

FSA Analytical Notes

—金融庁データ分析事例集—

2025 年 6 月 vol.3

地方銀行の貸出明細データ等とマクロ経済指標を用いた信用リスクに関する予兆分析の試行

(要旨)

本稿では、地方銀行の貸出明細データ等とマクロ経済指標を用いて信用リスクの動向を予測する機械学習モデルを構築し、地方銀行の経営状況に影響を与えうる予兆の捕捉を試みた。債務者区分の下方遷移を予測対象とし分析した結果、予兆を把握するのに有用と考えられる指標や、過去の危機時と比較した足元の経済環境について示唆を得た。共同データプラットフォームの本格運用開始を踏まえ、分析対象の拡大や指標の精査、モデルの改良を進め、金融機関との対話への活用等を進めていく。

1. はじめに

足元において、国内経済は新型コロナウイルス感染症拡大によるショックから緩やかな回復が続けてきた¹。一方で、民間金融機関における実質無利子・無担保融資の返済時期の到来や、人手不足および賃上げによる人件費上昇、原材料費上昇による物価高など企業を取り巻く環境は大きく変化している。こうした中、減少傾向にあった倒産件数についても、近年は上昇に転じている（図表 1）。また、世界各国の通商政策など経済政策をめぐる不確実性も高まっている（図表 2）。


将来的な信用リスクの増加等、金融機関の経営に影響を与えうる環境変化を早期に検知することを見据え、本稿では、地方銀行²の貸出明細等と国内外のマクロ経済指標を用いて債務者区分の下方遷移を予測する機械学習モデルを構築³し、国内産業の変化の兆し（予兆）をとらえることを試みた。

¹ 内閣府、「月例経済報告」（令和 7 年 3 月、4 月）

² 全国地方銀行協会加盟行 62 行（2024 年 9 月末時点）。


³ 本稿における機械学習モデルの構築手法、マクロ経済指標の選択にあたっては、2022、2023 年度に金融庁が有限責任あずさ監査法人に調査・研究を委託した「AI や ICT 技術を活用した経営改善支援の効率化に向けた調査・研究」および「AI 技術を活用した経営改善支援の効率化に向けた調査・研究」を参考にしている（https://www.fsa.go.jp/common/about/research/20230330_1/20230330_1.html）。

図表 1 倒産件数推移



(出所) 株式会社東京商工リサーチ

図表 2 世界の経済政策不確実性指数



(出所) Economic Policy Uncertainty

II. 機械学習モデル構築の流れ

本章では、使用データ、業種選定、変数選定、機械学習モデルの構築について説明する。

1. 使用データ

本分析に用いるデータは全国の地方銀行の法人向け貸出明細データ等及びマクロ経済指標データである。両データを基準日単位で結合し、1つのデータセットとして扱う。貸出明細データ等は、全国地方銀行協会の信用リスク情報統合サービス（CRITS）に登録されたデータベースから抽出・加工されたデータ及び共同データプラットフォームにおける貸出明細データの2種である。前者は2004年3月期から2023年12月期までのデータであり、後者は共同データプラットフォームが段階的に運用開始された2023年9月期以降のデータである。

2. 業種選定

マクロ環境の変化が企業に与える影響は業種等によって異なると考えられることから、機械学習に必要なデータ数が確保できる範囲で、分析対象とする企業群を限定することで、変数選択や結果の解釈が比較的容易になると期待される。本分析では、モデル構築対象をなるべく均質な集団としつつもサンプル数を確保するために業種による絞り込みを行うこととし、製造業を対象に分析を試

行する。なお、製造業は名目 GDP に占める割合が 2023 年で約 2 割⁴と最大である。国内銀行から国内製造業に対する貸出金額は 2023 年 3 月末時点で 64.7 兆円⁵であり、今回モデル構築時に使用したデータではこのうち 30.4%（19.7 兆円）が把握可能となっている。

3. 変数選定

今回モデル構築時に使用した変数を図表 3、図表 4 に示す。マクロ経済指標データは、国内外の 64 指標を採用している。金融・経済等に関する代表的なマクロ指標に加え、発電実績や公共機関からの受注額など、製造業に特に関連が深いと考えられる指数を選定している。

⁴ 内閣府、国民経済計算。

⁵ 日本銀行、「貸出先別貸出金」。国内銀行における国内店の銀行勘定のうち、製造業向けを対象とした残高。

図表 3 全国の地方銀行の法人
向け貸出明細データにおける変数

NO	指標	分類
001	当期売上高	財務
002	当期営業利益	
003	当期利益	
004	当期減価償却費	
005	当期受取利息_配当金	
006	当期支払利息_割引料	
007	当期総資産	
008	当期現金_預金	
009	当期流動資産	
010	当期固定資産	
011	当期流動負債	
012	当期固定負債	
013	当期短期借入金	
014	当期長期借入金	
015	当期資本金	
016	当期純資産	
017	与信残高_総額	貸出
018	与信残高_保証協会	
019	保全額_総額	
020	保全額_保証協会	
021	平均貸出金利	
022	平均残存期間	
023	最大延滞月数	
024	期末延滞月数	
025	債務者区分	

図表 4 マクロ経済指標データにおける変数

NO	指標	分類	出所
001	TOPIX	金融	株式会社東京証券取引所
002	Dow Jones Total Stock Market Index		S&P
003	無担保コールO/Nレート		日本銀行
004	国債利回り（1年）		財務省
005	国債利回り（3年）		財務省
006	国債利回り（5年）		財務省
007	国債利回り（米国・5年）		連邦準備制度
008	国債利回り（米国・10年）		連邦準備制度
009	為替（円／ドル）		日本銀行
010	為替（円／ユーロ）		欧州中央銀行
011	為替（ドル／ユーロ）		連邦準備制度
012	名目実効為替レート		日本銀行
013	総貸出平残（外銀・円貸出）		日本銀行
014	貸出約定平均金利（新規・短期）		日本銀行
015	貸出約定平均金利（新規・長期）		日本銀行
016	貸出約定平均金利（ストック・短期）		日本銀行
017	貸出約定平均金利（ストック・長期）		日本銀行
018	名目GDP成長率（前年度比）	景気	内閣府経済社会総合研究所
019	名目GDP成長率（前年同期比）		内閣府経済社会総合研究所
020	実質GDP成長率（前年度比）		内閣府経済社会総合研究所
021	実質GDP成長率（前年同期比）		内閣府経済社会総合研究所
022	実質GDP成長率（米国・前期比）		連邦準備制度
023	実質GDP成長率（ユーロ圏・前期比）		連邦準備制度
024	実質GDP成長率（アジア・前期比）		連邦準備制度
025	業況DI（中小企業・製造業・実績）		日本銀行
026	業況DI（中小企業・非製造業・実績）		日本銀行
027	業況DI（中堅企業・製造業・実績）		日本銀行
028	業況DI（中堅企業・非製造業・実績）		日本銀行
029	業況DI（大企業・製造業・実績）		日本銀行
030	業況DI（大企業・非製造業・実績）		日本銀行
031	景気動向指数CI（一致指数）	生産	内閣府経済社会総合研究所
032	景気動向指数CI（先行指数）		内閣府経済社会総合研究所
033	景気動向指数DI（一致指数）		内閣府経済社会総合研究所
034	景気動向指数DI（先行指数）		内閣府経済社会総合研究所
035	中小企業売上見通しDI		日本政策金融公庫
036	倒産件数_全国		総務省（東京商工リサーチ）
037	倒産負債額_全国		総務省（東京商工リサーチ）
038	発電実績_全国		資源エネルギー庁
039	公共機関からの受注額		国土交通省
040	新設建築物（居住用）床面積_全国		国土交通省
041	新設建築物（居住用）工事予定額_全国	消費	国土交通省
042	貨物輸送量		国土交通省
043	鉱工業出荷指数		経済産業省
044	鉱工業在庫指数		経済産業省
045	製造工業生産能力指数		経済産業省
046	機械受注額（原系列・製造業）		内閣府経済社会総合研究所
047	機械受注額（原系列・非製造業）		内閣府経済社会総合研究所
048	第3次産業活動指数（第3次産業総合）		経済産業省
049	商業販売額_商業計		経済産業省
050	商業販売額_卸売業計		経済産業省
051	商業販売額_小売業計	物価	経済産業省
052	訪日外客数_総数		日本政府観光局（国際観光振興機構）
053	旅客輸送量		国土交通省
054	消費者態度指数		内閣府経済社会総合研究所
055	国内企業物価指数（総平均）		日本銀行
056	地価_全国		国土交通省
057	WTI原油価格		米国エネルギー情報局
058	完全失業率（原数値）	雇用	厚生労働省
059	労働力人口（原数値）		厚生労働省
060	新規求人数		厚生労働省
061	有効求人倍率（原数値）		厚生労働省
062	将来人口推計（t+1期集計）_全国		国立社会保障・人口問題研究所
063	住民基本台帳人口_全国		総務省
064	失業率（米国）		連邦準備制度

4. モデル構築

本分析では、各金融機関が貸出先の財務状況等を勘案し信用リスクに応じて付与する区分である債務者区分⁶を予測対象とし、基準日時点で債務者区分が正常先である債務者が1年後同日時点で下方遷移（以下、「債務者区分下方遷移」）するか否かを予測する。一般に、債務者区分の正常先から要注意先以下への下方遷移は、マクロ経済状況を含めた当該債務者の業況悪化を示しており、与信費用の増加によって金融機関の経営状況にも影響するものと考えられる。したがって、債務者区分下方遷移を予測対象とすることは、地方銀行の経営状況に影響を及ぼすような産業の変調をとらえるという本分析の目的に合致するものと考えられる。

本分析における機械学習モデル構築に際しては、数多くの機械学習分野の調査・研究で利用されており、高い予測性能を発揮することで知られている XGBoost（「eXtreme Gradient Boosting」の略称）⁷を用いる。

また、学習にあたってはモデルの過学習を抑制するためデータを分割⁸する。利用可能データの都合上、2022 年度分までは①学習用、②予測精度確認用、③結果確認用の 3 種類に分割し、2023 年度分については全データを②、③の双方に用いる⁹。

説明変数は、前節で示した変数に前処理を施したものを機械学習モデルの学習時に投入している。具体的には、図表 3 および 4 の全変数について、原数値そのまま、1 年前同日の原数値、1 年前との差分（原数値－1 年前同日原数値）、1 年前との比（原数値／1 年前同日原数値）の 4 パターン（計 352 変数）を投入している。他方、目的変数は債務者区分下方遷移であり、下方遷移しなかった場合は「0」、下方遷移した場合は「1」となる変数である。

なお、本分析の目的は将来予測であるため、説明変数と目的変数の時点は一致させていない。すなわち、説明変数は基準日とその 1 年前同日のデータである一方、目的変数は基準日から 1 年後同日の下方遷移の有無であり、基準日時点に観測可能なデータのみを用いた将来予測を実施している¹⁰。

⁶ 本分析で用いたデータでは、債務者区分を「正常先、要注意先、要管理先、破綻懸念先、実質破綻先、破綻先」の 6 区分で表記しており、本分析における債務者区分の名称もこれに倣っている。

⁷ CHEN, Tianqi; GUESTRIN, Carlos. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*. 2016. p. 785-794.

⁸ データの分割に際しては、特定時点のデータが偏って配分されないよう、各時点から抽出されるサンプル数の平準化を行っている。また、債務者区分下方遷移についても同様に偏って配分されないようサンプル数の平準化を行っている。なお、次章の図表 5 で示す通り、債務者区分下方遷移割合の実績は、年度によっては 10% 以下と低位であり、そのまま学習した場合、データの偏りの影響を受けることが想定されることから、債務者区分が下方遷移しない先に対しアンダーサンプリングを実施している。

⁹ 分割したデータのサンプル数は次の通り（括弧内は債務者区分下方遷移先の内数）。①学習用・～2022 年度：149,135（72,820）先。②予測精度確認用・～2022 年度：37,284（18,205）先。③結果確認用・～2022 年度：143,194（10,193）先。②・③予測精度、結果確認用・2023 年度：57,408（5,405）先。

¹⁰ 実際には、公的統計や決算情報など、指標によって基準日からは数カ月後に観測可能となるものが多いが、予測対象は 1 年先であるため、数カ月遅れの情報を加味しても未来情報の先取りは生じない。


Ⅲ. 結果

本章では、構築した機械学習モデルの予測精度と出力結果を確認し、その解釈を行う。

1. 債務者区分下方遷移状況の確認

まずは、本分析の対象（業種：製造業、基準日時点債務者区分：正常先）における債務者区分下方遷移の実績を図表 5 に示す。2009 年度のリーマン・ショック期で下方遷移率が大幅に上昇した後、緩やかに減少し、2020 年度の新型コロナウイルス感染症拡大期において再度小幅に上昇し、再度緩やかに減少している。

図表 5 債務者区分下方遷移状況



2. モデルの予測精度と説明変数の寄与度

精度確認の指標は AUC¹¹を用いる（図表 6）。機械学習モデルの精度確認には正解率¹²、再現率¹³等も用いられるが、これらの指標は予測結果の正解／不正解の判定に際して閾値の設定が必要であるのに対し、AUC は閾値の設定を必要とせず、恣意性が入りこみにくい。

¹¹ AUC は機械学習モデルの出力結果の序列性について示す指標で 0～1 の間の値をとる。AUC=0.5 である場合に偶然と変わらない精度を示し、数値が高いほど精度が高いことを示す。

¹² 正解率：機械学習モデルが出力したすべての予測のうち、正しく予測した割合。


¹³ 再現率：実際に予測ターゲットであった先のうち、モデルが予測ターゲットであると予測できた割合。

図表 6 検証データに対する予測精度


期間		～2022 年度
分割データ	②予測精度確認用	0.822
	③結果確認用	0.773

構築したモデルの精度については、③結果確認用にて若干下がるものの、②予測精度確認用と③の両者に対して比較的高い精度と考えられる¹⁴。

ここで、説明変数の予測への寄与について確認する。確認には SHapley Additive exPlanations (SHAP) と呼ばれる手法を用いる。SHAP 値とは、個々のサンプルにおいて、各変数が予測値にどの程度寄与しているかを示す値であり、その絶対値が予測値への寄与の大きさを、符号が寄与の方向をそれぞれ意味する¹⁵。図表 7 および図表 8 に結果を示す。

図表 7 予測への寄与が大きい変数
(SHAP 値の絶対平均)

図表 8 個々のサンプルに対する SHAP 値の分布



¹⁴ なお、構築したモデルを共同データプラットフォームのデータ側で精度確認が可能となる 2023 年度のデータに適用したところ、AUC=0.633 となり、2022 年度までに比べ低い結果となった。これは貸出明細に関する 2 種類のデータセットを利用したため、2022 年度から 23 年度にかけて不連続性があり、2023 年度のデータのうち、財務、貸出に関する変数の基準日 1 年前の値が取得できず、基準日 1 年前の値との差分、および比の項目も併せて欠損となっていることによる影響と考えられる。

¹⁵ 詳細は、Lundberg, S. and Lee, S. A Unified Approach to Interpreting Model Predictions. “*Proceedings of the 31st International Conference on Neural Information Processing Systems*”, 2017. p.4768-4777.、日本銀行ワーキングペーパーシリーズ (2023.3)「格付け分類モデルにおける機械学習の応用：機械学習の説明可能性を高める手法」、FSA Analytical Notes (2025.6)「信用保証制度の利用状況に関する実態把握」等を参照。

図表 7 より、当期利益が最も予測に寄与しているほか、当期支払利息_割引料、当期営業利益が続くなど、貸出あるいは債務者財務に関する指標が上位に位置していることがわかる。なお、図表 7 においては、個別債務者に対する SHAP 値を絶対値を取ったうえで平均化したものを示しているため、予測値に対し正負どちらの方向で寄与しているかについては示されていない点に注意が必要である。

また、図表 8 は、個々のサンプルにおける SHAP 値の分布を蜂群図で示している。この図は色で変数のとる値の大小を、横軸で個々のサンプルにおける SHAP 値を、各変数の縦方向の広がり度で SHAP 値の分布を示している。例えば当期利益については、当該変数の値が高い（赤色）場合に、予測値を下げる（債務者区分が下方遷移しにくい）方向へ寄与していることがわかる。逆に、当期支払利息_割引料については、当期変数の値が高い（赤色）場合に予測値を上げる（債務者区分が下方遷移しやすい）方向へ寄与していることがわかる。

今回構築した機械学習モデルに対する SHAP を用いた分析において、マクロ経済指標は上位に位置しておらず¹⁶、主に貸出および財務に関する情報が予測に寄与していた¹⁷。他方、マクロ経済指標のみでモデルを構築した場合の②予測精度確認用データにおける予測精度は $AUC=0.601$ であり、全指標でモデル構築した場合よりも予測精度は低いものの、偶然と同等の予測精度とされる $AUC=0.500$ を超えているため、マクロ経済指標も一定程度の説明力を有すると考えられる。


3. 出力結果

機械学習モデルによって算出された個々の債務者に対する債務者区分下方遷移の予測確率の平均値をとり、実績と重ねてプロットしたものが図表 9 になる。

¹⁶ 図表 7 中では省略されているが、個々のサンプルに対する SHAP 値の絶対値平均が最も高いマクロ経済指標は景気動向指数 CI（先行指数）であり、その値は 0.03 であった。

¹⁷ なお、貸出および債務者財務に関する指標のみでモデルを構築した場合の②予測精度確認用データにおける予測精度は $AUC=0.816$ であり、全指標で構築した場合に比べ若干劣るものの、依然として高い精度が確認された。このことから、債務者区分の下方遷移に対しては貸出及び債務者財務に関する変数の説明力が高いと示唆される。

図表 9 債務者区分下方遷移に関する予実比較




予測と実績の推移は似たような動きを示しており、機械学習モデルは債務者区分の下方遷移状況を十分に捕捉できていると言える。なお、予測が個々の債務者における下方遷移確率を集約（モデルが出力する結果を単純平均）したものであるのに対し、実績は各年度の母数に占める下方遷移先の割合であることから、両者の水準に差が生じる点には留意が必要である¹⁸。

また、図表 10 は、機械学習モデルによって算出された個々の債務者に対する債務者区分下方遷移の予測確率について、その分布の時系列推移を示したものである。

¹⁸ 脚注 8 に記載の通り、債務者区分の下方遷移という実際には起こりにくい事象に対する予測精度向上のため、学習時にはアンダーサンプリングを実施（大多数を占める下方遷移しないサンプルを少なく抽出）している。このため、モデルによる予測上は下方遷移確率が数十%以上と極端に大きい債務者も出現し、全体的に予測の水準が実績より高い結果になっていると考えられる。本分析は信用リスクの予兆に関する全体傾向の把握を目的としているため、予測値の水準は調整していないが、仮に本モデルを個々の債務者の下方遷移確率の予測値として参照する場合は、実績に応じて出力結果に掛け目をかける等の調整を行うことが考えられる。


図表 10 機械学習モデル算出の債務者区分下方遷移の予測確率の分布推移




債務者区分下方遷移の予測確率の平均値や中央値（50%点）は、図表 5 で示した債務者区分下方遷移状況と同様、2008、2009 年度のリーマン・ショック期で大幅に上昇しているほか、2020 年度の新型コロナウイルス感染症拡大期においても小幅に上昇が見られる。2023 年度以降については、前章で記載した通り使用データ変更に伴い参考値となる。

このうち、2009、2018、2020、2024 年度を抽出して、ヒストグラムおよび密度分布を描いたものを図表 11～図表 14 に示す。2018 年度は経済状況が比較的安定している状態、2009、2020 年度はそれぞれリーマン・ショック期、新型コロナウイルス感染症拡大期である。


図表 11 債務者区分下方遷移確率分布
(2009 年度)




図表 12 債務者区分下方遷移確率分布
(2018 年度)



図表 13 債務者区分下方遷移確率分布
(2020 年度)




図表 14 債務者区分下方遷移確率分布
(2024 年度)




図表 11 の 2009 年度は高位側に分布が集中し、低位側に向かってゆるやかに裾野が広がっている。リーマン・ショックにより財務状況が悪化した債務者が多く生じ、全体の下方向遷移確率を押し上げたことを示している。図表 12 の 2018 年度では低位側に分布が集中しており、高位側に向かって裾野が広がっている。当年度は図表 11 の時期や、図表 13 の時期に比べて経済的に安定した時期であり、財務状況が悪化した債務者は少なく、全体の下方向遷移確率が低下したことを示している。図表 13 の 2020 年度では低位側への分布集中が緩和され、高位側の分布が高まっている。新型コロナウイルス感染拡大による経済的ショックにより、財務状況の悪化した債務者が生じ、全体の下方向遷移確率を若干押し上げたことを示している。図表 14 の 2024 年度では低位側に加えて中央付近にも分布集中が見られ、2 峰存在する分布となっている。2024 年度については債務者の財務状況、およびマクロ経済指標の変化のほか、使用データの切り替えに伴う影響も考えられることから、今後の状況に注視が必要である。

ここで、分布の形状を表す代表的な値である IQR¹⁹、歪度²⁰、尖度²¹の推移について図表 15～図表 17 において確認を行う。


図表 15 確率分布代表値の推移 (IQR)



図表 16 確率分布代表値の推移 (歪度)



図表 17 確率分布代表値の推移 (尖度)



図表 16 の歪度の推移については、2009 年度のリーマン・ショック期で水準が大幅に低下しているほか、2020 年度の新型コロナウイルス感染症拡大期においても水準の低下が見られるものとなった。これは、通常は債務者区分下方遷移確率が低いところに極めて多く分布している（歪度が大きい）一方、リーマン・ショック及び新型コロナウイルス感染症拡大期に、債務者区分下方遷移確率が大きく算出された企業が比較的多くなり分布の観点からは平準化された（歪度が小さくなる）ことを意味する。他方、図表 15 の IQR 及び図表 17 の尖度の推移については、それぞれ 2009 年度のリーマン・ショック期と、2020 年度の新型コロナウイルス感染症拡大期において逆方向の動きをするなど、景気後退の予兆との関係は一概には言えない結果となった。

¹⁹ IQR：Interquartile Range（四分位範囲）…第3四分位数（75%点）から第1四分位数（25%点）を引いた値として算出される。データのばらつきを表す指標。

²⁰ 歪度：分布の非対称性を示す指標。今回のような度数分布の場合、中心に度数が集中していれば0、中心より左側に度数が集中していれば正、中心より右側に度数が集中していれば負の値をとる。

²¹ 尖度：分布の鋭さを示す指標。値が大きいほど鋭いピークを持つ分布であり、値が小さいほど緩やか平らに近い分布を示す。

4. 本分析の活用と課題

前節より、金融機関の経営に影響を与えるような国内産業の予兆を捉えるにあたり、モデルが出力する分布の形状を確認しつつ、特にその数値の動きが明確で解釈が容易である平均値、中央値、歪度の3指標を中心にモニタリングすることで、足元の状況変化を捕捉し得るとの示唆が得られた。指標の判断基準としては、前年からの数値の水準の大小比較や傾向確認、リーマン・ショックと新型コロナウイルス感染症拡大期といった特定時期と現状との水準比較が考えられる。

一方で課題もある。1つ目が、予測時点に関する課題である。本分析においては、機械学習モデルの構築にあたり、各年3月末時点を基準日としたデータを学習に用いている。このため、基準日以降に何らかの経済的ショックが生じた場合、その反映は翌年度のデータによる学習まで待たなければならない。2つ目が、モデルの更新におけるデータの連続性に関する課題である。共同データプラットフォームのデータは2023年9月期以降のデータであり、今回の機械学習モデル構築に使用したデータとは不連続であるため今後のモデルの挙動を注視する必要がある。特に、図表6（脚注14）における2023年度の予測精度や図表14における分布のように、データの切り替えに伴う影響が生じる可能性については特に注意が必要と考えられる。

IV. まとめ

本分析では、地方銀行の貸出明細データ等及びマクロ経済指標データを用いて金融機関の経営状況に影響を与えるような国内産業の変化の予兆把握を試みた。データ制約等の課題は残るものの、個別債務者に対する債務者区分の下方遷移について一定の精度で予測可能な機械学習モデルを構築することができ、また、モデルによる予測結果を過去の危機時の傾向と比較することで、足元の予兆把握において、一定の示唆を得られることが確認できた。

なお、本分析は試行的に製造業を対象としたが、製造業の中でも食品、機械等さまざまな分野があるため、業種を細分化し、それに応じたマクロ変数を取捨選択することで異なる結果が得られる可能性がある。また、同様の手法で全産業や製造業以外の業種に拡張するといった応用も可能である。

引き続き、足元の経済状況や貸出先の信用リスク等に関する金融機関との対話に活用すべく、分析対象の拡大や指標の精査、モデルの精度向上等に取り組むとともに、共同データプラットフォームの本格的な運用開始を踏まえ、モニタリングの高度化に向けた明細データの活用可能性を検証していく。