbone et al. (2021) や Nguyen et al. (2022) を参考に金融セクターに属する企業は当該分析から除外する。あわせて、セクターにより分割したサブサンプルを作成し、同様にパネルデータ分析を実施する。これは先行研究の中で、高排出セクターにおいて炭素排出量と信用リスクの関係がより強くなることが報告されているため、本研究においても確認を行うべく実施するものである。また、欠落変数バイアスおよび目的変数とコントロール変数が非線形の関係を持つ可能性に対処するため、有賀ほか (2021) を参考に Double Machine Learning (DML) を用いて頑健性の確認を行い、線形回帰分析による結果を補完する。以上の分析を行った結果、国内の上場企業において、炭素強度とデフォルト距離に負の関係があること、その関係は炭素排出量が多いとされるセクターでより顕著に見られることがわかった。

本研究の意義は、大きく2つあると考える。まず1つ目としては、信用リスクを表す指標としてデフォルト距離を採用する点である。前述のとおり、日本国内においては、炭素排出量と信用リスクの関係に焦点をあて

て研究を行っているものは少なく、それをテーマに報告している Okimoto and Takaoka (2022) においても、CDS スプレッドと炭素排出量の関係に着目して分析を行っている。CDS は一時的なネガティブニュースに対し、過度にスプレッドが大きくなることや企業の信用力以外の要因、例えば、流動性の低下の影響を受けることが指摘されているため、本研究では、デフォルト距離を用いることで、Okimoto and Takaoka (2022) の「排出量が多い企業は、カーボンリスクが高いとみなされ、CDS スプレッドが大きくなる（信用リスクが高くなる）傾向にある」という結論を検証、補完することを目指す。なお、信用リスクを表す指標としてデフォルト距離を採用するものとしては、筆者の知る限り本研究が国内ではじめてである。

2つ目としては、DML を用いた頑健性の確認を行い、先行研究では活用されなかった分析手法を用いる点である。有賀ほか (2021) で述べられている通り、既存の研究は、基本的に線形回帰モデルを軸に分析を行っており、目的変数（デフォルト距離）とコントロール変数が非線形の関係を持つ可能性に対処できていないおそれや特定のコントロール変数を選択的に採用しているため、欠落変数バイアスが生じるおそれがある。そのため、本研究では、有賀ほか (2021) を参考に線形回帰モデルとともに Chernozhukov et al. (2018) が提案した DML を用いたセミパラメトリック・モデルによる分析も行う。

2 先行研究と仮説

本節では、炭素排出量と信用リスクの関係について、日本国内と比較して研究が進んでいる海外を中心にすでに報告されている先行研究をまとめる。当該先行研究を踏まえた上で、本研究における仮説を示す。

2.1 先行研究

海外における炭素排出量と信用リスクに関する研究は、信用リスクを表す指標としてどのような変数を用いたかによって大別される。信用リスク指標として用いられているものとしては、財務情報や市場情報等を加味したデフォルト距離や信用格付、主に財務情報を勘案した負債コスト（例えば、企業の支払利息や有利子負債の情報から計測される）、主に市場情報を勘案した市場性の債券スプレッド、CDS スプレッドなどが挙げられる。まず、炭素排出量とデフォルト距離を対象に分析したものとしては、Capasso et al. (2020) や Kabir et al. (2021) , Nguyen et al. (2022) が挙げられる。Capasso et al. (2020) では、欧州企業を対象に、炭素排出量および炭素強度とデフォルト距離の関係について、企業単位のパネルデータを対象に線形回帰モデルを用いて分析し、両者に負の関係があること、すなわち、炭素排出量が多いほどデフォルト距離が小さくなることを示している。Kabir et al. (2021) においても、42 ヶ国の企業を対象に炭素排出量とデフォルト距離に負の関係があること、炭素排出量が多い企業ほどその影響を受けやすいことを示している。また、Nguyen et al. (2022) では、S&P500 の非金融セクターの企業を対象に分析を行っているが、こちらの論文においても、炭素強度とデフォルト距離が負の関係にあることを示している。

次に、炭素排出量と信用格付を対象に分析したものとしては、Safiullah et al. (2021) が挙げられる。Safiullah et al. (2021) では、パネルデータ分析を通して、炭素排出量の多さが信用格付に負の影響を与えていることが確認されている。この結果は上で述べたデフォルト距離における研究と同様、炭素排出が大きいほど、信用リスクが大きくなることを示している。Carbone et al. (2021) においては、欧州の非金融セクターの企業を対象に信用格付とデフォルト距離という枠組みの両方を用いて評価することで、信用リスクに焦点を当てた既存の文献よりも全体像を把握できる形で報告を行っており、炭素排出量と信用リスクに正の関係があることを示している。これらの研究に加えて、炭素排出量ではなく、ESG スコアにおける環境パフォーマンスと信用格付の関係を報告している研究もあり、Attig et al. (2013) や Bauer and Hann (2010) が挙げられる。Attig et al. (2013) では、企業の信用格付と環境パフォーマンスを含む ESG スコアの関係を分析し、環境パフォーマンスが良いほど格付が良くなることを示しており、Bauer and Hann (2010) では、環境パフォーマンスの低さは、社債の信用格付の悪化とスプレッドの上昇に関連することを実証している。

また、デフォルト距離や信用格付以外にも財務情報をベースとした負債コストや市場情報をベースとした債券スプレッド、CDS スプレッドと炭素排出量もしくは環境パフォーマンスの関係について分析するものも報告されている。負債コストについては、Chava (2014) や Eliwa et al. (2021) , Delis et al. (2018) , Jung et al. (2018) , Kleimeier and Viehs (2018) , Liu et al. (2019) , Wang et al. (2021) が挙げられ、債券スプレッドや CDS スプレッドについては、Barth et al. (2022) や Höck et al. (2020) , Seltzer et al. (2022) が挙げられる。いずれも炭素排出量が多い企業や環境パフォーマンスが悪い企業は、負債コストや債券スプレッド、CDS スプレッドという形で表された信用リスクが高いという傾向にあることが示されている。

一方で、日本国内においては、炭素排出量と、株式リターンや企業パフォーマンスといったファイナンス関連指標との関係に関する研究はあるものの信用リスクとの関係に着目したものは少ない。信用リスクとの

関係に焦点をあてた研究としては、Okimoto and Takaoka (2022) が挙げられ、CDS スプレッドと炭素排出量の関係に着目して、長期の CDS スプレッドに炭素排出量が影響を与えていることを示唆している。一方で、ROA やトービンの q といった企業パフォーマンスと炭素排出量に関する研究としては、有賀ほか (2021) が挙げられる。有賀ほか (2021) では、既存研究における欠落変数の存在や線形回帰モデルの欠点を指摘し、Chernozhukov et al. (2018) で提唱された DML の手法を採択した上で、CO₂ 排出量の少ない企業ほど長期的な企業パフォーマンスが良好になり、株主資本コストが低くなることを確認している。有賀ほか (2021) で用いられた DML の手法を本研究の頑健性の確認において採用する。

2.2 仮説

上で見たとおり、先行研究では炭素排出量の多さと当該企業の信用リスクに正の関係があることが確認されているが、先行研究は海外企業を対象にしたものが多く、日本国内ではこの関係に着目した研究は少ない。その日本国内を対象とした研究である Okimoto and Takaoka (2022) では、CDS スプレッドと炭素排出量の関係に着目して分析を行っているが、CDS は一時的なネガティブニュースに対し、過度にスプレッドが大きくなることや企業の信用力以外の要因、例えば、流動性の低下の影響を受けることが指摘されている。このような問題点から信用リスクを表す他の指標で検証をすることが望ましいと考える。

そこで、本研究においては、信用リスクを表す指標として、Merton (1974) に基づくデフォルト距離を採用する。デフォルト距離の定義は、「現時点の企業資産の市場価値」を A_0 、「将来の負債総額」を D_T 、「企業資産の期待成長率」を μ_A 、「企業資産のボラティリティ」を σ_A 、「将来時点」を T とすると、

$$DD = \frac{\ln\left(\frac{A_0}{D_T}\right) + \left(\mu_A - \frac{\sigma_A^2}{2}\right)T}{\sigma_A\sqrt{T}}$$

であり、負債満期において債務超過状態になることを企業の倒産とみなしたとき、企業の資産価値がデフォルトからどの程度離れているか、資産価値のボラティリティを基準に計測するものと解釈できる。また、対象企業の信用リスクをモニタリングするために金融機関等で活用されることが多く、代表的な信用リスク指標である。炭素排出量が信用リスクに波及する経路として、炭素排出量が多くなると、レピュテーションや炭素税等の観点から企業の売上高やキャッシュフローが悪化し、ひいては B/S に悪影響を及ぼすことが考えられる。デフォルト距離の計算においては、上式のとおり、B/S 上の負債の情報 (D_T) を利用するので、デフォルト距離を利用することでこの波及経路を考慮した分析ができると考える。なお、デフォルト距離の定義や細かな変数の設定は付録 A を参照されたい。

あわせて、セクターにより分割したサブサンプルを作成し、分析を実施する。これは、高排出セクターにおいて炭素排出量と信用リスクの関係がより強くなることが報告されているため、本研究においても確認を行うべく実施するものである。信用リスク管理上、セクターごとにリスクが違うということであれば、管理方法が大きく変わる可能性があるため、このサブサンプル分析は重要だと考える。

以上を踏まえ、本研究では以下の仮説について検証を行う。

仮説 1：日本国内を対象にしたとき、GHG 排出量、CO₂ 排出量もしくは炭素強度とデフォルト距離は負の関係にある。

仮説 2：高排出セクターに限定したサンプルにおいて、GHG 排出量、CO₂ 排出量もしくは炭素強度とデフォルト距離との負の関係性は強くなる。

3 研究方法

本節では、前節に示した2つの仮説を検証するために使用するデータおよび検証方法を示す。まず、研究対象と利用するデータについて説明する。次に仮説を検証するための方法として、線形回帰モデルを用いる分析について説明する。くわえて、結果の頑健性を確かめるために Double Machine Learning (DML) を用いる分析手法について説明する。

3.1 研究対象と利用データ

研究対象は、2022年10月時点で日本国内で上場している企業のうち、炭素排出量 (GHG 排出量データもしくは CO₂ 排出量データ) を取得でき、くわえてデフォルト距離を計算できる企業 831 社とする。前節で述べたとおり、Carbone et al. (2021) や Nguyen et al. (2022) を参考に金融セクターに属する企業は当該分析から除外する。

企業により開示される炭素排出量は、基本的に1年間の排出量として開示され、その1年間は、当該企業の会計期間に対応して、開示されることが多い。また、炭素排出量は、事業者自らによる温室効果ガスの直接排出 (燃料の燃焼、工業プロセス) を指す Scope1、他社から供給された電気、熱・蒸気の使用に伴う間接排出を指す Scope2、Scope1 および Scope2 以外の間接排出 (事業者の活動に関連する他社の排出) を指す Scope3 に大別されるが、本研究では、Scope1 および Scope2 の排出量の合計を炭素排出量として扱う。Busch et al. (2022) で述べられているように、Bloomberg や CDP, Thomson Reuters, MSCI 等のデータ取得源の間において、また、企業間においても算定基準の違いなどから、Scope3 の炭素排出量データにばらつきがあることがわかっており、その点に鑑み、本研究においては、Scope3 は分析対象外とする。

本研究の分析にあたっては、有賀ほか (2021) を参考に対象企業の多さの点で Bloomberg の GHG 排出量データを利用する。そして、2022年10月末の日本国内の上場先を対象に十分なデータが取得できる2012年度から2021年度における排出量データを対象とする。Bloomberg には、GHG 排出量のデータを基礎としつつ、GHG 排出量のデータがない場合は、CO₂ 排出量データで補完を行うデータ項目があり、昨今のカーボン・ニュートラル対応では GHG 排出量が中心的な指標になっていること、一方で CO₂ 排出量データの方がカバレッジが大きいことから、当該データ項目を採用する。なお、分析にあたっては、GHG 排出量を用いているか CO₂ 排出量を用いているかはダミー変数を用いてコントロールする。

デフォルト距離の計算にあたっては、日次の株価データおよび四半期次の負債データを SPEEDA から取得する。また、財務指標等のコントロール変数やマクロ変数のデータは、炭素排出量のデータとあわせて Bloomberg から取得する。

3.2 各変数の基本統計量と相関

各変数の基本統計量と相関係数行列は、表1, 2のとおりである。なお、炭素排出量および総資産は自然対数値であり、炭素強度は、炭素排出量/売上高で算出しているものである。炭素排出量の元の単位は1,000メートルトン、総資産、売上高の元の単位は10億円である。

表 1: 基本統計量

本表は、線形回帰モデルで採用する各変数のウィンソライズ処理後の基本統計量である。炭素排出量は、GHG 排出量 (GHG 排出量が開示されていない場合は、CO₂ 排出量)、炭素強度は炭素排出量/売上高、ボラティリティはデフォルト距離の計算過程で得られる企業資産のボラティリティである。なお、炭素強度が 0 になる先は、小数第 4 位以下で値があるものであり、炭素排出量と総資産は自然対数値である。

	サンプルサイズ	平均	標準偏差	最小値	25% 点	50% 点	75% 点	最大値
デフォルト距離	5492	5.465	2.706	0.526	3.598	5.046	6.866	16.061
炭素排出量 (ln)	5492	4.716	2.319	-1.872	3.239	4.596	6.240	10.991
炭素強度	5492	1.656	4.401	0.000	0.170	0.410	0.990	35.355
有利子負債/総資産	5492	0.202	0.163	0.000	0.064	0.172	0.310	0.680
営業利益率	5492	0.074	0.080	-0.145	0.032	0.057	0.093	0.504
剰余金/総資産	5492	0.341	0.192	-0.202	0.200	0.335	0.468	0.814
総資産 (ln)	5492	5.754	1.539	2.180	4.652	5.694	6.777	9.853
運転資本/総資産	5492	0.214	0.172	-0.187	0.093	0.210	0.335	0.650
固定資産/総資産	5492	0.831	0.476	0.037	0.473	0.803	1.089	2.515
ボラティリティ	5492	0.164	0.084	0.026	0.100	0.151	0.213	0.481

表 2: 相関係数行列

本表は、線形回帰モデルで採用する各変数の相関係数行列である。炭素排出量は、GHG 排出量 (GHG 排出量が開示されていない場合は、CO₂ 排出量)、炭素強度は炭素排出量/売上高、ボラティリティはデフォルト距離の計算過程で得られる企業資産のボラティリティである。なお、炭素排出量と総資産は自然対数値である。

	デフォルト 距離	炭素排出量 (ln)	炭素強度	負債 /総資産	営業 利益率	剰余金 /総資産	総資産 (ln)	運転資本 /総資産	固定資産 /総資産	ボラティ リティ
デフォルト距離	1.000									
炭素排出量 (ln)	-0.141	1.000								
炭素強度	-0.143	0.522	1.000							
有利子負債/総資産	-0.346	0.452	0.380	1.000						
営業利益率	0.381	-0.099	-0.066	-0.090	1.000					
剰余金/総資産	0.437	-0.250	-0.199	-0.691	0.242	1.000				
総資産 (ln)	-0.030	0.761	0.200	0.324	0.091	-0.152	1.000			
運転資本/総資産	0.251	-0.454	-0.273	-0.648	0.151	0.604	-0.337	1.000		
固定資産/総資産	-0.162	0.495	0.502	0.437	-0.125	-0.242	0.070	-0.463	1.000	
ボラティリティ	0.102	-0.334	-0.208	-0.514	0.327	0.489	-0.250	0.568	-0.284	1.000

3.3 線形回帰モデル

本研究では、まず、以下の

$$DD_{it} = \alpha + \beta X_{it} + \sum_k \gamma_k Y_{k,it} + \sum_\ell \delta_\ell Z_{\ell,t} + \varepsilon_{it} \quad (1)$$

という線形回帰モデルを中心に検証を行う。(1) 式の変数の添え字 i は各企業、 t は各時点を表すものとする。まず、目的変数 DD_{it} は、信用リスクを表す指標として、Merton の構造型モデルにおけるデフォルト距離を採用する。デフォルト距離については、2.2 節で述べたように値が大きいほど B/S 上での債務超過の可能性という点で、信用リスクが低く、値が小さいほど信用リスクが高いと解釈できる。算出方法は付録 A を参照されたい。説明変数 X_{it} は、先行研究同様、「炭素排出量 (GHG 排出量データもしくは CO₂ 排出量データ) の自然対数値」、あるいは「炭素強度 (炭素排出量/売上高)」のいずれかとし、それぞれについて分析を行う。また、前項で述べたとおり、説明変数 X_{it} として GHG 排出量もしくは CO₂ 排出量を用いているかは (1) 式の線形回帰モデルに、切片に対するダミー変数を組み入れることでコントロールする。仮説 1 については、(1) 式において、 β が有意に負になるかを確認し、仮説 2 については、高排出セクターとそれ以外のセクターの 2 つの企業グループに分けて分析したときに高排出セクターに属するグループの方が β が有意に負で、絶対値が大きくなっているかを確認することになる。

コントロール変数 $\{Y_{k,it}\}$ は、Capasso et al. (2020) や有賀ほか (2021) などの先行研究を参考に、有利子負債/総資産、営業利益率、剰余金/総資産、総資産の自然対数値、運転資本/総資産、固定資産/総資産、デフォルト距離の計算過程で得られる企業資産のボラティリティを採用する。また、マクロ変数の $\{Z_{\ell,t}\}$ については、同様の先行研究を参考に、West Texas Intermediate (WTI) 価格および四半期ごとの GDP 成長率を採用する。前項で述べたとおり、開示されている炭素排出量情報は、当該企業の会計年度に準じて開示されており、基本的にコントロール変数として用いる財務情報と炭素排出量情報は同じ期間を対象としている。また、Safiullah et al. (2021) や有賀ほか (2021) などの先行研究と同様、時間の固定効果と産業ダミーを導入する。すなわち、対象のデフォルト距離の年度および対象企業の属する産業セクターにしたがい、(1) 式の線形回帰モデルにおいて、切片に対するダミー変数を組み入れる。産業ダミーについては、カーボン・ニュートラル対応でスタンダードになっている世界産業分類基準 (GICS) の Industry Group を用いる。 ε_{it} は誤差項である。

なお、Capasso et al. (2020) で述べられているように、デフォルト距離については、同一企業内で系列相関している傾向にある。そのため、標準誤差の計算の際には、同一企業内の年度ごとの誤差項について、互いに相関があり、分散も不均一であるという仮定を許容する、企業のクラスタリングに対してロバストな標準誤差を算出する。本研究においては、R の estimatr パッケージの `lm_robust` を用いて、企業をクラスタとして指定し、Stata で求められるものと同じクラスタロバストな標準誤差を計算している。また、欠損値については、サンプルサイズが小さくなることを防ぐべく、欠損値をもつデータは削除せずに該当の変数の平均値を入力した上、各変数ごとに欠損値か否かについて、切片に対するダミー変数を組み入れ、コントロールする。各変数については、外れ値の影響を勘案し、上下 0.5% を超えるものについては、それぞれ上下 0.5 パーセントイル値に置換する (ウィンソライズ処理)。

3.4 Double Machine Learning (DML)

有賀ほか (2021) にある通り、線形回帰モデルでは、目的変数 (デフォルト距離) とコントロール変数の非線形の関係適切にとらえられない可能性があり、また、特定のコントロール変数を選択的に採用していることから、欠落変数バイアスが生じるおそれがある。先行研究では、コントロール変数を最初に特定しているため、欠落変数がある場合に過大に炭素排出の効果を推定する可能性がある。そのため、欠落変数バイアスを考慮した頑健性の確認が必要であると考えられる。

以下、Chernozhukov et al. (2018) により提案された DML を用いた分析手法を説明する。

(i) まず, 以下のような回帰モデル

$$\begin{aligned} DD_{it} &= \alpha + \beta X_{it} + f(\{Y_{k,it}\}, \{Z_{\ell,t}\}) + \varepsilon_{it}, \\ E(\varepsilon_{it} | X_{it}, \{Y_{k,it}\}, \{Z_{\ell,t}\}) &= 0 \end{aligned} \quad (2)$$

を考える. ここで, f は, コントロール変数 $\{Y_{k,it}\}$ とマクロ変数 $\{Z_{\ell,t}\}$ の何らかの関数形とする.

(ii) 次に, 以下のように, 条件付き期待値の性質である繰り返し期待値の法則を利用すると,

$$E(DD_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\}) = \alpha + E(X_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\})\beta + f(\{Y_{k,it}\}, \{Z_{\ell,t}\}) + \varepsilon_{it} \quad (3)$$

であるから, (2) 式とあわせて,

$$DD_{it} - E(DD_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\}) = (X_{it} - E(X_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\}))\beta + \varepsilon_{it} \quad (4)$$

という式が得られる. これより, 本来は, (2) 式において, f の関数形を規定すべきところだが, f を求めなくても, $DD_{it} - E(DD_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\})$ および $X_{it} - E(X_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\})$ を求めることができれば, 最小二乗法により β の推定値を求められる.

(iii) $DD_{it} - E(DD_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\})$ および $X_{it} - E(X_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\})$ は, DD_{it} と X_{it} を $\{Y_{k,it}\}$ と $\{Z_{\ell,t}\}$ でそれぞれ推定したときの残差と考えられ, DML では, 条件付き期待値 $E(DD_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\})$ および $E(X_{it} | \{Y_{k,it}\}, \{Z_{\ell,t}\})$ を機械学習手法を用いてノンパラメトリック推定する. ノンパラメトリック推定に機械学習を用いることで, より多くの変数をモデルに組み込むことができ, 目的変数とコントロール変数が非線形の関係にある可能性にも対処することができる. 本研究では, 前項の 9 つのコントロール変数に加え, 有賀ほか (2021) を参考に 73 の変数を別途追加して, あわせて 82 の変数で機械学習を実施する. 採用する変数の一覧は, 付録 B を参照されたい. また, 推定においては, 三浦ほか (2019) 等, 信用リスクの分析で活用されることが多い, ツリー系の機械学習手法である XGBoost と Random Forest を採用する. XGBoost については, 雉子波ほか (2022) を参考に, 表 3 の設定の下, ベイズ最適化を用いて, テストデータの RMSE が最小となるパラメータを探索する. Random Forest については, 三浦ほか (2019) や Boehmke and Greenwell (2019) を参考に, 表 3 の設定の下, グリッドサーチを行い, テストデータの RMSE が最小となるパラメータを探索する. いずれもホールドアウト検証で, 80% をモデル構築用のデータ, 残りの 20% をテストデータとして用いる.

表 3: ハイパーパラメータの探索範囲

XGBoost		Random Forest	
ハイパーパラメータ	範囲	ハイパーパラメータ	候補
max depth	3~9	mtry*	0.050, 0.150, 0.250
min child weight	0.1~10.0		0.333, 0.400
gamma	0.0~1.0	min node size	1, 3, 5, 10
colsample bytree	0.60~0.95		
subsample	0.60~0.95		

* mtry は、候補に記載した数値にモデルで採用する変数の数値を乗じたものをもって、グリッドサーチを行う。

(iv) 最後に、 β の推定を以下の通りに行う。なお、 β の推定値に係る標準誤差の算出および有意性の検定については、付録 C を参照されたい。

- $DD_{it} - E(DD_{it}|\{Y_{k,it}\}, \{Z_{\ell,t}\})$ および $X_{it} - E(X_{it}|\{Y_{k,it}\}, \{Z_{\ell,t}\})$ を、 DD_{it} および X_{it} を $\{Y_{k,it}\}, \{Z_{\ell,t}\}$ でそれぞれノンパラメトリック推定した際の残差 \hat{U}, \hat{V} とし、推定した関数を $\hat{\ell}, \hat{m}$ とする。
- データセットを 2 つに分割し、1 つ目のサブセットに対して、 $\hat{\ell}_1$ および \hat{m}_1 を

$$\begin{aligned} DD_1 &= \hat{\ell}_1(Y_1, Z_1) + \hat{U}_{1,1}, \\ X_1 &= \hat{m}_1(Y_1, Z_1) + \hat{V}_{1,1} \end{aligned}$$

の通り推定する。なお、各変数の添え字は、データセットを分割して作成するサブセットのうち、1 つ目もしくは 2 つ目のサブセットに係るものかを示すものとし、 $\hat{U}_{1,2}$ のように添え字を 2 つ用いている場合、1 つ目の添え字は、推定の際に使用したサブセット、2 つ目の添え字は、推定したモデルを適用したサブセットを指すものとする。また、ここでの Y は、コントロール変数群、 Z は、マクロ変数群を指すものとする。

- 次に 2 つ目のサブセットに対して、上記で推定した機械学習モデルを適用し、残差 $\hat{U}_{1,2}, \hat{V}_{1,2}$ を求める。その上で、 $\hat{U}_{1,2}, \hat{V}_{1,2}$ を利用して、線形回帰モデルを推定し、

$$\hat{U}_{1,2} = a + \hat{\beta}_1 \hat{V}_{1,2} + \hat{\varepsilon}_1$$

から係数の推定値 $\hat{\beta}_1$ を得る。

- 上の処理をサブセットを入れ替えて繰り返し、係数の推定値 $\hat{\beta}_2$ を求め、 $\hat{\beta}_1$ と $\hat{\beta}_2$ の平均値を推定値 $\hat{\beta}$ とする。

4 実証結果

ここでは、前節で記載した線形回帰モデルを用いて、4.1～4.2において仮説1～2について、分析結果を示し、4.3において、DMLを用いた分析結果を示す。

4.1 仮説1に対する結果と考察

ここでは、前節で説明したサンプル全体に対する線形回帰分析の結果、つまり、仮説1の検証結果について述べる。表4に記載のとおり、炭素排出量および炭素強度に関する分析を実施しており、時間の固定効果と産業ダミーを考慮した分析を行っている*1。

炭素排出量に係る推定値は、負であるものの、統計的に有意にならないことが確認できる。一方で、炭素強度に係る推定値は、有意に負であることがわかる（有意水準5%）。つまり、単位売上高当たりの炭素排出量がより多い場合、デフォルト距離が小さく、信用リスクが大きくなる関係にあることが示されている。炭素強度のみ有意な結果になる点は、Carbone et al. (2021)とも整合しており、企業規模等が考慮されている炭素強度の方が、企業間やセクター間での比較可能性が高い指標として市場で認識されているということが理由として考えられる。この点については、TCFD (2017)でも言及されている。

上記の分析結果から、対象企業の信用リスクは、財務指標などをコントロールした上でも炭素強度と負の関係にあることが確認でき、仮説1が成り立つことがわかる。これは、Kabir et al. (2021)で指摘されているように、法規制への対応やレピュテーションリスクのために、企業収益やキャッシュフローの不確実性が高まると市場で考えられ、それが信用リスクの上昇につながっている可能性があると考えられる。

なお、コントロール変数については、表4に記載しているように概ね先行研究で報告されているものから大きく乖離するものではない。営業利益率や剰余金／総資産、運転資本／総資産、WTIは、デフォルト距離と有意に正の関係にある。つまり、営業利益率や剰余金／総資産、運転資本／総資産、WTIの値が大きい場合、デフォルト距離も大きくなる関係にあることがわかる。一方で、有利子負債／総資産およびボラティリティは、デフォルト距離と有意に負の関係にあり、有利子負債／総資産およびボラティリティの値が大きい場合、デフォルト距離が小さくなる関係にあることがわかる。

*1 説明変数から目的変数への作用がある可能性に鑑み、説明変数およびコントロール変数について、1期前の数値を利用した分析をあわせて行っているが、仮説1および2ともに以下の結果と同様のものが得られている。

表 4: サンプル全体に対する線形回帰分析の結果

本表は、目的変数をデフォルト距離、説明変数を炭素排出量もしくは炭素強度とした、サンプル全体に対する線形回帰分析の結果である。炭素排出量は、GHG 排出量（データがなければ、CO₂ 排出量）、炭素強度は炭素排出量／売上高、ボラティリティはデフォルト距離の計算過程で得られる企業資産のボラティリティ、WTI は West Texas Intermediate 価格、GDP は四半期ごとの GDP 成長率であり、炭素排出量と総資産は自然対数値である。下表以外に各変数について、欠損値ダミー、説明変数が GHG 排出量か CO₂ 排出量かを表す GHG ダミーを利用している。なお、GHG ダミーに係る推定値は、統計的に有意にならないことを確認している。括弧内は標準誤差の値で、企業についてクラスタロバストな標準誤差を利用している。なお、***は $p < 0.01$, **は $p < 0.05$, *は $p < 0.1$ を示している。

	(1) 炭素排出量	(2) 炭素強度
炭素排出量	-0.025 (0.050)	
炭素強度		-0.033 *** (0.010)
有利子負債／総資産	-3.267 *** (0.423)	-3.153 *** (0.419)
営業利益率	12.256 *** (1.005)	12.314 *** (1.016)
剰余金／総資産	3.650 *** (0.413)	3.629 *** (0.410)
総資産	0.100 (0.067)	0.083 ** (0.032)
運転資本／総資産	2.067 *** (0.434)	2.130 *** (0.431)
固定資産／総資産	0.183 (0.142)	0.222 * (0.114)
ボラティリティ	-8.910 *** (0.707)	-8.893 *** (0.705)
WTI	0.033 *** (0.005)	0.033 *** (0.005)
GDP	-0.044 (0.046)	-0.044 (0.046)
Year Fixed Effect	Yes	Yes
Sectoral Fixed Effect	Yes	Yes
Observations	5492	5492
Adjusted R ²	0.599	0.600

4.2 仮説 2 に対する結果と考察

次に、セクターにより分割したサブサンプルによる分析、つまり、仮説 2 に対する結果を示す。Safiullah et al. (2021) で指摘されているように、高排出セクターは、法規制対応コストや炭素税対応コスト、レピュテーションリスクなど、より多くの気候変動関連の問題に直面する可能性があるため、高排出セクターに属するか否かで、炭素関連のリスクの評価水準が違う可能性がある。したがって、本節にて、高排出セクターか否かでサンプル全体を分割し、その上で、デフォルト距離と、炭素排出量および炭素強度との関係について確認を行う。

分割するにあたり、TCFD (2021) で銀行が開示すべきと定められているセクターである “carbon-related assets” を参考に、以下の表 5 に挙げたセクターを炭素関連セクターと定義し、そのセクターに属するサンプルを対象に分析を行う。当該セクターに属しないサンプルは非炭素関連セクターと定義する。なお、炭素関連セクターに属するか否かは、企業ごとに付与している GICS を用いて判定を行う。

表 5: 炭素関連セクターの対象業種

Energy	Transportation	Metaterials and Buildings	Agriculture, Food, and Forest Products
- Oil and Gas	- Air Freight	- Metals and Mining	- Beverages
- Coal	- Passenger Air Transportation	- Chemicals	- Agriculture
- Electric Utilities	- Maritime Transportation	- Construction Materials	- Packaged Food and Meats
	- Rail Transportation	- Capital Goods	- Paper and Forest Products
	- Trucking Services	- Real Estate Management and Development	
	- Automobiles and Components		

(出所) TCFD (2021)

結果は、表 6 に示されているとおりである。表 6 の炭素関連セクターにおいて、炭素排出量および炭素強度に係る推定値ともに、有意に負であることが確認できる (有意水準 5%)。一方、表 6 の非炭素関連セクターにおいては、炭素排出量および炭素強度に係る推定値ともに有意に負の関係にはならない (有意水準 5%)。このことから、日本国内においては、炭素関連セクターにおいて、炭素排出とデフォルト距離の負の関係が非炭素関連セクターよりも顕著であり、仮説 2 が成り立つ傾向にあることがわかる。

表 6: セクターサブサンプルに対する線形回帰分析の結果

本表は、目的変数をデフォルト距離、説明変数を炭素排出量もしくは炭素強度とした、炭素関連セクターおよび非炭素関連セクターに対する線形回帰分析の結果を示したものである。炭素排出量は、GHG 排出量（データがなければ、CO₂ 排出量）、炭素強度は炭素排出量／売上高、ボラティリティはデフォルト距離の計算過程で得られる企業資産のボラティリティ、WTI は West Texas Intermediate 価格、GDP は四半期ごとの GDP 成長率であり、炭素排出量と総資産は自然対数値である。下表以外に各変数について、欠損値ダミー、説明変数が GHG 排出量か CO₂ 排出量かを表す GHG ダミーを利用している。なお、GHG ダミーに係る推定値は、統計的に有意にならないことを確認している。括弧内は標準誤差の値で、企業についてクラスタロバストな標準誤差を利用している。なお、***は $p < 0.01$ 、**は $p < 0.05$ 、*は $p < 0.1$ を示している。

	炭素関連 (1)	炭素関連 (2)	非炭素関連 (1)	非炭素関連 (2)
炭素排出量	-0.121 *** (0.046)		0.146 (0.098)	
炭素強度		-0.039 *** (0.010)		0.006 (0.118)
有利子負債／総資産	-3.228 *** (0.481)	-3.140 *** (0.485)	-4.121 *** (0.748)	-3.986 *** (0.785)
営業利益率	12.435 *** (1.562)	12.658 *** (1.582)	12.306 *** (1.196)	12.124 *** (1.199)
剰余金／総資産	3.668 *** (0.473)	3.737 *** (0.468)	3.313 *** (0.637)	3.399 ** (0.643)
総資産	0.215 *** (0.069)	0.093 ** (0.039)	-0.064 (0.125)	0.088 (0.054)
運転資本／総資産	2.345 *** (0.551)	2.330 *** (0.548)	1.960 *** (0.668)	1.917 *** (0.678)
固定資産／総資産	0.436 *** (0.161)	0.373 *** (0.139)	-0.271 (0.263)	0.041 (0.229)
ボラティリティ	-10.959 *** (0.995)	-11.026 *** (0.996)	-7.176 *** (0.951)	-7.028 *** (0.939)
WTI	0.027 *** (0.006)	0.027 *** (0.006)	0.040 *** (0.007)	0.041 *** (0.007)
GDP	0.009 (0.072)	0.009 (0.072)	-0.105 ** (0.045)	-0.110 ** (0.046)
Year Fixed Effect	Yes	Yes	Yes	Yes
Sectoral Fixed Effect	Yes	Yes	Yes	Yes
Observations	3424	3424	2068	2068
Adjusted R ²	0.575	0.577	0.621	0.619

4.3 DML による結果と考察

本研究においては、前節で有意な結果が得られた炭素強度を対象に分析を行う。また、サンプル全体に対する分析に加え、炭素排出量の効果が異なると考えられる、炭素関連セクターと非炭素関連セクターのサブサンプルについても分析を実施する。

結果は、表 7 の通りである。炭素関連セクターについては、XGBoost および Random Forest ともに有意水準 5% で、推定値は負である一方、全体および非炭素関連セクターについては、統計的に有意にならないことがわかる。サンプル全体は、前述の結果と異なり、有意にならないことから、サンプル全体に対する分析を行う際、線形回帰モデルでは欠落変数等のバイアスが生じている可能性が否めない。一方で、炭素関連セクターについては、欠落変数バイアスと目的変数とコントロール変数が非線形の関係にある可能性に対処した場合においても、前節で示した炭素強度と信用リスクの負の関係は変わらず、その結果の頑健性について一定の確認ができる。

表 7: DML の結果

本表は、Double Machine Learning による炭素強度の係数の推定結果を示すもの。(1) はサンプル全体に対する分析結果、(2) は炭素関連セクターに属するサンプルに対する分析結果、(3) は非炭素関連セクターに属するサンプルに対する分析結果。括弧内は標準誤差の値である。なお、***は $p < 0.01$, **は $p < 0.05$, *は $p < 0.1$ というを示している。

	(1) 全体	(2) 炭素関連	(3) 非炭素関連
炭素強度 (XGBoost)	-0.016 *	-0.050 ***	0.011
	(0.012)	(0.017)	(0.024)
炭素強度 (Random Forest)	-0.023 *	-0.059 ***	0.025
	(0.014)	(0.020)	(0.027)
Observations	5492	3424	2068

5 まとめ

本研究では、2012年度から2021年度の国内上場企業を対象として、移行リスクが相対的に高い企業は、移行リスクが低い企業と比べて、信用リスクが大きいかの分析を行った。具体的には、企業の移行リスクを表す指標としてGHG排出量、CO₂排出量およびそれらを売上高で除した炭素強度を採用し、企業の信用リスクを表す指標として、Merton (1974) に基づくデフォルト距離を採用した上で、線形回帰分析を中心に検証を行っている。

結果としては、炭素排出量が多いとされるセクターにおいて、炭素強度とデフォルト距離に負の関係があること、つまり、単位売上高当たりの炭素排出量が多い場合、デフォルト距離が小さく、信用リスクが大きくなる関係にあることがわかった。この結果は、DMLで欠落変数バイアスの問題および目的変数とコントロール変数が非線形の関係を持つ可能性に対処した場合に注目した場合においても同様のものであり、その頑健性を一定程度確認できた。

以上から、「炭素排出量が多いとされるセクターにおいて、移行リスクが相対的に高い企業は、移行リスクが低い企業と比べて、信用リスクが高くなる」ということが言えると考えられる。これは、炭素排出量が多い場合、炭素税の導入や法規制の変化、レピュテーションリスクにより、将来、財務的打撃を受ける可能性が大きくなり、結果として、倒産確率の上昇を通じて信用リスクが高くなる可能性があるということを示唆している。そして、これらの結果に鑑み、気候変動リスクは、金融機関の経営管理上重要なリスクとされている信用リスクと関連性があるリスクドライバーとして、投資家や金融機関において管理すべきリスクであり、その管理は、金融システム全体に対するリスクを制御する一助になると考える。

ただし、上記分析結果は、現時点で炭素排出量の開示がなされている企業について分析を行ったものであり、企業規模の比較的大きな企業にサンプルが偏っている等、セレクションバイアスが存在する可能性は否定できない。また、気候変動リスクに対する法規制はまだまだ発展途上の段階であり、今後の動向次第で本研究で示している気候変動リスクと信用リスクの関係性も変わりうるものと考えられる。特にセレクションバイアスについては、検証結果に大きく影響を与える可能性があるが、現時点で開示されている排出量データが少ない等、データアベイラビリティの観点から分析が難しく、今後の大きな課題である。以上の点に鑑み、データの可用性や規制動向を注視しつつ、継続的にその関係の分析を続けていくことが今後のリスク管理上重要になるものと考えられる。

参考文献

- [1] Attig, N., Ghouli, S. E., Guedhami, O., and Suh, J. (2013). Corporate social responsibility and credit ratings. *Journal of Business Ethics*, 117(4):679-694.
- [2] Bauer, R. and Hann, D. (2010). Corporate environmental management and credit risk. *SSRN Electric Journal*, 1660470.
- [3] Barth, F., Hübel, B., and Scholz, H. (2022). ESG and corporate credit spreads. *Journal of Risk Finance*, 23(2):169-190.
- [4] Bharat, S. and Shumway, T. (2008). Forecasting default with the merton distance to default model. *Review of Financial Studies*, 21(3):1339-1369.
- [5] Black, F. and Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of Political Economy*, 81(3):637-654.
- [6] Boehmke, B. and Greenwell, B. (2019). Hands-on machine learning with R. Chapman and Hall/CRC.
- [7] Bolton, P. and Kacperczyk, M. (2021). Do investors care about carbon risk? *Journal of Financial Economics*, 142(2):517-549.
- [8] Busch, T., Johnson, M., and Pioch, T. (2022). Corporate carbon performance data: Quo vadis? *Journal of Industrial Ecology*, 26(1):350-363.
- [9] Capasso, G., Gianfrate, G., and Spinelli, M. (2020). Climate change and credit risk. *Journal of Cleaner Production*, 266:121634.
- [10] Carbone, S., Giuzio, M., Kapadia, S., Krämer, J. S., Nyholm, K., and Vozian, K. (2021). The low-carbon transition, climate commitments and firm credit risk. European Central Bank Working Paper Series No. 2631.
- [11] Chava, S. (2014). Environmental externalities and cost of capital. *Management Science*, 60(9):2223-2247.
- [12] Chernozhukov, V., Chetverikov, D., Demirer, M., Duflo, E., Hansen, C., Newey, W., and Robins, J. (2018). Double/debiased machine learning for treatment and structural parameters. *Econometrics Journal*, 21(1):1-68.
- [13] Delis, M. D., De Greiff, K., and Ongena, S. (2018). Being stranded on the carbon bubble? Climate policy risk and the pricing of bank loans. SFI Research Paper Series 18-10.
- [14] Eliwa, Y., Aboud, A., and Saleh, A. (2021). ESG practices and the cost of debt: Evidence from EU countries. *Critical Perspectives on Accounting*, 79:102097
- [15] Höck, A., Klein, C., Landau, A., and Zwergel, B. (2020). The effect of environmental sustainability on credit risk. *Journal of Asset Management*, 21(2):85-93.
- [16] Jung, J., Herbohn, K., and Clarkson, P. (2018). Carbon risk, carbon risk awareness and the cost of debt financing. *Journal of Business Ethics*, 150(4):1151-1171.
- [17] Kabir, M. N., Rahman, S., Rahman, M. A., and Anwar, M. (2021). Carbon emissions and default risk: International evidence from firm-level data. *Economic Modelling*, 103:105617.
- [18] Kleimeier, S. and Viehs, M. (2018). Carbon disclosure, emission levels, and the cost of debt. *SSRN Electric Journal*, 2719665.

- [19] Liu, X., Wang, E., and Cai, D. (2019). Green credit policy, property rights and debt financing: Quasi-natural experimental evidence from China. *Finance Research Letters*, 29:129-135.
- [20] Merton, R. C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *The Journal of finance*, 29(2):449-470.
- [21] Nguyen, Q., Diaz-Rainey, I., and Kuruppuarachchi, D. (2022). In search of climate distress risk. *International Review of Financial Analysis*, 85:102444.
- [22] Okimoto, T. and Takaoka, S. (2022). Credit default swaps and corporate carbon emissions. Nippon Finance Association The 30th Anniversary Annual Conference Program.
- [23] Safiullah, M., Kabir, M. N., and Miah, M. D. (2021). Carbon emissions and credit ratings. *Energy Economics*, 100:105330.
- [24] Seltzer, L. H., Starks, L., and Zhu, Q. (2022). Climate regulatory risk and corporate bonds. National Bureau of Economic Research Working Papers No. 29994.
- [25] TCFD. (2017). Annex: Implementing the Recommendations of the Task Force on Climate-related Financial Disclosures. https://assets.bbhub.io/company/sites/60/2021/07/2021-TCFD-Implementing_Guidance.pdf. (Accessed: 2022/12/26)
- [26] TCFD. (2021). Recommendations of the task force on climate-related financial disclosures. <https://assets.bbhub.io/company/sites/60/2021/10/FINAL-2017-TCFD-Report.pdf>. (Accessed: 2022/12/26)
- [27] Wang, Y. C., Feng, Z. Y., and Huang, H. W. (2021). Corporate carbon dioxide emissions and the cost of debt financing: Evidence from the global tourism industry. *International Journal of Tourism Research*, 23(1):56-69.
- [28] 有賀涼, 五島圭一, 千葉貴司. (2021). CO2 排出量と企業パフォーマンス: Double Machine Learning を用いた日本の実証研究. 日本銀行金融研究所ディスカッションペーパーシリーズ No. 2021-J-11.
- [29] 雉子波晶, 杉本誠忠, 酒本隆太, 鈴木智也. (2022). 機械学習による為替フォワード取引期間の判別モデルおよび運用シミュレーション. 『ジャファイア・ジャーナル』, 20:22-40.
- [30] 三浦翔, 井實康幸, 竹川正浩. (2019). 入出金情報を用いた信用リスク評価—機械学習による実証分析—. 日本銀行金融研究所ディスカッションペーパーシリーズ No. 2019-J-4.
- [31] 森平爽一郎. (2000). 信用リスクの測定と管理第 6 回: オプションモデルによる倒産確率推定: 基礎. 『証券アナリストジャーナル』, 38(1):85-100.

付録 A デフォルト距離算出の詳細

Merton の構造型モデルとデフォルト距離の算出方法および各パラメータの設定について概説する。本研究においては、信用リスクを測定するにあたって、Black and Scholes (1973) と Merton (1974) のオプション価格決定理論に基づくオプション・アプローチを採用する。また、デフォルト距離の計算に必要な各パラメータの設定は、以下に述べるように森平 (2000) に従う。

デフォルト距離の算出においては、企業の倒産は、負債満期において債務超過状態になることとみなす。いま、負債の満期時点を T とし、 D_T をその時点の負債総額 (定数) とする。また、 t 時点 ($t = 0, \dots, T$) の企業の資産価値 A_t が次の

$$dA_t = \mu_A A_t dt + \sigma_A A_t dW_t^P \quad (5)$$

という確率過程に従うものとする。ただし、 μ_A は企業の資産の期待成長率、 σ_A は企業の資産のボラティリティ、 W_t^P は実確率測度 P の下での標準ブラウン運動とする。

A_0 を現時点の企業の資産価値とすると、将来時点 T における企業の資産価値 A_T は、(4) 式の確率微分方程式を解くことにより、

$$\begin{aligned} A_T &= A_0 \exp\left(\left(\mu_A - \frac{\sigma_A^2}{2}\right)T + \sigma_A W_T^P\right) \\ \therefore \ln A_T &= \ln A_0 + \left(\mu_A - \frac{\sigma_A^2}{2}\right)T + \sigma_A W_T^P \end{aligned}$$

となることから、 $\ln A_T$ は、平均 $\ln A_0 + \left(\mu_A - \frac{\sigma_A^2}{2}\right)T$ 、分散 $\sigma_A^2 T$ の正規分布に従うことがわかる。よって、負債満期において債務超過になる確率 PD は、

$$\begin{aligned} PD &= P(A_T < D_T) \\ &= 1 - N\left(\frac{\ln\left(\frac{A_0}{D_T}\right) + \left(\mu_A - \frac{\sigma_A^2}{2}\right)T}{\sigma_A \sqrt{T}}\right) \end{aligned} \quad (6)$$

となる。ただし、 $N(\cdot)$ は累積標準正規分布関数とする。

そして、(5) 式の累積標準正規分布関数の引数を本研究で用いる「デフォルト距離」 (DD)、すなわち、

$$DD = \frac{\ln\left(\frac{A_0}{D_T}\right) + \left(\mu_A - \frac{\sigma_A^2}{2}\right)T}{\sigma_A \sqrt{T}} \quad (7)$$

とする。この指標は、企業の資産価値がデフォルトからどの程度離れているか、ボラティリティを基準に計測するものと解釈できる。

デフォルト距離の算出式は、(6) 式のとおりだが、実際の計算には、「現時点の企業資産の市場価値 A_0 」、 $\left[$ 将来の負債総額 D_T 」、 $\left[$ 企業資産の期待成長率 μ_A 」、 $\left[$ 企業資産のボラティリティ σ_A 」、 $\left[$ 将来時点 T 」の 5 つのパラメータが必要になる。本研究においては、森平 (2000) に従い、「将来の負債総額 D_T 」は、現時点の簿価上の負債総額、「企業資産の期待成長率 μ_A 」は、 $\left(\frac{E_0}{A_0}\right)\mu_E$ 、「将来時点 T 」は、1 年として計算を行う。なお、「企業資産の期待成長率 μ_A 」を算出する際に必要になる μ_E は、株主資本期待成長率を表すものだが、各

企業の株価から求める日次対数収益率をもとに算出する。すなわち、日次対数収益率の平均値を 250 倍し年率換算したものを株主資本期待成長率 μ_E とする。本研究では、森平 (2000) において、対象とする期間は 60 日から 180 日ほどとすることが妥当であるとしていること、デフォルト距離の性質がタイムリーに信用リスクを測定するよりも長期間の動きの中で当該企業の信用リスクをモニタリングするために使われることが多いことから、対象とする期間を 180 日として日次収益率の計算を行う。残りの「現時点の企業資産の市場価値 A_0 」、 σ_A の 2 つのパラメータについては、Bharat and Shumway (2008) や Capasso et al. (2020) を参考に、

$$E_0 = A_0 N(d_1) - D_T \exp(-r_f T) N(d_2),$$

$$\sigma_A = \frac{E_0}{A_0 N(d_1)} \sigma_E$$

の連立非線形方程式を解くことにより求める。本研究においては、R の `nleqslv` パッケージを用い、Broyden Method の下、上の連立方程式を解く。局所解に陥る可能性があるため、個別の企業ごとに時系列でデフォルト距離の挙動で不自然な点がないか、デフォルト距離の値が負の値になっていないかなどの確認を行う。上式の E_0 は現時点の企業の株式価値であり、 d_1 および d_2 は、

$$d_1 = \frac{\ln\left(\frac{A_0}{D_T}\right) + \left(r_f + \frac{\sigma_A^2}{2}\right)T}{\sigma_A \sqrt{T}},$$

$$d_2 = \frac{\ln\left(\frac{A_0}{D_T}\right) + \left(r_f - \frac{\sigma_A^2}{2}\right)T}{\sigma_A \sqrt{T}}$$

とする。

上式の中で、リスクフリーレート r_f および株主資本ボラティリティ σ_E を追加的に設定する必要がある。リスクフリーレートは、日本国債 10 年金利、株主資本ボラティリティ σ_E は、株主資本期待成長率 μ_E と同様、日次対数収益率の標準偏差を $\sqrt{250}$ 倍し、年率換算したものとする。対象とする期間も株主資本期待成長率 μ_E と同様、180 日として日次収益率の計算を行う。

付録 B DML で採用した変数

Double Machine Learning では、線形回帰分析で採用したコントロール変数に加え、以下の変数をコントロール変数として採用した。

表 8: DML で使用した変数の一覧

1	売上高総利益率	38	売上高変化率 (1 年)
2	EBITDA マージン	39	売上高変化率 (5 年)
3	税引前利益率	40	営業利益変化率 (1 年)
4	当期純利益率	41	営業利益変化率 (5 年)
5	持続的成長率	42	EBITDA 変化率 (1 年)
6	ROA	43	EBITDA 変化率 (5 年)
7	ROE	44	営業キャッシュフロー変化率 (1 年)
8	PBR	45	営業キャッシュフロー変化率 (5 年)
9	配当性向	46	フリーキャッシュフロー変化率 (1 年)
10	債務合計 / EBITDA ^{*1}	47	フリーキャッシュフロー変化率 (5 年)
11	純債務 / EBITDA	48	1 株当たり純資産変化率 (1 年)
12	EBITDA / 支払利息	49	1 株当たり純資産変化率 (5 年)
13	(EBITDA - 資本的支出) / 支払利息	50	1 株当たり配当金変化率 (1 年)
14	EBIT / 支払利息	51	1 株当たり配当金変化率 (5 年)
15	自己資本比率	52	総資産変化率 (1 年)
16	長期債務 / 総資本 ^{*2}	53	総資産変化率 (5 年)
17	長期債務 / 総資産	54	棚卸資産変化率 (1 年)
18	債務合計 / 総資本	55	棚卸資産変化率 (5 年)
19	債務合計 / 自己資本	56	運転資本変化率 (1 年)
20	純債務 / 自己資本	57	運転資本変化率 (5 年)
21	現金比率	58	固定資産変化率 (1 年)
22	流動比率	59	固定資産変化率 (5 年)
23	当座比率	60	資本的支出変化率 (1 年)
24	売上債権回転率	61	資本的支出変化率 (5 年)
25	棚卸資産回転率	62	総資本変化率 (1 年)
26	仕入債務回転日数	63	総資本変化率 (5 年)
27	キャッシュ・コンバージョン・サイクル	64	債務合計変化率 (1 年)
28	資本的支出 / 総資産	65	債務合計変化率 (5 年)
29	営業キャッシュフロー / 債務合計	66	短期債務変化率 (1 年)
30	フリーキャッシュフロー利回り	67	短期債務変化率 (5 年)
31	従業員 1000 人当たり純利益	68	仕入債務変化率 (1 年)
32	社外取締役比率	69	仕入債務変化率 (5 年)
33	独立取締役比率	70	純資産変化率 (1 年)
34	女性取締役比率	71	純資産変化率 (5 年)
35	女性役員比率	72	従業員数変化率 (1 年)
36	取締役平均年齢	73	従業員数変化率 (5 年)
37	外国人持株比率		

^{*1} 債務とは、負債のうち、有利子負債のことを指す。

^{*2} 総資本とは、債務合計と純資産の合計のことを指す。

付録 C DML における β の推定値の標準誤差と有意性の検定

「3.4 Double Machine Learning (DML)」における (2) 式の β の推定値に係る標準誤差の算出方法および有意性の検定について示す。なお、これらについては、Chernozhukov et al. (2018) および有賀ほか (2021) にしたがって、実施している。

まず、 β の推定値 $\hat{\beta}$ の標準誤差 \hat{se} は、

$$\begin{aligned}\hat{se} &= \frac{\hat{\sigma}}{\sqrt{N}}, \\ \hat{\sigma}^2 &= \left(\frac{1}{N} \sum_{i=1}^N \hat{V}_i^2 \right)^{-2} \frac{1}{N} \sum_{i=1}^N \hat{V}_i^2 \hat{\zeta}_i^2, \\ \hat{V}_i &:= X_i - \hat{m}(Y_i, Z_i, I_{\kappa(i)}^C), \\ \hat{\zeta}_i &:= \left(DD_i - \hat{\ell}(Y_i, Z_i, I_{\kappa(i)}^C) \right) - \left(X_i - \hat{m}(Y_i, Z_i, I_{\kappa(i)}^C) \right) \hat{\beta}, \\ \kappa(i) &:= \{\kappa \in \{1, 2\} : i \in I_\kappa\}\end{aligned}$$

により算出する。ただし、添え字 i は、各サンプル、 N はサンプルサイズを示す。また、「3.3 線形回帰モデル」と同様に、 DD_i は目的変数であるデフォルト距離、 X_i は説明変数である炭素強度 (炭素排出量/売上高)、 Y_i はコントロール変数群、 Z_i はマクロ変数群、をそれぞれ表すものとする。くわえて、 $\hat{\ell}$ 、 \hat{m} は、「3.4 Double Machine Learning (DML)」の (iv) と同様、 DD_i および X_i を Y_i 、 Z_i でそれぞれ機械学習を用いてノンパラメトリック推定した際に推定した関数を示す。なお、 $\hat{\ell}$ および \hat{m} の 3 つ目の引数は、推定したときに利用したサンプルが、「3.4 Double Machine Learning (DML)」の (iv) において、データセット全体を 2 つに分割して作成したサブサンプルのいずれにあたるものかを表す。

次に、有意性の検定については、帰無仮説を $\beta = 0$ とし、

$$\frac{\hat{\beta} - 0}{\hat{se}} \sim N(0, 1)$$

を検定統計量とする。この検定統計量が、漸近的に標準正規分布に従うものとして、有意水準 (本研究では、5%) に基づき、帰無仮説が棄却されるかの検定を行う。