

AIを活用した金融の高度化に関する
ワークショップ
(第3回「信用評価」)

【共同研究】

「入出金情報を用いた信用リスク評価」

2019年2月18日
日本銀行 金融機構局
金融高度化センター
三浦 翔



Bank of Japan



共同研究

「入出金情報を用いた信用リスク評価」

本共同研究は、りそな銀行様にデータをご提供頂き、CRD協会様よりモデル構築・データ加工等でご協力頂いております。また、統計数理研究所・山下教授、武蔵野大学・山中准教授からのご助言をもとに研究を行っております。

なお、本稿に示されている意見は、筆者個人に属し、日本銀行並びに所属する各組織の公式見解を示すものではありません。また、ありうべき誤りはすべて筆者個人に属します。

ワークショップにおける本研究の位置付け

- 実務では、与信先の信用力の変化を察知するなどの目的で、RM(渉外担当)が経験則に基づき、担当先の預金口座の残高や入出金の動きなどを目で見えて評価することが行われてきた。
- しかし、与信ポートフォリオ全体の信用評価に口座情報を用いるためには、情報量の多さのため、モデルやシステムなどによる評価が必要となる。
- 足元では、金融機関におけるデータ整備やコンピュータ性能の向上等により、大量の情報・データを処理・分析できる環境が整いつつある。
- そこで、本研究では、入出金情報を用いた与信ポートフォリオ管理において、「AI(機械学習)による適切な信用評価が可能か」という分析を通じたAI活用の検証を行った。

共同研究

1. 本研究の問題意識
2. 分析データ・モデル
3. 分析結果

共同研究

1. 本研究の問題意識
2. 分析データ・モデル
3. 分析結果

本研究の問題意識

① 中堅中小企業の信用力変化の予兆^(※)指標創出

- 大企業を中心とした上場企業には、株価など参照する予兆指標が存在し、リスク管理のモニタリングに活用されている。
- 一方、中堅中小企業には上記のような広く使われる予兆指標が存在せず、リスク管理の高度化余地がある。
- また、多くの金融機関では、大企業を中心として大きな与信を実行している先には、ヒアリング等を通じ、できるだけ早期に信用力変化を捕捉しようというインセンティブが働く。
- 一方、与信額の小さな中堅中小企業に対し、担当者がヒアリング等を頻繁に行い信用力変化を捕捉することは高コスト。

⇒ 中堅中小企業に対する予兆指標を創出し、モニタリングへの活用を行いたい。

(※) 本分析では、「デフォルト発生の数か月前の時点でデフォルト発生を正しく予測できること」と定義。

本研究の問題意識

② 財務以外の情報を用いた信用リスク評価

(ア) 財務データ(情報)の信頼性

- 中堅中小企業においては、会計知識が十分でない担当者(経営者)が作成した計数であったり、場合によっては改竄された計数の可能性もあり、財務データの信頼性が十分でない(信用評価に十分でない)場合がある。

(イ) 即時性

- 決算は1年あるいは四半期に一度などの頻度で更新され、タイムリーな信用力評価の観点では、タイムラグを含んでいる場合がある。

⇒ 財務以外の情報をもとに、中堅中小企業の予兆指標を創出できないか？

問題意識の検証案【データ編】

- 当問題意識から、以下の要件を満たす予兆指標の算出を目指したい。
 - A) 株価等のマーケットの情報でなく、(非上場の)中堅中小企業でも算出可能な指標であること
 - B) 計数に作成者の知見や意図が入り込む余地がなるべく少ない指標であること
 - C) タイムリーに算出可能な指標であること
- 上記要件を満たす指標として、預金口座の入出金データをもとにした信用評価指標の創出を企図する。

問題意識の検証案【モデル編】

- 入出金データは明細数(入出金の取引回数)が多く、抽出される情報量も多いため、指標を多く取り込む必要があり、機械学習のモデルが有効と考えられる。
- これまで信用評価モデルとして広く用いられてきた統計モデル【ロジットモデル】を用いると、適切なモデルが構築できない(モデル精度が大きく落ちる?)のかを併せて検証したい。
- そこで、取り込める指標数が多く、自由度の高い機械学習モデルに加え、従来のモデル構築アプローチ(※)を用いてモデルを構築し、モデルの精度比較を行う。

(※) 単指標のAR値や指標間相関などをもとにした指標選択によって採用候補を絞り込み、ロジットモデルに適用した場合の精度をもとに最終的なモデルを決定する手法。

共同研究

1. 本研究の問題意識
2. 分析データとモデル
3. 分析結果

分析概要

➤ 使用するデータ(入出金及び格付データ)

- ✓ 中堅中小企業の2014/10～2018/5(44ヶ月分)の入出金情報、及び、対応する格付(デフォルト含む)データを使用。(※)本分析では要管理先以下への格下げをデフォルトと定義。
- ✓ 約8,000件(うちデフォルト約1,400件)の債務者データを抽出。トレーニングデータとテストデータに2分割し、パラメータのチューニングを実施。
- ✓ 各モデルの精度は、月次の債務者ポートフォリオ全体(以下、運用シミュレーション)におけるAR値によって検証する。
- ✓ 入出金データは、月次で摘要グループ(詳細後述)で集計した指標をベースとし、前月・前年比、標準偏差などの加工を行った指標と併せ、約6,000指標を採用候補とする。

➤ 使用するモデル

- ✓ ランダムフォレスト・勾配ブースティングツリーといった機械学習モデルに加え、ロジットモデルを使用する。

データ整備：入出金データ

➤ 入出金情報(摘要コード)の整理

- ✓ オリジナルの摘要コードは項目数も多く複雑なため、「入払区分」および「摘要内容漢字」から10個の「摘要グループ」を作成する(摘要グループは定性判断にて集約)。
- ✓ 入出金データに加え、預金残高(月中平残)を用いる。

No.	大項目	摘要グループ	概要
1	入金	売上	振込、でんさい、外為、など
2		投資	投資信託など
3		融資	融資
4		入金その他	カードなど
5	出金	原価	でんさい、送金、振込、など
6		変動費	カード、税金、など
7		固定費	光熱費、NHK受信料、など
8		返済	貸利息、返済、保証料、など
9		投資	投資信託など
10		不渡	不渡など
11	預金残高	預金残高	預金口座の残高(月中平残)

データ整備：入出金データ

- 前頁「摘要グループ」ごとに、金額及び件数(入出金回数)を月次集計して指標を作成。
 - ✓ 入出金情報は、直近24ヶ月(2年)分を使用。
- また、上記指標に加え、モデル精度向上を企図し、指標を「売上高」などで除した基準化(規模の情報を落とす)、前月比や前年比、期間合計・期間標準偏差など、各加工により指標バリエーションを追加。
 - ✓ 全体の指標数は、5,989指標を使用。

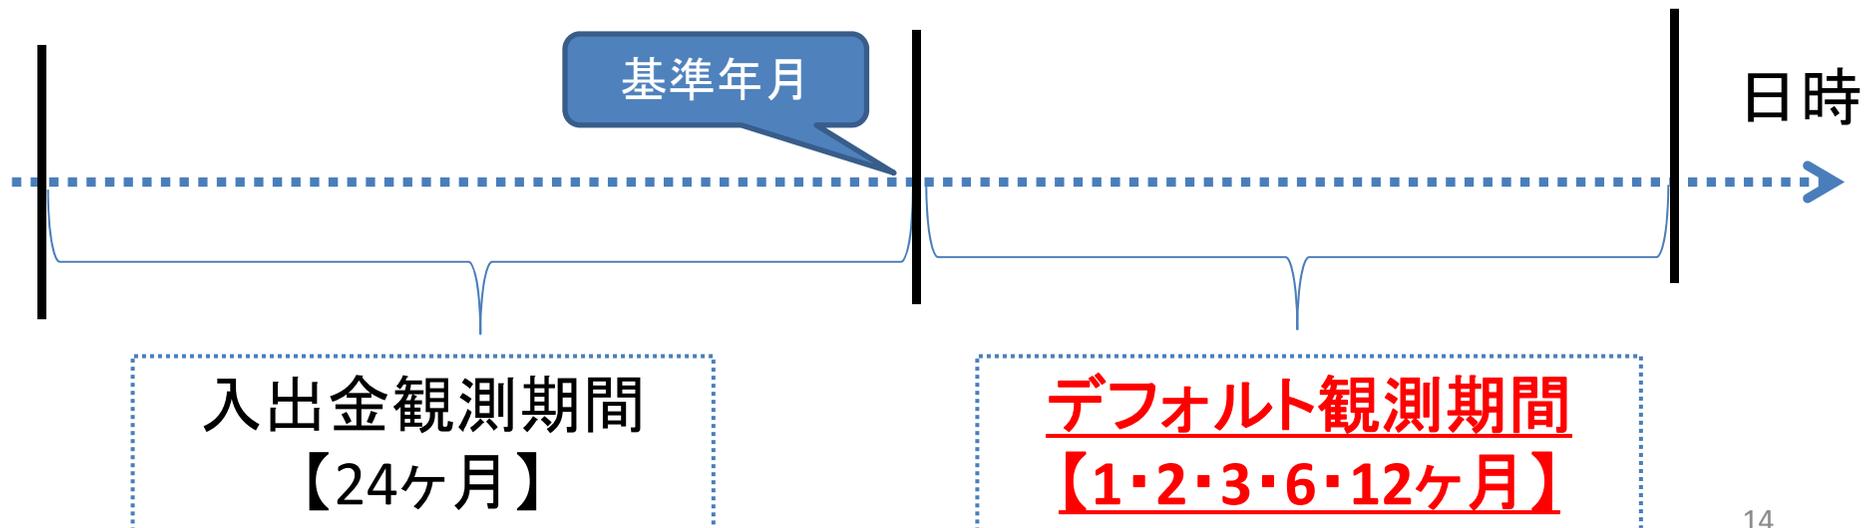
index	指標数	概要
①	3	売上高、総資産、与信残高
②	984	入出金の月中合計(金額、及び、回数)
③	2,952	②/①で計算される指標
④	943	各指標の前月比
⑤	492	各指標の前年比
⑥	615	期間合計・標準偏差、期間合計の前年比など
合計	5,989	

月次の集計値だけでなく、様々な指標バリエーションを検証。
以下、「カテゴリ」と記載。

データ整備：入出金データとデフォルト観測期間

- 入出金データに対し、内部格付の時系列データ(デフォルト含む)の情報を紐付けし、分析用データを作成。
- 基準年月(入出金データ締め時点)からデフォルト観測期間に幅を持たせ、各期間におけるデフォルト発生をモデルにて予測。予兆管理指標としての有効性を検証。
 - ✓ 本分析では、デフォルト観測期間(以下、リスクホライズン:RH)を1・2・3・6・12ヶ月間の5パターンを設定。

【想定する入出金、及び、デフォルトの観測期間】



モデル概要

- 使用する指標が多いため、機械学習のモデルを採用。
また、ロジットモデルも採用し、モデル精度の比較検証を行う。

モデル	特徴
ランダムフォレスト	<ul style="list-style-type: none">➤ サンプル及び指標をランダムに抽出し、多数の決定木を独立に生成する手法。➤ (比較的)過学習しにくいモデル構造。
勾配ブースティングツリー (XGBoost)	<ul style="list-style-type: none">➤ 決定木を作る際に、それまでに作られたすべての決定木の結果を利用し、逐次的に決定木を構築していく手法。➤ 過学習しやすい傾向があるため、クロスバリデーション等を用いてパラメータをチューニングする必要がある。
ロジットモデル	<ul style="list-style-type: none">➤ 現在、信用評価モデルで最も広く採用されている統計モデル。➤ 指標のスコア化を行い、ステップワイズで指標選択・モデル構築を実施。➤ 過学習しにくいモデル構造。

モデル評価指標：AR値

- 「デフォルトと非デフォルトの債務者について、信用スコアがどの程度正しく序列付けられているか」を評価する指標として、AR値が広く用いられている。

	信用スコア①	信用スコア②
高	○	○
	○	○
	×	○
	○	×
	×	○
低	○	×

↑信用力
↓信用力

○：非デフォルト、×：デフォルト

左表の例では、信用スコア②の方がデフォルト先の信用力に低い序列を与えており、AR値が高い(①:0.25<②:0.75)。

- AR値は1以下の値を取り、値が大きい程、その信用スコアがデフォルトを正しく判別・予測していると解釈できる。
- 但し、対象とする母集団によってAR値の水準は異なり、企業規模が大きい程水準が高いとされている。
 - ✓ 一般的な財務スコアリングモデルの水準として、中小企業のAR値は0.6程度あれば十分な水準とされている。

共同研究

1. 本研究の問題意識
2. 分析データとモデル
3. 分析結果

単指標分析

- モデル構築に際し、AR値を用いた単指標分析を実施。
- 各摘要グループ別の上位20指標の平均値は下表の通り。
 - ✓ 「預金残高」のデフォルト判別力が高い。続いて、出金返済、入金売上、出金原価、出金変動費、などが高い傾向。
 - ✓ デフォルト観測期間(リスクホライズンRH)が長いほどAR値の水準は低下し、直感と整合的な結果。

カテゴリ (摘要グループ)			AR値				
			RH: 1M	2M	3M	6M	12M
1	入金	売上	0.2740	0.2662	0.2388	0.2089	0.1825
2		投資	0.0729	0.0981	0.0928	0.1098	0.1075
3		融資	0.2208	0.2182	0.2213	0.2116	0.1935
4		入金その他	0.2213	0.1733	0.1720	0.1613	0.1535
5	出金	原価	0.2521	0.2427	0.2217	0.1930	0.1633
6		変動費	0.2401	0.2357	0.2157	0.1834	0.1593
7		固定費	0.2347	0.2334	0.1945	0.1784	0.1702
8		返済	0.3302	0.3137	0.3065	0.2758	0.2644
9		投資	0.0329	0.0225	0.0174	0.0174	0.0166
10		不渡	0.0319	0.0223	0.0179	0.0093	0.0061
預金残高(月中平残)			0.4942	0.4782	0.4705	0.4497	0.4191

データ分析：単指標分析

- 全5,989指標中、最もAR値が高い指標は「預金残高」、及び「預金残高を加工した指標」。下表は、各RHにおける上位5指標のAR値を記載したもの。

AR 順位	カテゴリ	AR値				
		RH:1M	RH:2M	RH:3M	RH:6M	RH:12M
1	預金残高	0.5460	0.5289	0.5209	0.4978	0.4621
2	預金残高	0.5313	0.5163	0.5028	0.4837	0.4516
3	預金残高	0.5296	0.5096	0.5012	0.4832	0.4515
4	預金残高	0.5288	0.5088	0.5012	0.4718	0.4401
5	預金残高	0.5182	0.5075	0.4902	0.4706	0.4384

- 預金残高(及び預金残高を加工した指標)を除いた上位は、
下表の通り「出金返済」の指標が多い。
✓ 全体順位はデフォルト観測期間が長い程低下する傾向。

RH:1M		RH:2M		RH:3M		RH:6M		RH:12M	
順位	カテゴリ	順位	カテゴリ	順位	カテゴリ	順位	カテゴリ	順位	カテゴリ
28	出金返済	38	出金返済	36	出金返済	62	出金返済	34	入金融資
49	出金返済	46	出金返済	49	出金返済	78	出金返済	66	出金返済
50	入金その他	53	出金返済	64	出金返済	79	出金返済	77	出金返済
60	入金その他	69	出金返済	71	出金返済	81	出金返済	82	総資産
65	出金返済	76	出金返済	73	出金返済	85	総資産	83	入金融資

モデル構築結果①(ランダムフォレスト)

- ランダムフォレストを用いて、チューニングパラメータ(決定木の数、指標ユニバース数)を変更したときのテストデータにおけるAR値は下表の通り。
 - ✓ 今般の試算(下表はRH:3ヶ月の結果)では、決定木の数が350、指標ユニバース数が150のときにAR値最大(0.7070)。
 - ✓ 指標ユニバース数を大きくすると、やや過学習の傾向。

【テストデータのAR値(縦軸:木の数 / 横軸:指標ユニバース数)】

	50	100	150	200	250	300	350	400	450	500
50	0.6627	0.6796	0.6767	0.6812	0.6718	0.6857	0.6830	0.6786	0.6761	0.6752
100	0.6772	0.6953	0.6951	0.7013	0.6951	0.6907	0.6895	0.6892	0.6915	0.6914
150	0.6930	0.6983	0.6981	0.6970	0.6992	0.6970	0.6888	0.6940	0.6871	0.6844
200	0.6962	0.7055	0.6975	0.6976	0.6960	0.7029	0.6883	0.6935	0.6882	0.6936
250	0.6978	0.6985	0.7014	0.6967	0.7019	0.6952	0.6953	0.6971	0.6958	0.6935
300	0.7000	0.6988	0.6990	0.6977	0.6985	0.7031	0.6920	0.6973	0.6915	0.6880
350	0.7007	0.7014	0.7070	0.7041	0.6963	0.7009	0.6974	0.6971	0.6927	0.6982
400	0.7021	0.7040	0.7020	0.7025	0.7005	0.6985	0.6965	0.6957	0.6956	0.6906
450	0.7000	0.7059	0.7005	0.7034	0.7005	0.6996	0.6987	0.7001	0.6928	0.6931
500	0.6978	0.7061	0.7023	0.7011	0.7035	0.7006	0.6999	0.6971	0.6977	0.6959

モデル構築結果①(ランダムフォレスト)

- 前頁で最大AR値となった試行パターンにおける指標重要度は、下表の通り。
 - ✓ 上位20指標中、17指標が「預金残高」。他は「出金返済」が3指標と、重要度の高い指標のカテゴリが限定的。
 - ✓ 下表には記載がないが、「預金残高」・「出金返済」以外の指標の最上位は「与信残高」の85位。

重要度 順位	カテゴリ	Mean Decrease Gini	比率	累積比率
1	預金残高	20.05	1.0%	1.0%
2	預金残高	17.86	0.9%	1.9%
3	預金残高	15.89	0.8%	2.7%
4	預金残高	14.95	0.7%	3.4%
5	預金残高	14.00	0.7%	4.1%
6	預金残高	13.76	0.7%	4.8%
7	預金残高	13.57	0.7%	5.5%
8	預金残高	12.59	0.6%	6.1%
9	預金残高	12.42	0.6%	6.7%
10	預金残高	11.93	0.6%	7.3%

重要度 順位	カテゴリ	Mean Decrease Gini	比率	累積比率
11	預金残高	10.69	0.5%	7.8%
12	預金残高	10.13	0.5%	8.3%
13	出金返済	9.87	0.5%	8.8%
14	出金返済	9.39	0.5%	9.3%
15	預金残高	8.90	0.4%	9.7%
16	出金返済	8.70	0.4%	10.1%
17	預金残高	8.59	0.4%	10.6%
18	預金残高	8.47	0.4%	11.0%
19	預金残高	8.02	0.4%	11.4%
20	預金残高	8.00	0.4%	11.8%

(※)上記表では、預金残高以外の指標をハイライトしている。

モデル構築結果②(勾配ブースティング)

- 勾配ブースティングを用いて、チューニングパラメータを変更したときのテストデータにおけるAR値は下表の通り(※)。
 - ✓ 今般の分析(下表はRH:3ヶ月の結果)では、決定木の深さが4、学習率 η が0.01のときにAR値最大(0.7329:ランダムフォレストに優位)。
 - ✓ 決定木の深さを大きくすると、過学習の傾向。

【テストデータのAR値(縦軸:木の深さ/横軸:学習率 η)】

	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1
1	0.6521	0.6641	0.6676	0.6755	0.6677	0.6685	0.6737	0.6668	0.6721	0.6671
2	0.7123	0.7165	0.7118	0.7106	0.7115	0.7087	0.7155	0.7140	0.7093	0.7100
3	0.7266	0.7261	0.7225	0.7246	0.7211	0.7254	0.7205	0.7249	0.7150	0.7227
4	0.7329	0.7263	0.7297	0.7183	0.7241	0.7228	0.7210	0.7231	0.7126	0.7194
5	0.7181	0.7186	0.7163	0.7177	0.7139	0.7107	0.7067	0.7003	0.6973	0.6977
6	0.6977	0.6999	0.6941	0.6941	0.7030	0.7060	0.6884	0.6999	0.7019	0.7012

(※)AR値最大となるパラメータ設定(決定木の深さ4・学習率 η 0.01)における決定木の数(反復回数)は、クロスバリデーションにて500回としモデル構築した。

モデル構築結果②(勾配ブースティング)

- 前頁で最大AR値となった試行パターンにおける指標重要度は、下表の通り。
 - ✓ 上位20指標中、「預金残高」が8指標で、最多は「出金返済」の10指標。他にも複数のカテゴリの指標が上位。
 - ✓ ランダムフォレスト対比でAR値の上昇が確認されたが、下表の通り、より多くの指標の情報を取り込むことにより、モデル精度向上が果たされていると考えられる。

重要度 順位	カテゴリ	Gain (比率)	累積比率
1	預金残高	17.7%	17.7%
2	出金返済	8.4%	26.0%
3	預金残高	5.4%	31.4%
4	出金返済	4.6%	36.0%
5	預金残高	3.6%	39.6%
6	出金返済	2.4%	42.0%
7	預金残高	2.0%	44.0%
8	預金残高	2.0%	46.0%
9	出金返済	1.9%	47.9%
10	出金返済	1.7%	49.6%

重要度 順位	カテゴリ	Gain (比率)	累積比率
11	出金返済	1.5%	51.0%
12	預金残高	1.3%	52.3%
13	出金返済	1.0%	53.4%
14	出金原価	0.9%	54.3%
15	出金返済	0.9%	55.2%
16	出金返済	0.9%	56.1%
17	与信残高	0.9%	57.0%
18	預金残高	0.8%	57.8%
19	出金返済	0.7%	58.5%
20	預金残高	0.7%	59.2%

(※)上記表では、預金残高以外の指標をハイライトしている。

モデル構築結果(ロジットモデル)

- ロジットモデル構築に際し、単指標AR値や上記2モデルの指標重要度をもとに指標の採用候補を検討。
 - ✓ 各指標のスコア化を行い、AR値の上昇を確認している。
- 様々な指標組合せを試行し、ステップワイズ(指標減少法)で最適な組合せを探索。結果、採用される指標数は20 (RH:3ヶ月の結果。採用候補32指標から選択)であった。

番号	カテゴリ	係数	Std.Error	z.value	Pr(> z)
0	(切片項)	5.342	0.393	13.602	0.000
1	出金返済	-1.070	0.066	-16.140	0.000
2	預金残高	-0.446	0.060	-7.445	0.000
3	出金返済	-0.376	0.056	-6.730	0.000
4	預金残高	-0.346	0.081	-4.244	0.000
5	預金残高	-0.520	0.129	-4.034	0.000
6	預金残高	0.539	0.145	3.717	0.000
7	預金残高	-0.207	0.057	-3.623	0.000
8	預金残高	-0.278	0.080	-3.460	0.001
9	預金残高	-0.436	0.128	-3.416	0.001
10	与信残高	-0.564	0.169	-3.345	0.001

番号	カテゴリ	係数	Std.Error	z.value	Pr(> z)
11	預金残高	0.304	0.093	3.279	0.001
12	出金返済	-0.276	0.086	-3.200	0.001
13	預金残高	-0.207	0.085	-2.429	0.015
14	出金原価	-0.292	0.123	-2.368	0.018
15	出金返済	-0.238	0.105	-2.264	0.024
16	預金残高	0.250	0.111	2.256	0.024
17	預金残高	0.311	0.143	2.176	0.030
18	預金残高	-0.342	0.167	-2.051	0.040
19	預金残高	-0.171	0.085	-2.005	0.045
20	預金残高	-0.155	0.082	-1.893	0.058

(※) 上記表では、預金残高以外の指標をハイライトしている。

モデル構築結果(運用シミュレーション)

- 運用検証のシミュレーションとして、中堅中小企業の全与信先ポートフォリオに適用した場合のAR値を算出し、下表を得た(Ar値は直近12ヶ月間の平均値)。
 - ✓ いずれのモデルにおいても、デフォルト観測期間が長くなるとAR値低下傾向。但し、0.7~0.8弱といずれも高い水準。
 - ✓ 機械学習のモデルでは、勾配ブースティングがランダムフォレスト対比でやや優位な結果。
 - ✓ 機械学習対比、ロジットモデルはやや劣後する水準だが、水準自体は0.65~0.75程度と、一般的な財務スコアリングモデルと比較しても相応の水準を有すると考えられる。

モデル	デフォルト観測期間(RH)				
	1M	2M	3M	6M	12M
ランダムフォレスト	0.7749	0.7578	0.7482	0.7429	0.7166
勾配ブースティング	0.7876	0.7797	0.7728	0.7377	0.7244
ロジットモデル	0.7432	0.7558	0.6777	0.6728	0.6509

モデル構築結果(メイン・非メイン別)

- メイン取引先^(※)と非メイン取引先でモデルの予測精度に差分が生じているか検証した。
(※)メイン取引先は、「直近一年間の入金売上合計がPLの売上高の30%以上を占める先」と定義。
- ✓ 運用シミュレーションデータにおけるメイン・非メイン別のAR値の差分は下表の通り。
- ✓ いずれのモデル・デフォルト観測期間においてもメイン取引先の方がAR値が高い結果。
- ✓ 但し、その差分(約0.03~0.07)は限定的で、非メイン先においても相応の水準を確保している。

ランダムフォレスト	デフォルト観測期間(RH)				
	1M	2M	3M	6M	12M
メイン	0.7835	0.7980	0.7848	0.7563	0.7542
非メイン	0.7622	0.7347	0.7259	0.7314	0.6866
差分	(+0.0213)	(+0.0633)	(+0.0590)	(+0.0249)	(+0.0676)
勾配ブースティング	1M	2M	3M	6M	12M
メイン	0.8150	0.8014	0.8067	0.7524	0.7468
非メイン	0.7760	0.7680	0.7490	0.7238	0.7012
差分	(+0.0390)	(+0.0334)	(+0.0577)	(+0.0287)	(+0.0456)

モデル構築結果（財務スコアリング計数の併用）

- 法人債務者の信用評価を定量的に行う際、財務スコアリングモデルが広く使われている。
- 当分析では、財務情報から計算されたスコアを指標候補とした場合の各モデルの精度向上を検証した^(※)。
 (※)本分析では、CRD協会様の財務スコアリングモデルを利用。
- ✓ 財務スコアを用いたときの運用シミュレーションにおけるAR値は下表の通り。各モデルにおいて、+0.1程度上昇。
- ✓ 勾配ブースティングやロジットモデルではAR値の水準が0.8台後半で、モデル精度としては極めて高い水準。

モデル	デフォルト観測期間				
	1M	2M	3M	6M	12M
ランダム フォレスト	0.8073 (+0.032)	0.8384 (+0.081)	0.8416 (+0.093)	0.8367 (+0.094)	0.8193 (+0.103)
勾配ブース ティング	0.8629 (+0.075)	0.8712 (+0.092)	0.8650 (+0.092)	0.8551 (+0.117)	0.8244 (+0.100)
ロジット モデル	0.8603 (+0.117)	0.8736 (+0.118)	0.8690 (+0.191)	0.8580 (+0.185)	0.8298 (+0.179)

(※)各セル下段()内の数字は、財務スコアを用いない場合との差分

モデル構築結果(まとめ①)

1. 入出金情報を用いた信用評価の分析結果

- 機械学習モデルを用いた結果、いずれのデフォルト観測期間においてもAR値が0.7以上と、予兆管理指標として十分に活用可能な水準。
- ロジットモデルは(精度向上の余地があるものの)機械学習モデル対比で相応の差が確認された。
 - ✓ ロジットモデルは、モデル精度は機械学習対比で低いが、AR値の水準自体が低いものではない(AR値0.65以上)。
- 運用面(モデル理解のしやすさ、指標の感応度などが分かりやすい)を勘案すると、ロジットモデルを採用・使用する、という判断も考えられる。

モデル構築結果(まとめ②)

2. メイン・非メイン別の精度比較結果

- メイン取引を行っている債務者は、非メイン対比でデフォルト予測精度が高い結果。
 - ✓ メイン取引先は、入出金情報の多くを捕捉可能なため、デフォルト予測精度が高いと考えられる。
- 但し、非メイン取引先においても相応の予測精度を確保している。
 - ✓ 費用対効果の面から、非メインの取引先に対してRMが電話・訪問等を行うモニタリングはコスト高。
 - ✓ 本予兆指標をモニタリングすることで、RMが担当先に電話・訪問等を行わずとも予兆管理が可能であるとする、モニタリング効率化の観点から、非メイン先に対する予兆管理指標としても重要と考えられる。

モデル構築結果(まとめ③)

3. 財務スコアリング計数の併用結果

- 財務スコアをモデルの指標に採用した場合、AR値が約0.1上昇。0.8台後半の水準と極めて高い予測精度を実現。
- 入出金情報のみでも予測精度として十分な水準（AR値0.7強）だが、財務情報を加えることにより、即時性と予測精度の両面を有する予兆管理指標となり得る。
- ✓ 中堅中小企業の財務情報は年に一度の更新であることが多く、信用力の変動をよりタイムリーに把握するためには、入出金情報を用いたモニタリングが有効と考えられる。

今般の分析で苦労した点【データ整備編】

- 入出金データは長期に亘って保存されているが、比較的容易に取得・利用できるのは足元のデータに限られており、データ抽出・加工の必要があった。
 - ✓ テキストで保存されている過去データを整備し、利用可能なデータベースに加工する作業等に工数を要した。
- 入出金情報特有のデータの前処理に工数を要した。
 - ✓ 「営業店のオペレーションを確認・把握する」、「傾向を捉えるために統計量を確認する」、「信用リスクの観点で意味のある値か検討する」等、様々な観点で検討を重ねながらデータ加工・計数作成を進める必要があった。
 - ✓ 大規模なデータを取り扱うため、モデル構築過程に入ってから予期せぬデータ不備が見つかることがあり、データ再作成まで立ち戻る必要が生じることもあった。
 - 一部データ項目が隣の項目値と統合され列数が異なる明細がある、データ加工の過程で数字が丸められている項目がある、など。

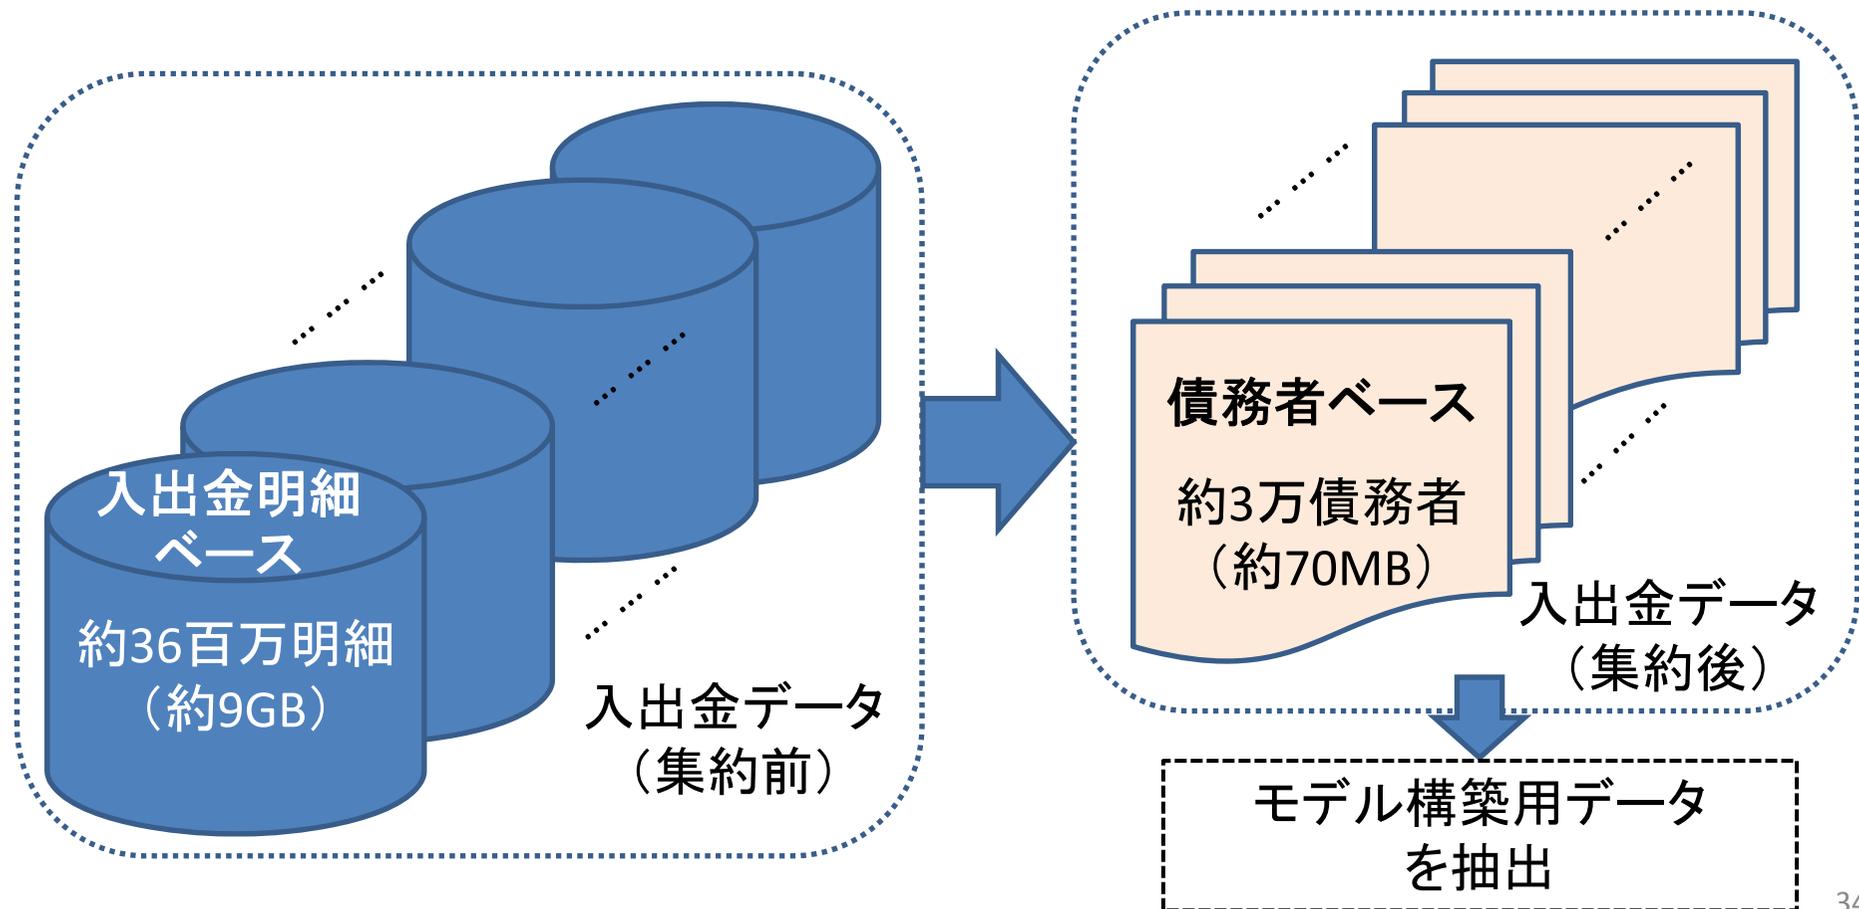
今般の分析で苦労した点【モデル構築編】

- 機械学習モデルは、パラメータのチューニングにトライ&エラーが必要。一度の計算時間も相応に要するため、最も時間的コストを要した。
 - ✓ 特に、ブースティングは過学習しやすい傾向にあるため、チューニングを丹念に行う必要があった。
 - ✓ 本分析は、(サーバ等は使用せず)デスクトップPCで実施。
- 一方、ロジットモデルは指標加工や指標選択などに工数がかかり、機械学習とは異なる観点でそれぞれに時間的コストが必要。
- 入出金情報は財務情報よりも高頻度であるため、財務スコアリングモデル構築では従来検討したことのないポイントを整理する必要があった(例:デフォルトフラグの立て方、など)。

ご清聴、ありがとうございました。

【補論】データの容量・規模感

- 使用する入出金データ(預金口座取引履歴データ)は、毎月約36百万程度の明細数(csvファイルで約9GB)。
- 債務者ごとに入出金項目の摘要グループ別に集計することによって、月次で約3万件程度の債務者情報に集約。



【補論】モデル概要①

- 決定木 (Decision Tree) とは、特定の指標によって集団を2分割することを繰り返し、デフォルト・非デフォルトをよりきれいに判別できる集団の条件を求める手法。
 - ✓ 決定木の特徴として、外れ値に強い・数値変数と離散変数 (カテゴリ) が混合したデータにも適用可能な点などがある。
 - ✓ 一方で、過学習しやすいという特徴もある。
- 上記の通り、決定木には「過学習しやすい」というデメリットがあるため、この点を補うための機械学習の手法・モデルが開発されている。
 - ✓ 基本的な発想として「一本の決定木ではどうしても過学習してしまうので、たくさんの決定木を集めて多数決で決めることによって予測精度を高める」ことを企図している。
- 今般の分析では、決定木をベースとした機械学習モデルとして、「ランダムフォレスト」及び「勾配ブースティングツリー」を試行。

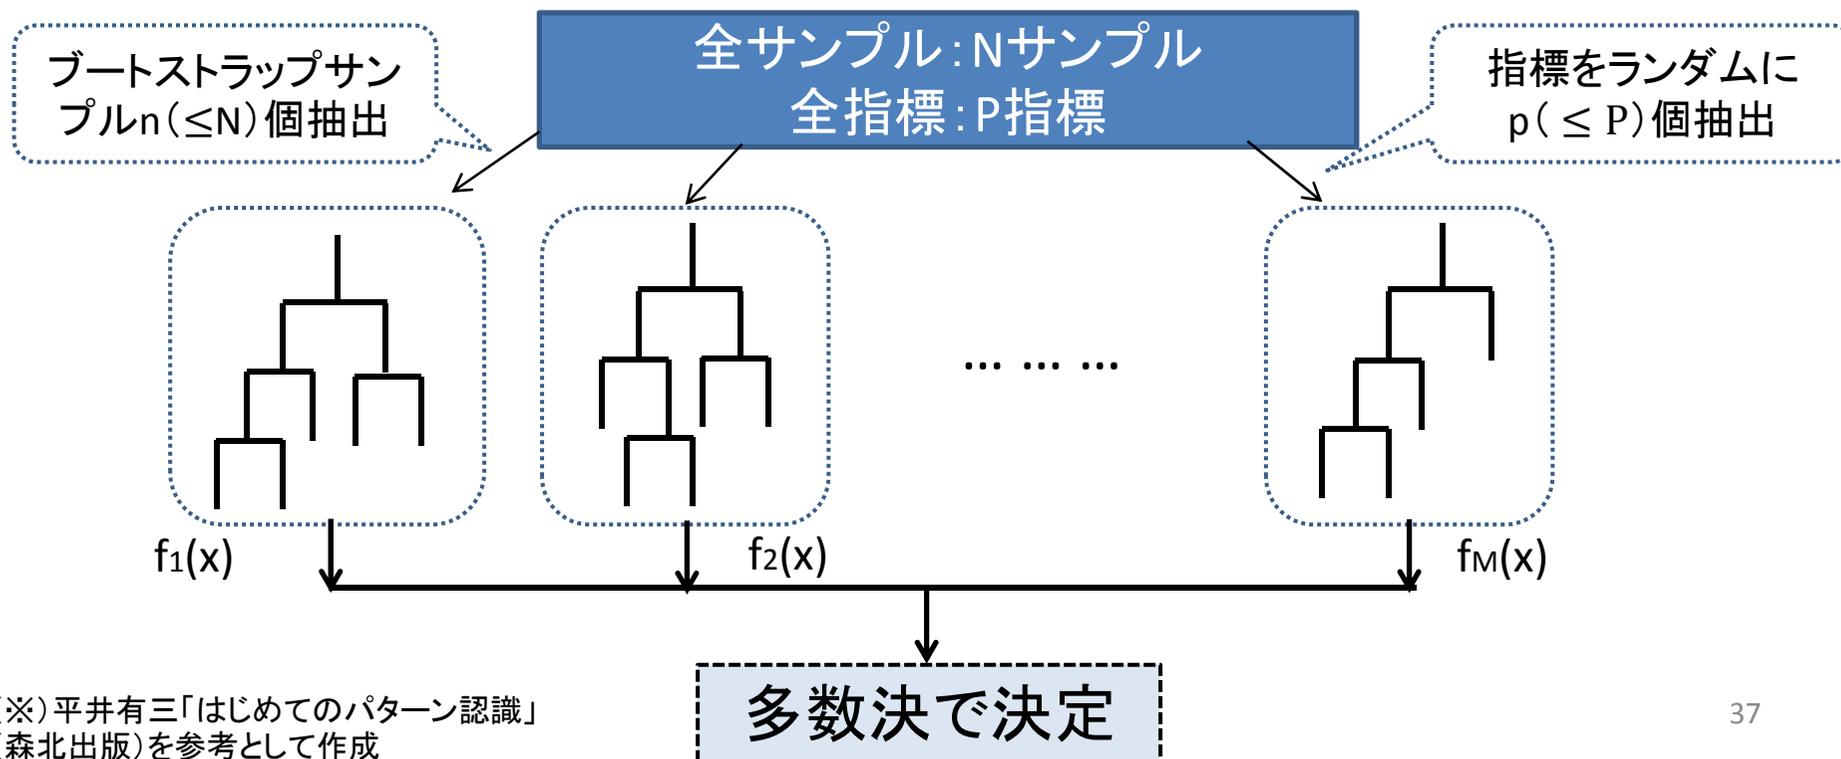
【補論】モデル概要②

- 「ランダムフォレスト」及び「勾配ブースティングツリー」は、いずれも決定木をベースにしたアンサンブル学習モデル。
 - ✓ アンサンブル学習とは、一つ一つでは「弱い(判別精度の低い)学習器(※)を組み合わせて強い(//高い)モデルを構築する」学習手法。(※)両モデルの弱学習器は「決定木」。
 - ✓ アンサンブル学習は、ランダムフォレストのように複数の弱学習器を独立に学習する『バギング』と複数の弱学習器を順番に学習していく『ブースティング』に大別される。
(バギング Baggingは、Bootstrap AGGregatINGの略語)
- 両モデルとも指標重要度を計算することが可能なため、各サンプルの予測値(デフォルト確率等)の説明が付きやすい。
 - ✓ 但し、ロジットモデルのような指標の「感応度」とは異なり、「各指標を用いて分類した場合、どの程度分類精度が向上するか」という観点から重要度の評価を行う。

【補論】ランダムフォレスト

➤ ランダムフォレストは以下①～③のプロセスを一定回数(以下ではM回) 独立に繰り返すことにより作成(概要)。

- ①: 全サンプルから、ランダムサンプリングによりサブサンプルを生成(ブートストラップサンプル)
- ②: 全指標から、一定の指標の数をランダムに抽出。
- ③: 指定したノード数に達するまで、サブサンプルを最も良く分類する指標及び閾値を用いて、決定木を構築。

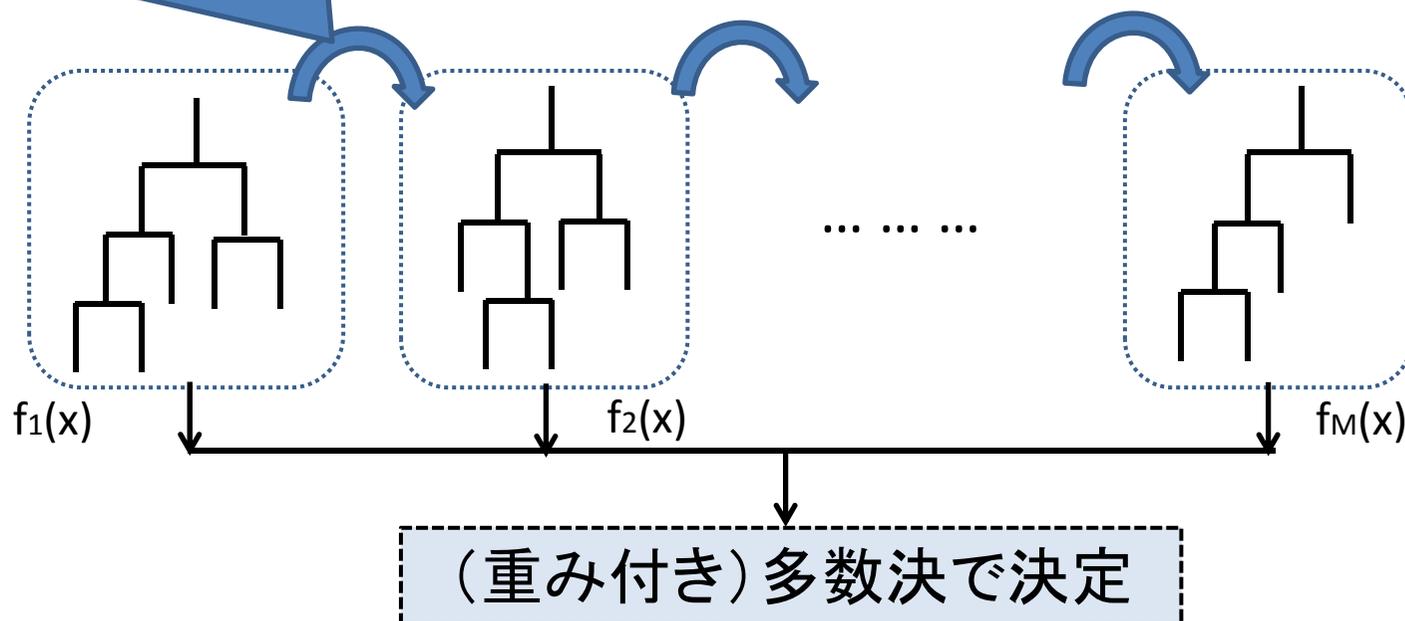


(※) 平井有三「はじめてのパターン認識」
(森北出版)を参考として作成

【補論】勾配ブースティングツリー

- 勾配ブースティングツリーは以下②・③のプロセスを一定回数（以下ではM回）逐次的に繰り返すことにより作成。
- ①: 初期値として、全サンプルに対し損失関数^(※)を最小化する値を設定。
 - ②: 各時点でのモデルの予測値と実績値の(疑似)残差を目的変数として、より残差を小さくする決定木を構築する。
 - ③: ②で作成した決定木の予測値を加算する。
- (※)分類の場合は「対数損失関数」が広く用いられる。本分析でも同損失関数を採用。

(疑似)残差を計算し、残差を最小化する方向(勾配)に決定木を構築する



本資料に関する照会先

日本銀行 金融機構局 金融高度化センター

三浦 翔

電話 03-3277-3081

email kakeru.miura@boj.or.jp

- 本資料に掲載されている情報の正確性については万全を期しておりますが、利用者が本資料の情報をを用いて行う一切の行為について、何ら責任を負うものではありません。