

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・研究報告書

2023年3月31日
有限責任あずさ監査法人

注：本報告書は、金融庁の委託により有限責任 あずさ監査法人が実施した調査結果を取りまとめたものである。有限責任 あずさ監査法人は、調査時点で入手した情報に基づき本報告書を適時に取りまとめるよう努めているが、本調査報告書の内容は、本調査の対象に含まれない特定の個人や組織が置かれている状況に対応するものとは限らず、また、情報を受け取った時点及びそれ以降において、その情報の正確性や完全性を保証するものではない。また、本報告書は委託者である 金融庁に対してのみ提出したものであり、本報告書を閲覧あるいは本報告書のコピーを入手閲覧した第三者の本報告書の利用に対して、有限責任 あずさ監査法人は直接ないしは間接の責任を負うものではない。

エグゼクティブサマリー

- 本調査・研究は、AI等のデジタル技術を活用して、業況悪化の兆候が見られるような経営改善支援が必要な先を発見し、早期の経営改善支援等を行うことで、事業者の経営改善・事業再生を促していくことを目指すため令和4年4月に開始した
- 当該目的を達成するため現在の経営改善支援実務の課題に基づき「AI技術を活用した新業務フロー案」を策定し、新業務フロー案を実現するため、①AIモデルの開発、②金融機関との実証事業、③金融機関とのワークショップ、という流れで事業を行うこととした
- また、事業の実効性を高めるため、学術経験者・実務家・AI専門家などを委員とした「AIを活用した経営改善支援に係る研究会（AI活用研究会）」を開催し、当該研究会での意見を参考に検討を進めた
- AIモデルの開発では、経営改善が必要となる先（業績が悪化する先）を早期発見すること及び経営改善の可能性が高い企業を発見することといった「モデル開発コンセプトの確定」、それを実現するための、「モデル母集団の定義」・「教師ラベルの定義」・「アルゴリズムの選定」を行い、本調査・研究で開発するAIモデルの要件定義を行った
- 同時に、AIモデル開発に必要なデータを確保するため4つの共同研究先からの協力を得て、策定した要件定義通りのAIモデルの開発が可能となった
- 開発するAIモデルが本調査の目的を達成し得るよう、AIモデル開発計画の策定、AIモデルの評価指標の設定やデータクレンジング、説明変数の作成等を実施した
- それぞれの開発コンセプトごとにAIモデルを開発した結果、概ね実務適用可能な水準のモデル精度が実現した
- また、AIモデルの解釈性や説明力の向上のため、研究会において出力結果のあり方についても検討し、経営改善支援の実務に組み込むことが可能なAI出力イメージの具体化が実現した
- その後、開発したAIモデルが実際の金融機関データにおいても有効に機能するか確認するため、横浜銀行・栃木銀行・浜松いわた信用金庫、大東京信用組合の4機関の協力を得て、実際の金融機関データを用いたAIモデルの検証（実証事業）を実施し、結果に対する意見も伺ったところ、概ね実務に適用可能な精度レベルをクリアしており、本調査にて採用したアプローチが有効であることが立証された
- あわせて、本モデルを実務適用に結びつけるため、上記4機関とワークショップを実施した。ワークショップでは、AIモデルを活用することで、定量基準での支援先の選定や支援先の捕捉範囲の拡大により、支援業務が効率的・効果的に行える可能性があるとの示唆が得られた
- 一方、導入にあたっては、既存業務やシステム、既存モデルとの親和性や、導入にかかるコスト等を鑑みながら、規程類などの体制整備も行うことが必要との意見も聞かれたため、まずは、本部等の部署でトライアル的に導入し、精度検証を繰り返しながら、導入範囲を少しずつ拡大していくというアプローチが有効であるとの意見も聞かれた
- 上記の研究結果や課題を踏まえ、次年度以降は実際の金融機関での実用化やモデルの高度化に向けて、さらなる調査・研究を進めていく予定である

Contents

	Page
1 本調査の背景・目的・調査概要	4
2 経営改善等に活用可能なデータにかかる調査	9
2-1 現状の経営改善支援業務の整理・課題抽出とAI技術を用いた新たな業務フローの基礎検討	10
2-2 データの調査・取得	13
3 AI技術の活用可能性にかかる研究	16
3-1 AI技術を活用したプロトタイプ要件定義	17
3-2 データクレンジングとプロトタイプAIモデルの開発	24
3-3 実用化に向けたUIの基礎検討	48
4 金融機関による実証事業	57
5 金融機関等向けワークショップ	68
6 本調査・研究の今後の課題	74
7 添付資料	76

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出とAI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 金融機関等向けワークショップ

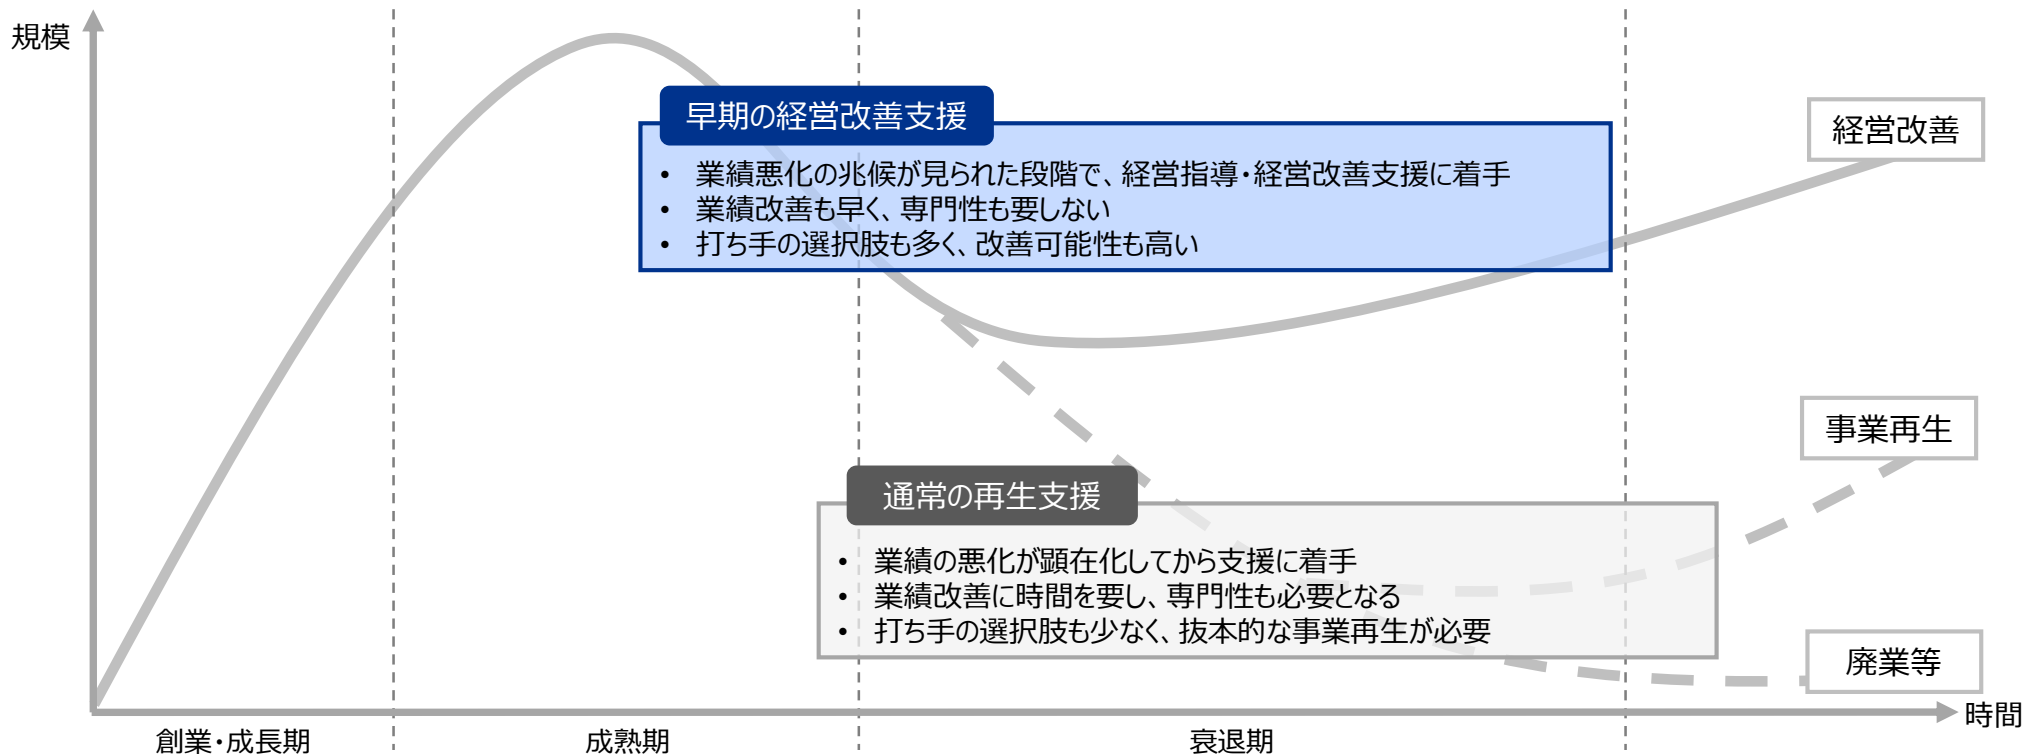
6 本調査・研究の今後の課題

7 添付資料

本調査・研究の背景・目的

- 新型コロナや、原油高等の影響もあり、過去の企業再生局面と比べても、金融支援や経営改善支援を必要とする事業者は多く、経営改善・事業再生支援を効率的・効果的に実施していくことが必要。
- 具体的には、AI等のデジタル技術を活用して、業況悪化の兆候が見られるような経営改善支援が必要な先を発見し、早期の経営改善支援等を行うことで、事業者の経営改善・事業再生を促していくことを目指す。

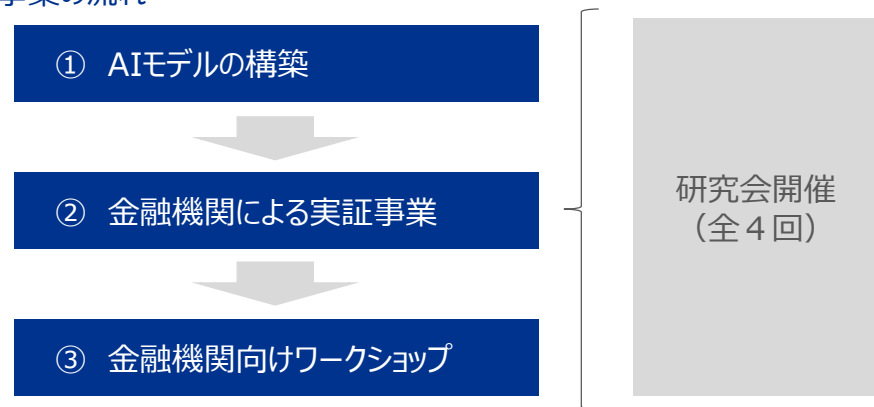
■ 経営改善支援が必要な先の特定（早期発見）のイメージ



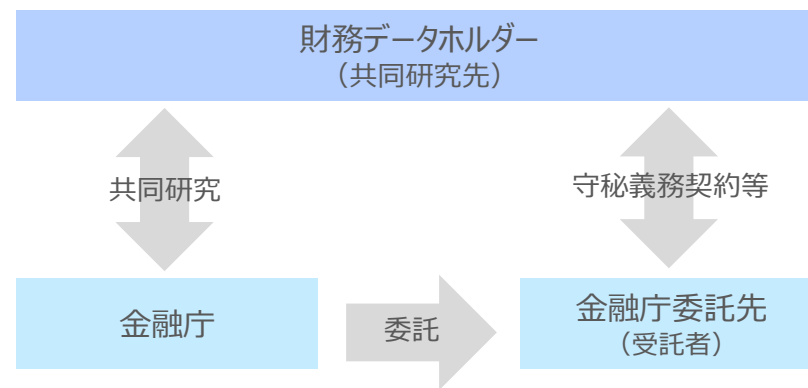
本調査・研究の流れ・実施体制

- 令和4年4月1日より「AIやICTを活用した経営改善支援の効率化に向けた調査・研究」を開始。企業財務データを保有する財務データホルダーとも共同研究を行うことで、経営改善支援が必要な先を早期に発見にする仕組みの構築を目指す。
- 調査・研究に際しては、AIモデルの構築に加え、金融機関による実証事業やワークショップの実施、有識者等で構成される研究会の開催により、実効性を高めていく。

■ 事業の流れ

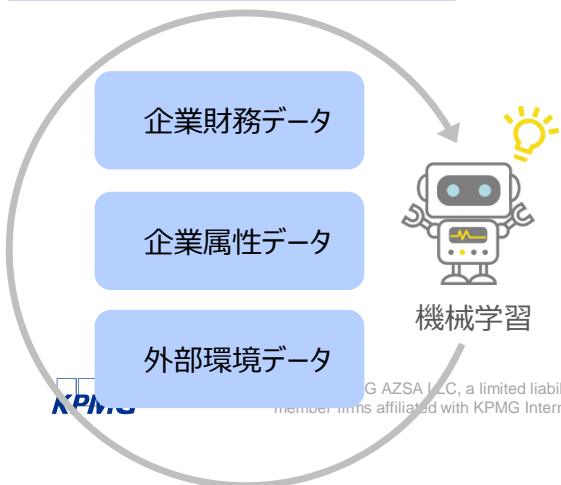


■ 事業実施体制

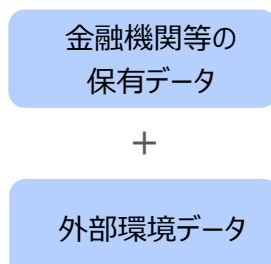


■ モデル構築のイメージ

① AIモデルの構築 (プロトタイプ)



② データをインプット



③ 結果のアウトプット (経営改善支援先の早期発見)

NO	企業名	地域	業種	AIモデルスコア
1	●●工業(株)	長野県〇〇市	製造業	25
2	(株)△△食品	長野県〇〇市	製造業	33
3	(有)■ ■ 工芸	長野県△△市	製造業	42
4	(株)〇〇商店	長野県△△市	小売業	44

本調査・研究の調査概要

- 本調査・研究における調査概要は以下の通り。
- 以降の章では、以下に記載した調査項目ごとに調査・研究内容を取りまとめている。

本調査の業務内容	具体的な調査項目	調査項目の概要
①経営改善等に活用可能なデータにかかる調査	<p>①-1:現状の経営改善支援業務の整理と課題抽出</p> <p>①-2:AI技術を用いた新たな業務フローの基礎検討</p> <p>①-3:データの調査・取得</p>	<ul style="list-style-type: none"> ■ 有識者/実務家へのヒアリングや研究会を通じ、現状の経営改善支援業務のフローを整理し、課題を抽出（AsIsの理解） ■ 現場での活用を視野に、AI技術を用いた新たな業務フロー及びUIの基礎検討を行うとともに業務への活用方法についても研究会を通じ整理(ToBe像設計) ■ 経営改善先の早期発見や経営改善可能性の算出等に資するデータについて、有識者へのヒアリングや研究会を通じて整理 ■ データを取得、データ構成を統一化するクレンジング作業の実施
②AI技術の活用可能性にかかる研究	<p>②-1:AI技術を活用したプロトタイプ要件定義</p> <p>②-2:データクレンジング</p> <p>②-2:AI技術を活用したプロトタイプの開発</p> <p>②-4:実用化に向けたUIの基礎検討</p>	<ul style="list-style-type: none"> ■ ①-1で明らかとなった課題解決に資するようプロトタイプ要件定義を実施 ■ 要件定義の際、経営改善支援業務の効率化を具現化可能なプロトタイプの精度などの目標値も設定 ■ 取得したデータを統一化する等クレンジング作業の実施 ■ クレンジングしたデータを用い、プロトタイプの開発を行うとともに、研究会を通じて意見収集・整理
③金融機関による実証事業	金融機関内での実データ等を用いた検証	<ul style="list-style-type: none"> ■ ①及び②の調査結果に基づき、金融機関内での実データ等を用いた検証を実施 ■ 同時にモデル高度化に係る検証も実施
④金融機関等向けワークショップ	ワークショップの開催	<ul style="list-style-type: none"> ■ 4つの金融機関にてワークショップを開始し、業務フロー基礎検討結果やUIイメージを用いて、実際の企業支援の現場での活用可能性を検証 ■ ワークショップを通じ把握した課題・改善点等を取りまとめ、次年度調査の方向性を整理

本調査・研究のスケジュール

■ 本調査・研究の実施スケジュールは以下の通り

	2022年									2023年		
	4月	5月	6月	7月	8月	9月	10月	11月	12月	1月	2月	3月
研究会 ワークショップ等				▼ 研究会(1回目)		▼ 研究会(2回目)			研究会(3回目) ▼	ワークショップ(1回目) ▼ ワークショップ(2回目) ▼ ワークショップ(3回目) ▼ ワークショップ(4回目) ▼		最終報告 ▼ 研究会(4回目) ▼
①経営改善等に 活用可能なデータ にかかる調査	①-1：現状の経営改善支援業務 の整理と課題抽出		①-2：AI技術を用いた新 たな業務フローの基礎検討			①-3：データの調査・取得						
②AI技術の活用 可能性にかかる 研究	②-1：AI 技術を活用 したプロト タイプの要件 定義		②-2：データクレンジング			②-3：AI技術を活用したプロトタイプ の開発						
							②-4：実用化に向けたUIの基礎検討					
③金融機関による 実証事業										③：金融機関による実証事業		
④金融機関等向け ワークショップ											④：ワーク ショップ	

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出と
AI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

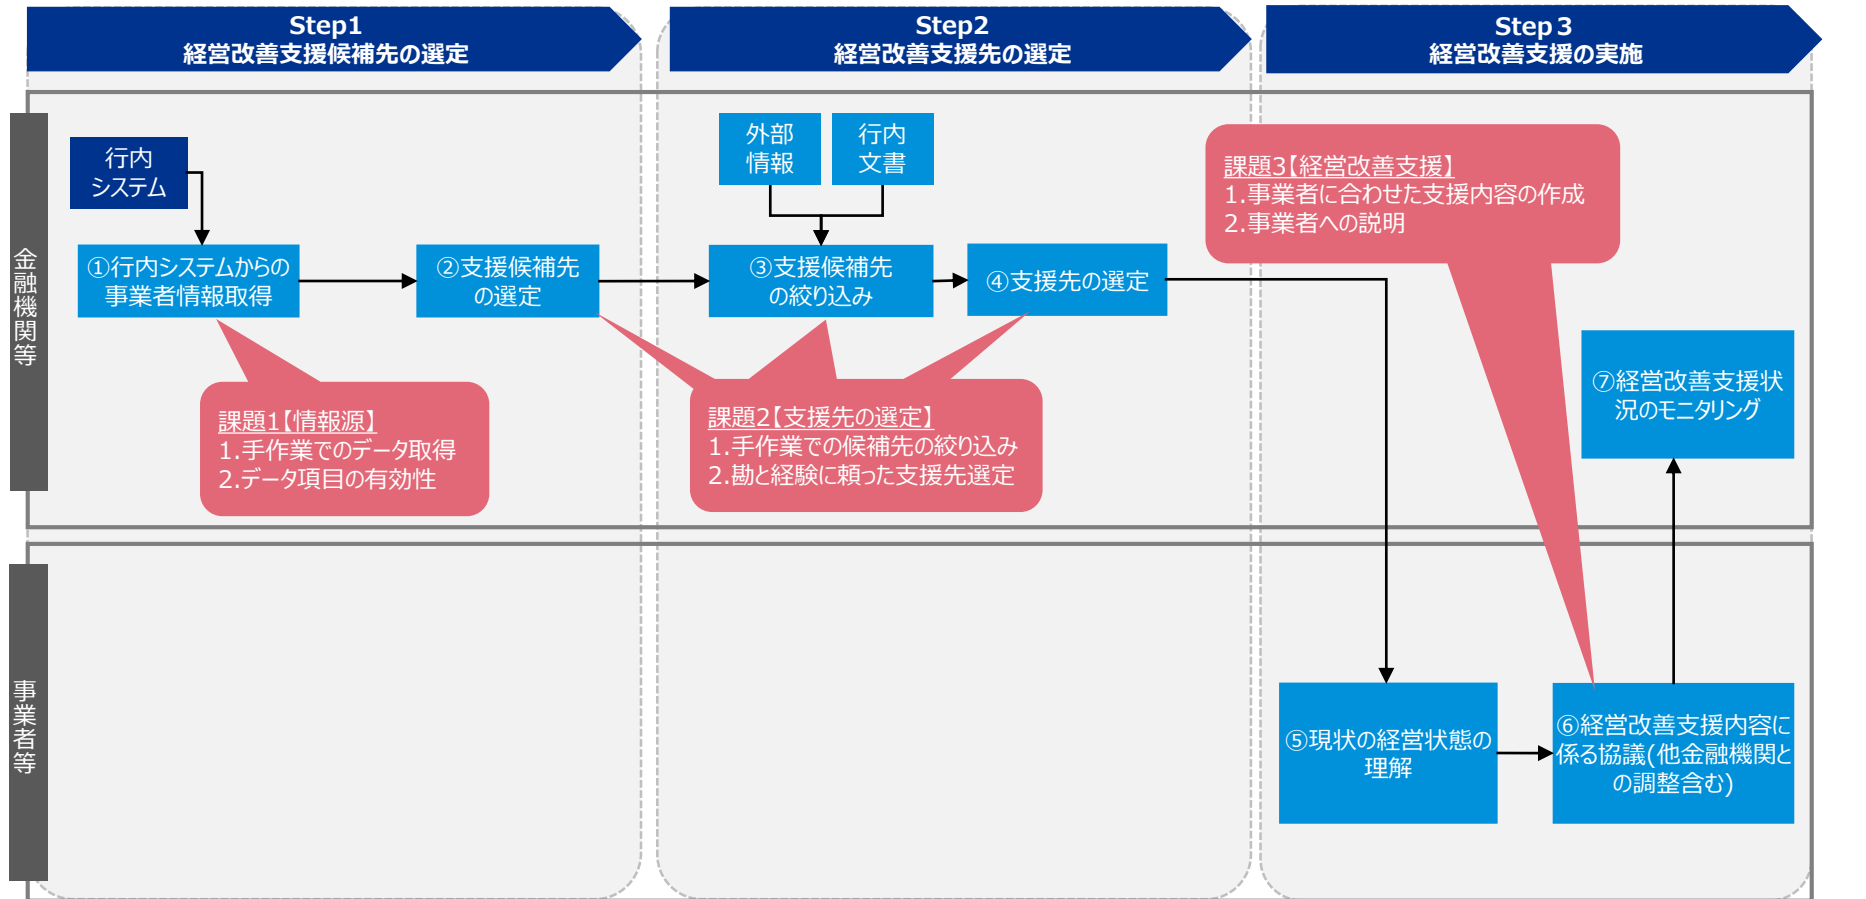
5 金融機関等向けワークショップ

6 本調査・研究の今後の課題

7 添付資料

2-1 現状の経営改善支援業務の整理と課題抽出 [1/2]

■ 現状の経営改善支援の業務フロー及び業務上の課題（仮説）について、以下の通り整理した。



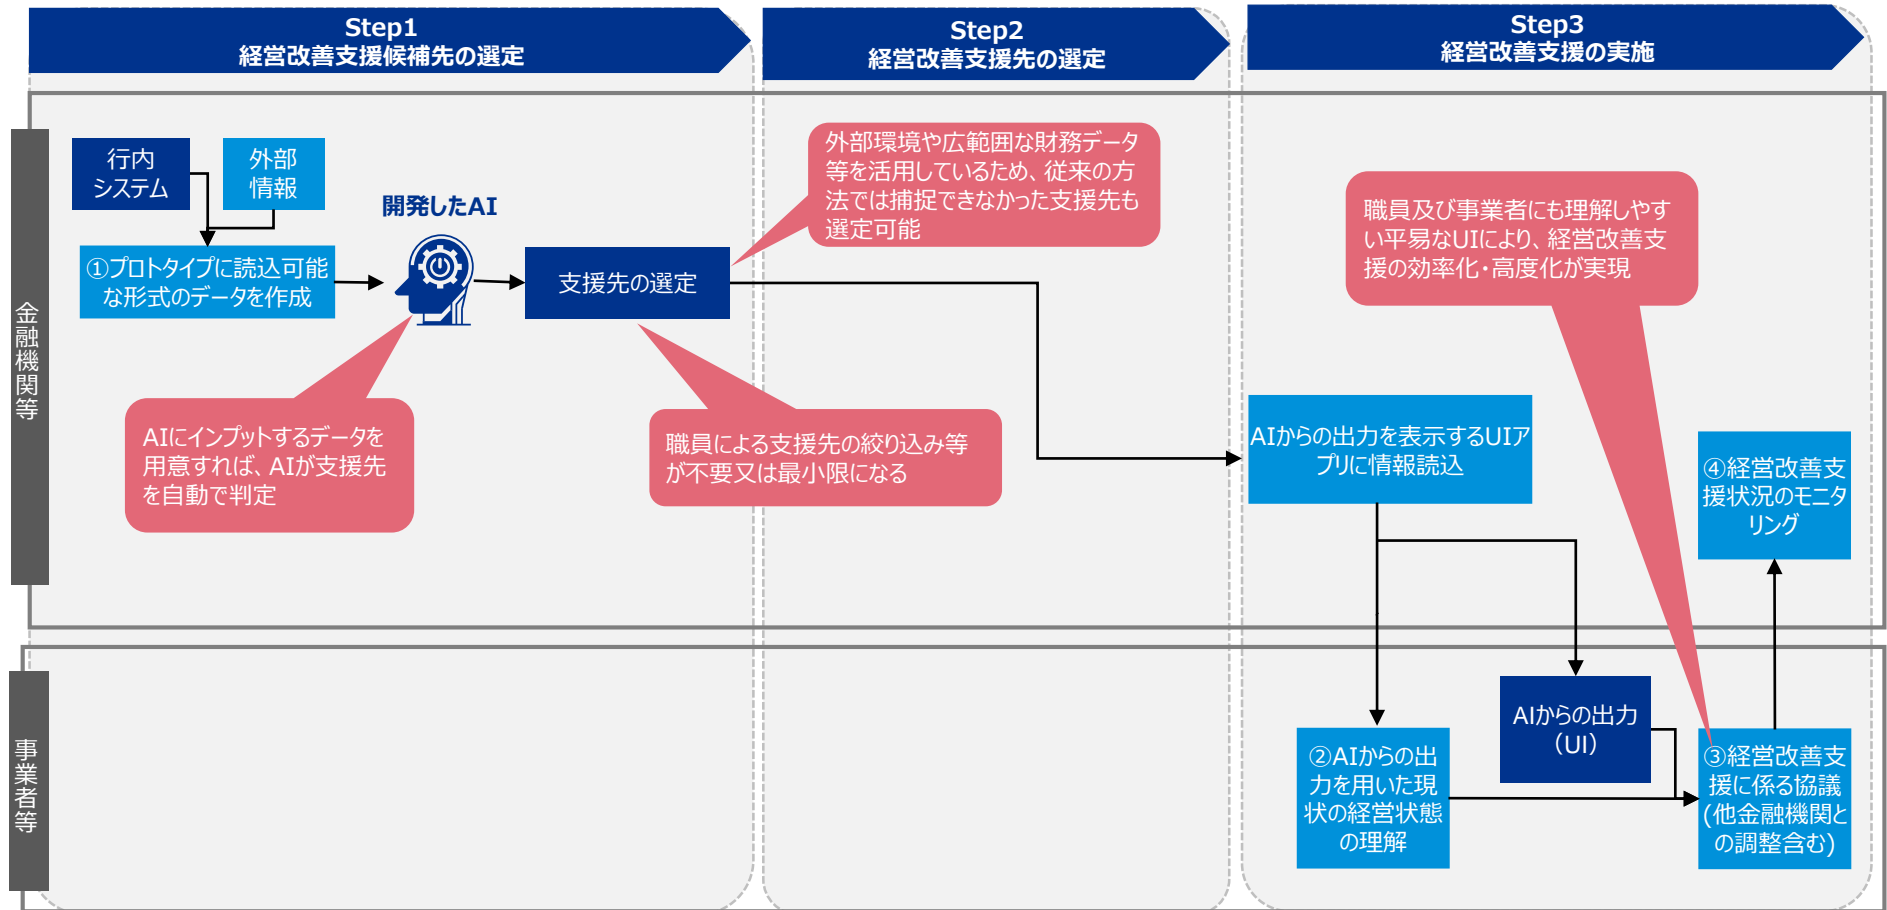
2-1 現状の経営改善支援業務の整理と課題抽出 [2/2]

■ 現状の経営改善支援業務の課題と改善の方向性（仮説）について、以下の通り整理した。

課題No	課題（仮説）	課題の概要（仮説）	改善の方向性（仮説）
課題1 【情報源】	1-1 手作業でのデータ取得	<ul style="list-style-type: none"> 職員が手作業で支援候補先の抽出に必要なデータを取得しており、業務負荷が高い 	<ul style="list-style-type: none"> 支援候補先の選定に有効なデータを自動で取得したうえで、個別のデータ項目が、支援候補先の選定にどの程度寄与しているかを算定する
	1-2 データ項目の有効性	<ul style="list-style-type: none"> 勘と経験に基づき限られたデータ項目を抽出しているため、支援候補先の抽出に有効なデータ項目となっているかの検証が困難 	
課題2 【支援先の選定】	2-1 手作業での候補先の絞り込み	<ul style="list-style-type: none"> 支援候補先を抽出した後、行内システムや外部からの情報等も組み合わせて支援候補先を絞り込んでおり、業務負荷が高い 	<ul style="list-style-type: none"> 過去の経営改善支援の実績データや外部情報、企業の財務データ等に基づき支援先を自動で選定 定量的・科学的なアプローチ（AI技術）を導入することで、支援先の選定結果の事後検証と、結果を踏まえた選定基準見直し（AIの再学習等）といった改善活動を実施できる
	2-2 勘と経験に頼った支援先選定	<ul style="list-style-type: none"> 最終的には、勘と経験に基づき経営改善支援先を特定しており、真に経営改善支援が必要な先を抽出できているかの（事後）検証が困難 	
課題3 【経営改善支援】	3-1 事業者に合わせて支援内容の作成	<ul style="list-style-type: none"> 経営改善支援先の選定後に、別途手作業等で分析した情報などをもとに、経営改善支援策の作成を行っており、業務負荷が高い 	<ul style="list-style-type: none"> 経営改善支援先として選定された要因や改善のポイントを規模別・業種別等で自動的に抽出する
	3-2 事業者への説明	<ul style="list-style-type: none"> 網羅的な情報に基づき分析を行っていないため、事業者に対して納得感のある説明が困難 	

2-1 AI技術を用いた新たな業務フローの基礎検討

■ AI技術活用後の経営改善支援の業務フロー（仮説）について、以下の通り整理した（Step2は不要になる）。



■ : システム ■ : 人のマニュアル作業

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出とAI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 金融機関等向けワークショップ

6 本調査・研究の今後の課題

7 添付資料

2-2 データの調査・取得

－企業の財務データ等の整理・取得

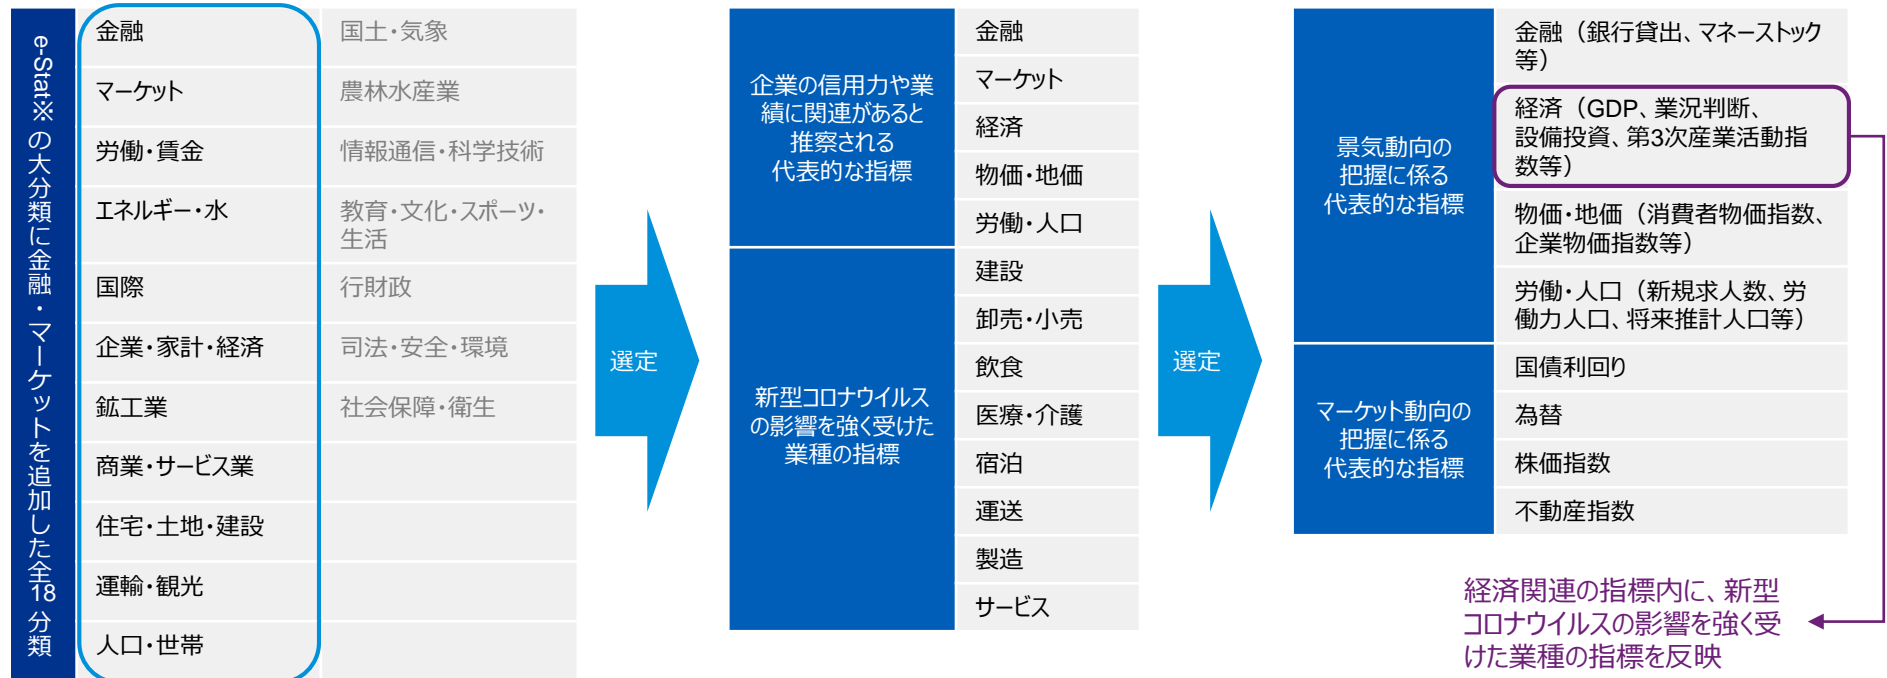
- 経営改善支援が必要な先を特定等するために必要と考えられる企業の財務データ等の要件を以下の通り定義し、共同研究先に対して提示。
- 共同研究先ごとにデータの保有状況も異なることから、モデルの種類（本報告書p.21）に応じ、下表で整理したデータの全部又は一部を用いてAIモデルを開発した。

種類	単位	要件	間隔/期間	項目（例）
企業属性データ	個社単位データ	<ul style="list-style-type: none"> 基本情報、企業の性質や特徴を表す内容を含むデータであること 店番・CIF番号などの企業を一意に特定するコードを持つこと（顧客情報保護の観点から既存コードがマスキングされることは問われないが、下記データ等と紐づけ可能なコードとなっていること） 最新の属性が反映されたデータであることが望ましい 	－ (最新一時点のデータ)	企業特定コード、業種、業歴（事業年数等）、従業員数、所在地 等
財務データ		<ul style="list-style-type: none"> 財務諸表のうち、貸借対照表と損益計算書における各勘定科目の値を含むデータであること 企業属性データとコード等で紐づけることができること 決算年月日とその時点の財務情報が分かること 	間隔：年次、半期、四半期、月次など 期間：過去5年以上あることが望ましい	企業特定コード、決算年月日、流動資産、固定資産、資本金、売上高、営業利益、経常利益、当期利益 等
企業の業況関連データ		<ul style="list-style-type: none"> 企業属性データとコード等で紐づけることができること 企業属性及び財務データ以外で企業の業況や経営状態が分かるデータ（例：債務者区分） 	間隔：格付実施期間ごと 期間：過去5年以上あることが望ましい	企業特定コード、基準年月日、債務者区分、延滞開始年月、延滞の回数 等
経営改善支援の実施有無データ	個社単位データ	<ul style="list-style-type: none"> 企業属性データとコード等で紐づけることができること 経営改善支援実施時期が分かること 	期間：過去5年以上あることが望ましい	企業特定コード、支援開始時期、支援終了時期、支援内容 等

2-2 データの調査・取得

－外部環境データの整理・取得

- 本調査・研究ではモデルの予測対象として、新型コロナウイルスの影響も含んだ企業の信用力や業績の変化を検知することを想定している。そのため個社単位の属性や財務データ以外に、企業の信用力や業績との関連があることが推察されるマクロ経済情報や、新型コロナウイルスの影響を強く受けた業種に係るデータを外部環境データとして採用することとした。
- 各府省等が公表する統計データや日本銀行のオープンデータから、本調査・研究の目的を踏まえて下図の通り外部環境データを選定した。



※e-Statとは、「政府統計の総合窓口」のことであり、各府省等が公表する統計データの一つにまとめ、統計データの検索をはじめとした、さまざまな機能を備えた政府統計のポータルサイト

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出と
AI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプ要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 金融機関等向けワークショップ

6 本調査・研究の今後の課題

7 添付資料

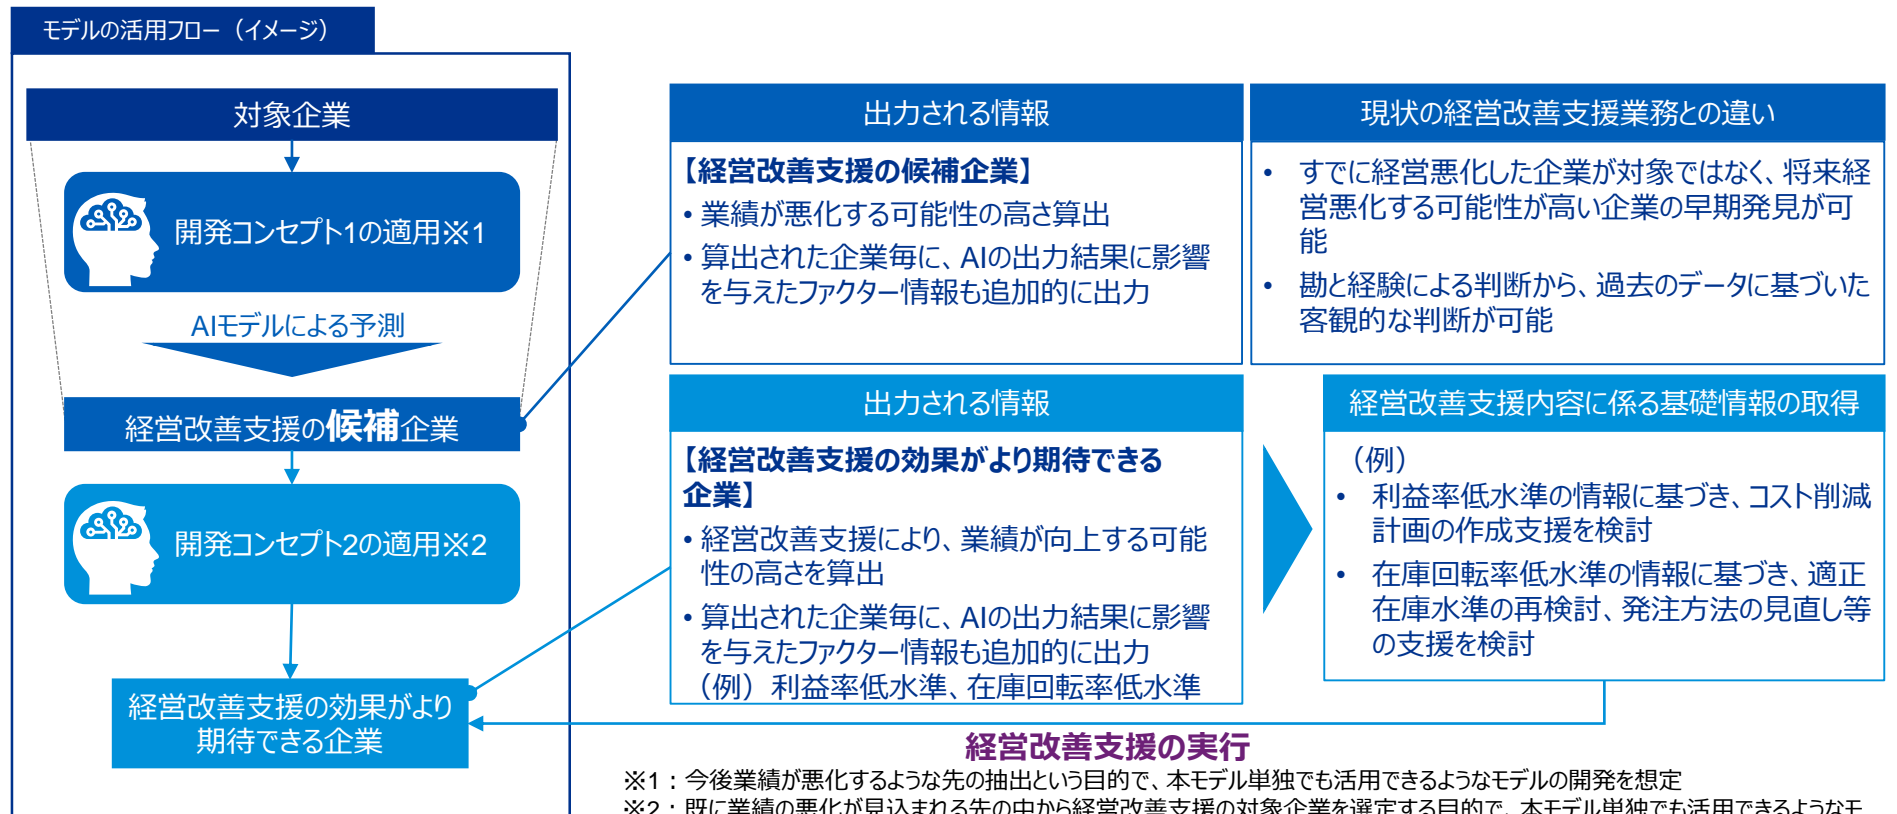
AIモデル（プロトタイプ）の開発コンセプトの検討 [1/2]

- 本調査・研究の目的は、「経営改善支援が必要な先を早期に特定し、当該先に対して経営改善支援策を講じることで、事業者の経営改善を実現すること」である。
- 本目的を達成し得るAIモデルの開発コンセプトを「業績低下の可能性が高い企業の特定」、「経営改善支援により業績が向上する企業の特定」と設定し、下表の通り整理した。
- 本調査・研究では下表の2つの開発コンセプトを満たすAIモデルの開発を試行した。

#	開発コンセプト	モデル構築の母集団		構築したモデルを当てはめる企業
		学習データの対象	モデルによって検知する事象	
1	<p>【Basic】業績低下の可能性が高い企業の特定</p> <p>現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル</p>	一定期間内において業績が悪くはない企業	一定期間経過後に、業績が低下する企業	学習データの対象となる企業（ただし時点が学習データより新しい等により学習データには含まれない企業）
2	<p>【Advanced】経営改善支援により業績が向上する企業の特定</p> <p>現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル</p>	一定期間内において経営改善支援の候補となりえる業況にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）	一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業	同上

AIモデル（プロトタイプ）の開発コンセプトの検討 [2/2]

- 開発コンセプト1と開発コンセプト2を経営改善支援業務に活用した場合の業務フローのイメージは左下図の通り。
- 開発コンセプト1によって「経営改善支援が必要な先の特定（早期発見）」、開発コンセプト2によって「経営改善支援の効果がより期待できる企業の特定」と、「経営改善支援内容に係る基礎情報の取得」が可能となるよう検討を進めた。



AIアルゴリズムの選定

- 開発コンセプト1については、予測のアルゴリズム（ロジスティック回帰・ランダムフォレスト・勾配ブースティング・多層パーセプトロン）を候補として検討した。加えて、開発コンセプト2については、経営改善支援の実施有無データの入手状況等に応じて、因果推論のアルゴリズム（Meta-Learners）を候補として検討した。
- 下表にて整理したアルゴリズムの評価、アルゴリズムの特徴、モデル構築の難易度を踏まえて、構築するモデルのAIアルゴリズムの選定を行い、開発コンセプト1、開発コンセプト2のいずれもロジスティック回帰、ランダムフォレスト、勾配ブースティングの3つの予測のアルゴリズムを採用することとした。
- また、開発コンセプト2については、少数ではあったが経営改善支援の実施有無データの入手見通しが立ったことから、伝統的な因果推論の手法に加え、機械学習による因果推論手法であるMeta-Learners（DA-Learner）を採用し、因果推論モデルを試行することとした。

開発コンセプト	手法	アルゴリズム名	アルゴリズムの概説 (各アルゴリズムの概説については、「AIアルゴリズムの概説」 (本報告書 p.97 - p.104) に別途記載。)	アルゴリズムの評価（開発コンセプト1）/ アルゴリズムの特徴（開発コンセプト2）				モデル構築の 容易さ
				精度	解釈性	計算 負荷	業界での 利用実績	
開発 コンセプト1	予測	ロジスティック回帰	ロジスティック曲線を用いて、目的変数を回帰分析の手法で予測する方法。金融機関実務において企業の信用力評価に最も活用されている方法。	△	◎	◎	◎	◎
		ランダムフォレスト	多くの決定木（学習データを条件分岐によって分割していくことで分類問題を解く手法）モデルを構築し、多数の決定木の予測値の平均値を最終的な予測値とする方法。	○	○	○	○	○
		勾配ブースティング	決定木を構築し、当該決定木が外したサンプルに当てはまるようにウェイトを調整して、次の決定木を構築する。これを繰り返して最終的な予測値とする方法。	○	○	○	○	○
		多層パーセプトロン	複数の入力値に対し、それぞれ調整した重みをかけて出力値を計算し、その結果を用いて分類する方法。	◎	△	△	△	△
開発 コンセプト2	予測	開発コンセプト1と同様にロジスティック回帰、ランダムフォレスト、勾配ブースティング、多層パーセプトロンをアルゴリズムの候補とする。						○
	因果推論	Meta-Learners ※	因果推論を行うための論理フローの各ポイントに主要な機械学習アルゴリズム（ロジスティック回帰、ランダムフォレスト等）を適用し、介入効果を推定する方法。	<ul style="list-style-type: none"> データの特性に合わせて機械学習アルゴリズムを選択することができる。 データの不均衡性に対応できる手法もある。 				△

※：個別企業への因果効果を推定するために、機械学習を用いた因果推論のアルゴリズムを候補とした。

モデル開発母集団と教師ラベルの要件定義

- 開発コンセプトごとにモデル開発母集団と教師ラベルの要件定義を行った。
- 信用力の序列情報については、共同研究先ごとに保有している情報が異なることから、データの特徴に応じ、債務者区分や信用スコア等を採用した。

【開発コンセプト1】

開発コンセプト	現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル	モデル開発母集団の対象	一定期間内において 業績が悪くはない企業	モデルによって検知する事象 (教師ラベル)	一定期間経過後に、 業績が低下 する企業
案	モデル開発母集団の定義 【業績が悪くはないの定義（案）】	教師ラベルの定義 【業績が低下の定義（案）】	補足 【信用力の序列情報】		
①	「信用力の序列情報」が一定程度以上 (債務者区分が要注意先以上など)	「信用力の序列情報」が一定程度以下に遷移 (債務者区分が要管理先以下に下方遷移など)	共同研究先毎に以下の情報を使用 <ul style="list-style-type: none"> • 債務者区分 • 信用スコア • 他の共同研究先データから推測した債務者区分や信用スコア 		
②	財務指標（信用リスク管理等の観点から既に重要と認識している指標）が一定の範囲内	財務指標が一定の範囲より低下			

【開発コンセプト2】

開発コンセプト	現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル	モデル開発母集団の対象	一定期間内において 経営改善支援の候補となりえる業況 にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）	モデルによって検知する事象 (教師ラベル)	一定期間経過後、実際に 経営改善支援を受けて、業績が向上 した企業
案	モデル開発母集団の定義 【経営改善支援の候補となりえる業況の定義（案）】	教師ラベルの定義 【業績が向上の定義（案）】	補足 経営改善支援を受けた先の定義(案)		
①	「信用力の序列情報」が一定程度以下 (債務者区分が要管理先以下など)	「信用力の序列情報」が一定程度以上に遷移 (債務者区分が、要注意先以上に上方遷移など)	共同研究先毎に以下の情報を使用 <ul style="list-style-type: none"> • 「経営改善支援の候補となりえる業況」となった以降に、経営改善支援が実践されたこと • ただし、経営改善支援の実施有無の情報を保有していない場合、本条件は課さない想定 		
②	過去一定期間の「信用力の序列情報」が当該時点よりも悪化する水準に遷移 (債務者区分が、正常先から要注意先、要注意先から要管理先に下方遷移したなど)	「信用力の序列情報」がある時点からより良好な水準へ遷移 (債務者区分が、要管理先から要注意先、要注意先から正常先など上方遷移したなど)			

モデル開発計画

- データの頻度、項目、母集団等の観点から構築するモデルの種類を検討し、モデル精度等の基準となる財務のみモデルのほか、全ての共同研究先に共通するデータで構築した汎用モデル、各共同研究先独自のデータで構築した共同研究先モデルを構築することとした。
- 開発コンセプト2については、上記に加え、因果推論モデルを試行することとした。
- なお、高頻度な財務を用いたモデルの有効性の検証を目的として、財務項目のデータ間隔を月次としたモデル（月次モデル）構築の検討を行ったものの、月次の財務データの受領が実現できなかったため、モデル開発計画の対象外とした。

構築するモデル	手法	財務項目の頻度	モデルの概要	モデルの目的
財務のみモデル (ベースラインモデル)	予測	年次	<ul style="list-style-type: none"> ➢ 財務項目のみを使用したモデル (外部環境データや定性項目は用いない) ➢ 財務のみモデルはある特定の共同研究先データにて構築 	<ul style="list-style-type: none"> ➢ モデルの精度等の基準となるモデル ➢ 基本的には、他モデルは本モデルの精度等をどの程度上回ったかにより、評価を行う
汎用モデル			<ul style="list-style-type: none"> ➢ 全ての共同研究先データにて共通する財務項目と属性項目、外部環境データのみ用いたモデル ➢ 共同研究先毎のモデル精度の差が最小となるように共同研究先間データにてクロスバリデーションを実施 	<ul style="list-style-type: none"> ➢ 一般的な説明変数のみ用いた実務適用が容易なモデルを構築し、その精度を確認する ➢ あらゆる中小企業に対してもある程度の精度が期待できる汎化性能の高いモデルを構築する ➢ 原則として、本モデルを実際の金融機関のデータを用いた検証に活用する
共同研究先モデル			<ul style="list-style-type: none"> ➢ 各共同研究先データで使用可能な財務項目と属性項目、外部環境データに加え、共同研究先毎の独自の項目を使用して、共同研究先毎に構築したモデル 	<ul style="list-style-type: none"> ➢ 各共同研究先にて取得することができる項目を使用してモデルを構築し、その精度を確認する ➢ 情報量の異なる共同研究先データでモデルを構築して汎用モデルとの精度等の比較を行い、定性情報の有用性確認や今後の活用可能性等についての考察を行う
因果推論モデル 【開発コンセプト2のみ】			因果推論	<ul style="list-style-type: none"> ➢ 経営改善支援の実施有無に関する情報を用いて、開発コンセプト2の本来のアプローチである因果推論の手法を用いたモデル

モデルの評価指標

■ 本調査・研究で開発するAIモデルを評価する指標は、各評価の観点から踏まえ下表のように設定した。

#	評価観点	評価指標	補足説明
1	<ul style="list-style-type: none"> モデル全体の精度が高いか 企業を信用力に応じて序列付けることができるか 	<ul style="list-style-type: none"> AUC、AR値 (数値による評価指標) CAP曲線 (視覚的な評価) 	<ul style="list-style-type: none"> 経営改善支援候補先に対する職員による精査が、現行業務と比べて削減されるような高い精度を持つかを評価するもの 特定の条件 (例：閾値を設定する) を設けず、モデル全体として一定以上の精度があるかを評価 機械学習モデルの2値分類問題ではAUCを用いることが多いため本調査・研究ではAUCを設定。また信用リスク管理の実務上AR値を用いることも多いため、AR値も設定 (参考：AR値 = AUC × 2 - 1)
2	<ul style="list-style-type: none"> モデルスコアのある閾値以上の先に多く正例 (経営改善支援が必要な先) が含まれるか 	<ul style="list-style-type: none"> スコアランク毎の正例の割合 適合率 (precision) (正と予測したものに対し、実際に正であるものの割合) 	<ul style="list-style-type: none"> 本モデルを実務に活用する際は、あるスコア以上の企業を抽出し、その先の一部又は全部に対し経営改善支援を実施する想定 そのため抽出された企業に多く経営改善支援が必要な先が含まれていることが重要なため、本評価指標を設定。当該評価が高いと支援候補先の精査を行う職員の業務負荷削減につながる
3	<ul style="list-style-type: none"> モデルスコアのある閾値以上の先の正例 (経営改善支援が必要な先) が、全体の正例の多くを捕捉できているか 	<ul style="list-style-type: none"> 再現率 (recall) (実際に正のものに対し、正しく正と予測できたものの割合) 	<ul style="list-style-type: none"> あるスコア以上の企業を抽出した際、経営改善支援が必要な先のうち何割を捕捉できているかを評価するための指標 当該評価が高いと、これまで捕捉することのできなかった経営改善支援候補先が特定できることを意味する

モデル開発におけるKPIの設定・評価方法

■ モデル開発におけるKPIは、以下の2つの観点を踏まえ設定した。

- ① 現行の経営改善支援実務では活用していない情報により、これまで捕捉することのできなかった経営改善支援候補先が特定できること。
- ② 抽出された経営改善支援候補先に対する職員による精査が、現行業務と比べて削減されるような高い精度を持つこと。

■ また、当該KPIを踏まえた具体的な評価方法は以下の通りとする。

観点	モデル開発におけるKPI	
	共同研究先データを使用したモデル開発	金融機関による実証事業
①	<ul style="list-style-type: none"> • 現行の信用リスクモデル※1では活用していないデータ（外部環境データや定性データ等）を分析に活用出来ているか。 • 現行の経営改善支援業務では捕捉できていなかったような経営状態（足元では正常先等）の企業を分析対象に出来ているか。 	<ul style="list-style-type: none"> • 開発したモデルに、実証事業に参加する金融機関における従来のモデルでは経営改善支援の対象でなかった企業のデータを当てはめて特定された企業の中に、実際に突発的に業績が悪化した先や経営改善支援を実施した先が含まれているか。
②	<ul style="list-style-type: none"> • 汎用モデルと共同研究先モデルのテスト用データ※2における精度が、財務のみモデルの精度よりも高いか。 • 開発したモデルにテスト用データを当てはめて出力したスコアの悪い上位企業に、経営改善支援が必要な先（実際に業況が悪化した先）の多くが含まれるか。 	<ul style="list-style-type: none"> • 開発したモデルに、実証事業に参加する金融機関における企業のデータを当てはめて特定された企業の中に、実際に突発的に業績が悪化した先、経営改善支援を実施した先の多くが含まれているなど、相応の精度があるか。

※1 現行の信用リスクモデルは、多くは企業財務及び企業属性のみ勘案していることが多い。定性情報や外部環境情報はモデルによる定量評価後の定性評価により勘案している。本調査・研究ではモデルそのものに外部環境や定性データ等を加味することを想定している。

※2 テスト用データの作成方法は、「学習用データとテスト用データの作成」（本報告書 p.37）に記載。

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出と
AI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 金融機関等向けワークショップ

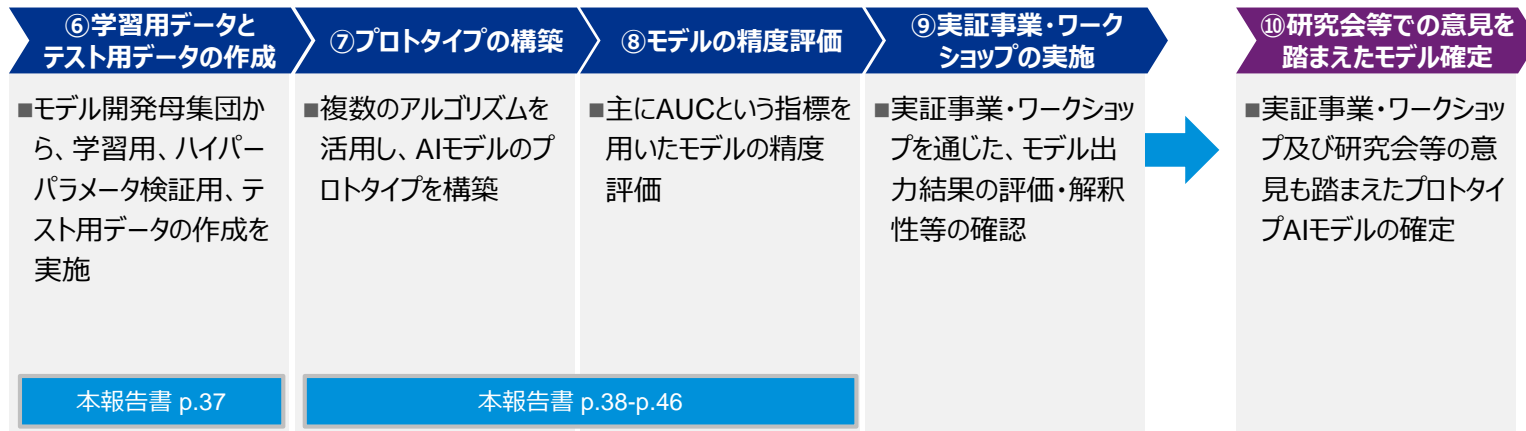
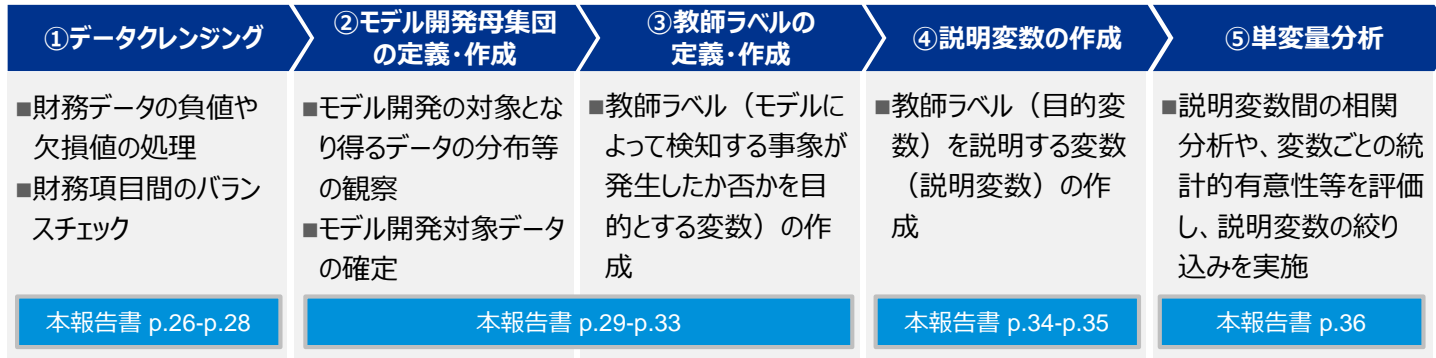
6 本調査・研究の今後の課題

7 添付資料

プロトタイプAIの開発手順

■ プロトタイプAIは、以下の手順に沿って開発を行った。

【本調査・研究におけるAI技術を活用したプロトタイプ開発の手順】



共同研究先の企業の財務データのクレンジング

■ 共同研究先データ共通の企業の財務データのクレンジング方法として、負値データの取り扱い、欠損データの取り扱い等を以下の通り定めた。

手順	処理項目	処理内容
1	財務情報が誤りである可能性があるデータの削除	<ul style="list-style-type: none"> 「資産合計」がゼロ以下のデータを削除する。
2	負値が不適切な財務項目に負値が入力されているデータの処理	<ul style="list-style-type: none"> 負値が不適切な財務項目に負値が入力されているデータを削除する。
3	現金・預金が負値のレコードの処理	<ul style="list-style-type: none"> 「現金・預金」の負値は当座貸越とみなし、その分「短期借入金」を増加させる。 「現金・預金」、「短期借入金」が関連する財務項目値を修正する。
4	財務項目（細目）の欠損の処理	<ul style="list-style-type: none"> 財務項目（細目）の欠損は一部の例外を除き、ゼロ値を入力する。
5	財務項目（演算項目）の欠損の処理	<ul style="list-style-type: none"> 「当座資産計」や「売上総利益」等の財務項目（演算項目）の欠損については、手順4までの処理を実行したデータにて、演算を行い算出した値を入力する。
6	バランスチェック	<ul style="list-style-type: none"> 以下の財務項目について左右の値を比較し、バランスチェックを行う。 <ul style="list-style-type: none"> ■ 資産合計 = 流動資産計 + 固定資産計 + 繰り延べ資産計 ■ 負債合計 = 流動負債計 + 固定負債計 + 特別法上の準備金 ■ 負債・資本合計 = 負債合計 + 資本合計 ■ 資産合計 = 負債・資本合計 ■ 経常利益 = 営業利益 + 営業外収益 - 営業外費用 ■ 当期利益 = 税引前当期利益 - 法人税等充当額 + 少数株主損益 左右の値の差が1% ^(注) 以上のデータを削除する。

(注) パーセンテージの設定は他の共同研究先データの状況を踏まえて調節する。

外部環境データの整備

– 分析対象とする外部環境データ候補

■ モデル開発に用いる具体的な外部環境データは以下の通り。

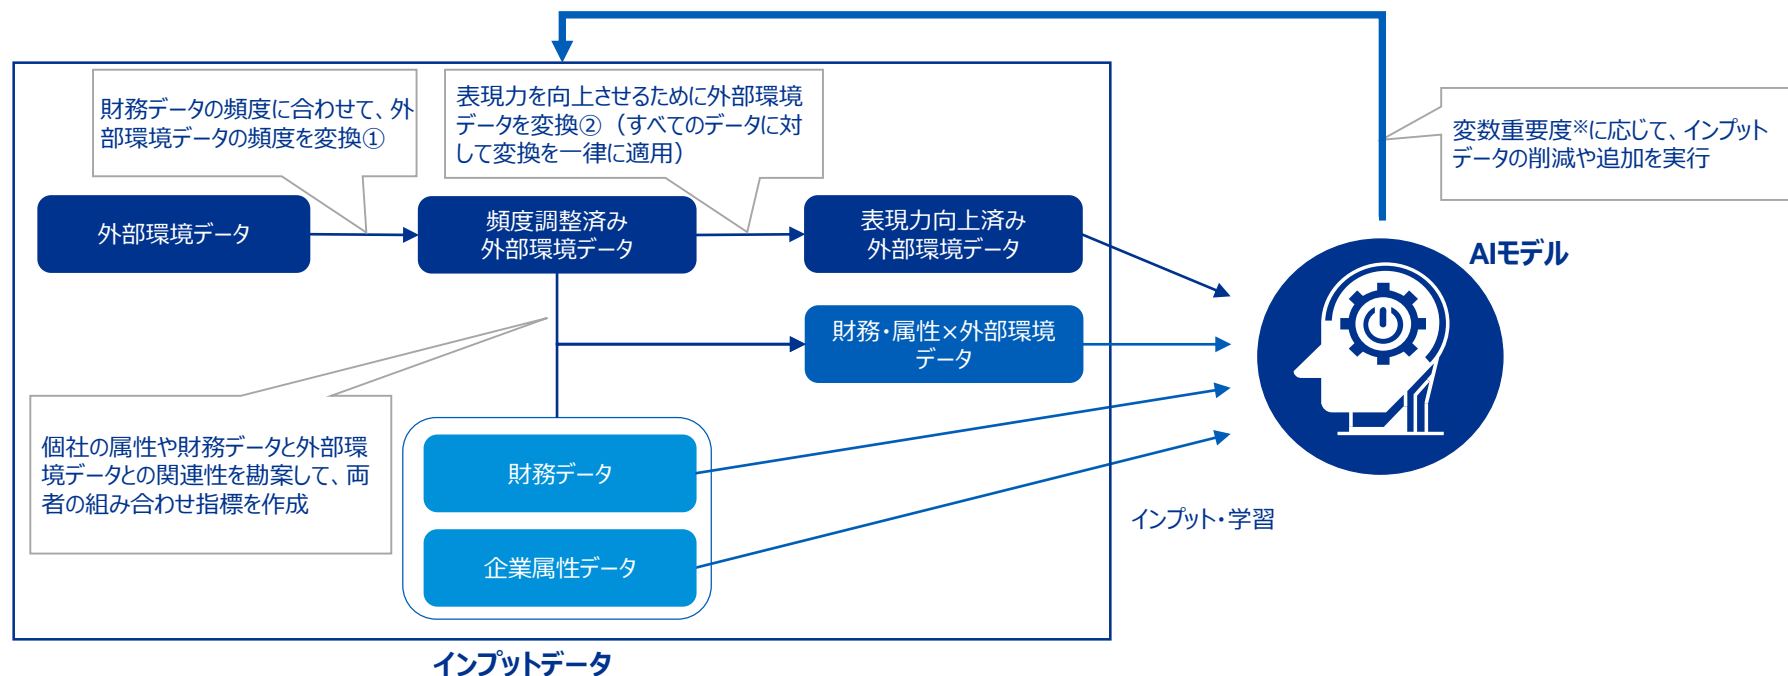
種類	マーケット関連データ	経済関連データ	金融関連データ	物価・地価関連データ	労働・人口関連データ
項目名	<ul style="list-style-type: none"> 為替レート 無担保コールO/Nレート 国債利回り TOPIX 日経225 東証REIT指数 Dow Jones Total Stock Market Index 	<ul style="list-style-type: none"> GDP成長率 業況判断DI 景気動向指数 中小企業売上見通しDI 発電実績 エネルギー消費量 入港船舶の総トン数 公共機関からの受注工事額 新設建築物（住宅）床面積、工事予定額 商業販売額 客室稼働率、宿泊者数 訪日外国人数 貨物・旅客輸送量 鉱工業生産・出荷・在庫指数 製造工業生産能力・稼働率指数、予測指数 機械受注額 第3次産業活動指数 	<ul style="list-style-type: none"> 貸出約定平均金利 総貸出平残 マネタリーベース マネーストック 倒産件数 倒産負債総額 	<ul style="list-style-type: none"> 消費者物価指数 消費者態度指数 企業物価指数 企業向けサービス価格指数 WTI原油価格 地価 	<ul style="list-style-type: none"> 完全失業率 労働力人口 常用雇用指数 新規求人数 有効求人倍率 将来推計人口 住民基本台帳人口

※ 下線は新型コロナウイルスの影響を強く受けた業種に係る指標データ

外部環境データの整備

– 外部環境データ使用方法（概要）

- 財務データの頻度は年次が想定されるが、外部環境データの頻度は年次だけでなく、日次や月次、四半期も存在する。そのためモデルへのインプットの前に財務データの頻度に合わせて外部環境データの頻度を変換することとした。
- 頻度の変換後、モデルインプット時の外部環境データの表現力を向上させるための変換を行った。
- さらに、個社の属性や財務データと外部環境データを組み合わせて作成する指標も重要であることから、当該指標についても検討し、採用することとした。



※ 変数重要度とはインプットデータが目的変数の予測にどれくらい寄与しているかを測る指標

モデル開発母集団と教師ラベルの詳細設計

– モデル開発母集団と教師ラベル設計の概要

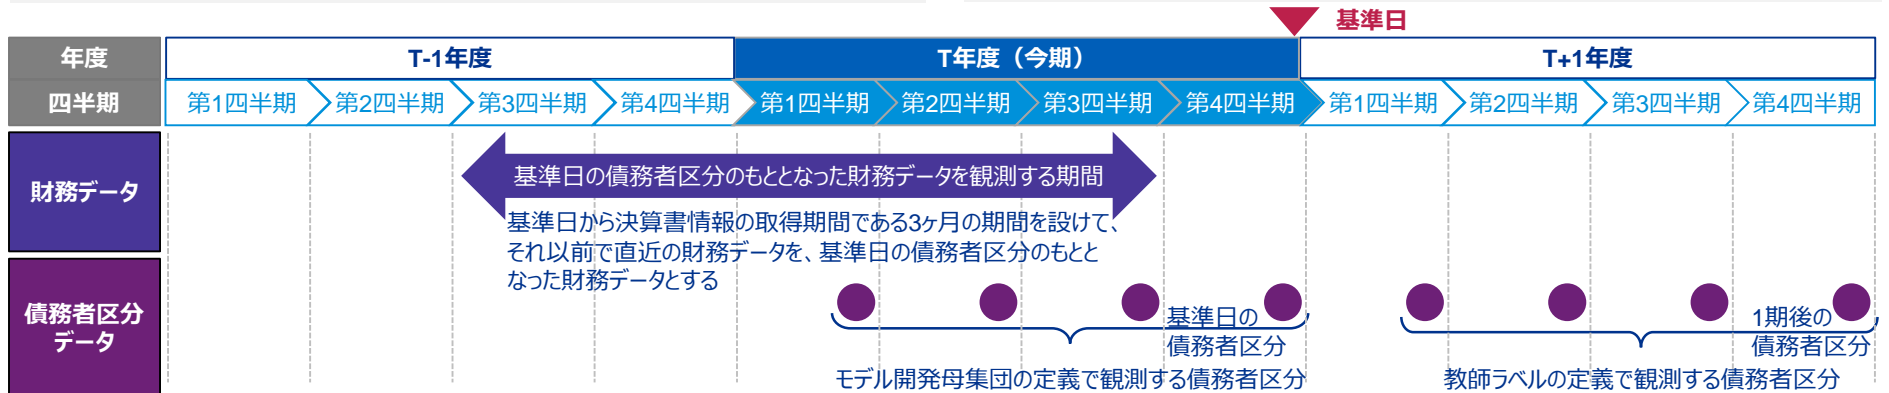
- 共同研究先データに対して、開発コンセプト毎にモデル開発母集団の定義と、教師ラベルの定義を行うにあたっての、共通的な考え方を以下に示す。
- **ただし、債務者区分ではなく信用スコアを有する共同研究先については当該スコアを用いて、下記と同じ概念で定義している（次頁以降同様）。**

モデル開発母集団の定義

- 以下3点の条件を満たす企業から、モデル開発母集団の対象を定義する。
 - 基準日時点の債務者区分のもととなった財務データとその1年前財務を有する（2期連続の財務データを有する）
 - 基準日から1期後の債務者区分を有する
 - 基準日から過去1年間の債務者区分を観測し、開発コンセプト毎に定めた基準に該当する
- 基準日から過去1年間の債務者区分とは、基準日含む過去4四半期の債務者区分とする。ただし、期末のみ債務者区分が付与されている企業については、基準日の債務者区分のみ観測する。

教師ラベルの定義

- 教師ラベルは、開発コンセプト毎に、モデルによって検知する事象に該当する企業を「正例」、それ以外の企業を「負例」として定義する。
- 基準日より未来の1年間の債務者区分を観測し、開発コンセプト毎に定めた基準にもとづいて教師ラベルを付与する。
- 基準日より未来の1年間の債務者区分とは、基準日を除いた未来の4四半期分の債務者区分とする。ただし、期末のみ債務者区分が付与されている企業については、1年後の債務者区分のみ観測する。



モデル開発母集団と教師ラベルの詳細設計

– 開発コンセプト1における詳細設計[1/2]

【モデル開発母集団の定義】

- 「一定期間内において業績が悪くはない企業」をモデル開発母集団の対象とした。
- 基準日から過去1年間の債務者区分を観測し、モデル開発母集団の対象・対象外とするものを、その例とともに以下に示す。

対象 / 対象外	基準日から過去1年間の債務者区分	基準日から過去1年間の債務者区分の例（基準日を2016年3月とした場合）				
		債務者区分付与の頻度	2015年6月	2015年9月	2015年12月	2016年3月(基準日)
モデル開発母集団の対象	常に「正常先」	四半期ごと	正常先	正常先	正常先	正常先
		期末のみ	—	—	—	正常先
	もっとも悪い区分が「要注意先」	四半期ごと	正常先	要注意先	要注意先	正常先
		期末のみ	—	—	—	要注意先
モデル開発母集団の対象外	もっとも悪い区分が「要管理先」以下	四半期ごと	要管理先以下	要注意先	要注意先	要注意先
		期末のみ	—	—	—	要管理先以下

モデル開発母集団と教師ラベルの詳細設計

– 開発コンセプト1における詳細設計[2/2]

【教師ラベルの定義】

- 「一定期間経過後に、業績が低下する企業」をモデルによって検知する事象（教師ラベル）とした。
- 教師ラベルは、「一定期間経過後に、業績が低下する企業」を「正例」、「それ以外の企業」を「負例」として定義した。
- 具体的には下表の通り、基準日から過去1年間の債務者区分と、当該基準日から1期後（1年後）までの債務者区分の変化に応じて、教師ラベルを定義した。

#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル	#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル
1	常に「正常先」	常に「正常先」	負例	4	もっとも悪い区分が「要注意先」	常に「正常先」	負例
2	常に「正常先」	もっとも悪い区分が「要注意先」	正例	5	もっとも悪い区分が「要注意先」	もっとも悪い区分が「要注意先」	負例
3	常に「正常先」	もっとも悪い区分が「要管理先」以下	正例	6	もっとも悪い区分が「要注意先」	もっとも悪い区分が「要管理先」以下	正例

- 上記定義における、基準日から1期後までの債務者区分は以下の通り（債務者区分付与の頻度が四半期の場合のみ記載。期末のみ債務者区分が付与されている企業については、基準日から1期後の債務者区分のみ観測する）。なお、開発コンセプト2も同様とした。

基準日から1期後までの債務者区分	基準日から1期後までの債務者区分の例（基準日を2016年3月とした場合）				
	2016年3月 （基準日）	2016年6月	2016年9月	2016年12月	2017年3月 （1期後）
常に「正常先」		正常先	正常先	正常先	正常先
もっとも悪い区分が「要注意先」		正常先	要注意先	正常先	正常先
もっとも悪い区分が「要管理先」以下		要注意先	要注意先	要管理先	要注意先

モデル開発母集団と教師ラベルの詳細設計

– 開発コンセプト2における詳細設計[1/2]

【モデル開発母集団の定義】

- 「一定期間内において経営改善支援の候補となりえる業況にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）」をモデル開発母集団の対象とした。
- ただし、「経営改善支援を受けた」かの条件は、経営改善支援有無データを保有する共同研究先データに対してのみ課すこととした。
- 基準日から過去1年間の債務者区分を観測し、モデル開発母集団の対象・対象外とするものを、その例とともに以下に示す。

対象 / 対象外	基準日から過去1年間の債務者区分	基準日から過去1年間の債務者区分の例（基準日を2016年3月とした場合）					
		債務者区分付与の頻度	2015年6月	2015年9月	2015年12月	2016年3月（基準日）	
モデル開発母集団の対象	常に「要注意先」	四半期ごと	要注意先	要注意先	要注意先	要注意先	
		期末のみ	－	－	－	要注意先	
	常に「要管理先」	四半期ごと	要管理先	要管理先	要管理先	要管理先	
		期末のみ	－	－	－	要管理先	
	「要注意先」と「要管理先」が混在		四半期ごと	要注意先	要管理先	要注意先	要注意先
	モデル開発母集団の対象外	常に「正常先」	四半期ごと	正常先	正常先	正常先	正常先
期末のみ			－	－	－	正常先	
「正常先」と、「要注意先」・「要管理先」が混在		四半期ごと	正常先	要注意先	要管理先	要注意先	
もっとも悪い区分が「破綻懸念先」以下		四半期ごと	要注意先	要管理先	破綻懸念先	実質破綻先	
		期末のみ	－	－	－	破綻懸念先	

モデル開発母集団と教師ラベルの詳細設計

– 開発コンセプト2における詳細設計[2/2]

【教師ラベルの定義】

- 「一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業」をモデルによって検知する事象（教師ラベル）とした。
- ただし、「経営改善支援を受けた」かの条件は、経営改善支援有無データを保有する共同研究先データに対してのみ課すこととした。
- 教師ラベルは、「一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業」を「正例」、「それ以外の企業」を「負例」として定義した。
- 具体的には下表の通り、基準日から過去1年間の債務者区分と、当該基準日から1期後（1年後）までの債務者区分の変化に応じて、教師ラベルを定義した。

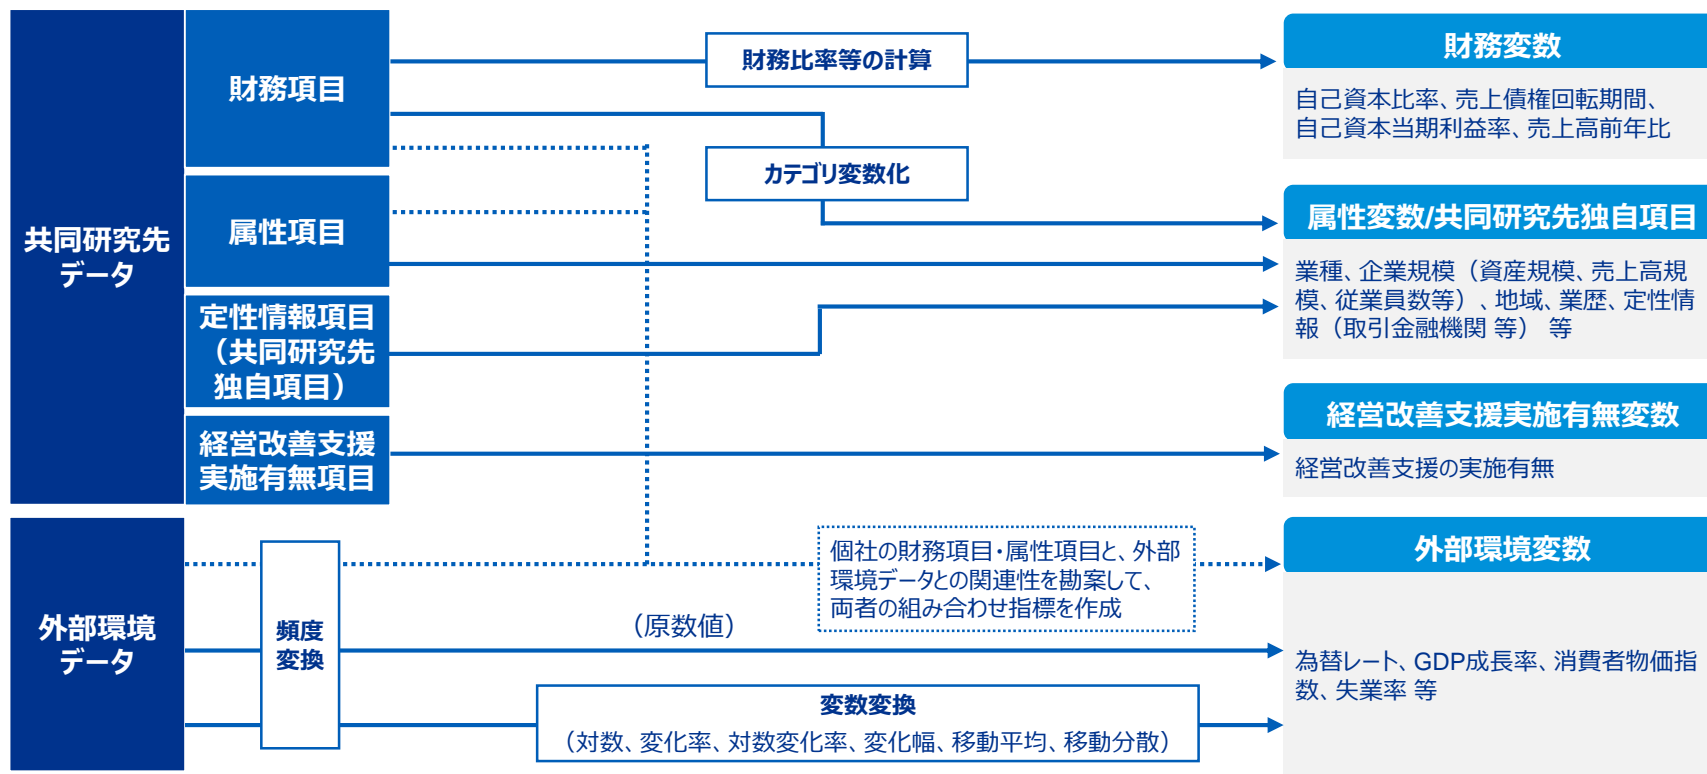
#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル
1	常に「要注意先」	常に「正常先」	正例
2	常に「要注意先」	もっとも悪い区分が「要注意先」	負例
3	常に「要注意先」	もっとも悪い区分が「要管理先」以下	負例

#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル
4	常に「要管理先」	常に「正常先」	正例
5	常に「要管理先」	もっとも悪い区分が「要注意先」	正例
6	常に「要管理先」	もっとも悪い区分が「要管理先」以下	負例
#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル
7	「要注意先」と「要管理先」が混在	常に「正常先」	正例
8	「要注意先」と「要管理先」が混在	もっとも悪い区分が「要注意先」	負例
9	「要注意先」と「要管理先」が混在	もっとも悪い区分が「要管理先」以下	負例

説明変数の作成

– 説明変数作成の全体フロー

- 共同研究先データ、外部環境データを使用して、財務比率等の計算、カテゴリ変数化、変数変換、財務項目・属性項目と外部環境データの組み合わせ指標の作成を行い、「財務変数」、「属性変数」、「経営改善支援実施有無変数」、「外部環境変数」をモデルの説明変数として作成した。
- 具体的な作成フローは、下図の通り。



説明変数の作成

– 財務変数の作成

- 共同研究先データの財務項目同士を組み合わせ、財務比率等を計算し、100以上の財務変数を作成した。
- 作成した財務変数は、「健全性」、「効率性」、「収益性」、「成長性」、「生産性」、「流動性」、「債務償還能力」、「資金繰り」の観点で評価できるものごとに分類を行った。
- 上記のように、分類を行った理由は、以下の通り。
 - 単変量分析における説明変数の1次絞り込みや、モデルの変数選択を、各評価観点を持つ変数にてバランス良く行うため。
 - モデルからの出力UIに表示される財務変数を分類ごとに整理することで、顧客への説明が容易になると思料するため。
- 分類ごとの財務変数の例は以下の通り。

#	分類	財務変数の例
1	健全性	自己資本比率、固定長期適合率 等
2	効率性	売上債権回転期間、棚卸資産回転期間 等
3	収益性	自己資本当期利益率、売上高経常利益率 等
4	成長性	売上高前年比、営業利益前年比 等
5	生産性	従業員一人当たり売上高、売上高付加価値率
6	流動性	当座比率、流動比率 等
7	債務償還能力	インタレストカバレッジレシオ、総債務償還年数 等
8	資金繰り	売上高キャッシュフロー比率、売上高運転資本比率

単変量分析

- 財務変数、属性変数、外部環境変数については、多重共線性の排除、モデル解釈性の向上等を目的として、以下の内容にて説明変数の絞り込みを実施した（欠損率を除いた以下の処理はロジスティック回帰にのみ適用。それ以外のAIアルゴリズムには本件は適用しない）。
 - モデル開発コンセプトごとに、教師ラベルに対して1つの説明変数として構築したロジスティック回帰モデルの欠損率、AR値、推定値のP値、符号条件が、設定した基準を満たす変数を、説明変数とした（属性変数についてはロジスティック回帰モデルは構築せず、欠損率のみを確認）。
 - 財務変数、外部環境変数については、説明変数間の相関係数を確認し、強相関となった変数の対については、一方のみを説明変数候補とした（財務変数については、分類ごとに相関係数の確認）。

【単変量分析で設定した基準】

欠損率

欠損率が多い変数は除外

AR値

単一の変数だけでもある程度の説明力を有するものに限定

P値

単一の変数だけでも統計的な有意性を有するかを判定

符号条件

教師ラベルと変数間の正負の関係性を設定

【相関係数の確認の例（債務償還能力に分類される財務変数間の相関係数）】

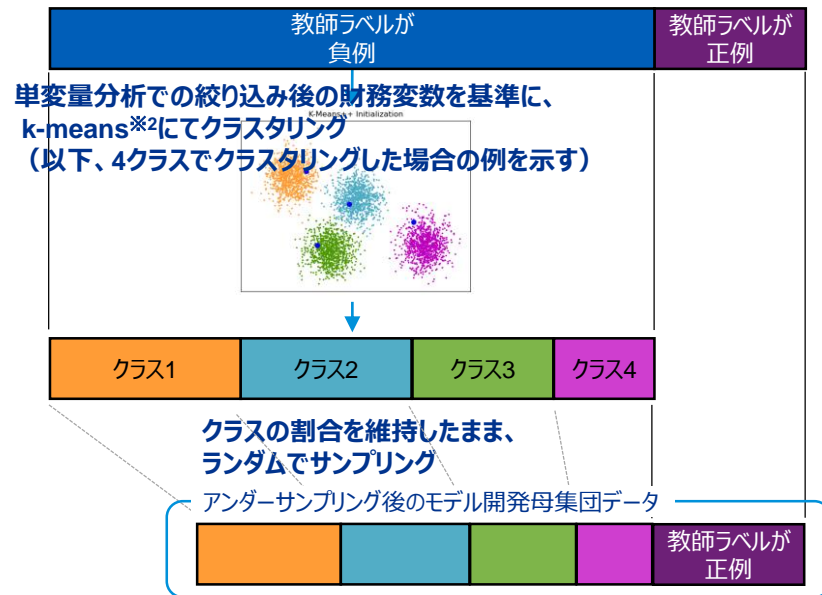
変数名	変数ラベル	相関係数																
IDX074	支払利息割引料総利益率	1.00	0.37	0.56	0.00	0.00	-0.06	-0.06	0.68	0.38	0.97	0.00	0.00	0.00	0.02	0.05	0.06	
IDX075	支払利息割引料営業利益率	0.37	1.00	0.78	0.00	0.01	-0.02	-0.02	0.62	0.98	0.34	0.00	0.00	0.00	0.00	-0.06	-0.07	-0.09
IDX076	支払利息割引料経常利益率	0.56	0.78	1.00	0.00	0.00	-0.03	-0.03	0.82	0.80	0.53	0.00	0.00	0.00	0.00	-0.07	-0.07	-0.09
IDX077	売上高金利負担率	0.00	0.00	0.00	1.00	0.54	0.07	0.05	0.00	0.00	0.12	0.05	-0.01	0.00	0.01	0.00	0.00	0.00
IDX078	売上高純金利負担率	0.00	0.01	0.00	0.54	1.00	0.07	0.09	0.00	0.01	-0.02	0.02	0.01	-0.01	0.00	0.01	0.00	0.00
IDX079	総資産金利負担率	-0.06	-0.02	-0.03	0.07	0.07	1.00	0.96	-0.04	-0.02	-0.06	0.01	0.00	0.00	0.00	-0.05	-0.05	-0.05
IDX080	総資産純金利負担率	-0.06	-0.02	-0.03	0.05	0.09	0.96	1.00	-0.04	-0.02	-0.06	0.01	0.00	0.00	0.00	-0.05	-0.05	-0.05
IDX081	金利カバレッジ	0.68	0.62	0.82	0.00	0.00	-0.04	-0.04	1.00	0.63	0.67	0.00	0.00	0.00	0.00	-0.08	-0.08	-0.08
IDX082	インタレストカバレッジレシオ	0.38	0.98	0.80	0.00	0.01	-0.02	-0.02	0.63	1.00	0.35	0.00	0.00	0.00	0.00	-0.06	-0.07	-0.09
IDX083	支払利息割引料現金預金率	0.97	0.34	0.53	0.00	-0.02	-0.06	-0.06	0.67	0.35	1.00	0.00	0.00	0.00	0.02	0.06	0.07	0.07
IDX084	総支出支払利息割引料率	0.00	0.00	0.00	0.12	0.02	0.01	0.01	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00
IDX085	経費支払利息割引料率	0.00	0.00	0.00	0.05	0.01	0.00	0.00	0.00	0.00	0.00	0.28	1.00	0.00	0.00	0.00	0.00	0.00
IDX086	流動資産引当率	0.00	0.00	0.00	-0.01	-0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.06	0.00	0.00	0.00
IDX087	当座資産引当率	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	1.00	0.00	0.00	0.00
IDX088	債務超過解消年数	0.02	-0.06	-0.07	0.01	0.01	-0.05	-0.05	-0.08	-0.06	0.02	0.00	0.00	0.00	0.00	1.00	0.50	0.37
IDX089	総債務償還年数	0.05	-0.07	-0.07	0.00	0.00	-0.05	-0.05	-0.08	-0.07	0.06	0.00	0.00	0.00	0.00	0.50	1.00	0.66
IDX090	純有利子負債償還年数	0.06	-0.09	-0.09	0.00	0.00	-0.05	-0.05	-0.08	-0.09	0.07	0.00	0.00	0.00	0.00	0.37	0.66	1.00

学習用データとテスト用データの作成

- モデル開発母集団に占める負例の割合と正例の割合が大きく異なるデータ（不均衡データ）をそのまま用いて機械学習モデルを構築すると、見かけ上の精度（正解率：Accuracy）は高いものの、正例を正しく正例と予測する精度（再現率：Recall）が低くなる。そのため、正例のサンプル数に合わせて、不均衡データをアンダーサンプリングし、バランス調整を行った。
- 上記のアンダーサンプリングを実施したデータを、モデル構築を行う学習用データ、モデルのハイパーパラメータの検証を行うパラメータ検証用データ、構築したモデルの精度を確認するテスト用データに分割した※1。
- アンダーサンプリングとデータの分割イメージは下図の通り。

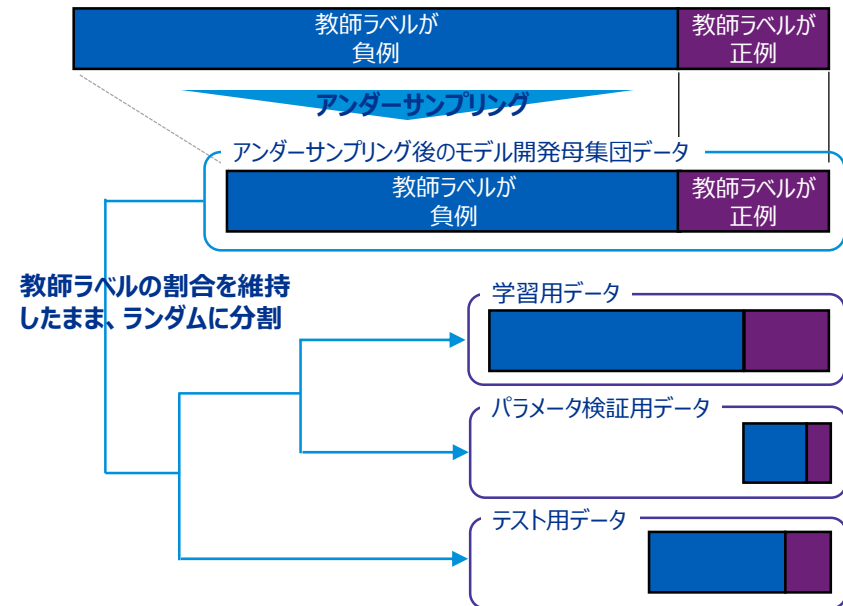
【アンダーサンプリング】

モデル開発母集団すべてのデータ



【データの分割】

モデル開発母集団すべてのデータ

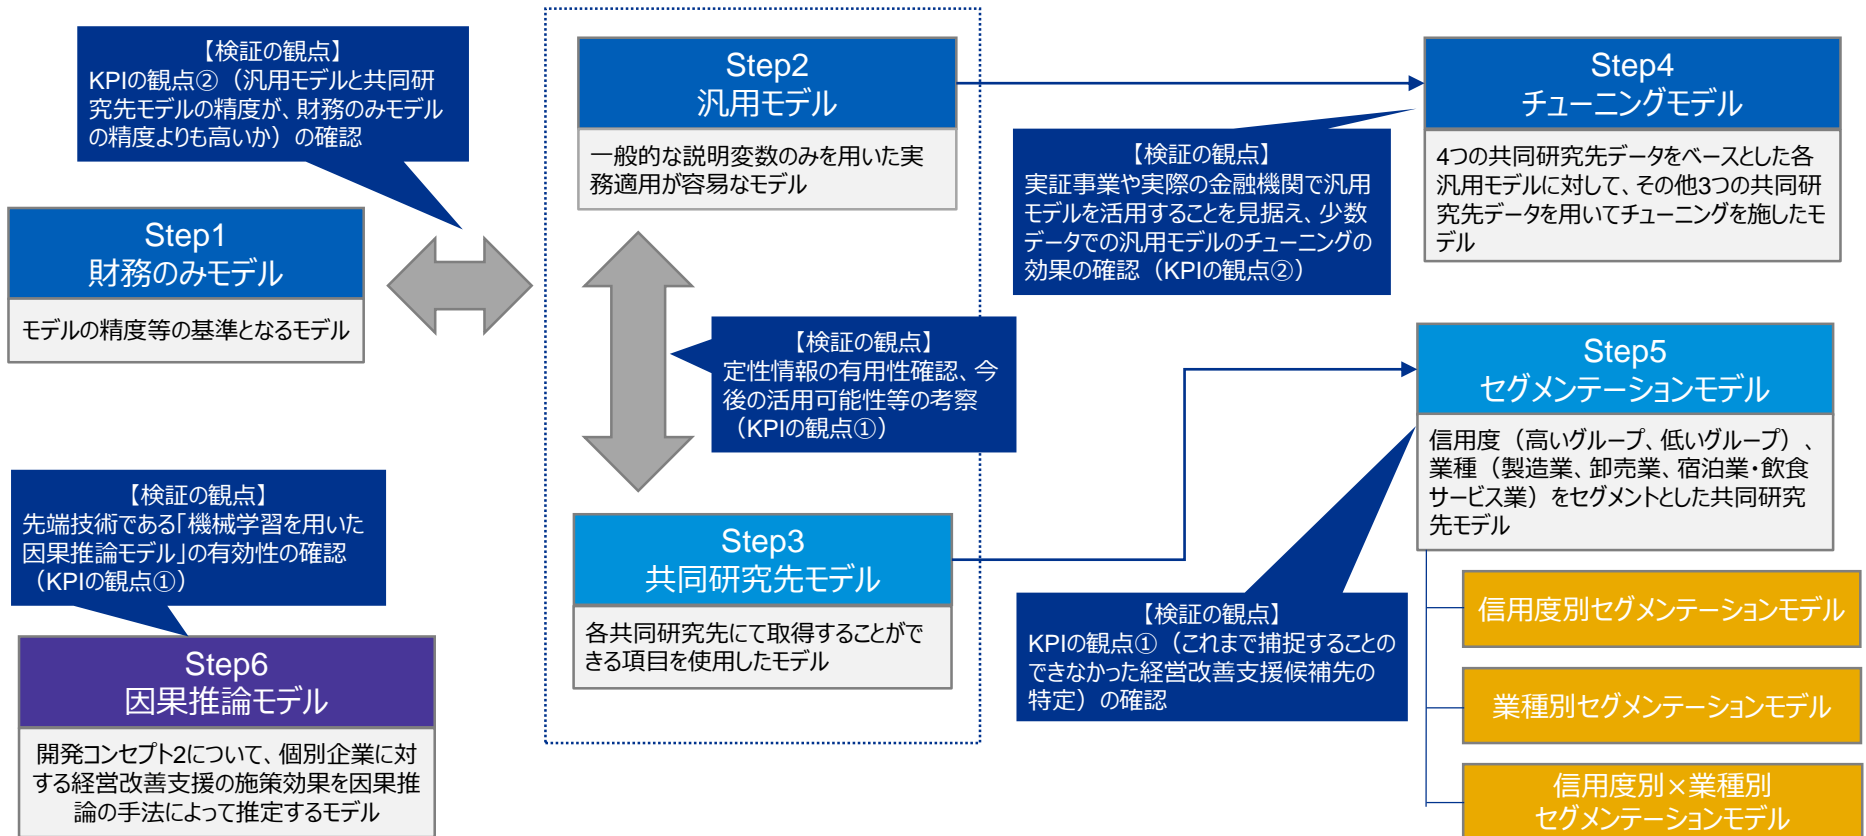


※1 データ分割の考え方は、「モデル構築におけるデータの分割の概説」（本資料 p.106）に記載。

※2 k-meansは、クラスタリング手法の1つで、クラスターの数だけデータの重心を求め、その重心に最も近いデータを当該クラスターに分類されるデータと定める分類アルゴリズム

開発したモデル一覧

■ 本調査・研究で開発したモデルの一覧と、開発したモデルを用いた検証の観点とは下図の通り。Step1からStep6の順にて、モデル開発を行った。



開発したモデル精度一覧

- 開発したモデルの精度一覧は下表の通り。それぞれ、ロジスティック回帰（L）、ランダムフォレスト（R）、勾配ブースティング（G）の順番でAUCを記載している。
- 開発コンセプト1、開発コンセプト2いずれも、平均的には財務のみモデルよりも精度が高い汎用モデル、共同研究先モデルの構築が実現している。また、汎用モデルの精度の最大値が0.8を超えるアルゴリズムもあり、実務に耐え得るモデルとなっていると評価できる。

共同研究先	開発コンセプト1			開発コンセプト2		
	財務のみモデル	汎用モデル (チューニング前)	共同研究先モデル (セグメンテーションなし)	財務のみモデル	汎用モデル	共同研究先モデル
平均値※		L:0.650 R:0.708 G:0.695	L:0.661 R:0.716 G:0.706		L:0.746 R:0.787 G:0.786	L:0.760 R:0.787 G:0.794
最小値※	L:0.654 R:0.657 G:0.670	L:0.519 R:0.671 G:0.590	L:0.519 R:0.671 G:0.590	L:0.790 R:0.799 G:0.803	L:0.676 R:0.696 G:0.707	L:0.688 R:0.712 G:0.725
最大値※		L:0.770 R:0.798 G:0.805	L:0.801 R:0.821 G:0.832		L:0.788 R:0.823 G:0.817	L:0.804 R:0.819 G:0.825

※ Lはロジスティック回帰、Rはランダムフォレスト、Gは勾配ブースティングを意味し、それぞれの数値はモデル精度の評価指標であるAUCを意味する。

※ 汎用モデル、共同研究先モデルについては、4つの共同研究先のモデルの平均値、最小値、最大値を掲載。

AUCの平均値、最小値、最大値が0.7を超えているものについては、**太字**で記載。

汎用モデルのチューニングについて [1/2]

- 実証事業や実際の金融機関にて今回開発したモデルを活用する場合は、汎用モデルをそのまま用いることを想定している。ただし、個別金融機関に汎用モデルをそのまま適用した場合、モデルの精度が十分でなくなる恐れがあるため、各金融機関データを用いて追加的な学習を行い、汎用モデルを調整（チューニング）することで、実務適用に耐え得る精度を達成できるか検証を行った。
- 具体的には共同研究先データを用いて以下の方法にて検証を行った。

【アルゴリズムごとのチューニング方法】

- ロジスティック回帰はファインチューニング、ランダムフォレストと勾配ブースティングについては追加学習を行うことでモデルのチューニングを行う。

アルゴリズム	チューニング方法	説明
ロジスティック回帰	ファインチューニング	チューニングに用いる学習データにもモデルが適応するように、既存のモデルにおける回帰係数の調整を行う。
ランダムフォレスト	追加学習	既存のモデルにおける決定木は変更せずに、チューニングに用いる学習データにもモデルが適応するように、既存のモデルに対してチューニング用データだけで学習した新たな決定木を追加する。
勾配ブースティング		

【チューニングに用いるデータ】

- 実証事業や、実際の金融機関でのモデルのチューニングシーンを想定し、汎用モデル構築時よりも少ないデータにてモデルのチューニングを行った。
- 各共同研究先のモデル開発母集団のデータ数を踏まえ、チューニングに用いるデータは約6,000件とした。

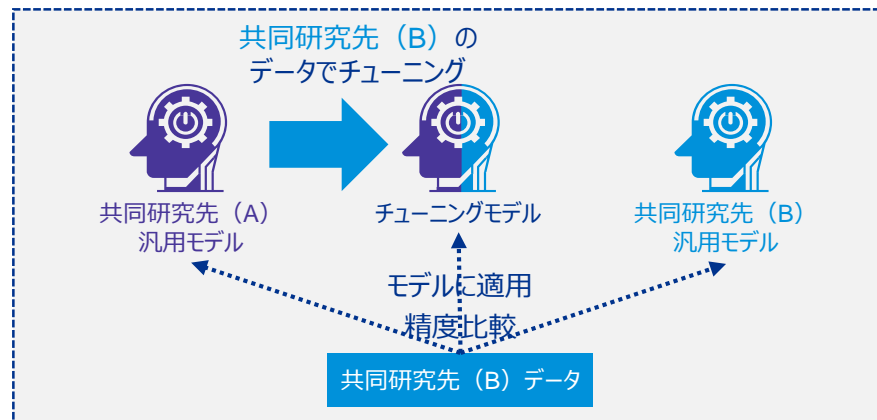
汎用モデルのチューニングについて [2/2]

【チューニングのパターン】

- 4つの共同研究先データをベースとした各汎用モデル（ベースモデル）に対して、以下の2通りのパターンにて、チューニングを行った。
 - パターン①：その他3つの共同研究先のいずれかのデータを用いて、1回のチューニングを行う。
 - パターン②：その他3つの共同研究先それぞれのデータを用いて、3回のチューニングを行う。
- 上記パターン②については、モデルのアルゴリズムの特徴により、ロジスティック回帰と勾配ブースティングは、ファインチューニング・追加学習を行う順番によって構築されるモデルの精度が異なるため、複数の順番にてチューニングを行った。

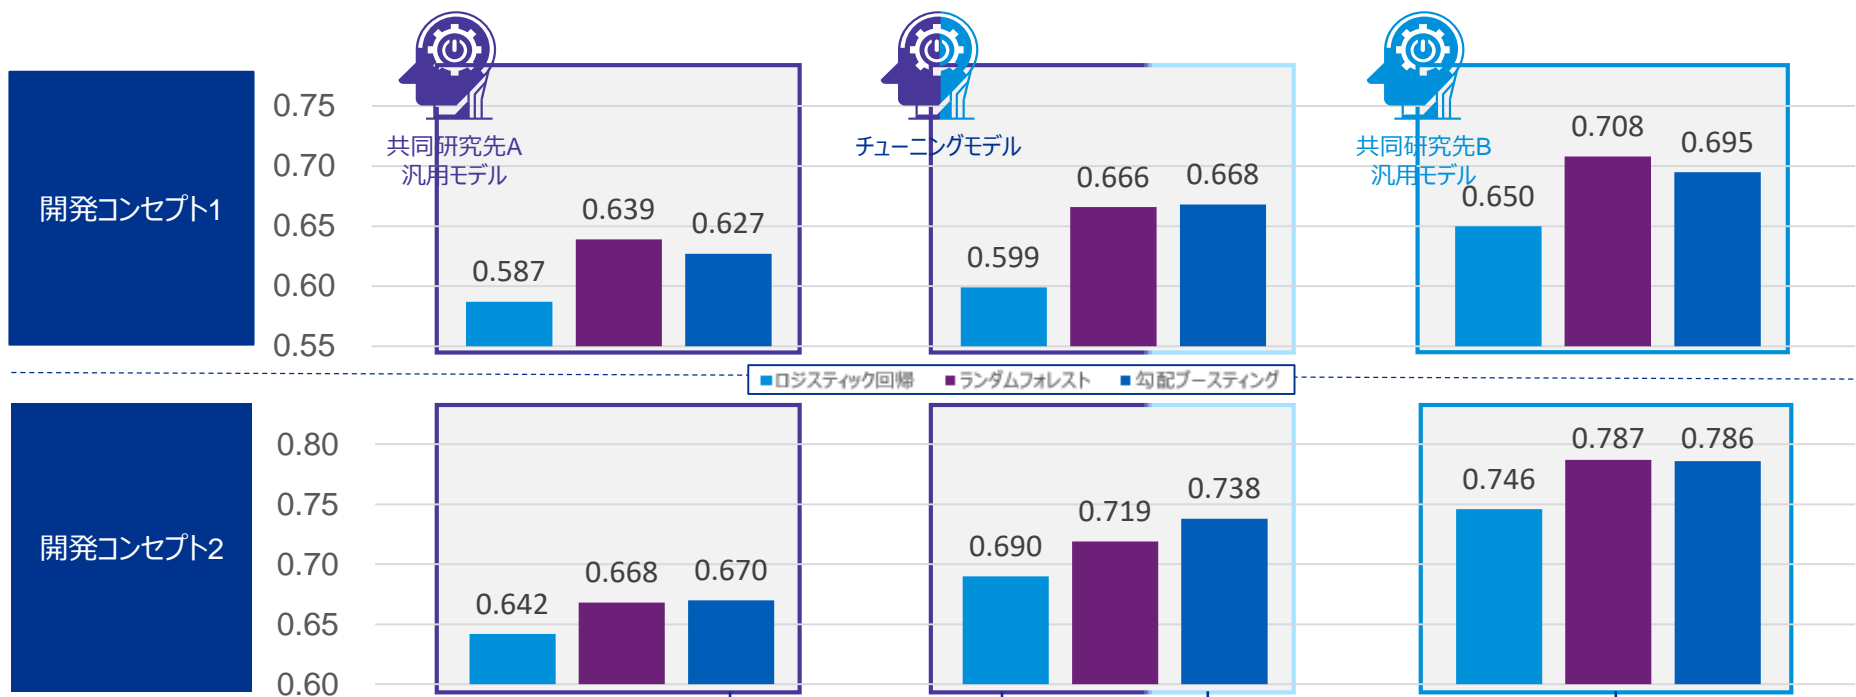
【チューニングしたモデルの精度検証】

- 精度の検証は、「ある共同研究先（A）の汎用モデル」、「ある共同研究先（A）の汎用モデルを別の共同研究先（B）のデータにてチューニングを行ったモデル（チューニングモデル）」、「別の共同研究先（B）の汎用モデル」の3通りのモデルに、共同研究先（B）のデータを適用した場合の精度を比較することで行った。



汎用モデルのチューニング結果

- 汎用モデルをチューニングした場合の精度検証結果は以下の通り。なお、前頁記載のチューニングのパターン②については、異なる共同研究先データで3回チューニングしたことによる精度向上や、チューニングの順番による特徴の変化は得られなかったため、ここでは、パターン①（その他3つの共同研究先のいずれかのデータを用いて、1回のチューニングを行う）の結果について示している。
- チューニングには、約6,000件のデータを用いており、以下の精度はパターン①の全ての組み合わせにて検証した結果のAUC平均値を記載。



チューニングを実施することによって、精度が向上することを確認。

共同研究先Bのデータを十分に活用して構築したモデルよりも、チューニングモデルの精度は劣るものの、精度の差は限定的。大量データを持たない金融機関においても、独自モデルを構築したときと同水準の精度を持つモデルを、汎用モデルのチューニングによって構築ができることが示唆される。

セグメンテーションモデルの構築について

- 共同研究先データを用いたモデル構築の結果、開発コンセプト1については、開発コンセプト2と比較して精度が低水準であったこと、全体の精度を確保することをメインとしつつ、（モデルの使用シーンに合わせて、）個別ケースの精度を確保するため、特定の区分（セグメント）に対して精度が出るモデル（セグメンテーションモデル）の構築を検討。
- セグメントは「信用度（共同研究先によって債務者区分や信用スコアを使用）」と「業種」を用いてモデルの構築を行った。
 - ✓ 信用度については、各共同研究先ごとに、信用度が高いグループと低いグループにてセグメンテーションを行った。
 - ✓ 業種については、下記の内容を踏まえて、製造業、卸売業、宿泊業・飲食サービス業についてセグメンテーションを行った。
 - 開発コンセプト1における特定の共同研究先モデルについて、業種別のテストデータに対する精度を確認すると、製造業、卸売業、宿泊業・飲食サービス業については全体を予測した際と比較して精度が高く、学習データの件数も多いため、セグメンテーションモデルにて精度向上が見込まれることから、これらにてセグメンテーションを行った。
 - なお、製造業、卸売業、宿泊業・飲食サービス業については、コロナの影響を受けた業種・事業者数が多い業種であるため、今回の調査・研究の目的と合致している。
 - ✓ 業種別にセグメンテーションを行う際においては、業種特有の外部環境を考慮することを目的に、下表の通り外部環境データの絞り込みを実施。
 - 例えば、経済関連データについては、業種に関連する外部環境データを使用する、マーケット関連データについては国内のマーケットデータに限定する等の絞り込みを行うこととした。

共通して使用する外部環境データ	製造業に使用する外部環境データ	卸売業に使用する外部環境データ	宿泊業・飲食サービス業に使用する外部環境データ
<ul style="list-style-type: none"> • GDP成長率 • 景気動向指数 • 中小企業売上見通しDI • 発電実績 • エネルギー消費量 • 入港船舶総トン数 • 公共機関からの受注額 	<ul style="list-style-type: none"> • 鉱工業在庫指数 • 鉱工業出荷指数 • 製造工業生産能力指数 • 機械受注額（製造業） • 業況判断指数（製造業） 	<ul style="list-style-type: none"> • 商業販売額 • 第3次産業活動指数 • 貨物輸送量 • 機械受注額（非製造業） • 業況判断指数（非製造業） 	<ul style="list-style-type: none"> • 訪日外客数 • 定員稼働率 • 実宿泊数 • 旅客輸送量 • 第3次産業活動指数 • 機械受注額（非製造業） • 業況判断指数（非製造業）

セグメンテーションモデルの精度一覧

- 開発したセグメンテーションモデルの精度一覧は下表の通り。それぞれ、ロジスティック回帰（L）、ランダムフォレスト（R）、勾配ブースティング（G）の順番でAUCを記載している。

		信用度別セグメンテーション					
		セグメンテーションなし		信用度が高いグループ		信用度が低いグループ	
		平均値※	最大値※	平均値※	最大値※	平均値※	最大値※
業種別セグメンテーション	セグメンテーションなし	共同研究先モデル L:0.708 R:0.730 G:0.745	L:0.801 R:0.821 G:0.832	信用度別セグメンテーションモデル L:0.736 R:0.767 G:0.782	L:0.799 R:0.828 G:0.841	L:0.702 R:0.716 G:0.729	L:0.724 R:0.734 G:0.753
	製造業	業種別セグメンテーションモデル L:0.722 R:0.743 G:0.753	L:0.803 R:0.822 G:0.834	信用度別×業種別セグメンテーションモデル L:0.753 R:0.780 G:0.795	L:0.787 R:0.821 G:0.841	L:0.691 R:0.709 G:0.713	L:0.724 R:0.735 G:0.743
	卸売業	L:0.714 R:0.747 G:0.749	L:0.805 R:0.835 G:0.843	L:0.731 R:0.765 G:0.773	L:0.776 R:0.807 G:0.822	L:0.704 R:0.718 G:0.722	L:0.738 R:0.741 G:0.735
	宿泊業・飲食サービス業	L:0.651 R:0.700 G:0.696	L:0.669 R:0.769 G:0.753	L:0.647 R:0.678 G:0.668	L:0.687 R:0.695 G:0.701	L:0.675 R:0.679 G:0.665	L:0.735 R:0.722 G:0.735

注 セグメンテーションによる効果は、共同研究先モデルとセグメンテーションモデルに対して、各セグメントのデータを当てはめた場合の精度を比較することで確認する必要がある。上表の共同研究先モデルの精度は、共同研究先モデルに対して、セグメンテーションを行わないデータを当てはめた場合のものを表しており、この精度と、各セグメンテーションモデルの精度を単純に比較することは出来ないことに留意。

- ※ 一部の共同研究先については、セグメンテーションによってモデル開発母集団が十分に得られなかったため、3つの共同研究先のモデルの平均値、最大値を掲載。よって、信用度、業種ともにセグメンテーションを行わないモデルで掲載している精度は、p.39の結果と異なる。
AUCの平均値、最大値が0.7を超えているものについては、**太字**で記載。

因果推論モデル構築

– 伝統的な因果推論モデルによる全体的な効果の推定

【前提】

- 伝統的な因果推論モデルで経営改善施策の全体的な効果をベンチマークとして推定後、機械学習を使用した因果推論モデルを利用して個別企業への効果を推定した。（ただし、現時点では経営改善支援先が約50件しかないため、実務に耐えるモデルは作成できないことが想定）
- 共同研究先データで下記の期間に該当する変数を持っている企業のレコードを使用して、経営改善支援を実施することで平均的にどれくらい信用スコアが変化するか推定を行った。



【手法】

- 傾向スコア（経営改善支援が実施される確率）をサンプルの重みとして使用し、経営改善支援を実施したグループの信用スコアの平均と、未実施のグループの信用スコアの平均を計算し、これらの差分をとることで効果を推定する。




- ① 経営改善支援の実施グループと、未実施グループの企業属性（財務状況や属性）は異なり、両グループの単純比較では経営改善支援の効果を正しく推論することができない。そこで、傾向スコア（経営改善支援が実施される確率）を用いて、両グループの企業属性を等しくするように調整を行う。

※ 信用スコアが経営改善支援の実施企業の最大（55.44点）と最小（36.85点）の範囲内に入る企業のみ使用（経営改善支援の非対象企業を除くため）

【結果】

経営改善支援の実施によって、信用スコアが約0.83点上昇する結果となっている。（ただし、計算の余地は残っており、バイアスの排除はまだ完全ではない）

経営改善支援の実施効果（95%信頼区間）



因果推論モデル構築

– 機械学習モデルによる個別企業への効果の推定

【手法】

- 機械学習を利用した因果推論モデルとして、DA-Learner（Domain Adaptation Learner）を利用した。
- DA-Learnerは、Meta-Learnersの一種で、処置群と対象群を別々にモデリングに用い、各群のデータ量が不均衡な場合や各群が持つ変数分布に偏りがあっても有効な手法。


【手法の説明】

- ① 前頁の統計的モデルと同様に傾向スコア（経営改善支援の実施確率）でサンプルの重みづけをする。
- ② 経営改善支援の実施、未実施のグループそれぞれで信用スコアを予測するモデルを作成する。
- ③ このモデルを使用して、経営改善支援先の支援が実施されなかった場合の信用スコアを推定（未実施先も同様）することで、各企業の経営改善支援の実施、未実施の推定された信用スコアを算出する。
- ④ ③で推定された経営改善支援実施と未実施の信用スコアの差を財務変数で予測することで、経営改善支援の効果の推定する。

【結果】

全体の経営改善支援実施効果

経営改善支援実施により、信用スコアが約0.57点上昇する結果となっている。



個社の経営改善支援実施効果の確認


平均的な経営改善支援効果0.569点から、個社要因によって経営改善支援の効果がどれほど異なるかをモデルから確認することができる。

■ ケース

経営改善支援未実施企業であるものの、2017年時点の信用スコア38.51点と信用スコアが低い企業に対する因果推論

■ 因果推論結果

- 経営改善支援実施により、信用スコアが約1.47点上昇すると推定
- 推定の個社要因は右図の通り



プロトタイプAIの開発結果概要

- 設定したKPIについて、評価指標等も活用して確認したところ、以下の通り概ね達成が確認された。

汎用モデルの 開発結果概要

- 一般的な説明変数のみを用いた場合でも、財務のみモデルよりも高い精度を有し、概ね実務適用可能な水準の標準的なモデル構築を実現
- 少数データで追加的に学習（ファインチューニング・追加学習等）させた結果、精度が高まるケースが確認できる等、少数データしか持たない金融機関における汎用モデルの活用方法を確認

共同研究先 モデルの 開発結果概要

- 一般的な説明変数に加えて、定性情報等の追加情報を活用することで、汎用モデルより高い精度が実現
また、業種別や信用度別にセグメンテーションモデルを構築することでさらに高い精度を実現する等、使用シーンに合わせた活用の可能性を確認

因果推論 モデルの 開発結果概要

- 先端技術である「機械学習を用いた因果推論モデル」についても試行し、個別企業に対する因果効果（経営改善支援による業績の向上）の推定が可能であることを確認
（本調査ではサンプルが少なかつたため、統計的な有意性は得られていない）
- 金融機関の実証事業にて本手法の有効性を再度確認

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出と
AI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 金融機関等向けワークショップ

6 本調査・研究の今後の課題

7 添付資料

AIからの出力結果イメージとその活用

– Step1 経営改善支援先の早期発見・優先順位付け

- 実用化した際の、AIモデルの解釈性や説明力の向上のため、AIモデルからの出力結果についても検討を行った。
- 多数の取引先を抱える担当者の業務効率化のために、モデルを活用して、業績悪化の可能性が高い先のリストを抽出（抽出企業数は、閾値を変えることで調整可能）する機能を検討した。
- リストを活用することで、担当者が認識していないが、経営改善支援の必要性が高いと考えられる先を特定し、訪問の優先順位付けを行うことが可能となる。

（例）地域や業種での絞り込みや並び替え機能を搭載し、優先順位をつける際の検討に活用

（例）業況に問題がない先と認識していたが、スコアが低いので詳細に調査を実施

（例）経営改善支援スコアはそこまで低くないが、原油価格上昇の影響を受けやすいので、優先的な訪問を検討

NO	企業名	地域	業種	経営改善支援スコア (1年以内の業績悪化可能性)	シミュレーション1 (例：原油価格が●%上昇)	シミュレーション2 (例：為替レートが●%円安)
1	●●工業(株)	●●県○○市	製造業	9	25	15
2	(株) △△食品	●●県○○市	製造業	18	30	28
3	(有) ■■工芸	●●県△△市	製造業	21	26	28
4	(株) ○○商店	●●県△△市	小売業	25	28	26
5	▲▲荘(株)	●●県□□市	宿泊業	31	38	25
6	□□建設(株)	●●県□□市	建設業	42	18	35

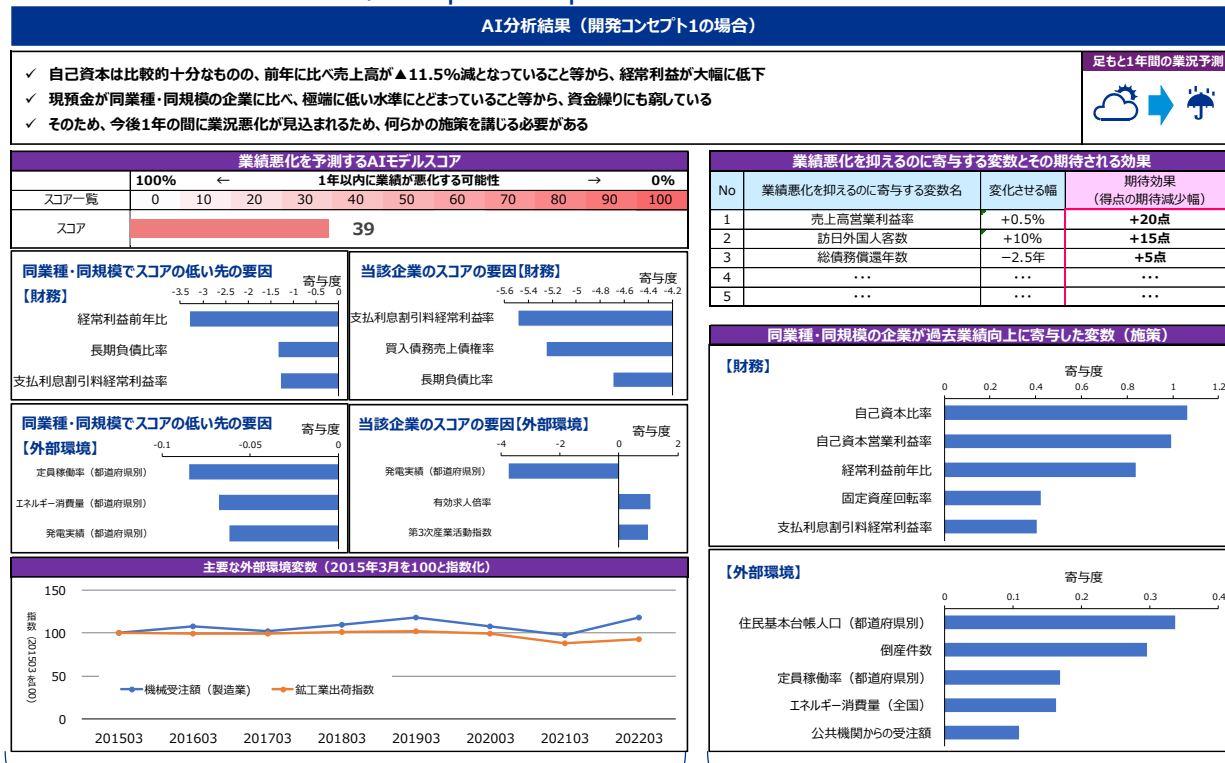
(※) 企業名やスコアをクリックすることで、「企業概要（金融機関保有データ）」や「経営改善スコア」の詳細を把握可能

リストを活用し、訪問の優先順位付けを実施

AIからの出力結果イメージとその活用

– Step2 経営改善支援先への対応策の検討 [1/3]

- 業績悪化を予測するスコアについて、財務・外部環境別に要因を算出。同業種・同規模の企業と比べて、スコアが悪い要因がどこにあるのか等の分析を行うことができる機能を検討した。
- 当該機能と外部環境シミュレーション（参考1、本報告書 p.54）や財務分析（参考2、本報告書 p.55）と組み合わせることで、足元の業況変化等も踏まえた対応の検討も可能となる。
- 具体的な活用イメージは本報告書p.51及びp.52を参照。



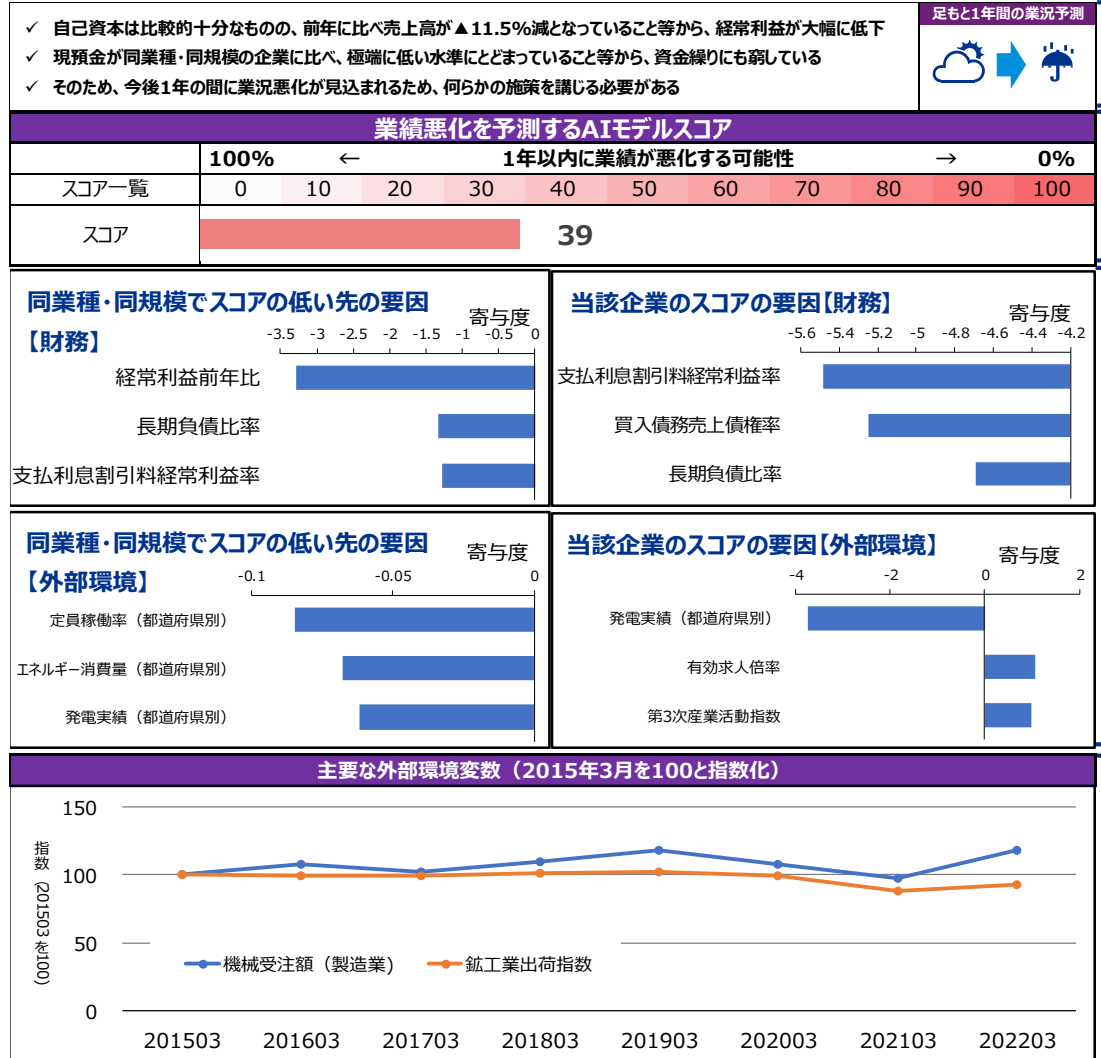
**業績悪化を抑えるために
寄与する指標を把握し、
対応策を検討**

詳細を本報告書 p.51に記載

詳細を本報告書 p.52に記載

AIからの出力結果イメージとその活用

– Step2 経営改善支援先への対応策の検討 [2/3]



- 金融機関の若手職員でも理解できるよう、冒頭に業況サマリーをコメントと業況天気図により表現
- 業況サマリーのコメントは現状人間により作成する必要があるものの、AIが数値情報からテキストを自動生成する技術は存在することから、今後こうしたAI技術の活用を検討

- 企業の属性情報（業種や規模等）、財務データ、外部環境データから、AIモデルスコアを算出する。
- AIモデルスコアは、開発コンセプトごとに以下を表すものである。
 - 開発コンセプト1：1年以内に業績が悪化する可能性の低さ
 - 開発コンセプト2：1年以内に経営改善支援により業績が向上する可能性の高さ

- AIモデルスコアに寄与した要因を、財務、外部環境別に算出。
- 寄与度が正の指標はAIスコアを上昇、負の指標はAIスコアを低下させていることを表す。（例：総債務償還年数の寄与度が1.5の場合、当該要因によってAIモデルスコアが1.5上昇することを表す。）
- 同業種・同規模の企業と比べて、スコアが悪い要因がどこにあるのか等の分析が可能。

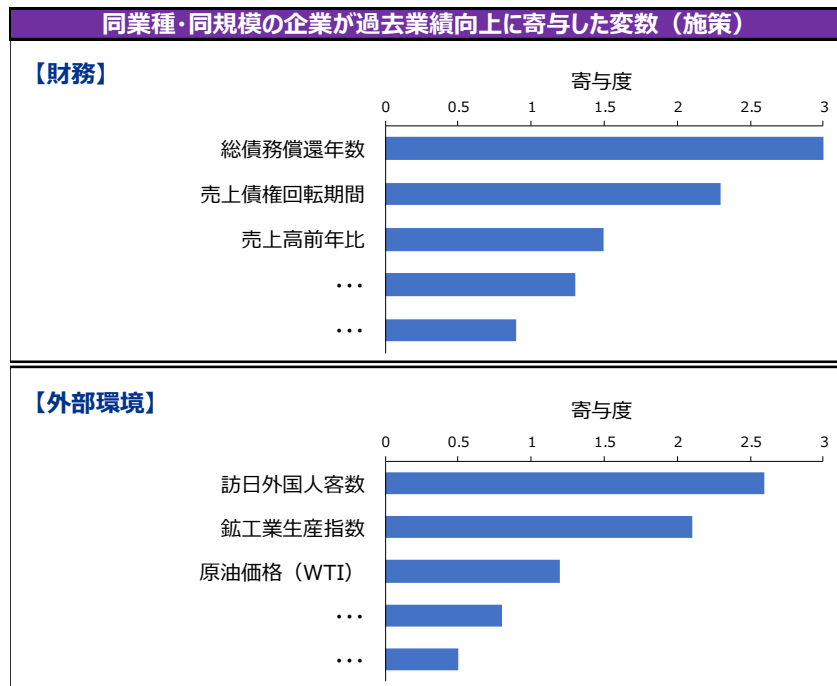
- 分析対象企業の業種に関する主要な外部環境変数のトレンドを確認し、当該企業の業界が置かれている外部要因の把握を行う。
- さらに外部環境シミュレーションを含めた事業者との対話に活用する。

AIからの出力結果イメージとその活用

– Step2 経営改善支援先への対応策の検討 [3/3]

業績悪化を抑えるのに寄与する変数とその期待される効果			
No	業績悪化を抑えるのに寄与する変数名	変化させる幅	期待効果 (得点の期待減少幅)
1	売上高営業利益率	+0.5%	+20点
2	訪日外国人客数	+10%	+15点
3	総債務償還年数	-2.5年	+5点
4
5

- 財務変数、外部環境変数のうち、AIモデルスコアを大きく向上させる変数を、向上させるために必要な変化の幅と共に算出。
- ここで示されるものは、モデルのスコア算出における理論値であるため、モデル外部環境シミュレーション（参考1）や財務分析（参考2）と組み合わせるなど、分析企業の実態に合わせて活用する。



- 開発コンセプト2のモデルで別途算定される情報
- 本情報を参考に、当該企業の業績向上のヒントを獲得するためのもの
- 具体的には、財務状況のどの指標（例：効率性や債務償還能力）が改善されると、業績向上の可能性が上がるか、また外部環境にどのような変化（例：訪日外国人客数の回復）が起きると、業績向上の可能性が上がるかが分かる。
- この情報から今は業績悪化の可能性が高い企業に対し、本当に悪化する前にどのような支援をすればよいかを検討する基礎資料になる。

AIからの出力結果イメージとその活用

– Step3 企業訪問・経営改善支援の実施

- 事業者との対話を実施するための、外部説明用の分析結果を出力する帳票を検討した。
- これらを活用することで、事業者との目線合わせを行うとともに、経営改善に向けた対応策が検討可能となる。

事業者説明用の帳票（イメージ）

AIを活用した今後の業況予測とポイント

〇〇工業株式会社 令和●年●月●日

■今後の業況（AIによる業況予測）

今後の業況の見通し	
外部環境変化の影響 (原油価格が10%高騰)	

<コメント（例）>

- AIに基づく予測では、今後の業況の見通しは曇。
- 財務指標としては、売上高、営業利益率、支払利息に悪化の兆候がある。
- 外部指標としては、原油価格、為替レート、鉱工業指数の影響を受けやすいので、その動向には注視が必要。
- 例えば、原油価格が10%高騰した場合、財務指標はより悪化（曇から雨）する可能性が高い。

■主な財務指標のポイント

売上高	(例) 売上高の変動が今後の業況に大きく影響を与える。例えば、現状よりも売上高が●千円向上すれば、業況の改善が見込まれる（悪化可能性が大きく低下する）。
営業利益率	...
支払利息	...

■主な外部指標のポイント

原油価格	(例) 原油価格の変動が今後の業況に大きく影響を与える。例えば、原油価格が●%上昇した場合、業績が●pt程度悪化する可能性がある。
為替レート	...
鉱工業指数	...

■memo

事業者説明用の帳票
を用いて、対話を実施、
改善策を検討

AIからの出力結果イメージとその活用


－（参考1）外部環境変化シミュレーション

- モデルで算定された業績悪化を予測するスコアが、外部環境指標を変化させたときに、どのように変化するかシミュレーションが可能となる機能を検討した。
- 外部環境の変化はユーザーが任意で指定できるため、足元の原油高騰やコロナによるインバウンドの減少など、足元の状況を反映させた分析・対応策の検討が可能となる。

シミュレーション結果

ユーザーが任意に指定（AIでは予測できない）

外部環境（2015年3月を100とした指数）			
	ベースシナリオ	シナリオ1	シナリオ2
宿泊定員稼働率	49.7	32.1	89.3
訪日外国人客数	12.7	4.3	25.9
〇〇〇	〇〇		
〇〇〇	〇〇		



AIスコアの算出に使用された外部環境指標の値（ベースシナリオ）に対して、変化させた任意の値を入力する。

左にて入力した外部環境指標の値にてシミュレーションを行ったAIスコアが表示される。

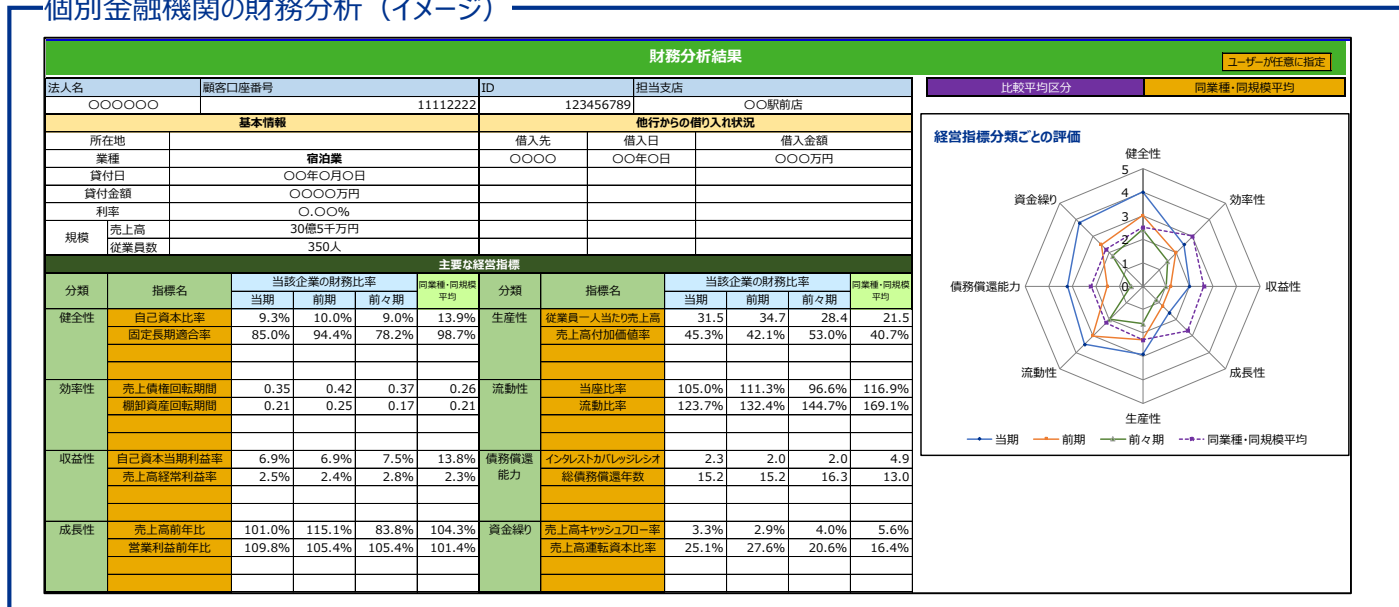
シミュレーションを踏まえた支援の方向性の検討等に活用

AIからの出力結果イメージとその活用

－（参考2）財務分析等との連携

- AIモデルの算出結果と各金融機関で用いている財務分析を組み合わせることの有効性について検討した。
- これにより、深い分析や顧客との対話に活用することが可能となる。


個別金融機関の財務分析（イメージ）



算出結果を組み合わせることで、
更なる検討が可能



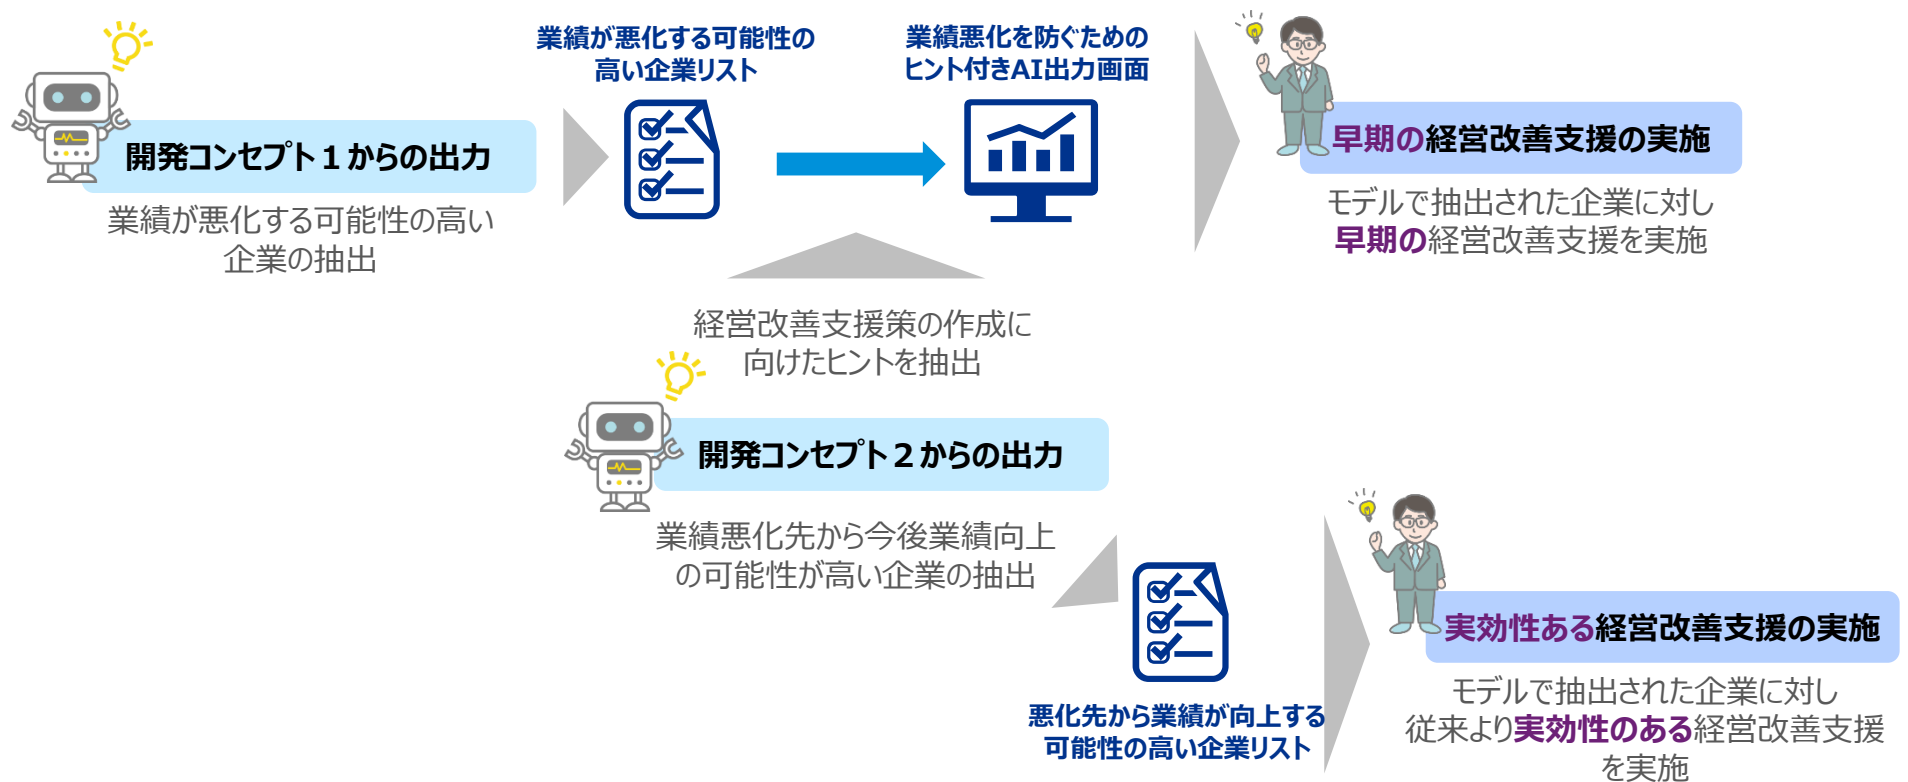
AIからの出力結果



（補足） AIモデルからの出力情報の業務利用方法（案）

– 2つのAIモデルの活用イメージ

- 開発コンセプト1と2の2つのAIモデルの具体的な活用イメージは以下の通り。
- 2つのAIモデルを連携させることで、経営改善支援の効率化・高度化を目指す。



1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出とAI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 金融機関等向けワークショップ

6 本調査・研究の今後の課題

7 添付資料

実証事業の概要

- 本調査・研究では、財務データや外部環境データ等を用いて経営改善支援先を早期発見するAIモデルの開発を行った。この**モデルをより実効性の高いものとする**ため、金融機関の実データを用いて以下について検証を行った。
 - ① 開発したAIモデルが金融機関の実データにおいても有効に機能するかの検証
 - ② 金融機関の実データを活用したモデルの個別カスタマイズ・高度化可能性の検証
- 実証事業先：横浜銀行、栃木銀行、浜松いわた信用金庫、大東京信用組合
- 具体的な実施内容は下表の通り。

検証内容	詳細
① 開発したAIモデルの有効性の検証	■ 汎用モデルの精度検証（AUC、適合率と再現率等）
	■ 汎用モデルの解釈性の確認（予測結果に寄与した変数）
	■ チューニングモデルの精度検証（モデルの精度検証（AUC）） ✓ 各金融機関のデータの一部を用いて汎用モデルを追加学習（チューニング）した際の精度を検証
	■ 実証事業先モデルの精度検証（モデルの精度検証（AUC）） ✓ 各金融機関の全データを用いて汎用モデルを再学習した際の精度を検証
② AIモデルの個別カスタマイズ・高度化可能性の検証	<ul style="list-style-type: none"> ■ 実際の金融機関データにしか存在しない教師データ・説明変数を用いたAIモデル開発 ✓ 企業に関するテキストデータを用いて構築したモデルの有効性を検証 ✓ 経営改善支援の実績データを用いて構築したモデルの有効性を検証 ■ 金融機関におけるAIモデルの個別カスタマイズ内容や高度化内容に係る整理

実証事業にて検証したモデルの概要

– 検証内容①

- 本実証事業のうち、①開発したAIモデルの有効性の検証では、本調査・研究にて構築した汎用モデルのほか、実証事業先データを使用して新たに実証事業先モデルを構築した。各モデルの概要と目的は下表の通り。

種類	アルゴリズム	モデルの概要	実証事業における目的
汎用モデル		<ul style="list-style-type: none"> ■ 共同研究先のデータを使用し、一般的な説明変数のみを用いて構築したモデル ■ 新たに学習を行う必要がないため、実務適用が容易 	<ul style="list-style-type: none"> ➢ モデルの精度検証（AUC、適合率と再現率等） ➢ モデルの解釈性の確認（スコアの寄与度の解釈性など）
チューニングモデル	<ul style="list-style-type: none"> ■ ロジスティック回帰 ■ ランダムフォレスト ■ 勾配ブースティング 	<ul style="list-style-type: none"> ■ 実証事業先データの一部を用いて追加的な学習を行い、汎用モデルを調整（チューニング）して構築したモデル ■ 使用する説明変数は、汎用モデルと同じ 	<ul style="list-style-type: none"> ➢ 汎用モデルとの精度比較（AUC） ➢ （汎用モデルの精度が低い場合）少数データでのチューニングの有効性の検証
実証事業先モデル		<ul style="list-style-type: none"> ■ 実証事業先データのみを用いて構築したモデル ■ 使用する説明変数は、汎用モデルと同じ 	<ul style="list-style-type: none"> ➢ 汎用モデルとの精度比較（AUC） ➢ （汎用モデルの精度が低い場合）実証事業先モデル構築の意義の確認

実証事業先データを適用した場合のモデル精度概要

– 検証内容①

- 4つの実証事業先データを用いたモデル精度一覧は下表の通り。
- 開発コンセプト1及び開発コンセプト2において、汎用モデル・チューニングモデル・実証事業先モデルともに概ねAUCが0.7となっており、実際の金融機関データを用いても本アプローチは有効であることが立証された。
- チューニングモデルや実証事業先モデルの精度は概ね汎用モデルより高くなっており、各金融機関がモデルを活用する際は実証事業先データを一部用いたチューニング又は、データ全量を用いた再学習を行うと、より業務効率化等に資するモデルとしての実務適用が可能となることが示唆された。

実証事業先	開発コンセプト1			開発コンセプト2		
	汎用モデル	チューニングモデル	実証事業先モデル	汎用モデル	チューニングモデル	実証事業先モデル
平均値※	L: 0.627 R: 0.644 G: 0.662	L: 0.621 R: 0.684 G: 0.696	L: 0.662 R: 0.716 G: 0.706	L: 0.736 R: 0.736 G: 0.743	L: 0.747 R: 0.744 G: 0.743	L: 0.689 R: 0.731 G: 0.738
最大値※	L: 0.665 R: 0.697 G: 0.710	L: 0.689 R: 0.703 G: 0.707	L: 0.692 R: 0.758 G: 0.759	L: 0.795 R: 0.809 G: 0.802	L: 0.820 R: 0.842 G: 0.860	L: 0.845 R: 0.860 G: 0.868

※ Lはロジスティック回帰、Rはランダムフォレスト、Gは勾配ブースティングを意味し、それぞれの数値はモデル精度の評価指標であるAUCを意味する。

※ 汎用モデル、チューニングモデルについては、それぞれの実証事業先データで最も精度の高かったモデルの平均値、最大値を掲載。

実証事業先モデルについては、4つの実証事業先での平均値、最大値を掲載。

AUCの平均値、最大値が0.7を超えているものについては、**太字**で記載。

実証事業にて検証したモデルの概要

– 検証内容②

- 本実証事業のうち、②AIモデルの個別カスタマイズ・高度化可能性の検証では、実証事業先データを用いて、新たに高度化検証モデルと因果推論モデルを構築した。各モデルの概要と目的は下表の通り。

種類	アルゴリズム	モデルの概要	実証事業における目的
高度化検証モデル	勾配ブースティング	<ul style="list-style-type: none"> ■ 実証事業先モデルに、テキストデータの情報を説明変数として加えて構築したモデル 	<ul style="list-style-type: none"> ➢ テキストデータを用いたモデルの有効性の検証
因果推論モデル	<ul style="list-style-type: none"> ■ 逆確率重み付き推定 ■ Meta-Learners (DA-Learner) 	<ul style="list-style-type: none"> ■ 経営改善支援を行った際の業績改善効果等を測定するため、経営改善支援の実施有無に関する情報を活用して、因果推論（原因と結果を統計的手法等により推論するモデル）の手法により構築したモデル 	<ul style="list-style-type: none"> ➢ 経営改善支援の実績データを用いたモデルの有効性の検証 ➢ 経営改善支援に有効な変数の確認

テキストデータを用いたモデルの有効性検証 [1/2]

- 金融に特化させた大規模言語モデル（下部参照）を活用して、ポジティブスコア（業績にプラスに寄与するスコア）とネガティブスコア（業績にマイナスに寄与するスコア）をテキストデータの各項目※ごとに付与し、当該スコアを実証事業先モデルの説明変数に加えて高度化検証モデル（テキストデータ追加モデル）を構築した。
※ 今後の業況見通しなどの数項目
- 高度化検証モデルのAUCは下表の通り。テキストデータを含まない実証事業先モデルと比べ、精度としてはほぼ同水準であった。

アルゴリズム	開発コンセプト1		開発コンセプト2	
	高度化検証モデル (テキストデータを含む)	実証事業先モデル (テキストデータを含まない)	高度化検証モデル (テキストデータを含む)	実証事業先モデル (テキストデータを含まない)
ロジスティック回帰	0.690	0.679	0.703	0.680
ランダムフォレスト	0.726	0.723	0.717	0.710
勾配ブースティング	0.736	0.726	0.719	0.711

【大規模言語モデルについて】

- 大規模言語モデルとは、文章分類、文章生成や機械翻訳などの自然言語処理タスクの実行を目的に、従来のAIモデルと比較して大規模なテキストデータを事前に学習して構築されたモデルをいう。今回の分析では、BERT（Bidirectional Encoder Representations from Transformers）と呼ばれる大規模言語モデルの中でも、高い精度を持つことが知られるモデルを活用。
- 今回は、あずさ監査法人が独自に蓄積・収集した金融に関する文書（テキストデータ）を追加的に学習させて、テキストに対するポジティブな内容（「好調」や「売上増加」）やネガティブな内容（「赤字」や「売上減少」）に基づき精度の高いスコアを付与できるように修正したモデルを使用し、分析を行っている。

テキストデータを用いたモデルの有効性検証 [2/2]

- 高度化検証モデルについて、テキストデータ変数の重要度（順位、モデルの説明変数は全315変数）は下表の通り。
- 最上位に該当するテキスト項目も存在しており、今後データの整備（変数化等）を工夫することで、モデルの精度や解釈性において効果的な変数となり得るものと思料。

テキスト項目	開発コンセプト1		開発コンセプト2	
	ポジティブスコア	ネガティブスコア	ポジティブスコア	ネガティブスコア
当該企業の現況、今後の業績見通し、問題点等	70位～6位	61位～9位	22位～1位	19位～3位

【テキストデータの活用がもたらす効果（将来的な発展可能性も含む）】

- 元々の実証事業先モデルの精度が高かったため、テキストデータを追加したことによる精度向上は限定的であったが、それぞれの変数の重要度は高く、今回の試行により、以下の効果（発展可能性含）が得られた
 - ① モデル精緻化
 - ・ テキストデータの整備等を工夫することで実現する可能性
 - ② モデルの解釈性の向上
 - ・ AIスコアの高低の要因につながるコメントを特定することで、経営改善支援につながるヒントが獲得できる可能性
 - ・ AIスコアの高低の理由を説明する文書（コメント）を自動生成するAIを開発することで、解釈性の向上・業務効率化が図られる可能性
- 金融機関にとって、テキストデータに対するAI活用は将来的に発展可能性の高い分野であるため、当該分野の研究開発は重要となる

経営改善支援の実績データを用いたモデルの有効性検証 [1/4]

- 経営改善支援を行った際の業績改善効果等を測定（①経営改善支援の介入効果の検証、②経営改善支援の介入効果へ寄与する変数の確認）するため、経営改善支援の実施有無に関する情報を活用して、因果推論（原因と結果を統計的手法等により推論するモデル）の手法によりモデルを構築した。
- 具体的な方法は以下の通り。

①経営改善支援の介入効果の検証

1. 伝統的な因果推論モデル（逆確率重み付き推定）にて、経営改善支援の全体的な介入効果を推定
2. 機械学習を使用した因果推論モデル（DA-Learner）にて、個別企業への経営改善支援の介入効果を推定し、その平均から全体的な介入効果を推定
 - 機械学習を使用した因果推論モデルは先進的な取組みのため、経営改善支援の全体的な介入効果が伝統的な因果推論モデルと整合的であるかを確認すべく、上記2つの手法を使用する。
 - 経営改善支援の効果は経営改善支援を実施することで平均的にどの程度、信用スコアに変動があるか推定することで行う。なお、信用スコアとは企業の信用度を100点満点で評価したものである。

②経営改善支援の介入効果へ寄与する変数の確認

- 機械学習を使用した因果推論モデル（DA-Learner）にて、説明変数の寄与度を個社ごとに算出し、その平均から全体の経営改善支援の介入効果に寄与した変数を確認
- あわせて実際に経営改善支援を実施した企業を1社選択し、以下を確認する。
 - 個社企業への経営改善支援の介入効果に寄与する変数を確認
 - どのような企業への経営改善支援が有効であるかの確認

経営改善支援の実績データを用いたモデルの有効性検証 [2/4]


– 経営改善支援の効果検証結果

- 以下2点から、経営改善支援による介入効果がプラスであること（信用スコアの上昇）が確認できた。
 - 伝統的な因果推論モデル（逆確率重み付き推定）と、機械学習を使用した因果推論モデル（DA-Learner）のいずれも、経営改善支援を実施することによって、信用スコアが上昇した。
 - いずれの手法においてもその95%信頼区間が正の区間を示しており、統計的な有意性を得ることができた。

① 経営支援改善の介入効果の検証結果

【伝統的な因果推論モデル（逆確率重み付き推定）】

- 経営改善支援の実施によって、信用スコアが約3.10点上昇する結果となっている。



【機械学習を使用した因果推論モデル（DA-Learner）】

- 経営改善支援の実施によって、信用スコアが約2.55点上昇する結果となっている。




経営改善支援の実績データを用いたモデルの有効性検証 [3/4]

– 経営改善支援を実施した場合の介入効果の予測値への寄与度の高い変数

②経営改善支援を実施した場合の介入効果の予測値への寄与度の高い変数の確認結果[1/2]

【全体の経営改善支援を実施した場合の介入効果の予測値（＝信用スコアの改善期待値）に寄与する変数】

■ 各変数右端の値は、各変数の介入効果の予測値への寄与度を示した全体結果の平均値（絶対値ベース）



■ 左表の上位に位置する変数ほど経営改善支援を実施した場合の介入効果の予測値へ与える寄与度が大きい。

※左図の値は寄与度の大きい変数を示すため、絶対値で記載。そのため、介入効果の予測値へプラスに寄与（＝信用スコアの予測値を上昇させる）を及ぼすものばかりではない。

■ デット・エクイティ・レシオがもっとも寄与度が高く、次いで収益性（自己資本総利益率や従業員一人当たり売上高）や手元流動性（当座レシオやクイックレシオ）が寄与していることが分かる。

経営改善支援の実績データを用いたモデルの有効性検証 [4/4]

– 経営改善支援を実施した場合の介入効果の予測値への寄与度の高い変数


② 経営改善支援を実施した場合の介入効果の予測値への寄与度の高い変数の確認結果[2/2]

【個社企業へ経営改善支援を実施した場合の各変数の介入効果の予測値（＝信用スコアの改善期待値）への寄与度を確認】

■ 下図における正の値をとる変数は、経営改善支援を実施した場合の介入効果の予測値にプラスに寄与し、負の値をとる変数は、経営改善支援を実施した場合の効果の予測値にマイナスに寄与していることを示す。各絶対値が大きい変数の順に上から並べている。

※各変数の左側の値は当該個社の経営改善支援を実施前の実績値

$f(x) = 3.331$ (= 当該個社へ支援を実施した場合の介入効果の改善期待値)



＜左記企業の例＞

- 支援前債務者区分：要注意先
- 支援後債務者区分：正常先
- 分析から得られる示唆
 - 当該個社は因果推論モデルによると、経営改善支援による介入効果はあると予測されている。
 - 左図記載の支援実施前の実績値を踏まえ、借入過多に陥っている企業と推定され、DELレシオや負債比率が介入効果の予測値へプラスに寄与。
 - 事実として、当該企業は経営改善支援を受けることにより、上記の通り債務者区分が上方遷移。
 - 以上を踏まえると、資金繰り表の策定や経営改善計画策定支援等の支援の結果、事業者の資金調達構成が見直され、経営改善が果たされたのではないかとこのようなストーリーが推測可能。

変数ごとの値は、平均的な介入効果である「信用スコア+約2.55（P65の結果）」を基準として、各変数の値がどの程度プラス（マイナス）側へ信用スコアの変動に影響したかを意味する

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出と
AI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 **金融機関等向けワークショップ**

6 本調査・研究の今後の課題

7 添付資料

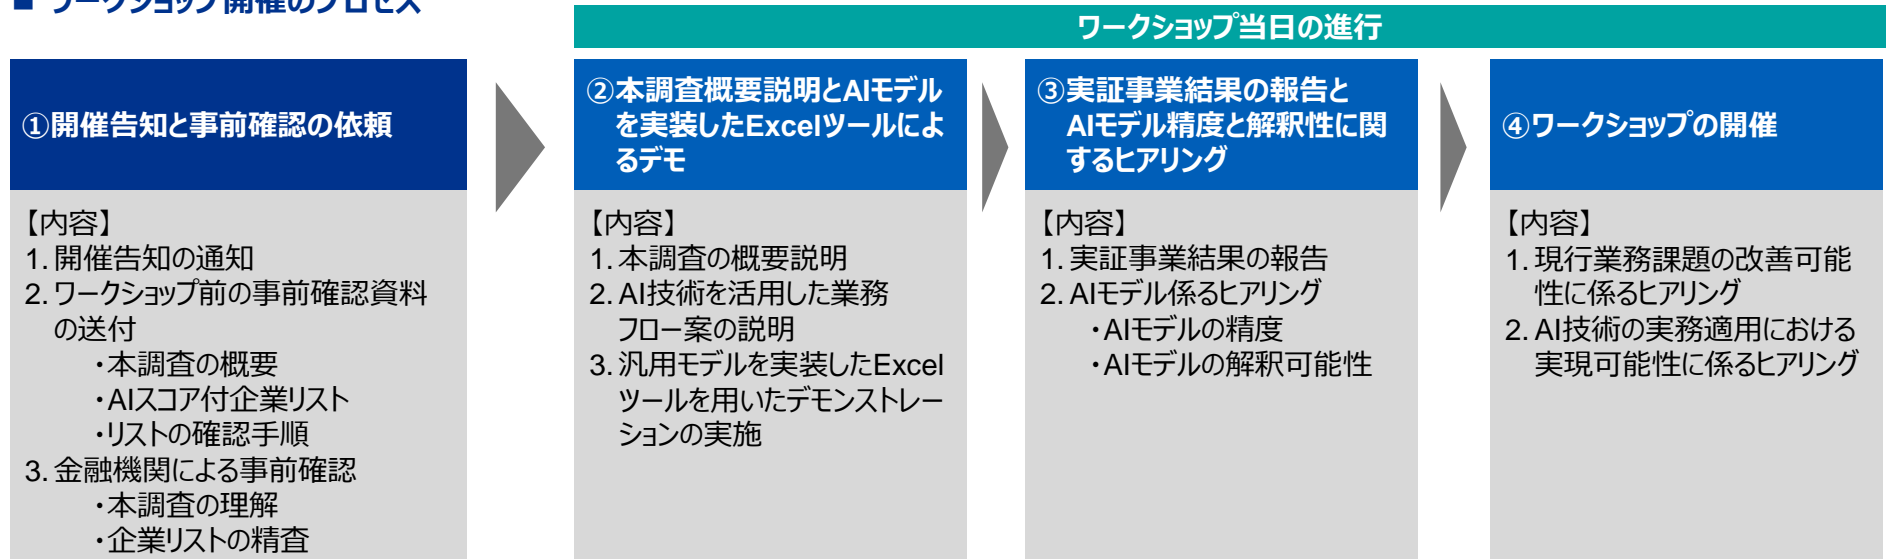
金融機関とのワークショップの概要

- 実証事業の結果も踏まえ、2023年2月にワークショップを開催した。
- ワークショップでは、以下について、金融機関の実務を担う職員と意見交換（ヒアリング）を実施した。
 - ① 実証モデルの結果を踏まえたモデル改善（精度や解釈性）について
 - ② 現行の業務課題の把握及び今後のAI技術導入による改善可能性について

■ 対象金融機関

No	ワークショップを開催した金融機関	参加部署	開催時期
1	横浜銀行	融資部	2023年2月9日
2	栃木銀行	事業支援部、事務システム部	2023年2月9日
3	浜松いわた信用金庫	経営サポート部、デジタル推進部	2023年2月7日
4	大東京信用組合	総合企画部 他	2023年2月13日

■ ワークショップ開催のプロセス



ワークショップにてヒアリングした事項一覧

- ワークショップにて、ヒアリングした事項は下表の通り
- AIモデルのより具体的な精度検証のため、実証事業先にAIスコアを付与した経営改善支援候補リストを事前に配布し、個別にリストの妥当性についての評価を受けた。

大項目	項目	#	調査内容
AIモデルの精度	モデル全体の精度	1	<ul style="list-style-type: none"> • AIモデル全体の精度（AUC）や抽出された企業の順序が受入可能な水準となっているか • AIから出力されるスコアを活用し、ある閾値以上の企業を重点的にモニタリングすることで、経営改善支援業務が効率化されたり、より実効性を高めることが実現し得る精度となっているか
	経営改善支援候補リストの妥当性	2	<ul style="list-style-type: none"> • 今後業績が悪化する可能性が高い先を特定するモデル（開発コンセプト1）から抽出した企業リストの妥当性 • 今後業績が向上する可能性が高い先を特定するモデル（開発コンセプト2）から抽出した企業リストの妥当性
AIモデルの解釈可能性	AIモデル全体の解釈可能性	3	<ul style="list-style-type: none"> • AIモデルに採用されている説明変数やその寄与度が審査や経営改善支援実務と照らして、解釈可能で納得的か
	企業リストの解釈可能性	4	<ul style="list-style-type: none"> • ある会社のスコアとその要因を示した寄与度等を表示しているが、実務家でも理解できるものとなっているか
現行業務課題の改善可能性	情報源	5	<ul style="list-style-type: none"> • 経営改善支援の前提となる各情報を取得する業務が効果的かつ効率的になるか
	支援候補先の作成	6	<ul style="list-style-type: none"> • 経営改善支援候補先を選定する業務が効果的かつ効率的になるか
	事業者への経営改善支援	7	<ul style="list-style-type: none"> • 事業者に対する支援内容を検討し、実行する業務が効果的かつ効率的になるか
AI技術の実務適用に係る実現可能性		8	<ul style="list-style-type: none"> • 「開発コンセプト1と2」のAIモデルを活用した新業務フロー案は実現できそうか • 新業務フロー案を実現するにあたっての課題はあるか

実証事業を踏まえたヒアリング結果概要

- ヒアリング項目毎の金融機関からのご意見概要は下表の通り
- 本調査・研究にて設定した実証事業先にて確認するKPIは概ね達成できた

#	ヒアリング項目	結果概要	
		主な好意的なご意見	主な改善点・課題に係るご意見
P70 #1-2	AIモデルの精度	<ul style="list-style-type: none"> ● AIモデルの精度は実務に耐えうる水準か ・ 全体的なモデルの精度は問題ない 	<ul style="list-style-type: none"> ● AIモデルの精度は実務に耐えうる水準か —
		<ul style="list-style-type: none"> ● モデルより抽出された支援候補リストの確認結果は如何か ・ 抽出された企業リストの中に実際に業績悪化（業績向上）した先が含まれていることが確認された ・ リストの中には、従来はモニタリングできていないような企業も含まれており、こうした客観的な方法で抽出されたリストは有益 	<ul style="list-style-type: none"> ● モデルより抽出された支援候補リストの確認結果は如何か ・ 事業意欲は経営者の年齢等にも関係があるので、そういったものを考慮したリストになると有用ではないか ・ 抽出されたリストの中に、手元流動性が高いものの、赤字の企業が含まれていない等もあったので、リストの抽出条件をカスタマイズ（資金繰り面を重視する等）できるモデルになれば有益ではないか ・ 債務者区分ではなく、格付けを利用しても有用ではないか
P70 #3-4	AIモデルの解釈可能性	<ul style="list-style-type: none"> ● 寄与した説明変数の一覧は実務的に解釈可能か ・ 寄与度が上位となった説明変数は、実務的に違和感なく解釈可能である 	<ul style="list-style-type: none"> ● 寄与した説明変数の一覧は実務的に解釈可能か ・ 説明変数に資金繰りに関する項目をもう少し含むべきではないか ・ 業種（中分類・小分類）や外部環境変数（地域区分等）の粒度を細分化できれば、より解釈が進むのではないか ・ 一部の金融機関の取引先においては外部環境変数は重要ではない
		<ul style="list-style-type: none"> ● 各個社単位のAI出力結果は実務的に解釈可能か ・ 同規模、同業種のスコアの要因は参考になる ・ AI出力結果について、事業者との話のきっかけとして有益 	<ul style="list-style-type: none"> ● 各個社単位のAI出力結果は実務的に解釈可能か ・ 出力結果を業種別にカスタマイズでき、更に意味合いを補足するテキストをAIによって付加できると解釈性が向上する ・ AIスコアの過去の長期推移も示されると尚よい ・ 同規模、同業種内における当該企業の立ち位置が分かると尚よい

現行業務課題と改善可能性にかかるヒアリング結果概要

■ 4 機関に対し、AIモデル導入による現行業務の改善可能性や実務適用に向けた課題等についてヒアリングを実施（P70：#5-8）。主な意見は下表の通り。

金融機関名	項目	主な意見
A金融機関	現行業務の課題	<ul style="list-style-type: none"> 経営改善支援先の絞り込みは、ヒアリング等の定性基準が中心で、明確な定量基準はない。 本部に経営改善支援の話がきた段階で既に業績が悪化していることがある。
	業務の改善可能性	<ul style="list-style-type: none"> 本AIモデルを活用するとデータに基づき客観的な基準で早期に支援先を選定できる。特に外部環境データ等、日常業務では把握しきれていないデータが含まれている点は有用。
	今後の実務適用	<ul style="list-style-type: none"> 既存の支援先選定業務との重複もなく、本部でトライアル的に導入するのであれば、そこまでハードルは高くない。 新たな業務フローが増えるので規程類等の整備や既存業務や既存システムとの親和性を加味した対応が必要となる。
B金融機関	現行業務の課題	<ul style="list-style-type: none"> 支援先の選定は資金収支等を踏まえ行っており、最後は人の目でも判断するので、相応の時間がかかっている。
	業務の改善可能性	<ul style="list-style-type: none"> 支援先の選定がAIで自動的にできるのであれば業務効率化につながる。また、今回受領したリストには、これまで注目していない先が入っており、気づきという観点では有用。
	今後の実務適用	<ul style="list-style-type: none"> 導入時点では精度の問題もあるので、事後検証的に使う等、補完的に利用しつつ、データの蓄積を進めていき、精度が上がった段階で、支援リスト作成の実務に組み込んでいくことが現実的ではないか。
C金融機関	現行業務の課題	<ul style="list-style-type: none"> 定性情報等を踏まえて、営業担当者の判断で訪問先を選定している。
	業務の改善可能性	<ul style="list-style-type: none"> データに基づく客観的なリストが作成できることで、本当に支援すべき先の選定に活かせる可能性がある。今回受領したリストには、現行の支援業務では捕捉できていなかったような企業が入っており、その点も評価できる。
	今後の実務適用	<ul style="list-style-type: none"> 本部でトライアル的に利用し、効果検証をしながら、徐々に適用範囲を拡げる形での導入が検討できる。 融資残高等の取引情報を加味したリストの作成や試算表などを活用したタイムリーな評価を実現するなど、一定のカスタマイズが必要。また、ベンチマークとなる業種は細分化が望ましい。
D金融機関	現行業務の課題	<ul style="list-style-type: none"> 支援先は、融資残高等、一定の条件で絞り込んだうえで、最終的には担当者の判断で選定している。
	業務の改善可能性	<ul style="list-style-type: none"> 全先を対象としてリスト化できる点が有用。今回受領したリストの中には、今まで注目していない先も含まれていたが、よくよく分析してみると、なるほどと思う先であった。 訪問する際の参考資料にもなるので、経営改善支援を行う場面でも効果的な対話等のきっかけになると考えた。
	今後の実務適用	<ul style="list-style-type: none"> まずは、本部での導入となると思うが、最終的には、店舗でも作成・シミュレーションができるのが理想。 解説書もセットで展開する必要があるので、初期コストは相応にかかる。

実証事業及びワークショップ実施結果のまとめ

実証事業① 実際の金融機関データを用いたモデルの精度検証結果

- 共同研究先データを用いて開発した汎用モデルを実際の金融機関データを用いて検証を実施
- 開発コンセプト1及び開発コンセプト2において、汎用モデル・チューニングモデル・実証事業先モデルともに概ねAUCが0.7となっており、実際の金融機関データを用いても本モデルは有効であることが立証された
- 実証事業先へのAIモデル適用方法により精度の違いが出ており、「①汎用モデルをそのまま適用」⇒「②一部データを用いたチューニング」⇒「③実証事業先のデータ全てを用い、再学習させたモデル再構築」の順で精度が高い傾向にあるものの、②と③において精度の差は大きくない
- そのため、チューニングを行うことで実務に耐え得る精度を獲得できることが示唆された

実証事業② AIモデルの個別カスタマイズ・高度化可能性の検証

- 一部の金融機関において、実際の金融機関内部にのみ存在しているようなテキスト情報を用いてモデルのカスタマイズを実施
- 元々の実証事業先モデルの精度が高かったため、精度の向上は限定的であったが、各変数の重要度は高く、今後は金融機関内部に蓄積されたテキスト情報の整備や重要度が高い文言の特定等を進めることで、精度改善や解釈性の向上につながる可能性が高いことが示唆された
- 経営改善支援施策の効果検証についても実証し、支援策全体の効果検証や個社別の因果推論結果は、今後の実効性ある経営改善支援の実現に有益な結果であることも示唆された

実証事業に対する主な意見

- 全体的なモデルの精度については、さらなる改善が必要であるものの実務に耐え得る水準である
- 個別のリストについても、実際に業績が悪化した先やこれまで捕捉していない先が含まれる等、一定の有用性がある
- 説明変数の解釈性や寄与度については、実務上違和感がない
- 業種や地域分類、試算期財務データ等のより粒度の細かい情報の活用や、融資額・非保全額などを勘案のうえリスト抽出することで、AIモデル精度と解釈可能性の向上につながるのではないかと

現行業務の改善可能性に対する主な意見

- 現行業務では、必ずしも定量データに基づき支援先の選定を行っていない中、客観的な基準でリストが作成できることで支援業務が効果的に行える可能性がある
- 実務適用については、まずは本部等の部署でトライアル的に導入し、精度検証を繰り返しながら、導入範囲を決めていくのではないかと
- 導入にあたっては、既存業務やシステム、既存モデルとの親和性や、導入にかかるコスト等を鑑みながら、規程類などの体制整備も行うことが必要

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出と
AI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 金融機関等向けワークショップ

6 本調査・研究の今後の課題

7 添付資料

今年度の課題の棚卸し・次年度へ向けた方向性

課題の類型		No	今年度の課題	次年度の方向性（案）
モデル高度化	データ	1	・より短期での業況変化を把握できると実務上有用なのではないか	・金融機関内部にしか蓄積されていないような高頻度データ（月次財務、試算期財務等）と、より粒度の細かいデータ（業種分類の細分化等）の活用
		2	・経営改善支援を実際に行うことで業績が向上するような先を予測できるようにしてほしい	・支援をしたことで業績が向上した先と自力で向上した先を峻別できる教師ラベルの作成
		3	・債務者区分は必ずしも財務状態と連動するわけではないので、業績に応じた序列付けがされた企業リストがほしい	・信用格付等の別の序列情報を用いた教師ラベルの検討
		4	・定性情報（経営者年齢や後継者有無など）や実態財務情報を加味して支援しているため、当該情報も踏まえて欲しい	・金融機関内部にしか蓄積されていない定性情報/実態財務情報の活用
		5	・渉外記録やCRMシステムなどに蓄積されたテキストを主とする情報も積極的に活用してほしい	・テキスト情報を説明変数に活用可能な自然言語処理を用いたモデルの開発
	モデル	6	・業種や規模などのセグメントを活用する等、より納得的（精度の高い）な結果を出力してほしい	・今年度モデルで精度の低かったセグメントモデルの要因分析 ・業種や規模などのセグメントモデルの精緻化 ・より高度なアルゴリズム・モデルの検討
		7	・突発倒産先も検知できるようにしてほしい	・過去に突発倒産した先を用いたモデルの検証 ・突発倒産先も教師ラベルに加えたモデル開発
		8	・スコアの要因を説明する情報として数値的な寄与度だけでなく営業店でも解釈可能なテキストでの要因説明をしてほしい	・業況を端的に表現するテキストの自動生成の仕組み検討
実務適用	9	・実質的に経営が一体となっている関連会社や親会社の財務状態や業種等も考慮した結果（スコア）を出力してほしい	・実質的に経営が一体となっている関連会社や親会社との関係を考慮したAI出力結果の活用方法の整理	
	10	・金融機関ごとに審査目線や支援方針が異なるので、それを反映できるようにAI出力結果もカスタマイズできるようにしてほしい	・（伴走支援を通じた）業態ごと、地域ごと等にAIを実務適用する際の各論点（実施体制、手続き、規定、システムとの親和性等）を整理し、横展開を行う	
	11	・新しい業務フローを実務適用する場合は規程類などの体制整備も必要となる		
	12	・支援先の選定に通常用いられている情報（残高・非保全額など）も加味したリスト作成をしてほしい		
	13	・新技術を導入するとしても、既存業務やシステム、既存モデルとの親和性に配慮してほしい		

1 本調査の背景・目的・調査概要

2 経営改善等に活用可能なデータにかかる調査

2-1 現状の経営改善支援業務の整理・課題抽出とAI技術を用いた新たな業務フローの基礎検討

2-2 データの調査・取得

3 AI技術の活用可能性にかかる研究

3-1 AI技術を活用したプロトタイプの要件定義

3-2 データクレンジングとプロトタイプAIモデルの開発

3-3 実用化に向けたUIの基礎検討

4 金融機関による実証事業

5 金融機関等向けワークショップ

6 本調査・研究の今後の課題

7 添付資料

7. 添付資料 Contents

	Page
7-1 研究会の概要・参加者・主な意見	78
7-2 本調査・研究におけるAIモデル構築数	95
7-3 AIアルゴリズムの概説	97
7-4 モデル構築におけるデータの分割の概説	105
7-5 AIモデルの評価指標の概説	107

7-1 研究会の概要・参加者・主な意見

7-2 本調査・研究におけるAIモデル構築数

7-3 AIアルゴリズムの概説

7-4 モデル構築におけるデータの分割の概説

7-5 AIモデルの評価指標の概説

第1回研究会概要

- 第1回研究会の日時・場所・議題は以下の通り。

研究会名	「AIを活用した経営改善支援に係る研究会」（第1回）
日時	2022年7月1日（金）午後2時～午後4時
場所	「Webex」によるWeb会議
議題	<p>1. 現行の経営改善支援業務の理解</p> <ul style="list-style-type: none">• 現行の経営改善支援業務フローの確認<ul style="list-style-type: none">– 現行業務フローの適切性（理解が正しいか）• 現行の経営改善支援業務の課題認識<ul style="list-style-type: none">– 課題認識の妥当性（現場の作業負担、リストの精度 など）– 追加的な課題の有無• AI技術を用いた新しい経営改善支援業務フロー案<ul style="list-style-type: none">– AI適用後の業務フロー案の実現可能性– AI技術を活用するための留意点や現場目線からの要望 <p>2. プロトタイプAI開発コンセプトについて</p> <ul style="list-style-type: none">• 本調査・研究の目的を踏まえたAI開発のコンセプト<ul style="list-style-type: none">– 開発コンセプトの妥当性・合目的性• AIアルゴリズム候補について<ul style="list-style-type: none">– アルゴリズム候補の網羅性及び妥当性 <p>3. プロトタイプAI開発に用いるデータについて</p> <ul style="list-style-type: none">• プロトタイプAIモデル構築のためのデータ母集団と目的変数（教師ラベル）の定義について<ul style="list-style-type: none">– 学習データ及び教師ラベルの定義の妥当性• 外部環境データについて<ul style="list-style-type: none">– 想定している外部環境データの網羅性及び適切性

第1回研究会参加者一覧 [1/2]

■ 第1回研究会参加の研究会委員（計13名）の一覧は以下の通り。

	氏名	所属
委員	有竹 博史	東京信用保証協会 業務総轄室 業務総轄部長
	和泉 潔	東京大学大学院 工学系研究科 システム創成学 教授
	内山 功士	浜松いわた信用金庫 デジタル推進部 デジタル業務課 課長
	河合 祐子	Japan Digital Design株式会社 代表取締役CEO
	三川 剛	株式会社エルテス 取締役
	鈴木 明美	大東京信用組合 常勤理事・総合企画部長
	筒木 光	TKC全国会システム委員会 TKC経営指標編集小委員会 委員
	中村 康浩	株式会社横浜銀行 融資部 担当部長
	名取 良訓	信金中央金庫 総合企画部しんきんイノベーションハブ 次長
	松崎 堅太郎	TKC全国会中小企業支援委員会 副委員長
	宮川 大介	一橋大学 経営管理研究科 経営管理専攻 准教授
	矢内 紘之	株式会社帝国データバンク 企総部 企画課長
	吉田 茂樹	株式会社栃木銀行 事業支援部 副部長

第1回研究会参加者一覧 [2/2]

■ 第1回研究会のオブザーバー（計11組織）の一覧は以下の通り。

	組織名
オブザーバー	一般社団法人全国地方銀行協会
	一般社団法人第二地方銀行協会
	一般社団法人全国信用金庫協会
	一般社団法人全国信用組合中央協会
	一般社団法人全国信用保証協会連合会
	株式会社商工組合中央金庫
	株式会社日本政策金融公庫
	株式会社TKC
	中小企業庁事業環境部金融課
	経済産業省経済産業政策局地域経済産業グループ
	内閣官房デジタル田園都市国家構想実現会議事務局

第1回研究会における主な意見

■ 第1回研究会における主な意見は以下の通り。

議題1「現行の経営改善支援業務の理解」

- 事務局が提示した経営改善支援の業務フローは、実務と概ね相違はない。
- 経営改善支援業務の課題としては、経営者との経営改善における課題の共有や経営改善の有効な手段が提供できていないこと等がある。
- 事業者に経営改善の必要性を理解してもらうために、AIでただ支援先を抽出するだけでなく、外部環境データ等を含む各指標（説明変数）の寄与度や外部環境の影響をどの程度受けるのかを分析する機能など、事業者との会話のきっかけになるような仕組みを検討してほしい。
- 支援機関によって経営改善支援先の認識が異なるので、共通の目線を持つ意味で、今回の研究は非常に良い取組みである。
- AIを活用することで、現行の信用リスクモデルに基づく分析では支援先と認識していないような先が出てくる点には非常に期待している。

議題2「プロトタイプAI開発コンセプトについて」

- 広く支援先を発見したいという点と抽出した支援先が正確であるという点は、通常トレードオフになるものなので、それぞれのモデルの目的やユースケースを想定したうえで、モデルを設計すべきである。
- 4つの共同研究先データの特徴を踏まえ、データ毎に構築すべきモデルやアルゴリズムの整理を行い、各データの価値を最大限に活かすよう、モデル開発を進めるべき。また、クロスバリデーションの手法を用い、モデルの精度検証を行うべきである。
- 今回のモデルでは、財務状況が悪化するものを見抜くものであって、具体的な改善項目（ビジネスモデルが悪い、後継者不足等）を見抜くものではないことは明確にすべきである。

議題3「プロトタイプAI開発に用いるデータについて」

- 広く支援先を発見したいという点と抽出した支援先が正確であるという点は、通常トレードオフになるものなので、それぞれのモデルの目的やユースケースを想定したうえで、モデルを設計すべきである。
- 経営改善先の把握には、財務データや外部環境データだけでなく、定性的な情報・データをいかに入れていけるかが重要になると考えられるので、定性データについても検討すべき。
- 財務データについて、年次のストックデータだけでなくできる限りフローに近いデータを活用すると、業況悪化の予測精度が高まると考えられる。
- 地域金融機関が有する財務データは、今回モデルを構築する共同研究先データと比較して欠損が大きいと考えられるため、実務適用の際には対応を検討すべき。

第2回研究会概要

- 第2回研究会の日時・場所・議題は以下の通り。

研究会名	「AIを活用した経営改善支援に係る研究会」（第2回）
日時	2022年9月2日（金）午後3時～午後5時
場所	「Webex」によるWeb会議
議題	<p>1. KPIの設定・モデル開発計画について</p> <ul style="list-style-type: none">モデル開発計画<ul style="list-style-type: none">データの特徴（データ頻度、項目、母集団等）を踏まえた計画となっているか、データを有効活用できる計画となっているか現行の経営改善支援業務の課題認識開発するモデルの目的が適切か追加的な課題の有無 <p>2. モデル開発用データ整備とモデルの評価指標について</p> <ul style="list-style-type: none">モデル開発母集団と教師ラベルの定義<ul style="list-style-type: none">モデル開発母集団と教師ラベルの定義を行うにあたって、財務情報や信用力の序列情報を適切に扱えているか各開発コンセプトに対する定義が、本調査・研究にて開発するモデルの目的（経営改善支援が必要な先の特定（早期発見））に沿ったものとなっているかモデルの評価指標について<ul style="list-style-type: none">モデルの評価の観点や評価指標が適切か <p>3. AIからの出力結果の実務活用について</p> <ul style="list-style-type: none">AIからの出力UIイメージとその活用<ul style="list-style-type: none">UIイメージは実務適用が可能なものとなっているか（情報量や理解のしやすさ等）シナリオ分析機能以外に実務適用する際に必要な機能はあるか

第2回研究会参加者一覧 [1/2]

■ 第2回研究会参加の研究会委員（計13名）の一覧は以下の通り。

	氏名	所属
委員	有竹 博史	東京信用保証協会 業務総轄室 業務総轄部長
	和泉 潔	東京大学大学院 工学系研究科 システム創成学 教授
	内山 功士	浜松いわた信用金庫 デジタル推進部 デジタル業務課 課長
	河合 祐子	Japan Digital Design株式会社 代表取締役CEO
	三川 剛	株式会社エルテス 取締役
	鈴木 明美	大東京信用組合 常勤理事・総合企画部長
	筒木 光	TKC全国会システム委員会 TKC経営指標編集小委員会 委員
	中村 康浩	株式会社横浜銀行 融資部 担当部長
	名取 良訓	信金中央金庫 総合企画部しんきんイノベーションハブ 次長
	松崎 堅太郎	TKC全国会中小企業支援委員会 副委員長
	宮川 大介	一橋大学 経営管理研究科 経営管理専攻 准教授
	矢内 紘之	株式会社帝国データバンク 企総部 企画課長
	吉田 茂樹	株式会社栃木銀行 事業支援部 副部長

第2回研究会参加者一覧 [2/2]

■ 第2回研究会参加のオブザーバー（計11組織）の一覧は以下の通り。

	組織名
オブザーバー	一般社団法人全国地方銀行協会
	一般社団法人第二地方銀行協会
	一般社団法人全国信用金庫協会
	一般社団法人全国信用組合中央協会
	一般社団法人全国信用保証協会連合会
	株式会社商工組合中央金庫
	株式会社日本政策金融公庫
	株式会社TKC
	中小企業庁事業環境部金融課
	経済産業省経済産業政策局地域経済産業グループ
	内閣官房デジタル田園都市国家構想実現会議事務局

第2回研究会における主な意見

■ 第2回研究会における主な意見は以下の通り。

議題1「KPIの設定・モデル開発計画について」

- KPIの①の観点と②の観点を全く同等にする必要はなく、観点②にて全体の精度を確認、観点①にて特定のケース（製造業・非製造業等）での精度を確認するのも良い。
- 必ずしも全体として高い精度が出なくても、特定のケースで精度が出ることを見出すことも有益である。

議題2「モデル開発用データ整備とモデルの評価指標について」

- 各財務項目が実際に財務の悪化に反映されるまでタイムラグについて留意してほしい（例えば、利益の変動は財務悪化までのタイムラグがあるが、資本の変動はダイレクトに財務悪化につながる）。
- 重要な財務項目だが、欠損が多いものについては、0で欠損埋めを行うと信用力が適切に評価出来なくなるので、取り扱いに留意して欲しい。
- 開発コンセプト2では、経営状態が悪い状態から「経営改善支援を受けずに」良くなった先は負例、「経営改善支援を受けて」良くなった先を正例、「経営改善支援を受けて」良くならなかった先は負例のラベルがついてることが望ましい。
- AUCの点推定値だけではなく、標準誤差や信頼区間について算出し、推定値の精度測定を行うと良い。
- 適合率と再現率にかかる閾値の設定については、経営改善支援にかかるコストと、支援によって業績が回復して得られるゲインのトレードオフのなかで、一番良いポイントを探すのが通常的最適化の方法。どこの閾値が最適だと考えるかは議論としてとりまともても良い。

議題3「AIからの出力結果の実務活用について」

- コンセプト1、コンセプト2でスコアの高さの意味合いを整合的にした方が良い。
- スコアの大きさの意味合いについて、一定のレンジ毎の説明があると良い。
- 同業種だけではなく同規模企業との比較ができると良い。
- 外部環境データとして地域性のある情報も含まれると良い。

第3回研究会概要

- 第3回研究会の日時・場所・議題は以下の通り。

研究会名	「AIを活用した経営改善支援に係る研究会」（第3回）	
日時	2022年11月25日（金）午前10時～午前12時	
場所	「Webex」によるWeb会議	
議題	<p>1. プロトタイプAIの開発結果等</p> <ul style="list-style-type: none"> プロトタイプAIの開発結果 <ul style="list-style-type: none"> 本調査・研究のKPIが達成されているか 汎用モデルのチューニング結果 <ul style="list-style-type: none"> 汎用モデルとチューニングモデルをどのように使い分けるか セグメンテーションモデルの構築結果 <ul style="list-style-type: none"> モデルの使用シーンを踏まえたセグメンテーションとなっているか <p>2. AIからの出力結果の実務活用について</p> <ul style="list-style-type: none"> AIからの出力結果とその活用 <ul style="list-style-type: none"> 新たな業務フローを実現する出力結果イメージとなっているか 	<p>3. 金融機関による実証事業・ワークショップについて</p> <ul style="list-style-type: none"> 金融機関による実証事業・ワークショップの概要 <ul style="list-style-type: none"> 実証事業・ワークショップの実施内容の確認

第3回研究会参加者一覧 [1/2]

■ 第3回研究会参加の研究会委員（計13名）の一覧は以下の通り。

	氏名※	所属
委員	有竹 博史	東京信用保証協会 業務総轄室 業務総轄部長
	和泉 潔	東京大学大学院 工学系研究科 システム創成学 教授
	内山 功士	浜松いわた信用金庫 デジタル推進部 デジタル業務課 課長
	河合 祐子	Japan Digital Design株式会社 代表取締役CEO
	三川 剛	株式会社エルテス 取締役
	鈴木 明美	大東京信用組合 常勤理事・総合企画部長
	筒木 光	TKC全国会システム委員会 TKC経営指標編集小委員会 委員
	中村 康浩	株式会社横浜銀行 融資部 担当部長
	名取 良訓 (北口 裕也)	信金中央金庫 総合企画部しんきんイノベーションハブ 次長 (信金中央金庫 総合企画部しんきんイノベーションハブ 上席調査役)
	原 浩二	株式会社栃木銀行 事業支援部 主任調査役
	松崎 堅太郎	TKC全国会中小企業支援委員会 副委員長
	宮川 大介	一橋大学 経営管理研究科 経営管理専攻 教授
	矢内 紘之 (木村 公平)	株式会社帝国データバンク 企総部 企画課長 (株式会社帝国データバンク プロダクトデザイン部 プロダクトデザイン課 課長)

※ 下線：委員の変更があったもの。（括弧）：委員の代理で出席したもの。

第3回研究会参加者一覧 [2/2]

■ 第3回研究会参加のオブザーバー（計11組織）の一覧は以下の通り。

	組織名
オブザーバー	一般社団法人全国地方銀行協会
	一般社団法人第二地方銀行協会
	一般社団法人全国信用金庫協会
	一般社団法人全国信用組合中央協会
	一般社団法人全国信用保証協会連合会
	株式会社商工組合中央金庫
	株式会社日本政策金融公庫
	株式会社TKC
	中小企業庁事業環境部金融課
	経済産業省経済産業政策局地域経済産業グループ
	内閣官房デジタル田園都市国家構想実現会議事務局

第3回研究会における主な意見

■ 第3回研究会における主な意見は以下の通り。

議題1「プロトタイプAIの開発結果等」

- 全体の精度としてはAUCも高く出ており、個別金融機関での実証事業で使用しても問題ないモデルとなっている。
- 実証事業では、AI技術を導入することで、これまで業績悪化を予兆できていない先が特定できているか、業務効率化が可能かという点について、実務の目線から確認した方が良い。
- 今後、全体の精度向上や更なる業務効率化の観点から、より複雑なモデルを構築していくことが考えられるが、その際には、事業者への説明可能性等も考慮しながら検討してほしい。
- 定性情報が精度向上に寄与するというのは、非常に有益な情報。今後、金融機関が保有している入出金情報等の活用も検討してほしい。
- 徐々に業況が悪化する先だけでなく、突発的に業況が悪化する先が予測できると有用。
- 今回、汎用モデルやチューニングモデル、セグメントモデル等、複数のモデルを構築しているが、どのモデルを適用するべきかは、金融機関の状況によっても異なる。どのモデルが適しているかの簡単な指針（モデルケース）のようなものを示すことができれば、活用が進むのではないか。
- 構築したモデルで、どの変数が精度向上に寄与したか一覧性のある形で示してほしい。

議題2「AIからの出力結果の実務活用について」

- 外部環境データは、一見、因果関係が想像しにくいものも含まれているので解釈が難しい。例えば、表示する際には、業種に関連するものに限定してもよいのではないか。
- 今後は、この研究結果を各支援機関がどのように活用していくのがポイント。その際には、AIの結果だけに頼るのではなく、事業者との対話で重要なポイントを説明資料に落とし込むなど、人がやるところとAIがやるところをうまく融合することが重要。
- 今回のAIモデルの選定先と自社で独自に選定した支援先を見比べることで、早期かつ正確に支援先を把握できるようになると考えている。
- 財務面の情報量をもう少し増やす等、事業者と議論が進むような工夫の余地はある。
- 現状は、出力結果をもとに人で分析する部分が多いが、将来的には経営改善支援のシナリオなど、経営改善に役立つ情報をシステムティックに出せないかは検討し続けてほしい。
- セグメンテーションモデルの一部（飲食など）で精度が出ていない部分があるが、どうすれば精度を上げていけるのか、要因分析・対応事項の整理を検討してほしい。

第4回研究会概要

- 第4回研究会の日時・場所・議題は以下の通り。

研究会名	「AIを活用した経営改善支援に係る研究会」（第2回）
日時	2023年2月24日（金）午後4時～午後6時
場所	「Webex」によるWeb会議
議題	<p>1. 汎用モデルの精度検証結果</p> <ul style="list-style-type: none">汎用モデルの精度検証結果<ul style="list-style-type: none">汎用モデルが実際の金融機関データを用いても有効に機能するか汎用モデルの解釈性の確認結果<ul style="list-style-type: none">汎用モデルから抽出された結果は金融機関の実務に照らして解釈可能かAIモデルの個別カスタマイズ・高度化可能性<ul style="list-style-type: none">金融機関にしか存在しないデータを用いた個別カスタマイズや高度化が有益かどうか <p>2. ワークショップの結果について</p> <ul style="list-style-type: none">実証事業の結果を踏まえたヒアリング結果<ul style="list-style-type: none">今後どのように精度や解釈性をどう向上させていくか業務の改善可能性にかかるヒアリング結果<ul style="list-style-type: none">今後の実務適用に向けた課題は何か、どのように進めていけばいいか <p>3. 本調査・研究の総括</p> <ul style="list-style-type: none">本調査・研究の総括内容のご確認

第4回研究会参加者一覧 [1/2]

■ 第4回研究会参加の研究会委員（計13名）の一覧は以下の通り。

	氏名※	所属
委員	有竹 博史	東京信用保証協会 業務総轄室 業務総轄部長
	和泉 潔	東京大学大学院 工学系研究科 システム創成学 教授
	内山 功士	浜松いわた信用金庫 デジタル推進部 デジタル業務課 課長
	河合 祐子	Japan Digital Design株式会社 代表取締役CEO
	三川 剛	株式会社エルテス 取締役
	鈴木 明美 (柴橋 英範)	大東京信用組合 常勤理事・総合企画部長 (大東京信用組合 総合企画部 考査役)
	筒木 光	TKC全国会システム委員会 TKC経営指標編集小委員会 委員
	中村 康浩	株式会社横浜銀行 融資部 担当部長
	名取 良訓 (北口 裕也)	信金中央金庫 総合企画部しんきんイノベーションハブ 次長 (信金中央金庫 総合企画部しんきんイノベーションハブ 上席調査役)
	原 浩二	株式会社栃木銀行 事業支援部 主任調査役
	松崎 堅太郎	TKC全国会中小企業支援委員会 副委員長
	宮川 大介	一橋大学 経営管理研究科 経営管理専攻 教授
	矢内 紘之 (欠席)	株式会社帝国データバンク 企総部 企画課長

※（括弧）：委員の代理で出席したもの。または欠席したもの。

第4回研究会参加者一覧 [2/2]

■ 第4回研究会参加のオブザーバー（計11組織）の一覧は以下の通り。

	組織名
オブザーバー	一般社団法人全国地方銀行協会
	一般社団法人第二地方銀行協会
	一般社団法人全国信用金庫協会
	一般社団法人全国信用組合中央協会
	一般社団法人全国信用保証協会連合会
	株式会社商工組合中央金庫
	株式会社日本政策金融公庫
	株式会社TKC
	中小企業庁事業環境部金融課
	経済産業省経済産業政策局地域経済産業グループ
	内閣官房デジタル田園都市国家構想実現会議事務局

第4回研究会における主な意見

■ 第4回研究会における主な意見は以下の通り。

議題1「汎用モデルの精度検証結果」（議題3「本調査・研究の総括」の内容も含む）

- 全体の精度としては実務適用に向けて問題ない水準である。
- 構築したモデルごとの得意・不得意の分析や、モデル構築時のデータと実証事業のデータの差から生じる結果を分析することで、実務適用が進んでいくのではないか。
- 本調査研究では基本的に年1回の財務データを参照しているが、より短期で信用度合いを見る場合には、資金繰りの情報が重要になると思料。短期で見ると預金残高などのデータが重要になってくるのではないか。
- 取引情報（仕入・販売情報）も重要な情報。取引先リストなどの情報をモデルとして利用できれば高度化のヒントになると思料。
- テキストデータを活用できると、経営改善支援実務が相当に効果的に行えるように感じている。
- テキストデータの活用については、単語として捉えるのではなく、前後の文脈まで考慮することで精度向上につながる可能性が高い。その際は一般的な言語モデルではなく、経営や財務等にチューンアップしたモデルが必要になると考えられる。
- 定性情報やテキストデータを活用するにあたり、金融機関職員がデータをどのように蓄積していくか（分かりやすい言葉の使用、頻度の統一など）について目線合わせが必要になる。
- 因果推論の取組みについて、今回は試行的に行っているが、今後は実務への適用も意識して、さらに精緻に発展的な内容に広げて欲しい。

議題2「ワークショップの結果について」（議題3「本調査・研究の総括」の内容も含む）

- 今回構築したモデルは、金融機関に積極的に使ってもらい、経営者や他の支援者との目線合わせに活用されていくことを期待している。
- 外部環境変数（エネルギー消費量など）の結果については、どのように解釈し、顧客と対話していくか検討が必要。
- モデルやそのアウトプットを金融機関ごとにカスタマイズすることはモデルを浸透させ、実効性を高めることには良いことだが、そもそもの今回の取組みの目的や、結果の解釈が金融機関で異なるのは良い状態ではないため、政策サイドで適切な発信を行っていく必要がある。
- データの収集や取込み等、実際にモデルを実務適用する際の作業イメージが必要ではないか。

7-1 研究会の概要・参加者・主な意見

7-2 本調査・研究におけるAIモデル構築数

7-3 AIアルゴリズムの概説

7-4 モデル構築におけるデータの分割の概説

7-5 AIモデルの評価指標の概説

本調査・研究におけるAIモデル構築数

モデル名称	モデル構築数	詳細
早期発見モデル（開発コンセプト1）	195	
財務のみモデル	3	1つの共同研究先に対して3つのアルゴリズムで構築
汎用モデル	12	各共同研究先ごとに3つのアルゴリズムで構築
共同研究先モデル	12	各共同研究先ごとに3つのアルゴリズムで構築
チューニングモデル	36	各共同研究先ごとに他の共同研究先のデータを再学習させて構築
セグメンテーションモデル	132	各共同研究先ごとに業種別・信用度別（又はその組み合わせ）に3つのアルゴリズムで構築
経営改善モデル（開発コンセプト2）	65	
財務のみモデル	3	1つの共同研究先に対して3つのアルゴリズムで構築
汎用モデル	12	各共同研究先ごとに3つのアルゴリズムで構築
共同研究先モデル	12	各共同研究先ごとに3つのアルゴリズムで構築
チューニングモデル	36	各共同研究先ごとに他の共同研究先のデータを再学習させて構築
因果推論モデル	2	1つの共同研究先にて2つのアルゴリズムで構築
実証事業先モデル	124	
チューニングモデル	96	実証事業先1先につき各共同研究先ごとに3つのアルゴリズム・2つの開発コンセプトで構築
実証事業先モデル	24	実証事業先1先につき3つのアルゴリズム・2つの開発コンセプトで構築
高度化検証モデル	2	1つの実証事業先データを用いて2つの開発コンセプトで構築
因果推論モデル	2	1つの実証事業先データを用いて2つのアルゴリズムで構築
合計	384	

7-1 研究会の概要・参加者・主な意見

7-2 本調査・研究におけるAIモデル構築数

7-3 AIアルゴリズムの概説


7-4 モデル構築におけるデータの分割の概説

7-5 AIモデルの評価指標の概説

AIアルゴリズムの概説 [1/7]

■ ロジスティック回帰の概説

下図のようなロジスティック曲線を用いて、目的変数を回帰分析の手法で予測する方法。金融機関実務において企業の信用力評価に最も活用されている方法。



$$Z = \alpha_0 + \beta_1 X_1 + \beta_2 X_2 + \dots$$

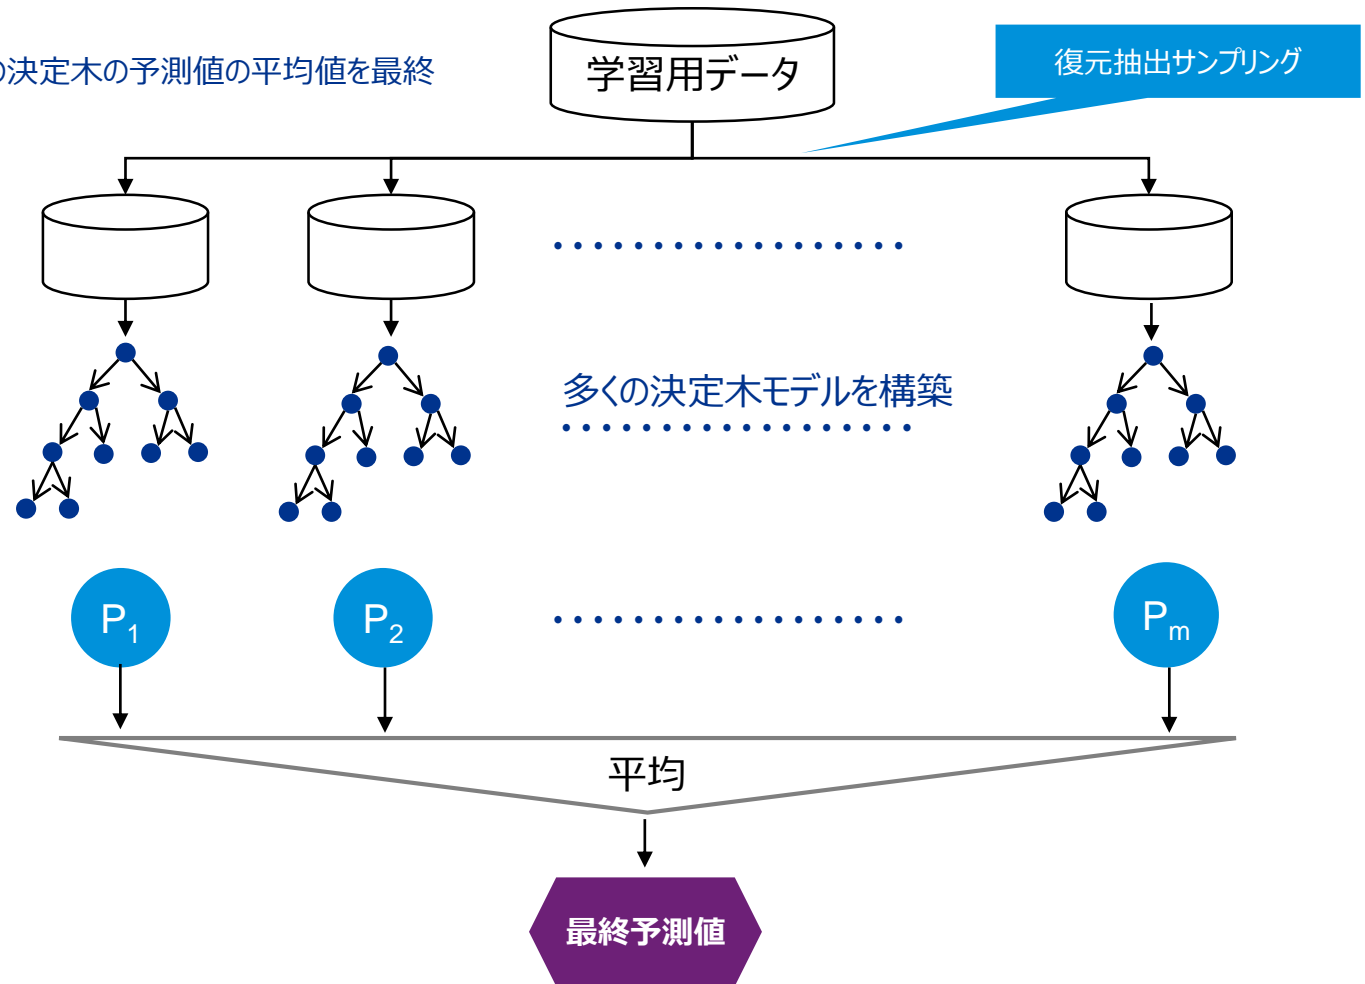
X_i : i 番目の説明変数 (特徴量)

α_0 、 β_i : 切片及び回帰係数

AIアルゴリズムの概説 [2/7]

■ ランダムフォレストの概説

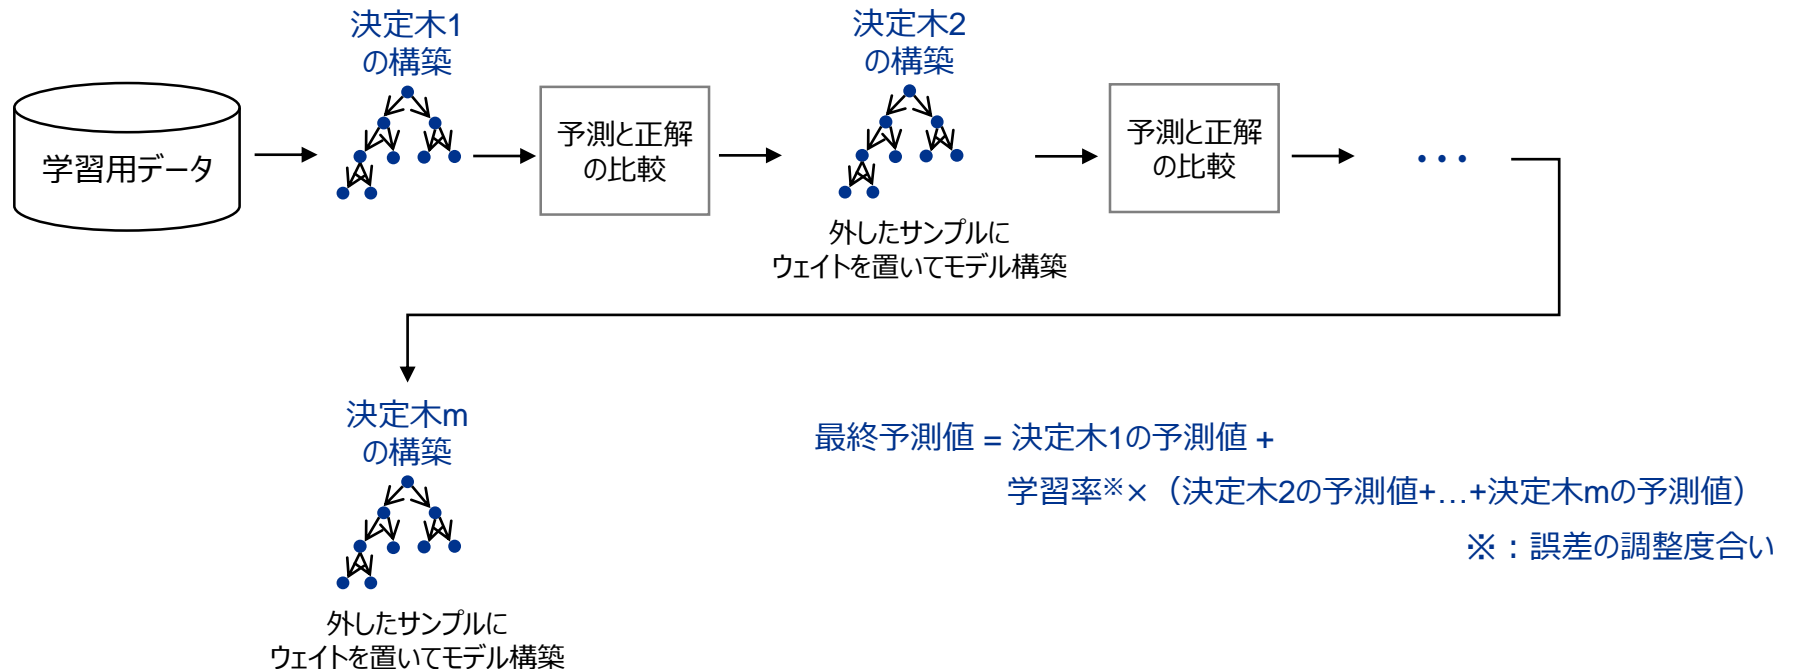
多くの決定木モデルを構築し、多数の決定木の予測値の平均値を最終的な予測値とする方法



AIアルゴリズムの概説 [3/7]

■ 勾配ブースティングの概説

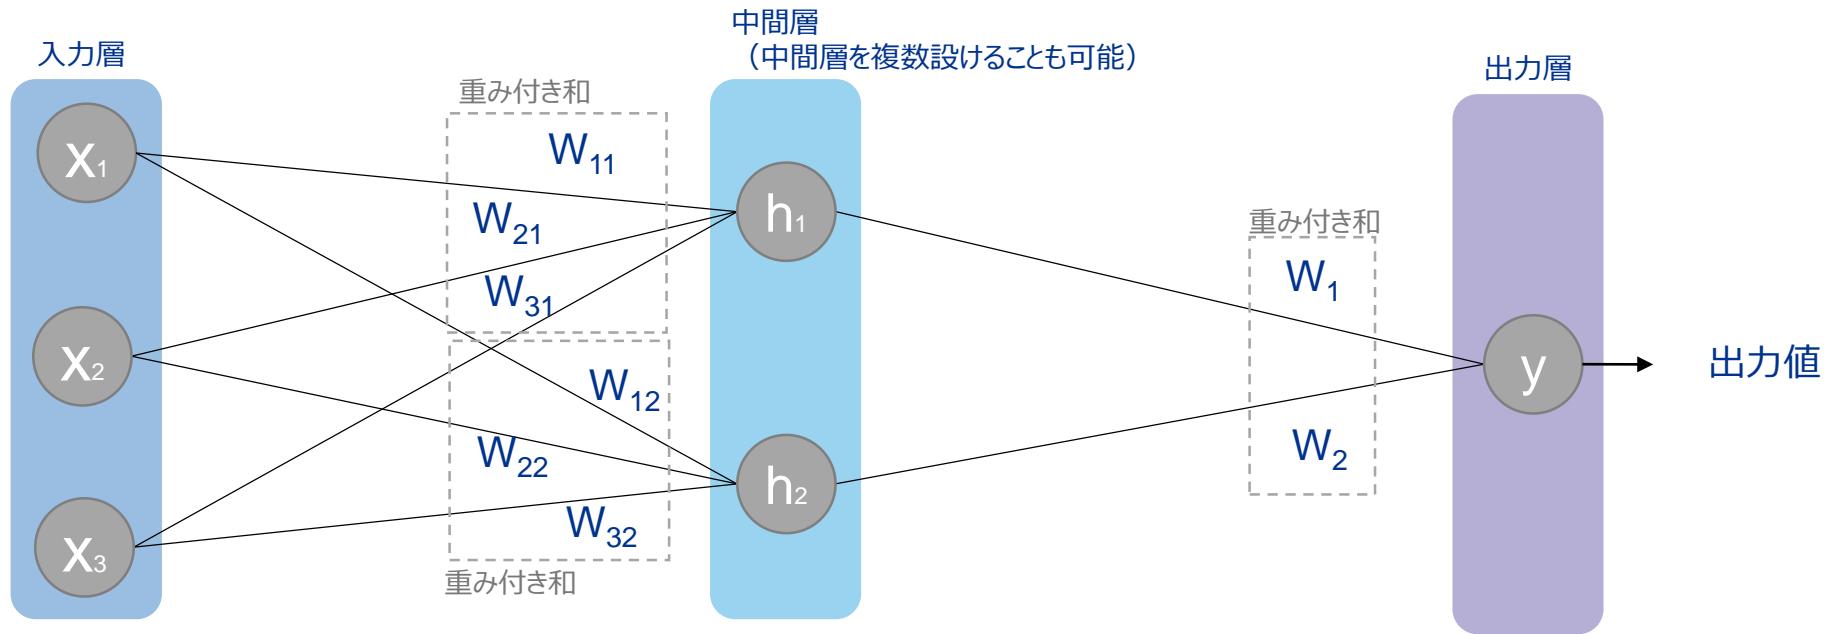
決定木を構築し、当該決定木が外したサンプルに当てはまるようにウェイトを調整して、次の決定木を構築する。これを繰り返して最終的な予測値とする方法



AIアルゴリズムの概説 [4/7]

■ 多層パーセプトロンの概説

複数の入力値に対し、それぞれ調整した重みをかけて出力値を計算し、その結果を用いて分類する方法。



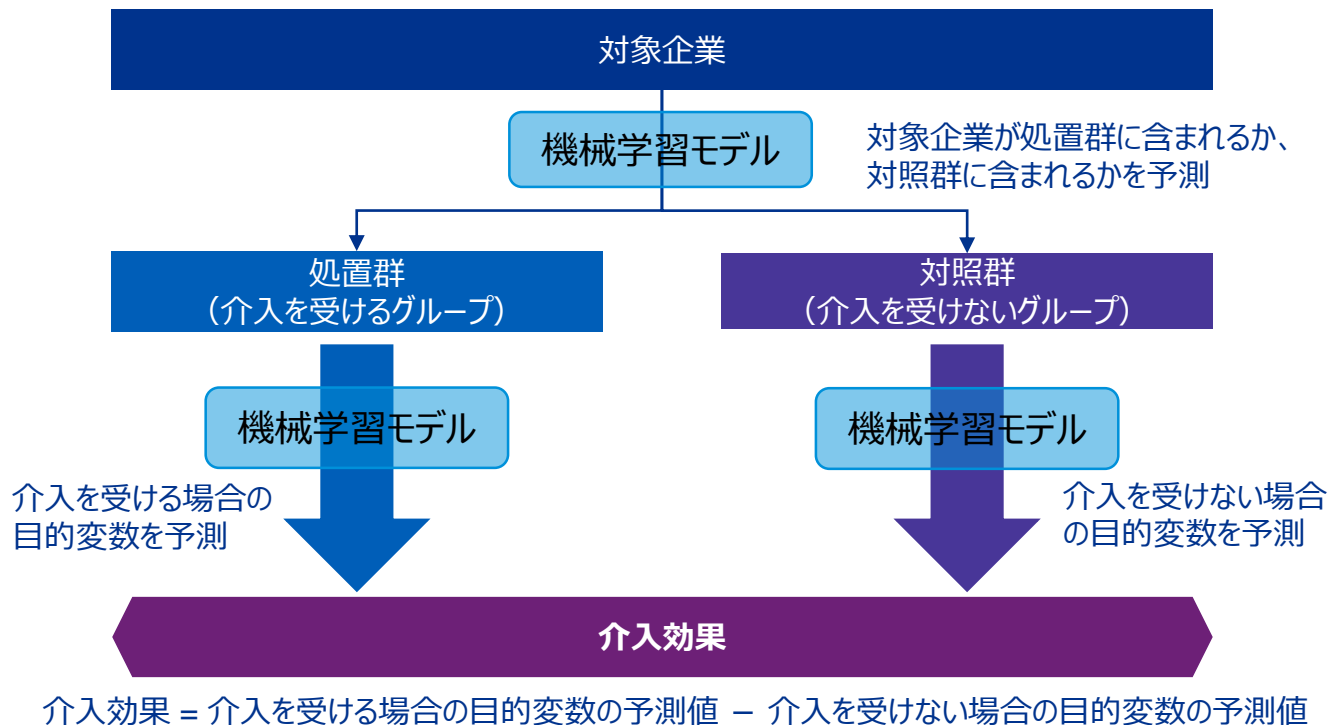
入力値 ($x_1 \sim x_3$) に対して、学習済みの重み ($W_{11} \sim W_{31}$) をかけたものの和を計算し、中間層のノード h_1 を算出する。同様に h_2 も算出する。

中間層のノード ($h_1 \sim h_2$) に対して、学習済みの重み ($W_1 \sim W_2$) をかけたものの和を計算し、出力値を算出する。

AIアルゴリズムの概説 [5/7]

■ Meta-Learnersの概説

因果推論を行うための論理フローの各ポイントに主要な機械学習アルゴリズム（ロジスティック回帰、ランダムフォレスト等）を適用し、介入効果の推定を行う手法。

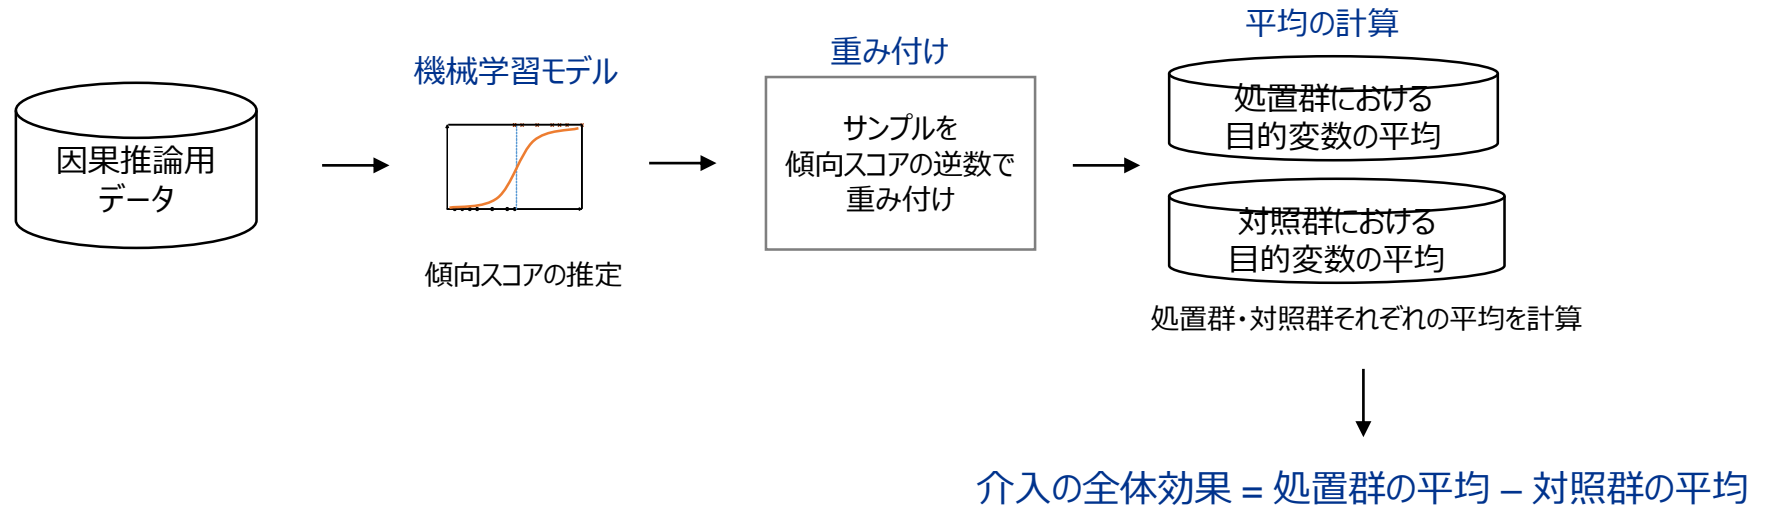


(注) Meta-Learnersの中には様々なアルゴリズムがあり、各ポイントにおける機械学習モデルの適用有無や適用方法、介入効果の算出方法は、各アルゴリズムによって異なる。

AIアルゴリズムの概説 [6/7]

■ 傾向スコアを用いた逆確率重み付き推定による因果推論（伝統的な因果推論）

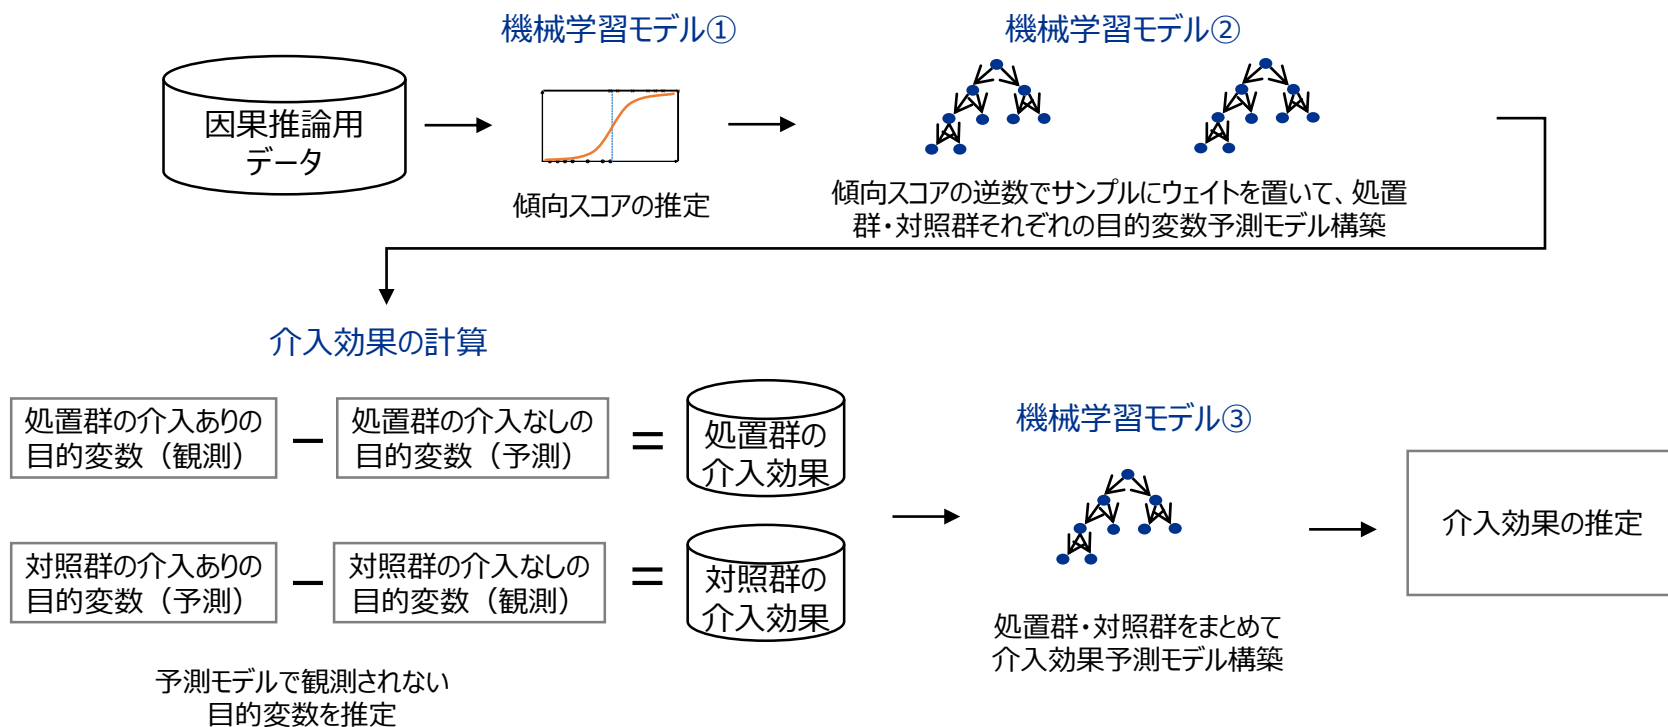
傾向スコア（介入が行われる確率）をサンプルの重みとして使用し、処置群の目的変数と、対照群の目的変数の平均を計算し、これらの差分をとることで介入の全体効果を推定する。



AIアルゴリズムの概説 [7/7]

■ DA-learner (Domain Adaptation Learner) を用いた分析

傾向スコア（介入が行われる確率）をサンプルの重みとして使用し、処置群の目的変数と、対照群の目的変数の予測モデルを構築する。観測できない目的変数を予測モデルで推定し、介入ありと介入なしの目的変数の差分のモデルを構築することにより個体効果を推定する。



7-1 研究会の概要・参加者・主な意見

7-2 本調査・研究におけるAIモデル構築数

7-3 AIアルゴリズムの概説

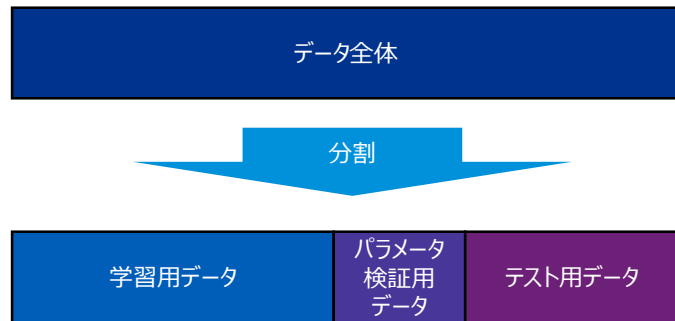
7-4 モデル構築におけるデータの分割の概説

7-5 AIモデルの評価指標の概説

モデル構築におけるデータの分割の概説

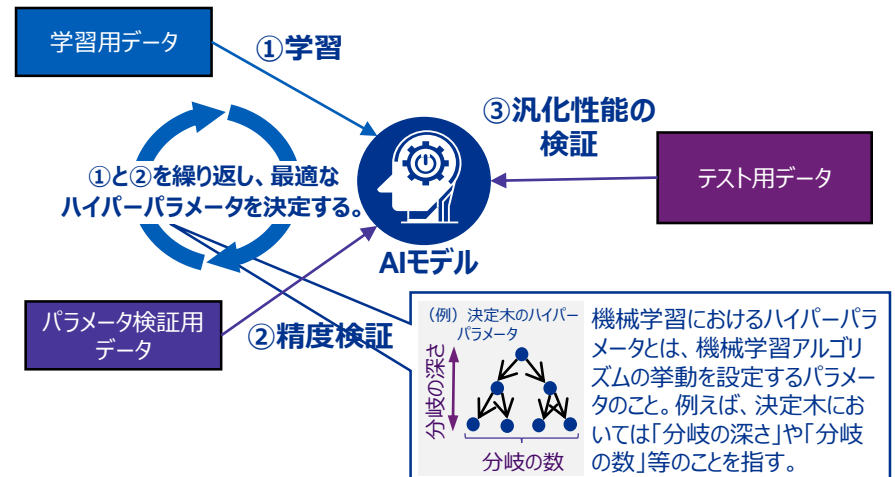
- モデル構築においては、ひとかたまりのデータを用途別に分割しておくことが一般的で、大別すると学習用データと、テスト用データに分割を行う。
- 機械学習モデルは、未知のデータに対して精度が悪化する「過学習」を起こしやすいため、モデルを構築した後に未知のデータで性能（汎化性能）を測る必要があり、学習用データを使用してモデルの構築を行い、未知のデータとしてテスト用データを使用してそのモデルの汎化性能を検証する。
（通常、未知のデータは目的変数の値（正解）が分からないため、既知データで構築したモデルを評価することが出来ないが、データの分割を行うことで目的変数の値（正解）を持った未知データとして扱うことが可能となる。）
- また機械学習モデルは、ハイパーパラメータのチューニングを行う必要があることから、チューニングによる精度検証を行うためのデータが必要になる。上記の学習用データとテスト用データに加えて、そのパラメータ検証用のデータも、ひとかたまりのデータから分割して作成する。

データの分割



※各データに分割する割合は、モデル構築の条件に合わせて都度決定する。

分割したデータを使ったモデル構築フロー



7-1 研究会の概要・参加者・主な意見

7-2 本調査・研究におけるAIモデル構築数

7-3 AIアルゴリズムの概説

7-4 モデル構築におけるデータの分割の概説

7-5 AIモデルの評価指標の概説

AIモデルの評価指標の概説 [1/2]

- 本資料にて示したAIモデルの評価指標である、適合率、再現率についての概説は以下の通り。

混同行列と評価指標

- 混同行列は、モデルでデータを分類した際にその正解・不正解をまとめた行列のこと。クラス分類を行うモデルの性能・精度の確認に使用される。

- 正例（ポジティブ）と負例（ネガティブ）の2クラスがあるデータセットに対して、以下が定義される。

- 真陽性（True Positive、TP）：実際にポジティブのデータを正しくポジティブと予測したもの（数）
- 偽陽性（False Positive、FP）：実際にはネガティブのデータを間違ってポジティブと予測したもの（数）
- 真陰性（True Negative、TN）：実際にネガティブのデータを正しくネガティブと予測したもの（数）
- 偽陰性（False Negative、FN）：実際にはポジティブのデータを間違ってネガティブと予測したもの（数）

		モデルの予測	
		1 (Positive)	0 (Negative)
実データの クラス	1 (Positive)	TP	FN
	0 (Negative)	FP	TN

- 上記で定義した混同行列の4つの数値を使用して、以下のような評価指標が計算される。


- 正解率(accuracy) = $\frac{TP+TN}{TP+FP+FN+TN}$ ・ 予測結果全体に対し正しく予測できたものの割合
- 適合率(precision) = $\frac{TP}{TP+FP}$ ・ ポジティブと予測したものに、実際にポジティブであるものの割合
- 再現率(recall) = $\frac{TP}{TP+FN}$ ・ 実際にポジティブのものに対し、正しくポジティブと予測できたものの割合

AIモデルの評価指標の概説 [2/2]

- 本資料にて示したAIモデルの評価指標である、AUC、AR値、CAP曲線についての概説は以下の通り。

ROC曲線とAUC


- モデルにデータを当てはめたとき、実際にイベント（「企業業績の低下」など、モデルによって検知する事象）が発生した全てのデータのうち、正しく検知ができた割合のことを、真陽性率（TPR）という。また、実際にイベントが発生しなかった全てのデータのうち、間違えて検知した割合を偽陽性率（FPR）という。
- 検知するかしないかは、モデルで推定されたイベント発生確率に対して閾値を設け、それを上回ったかどうかで判定しており、**ROC曲線**は、当該閾値を変更した際に変化するTPRとFPRをそれぞれ縦軸、横軸にプロットしたもので、下図のような曲線を描く。



- **AUC (Area Under the Curve)** は、ROC曲線の下部分の面積のことをいう。ROC曲線は、右にいくほど下がることはないこと、偽陽性率（横軸）が小さい段階で、真陽性率が高いモデルほど良いことから、AUC（上記面積）が大きいほど、優れたモデルであることを意味する。

CAP曲線とAR値

- **CAP曲線**は、横軸にモデルで推定されたイベント発生確率の上位 x 件の、全てのデータ件数 (N) に対する割合 (x/N) を、縦軸に推定されたイベント確率の高い上位 x 件のうち実際にイベントが発生した件数 (N_x) の、イベントが発生した全てのデータ件数 (N_1) に対する割合 (N_x / N_1) をプロットしたものであり、下図の**B**のような曲線を描く。
- モデルの説明力が全くない場合は **C** の直線を描き、予測が完全に正解したモデルの場合は **A** のような形を描く。



- BとCで囲まれた部分の面積の、AとCで囲まれた部分の面積に対する比を、**AR値**という。すなわち、値が1に近づくほど、予測が完全に正解したモデルに近いことを意味する。

$$\text{AR値} = \frac{\text{BとCで囲まれた部分の面積}}{\text{AとCで囲まれた部分の面積}}$$



ここに記載されている情報はあくまで一般的なものであり、特定の個人や組織が置かれている状況に対応するものではありません。私たちは、的確な情報をタイムリーに提供するよう努めておりますが、情報を受け取られた時点及びそれ以降においての正確さは保証の限りではありません。何らかの行動を取られる場合は、ここにある情報のみを根拠とせず、プロフェッショナルが特定の状況を綿密に調査した上で提案する適切なアドバイスをもとにご判断ください。

© 2023 KPMG AZSA LLC, a limited liability audit corporation incorporated under the Japanese Certified Public Accountants Law and a member firm of the KPMG global organization of independent member firms affiliated with KPMG International Limited, a private English company limited by guarantee. All rights reserved.



付属資料 研究会の資料・議事録

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 【第1回研究会資料】

2022年7月1日

有限責任 あずさ監査法人

委託元：金融庁

注：本報告書は、金融庁の委託により有限責任 あずさ監査法人が実施した調査結果を取りまとめたものである。有限責任 あずさ監査法人は、調査時点で入手した情報に基づき本報告書を適時に取りまとめるよう努めているが、本調査報告書の内容は、本調査の対象に含まれない特定の個人や組織が置かれている状況に対応するものとは限らず、また、情報を受け取った時点及びそれ以降において、その情報の正確性や完全性を保証するものではない。また、本報告書は委託者である金融庁に対してのみ提出したものであり、本報告書を閲覧あるいは本報告書のコピーを入手閲覧した第三者の本報告書の利用に対して、有限責任 あずさ監査法人は直接ないしは間接の責任を負うものではない。

Contents

	Page
1 本調査の背景・目的	3
2 現行の経営改善支援業務の理解	8
3 プロトタイプAI開発のコンセプトについて	12
4 プロトタイプAI開発に用いるデータについて	16
5 添付資料	24



1 本調査の背景・目的

2 現行の経営改善支援業務の理解

3 プロトタイプAI開発のコンセプトについて

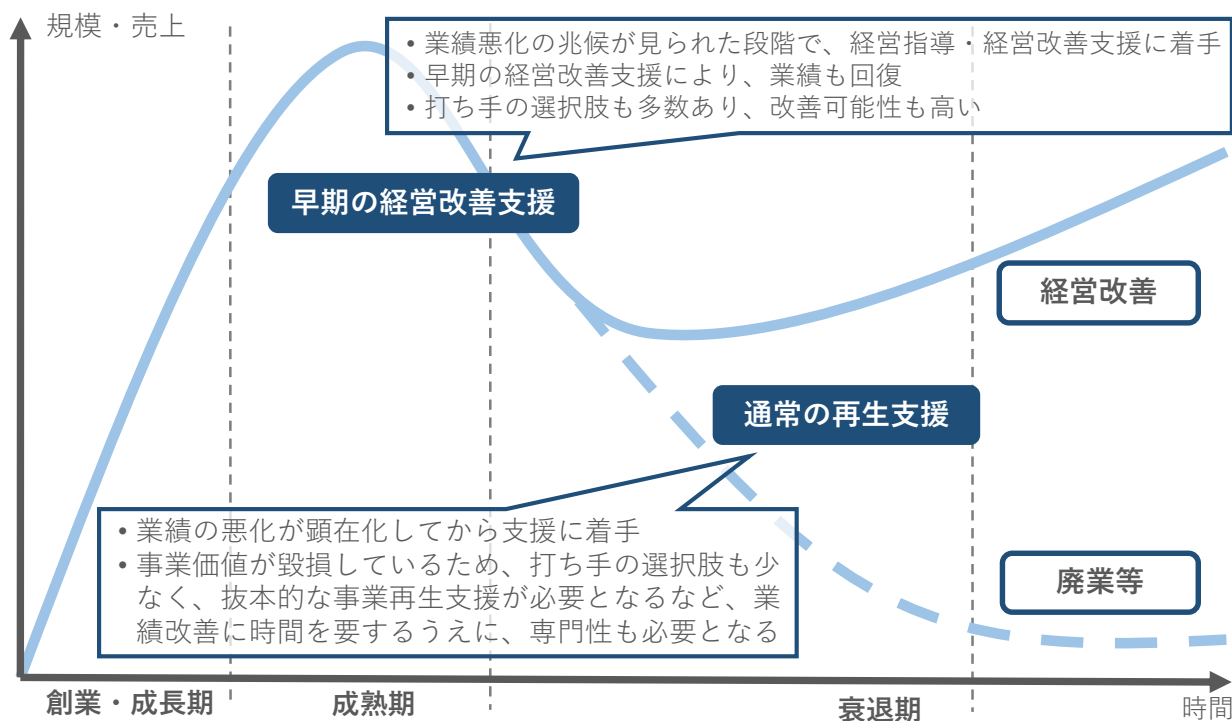
4 プロトタイプAI開発に用いるデータについて

5 添付資料

本調査・研究の背景・目的

- 新型コロナや、原油高等の影響もあり、過去の企業再生局面と比べても、金融支援や経営改善支援を必要とする事業者は多く、**経営改善・事業再生支援を効率的・効果的に実施していくことが必要**。
- 具体的には、**AI等のデジタル技術**を活用して、**業況悪化の兆候**が見られるような**経営改善支援が必要な先を発見し、早期の経営改善支援等を行う**ことで、事業者の経営改善・事業再生を促していくことを目指す。

■ 経営改善支援が必要な先の特定（早期発見）のイメージ



■ 自民党・金融調査会提言 (令和3年5月20日公表)

過去の企業再生局面と比べ、影響を受ける業種等は広範・幅広く、政府系ファンドや中小企業再生支援協議会等とも連携してノウハウ改善を進めることや、金融庁の「ノウハウ共有プロジェクト」等の再生支援の基盤を拡充していくことが必要である。加えて、**AIやICTを活用し、事業再生の能率的・効果的実施を図ることが出来ないか、業種等ごとに共通的・典型的な再生手法等を確立できないか、具体的な研究を早急に進めるべきである。**

■ 成長戦略フォローアップ (令和3年6月18日閣議決定)

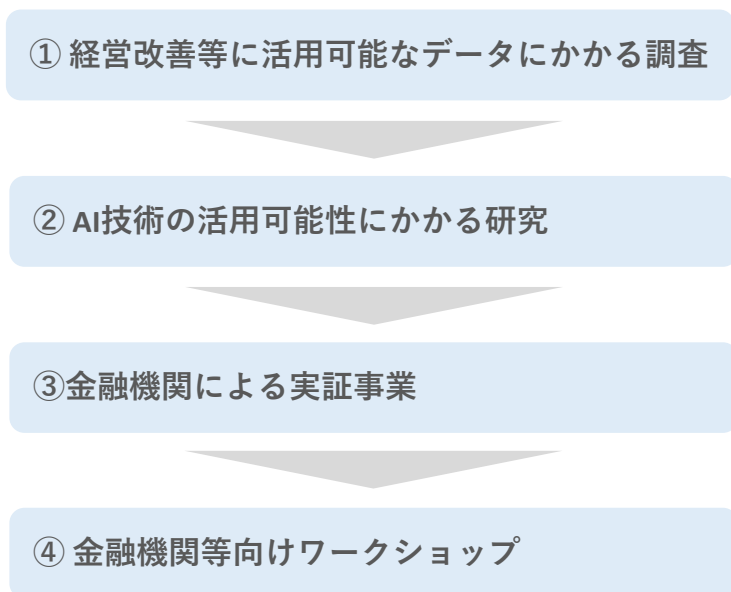
9. 足腰の強い中小企業の構築
- (1) 中小企業の事業継続と事業再構築への支援
 - ii) 事業再構築への支援
- 事業者支援を全国でかつ同時に進めるため、関係省庁において**AIやICTを活用した能率的で効果的な支援の方法や業種等ごとの共通的で典型的な事業再生の手法等の研究を行う。**

(出所) 金融庁監督局地域金融企画室「効果的・効率的な経営改善手法の検討」

本調査・研究の施策概要

- 令和4年4月1日より「AIやICTを活用した経営改善支援の効率化に向けた調査・研究」を開始。AI技術を活用し、財務データや外部環境データを機械学習等することで、**経営改善先を早期発見するモデルの構築**を目指す。
- 調査・研究の中では、**金融機関による実証事業**や**金融機関等向けのワークショップ**を行うとともに、**有識者等で構成される研究会を開催**することで、実効性を高めていく。

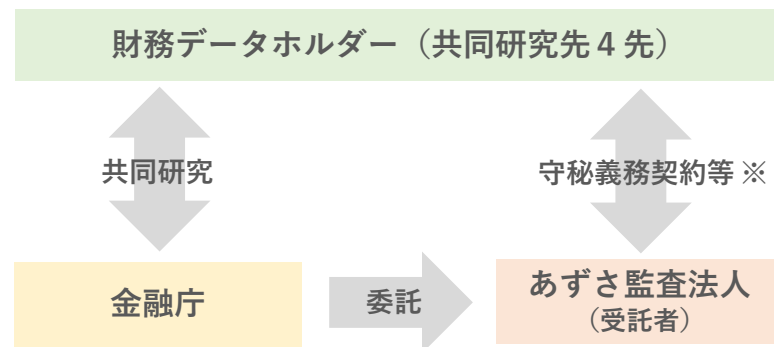
■ 委託事業の流れ



※各項目のスケジュールと主なタスク内容は次頁のとおり

(出所) 金融庁監督局地域金融企画室「効果的・効率的な経営改善手法の検討」(一部加筆)

■ 委託事業の体制



※：共同研究先・金融庁・あずさ監査法人の3社間覚書等の契約の場合もある。

本調査・研究のスケジュール

■ 本調査・研究の全体スケジュールと主なタスク内容は以下の通り。

	2022年									2023年		
	4月	5月	6月	7月	8月	9月	10月	11月	12月	1月	2月	3月
研究会 ワークショップ				▼研究会(1回目)	▼研究会(2回目)		▼研究会(3回目)			ワークショップ(1回目)▼ ワークショップ(2回目)▼	▼研究会(4回目)	
①経営改善等に 活用可能なデー タにかかる調査	①-1：現状の経営改善支援業務 の整理と課題抽出		①-2：データの調査・取得とデータ クレンジング									
②AI技術の活用 可能性にかかる 研究			②-1：AI 技術を活 用したプロ トタイプの 要件定義	②-2：AI技術を活用したプロトタイプの開発			②-3：AI技術を用いた新たな業務 フローの基礎検討		②-4：実用化に向けたUIの 基礎検討			
③金融機関によ る実証事業							③：金融機関による実証事業					
④金融機関等向 けワークショップ										④：ワーク ショップの 開催		

研究会における予定議題

- 本日の研究会の議題、今後の研究会にて予定している議題は以下のとおり。

開催回	開催時期	議題（予定）
第1回 （今回）	本日	<ul style="list-style-type: none"> ■ 現行の経営改善支援業務の理解 <ul style="list-style-type: none"> ・ 現行の経営改善支援業務フローの確認 ・ 現行の経営改善支援業務の課題認識 ・ AI技術を用いた新しい経営改善支援業務フロー案 ■ プロトタイプAI開発のコンセプトについて <ul style="list-style-type: none"> ・ 本調査・研究の目的を踏まえたAI開発のコンセプト ・ AIアルゴリズム候補について ■ プロトタイプAI開発に用いるデータについて <ul style="list-style-type: none"> ・ プロトタイプAIモデル構築のためのデータ母集団と目的変数（教師ラベル）の定義について ・ 外部環境データについて <p>※議論いただきたい事項の詳細につきましては、別添資料（「AIを活用した経営改善支援に係る研究会」（第1回）における議題）に記載しております。</p>
第2回	2022年8月下旬（予定）	<ul style="list-style-type: none"> ■ 共同研究先データの処理内容（クレンジング方法、対象の絞り込みなど） ■ プロトタイプAIモデルの第1版の提示とその内容にかかる意見招請
第3回	2022年10月下旬（予定）	<ul style="list-style-type: none"> ■ 第2回研究会を踏まえたプロトタイプAIモデルの開発結果報告
第4回	2023年2月下旬（予定）	<ul style="list-style-type: none"> ■ 金融機関における実際のデータを用いた検証の結果報告 ■ 本調査・研究の取りまとめ、今後の課題整理



1 本調査の背景・目的

2 現行の経営改善支援業務の理解

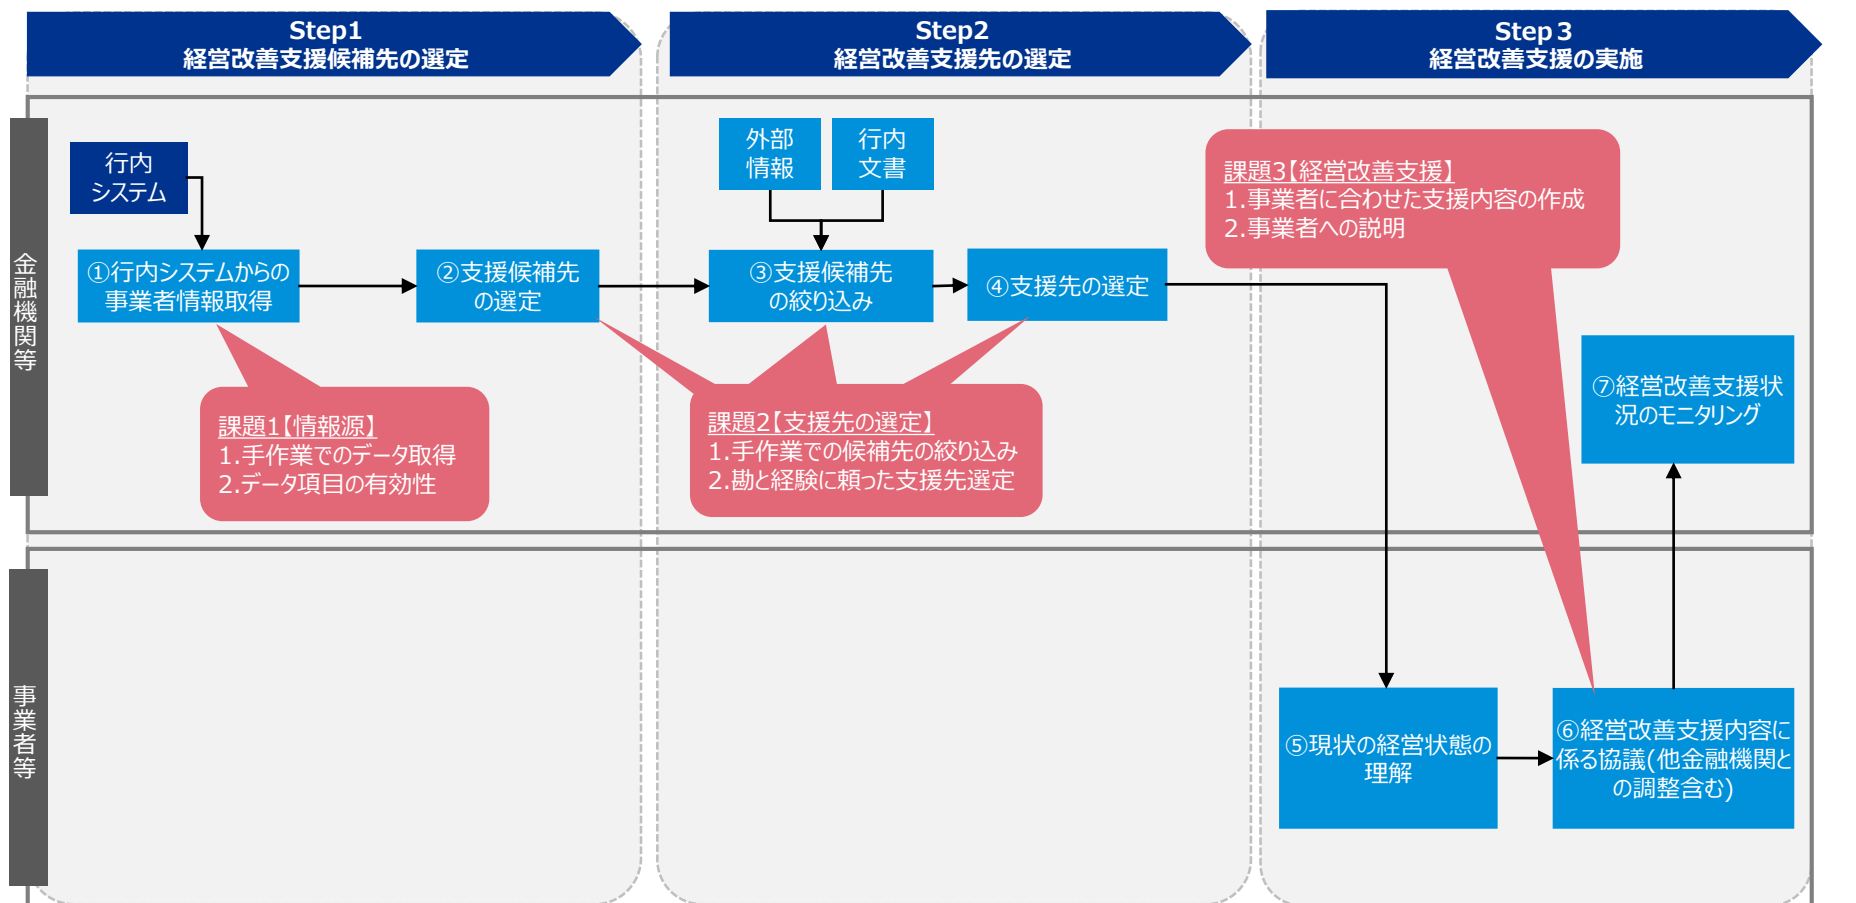
3 プロトタイプAI開発のコンセプトについて

4 プロトタイプAI開発に用いるデータについて

5 添付資料

現状の経営改善支援業務の整理と課題抽出 [1/2]

■ 現状の経営改善支援の業務フロー及び業務上の課題（仮説）は以下の通り。



■ : システム □ : 人のマニュアル作業

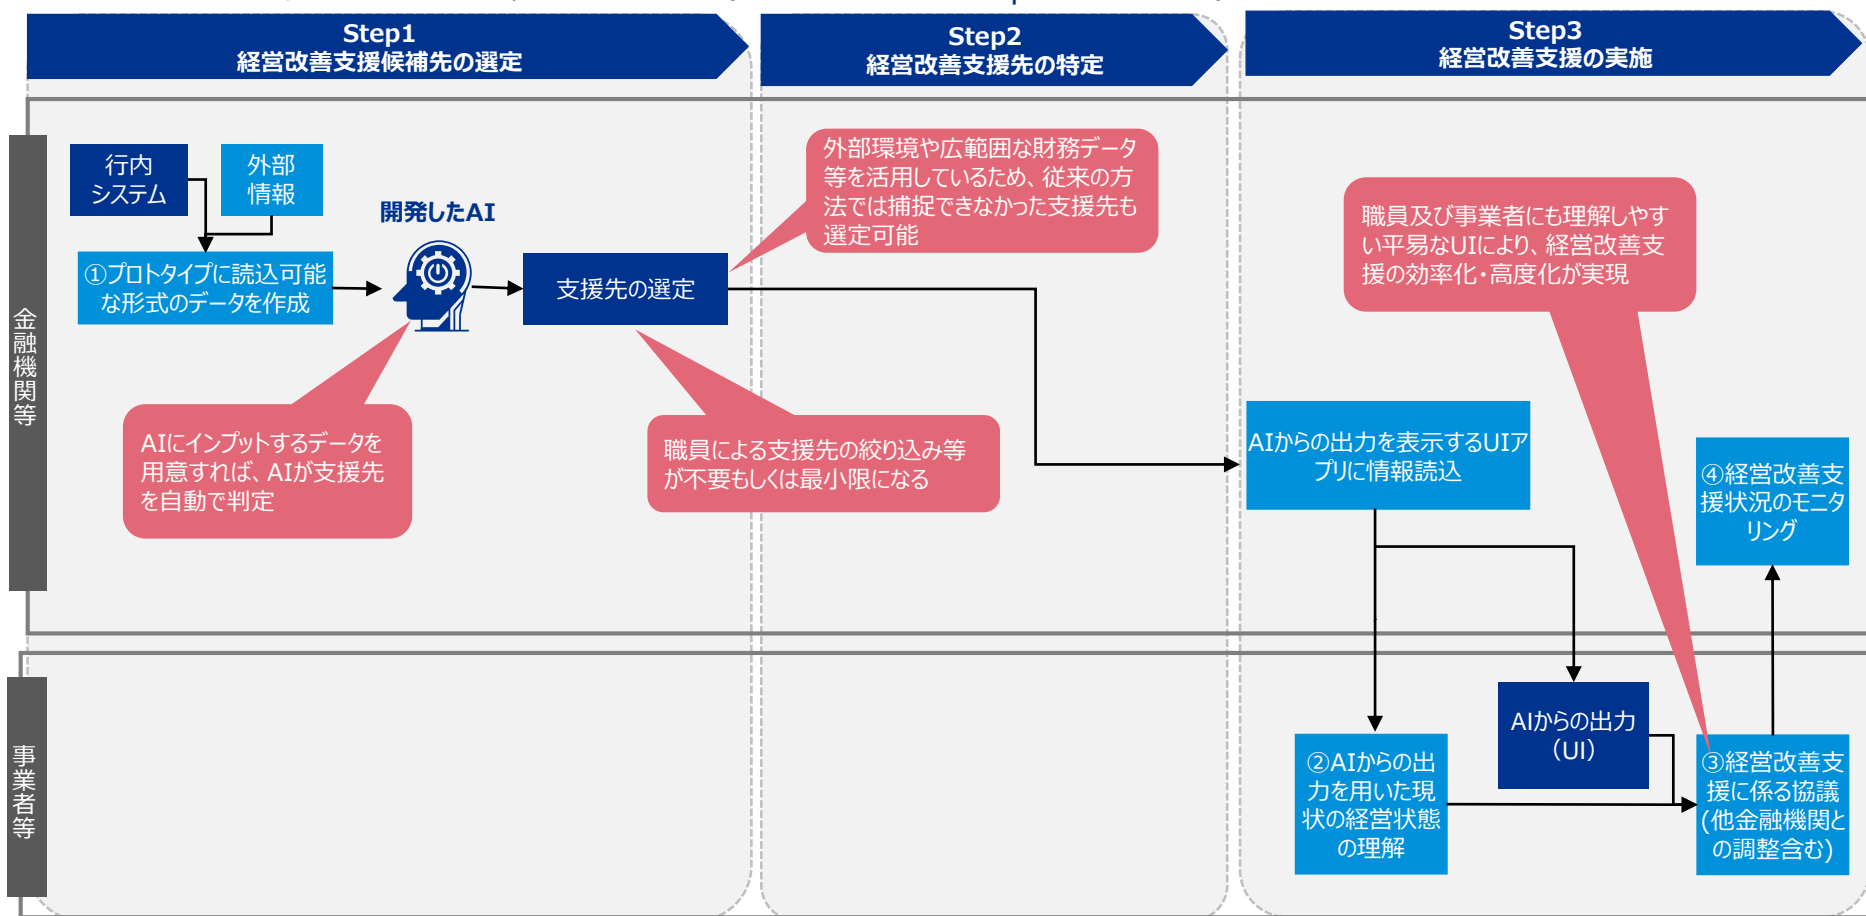
現状の経営改善支援業務の整理と課題抽出 [2/2]

■ 現状の経営改善支援業務の課題と当該課題の改善方向性（仮説）は以下の通り。

課題No	課題（仮説）	課題の概要（仮説）	改善の方向性（仮説）
課題1 【情報源】	1-1 手作業でのデータ取得	<ul style="list-style-type: none"> 職員が手作業で支援候補先の抽出に必要なデータを取得しており、業務負荷が高い 	<ul style="list-style-type: none"> 支援候補先の選定に有効なデータを自動で取得したうえで、個別のデータ項目が、支援候補先の選定にどの程度寄与しているかを算定する
	1-2 データ項目の有効性	<ul style="list-style-type: none"> 勘と経験に基づき限られたデータ項目を抽出しているため、支援候補先の抽出に有効なデータ項目となっているかの検証が困難 	
課題2 【支援先の選定】	2-1 手作業での候補先の絞り込み	<ul style="list-style-type: none"> 支援候補先を抽出した後、行内システムや外部からの情報等も組み合わせて支援候補先を絞り込んでおり、業務負荷が高い 	<ul style="list-style-type: none"> 過去の経営改善支援の実績データや外部情報、企業の財務データ等に基づき支援先を自動で選定 定量的・科学的なアプローチ（AI技術）を導入することで、支援先の選定結果の事後検証と、結果を踏まえた選定基準見直し（AIの再学習等）といった改善活動を実施できる
	2-2 勘と経験に頼った支援先選定	<ul style="list-style-type: none"> 最終的には、勘と経験に基づき経営改善支援先を特定しており、真に経営改善支援が必要な先を抽出できているかの（事後）検証が困難 	
課題3 【経営改善支援】	3-1 事業者に合わせて支援内容の作成	<ul style="list-style-type: none"> 経営改善支援先の選定後に、別途手作業等で分析した情報などをもとに、経営改善支援策の作成を行っており、業務負荷が高い 	<ul style="list-style-type: none"> 経営改善支援先として選定された要因や改善のポイントを規模別・業種別等で自動的に抽出する
	3-2 事業者への説明	<ul style="list-style-type: none"> 網羅的な情報に基づき分析を行っていないため、事業者に対して納得感のある説明が困難 	

AI技術を用いた新たな業務フローの基礎検討

■ AI技術活用後の経営改善支援の業務フロー（仮説）は以下の通り（Step2は不要になる）。





1 本調査の背景・目的

2 現行の経営改善支援業務の理解

3 プロトタイプAI開発のコンセプトについて

4 プロトタイプAI開発に用いるデータについて

5 添付資料

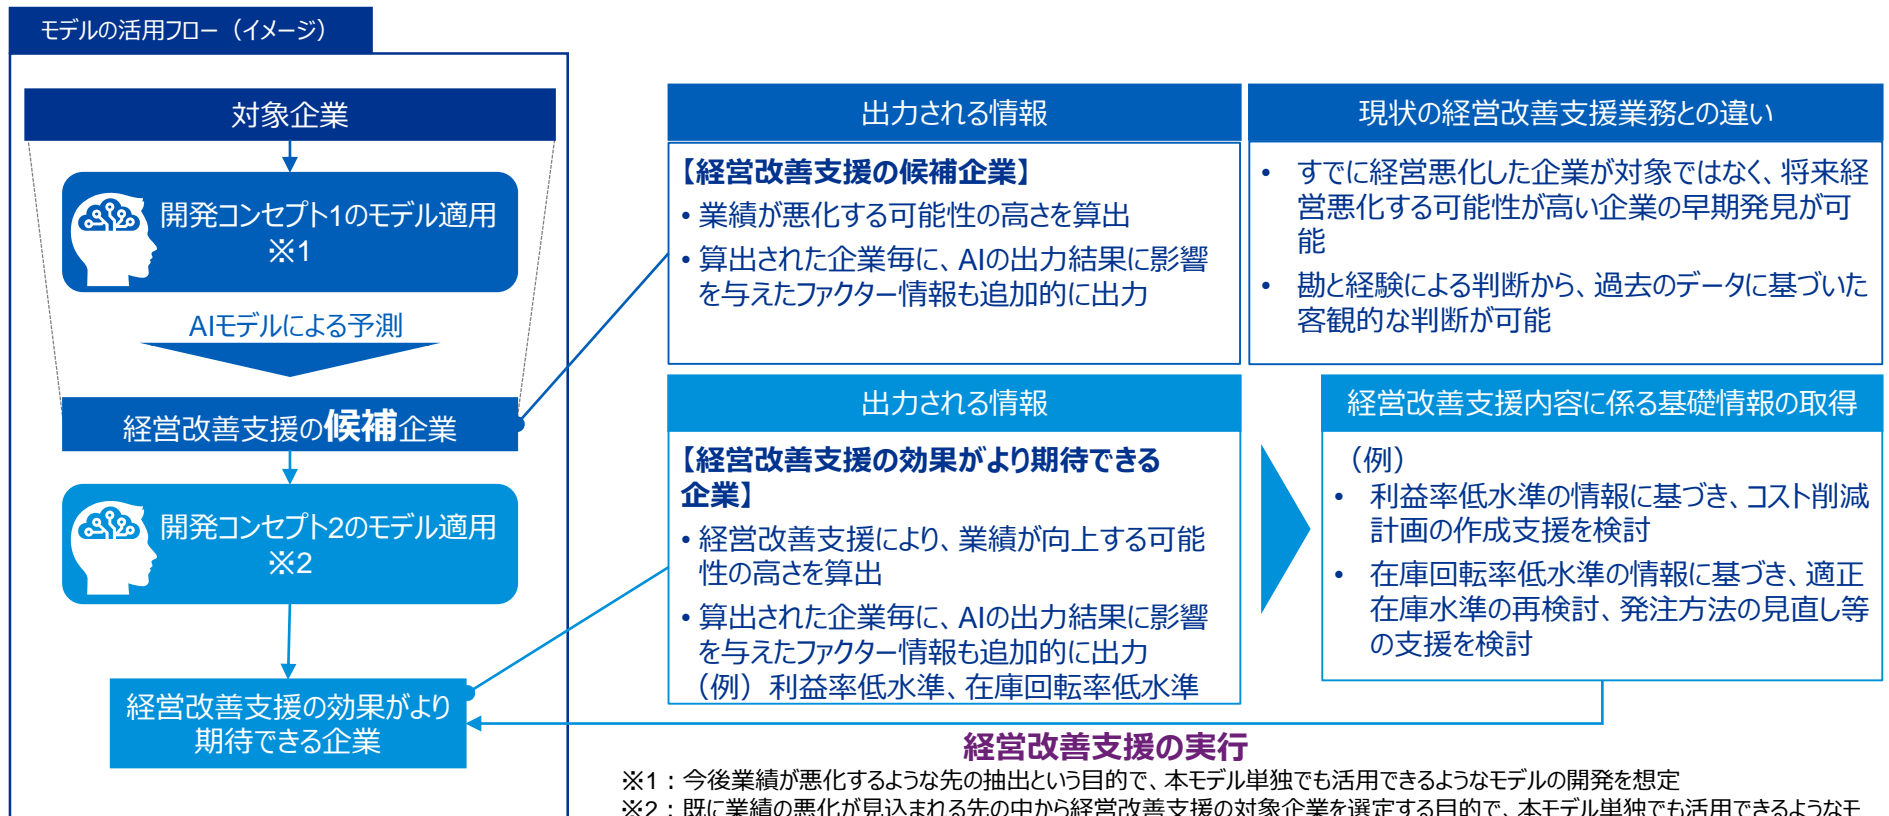
AIモデル（プロトタイプ）の開発コンセプトの検討 [1/2]

- 本調査・研究にて開発するAIモデル（プロトタイプ）の目的は、「経営改善支援が必要な先の特定（早期発見）」である。
- 本目的を達成し得るAIモデルの開発コンセプトととして、2つの方法が想定されるため、下表にて整理した。
- 本調査・研究では下表の2つの開発コンセプトを満たすAIモデルの開発（まずはBasicモデルに着手）を検討していきたい。

#	開発コンセプト	モデル構築の母集団		構築したモデルを当てはめる企業
		学習データの対象	モデルによって検知する事象	
1	<p>【Basic】業績低下の可能性が高い企業の特定</p> <p>現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル</p>	一定期間内において業績が悪くはない企業	一定期間経過後に、業績が低下する企業	学習データの対象となる企業（ただし時点が学習データより新しい等により学習データには含まれない企業）
2	<p>【Advanced】経営改善支援により業績が向上する企業の特定</p> <p>現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル</p>	一定期間内において経営改善支援の候補となりえる業況にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）	一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業	同上

AIモデル（プロトタイプ）の開発コンセプトの検討 [2/2]

- 開発コンセプト1と開発コンセプト2を経営改善支援業務に活用した場合のフローイメージは左下の通り。
- 開発コンセプト1によって「経営改善支援が必要な先の特定（早期発見）」、開発コンセプト2によって「経営改善支援の効果がより期待できる企業の特定」と、「経営改善支援内容に係る基礎情報の取得」が可能となるよう検討を進める。



AIアルゴリズム候補

- 開発コンセプト1については、予測のアルゴリズム（ロジスティック回帰・ランダムフォレスト・勾配ブースティング・多層パーセプトロン）を候補とする。開発コンセプト2については、因果推論のアルゴリズム（Meta-Learners）を候補にするほか、経営改善支援の実施有無データの入手状況等に応じて、予測のアルゴリズムも候補として検討する。
- 下表にて整理した、各アルゴリズムに対する精度・解釈性・計算負荷・業界での利用実績を軸とした評価、アルゴリズムの特徴、モデル構築の難易度を踏まえて、構築するモデルのAIアルゴリズムを選定する。

開発コンセプト	手法	アルゴリズム名	アルゴリズムの概説	アルゴリズムの評価（開発コンセプト1） / アルゴリズムの特徴（開発コンセプト2）				モデル構築の容易さ
				精度	解釈性	計算負荷	業界での利用実績	
開発コンセプト1	予測	ロジスティック回帰	ロジスティック曲線を用いて、目的変数を回帰分析の手法で予測する方法。金融機関実務において企業の信用力評価に最も活用されている方法。	△	◎	◎	◎	◎
		ランダムフォレスト	多くの決定木（学習データを条件分岐によって分割していくことで分類問題を解く手法）モデルを構築し、多数の決定木の予測値の平均値を最終的な予測値とする方法。	○	○	○	○	○
		勾配ブースティング	決定木を構築し、当該決定木が外したサンプルに当てはまるようにウェイトを調整して、次の決定木を構築する。これを繰り返して最終的な予測値とする方法。	○	○	○	○	○
		多層パーセプトロン	複数の入力値に対し、それぞれ調整した重みをかけて出力値を計算し、その結果を用いて分類する方法。	◎	△	△	△	△
開発コンセプト2	予測	開発コンセプト1と同様にロジスティック回帰、ランダムフォレスト、勾配ブースティング、多層パーセプトロンをアルゴリズムの候補とする。						○
	因果推論	Meta-Learners ※	因果推論を行うための論理フローの各ポイントに主要な機械学習アルゴリズム（ロジスティック回帰、ランダムフォレスト等）を適用し、介入効果を推定する方法。	<ul style="list-style-type: none"> データの特性に合わせて機械学習アルゴリズムを選択することができる。 データの不均衡性に対応できる手法もある。 				△

※：個別企業への因果効果を推定するために、機械学習を用いた因果推論のアルゴリズムを候補とした。



1 本調査の背景・目的

2 現行の経営改善支援業務の理解

3 プロトタイプAI開発のコンセプトについて

4 プロトタイプAI開発に用いるデータについて

5 添付資料



4-1 プロトタイプAI開発に用いるデータについて (財務データ)

個社単位の財務データ等に係る要件

■ 入手可能性を鑑みて、下表で整理したデータの全部もしくは一部を用いてAIを開発していく想定である。

種類	単位	要件	間隔/期間	項目（例）
企業属性データ	個社単位データ	<ul style="list-style-type: none"> 基本情報、企業の性質や特徴を表す内容を含むデータであること 店番・CIF番号などの企業を一意に特定するコードを持つこと （顧客情報保護の観点から既存コードがマスキングされることは問われないが、下記データ等と紐づけ可能なコードとなっていること） 最新の属性が反映されたデータであることが望ましい 	— (最新一時点のデータ)	企業特定コード、業種、業歴（事業年数等）、従業員数、所在地 等
財務データ		<ul style="list-style-type: none"> 財務諸表のうち、貸借対照表と損益計算書における各項目の値を含むデータであること 企業属性データとコード等で紐づけることができること 決算年月日とその時点の財務情報が分かること 	間隔：年次、半期、四半期、月次など 期間：過去5年以上あることが望ましい	企業特定コード、決算年月日、流動資産、固定資産、資本金、売上高、営業利益、経常利益、当期利益 等
企業の業況関連データ		<ul style="list-style-type: none"> 企業属性データとコード等で紐づけることができること 企業属性および財務データ以外で企業の業況や経営状態が分かるデータ（例：債務者区分） 	間隔：格付実施期間ごと 期間：過去5年以上あることが望ましい	企業特定コード、基準年月日、債務者区分、延滞開始年月、延滞の回数 等
経営改善支援の実施有無データ	個社単位データ	<ul style="list-style-type: none"> 企業属性データとコード等で紐づけることができること 経営改善支援実施時期が分かること 	期間：過去5年以上あることが望ましい	企業特定コード、支援開始時期、支援終了時期、支援内容 等

学習データと教師ラベルの定義（案）

■ 開発コンセプト1

開発コンセプト	現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル	学習データの対象	一定期間内において 業績が悪くはない企業	モデルによって検知する事象（教師ラベル）	一定期間経過後に、 業績が低下 する企業
案	学習データの定義 【業績が悪くはないの定義（案）】	教師ラベルの定義 【業績が低下の定義（案）】	補足 【信用力の序列情報】		
①	「信用力の序列情報」が一定程度以上（債務者区分が要注意先以上など）	「信用力の序列情報」が一定程度以下に遷移（債務者区分が要管理先以下に下方遷移など）	共同研究先毎に以下の情報を使用 <ul style="list-style-type: none"> 債務者区分 信用スコア 他の共同研究先データから推測した債務者区分や信用スコア（検討事項） 		
②	財務指標（信用リスク管理等の観点から既に重要と認識している指標）が一定の範囲内	財務指標が一定の範囲より低下			

■ 開発コンセプト2

開発コンセプト	現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル	学習データの対象	一定期間内において 経営改善支援の候補となりえる業況 にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）	モデルによって検知する事象（教師ラベル）	一定期間経過後、実際に 経営改善支援を受けて、業績が向上 した企業
案	学習データの定義 【経営改善支援の候補となりえる業況の定義（案）】	教師ラベルの定義 【業績が向上の定義（案）】	補足 経営改善支援を受けた先の定義(案)		
①	「信用力の序列情報」が一定程度以下（債務者区分が要管理先以下など）	「信用力の序列情報」が一定程度以上に遷移（債務者区分が、要注意先以上に上方遷移など）	共同研究先毎に以下の情報を使用 <ul style="list-style-type: none"> 「経営改善支援の候補となりえる業況」となった以降に、経営改善支援が実践された 経営改善支援の実施有無の情報を保有していない場合、本条件は課さない想定 		
②	過去一定期間の「信用力の序列情報」が当該時点よりも悪化する水準に遷移（債務者区分が、正常先から要注意先、要注意先から要管理先に下方遷移したなど）	「信用力の序列情報」がある時点からより良好な水準へ遷移（債務者区分が、要管理先から要注意先、要注意先から正常先など上方遷移したなど）			



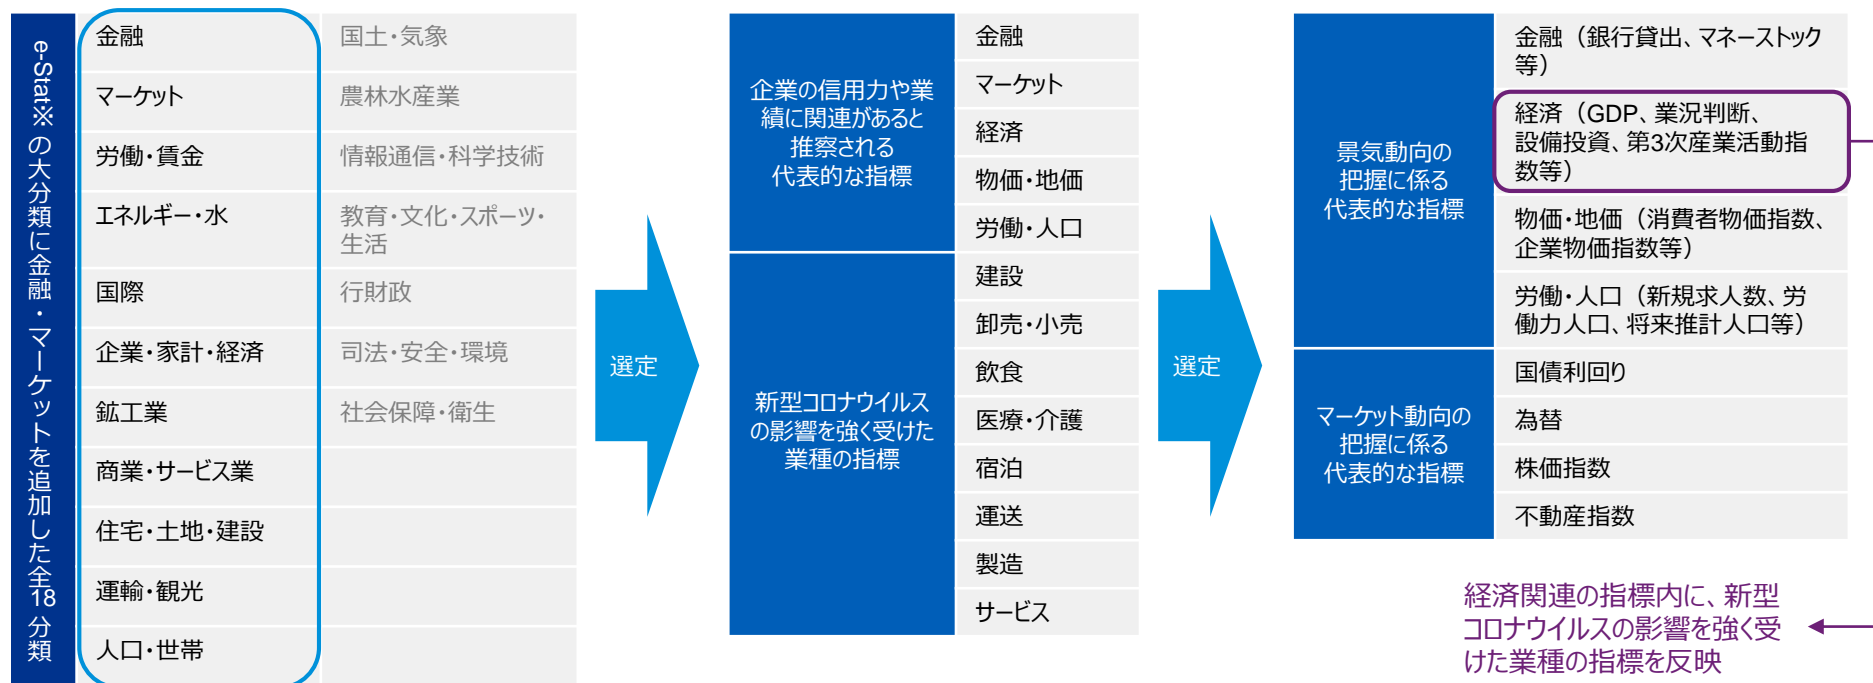
4-2

プロトタイプAI開発に用いるデータについて
(外部環境データ)

外部環境データの整備

– 外部環境データ候補の選定

- 本調査・研究ではモデルの予測対象として、新型コロナウイルス下における企業の信用力や業績の変化を検知することを想定している。そのため個社単位の属性や財務データ以外に、企業の信用力や業績との関連があることが推察されるマクロ経済情報や、新型コロナウイルスの影響を強く受けた業種に係るデータを外部環境データとして採用する。
- 各府省が公表する統計データや日本銀行のオープンデータから、本調査・研究の目的を踏まえて下図の通り外部環境データ候補を選定した。



※e-Statとは、「政府統計の総合窓口」のことであり、各府省が公表する統計データを一つにまとめ、統計データの検索をはじめとした、さまざまな機能を備えた政府統計のポータルサイト

外部環境データの整備

－ 分析対象とする外部環境データ候補

- 具体的に想定している外部環境データ候補は以下のとおり。
- 下表以外の業界別事業再生事典※1、業種別審査事典※2に記載されている指標についても有用であると考えているが、業種別に詳細な情報であるため分析過程で業種・業界別の分析が必要になった際に活用する。

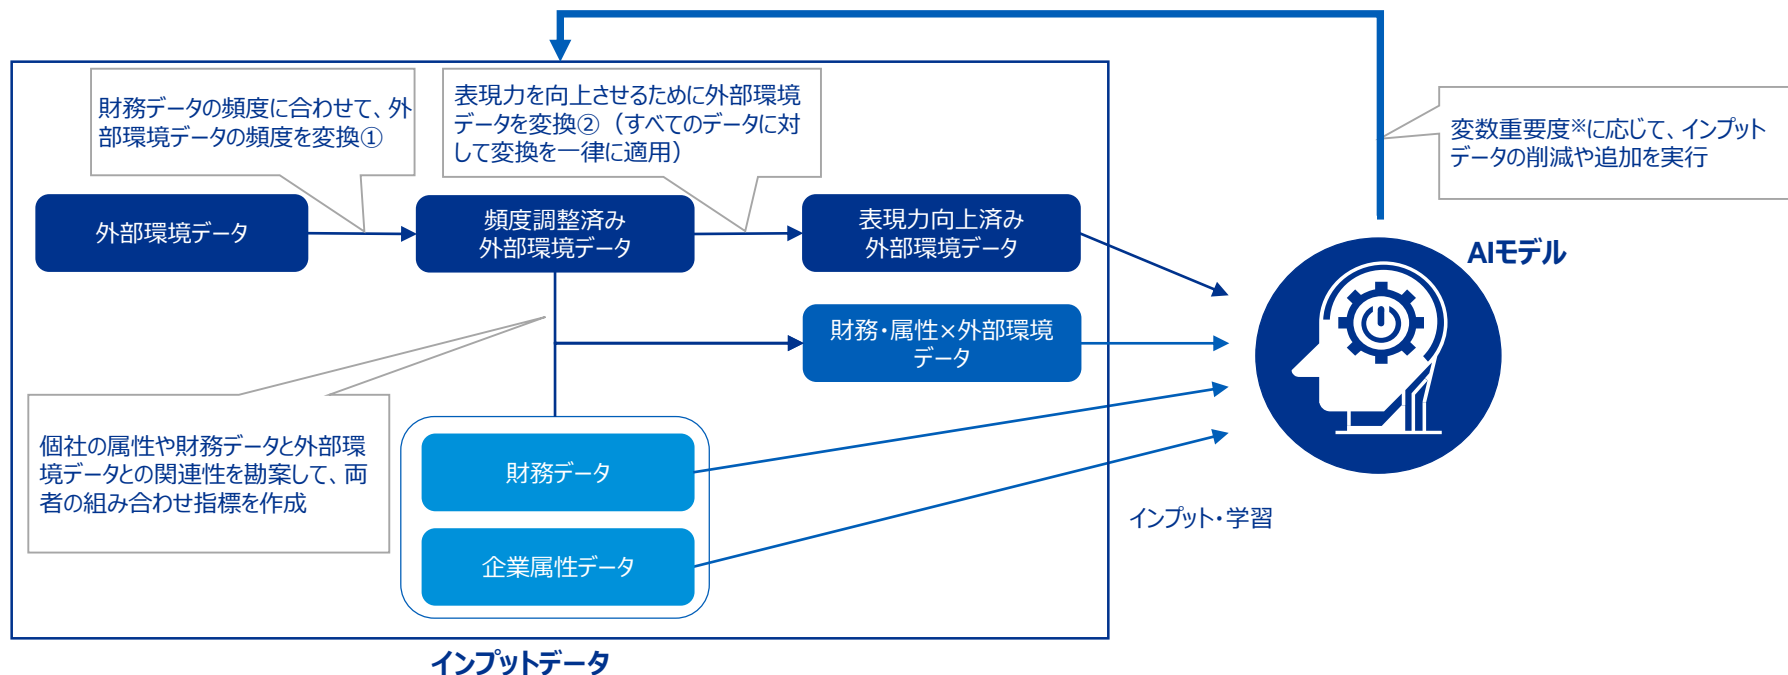
種類	マーケット関連データ	経済関連データ	金融関連データ	物価・地価関連データ	労働・人口関連データ
項目名	<ul style="list-style-type: none"> 為替レート 無担保コールO/Nレート 国債利回り TOPIX 日経225 東証REIT指数 Dow Jones Total Stock Market Index 	<ul style="list-style-type: none"> GDP成長率 業況判断DI 景気動向指数 中小企業売上見通しDI 発電実績 エネルギー消費量 入港船舶の総トン数 公共機関からの受注工事額 新設建築物（住宅）床面積、工事予定額 商業販売額 客室稼働率、宿泊者数 訪日外国人数 貨物・旅客輸送量 鉱工業生産・出荷・在庫指数 製造工業生産能力・稼働率指数、予測指数 機械受注額 第3次産業活動指数 	<ul style="list-style-type: none"> 貸出約定平均金利 総貸出平残 マネタリーベース マネースtock 倒産件数 倒産負債総額 	<ul style="list-style-type: none"> 消費者物価指数 消費者態度指数 企業物価指数 企業向けサービス価格指数 WTI原油価格 地価 	<ul style="list-style-type: none"> 完全失業率 労働力人口 常用雇用指数 新規求人数 有効求人倍率 将来推計人口 住民基本台帳人口

※1 『業界別事業再生事典』 一般社団法人金融財政事情研究会
 ※2 『業種別審査事典』 一般社団法人金融財政事情研究会
 ※3 下線は新型コロナウイルスの影響を強く受けた業種に係る指標データ
 ※4 別紙「外部環境データ候補一覧」備考欄に地域別、業種別の指標データとして活用する指標を記載

外部環境データの整備

– 外部環境データ使用方法（概要）

- 財務データの頻度は年次が想定されるが、外部環境データの頻度は年次だけでなく、日次や月次、四半期も存在する。そのためモデルへのインプットの前に財務データの頻度に合わせて外部環境データの頻度を変換する。
- 頻度の変換後、モデルインプット時の外部環境データの表現力を向上させるための変換を行う。
- さらに、個社の属性や財務データと外部環境データを組み合わせて作成する指標も重要であることから、今後分析を進める上で当該指標の詳細を検討していく。



※ 変数重要度とはインプットデータが目的変数の予測にどれくらい寄与しているかを測る指標



1 本調査の背景・目的

2 現行の経営改善支援業務の理解

3 プロトタイプAI開発のコンセプトについて

4 プロトタイプAI開発に用いるデータについて

5 添付資料

実用化に向けたUIイメージ [1/2]

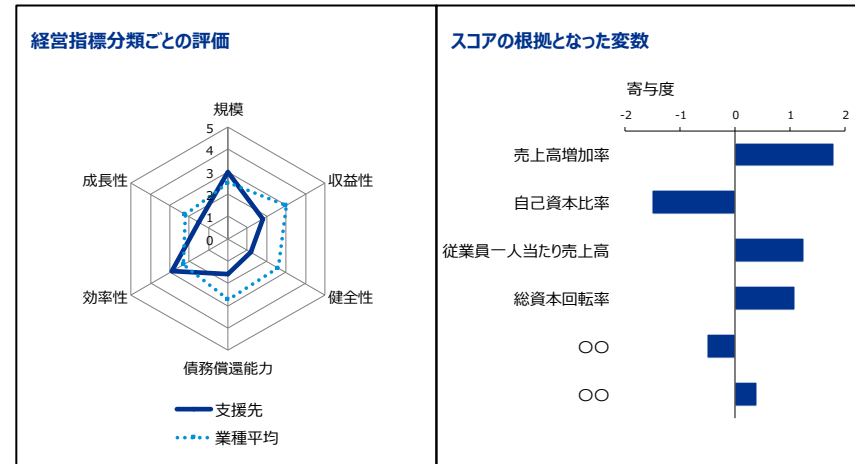
～開発コンセプト1のUIイメージ～

- 支店職員および事業者が利用可能なユーザーインターフェースのイメージ（事務局の仮説）は以下の通りである。
- 当イメージは、開発コンセプト1のモデルの出力を想定したものである。

【プロトタイプ^①の出力を説明するユーザーインターフェース（イメージ）】 （開発コンセプト1のモデルの出力を想定）

法人名		顧客口座番号	ID	作成日		年月日		
〇〇〇〇〇〇		11112222	123456789	〇〇駅前店				
基本情報				他社からの借入れ状況				
所在地		借入先	借入日	借入金額				
業種	〇〇業	〇〇〇〇	〇〇年〇日	〇〇〇万円				
貸付日	〇〇年〇月〇日							
貸付金額	〇〇〇〇万円							
利率	〇.〇〇%							
資本金	〇〇〇万円							
従業員数	〇人							
主要な経営指標								
分類	指標名	データ	業種平均	分類	指標名	データ	業種平均	
規模	売上高	〇〇	〇〇	債務償還能力	債務償還年数	〇〇	〇〇	
収益性	従業員1人当り売上高	〇〇	〇〇	効率性	総資本回転率	〇〇	〇〇	
健全性	自己資本比率	〇〇	〇〇	成長性	売上高増加率	〇〇	〇〇	

AIモデルスコアの評価												
スコア一覧	低	0	1	2	3	4	5	6	7	8	9	高
スコア	6.8											



実用化に向けたUIイメージ [2/2]

～開発コンセプト2のUIイメージ～


- 支店職員および事業者が利用可能なユーザーインターフェースのイメージ（事務局の仮説）は以下の通りである。
- 当イメージは、開発コンセプト2のモデルの出力を想定したものである。

【プロトタイプ®の出力を説明するユーザーインターフェース（イメージ）】 （開発コンセプト2のモデルの出力を想定）

法人名		顧客口座番号	ID	作成日 年 月 日		担当支店
〇〇〇〇〇〇		11112222	123456789	〇〇年〇月〇日		〇〇駅前店
基本情報			他社からの借入れ状況			
所在地	〇〇業		借入先	借入日	借入金額	
業種	〇〇業		〇〇〇〇	〇〇年〇日	〇〇〇万円	
貸付日	〇〇年〇月〇日					
貸付金額	〇〇〇〇万円					
利率	〇.〇〇%					
資本金	〇〇〇万円					
従業員数	〇人					

優先順位の高いと思われる改善箇所（スコアの要因のうちマイナスの値が大きいもの）				
指標名	当該企業データ	業種平均	同業種上位〇〇%平均	当該企業スコアでの寄与度
棚卸資産回転期間	〇〇	〇〇	〇〇	〇〇
有利子負債比率	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇
〇〇	〇〇	〇〇	〇〇	〇〇


AIモデルスコアの評価										
スコア一覧	経営改善の可能性【確度】									高
	低	0	1	2	3	4	5	6	7	
スコア	1.5									



AIアルゴリズムの概説 [1/5]

■ ロジスティック回帰の概説

下図のようなロジスティック曲線を用いて、目的変数を回帰分析の手法で予測する方法。金融機関実務において企業の信用力評価に最も活用されている方法。



$$Z = \alpha_0 + \beta_1 X_1 + \beta_2 X_2 + \dots$$

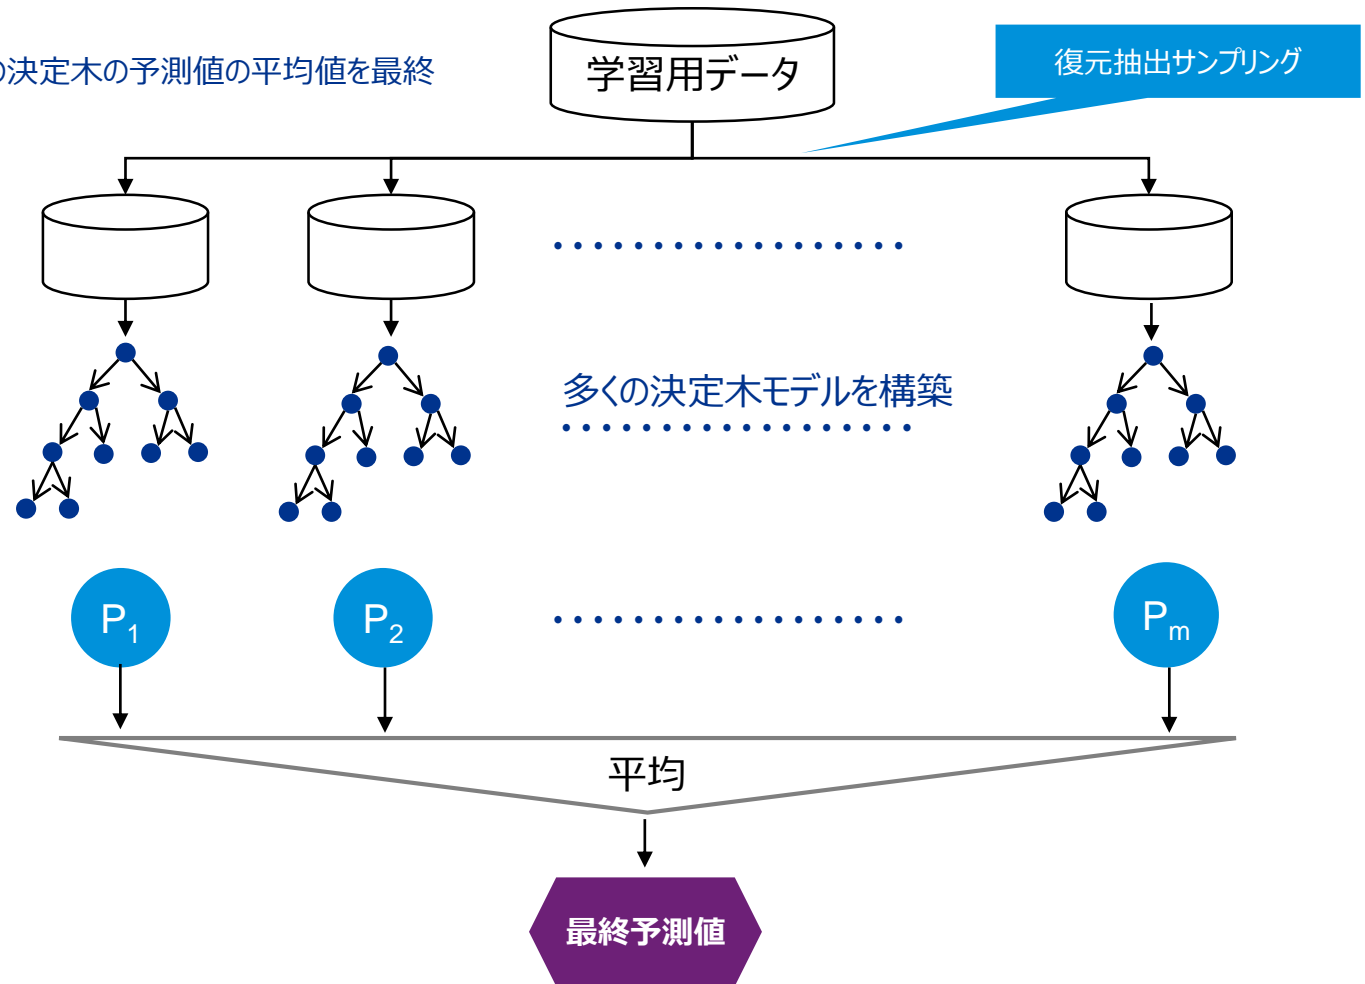
X_i : i 番目の説明変数 (特徴量)

α_0 、 β_i : 切片および回帰係数

AIアルゴリズムの概説 [2/5]

■ ランダムフォレストの概説

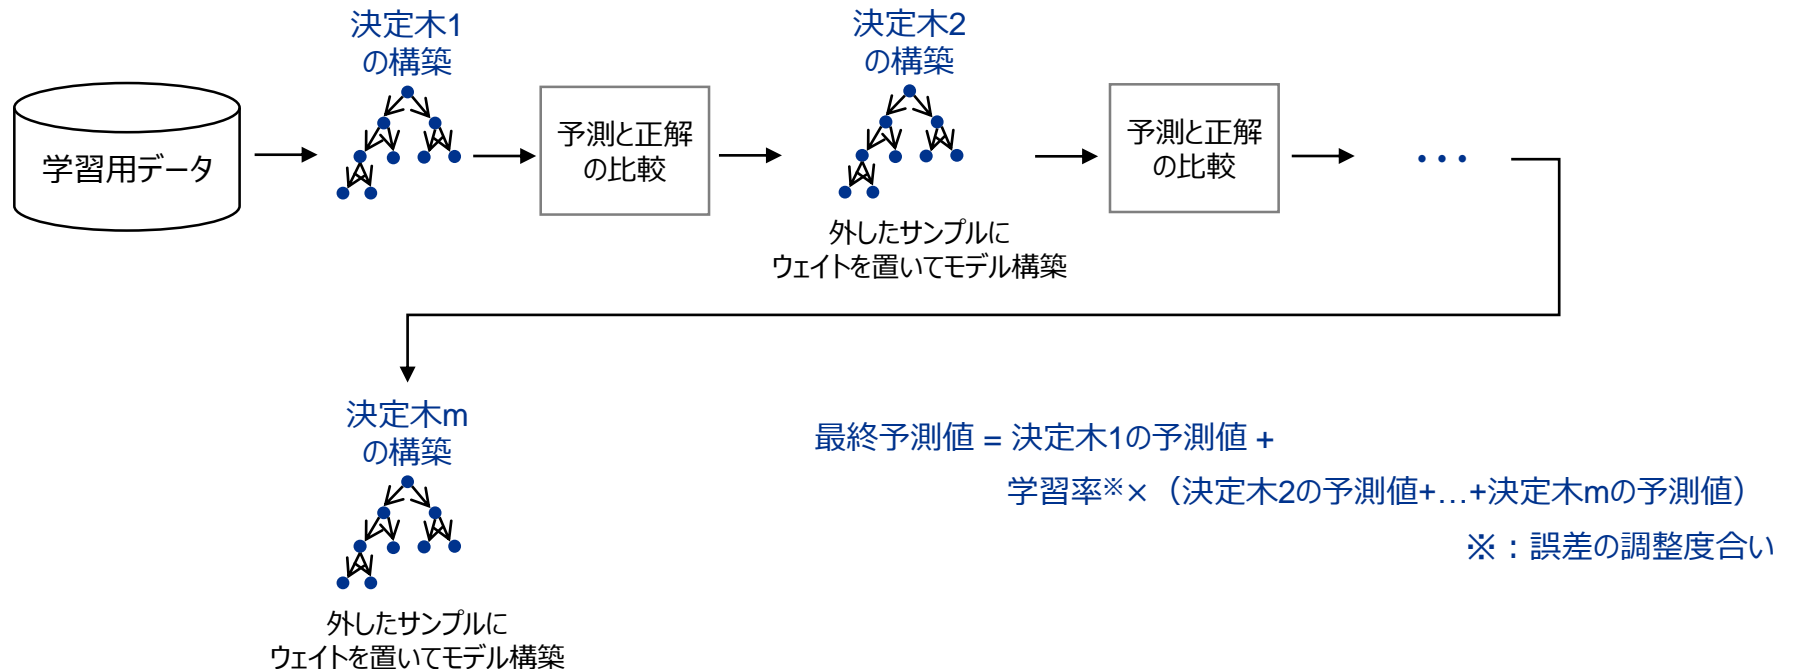
多くの決定木モデルを構築し、多数の決定木の予測値の平均値を最終的な予測値とする方法



AIアルゴリズムの概説 [3/5]

■ 勾配ブースティングの概説

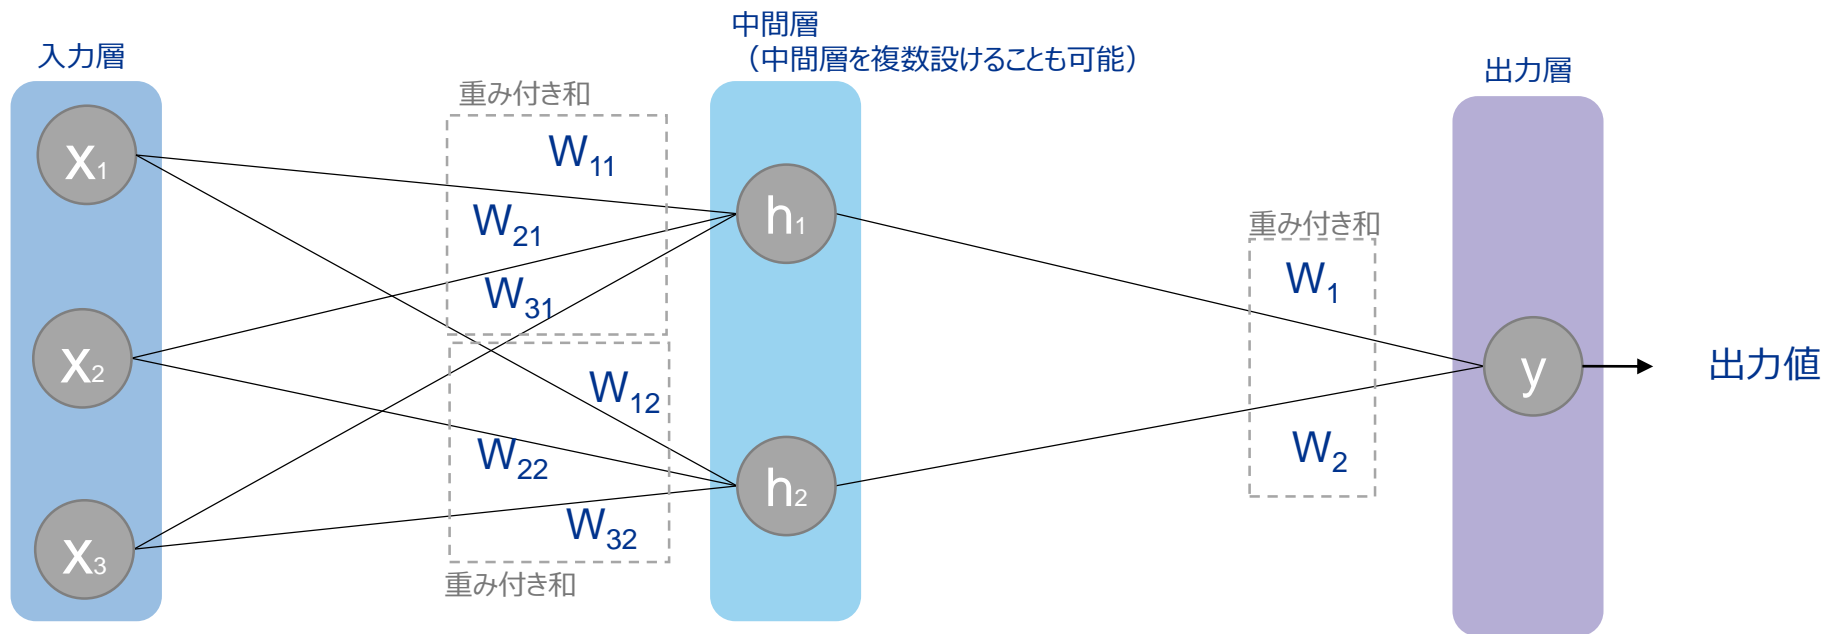
決定木を構築し、当該決定木が外したサンプルに当てはまるようにウェイトを調整して、次の決定木を構築する。これを繰り返して最終的な予測値とする方法



AIアルゴリズムの概説 [4/5]

■ 多層パーセプトロンの概説

複数の入力値に対し、それぞれ調整した重みをかけて出力値を計算し、その結果を用いて分類する方法。



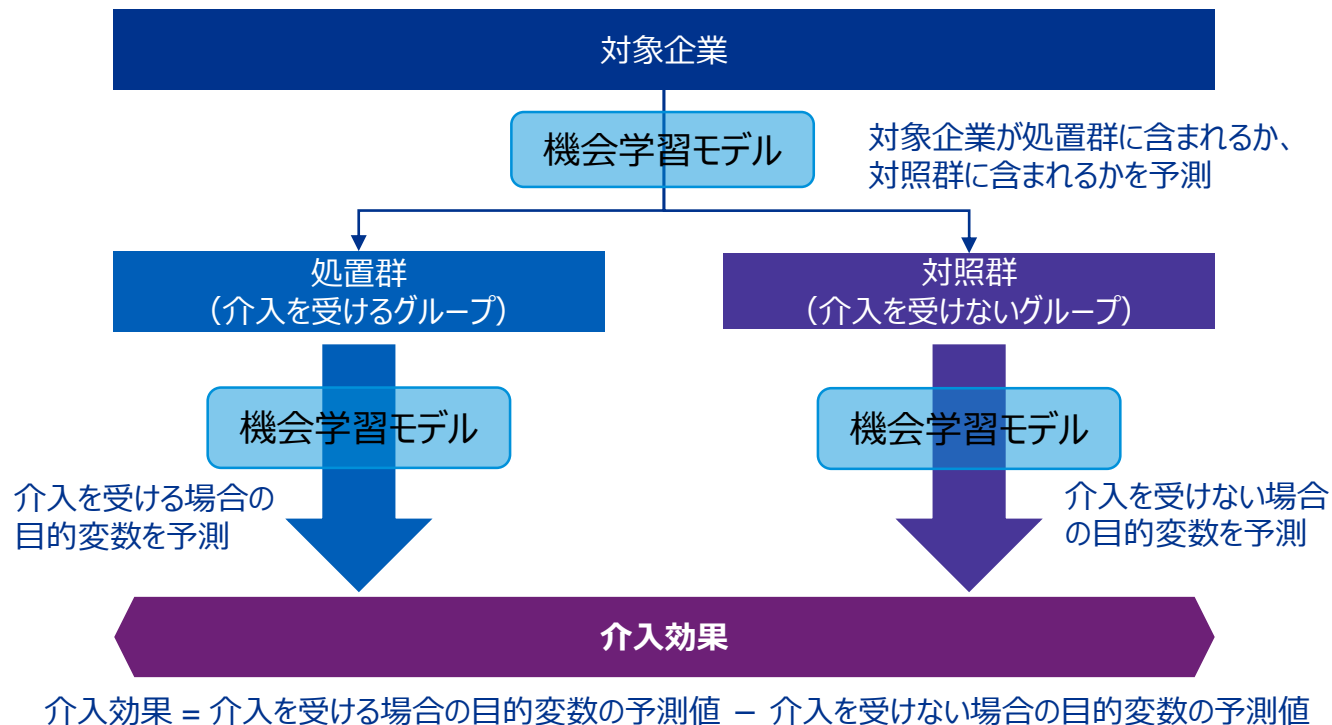
入力値 ($x_1 \sim x_3$) に対して、学習済みの重み ($W_{11} \sim W_{31}$) をかけたものの和を計算し、中間層のノード h_1 を算出する。同様に h_2 も算出する。

中間層のノード ($h_1 \sim h_2$) に対して、学習済みの重み ($W_1 \sim W_2$) をかけたものの和を計算し、出力値を算出する。

AIアルゴリズムの概説 [5/5]

■ Meta-Learnersの概説

因果推論を行うための論理フローの各ポイントに主要な機械学習アルゴリズム（ロジスティック回帰、ランダムフォレスト等）を適用し、介入効果の推定を行う手法。



(注) Meta-Learnersの中には様々なアルゴリズムがあり、各ポイントにおける機械学習モデルの適用有無や適用方法、介入効果の算出方法は、各アルゴリズムによって異なる。



ここに記載されている情報はあくまで一般的なものであり、特定の個人や組織が置かれている状況に対応するものではありません。私たちは、的確な情報をタイムリーに提供できるよう努めておりますが、情報を受け取られた時点およびそれ以降においての正確さは保証の限りではありません。何らかの行動を取られる場合は、ここにある情報のみを根拠とせず、プロフェッショナルが特定の状況を綿密に調査した上で提案する適切なアドバイスをもとにご判断ください。

© 2022 KPMG AZSA LLC, a limited liability audit corporation incorporated under the Japanese Certified Public Accountants Law and a member firm of the KPMG global organization of independent member firms affiliated with KPMG International Limited, a private English company limited by guarantee. All rights reserved.

The KPMG name and logo are trademarks used under license by the independent member firms of the KPMG global organization.

「AI を活用した経営改善支援に係る研究会」(第1回)

開催日時： 7月1日(金) 14時00分～16時00分

開催方法： 「Webex」による Web 会議形式

委員：

有竹 博史 東京信用保証協会 業務総轄室 業務総轄部長
和泉 潔 東京大学大学院 工学系研究科システム創成学 教授
内山 功士 浜松いわた信用金庫 デジタル推進部 デジタル業務課 課長
河合 祐子 Japan Digital Design 株式会社代表取締役 CEO
三川 剛 株式会社エルテス 取締役
鈴木 明美 大東京信用組合 常務理事
筒木 光 TKC 全国会システム委員会 TKC 経営指標編集小委員会 委員
中村 康浩 株式会社横浜銀行 融資部 担当部長
名取 良訓 信金中央金庫 総合企画部しんきんイノベーションハブ 次長
松崎 堅太郎 TKC 全国会中小企業支援委員会 副委員長
宮川 大介 一橋大学 経営管理研究科 経営管理専攻 准教授
矢内 紘之 株式会社帝国データバンク 企総部 企画課長
吉田 茂樹 株式会社栃木銀行 事業支援部 副部長

議事進行：

秋場 良太 有限責任あずさ監査法人金融統轄事業部 ディレクター

■アジェンダ

1. 開会
2. 金融庁挨拶
3. 構成員紹介
4. 事務局説明
5. 討議
6. 閉会

(主なやり取り)

○ 研究会委員

弊社は、銀行の業務の一部として銀行の保有するデータ等を用いて与信モデルを作ることを行っております。その与信モデルというのは当然ながら機械学習を使ったモデルですが、そういう意味では、今日議題になっていることのごく一部を実装している会社でございます。

その立場から前提条件の理解の確認のために質問をさせていただきます。経営改善支援業務ということでプロセスをお書き出しいただいておりますが、大きめの質問として、私どもが作っているのは与信モデルなので会社がデフォルトせずにお金を払ってくれるかということターゲットにしております。基本的には、手元で資金不足になるか否かを評価すればよいので分析の対象ははっきりしていますが、本件は経営改善ということで、要経営改善ステータスはもっとマルチな要素が関連してきます。単にお金が足りないというだけでなく、経営者の後続がないことや人が雇えないこと、半導体不足、作っているものがアウトオブデートになっているので、ビジネスモデルの転換をしなくてはいけない等、色々な場面が要経営改善と認定されると思われそうですが、どの程度、要経営改善先の要素を絞り込む前提とすればよいかというのがまず1つめの質問です。要経営改善をどう定義するかによって、どういう分析をすればよいかを決めなければいけないと思います。そうすると例えばより幅広いもの、例えば財務状況のみから分析するとして、どの程度の状況になったらお金を払えなくなるかもしれないというものを見抜く、これは、何をエンドゲームに置くのかっていうことにもよりますが、ただ財務状況の分析だけに絞るとすると成果を公表する時にもものすごく気を付けて公表しなくてはならないと思っていて、モデルが示すところはある程度財務状況が悪化するということを見抜くものであって、それ以外の要経営改善ステータスを見抜くものではないということを示さなくてはなりません。そのあたりを踏まえて、一体何を指すべきか、ということが1つ目の質問で聞きたかったことです。

2つ目の質問は、何を分析したいかによってデータの範囲が異なり、経営環境の悪化を見るのであれば外部データの範囲が広がります。冒頭あったように、経営環境に大きく影響を与えるものとしてガソリン代の高騰、あるいは人件費がこれから上がっていくであるとか、こうしたものを織り込んでいかなければいけないと思いますが、そういうことまでデータの範囲としてとりこんでいくものなのか、あるいは一期・二期先の財務悪化だけを織り込むものなのかによってデータの範囲が異なるので、どの程度のことを念頭に置いて議論すればよいかを確認させてもらいたいと思います。

3つ目はデータの欠損リスクについて、でございます。地域金融機関だと財務データそのものが上場会社に比べ不十分であることが多く、今回、ある程度そろったデータを使ってモデルを作るのかと思いますが、実際に地域金融機関に適用した際の欠損リスクをどのように考えればよいか、欠損リスクについて、検討する余地があるか確認させて頂ければと思います。

○ 事務局

ご意見ありがとうございます。最初の質問について、今回のターゲットは単純にデフォルトするかしないか、明らかに貸したお金が返せないという明確なものではなく、業績の悪化を早めに検知するという形で非常に曖昧なのでいろいろな要素があり、難しいのではないかと、というご指摘だと思っています。今回の AI プロトタイプでは、当てたい事象は業績が悪化するかしないか、ということで倒産するかしないかという与信モデルと比べたときに事象は異なりますが、悪化をとらえるという点で同じようなものだと考えています。ただ、1つ1つの因果関係までは難しいと思いますので、その意味で与信モデルと今回のモデルが大きく変わるものではないと思っています。ある程度業績が悪化するかしないか予測するモデルができたところで、色々な要因で悪化するかしないかというのがあろうかと思っています。そこは、従来の与信モデルと異なり、AI が判断したスコアのファクターは出てくるため、金融機関の職員がその情報を見つアクションができるよう繋げられれば良いと思っています。今回の AI の結果がダイレクトに自社の製品のライフサイクルが古いので駄目とか、人を採用できないから経営改善ができないとかそこまで出せるものではなく、1歩か2歩手前の参考情報を出すことで、経営改善支援全体の効率的な取組みができればと思っています。

2点目のデータの範囲は、後ほどの議論のテーマにも入れさせていただいておりますが、与信モデルでは財務情報と入出金の履歴を使って予測することがプラクティスとしてあるかと思っています。今般の AI プロトタイプでは、今のところのデータの範囲としては、個社の財務情報に加えて、外部環境データとして物価とか鉱工業生産指数とか労働とか人口とか為替とかエネルギー価格とか幅広に勘案して経営改善支援先の早期発見ができないかと考えています。そこが上手くいくかはあまり取組みの無いテーマなので、あれですが、視野に入れてやっております。

3つ目の欠損問題については、欠損の情報を推測するような手法はあろうかと思いますが、まずは欠損が無い情報を使って AI モデルを作ればと思っています。今回の共同研究先の4社は相応に財務情報の管理をされて今回の調査研究に協力頂いているので、きちっとしたデータが入っているかと思っています。ただ、実務に適用する時には欠損が出ることはあり得るので、その対処方法として業種・規模平均や最も悪い値として財務項目を補完するなど実務的に適用しやすい形で穴埋めすることで、実務適用上も対応できないかと考えています。多くの金融機関において、欠損となる説明変数は実務に使えないため、多くの金融機関で欠損になっていないものを使いつつ、なるべく幅広い説明変数を使うというようなバランスをとった形でできないかと考えています。

○ 研究会委員

ありがとうございます。追加で確認しますが、業績悪化の定義は何だと考えているのでし

ようか。また、業績悪化を収益マージンの低下で考えるのか、自己資本の低下で考えるのか、今の段階で考えがあればお聞かせ頂きたいと存じます。

また、業績悪化の定義をフロー部分に着目するようなモデルを考えている場合には業種別にファクターが変わってくるかと思いますが、業種別のモデルを作るという考え方も今のところ排除しないということによろしいでしょうか。

○ 事務局

ご意見ありがとうございます。業績悪化の定義については、色々な業績悪化がありますが、金融機関においては、信用力が悪化するか否かだと思います。信用力は自己資本や収益性や債務負担など、いくつかのファクターがありますが、この研究会で目指す業績悪化とは信用力の低下を当てたいと思っています。信用力の低下の定義はデータ提供者のデータ保有状況にもよりますが、債務者区分などの形で特定の業績悪化要因ではなく、様々な要因による信用力の悪化を当てに行く形で業績悪化を捕捉できないかと考えています。

2つ目の業種別のモデルという点をご指摘の通り、業種別に業績悪化の要因は異なるので、業種別の要因が分かるようなモデルを作るということを想定しています。実際にモデルを業種毎に分けて作るかは要検討ですが、tree系のモデルのように様々な要因で枝分かれて作るものでは、業種を説明変数に入れることで業種影響を補完できないかと思っています。また、外部環境データの感応度も業種によって異なると思いますので、外部環境にどの業種が反応するかということが上手く捕捉できるような形の説明変数を作って、業種毎の景気感応度を表現できるものを目指していきたいと考えています。

○ 研究会委員

金融機関が業績の悪化を判断する最初の入口は入出金の異常がないか、あるいは月次の試算表で業績悪化が顕在化していないか、これは月次で試算表を徴求しているか等によると思いますが、今回の検討では、ストックとフローの切れ目が気になっています。ストックで年次の決算を見て悪いかどうかはAIを使わなくても分かる話だと思います。決算説明の半年前とかに業績悪化の予兆をモデルで検知して、決算の悪化を予測することが今回の目的だと思っていますが、フローに近いデータが無いとその辺は捕まえないかと思っています。業種によっては日次で売上を締めているような形の企業もあるでしょうから、そういうところでは日次の売上の締めを見るのがフローに近かったりするのではないかと思います。メインバンクとしての集中度にもよると思いますが、入出金がある程度集中していれば月次の入出金のイレギュラーな動きとかで、例えば、支払難になっている月が3か月続いていて、マクロデータや何かの行動でこうなったらしい、とかにも気づいていくと思いますが、その辺のフローとストックのデータの捕捉具合のバランスをどうするかが重要だと思います。

2点目はデータとして数値が中心だと思いますが、定性的な情報もデータとして、何か評

点として入れるかその点についてご教示頂きたいです。

○ 事務局

ご意見ありがとうございます。通常、中小企業だと1年に1回決算があって、それを金融機関の方が入手していますが、その間の動きは当然重要だと思います。データ提供会社のデータ保有状況にもよりますが、多くは年に1回の財務情報しか手に入らないので、データの制約の中で何とかできないかと考えています。銀行は入出金が見られるのでそのような情報を使うことも重要だと思いますが、今回は見ることができないのでそこは今後の課題です。データの制約がある中でも何かしら経営改善支援が早期発見できるものがあると思っています。金融機関の実務上、足元の2、3期の決算報告書の情報を利用して、今後経営悪化するかがもし分かれば実務的にも有難いとも思っていますので、制約の中で有益な結果が出せればと思っています。今回の共同研究先の一部では、月次の財務情報が取得可能となっております。月次と年次で得られる効果を比較して実務で使う時にどのようにすればいいか研究の成果としてまとめられれば良いと思います。

2つ目の担当者による定性情報について、我々も当初は渉外記録を取ればと思っていますでしたが、今回そのような情報は取れないので、実証事業のタスクでどの程度そのような情報があるのかを踏まえて、今後の発展として入れることができないか考えられればと思っています。共同研究先の中には、メインか非メインか、取引先数などの情報がありますので、その情報を含めたモデルの精度と数値データのみを比較して定性情報を入れることの効果がどれだけ重要か成果として取りまとめられればと思っています。

○ 研究会委員

ありがとうございます。後者の定性情報については、金融機関の匠の技だと思います、そうしたところもヒアリング項目化して蓄積されていくと予測に使えるようになったりもするかもしれません。

○ 事務局

ご意見ありがとうございます。金融機関との実証事業でそういったところも、用意したいと思っています。

○ 研究会委員

現行業務フローの適切性についてですが、我々も同じようなフローチャートを作っておりまして、大まかな流れとしては今回提示されたものと近いと思っています。Step1について、私どもでは渉外担当者が取引先を直接訪問してモニタリングした情報を「事業性評価シート」という形で情報を蓄積しています。財務データや定性情報を蓄積した中で、課題がある先については Step2 という形で課題を整理し、店舗と本部の所管が内容をイントラネッ

トで共有し、全先の課題解決に向けた取組みはできないので、5段階で優先順位をつけています。A~Eという形でつけて、時間的に余裕のない先を優先して Step 3 という形で、内部で支援できるものと、私どもでは課題解決できないところについては外部の専門家、あるいは専門機関を活用して取引先の課題に合った専門家等を派遣して、営業店等の職員、あるいは本部の関係者も同席しながら、相手先の企業の経営者と課題共有をして、数回に渡った面談で課題解決の提案を行い、その後フォローアップをするという流れでございます。今回のフロー図はコンパクトにまとめられていると認識しています。

○ 事務局

ご意見ありがとうございます。一連の経営改善支援業務で認識されている課題はどのようなものでしょうか。

○ 研究会委員

1,000 先近い本業支援先をリストアップして、200 先程優先度の高い先があるのですが、経営者と課題を共有する、経営者に本気になってもらうことが困難となっております。また、経営者と課題を共有できても改善の有効な手段が提案できていないことも課題だと思っています。

○ 事務局

本業支援先をリストアップする際やトライアージする際の課題はあるのでしょうか。

○ 研究会委員

ヒアリングの中で、売上は下がっているがゼロゼロ融資などで資金繰りはできているからしばらく大丈夫といったような先は劣後としていますが、手持ち資金が乏しいのでなんらかの手立てをしないと間に合わないところは優先順位では高くしております。特に優先順位をつけることについては、課題はないと思っています。

○ 研究会委員

何が 이슈かがこのブロックでは大事だと思っています。スライドの中では、クイックにリスト化ができることでいいことがあるかもしれない、何らかの予測をうまくやることでいいことがあるかもしれないという話ですが、今の話だとその部分はある程度上手くできている金融機関があるということです。今回の取組みの KPI として何を実現できればプロジェクトとしてクリアできたのかというところは、明らかにしておいた方が良いと思います。

スライドの中でもあった議論としては効果的な再生手法の検討をするという題目になっておりますが、先ほどの話では課題がある会社を見つけたときにどうアプローチするかを

考えるのがテーマだと思いますので、次の開発コンセプトのところで議論ができればと思いますが、個人的には業績悪化の予測モデルではないと思っています。まずは KPI の設定をリクエストとして申し上げた次第です。

○ 事務局

ご意見ありがとうございます。KPI は事務局内でも協議し設定できればと思っておりまして、第二回・三回で報告できればと思っています。

2 点目のご意見につきましては、後程の議論でどの手法を使うかに絡むと思うので、そこでディスカッションできればと思っています。

○ 研究会委員

フローとしては概ねこのような形でやっているかと思います。実際の経営改善支援先の絞り込みの際は、お客様のサポートニーズを吸い上げたうえで最終的な絞り込みをしています。例えば、要注意先の中でも積極的にお客さんをサポートしていくべき先、あるいはお客様の方からサポートニーズがある先というところを、ヒアリング等を通じて絞り込んでいくというプロセスが入っているので、Step2、3 を 1 つにしているような枠組みとなっています。

その中で、BS に関することなのか、PL に関することなのか、あるいはその両方なのかという課題の共通認識の中で、どのようなソリューションメニューを提供していくかというところをお客様と一緒に考えていくような流れとと思っています。

先ほど決算が年 1 回ということ、可能であれば半年くらい前から予測をたてて、こういった財務状況の会社は経営状況が悪くなりそうというところを予測するという話があったと思いますが、それを考えると、どういうデータを使えば予測ができるのかイメージが湧いてこないというのが率直な感想です。

○ 事務局

ご意見ありがとうございます。大きな違和感はないものの個別で見ると異なる点があることは理解いたしました。ソリューションメニューや決算頻度を踏まえた予測の在り方や予測の期間については賜ったので、データの制約がある中ではありますが、金融機関の皆様にも納得的なものにしたいと思っています。

ちなみに、現場の職員の皆様に活用していただくイメージとしましては、新たな業務フローということで記載をさせて頂いておりますが、次の一手をいかに分かりやすく出すかということが重要だと認識しました。参考資料として 28 ページと 29 ページに実用化に向けた UI のイメージを記載しておりますが、こういったようなモデルの出力を利用して次の一手の参考になるものを出していく、あとはこのプロジェクトと並行的にやっている虎の巻での検討結果と合わせて検討できればと思っている次第です。

○ 研究会委員

14 ページのモデル活用フローのところですが、コンセプト 1 と 2 で別々のモデルを作る場合に、KPI をどのように設定するかという学習の設定の仕方を決める必要があると思います。その場合に重要なのは、11 ページのところで説明がありましたが、できるだけ取りこぼしの無いように従来見つけられなかったものを AI モデルで発見したいという点、アラートが出たときには正確性が高く調べ直すことも最小限にしたいという点は、通常 AI モデルではトレードオフになるものなので、それをどう決めるかはコンセプト 1 とコンセプト 2 で実際にユースケースを考えながら決めるというのが非常に重要なステージになると思います。ここは、単なる過去データだけでなく、ユースケースを考えながらやっていただきたく存じます。その場合に、モデルがどのタイプの業種には精度が良いのか悪いのかといったある種の割り切りも必要だと思しますので、ユースケースを考えながらメタパラメータであるモデルの設定をやっていただきたいと思います。

○ 事務局

ご意見ありがとうございます。一番の目的はリストの精度が高いものが最初のターゲットとは思ものの、従来捕捉できなかったものを捕捉できたという欲も書いているので、プロトタイプごとの特徴を踏まえて、プロトタイプごとの活用シーンも整理したいと思っています。

○ 研究会委員

14 ページのスライドのところで、KPI の話があり、現場で支援していて 2 点思うことがございます。

1 つ目が、営業キャッシュフローが赤字になっている企業についてです。これには、いろいろな原因がありますが、売上がコロナで蒸発してしまったとか、採算の悪い仕事を取っているとかがありますが、こういった企業への支援は大変時間がかかる部分があります。いわゆるトップライン改善と呼ばれる売上をどう上げていくかというところになるので、早めに手をつけていく必要があります。これが、PL 改善の世界としての傾向として感じています。

2 つ目は、BS について、企業が生み出す営業キャッシュフローと比較して返済ペースが早いという企業についてです。単純に金融機関にそういった状況を説明して、借換えやリスクやその他のいろいろな財務改善をしていただければよいのですが、内容を見るとなぜ返済ペースと営業キャッシュフローが合っていないかというと、正常運転資金を継続融資でやればよいが、消費者貸付で融資いただいているので、正常運転資金を割り込んで返済が始まってしまうケースがあります。この 2 つくらいが現場で、共通してあることかと思っ
ていまして、これら現場の認識についても、本調査研究に活かしていただければ有難いです。

○ 事務局

ご意見ありがとうございます。AI モデルの説明変数としてどのような情報を取り込むか、また、営業キャッシュフローなどは、モデルを分けるときに有益な情報ですので、モデル開発になるべく組み入れられるようにと思っています。

○ 研究会委員

15 ページの関連ですが、今回の取組みについて開発コンセプトを 2 段階に分けて取り組むのは良いアイデアだと思いますが、開発コンセプト 2 はかなり難しいと思います。単に、業況が悪くなるだけではなく、金融機関が介入をしたことで改善するところを探しに行きたいという難易度の高い取組みとなっております。予測と因果推論に分けざるを得ないと思いますが、介入したということと、介入前後のパフォーマンスが見えてないといけないので難易度が高いと思います。

ただ、やってみないと分からないので、やってみるといえるところはあると思いますが、バックアッププランとして、アノテーションをして、当てに行くフラグを設定すれば、開発コンセプト 1 の予測の手法である程度解決できる場所もあると思います。何らかの手を入れれば良くなるかもしれないということで、専門的な知見から見てフラグ付けができるのであれば、そのフラグを立てたうえで予測をしにいけばいいと思います。ドメイン知識を使ってアノテーションをする必要がありますが、そこを飛ばして、単に業績が悪くなったところだけを当てにいくと間違った方向になってしまう気がするので、バックアッププランとして予測だけでも最後まで通せるように構築していくというのも考えてみてはいかがでしょうかというのがコメントです。

○ 事務局

ご意見ありがとうございます。後程、どのように教師ラベルを設定するかについてもご意見賜ればと思っております。

○ 研究会委員

13 ページの AI モデルの開発コンセプトについて、当金融機関では、様々な企業に対して限られた人員で支援を行っており、財務データや外部環境を踏まえたアラートにより行動の示唆を与えてくれるモデルが構築できるのであれば、営業活動や支援活動の一助となるかと思えます

○ 事務局

ご意見ありがとうございます。まさに、現場で動かれている方々のサポートができるものをターゲットとしていますので、引き続きご意見賜ればと思えます。

○ 研究会委員

28 ページの UI イメージにおいて示されている出力内容については、すでに金融機関が用いている財務分析シート等である程度把握できるような内容かと思います。したがって、例えば、ヒアリング項目や外部環境の情報といった事業者との会話のきっかけになるような仕掛けができると良いと思います。

○ 事務局

ご意見ありがとうございます。いただいたご意見については、今後の検討の参考にさせていただきます。

○ 研究会委員

Step1 のところで、我々も同じようなステップを踏んで支援先を定めています。今回の取組みについて効率的にやるのが 1 つの目的だと考えています。支援先について、支援をしなくてもいいような先も実はあって、要注意先・破綻懸念先に長いこと入っていてゴールが見えないということもあります。一方で、正常先からいきなり破綻みたいなものも日々あります。今回 AI を活用して、今まで支援先として認識していないような支援先が出てくるということで期待させていただきたいと思います。

コンセプト 2 でデフォルト予測ではなく、経営改善支援をすることが目的との話がありましたが、顧客目線で考えますと、経営改善したいというのはお金が心配ということです。そう考えると、学習の設定の仕方で KPI はどこに持っていくかという話がありましたが、お金がどうなっていくか、どのようにお金の調達を行えばクリアできる、というようなのができると良いと思っています。

○ 事務局

ご意見ありがとうございます。2 点目でいただいたご意見もコンセプト 2 の開発に活かされればと思っております。

○ 研究会委員

9 ページのフローについてはまさにこういう状況で、業務フローのところでは各金融機関のおっしゃる通り概ね同じような形で、Step1 のところでは格付が 1 ノッチほどダウンなど業況悪化の芽がある先を本部でリストアップして、支店にリストを回送してそこで設定していくという形の動きとなっております。ただ、経営改善は業況悪化のみでなく、事業承継の課題や経営者年齢も見て、事業継承に課題があると思われる先をリストアップして経営改善に繋げるようなことは取り組んでいます。業況悪化とは、別のセグメントとして、スタートアップ企業は訪問すると経営改善のニーズが高いセグメントであり、そういった先に

についても取り組んでいくところがあります。29 ページの UI のところで、お客様の所に行っ
て経営改善が必要であることを知ってもらうことが難しいところであり、最低限 AI モデル
といっても指標や説明変数の寄与度が出て職員がお客様に説明できるようなものを作成し
てもらえるとありがたいです。

○ 事務局

ご意見ありがとうございます。スタートアップ企業の支援ニーズは具体的にどのような
ものがありますか。

○ 研究会委員

原価低減のために、原価計算の精緻化をしたいとかいろいろなニーズがありますが、具体
的な経営改善支援は職員ではできかねるため、実際の支援にあたっては、それらを聞いたう
えで、専門家派遣という形で中小企業診断士や税理士や公認会計士という方の派遣に繋げ
て解決につなげていくようなフローになっています。

○ 研究会委員

私たちは中小企業をどうすれば守れるかというところ、倒産を回避できるかというところ
が究極の目的であると思っています。開発コンセプトのところではアルゴリズムが 2 段階
に分かれています。いかに目に見えないものを落とし込んでいけるかというところが大事
なところかなと理解しています。

○ 研究会委員

開発コンセプト 1 のところで、どの位の期間を見ていくかというところ、業績の悪くなる
前と後の期間については議論頂けると良いと思っています。期間が長くなるほどモデル
構築が難しく、データにも欠損が出てくるというようなことがある一方で、あまり近いと自
明になるというようなトレードオフがあると思いますので、そのあたりの最適解を探すこ
とが重要だと思っています。

開発コンセプト 2 では、改善した時に信用力の序列が一定以上に遷移するとされていま
すが、経営改善を果たしたが M&A や分社化されたなど会社という単位での連続性が失わ
れるケースもあるので、どのように捉えるかというところも論点と考えています。

もう一点、コロナの期間を時系列的にどのように捉えていくか、コロナ期を含む財務情報
で作ったモデルがコロナ後適用できるかというところあるいはそこを外したデータを用意
すべきか、というところも議論になってくるかと思っています。

最後にもう一点、共同研究先ごとに AI を作って比較するのであれば、債務者区分など同
じ基準で採録されたものの方が出しやすいと思います。

○ 事務局

ご意見ありがとうございます。企業の分割や合併は個別に事情がありますので、なるべくデータ分析対象期間で同じ企業が連続している先に限定して作った方が良いと思っています。ご意見踏まえてモデル開発に活かせればと思っています。

○ 研究会委員

開発コンセプト 1 も債務者区分を教師データに用いるとすると、従来のモデルとどのような点が異なっているのかがイメージが湧かないです。

○ 事務局

ご意見ありがとうございます。4つの会社様で保有するデータの状況が異なっており、情報の深度、粒度含めて違いがでるようにいろいろな分析ができるようにと思っています。債務者区分の遷移の予測との違いについては我々も認識しているので、今回の政策目的に照らした形でモデルを構築できればと思っています。

○ 研究会委員

AI のアルゴリズム候補をいくつか選んでいましたが、議論してどれを使うかを決めて作るか、同じデータで複数試してみて結果が出ているものとの乖離を見て決めるのか、どのようなやり方で選ぶか気になっている次第です。

○ 事務局

ご意見ありがとうございます。明らかに不要なものがあればそれを除いて選定しますが、まずは幅広に試しつつ、結果を見て絞り込めればと思っています。

○ 研究会委員

ありがとうございます。我々も似たようなことをやったことがあって、各アルゴリズムにより結果が違うので、複数のアルゴリズムを試した方が良いと思っています。

○ 研究会委員

フラグとデータの種別に関して、コメントします。フラグに関しては整理がされていると思いますが、使い方について次の研究会でまた整理するのが良いと思います。今、やり方が何種類かあって、最初のやり方は悪くなりそうところを当ててその後の対応は別途考えるというのが 1 つ、開発コンセプト 2 として、手を入れたら効果のある先がどこかを見つけることで組み合わせるといったものがもう 1 つとなっております。最後のアイディアとして、一旦悪くなって介入した結果良くなったというフラグがあればそれを予測するのが分かりやすいという整理だと思うので、どれが上手くいくかは分からないので保険をかけな

がら進めていくのがいいと思います。

もう一つは、今回ものすごく貴重なユニークなデータが 4 種類集まっています。これらのデータを有効に活用するやり方として、各々のデータで構築すべきモデルの種別を整理した方が良くと思っています。例えば、データの頻度においては月次や年次の違いがあります。また、カバレッジにおいても違うかもしれないという話がありました。そのため、ある種の守備範囲を決めて各々のデータの価値を最大限に活かすような形でのモデル開発が 1 つ試行されても良いと思います。

また、データ間でのクロスバリデーションも試行されるとどれくらい汎化性があるモデル構築ができているかという目線でのチェックもできるかと思いました。

○ 事務局

ご意見ありがとうございます。開発に活かしたいと思います。なお、今回ご意見にもでておりましたが、「一定期間」については、現状 1 年後を想定しております。

(以上)

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 【第2回研究会資料】

2022年9月2日

有限責任 あずさ監査法人

委託元：金融庁

注：本報告書は、金融庁の委託により有限責任 あずさ監査法人が実施した調査結果を取りまとめたものである。有限責任 あずさ監査法人は、調査時点で入手した情報に基づき本報告書を適時に取りまとめるよう努めているが、本調査報告書の内容は、本調査の対象に含まれない特定の個人や組織が置かれている状況に対応するものとは限らず、また、情報を受け取った時点及びそれ以降において、その情報の正確性や完全性を保証するものではない。また、本報告書は委託者である金融庁に対してのみ提出したものであり、本報告書を閲覧あるいは本報告書のコピーを入手閲覧した第三者の本報告書の利用に対して、有限責任 あずさ監査法人は直接ないしは間接の責任を負うものではない。

Contents

	Page
1 スケジュール、本研究会の議題等	3
2 KPIとモデル開発計画	6
3 モデル開発用データ整備とモデルの評価指標	13
4 AIからの出力結果の実務活用	36
5 添付資料	39



1 スケジュール、本研究会の議題等

2 KPIとモデル開発計画

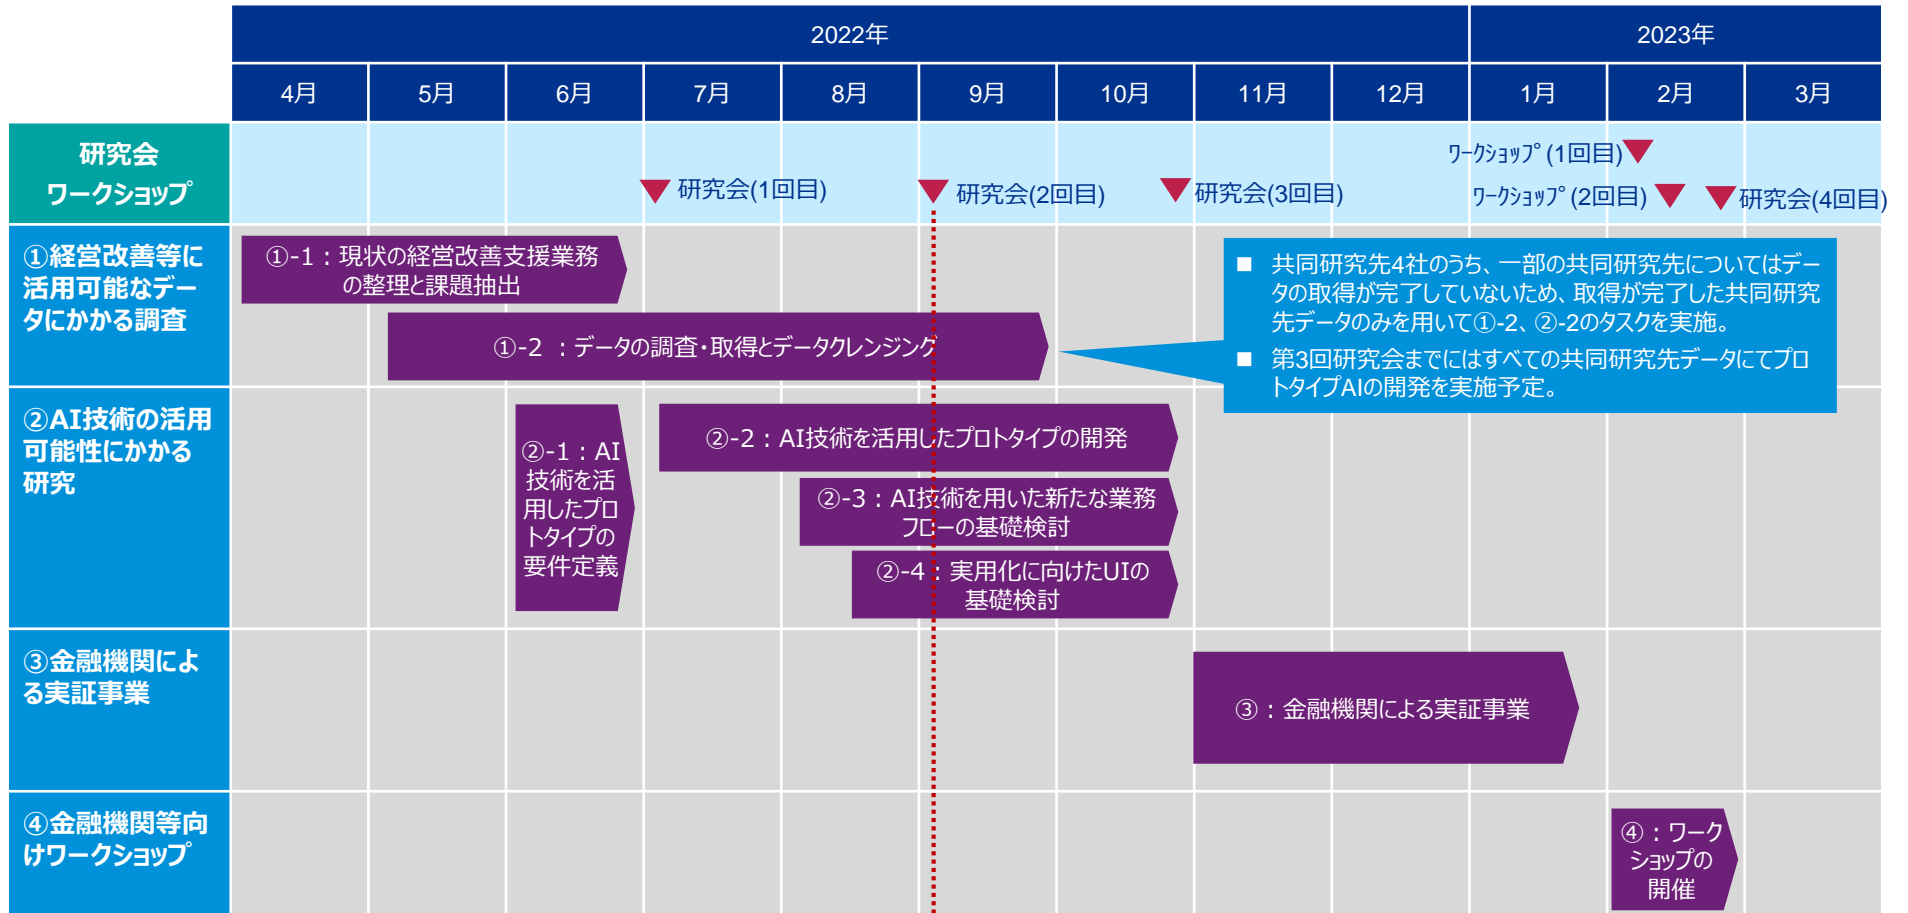
3 モデル開発用データ整備とモデルの評価指標

4 AIからの出力結果の実務活用

5 添付資料

本調査・研究のスケジュール

■ 本調査・研究の全体スケジュールと主なタスク内容は以下の通り。



研究会における予定議題

- 本日の研究会の議題、今後の研究会にて予定している議題は以下のとおり。

開催回	開催時期	議題（予定）
第1回	2022年7月1日（終了）	<ul style="list-style-type: none"> ■ 現行の経営改善支援業務の理解 ■ プロトタイプAI開発のコンセプトについて ■ プロトタイプAI開発に用いるデータについて
第2回 （今回）	本日	<ul style="list-style-type: none"> ■ KPIの設定・モデル開発計画について ■ モデル開発用データ整備とモデルの評価指標について <ul style="list-style-type: none"> ・ データクレンジングについて ・ モデル開発母集団と教師ラベルの定義について ・ 説明変数の作成について ・ 単変量分析について ・ 学習用データとテスト用データの作成について ・ モデルの評価指標について ■ AIからの出力結果の実務活用について <ul style="list-style-type: none"> ・ AIからの出力UIイメージとその活用 <p>※議論いただきたいポイントにつきましては、別添資料（「AIを活用した経営改善支援に係る研究会」（第2回）における議論のポイント）に記載しております。</p>
第3回	2022年10月下旬（予定）	<ul style="list-style-type: none"> ■ 第2回研究会を踏まえたプロトタイプAIの開発結果報告 ■ 金融機関の実証事業・ワークショップの進め方について
第4回	2023年2月下旬（予定）	<ul style="list-style-type: none"> ■ 金融機関における実際のデータを用いた検証の結果報告 ■ 本調査・研究の取りまとめ、今後の課題整理

1 スケジュール、本研究会の議題等

2 KPIとモデル開発計画

3 モデル開発用データ整備とモデルの評価指標

4 AIからの出力結果の実務活用

5 添付資料

本調査・研究のKPIの設定

- 本調査・研究のKPIは、以下の2つの観点で設定する。
 - ① 現行の経営改善支援実務では活用していない情報により、これまで捕捉することのできなかつた経営改善支援候補先が特定できること。
 - ② 抽出された経営改善支援候補先に対する職員による精査が、現行業務と比べて削減されるような高い精度を持つこと。
- 共同研究先データを使用したモデル開発と、金融機関による実証事業における、具体的な評価方法は以下の通りとする。

観点	評価方法	
	共同研究先データを使用したモデル開発	金融機関による実証事業
①	<ul style="list-style-type: none"> • 現行の信用リスクモデル※1では活用していないデータ（外部環境データや定性データ等）を分析に活用出来ているか。 • 現行の経営改善支援業務では捕捉できていなかったような経営状態（足元では正常先等）の企業を分析対象に出来ているか。 	<ul style="list-style-type: none"> • 開発したモデルに、実証事業に参加する金融機関における従来のモデルでは経営改善支援の対象でなかった企業のデータを当てはめて特定された企業の中に、実際に突発的に業績が悪化した先や経営改善支援を実施した先が含まれているか。
②	<ul style="list-style-type: none"> • 汎用モデル※2と共同研究先モデル※2のテスト用データ※3における精度が、財務のみモデル※2の精度よりも高いか。 • 開発したモデルにテスト用データ※3を当てはめて出力したスコアの悪い上位企業に、経営改善支援が必要な先（実際に業況が悪化した先）の多くが含まれるか。 	<ul style="list-style-type: none"> • 開発したモデルに、実証事業に参加する金融機関における企業のデータを当てはめて特定された企業の中に、実際に突発的に業績が悪化した先、経営改善支援を実施した先の多くが含まれているなど、相応の精度があるか。

※1 現行の信用リスクモデルは、多くは企業財務及び企業属性のみ勘案していることが多い。定性情報や外部環境情報はモデルによる定量評価後の定性評価により勘案している。本調査・研究ではモデルそのものに外部環境や定性データ等を加味することを想定している。

※2 汎用モデル、共同研究先モデル、財務のみモデルの詳細は、「モデル開発計画」（本資料 p.10-p.11）に記載。

※3 テスト用データの作成方法は、「学習用データとテスト用データの作成」（本資料 p.25）に記載。

AIモデル（プロトタイプ）の開発コンセプト [1/2]

– 第1回研究会資料の再掲

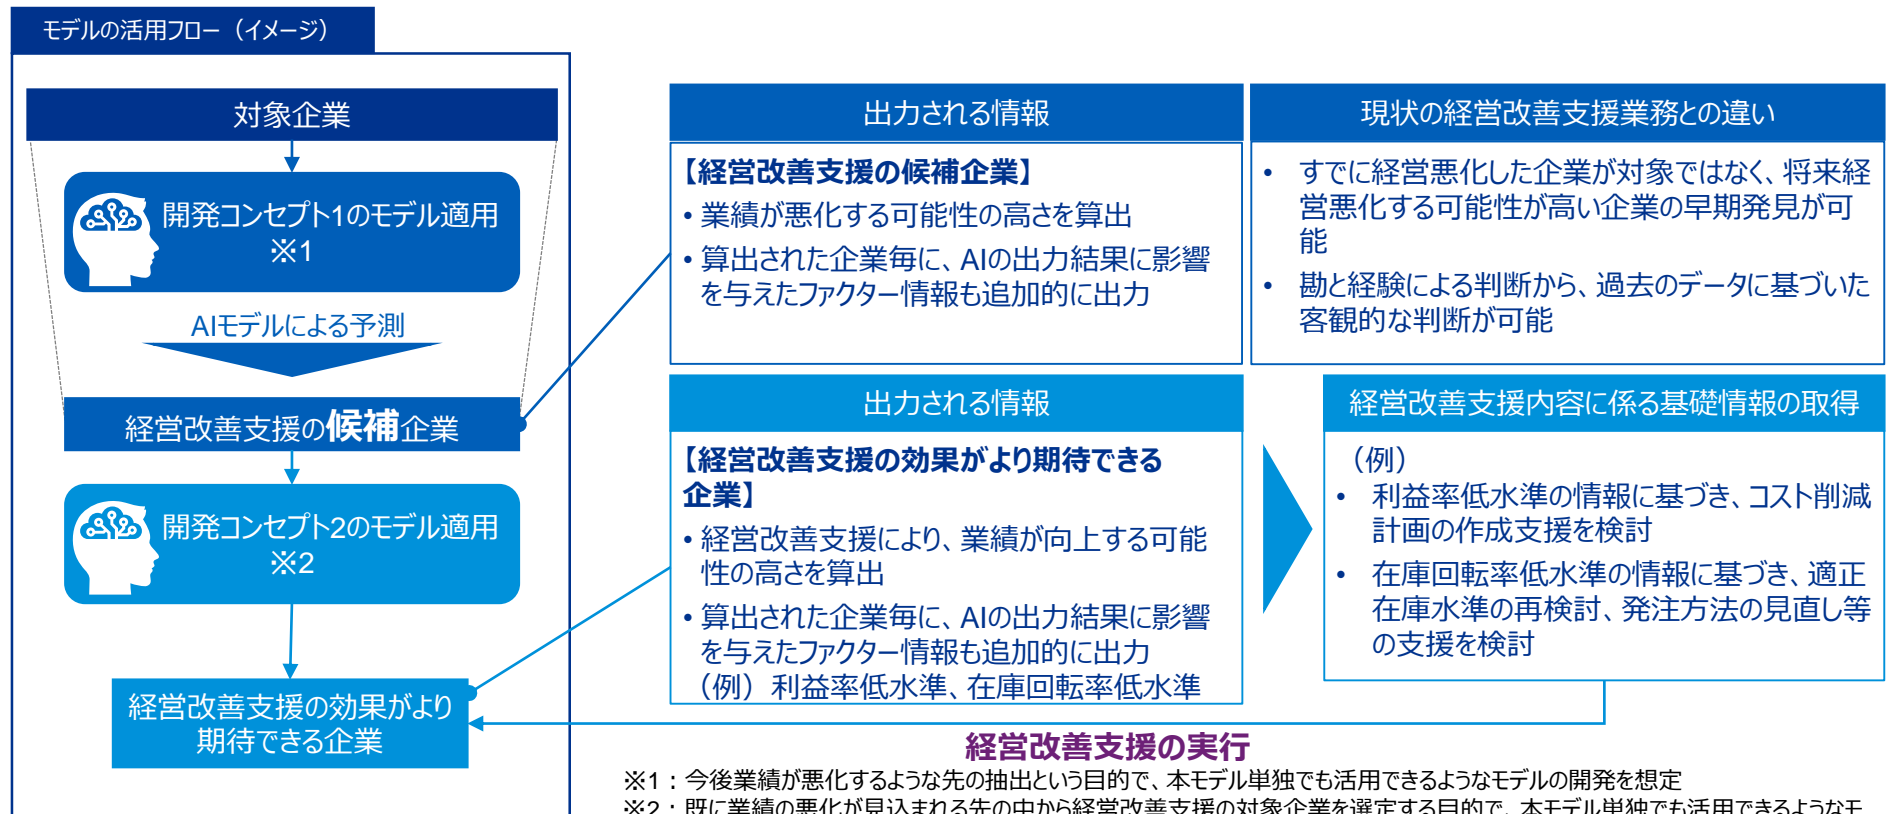
- 本調査・研究にて開発するAIモデル（プロトタイプ）の目的は、「経営改善支援が必要な先の特定（早期発見）」である。
- 本目的を達成し得るAIモデルの開発コンセプトとして、2つの方法が想定されるため、下表にて整理した。
- 本調査・研究では下表の2つの開発コンセプトを満たすAIモデルの開発（まずはBasicモデルに着手）を検討していきたい。

#	開発コンセプト	モデル構築の母集団		構築したモデルを当てはめる企業
		学習データの対象	モデルによって検知する事象	
1	<p>【Basic】業績低下の可能性が高い企業の特定</p> <p>現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル</p>	一定期間内において業績が悪くはない企業	一定期間経過後に、業績が低下する企業	学習データの対象となる企業（ただし時点が学習データより新しい等により学習データには含まれない企業）
2	<p>【Advanced】経営改善支援により業績が向上する企業の特定</p> <p>現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル</p>	一定期間内において経営改善支援の候補となりえる業況にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）	一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業	同上

AIモデル（プロトタイプ）の開発コンセプト [2/2]

– 第1回研究会資料の再掲

- 開発コンセプト1と開発コンセプト2を経営改善支援業務に活用した場合のフローイメージは左下の通り。
- 開発コンセプト1によって「経営改善支援が必要な先の特定（早期発見）」、開発コンセプト2によって「経営改善支援の効果がより期待できる企業の特定」と、「経営改善支援内容に係る基礎情報の取得」が可能となるよう検討を進める。



モデル開発計画（案） [1/2]

- データの頻度、項目、母集団等の観点から構築するモデルの範囲を定め、モデル開発計画を事前に作成してモデル開発を進める。
- 本調査・研究にて開発するモデルとその目的を、以下のとおり設定する。
- 予測の手法を用いるモデルについては、共同研究先毎にロジスティック回帰、ランダムフォレスト、勾配ブースティングの3つのアルゴリズムのモデルを構築する。因果推論の手法を用いるモデルについては、共同研究先毎にMeta-Learnersのアルゴリズムのモデルを構築する*。

【開発コンセプト1】

構築するモデル	手法	財務項目の頻度	モデルの概要	モデルの目的
財務のみモデル (ベースラインモデル)	予測	年次	<ul style="list-style-type: none"> ➢ 財務項目のみを使用したモデル (外部環境データや定性項目は用いない) ➢ 財務のみモデルはある特定の共同研究先データにて構築 	<ul style="list-style-type: none"> ➢ モデルの精度等の基準となるモデル ➢ 基本的には、他モデルは本モデルの精度等をどの程度上回ったかにより、評価を行う
汎用モデル			<ul style="list-style-type: none"> ➢ 全ての共同研究先データにて共通する財務項目と属性項目、外部環境データのみ用いたモデル ➢ 共同研究先毎のモデル精度の差が最小となるように共同研究先間データにてクロスバリデーションを実施 	<ul style="list-style-type: none"> ➢ 一般的な説明変数のみ用いた実務適用が容易なモデルを構築し、その精度を確認する ➢ あらゆる中小企業に対してもある程度の精度が期待できる汎化性能の高いモデルを構築する ➢ 原則として、本モデルを実際の金融機関のデータを用いた検証に活用する
共同研究先モデル			<ul style="list-style-type: none"> ➢ 各共同研究先データで使用可能な財務項目と属性項目、外部環境データに加え、共同研究先毎の独自の項目を使用して、共同研究先毎に構築したモデル 	<ul style="list-style-type: none"> ➢ 各共同研究先にて取得することができる項目を使用してモデルを構築し、その精度を確認する ➢ 情報量の異なる共同研究先データでモデルを構築して汎用モデルとの精度等の比較を行い、定性情報の有用性確認や今後の活用可能性等についての考察を行う
月次モデル		月次	<ul style="list-style-type: none"> ➢ 財務項目のデータ間隔を月次としたモデル 	<ul style="list-style-type: none"> ➢ 月次の財務項目を用いて学習したモデルの予測精度を確認し、高頻度な財務を用いたモデルの有効性の検証を行う

*各アルゴリズムの概説については、「AIアルゴリズムの概説」（本資料 p.40-p.43）に記載。

モデル開発計画（案） [2/2]

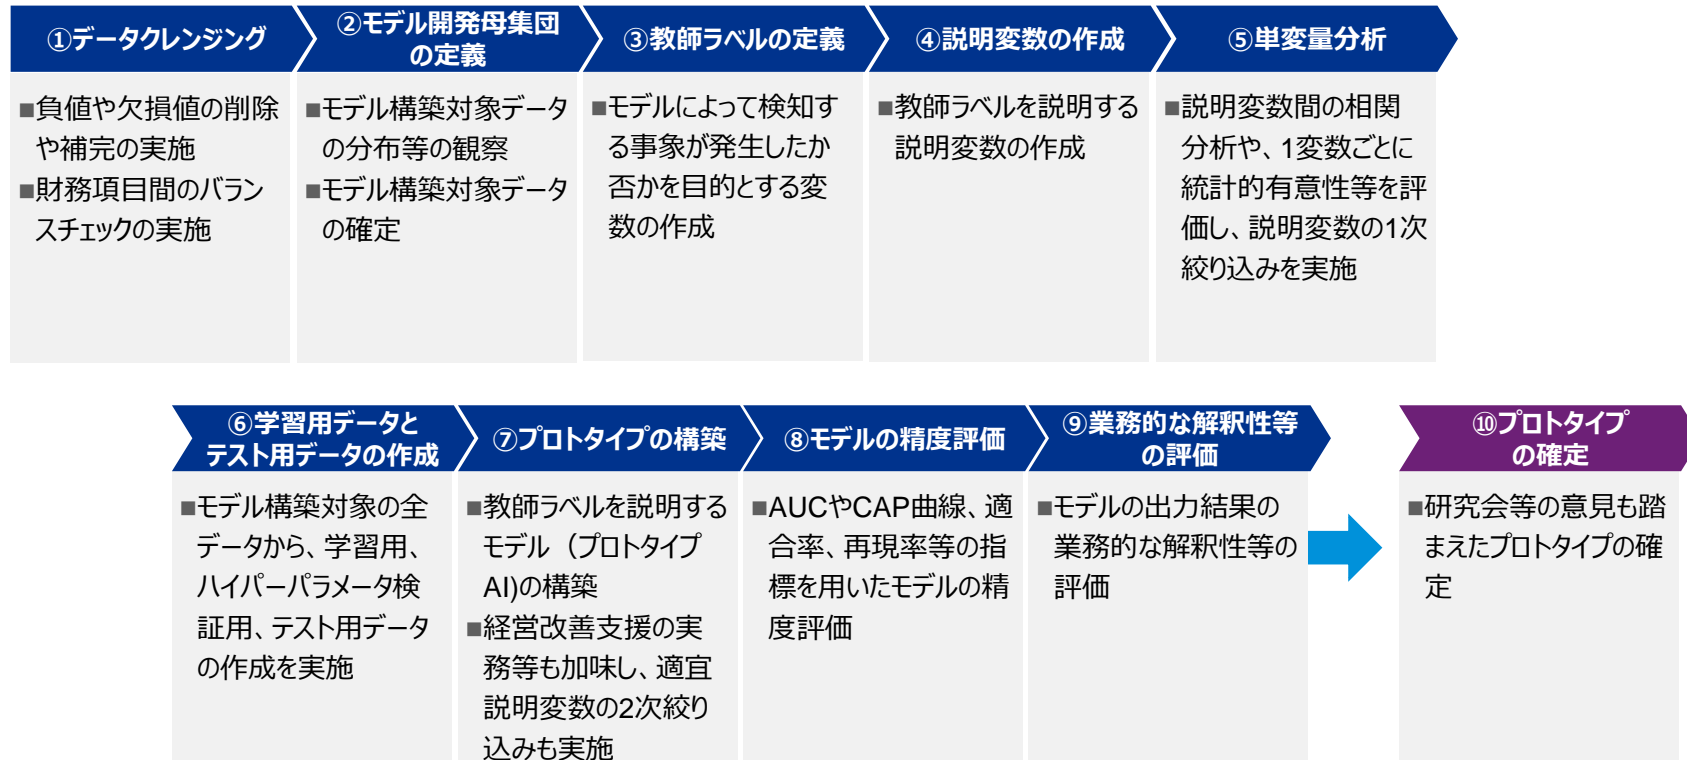
【開発コンセプト2】

構築するモデル	手法	財務項目の頻度	モデルの概要	モデルの目的
財務のみモデル (ベースラインモデル)	予測	年次	<ul style="list-style-type: none"> ➢ 財務項目のみを使用したモデル (外部環境データや定性項目は用いない) ➢ 財務のみモデルはある特定の共同研究先データにて構築 	<ul style="list-style-type: none"> ➢ モデルの精度等の基準となるモデル ➢ 基本的には、他モデルは本モデルの精度等をどの程度上回ったかにより、評価を行う
汎用モデル			<ul style="list-style-type: none"> ➢ 全ての共同研究先データにて共通する財務項目と属性項目、外部環境データのみ用いたモデル ➢ 共同研究先毎のモデル精度の差が最小となるように共同研究先間データにてクロスバリデーションを実施 	<ul style="list-style-type: none"> ➢ 一般的な説明変数のみ用いた実務適用が容易なモデルを構築し、その精度を確認する ➢ あらゆる中小企業に対してもある程度の精度が期待できる汎化性能の高いモデルを構築する ➢ 原則として、本モデルを実際の金融機関のデータを用いた検証に活用する
共同研究先モデル			<ul style="list-style-type: none"> ➢ 各共同研究先データで使用可能な財務項目と属性項目、外部環境データに加え、共同研究先毎の独自の項目を使用して、共同研究先毎に構築したモデル 	<ul style="list-style-type: none"> ➢ 各共同研究先にて取得することができる項目を使用してモデルを構築し、その精度を確認する ➢ 情報量の異なる共同研究先データでモデルを構築して汎用モデルとの精度等の比較を行い、定性情報の有用性確認や今後の活用可能性等についての考察を行う
因果推論モデル			因果推論	<ul style="list-style-type: none"> ➢ 経営改善支援の実施有無に関する情報を用いて、開発コンセプト2の本来的アプローチである因果推論の手法を用いたモデル

プロトタイプAIの開発手順

- プロトタイプAIは、以下の手順に従って開発を行う。

【本調査・研究におけるAI技術を活用したプロトタイプ開発の手順】



1 スケジュール、本研究会の議題等

2 KPIとモデル開発計画

3 モデル開発用データ整備とモデルの評価指標

4 AIからの出力結果の実務活用

5 添付資料

データクレンジング

■ 共同研究先データ共通のデータクレンジング方法として、負債データの取り扱い、欠損データの取り扱い等を以下の通り定める。

手順	処理項目	処理内容
1	財務情報が誤りである可能性があるデータの削除	<ul style="list-style-type: none"> 「資産合計」がゼロ以下のデータを削除する。
2	負債が不適切な財務項目に負債が入力されているデータの処理	<ul style="list-style-type: none"> 負債が不適切な財務項目に負債が入力されているデータを削除する。
3	現金・預金が負債のレコードの処理	<ul style="list-style-type: none"> 「現金・預金」の負債は当座貸越とみなし、その分「短期借入金」を増加させる。 「現金・預金」、「短期借入金」が関連する財務項目値を修正する。
4	財務項目（細目）の欠損の処理	<ul style="list-style-type: none"> 財務項目（細目）の欠損は一部の例外を除き、ゼロ値を入力する。
5	財務項目（演算項目）の欠損の処理	<ul style="list-style-type: none"> 「当座資産計」や「売上総利益」等の財務項目（演算項目）の欠損については、手順4までの処理を実行したデータにて、演算を行い算出した値を入力する。
6	バランスチェック	<ul style="list-style-type: none"> 以下の財務項目について左右の値を比較し、バランスチェックを行う。 <ul style="list-style-type: none"> ■ 資産合計 = 流動資産計 + 固定資産計 + 繰り延べ資産計 ■ 負債合計 = 流動負債計 + 固定負債計 + 特別法上の準備金 ■ 負債・資本合計 = 負債合計 + 資本合計 ■ 資産合計 = 負債・資本合計 ■ 経常利益 = 営業利益 + 営業外収益 - 営業外費用 ■ 当期利益 = 税引前当期利益 - 法人税等充当額 + 少数株主損益 左右の値の差が1%^(注)以上のデータを削除する。

(注) パーセンテージの設定は他の共同研究先データの状況を踏まえて調節する。

モデル開発母集団と教師ラベルの定義

– 第1回研究会資料の再掲

■ 開発コンセプト1

開発コンセプト	現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル	モデル開発母集団の対象	一定期間内において 業績が悪くはない企業	モデルによって検知する事象 (教師ラベル)	一定期間経過後に、 業績が低下 する企業
案	モデル開発母集団の定義 【業績が悪くはないの定義 (案)】	教師ラベルの定義 【業績が低下の定義 (案)】	補足 【信用力の序列情報】		
①	「信用力の序列情報」が一定程度以上 (債務者区分が要注意先以上など)	「信用力の序列情報」が一定程度以下に遷移 (債務者区分が要管理先以下に下方遷移など)	共同研究先毎に以下の情報を使用 <ul style="list-style-type: none"> 債務者区分 信用スコア 他の共同研究先データから推測した債務者区分や信用スコア (検討事項) 		
②	財務指標 (信用リスク管理等の観点から既に重要と認識している指標) が一定の範囲内	財務指標が一定の範囲より低下			

■ 開発コンセプト2

開発コンセプト	現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル	モデル開発母集団の対象	一定期間内において 経営改善支援の候補となりえる業況 にある企業 (ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業)	モデルによって検知する事象 (教師ラベル)	一定期間経過後、実際に 経営改善支援を受けて、業績が向上 した企業
案	モデル開発母集団の定義 【経営改善支援の候補となりえる業況の定義 (案)】	教師ラベルの定義 【業績が向上の定義 (案)】	補足 経営改善支援を受けた先の定義(案)		
①	「信用力の序列情報」が一定程度以下 (債務者区分が要管理先以下など)	「信用力の序列情報」が一定程度以上に遷移 (債務者区分が、要注意先以上に上方遷移など)	共同研究先毎に以下の情報を使用 <ul style="list-style-type: none"> 「経営改善支援の候補となりえる業況」となった以降に、経営改善支援が実践されたこと 経営改善支援の実施有無の情報を保有していない場合、本条件は課さない想定 		
②	過去一定期間の「信用力の序列情報」が当該時点よりも悪化する水準に遷移 (債務者区分が、正常先から要注意先、要注意先から要管理先に下方遷移したなど)	「信用力の序列情報」がある時点からより良好な水準へ遷移 (債務者区分が、要管理先から要注意先、要注意先から正常先など上方遷移したなど)			

モデル開発母集団と教師ラベルの定義

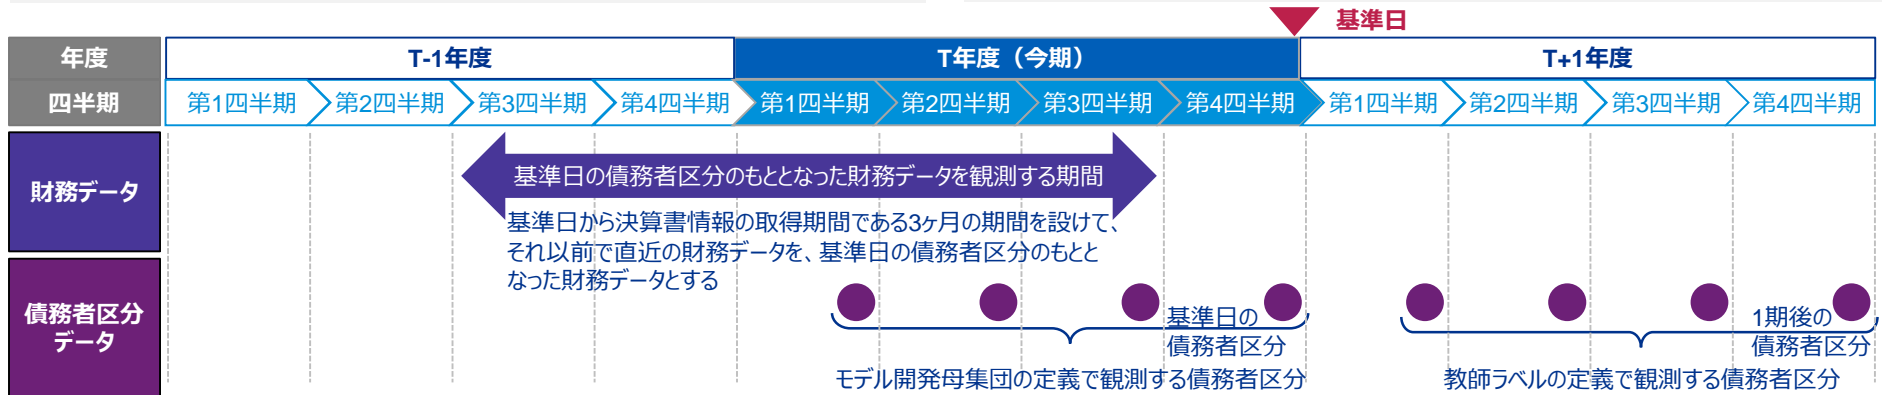
- 共同研究先データに対して、開発コンセプト毎にモデル開発母集団の定義と、教師ラベルの定義を行うにあたっての、共通的な考え方を以下に示す。
- ただし、**債務者区分ではなく信用スコアを有する共同研究先については当該スコアを用いて、下記と同じ概念で定義する（以下同様）。**

モデル開発母集団の定義

- 以下3点の条件を満たす企業から、モデル開発母集団の対象を定義する。
 - 基準日時点の債務者区分のもととなった財務データとその1年前財務を有する（2期連続の財務データを有する）
 - 基準日から1期後の債務者区分を有する
 - 基準日から過去1年間の債務者区分を観測し、開発コンセプト毎に定めた基準に該当する
- 基準日から過去1年間の債務者区分とは、基準日含む過去4四半期の債務者区分とする。ただし、期末のみ債務者区分が付与されている企業については、基準日の債務者区分のみ観測する。

教師ラベルの定義

- 教師ラベルは、開発コンセプト毎に、モデルによって検知する事象に該当する企業を「正例」、それ以外の企業を「負例」として定義する。
- 基準日より未来の1年間の債務者区分を観測し、開発コンセプト毎に定めた基準にもとづいて教師ラベルを付与する。
- 基準日より未来の1年間の債務者区分とは、基準日を除いた未来の4四半期分の債務者区分とする。ただし、期末のみ債務者区分が付与されている企業については、1年後の債務者区分のみ観測する。



モデル開発母集団と教師ラベルの定義

– 開発コンセプト1 [1/2]

【モデル開発母集団の定義】

- 「一定期間内において業績が悪くはない企業」をモデル開発母集団の対象とする。
- 基準日から過去1年間の債務者区分を観測し、モデル開発母集団の対象・対象外とするものを、その例とともに以下に示す。

対象 / 対象外	基準日から過去1年間の債務者区分	基準日から過去1年間の債務者区分の例（基準日を2016年3月とした場合）				
		債務者区分付与の頻度	2015年6月	2015年9月	2015年12月	2016年3月(基準日)
モデル開発母集団の対象	常に「正常先」	四半期ごと	正常先	正常先	正常先	正常先
		期末のみ	—	—	—	正常先
	もっとも悪い区分が「要注意先」	四半期ごと	正常先	要注意先	要注意先	正常先
		期末のみ	—	—	—	要注意先
モデル開発母集団の対象外	もっとも悪い区分が「要管理先」以下	四半期ごと	要管理先以下	要注意先	要注意先	要注意先
		期末のみ	—	—	—	要管理先以下

モデル開発母集団と教師ラベルの定義

– 開発コンセプト1 [2/2]

【教師ラベルの定義】

- 「一定期間経過後に、業績が低下する企業」をモデルによって検知する事象（教師ラベル）とする。
- 教師ラベルは、「一定期間経過後に、業績が低下する企業」を「正例」、「それ以外の企業」を「負例」として定義する。
- 具体的には下表の通り、基準日から過去1年間の債務者区分と、当該基準日から1期後（1年後）までの債務者区分の変化に応じて、教師ラベルを定義する。

#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル	#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル
1	常に「正常先」	常に「正常先」	負例	4	もっとも悪い区分が「要注意先」	常に「正常先」	負例
2	常に「正常先」	もっとも悪い区分が「要注意先」	正例	5	もっとも悪い区分が「要注意先」	もっとも悪い区分が「要注意先」	負例
3	常に「正常先」	もっとも悪い区分が「要管理先」以下	正例	6	もっとも悪い区分が「要注意先」	もっとも悪い区分が「要管理先」以下	正例

- 上記定義における、基準日から1期後までの債務者区分は以下のとおり（債務者区分付与の頻度が四半期の場合のみ記載。期末のみ債務者区分が付与されている企業については、基準日から1期後の債務者区分のみ観測する）。なお、開発コンセプト2も同様とする。

基準日から1期後までの債務者区分	基準日から1期後までの債務者区分の例（基準日を2016年3月とした場合）				
	2016年3月 (基準日)	2016年6月	2016年9月	2016年12月	2017年3月 (1期後)
常に「正常先」		正常先	正常先	正常先	正常先
もっとも悪い区分が「要注意先」		正常先	要注意先	正常先	正常先
もっとも悪い区分が「要管理先」以下		要注意先	要注意先	要管理先	要注意先

モデル開発母集団と教師ラベルの定義

– 開発コンセプト2 [1/2]

【モデル開発母集団の定義】

- 「一定期間内において経営改善支援の候補となりえる業況にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）」をモデル開発母集団の対象とする。
- ただし、「経営改善支援を受けた」かの条件は、経営改善支援有無データを保有する共同研究先データに対してのみ課す。
- 基準日から過去1年間の債務者区分を観測し、モデル開発母集団の対象・対象外とするものを、その例とともに以下に示す

対象 / 対象外	基準日から過去1年間の債務者区分	基準日から過去1年間の債務者区分の例（基準日を2016年3月とした場合）					
		債務者区分付与の頻度	2015年6月	2015年9月	2015年12月	2016年3月（基準日）	
モデル開発母集団の対象	常に「要注意先」	四半期ごと	要注意先	要注意先	要注意先	要注意先	
		期末のみ	—	—	—	要注意先	
	常に「要管理先」	四半期ごと	要管理先	要管理先	要管理先	要管理先	
		期末のみ	—	—	—	要管理先	
	「要注意先」と「要管理先」が混在		四半期ごと	要注意先	要管理先	要注意先	要注意先
	モデル開発母集団の対象外	常に「正常先」	四半期ごと	正常先	正常先	正常先	正常先
期末のみ			—	—	—	正常先	
「正常先」と、「要注意先」・「要管理先」が混在		四半期ごと	正常先	要注意先	要管理先	要注意先	
もっとも悪い区分が「破綻懸念先」以下		四半期ごと	要注意先	要管理先	破綻懸念先	実質破綻先	
		期末のみ	—	—	—	破綻懸念先	

モデル開発母集団と教師ラベルの定義

– 開発コンセプト2 [2/2]

【教師ラベルの定義】

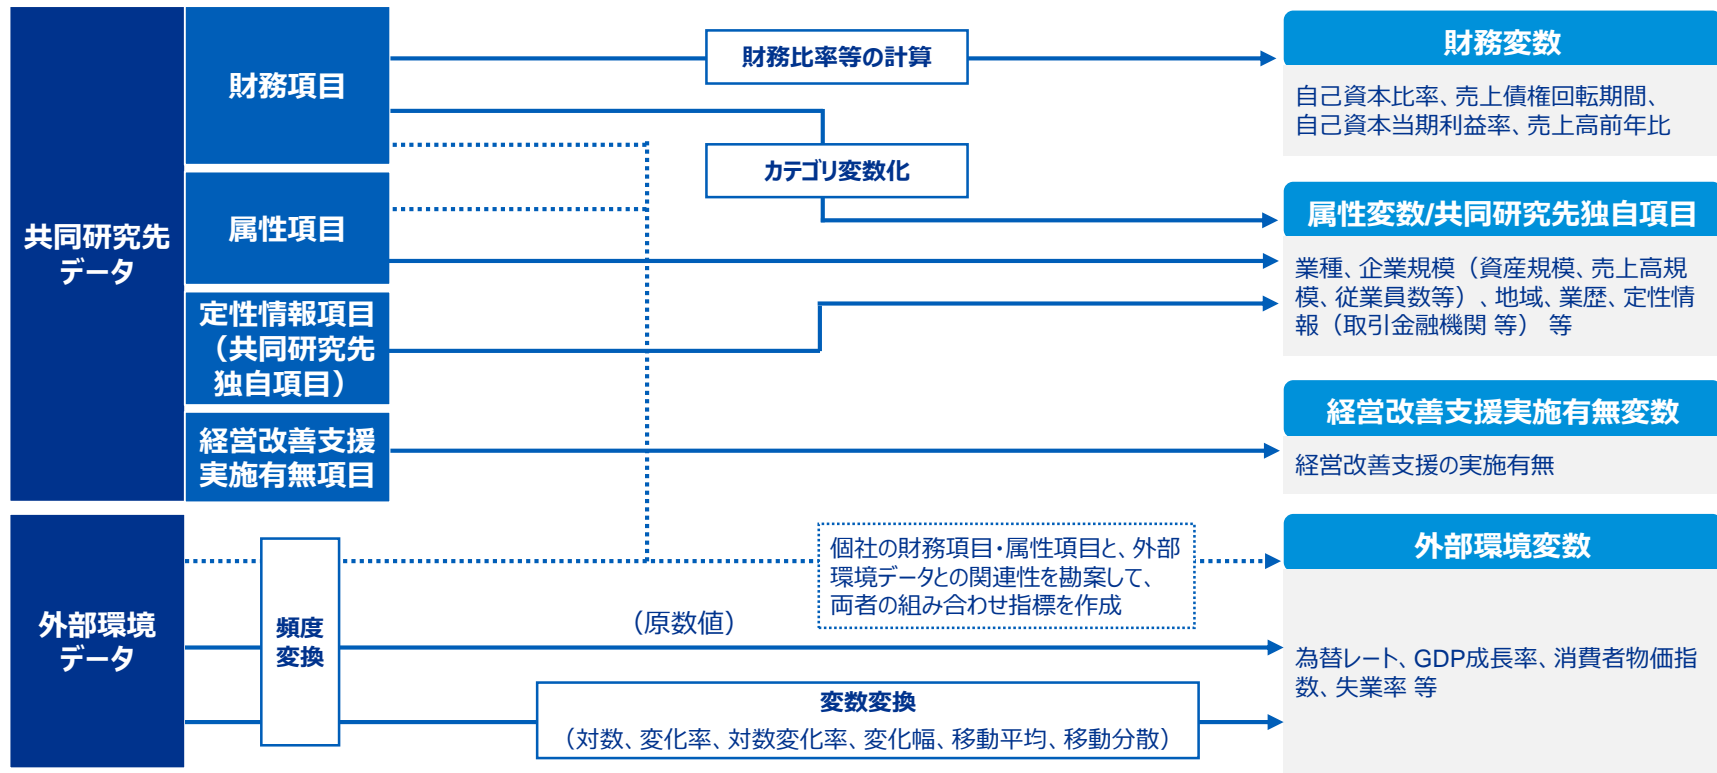
- 「一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業」をモデルによって検知する事象（教師ラベル）とする。
- ただし、「経営改善支援を受けた」かの条件は、経営改善支援有無データを保有する共同研究先データに対してのみ課す。
- 教師ラベルは、「一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業」を「正例」、「それ以外の企業」を「負例」として定義する。
- 具体的には下表の通り、基準日から過去1年間の債務者区分と、当該基準日から1期後（1年後）までの債務者区分の変化に応じて、教師ラベルを定義する。

#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル
1	常に「要注意先」	常に「正常先」	正例
2	常に「要注意先」	もっとも悪い区分が「要注意先」	負例
3	常に「要注意先」	もっとも悪い区分が「要管理先」以下	負例

#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル
4	常に「要管理先」	常に「正常先」	正例
5	常に「要管理先」	もっとも悪い区分が「要注意先」	正例
6	常に「要管理先」	もっとも悪い区分が「要管理先」以下	負例
#	基準日から過去1年間の債務者区分	基準日から1期後までの債務者区分	教師ラベル
7	「要注意先」と「要管理先」が混在	常に「正常先」	正例
8	「要注意先」と「要管理先」が混在	もっとも悪い区分が「要注意先」	負例
9	「要注意先」と「要管理先」が混在	もっとも悪い区分が「要管理先」以下	負例

説明変数の作成

- 共同研究先データ、外部環境データを使用して、財務比率等の計算、カテゴリ変数化、変数変換、財務項目・属性項目と外部環境データの組み合わせ指標の作成を行い、「財務変数」、「属性変数」、「経営改善支援実施有無変数」、「外部環境変数」をモデルの説明変数として作成した。
- 共同研究先データと外部環境データからの各変数作成フローは、下図のとおり。



説明変数の作成

– 財務変数の作成

- 共同研究先データの財務項目同士を組み合わせることで財務比率等を計算し、100以上の財務変数を作成した。
- 作成した財務変数は、「健全性」、「効率性」、「収益性」、「成長性」、「生産性」、「流動性」、「債務償還能力」、「資金繰り」の観点から評価できるものごとに分類を行った。
- 上記のように、分類を行った理由は、以下のとおり。
 - 単変量分析における説明変数の1次絞り込みや、モデルの変数選択を、各評価観点を持つ変数にてバランス良く行うため。
 - モデルからの出力UIに表示される財務変数を分類ごとに整理することで、顧客への説明が容易になると思料するため。
- 分類ごとの財務変数の例は以下のとおり。

#	分類	財務変数の例
1	健全性	自己資本比率、固定長期適合率 等
2	効率性	売上債権回転期間、棚卸資産回転期間 等
3	収益性	自己資本当期利益率、売上高経常利益率 等
4	成長性	売上高前年比、営業利益前年比 等
5	生産性	従業員一人当たり売上高、売上高付加価値率
6	流動性	当座比率、流動比率 等
7	債務償還能力	インタレストカバレッジレシオ、総債務償還年数 等
8	資金繰り	売上高キャッシュフロー比率、売上高運転資本比率

単変量分析

- 財務変数、属性変数、外部環境変数については、多重共線性の排除、モデル解釈性の向上等を目的として、以下の内容にて説明変数の絞り込みを実施した。（欠損率を除いた以下の処理はロジスティック回帰にのみ適用。それ以外のAIアルゴリズムには本件は適用しない）
 - モデル開発コンセプトごとに、教師ラベルに対して1つの説明変数として構築したロジスティック回帰モデルの欠損率、AR値、推定値のP値、符号条件が、設定した基準を満たす変数を、説明変数とする（属性変数についてはロジスティック回帰モデルは構築せず、欠損率のみを確認する）。
 - 財務変数、外部環境変数については、説明変数間の相関係数を確認し、強相関となった変数の対については、一方のみを説明変数候補とする（財務変数については、分類ごとに相関係数の確認を行う）。

【単変量分析で設定した基準】

欠損率

欠損率が多い変数は除外

AR値

単一の変数だけでもある程度の説明力を有するものに限定

P値

単一の変数だけでも統計的な有意性を有するかを判定

符号条件

教師ラベルと変数間の正負の関係性を設定

【相関係数の確認の例（債務償還能力に分類される財務変数間の相関係数）】

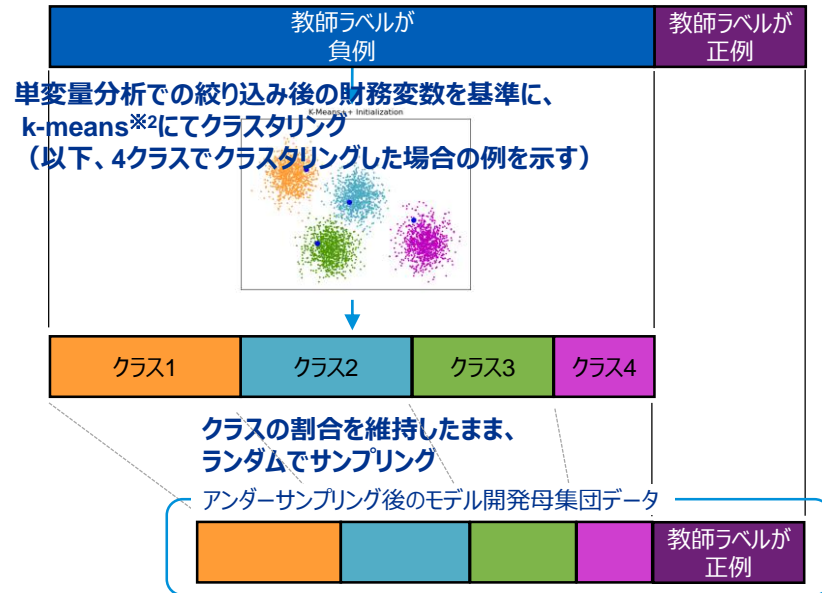
変数名	変数ラベル	相関係数																
IDX074	支払利息割引料総利益率	1.00	0.37	0.56	0.00	0.00	-0.06	-0.06	0.68	0.38	0.97	0.00	0.00	0.00	0.00	0.02	0.05	0.06
IDX075	支払利息割引料営業利益率	0.37	1.00	0.78	0.00	0.01	-0.02	-0.02	0.62	0.98	0.34	0.00	0.00	0.00	0.00	-0.06	-0.07	-0.09
IDX076	支払利息割引料経常利益率	0.56	0.78	1.00	0.00	0.00	-0.03	-0.03	0.82	0.80	0.53	0.00	0.00	0.00	0.00	-0.07	-0.07	-0.09
IDX077	売上高金利負担率	0.00	0.00	0.00	1.00	0.54	0.07	0.05	0.00	0.00	0.12	0.05	-0.01	0.00	0.01	0.00	0.00	0.00
IDX078	売上高純金利負担率	0.00	0.01	0.00	0.54	1.00	0.07	0.09	0.00	0.01	-0.02	0.02	0.01	-0.01	0.00	0.01	0.00	0.00
IDX079	総資産金利負担率	-0.06	-0.02	-0.03	0.07	0.07	1.00	0.96	-0.04	-0.02	-0.06	0.01	0.00	0.00	0.00	-0.05	-0.05	-0.05
IDX080	総資産純金利負担率	-0.06	-0.02	-0.03	0.05	0.09	0.96	1.00	-0.04	-0.02	-0.06	0.01	0.00	0.00	0.00	-0.05	-0.05	-0.05
IDX081	金利カバレッジ	0.68	0.62	0.82	0.00	0.00	-0.04	-0.04	1.00	0.63	0.67	0.00	0.00	0.00	0.00	-0.08	-0.08	-0.08
IDX082	インタレストカバレッジレシオ	0.38	0.98	0.80	0.00	0.01	-0.02	-0.02	0.63	1.00	0.35	0.00	0.00	0.00	0.00	-0.06	-0.07	-0.09
IDX083	支払利息割引料現金預金率	0.97	0.34	0.53	0.00	-0.02	-0.06	-0.06	0.67	0.35	1.00	0.00	0.00	0.00	0.00	0.02	0.06	0.07
IDX084	総支出支払利息割引料率	0.00	0.00	0.00	0.12	0.02	0.01	0.01	0.00	0.00	0.00	1.00	0.28	0.00	0.00	0.00	0.00	0.00
IDX085	経費支払利息割引料率	0.00	0.00	0.00	0.05	0.01	0.00	0.00	0.00	0.00	0.00	0.28	1.00	0.00	0.00	0.00	0.00	0.00
IDX086	流動資産引当率	0.00	0.00	0.00	-0.01	-0.01	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.06	0.00	0.00	0.00
IDX087	当座資産引当率	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	1.00	0.00	0.00	0.00
IDX088	債務超過解消年数	0.02	-0.06	-0.07	0.01	0.01	-0.05	-0.05	-0.08	-0.06	0.02	0.00	0.00	0.00	0.00	1.00	0.50	0.37
IDX089	総債務償還年数	0.05	-0.07	-0.07	0.00	0.00	-0.05	-0.05	-0.08	-0.07	0.06	0.00	0.00	0.00	0.00	0.50	1.00	0.66
IDX090	純有利子負債償還年数	0.06	-0.09	-0.09	0.00	0.00	-0.05	-0.05	-0.08	-0.09	0.07	0.00	0.00	0.00	0.00	0.37	0.66	1.00

学習用データとテスト用データの作成

- モデル開発母集団に占める負例の割合と正例の割合が大きく異なるデータ（不均衡データ）をそのまま用いて機械学習モデルを構築すると、見かけ上の精度（正解率：Accuracy）は高いものの、正例を正しく正例と予測する精度（再現率：Recall）が低くなる。そのため、正例のサンプル数に合わせて、不均衡データをアンダーサンプリングし、バランス調整を行う。
- 上記のアンダーサンプリングを実施したデータを、モデル構築を行う学習用データ、モデルのハイパーパラメータの検証を行うパラメータ検証用データ、構築したモデルの精度を確認するテスト用データに分割する※1。
- アンダーサンプリングとデータの分割イメージは下図のとおり。

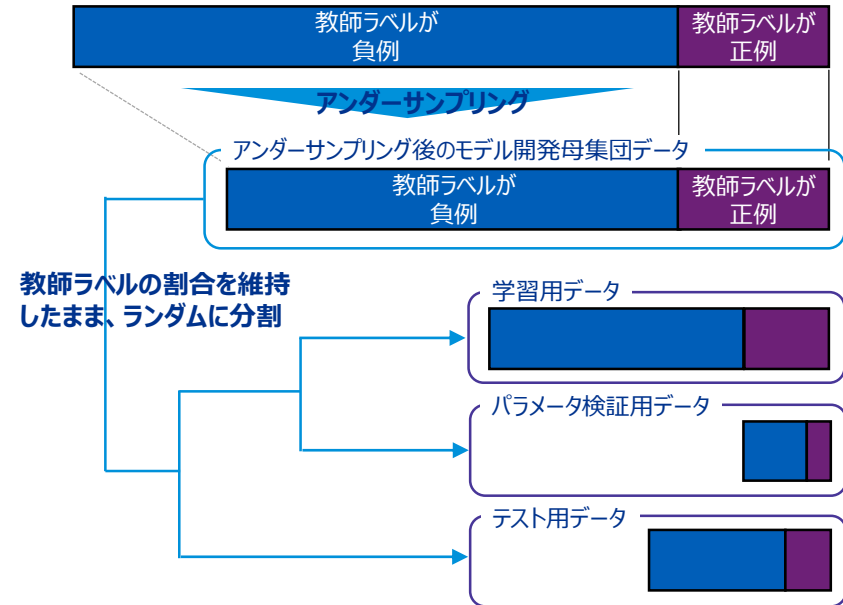
【アンダーサンプリング】

モデル開発母集団すべてのデータ



【データの分割】

モデル開発母集団すべてのデータ



※1 データ分割の考え方は、「機械学習モデル構築におけるデータの分割の概説」（本資料 p.44）に記載。

※2 k-meansは、クラスタリング手法の1つで、クラスターの数だけデータの重心を求め、その重心に最も近いデータを当該クラスターに分類されるデータと定める分類アルゴリズム

モデルの評価指標

■ 本調査・研究で開発するAIモデルを評価する指標は、各評価の観点から鑑みて下表のように設定した。

#	評価観点	評価指標	補足説明
1	<ul style="list-style-type: none"> モデル全体の精度が高いか 企業を信用力に応じて序列付けることができるか 	<ul style="list-style-type: none"> AUC、AR値 (数値による評価指標) CAP曲線 (視覚的な評価) 	<ul style="list-style-type: none"> 経営改善支援候補先に対する職員による精査が、現行業務と比べて削減されるような高い精度を持つかを評価するもの 特定の条件 (例：閾値を設定する) を設けず、モデル全体として一定以上の精度があるかを評価 機械学習モデルの2値分類問題ではAUCを用いることが多いため本調査・研究ではAUCを設定。また信用リスク管理の実務上AR値を用いることも多いため、AR値も設定 (参考：AR値 = AUC × 2 - 1)
2	<ul style="list-style-type: none"> モデルスコアのある閾値以上の先に多く正例 (経営改善支援が必要な先) が含まれるか 	<ul style="list-style-type: none"> スコアランク毎の正例の割合 適合率 (precision) (正と予測したものに対し、実際に正であるものの割合) 	<ul style="list-style-type: none"> 本モデルを実務に活用する際は、あるスコア以上の企業を抽出し、その先の一部もしくは全部に対し経営改善支援を実施する想定 そのため抽出された企業に多く経営改善支援が必要な先が含まれていることが重要なため、本評価指標を設定。当該評価が高いと支援候補先の精査を行う職員の業務負荷削減につながる
3	<ul style="list-style-type: none"> モデルスコアのある閾値以上の先の正例 (経営改善支援が必要な先) が、全体の正例の多くを捕捉できているか 	<ul style="list-style-type: none"> 再現率 (recall) (実際に正のものに対し、正しく正と予測できたものの割合) 	<ul style="list-style-type: none"> あるスコア以上の企業を抽出した際、経営改善支援が必要な先のうち何割を捕捉できているかを評価するための指標 当該評価が高いと、これまで捕捉することのできなかった経営改善支援候補先が特定できることを意味する

(参考) プロトタイプAI開発の進捗状況

– 今回の研究会で報告するプロトタイプAI (ver.0)

- モデル開発計画で定めたモデルのうち今回の研究会で報告するプロトタイプAI (ver.0) は、下表のとおり、開発コンセプト1、開発コンセプト2ともに財務のみモデル、共同研究先モデルである。
- 各モデルごとに1つの共同研究先データを用いて構築したものを報告する。

【モデル開発計画と、今回の研究会で報告するモデル】

 : 今回の研究会で報告するモデル

開発コンセプト	開発コンセプト1			開発コンセプト2				
手法	予測			予測	因果推論			
データ頻度	年次		月次	年次				
構築するモデル	財務のみモデル	汎用モデル	共同研究先モデル	月次モデル	財務のみモデル	汎用モデル	共同研究先モデル	因果推論モデル

【各モデルにて使用する説明変数】



【財務のみモデルと共同研究先モデルの関係】



(参考) プロトタイプAI開発の進捗状況

– 開発コンセプト1 (財務のみモデル) [1/2]


【使用する説明変数】

財務変数


【モデルの精度】

	ロジスティック 回帰	ランダム フォレスト	勾配 ブースティング
AUC	0.654	0.657	0.670
AR値	0.308	0.313	0.340

【スコアランクごとの正例の割合】



【CAP曲線】

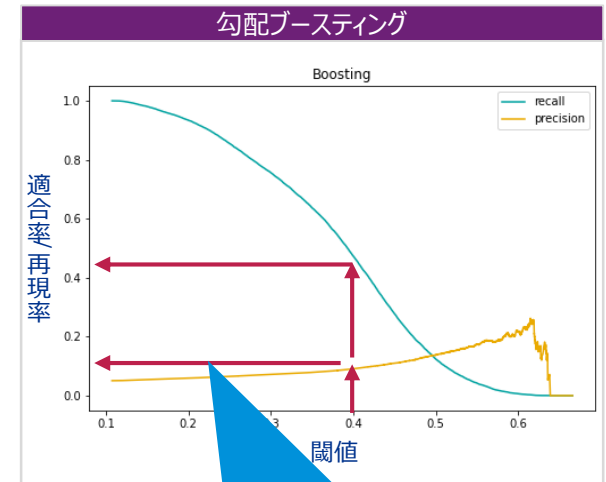

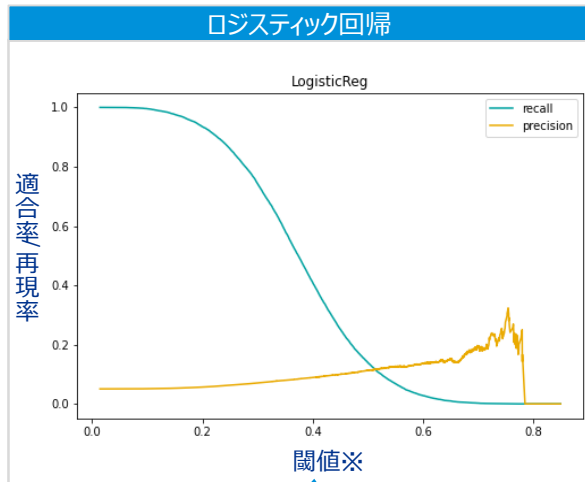


(参考) プロトタイプAI開発の進捗状況

– 開発コンセプト1 (財務のみモデル) [2/2]

【適合率 (Precision) と再現率 (Recall)】

正例と負例を判定する閾値を変化させた時の、適合率 (Precision) と再現率 (Recall) の推移は以下のとおり。



※出力されるスコアのある値より悪い先をモデルが予測する正例とする。そのための閾値

- 閾値を仮に0.4とした場合、適合率 (precision) が約0.1、再現率 (recall) が約0.4となっている。
- そのため閾値以上の先には、約1割正例が含まれ、その捕捉された正例は、全正例先の約4割を占めることを意味する。
- 閾値を上げると適合率は上がるが、再現率は下がることになる。

(参考) プロトタイプAI開発の進捗状況

– 開発コンセプト1 (共同研究先モデル) [1/2]


【使用する説明変数】




【モデルの精度】

	ロジスティック 回帰	ランダム フォレスト	勾配 ブースティング
AUC	0.637	0.649	0.679
AR値	0.271	0.298	0.359

【スコアランクごとの正例の割合】



【CAP曲線】


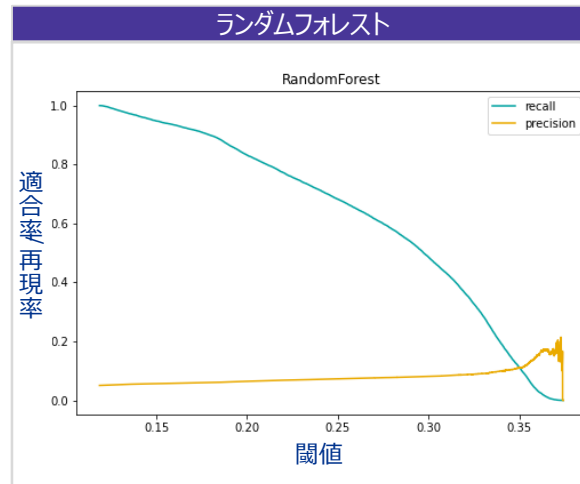



(参考) プロトタイプAI開発の進捗状況

– 開発コンセプト1 (共同研究先モデル) [2/2]

【適合率 (Precision) と再現率 (Recall)】

正例と負例を判定する閾値を変化させた時の、適合率 (Precision) と再現率 (Recall) の推移は以下のとおり。



(参考) プロトタイプAI開発の進捗状況

– 開発コンセプト2 (財務のみモデル) [1/2]


【使用する説明変数】

財務変数


【モデルの精度】

	ロジスティック 回帰	ランダム フォレスト	勾配 ブースティング
AUC	0.790	0.799	0.803
AR値	0.580	0.598	0.606

【スコアランクごとの正例の割合】



【CAP曲線】






(参考) プロトタイプAI開発の進捗状況

– 開発コンセプト2 (財務のみモデル) [2/2]

【適合率 (Precision) と再現率 (Recall)】

正例と負例を判定する閾値を変化させた時の、適合率 (Precision) と再現率 (Recall) の推移は以下のとおり。



(参考) プロトタイプAI開発の進捗状況

– 開発コンセプト2 (共同研究先モデル) [1/2]

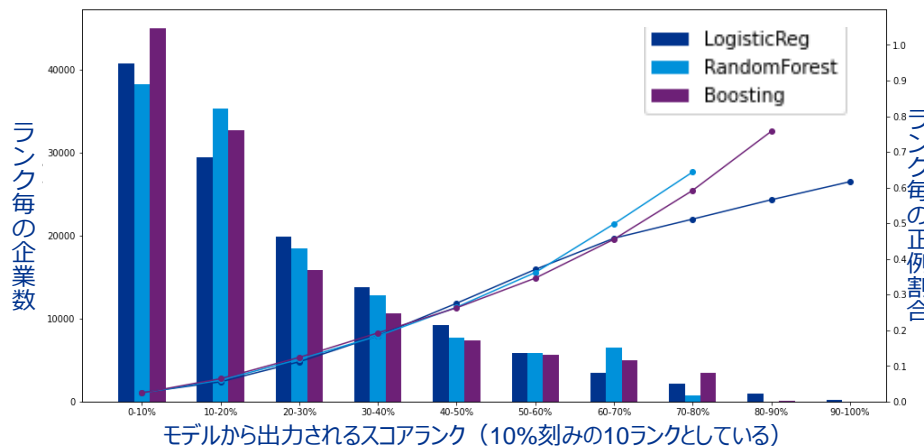
【使用する説明変数】




【モデルの精度】

	ロジスティック 回帰	ランダム フォレスト	勾配 ブースティング
AUC	0.799	0.800	0.811
AR値	0.599	0.599	0.622

【スコアランクごとの正例の割合】



【CAP曲線】






(参考) プロトタイプAI開発の進捗状況

– 開発コンセプト2 (共同研究先モデル) [2/2]

【適合率 (Precision) と再現率 (Recall)】

正例と負例を判定する閾値を変化させた時の、適合率 (Precision) と再現率 (Recall) の推移は以下のとおり。





1 スケジュール、本研究会の議題等

2 KPIとモデル開発計画

3 モデル開発用データ整備とモデルの評価指標

4 AIからの出力結果の実務活用


5 添付資料

AIからの出力UIイメージとその活用

– 開発コンセプト1および2のUIイメージ [1/2]

- 開発されたAIモデルの出力結果を経営改善支援の業務に活用するためには、機能性の高いユーザーインターフェース（UI）が求められる。
- モデル開発コンセプト毎に、UIとしては大きく2つの機能が必要である＊。
 - 企業の足もとの業況が分かるUI（下図）
 - 将来の財務/外部環境変数の値を任意で指定することにより、将来のスコアがシミュレーションできるUI（次ページ）

法人名	顧客口座番号	ID	担当支店
〇〇〇〇〇〇	11112222	123456789	〇〇駅前店
基本情報		他行からの借り入れ状況	
所在地		借入先	借入日
業種	宿泊業	〇〇〇〇	〇〇年〇日
貸付日	〇〇年〇月〇日		借入金額
貸付金額	〇〇〇〇万円		〇〇〇万円
利率	〇.〇〇%		
規模	売上高	30億5千万円	
	従業員数	350人	
主要な経営指標			
分類	指標名	当該企業	業種平均
健全性	自己資本比率	9.3%	13.9%
	固定長期適合率	85.0%	98.7%
効率性	売上債権回転期間	0.35	0.26
	棚卸資産回転期間	0.21	0.21
収益性	自己資本当期利益率	6.9%	13.8%
	売上高経常利益率	2.5%	2.3%
成長性	売上高前年比	101.0%	104.3%
	営業利益前年比	109.8%	101.4%



＊今回の研究会では概念について議論するものの、実際に実装するにあたってのUIは、各機関ごとに設計が必要。

AIからの出力UIイメージとその活用

– 開発コンセプト1および2のUIイメージ [2/2]


- 将来の財務/外部環境変数の値をユーザーが任意で指定することにより、将来のスコアがシミュレーションできるUIのイメージは以下の通り。
- ユーザーが任意に財務や外部環境の変数を設定することで、コロナ等で財務状況や外部環境が変化した場合の影響等を把握することが可能。

■ シミュレーション設定インターフェース (イメージ)

財務			
	ベースシナリオ	シナリオ1	シナリオ2
売上高前年比	101.3%	85.0%	110.0%
総債務償還年数	15.2	19.4	11.8
〇〇〇	〇〇		
〇〇〇	〇〇		

外部環境 (2015年3月を100とした指数)			
	ベースシナリオ	シナリオ1	シナリオ2
宿泊定員稼働率	49.7	32.1	89.3
訪日外国人客数	12.7	4.3	25.9

ユーザーが任意に指定 (AIでは予測できない)





1 スケジュール、本研究会の議題等

2 KPIとモデル開発計画

3 モデル開発用データ整備とモデルの評価指標


4 AIからの出力結果の実務活用

5 添付資料

AIアルゴリズムの概説 [1/4]

■ ロジスティック回帰の概説

下図のようなロジスティック曲線を用いて、目的変数を回帰分析の手法で予測する方法。金融機関実務において企業の信用力評価に最も活用されている方法。



$$Z = \alpha_0 + \beta_1 X_1 + \beta_2 X_2 + \dots$$


X_i : i 番目の説明変数 (特徴量)

α_0 、 β_i : 切片および回帰係数

AIアルゴリズムの概説 [2/4]

■ ランダムフォレストの概説


多くの決定木モデルを構築し、多数の決定木の予測値の平均値を最終的な予測値とする方法



AIアルゴリズムの概説 [3/4]

■ 勾配ブースティングの概説

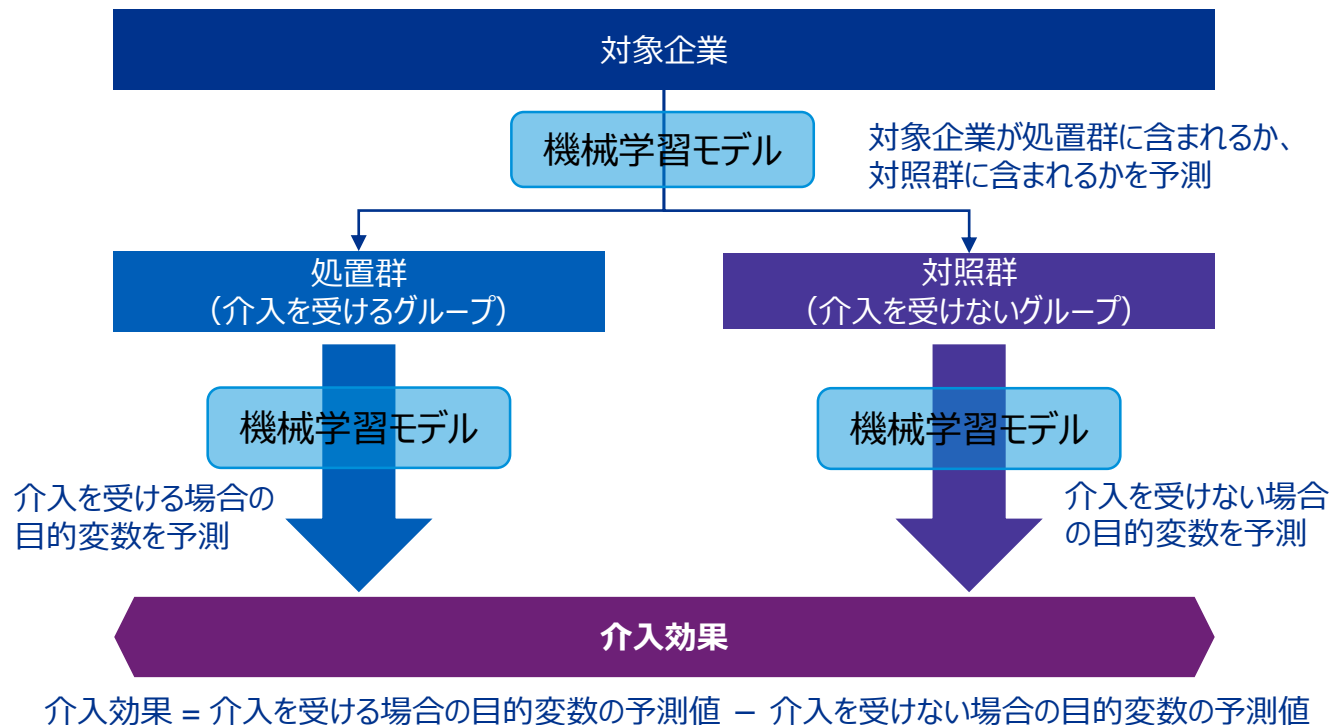
決定木を構築し、当該決定木が外したサンプルに当てはまるようにウェイトを調整して、次の決定木を構築する。これを繰り返して最終的な予測値とする方法



AIアルゴリズムの概説 [4/4]

■ Meta-Learnersの概説

因果推論を行うための論理フローの各ポイントに主要な機械学習アルゴリズム（ロジスティック回帰、ランダムフォレスト等）を適用し、介入効果の推定を行う手法。

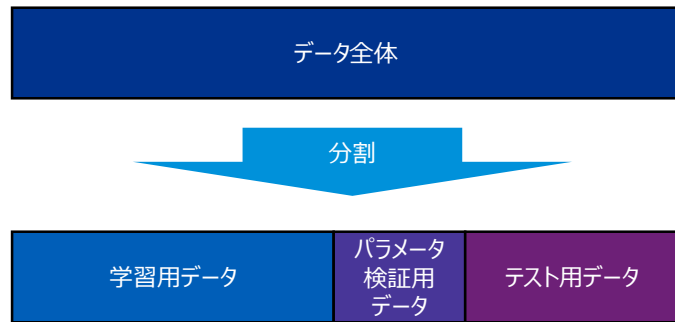


(注) Meta-Learnersの中には様々なアルゴリズムがあり、各ポイントにおける機械学習モデルの適用有無や適用方法、介入効果の算出方法は、各アルゴリズムによって異なる。

機械学習モデル構築におけるデータの分割の概説

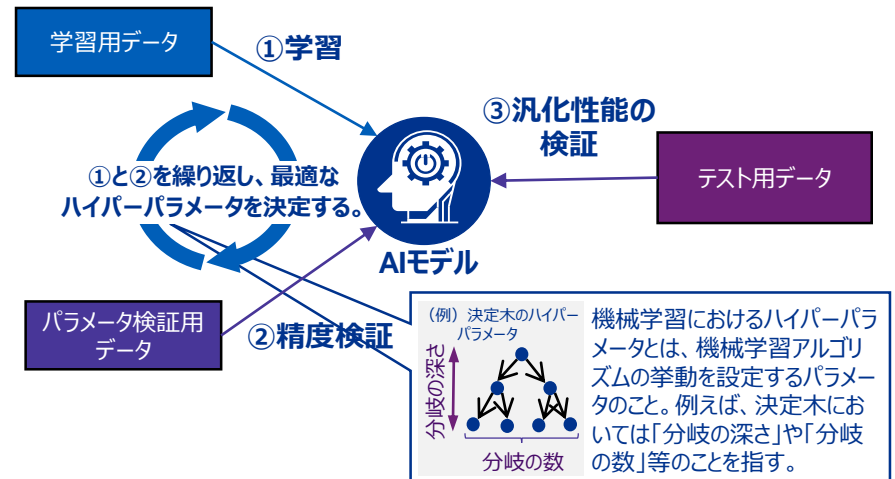
- モデル構築においては、ひとかたまりのデータを用途別に分割しておくことが一般的で、大別すると学習用データと、テスト用データに分割を行う。
- 機械学習モデルは、未知のデータに対して精度が悪化する「過学習」を起こしやすいため、モデルを構築した後に未知のデータで性能（汎化性能）を測る必要があり、学習用データを使用してモデルの構築を行い、未知のデータとしてテスト用データを使用してそのモデルの汎化性能を検証する。
（通常、未知のデータは目的変数の値（正解）が分からないため、既知データで構築したモデルを評価することが出来ないが、データの分割を行うことで目的変数の値（正解）を持った未知データとして扱うことが可能となる。）
- また機械学習モデルは、ハイパーパラメータのチューニングを行う必要があることから、チューニングによる精度検証を行うためのデータが必要になる。上記の学習用データとテスト用データに加えて、そのパラメータ検証用のデータも、ひとかたまりのデータから分割して作成する。

データの分割



※各データに分割する割合は、モデル構築の条件に合わせて都度決定する。

分割したデータを使ったモデル構築フロー



AIモデルの評価指標の概説 [1/2]

- 本資料にて示したAIモデルの評価指標である、適合率、再現率についての概説は以下のとおり。

混同行列と評価指標

- 混同行列は、モデルでデータを分類した際にその正解・不正解をまとめた行列のこと。クラス分類を行うモデルの性能・精度の確認に使用される。
- 正例（ポジティブ）と負例（ネガティブ）の2クラスがあるデータセットに対して、以下が定義される。
 - 真陽性（True Positive、TP）：実際にポジティブのデータを正しくポジティブと予測したもの（数）
 - 偽陽性（False Positive、FP）：実際にはネガティブのデータを間違ってポジティブと予測したもの（数）
 - 真陰性（True Negative、TN）：実際にネガティブのデータを正しくネガティブと予測したもの（数）
 - 偽陰性（False Negative、FN）：実際にはポジティブのデータを間違ってネガティブと予測したもの（数）

		モデルの予測	
		1 (Positive)	0 (Negative)
実データの クラス	1 (Positive)	TP	FN
	0 (Negative)	FP	TN

- 上記で定義した混同行列の4つの数値を使用して、以下のような評価指標が計算される。


- 正解率(accuracy) = $\frac{TP+TN}{TP+FP+FN+TN}$ ・ 予測結果全体に対し正しく予測できたものの割合
- 適合率(precision) = $\frac{TP}{TP+FP}$ ・ ポジティブと予測したものに、実際にポジティブであるものの割合
- 再現率(recall) = $\frac{TP}{TP+FN}$ ・ 実際にポジティブのものに対し、正しくポジティブと予測できたものの割合

AIモデルの評価指標の概説 [2/2]

- 本資料にて示したAIモデルの評価指標である、AUC、AR値、CAP曲線についての概説は以下のとおり。

ROC曲線とAUC


- モデルにデータを当てはめたとき、実際にイベント（「企業業績の低下」など、モデルによって検知する事象）が発生した全てのデータのうち、正しく検知ができた割合のことを、真陽性率（TPR）という。また、実際にイベントが発生しなかった全てのデータのうち、間違えて検知した割合を偽陽性率（FPR）という。
- 検知するかしないかは、モデルで推定されたイベント発生確率に対して閾値を設け、それを上回ったかどうかで判定しており、**ROC曲線**は、当該閾値を変更した際に変化するTPRとFPRをそれぞれ縦軸、横軸にプロットしたもので、下図のような曲線を描く。



- **AUC (Area Under the Curve)** は、ROC曲線の下部分の面積のことをいう。ROC曲線は、右にいくほど下がることはないこと、偽陽性率（横軸）が小さい段階で、真陽性率が高いモデルほど良いことから、AUC（上記面積）が大きいほど、優れたモデルであることを意味する。

CAP曲線とAR値

- **CAP曲線**は、横軸にモデルで推定されたイベント発生確率の上位 x 件の、全てのデータ件数 (N) に対する割合 (x/N) を、縦軸に推定されたイベント確率の高い上位 x 件のうち実際にイベントが発生した件数 (N_x) の、イベントが発生した全てのデータ件数 (N_1) に対する割合 (N_x / N_1) をプロットしたものであり、下図の**B**のような曲線を描く。
- モデルの説明力が全くない場合は **C** の直線を描き、予測が完全に正解したモデルの場合は **A** のような形を描く。



- BとCで囲まれた部分の面積の、AとCで囲まれた部分の面積に対する比を、**AR値**という。すなわち、値が1に近づくほど、予測が完全に正解したモデルに近いということの意味する。

$$\text{AR値} = \frac{\text{BとCで囲まれた部分の面積}}{\text{AとCで囲まれた部分の面積}}$$



ここに記載されている情報はあくまで一般的なものであり、特定の個人や組織が置かれている状況に対応するものではありません。私たちは、的確な情報をタイムリーに提供できるよう努めておりますが、情報を受け取られた時点およびそれ以降においての正確さは保証の限りではありません。何らかの行動を取られる場合は、ここにある情報のみを根拠とせず、プロフェッショナルが特定の状況を綿密に調査した上で提案する適切なアドバイスをもとにご判断ください。

© 2022 KPMG AZSA LLC, a limited liability audit corporation incorporated under the Japanese Certified Public Accountants Law and a member firm of the KPMG global organization of independent member firms affiliated with KPMG International Limited, a private English company limited by guarantee. All rights reserved.

The KPMG name and logo are trademarks used under license by the independent member firms of the KPMG global organization.

「AI を活用した経営改善支援に係る研究会」(第2回)

開催日時： 9月2日(金) 15時00分～17時00分

開催方法： 「Webex」による Web 会議形式

委員：

有竹 博史 東京信用保証協会 業務総轄室 業務総轄部長
和泉 潔 東京大学大学院 工学系研究科システム創成学 教授
内山 功士 浜松いわた信用金庫 デジタル推進部 デジタル業務課 課長
河合 祐子 Japan Digital Design 株式会社代表取締役 CEO
三川 剛 株式会社エルテス 取締役
鈴木 明美 大東京信用組合 常務理事
筒木 光 TKC 全国会システム委員会 TKC 経営指標編集小委員会 委員
中村 康浩 株式会社横浜銀行 融資部 担当部長
名取 良訓 信金中央金庫 総合企画部しんきんイノベーションHub 次長
松崎 堅太郎 TKC 全国会中小企業支援委員会 副委員長
宮川 大介 一橋大学 経営管理研究科 経営管理専攻 准教授
矢内 紘之 株式会社帝国データバンク 企総部 企画課長
吉田 茂樹 株式会社栃木銀行 事業支援部 副部長

議事進行：

秋場 良太 有限責任あずさ監査法人金融統轄事業部 ディレクター

■アジェンダ

1. 開会
2. 事務局説明
3. 討議
4. 閉会

(主なやり取り)

○ 研究会委員

P7の部分のKPIと評価方法ですが、以前のコメントを反映していただき、ありがとうございます。単なるコメントに近いのですが、このやり方は非常によろしいと思っています。ただ、2つに分けたときに1点気を付けることは、①の観点と②の観点を全く同等にする必要はないということです。どういうことかということ、例えば、②の方で、全体的な精度がおかしくないかをテストするというのでメインにして、①の方である特定のケースでは、今回のデータを使うと非常によくあてはまると。そういう意味では、どちらかということ、①を従というかサブとするという使い形にしてもいいかと思っています。どうしても、新しいデータを使うときには得意不得意がありますので、全ての精度をよくするのは一般的には非常に難しくなります。①はどちらかということサブとして個別のケースを見るという使い方でもいいのかなと思いました。

○ 事務局

まさに、今回のモデルは、一般的な信用リスクモデルと比べると母集団も対象データも広いので、そのようにしたいと思います。次回そういった形でご報告できればと思います。ご意見ありがとうございます。

○ 研究会委員

私も、KPIの設定の仕方やモデルの開発計画については、前回の議論を踏まえていただいているので、いい形になっていると思いました。この後、評価指標をどう設定するかというのは次のセクションでの議論だと思いますので、ここでは、評価するときの方針について、1点コメントします。先ほどの話と重複する部分もありますが、全体のデータに対して、1枚のモデルで望んだ結果が得られるということが実現できれば一番良いと思いますが、必ずしもそうではない場合でも、このセグメントについては、狙った成果が確認できているというまとめ方があるのかなと思いました。過去の多くの取組みをされている中で、既に実績があると思いますが、例えば、製造業と非製造業を分けただけでも予測の難易度にだいぶ差があるみたいなことはよくある話だと思います。必ずしも全体に対して1枚のモデルで通用しなくても、こういう区切りでは適用できるということにも価値があると思います。

○ 事務局

貴重なご意見ありがとうございます。幅広なデータなので、特定ケース、セグメントごとにモデルを作って、そのケースでは有益である、といったまとめ方も検討できればと思います。

○ 研究会委員

丁寧にご説明いただき誠にありがとうございます。非常に楽しみな展開になってきたなと思っています。今回、データの提供者が複数となっていると承っておりまして、分析をするに当たり、データの提供者と申しますか、債権者の主観も含めて判断する区分を評価としてとらえているという枠組みになっていると理解していますが、債務者区分の付け方に、データの提供主体による癖のようなものはないのかであるとか、あるデータの要素に関して債務者区分にはねてくるリアクションまでの期間が要素によっても違うかもしれませんし、データ提供者によっても違うような気がします。その点について、考えがあればお聞かせいただきたいです。

○ 事務局

ありがとうございます。債務者区分をベースに資料を作成しているが、特に経営改善支援の問題意識の一つとして、例えば、資金繰り支援をしている、実抜計画を作成しているなどの場合には、区分をあげている、実際はそんなに恣意性はない一定のルールに基づく区分をつけていますが、さはさりながら実態としてはそういうところがあります。今回はデータ提供者に債務者区分がある場合、本来は信用力の序列情報に基づく信用力の変化を見たいところですが、債務者区分で代替して信用力の変化を見ようと考えております。

本来は、債務者区分という区分をあげている影響に依らないデータも使用したいという思いがありまして、例えば、あるデータ提供会社では信用スコアがついているので、ある程度客観的な情報な気がしますので、それを採用するなど、各データ提供会社のデータの癖に合わせてデータの癖が悪影響を及ぼさないようなモデルを構築していきたいです。例えば、債務者区分には遅効性がありまして、3末に区分がついていたとしても、それは1年前の財務情報を見るなど、データの整備上そういった遅効性は反映しようと思っています。まだ、データを受領したばかりであり、癖を完璧には把握できていない状況ですので、実際に4つの会社様のデータを使って、実際にモデルが仕上がった際には癖が変に影響を与えないように検討していきたいと思っています。

次にモデル開発計画について、財務のみモデルをベースラインにして、汎用モデル、共同研究先モデルを作ることを想定しておりますが、こちらは違和感ありますでしょうか。

○ 研究会委員

特にモデル開発計画には違和感ないと思っています。今取っているデータは銀行系のデータは信ぴょう性がある程度高いから問題ないと思いますが、それ以外のデータを入れた場合に、業種によって影響が出るものが異なると思っています。例えば、円安だとすると、影響が出る業種もあれば、出ない業種もあると思います。また、旅館業とかであれば訪日外国人数など、少し細かい論点だが、そういったことが響いてくることもあります。その辺のモデルの粒度、すなわちマクロ的な影響のみを見ていくのか、ある程度業種に特化した細かいところまで見るのか、両者を併用するのか、その辺りの考え方をご教授いただきたいと思

います。

○ 事務局

ありがとうございます。ご質問の意図としては、マクロ的に非製造業と製造業くらいの区分で有効なものを目指すのか、コロナで特に影響を受けた宿泊業や外食産業のような先にスポットライトをあてるのか、あるいは両方にあてるのかということでしょうか。

○ 研究会委員

そうです。

○ 事務局

こちらはまさに、どういった先にそういったアプローチが効くのかという点はまさに分析しているところです。足元では、細かな業種による影響も見えていたりもしますので、そこは試行錯誤のうえとは思っていますけれども、今回の調査研究の目的としては、いわゆる新型コロナで影響を受けた業種の業況悪化を早めに捕捉したいということですので、広くザクっとしたものというよりは、本当に支援が必要な企業に有益なアプローチができるようなものを構築したいと思っています。想定では、新型コロナの影響を受けたコロナ業種に効くものを、という思いはありますが、実際には試行錯誤しながら進めていきたいと思っています。

○ 研究会委員

P10の真ん中の汎用モデルには、あらゆる中小企業と記載してありますが、ある意味ここにはメッシュがかかるということでしょうか。

○ 事務局

今回の資料でも全体の精度のみ示しておりますが、あまねく精度を上げていくというのは厳しいという感覚もありまして、特定のセグメントに効くものという風になるかもしれませんが、どの金融機関でも使えるものにしていきたいと考えています。

○ 研究会委員

足元、円安の要素がかなりの影響を与えていると思っているので、その辺の要素を反映していただけるといいのかなぁと思っています。

○ 事務局

外部環境変数にはそういった為替データも含んでおりますので、そういった示唆が出せ

ないか検討できるようにしたいと思います。

○ 研究会委員

P18 のコンセプト 1 のラベルが記載してありまして、これ自体はこれでいいと思いますが、マクロトレンドのような全体の事情により要注意先や要管理先になるケースもあると思います。それをラベルの時点で対応するのか、P21 の説明変数の作成の外部環境データの部分で見ると、そういったマクロの影響をどこで吸収しようとしていますでしょうか。

○ 事務局

ありがとうございます。ご質問いただいた内容ですが、トレンドによって要注意、要管理になったところを検知してもあまり意味がないと思います。トレンドの影響をうまく外部環境変数で除外できればいいと思いますが、ちょっとここはやってみないと分からないという状況です。今回、外部環境変数を入れている一番の目的は、円安もそうですし、外国人訪日客数もそうですが、ある業種・業態とマクロの環境は業種によって、為替が効く、エネルギー価格が効く等、異なりますので、そこをメインで分析できればと思っています。

○ 研究会委員

今後の整理のされ方についてお願いがあります。今回、場合分けがものすごく多くなると思います。先ほどの話で更なる業種の場合分けが出てきたときに、だいたい枝分かれがでてくると思います。今後整理をされる際に、マトリックスの形にしてみたり、枝分かれしているものを図示してみたり、どこがワークしていて、どこの部分がワークしないのかといった一覧性のある資料、これは言うのは簡単で作るのは難しいものだと思いますが、そういうものを意識していただくとプロジェクト全体を見通すのも役立つと思いますし、うまくできているところ、できていないところが視覚的にもはっきりしてきますので、ぜひご検討いただければと思います。

○ 事務局

今回は、4つの共同研究先があり、組み合わせの数も多いので、ご指摘を踏まえて、検討したいと思います。ポテンヒットといえますか、開発計画を作成したのに、漏れていたということがないようにしたいと思います。

それでは、最初の議題については、一通り意見をいただき、概ね違和感ないとのことですので、モデル開発計画はこれで進めさせていただければと思います。委員の先生にいただきましたコメントはモデル開発に活かしていきたいと思っています。

次の議題に進みたいと思います。まず、データクレンジングですけれども、こちらは一般的な方法かなと思っていますが、いかがでしょうか。

○ 研究会委員

クレンジングは問題ないです。先ほど申し上げた通り、気になるのは、それぞれの項目が実際に財務の悪化につながるまでのタイミングが異なるという点です。実際に回してみないと分からないと思いますが、その点は少し気になっている。データクレンジング自体の枠組みに気になるところは特にないということです。

○ 事務局

データのタイムラグというのは、スコアがあるデータを使った場合は、スコアが上昇したり下がったりという変化が、どのタイミングで財務に影響を与えたのかということでしょうか。もちろん、外部環境等のマクロ環境も含めてという理解でしょうか。

○ 研究会委員

外部環境も含めてというよりは、例えば、資本が変動した場合と利益が変動した場合というのは、利益が変動してすぐに財務が悪くなるかということそこには、タイムラグがある訳です。それに対して、バランスシートの最終形である資本が変動した場合は、それイコール財務の悪化ということになります。同じ財務諸表に載っている項目ではあるが、その影響のタイミングは項目によって異なるので、その点がとても気になるという点でございます。

○ 事務局

ご指摘いただいたとおり、いつ時点の財務の変化を見てスコアに反映しているか等、それぞれの共同研究先の中で行っている実務に依存すると思うので、共同研究先データの特徴も踏まえてモデル開発に反映していきたいと考えています。

○ 研究会委員

ライブなデータが入金出金のデータということになりますけれども、それに近いものとしてここで挙げられるものとしては、売上ということになるのだらうと思います。入金出金から売上を予測し、売上から資本動向を予測し、資本動向の変化と財務の悪化というものがどういうコリレーションがあるかという発想で段階的で分析をするくらいラグがあるので、財務データがずらっと並んでいると気になるなと思いました。

○ 事務局

趣旨はよくわかりました。貴重なご意見ありがとうございます。

○ 研究会委員

全体感としては違和感ないのですが、ちょっと各論的な話ですが、どこまで細かく捕捉するかという話と直接関係する部分ではありますが、例えば、未収金のような項目があっ

た場合、それが長期なのか短期なのか分類されずに入っているとといったような、意外とそういう項目は資本にダイレクトに影響してくるので、何気ない勘定でも金額が大きい場合重要視しなければならないとか、例えば、出資金3億とか過大な出資金があった場合、それが貸し倒れていないかなど、勘定科目の全体の中でも大きいのが、科目としてはマイナーなものをどう見ていくかという点はどうしていくのかなと思っています。

○ 事務局

まさに本表に記載していない裏書譲渡手形や割引手形などは、個別注記表に記載してあったりするのですが、信用力の変化には重要な項目であったりする点は、重要なご指摘かと思えます。データ提供者ごとにデータの粒度に多少ばらつきがあります。ある会社では細かい区分のデータを有している一方、ある会社では売上と原価と営業利益といった大項目・中項目レベルしかない場合がありますので、まさにご指摘いただいたのは、どちらがいいとか悪いとかではなく、データ提供会社それぞれは細かいデータを有しているが、今回許容できるデータ提供の範囲が異なっているので粒度が違うということですが、粒度によってモデルの精度がどの程度違うか等については、分析していきたいと思っています。

具体的には、今回、共同研究先モデルを作る想定ですので、定性情報がメインではあります。財務情報の粒度も影響があると思えますので、それらが、モデルの精度等にどう影響を与えるかをしっかりと見たいと思っています。

○ 研究会委員

承知しました。実際は、個別の企業によってもものすごく粗い粒度のデータしか出してこない等もあつたりしますので、その辺り気を付けていただければなと思いました。

○ 事務局

貴重なご意見ありがとうございます。

○ 研究会委員

データクレンジングの件で確認と意見があります。まず、3ポツの現預金の部分ですけれども、補正として、負債を短期借入金に振り替えるというのは一般的にやっていることだと思いますが、全体の流動資産合計、資産合計、流動負債合計、負債合計についても絶対値を足しこんで補正をしているということでもよろしいでしょうか。

○ 事務局

資料上は現預金と短期借入金を補正するとしていますが、実際には、財務の右左がバランスするように各項目を修正しています。

○ 研究会委員

決算期変更等があると、12 か月未満の決算が出来ますが、PL の主要項目を年次換算するという処理は行っているのでしょうか。

○ 事務局

12 か月未満の異例決算で売上処理をする際には、まさにご指摘のとおり決算月数で割って、12 か月をかけるといった決算換算はしております。他方、そういった処理が適切であるのかという点について思案しています。データ量も多いので、まずは、そういった処理はせず、12 か月の正常決算先だけのデータを用いようかなと思っていますところでは。

○ 研究会委員

割引手形や裏書譲渡手形は非常に重要ですが、今でいうと個別注記表に記載することになっていますが、記載が漏れている中小企業が多いという認識です。これはゼロに処理すると、悪いものがよく評価される可能性がありますので、ゼロではなく、null にする等の丁寧な処理が重要ではないかと思いました。

○ 事務局

ありがとうございます。その他投資、その他流動資産などの細かい項目が欠損であった場合にはゼロという処理をしますけれども、割引手形や裏書譲渡手形については、欠損だったら1、欠損でない場合は0など、欠損データある先のフラグを立てて、そういった先の問題点を検討していけたらと思っています。

続いて、モデル開発母集団の定義について、ご意見をいただきたい。開発コンセプト1については、ある程度業績のいい先が、業績が悪くなるというもので、このモデルを作る対象をどうするかという話ですが、ある程度足元業績が安定している先に限定してモデル設計を行いたいと思っています。定義としては、1年ごとにしかスコアや債務者区分がないという先は、1年単位でみるしかありませんが、四半期単位でデータがある先は、足元1年間正常先と確認された先又は正常先と要注意先を行ったり来たりする先を限定したいと思っています次第です。この定義自体に違和感はないでしょうか。

○ 研究会委員

これに関しては、特段の違和感はありません。

○ 研究会委員

コンセプト1のラベルについては、違和感はないです。コンセプト2について、このモデルで面白い取組みなのは、現状ノーマルでダウングレードした先の予測モデルを作成し、ダウングレードした先について介入行為を踏まえて回復したところの予測をかませるとい

ものをジョイントすることで、やりたいことを実現する取組みですよね。理にかなっているし、過去に見たことのない例なので、とても面白いと考えています。大事なのは、1つ目のコンセプトで下がったところと、2つ目のコンセプトで上がるところがうまくつながらないといけないと思っていますが、その際に、開発コンセプト2で1をとるところと0をとるところの確認をしたいのですが、バッドの状態からそのままの先は0で、バッドの状態から介入を受けて上がった先は1で、バッドの状態から介入を受けずに上がった先は0になっているといいなと感じましたが、そういうラベルの振り方になっていますでしょうか。

○ 事務局

ありがとうございます。前提として、介入があったかわかる情報が4つの会社のうち1社しかありませんので、3つの会社では介入があったかが分からないので、介入の有無にかかわらず、悪い状態からよくなった先に1を立てるという風にしています。次に、介入があったかわかる先についても、現状では、介入を受けて上がった先は1で、介入を受けずに上がった先は0というようなラベルの振り方にはしていません。実際は、介入がある先のデータ分析作業が進んでいないというのが正確な表現ですけれども、理想としてはそういうところというのは認識いたしました。

○ 研究会委員

趣旨を整理しますと、開発コンセプト2は2つ考える必要があり、介入するということと回復するというところが必要です。それを予測モデルの枠組みで考えようとしているので、1の対象としては、介入されて回復したが1で、それ以外が全部0とする必要があります。なぜかというと、介入したところだけですとそこのセレクションの問題があるので、やりたい分析にならないと思います。介入したのでけれど、あまりうまくいかなかった先は0にしないといけないのだらうと思います。それと同時に、一番難しい点ですけれども、これは前回の研究会の際にも申し上げましたが、介入の情報がないところについて、単にバッドからグッドに変わったところでもいいのかというのは議論の余地があると思います。これだと、単に業績のボラティリティが大きい先だけを抽出することになりますので、やりたいこととずれてしまいます。前回、アノテーションという表現を使いましたが、なんらか2段階目で振るべき1のフラグ付けは検討した方がいいと思います。そうでないと、ただ、業績の振れ幅が大きい先を抽出しているだけでしょ、という批判に耐えられなくなってしまうと思います。

○ 事務局

ありがとうございます。何もしなくても業績が回復したとか、例えば、今円安が進んでいるので、輸出関連企業などにフラグ1を立てているというのがあるかと思います。理想は実際の金融機関のデータをお預かりした時に、実際に介入した情報が明確に分ければ、それを

充てるというのが理想だと思いますけれど、実データを使った実証は11月以降で、時間的に厳しいということもありますので、弊社内でもサンプルは多くないですが、実際にデータを分析してみて、介入行為があったかを把握する、疑似的にアノテーションができるかは考えてみたいと思います。あと、1社が介入したかのデータがありますので、そこは因果推論の手法も活用して、ご指摘いただいたバッドで介入してグッドになった先に1が立てられるように、気を付けて作業したいと思っています。

続きまして、教師ラベルの振り方に違和感あれば、コメントいただければと思います。

○ 研究会委員

違和感ありません。

○ 研究会委員

基本的には異論はございません。要管理先以下がモデルの教師ラベルに入ることになりますので、開発コンセプト1はデフォルト予測を内包することになるのかなと理解していますが、「延滞がある」という直接的な情報がない点、その辺は留意していただければと思います。

○ 研究会委員

特段の違和感はありませんが、P17の基準月ですが、コロナの影響の度合いを含めたいということで、毎年の3月期をベースにおいて分析するという認識でよろしいでしょうか。

○ 事務局

3末基準で複数年度、2015年3末くらいから1年単位でということ想定しております。

○ 事務局

ありがとうございます。概ね違和感ないと意見いただきましたので、この定義で母集団と教師ラベルに沿ってモデル開発を進められたらと思っています。説明変数の作成については、得られた情報を用いて、あの手この手で、信用力の変化をきちんと捕捉するために取りうる手段はしっかりとやっていきたいと思っています。多少時間がありますが、この辺の説明変数のつくりや、アンダーサンプリングの話などで、何かございますでしょうか。

○ 研究会委員

特にございませぬ。

○ 事務局

ありがとうございます。続きまして、モデルの評価指標について、ご意見を賜われればと

思っております。今回 P27 以降に進捗状況としてモデルの開発状況を示していますけれども、コンセプト 2 は精度が高いが、コンセプト 1 はそうでもないなどではありますが、現段階では、モデルの精度であるとか、精度がこの程度であれば実務に使えるかなどという点ではなく、評価の仕方がまずは適切かという観点でご意見をいただければと思っています。本日、モデルの評価指標が適切であるかをある程度定めて、10 月末に予定しております研究会で開発結果をご報告したいと考えております。モデルの評価指標としては、最初の KPI であるそもそも精度が高いものとなっているかという点は 1 と 2 になります。今まで捕捉できていない先をある程度捕捉できているかという点は 3 になりますが、こちら、ご意見ございますでしょうか。

○ 研究会委員

評価指標については、標準的なものを使用しており、違和感はありません。

○ 研究会委員

違和感はありません。閾値を動かしたときに、プレジジョンやリコールがどういう挙動になるかをつけていただいているので、見やすくなっていると思いました。P28 の財務変数のみのベーシックなモデルと次のページ以降のそれプラスアルファで、よりリッチな情報を使用したモデルについて、AUC なり AR 値なりを比較していくと思いますが、これも堅いことをいう人がいるかもしれないという観点での意見ですが、AUC の点推定値だけではなくて、コンフィデンス値を書くなど、エラーがどの程度あるのかは求めておいた方がいいのではないかと思います。計算に時間がかかるかもしれないので、最終的に使う部分だけでもいいかもしれませんが、追加した変数のコントリビューションが統計的にゼロとは違うのかは、研究者側は気にする気がするので、求めておいた方がいいと思います。

○ 事務局

ありがとうございます。汎用モデルについては、点推定だけではなく、Standard Error も見られたらと思っています。4 つの会社から大量のデータを預かっており、1 回の学習に短くても数十分とか 1 時間とかかかっているもので、それでモデルが 4 つあり、色々なアルゴリズムでということもあり、弊社のコンピューターリソースも限られている中で、なかなか難しいものの、最終的に汎用的な調査研究や因果推論を使ったものを取りまとめるときには、なるべく Standard Error も算定できたらと思っています。

○ 事務局

ありがとうございます。それでは、一旦こちらで評価指標を設定させていただくことといたします。

○ 研究会委員

UIについては大変見やすくなったと思います。業界平均や、各指標の安全性なり健全性もセグメントごとに出ており、また、寄与度についても出ていますので、顧客に説明するときはそういったものを利用すればいいと思いますので、基本的には特に違和感ないと思います。スコアについては、コンセプト2はスコアが高く出れば、改善の余地があるということで良くなる先、コンセプト1はスコアが高く出れば、悪化の兆候があるということで悪くなる先となっていると思います。説明を聞けば分かりますが、一般的には、スコアが高い方がよくなる先という印象がありますので、その点については、工夫した方がいいと思います。

○ 事務局

ありがとうございます。ご意見を踏まえ検討させていただきます。

○ 研究会委員

事業者との会話のきっかけになるような仕組みについて、意見を反映していただきましてありがとうございます。P38のスコアを変化させて対話につなげるという点は非常にイメージが沸きました。

そのうえで、いくつか希望があるので、お伝えさせていただきますと、P37のスコアの数値が分かりづらいため、例えば、1~3、4~6、7~9のレンジでいいと思いますが、そこにどういった状態を表しているかの説明がある分かりやすくなると思いました。また、P37に同業種との比較を入れていますが、同業種同規模といった情報があるとより分かりやすいと思いました。

○ 事務局

規模というのは、売上や従業員数など何か役に立つものはありますでしょうか。

○ 研究会委員

何かしらの規模情報があって比較ができればいいと思います。大きさが違うと判断も変わってきますので。

○ 事務局

つまり、何かしらの規模、売上なり従業員数なりで比較できればいいということでしょうか。

○ 研究会委員

また、外部環境のところでいいますと、地域金融機関なので、地域性のある情報はあった方がいいと思いました。

○ 事務局

地域性というのは具体的には、地域ごとの外部環境のことを指しているということでしょうか。

○ 研究会委員

外部環境のイメージです。

○ 事務局

例えば、営業エリアでの人口動態であるとか、そこまで細かい情報があるかは分かりませんが、訪日外国人客数などを地域の粒度で示すということでしょうか。

○ 研究会委員

その通りです。

○ 事務局

まさに、最初にご指摘いただいたスコアごとの意味合いというところですが、よく外部格付けでもAAAはこういうことのような説明は文章で説明するというイメージであってまじでしょうか。例えば、各金融機関で、正常先を10に区分していて、その意味づけをしていると思いますが、そういったところの文章が記載されていればいいのでしょうか。

○ 研究会委員

イメージとしては、今回は早期に経営悪化先を発見するということですので、例えばP38の5.8というスコアが早期の経営改善が可能な状態であることが分かるように、スコアの意味が示されているといいと思います。

○ 事務局

承知しました。例えば、スコアが8であるとか9であった場合には、足元数カ月以内に何かしらの手立てが必要な先といった説明があると分かりやすいということか。

○ 研究会委員

その通りです。

○ 研究会委員

活用の結果について、業種別の要素が盛り込まれているのが大歓迎でありがたいと思っています。我々のところにも業種別の審査辞典というものがあまして、業種によっては、平均値はこれくらいですとか、業種によっても指標の判断の基準が違ってきますので、先

ほども出ましたけれども、母集団といたしますか、データの中身の企業規模がどの層に集中するのか、上位層に集中するのかバランスよくなっているのかによって、結果がかなり違ってくると思います。先ほども出ましたが、企業規模別で分析できる仕組みが反映されれば大変ありがたいと思っております。基準については、資本金だとか、従業員数だとか、総資産だとか、売上だとかを選択して分析できると、企業の実態に近いところが出てきて、より活用しやすいと考えております。

○ 事務局

これはある企業の業況であって、業種の平均はもちろんのこと、宿泊業を例にとると従業員5名以内の家族でやっている宿泊業の平均はどうかとか、ある程度規模を持っている100名の規模を持つ宿泊業ではどうかとか、場合によっては、同業種同規模のスコアの要因も変わるとありがたいということでもよろしいでしょうか。

○ 研究会委員

その理解で問題ありません。

○ 研究会委員

P37は非常に各項目、経営指標に応じて出てくるということで興味深く拝見しております。それぞれのデータ提供会社によって、別々のモデルを作るという議論ありましたが、データの提供元によって、経営指標の平均値等、同じ業界でも差異が生じると思うので、その点は反映していただけないのではないかと思います。

○ 事務局

共同研究先によって企業の規模であるとかも含め、データの差異があると思しますので、その違いを分析して、反映したいと思います。

○ 研究会委員

これまでご発言いただいた方々と同じような印象を持っています。レイアウトそのものはみやすくいいのかなと思います。下に注書きがありますけれども、金融機関ごとに設計が必要ということで、ある程度カスタマイズ、すなわち、ここは金融機関ごとに使いやすくするということはある程度できるかなと考えております。

今回のUIを見たイメージとしては、事業性評価をした結果のシートに似ているという印象を持っておりまして、P38のところではいいかと、シナリオ1と2がいわゆる楽観シナリオと悲観シナリオという数値設定をして、そのレンジの中でどうブレそうかという点を予測できる点は素晴らしいなと思っております。同業種でのスコアのところですが、色々な数字がありますので、対象となる企業がどれだけ強み弱みがあるかという点が分か

るのかなという点がありますので、お客様に対する納得性が高いと思っております。

気になる点としては、他の実務家のご意見と同じで、数字ごとの定義が知りたいなと思っている。業種平均の数字のこの例でいいますと、売上高 30 億 5 千万円で従業員 350 人としていますが、30 億 5 千万円と同じ規模なのか、どの程度の比較ができるのかという、母数によっても平均が異なると思うので、絞れるのであれば、対象規模と同規模との比較が見たいなと思っています。我々は数値を 3 期並べるといふカルチャーがありますが、主要指標でいいと思いますので、3 期間が入るようなレイアウトだといふのではないのでしょうか。一定規模の企業でいうと、大体 3 年間の中期経営計画を作成する企業が多いので、前 3 年を見るというのがスタンダードになっている気がしますので、特殊要因で上下動する期を排除出来たりもしますので、そういった機能があるといいと思います。

○ 事務局

ありがとうございます。当該企業の過去 3 期ということでしたけれども、同じような規模同じような業種の平均についても過去 3 期必要と考えていますでしょうか。

○ 研究会委員

業種平均はそこまでブレないと思いますので、1 期あれば十分ではないかと思います。当該企業の数字は 3 期並べるといい気がします。

○ 事務局

事業性評価のシートに似ているという話がありましたが、事業性評価のシートのうち、この指標が有用であるのか等はありますでしょうか。

○ 研究会委員

書いてあることは、ほとんど同じような印象で、違いとしては、SWOT 分析が入るくらいで、概ね同じです。なんとなく事業性評価のシートに近いのかなという印象を最初に持ちました。

○ 事務局

SWOT 分析は、いわゆるその企業の財務の定量状況ではなくて、強み弱みなどの定性的な分析の結果が書かれているということでしょうか。

○ 研究会委員

例えば、この外部環境というのはまさにそうだと思います。こちらが、業界平均と比較して、当社自体が強いのか弱いのか、強いところはどこなのか、弱いところはどこなのか、というところを分析していると思いますので、SWOT 分析の要素がこのシートには既に一部

含まれているというイメージがありますね。

○ 事務局

貴重なご意見ありがとうございます。3期平均の部分ですとか、他の委員の先生方からもご意見ありましたが、スコアの定義の部分については、是非とも反映したいと考えています。

○ 研究会委員

詳細な説明をいただきましてありがとうございました。ちょっと、先生方や実務家の方々からのコメントもありましたが、少し厳しめなコメントをさせていただければと思います。私の今の印象は、たとえば悪いのですが、委員の皆様のご意見をうかがいながら 42.195km を走ってきたのですが、この UI のところで、ゴール直前で大転倒してしまったなという印象でございます。

右上のスコアでございますが、実務的に私が何を悩んでいるかといいますと、早期に経営改善が必要だと、経営者の方々から資金繰り支援が必要だ、経営を何とかしたいといった意見が出た際に、それを金融機関にいても分かってくれないのだと、というようなところがありまして、今回もこの AI を活用して、現場の行動変容を促すことがゴールであると思っています。例えば、このスコアで確度が高い、あるいは低いといったことを出すこと自体は必要だと思うのですが、経営改善していくことが簡単である、あるいはかなり難しいということが出たとしますと、現場はどういった行動をするかという、金融機関にとっては確度が高いところからやろうとか、確度が低いところを放っておいてやろうと、いったことが起こってしまうと、それでは本末転倒だと思っています。こういった数字がやはり独り歩きするのは怖いという印象を受けておまして、極論いってしまえば、このスコアはいらんのではないのかと思います。現場観として一番切実なのは、現場で経営改善が進まない、現預金の残高が着々と減っていくことになります。それに対して、財務的な手当て、リスケするか追加で融資いただくのか、あるいは抜本的な再生を行うのかといったところがあるかと思いますが、そこに対して早めに手当てをしていくと、要するに今のこの状況であれば例えば半年、1年たったら現預金が尽きちゃうよと、そういうようなアラートがないと、実際に現場に落とし込んだときに使うのは、現場の職員だと思いますが、現場として一番センシティブというかここがポイントということであれば、やはりキャッシュの残高であるとか、いつまで資金が持つのかというアラートが出てくれるといいのではないかと。

私のいる県では、地域特性は分かりませんが、業種では旅館や建設、製造と色々ありますが、結局はどの業種であっても最終的にお金がなくなれば終わりといったことは変わりありません。そこさえ、共通認識を持つことが出来れば、その先は、個別の話として、支援者と金融機関が握ればいい話です。私としては、もっと情報を絞り込んでいただいて、破綻可能性や将来的にどこまで資金が持つのか等のアラートが出てさえいればいいと思っています。

○ 事務局

貴重なご意見ありがとうございます。この先が、資金があと半年ないしは1年で尽きそう
だみたいなりストが出てくると分かりやすいということであってますでしょうか。

○ 研究会委員

実務的には、悪い先であるという認識がお互いに分かったからアクションができること
になります。今回はそうなる前に、早く察知できれば、より早くアクションができるという
ことかと思しますので、例えばそういった情報がAIを使ってはじき出せる、それさえでき
ればいいという思いでおりました。

○ 事務局

このスコアの意図としては、コンセプト1の場合、悪くなる確度が高い先という観点で示
しておりますので、具体的には、8点以上は業績がかなり悪そうですので、今後早期に対応
する必要がありますよ、ということを意味しているのですが、それでも違和感がありますで
しょうか。

○ 研究会委員

結局、総合スコアでラベリングしてしまったときに、いい悪いという結果が出るというロ
ジックにした場合に、現場とすると優先順位をつけてやりますよということであればいい
のですけれども、逆に優先度が低いからやらないというやり方をやっていくと、これはあく
までも単なる予測であって、確実にマッチするものではないと思います。むしろ、現場の納
得感があるのは、AIで総合的に分析したからそうですというよりは、将来的な破綻可能性
であるとか、資金がどこまで持つとか、その辺の方が、説得力があると思っております。タ
イトルが、「経営改善の可能性（確度）」となっておりますので、ここを単純に変えればいい
ということかもしれませんが、5.8という数値が現場で独り歩きした時に、これが高いのか
低いのか、高かったらどうするのか、低かったらどうするのか、と現場観とするとどう動く
のだろう、というのが非常に不安なのですよね。

○ 事務局

この研究会は別の研究会とセットで検討しておりまして、別の研究会では、業種ごとにど
ういったアクションを行えば経営改善していくのかという具体的な打ち手について、議論
することとしております。従いまして、AIの力を借りて本当に救わなきゃいけない先につ
いては、本研究会である程度は抽出できますので、そういった先に対して、もう一つの研究
会で検討しております具体的な打ち手を講じるということがあると思っておりますので、最終的
な報告の際には、その点も踏まえながらまとめたいと思っております。

○ 研究会委員

最終的には活用できるかというところでして、アウトプットしたこの資料をみて、すぐに席を立って行動につながるかと考えたときに、分析資料ですとか統計資料という風にみてしまう可能性があるのではないかということ懸念しました。スコアの5.8というものについても、考えなくなってしまう可能性があるのではないかと思いましたが、本来であれば、経営改善支援が必要な先をすべて対応しなければいけないと思いますが、経営資源が限られている中においては、全部いっぺんに支援することはできませんので、5.8だから早くやろうとか、3.2だから後回しにしようとか、スコアを頼ってしまう可能性は十分にあるのではないかと思ってしまう。

また、5.8とかの指標であっても時間軸、例えば6ヵ月以内に外部要因があるのでこうなるとか、対象先の顧客の窮境要因が非常に根本的な問題なのでとか、リスクの大きさを定量化するとかそのような仕組みの方がいいのではないかと思ったのが1つです。

2つ目は、経営改善支援と一言でいいますが、支援するのにもリスクを伴うと思っており、顧客にもリスク、例えばコストかもしれないが、そういう覚悟をしてもらわないといけないと思います。経営改善するためには、こういう支援が必要だけれども、そのためにはこんなリスクがあるよ、というところまで具体的に示していただくなど、顧客も現場も、結果を見て行動変容につながるものにしてほしいと思っている。

○ 事務局

この結果を鵜呑みにして8点以上の先を支援することというマニュアルができれば、それ以上しか見ないという弊害があったり、ここで示しているものはあくまでもイメージですけれども、情報があまりにも表層的であるので、これを見ても行動につながらないといったことはあるかと思えます。さはさりながら、2つの研究会が走っておりますけれども、本研究会ではある程度様々な情報を使いながら、多くの取引先の中から本当に支援が必要な先を機械的に抽出するという部分は必要かと思っておりますので、次のアクション、すなわち、行動につながるという部分については、もう一つの研究会の結果と連携していくということなのかなと思っております。なかなか、4つの会社からいただいている情報から、すぐに動かなきゃというものをらせるかということはあると思いますが、いただいた意見は事務局側で再度検討したいと思います。貴重なご意見ありがとうございました。

是非、今後も批判的なご意見もどんどんいただければ非常にありがたいと思っておりますので、引き続きよろしく願いいたします。

○ 事務局

議題については以上になりますが、最後に全体通して、何かご意見なり、ご質問なりある方いらっしゃいますでしょうか。

○ 研究会委員

やはりスコアのところが非常に気になるところです。アウトプットとしては、既視感もなく外部環境データを使っているところも非常にユニークだと思いますが、とどのつまり、何を結論として出すかは議論になると思います。6ヵ月以内に資金繰りの懸念が派生する確率が極めて高いであるとか、普通であるとか、懸念はないとか、そのくらいの分類でスクリーニングして、外部環境次第では非常に悪化、良化するなど、シミュレーションにも入っていたと思いますが、それによって銀行の行動を変えていくという方が実用的になるような気がしましたので、今後のアウトプットの出し方は検討が必要かと思いました。

○ 事務局

ご指摘いただいたのは、スコアが独り歩きしても困るので、スコアという形で出すというよりは、アラートメッセージになるといいのではないかということでしょうか。

○ 研究会委員

資金繰りが厳しい先がABCの三段階で出るなど、そのくらいのものでいいのではないかということです。

○ 研究会委員

足元まで続いている議論について1点とその他言い忘れたことについて1点申し上げたいと思います。比較的、分析の予測のウインドウの話がされているように聞こえました。どのくらいの幅で予測するイベントが起こるかということで、今は1年間という期間を設定していたと思いますが、そこは、ウインドウの設定の仕方に出てくる値の意味合いは変わってきますから、期間の設定をうまく調整することで、今回のプロジェクトの中では実装するところまではいかないと思いますので、あくまで考え方としては、3か月以内のウインドウの場合や1年以内のウインドウの場合を使い分けることで、これまで委員の先生方がおっしゃられたことに対応するというのはあり得るのではないかと思います。

それからコンセプトの議論をするという観点から申し上げますが、リコールなのかプレシジョンなのかという議論があったと思いますが、一度こういう指標を出して、あとは金融機関の判断に委ねるとするのが自然だとは思いますが、マクロな観点から見たときには、最適な閾値は、支援にかかるコストと支援をして経営改善により得られるゲインのバランスで決まってくると思います。通常の教科書的な話でいうと、支援にかかるコストと支援により回避できるクレジットコストの顕在化をバランスさせたときに、このくらいの閾値であれば支援すべきであるようなことは、コンセプトとしては取り出せると思います。構築したモデルの外側での話として、金融庁の立場で考えると当然出てくる話なのかなと思います。それに照らした場合、個別金融機関が支援している支援していないという議論になるかも

しれませんが、そこまで議論としては書き込んでおいても、今回、実装しなかったとしても、理想的な検討の材料になるのではないかと思います。

○ 事務局

まさに、今回実装というところまではできませんが、報告書を取りまとめるときに、閾値なり、モデルの活用を検討するといった形で報告書上には取りまとめたりですとか、そういった形でご意見を踏まえられればと思っています。

○ 事務局

その他にございますでしょうか。

○ 研究会委員

タイムフレームの話は非常に重要だと思っております、弊社でも信用リスクの計測モデルのようなものを作っているのですが、どのくらいの長さのデフォルトを予測するのかというのは、結果に大きく影響を与えるので、この概念は非常に重要なものとして考慮した方がいいと思いますので、最後に付け加えさせていただきました。

○ 事務局

貴重なご意見ありがとうございます。事務局で検討したいと思います。

(以上)

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 【第3回研究会資料】

2022年11月25日
有限責任 あずさ監査法人
委託元：金融庁

注：本報告書は、金融庁の委託により有限責任 あずさ監査法人が実施した調査結果を取りまとめたものである。有限責任 あずさ監査法人は、調査時点で入手した情報に基づき本報告書を適時に取りまとめるよう努めているが、本調査報告書の内容は、本調査の対象に含まれない特定の個人や組織が置かれている状況に対応するものとは限らず、また、情報を受け取った時点及びそれ以降において、その情報の正確性や完全性を保証するものではない。また、本報告書は委託者である金融庁に対してのみ提出したものであり、本報告書を閲覧あるいは本報告書のコピーを入手閲覧した第三者の本報告書の利用に対して、有限責任 あずさ監査法人は直接ないしは間接の責任を負うものではない。

Contents

	Page
1 スケジュール、本研究会の議題等	3
2 プロトタイプAIの開発結果等	6
3 AIからの出力結果の実務活用について	19
4 金融機関による実証事業・ワークショップについて	30
5 添付資料	32



1 スケジュール、本研究会の議題等

2 プロトタイプAIの開発結果等

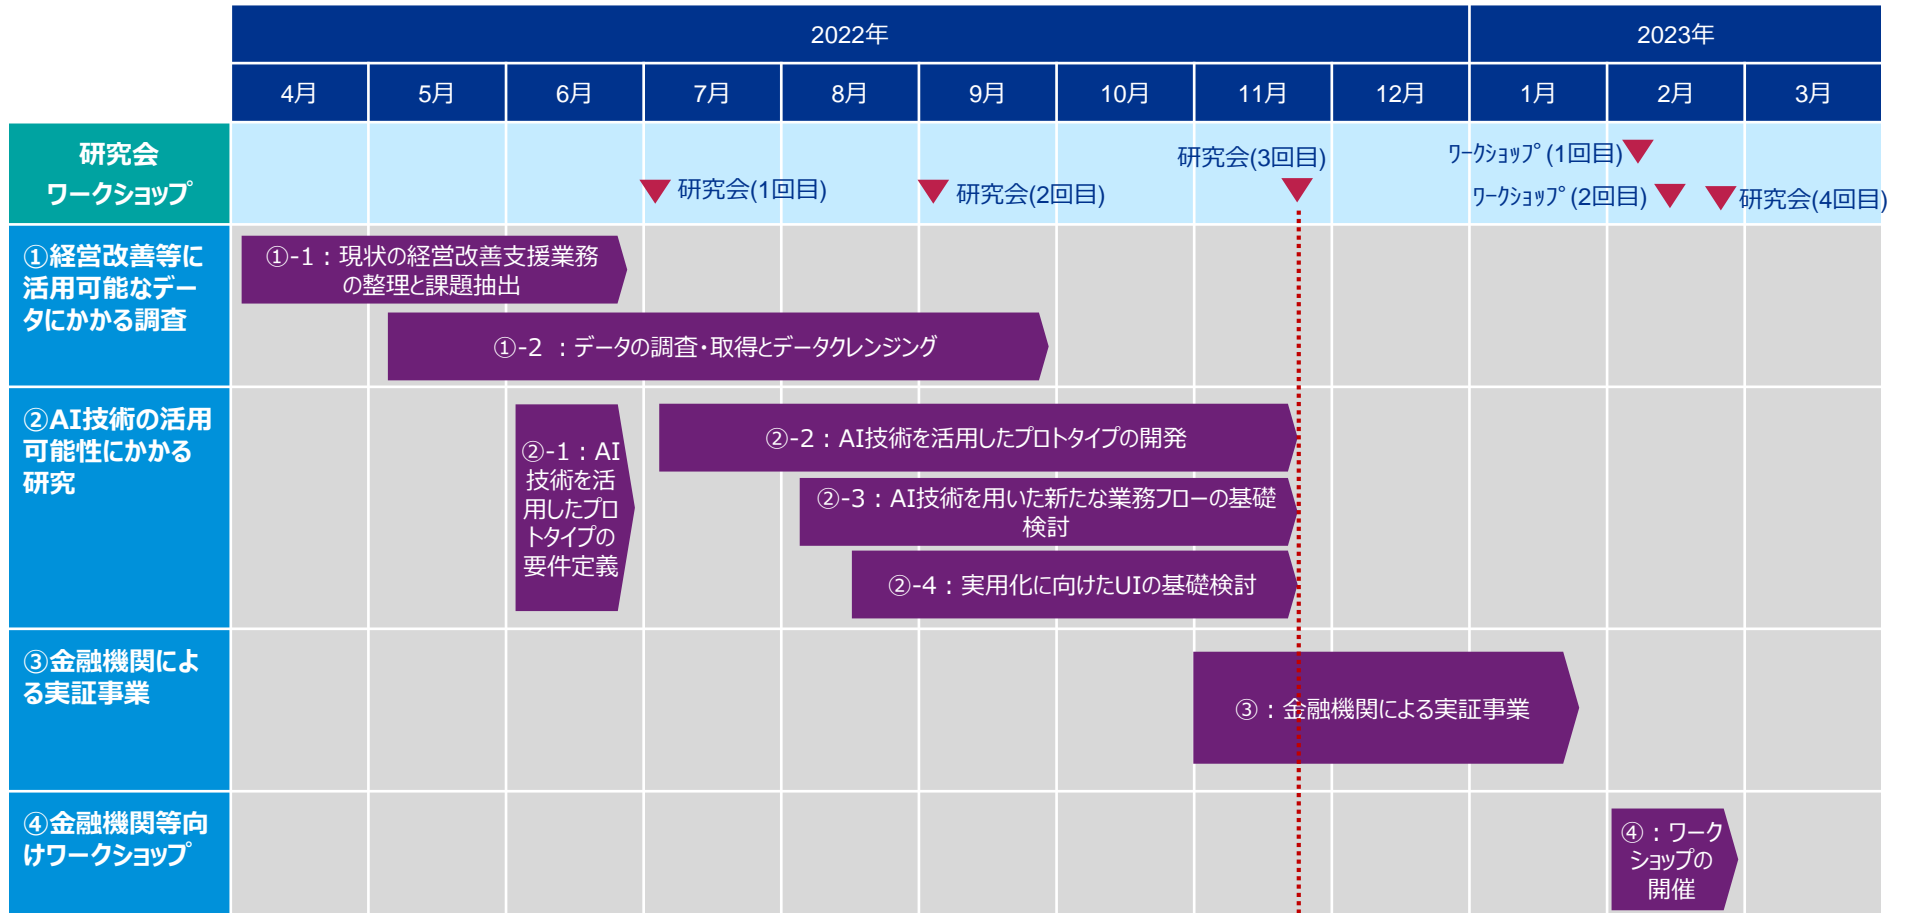
3 AIからの出力結果の実務活用について

4 金融機関による実証事業・ワークショップについて

5 添付資料

本調査・研究のスケジュール

■ 本調査・研究の全体スケジュールと主なタスク内容は以下のとおり。



研究会における予定議題

- 本日の研究会の議題、今後の研究会にて予定している議題は以下のとおり。

開催回	開催時期	議題（予定）
第1回	2022年7月1日（終了）	<ul style="list-style-type: none">■ 現行の経営改善支援業務の理解■ プロトタイプAI開発のコンセプトについて■ プロトタイプAI開発に用いるデータについて
第2回	2022年9月2日（終了）	<ul style="list-style-type: none">■ KPIの設定・モデル開発計画について■ モデル開発用データ整備とモデルの評価指標について■ AIからの出力結果の実務活用について
第3回 （今回）	2022年11月25日（本日）	<ul style="list-style-type: none">■ プロトタイプAIの開発結果等<ul style="list-style-type: none">・ プロトタイプAIの開発結果・ 汎用モデルのチューニング結果・ セグメンテーションモデルの構築結果■ AIからの出力結果の実務活用について■ 金融機関による実証事業・ワークショップについて
第4回	2023年2月下旬（予定）	<ul style="list-style-type: none">■ 金融機関における実際のデータを用いた検証の結果報告■ 本調査・研究の取りまとめ、今後の課題整理



1 スケジュール、本研究会の議題等

2 プロトタイプAIの開発結果等

3 AIからの出力結果の実務活用について

4 金融機関による実証事業・ワークショップについて

5 添付資料

本調査・研究のKPIの設定

– 第2回研究会資料の再掲

- 本調査・研究のKPIは、以下の2つの観点で設定する。
 - ① 現行の経営改善支援実務では活用していない情報により、これまで捕捉することのできなかった経営改善支援候補先が特定できること。
 - ② 抽出された経営改善支援候補先に対する職員による精査が、現行業務と比べて削減されるような高い精度を持つこと。
- 共同研究先データを使用したモデル開発と、金融機関による実証事業における、具体的な評価方法は以下のとおりとする。

観点	評価方法	
	共同研究先データを使用したモデル開発	金融機関による実証事業
①	<ul style="list-style-type: none"> • 現行の信用リスクモデル※1では活用していないデータ（外部環境データや定性データ等）を分析に活用出来ているか。 • 現行の経営改善支援業務では捕捉できていなかったような経営状態（足元では正常先等）の企業を分析対象に出来ているか。 	<ul style="list-style-type: none"> • 開発したモデルに、実証事業に参加する金融機関における従来のモデルでは経営改善支援の対象でなかった企業のデータを当てはめて特定された企業の中に、実際に突発的に業績が悪化した先や経営改善支援を実施した先が含まれているか。
②	<ul style="list-style-type: none"> • 汎用モデル※2と共同研究先モデル※2のテスト用データにおける精度が、財務のみモデル※2の精度よりも高いか。 • 開発したモデルにテスト用データを当てはめて出力したスコアの悪い上位企業に、経営改善支援が必要な先（実際に業況が悪化した先）の多くが含まれるか。 	<ul style="list-style-type: none"> • 開発したモデルに、実証事業に参加する金融機関における企業のデータを当てはめて特定された企業の中に、実際に突発的に業績が悪化した先、経営改善支援を実施した先の多くが含まれているなど、相応の精度があるか。

※1 現行の信用リスクモデルは、多くは企業財務及び企業属性のみ勘案していることが多い。定性情報や外部環境情報はモデルによる定量評価後の定性評価により勘案している。本調査・研究ではモデルそのものに外部環境や定性データ等を加味することを想定している。

※2 汎用モデル、共同研究先モデル、財務のみモデルの説明は、「開発したモデル一覧」（本資料 p.11）に記載。

モデルの評価指標

– 第2回研究会資料の再掲

■ 本調査・研究で開発するAIモデルを評価する指標は、各評価の観点を鑑みて下表のように設定した。

#	評価観点	評価指標	補足説明
1	<ul style="list-style-type: none"> モデル全体の精度が高いか 企業を信用力に応じて序列付けることができるか 	<ul style="list-style-type: none"> AUC、AR値 (数値による評価指標) CAP曲線 (視覚的な評価) 	<ul style="list-style-type: none"> 経営改善支援候補先に対する職員による精査が、現行業務と比べて削減されるような高い精度を持つかを評価するもの 特定の条件 (例：閾値を設定する) を設けず、モデル全体として一定以上の精度があるかを評価 機械学習モデルの2値分類問題ではAUCを用いることが多いため本調査・研究ではAUCを設定。また信用リスク管理の実務上AR値を用いることも多いため、AR値も設定 (参考：AR値 = AUC × 2 - 1)
2	<ul style="list-style-type: none"> モデルスコアのある閾値以上の先に多く正例 (経営改善支援が必要な先) が含まれるか 	<ul style="list-style-type: none"> スコアランク毎の正例の割合 適合率 (precision) (正と予測したものに対し、実際に正であるものの割合) 	<ul style="list-style-type: none"> 本モデルを実務に活用する際は、あるスコア以上の企業を抽出し、その先の一部もしくは全部に対し経営改善支援を実施する想定 そのため抽出された企業に多く経営改善支援が必要な先が含まれていることが重要なため、本評価指標を設定。当該評価が高いと支援候補先の精査を行う職員の業務負荷削減につながる
3	<ul style="list-style-type: none"> モデルスコアのある閾値以上の先の正例 (経営改善支援が必要な先) が、全体の正例の多くを捕捉できているか 	<ul style="list-style-type: none"> 再現率 (recall) (実際に正のものに対し、正しく正と予測できたものの割合) 	<ul style="list-style-type: none"> あるスコア以上の企業を抽出した際、経営改善支援が必要な先のうち何割を捕捉できているかを評価するための指標 当該評価が高いと、これまで捕捉することのできなかった経営改善支援候補先が特定できることを意味する

AIモデル（プロトタイプ）の開発コンセプト [1/2]

– 第1回研究会資料の再掲

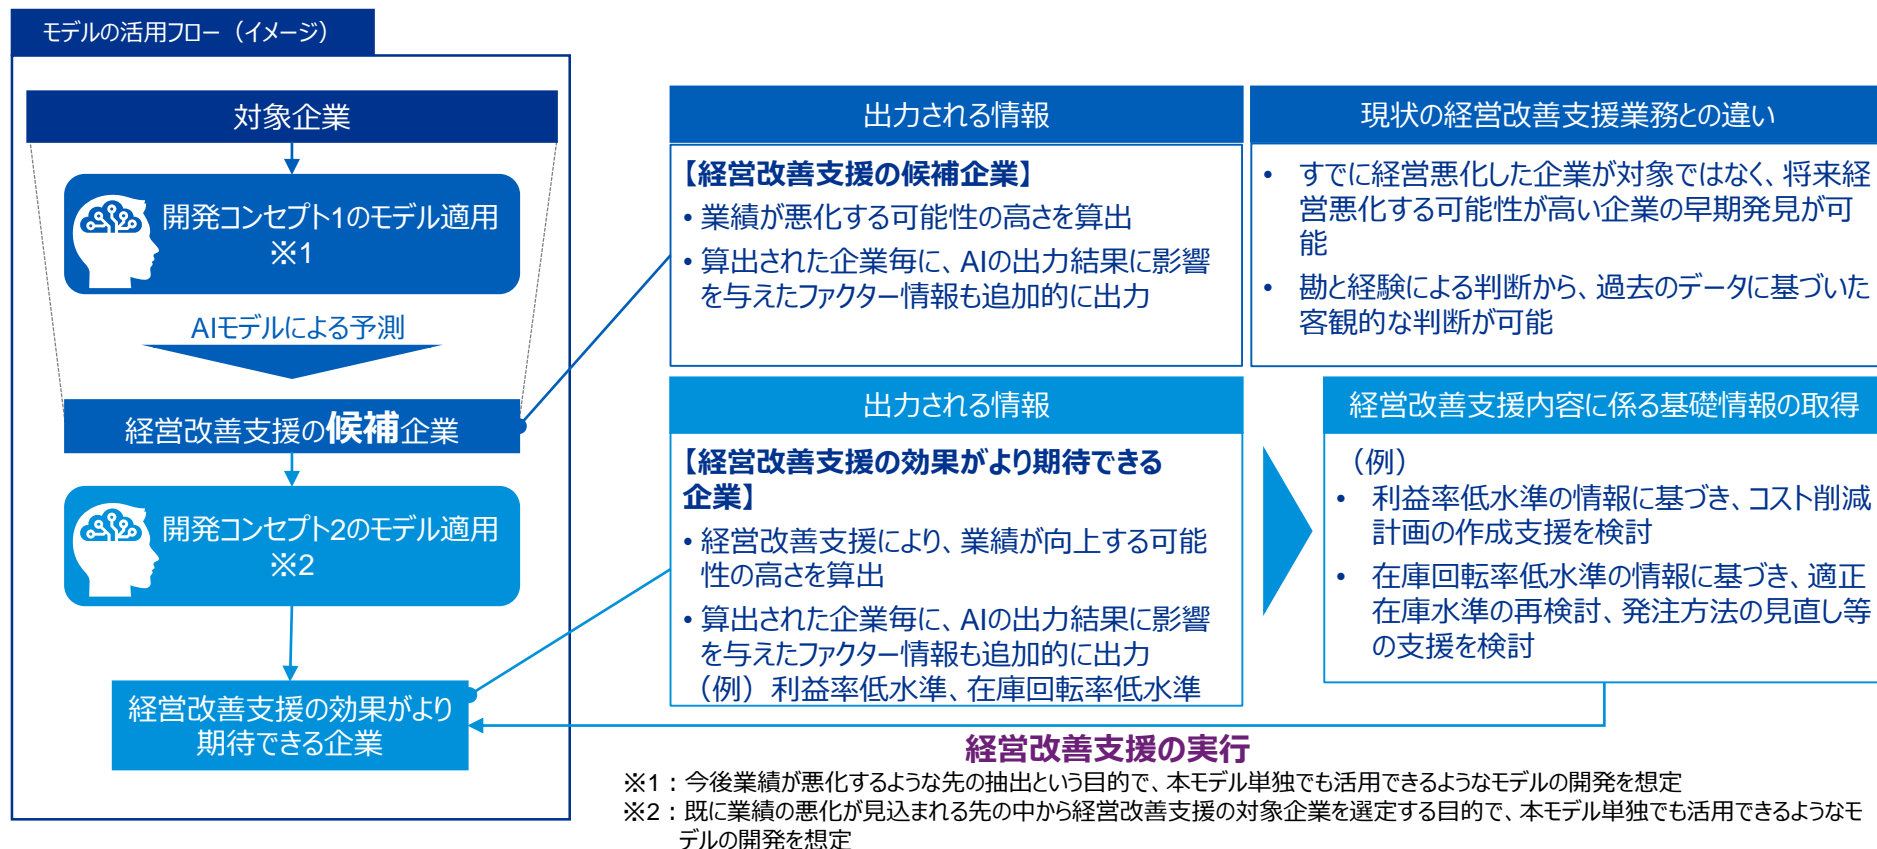
- 本調査・研究にて開発するAIモデル（プロトタイプ）の目的は、「経営改善支援が必要な先の特定（早期発見）」である。
- 本目的を達成し得るAIモデルの開発コンセプトととして、2つの方法が想定されるため、下表にて整理した。
- 本調査・研究では下表の2つの開発コンセプトを満たすAIモデルの開発（まずはBasicモデルに着手）を検討していきたい。

#	開発コンセプト	モデル構築の母集団		構築したモデルを当てはめる企業
		学習データの対象	モデルによって検知する事象	
1	<p>【Basic】業績低下の可能性が高い企業の特定</p> <p>現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル</p>	一定期間内において業績が悪くはない企業	一定期間経過後に、業績が低下する企業	学習データの対象となる企業（ただし時点が学習データより新しい等により学習データには含まれない企業）
2	<p>【Advanced】経営改善支援により業績が向上する企業の特定</p> <p>現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル</p>	一定期間内において経営改善支援の候補となりえる業況にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）	一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業	同上

AIモデル（プロトタイプ）の開発コンセプト [2/2]

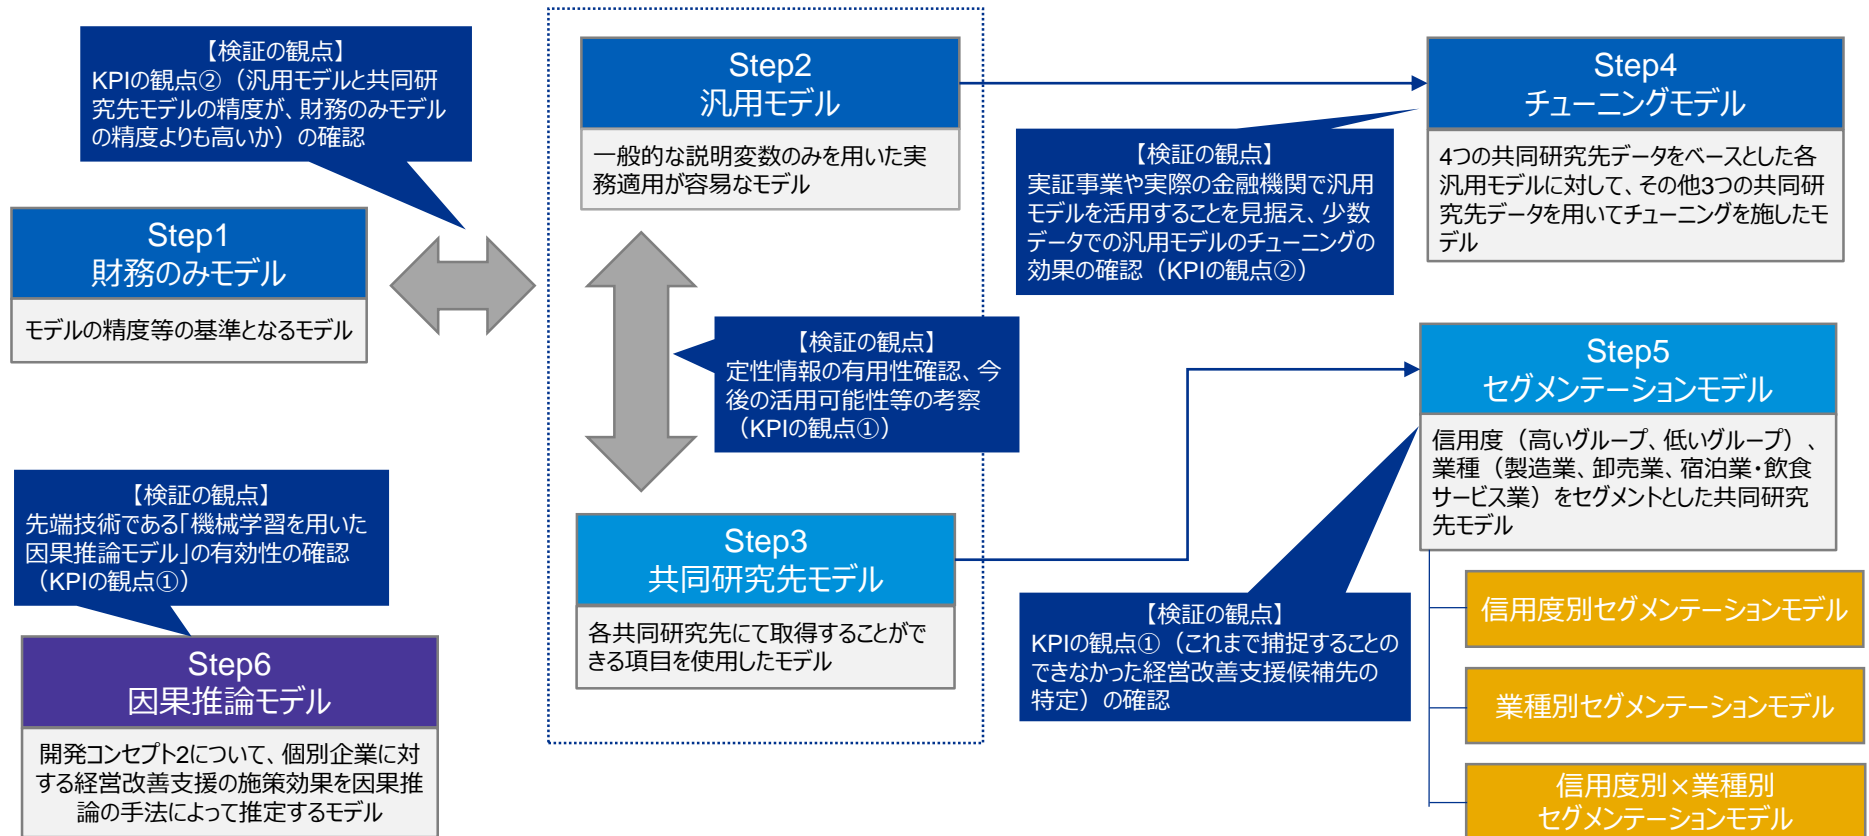
– 第1回研究会資料の再掲

- 開発コンセプト1と開発コンセプト2を経営改善支援業務に活用した場合のフローイメージは左下のとおり。
- 開発コンセプト1によって「経営改善支援が必要な先の特定（早期発見）」、開発コンセプト2によって「経営改善支援の効果がより期待できる企業の特定」と、「経営改善支援内容に係る基礎情報の取得」が可能となるよう検討を進める。



開発したモデル一覧

- 本調査・研究で開発したモデルの一覧と、開発したモデルを用いた検証の観点とは下図のとおり。Step1からStep6の順にて、モデル開発を行った。



プロトタイプAIの開発結果概要

- 第2回研究会において設定されたKPIについて、評価指標等も活用して確認したところ、以下のとおり概ね達成が確認された。

汎用モデルの 開発結果概要

- 一般的な説明変数のみを用いた場合でも、財務のみモデルよりも高い精度を有し、概ね実務適用可能な水準の標準的なモデル構築を実現
- 少数データで追加的に学習（ファインチューニング・追加学習等）させた結果、精度が高まるケースが確認できる等、少数データしか持たない金融機関における汎用モデルの活用方法を確認

共同研究先 モデルの 開発結果概要

- 一般的な説明変数に加えて、定性情報等の追加情報を活用することで、汎用モデルより高い精度が実現
また、業種別や信用度別にセグメンテーションモデルを構築することでさらに高い精度を実現する等、使用シーンに合わせた活用の可能性を確認

因果推論 モデルの 開発結果概要

- 先端技術である「機械学習を用いた因果推論モデル」についても試行し、個別企業に対する因果効果（経営改善支援による業績の向上）の推定が可能であることを確認
（本調査ではサンプルが少なかったため、統計的な有意性は得られていない）
- 今後、金融機関の実証事業にて本手法の有効性を確認

開発したモデル精度一覧

- 開発したモデルの精度一覧は下表のとおり。それぞれ、ロジスティック回帰、ランダムフォレスト、勾配ブースティングの順番でAUCを記載している。
- 開発コンセプト1、開発コンセプト2いずれも、平均的には財務のみモデルよりも精度が高い汎用モデル、共同研究先モデルの構築が実現している。また、汎用モデルの精度の最大値が0.8を超えるアルゴリズムもあり、実務に耐え得るモデルとなっていると評価できる。
- 開発コンセプト1、開発コンセプト2いずれの汎用モデル（ある特定の共同研究先のもの）、共同研究先モデル（ある特定の共同研究先のもの）に関する評価として、スコアランクごとの正例の割合、CAP曲線、適合率と再現率を、「開発したモデルの評価」（本資料 p.33-p.38）にて掲載。

共同研究先	開発コンセプト1			開発コンセプト2		
	財務のみモデル	汎用モデル (チューニング前)	共同研究先モデル (セグメンテーションなし)	財務のみモデル	汎用モデル	共同研究先モデル
平均値※		0.652 0.707 0.694	0.661 0.716 0.706		0.747 0.786 0.786	0.760 0.787 0.794
最小値※	0.654 0.657 0.670	0.519 0.671 0.590	0.519 0.671 0.590	0.790 0.799 0.803	0.676 0.696 0.707	0.688 0.712 0.725
最大値※		0.770 0.798 0.805	0.801 0.821 0.832		0.788 0.823 0.817	0.804 0.819 0.825

※ 汎用モデル、共同研究先モデルについては、4つの共同研究先のモデルの平均値、最小値、最大値を掲載。
AUCの平均値、最小値、最大値が0.7を超えているものについては、**太字**で記載。

汎用モデルのチューニングについて [1/2]

- 実証事業や実際の金融機関にて今回開発したモデルを活用する場合は、汎用モデルをそのまま用いることを想定している。ただし個別金融機関に汎用モデルをそのまま適用した場合、モデルの精度が十分でなくなる恐れがあるため、各金融機関データを用いて追加的な学習を行い、汎用モデルを調整（チューニング）することで、実務適用に耐え得る精度を達成できるか検証を行う。
- 具体的には共同研究先データを用いて以下の方法にて検証する。

【アルゴリズムごとのチューニング方法】

- ロジスティック回帰はファインチューニング、ランダムフォレストと勾配ブースティングについては追加学習を行うことでモデルのチューニングを行う。

アルゴリズム	チューニング方法	説明
ロジスティック回帰	ファインチューニング	チューニングに用いる学習データにもモデルが適応するように、既存のモデルにおける回帰係数の調整を行う。
ランダムフォレスト	追加学習	既存のモデルにおける決定木は変更せずに、チューニングに用いる学習データにもモデルが適応するように、既存のモデルに対してチューニング用データだけで学習した新たな決定木を追加する。
勾配ブースティング		

【チューニングに用いるデータ】

- 実証事業や、実際の金融機関でのモデルのチューニングシーンを想定し、汎用モデル構築時よりも少ないデータにてモデルのチューニングを行う。
- 各共同研究先のモデル開発母集団のデータ数を踏まえ、チューニングに用いるデータは約6,000件とする。

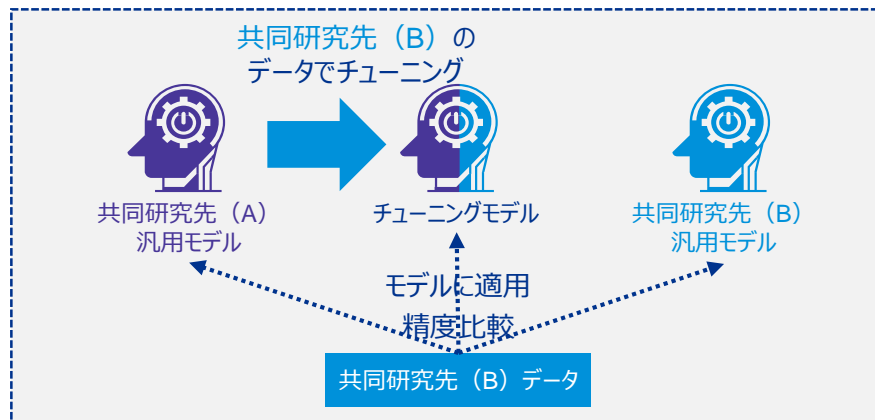
汎用モデルのチューニングについて [2/2]

【チューニングのパターン】

- 4つの共同研究先データをベースとした各汎用モデル（ベースモデル）に対して、以下の2通りのパターンにて、チューニングを行う。
パターン①：その他3つの共同研究先のいずれかのデータを用いて、1回のチューニングを行う。
パターン②：その他3つの共同研究先それぞれのデータを用いて、3回のチューニングを行う。
- 上記パターン②については、モデルのアルゴリズムの特徴により、ロジスティック回帰と勾配ブースティングは、ファインチューニング・追加学習を行う順番によって構築されるモデルの精度が異なるため、複数の順番にてチューニングを行う。


【チューニングしたモデルの精度検証】

- 精度の検証は、「ある共同研究先（A）の汎用モデル」、「ある共同研究先（A）の汎用モデルを別の共同研究先（B）のデータにてチューニングを行ったモデル（チューニングモデル）」、「別の共同研究先（B）の汎用モデル」の3通りのモデルに、共同研究先（B）のデータを適用した場合の精度を比較することで行う。



汎用モデルのチューニング結果

- 汎用モデルをチューニングした場合の精度検証結果は以下のとおり。なお、前頁記載のチューニングのパターン②については、異なる共同研究先データで3回チューニングしたことによる精度向上や、チューニングの順番による特徴の変化は得られなかったため、ここでは、パターン①（その他3つの共同研究先のいずれかのデータを用いて、1回のチューニングを行う）の結果について示している。
- チューニングには、約6,000件のデータを用いており、以下の精度はパターン①の全ての組み合わせにて検証した結果のAUC平均値を記載。



チューニングを実施することによって、精度が向上することを確認。

共同研究先Bのデータを十分に活用して構築したモデルよりも、チューニングモデルの精度は劣るものの、精度の差は限定的。大量データを持たない金融機関においても、独自モデルを構築したときと同水準の精度を持つモデルを、汎用モデルのチューニングによって構築ができることが示唆される。

セグメンテーションモデルの構築について

- 共同研究先データを用いたモデル構築の結果、開発コンセプト1については、開発コンセプト2と比較して精度が低水準であったこと、第2回研究会にて委員から、全体の精度を確保することをメインとしつつ、（モデルの使用シーンに合わせて、）個別ケースの精度を確保する方法を進めてはどうかとの意見があったことも踏まえて、特定の区分（セグメント）に対して精度が出るモデル（セグメンテーションモデル）の構築を検討。
- セグメントは「信用度（共同研究先によって債務者区分や信用スコアを使用）」と「業種」を用いてモデルの構築を行う。
 - ✓ 信用度については、各共同研究先ごとに、信用度が高いグループと低いグループにてセグメンテーションを行う。
 - ✓ 業種については、下記の内容を踏まえて、製造業、卸売業、宿泊業・飲食サービス業についてセグメンテーションを行う。
 - 開発コンセプト1における特定の共同研究先モデルについて、業種別のテストデータに対する精度を確認すると、製造業、卸売業、宿泊業・飲食サービス業については全体を予測した際と比較して精度が高く、学習データの件数も多いため、セグメンテーションモデルにて精度向上が見込まれることから、これらにてセグメンテーションを行う。
 - なお、製造業、卸売業、宿泊業・飲食サービス業については、コロナの影響を受けた業種・事業者数が多い業種であるため、今回の調査・研究の目的と合致している。
 - ✓ 業種別にセグメンテーションを行う際においては、業種特有の外部環境を考慮することを目的に、下表のとおり外部環境データの絞り込みを実施。
 - 例えば、経済関連データについては、業種に関連する外部環境データを使用する、マーケット関連データについては国内のマーケットデータに限定する等の絞り込みを行う。

共通して使用する外部環境データ	製造業に使用する外部環境データ	卸売業に使用する外部環境データ	宿泊業・飲食サービス業に使用する外部環境データ
<ul style="list-style-type: none"> • GDP成長率 • 景気動向指数 • 中小企業売上見通しDI • 発電実績 • エネルギー消費量 • 入港船舶総トン数 • 公共機関からの受注額 	<ul style="list-style-type: none"> • 鉱工業在庫指数 • 鉱工業出荷指数 • 製造工業生産能力指数 • 機械受注額（製造業） • 業況判断指数（製造業） 	<ul style="list-style-type: none"> • 商業販売額 • 第3次産業活動指数 • 貨物輸送量 • 機械受注額（非製造業） • 業況判断指数（非製造業） 	<ul style="list-style-type: none"> • 訪日外客数 • 定員稼働率 • 実宿泊数 • 旅客輸送量 • 第3次産業活動指数 • 機械受注額（非製造業） • 業況判断指数（非製造業）

セグメンテーションモデルの精度一覧

- 開発したセグメンテーションモデルの精度一覧は下表のとおり。それぞれ、ロジスティック回帰、ランダムフォレスト、勾配ブースティングの順番でAUCを記載している。

		信用度別セグメンテーション					
		セグメンテーションなし		信用度が高いグループ		信用度が低いグループ	
		平均値※	最大値※	平均値※	最大値※	平均値※	最大値※
業種別セグメンテーション	セグメンテーションなし	共同研究先モデル 0.708 0.730 0.745	0.801 0.821 0.832	信用度別セグメンテーションモデル 0.736 0.767 0.782	0.799 0.828 0.841	0.702 0.716 0.729	0.724 0.734 0.753
	製造業	業種別セグメンテーションモデル 0.722 0.743 0.753	0.803 0.822 0.834	信用度別×業種別セグメンテーションモデル 0.753 0.780 0.795	0.787 0.821 0.841	0.691 0.709 0.713	0.724 0.735 0.743
	卸売業	0.714 0.747 0.749	0.805 0.835 0.843	0.731 0.765 0.773	0.776 0.807 0.822	0.704 0.718 0.722	0.738 0.741 0.735
	宿泊業・飲食サービス業	0.651 0.700 0.696	0.669 0.769 0.753	0.647 0.678 0.668	0.687 0.695 0.701	0.675 0.679 0.665	0.735 0.722 0.735

注 セグメンテーションによる効果は、共同研究先モデルとセグメンテーションモデルに対して、各セグメントのデータを当てはめた場合の精度を比較することで確認する必要がある。上表の共同研究先モデルの精度は、共同研究先モデルに対して、セグメンテーションを行わないデータを当てはめた場合のものを表しており、この精度と、各セグメンテーションモデルの精度を単純に比較することは出来ないことに留意。

※ 一部の共同研究先については、セグメンテーションによってモデル開発母集団が十分に得られなかったため、3つの共同研究先のモデルの平均値、最大値を掲載。よって、信用度、業種ともにセグメンテーションを行わないモデルで掲載している精度は、p.13の結果と異なる。
AUCの平均値、最大値が0.7を超えているものについては、**太字**で記載。



1 スケジュール、本研究会の議題等

2 プロトタイプAIの開発結果等

3 AIからの出力結果の実務活用について

4 金融機関による実証事業・ワークショップについて

5 添付資料

AIからの出力結果イメージとその活用

– Step1 経営改善支援先の早期発見・優先順位付け

- 多数の取引先を抱える担当者の業務効率化のために、モデルを活用して、業績悪化の可能性が高い先のリストを抽出（抽出企業数は、閾値を変えることで調整可能）。
- 担当者が認識していないが、経営改善支援の必要性が高いと考えられる先を特定し、訪問の優先順位付けに活用。
- また、外部環境変化のシミュレーション結果も表示することで、景気変動の影響等も踏まえた優先順位付けも可能。

（例）地域や業種での絞り込みや並び替え機能を搭載し、優先順位をつける際の検討に活用

（例）業況に問題がない先と認識していたが、スコアが低いので詳細に調査を実施

（例）経営改善支援スコアはそこまで低くないが、原油価格上昇の影響を受けやすいので、優先的な訪問を検討

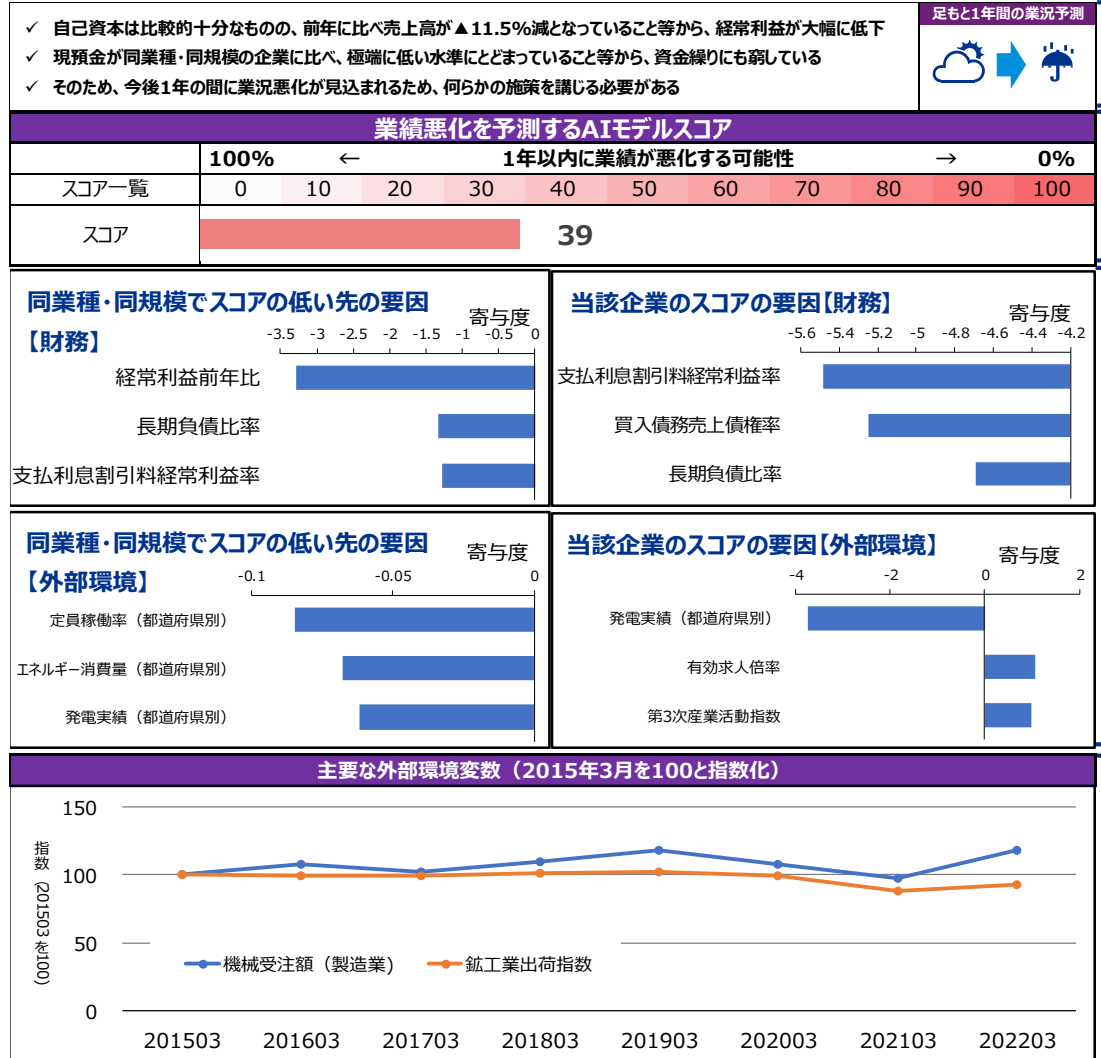
NO	企業名	地域	業種	経営改善支援スコア (1年以内の業績悪化可能性)	シミュレーション1 (例：原油価格が●%上昇)	シミュレーション2 (例：為替レートが●%円安)
1	●●工業(株)	●●県○○市	製造業	9	25	15
2	(株) △△食品	●●県○○市	製造業	18	30	28
3	(有) ■■工芸	●●県△△市	製造業	21	26	28
4	(株) ○○商店	●●県△△市	小売業	25	28	26
5	▲▲荘(株)	●●県□□市	宿泊業	31	38	25
6	□□建設(株)	●●県□□市	建設業	42	18	35

(※) 企業名やスコアをクリックすることで、「企業概要（金融機関保有データ）」や「経営改善スコア」の詳細を把握可能

リストを活用し、訪問の優先順位付けを実施

AIからの出力結果イメージとその活用

– Step2 経営改善支援先への対応策の検討 [1/2]



- 金融機関の若手職員でも理解できるよう、冒頭に業況サマリーをコメントと業況天気図により表現
- 業況サマリーのコメントは現状人間により作成する必要があるものの、AIが数値情報からテキストを自動生成する技術は存在することから、今後こうしたAI技術の活用を検討

- 企業の属性情報（業種や規模等）、財務データ、外部環境データから、AIモデルスコアを算出する。
- AIモデルスコアは、開発コンセプトごとに以下を表すものである。
 - 開発コンセプト1：1年以内に業績が悪化する可能性の低さ
 - 開発コンセプト2：1年以内に経営改善支援により業績が向上する可能性の高さ

- AIモデルスコアに寄与した要因を、財務、外部環境別に算出。
- 寄与度が正の指標はAIスコアを上昇、負の指標はAIスコアを低下させていることを表す。（例：総債務償還年数の寄与度が1.5の場合、当該要因によってAIモデルスコアが1.5上昇することを表す。）
- 同業種・同規模の企業と比べて、スコアが悪い要因がどこにあるのか等の分析が可能。

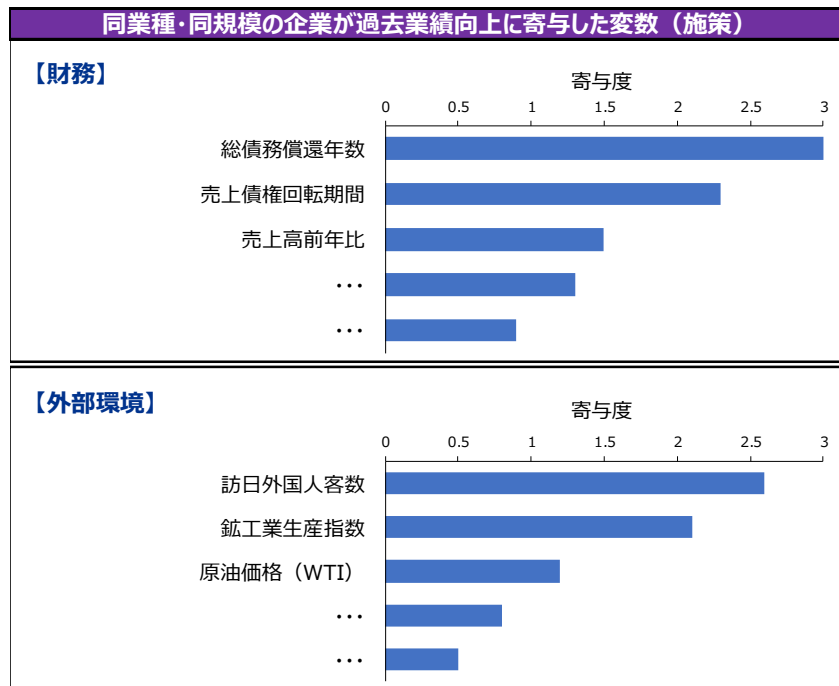
- 分析対象企業の業種に関する主要な外部環境変数のトレンドを確認し、当該企業の業界が置かれている外部要因の把握を行う。
- さらに外部環境シミュレーションを含めた事業者との対話に活用する。

AIからの出力結果イメージとその活用

– Step2 経営改善支援先への対応策の検討 [2/2]

業績悪化を抑えるのに寄与する変数とその期待される効果			
No	業績悪化を抑えるのに寄与する変数名	変化させる幅	期待効果 (得点の期待減少幅)
1	売上高営業利益率	+0.5%	+20点
2	訪日外国人客数	+10%	+15点
3	総債務償還年数	-2.5年	+5点
4
5

- 財務変数、外部環境変数のうち、AIモデルスコアを大きく向上させる変数を、向上させるために必要な変化の幅と共に算出。
- ここで示されるものは、モデルのスコア算出における理論値であるため、モデル外部環境シミュレーション（参考1）や財務分析（参考2）と組み合わせるなど、分析企業の実態に合わせて活用する。



- 開発コンセプト2のモデルで別途算定される情報
- 本情報を参考に、当該企業の業績向上のヒントを獲得するためのもの
- 具体的には、財務状況のどの指標（例：効率性や債務償還能力）が改善されると、業績向上の可能性が上がるか、また外部環境にどのような変化（例：訪日外国人客数の回復）が起きると、業績向上の可能性が上がるかが分かる。
- この情報から今は業績悪化の可能性が高い企業に対し、本当に悪化する前にどのような支援をすればよいかを検討する基礎資料になる。

AIからの出力結果イメージとその活用

– Step3 企業訪問・経営改善支援の実施

- 外部説明用の分析結果をもとに、事業者との対話を実施。事業者との目線合わせを行うとともに、経営改善に向けた対応策を検討。
- また、「業種別支援の着眼点（仮称）」(参考3)も別途活用し、適切な経営改善に向けた初動対応を行う。

事業者説明用の帳票（イメージ）

AIを活用した今後の業況予測とポイント

〇〇工業株式会社
令和●年●月●日

■今後の業況（AIによる業況予測）

今後の業況の見通し

外部環境変化の影響
 （原油価格が10%高騰）

<コメント（例）>

- AIに基づく予測では、今後の業況の見通しは曇。
- 財務指標としては、売上高、営業利益率、支払利息に悪化の兆候がある。
- 外部指標としては、原油価格、為替レート、鉱工業指数の影響を受けやすいので、その動向には注視が必要。
- 例えば、原油価格が10%高騰した場合、財務指標はより悪化（曇から雨）する可能性が高い。

■主な財務指標のポイント

売上高	（例）売上高の変動が今後の業況に大きく影響を与える。例えば、現状よりも売上高が●千円向上すれば、業況の改善が見込まれる（悪化可能性が大きく低下する）。
営業利益率	...
支払利息	...

■主な外部指標のポイント

原油価格	（例）原油価格の変動が今後の業況に大きく影響を与える。例えば、原油価格が●%上昇した場合、業績が●pt程度悪化する可能性がある。
為替レート	...
鉱工業指数	...

■memo

事業者説明用の帳票
 を用いて、対話を実施、
 改善策を検討

AIからの出力結果イメージとその活用


– (参考1) 外部環境変化シミュレーション

- モデルで算定された業績悪化を予測するスコアが、外部環境指標を変化させたときに、どのように変化するかシミュレーションが可能。
- 外部環境の変化はユーザーが任意で指定できるため、足元の原油高騰やコロナによるインバウンドの減少など、足元の状況を反映させた分析・対応策の検討が可能。

シミュレーション結果

ユーザーが任意に指定 (AIでは予測できない)

外部環境 (2015年3月を100とした指数)			
	ベースシナリオ	シナリオ1	シナリオ2
宿泊定員稼働率	49.7	32.1	89.3
訪日外国人客数	12.7	4.3	25.9
〇〇〇	〇〇		
〇〇〇	〇〇		



AIスコアの算出に使用された外部環境指標の値 (ベースシナリオ) に対して、変化させた任意の値を入力する。

左にて入力した外部環境指標の値にてシミュレーションを行ったAIスコアが表示される。

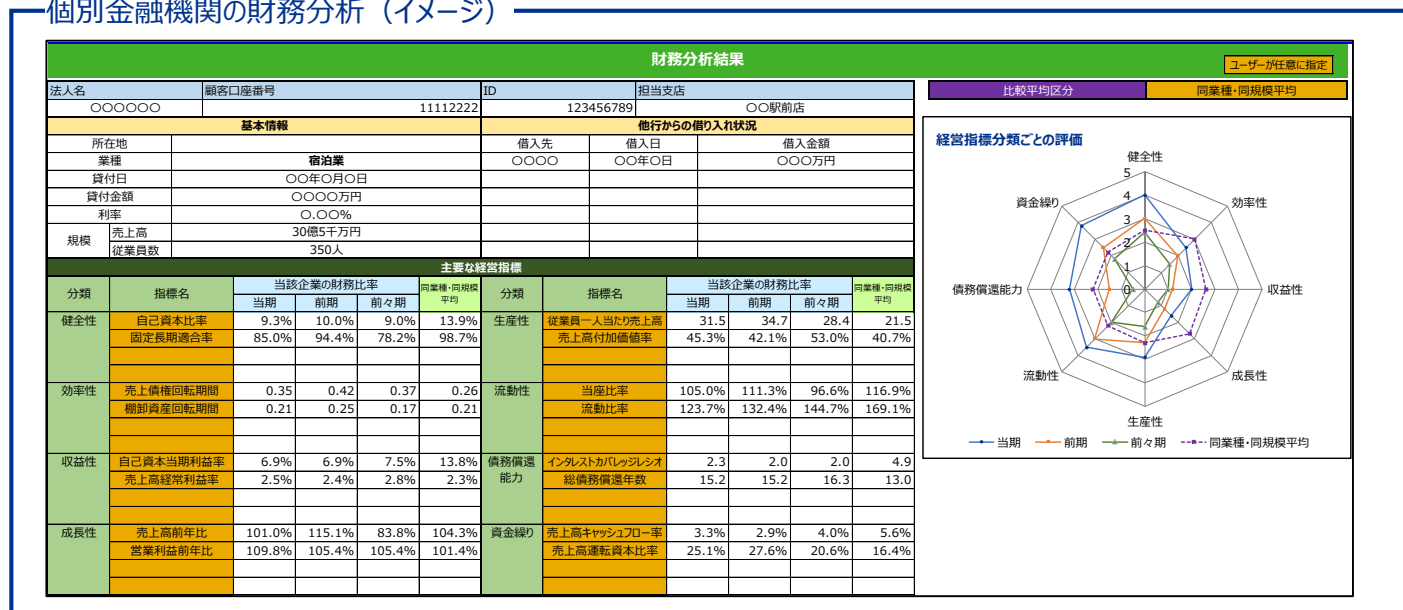
シミュレーションを踏まえた支援の方向性の検討等に活用

AIからの出力結果イメージとその活用

– (参考2) 財務分析等との連携

- AIモデルの算出結果と各金融機関で用いている財務分析を組み合わせることで、より深い分析や顧客との対話に活用。


個別金融機関の財務分析 (イメージ)



算出結果を組み合わせることで、
更なる検討が可能



AIからの出力結果



AIからの出力結果イメージとその活用

－（参考3）業種別支援の着眼点（仮称）

- 金融機関等の若手職員や経験年数の浅い方々が、現場での経営改善支援の初動を実施するために業種別の着眼点をまとめたもの。
- 中小企業／業種に共通する現実的な課題や特性を把握し、経営課題や支援の方向性を見極めるための基本的なポイントにフォーカス。
- 令和4年度は、全業種共通、建設業、飲食業、小売業、卸売業、運送業について作成予定。

活用事例1 ～事業者訪問前の事前準備～



- ✓ 「業種別支援の着眼点」を訪問前に参照することで、財務の動きの理由の把握やビジネスモデルの理解（事業性の把握）等、効果的かつ効率的に訪問（ヒアリング）準備を実施。
- ✓ 例えば、建設業では、売上総利益、売上原価等に注目することや、注目する理由等について記載。
- ✓ AIを活用して算定された今後の業績悪化に影響のありそうな指標や財務分析等の結果と組み合わせる事前準備を行うことで、より効率的・効果的な分析が可能。

【事業者訪問前】
中小規模建設業の目利き(決算資料編) その1

1 売上総利益 (完成工事利益)

建設業は、製造業と同じでモノ（商材）とモノから生み出した「労務」が重要な資源です。売上の大半が労務費であることから、売上原価（完成工事原価）に注目する必要があります。特に、中小規模建設業は、労務費が売上高の半分以上を占める傾向があり、労務費の増減が業績に大きく影響を及ぼすことが特徴です。労務費の増減は、労務単価の変動や、労務効率の向上・低下によって大きく変動します。労務単価の変動は、労務単価の算定方法（労務単価＝労務費÷労務量）によって大きく変動します。労務単価の算定方法は、労務単価の算定方法によって大きく変動します。労務単価の算定方法は、労務単価の算定方法によって大きく変動します。

2 売上原価 (完成工事原価)

売上原価は、売上高から売上総利益を引いた金額です。売上原価は、売上高の大半を占める傾向があり、売上原価の増減が業績に大きく影響を及ぼすことが特徴です。売上原価の増減は、売上原価の算定方法（売上原価＝売上高－売上総利益）によって大きく変動します。売上原価の算定方法は、売上原価の算定方法によって大きく変動します。

3 固定資産台帳 (稼働率)

固定資産台帳は、固定資産の取得と処分を記録する台帳です。固定資産の取得と処分は、固定資産の増減を記録する台帳です。固定資産の増減は、固定資産の算定方法（固定資産＝取得－処分）によって大きく変動します。固定資産の算定方法は、固定資産の算定方法によって大きく変動します。

活用事例2 ～事業者訪問時のヒアリング資料～



- ✓ ヒアリングや現場確認の際に「業種別支援の着眼点」を示しながら経営者等と対話を実施し、経営課題や支援の方向性を検討。
- ✓ 例えば、建設業では、工事施行体制や、工事種別・受注経路等について、ヒアリングを実施し、状況を把握。
- ✓ AIを活用して算定された指標や財務分析等の結果がなぜ生じたか等の分析が可能

【事業者訪問時】
中小規模建設業の目利き(訪問時編) その1

1 工事施工体制

建設業は、製造業と同じでモノ（商材）とモノから生み出した「労務」が重要な資源です。売上の大半が労務費であることから、売上原価（完成工事原価）に注目する必要があります。特に、中小規模建設業は、労務費が売上高の半分以上を占める傾向があり、労務費の増減が業績に大きく影響を及ぼすことが特徴です。労務費の増減は、労務単価の変動や、労務効率の向上・低下によって大きく変動します。労務単価の変動は、労務単価の算定方法（労務単価＝労務費÷労務量）によって大きく変動します。労務単価の算定方法は、労務単価の算定方法によって大きく変動します。

2 工事種別・受注経路

建設業は、製造業と同じでモノ（商材）とモノから生み出した「労務」が重要な資源です。売上の大半が労務費であることから、売上原価（完成工事原価）に注目する必要があります。特に、中小規模建設業は、労務費が売上高の半分以上を占める傾向があり、労務費の増減が業績に大きく影響を及ぼすことが特徴です。労務費の増減は、労務単価の変動や、労務効率の向上・低下によって大きく変動します。労務単価の変動は、労務単価の算定方法（労務単価＝労務費÷労務量）によって大きく変動します。労務単価の算定方法は、労務単価の算定方法によって大きく変動します。

(参考) AIからの出力結果イメージとその活用

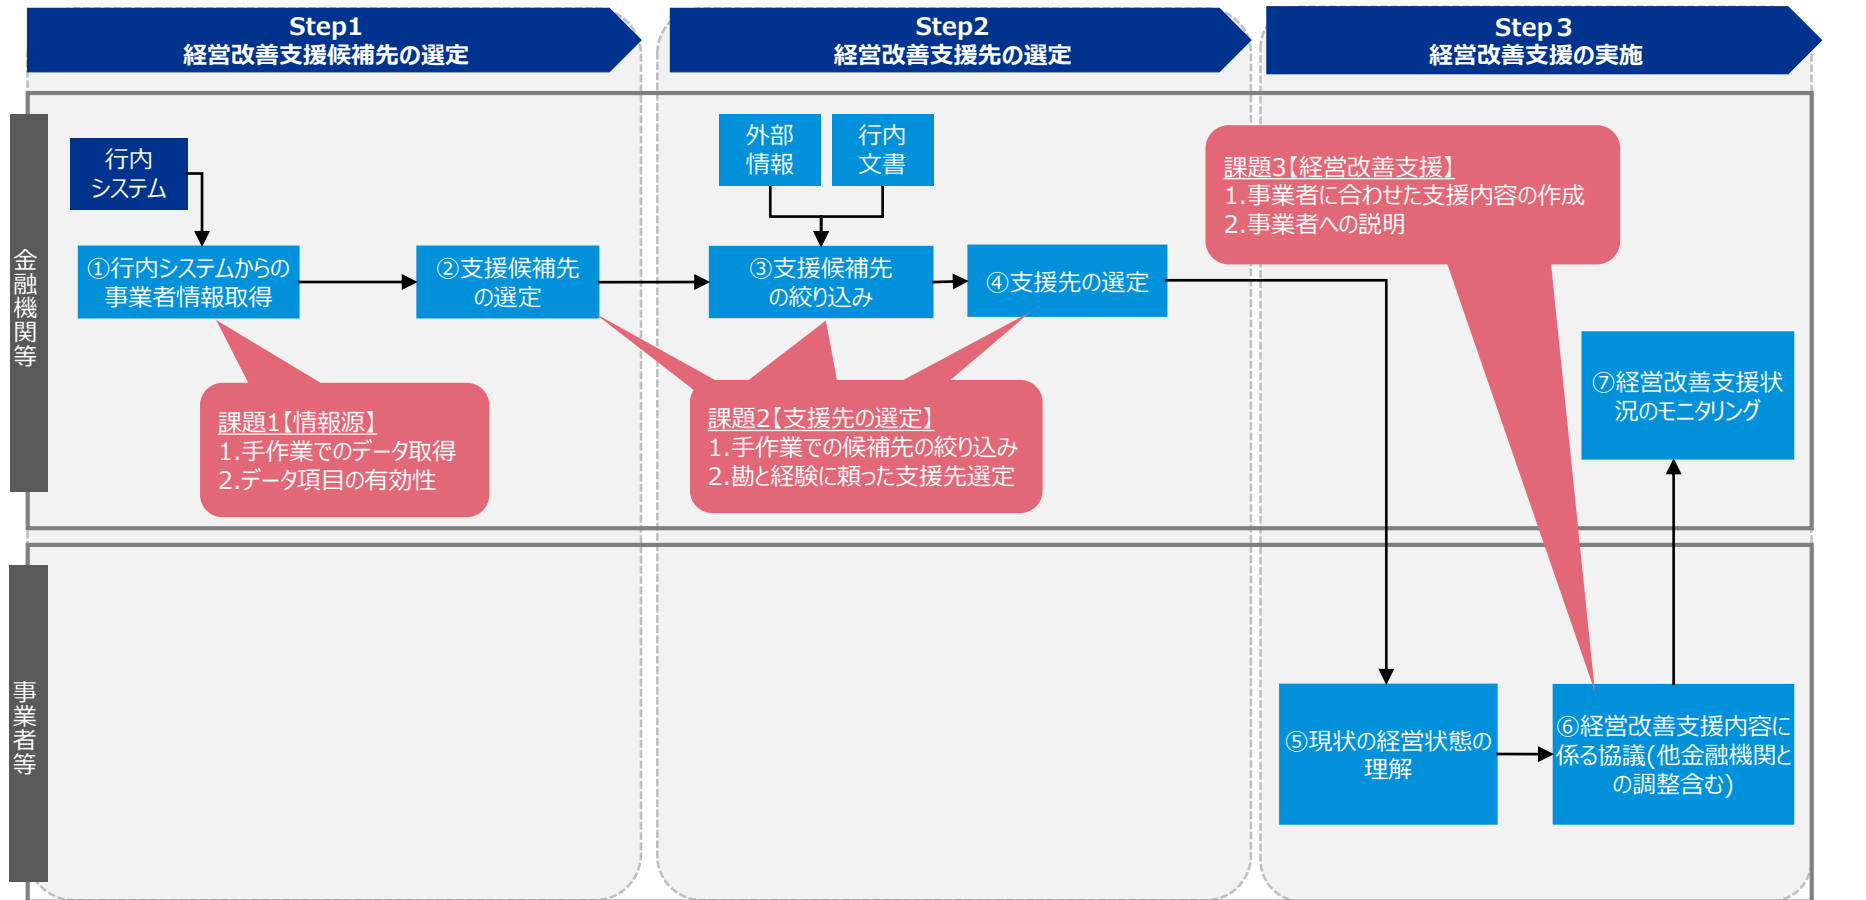
– 開発コンセプト1および開発コンセプト2の連携

- 本調査にて開発する2種類のモデルの入出力情報を改めて整理し、各モデルの出力情報をどのように業務に利用するかについて下表のとおり整理。
- 2つのモデルからの出力をうまく組み合わせながら、経営改善支援業務に活用することを想定している。

モデル種類	モデルのコンセプト	モデルへの入力情報	モデルからの出力情報	業務目的上利用するAIモデルからの出力情報	モデルの業務上の利用目的
開発コンセプト1	<ul style="list-style-type: none"> 業績低下の可能性が高い企業の特定 現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル 	<ul style="list-style-type: none"> 業績が悪くはない時の <ul style="list-style-type: none"> ✓財務・属性情報 ✓その他定性情報 外部環境情報 	<ul style="list-style-type: none"> 個社単位の情報 <ul style="list-style-type: none"> ✓業績が悪化する可能性の高さが付与された企業リスト ✓出力情報に影響を与えたファクター情報 統計・集計情報 <ul style="list-style-type: none"> ✓業種・規模等別のスコアや財務比率、AI出力に影響あるファクター等の統計情報 	<ul style="list-style-type: none"> 開発コンセプト1からの出力情報 <ul style="list-style-type: none"> ✓個社単位の情報 ✓統計・集計情報 開発コンセプト2からの出力情報 <ul style="list-style-type: none"> ✓統計・集計情報 	<ul style="list-style-type: none"> 取引先企業のうち、業況悪化が見込まれる先の早期発見・早期対応 検知された企業の業況が悪い理由の把握【コンセプト1の出力情報を活用】 検知された企業と類似した企業の業績向上のためのヒントの獲得【コンセプト2の出力情報を活用】
開発コンセプト2	<ul style="list-style-type: none"> 経営改善支援により業績が向上する企業の特定 現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル 	<ul style="list-style-type: none"> 業績が悪い時の <ul style="list-style-type: none"> ✓財務・属性情報 ✓その他定性情報 外部環境情報 	<ul style="list-style-type: none"> 個社単位の情報 <ul style="list-style-type: none"> ✓業績が向上する可能性の高さが付与された企業リスト ✓出力情報に影響を与えたファクター情報 統計・集計情報 <ul style="list-style-type: none"> ✓業種・規模等別のスコアや財務比率、AI出力に影響あるファクター等の統計情報 	<ul style="list-style-type: none"> 開発コンセプト2からの出力情報 <ul style="list-style-type: none"> ✓個社単位の情報 ✓統計・集計情報 	<ul style="list-style-type: none"> 業績が悪い取引先企業のうち、経営改善支援を実施すれば、業績向上が見込まれる先の発見とその先への経営改善支援 特定された企業の業績向上のためのヒントの獲得【コンセプト2の出力情報を活用】

(参考) 現状の経営改善支援業務

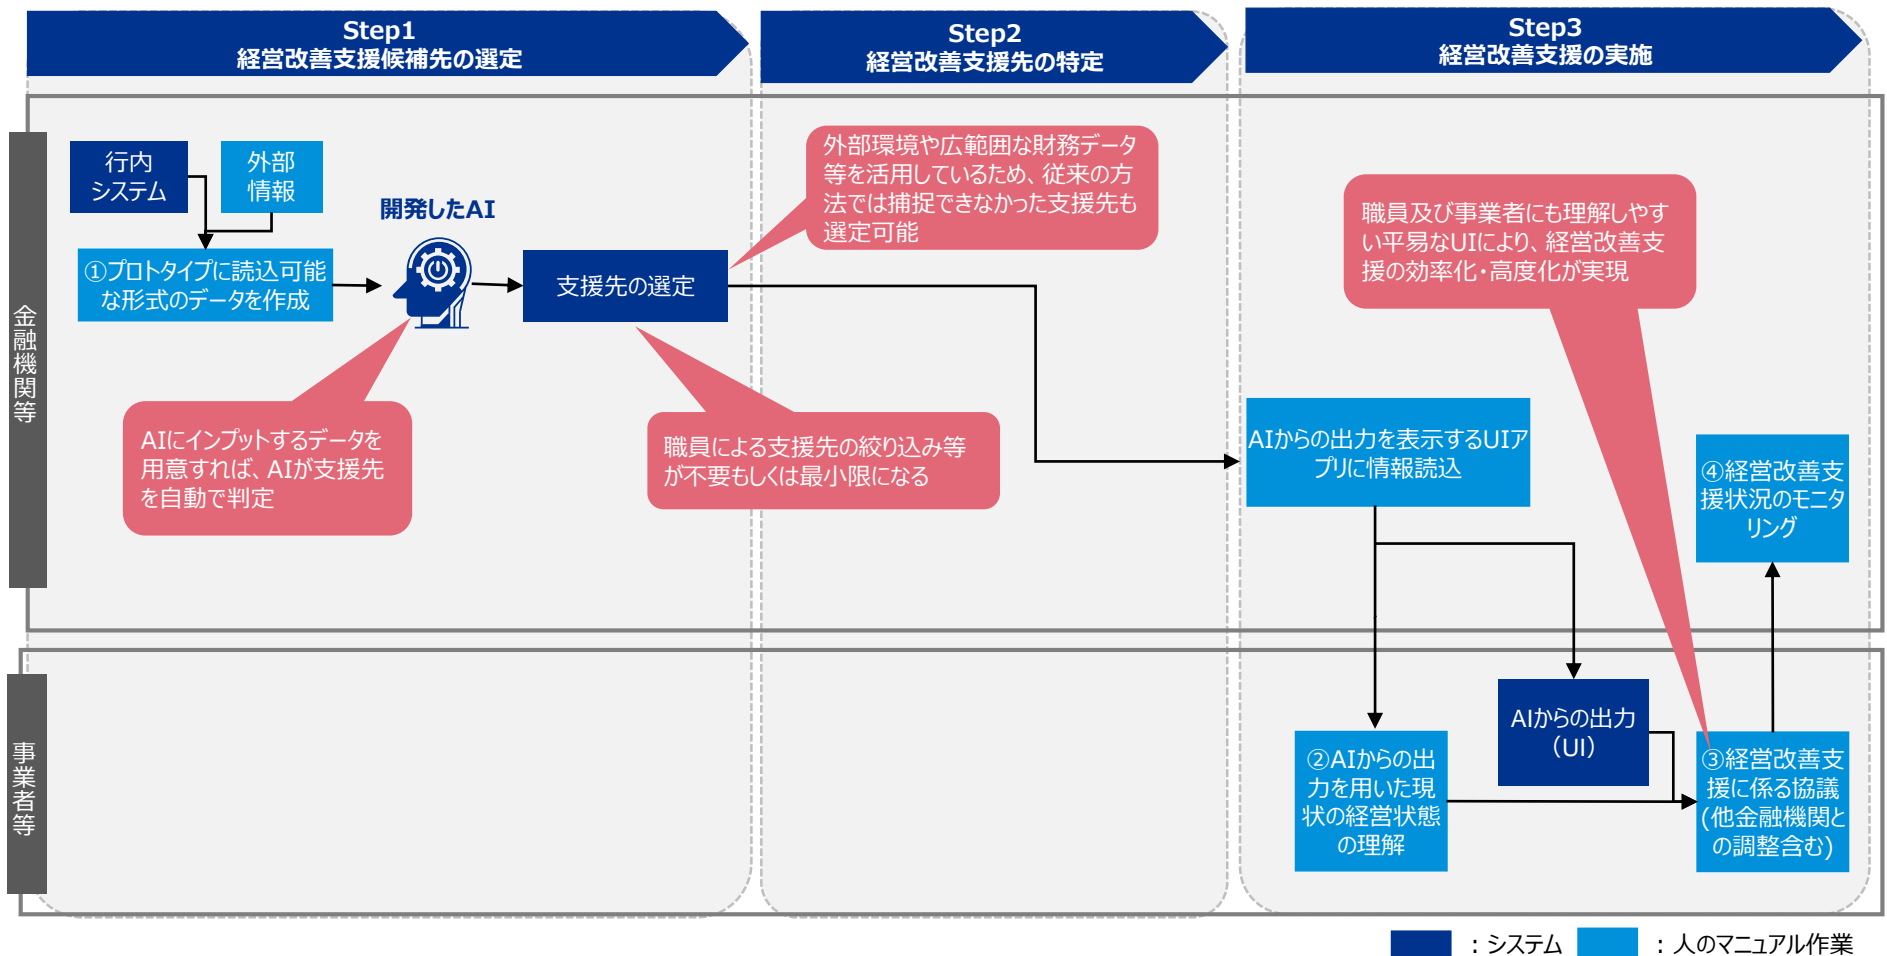
– 第1回研究会資料再掲



■ : システム ■ : 人のマニュアル作業

(参考) AI技術を用いた新たな業務フローの基礎検討

– 第1回研究会資料再掲





1 スケジュール、本研究会の議題等

2 プロトタイプAIの開発結果等

3 AIからの出力結果の実務活用について

4 金融機関による実証事業・ワークショップについて

5 添付資料

金融機関による実証事業・ワークショップの概要

【概要】

- 現在、財務データや外部環境データ等を用いて経営改善支援先を早期発見するAIモデルの開発を進めている。
この**モデルをより実効性の高いものとする**ため、金融機関の実データを用いて以下について検証を行う。〈実証事業〉
 - ① 開発したAIモデルが金融機関の実データにおいても有効に機能するかの検証
 - ② 金融機関の実データを活用したモデルの個別カスタマイズ・高度化可能性の検証（一部金融機関のみで実施）
- また、当該金融機関において、AIモデルからの出力結果をもとに、本部職員・現場担当者等とワークショップを行うことで、**実務適用上の課題整理、効果的なUI設計等**を行う。〈ワークショップ〉

【参加機関】

横浜銀行、栃木銀行、浜松いわた信用金庫、大東京信用組合の4機関

【実施内容・期間】

項目	対象者	実施内容案	実施期間（時期）
実証事業	金融機関の本部職員	①開発したAIモデルの有効性の検証 <ul style="list-style-type: none"> ➢ モデルの精度検証（AUC・AR値、適合率と再現率等） ➢ モデルの解釈性の確認（スコアの寄与度の解釈性など） ②AIモデルの個別カスタマイズ・高度化可能性の検証 <ul style="list-style-type: none"> ➢ 実際の金融機関データにしか存在しない教師データ・説明変数を用いたAIモデル開発（例：経営改善支援の実績データ） ➢ 当該モデルと共同研究先データで開発したモデルの比較（精度・解釈性等） ➢ 金融機関におけるAIモデルの個別カスタマイズ内容や高度化内容に係る整理 	実施期間：約3ヶ月 実施時期：令和4年11月 ～令和5年1月
ワークショップ	金融機関の本部職員 金融機関の現場担当者等	AIモデルからの出力結果に基づき、ディスカッションを行う <ul style="list-style-type: none"> ➢ AIモデルを活用した業務フローの検討 ➢ 設計したUIの実務適用上の課題の整理 	実施期間：約1ヶ月 実施時期：令和5年2月



1 スケジュール、本研究会の議題等

2 プロトタイプAIの開発結果等

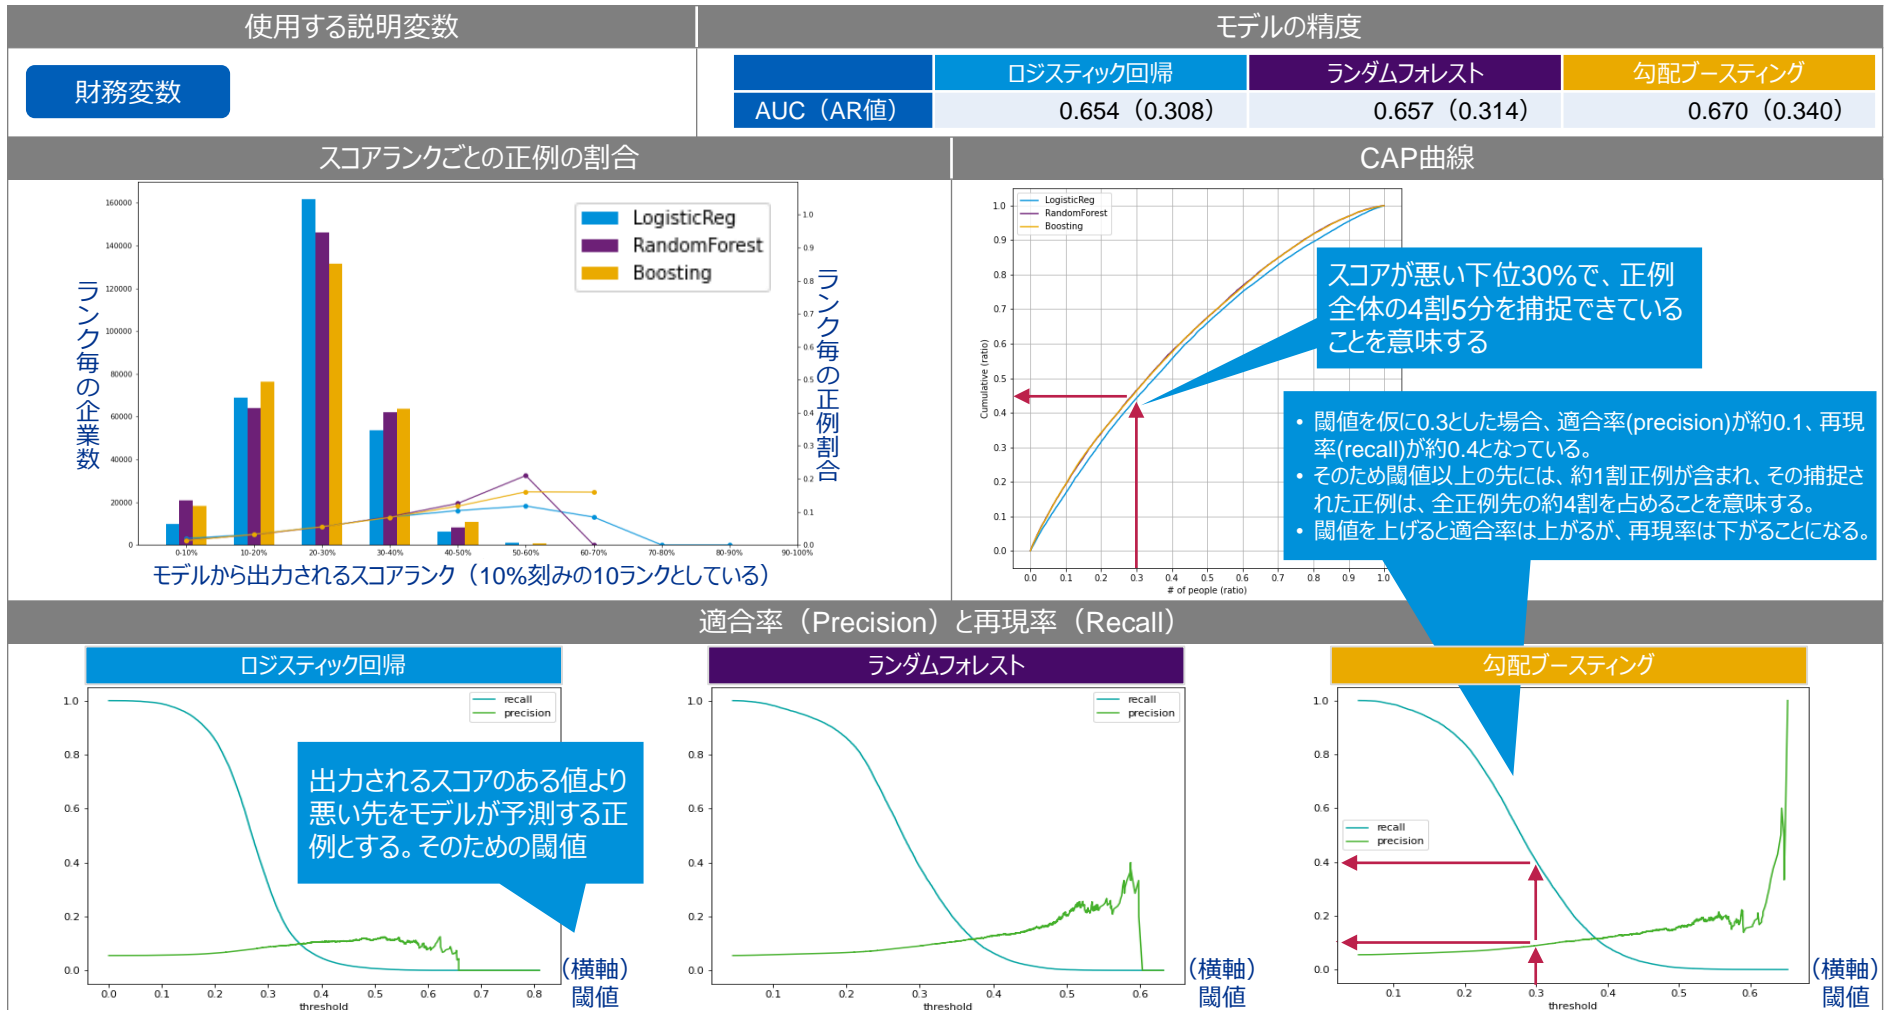
3 AIからの出力結果の実務活用について

4 金融機関による実証事業・ワークショップについて

5 添付資料

開発したモデルの評価

– 開発コンセプト1（財務のみモデル）



開発したモデルの評価

– 開発コンセプト1 (汎用モデル)

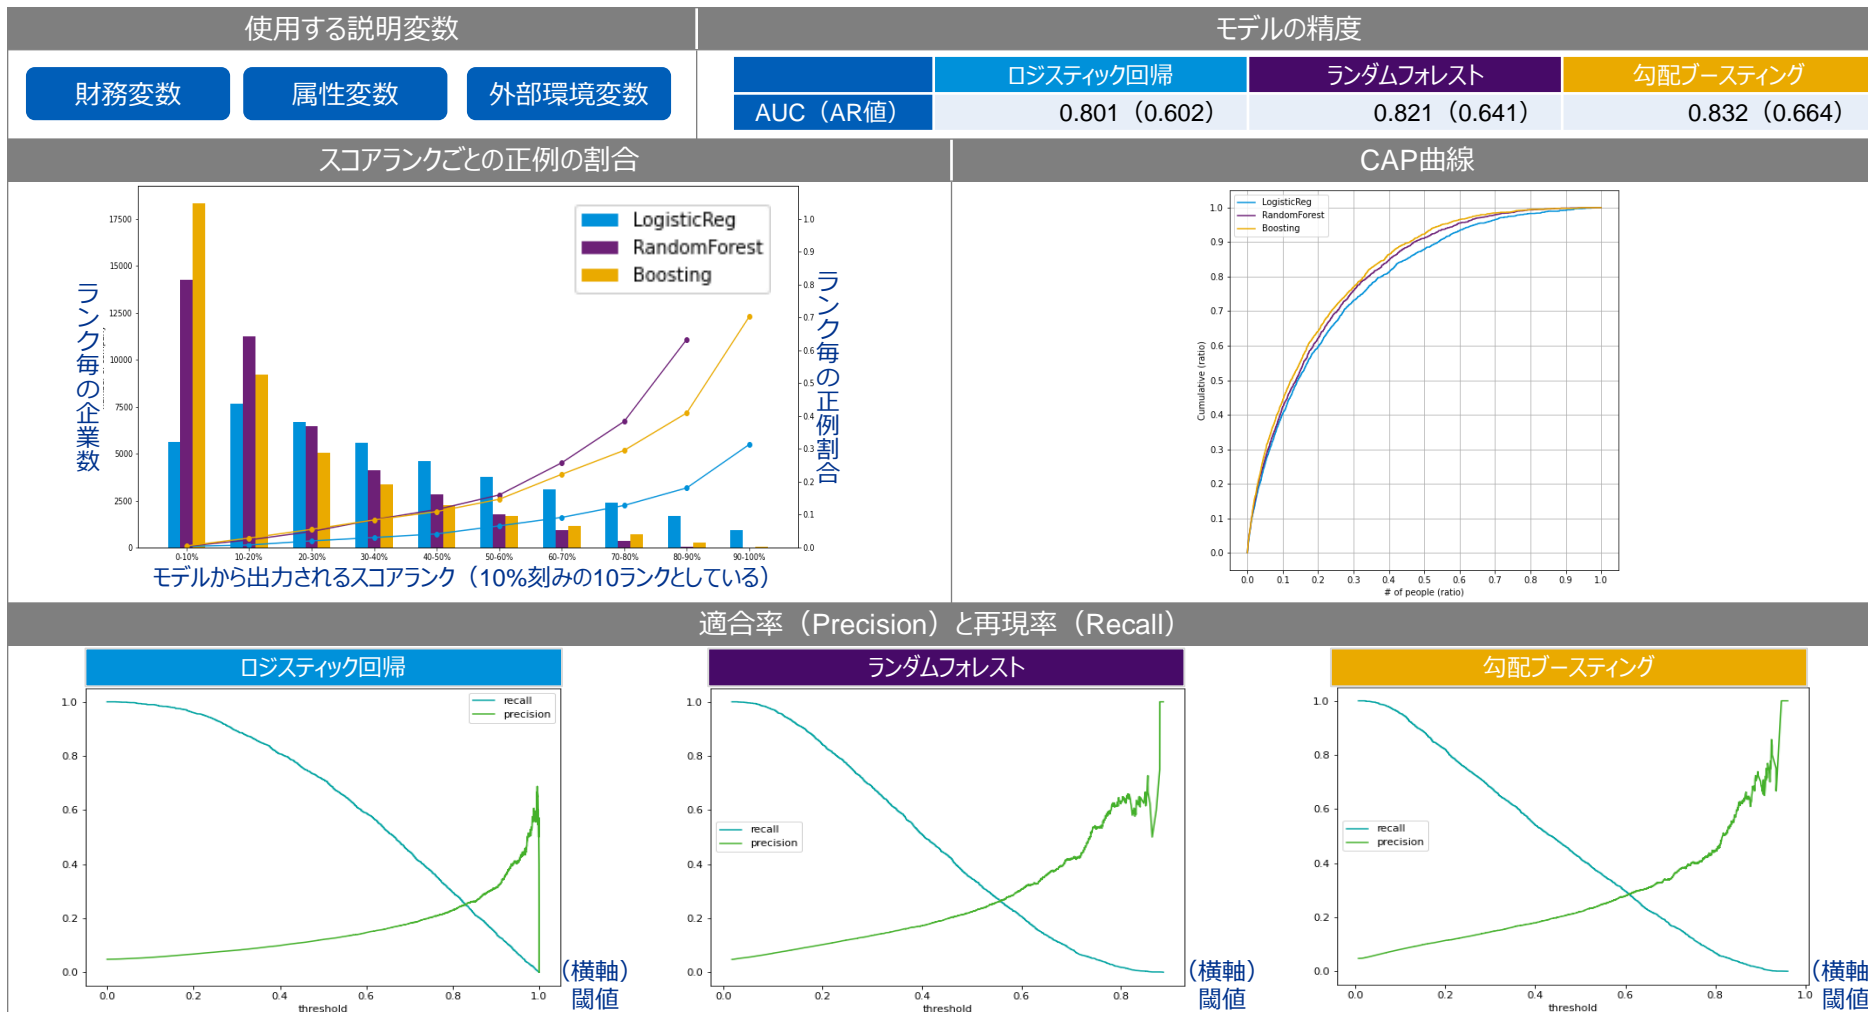
注：ある特定の共同研究先の汎用モデルのものを示している。



開発したモデルの評価

– 開発コンセプト1（共同研究先モデル）

注：ある特定の共同研究先の共同研究先モデルのものを示している。



開発したモデルの評価

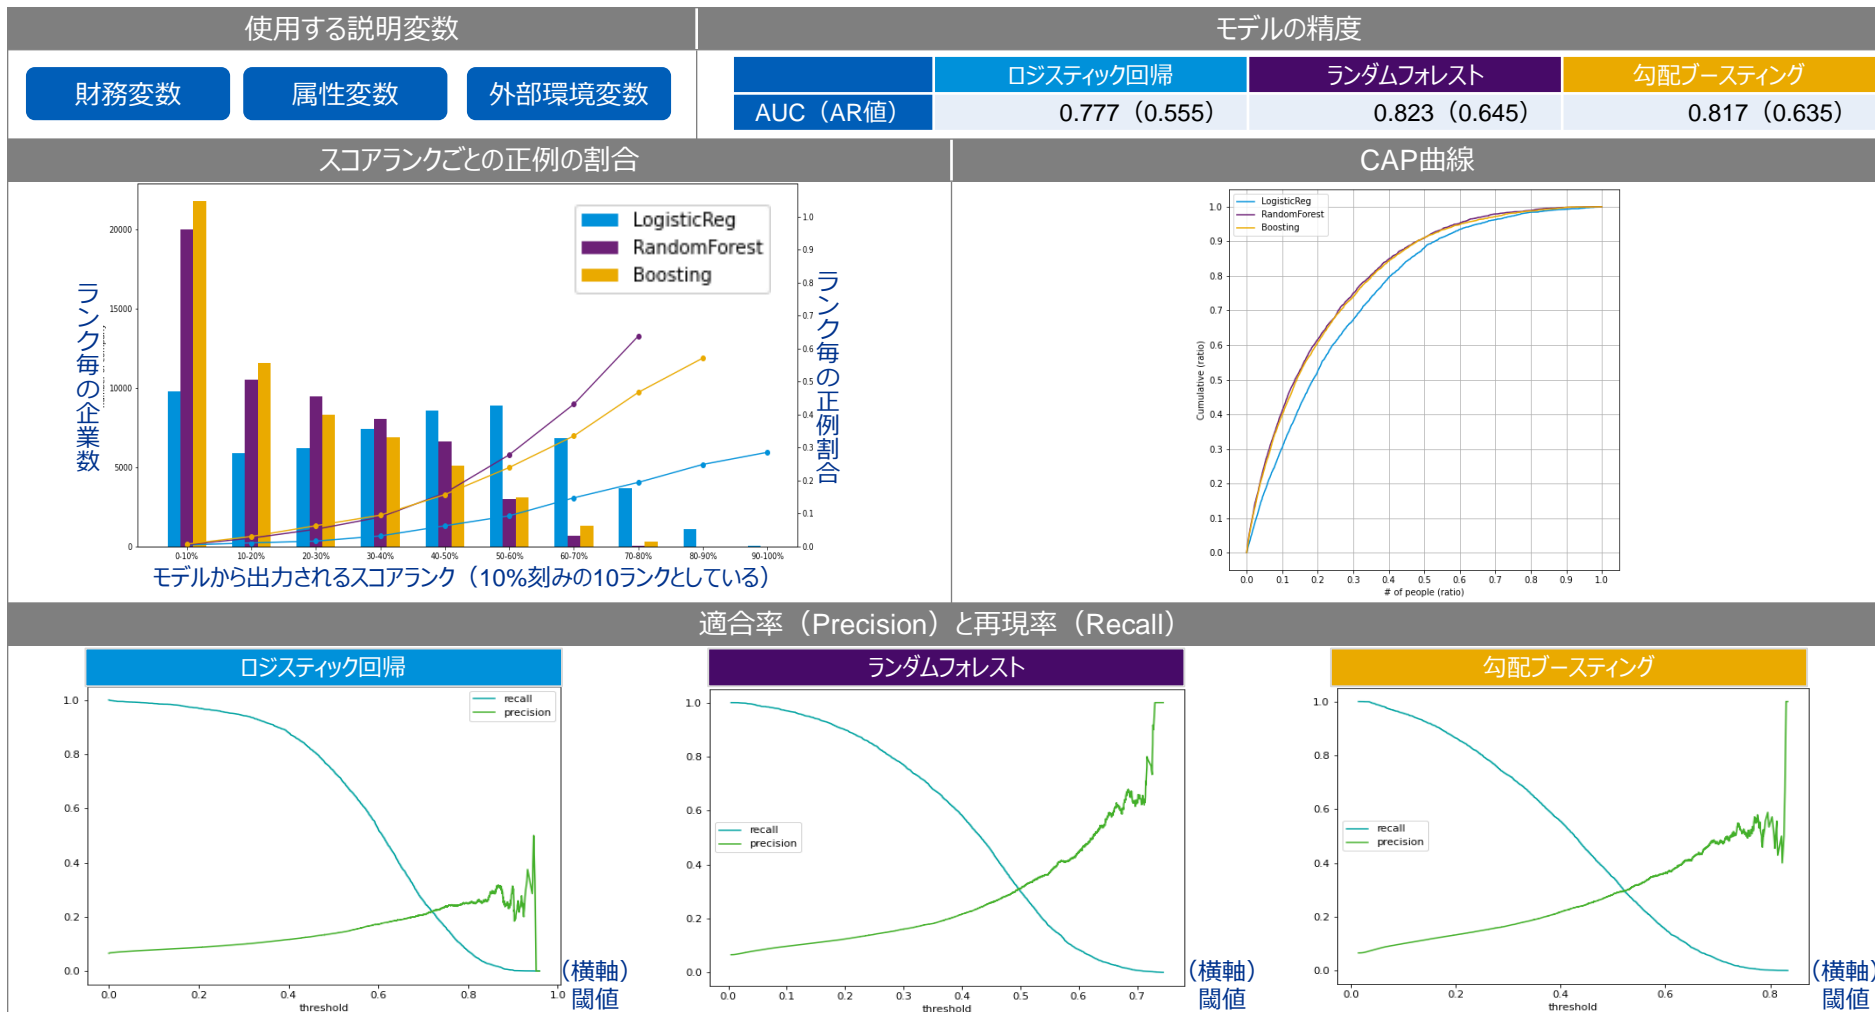
– 開発コンセプト2（財務のみモデル）



開発したモデルの評価

– 開発コンセプト2 (汎用モデル)

注：ある特定の共同研究先の汎用モデルのものを示している。



開発したモデルの評価

– 開発コンセプト2（共同研究先モデル）


注：ある特定の共同研究先の共同研究先モデルのものを示している。



開発したモデルの評価

– 精度の統計的評価（区間推定）

- 開発した汎用モデル、共同研究先モデルについて、そのAUCの95%信頼区間を算出し、精度に関する統計的な確認を行った。
- 開発した共同研究先モデルのうち最も精度の高かったモデルと、同一共同研究先の汎用モデルのAUCについて、その95%信頼区間を下図に示す。
- 開発コンセプト1については、汎用モデルと共同研究先モデルの信頼区間を考慮しても、汎用モデルより共同研究先モデルの精度が高く、共同研究先が独自に保有している説明変数が精度の向上に寄与していると考えられる。
- 開発コンセプト2については、汎用モデル・共同研究先モデルともに高い精度を達成しているため、両社の違いはAUCの信頼区間を考慮すると差はみられない結果となった。




開発したモデルの評価


– 汎用モデルの汎化性能の確認（クロスバリデーションの結果）

- 開発コンセプト1、開発コンセプト2ともに開発した4つの共同研究先の汎用モデルの精度と、各汎用モデルの学習データとは異なる共同研究先のデータを適用した場合の精度との差は下図のとおり。
- 下図のなかで縦方向のばらつき小さいモデルほど、モデル構築に使用したデータとは異なる共同研究先データに対しても安定した精度で予測が出来ていることを示している。
- 概ね異なる共同研究先データに対しては精度の悪化が見られたが、一部のモデルは悪化の程度が限定的かつばらつきが少なく、一定の汎用性を持つと考えられる。

開発コンセプト1



開発コンセプト2



ある共同研究先の汎用モデルの精度と、その学習データと異なる3つの共同研究先のデータを予測した場合の精度との差

因果推論モデル構築

– 伝統的な因果推論モデルによる全体的な効果の推定

【前提】

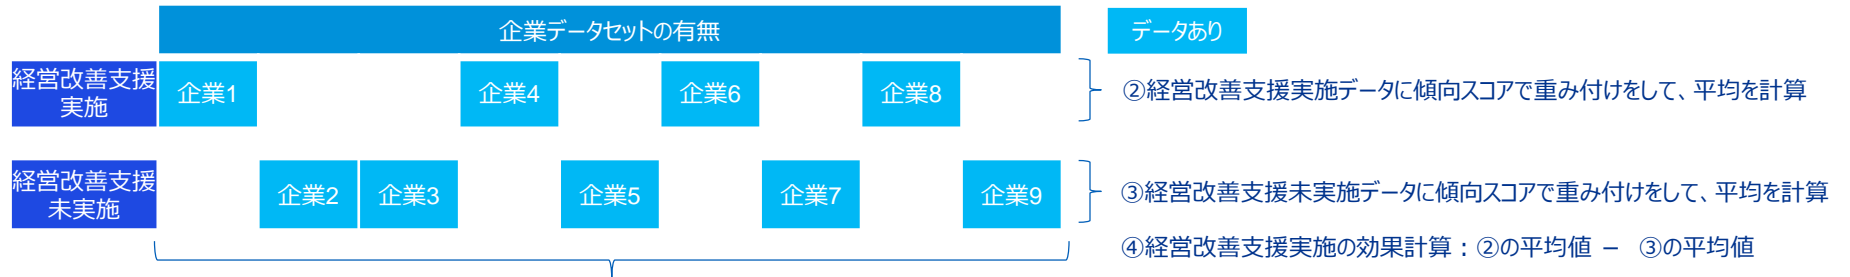
- 伝統的な因果推論モデルで経営改善支援実施の全体的な効果をベンチマークとして推定後、機械学習を使用した因果推論モデルを利用して個別企業への効果を推定する。
(ただし、現時点では経営改善支援実施企業のデータが45件しかないため、実務に耐えるモデルは作成できないことが想定される)
- 伝統的な因果推論モデルでは、下図の期間に該当する変数を持っている企業のデータを使用して、経営改善支援を実施することで平均的にどれくらい信用スコアが変化するか推定を行っている。



因果推論母集団 (全体) ※	9,548件
因果推論母集団 (経営改善支援実施)	45件

【手法】

- 傾向スコア（経営改善支援が実施される確率）をサンプルの重みとして使用し、経営改善支援を実施したグループの信用スコアの平均と、経営改善支援未実施のグループの信用スコアの平均を計算し、これらの差分をとることで効果を推定する。




- ① 経営改善支援実施グループと、経営改善支援未実施グループの企業属性（財務状況や属性）は異なり、両グループの単純比較では、経営改善支援実施の効果を正しく推論することができない。そこで、傾向スコア（経営改善支援が実施される確率）を用いて、両グループの企業属性を等しくするように調整を行う。

※ 信用スコアが経営改善支援実施企業の最大（55.44点）、最小（36.85点）の範囲内に入る企業のみ使用（経営改善支援非対象企業を除くため）

【結果】

経営改善支援実施によって、信用スコアが約0.83点上昇する結果となっている。（ただし、計算の余地は残っており、バイアスの排除はまだ完全ではない）

経営改善支援実施効果（95%信頼区間）



因果推論モデル構築

– 機械学習モデルによる個別企業への効果の推定

【手法】

- 機械学習を利用した因果推論モデルとして、DA-Learner (Domain Adaptation Learner) を利用した。
- DA-learnerは、Meta-Learnersの一種で、処置群と対象群を別々にモデリングに用い、各群のデータ量が不均衡な場合や各群が持つ変数分布に偏りがあっても有効な手法。


【手法の説明】

- ① 伝統的な因果推論モデルと同様に傾向スコア（経営改善支援実施確率）でサンプルの重みづけをする。
- ② 経営改善支援実施、未実施のグループそれぞれで信用スコアを予測するモデルを作成する。
- ③ このモデルを使用して、経営改善支援実施先が経営改善を実施しなかった場合の信用スコアを推定（未実施先も同様）する。
- ④ ③で推定された経営改善支援を実施した場合と実施しなかった場合の信用スコアの差を測定することで、経営改善支援を実施した際の効果を推定する。

【結果】

全体の経営改善支援実施効果

経営改善支援実施により、信用スコアが0.569点上昇する結果となっている。



個社の経営改善支援実施効果の確認


平均経営改善支援実施効果0.569点から、個社要因によって経営改善支援実施の効果がどれほど異なるかをモデルから確認することができる。

■ ケース

経営改善支援未実施企業であるものの、2017年時点38.51点と信用スコアが低い企業に対する因果推論

■ 因果推論結果


- 経営改善支援実施により、信用スコアが約1.47点上昇すると推定
- 推定の個社要因は右図のとおり



AIアルゴリズムの概説 [1/6]

■ ロジスティック回帰の概説

下図のようなロジスティック曲線を用いて、目的変数を回帰分析の手法で予測する方法。金融機関実務において企業の信用力評価に最も活用されている方法。



$$Z = \alpha_0 + \beta_1 X_1 + \beta_2 X_2 + \dots$$


X_i : i 番目の説明変数 (特徴量)

α_0 、 β_i : 切片および回帰係数

AIアルゴリズムの概説 [2/6]

■ ランダムフォレストの概説

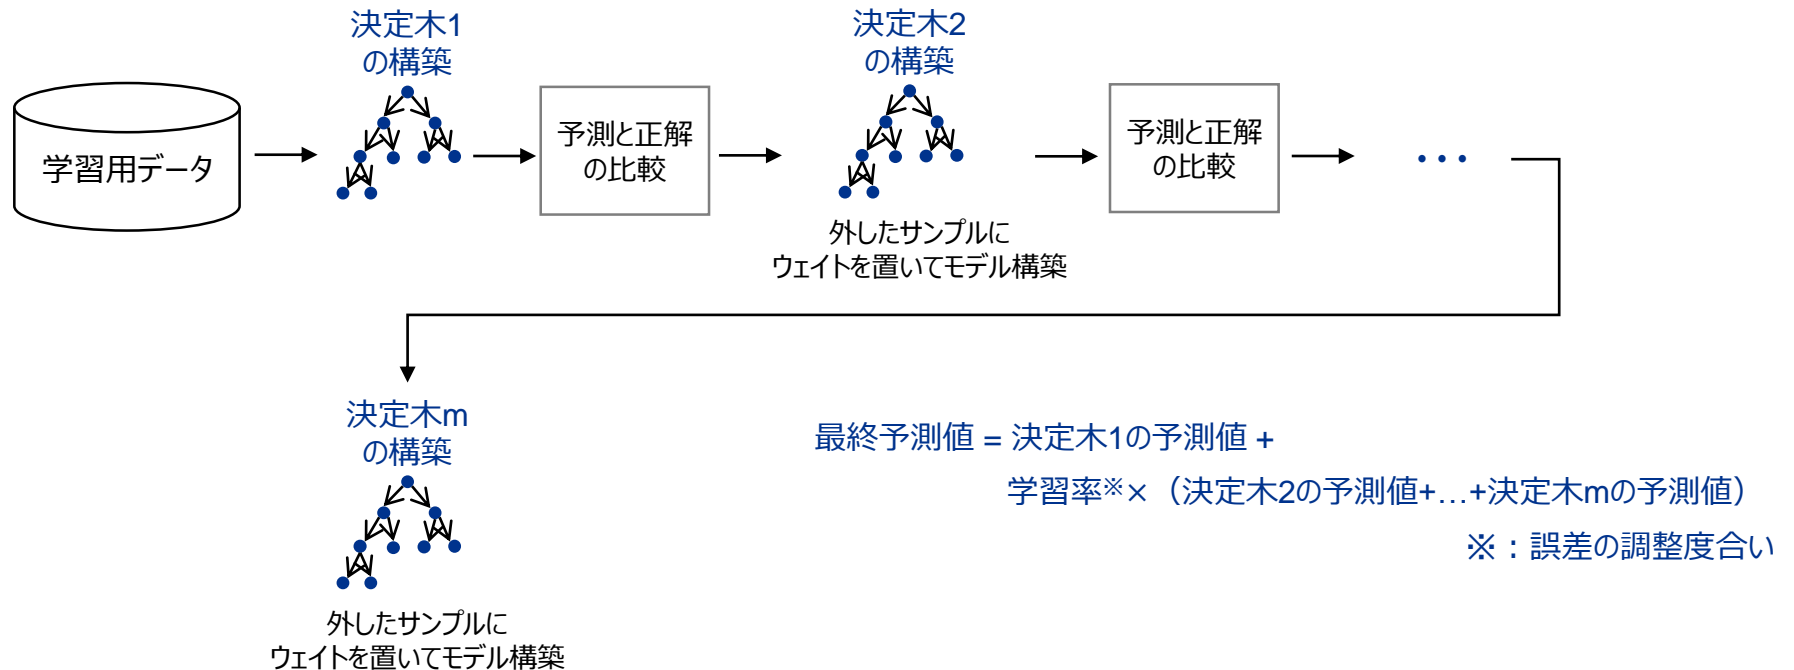
多くの決定木モデルを構築し、多数の決定木の予測値の平均値を最終的な予測値とする方法



AIアルゴリズムの概説 [3/6]

■ 勾配ブースティングの概説


決定木を構築し、当該決定木が外したサンプルに当てはまるようにウェイトを調整して、次の決定木を構築する。これを繰り返して最終的な予測値とする方法



AIアルゴリズムの概説 [4/6]

■ Meta-Learnersの概説

因果推論を行うための論理フローの各ポイントに主要な機械学習アルゴリズム（ロジスティック回帰、ランダムフォレスト等）を適用し、介入効果の推定を行う手法。




(注) Meta-Learnersの中には様々なアルゴリズムがあり、各ポイントにおける機械学習モデルの適用有無や適用方法、介入効果の算出方法は、各アルゴリズムによって異なる。

AIアルゴリズムの概説 [5/6]

■ 傾向スコアを用いた逆確率重み付き推定による因果推論（伝統的な因果推論）


傾向スコア（介入が行われる確率）をサンプルの重みとして使用し、処置群の目的変数と、対照群の目的変数の平均を計算し、これらの差分をとることで介入の全体効果を推定する。



AIアルゴリズムの概説 [6/6]

■ DA-learner (Domain Adaptation Learner) を用いた分析

傾向スコア（介入が行われる確率）をサンプルの重みとして使用し、処置群の目的変数と、対照群の目的変数の予測モデルを構築する。観測できない目的変数を予測モデルで推定し、介入ありと介入なしの目的変数の差分のモデルを構築することにより個体効果を推定する。



AIモデルの評価指標の概説 [1/2]

- 本資料にて示したAIモデルの評価指標である、適合率、再現率についての概説は以下のとおり。

混同行列と評価指標

- 混同行列は、モデルでデータを分類した際にその正解・不正解をまとめた行列のこと。クラス分類を行うモデルの性能・精度の確認に使用される。
- 正例（ポジティブ）と負例（ネガティブ）の2クラスがあるデータセットに対して、以下が定義される。
 - 真陽性（True Positive、TP）：実際にポジティブのデータを正しくポジティブと予測したもの（数）
 - 偽陽性（False Positive、FP）：実際にはネガティブのデータを間違ってポジティブと予測したもの（数）
 - 真陰性（True Negative、TN）：実際にネガティブのデータを正しくネガティブと予測したもの（数）
 - 偽陰性（False Negative、FN）：実際にはポジティブのデータを間違ってネガティブと予測したもの（数）

		モデルの予測	
		1 (Positive)	0 (Negative)
実データの クラス	1 (Positive)	TP	FN
	0 (Negative)	FP	TN

- 上記で定義した混同行列の4つの数値を使用して、以下のような評価指標が計算される。


- 正解率(accuracy) = $\frac{TP+TN}{TP+FP+FN+TN}$ ・ 予測結果全体に対し正しく予測できたものの割合
- 適合率(precision) = $\frac{TP}{TP+FP}$ ・ ポジティブと予測したものに対し、実際にポジティブであるものの割合
- 再現率(recall) = $\frac{TP}{TP+FN}$ ・ 実際にポジティブのものに対し、正しくポジティブと予測できたものの割合

AIモデルの評価指標の概説 [2/2]

- 本資料にて示したAIモデルの評価指標である、AUC、AR値、CAP曲線についての概説は以下のとおり。

ROC曲線とAUC


- モデルにデータを当てはめたとき、実際にイベント（「企業業績の低下」など、モデルによって検知する事象）が発生した全てのデータのうち、正しく検知ができた割合のことを、真陽性率（TPR）という。また、実際にイベントが発生しなかった全てのデータのうち、間違えて検知した割合を偽陽性率（FPR）という。
- 検知するかしないかは、モデルで推定されたイベント発生確率に対して閾値を設け、それを上回ったかどうかで判定しており、**ROC曲線**は、当該閾値を変更した際に変化するTPRとFPRをそれぞれ縦軸、横軸にプロットしたもので、下図のような曲線を描く。



- **AUC (Area Under the Curve)** は、ROC曲線の下部分の面積のことをいう。ROC曲線は、右にいくほど下がることはないこと、偽陽性率（横軸）が小さい段階で、真陽性率が高いモデルほど良いことから、AUC（上記面積）が大きいほど、優れたモデルであることを意味する。

CAP曲線とAR値

- **CAP曲線**は、横軸にモデルで推定されたイベント発生確率の上位 x 件の、全てのデータ件数 (N) に対する割合 (x/N) を、縦軸に推定されたイベント確率の高い上位 x 件のうち実際にイベントが発生した件数 (N_x) の、イベントが発生した全てのデータ件数 (N_1) に対する割合 (N_x / N_1) をプロットしたものであり、下図の**B**のような曲線を描く。
- モデルの説明力が全くない場合は **C** の直線を描き、予測が完全に正解したモデルの場合は **A** のような形を描く。



- BとCで囲まれた部分の面積の、AとCで囲まれた部分の面積に対する比を、**AR値**という。すなわち、値が1に近づくほど、予測が完全に正解したモデルに近いということの意味する。

$$\text{AR値} = \frac{\text{BとCで囲まれた部分の面積}}{\text{AとCで囲まれた部分の面積}}$$



ここに記載されている情報はあくまで一般的なものであり、特定の個人や組織が置かれている状況に対応するものではありません。私たちは、的確な情報をタイムリーに提供できるよう努めておりますが、情報を受け取られた時点およびそれ以降においての正確さは保証の限りではありません。何らかの行動を取られる場合は、ここにある情報のみを根拠とせず、プロフェッショナルが特定の状況を綿密に調査した上で提案する適切なアドバイスをもとにご判断ください。

© 2022 KPMG AZSA LLC, a limited liability audit corporation incorporated under the Japanese Certified Public Accountants Law and a member firm of the KPMG global organization of independent member firms affiliated with KPMG International Limited, a private English company limited by guarantee. All rights reserved.

The KPMG name and logo are trademarks used under license by the independent member firms of the KPMG global organization.

「AI を活用した経営改善支援に係る研究会」(第3回)

開催日時： 11月25日(金) 10時00分～12時00分

開催方法： 「Webex」による Web 会議形式

委員：

有竹 博史 東京信用保証協会 業務総轄室 業務総轄部長
和泉 潔 東京大学大学院 工学系研究科システム創成学 教授
内山 功士 浜松いわた信用金庫 デジタル推進部 デジタル業務課 課長
河合 祐子 Japan Digital Design 株式会社代表取締役 CEO
三川 剛 株式会社エルテス 取締役
鈴木 明美 大東京信用組合 常務理事
筒木 光 TKC 全国会システム委員会 TKC 経営指標編集小委員会 委員
中村 康浩 株式会社横浜銀行 融資部 担当部長
名取 良訓^{※1} 信金中央金庫 総合企画部しんきんイノベーションハブ 次長
原 浩二 株式会社栃木銀行 事業支援部 主任調査役
松崎 堅太郎 TKC 全国会中小企業支援委員会 副委員長
宮川 大介 一橋大学 経営管理研究科 経営管理専攻 教授
矢内 紘之^{※2} 株式会社帝国データバンク 企総部 企画課長

議事進行：

秋場 良太 有限責任あずさ監査法人金融統轄事業部 ディレクター

※の記載のある委員については当日以下の通り代理出席者が参加。

※1：北口 裕也 信金中央金庫 総合企画部しんきんイノベーションハブ 上席調査役

※2：木村 浩平 株式会社帝国データバンク プロダクトデザイン部
プロダクトデザイン課 課長

■アジェンダ

1. 開会
2. 事務局説明
3. 討議
4. 閉会

(主なやり取り)

○ 研究会委員

1点感想に近いですが、P13のモデル精度一覧の表について、正直思ったよりかなりAUCが高かったというのがびっくりしました。特に開発コンセプト2の方は、事例が少ないにもかかわらずかなり高い数字が出ていましたので、特にKPIとして今回のもので問題がないと思います。

もう一点、今後に関してですが、やはり開発コンセプト1も含めて全体の精度向上という意味で、より複雑なモデル、高度なモデルを使うことが考えられるかと思います。その際に複雑なモデルを使いますとブラックボックスになりますので、説明可能なAIの手法である、例えばSHAPなどを使って、どの変数が今回の低いスコアもしくは回復の方の要因になり得るかということをしっかり説明できるように、合わせて使った方がいいのかなと思います。以上、少し感想に近いですが、KPIというか精度に関する感想とフューチャーワークに関してでした。どうもありがとうございます。

○ 事務局

皆様方のご協力なりご意見のおかげで精度としては、十分かというところではないものの、ある程度の精度が達成できたので、改めて皆様にも感謝申し上げたいと思います。KPIとしては概ね達成できたのではないかとご意見賜りましたが、全部、この表の中で0.8以上になっていると理想ですので、今後より複雑なディープラーニングを用いたような方法を使ったりして、そういった検討ができればと思います。ありがとうございました。

ちなみにこちら実務的な運用のカバーをすることによって大前提ですけれども、こちら先生におかれては、このモデルを使って実証事業に移っても今回の目的であるの経営改善支援の業務が効率化できるかどうかみたいな確認はできそう、というお考えですか。

○ 研究会委員

特に、この後のセクション分けとか、いくつか信用度とか業種別のセクションで得意不得意もしっかり分析していただきましたので、そういった条件を見極めながらであれば、十分実用に足ると思います。

○ 研究会委員

ご説明いただきましてありがとうございます。全体的な印象としては、非常に難しいタスクだったと思うのですが、2つのコンセプトを上手く分割してつなげられる形でモデル化したことで、良いものができたのではないかなと思います。先ほど、お話しあった通り、もちろんこれから改善の余地はいろんな面であると思うのですが、現状において目的としているものが達成されているのではないかなというのが私の印象です。

1点だけ、いただいているお題の中の最初のところで、KPIが達成されているかどうかと

いうところのくだりがあるって、その意味でも実証実験に移ることは問題ないと思いますが、そこに移る中で追加的に KPI というわけではないのですけれども、達成度合いを確認することができる部分もあるかなと思ひまして、具体的には今回は先ほど2つの KPI ということで、分かってなかったことが見つかるといいね、というところと、コスト削減できればいいね、ということでその両方においてやはり実務的な観点からの評価が必要だと思ひます。後者は人的な資源がどれくらい節約されたのかということが今後の評価の軸になると思ひますし、前者に関してもこれは正常先であるところから悪いことが起こることを予見できればということで、本当に気付かなかったようなところが予測されている先に含まれているのかということが重要だと思ひます。なので、正常先というふうにひとくくりにしても、例えば格付けという意味ではレイヤーがありますから、非常に良いところと思ひていたけれども、モデルを回すことである程度事前の予兆が確認できたみたいな視点も、せつかくこういういいモデルができて、精度面でも AUC が一定の水準を達成できているということ踏まえると、追加的な視点としては持っていてもいいのかなと思ひました。私からは以上です。

○ 事務局

先ほど2つの KPI のより実務的な確認という意味では、この後実証事業で可能な範囲で、実務家の方に今までのやり方では気づかなかった先が含まれているのかとかそういったことは確認できればと思ひています。あとは実際にコスト削減につながるかどうかについても、どれくらい時間が削減されるのかとか、いくつかそういう効率化の目線の評価というのはでき得るかと思ひますので、可能な範囲で今後の実証事業、あとはワークショップでの現場の方々からの意見を賜って確認できればと思ひています。ありがとうございました。

○ 研究会委員

ご説明いただきありがとうございました。事前に資料をお送りいただいた後に、しっかり読み込めていなくて、モデル自体をどのくらい理解できたかということとはございますが、結論においては、先生方、他の皆様方からお話があった通りで、十分な精度であり、実証実験に持っていても良いような結果を出しているのだろうと理解しております。ただ、そもそもこのモデル自体の基本的なことをもう少し理解しないといけないということで、おそらく資料に開発コンセプトをもう少しこういう形で具体的に考えましたってことが書いてあるのだろうと思ひるので、後でまたきっちり読ませていただきたいというふうに思ひます。

まず、このベーシックモデル、アドバンスモデルの2つがあり、ベーシックモデルでは一定期間内において業績が悪くはない企業から将来悪化する企業を見つけ出すということで、この一定期間というのは、だいたいどのくらいの期間を置かれたのでしたっけ。

○ 事務局

1年間ですね、今回は1年単位でやっています。

○ 研究会委員

はい、わかりました。先ほどその信用度合いに、もともとの信用度合い、正常先なのか、要注意先なのかみたいなことを分けて考えて、業績が低下するということの定義は何かというと、例えば正常先のものであれば正常先が、経営改善が必要な先まで何段階か落ちた、これをもって業績が低下する。あるいは、業績支援が必要にならないところまで落ちなければ、業績低下とはみなさないということですね。その正常先が要注意、正常先の格付けが落ちたとか、そういうことはモデルには入らないということですね。

○ 事務局

ありがとうございます。例えば、ある要管理先とか破綻懸念先以下に落ちた先を当てにくっていうと通常の信用リスクモデルと変わらないので、今回はですね、正常先から要注意先に大きく遷移したのも、予測の対象としているとともに、あるバーよりも下がっちゃったような先、要管理先以下に下がっちゃったような先も当てるといことで、作っています。

○ 研究会委員

はい。なるほど、わかりました。実際に、財務指標、通常使うような財務指標以外に使われたものっていうのは、業種別に勘案されたもののリストがどこかにあったかと思うのですが、これは基本的にほぼマクロ経済指標的なものを使われたと、そういうイメージですか。

○ 事務局

そうですね。汎用モデルについては、財務、BS・PLの情報とマクロの情報ですね。

○ 研究会委員

なるほど、わかりました。理解したと思います。あと、考えられるとすれば、例えば銀行が持っている、他の情報で、まさにチューニングのところというか、独自データを持っているところで、定性的な情報を加味すると当然のことながら精度が上がるといのが、途中で結果に出ていると思うのですけれども、それにもう少し定量的なデータで、銀行が持っているもの、例えば入出金情報であるとか、これまで使い切れていなかったようなものを足していく余地もあるといえはあるとい感じですかね。

○ 事務局

そうですね、まさにご指摘の通りで、その追加的に定性情報を加えて、そういったものを

ここでは共同研究先モデルと呼ばせていただいていますけれども、そういった定性情報を加味すると、精度が上がったのは確認できました。個別の金融機関がお持ちの、まさに入金データとかは、今回は勘案することはできませんでしたが、フューチャーワークとして、まさにそういったものが勘案できるとより精度も上がると思っております。

○ 研究会委員

なるほど、了解いたしました。ありがとうございます。自分たち自身も信用リスク評価モデルを作っている立場としては、多分、データの種類としてもう少し足せるものがあるのだろうなというふうに思う一方で、現段階ではこれで十分ではないかなというふうに思います。ありがとうございます。

○ 研究会委員

結果は、他の委員の先生方もおっしゃっていた通り、結構精度が高く出ているなと思いました。やっぱり KPI なので、今すぐこの場で決めろということはないですけども、ワークを通じて平均を 0.65 とか、ちょっと分かりませんが、平均値とかにおいて KPI を定めたり、0.5 台は出さなかったりとかですね、数字なのでそういう目標を決めて、それに応じてなぜ到達していないかとか、逆算して考えてやるようなやり方も必要なのではなかろうかというのは、結果に関しては思いました。特段実証事業に移るには問題ないと思うのですが、一つ数値目標のようなものを標準として定めて、そこに向かってやられるのがいいのではないかというのは、まず KPI に関する意見でございます。

次に、最初のコンセプトの 2 段階のスクリーニングで、今、普通に、ステップ 1 とステップ 2 で、P9 かな、ベーシックとアドバンストですね。ベーシックについては、通常、銀行さんがやっている中でも気づき得ると思えますけれども、このモデルを使って、銀行さん的には、今気づいていないとか、ごく正常で何も問題ないと思っているという先の中で、このモデルを使ったら、警報が出る先がいくつか出てきていて、それをかけて実際にそうなるかならないかみたいなものをマッチングしていったりしないと、一番のところの本質的な正否みたいなものは判定しにくいと思って、そういうようなやり方も考えた方がいいのではないかと思いました。だんだん悪化してくる先というのは、動的に見極めやすいですし、周囲の業界の評判とかを聞いていると分かたりするのですが、ある月突然悪化したりというのは困るということがあると思うので、ある月に突然落ちたりするものが動的に気づく前に AI で気づけると非常に有益じゃないかと思うので、少しそんなような観点を踏まえながら実証していただけるといいなと思いました。以上でございます。

○ 事務局

最初コメントいただいた数値目標、これを始める前は、そもそも精度なんて出るのかどうか、数値目標を設定するにしても、何か過去やられた研究があるかということと必ずしもそ

うではなかったのですが、実際に数値目標を設定することがなかなか厳しかったということですね。ただ今回、様々な方のご協力によっていろんな数値みたいなものが出せたので、今後はまさにご指摘いただいた KPI について、数値的な目標を掲げてというか、きちんと設定して評価できればなと思っています。実証事業においては、実際こういった共同研究先で数値が出たので、個別の金融機関さんに当てはめたときにどれぐらい AUC いくかどうかみたいなのは検討したいなと思った次第です。

次にマッチングですね。まさにご指摘いただいた通り、実態としてこのモデルのコンセプト 1 とかで下がりそうだというのがあって、実際それが下がりそうだった先が本当に下がったのかどうかみたいなのは確認したほうがいいということだと思います。そこは、もしできたらですが、実証事業先で過去 3 年ぐらいのデータを使って、その 3 年前は業績よかったけれど、その 1 年後悪くなった先みたいなのが実際あると思うので、そういったものをこのモデルを使ってちゃんと捕捉できているか、全部が全部は捕捉ができないと思いますけれども、捕捉ができたかどうかというのは確認できたらなと思っています。その意味でも、KPI は個別の先でもちゃんと捕捉できているかということは掲げていますので、それは実証事業の結果で検証したいと思っています。

最後、突発倒産・突然破産はなかなかこのモデルでも捕捉することが難しい領域であるものの、フューチャーワークとして、徐々に悪化する先の多くはこのモデルで検知できるかと思っていますけれども、突発的に悪くなるような先は当然サンプルとしては相応にありますので、それを逆に捕捉できるようなものはどういう工夫が必要かというのは、こちらも今後の課題として整理したいと思っています。ありがとうございました。

○ 研究会委員

はい、わかりました。よろしく申し上げます。

○ 研究会委員

ありがとうございます。定性情報の有効性がここで確認できたということは、非常に良かったなというふうに感じています。資料の後半の方に、財務で重要な項目ですとかマクロ変数ですとか実際に実証事業に使われるときに表示されるものだと思いますが、ここに有用だった情報も、開発があったモデルの方は入るのだなという認識をしておりますが、そういう認識でよろしかったでしょうか。

○ 事務局

ありがとうございます。ご質問の趣旨としては、汎用的なモデルの中に定性情報が入るかということでしょうか。

○ 研究会委員

そうですね。

○ 事務局

今回の汎用的なモデルを作って、それを他の金融機関さんに、じゃあそこが当てはまるかどうかという、モデルの中には、例えば後継者有無みたいなものが有効だとなったときに、金融機関さんでそれを情報として蓄積できていないとかとなると、他の金融機関さんに当てはめることが難しかったりするので、今回の汎用モデルでは、本当にどの金融機関さんもお持ちの財務情報と、外部のマクロ情報だけを使ったモデルを作っているの、そのモデルを使って他の金融機関さんに適用というふうには考えています。

定性情報は、今回個別にお見せすることは難しいですけど、定性情報が非常に効いているのは、事務局サイドでは確認できているので、場合によっては定性情報も加味したモデルも別途用意して、そういった情報が個別の金融機関さんでも取得できるのであれば、そのモデルをうまく活用いただくということは十分あり得るかなと思っています。なので、今回の調査で汎用モデルに絞って使ってもらえますというよりは、個別の金融機関さんのデータの整備の状況とか、利用シーンの状況とか、データの利用状況等を踏まえて、今回作ったモデルの中でどれが適切かというのは、当然個別の金融機関さんで違うかと思しますので、そこを選んでいただくということかなと思っています。

実証事業で12月以降に個別の金融機関さんのデータに当てはめて、ある程度想定する精度がいくかどうか等の確認は、メインとしてはその汎用モデルで想定していますが、場合によっては個別の定性情報が入手できればそこでも確認できればと思っています。

○ 研究会委員

ありがとうございました、よくわかりました。

○ 事務局

一通りご意見賜りましたが、概ね KPI として達成できていると理解していますし、プロセスなり開発の結果もそんなに問題が無いのかなと思っています。このプロトタイプを使って実証事業に移行するというのも違和感ないというふうにご意見いただいたと理解していますので、こちらを使って12月以降進められればと思っています。

最後に、経営改善支援の有無の教師ラベルの件です。本来であれば、ある財務状況があって経営改善計画を作った先とか、リスクに応じた先とかいろんな経営改善支援をして、その後業績がどうなったかという情報があると、より教師ラベルとしては適切かと思えます。そういったご意見を先ほどいただいたかと思えます。実証事業の協力先の銀行さんで、そういった情報のご提供が可能ですというふうに言っていて、今やりとりさせていただいているので、本当に欲しい教師ラベルを使って、このモデルがどうなるのか、あとは因果推論の技術を使うとどれぐらい有益な結果が出せるのかというのはやりたいと思っています。

そこは今回の共同研究先では取れない、本当に実際の金融機関さんにしかないデータを使って、ちゃんと精緻な教師ラベルを作ったらどれぐらい精度がいくのかどうかというのを確認できればと思っていますので、その結果は最後の研究会でご報告できればと思いますので、よろしくお願いいたします。

あとは今回詳しい説明を割愛しましたが、第 2 回研究会でご意見賜った精度の区間推定や他の精度でどれぐらい汎化性能があるかというクロスバリデーションの話について、信頼区間については、区間推定した中でもある程度精度が高いということが確認できました。また、クロスバリデーションをしても、他のデータに当てはめても大幅に精度が下がるといことがなかったので、ある程度汎化性能の高いモデルができたのかなと思っています。因果推論の結果についても、今こちらにお示ししていますが、サンプルが少なかったので、経営改善支援を実施したら信用スコアとしては 0.5 点ぐらい上がる効果があったという結果ですが、信頼区間で見ると-2 から 3 くらいだったのでかなり幅があると。これはサンプルが非常に少なかったからということです。ただ、この右側にお示した通り、個社単位でこういったところの財務的な要因が寄与して業績改善の効果が見られたかというのが、こういった単位で見られるので、この場合ですとある程度債務の負担が軽減されたり、あとは一人当たりの売上が向上したりとか、そういった要因で 1 年以内の業績の向上が見られたみたいなのがあるので、こういった結果は個別の事業者様なり、金融機関さん内部での検討に使えるのではないかなと考えた次第です。こちらの結果もうまく使って、実際の金融機関のデータをさらにうまく活用して、この因果推論の有効性も精査できればなど考えている次第です。ありがとうございました。

まずはこの議題 1 を通して、他に委員の先生方、コメント等ある方いらっしゃいますでしょうか。

○ 研究会委員

議題 1 の中で 2 点ありまして、一つはこのチューニングのところの話なのですが、私がそもそも思っていたことよりも、だいぶ進んだことをトライされていて、そこは素晴らしいなと思いました。特にこういうドメインにフィットさせる形で汎用モデルを修正した上で、より良い実務的な成果を目指すという方向性は非常にいいなと思いました。

一方で、やっぱり難しい部分も当然あると思います。このあたり、BERT の日本語の言語という金融市場にドメインをフィットさせるという有名なリサーチがありますけれども、技術的にもかなり先進的な話ですし、うまくいくかどうかやってみないと分からないところもあるので、結構チャレンジングなものだというのは、やっぱり認識を共有しておく必要があるのかなと思います。特になぜそういうことを申し上げているかということ、あまりここが、風呂敷を広げすぎないほうがいいのではないかなと思います。先ほどのプレゼンの中で、コンセプト的には小さな銀行さんがあって、そのドメインにフィットさせる形で汎用モデルをチューニングした結果、よくなるというストーリーを描けるわけなのですが、

ただ本当にできるのかどうかというのは、やっぱりケースバイケースでかなり状況は違うと思いますので、そこはもうちょっとケースをできる限り、ぼやかした形でもいいのですけれども、示していただいて、こういうケースであればチューニングの効果がありますよというのを、背後にある理屈を直感とともに示していただくと、より有効に使われるのではないかなというふうに思いました。

それから、セグメントを分けてモデルを開発されるというところが、こっちの最後のポイントであるのですが、これも非常にいいポイントだと思いました。ただ、こここそ腕の見せ所というところがあると思っていて、どういうセグメントに切り分けることで実務的に使いやすくなるのかというあたりは、今後の実証実験の中で、実務家の方々のご意見を踏まえながら得られるところだろうなと思って、私としては非常に関心があるところなので、ぜひそういう結果も今後の研究会の中でフィードバックいただくとありがたいなと思ったところです。

○ 事務局

はい、ありがとうございます。確かに最初のチューニングは、今は当然平均値でとっているんで、徐々に精度が上がるような結果で示していますが、今後実証事業で4つの会社さんですね、信金さん、信組さんも含めた会社さんで、本当にうまくいくのかどうかを確認するので、ご示唆いただいた点はそこで確認できればと思っていますし、よりわかりやすいケース分けができれば、そこも取りまとめればと思っています。

セグメント分けも、今回は挙げられたセグメントですが、今後のフューチャーワークとしてどういうセグメント分けがより実務にヒットするのかは、実証研究で確認できれば確認したいとは思っているものの、そこはフューチャーワーク、今後の検討課題として取りまとめさせていただければと思いますので、コメントありがとうございます。

○ 研究会委員

セグメンテーションのところは、是非業種だけではなくて、例えば規模であるとか、考えていただけるといいのかなというふうに思いますのと、私自身が、例えば本当に自分がこのモデルを触らせていただければ、いろいろやってみたいなというふうに思うことは多々あるのですけれども、その中で多分、実証実験の結果を示していただくときに出てくるのだろうなというふうに思うのですが、そもそも外部的なデータを加えたものの、一体何が効いていて、何が効いていないのか、それをどういうふうに入れ替えていけば精度が上がっていくのかということであるとか、あるいは既存使っている財務情報でも、おそらくこのモデルで効いているものと効いていないものというのは当然あると思いますが、そういったところをウェイト付けすることによって精度を高めていくような考え方があり得るのか、あるいは何かを除くことで、むしろ引き算で除くことで精度が上がる可能性があるのか、みたいなことを自分が手元にやったらきっといろいろ試してみるだろうなというふうに思っ

たので、ぜひともそういったことも実証実験を通じて見せていただけるとありがたいなというふうには思いました。

○ 事務局

ありがとうございます。個別に説明変数のリストがどこでどこが効いているとか、今回は割愛させていただきましたが、個別の実証事業で当てはめたときにどういった変数が効いていったか等をご説明できればと思いますので、ありがとうございます。ただ、今回ご提示した出力のイメージを別紙にもお示ししてしまして、そこは一つのサンプルですが、どういったところが効いていたかとか、どういう外部環境変数が寄与していたかというのは、効いているやつをピックアップしているので、そこを見ていただければ、少ないサンプルですが、ご参考になればと思っています。ありがとうございました。

続きましては、実際にただ今ご議論いただいた AI モデルを使ったものの、実務に生かせないということであれば、モデルを作っただけで終わったら何の意味もないので、実務活用が可能かどうかを主に実務家の方にご意見賜れればと思っています。実際の使い方は冒頭でご説明しましたが、ご意見いただく前に、より理解を深めていただくために、Excel ベースで恐縮ですけれども、デモンストレーションさせていただいて、このような形で利用できるのではないかというのを、数分でご説明できればと思います。冒頭ご説明した通り、スコアが悪い先から昇順で並べて、今、建設業だけピックアップしています。例えば、このリストの中で、企業名とか当然割愛していますけれども、個社名を見ると、金融機関におかれては、この会社か、とか分かるかと思うので、少し気になったら、このリストを叩いていただくとこのように出て、この会社さん建設業だけど、かなり負担が重かったり、利益があまり上がっていないので、こういった財務的な要因がマイナスに寄与してスコアが低いとか、外部環境としては、建設の工事予定額というのがあまり予定されていないので、景気も悪くなったと、業況が 1 年後悪くなりそうだというのが分かったり、あと右下に書いてあるような、同規模同業種の企業が、どういう財務的要因、外部要因で向上したかというのもわかるので、ここはこういったものを使って、会話のヒントにする。あとは当然、金融機関さんがお持ちのこういった財務分析結果があるかと思しますので、レーダーチャートとかを見て、どういったところが弱い、ここはちょっと手元の資金繰りが悪いのではないかとか見て取れますけれど、そういったものでやるということなのかなと思います。

あとは、いい例です。いい例ですと逆にスコアがすごく良くなりましたということで、先ほどマイナスに振れていたのがプラスに振れるようになったのが見て取れるかと。ここは利益がよく上がっていたり、あとは外部環境として人口が減っているものの足元の有効求人倍率とか、発電実績、ここは足元のマクロ的な経済の活動が活性しているということでもよく出ていたりというのが分かたり、財務要因もこのように業種平均と比べて、ここが当該企業のレーダーチャートですけれども、こういう要因で良いのだという形で会話のきっかけになればと思っています次第です。少し簡単ですけど、デモンストレーションさせていた

できました。あくまでもこちらは例示で、個別に金融機関さんが最終的には設計してやりませんが、ここで並んでいるようなものを使えば、こういった業務への活用、ここで想定しているような新しい業務フローが実現できるのではないかなと事務局サイドでは考えている次第です。今の説明をお聞きいただいて、他の方から何かここはこうした方がいいのではないかなとか、これは納得的だとか、ご意見ある方、ご発言いただいてもよろしいでしょうか。

○ 研究会委員

はい、いまご説明いただいて特に違和感はないです。ただ、帳票の出力イメージですけれども、外部環境データを出力帳票に出して具体的に納得感があるというのは、業種に関連するような外部環境データであれば、出力しても使えるのかなという印象があります。例えば宿泊業で言えば、訪日外国人数とか客室稼働率とか、そういったものって最終的には財務要因の方に、分析してブレイクダウンできますので、そのことに関しては出力するという意味があるかなと、一方で GDP 成長率だとか、発電電力量だとか、エネルギー消費量ってあまりにもファンダメンタルすぎて、モデルの変数に組み込むこと自体は理解できるのですが、アウトプットすることに何か意味があるのかなというのは、若干、疑問に思ったところでは。

○ 事務局

ありがとうございます。まさに貴重なご意見ありがとうございます。全体を、違和感ないということですが、こういった出力の工夫はおっしゃっていただいた通り宿泊業ですと、今ご提示しておりますけれど、分かりやすいですが、例えばこういう卸売業で提示している第3次活動指数とかはものすごくファンダメンタルなので、あまり事業者様との会話のヒントになりにくいというようなご意見かと思うので、ここは確かに本当に固有に関係のあるようなものを提示すべきということは調査結果としても取りまとめたいと思います。ありがとうございました。

○ 研究会委員

先ほどの委員の方もご発言有ったのですが、スコアを出す以上、財務要因とマクロ変数それぞれが、点数に寄与したウェイトを出すことができますか。

○ 事務局

そうですね、はい、出すことはできます。ここで今、卸売業を出していますが、少し分かりにくく恐縮ですが、寄与度と書いていて、この企業ですと利益がすごく減ったのが、経常利益前年比が寄与度マイナス 15 になっていますので、そのぐらい寄与しているということですね、100 点満点中。一方、この外部環境ですと、エネルギー消費量で非常にファンダメンタルなものですが、マイナス 1 点ぐらい、そういうような寄与の程度がわかる

ものは出すことは可能です。なので、実際はそういうどれぐらいインパクトがあったか、外部と財務を見ていただいて、なのかなと思った次第です。

○ 研究会委員

寄与した財務指標ってこんなに少なくないですよ。

○ 事務局

ここはですね、寄与した代表的な3つピックアップしてですね、実際には何百個も作っているんで、一覧で見た方がいいのはおっしゃる通りです。

○ 研究会委員

はい、ありがとうございます。

○ 研究会委員

私も、今の説明を聞いて、全体的なイメージはつかめました。ありがとうございます。P20の一覧表を実際の実務で使う上では、各企業の売上高であるとか、預貸金の残高、格付査定情報、保全の状況を見ながら使っていますので、そのような情報があるとより使いやすいのかなと思いました。

○ 事務局

ありがとうございました。今回はメインとして、このAIの出力結果をどう実務的に活用いただくか、なので、そういった情報をつけていないものの、実際にこういうものをヒントに各金融機関さんで応用するときには、すでに一覧表を出して管理されているその情報も付記してやるといいのかなと思いますので、ありがとうございます。これだけを見てやるのですよ、みたいな形にちょっと伝わってしまったかなと思うので、そこは誤解がないように、報告書でも取りまとめられたらと思っています。貴重なご意見ありがとうございます。

○ 研究会委員

また、このシミュレーションのシナリオの欄は大変面白いなと思いました。事例では原油価格や為替レートの記載がありますが、その時々によって、シナリオの内容が変わると思いますが、金融機関側で任意に変更できるイメージがつかなかったんで、どうやって我々の方で運用して使っていくのかご教示いただければ幸いです。

○ 事務局

ありがとうございます。1個モデルができると、今お示ししているものがありますけれども、今は為替とか訪日外国人客数とかそういったところで、1年、2年経つと為替じゃなく

て株なのか地価なのか少し分からないですが、そういった要因が変わるので、その時々に応じてどういったマクロの要因と影響があるかを手元で見たいということだと思います。それにつきましてはこういったシミュレーション、外部環境が変わるとスコアが悪化するかみたいなことは算定できますので、きちんとすぐ算定できるようにさきほどデモンストレーションしたシートを作る必要がありますが、そこは技術的には容易ですので、そういったものでスコアがどう変わるかというのを横につけるといいのかなと思った次第です。

○ 研究会委員

ありがとうございます。

○ 研究会委員

サンプルの方も見させていただいて、前回から随分改善されているということについて本当に感謝しています。また、モデルの精度が高いということについても、先ほど先生方から色々お話がありましたけれども、非常に驚いているところでございます。今回、どのような結果が出るかということは今から楽しみにしておりますが、また先行きに向けては、出た結果をどう活用するかというところがむしろこれからの課題なのかなということも思っております。やはり出た結果を取引先に対してどういうふうに対話資料として活用していくかということが、これからいろいろ課題を送り出していかなくちゃいけないのかなと。

例えば職員のレベルアップも必要でしょうし、またどうやって取引先に出た結果を理解してもらうか、そういった意味では要因分析のいろんな財務指標なり、こういった結果に至った要因の簡単な解説書みたいなものがあると、取引先に資料を渡した後も十分読んでもらえる、そういったところになる。なかなかこの指標を見てすぐに納得してもらえる先はそうそう多くはないので、その辺の細かい努力が必要なのかなと思っております。

ご質問になりますけれども、サンプルということだと思いますけれども、表示される指標というのがある程度、金融機関側で相手に応じて選択し、結果のところに表示するというのは可能でしょうか。

○ 事務局

はい、ご意見ありがとうございます。そうですね、その出力結果の活用の設計次第で、金融機関様、あとはお見せする事業者様に合わせて仕様を選ぶことは可能です。先ほどデモンストレーションでご提示しましたが、こちらはちょっと固定ですが、財務については見たい財務項目に変えることも可能ですので、この企業はこういったところの情報をお伝えするとちゃんと真摯に考えていただくとかですね、そういったことの工夫は十分できる次第です。このAIの出力の結果については、固定な形でご提示して、企業によって結果が変わるだけというふうにはなっていますけれども、そちらについても技術的には全然です。財務指標にいくつも候補があったりするので、そこは技術的には可能です。

○ 研究会委員

はい、ありがとうございます。私の方からは以上でございます。

○ 事務局

ありがとうございました。確かに最終的には取引先様への対話、そこにはいかないという意味がないかと思っておりますので、今事務局サイドで先ほどの資料にあります通り、簡単な絵でサンプルをお示したかと思っておりますが、ここもワークショップ等で実際の本部の方、場合によっては現場の担当者の方にもご意見いただいて、どういったものがあるとうまく事業者様との対話につながるかというのはまとめられる範囲でまとめていければと思っています。ありがとうございます。

あとは実際に使うときはそうですね、解説書は必要かと思っておりますので、ありがとうございます。

○ 研究会委員

ご説明ありがとうございました。前回の意見を踏まえ、いろいろ反映されているのかなというふうにお見受けして聞いておりました。今、他の金融機関様からも意見としてもありましたが、P21 のところで出力結果のイメージということで出ておまして、今のところは固定で3つ指標が出てくるといような形であったかと思っております。それ以外にどういったものが使えるのかというところで、候補を選べたりする、ここに出てくるものを選べたりするとより良いのかなと私自身も非常に思ったところでございます。やはり銀行の担当者含め、気になっている外部環境の指標というのは当然あるかと思っておりますので、そこで選べるようになると非常に資料としての有効性も高まるのかなと思ったところでございます。当然、銀行さんにしても企業さんにしても気になる指標というのがあるかと思っておりますので、それが反映されるといいのかなというところでございました。

○ 事務局

はい、ありがとうございました。貴重なご意見かと思っておりますので、実際に金融機関さんでは、先ほど Excel でデモしましたけれども、あれをもう少し精緻化したものを使って、我々が想定しているようなこういった業務が実現できそうかというのを確認する予定ですので、いただいたご意見を踏まえて、実際に使っていただく我々手元のツールも改善できればと思っていますので、ありがとうございます。

○ 研究会委員

あともう一点、前半のところでも話がありましたが、どの定性情報が結果に大きな影響を与えているのかということが表に出てくると、やはりそういった情報をしっかり組み入れ

てやるということが非常に重要になってくるのかなと思いますので、そのあたりも今後のところで出てくると非常に良いのかなと思った次第でございます。以上でございます。

○ 事務局

ありがとうございました。今回いくつもモデルを作っているのですが、そのモデルごと財務、外部環境要因、定性要因、どういふ変数が効いているかのお手元にありますので、ここはデータを提供いただいた会社様とのご相談ですけれど、どの変数が効いていたかみたいな情報は第4回の研究会で可能な範囲でご提示できればと思っています。ありがとうございました。

○ 研究会委員

はい、ぜひよろしくお願ひしたいと思います。失礼いたします。

○ 事務局

ありがとうございます。その点については、ぜひ報告書でも可能な範囲でお示しできればと思っていますので、ありがとうございました。

○ 研究会委員

ご説明ありがとうございます。私の方は、P20の結果イメージの一覧なのですが、現在の想定としては、我々が今基準としている経営改善すべき先の選定基準に加えて、この経営改善支援スコアの要素を取り込めれば、より前の段階で経営改善支援をすべき先の選定が幅広にできると思っていますので、そういう面で非常に活用できるのかなというイメージを持っています。

それから、実際の結果イメージのP21の表について、これはいろいろと工夫する必要があるのかもしれませんが、私個人の印象としては、外部環境に関する表が割合的には多いのかなと思っけてまして、実務としてはどうしても財務の方にスポットを当てるケースが多くなって、検証するにしても財務の方を見るケースが多いので、紙面構成上の問題かもしれませんが、もう少し財務の方の割合を多くした方がよりいいのかなと、実務の面から申し上げると、そういう印象を受けています。

加えまして、P23の、これはまだイメージの段階なのですが、同じようにお取引先に何か示すようなペーパーを作る際には、財務諸表のところを少し強調した方がいいのかなと思っけておりまして、外部指標のところをあまり強調しすぎると、お取引先単独では如何ともし難いので、そこから議論が進まなくなってしまう可能性もあるので、どちらかというところでは財務諸表で、こういうところを直せば、というところで、それを直すにはどうしたらいいかというのをディスカッションできるようなペーパーがより望ましいのではないかなという印象を受けています。以上でございます。

○ 事務局

そうですね。今回の調査研究では財務だけじゃなくて外部環境も使うというのが最初に掲げたのもあって、財務と外部環境、同じような紙面構成、場合によっては外部環境の方が多構成になっていたかと思いますが、ご指摘いただいた通り、聞いている会社様においては、外部環境は自分らではどうしようもないところはあるかと思いますが、より財務的な要因が全面に出るような形で、外部環境は補足的な位置づけではあるかと思いますが、そこは確かに実際のこの帳票のブラッシュアップに活用させていただければと思います。ありがとうございました。

あとは、様々な基準で一覧化しているというところに、このスコアは使えそうだとということでコメントいただいたと思います。実際にこのスコア、当然改善すべき点はあるかと思いますがけれども、この結果を使ったり、その結果を使って新たな業務を回したりということは、当然工夫は必要ですが、可能そうか、今の印象をお伺いさせていただいてもよろしいでしょうか。

○ 研究会委員

可能だと思います。

○ 事務局

わかりました。いまは机上で大丈夫だろうということかと思いますが。実証事業で、より実務で使えるか、うまくこういったものを使った業務フローは実現できそうか、を確認できればと思いますので、よろしく願いいたします。

○ 研究会委員

全体としては、概ね今までの意向が反映されてきているのかなということで、違和感はないと思っています。支援先の選定という意味では、スコアで設定するというのは非常に効率的だと思うのですが、そのスコアをどういう閾値というか設定するかということは、今後考えていかなければならないかなと思っています。

あと、資金繰りについて、目に見えて資金繰りが逼迫している先というのは当然ながら、そのスコアに限らず優先順位というのは高くなると思いますが、我々が気づかない段階でその資金繰りの急速な悪化というか、いわゆる突発倒産のリスクみたいなものを今回どこまでスコアで拾えているかなというところが気になります。

あと出力結果は P22 のところについて、いろいろお話出ていたと思うのですが、単純にその変数だけ、財務の数値だけそのまま伝えてもおそらく経営者には響かないと思います。なので、そこで業種別支援の着眼点みたいなものを活用して、財務数値を分解してどこの課題から取り組んでいくかということですね。ここはまさに AI だけに頼るのではなくて、

その対話を通じて説明資料に落とし込むなど、人がやらなければならないところという意味合いなのかなということを受け止めさせていただきました。

外部環境について、スコアの要因とか外部環境変数などを見せるということは非常にいいことだと思いますし、それらをシミュレーションに含めた対話というのは非常に有効だと思います。以上でございます。

○ 事務局

最初もご説明いただいた、実際運用するときの閾値ですが、そこは各金融機関さんのお考えかなと思っています。本日はご説明しませんでした、モデルから出てきた結果ですね、例えば参考資料の開発モデルの評価を見ていただくとちょっとわかりにくいかもしれませんが、こちら横軸にまさに先ほどお示したスコアですね、1点満点になっていますけど、これ100倍していただければ100点満点です。縦軸が割合なのですが、この緑の曲線、precisionということで適合率と言われるもので、経営改善支援が必要として抽出された先が、実際に経営改善が必要な先であった割合ですけれども、例えば閾値を80点としましたという、この適合率では40%なので、要は100社抽出したうち本当な経営改善が必要な先は40社というふうに捉えていただければと思います。なので、閾値を上げれば上げるほど、経営改善が必要な先をピンポイントであてることのできるとも濃いリストになるということですね。例えば、閾値を上げると、6、7割含まれていると、100社抽出したうち本当な経営改善が必要な先が60社ぐらい含まれているということなんです。

一方、この薄いちょっと青っぽい曲線が、recallということで再現率と言われるもので、経営改善先全体のうちどの程度経営改善先を抽出できたかという割合ですが、当然閾値を絞ると、本当に経営改善支援が必要な先が100社ありましたが、そのうち補足できているのが10%弱ということですね。このように閾値が限定されると、当然濃いリストになるので、そのリストに含まれている先は当然経営改善支援が必要な先が含まれますが、濃度を濃くすればするほどですね、例えばここをリスト化しますといったときに、じゃあ全体で経営改善支援が必要な先は1割弱しか入っていませんということになるかと思うので、ここはトレードオフになるかと思います。なので、我々はやはりある程度救いたいのので広めに閾値を設定して、5割以上の先、経営改善支援が必要な先の5割ぐらいは捕捉しつつ、そうするとそのリスト内では100社中10社ぐらいしか入っていないという密度の薄いリストになる。一方で、効率的に運営したり、多少の漏れはあるけれども確実に本当に業績が思わしくない先を着実に救ったりしたいというのであればある程度閾値をきつくして、ある程度スコアが悪い先を注力するみたいな、金融機関の考えに応じて、閾値を設定するというようになってくるのかなと思った次第です。答えがあるものではないので、こちらは各金融機関さんのリスクアペタイトという表現が適切かあれですが、それに依って閾値設定をご検討されるということなのかなと思っている次第です。ちょっと補足させていただきました。

あとご指摘いただいた通り、資金繰りが主になっての突発倒産ですね。そちらはどれだけ

捕捉できているかは事務局サイドでも確認はできておらず、突発的に倒産したかどうかの情報も限られているので、そこはフューチャーワークとして、今後の課題としてそういったことが検討できればなと思っています。ありがとうございました。

○ 研究会委員

ありがとうございます。前々回でしたか、会議で、ちょっとマラソンのゴールの直前で転んじゃったのではないかと大変失礼な発言をしてしまったのですが、逆に、今日の専門家の先生方のご評価であるとか、ユーザーである金融機関の皆様方のご意見を拝聴していると、過日のワールドカップのドイツ対日本戦を見ているかのような素晴らしい逆転劇だったなというそんな感想を持っておりまして、本当に事務局をはじめ関わられている皆様方のご助力がいかばかりだったかということに本当に敬意を表する次第でございます。

それで、議論は尽くされているかなというところはあるのですが、現場レベルとしましては、やはりこれをいかに使っていただけるかというところのフェーズに入っていくだろうと思っております。私も先日、特定の金融機関さんのことだとは思っておりますけれども、中古自動車販売業のお客様からですね、ご相談ありまして、なんだろうと思ってお聞きしてみたら、実は非常に資金繰りの苦しい状況なのだけれども、全くその金融機関さんの方から何をどうした方がいいとかですね、アドバイスがないと。社長にお聞きしたらですね、車を売っている場合ではなくて、僕はもう四六時中資金繰りのことしか考えていないのだと、誰か助けてくれみたいな状況だという話だったのですが、それは金融機関さんにご相談したらいいのではないですかという話をしたのですが、相談していいものなのか、ときたまものですから、いやいやという話をさせていただいたのですが、やはり借りている企業の、特に小規模あるいは中小規模の事業者さんというのは怖くてちょっとやっぱり言い出せないということで、逡巡されておられるという方もおそらく多くいらっしゃるのだと思います。ちょっと私は今回の研究がそういったところにスポットを当てていただきましてですね、金融機関の側から声をかけていただく、あるいは税理士であるとか中小企業診断士であるとか周りの専門家を巻き込んでいただくと、こういったところにつながっていただくというところが大成功なのかなというふうに、個人的には感じているところでございます。

前回、ぜひ行員のケツが浮くような、そんな実務的なご発言がありましたけれども、まさに少しそのところを後押ししていただけるようなこと、ここが今後起きていけば非常にいいだろうと思っておりますので、ぜひこんな形でまとめていただければありがたいかと思っております。以上でございます。

○ 事務局

まさにそうですね、最終的には使っていただいたり、本当にその金融機関の行職員が会話

のきっかけ、あとは経営者の方にこういった活動を通じた、先ほど資料上でご提示したようなものを見ることによって、言い出しにくいことも言えたりとかですね、やはり密なコミュニケーションができるということが大事かと思imasるので、そういった会話につなげられるようなものにつなげていければと思っています。

どこまで実証事業とワークショップでできるかあれですけど、まあ完璧にはやはりできないかなと思いますけれども、最終的にはこの取り組みを通じて、あとフューチャーワークもなるべく打ち取るような形で継続的にやってですね、今ご示唆いただいたところが本当に実現できるようなものになればと思っていますので、先生におかれては引き続きアドバイスいただければと思いますので、ありがとうございます。

実証事業の結果は、4回目の研究会は2月末あたりを予定しているので、その結果もご報告しますので、改めてその結果を踏まえてですね、ご意見賜ればと思います、ありがとうございます。

一旦実務家の方からは全員のご意見を頂戴できたのかなと思っています。全体通じて、あとはAIの専門家なり、学識経験者様なりですね、このAIの活用について何かご意見、コメント等ある方いれば是非とは思っていますが、いかがでしょうか。

○ 研究会委員

実務的な活用については、委員の先生方からのお話を踏まえて着々と進められるということだと思いました。もう少し先を見据えたときにどのようなやや超越的な角度からフューチャーワークがあり得るかという点で2点コメントしたいと思います。

一つは、例えば外部環境について個別の会社さんはどうしようもないという議論もあって、まったくおっしゃる通りだと思うのですが、裏を返すと個別の財務指標に関してもどうしようもないところもあるかもしれない訳です。その意味で今回の素材を使ったときにある種の勝ち筋というか、どういうことならば制約条件の中で対応していけるのかということが将来的には見出されるべきなのだろうなと思っています。すでに素材はあると思っ
ていまして、すなわちそのどういうときに将来先行きが悪くなりそうかというところと、その後どこに手を打てば復活できそうかという情報がシステムから出てくるわけですので、その中で実務的な観点から一筆書きでシナリオになり得るものって何だろうというのを見出すべきところだと思います。今回の実証事業の中ではひとまず実務家の先生方のある意味専門的な知識を活用して脳内でそうしたシナリオを見出すということになるのだろうと思うのですが、将来的にもそういう人間が関与する余地は大分残ると思いますけれども、基本的な勝ち筋のある種の最適化の下でシステムから出力結果を取り出すということが展望されてもいいのかなと思います。それがある程度システムティックにできていれば、基本的なところについて手を打つというのがある意味自動的にサジェストされますのでそういうものがあってもいいのではないというのが、これはもちろん今回の事業でなく将来的な課題ですが、展望されるべきかなと思います。

もう一つは、これも先ほどの外部環境の話に関係するのですけれども、例えば金融庁さんの側から見た場合であるとか政府部門から見た場合は、もうちょっと大きな視点で物事を見るための道具としても使えるのだらうなと思います。その場合、為替なり金利なりの見通しをインプットしたときに全体としてどういったことが起こるのかというのをシミュレートする道具にも使えると思うので、そういう使い方も展望されるべきだらうと思います。その際、もちろんデータをどうするのだという話になるわけですが、データの整備がこれから進むことによって、実務的な使い方とは全く違いますけれども、全数に対してこのモデルを自動で回しておいて裏側でスコアを計算するということが政府部門としてできることの一つだと思いますので、現状ではSFチックに聞こえるかもしれませんが、割と近い将来に実現可能なものとして有効な利用方法ではなかろうかと思いました。

○ 事務局

最初にご示唆いただいた、今はAIのスコアとかその要因ということで、その結果を踏まえて人間がどういったところが、勝ち筋というコメントいただきましたけれども、業績が向上するポイントはどういうところにありそうかというのを考えないといけないとは思いますが、技術的に、いろんな技術がディープラーニングを中心にありますので、そういった勝ち筋みたいなもののヒントが出せるようなことは、今後の課題として報告書でも触れていければと思います。

あとは、確かに今回、金融庁だけではなく経済産業省や内閣官房デジタル田園都市国家構想の方々もご参加頂いているので、まさに我が国としてデジタル技術を活用して、以下に成長するかとか、国全体としてのDXという表現が適切かわからないですけれども、そういったことの一つの取組の一環の一個がこの調査研究家としますので、そういった方々オブザーバーで参加いただいているので、今先生がおっしゃったものをヒントにいろんな有意義な取り組みをしていただければと思った次第です。

その他、コメント、感想でもいいですけれども全体通して何かありますでしょうか。

○ 研究会委員

よろしいですか。ごく簡単に確認させてください。まず、AIツールに入れるデータは基本的に正確であるという前提において構成されているのでしたっけ。何が言いたいかというと、粉飾とかがあってもそれは別の話でそれは別に見極めないといけないのか、そういうものも場合によってはある形で捕捉し得るのか、確認として教えていただきたいと思いません。

○ 事務局

ありがとうございます。基礎的なデータクレンジング、例えばBS・PLの右左が合っていないとか、PLの粗利引いたら粗利益になるとか、そういうロジックチェックですとか、大

事な指標が欠損になっているとかクレンジングはしています。ただ、そういう基礎的なクレンジングした上でも実は粉飾だったということは今回なかなか取り除けていないというのが実態です。さはさりながら、それが十分かどうかはわかりませんが、粉飾自体もある程度スクリーニングする取り組みはあるかと思うので、場合によっては実際に活用される際は、そういったものを経たデータを使うというのが、ご指摘の通り前提かと思いますが、基本的なデータクレンジングは、使うときには作る必要があるかと思います。

○ 研究会委員

2点ありまして、1点目はコメントに近いですがP18のセグメンテーション、今後フューチャーワークとして精度を上げる際に、ここだと宿泊業、飲食サービス業とか苦手なところがどうしてあったのか、それに対してデータをただ単に足せばいいのか、それともモデルを複雑にすればいいのかというところで、何が精度を下げていたのかという追加分析とそれに対する対応ということで、フューチャーワークにつなげればいいのかと思うのが1点目でございます。

2点目は、P20、アプリケーションについて、先ほどのお話の中でシミュレーション1、2とあって、外部の影響というのはなかなか見られると良いのだけれどもコントロールしづらいというお話もありましたが、ジャストアイデアで、例えば銀行のストレステストみたいな形で、例えば気候変動の規制が変わったことによってこういった企業の財務のどういうところに影響があって、という形でいくつかあり得るシナリオを決めていただきまして、それがどの外部変数に影響を与えるかというところは人で与えて、それに対する各企業様の反応をこれで見えていくというストーリーに基づいた形でアプリケーション考えていくといいのかなと思いました。以上です。

○ 事務局

本日も何人かの委員の先生方からどういう要因が悪くて、どういう要因が効いているかが見えないとご示唆いただきましたので、実際にお使いいただくときは、この冒頭の宿泊飲食のどういったところが効いていてですとか、うまくいかなかった点、苦手な部分というのはフューチャーワークとして取りまとめたいと思います。業種によって、うまく当てられているもの、当てられていないものというのは、今回の調査で分かりましたので、どういう要因でうまく上がっていないのかですとか、逆に効いている指標も含めてですけれど今後の課題として取りまとめたいと思います。

2点目おっしゃっていただいたシナリオ分析、今はこの出力のイメージで断片的に原油価格がこうだとかあると思います。他の外部環境がそのまま、原油価格だけ20%とかはあり得ないかと思うので、先生にご指摘いただいた通り、より現実的な外部環境の変化等も踏まえたシナリオに応じて財務の影響等、そういったシナリオ分析ができるものというのは実現すると非常に有益かなと思っています。ありがとうございます。

その他ありますでしょうか。よろしいですかね、ありがとうございます。本日は色々と忌憚のないご意見いただきまして、全体を通じてモデルの開発プロセスとかこれを使った事業事業への意向というのは違和感ないということですし、実際のモデルは実務に活用して初めて意味が出せたと思いますけれども、そちらについても全体的な方向性として、いくつか課題はいただいたので打ち取る必要はありますけれども、その違和感ないということなので、より実務でいかに使えるかは実証事業、ワークショップで確認できればと思います。

最後、何度も頭出しさせていただきましたが、金融機関での実証事業・ワークショップを簡単にまとめていて、こちらにご協力いただいている金融機関さんとしては、横浜銀行様、栃木銀行様、浜松いわた信用金庫様、大東京信用組合様ということで、今回の研究会にもご参加頂いている機関ですが、この4つの機関で実証事業を確認できればと思っています。事業としては、まさに使ったAIモデルが有効かとか、一部の銀行様では教師ラベルがより精緻なものを使って、そういった高度化が活用可能かというのを、まずこの4つの金融機関様のデータを使って確認できればと思っています。

それも踏まえて、最後、2月になろうかと思いますが、ワークショップを開いて現場の方の本当に使えるのかとかですね、今回の研究会でも出力帳票としてこういう情報が必要だとかというのはご示唆いただきましたので、それも踏まえたうえで、再度、本当に実務を担当されている方に意見をいただいて、実際の業務上の課題などを整理できればと思っていますので、何卒よろしくお願いいたします。こちらについては最後の研究会で結果ご報告できるかと思っていますのでよろしくお願いいたします。

(以上)

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 【第4回研究会資料】

2023年2月24日
有限責任 あずさ監査法人
委託元：金融庁

注：本報告書は、金融庁の委託により有限責任 あずさ監査法人が実施した調査結果を取りまとめたものである。有限責任 あずさ監査法人は、調査時点で入手した情報に基づき本報告書を適時に取りまとめるよう努めているが、本調査報告書の内容は、本調査の対象に含まれない特定の個人や組織が置かれている状況に対応するものとは限らず、また、情報を受け取った時点及びそれ以降において、その情報の正確性や完全性を保証するものではない。また、本報告書は委託者である金融庁に対してのみ提出したものであり、本報告書を閲覧あるいは本報告書のコピーを入手閲覧した第三者の本報告書の利用に対して、有限責任 あずさ監査法人は直接ないしは間接の責任を負うものではない。

Contents

	Page
1 スケジュール、本研究会の議題等	3
2 実証事業の結果概要	6
3 ワークショップの結果概要	20
4 本調査・研究の総括と今後の課題	28
5 添付資料	31



1 スケジュール、本研究会の議題等

2 実証事業の結果概要

3 ワークショップの結果概要

4 本調査・研究の総括と今後の課題

5 添付資料

本調査・研究のスケジュール

■ 本調査・研究の全体スケジュールと主なタスク内容は以下のとおり。

	2022年									2023年		
	4月	5月	6月	7月	8月	9月	10月	11月	12月	1月	2月	3月
研究会 ワークショップ				▼ 研究会(1回目)		▼ 研究会(2回目)		研究会(3回目) ▼		ワークショップ(1回目) ▼ ワークショップ(2回目) ▼ ワークショップ(3回目) ▼ ワークショップ(4回目) ▼		最終報告書▼ 研究会(4回目)
①経営改善等に 活用可能なデータ にかかる調査	①-1：現状の経営改善支援業務 の整理と課題抽出		①-2：データの調査・取得とデータクレンジング									
②AI技術の活用 可能性にかかる 研究			②-1：AI 技術を活用したプロ トタイプ の要件定義	②-2：AI技術を活用したプロトタイプの開発			②-3：AI技術を用いた新たな業務フローの基礎 検討			②-4：実用化に向けたUIの基礎検討		
③金融機関による 実証事業							③：金融機関による実証事業					
④金融機関等向け ワークショップ										④：ワー クショップ の開催		

研究会における予定議題

- 本日の研究会の議題、今後の研究会にて予定している議題は以下のとおり。

開催回	開催時期	議題（予定）
第1回	2022年7月1日（終了）	<ul style="list-style-type: none">■ 現行の経営改善支援業務の理解■ プロトタイプAI開発のコンセプトについて■ プロトタイプAI開発に用いるデータについて
第2回	2022年9月2日（終了）	<ul style="list-style-type: none">■ KPIの設定・モデル開発計画について■ モデル開発用データ整備とモデルの評価指標について■ AIからの出力結果の実務活用について
第3回	2022年11月25日（終了）	<ul style="list-style-type: none">■ プロトタイプAIの開発結果等■ AIからの出力結果の実務活用について■ 金融機関による実証事業・ワークショップについて
第4回 （今回）	2023年2月24日（本日）	<ul style="list-style-type: none">■ 実証事業の結果概要（実際の金融機関データを用いた検証結果）■ ワークショップの結果概要■ 本調査・研究の総括と今後の課題



1 スケジュール、本研究会の議題等

2 実証事業の結果概要

3 ワークショップの結果概要

4 本調査・研究の総括と今後の課題

5 添付資料

本調査・研究のKPIの設定

– 第2回研究会資料の再掲

- 本調査・研究のKPIは、以下の2つの観点で設定する。
 - ① 現行の経営改善支援実務では活用していない情報により、これまで捕捉することのできなかった経営改善支援候補先が特定できること。
 - ② 抽出された経営改善支援候補先に対する職員による精査が、現行業務と比べて削減されるような高い精度を持つこと。
- 共同研究先データを使用したモデル開発と、金融機関による実証事業における、具体的な評価方法は以下のとおりとする。

観点	評価方法	
	共同研究先データを使用したモデル開発	金融機関による実証事業
①	<ul style="list-style-type: none"> • 現行の信用リスクモデル※1では活用していないデータ（外部環境データや定性データ等）を分析に活用出来ているか。 • 現行の経営改善支援業務では捕捉できていなかったような経営状態（足元では正常先等）の企業を分析対象に出来ているか。 	<ul style="list-style-type: none"> • 開発したモデルに、実証事業に参加する金融機関における従来のモデルでは経営改善支援の対象でなかった企業のデータを当てはめて特定された企業の中に、実際に突発的に業績が悪化した先や経営改善支援を実施した先が含まれているか。
②	<ul style="list-style-type: none"> • 汎用モデルと共同研究先モデルのテスト用データにおける精度が、財務のみモデルの精度よりも高いか。 • 開発したモデルにテスト用データを当てはめて出力したスコアの悪い上位企業に、経営改善支援が必要な先（実際に業況が悪化した先）の多くが含まれるか。 	<ul style="list-style-type: none"> • 開発したモデルに、実証事業に参加する金融機関における企業のデータを当てはめて特定された企業の中に、実際に突発的に業績が悪化した先、経営改善支援を実施した先の多くが含まれているなど、相応の精度があるか。

※1 現行の信用リスクモデルは、多くは企業財務及び企業属性のみ勘案していることが多い。定性情報や外部環境情報はモデルによる定量評価後の定性評価により勘案している。本調査・研究ではモデルそのもののに外部環境や定性データ等を加味することを想定している。

AIモデル（プロトタイプ）の開発コンセプト [1/2]

– 第1回研究会資料の再掲

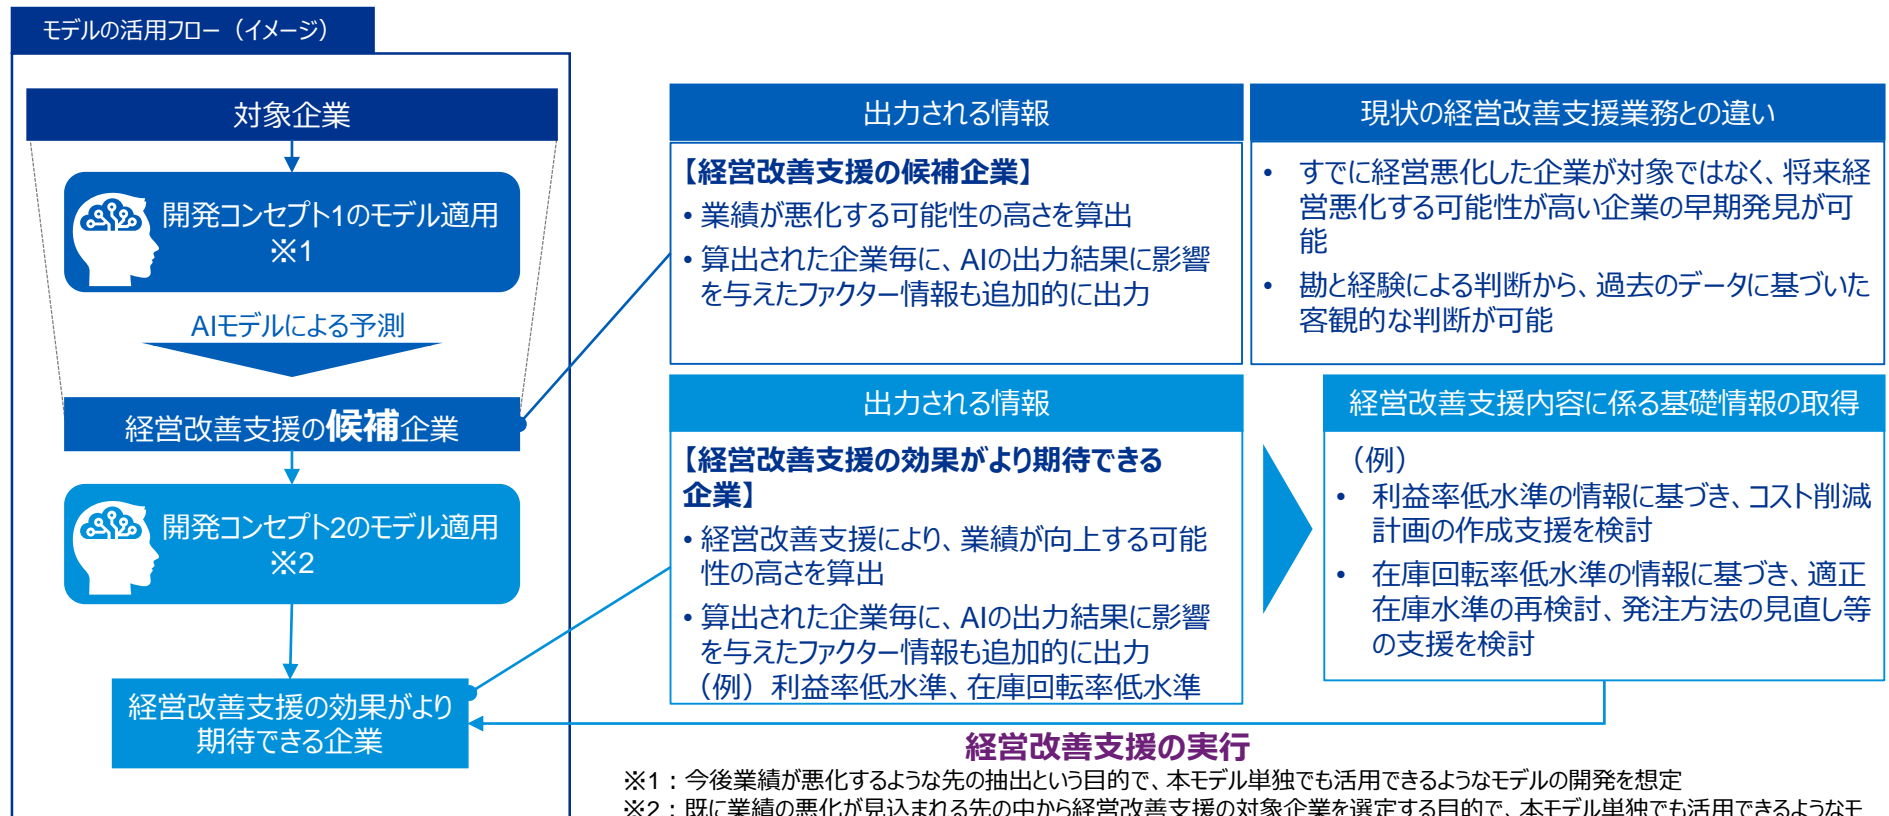
- 本調査・研究にて開発するAIモデル（プロトタイプ）の目的は、「経営改善支援が必要な先の特定（早期発見）」である。
- 本目的を達成し得るAIモデルの開発コンセプトととして、2つの方法が想定されるため、下表にて整理した。
- 本調査・研究では下表の2つの開発コンセプトを満たすAIモデルの開発（まずはBasicモデルに着手）を検討していきたい。

#	開発コンセプト	モデル構築の母集団		構築したモデルを当てはめる企業
		学習データの対象	モデルによって検知する事象	
1	<p>【Basic】業績低下の可能性が高い企業の特定</p> <p>現在の業績は悪くはない企業が、一定期間経過後に業績が悪化するような先を特定するモデル</p>	一定期間内において業績が悪くはない企業	一定期間経過後に、業績が低下する企業	学習データの対象となる企業（ただし時点が学習データより新しい等により学習データには含まれない企業）
2	<p>【Advanced】経営改善支援により業績が向上する企業の特定</p> <p>現在、経営改善支援の対象となりえる企業が、その後実際に経営改善支援を受けたことで業績が向上するような先を特定するモデル</p>	一定期間内において経営改善支援の候補となりえる業況にある企業（ただし経営改善支援は受けておらず、またデフォルト状態にもなっていない企業）	一定期間経過後、実際に経営改善支援を受けて、業績が向上した企業	同上

AIモデル（プロトタイプ）の開発コンセプト [2/2]

– 第1回研究会資料の再掲

- 開発コンセプト1と開発コンセプト2を経営改善支援業務に活用した場合のフローイメージは左下のとおり。
- 開発コンセプト1によって「経営改善支援が必要な先の特定（早期発見）」、開発コンセプト2によって「経営改善支援の効果がより期待できる企業の特定」と、「経営改善支援内容に係る基礎情報の取得」が可能となるよう検討を進める。



実証事業の概要

- 本調査・研究では、財務データや外部環境データ等を用いて経営改善支援先を早期発見するAIモデルの開発を行った。この**モデルをより実効性の高いものとする**ため、金融機関の実データを用いて以下について検証を行った。
 - ① 開発したAIモデルが金融機関の実データにおいても有効に機能するかの検証
 - ② 金融機関の実データを活用したモデルの個別カスタマイズ・高度化可能性の検証
- 実証事業先：横浜銀行、栃木銀行、浜松いわた信用金庫、大東京信用組合
- 具体的な実施内容は下表のとおり。

検証内容	詳細
① 開発したAIモデルの有効性の検証	■ 汎用モデルの精度検証（AUC、適合率と再現率等）
	■ 汎用モデルの解釈性の確認（予測結果に寄与した変数）
	■ チューニングモデルの精度検証（モデルの精度検証（AUC）） ✓ 各金融機関のデータの一部を用いて汎用モデルを追加学習（チューニング）した際の精度を検証
	■ 実証事業先モデルの精度検証（モデルの精度検証（AUC）） ✓ 各金融機関の全データを用いて汎用モデルを再学習した際の精度を検証
② AIモデルの個別カスタマイズ・高度化可能性の検証	<ul style="list-style-type: none"> ■ 実際の金融機関データにしか存在しない教師データ・説明変数を用いたAIモデル開発 ✓ 企業に関するテキストデータを用いて構築したモデルの有効性を検証 ✓ 経営改善支援の実績データを用いて構築したモデルの有効性を検証 ■ 金融機関におけるAIモデルの個別カスタマイズ内容や高度化内容に係る整理

実証事業にて検証したモデルの概要（検証内容①）

- 本実証事業のうち、①開発したAIモデルの有効性の検証では、本調査・研究にて構築した汎用モデルのほか、実証事業先データを使用して新たに実証事業先モデルを構築した。各モデルの概要と目的は下表のとおり。

種類	アルゴリズム	モデルの概要	実証事業における目的
汎用モデル		<ul style="list-style-type: none"> ■ 共同研究先のデータを使用し、一般的な説明変数のみを用いて構築したモデル ■ 新たに学習を行う必要がないため、実務適用が容易 	<ul style="list-style-type: none"> ➢ モデルの精度検証（AUC、適合率と再現率等） ➢ モデルの解釈性の確認（スコアの寄与度の解釈性など）
チューニングモデル	<ul style="list-style-type: none"> ■ ロジスティック回帰 ■ ランダムフォレスト ■ 勾配ブースティング 	<ul style="list-style-type: none"> ■ 実証事業先データの一部を用いて追加的な学習を行い、汎用モデルを調整（チューニング）して構築したモデル ■ 使用する説明変数は、汎用モデルと同じ 	<ul style="list-style-type: none"> ➢ 汎用モデルとの精度比較（AUC） ➢ （汎用モデルの精度が低い場合）少数データでのチューニングの有効性の検証
実証事業先モデル		<ul style="list-style-type: none"> ■ 実証事業先データのみを用いて構築したモデル ■ 使用する説明変数は、汎用モデルと同じ 	<ul style="list-style-type: none"> ➢ 汎用モデルとの精度比較（AUC） ➢ （汎用モデルの精度が低い場合）実証事業先モデル構築の意義の確認

実証事業先データを適用した場合のモデル精度（検証内容①）

- 4つの実証事業先データを用いたモデル精度一覧は下表のとおり。
- 開発コンセプト1及び開発コンセプト2において、汎用モデル・チューニングモデル・実証事業先モデルともに概ねAUCが0.7となっており、実際の金融機関データを用いても本アプローチは有効であることが立証された。
- チューニングモデルや実証事業先モデルの精度は概ね汎用モデルより高くなっており、各金融機関がモデルを活用する際は実証事業先データを一部用いたチューニングもしくは、データ全量を用いた再学習を行うと、より業務効率化等に資するモデルとしての実務適用が可能となることが示唆された。

実証事業先	開発コンセプト1			開発コンセプト2		
	汎用モデル	チューニングモデル	実証事業先モデル	汎用モデル	チューニングモデル	実証事業先モデル
平均値※	L: 0.627 R: 0.644 G: 0.662	L: 0.621 R: 0.684 G: 0.696	L: 0.662 R: 0.716 G: 0.706	L: 0.736 R: 0.736 G: 0.743	L: 0.747 R: 0.744 G: 0.743	L: 0.689 R: 0.731 G: 0.738
最大値※	L: 0.665 R: 0.697 G: 0.710	L: 0.689 R: 0.703 G: 0.707	L: 0.692 R: 0.758 G: 0.759	L: 0.795 R: 0.809 G: 0.802	L: 0.820 R: 0.842 G: 0.860	L: 0.845 R: 0.860 G: 0.868

※ Lはロジスティック回帰、Rはランダムフォレスト、Gは勾配ブースティングを意味し、それぞれの数値はモデル精度の評価指標であるAUCを意味する。

※ 汎用モデル、チューニングモデルについては、それぞれの実証事業先データで最も精度の高かったモデルの平均値、最大値を掲載。

実証事業先モデルについては、4つの実証事業先での平均値、最大値を掲載。

AUCの平均値、最大値が0.7を超えているものについては、**太字**で記載。

実証事業にて検証したモデルの概要（検証内容②）

- 本実証事業のうち、②AIモデルの個別カスタマイズ・高度化可能性の検証では、実証事業先データを用いて、新たに高度化検証モデルと因果推論モデルを構築する。各モデルの概要と目的は下表のとおり。

種類	アルゴリズム	モデルの概要	実証事業における目的
高度化検証モデル	勾配ブースティング	<ul style="list-style-type: none"> ■ 実証事業先モデルに、テキストデータの情報を説明変数として加えて構築したモデル 	<ul style="list-style-type: none"> ➢ テキストデータを用いたモデルの有効性の検証
因果推論モデル	<ul style="list-style-type: none"> ■ 逆確率重み付き推定 ■ Meta-Learners (DA-Learner) 	<ul style="list-style-type: none"> ■ 経営改善支援を行った際の業績改善効果等を測定するため、経営改善支援の実施有無に関する情報を活用して、因果推論（原因と結果を統計的手法等により推論するモデル）の手法により構築したモデル 	<ul style="list-style-type: none"> ➢ 経営改善支援の実績データを用いたモデルの有効性の検証 ➢ 経営改善支援に有効な変数の確認

テキストデータを用いたモデルの有効性検証 [1/2]

- 金融に特化させた大規模言語モデル（下部参照）を活用して、ポジティブスコア（業績にプラスに寄与するスコア）とネガティブスコア（業績にマイナスに寄与するスコア）をテキストデータの各項目※ごとに付与し、当該スコアを実証事業先モデルの説明変数に加えて高度化検証モデル（テキストデータ追加モデル）を構築した。
※ 今後の業況見通しなどの数項目
- 高度化検証モデルのAUCは下表のとおり。テキストデータを含まない実証事業先モデルと比べ、精度としてはほぼ同水準であった。

アルゴリズム	開発コンセプト1		開発コンセプト2	
	高度化検証モデル (テキストデータを含む)	実証事業先モデル (テキストデータを含まない)	高度化検証モデル (テキストデータを含む)	実証事業先モデル (テキストデータを含まない)
ロジスティック回帰	0.690	0.679	0.703	0.680
ランダムフォレスト	0.726	0.723	0.717	0.710
勾配ブースティング	0.736	0.726	0.719	0.711

【大規模言語モデルについて】

- 大規模言語モデルとは、文章分類、文章生成や機械翻訳などの自然言語処理タスクの実行を目的に、従来のAIモデルと比較して大規模なテキストデータを事前に学習して構築されたモデルをいう。今回の分析では、BERT（Bidirectional Encoder Representations from Transformers）と呼ばれる大規模言語モデルの中でも、高い精度を持つことが知られるモデルを活用。
- 今回は、あずさ監査法人が独自に蓄積・収集した金融に関する文書（テキストデータ）を追加的に学習させて、テキストに対するポジティブな内容（「好調」や「売上増加」）やネガティブな内容（「赤字」や「売上減少」）に基づき精度の高いスコアを付与できるように修正したモデルを使用し、分析を行っている。

テキストデータを用いたモデルの有効性検証 [2/2]

- 高度化検証モデルについて、テキストデータ変数の重要度（順位、モデルの説明変数は全315変数）は下表のとおり。
- 最上位に該当するテキスト項目も存在しており、今後データの整備（変数化等）を工夫することで、モデルの精度や解釈性において効果的な変数となり得るものと思料。

テキスト項目	開発コンセプト1		開発コンセプト2	
	ポジティブスコア	ネガティブスコア	ポジティブスコア	ネガティブスコア
当該企業の現況、今後の業績見通し、問題点等	70位～6位	61位～9位	22位～1位	19位～3位

【テキストデータの活用がもたらす効果（将来的な発展可能性も含む）】

- 元々の実証事業先モデルの精度が高かったため、テキストデータを追加したことによる精度向上は限定的であったが、それぞれの変数の重要度は高く、今回の試行により、以下の効果（発展可能性含）が得られた
 - ① モデル精緻化
 - ・ テキストデータの整備等を工夫することで実現する可能性
 - ② モデルの解釈性の向上
 - ・ AIスコアの高低の要因につながるコメントを特定することで、経営改善支援につながるヒントが獲得できる可能性
 - ・ AIスコアの高低の理由を説明する文書（コメント）を自動生成するAIを開発することで、解釈性の向上・業務効率化が図られる可能性
- 金融機関にとって、テキストデータに対するAI活用は将来的に発展可能性の高い分野であるため、当該分野の研究開発は重要となる

経営改善支援の実績データを用いたモデルの有効性検証[1/4]

- 経営改善支援を行った際の業績改善効果等を測定（①経営改善支援の介入効果の検証、②経営改善支援の介入効果へ寄与する変数の確認）するため、経営改善支援の実施有無に関する情報を活用して、因果推論（原因と結果を統計的手法等により推論するモデル）の手法によりモデルを構築。
- 具体的な方法は以下のとおり。

①経営改善支援の介入効果の検証

1. 伝統的な因果推論モデル（逆確率重み付き推定）にて、経営改善支援の全体的な介入効果を推定
2. 機械学習を使用した因果推論モデル（DA-Learner）にて、個別企業への経営改善支援の介入効果を推定し、その平均から全体的な介入効果を推定
 - 機械学習を使用した因果推論モデルは先進的な取組みのため、経営改善支援の全体的な介入効果が伝統的な因果推論モデルと整合的であるかを確認すべく、上記2つの手法を使用する。
 - 経営改善支援の効果は経営改善支援を実施することで平均的にどの程度信用スコアに変動があるか推定することで行う。なお、信用スコアとは企業の信用度を100点満点で評価したもの。

②経営改善支援の介入効果への寄与する変数の確認

- 機械学習を使用した因果推論モデル（DA-Learner）にて、説明変数の寄与度を個社ごとに算出し、その平均から全体の経営改善支援の介入効果に寄与した変数を確認
- あわせて実際に経営改善支援を実施した企業を1社選択し、以下を確認する。
 - 個社企業への経営改善支援の介入効果に寄与する変数を確認
 - どのような企業への経営改善支援が有効であるかの確認

経営改善支援の実績データを用いたモデルの有効性検証[2/4]


– 経営改善支援の効果検証結果

- 以下2点から、経営改善支援による介入効果がプラスであること（信用スコアの上昇）が確認できた。
 - 伝統的な因果推論モデル（逆確率重み付き推定）と、機械学習を使用した因果推論モデル（DA-Learner）のいずれも、経営改善支援を実施することによって、信用スコアが上昇した。
 - いずれの手法においてもその95%信頼区間が正の区間を示しており、統計的な有意性を得ることができた。

① 経営支援改善の介入効果の検証結果

【伝統的な因果推論モデル（逆確率重み付き推定）】

- 経営改善支援の実施によって、信用スコアが約3.10点上昇する結果となっている。



【機械学習を使用した因果推論モデル（DA-Learner）】

- 経営改善支援の実施によって、信用スコアが約2.55点上昇する結果となっている。




経営改善支援の実績データを用いたモデルの有効性検証[3/4]

– 経営改善支援を実施した場合の介入効果の予測値への寄与度の高い変数

②経営改善支援を実施した場合の介入効果の予測値への寄与度の高い変数の確認結果[1/2]

【全体の経営改善支援を実施した場合の介入効果の予測値（＝信用スコアの改善期待値）に寄与する変数】

■ 各変数右端の値は、各変数の介入効果の予測値への寄与度を示した全体結果の平均値（絶対値ベース）



■ 左表の上位に位置する変数ほど経営改善支援を実施した場合の介入効果の予測値へ与える寄与度が大きい。

※左図の値は寄与度の大きい変数を示すため、絶対値で記載。そのため、介入効果の予測値へプラスに寄与（＝信用スコアの予測値を上昇させる）を及ぼすものばかりではない。

■ デット・エクイティ・レシオがもっとも寄与度が高く、次いで収益性（自己資本総利益率や従業員一人当たり売上高）や手元流動性（当座レシオやクイックレシオ）が寄与していることが分かる。

経営改善支援の実績データを用いたモデルの有効性検証[4/4]

–経営改善支援を実施した場合の介入効果の予測値への寄与度の高い変数

②経営改善支援を実施した場合の介入効果の予測値への寄与度の高い変数の確認結果[2/2]

【個社企業へ経営改善支援を実施した場合の各変数の介入効果の予測値（＝信用スコアの改善期待値）への寄与度を確認】

■ 下図における正の値をとる変数は、経営改善支援を実施した場合の介入効果の予測値にプラスに寄与し、負の値をとる変数は、経営改善支援を実施した場合の効果の予測値にマイナスに寄与していることを示す。各絶対値が大きい変数の順に上から並べている。

※各変数の左側の値は当該個社の経営改善支援を実施前の実績値

$f(x) = 3.331$ (= 当該個社へ支援を実施した場合の介入効果の改善期待値)

2.243 = デット・エクイティ・レシオ

1.486 = 棚卸資産回転期間

4.236 = 負債比率

1.598 = 自己資本総利益率

0.69 = 長期負債比率


0.774 = 固定長期適合率

0.979 = 当座比率

0.984 = クイックレシオ

2.946 = 売上債権回転期間

47 other features



＜左記企業の例＞

■ 支援前債務者区分：要注意先

■ 支援後債務者区分：正常先

■ 分析から得られる示唆

- 当該個社は因果推論モデルによると、経営改善支援による介入効果はあると予測されている。
- 左図記載の支援実施前の実績値を踏まえ、借入過多に陥っている企業と推定され、DELレシオや負債比率が介入効果の予測値へプラスに寄与。
- 事実として、当該企業は経営改善支援を受けることにより、上記の通り債務者区分が上方遷移。
- 以上を踏まえると、資金繰り表の策定や経営改善計画策定支援等の支援の結果、事業者の資金調達構成が見直され、経営改善が果たされたのではないかとこのようなストーリーが推測可能。

変数ごとの値は、平均的な介入効果である「信用スコア+約2.55（P17の結果）」を基準として、各変数の値がどの程度プラス（マイナス）側へ信用スコアの変動に影響したかを意味する

1 スケジュール、本研究会の議題等

2 実証事業の結果概要

3 ワークショップの結果概要

4 本調査・研究の総括と今後の課題

5 添付資料

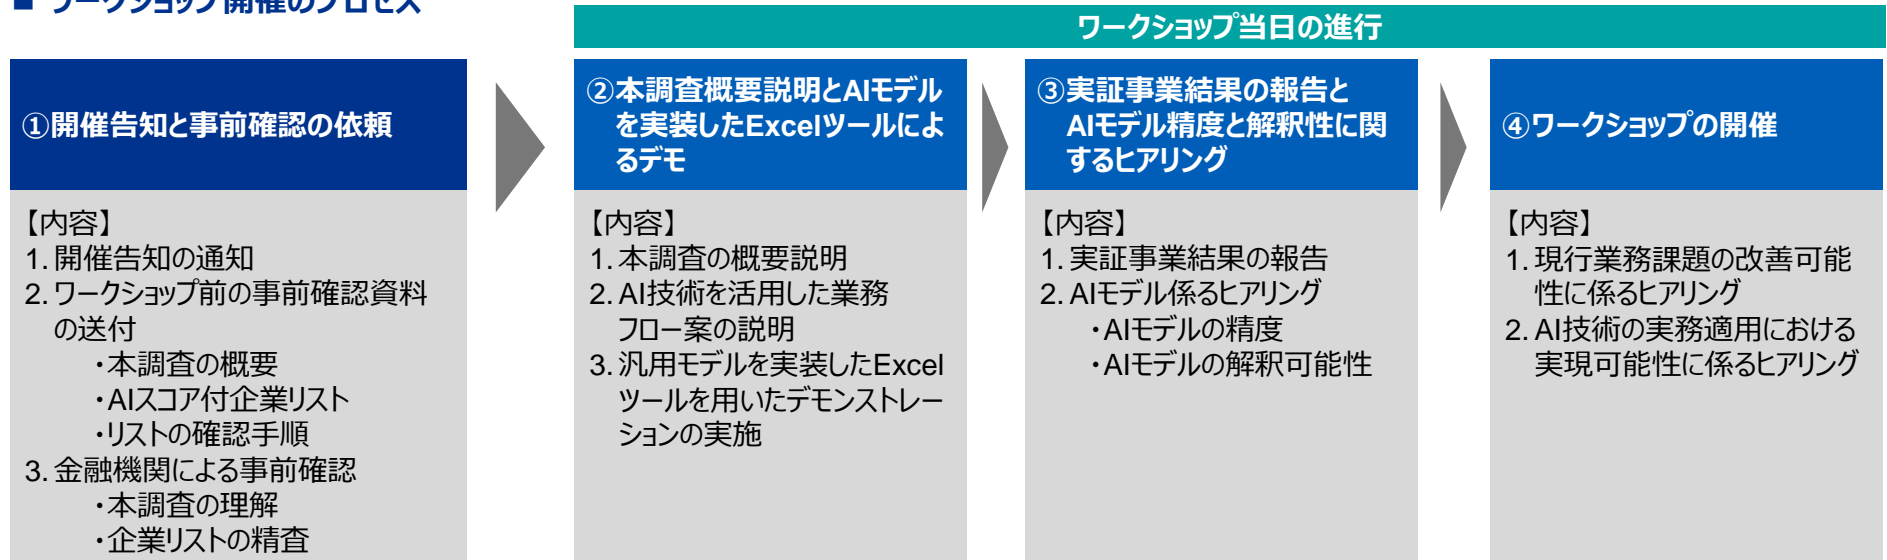
金融機関とのワークショップの概要

- 実証事業の結果も踏まえ、2023年2月にワークショップを開催。
- ワークショップでは、以下について、金融機関の実務を担う職員と意見交換（ヒアリング）を実施
 - ①実証モデルの結果を踏まえたモデル改善（精度や解釈性）について
 - ②現行の業務課題の把握及び今後のAI技術導入による改善可能性について

■ 対象金融機関

No	ワークショップを開催した金融機関	参加部署	開催時期
1	横浜銀行	融資部	2023年2月9日
2	栃木銀行	事業支援部、事務システム部	2023年2月9日
3	浜松いわた信用金庫	経営サポート部、デジタル推進部	2023年2月7日
4	大東京信用組合	総合企画部 他	2023年2月13日

■ ワークショップ開催のプロセス



ワークショップにてヒアリングした事項一覧

- ワークショップにて、ヒアリングした事項は下表の通り
- AIモデルのより具体的な精度検証のため、実証事業先にAIスコアを付与した経営改善支援候補リストを事前に配布し、個別にリストの妥当性を評価いただいている。

大項目	項目	#	調査内容
AIモデルの精度	モデル全体の精度	1	<ul style="list-style-type: none"> • AIモデル全体の精度（AUC）や抽出された企業の順序が受入可能な水準となっているか • AIから出力されるスコアを活用し、ある閾値以上の企業を重点的にモニタリングすることで、経営改善支援業務が効率化されたり、より実効性を高めることが実現し得る精度となっているか
	経営改善支援候補リストの妥当性	2	<ul style="list-style-type: none"> • 今後業績が悪化する可能性が高い先を特定するモデル（開発コンセプト1）から抽出した企業リストの妥当性 • 今後業績が向上する可能性が高い先を特定するモデル（開発コンセプト2）から抽出した企業リストの妥当性
AIモデルの解釈可能性	AIモデル全体の解釈可能性	3	<ul style="list-style-type: none"> • AIモデルに採用されている説明変数やその寄与度が審査や経営改善支援実務と照らして、解釈可能で納得的か
	企業リストの解釈可能性	4	<ul style="list-style-type: none"> • ある会社のスコアとその要因を示した寄与度等を表示しているが、実務家でも理解できるものとなっているか
現行業務課題の改善可能性	情報源	5	<ul style="list-style-type: none"> • 経営改善支援の前提となる各情報を取得する業務が効果的かつ効率的になるか
	支援候補先の作成	6	<ul style="list-style-type: none"> • 経営改善支援候補先を選定する業務が効果的かつ効率的になるか
	事業者への経営改善支援	7	<ul style="list-style-type: none"> • 事業者に対する支援内容を検討し、実行する業務が効果的かつ効率的になるか
AI技術の実務適用に係る実現可能性		8	<ul style="list-style-type: none"> • 「開発コンセプト1と2」のAIモデルを活用した新業務フロー案は実現できそうか • 新業務フロー案を実現するにあたっての課題はあるか

実証事業を踏まえたヒアリング結果概要

- ヒアリング項目毎の金融機関からのご意見概要は下表の通り
- 本調査・研究にて設定した実証事業先にて確認するKPIは概ね達成できたと考えている

#	ヒアリング項目	結果概要	
		主な好意的なご意見	主な改善点・課題に係るご意見
P22 #1-2	AIモデルの精度	<ul style="list-style-type: none"> ● AIモデルの精度は実務に耐えうる水準か ・ 全体的なモデルの精度は問題ない 	<ul style="list-style-type: none"> ● AIモデルの精度は実務に耐えうる水準か —
		<ul style="list-style-type: none"> ● モデルより抽出された支援候補リストの確認結果は如何か ・ 抽出された企業リストの中に実際に業績悪化（業績向上）した先が含まれていることが確認された ・ リストの中には、従来はモニタリングできていないような企業も含まれており、こうした客観的な方法で抽出されたリストは有益 	<ul style="list-style-type: none"> ● モデルより抽出された支援候補リストの確認結果は如何か ・ 事業意欲は経営者の年齢等にも関係があるので、そういったものを考慮したリストになると有用ではないか ・ 抽出されたリストの中に、手元流動性が高いものの、赤字の企業が含まれていない等もあったので、リストの抽出条件をカスタマイズ（資金繰り面を重視する等）できるモデルになれば有益ではないか ・ 債務者区分ではなく、格付けを利用しても有用ではないか
P22 #3-4	AIモデルの解釈可能性	<ul style="list-style-type: none"> ● 寄与した説明変数の一覧は実務的に解釈可能か ・ 寄与度が上位となった説明変数は、実務的に違和感なく解釈可能である 	<ul style="list-style-type: none"> ● 寄与した説明変数の一覧は実務的に解釈可能か ・ 説明変数に資金繰りに関する項目をもう少し含むべきではないか ・ 業種（中分類・小分類）や外部環境変数（地域区分等）の粒度を細分化できれば、より解釈が進むのではないか ・ 一部の金融機関の取引先においては外部環境変数は重要ではない
		<ul style="list-style-type: none"> ● 各個社単位のAI出力結果は実務的に解釈可能か ・ 同規模、同業種のスコアの要因は参考になる ・ AI出力結果について、事業者との話のきっかけとして有益 	<ul style="list-style-type: none"> ● 各個社単位のAI出力結果は実務的に解釈可能か ・ 出力結果を業種別にカスタマイズでき、更に意味合いを補足するテキストをAIによって付加できると解釈性が向上する ・ AIスコアの過去の長期推移も示されると尚よい ・ 同規模、同業種内における当該企業の立ち位置が分かると尚よい

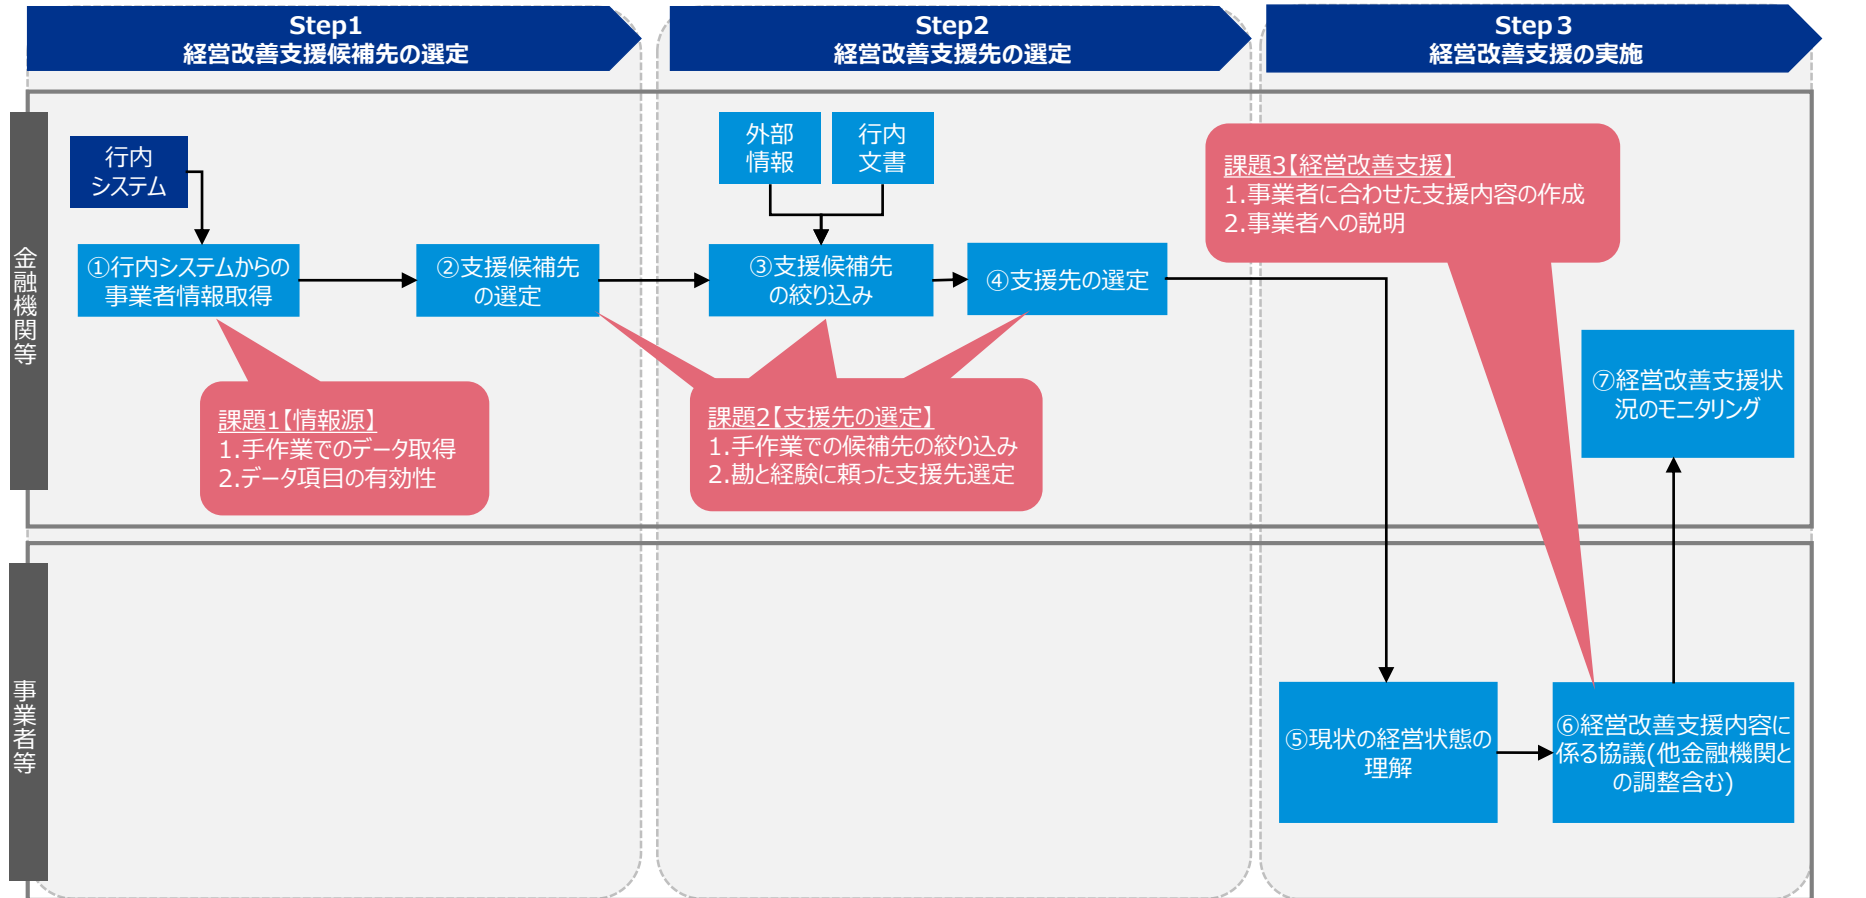
現行業務課題と改善可能性にかかるヒアリング結果概要

■ 4 機関に対し、AIモデル導入による現行業務の改善可能性や実務適用に向けた課題等についてヒアリングを実施（P22：#5-8）。主な意見は下表の通り。

金融機関名	項目	主な意見
A金融機関	現行業務の課題	<ul style="list-style-type: none"> 経営改善支援先の絞り込みは、ヒアリング等の定性基準が中心で、明確な定量基準はない。 本部に経営改善支援の話がきた段階で既に業績が悪化していることがある。
	業務の改善可能性	<ul style="list-style-type: none"> 本AIモデルを活用するとデータに基づき客観的な基準で早期に支援先を選定できる。特に外部環境データ等、日常業務では把握しきれていないデータが含まれている点は有用。
	今後の実務適用	<ul style="list-style-type: none"> 既存の支援先選定業務との重複もなく、本部でトライアル的に導入するのであれば、そこまでハードルは高くない。 新たな業務フローが増えるので規程類等の整備や既存業務や既存システムとの親和性を加味した対応が必要となる。
B金融機関	現行業務の課題	<ul style="list-style-type: none"> 支援先の選定は資金収支等を踏まえ行っており、最後は人の目でも判断するので、相応の時間がかかっている。
	業務の改善可能性	<ul style="list-style-type: none"> 支援先の選定がAIで自動的にできるのであれば業務効率化につながる。また、今回受領したリストには、これまで注目していない先が入っており、気づきという観点では有用。
	今後の実務適用	<ul style="list-style-type: none"> 導入時点では精度の問題もあるので、事後検証的に使う等、補完的に利用しつつ、データの蓄積を進めていき、精度が上がった段階で、支援リスト作成の実務に組み込んでいくことが現実的ではないか。
C金融機関	現行業務の課題	<ul style="list-style-type: none"> 定性情報等を踏まえて、営業担当者の判断で訪問先を選定している。
	業務の改善可能性	<ul style="list-style-type: none"> データに基づく客観的なリストが作成できることで、本当に支援すべき先の選定に活かせる可能性がある。今回受領したリストには、現行の支援業務では捕捉できていなかったような企業が入っており、その点も評価できる。
	今後の実務適用	<ul style="list-style-type: none"> 本部でトライアル的に利用し、効果検証をしながら、徐々に適用範囲を拡げる形での導入が検討できる。 融資残高等の取引情報を加味したリストの作成や試算表などを活用したタイムリーな評価を実現するなど、一定のカスタマイズが必要。また、ベンチマークとなる業種は細分化が望ましい。
D金融機関	現行業務の課題	<ul style="list-style-type: none"> 支援先は、融資残高等、一定の条件で絞り込んだうえで、最終的には担当者の判断で選定している。
	業務の改善可能性	<ul style="list-style-type: none"> 全先を対象としてリスト化できる点が有用。今回受領したリストの中には、今まで注目していない先も含まれていたが、よくよく分析してみると、なるほどと思う先であった。 訪問する際の参考資料にもなるので、経営改善支援を行う場面でも効果的な対話等のきっかけになると考えた。
	今後の実務適用	<ul style="list-style-type: none"> まずは、本部での導入となると思うが、最終的には、店舗でも作成・シミュレーションができるのが理想。 解説書もセットで展開する必要があるので、初期コストは相応にかかる。

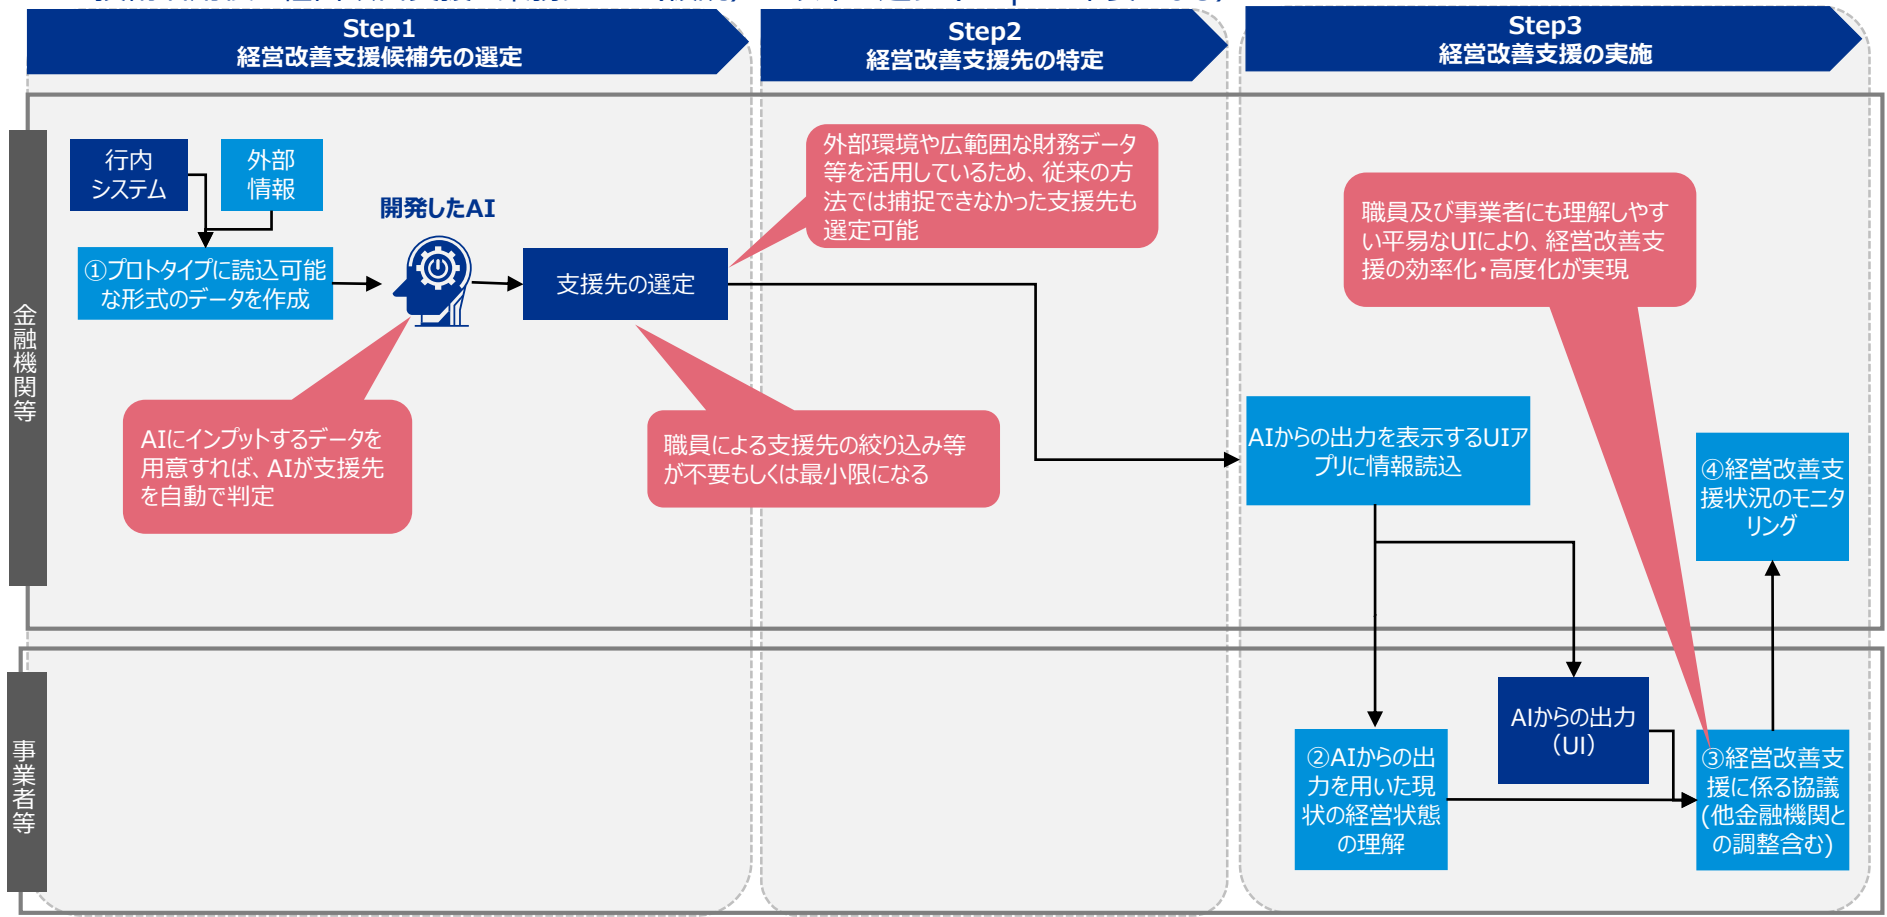
(参考) 現状の経営改善支援業務 - 第1回研究会資料再掲

■ 現状の経営改善支援の業務フロー及び業務上の課題（仮説）は以下の通り。



(参考) AI技術を用いた新たな業務フローの基礎検討 - 第1回研究会資料再掲

■ AI技術活用後の経営改善支援の業務フロー（仮説）は以下の通り（Step2は不要になる）。



■ : システム ■ : 人のマニュアル作業

実証事業およびワークショップのまとめ

実証事業① 実際の金融機関データを用いたモデルの精度検証結果

- 共同研究先データを用いて開発した汎用モデルを実際の金融機関データを用いて検証を実施
- 開発コンセプト1及び開発コンセプト2において、汎用モデル・チューニングモデル・実証事業先モデルともに概ねAUCが0.7となっており、実際の金融機関データを用いても本モデルは有効であることが立証された
- 実証事業先へのAIモデル適用方法により精度の違いが出ており、「①汎用モデルをそのまま適用」⇒「②一部データを用いたチューニング」⇒「③実証事業先のデータ全てを用い、再学習させたモデル再構築」の順で精度が高い傾向にあるものの、②と③において精度の差は大きくない
- そのため、チューニングを行うことで実務に耐え得る精度を獲得できることが示唆された

実証事業② AIモデルの個別カスタマイズ・高度化可能性の検証

- 一部の金融機関において、実際の金融機関内部にのみ存在しているようなテキスト情報を用いてモデルのカスタマイズを実施
- 元々の実証事業先モデルの精度が高かったため、精度の向上は限定的であったが、各変数の重要度は高く、今後は金融機関内部に蓄積されたテキスト情報の整備や重要度が高い文言の特定等を進めることで、精度改善や解釈性の向上につながる可能性が高いことが示唆された
- 経営改善支援施策の効果検証についても実証し、支援策全体の効果検証や個社別の因果推論結果は、今後の実効性ある経営改善支援の実現に有益な結果であることも示唆された

実証事業に対する主な意見

- 全体的なモデルの精度については、さらなる改善が必要であるものの実務に耐え得る水準である
- 個別のリストについても、実際に業績が悪化した先やこれまで捕捉していない先が含まれる等、一定の有用性がある
- 説明変数の解釈性や寄与度については、実務上違和感がない
- 業種や地域分類、試算期財務データ等のより粒度の細かい情報の活用や、融資額・非保全額などを勘案のうえリスト抽出することで、AIモデル精度と解釈可能性の向上につながるのではないかと

現行業務の改善可能性に対する主な意見

- 現行業務では、必ずしも定量データに基づき支援先の選定を行っていない中、客観的な基準でリストが作成できることで支援業務が効果的に行える可能性がある
- 実務適用については、まずは本部等の部署でトライアル的に導入し、精度検証を繰り返しながら、導入範囲を決めていくのではないかと
- 導入にあたっては、既存業務やシステム、既存モデルとの親和性や、導入にかかるコスト等を鑑みながら、規程類などの体制整備も行うことが必要



1 スケジュール、本研究会の議題等

2 実証事業の結果概要

3 ワークショップの結果概要

4 本調査・研究の総括と今後の課題

5 添付資料

本調査・研究の総括

- 本調査・研究は、AI等のデジタル技術を活用して、業況悪化の兆候が見られるような経営改善支援が必要な先を発見し、早期の経営改善支援等を行うことで、事業者の経営改善・事業再生を促していくことを目指すため令和4年4月に開始した
- 当該目的を達成するため、学術経験者・実務家・AI専門家などからのご意見を踏まえ、現在の経営改善支援実務の課題に基づき「AI技術を活用した新業務フロー案」を策定し、新業務フロー案を実現するため、①AIモデルの開発、②金融機関との実証事業、③金融機関とのワークショップ、という流れで事業を行うこととした。
- AIモデルの開発では、経営改善が必要となる先（業績が悪化する先）を早期発見すること及び経営改善の可能性が高い企業を発見することといった「モデル開発コンセプトの確定」、それを実現するための、「モデル母集団の定義」・「教師ラベルの定義」・「アルゴリズムの選定」を行い、本調査・研究で開発するAIモデルの要件定義を行った
- 同時に、AIモデル開発に必要なデータを確保するため4つの共同研究先にもご協力を賜り、策定した要件定義通りのAIモデルの開発が可能となった
- 開発するAIモデルが本調査の目的を達成し得るよう、学術経験者・AI専門家からのご助言を参考に、AIモデル開発計画の策定、AIモデルの評価指標の設定やデータクレンジング、説明変数の作成等を実施した
- それぞれの開発コンセプトごとにAIモデルを開発した結果、概ね実務適用可能な水準のモデル精度が実現した
- また、実務家からはAIモデルの解釈性や説明力の向上のため、出力結果のあり方について、様々なご意見を頂戴し、経営改善支援の実務に組み込むことが可能なAI出力イメージの具体化が実現した
- その後、開発したAIモデルが実際の金融機関データにおいても有効に機能するか確認するため、横浜銀行・栃木銀行・浜松いわた信用金庫、大東京信用組合の4機関にご協力いただき、実際の金融機関データを用いたAIモデルの検証（実証事業）を実施し、結果に対する意見も伺ったところ、概ね実務に適用可能な精度レベルをクリアしており、本調査にて採用したアプローチが有効であることが立証された
- あわせて、本モデルを実務適用に結びつけるため、上記4機関にご協力いただき、金融機関とのワークショップを開催した。ワークショップでは、AIモデルを活用することで、定量基準での支援先の選定や支援先の捕捉範囲の拡大により、支援業務が効率的・効果的に行える可能性があるとの示唆が得られた
- 一方、導入にあたっては、既存業務やシステム、既存モデルとの親和性や、導入にかかるコスト等を鑑みながら、規程類などの体制整備も行うことが必要との意見も聞かれたため、まずは、本部等の部署でトライアル的に導入し、精度検証を繰り返しながら、導入範囲を少しずつ拡大していくというアプローチが有効であるとの意見も聞かれた
- 上記の研究結果や課題を踏まえ、次年度以降は実際の金融機関での実用化に向けて、さらなる調査・研究を進めていく予定である

今年度の課題の棚卸し・次年度へ向けた方向性

課題の類型		No	今年度の課題	次年度の方向性（案）
モデル高度化	データ	1	・より短期での業況変化を把握できると実務上有用なのではないか	・金融機関内部にしか蓄積されていないような高頻度データ（月次財務、試算期財務等）と、より粒度の細かいデータ（業種分類の細分化等）の活用
		2	・経営改善支援を実際に行うことで業績が向上するような先を予測できるようにしてほしい	・支援をしたことで業績が向上した先と自力で向上した先を峻別できる教師ラベルの作成
		3	・債務者区分は必ずしも財務状態と連動するわけではないので、業績に応じた序列付けがされた企業リストがほしい	・信用格付等の別の序列情報を用いた教師ラベルの検討
		4	・定性情報（経営者年齢や後継者有無など）や実態財務情報を加味して支援しているため、当該情報も踏まえて欲しい	・金融機関内部にしか蓄積されていない定性情報/実態財務情報の活用
		5	・渉外記録やCRMシステムなどに蓄積されたテキストを主とする情報も積極的に活用してほしい	・テキスト情報を説明変数に活用可能な自然言語処理を用いたモデルの開発
	モデル	6	・業種や規模などのセグメントを活用する等、より納得的（精度の高い）な結果を出力してほしい	・今年度モデルで精度の低かったセグメントモデルの要因分析 ・業種や規模などのセグメントモデルの精緻化 ・より高度なアルゴリズム・モデルの検討
		7	・突発倒産先も検知できるようにしてほしい	・過去に突発倒産した先を用いたモデルの検証 ・突発倒産先も教師ラベルに加えたモデル開発
		8	・スコアの要因を説明する情報として数値的な寄与度だけでなく営業店でも解釈可能なテキストでの要因説明をしてほしい	・業況を端的に表現するテキスト自動生成モデルの開発
実務適用	9	・実質的に経営が一体となっている関連会社や親会社の財務状態や業種等も考慮した結果（スコア）を出力してほしい	・実質的に経営が一体となっている関連会社や親会社との関係を考慮したAI出力結果の活用方法の整理	
	10	・金融機関ごとに審査目線や支援方針が異なるので、それを反映できるようにAI出力結果もカスタマイズできるようにしてほしい	・（伴走支援を通じた）業態ごと、地域ごと等にAIを実務適用する際の各論点（実施体制、手続き、規定、システムとの親和性等）を整理し、横展開を行う	
	11	・新しい業務フローを実務適用する場合は規程類などの体制整備も必要となる		
	12	・支援先の選定に通常用いられている情報（残高・非保全額など）も加味したリスト作成をしてほしい		
	13	・新技術を導入するとしても、既存業務やシステム、既存モデルとの親和性に配慮してほしい		



1 スケジュール、本研究会の議題等

2 実証事業の結果概要

3 ワークショップの結果概要

4 本調査・研究の総括と今後の課題

5 添付資料



汎用モデルにおける寄与度の高い説明変数

予測結果に寄与した説明変数一覧（分類毎の結果）

汎用モデル（開発コンセプト1の結果）

■ 開発コンセプト1の予測結果に寄与した説明変数の一部は下表の通り


健全性	効率性	債務償還能力	資金繰り	収益性
有利子負債利率	棚卸資産回転期間	インタレストカバレッジレシオ	経常損益比率	総資本利益率
デット・エクイティ・レシオ	売上債権回転期間	支払利息割引料営業利益率	運転資本比率	売上高税引前当期利益率
など	など	など	など	など

成長性	生産性	流動性	属性変数	外部環境変数
総資産前年比	従業員一人当たり総費用	流動比率	地域区分	エネルギー消費量 [※]
売上高前年比	従業員一人当たり売上高	現金預金短期借入金率	業種区分	地価 [※]
など	など	など	など	など

※:地域グループ別

説明変数の分類毎の寄与度 汎用モデル（開発コンセプト1の結果）

■ 開発コンセプト1の説明変数の分類ごとの寄与度は以下の通り



予測結果に寄与した説明変数一覧（分類毎の結果）

汎用モデル（開発コンセプト2の結果）

■ 開発コンセプト2の予測結果に寄与した説明変数の一部は下表の通り


健全性	効率性	債務償還能力	資金繰り	収益性
自己資本比率	買入債務回転期間	支払利息割引料営業利益率	経常損益比率	総資本利益率
有利子負債利率	借入金回転期間	インタレストカバレッジレシオ	売上高運転資本比率	自己資本経常利益率
など	など	など	など	など

成長性	生産性	流動性	属性変数	外部環境変数
売上高前年比	従業員一人当たり売上高	キャッシュレシオ	地域区分	実宿泊者数 [※]
資本計前年比	従業員一人当たり総費用	当座比率	業種区分	地価 ^{†※}
など	など	など	など	など

†:対数変化率、※:地域グループ別

説明変数の分類毎の寄与度 汎用モデル（開発コンセプト2の結果）

■ 開発コンセプト2の説明変数の分類ごとの寄与度は以下の通り






AIアルゴリズムとAIモデル評価指標の概説

AIアルゴリズムの概説 [1/6]

■ ロジスティック回帰の概説

下図のようなロジスティック曲線を用いて、目的変数を回帰分析の手法で予測する方法。金融機関実務において企業の信用力評価に最も活用されている方法。



$$Z = \alpha_0 + \beta_1 X_1 + \beta_2 X_2 + \dots$$

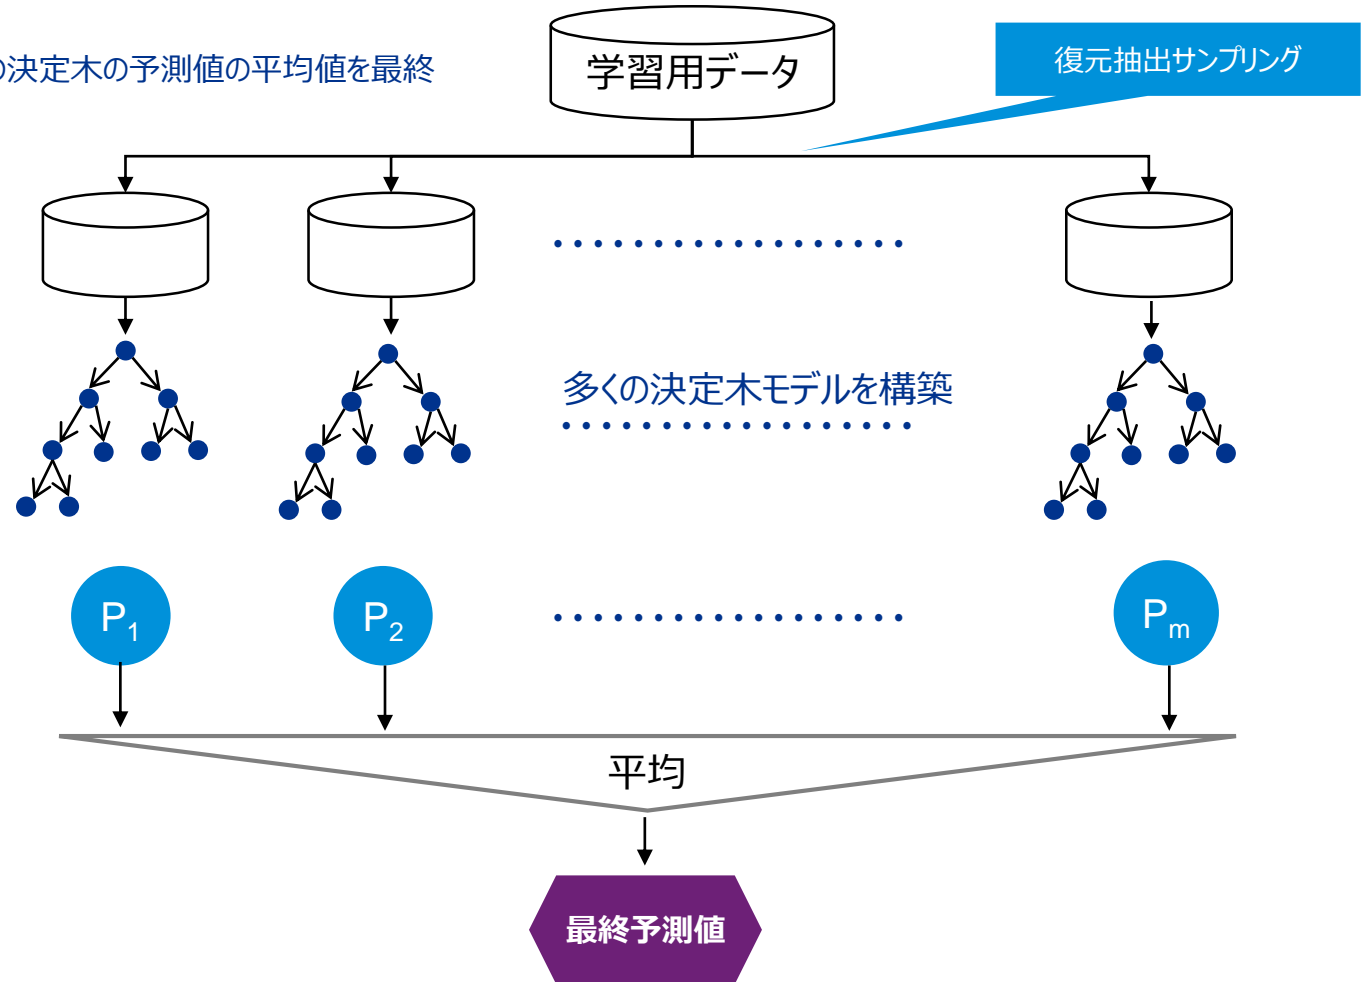
X_i : i 番目の説明変数 (特徴量)

α_0 、 β_i : 切片および回帰係数

AIアルゴリズムの概説 [2/6]

■ ランダムフォレストの概説


多くの決定木モデルを構築し、多数の決定木の予測値の平均値を最終的な予測値とする方法



AIアルゴリズムの概説 [3/6]

■ 勾配ブースティングの概説


決定木を構築し、当該決定木が外したサンプルに当てはまるようにウェイトを調整して、次の決定木を構築する。これを繰り返して最終的な予測値とする方法



AIアルゴリズムの概説 [4/6]

■ Meta-Learnersの概説

因果推論を行うための論理フローの各ポイントに主要な機械学習アルゴリズム（ロジスティック回帰、ランダムフォレスト等）を適用し、介入効果の推定を行う手法。

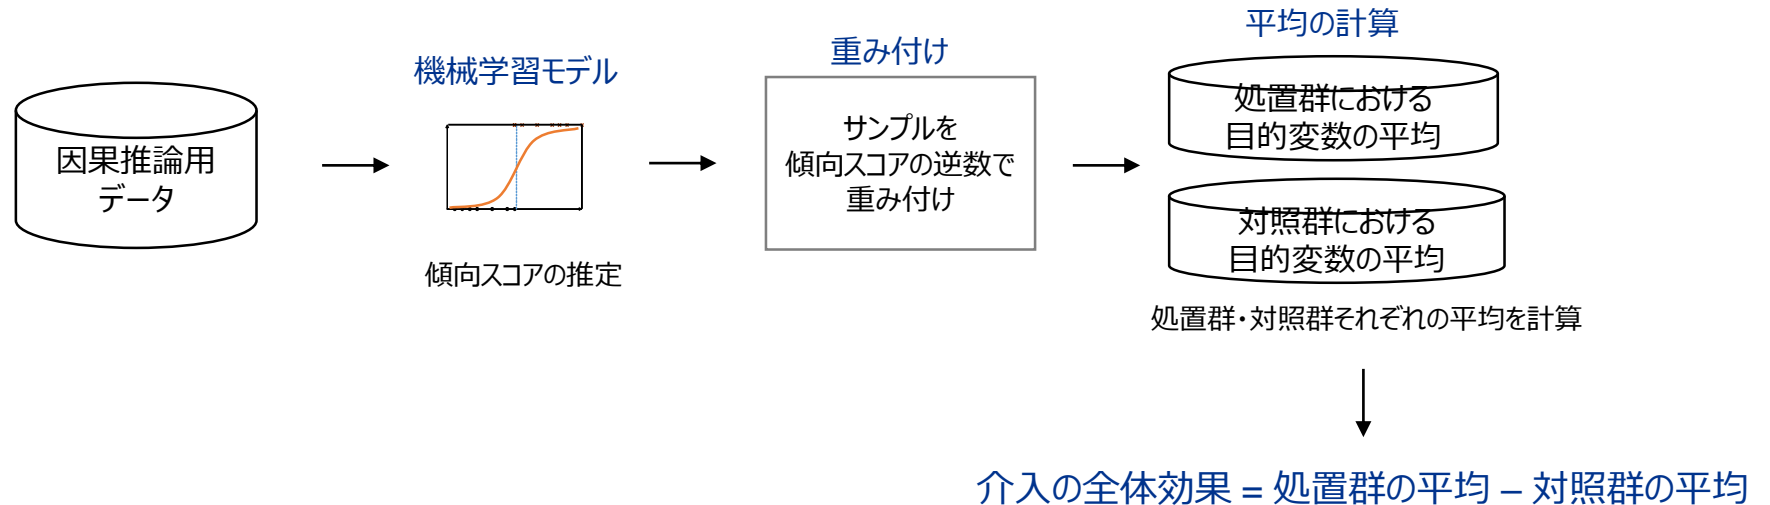


(注) Meta-Learnersの中には様々なアルゴリズムがあり、各ポイントにおける機械学習モデルの適用有無や適用方法、介入効果の算出方法は、各アルゴリズムによって異なる。

AIアルゴリズムの概説 [5/6]

■ 傾向スコアを用いた逆確率重み付き推定による因果推論（伝統的な因果推論）

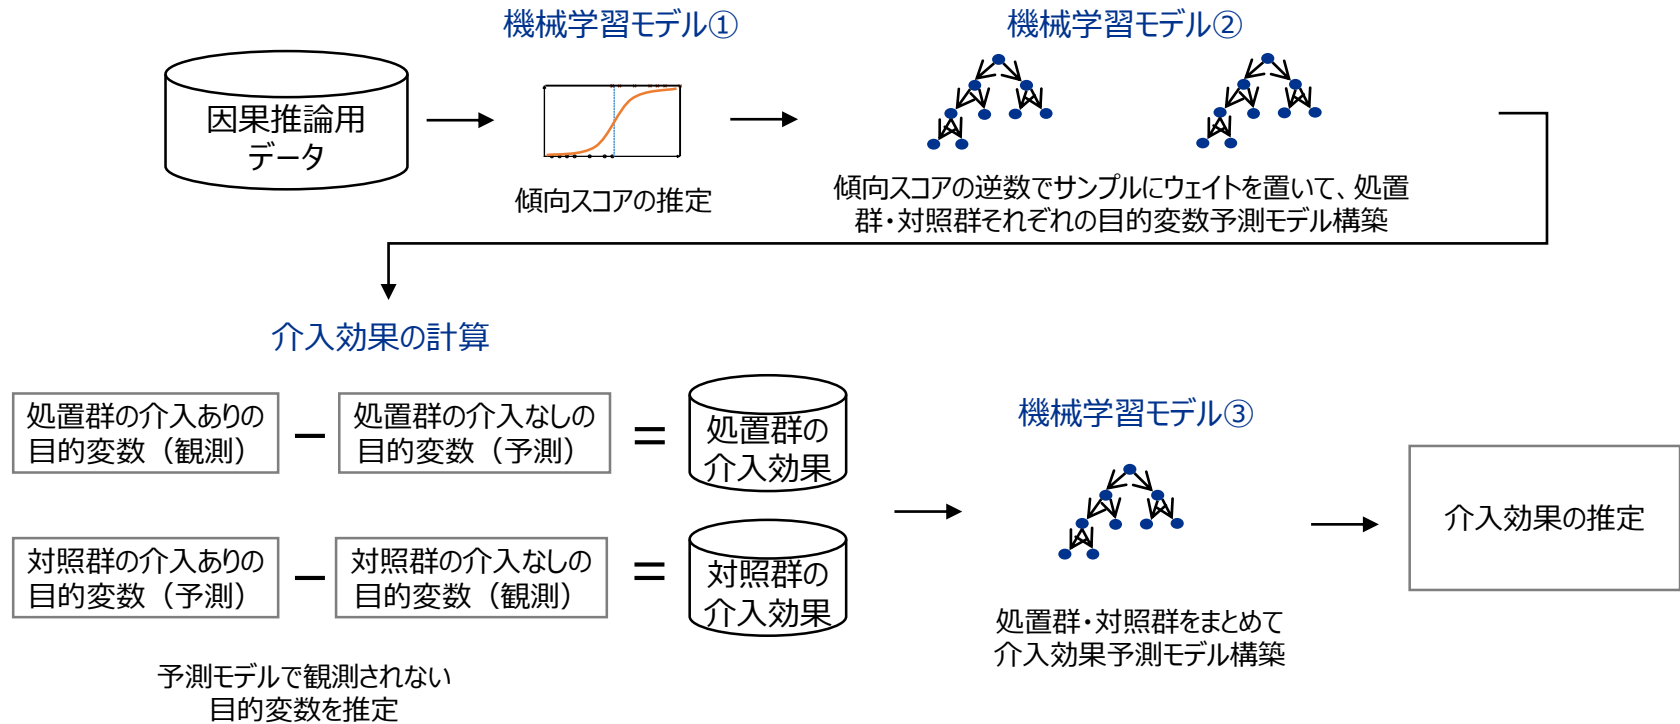
傾向スコア（介入が行われる確率）をサンプルの重みとして使用し、処置群の目的変数と、対照群の目的変数の平均を計算し、これらの差分をとることで介入の全体効果を推定する。



AIアルゴリズムの概説 [6/6]

■ DA-learner (Domain Adaptation Learner) を用いた分析

傾向スコア（介入が行われる確率）をサンプルの重みとして使用し、処置群の目的変数と、対照群の目的変数の予測モデルを構築する。観測できない目的変数を予測モデルで推定し、介入ありと介入なしの目的変数の差分のモデルを構築することにより個体効果を推定する。



AIモデルの評価指標の概説 [1/2]

- 本資料にて示したAIモデルの評価指標である、適合率、再現率についての概説は以下のとおり。

混同行列と評価指標

- 混同行列は、モデルでデータを分類した際にその正解・不正解をまとめた行列のこと。クラス分類を行うモデルの性能・精度の確認に使用される。
- 正例（ポジティブ）と負例（ネガティブ）の2クラスがあるデータセットに対して、以下が定義される。
 - 真陽性（True Positive、TP）：実際にポジティブのデータを正しくポジティブと予測したもの（数）
 - 偽陽性（False Positive、FP）：実際にはネガティブのデータを間違ってポジティブと予測したもの（数）
 - 真陰性（True Negative、TN）：実際にネガティブのデータを正しくネガティブと予測したもの（数）
 - 偽陰性（False Negative、FN）：実際にはポジティブのデータを間違ってネガティブと予測したもの（数）

		モデルの予測	
		1 (Positive)	0 (Negative)
実データの クラス	1 (Positive)	TP	FN
	0 (Negative)	FP	TN

- 上記で定義した混同行列の4つの数値を使用して、以下のような評価指標が計算される。


- 正解率(accuracy) = $\frac{TP+TN}{TP+FP+FN+TN}$ • 予測結果全体に対し正しく予測できたものの割合
- 適合率(precision) = $\frac{TP}{TP+FP}$ • ポジティブと予測したものに、実際にポジティブであるものの割合
- 再現率(recall) = $\frac{TP}{TP+FN}$ • 実際にポジティブのものに対し、正しくポジティブと予測できたものの割合

AIモデルの評価指標の概説 [2/2]

- 本資料にて示したAIモデルの評価指標である、AUC、AR値、CAP曲線についての概説は以下のとおり。

ROC曲線とAUC


- モデルにデータを当てはめたとき、実際にイベント（「企業業績の低下」など、モデルによって検知する事象）が発生した全てのデータのうち、正しく検知ができた割合のことを、真陽性率（TPR）という。また、実際にイベントが発生しなかった全てのデータのうち、間違えて検知した割合を偽陽性率（FPR）という。
- 検知するかしないかは、モデルで推定されたイベント発生確率に対して閾値を設け、それを上回ったかどうかで判定しており、**ROC曲線**は、当該閾値を変更した際に変化するTPRとFPRをそれぞれ縦軸、横軸にプロットしたもので、下図のような曲線を描く。



- **AUC (Area Under the Curve)** は、ROC曲線の下部分の面積のことをいう。ROC曲線は、右にいくほど下がることはないこと、偽陽性率（横軸）が小さい段階で、真陽性率が高いモデルほど良いことから、AUC（上記面積）が大きいほど、優れたモデルであることを意味する。

CAP曲線とAR値

- **CAP曲線**は、横軸にモデルで推定されたイベント発生確率の上位 x 件の、全てのデータ件数 (N) に対する割合 (x/N) を、縦軸に推定されたイベント確率の高い上位 x 件のうち実際にイベントが発生した件数 (N_x) の、イベントが発生した全てのデータ件数 (N_1) に対する割合 (N_x / N_1) をプロットしたものであり、下図の**B**のような曲線を描く。
- モデルの説明力が全くない場合は **C** の直線を描き、予測が完全に正解したモデルの場合は **A** のような形を描く。



- BとCで囲まれた部分の面積の、AとCで囲まれた部分の面積に対する比を、**AR値**という。すなわち、値が1に近づくほど、予測が完全に正解したモデルに近いということの意味する。

$$\text{AR値} = \frac{\text{BとCで囲まれた部分の面積}}{\text{AとCで囲まれた部分の面積}}$$



ここに記載されている情報はあくまで一般的なものであり、特定の個人や組織が置かれている状況に対応するものではありません。私たちは、的確な情報をタイムリーに提供できるよう努めておりますが、情報を受け取られた時点およびそれ以降においての正確さは保証の限りではありません。何らかの行動を取られる場合は、ここにある情報のみを根拠とせず、プロフェッショナルが特定の状況を綿密に調査した上で提案する適切なアドバイスをもとにご判断ください。

© 2023 KPMG AZSA LLC, a limited liability audit corporation incorporated under the Japanese Certified Public Accountants Law and a member firm of the KPMG global organization of independent member firms affiliated with KPMG International Limited, a private English company limited by guarantee. All rights reserved.

The KPMG name and logo are trademarks used under license by the independent member firms of the KPMG global organization.

「AI を活用した経営改善支援に係る研究会」(第4回)

開催日時：2月24日(金) 16時00分～18時00分

開催方法：「Webex」による Web 会議形式

委員：

有竹 博史 東京信用保証協会 業務総轄室 業務総轄部長
和泉 潔 東京大学大学院 工学系研究科システム創成学 教授
内山 功士 浜松いわた信用金庫 デジタル推進部 デジタル業務課 課長
河合 祐子 Japan Digital Design 株式会社代表取締役 CEO
三川 剛 株式会社エルテス 取締役
鈴木 明美^{※1} 大東京信用組合 常務理事
筒木 光 TKC 全国会システム委員会 TKC 経営指標編集小委員会 委員
中村 康浩 株式会社横浜銀行 融資部 担当部長
名取 良訓^{※2} 信金中央金庫 総合企画部しんきんイノベーションハブ 次長
原 浩二 株式会社栃木銀行 事業支援部 主任調査役
松崎 堅太郎 TKC 全国会中小企業支援委員会 副委員長
宮川 大介 一橋大学 経営管理研究科 経営管理専攻 教授
矢内 紘之 株式会社帝国データバンク 企総部 企画課長(欠席)

議事進行：

秋場 良太 有限責任あずき監査法人金融統轄事業部 ディレクター

※の記載のある委員については当日以下の通り代理出席者が参加。

※1：柴橋 英範 大東京信用組合 総合企画部 考査役

※2：北口 裕也 信金中央金庫 総合企画部しんきんイノベーションハブ 上席調査役

■アジェンダ

1. 開会
2. 事務局説明
3. 討議
4. 閉会

○ 研究会委員

それではまず、1つ感想というか、12 ページ目全体的なモデル精度ございますけれども、ご説明にありました通り平均的には 0.7 以上の評価値がありますので十分かなと思います。特に開発コンセプト 2 で仰っていただいた通り 0.8 以上のところが最大値の方でいくつかありますので、フューチャーワークになると思いますけれど、どこが得意でどういうケースにつき少し苦手だったとか、そういうところに踏み込んでいきますとどう改良するべきか、というところにつながるかと思います。これが全体的な感想です。

もう一点よろしいでしょうか。13 ページ目以降のテキストデータを使った所、非常に興味深く拝聴いたしました。今回仰っていた通り、14 ページ目にあります通り、比較的単純なポジネガのセンチメントスコアを入れただけでも、多少ですけれども精度向上が見られたということになりますので、14 ページ目の下に書かれていますように、最近発展の著しい大規模言語モデルを使ったもので、さらに詳細に見ていってケースケースでどんなテキストが文脈を見て書かれているか、というところまでいくとさらに向上する可能性が非常に高いと思います。その時に気を付けなければいけないこととしては、一般的な言語モデルだけではなくて、財務とか経営とかそういったところにチューンナップした言語モデルが必要になる可能性もありますので、フューチャーワークとしてそういったこともやるとさらにテキストデータによる精度向上が望めるかと思います。私からのコメントは以上になります。

○ 事務局

最初に仰っていただいた点については前回の研究会でもご指摘頂いた委員の先生いらっしゃいましたし、苦手な部分と得意な部分は今回セグメントモデルを作ったりして、当たっている業種、当たらなかった業種があるということまでの認識で、飲食店とかがあまり精度が高くなかったとかが、分かっていますのでその辺次年度に深堀して、場合によってはセグメントもより精緻なモデルを作ってやってみるとか、苦手な部分はなるべく精度があがるようにということを取り組んでいけたらと思っています。一方、得意な部分、特にコンセプト 2 とかですね、セグメント分けした時も精度が高かった先はあるので、苦手な先、精度が上がらなかった先の参考にはなるかと思っていますので、良かった部分と悪かった部分、両方を見て次年度に繋げられればと思っています。次年度以降もこのテキスト分析について、いろいろなお意見賜ればと思っています。今回はかなりクイックにやらせていただきましたけれども、大規模言語モデルを使うとしたら、経営とか企業の業況とかテキストに上手くフィットさせて、チューニングしていくとより良いということは認識していますので、そのあたりも技術的な面も含めて次年度以降アドバイス頂ければと思っています。我々としても、金融業界としても、比較的今回のメインは定量データを使ってやるということで、その実務適用がある程度できそうだとは思っているものの、なかなかテキスト情報、特に言語モデルを使ったものはこれから発展していくところかと思っていますので引き続きよろしくお願ひい

たします。

○ 研究会委員

3点ほどコメントと印象を申し上げたいと思います。全体としては、資料に載せられている数字は非常に要約された形でコンパクトにまとめられてはいるのですが、背後に様々な取り組みがあった上でここに到達していると思います。その意味で非常に難易度の高いタスクだったと思うのですが、上手くまとめられて、今後につながる良い成果になっているのかなと思ったのが全体の印象でした。

3点申し上げたいと思っていますのは主としてせつかく意味のある分析をされたので報告書にまとめられる際であるとか、来年度に向けて次の課題を考えられる際に少し参考になればなということなのですが、まず一つは今回多様なデータソースがあって、実証実験としても多様な主体がいるという非常に面白いフィールドだったわけですし、そういう意味でモデルを作る際に使っているデータなどを見ると、実際に運用する際のドメインが適合しているときに上手くいっているという想像があると思うのですが、そうじゃない場合にどれくらい上手くいかなかったのか、というあたりも整理された情報があると思いますので記載されておくと、実際に現場で何かをしようと思ったときに非常に有用な情報になるのではないかなと思いました。それが一つ目です。

二つ目も今後実用されていくということを考えた場合の頭の整理なのですが、おそらく今回取り組まれた成果をいろいろな金融機関さんが参考にして何かをしようと思ったときには使い方にそれなりに差があると思います。例えば規模が大きく、非常に優れた様々なノウハウをお持ちの金融機関さんが今回のことを踏まえて何かをしようと思うと、例えばテキストデータのより有効な活用という方にウェイトを置いてみたり、もしくは解釈の部分にもう少し知恵を絞ってみたり、マシンと人のタスク分配のところにもう少し考えを巡らせたり、というふうにかなり進んだ発展的な議論が可能だと思います。一方で、なかなか一足飛びでそこまでいけないという規模の比較的小さな金融機関さんもいらっしゃると思うのですが、そこにおいても今回議論されたような頭の使い方ですね、そこから得られる経済的なゲインの実現の仕方、例えばコスト削減が一番大きいところだと思いますけれども、そういったものを参考にするってことは十分にできると思いますし、ありもののモデルをそのまま使うということも当然できると思いますから、金融機関さんの状況に応じて今回の成果の使い方には差がありますよというあたりは一つ強調しておいても良いのかなと思いました。これが2点目です。

それから最後ですが、この後議論になるかもしれない来年度以降の課題の中に含まれるかと思いますが、因果推論まで踏み込まれたのが非常に素晴らしいと思いました。得てしてこういった研究では、予測モデルのところの構築、それ自体でも難しい訳ですからそこで息切れしてしまう場合が多いと思うのですが、今回金融機関さんのご協力もあって、極めて珍しいタイプの面白い因果推論ができています。もちろん課題はある

と思います。例えば、異質な処置効果を推計されようとしているのですけれども、どれくらいそこが信用できるのかなとか、通常の IPW で推計する時にやるようないくつかの付随するテストがあると思うのです。例えばプレトレンドの欠如に関するテストとか、そういうものも来年度以降もし取り組まれるのであれば、やられることによってより信ぴょう性が上がると思いますし、今回評点が 2 から 3 くらい上がったということですが、こういったエコノミックインパクトの評価についても本当に 2、3 評点上がったくらいで良いのかとか、どの段階からどの段階にあがったのかとか統計的な目線だけでなく、エコノミックな目線からの評価の軸もいろいろあると思いますので、是非今回の因果推論に踏み込んだところをベースにして、より発展的な取り組みに繋げて頂くのが有益ではなかろうかと思いました。私の方からは以上です。

○ 事務局

貴重なご意見ありがとうございました。最初に仰っていただいたのは、適合しなかった先、適合した先、特に適合しなかった先の深掘りはまさに次年度以降しっかりとやらなければいけないところかと思っていますので、引き続きアドバイス・ご意見等頂ければと思っています。二つ目ですけれども、こちらも次年度の大事なポイントなのかなと思っています。今、次年度の仕様書が公表されているので、どんなことを金融庁様が企図しているかを代弁させていただくと、まずは 5 つ程度の金融機関さんに実際データをご提供いただいて、今回のようなモデルを作って実務適用までご支援すると、それだけに終わらず、そこで得た結果、そこでは委員の先生に仰っていただいた規模の大きい所、小さい所、当然含まれるかと思うので、その 5 つ程度の金融機関さんの実務適用の支援を通じて規模の大小・業態によって、こういうところに工夫すると良いとかですね、横展開を、5 つで終わってしまっただけでは金融庁様の企図したところではないかと思っていますので、いろいろな金融機関さんに広がるということが大事になってくるかと思っていますし、次年度はそういった所まで調査をするということなので、ご指摘頂いた使い方の差なり、その差がどういうところにあるのかとか、差がある中で実際にその 5 つの金融機関さん以外でもその調査の結果を参考にすると自分のところでも上手く活用できるようなそんな形で取りまとめられたらと感じた次第です。最後に、因果推論について、こういった貴重な分析はなかなかできないですし、こういった取り組みを調査として公開するっていうことは金融業界としても非常に良いことかなと思っていますので、来年度もモデルを作るときの様々なテストとか、効果の検証は丁寧に実施できればと思っていますので、引き続きよろしく願いいたします。

その他ご意見ある方いらっしゃいますでしょうか。

○ 研究会委員

モデルの有効性だとかあるいは因果推論のところについては多分かなり良いものができるかなという印象を持ちました。ちょっと実用性のところに入るのかもしれませんが、

テキストデータのところで、この段階でここまで踏み込めたこと自体それなりのステップだと思うのですが、どういふテキストを読み込んだ結果どういふ結果が出たのか、みたいなことが裏では皆さん検証なされているのでしょうか、エグゼクティブサマリーレベルだとちょっとわかりにくいので、これは別に今見せてくれとかっていうことではないのですが、そのテキストデータがどのようなソースでどのような頻度で更新されているものを、こういう財務データと組み合わせた結果こうなったみたいなところがもう少しわかるようになっていた方が後々資料だけ見る人はわかりやすいのではないかなと思うので、その辺は差し支えない範囲で開示した方が良いのではないかなと思いました。あとフューチャーワークのところに入るのですが、まさに有効なテキストを作っていくってことがこれの精度を上げていくってことにもつながると思うのでより正確なAI判定ができるためのテキストの更新頻度とか、そういう文書の作り方、例えば日本語にありがちな「問題なしとしない」とかわかんないですけど、そういう言葉を使わないようにこのサンプルのところでは金融機関さんに徹底していただいて、わかりやすい言語で、ある程度軸を揃えて頻度も揃えて実証していくとより有効なものができるような気がしたので、その辺のガイドラインまである程度突っ込んでいいのではないかなというのが率直な感想です。

もう一つ結果のところ、デッドエクイティレシオの改善みたいなところが突出していると思うのですが、やはり直接的に金融機関さんが手が下せるところが突出して出ているというのが印象でございまして、その他にこの経営改善行為をやったら顕著に現れるデットエクイティレシオ以外の数字、ここだと負債関係のところですかね、自己資本総利益率、これはデットエクイティレシオにちょっと関連するような気がするので それ以外のキャッシュフローのところとか、あるいは売上増加につながったとか、利益性が改善したとか、他のところの濃淡ももう少しわかりやすいと単純に金融機関さんが金融行為を行っただけじゃない観点でも結果が出ているというようなことが分かるとより有用性が伝わると思いますし、金融機関さんがお使いになるときのヒントになると思うので、ちょっとそのような観点でも深掘りをしていったらいいのではなからうかなというふうにも思いました。以上でございます。

○ 事務局

最初にご指摘いただいたどんなテキスト情報を使って更新頻度がどれぐらいあるかということですが、こちらご協力いただいた金融機関さんの内部の情報であるので、その金融機関さんと相談の上、開示できる範囲では思っていますが、そこは金融機関さんのご事情もあるので、その点ご理解いただければと思っています。今回使わせていただいたテキストデータとしては、更新されているのですが、直近部分だけですので更新を反映していないといえないので、そこはご理解いただければと思っています。本来的には更新したほうが、時点時点のテキスト情報を使ってということだと思いますけれど、そこは今回限られた

時間があつたということなので、そこはご理解いただければと思っています。あとフューチャーワークということで、よりこういった分析にうまく活用できるためには元のデータがちゃんとしてなきゃいけない、あとはテキストデータもガイドラインでというのはまさに仰っていただいた通りかなと思っています。今回のソースもテキストデータのソースも金融機関の職員の人が実際一つ一つ書いた情報ですので、目的としては当然その企業の今はどういう業況かっていうのを分かるために記載しているということですが、今後の分析も踏まえてそういった表記揺れがないような形っていうのは仰っていただいた通りかと思うのでそこは次年度以降になるかと思えますけれども、ありがとうございます。最後ですね、まさに今スライドで投影しているものですが、デットに直接影響するもの以外、収益性とかあとは今回財務の情報しか見ることができていないですけれども、例えば後継者がいるかどうかとか、経営者の年齢とかですね、ここは分かるかどうかあれですけれども、扱っている商品のライフステージがどうだとか、そういうより定性的なものも加味できると単に負債関連の支援じゃなくて、より例えば販促の支援が効くかどうかとか、そういったことにもつながるし、後継者をちゃんと育てなきゃとか、そういうアドバイスにもつながると思うので、ここはまさに仰っていただいた通りかと思えますので、次年度はそういう情報もなるべく反映したような形でできればなと考えている次第です。ありがとうございました。

○ 研究会委員

ありがとうございます。本当にここまでありがとうございました。大変に良い結果で勇気づけられるものだなというふうに思います。私も実務の観点から二つございます。いずれもフューチャーワークに関するものでありまして、まず結果を見させていただいて、まさに今お示しいただいているページもそうですし、あるいは何が寄与度が高いファクターだったのかというあの棒グラフもそうなのですが、割と資金繰りそのものに関するものというのが、私が思っていたよりはちょっと軽めだったなという気がしております。例えば、与信管理モデルのようなものの中で特にその短期で信用度合いを見る場合、これはちょっと次のコメントにも関係してくるのですが、おそらく財務データを中心に使っているということですので、これ自体は評価の頻度としては年に1回とか、あるいはどんなに頑張っても2回とかそういうことなのだと思うのですが、もうちょっと短い頻度でものを考えていく場合には結構資金繰りがどうなのかということは相当効いてくるような気がいたしますので、例えば金融機関さんのお持ちのデータの中で最も資金繰りに影響するのは預金残高でありますので、こうしたものを取り込んでいくことで少し資金繰り的なもの、より短期的なことというのを考えていけると、良くなっていくという気がしたので、これはぜひ今回やっていただいたあずきさんということではなくて、金融機関の皆さまにこの話を伺いたいなというふうに思うのが一点であります。

もう一つはいろいろなファクターが当然あって先ほどの話にありましたように業種によ

って効くとか、効かないとかみたいな外部ファクターみたいなやつを取り込んでいくことは非常に大事だと思うことに加えてネットワークって結構大事だなというふうに思っています、誰から調達しているのか、誰に売っているのかと、誰に売っているのかの方がより大事なことが多いのですけれども、最近では誰から調達しているのかというのも結構大事だなというふうに思っておりますので、こういうことを取引データから取り込んでいくとあるとか、あるいはそれこそデータベンダーさんが各企業のデータを集約されているベンダーさんが取引先リストみたいなやつを出しておられることもあるかと思っておりますので、ネットワークの要素っていうのを取り込めると、より多分銀行員が目で見え気がつかないようなものっていうのが出てくる可能性があるなというふうに思ったという次第でございます。ちょっといずれも感想めいていて恐縮ですが、そんな感じでございます。

○ 事務局

最初に仰っていただいた預金とかはまさに後程ご説明しますが、ワークショップでも出ていたご意見でした。預金とかあとは試算表とかを使って1年単位だと粗いといえば粗いので半年後資金繰りが非常に悪化しているとかってところで支援をしている現場があるということですので、そこはより粒度の細かいデータが次年度使えないかっていうのはまさに今後の課題として取りまとめていますので、そこは可能な範囲でやればなと思っています。あと二つ目に仰っていただいた企業間ネットワークですね、こちらもご指摘のとおりで、ただそこはそういう情報が取ればということです。ただ、金融機関さんもリレーションなりを見ながら当然いろんな審査なりこういった改善業務もやられているのでそこはその情報があれば取り組むということかなと思っています。ありがとうございました。

では、他に何かこの実証事業の結果についてご意見等ある方いらっしゃいますでしょうか。これまでのコメントを踏まえると、実際のモデルの精度パフォーマンスという意味では実証事業先、実際の金融機関さんにも活用可能だっていうことはご評価いただいたのかなというふうには思っています。ただ当然いくつかフューチャーワーク的な課題を頂戴したので、それは次年度以降可能な範囲でできるもの、できないものもちろんありますけれども取り組んでいけたらなと考えています。

では続きまして、ワークショップですね、こちらはかなり実務的な話にはなりますけれども、こちらのテーマで議論させていただければと思っています。まず実際の議論の前に、実証事業にご協力いただいた4つの金融機関様にそれぞれ感想も含めて、あとは実際に今抱えられている経営改善支援業務の課題なり、こういった今回の調査研究で実際やらせていただいたAI技術等を使うとどう活かそうとか、実際使うにしてもこんなところが課題だとか、あとは全体通して実証事業、あと先日のヒアリングを受けた感想等で構いませんので一言ご説明いただければと思っています。

○ 研究会委員

このたび実証事業に参加させていただきまして本当にありがとうございました。結果については良い結果が出たということで正直ほっとしているというのが正直なところです。それからワークショップにつきましてもいろいろな意見交換をさせていただいて非常に有意義な時間を過ごさせていただきまして本当にありがとうございました。結果のところなのですけれども資料の 24 ページのところ、スライド 24 ページのところにワークショップの結果が書いてありまして、ちょっと我々の私どもの抱えている課題と今後の改善可能性それから実務適用ということでちょっと簡単にお話しさせていただければと思います。まず課題のところなのですけれども、以前もちょっとお話ししましたけれども今の支援先の絞り込みにおいて、定性基準が中心になっておりましたので明確な定量基準というのがはっきりとしてなかったというのが課題にありまして、それが今回のモデルの導入が実現すればそのところのカバーはできてくるのかなというふうに感じておりまして、定量面とそれに加えてヒアリング等の定性面を融合させることで非常に選定の精度のところ上がっていくのではないかなというふうに感じております。それから今回の研究の大きな目的の一つだと思いますけれども、本部のほうにそういった業況悪化等の話がきた段階ではスタートが遅いというようなときも多々ありますので、それを事前に察知できるというかピックアップできるということができるといえることになれば支援の着手もそれだけ早くなりますので非常に有効なかなというふうに思っております。それから改善の可能性のところなのですけれども、業務の改善ですね、こちらのところは今申し上げたとおり早期に支援先を選定できるということと、今回外部環境データ等を多く使っておりますが正直手前どもでも日常業務の中で常にウォッチしているわけではありませんで把握しきれてないデータがあるということはあるので、その点が今回のモデルに入っているということは非常に有用なんじゃないかなというふうに感じております。それから今後につきましてですけれども、今回の結果で非常に良い結果が出ていますが、とりあえずは本部でトライアル的に導入するということがまず初めに来るのかなというふうに考えております。ただその際に業務フローが増えますのでいろんな規程周りですとか、既存のシステムとの融合とか、いろんな対応が必要となりますのでその辺をケアした上で導入していくのかなというふうに考えております。いずれにしましても今後非常に利用させていただく道筋というかができたというふうに思っておりますので、今後活用していきたいというふうに考えております。私からは以上です。

○ 研究会委員

今回実証事業に参加させていただきましてありがとうございました。24 ページのところを簡単にご説明させていただきます。まず現行業務の課題ですが支援先の選定につきましては基本的に営業店から選定したものと本部関連部署で資金繰り業況等から債務者区分、残高、保全等を加味して追加すべき先がないかというものをチェックしています。従いまして営業店と本部で一定の手間と時間がかかっているのと、やはり行員の経験、勘に頼ってい

る部分も少なくないというのが現状でございます。業務の改善可能性につきましては支援先選定について客観的データをもとにAIで自動的にできれば業務効率化につながるものと考えています。実証事業のリストの中にはこれまで注目していない先が入っているという点を見ますとやはり行員の経験や勘に頼らない新たな気づきとしては有用なものだと思っております。

今後の実務の適用についてですが、今回の実証事業のリストではスコアが低い先に実際に業績が悪化した先が一定程度含まれていた一方で、当行の既存の支援先については案外高いスコアが出ておりました。そのため仮にある閾値以下を支援先と想定した場合、例えば当行で支援先の日安の先数から見ますとその対象のスコアがおよそ85程度になるかなと思うのですが、その場合に既存の支援先に当てはめてみますと、やはり7割ぐらいがスコア85以上となって選定から漏れる可能性があるかなと思いました。また1年以内に実質倒産になってしまった先のスコアを調査してみたのですが、その中で残高が少ない先もあったのですが、先数で半数以上が90点以上という高スコアが出ていたという結果が出ています。これらの原因として考えられるのは活用した財務データが不良資産と実態の純資産を考慮していないのと、資金繰りの寄与度というのですかね、そういったものが低かったのかなというところが考えられます。従いまして、債務者区分判定に用いるような修正データですね、不良資産とか一過性の損益の調整等、あと資金繰り等を反映させていく必要が今後あるかなと思っています。従いまして実務適用の方法としては、まずは事後検証的に補完的に活用しながらAIで学習する中で精度向上をしていきながら段階的に切り替えていくというのが妥当かなと考えております。以上でございます。

○ 研究会委員

実証実験に参加させていただきましてありがとうございます。24ページに沿って説明させていただきます。改善支援先については、債権額の大きい先や未保全額が大きい先、要注意先以下について、本部で営業支援システム上の交渉履歴や格付を見て選定し、営業店とディスカッションして重点支援先を決めており、選定に時間がかかっています。また、正常先や債権額の小さい先は営業店職員が個別の判断で選定しており、そこは勘と経験に頼る部分であり、同じく選定に時間がかかっていると感じております。

実証事業においては、コンセプトモデル1、コンセプトモデル2ともにリストの上位10先について、2020年3月時点の決算から現状においてランクアップないしはダウンというところを確認しましたが、いずれも2~3件の抽出結果でありました。決算情報登録後、AIモデルの方でアラートが出て、債権額の大きい先とか要注意先以下だけでなく正常先であっても、アラートに基づいて取引先を回れるようになる、または優先順位をつけて回れるようになれば良いなと思いました。

実務適用については、まずは本部の主管部署でトライアル的に利用しながら、徐々に適用範囲を広げていくというイメージでございます。また、リストを有効的に活用していく上で

は、債権残高、事業性評価の情報なども合わせて見られるようなものにしていくことが重要かなと思いました。また、先ほども話が出ましたけれど、試算表などから状況の変化が早く分かるようなものになると、より実用的になるのかなと思いました。最後に業種分類についてですが、例えば製造業であれば、大分類ではなく、中分類、例えば食品製造業とか輸送用機械器具製造業など、そのレベルまで粒度を下げることと同業種での比較がしやすくなるかと感じました。以上です。

○ 研究会委員

こちらの実証事業の方参加させていただきましてありがとうございました。こちらでも現状業務の課題としましては同じように 24 ページで説明させていただきます。当方では、経営改善先の選定について、基本的には融資残高と上位先の方の中でも担当者の判断で選定しているところになりまして、その中で、担当者目線でのやりやすいところとか仲の良いところにもなったりしますので、基本的に本当に悪いところが選定されているっていうイメージがないところも確かにありました。それを防ぐために私たちの方でも財務状況等で前期からの主要 7 項目ぐらいの財務情報が著しく悪化したところを点数化などして上位順に並び替えてその中で選定していく、ということも取り組んでいたところですが、結局選定理由であったり、説明理由であったりにおいて、そこでも恣意性が入ってきますのでちょっと難儀していたところでした。そのなかで、実証作業に関われたことをありがたく思っております。

結果としてはこのように全先を対象としてリスト化された中で、影響のあった指標が目で見えて分かるっていうところ個別で判断していく上で非常に有用だと思っています。実用で使っていく上で、想定される運用は、本部でまずデータベースの段階で抽出をして、その中で一定の A I 得点ラインを引いたうえで、債務残高や未保全等を当てた中で上位からまず支店 10 先ぐらいを投げて、そこで実態をとらえて判断をさせていく、そこで有用性が判断できた段階で店舗展開、というような流れで考えています。こちらにも書いてありますが、実際にはお客様に渡す帳票であったり解説書であったりもセットでつけていただきたいというところが本音です。当方のデータの不備等から算出にはご迷惑をおかけしましたが、例えば正常先であっても、既に財務状況は悪いという先も多数ありまして、その悪いところからさらにランクダウンするというイメージで算出になっていると思いますので、算出に無理があるというところも多々あったかと思っています。その中で、今回作っていただいた帳票等でも今のスコアというのですかね、今どのぐらいでそこからどのぐらい悪くなるのかという判断が少しつきにくいので、もう既に悪くなっている先に対してさらにランクダウンなのか、そこから上がるのかという、その判断がちょっとつきにくいというところは個人的な意見としてありました。この現状からの視点という部分につきまして、考え方等、何かありましたらご教示いただきたいと思います。以上です。

○ 事務局

ありがとうございました。そうですね、既に悪くなっている先なのか、ある程度良い先なのかというのは、過去のスコアの推移を一緒に見ながらやれば、多少そういったところも分かってくるかなとは思っています。こちらも実証事業を通じてご意見いただいた次第ですので、そういう工夫をしていくと、より実務にも使えそうになるのかなと思いますので、ありがとうございました。貴重なご意見ありがとうございました。

いま、実証事業にご協力いただいた4つの金融機関さんから、このヒアリングの結果の概要をご説明いただいた次第です。この点について実際に実務家の委員の方々から、ご意見なりコメントでも構いませんので、感想等でも構いませんので、一言いただけたらと思っています。

○ 研究会委員

ベーシックモデルに関しては、外部環境変数、マクロ変数がだいぶ絞り込まれて、財務中心のモデルになったということもありますので、金融機関にとっては支援ツールとしては扱いやすくなったなという印象を受けました。戻ってしまうのですが、18ページの経営改善支援を実施したことによって業績は好転して要注意が正常先になったというようなイメージだと思うのですが、このケースで寄与度の高い経営指標が、何人も委員の方がおっしゃっていましたが、デッドエクイティレシオがボンと出ていて、実務の立場とすると、経営支援のいわゆる早期経営改善の段階でこの資本構成を良化させるといのは、なかなか難しいというのが印象としてはあります。ここがどうして出てきたのかなと、ちょっと思ったのは、いわゆるボラティリティが高いような業種とか業態、不動産の例を出すまでもなく、いわゆる電子部品ですとかそういった精密機械関係の部品の卸とかいうのは意外と業績変動が激しくて、そういった業種であればトップラインがある程度確保されていれば、専門家を入れるなりして各種回転率の改善をさせれば有利子負債が減って、デッドエクイティレシオが良くなると、そのようなことは考えられるのですけれども、いずれにしても一定の期間経過後ってというのは、先ほど1年後と言っていましたよね、改善効果を測定する時間軸ってというのは、今言ったボラティリティの高いような業種は良いんですけど、いわゆる中小のメーカーの場合は統計上もステイブルに日本の中小企業って来ている場合が多いので、ここを改善させようとする効果測定の時間軸は1年じゃなくて3年とか5年見て、全体で改善されたかどうかというようなところを分析する必要があるのかなと個人的に思いました。ありがとうございます。

○ 事務局

ありがとうございました。今回、1年後ですと比較的データもあったりして、長期になればなるほどそのデータがあるかどうかという制限もつくとともに、モデル化自身も難易度が上がってくるため、今回は1年という短期、比較的経営改善を支援しているの方々からす

ると短期ではあったということです。ただ、今回の研究会ではある程度こういったアプローチが有効だということが分かりましたので、場合によっては、当然この分析をする上では経営改善支援は数年かけて、5年とか普通に皆様方見られていますので、そういう単位で効果があるのかどうかは見ていければと思っています。ありがとうございました。

○ 研究会委員

ありがとうございます、ちょっと全体的な本当に感想というような形になってしまうかもしれませんが、結果としてこういったものが仕上がったのは、今までにないものが見られるようになりましたので、非常に期待をしたいなというふうに思っています。というのは、銀行さんがしっかりこういうのを使って、お客様としっかり話していただける一つのツールができましたので、それを実際の現場の中で見てみたいというのが率直なところでございます。こういったものができましたので、いざ銀行さんのほうでは積極的に使っていて、経営者と積極的な対話をしていただくというのを期待したいというところがございます。その中で、一番ベースになってくるのは会計の数字を正しく入力するということかと思えます。しっかりお客様に正しい会計をやっていただくというのが大前提になるかなと思えますので、そこのところは肝に銘じてお客様にやっていただいて、じゃあどういふ支援が必要なのかというところが正しく出るような形で今後も引き続き支援をさせていただきたいなと思っております。今回、非常にありがとうございました。

○ 事務局

こちらこそありがとうございました。次年度以降は、まさに実務適用を進めていくというところなんです。5社程度の先に、実際、実務支援をするとともにそれをいかに横展開するにはどうしたらいいかというところも取りまとめる予定ですので、引き続き今仰っていただいたようなことも含めてご意見等いただければと思います。ありがとうございました。

○ 研究会委員

24 スライドのヒアリング結果ですね、今日、全ての金融機関の皆様からもコメントを生でいただきまして、非常に勇気づけられる結果だったというふうに思っています。ここにもあるのですが、支援してほしい先に対して、もう支援が入っているというところは正直どうでもいいわけですし、支援が入らずに悶々としている社長さんたちにどれだけ手を差し伸べていただけるかということが非常に大きなポイントになってくるのですが、再生支援協議会に持ち込むような案件であっても、実際そこまで金融機関さんのご理解をいただけるというところまで3年ぐらい要したところもあるのです。やっぱり金融機関さんとの目線合わせが全くできずに、金融機関さんからすればそれほど痛んでないというご判断だったのですが、社長は苦しくて苦しくてしょうがないと、資金繰り含めて将来どうしたらいいのか、という SOS を出されていると、まさにそこが今回 AI で補完でき

たというところになれば、これは非常に素晴らしい結果なんじゃないかなというふうに、すみません、感想めいたところですけど、感じました。また、ちょっと今回逆に気づかされたのが、いわゆる定量的な財務データ以外にテキストデータもお使いになっているというところがあって、多分そこに金融機関の渉外担当の方の皆様の生の声が入っていらっしゃるので、やっぱりテキストの部分というのがどういう形で活かされていくかというのは今後やっぱり大きなポイントというか、一つ方向性とすればすごくありがたいなと思っています。これ非常に卑近な事例ですけども、先週ちょっと、とある私の地元の金融機関の若手と現場の方から話があって、とある先で、社長が最近目を合わせてくれないのですけどどうしてですか、という質問がありまして、そういうことはやっぱり気にされているのですよ、現場では。それには、やはり理由がありまして、ちょっとこれこれこういう理由で、と言ったら非常にありがたがられておりましたけれども、まさに多分そういうような、社長の態度がおかしいとかですね、社長の服装が最近派手だとか、高い車買ったぞ、とかそういう話というのが多分金融機関の現場ではいろいろあがっていると思いますので、そういったところの情報として当てはまる場所がないかとかそんなところはですね、AI で何かしら分析ができるのではないかなと、そんなところも感じたところです。

最後、コメントにもありましたが、実際やってみたら、やっぱり決算書の信頼性が非常に低かったのになかなかそこが難しかった、というのがあるのですけれども、やっぱり例えば中小会計要領をチェックリストであるとかですね、書面添付制度を活用しているとか、そこまでいなくても税理士がどの程度の関与の度合いをしてやっているのかとか、月次決算をどうチェックしているのかとか、そういったところも来年に向けてですと、例えばデータ提供いただけるような金融機関さんが持っているデータがあって、それをデータ提供いただけるようであれば、よりスクリーニングかけられるのかなというような気もしておりますので、すみませんちょっと感想めいたところでございますが、以上でございます。ありがとうございます。

○ 事務局

実際ワークショップ・実証事業をやらせていただいて、先ほどの各金融機関さんからのご説明もありました通り、今まで見ていない先で、なるほどな、というところがあったというコメントはいただいているので、銀行の担当の方との目線合わせの一つの材料にこういった取り組みが使えれば我々としても非常にうれしい限りですので、ありがとうございます。またテキスト情報も、今回はある一つの金融機関さんにご協力いただいたわけですけども、今回のヒアリングを通じて別の金融機関さんでも例えば CRM システムに溜めていたりしているということですので、まさにこのテキスト情報については次年度以降にしっかりやって、やはりどうしても数字情報だけですと無味感想ですので、よりわかりやすく、あとは実効性高いものができればと思っていますので、先生ありがとうございます。

○ 研究会委員

ちょっと感想になってしまうのですが、資料 35 ページとか 38 ページのほうに、汎用モデルの寄与度について触れられているかと思うのですが、最初この研究が始まったときに、信用格付と似たような構成の寄与度になるのではないかな、というふうに私も思っていたのですが、信用格付では健全性であったりですとか資金繰りのところっていうのが配点が高くなるものなのなのですが、今回作っていただいた経営改善支援のモデルについては、収益性であったり、成長であったり、様々な分野から取り込まれているので、信用格付とは異なった視点のモデルになっているのかなというふうに考えております。興味深かったのは、私ども外部環境変数っていうのを使ったことがなかったもので、どれぐらいの寄与率になるのかなというのが非常に興味深かったのですが、実際 15 から 20%程度、個社にも影響を与えるということが分かって非常に勉強になりました。また来年度ですね、因果推論であったり、テキストデータを用いてさらにモデルの精度向上に取り組まれるということで、非常に期待しております。私のほうからは以上です。

○ 事務局

信用格付との違いという意味では、今回は広い意味でデフォルト状態にならないような先でも、つまり非デフォルトゾーンにいる先でも、遷移で悪化したり良化した動きを補足するようなモデルでしたと、そういう意味では成長性とかがですね、信用格付と比較してもウェイトが高い一つの要因なのかなとちょっと思っていた次第です。さはさりながらこちらは次年度以降の課題ではあるのかなと思っています。資金繰りとか、もしかしたら説明変数の作り込みで、資金繰りをちゃんと補足できていなかったりとかって、そういうところがあるのかなと思うので、試算表の情報、あとは他の先生からも預金の情報等コメントいただきましたけれど、そういったものを入れ込むとより資金繰りが実体感伴ってウェイトも上がってくるのかなと思った次第です。ありがとうございました。

○ 研究会委員

かなり次年度の方向性のところが具体的に検討されていらっしゃるのですが、私のほうからもいくつか具体的にこういうような事柄を検討されたらいかがでしょうかということで申し上げます。

まず一点目なのですが、因果推論のところの結果について、やはりああいう形でクリアにプレゼンテーションされると、皆さんの関心を非常に呼ぶと思います。特に特定の財務変数に関して特定の状態にあるときに介入をすると効果が強く出そうぞというの、強いメッセージだと思うわけです。ただ、ここで一つ整理しておく必要があるのは、今回は通常のやり方ではあるのですが、ある種処置に関して介入しましたということで統一した処置の計測の仕方をしているわけですね。なので、どういう処置をしたのかというような、処置自体の異質性については特に考慮していないというのが現状の分析だと認識

しています。ですので、こういう状況にあるときに介入をしたら効果がありましたというのは事実を描写はしてはいるのですけれども、何が起きているのかということ、描写は実はしていないのですね。なので、この意味で来年度、もし同じように因果推論されるのであれば、事前の属性に関する異質性を考慮するのも当然なのですけれども、処置自体をもう少し広範囲に計測していくということも重要だろうと思います。通常、金融庁さんに限らず、他の省庁で EBPM で行われているような取組のほぼ全てが、現状そういう形になっています。すなわち、何らかの補助金を提供する、であるとか、税制優遇を与える、ということだけではなくて、実際どのような中身の処置をしたのかということに降りて分析をすることが割と一般的になりつつあるのかなと思います。ですので、そこは現状実務家の先生方からもご指摘があったような、より現実感のある議論に向かっていくためには必要なステップだと思いますので、是非処置側のリファインメントというのを意識されてはどうかというふうに思うところです。これが一つ目です。

それから二つ目ですけれども、先程からでてきているテキストに関する話、それから現場の担当者の方がお持ちの情報と本部に上がってくる情報の違い、というようなくだりに関連するのですけれども、一つ頭の整理をしておく必要があるかなと思うのは定量的な情報と定性的な情報という区分けだけではなくて、構造化されている情報と構造化されていない情報という区分けもあるということですね。おそらく定性的な情報についてテキストで記録されているものについては処理を工夫していきましょう、という方向で話が進んでいると思いますから、それは全くそれで OK だと思うのですけれども、一つ今日の議論の中であまり注目されていなかったかなと思うのは、金融機関の職員の方がお持ちのいわゆるソフト情報ですね。例えば、経営者の顔色であったりとか、健康状態であったりとか、振る舞いであるとか、そういうデータに落とすことそのものが非常に難しい情報をうまく使うということが、やはり一つの芽として残しておいたほうが良いのじゃないかなと思います。どういうふうにやるかですけれども、海外でも最近そういう研究も進んでいますけれども、今回作ったようなモデルに任せる部分と人に任せる部分を峻別するということですね。特定の属性に関してはマシンに頼りきりにせず、人をフルに使う。もちろんそれでも一部はマシンに任せられますから、コスト削減できますので、そのタスク分配というのがうまくできれば、良いとこ取りになるわけですし、その視点を一つ、これかなりチャレンジングですけれども、今回ここまで進んだことを踏まえれば、次に視野に入ってくるかなと思います。

最後 3 点目、短くですけれども、冒頭のところで金融機関さんの種別によっていろんな今回の成果の使い方があるでしょうということを申し上げました。同じことは当然のごとくして金融庁さんにも当てはまることでありまして、じゃあここでの結果をどういうふうに使っていくのか、ある意味統一化された指標を吐き出すためのマシンなわけですから、いろんな金融機関さんを横並びにしてモニタリングするときに役立つかもしれませんし、金融庁さん自身が何か分析される際にも有効だと思います。なので、この辺りこの課題に書き

込むかどうかは別としても、来年度の一つの検討するべきものとしては、政策面から見たときにこれをどう使っていくのかというのもあり得るのではないかなと思った次第です。私からは以上です。

○ 事務局

因果推論の件は、処置の違いというか、リファインメントは来年度、よりしっかりできればと思っています。ありがとうございます。あとは人のできる部分、機械のできる部分、役割全部機械ではできないですので、その辺のものも当然実務適用する上では当然必要なことになってくるかと思しますので、まさにここに書いている実務適用の論点の一つかと思しますので、貴重なご意見ありがとうございます。それ以外何かご意見コメント等ある方いらっしゃいますでしょうか。

○ 研究会委員

次回への課題ですね。主なものの二つポイントがあると思っていて、一つは入力する情報、テキストなど新たなものを含めて入力のほうをリッチにして発展させたい、ということと、あと出力のほうを例えば自動生成など実際に実務で使いやすい形にしてほしい二つの方向性だと思います。

まず最初は、入力のほうですけれども何でもかんでもいろんな種類のものを足してしまうと、結局、今のモデルが必ずしもよくなるわけではないということがよくありますので、場合によっては今のモデルで不得意なところだけに集中してそこを改善する形にはどんな入力、新たな入力情報を入れればいいのか、という形で発展する方向が、一つあるかと思えます。ですので、ゼロベースでどんどん新しいものを入れるだけではなくて、今のものの得意不得意を踏まえながらやっていくというのは、一つ、入力をリッチにする方向としてはやりやすいかなと思っています。

あと出力のほうを業務に使いやすくするというのはいろんな方法があると思うのですが、ただ正直、自動生成はかなりやるのは大変かなとは思っていますので、まずはファーストステップで、ある特定のパターンに合わせて出力の文章を作ったりとか、テンプレートに合わせていくとか、そこから始めながら、いきなり急に ChatGPT を使うというのは難しいと思いますので、そこは段階で、割り切りながらでよろしいかなと思います。

プラス、このケースで判別したものに対してどれぐらい自信があるか、信頼できるか、ということも同時にきちっと選定できると先ほど言ったように人間に任せるかここは機械の結果を信用するかというところは判別にも業務のフローにもつながりやすいと思いますので、メタな視点で、出た結果の信頼度も考えられるような、そういった手法も足していくとよろしいかなと思います。以上3点になります。ありがとうございます。

○ 事務局

ありがとうございました。まさに、追加的に色々な情報を入れますという、発散してしまうかと思いますので、不得手なところを改善というのは、はい、ありがとうございました。あと、出力の、この自動生成、ちょっと言葉が悪いですけど、まさに最初はパターン化、形式的な文章でこの部分だけ何かしら埋める、みたいなそういうようなものをまずは考えていたので、全くゼロベースで ChatGPT のように生成というものは、かなり、ご指摘いただいたとおり、敷居が高いので、そういったところがまずは簡単にできればなどは考えていますので、引き続きアドバイスいただければと思います。最後仰っていただいた信頼度ですけども、ある企業ではスコアがすごい低く出たけれど実は蓋を開けたらそうでもなかった、みたいなことはあるかと思えますけれど、実際にそういうスコア結果が出ますけれど、この先の信頼度はちょっと低いのではないかとか、高いんのではないかって、そういったやり方があるということなのですかね。ちょっとすみません、追加でご質問して恐縮ですけれど。

○ 研究会委員

ベイジアンニューラルネットワークという形で、確率的に分布でもって出力するという方法も、ニューラルネットワークの一種でありますので、そうしますと今回、低く出たけれど、実はちょっと自信ないのだよね、っていうのもそれによって分布でわかります。そういうのも検討いただけたら幸いです。

○ 事務局

ありがとうございました、参考になりました。それ以外何かある方いますかね。

○ 研究会委員

ここまですて出てきた意見がある意味ちよつとなぞるような形で恐縮なのですが、出力の利用方法ということについて、これはモデルをどのようにするかとか、あるいはそもそも入力・出力の形をどうするかという技術的な話というよりも、使い方という方にむしろ向くのですが、これまでに実務家の方々のワークショップの中では出てきたとおりで、このモデルによって今まで人間の目では発見することができなかったリストが出てくると、ただ、その一方で、既にここまでにあったコメントにもあるように、その結果についての確からしさといいますか、それは分布で示すということも含めていろいろあり得るんだろうということもありますし、信用判定って突然死みたいなものもあるように確率はそんなに高くはないかもしれないけれども、ものすごくディスプレイティブなものもあったりすることなので、出てきた結果をどういうふうにするのかということについてはある程度議論をしたほうがいいのかというふうに思います。といいますのは、これにある程度の確率の分布を付すことができたとしても、それを自動的に格付に結びつけることはおそらくはできないのだらうと思います。どちらかという、もしかするとより広いリストアップを

することにこのモデルを使う、その後はあくまでも人間の目で格付なりあるいは絞り込みをしていくみたいなそういう使い方をするのか、それともある程度格付に紐付くような使い方をするのか、みたいなその使い方のところについては、よくよく誤解を排除することも含めて検討したほうがいいのかなというふうに思いました。というのは、ChatGPTが非常に話題になっていて、この人に答えを求める人が結構最近出てきてですね、そうではなくてこの人はオプションを出してくれるものなのだよ、ということが十分に理解されていないような気がするのです。万が一にもこのモデルがそういうような使いにならないように、という意味で申し上げた次第です。

○ 事務局

先生ありがとうございます。仰っていただいた通り、次年度は実務適用がメインではあるので、そのときには今アドバイスいただいた点を踏まえて具体化できればと思っています。ありがとうございました。

○ 研究会委員

ありがとうございます。今までの先生方の議論も含めて、非常に納得的で、いつも申し上げていることですが、やっぱり人の目でないと峻別できないことはあって、こうしたデータでしっかり AI で把握できることもあれば、普通に見ればわかるだろう経営者の服装が突然派手になったとか、どう考えても病んでいるとか、そういうことって突発的で確率は低いけれども、何か起こっている可能性は非常に高い、っていうようなことってあると思うのです。やっぱりそういうことに関してはいくつかの金融機関様にヒアリングされて、この項目の中に、ちょっと人の目で見るべきものとしてのサンプルみたいなものを、次の中では入れてみて、そういうのを追ってみるとというのが一つ有効なのではなかろうかなというふうに思いました。

あともう一つですがこのカスタマイザビリティのところなのですけれども、実務者の方が利用しやすいようにアウトプットをカスタマイズしていくっていうのは浸透させるという意味では非常に有用な反面、その原理原則の分析結果のところは金融機関さんによって変わってしまう、みたいなことがあってはあんまり良くないと思うので、それを金融庁様が横串でデータを見る際にも、ある程度あるところまでは共通の AI の分析結果が出ていて、それを A という金融機関さんではこう解釈して前向きに対処しました、B という金融機関さんはこういうふうに考えてある意味ちょっとホールド的な対処をしました、とかそういう結果を残していくことも大事な気がするのです、その根幹の部分は、やはり、アウトプットのユニバーサル化というか、共有化みたいなところは、逆に揺るがさない方がいいのではないかなという。これは思想というか、そもそものこのプロジェクトの立ち位置の決め方みたいなことだと思うのですけれども、ちょっとそこはあまりぶれないように考えられた方がいいのではなかろうかというふうに思いました。以上でございます。

○ 事務局

ありがとうございました。そうですね実務適用すると、どうしても現場のご意見に触れて、当初と少しずれちゃうということはあるかと思うので、コメントを踏まえ、次年度に取り組んでいければと思うのですけれど、ありがとうございました。

それでは先ほど実証事業先に協力いただいた委員の方々ご説明いただきましたけれども、実際全体通してコメント等いただければとは思っています。

○ 研究会委員

最終的に説明変数を見た中で、お客様といかにコミュニケーションを取っていくかというところが重要だと思います。例えば、外部要因変数のエネルギー消費量という項目があって、そこがスコアに効いていると資料で見取れても、実際現場の職員がそれをどう会話に活かしていったかというところがわからないものですから、財務変数はある程度理解して話ができるのかなと思いますが、その点も実務適用においては課題であると思いました。

○ 研究会委員

私は基本的には今まで出たような内容なのですけれども、ちょっと別の視点で言いますと、データの取り込みと算出ですか、実際に作業していく上で今どういうふうにデータを読み込ませていくのかというのが、金融機関側の作業イメージが湧かないので、そこの方の説明を一度お願いしたいと思います。

○ 事務局

ありがとうございます。実際にこれを使うときに、どういうふうなデータを集めてどうやってこのモデルに適用すればいいか、そういうところですか。

○ 研究会委員

そうですね。

○ 事務局

はい、わかりました。そちらも今回はですね、データとしては我々の方で全てハンドリングしてスコアを出したということですが、実際使う場合は、金融機関さんの方で、データも入手してやるということかと思います。必要なデータとしてはこちらにお示したようなこういった情報が、説明変数で使われているような情報が必要ですね。まずは財務の情報ですね。あとは定期的に外部環境変数もアップデートして、所定の場所に保存いただくということで、自動的にスコアが出るというような形になります。こちらについても次年度、実務

適用のところで、どうやってデータの管理とかするのとかかですね、そういったところはご議論させていただければなと思っている次第です。ありがとうございました。

○ 研究会委員

先ほど次年度以降の方向性のところでやっぱり感じたのですけれども、やはり皆様がコメントされているようにテキスト情報ですね、このところをどれだけ取り込めるかというところでだいぶ変わってくるのかなという印象を持っています。それから、あともう一つ資金繰りというキーワードが出てきていると思うのですけれども、先ほどの現預金というような言葉もありましたけれども、確かに現預金のところの水準もですね、銀行としてはかなり見ている一つの指標ですので、その辺のところも取り込みながら、モデルの精緻化というかですね、高度化ができたかなというふうに感じております。以上です。

○ 事務局

そうですね、次年度はテキスト情報とか自社の預金、あと自社の融資額は日々当然取れるかと思うので、そういうのを入れ込むと足元の状況、決算書とは違う新しい情報が盛り込まれますので、そんなものも取り込んでいけたらなと考えている次第です。ありがとうございました。

○ 研究会委員

課題の棚下しと次年度に向けた方向性は色々具体的に出てきているので、今後こういったところの課題を組み入れていくと、また楽しみなデータが出てくるかなと思っています。その中でやはり定性情報ですかね、どうやって取り込んでいくかということもありますけれど、定性情報を金融機関の職員がどうやって取っていくかということのも、ある意味いいところを取りだけになっても変なデータになってしまいますし、その辺の目線合わせも今後必要になってくるかなと思いました。以上でございます。

○ 事務局

ありがとうございました、承知いたしました。

○ 研究会委員

委員の方が報告いただいたところと被りますので、あと先ほど委員の方からも指摘があったとおり、経営改善支援と一口に言っても、確かにいろいろ濃淡がありますよねということです。ハンズオンで経営改善計画を作りました、その後の予実管理をやりました、ということ、会社のいわゆる自主的な経営改善の一つの方向性を与える、というようなそこまでも指すのかとか、それ以外の経営支援と言ってもいろいろ、究極的にはファイナンスも含めていろいろあるかと思えますけれども、その辺の深度・濃淡によってやっぱり結果に相当差

異が出るというところも、考慮に入れていただければと思います。

○ 事務局

ありがとうございました。はいそうですね、今回はまるっとやっているの、どんな具体的な支援かも含めてですね、検討は視野に入れていますので、ありがとうございました。

○ 研究会委員

私も今日総括的に感想めいたことを言わせていただくとすれば、非常に皆さんベクトルが合ってきて、これは使えるなという感じがしておりまして、先ほどの繰り返しになりますが、既に経営支援の手を差し伸べていただいている金融機関さんのご担当者に関しては、これはどうでもいいわけでございまして、いかに漏れがないかというところ。ここがやっぱりAIを使ってやっていく、人の目と手の判断で、というところだと思います。今日もテキストに関するコメントありましたけれども、今日やっばご議論を拝聴しているとですね、月次の決算データとか決算データというところを金融機関さんにご活用いただいているのですけれども、むしろですね、金融機関さん内部に蓄積されているデータというところのほうが、より現場に近かつ実態を反映しているかなというところもあるのではないかな、と逆に気づかされまして、ぜひもう来年の課題は出ていますけれども、このあたりぜひ金融機関さんと協力しながらやらせていただければありがたいかなと思っております。以上でございます。

○ 事務局

ありがとうございました。全委員の方々からコメント頂戴しまして、はい、ありがとうございます。いただいたご意見を踏まえると、やはりテキストデータですね、あと追加的な情報、構造情報、非構造含めてですけれど、そういったものがポイントということで、一旦この方向性としては記載があるので良いのかなというふうに思っています。実務適用する上での課題もいくつかの委員の方でコメントいただいていますので、一部ちょっと記載ぶりが曖昧な部分があるのでその部分についてはより具体的に書いて方向性として取りまとめていけたらなと思っています。

また、技術的な部分としては、より高度なモデルの検討とかっていうような形に留めていきますので、その反映は次年度にも含めてはいるものの、具体的にアドバイスいただいたのでそこはちょっと具体的に書きながら、こんな高度化ができないかということで取りまとめさせていただければと思っています。ただ全体的な方向性としては大きく違和感のないようなコメントだったのかなと理解していますので、一部修正しますが、今いただいた、ここに記載の方向性としては大きく乖離はないのかなと委員の先生方ですね、実務家の方々、AIの専門家、あと大学の教授の方々からいただいたのは大きく相違がないのかなと思っていますので、ここに記載の内容を次年度取り組んでいって、より有意義なものにでき

たらなど考えております。ありがとうございました。概ね同意ができたのかなと思っておりますのでこちらの方向性で来年度も引き続きやれればと考えています。

(以上)