

日本銀行 金融高度化センターワークショップ

「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

AIを活用した信用評価手法の 現状とこれから



2019年2月18日



りそな銀行

1.クレジットスコアリングとは？

2.従前からの信用評価モデル

3.信用評価手法高度化への取り組み

4.AI活用に関する課題

- 統計的手法やデータを活用した信用リスク評価はクレジットスコアリングが中心。
- クレジット・スコアリング・モデルとは？

企業や個人の財務・属性情報等により信用リスク（デフォルトしやすさ）を点数化（スコア化）する仕組み

※ 元々は個人向けクレジットカードの申込可否を決定する為の審査基準

- クレジット・スコアリングを用いた銀行の実務例
 - ① 貸出審査
銀行がお金を貸出す際の審査
 - ② 債務者格付
貸出先の企業や個人の信用リスク（デフォルトしやすさ）をランク付

事業性資金融資の例

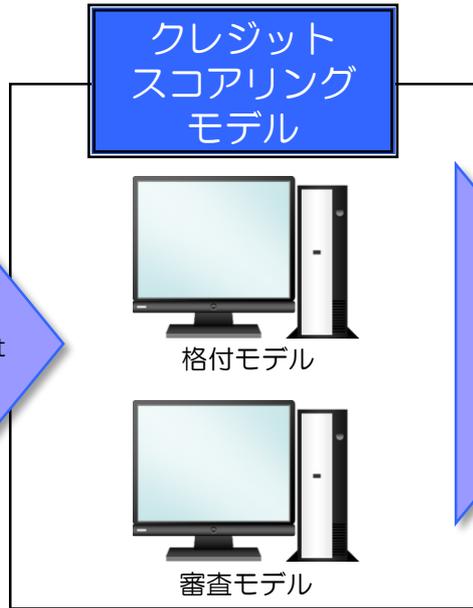
A社の情報

財務情報 (Balance Sheet)			
現預金	200	買掛金	200
売掛金	100	借入金	300
棚卸資産	200	資本金	400
土地建物	500	利益剰余金	100
総資産	1,000	総資本	1,000

財務情報 (Profit and Loss Statement)			
売上高	2,000		
営業利益	1,500		
経常利益	500		
当期純利益	100		

定性情報			
従業員数	200名		
設立	1993年		
業種	サービス業	etc...	

借入申込内容			
金額	1億円		
借入期間	5年		
担保・保証人	なし	etc...	



格付	
予想デフォルト確率	0.100%
格付	A格

貸出審査	
貸出可否	OK
貸出金利	0.80%

情報として利用することもある

審査：数時間から数日で回答

伝統的手法

「人」による審査

【メリット】

- ・ おおよそ正しい判断が可能

【デメリット】

- ・ ある程度経験が必要
- ・ 非常に時間がかかる
- ・ 審査担当者により「ゆらぎ」が生じやすい。

効率的に
信用リスクを
計測する方法で

クレジット スコアリング

「モデル」による審査

【メリット】

- ・ 人の目による恣意性がない
- ・ ユーザーの経験不問
- ・ 短時間

【デメリット】

- ・ 精度に課題

アメリカ（1990年前半）
Wells Fargo

日本（1998年）
東京都民銀行
（現きらぼし銀行）

● クレジット・スコアリングの利用状況

- ▶ 2002年頃からスコアリングによる貸出商品が増加
スコアリングモデル融資はピークで5兆円まで拡大

⇒ ところが、**想定以上の貸倒が発生**

- ▶ リーマン・ショック時、**格付の良い先からのデフォルト**が多発
⇒ スコアリングへの信頼感の揺らぎ
⇒ 法人向貸出におけるスコアリング貸出の規模縮小、撤退の動き
(消費性ローン、住宅ローン、法人格付モデルでは使用されている)

うまくいかなかった原因は？

▶ 従前から用いられているアルゴリズム

- ✓ ロジット・モデル
- ✓ 決定木 etc…

審査過程を単純化（モデル化）し、審査業務の効率化及び客観化が目的。

（参考）近年活用が広まっている機械学習アルゴリズム

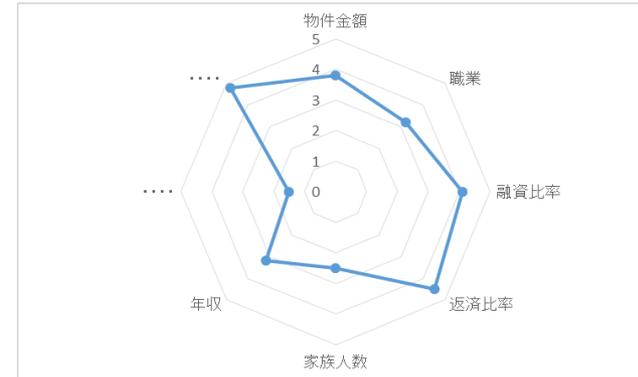
- ✓ ランダム・フォレスト
- ✓ ディープラーニング etc…

大量な情報を用い精度の向上を図る。人間が発見することができない複雑な関係を表現することも視野。

ロジットモデルを用いた審査モデル例

住宅ローンの例

項目	カテゴリー	点数	配点	項目	カテゴリー	点数	配点
物件金額	～1,000	10	10	家族人数	1	1	4
	～3,000	15			2	8	
	～5,000	10			3～4	4	
	～7,000	8			5	2	
	7,000超	4			6～	0	
職業	公務員	15	10	年収	～300万円	2	7
	会社員	10			300～500	5	
	自営業	4			500～700	7	
	会社役員	5			700～1,000	8	
融資比率	～70%	20	18	1,000～2,000	10	
	70%～80%	18			2,000～	7	
	80%～90%	10					
	90%～100%	8					
	100%～	0					
返済比率	0%～10%	15	14	スコア合計		97	
	10%～20%	14		予想デフォルト率		0.08%	
	20%～25%	10		貸出判定		可	
	25%～30%	5		優遇幅		1.50%	
	30%～	0					

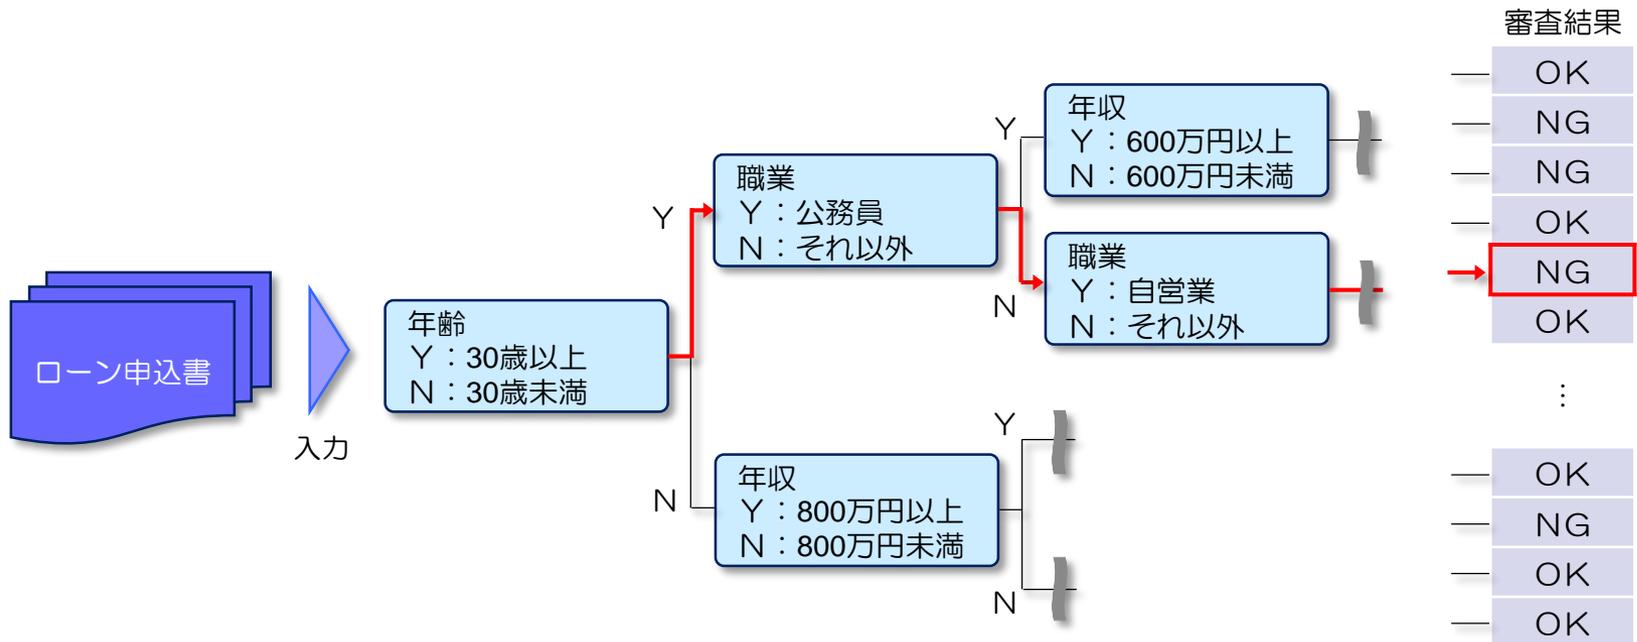


お客様の審査結果、諾否の理由が分かりやすい。

※計数は架空のものであり、実際のデータを分析した結果ではありません

決定木を用いた審査モデル例

カードローンの例



ロジットモデル同様、諾否の理由が分かりやすい。

● 融資審査における実用例



- ▶ 実務では、スコアリングモデルで審査が完結するものではなく、審査担当者が審査するお客様も存在する。
- ▶ 審査担当者は、経験（定性評価）を勘案し諾否を決定している。

目視審査の負担を減らすニーズあり

- ▶ 方法としては
 - ✓ 審査モデルの精度を向上させ目視審査の件数を減らす。
 - ✓ 目視審査の効率化のためAIを用いて審査を補助する。

- AI等を用いた信用評価手法の高度化が進行中。

2000年代前半のスコアリング貸出はなぜうまくいかなかったのか？

✓ スコアリングモデルが未熟

入力データは財務計数のみであることや、モデル構築技術も進展していなかったことから十分な精度がなかった。

✓ 定性分析を行っていない

決算書データのみ審査に用いていたため、業界分析や商流など審査に必要な分析を行っていなかった。

✓ 粉飾決算の可能性

借り手からすれば決算書を提出すれば貸出が可能であったことから、粉飾した決算書を提出するインセンティブが生じていた。

✓ 母集団の違い

モデル構築に使用するデータは人による審査を通り実際に貸出をしたデータを用いたが、審査対象のデータは人の審査をしていないことから母集団が異なる。

高度化に取り組んでいること

①非財務データの活用

口座入出金情報等財務計数以外の数値データの使用
文書データ等非構造データの利用
会計データ、SNS等の外部データの利用

②定性分析の補助

調査項目のデータを用いた自動化
ヒアリング事項のデータによる検証

③不正の排除

会計情報、口座入手情報を用いた粉飾決算の発見
循環取引等不正入出金データの発見

④顧客利便性の向上

非対面チャネル、スマホ完結
資金需要に則した短期融資

日本銀行等との共同研究結果活用事例

預金口座入出金データを用い信用評価を行う。

目的

- ✓ 大量に保有する口座入出金データを用いて信用評価に生かす
- ✓ 財務データでは発見できない要因を発見する
- ✓ 決算期のみではなく随時評価を行う

活用例

- ✓ 入出金データを用いた信用評価モデルを用いて「入出金格付」を付与（10段階 最高ランク10 最低ランク1）
- ✓ 月次での計測を行い、入出金格付け推移を観察

従来から算出

財務
格付
B格

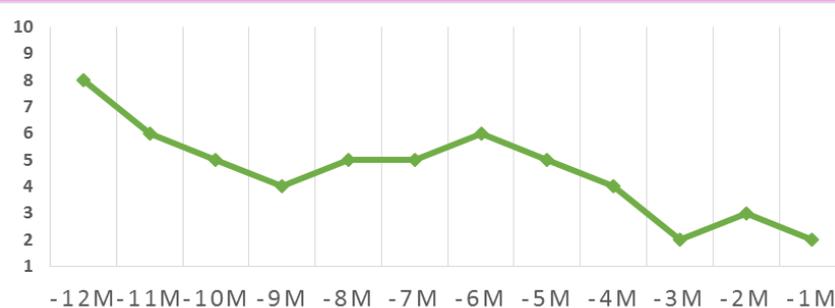


入出金
格付
2格

年1回

毎月

入出金格付の月次推移



従来から用いていた財務格付けを補完。直近の信用状況をモニタリング。

融資プロセスをオンライン化し、PCやスマホで融資申込プロセスが完結する融資手法。

オンラインレンディングの目的

顧客利便性の追求

- ✓ 来店や銀行員との面談が不要で、いつでも融資申し込み可能
- ✓ 提出書類がない、もしくは最低限
- ✓ 資金不足を銀行が予見しレコメンド。顧客の1クリックで融資が完結

オンラインレンディングは外部データの活用が可能となったこと、機械学習等データ分析手法が発展したことにより可能となったサービス。

オンラインレンディングの特徴

- ✓ **多種データの利用**
財務、口座入出金や外部データである会計、SNS等データを使用
- ✓ **大量データを使用**
機械学習等も導入し大量データを用いて審査

貸手のメリット

- ✓ 短期の貸出であり、**信用リスクが低減**できる。
- ✓ 人が介在しないため、**コストが削減**できる。
- ✓ 低コストで融資業務が可能であり、**融資対象企業の拡大**が図れる。
- ✓ 口座入出金情報等実際の取引に基づいており、**不正の余地が少ない**。

国内でサービスされているオンラインレンディング事例

企業名	類型	対象者	借入可能額 (万円)	借入期間 (カ月)	金利(%)
福岡銀行	提携型	営業エリア内のMFクラウド 会計利用企業	100-1,000	1-12	5.0-12.5
福井銀行			100-1,000	12(最長)	3.0-13.0
ジャパンネット銀行		ヤフーショッピング、ヤフ オクストア出店事業者	50-3,000	12(最長)	1.45-8.20
住信SBIネット銀行	自社型	中小企業など	50-3,000	12(最長)	1.999-7.999
アルトア		弥生会計利用者	50-3,000	12	2.8-14.8
J.Score	自社・ 提携型	個人	50-300	120(最 長)	0.8-1.2
アマゾン・キャピタル・サービス	プラッ フォーム 型	アマゾン出店事業者	10-5,000	3-6	8.9-13.9
楽天カード		楽天市場出店事業者	50-3,000	1-36	3.0-15.0
GMOイプシロン		GMOインプリオンの加盟店	30-5,000	6	3.5-12.0
リクルートファイナ ンスパートナーズ		じゃらんnet等の掲載事業者	10-1,500	73	2.0-14.9

出典：金融財政事情2018.11.19より一部抜粋・加筆

AIを活用した定性分析補助

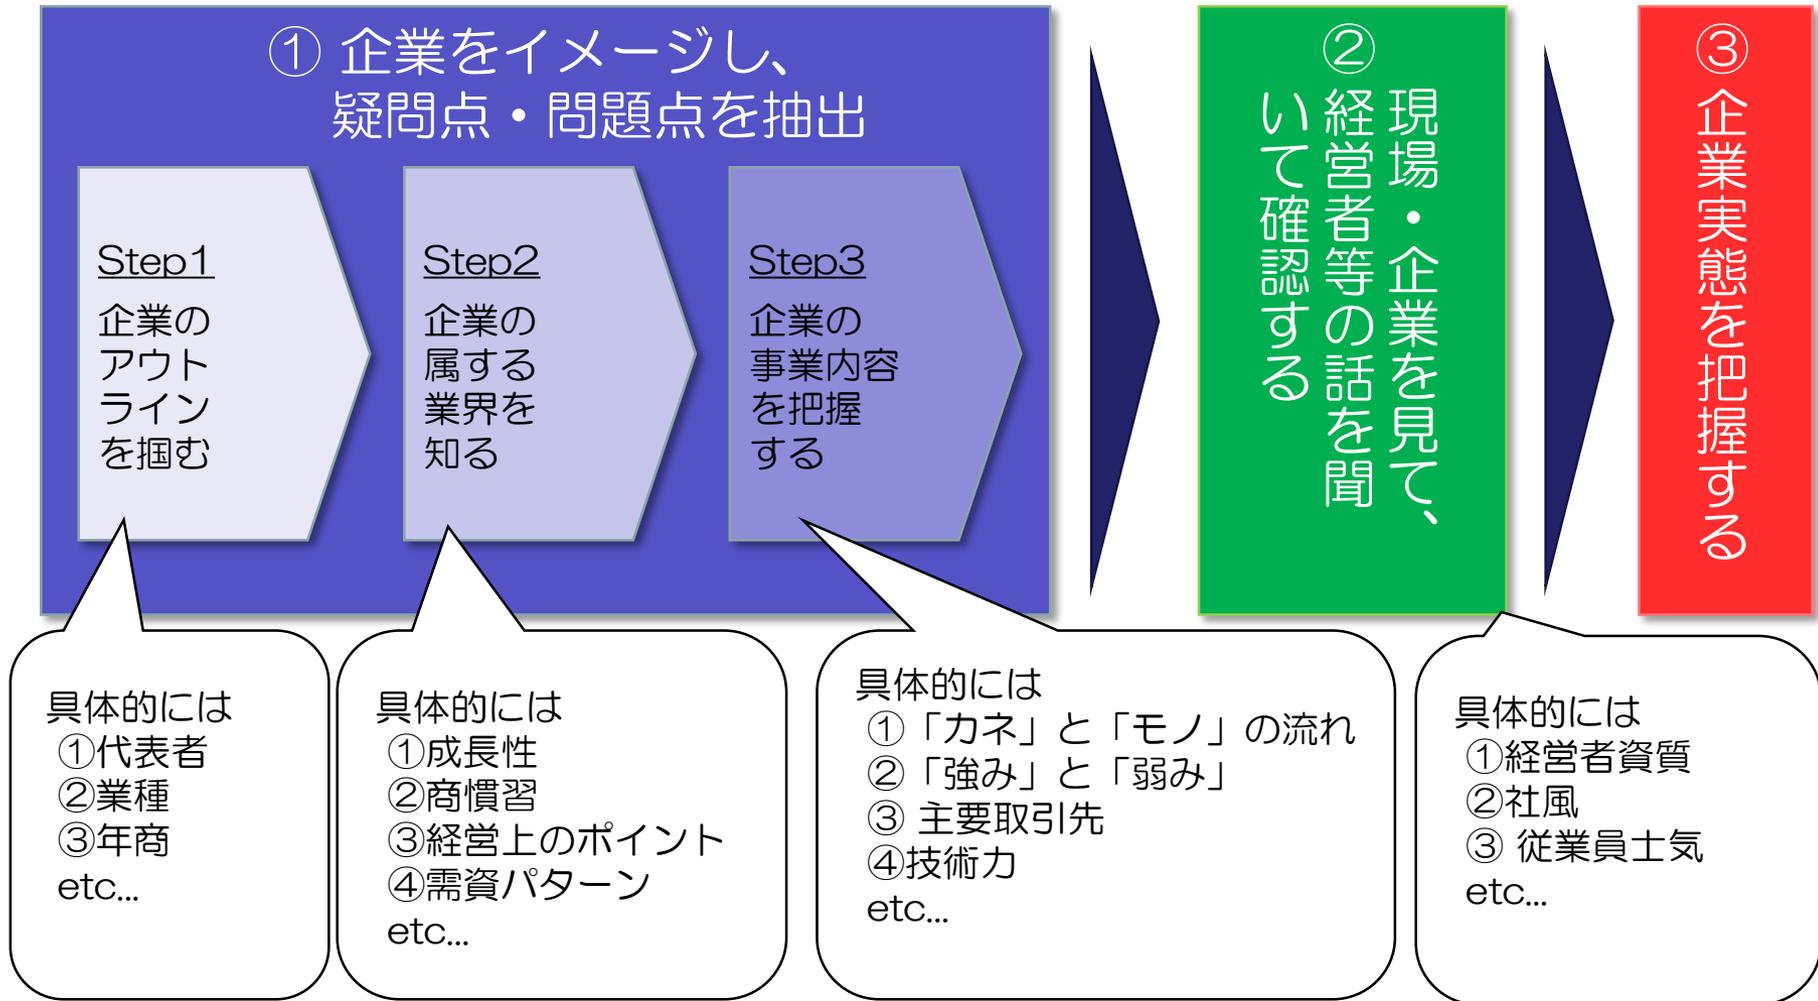
スコアリング融資は個人や小規模企業向けが中心であり、一般法人向けには活用されていない。

企業規模が大きくなるほど定性分析の重要性が高まり、過去のデータに依拠した従前のスコアリング融資では限界がある。

- 法人融資においては会社実権者へのヒアリングや業界動向、業況把握などに時間を費やしている。
- 定性分析を行うには、審査担当者が長年培ってきた知見・経験が必要。
(審査担当者はベテラン社員が担当しているケースが多い)

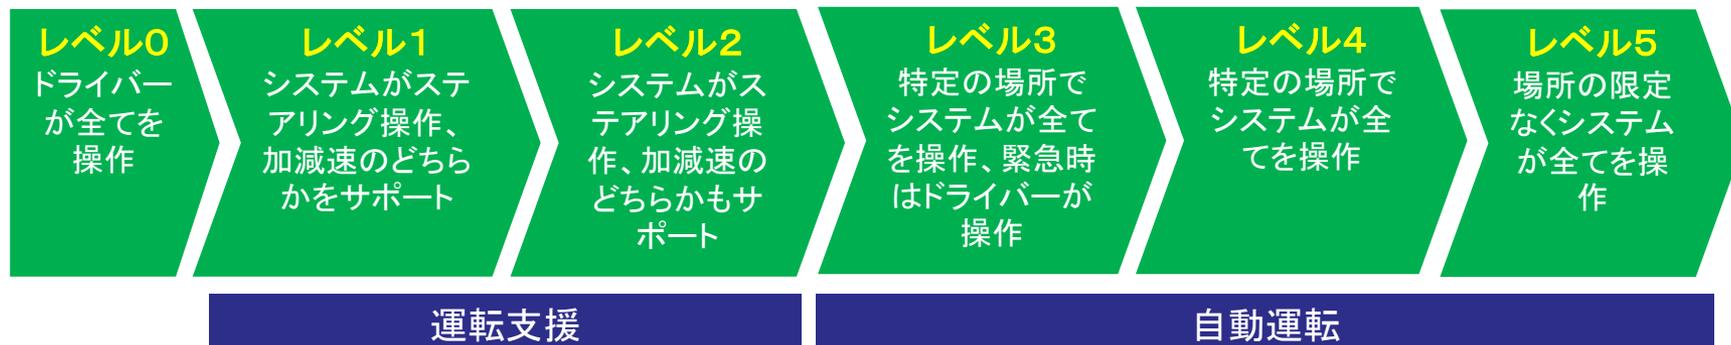
AIを用いた定性評価は難易度は高いが部分的に代替することは可能。
AIが得意な分野を見つけ代替にチャレンジしていく。

◆ 定性分析のステップ (法人)



自動車業界に目を向けてみると・・・

◆ 自動車の自動運転レベル



◆ 現状と目標レベル

レベル	内容	現状
レベル1	ステアリングアシストなど実用化	ほぼ実現
レベル2	高速道路運転など一部実用化	一部実現
レベル3	高速道路運転など一部実用化	一部実現、2020年実現目標
レベル4	海外メーカーで開発中	2020年一部実用化目標
レベル5	一部メーカーがコンセプトカーを発表	

金融分野においても一足飛びに考えるのではなく、自動運転レベルのようにステップを踏み、技術の進展を踏まえながら活用していくことが重要。

「レベル5」がすぐ実現すると思いがちであるが、簡単な話ではない。

貸出審査業務においてもレベルを設け、達成したいレベルを明確化し取り組んでいく必要がある。

◆ 自動審査レベル設定例

レベル	定義
レベル0	全て人が審査
レベル1	財務計数・審査に用いる指標をシステムで算出
レベル2	数値データを用いたモデルによる審査補助・一部自動審査
レベル3	ビッグデータ、非構造データを用いたモデルによる審査補助・一部自動審査
レベル4	一部の特殊な顧客を除いたほぼすべての顧客に対し自動審査
レベル5	全く人の判断は入らずにシステムで審査

◆ 現状と当面の目標設定例

レベル	0	1	2	3	4	5
個人(消費性資金)	現状					★
個人(住宅ローン)	現状				★	
小規模法人	現状				★	
中堅・大企業	現状			★		

◆ 定性分析のAIを用いた代替・補助案

項目	実施案
主要取引先	口座入出金明細、会計データ連携、Webサイト、決算書明細からリストアップ。
地域・業種動向	顧客との交渉履歴(CRM)から業種や地域の景況を把握する。 宿泊予約サイトから予約状況を入力する。 不動産サイトから賃貸物件の空室情報、家賃を入力する。
企業間ネットワーク サプライチェーン分析	入出金データ、受注・会計データから資金の流れを把握し企業ネットワークを構築。サプライチェーンの分析を行う。
評判、強み	飲食店であればSNSから店舗の評判、製造業であれば商品の評判を指標化。
リスク要因把握	ネット上のニュースから業況に影響を与えそうなニュースを抽出する。(因果関係をデータ化)
技術力	主要販売先から推測。
イベント検知	SNSから、企業の貸金未払発生やサービス品質低下などの情報を検知。

AIで代替可能な項目はAIで代替し、人は難易度の高い分析に集中することにより精度向上及び効率化を図る。

顧客の取引先の取引状況の変化を調査する

使用データ

入出金明細

振込・取立

会計情報

WEB

信用調査会社

社内審査情報



〇〇株式会社の主要販売先取引推移 月次入金額 (万円)

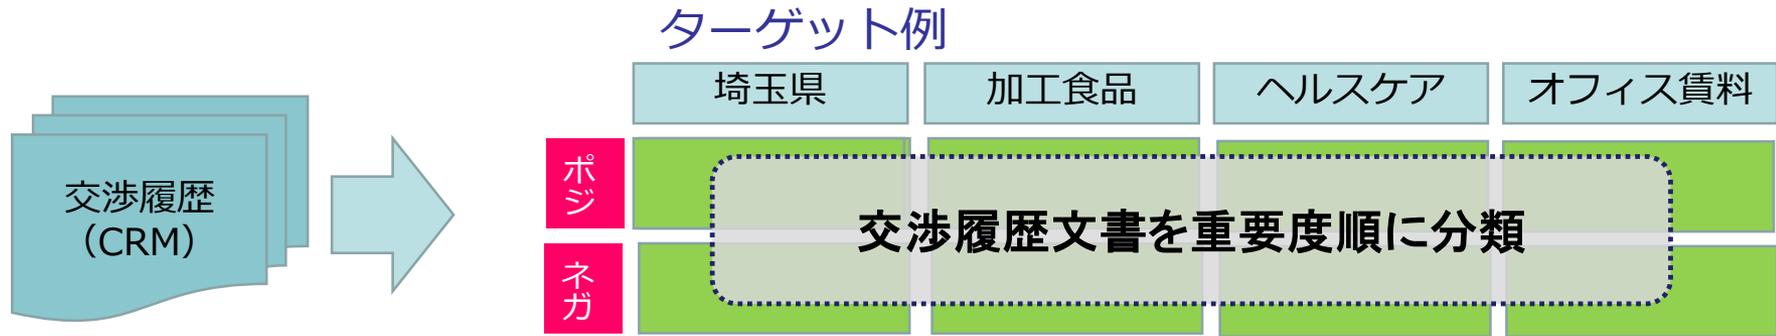
取引先	格付変動	1月	2月	3月	4月	5月	6月	・
A商事	A→A	100	100	0	0	0	0	
B商店	B→A	20	20	90	90	100	110	
C販売	B→B	10	12	10	25	2	20	
D商事	A→A	0	0	20	10	3	0	
...								

売上入金額推移	問題なし
主要取引先の変動	要チェック
主要取引先の信用力変化	問題なし

確認すべき事象が検出されれば通知

<事例 4>

主要営業エリアや特定業種などターゲット（評価軸）を設定し、ターゲットに対する景況感が記載されている交渉履歴文書を抽出する。



解析にはKibit等の自然言語処理AIを用いることができる。
Kibitは株式会社FRONTEOが開発した自然言語処理の人工知能エンジン。

営業担当社員がお客様から入手した「生」の声を有効活用する

<事例 5>

文書データを活用した地域景況インデックスの算出

沖縄銀行・三井情報・東京大学・琉球新報社によるPoC

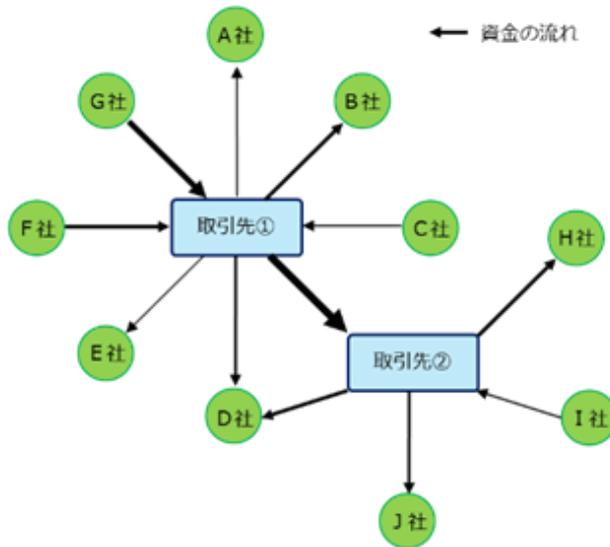
交渉履歴を用いて因果関係を分析することにより、企業やその周辺にどのような影響を及ぼすかを明らかにする。

出典：沖縄銀行WEBサイト

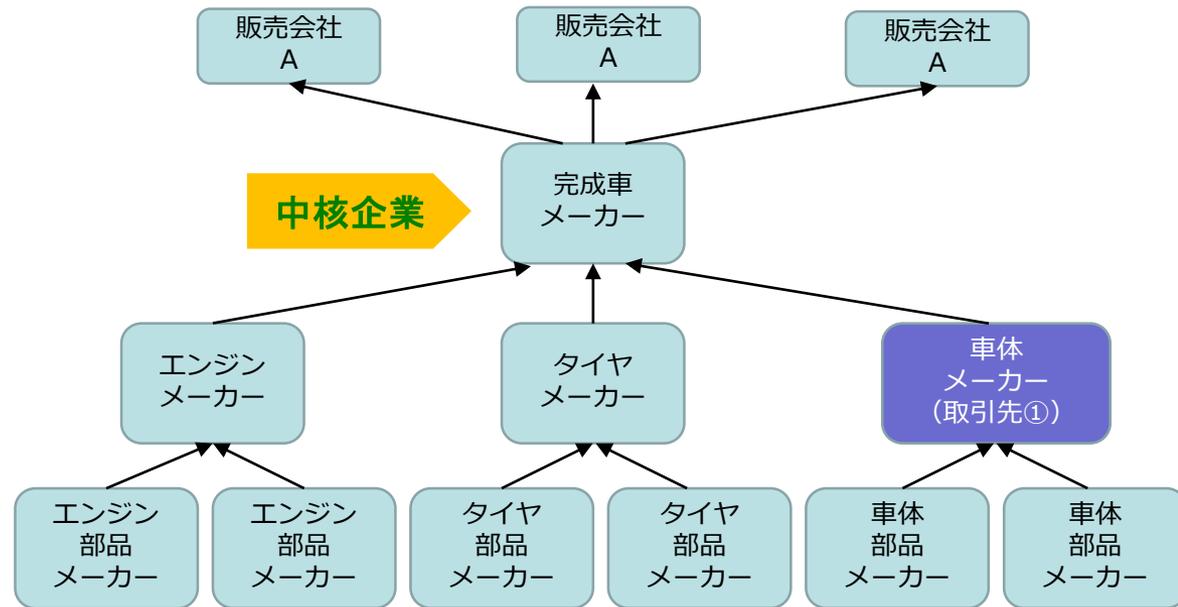
https://www.okinawa-bank.co.jp/news_release/2017101000028/

口座入出金情報や会計情報を用いて、企業間取引ネットワークを構築し、サプライチェーンの把握や、特定の企業が破綻した場合の影響調査に活用する。

企業ネットワーク



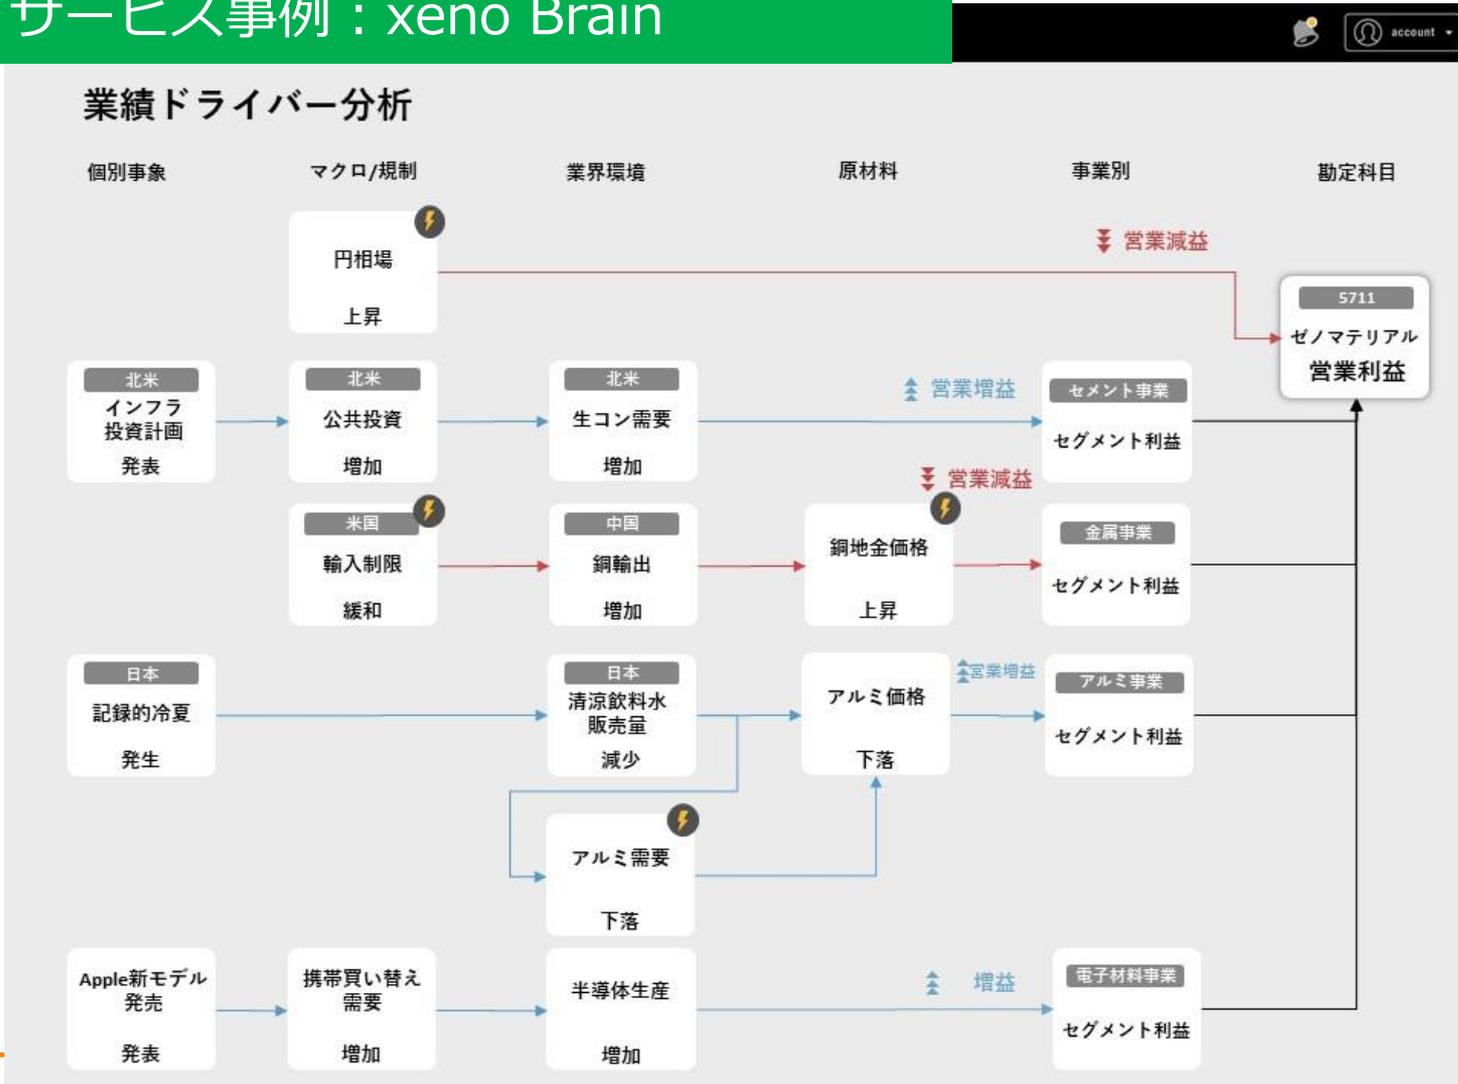
サプライチェーン



<出典> 「実践 金融データサイエンス」三菱UFJトラスト投資工学研究所から抜粋。一部加筆

ニュースから因果関係を抽出し企業に影響を与えるリスク要因を分析する

サービス事例：xeno Brain



出典：xenodata.lab

SNS書き込みを解析し、取引先に係る注意すべき情報を抽出する。

SNS書き込み例

A社のお弁当食べたけど、前よりまずくなった。変な肉使ってるんじゃないの？もう買うことはないかな。

この前、〇〇で家電を買ったんだけど、店員が最悪。商品知識が全くない。前もそうだった。社員教育どうなっているのだろう。

〇〇アパートに住んでいるんだけど、冬は寒いし、隣の部屋の声は聞こえるし、手抜き工事なんじゃないの？

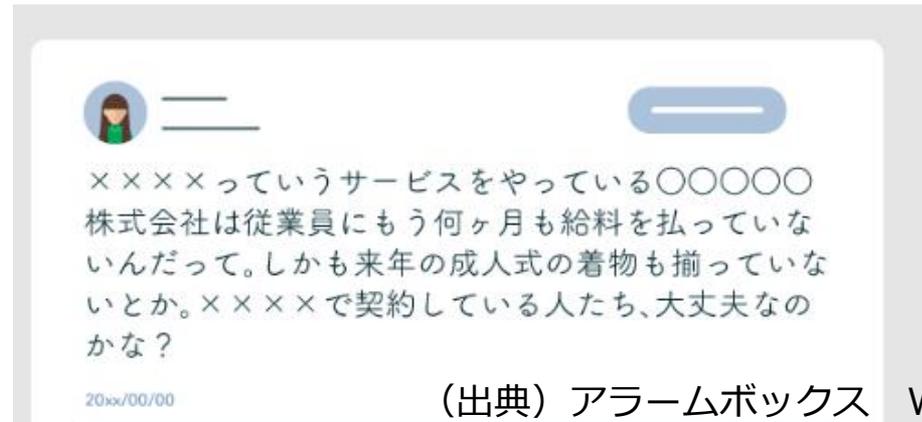
サービス事例：アラームボックス

倒産事例1

半年以上前からアラームが出ていた晴れ着のレンタル会社

ニュースでも話題になった晴れ着レンタルの会社。成人式当日にレンタルした着物がなく問題になりました。また、一般消費者だけでなく企業間でも代金未払いを起こしていましたが、インターネット上などでは以前から経営状態の悪化を示唆する情報がありました。

※情報はイメージです。



(出典) アラームボックス Webサイト
<https://alarmbox.jp/>

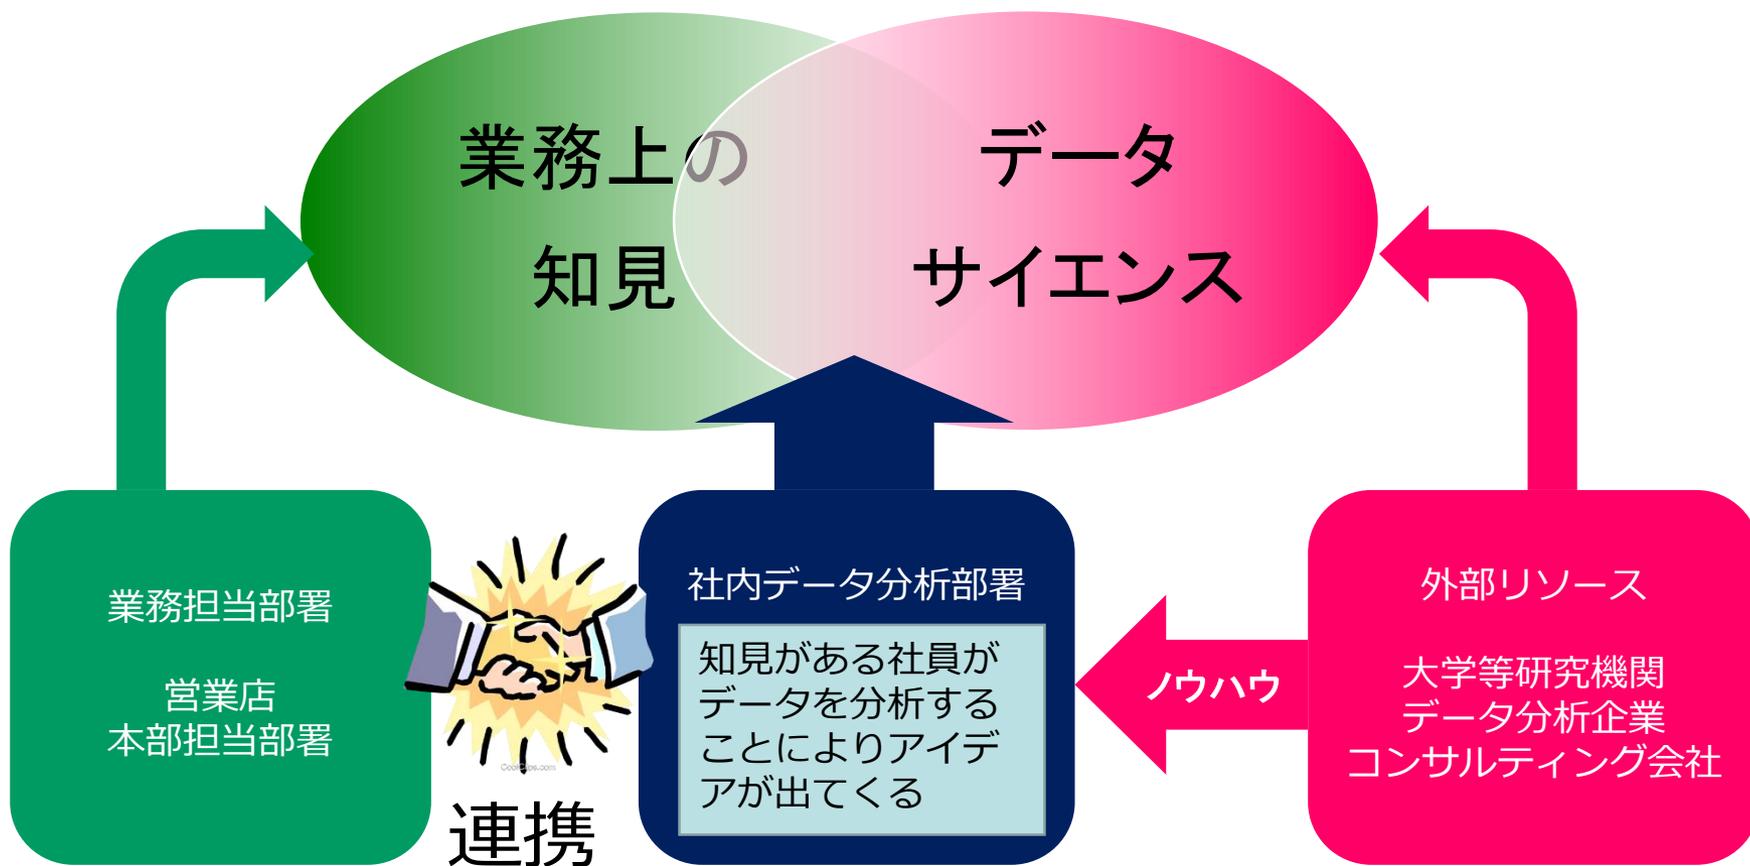
AI導入のパターン

パターン	事例	人的資源	費用
1	自社のデータを用い自社が中心となって開発 (内製化)	<事例1>口座入出金ス コアリングモデル	高度なスキルのある人材が必要 導入：大 運用：小
2	ベンダーの知見を活用し、自社データでモデル構築	<事例6> 企業間ネットワーク (ローン審査モデル)	AIの知見がある人材が必要 導入：中-大 運用：中
3	ベンダーが開発したAIを用いるが、自社でパラメータを推定	<事例4> 交渉履歴分析 Kibit (ワトソン)	AIの知見がある人材の在籍が望ましい 導入：中 運用：小-大
4	ベンダーからSaaS等で提供され契約すればすぐに利用可能	<事例7> Xeno Brain <事例8> アラーム ボックス	必要なし 導入：小 運用：小-大

- ✓ パターンにより、必要な資源（ヒト・モノ・カネ）が異なるのでどのパターンの開発なのかを認識したうえで取組む必要がある。
- ✓ パターン1、2は導入コストは大きいが他社との差別化が可能
- ✓ 人的資源の確保が困難な場合は、共同実施やコンサルティング会社への委託により代替することで対応可能な場合もある。

推進体制

過去の経験から人に蓄積された知見、先端のデータサイエンスが必要
双方の知見がある社内のデータ分析部署が重要な役割を担う



金融分野での活用の難しさ

◆ 社会科学分野への適用の難しさ

自然科学分野や囲碁・チェスといったゲームであれば、普遍的な真理や決められたルールの下での意思決定であるが、金融では人間の行動により結果が左右される。例えば東日本大震災のようなイベントや法令の改正によっても人の行動は変化することから、環境が時々刻々と変化する前提で考えなくてはならない。ビッグデータの活用においても過去のデータからの推論であり、環境が変わると予測は困難となることが想定される。さらには新モデル導入による行動の変化が要因となることもある。

◆ 原因となりうる事象の多様性

金融市場や景気動向、企業業績等は世界中での出来事に影響を受ける可能性があり、極端ではあるが、海外のある個人の行動や台風の進路等もが原因になり得る。すべてのデータをインプットすることは不可能なので、人間が重要性を判断し使用データを判断する必要がある。

限界・弱点を把握したうえで活用していく必要がある。

AI運営に関する課題

● ノウハウの蓄積

音声認識、画像処理等は金融機関以外でも用いられるAI技術であり、広く技術開発されている。その技術も公開されており、高度な技術が比較的簡単に利用可能である。

信用評価の分野においては、データが金融機関内に留まることから、ノウハウは社外に流出せず汎用的なモデルはない。

貸出業務は銀行の本業であり、AIを用いた審査ノウハウの蓄積及び伝承する体制を構築すべきである。

● 人員育成

AI審査ノウハウを社内で蓄積していくためには、「既製品」のAIを活用するノウハウだけでは十分ではなく、モデルを理解し改良できるスキルのある人材が必要である。

モデリング及び信用判断の知見が必要であり、双方の知見がある人材を育成していく必要がある。

AI運営に関する課題(つづき)

● ベンダーとの権利関係

モデル構築時にベンダーに委託するケースも多いと思われる。銀行及びベンダーの持つノウハウを活用しモデル構築を行うが、成果物の権利関係についても注意が必要である。

● モデルのブラックボックス化

審査モデルの高度化によりモデルがブラックボックス化しやすいが、審査結果に関しては諾否の理由を説明する必要がある。

データ活用に関する課題

● データの整理

社内データは分析できる状態にないことも多い。テキストファイルや、オフラインのストレージ、紙媒体での保存も多く分析可能なデータに整理する必要がある。

● データ加工スキル

データ加工、分析ができる人員の確保が必要。

データ分析をベンダーに依頼する場合でも、情報管理の観点からデータの抽出・加工は社内で行う必要がある。

● データの網羅性

AI活用には下記3軸の観点でデータを収集する必要がある。

1. データ項目：貸出の場合、金額、金利、期日などの項目が取得できるか？
2. データレコード：すべての取引（件数）が取得できるか？
3. 時間軸：過去何年間遡り取得できるか？

導入及び活用に関する課題

● PoCの成果

PoCを実施しても期待する成果が得られないケースもある。
成功率を高めるためには、データの質、AIの技術レベルを見極めることが重要。

PoCの結果が好ましくない場合、安易に諦めることなく原因分析をよく行えば有用な成果が得られることもある。

● PoCに対する評価

PoC実施の場合は実施前に評価軸を設定し共有しておかないと、実用化への意思決定ができにくい。

● 導入後の有効活用

導入後においても有効活用されないこともあり、強力な推進体制が必要。

PoC : Proof of Concept の略 概念実証

ご注意

本資料に示された意見は、発表者個人に属しりそな銀行の公式見解を示すものではありません。



RESONA

リスク統括部 金融テクノロジーグループ

荒川研一

03-6704-3851

kenichi.a.arakawa@resonabank.co.jp