

# 博士論文

営業活動における意思決定支援システム  
に関する研究

Study on decision-making support system in sales activities



東京大学大学院 工学系研究科  
先端学際工学専攻

氏名 37-157314 中山 義人

提出日 2020年12月1日

# 目次

---

第1章 序論 .....	1
1.1 本論文の背景と目的 .....	2
1.2 本論文の構成 .....	4
第2章 プロセスモデルに基づく 営業活動の意思決定支援 .....	7
2.1 はじめに .....	8
2.2 営業活動の意思決定支援システム .....	8
2.2.1 営業活動における意思決定の課題 .....	8
2.2.2 営業活動の結果を記録する営業日報 .....	10
2.2.3 営業活動の意思決定支援システムとは .....	11
2.2.4 営業活動の意思決定支援システムの現状 .....	13
2.3 プロセスモデルに基づく営業活動意思決定支援システムの構築 .....	14
2.3.1 プロセスモデルとプロセスマイニング .....	14
2.3.2 プロセスモデルに基づく営業活動意思決定支援システムの全体像 .....	16
2.3.3 従来のプロセスマイニングとの違い .....	17
2.3.4 関連研究 .....	19

---

2.4	営業活動におけるプロセスモデル構築の課題.....	22
2.4.1	営業日報における課題.....	22
2.4.2	顧客反応の抽出における課題.....	24
2.4.3	プロセスモデル構築の2つの課題.....	24
2.4.4	(参考)プロセス抽出後のプロセスモデルの作成.....	25
2.5	むすび.....	26
第3章	営業日報メールのアクティビティ分類.....	28
3.1	はじめに.....	29
3.2	営業日報メールのアクティビティ分類.....	29
3.2.1	アクティビティ分類とは.....	29
3.2.2	営業活動の標準アクティビティ.....	30
3.3	アクティビティ分類システムの構築.....	31
3.3.1	アクティビティ分類のアルゴリズム選定.....	31
3.3.2	評価データと訓練データの取得.....	33
3.3.3	LDA+熟練営業ノウハウによる分類システムの構築と評価.....	34
3.3.4	Doc2vec+SVM によるモデル構築と評価.....	35
3.4	アクティビティ分類の分類システム検証結果.....	36
3.5	むすび.....	36

---

第4章	プロセスモデルの構築と評価.....	38
4.1	はじめに.....	39
4.2	プロセスモデルの構築に向けて.....	39
4.2.1	プロセス抽出のモデル選定.....	40
4.2.2	営業活動意思決定支援システムの特徴とモデル選定.....	43
4.2.3	プロセスモデル構築のステップ.....	45
4.3	教師データの準備.....	47
4.3.1	教師データとは.....	47
4.3.2	案件シミュレータによる教師データの準備.....	47
4.4	部分観測マルコフ決定過程(POMDP)によるプロセスモデルの構築と評価.....	51
4.4.1	部分観測マルコフ決定過程(POMDP)によるプロセスモデル構築.....	51
4.4.2	隠れマルコフモデルと方策学習によるプロセスモデルの構築.....	54
4.4.3	部分観測マルコフ決定過程(POMDP)によるプロセスモデルの実適用評価..	57
4.4.4	意思決定支援システムの有効性に関する考察.....	66
4.4.5	(参考)行動変更を伴う案件の例.....	68
4.4.6	妥当性への脅威.....	74
4.5	深層強化学習によるプロセスモデルの構築と評価.....	75
4.5.1	深層強化学習によるプロセスモデルの構築.....	76

---

4.5.2	関連研究 .....	76
4.5.3	深層強化学習によるプロセスモデル構築ステップ .....	79
4.5.4	環境モデルの構築 .....	80
4.5.5	セルフプレイによる強化学習 .....	82
4.5.6	セルフプレイの実施過程 .....	84
4.5.7	深層強化学習のプロセスモデルの評価 .....	85
4.6	むすび .....	87
第5章	結論 .....	89
5.1	本論文の主たる成果 .....	90
5.2	今後の課題と展望 .....	91
5.2.1	能動学習(人間参加型機械学習)によるリコメンド精度向上 .....	91
5.2.2	サブゴールの設定によるリコメンド精度の向上 .....	92
5.2.3	アクティビティリストの柔軟な変更 .....	93
5.2.4	営業活動以外の分野への適用 .....	93
謝辞	.....	95
参考文献	.....	96

# 図目次

図 1.1	意思決定支援のシーンに求められる研究開発課題	3
図 1.2	営業活動意思決定支援システムのイメージ	4
図 1.3	本論文の構成	5
図 1.4	第4章の構成	6
図 2.1	営業活動における意思決定のイメージ	9
図 2.2	国内 CRM アプリケーション市場売上額予測(2016 年～2022 年)	10
図 2.3	営業活動の結果を記録する営業日報	11
図 2.4	営業活動意思決定支援システムのイメージ	12
図 2.5	意思決定における処方的分析と本研究の対象領域	13
図 2.6	限定的な営業活動の意思決定支援	14
図 2.7	BPMN で記述されたプロセスモデルの例	15
図 2.8	プロセスマイニングの概略1	16
図 2.9	プロセスマイニングの概略2	16
図 2.10	営業活動意思決定支援システムにおけるプロセスモデルの構築	17
図 2.11	本研究の位置付け	18
図 2.12	従来のプロセスマイニングと本論文で提案するプロセス抽出手法の違い	19
図 2.13	プロセスマイニングの3つのステップ	20
図 2.14	ディシジョンマイニングの概要	21
図 2.15	オペレーショナルサポートの概要	22
図 2.16	営業支援システム(SFA)とメールによる営業日報の違い(1)	23
図 2.17	営業支援システム(SFA)とメールによる営業日報の違い(2)	23
図 2.18	ポジティブ/ネガティブ判定による顧客反応の抽出	24
図 2.19	プロセスモデル構築の2つの課題	25
図 2.20	XES 形式から BPMN 形式への変換	26
図 3.1	営業日報メールのアクティビティ分類	30
図 3.2	営業活動の標準アクティビティ	31
図 3.3	トピック分類	32
図 3.4	LDA と Doc2vec+SVM の比較	33
図 3.5	選択されたアクティビティに従って内容を記入する登録画面	33
図 3.6	登録画面から取得した訓練データ	34
図 3.7	LDA によるモデル構築と評価	35
図 3.8	Doc2vec+SVM によるモデル構築と評価	35

図 3.9	アクティビティ分類のアルゴリズム検証結果.....	36
図 4.1	プロセスモデル構築の概要.....	40
図 4.2	静的ベイジアンネットワーク(SBN)の事例.....	41
図 4.3	動的ベイジアンネットワーク(DBN)の事例.....	42
図 4.4	営業活動意思決定支援システムの特徴と学習モデルの比較.....	45
図 4.5	4.3章以降の章立て.....	45
図 4.6	案件シミュレータの概要.....	47
図 4.7	案件シミュレータの詳細.....	48
図 4.8	フィードバックルールの詳細.....	49
図 4.9	生成された営業日報データ.....	49
図 4.10	顧客反応とアクティビティの組み合わせ類似度の測定とガウス分布.....	50
図 4.11	隠れマルコフモデルと行動制御.....	52
図 4.12	高次マルコフ連鎖.....	53
図 4.13	状態遷移確率(丸印)と出力確率(楕円)のイメージ.....	53
図 4.14	隠れマルコフモデルによるプロセスモデルの構築.....	54
図 4.15	隠れマルコフモデルのパラメータの定義.....	55
図 4.16	隠れマルコフモデルによるプロセスモデル構築の手順.....	55
図 4.17	POMDP によるプロセスモデル構築時のパラメータ.....	56
図 4.18	隠れマルコフモデルの状態数比較.....	57
図 4.19	受注率に影響を与える5つの要素.....	58
図 4.20	営業活動意思決定支援システムの適用環境.....	59
図 4.21	部分観測マルコフ決定過程(POMDP)によるプロセスモデルの評価モデル .....	60
図 4.22	リコメンド順位と採択数.....	61
図 4.23	A/B テストによる受注率の変化.....	62
図 4.24	営業担当者ごとのリコメンド採択率と受注率(失注率)の相関性(ターム1).....	63
図 4.25	営業担当者ごとのリコメンド採択率と受注率(失注率)の相関性(ターム2).....	64
図 4.26	受注案件におけるリコメンド採択率.....	65
図 4.27	行動変更受注貢献率.....	66
図 4.28	評価モデルに基づいた評価結果.....	67
図 4.29	某生命保険会社の受注事例.....	69
図 4.30	某出版会社の受注事例.....	70
図 4.31	某製造業における失注事例.....	71
図 4.32	某流通業における失注事例.....	72
図 4.33	グループ分類ごとのプロセス抽出.....	75
図 4.34	本手法の適用対象外の営業タイプ.....	75

---

図 4.35 深層強化学習によるプロセスモデルの構築 .....	76
図 4.36 状態価値関数と行動価値関数の計算 .....	77
図 4.37 強化学習の分類.....	78
図 4.38 深層強化学習によるプロセスモデル構築ステップ .....	80
図 4.39 LSTM による環境モデルの構築.....	81
図 4.40 構築された環境モデルによる予測結果.....	81
図 4.41 セルフプレイによる強化学習 .....	82
図 4.42 セルフプレイの収束結果.....	83
図 4.43 セルフプレイにより学習が進む過程.....	85
図 4.44 深層強化学習のプロセスモデルの評価.....	86
図 4.45 アンケート結果の平均の検定.....	87
図 5.1 能動学習(人間参加型機械学習)の概要 .....	91
図 5.2 能動学習(人間参加型機械学習)によるリコメンド精度の向上 .....	92
図 5.3 営業プロセスへのサブゴールの設定.....	92
図 5.4 アクティビティリストの柔軟な変更 .....	93
図 5.5 伊豆観光のイメージ.....	94
図 5.6 営業活動と観光案内の類似性.....	94



# 表目次

---

表 4.1 A/B テストによる受注率の変化.....	62
表 4.2 全案件のサマリーデータ(ターム1:2019/1-3).....	73
表 4.3 全案件のサマリーデータ(受注データのみ:ターム2:2019/4-6).....	73
表 4.4 セルフプレイの初期値.....	83

# 第1章

---

## 序論

## 1.1 本論文の背景と目的

「営業はアートである。」

営業活動は企業における様々な活動の中でも最も重要な活動の1つであるにも関わらず、生産現場や物流現場などの改善活動が徹底されてきた部門と異なり、長い間、個人の直感と生まれながらの才能によっておこなわれる「アート」とみなされてきた。しかし、技術の進展により、過去30年間で大きな変化が起こった。営業支援システム(SFA)<sup>1</sup>や近年のデジタルマーケティング<sup>2</sup>の登場により、「科学としての営業活動」という概念が作り出され多くの企業で推進されてきた[1][2]。

営業活動の目的は売上の拡大にあるが、案件型営業<sup>3</sup>の場合は、売上=案件数×受注率×販売単価と表すことができ、この中でも営業活動の管理対象となるのは案件数と受注率である。この2つの管理対象項目(Sales Performance と呼ばれる)に影響を与える要素は以下の5つの要素と定義されている[3]。

### 1. 才能(Aptitude)

顧客の求めているものを直感的に掴むことができる先天性のある才能など、個人的要因を指す。

### 2. モチベーション(Motivation)

顧客や会社の役に立ちたいなどの外的モチベーション、さらにはインセンティブなどの自分の欲求を満たすための内的モチベーションなど。

### 3. 個人の性格(Personal)

営業向きの外交的な性格などの適正、あるいは細かな気配りなどの顧客から好かれやすい性格。

### 4. 組織と環境(Organizational & Environmental)

上司のアドバイスや周りとの相談しやすい組織や環境など(内部環境)。さらには昨今のコロナ禍による景気後退などの景気変動は外部環境と呼ばれる。

### 5. スキル(Skill level)

主に営業経験などの熟練度に依存する。商談を有利に進めるためのテクニックなど。

<sup>1</sup> 営業担当者が所有する顧客情報や案件の進捗等の営業活動に関わる情報をシステム内で共有することで、営業の生産性を向上し効率化を進めることを目的とした情報システムである。

<sup>2</sup> 紙面広告などのアナログメディアと異なり、デジタルコンテンツやデジタルメディア、デジタルデバイスを活用したマーケティング活動を指す。これまでよりもターゲットを絞り込んだ訴求とその効果測定をきめ細かく把握できる。

<sup>3</sup> 営業活動を手法で分類すると、車や家やシステム販売などの案件をベースにした案件営業と、発注頻度の高い商品を特定の顧客に巡回訪問するルート営業、リアル店舗やECサイトなどの販売営業の3種類がある。

この中でも Sales Performance に大きな影響を与えるとされる「スキル (Skill level)」、さらに「対人関係 (Interpersonal)」「営業知識 (Selling-Related Knowledge)」「対応能力 (Degree of Adaptiveness)」の3つから構成されると定義されており[3][4]、まさに「顧客とのコミュニケーションを通じて、営業知識を動員し、対応方針を意思決定する力」と定義することができる。しかし、この定義された意思決定能力は極めて属人性が高いものであることから、これまでも科学的な研究対象とは捉えられてこなかった。さらには、ほとんどの営業支援システム(SFA)においても、標準機能サポートの範囲には含まれていない<sup>4</sup>。

しかし、平成30年に JST 研究開発センター (JST/CRDS) よりリリースされた「複雑社会における意思決定・合意形成を支える情報科学技術[5]」という戦略プロポーザルによると、近年は意思決定に関わる要因や影響が複雑化し、さらにスピードが求められる時代になってきたことが述べられている。さらに、このような時代では意思決定のシーンにおいても、膨大な可能性を探索し有効な意思決定の候補を高速に見つける技術の追求が重要な研究開発課題となることが提言されている。そしてこの技術課題の解決には、機械学習技術によるアプローチが意思決定の支援にも不可欠になることが述べられている。

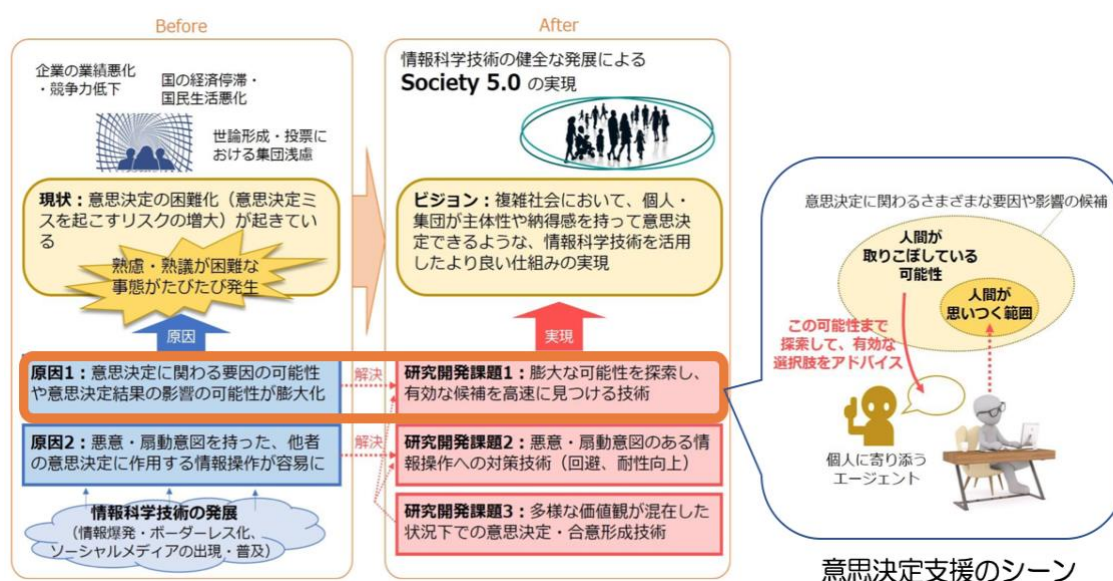


図 1.1 意思決定支援のシーンに求められる研究開発課題

(JST 研究開発センター「複雑社会における意思決定・合意形成を支える情報科学技術」より)

このように機械学習技術の進展により、これまで属人性の高かった意思決定を支援する仕組みが求められている時代背景の中で、本論文では、企業活動の中でもより複雑性の高い領域である営業活動の意思決定に注目した。「顧客とのコミュニケーションを通じて、営業知識を動員し、対応

<sup>4</sup> Salesforce では「Einstein AI」という機械学習機能を提供始めている。離反顧客を事前に予測し、それに対するアクションを促すリコメンドを営業担当者に通知するなどの特定アクティビティを対象にした取り組みが始まっている。

方針を意思決定する力を支援するには、顧客との間で常に変化する場面に応じた適切な対応方針のリコメンドが必要であり、営業活動のプロセス全般を通じてこのリコメンドを繰り返していくことで受注に誘導し、高い売上を実現することが可能となる。さらには、受注成果の高い営業活動の意思決定を、組織全員で再現可能となることで組織力の強化にもつなげることができる。

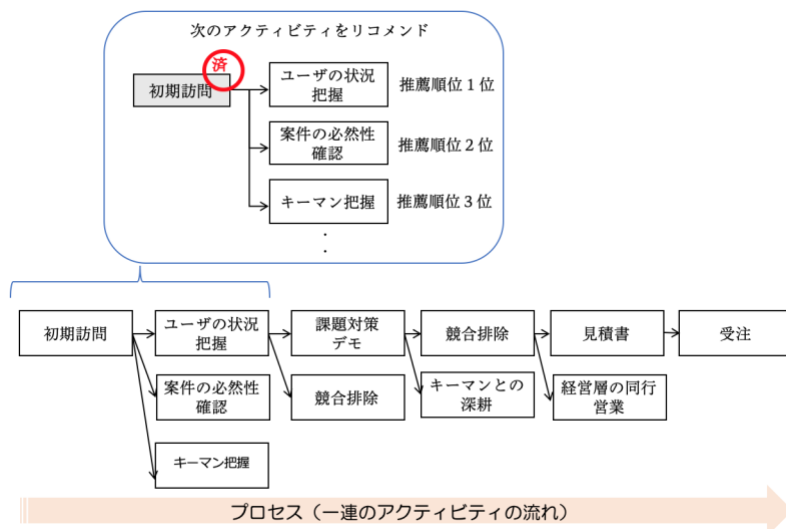


図 1.2 営業活動意思決定支援システムのイメージ

営業活動意思決定支援システムの構築を通じて、これまでアートとして捉えられてきた営業活動を、「個人・集団が主体感や納得感を持って意思決定できるような、情報科学技術を活用したより良い仕組み[5]」に転換することを目指す。

## 1.2 本論文の構成

本論文は具体的な構成は次の通りである。

- 第1章 序論
- 第2章 プロセスモデルに基づく営業活動の意思決定支援
- 第3章 営業日報メールのアクティビティ分類
- 第4章 プロセスモデルの構築と評価
- 第5章 結論

第2章「プロセスモデルに基づく営業活動の意思決定支援」では、営業現場における意思決定の課題を述べたのち、営業活動意思決定支援システムの目的と適用手法のアプローチについて

述べる。そのアプローチで用いるプロセスモデルとプロセスマイニングについても解説するとともに、本研究の適用手法の位置付けについても述べる。その後、入力データとなる営業日報データについて現実の導入企業の実態を述べるとともに、それに沿ったかたちで、本論文における適用手法の解決すべき技術課題を明らかにする。具体的には、営業日報が記載されているメールをアクティビティに分類する前処理の課題と、その後の分類された営業日報を入力情報として、機械学習により受注確率の高い営業プロセスを抽出しプロセスモデルを構築する課題について述べる。以降、第3章と第4章はそれぞれの技術課題について詳細化していく構成をとっている。そのため、すでに営業支援システム(SFA)を導入している企業では、アクティビティ分類の前処理を行う必要がないため、この第4章から始めることができる。逆に、営業支援システム(SFA)を未導入で、営業日報としてメールを活用している企業は、メールの記載内容からアクティビティに分類する前処理が必要となるため、第3章から始めていく想定である。

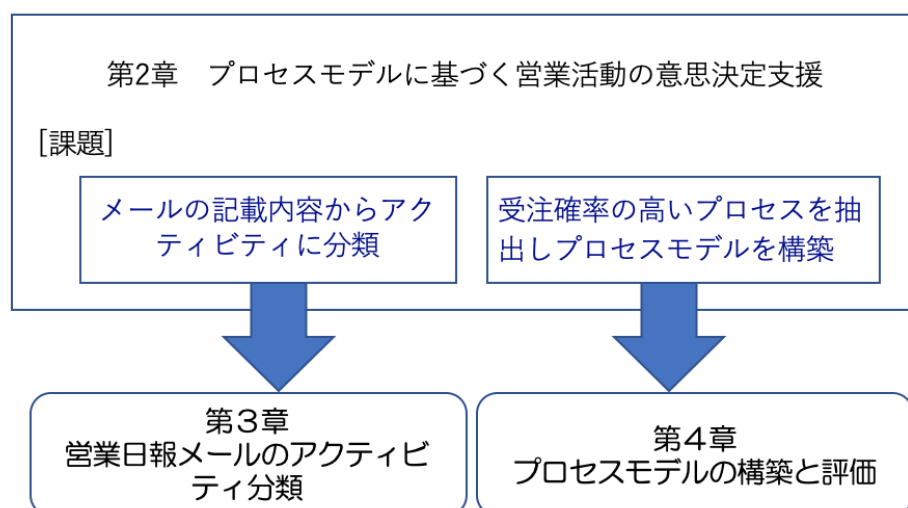


図 1.3 本論文の構成

第3章では、国内では約70%の企業が営業日報データの記録としてメールを利用しているという実態を受けて、メール内に自然文で蓄積された営業日報から、実施されたアクティビティを自然文解析により抽出し分類する試みを実施する。これにより、第4章のプロセスモデル構築に最低限必要となるデータ(日時、営業担当者名、案件名、アクティビティ名)を明示的な形式で準備することが可能となる。本節では、複数のアルゴリズムの比較からアクティビティを分類する分類システムに適したアルゴリズムを検証する。

第4章では、第3章で明示的な形式で準備できた営業日報データ(日時、営業担当者名、案件名、アクティビティ名)から、受注確率の高い系列情報(顧客反応とそれに対するアクティビティ)の組み合わせをプロセスとして抽出することで、プロセスモデルの構築をおこなう。これにより、営業活動プロセスを通じて、受注確率の高い次のアクティビティのリコメンドが可能となる。本節において

は、プロセスモデルの構築方法の解説と、構築されたプロセスモデルの実企業への適用と評価について示す。

具体的には、第4.2章にて、営業活動の特性を踏まえた上で複数のアルゴリズムの候補からプロセス抽出に適したアルゴリズムを選定した。第4.3章ではアルゴリズムの比較評価に必要な教師データを準備する。ここでは案件シミュレータにより大量教師データの生成を行っており、その詳細について述べる。その後、準備できた教師データを利用して、第4.4章では部分観測マルコフ決定過程(POMDP)によるプロセスモデルの構築の詳細と、実企業による適用評価の結果について述べる。ここでは、リコmendによる営業担当者の行動変更が結果として受注改善に影響を与えたことを確認した。同じく第4.5章では、第4.3章で準備できた同一の教師データを利用して、深層強化学習を用いたプロセスモデルの構築の詳細について述べる。最終的には、部分観測マルコフ決定過程(POMDP)によるプロセスモデルと、深層強化学習によるプロセスモデルのそれぞれのリコmendに対する評価を、熟練営業担当者によるアンケートにより行なう。その結果、深層強化学習によるプロセスモデルからのリコmendが営業の納得度において高い評価となった。

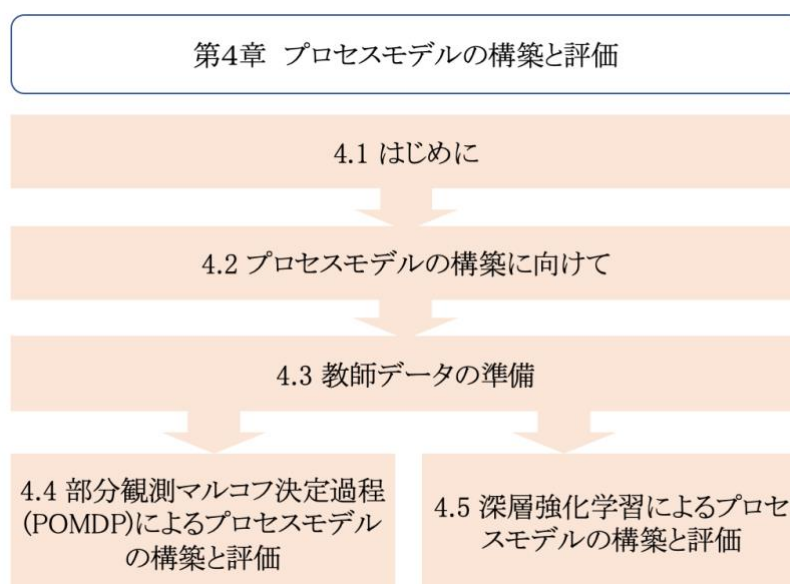


図 1.4 第4章の構成

最後に、第5章「結論」では、本論文の主たる成果と今後の展開について議論し、本論文のまとめとする。

## 第2章

---

# プロセスモデルに基づく 営業活動の意思決定支援



### 2.1 はじめに

第1章で述べたように、営業活動の意思決定は、これまで属人性の高さからあまり研究対象となつて来なかった。しかし、この意思決定を支援できる仕組みが提供できることは、組織的かつ効率的な営業活動につながり、ひいては企業業績の向上にも大きく貢献することができる。

本章では、上記の論議をより詳細かつ具体的に掘り下げることで、営業活動における意思決定の課題と、それを解決する営業意思決定支援システムのアプローチについて詳しく記述する。

まず、実際の営業活動場面における意思決定の状況について説明し、その問題の背景について示す。そして、その問題を解決するには、営業担当者にとって次に取るべき営業活動(アクティビティ)をリコメンドできる営業活動意思決定支援システムが必要であることを示す。

次に、それを実現するための営業活動意思決定システムの構築アプローチについて記述する。ここでは、プロセスマイニングというプロセス抽出技術を営業活動ドメインに応用したプロセスモデルの構築がポイントとなる。

その後、関連研究として従来のプロセスマイニングによるアプローチと本論文のアプローチの違いについて述べることで、本論文の位置付けを明確にするとともに、本論文で解決する課題をフェーズごとに明らかにする。またそのフェーズに沿って、次節以降の展開についても述べる。

### 2.2 営業活動の意思決定支援システム

#### 2.2.1 営業活動における意思決定の課題

営業活動は企業における様々な活動の中でも最も重要な活動の1つである。特に、営業活動における意思決定において、顧客の反応に基づいて次にどのような活動内容(アクティビティ)を選択するのかは、最終的な受注の可否に大きな影響を与えるものである。しかし、実際の営業現場では、顧客の反応に対するアクティビティの選択は営業担当者の経験や勘などに基づいて実施されるため、属人的要素が受注成果に影響を与えるという課題がある[6][7]。実際に営業担当者ごとに受注成果にはバラツキがあり、弊社の統計でもその差は3倍以上になることがある。

その理由としては以下が挙げられる。

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

・アクティビティの選択意思決定のルールは事前に決まっておらず、営業担当者の判断に任されている。営業マネージャーの管理は最終的な受注可否であり、途中のプロセスが管理されることは少ない。

・受注や失注に至るまで長期間に渡るため、顧客要求もその間に徐々に変化する。そのため、その変化に対応した意思決定を連続して実施していく必要がある。

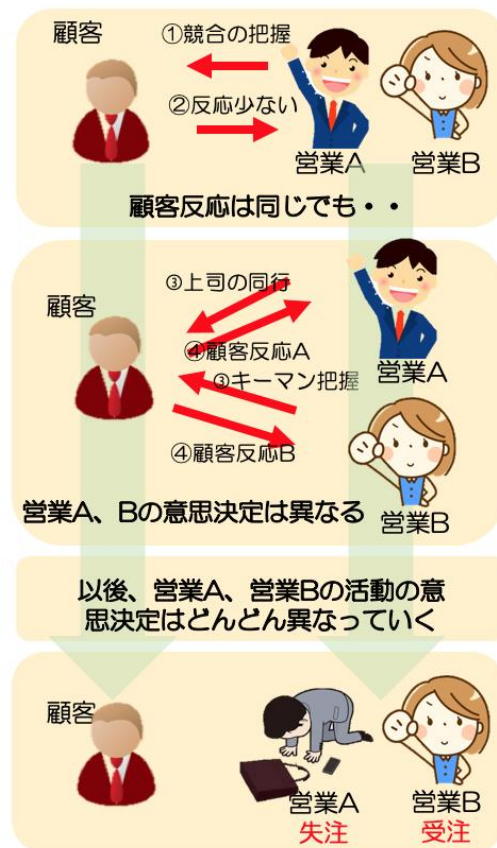


図 2.1 営業活動における意思決定のイメージ

図 2.1 では、当初に営業 A と営業 B は同一の顧客に対して「①競合の把握」という同一のアクティビティを実施し、それに対して顧客からは「②反応が少ない」と同一の顧客反応が返ってきたものの、その次のアクティビティ選択は営業 A は「③上司の同行」、営業 B では「③キーマン把握」と異なり、その結果、それぞれ異なる顧客反応が返る。以後、営業 A、営業 B の営業活動を通じた意思決定はどんどん異なるものとなり、これらの意思決定が連続で繰り返されたのちに、結果として受注や失注となる。このように、それぞれの営業担当者の経験などに基づきアクティビティは都度選択され、またこれらの意思決定は長期間に渡り連続して実施されることから、営業活動の意思決定には属人的な要素が多く、その結果が受注の可否に与える影響も大きいことが理解できよう。

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

そのため近年、意思決定から営業担当者の経験などの属人性のある要素を排除することにより、受注成果の高い営業活動を組織全員で再現可能な意思決定支援のニーズが高まってきた[8][9][10][11]。近年の営業支援システム(SFA)を包含するCRM市場の拡大はそれを示しており、2017年では前年比成長率10.1%増、1,056億4,900万円の市場規模、さらに2018年以降は顧客のデジタルトランスフォーメーション(DX)の浸透により年間平均成長率は6.2%、2022年市場規模は1,430億3,600万円と予測されている。



図 2.2 国内 CRM アプリケーション市場売上額予測(2016 年～2022 年)  
(IDC Japan 8/2018 市場調査レポートより)

しかし、営業支援システム(SFA)でカバーされている機能領域は、情報共有/プロセス管理/売上予測などが中心であり、この営業担当者の意思決定支援の領域はまさにこれからのテーマである。詳細は「2.2.3 営業活動の意思決定支援システムとは」で再度述べる。

### 2.2.2 営業活動の結果を記録する営業日報

一般的に、営業活動の意思決定の記録は営業日報に自然文として記載される。また企業により、メールまたは営業支援システム(SFA)にデータとして蓄積されていることが大半である。

ここで、営業支援システム(SFA)[12][13][14]について解説する。営業支援システム(SFA)は、営業担当者個人で留まりがちな顧客情報や案件の進捗、商談事例等の営業活動に関わる情報をデータ化して可視化し活用することで、営業の生産性を上げ、効率化を進めることを目的とした情報システムであり、米国から1995年ごろに入ってきた。日本でも、SalesForce.com<sup>5</sup>

<sup>5</sup> セールスフォース・ドットコムは、米国カリフォルニア州に本社を置く CRM ソリューションを中心としたクラウドコンピューティング・サービスの提供企業である。ビジネスアプリケーションおよびクラウドプラットフォームをインターネット経由で提供している。米 IT 調査会社ガートナーによる最新レポートでは、CRM の世界マーケットシェアは 16.1%で第 1 位、また同レポートによると日本国内の営業支援システム(SFA)のマーケットシェアは 60.4%を占めている。

(www.salesforce.co.jp) や, intra-mart DPS for Sales<sup>6</sup> (dps.intra-mart.jp) などが普及している。しかし, 営業支援システム(SFA)の日本国内での普及率は約 30%であり, 残りはメールを使った営業日報の共有となっている(ミック経済研究所, クラウド型 CRM 市場規模 2018 年度)。

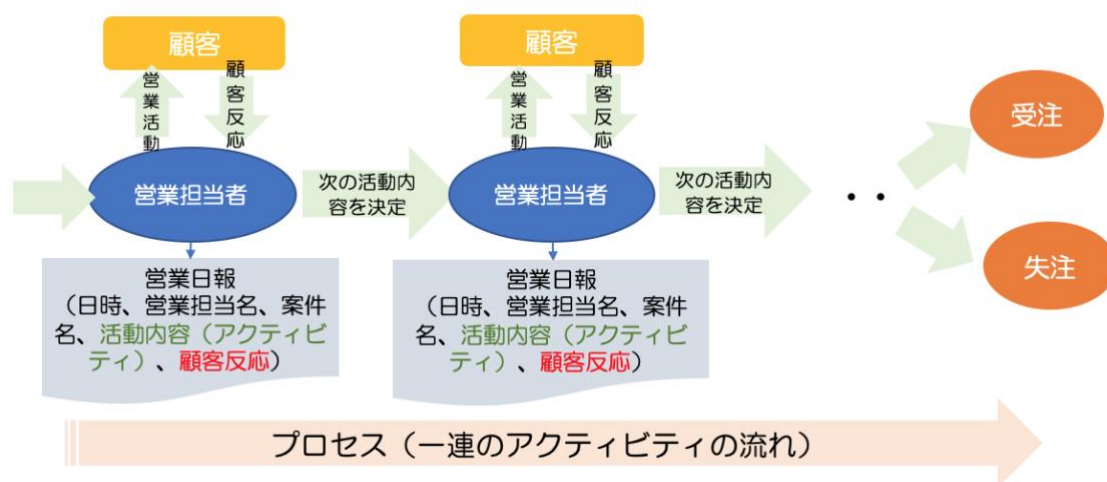


図 2.3 営業活動の結果を記録する営業日報

図2.3では, 営業担当者と顧客の関係, さらにはそれらが受注や失注に向かって時系列で遷移する状況を図式化した。このように, 実施した営業活動に対する顧客反応<sup>7</sup>を見て, 次の活動内容(アクティビティ)を選択していく。この一連のアクティビティの流れをプロセスと呼び, 営業活動のプロセスを通じて, 顧客反応とそれに対するアクティビティ選択が連続で実施される。またその系列は一般的に 20~100 と長く, 受注/失注結果は最後に判明する。この営業活動の詳細が営業日報に記録され蓄積されていくことになる。ただし, 顧客反応とそれに対するアクティビティの選択結果はそれぞれ別の営業日報に記載される。

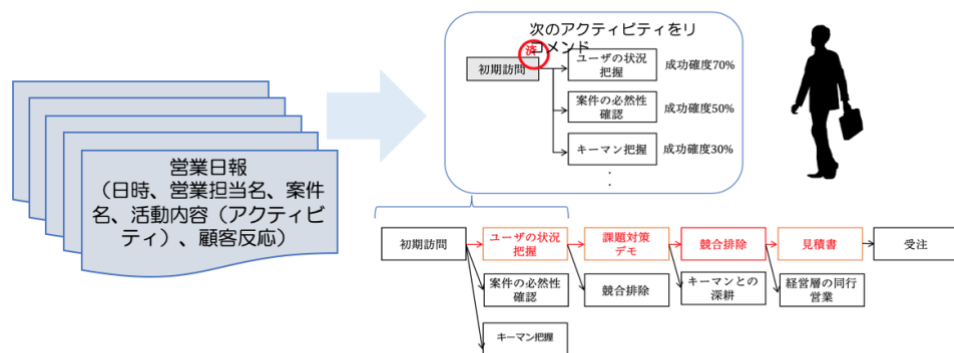
### 2.2.3 営業活動の意思決定支援システムとは

<sup>6</sup> intra-mart DPS for Sales は, 筆者の所属する(株)NTT データイントラマート社の提供する営業支援システムであり, 2020 年 6 月にリリースされた。シンプルかつ低コストでありながらも, これまでメールによる営業日報管理を行ってきた企業が簡単にスタートできる各種機能を揃えており, 30 社以上の導入実績がある。

<sup>7</sup> 顧客反応・・・営業担当者が, 次の活動内容(アクティビティ)を選択する際の根拠となるのが顧客反応である。本論文における意思決定支援システムの構築にあたり, 顧客反応はできるだけ単純化する必要があるため, (例えばプレゼンという活動内容に対し)良い/普通/悪いなどに近似した形式とした。

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

序章で述べたように、本論文の目的は、顧客との間で常に変化する場面に応じた適切な対応方針のリコメンドを、営業活動のプロセス全般を通じて繰り返していくことで受注に誘導し、高い売上を実現することが可能な意思決定支援システムの構築である。そのためには、過去の営業活動の意思決定履歴が記録されている営業日報データを用いて、営業活動中の顧客反応に対応した受注可能性の高い「次に実施すべき営業活動(アクティビティ)」を、営業担当者に都度リコメンドする仕組みが必要となる。また、図2.3において図式化したように、営業活動のプロセスを通じて、顧客反応とそれに対するアクティビティ選択は連続で実施されることから、この意思決定支援システムにおいても、営業活動の部分的な業務支援ではなく、営業活動のプロセス全般を通じてリコメンドを繰り返すことで営業担当者の意思決定を支援し、受注に誘導することが求められる。



※アクティビティは一つ一つの営業活動であり、一連のアクティビティの流れがプロセス

図 2.4 営業活動意思決定支援システムのイメージ

この意思決定支援においては、Gartner 社 (<https://www.gartner.com/jp/about>) が示した意思決定支援の発展段階(図2.5)がよく知られておりここで紹介する。Gartner は、意思決定支援の発展段階を、記述的分析(Descriptive Analytics)、診断的分析(Diagnostic Analytics)、予測的分析(Predictive Analytics)、処方的分析(Prescriptive Analytics)の順に発展するとしている。記述的分析は「What happened?(何が起きたか?)」、診断的分析は「Why did it happened?(なぜ起きたのか?)」という過去の情報分析であり、意思決定のための基礎情報の提供は可能となるものの、将来の予測には人間による属人的な判断(Human Input)が必要となる。予測的分析の段階では、一歩進んで「What will happen?(何が起きるか?)」として将来的な予測までが可能となるが、問題解決の方向性まで示してくれるわけではない。この次の段階の処方的分析により、「What should I do?(次にどうすべきか?)」まで示してくれるようになってこそ初めて問題解決に直結する意思決定支援が実現できると述べている。

現在、機械学習技術の著しい進化によって、この予測的分析は精度が大きく向上し、商品売上の需要予測、機器・部品等の故障予測など、多くのビジネスシーンにて活用されるようになったが、意思決定分野で期待が高まっているのがまさにこの処方的分析である。処方的分析は、事前に対



応方法までを定義しておくことで、意思決定とその後のアクションまでをコンピュータで自動実行する「自動意思決定」と、意思決定支援として「次はどうすべきか？」までは示すが、アクションの手前で人間による最終的な意思決定を求める「意思決定支援」という2タイプがある。工場などの自動制御分野と異なり、本論文で対象とする営業活動領域は、人間に成り代わってコンピュータが営業活動までを自動実行することはできない。そのため、本論文で目指すのは「処方的分析による意思決定支援」領域となる。メールは、過去の営業日報データの情報共有のみにとどまるため、記述的分析・診断的分析のレベルとなり、営業支援システム(SFA)ではそれに加えてプロセス管理が可能となることから売上予測などの予測的分析のレベルまで可能となる。しかし、処方的分析のレベルはメールはもちろん、営業支援システム(SFA)においてもほとんどカバーされていない領域である<sup>8</sup>。

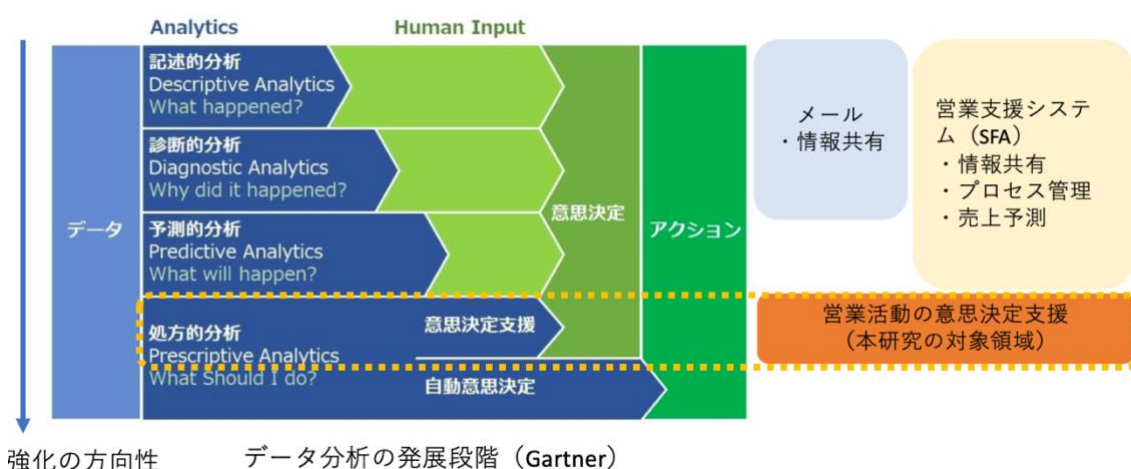


図 2.5 意思決定における処方的分析と本研究の対象領域  
(Gartner 「データ分析の発展段階」を元に加工)

### 2.2.4 営業活動の意思決定支援システムの現状

これまでも、意思決定支援のトレンドを背景として、営業活動における処方的分析の領域に機械学習を適用することで、営業活動の意思決定を支援するシステムの構築が試みられており学術分野でも報告がある[15][16][17][18][19]。ただしその内容は、顧客の行動データに基づいた顧客選別の効率化[20]、[21]や、販売見込みに基づいた売上予測[22]などの部分的な業務への適用に限られている。また、みずほ銀行の事例では、リコメンドを可能とするシステム利用についても報告されているが、営業タイミングに合わせた類似商談のリコメンドなど、ある時点のアクティビティに基づいたリコメンドであり、限定的な意思決定支援に限られている。初期訪問から受注に至るまでの

<sup>8</sup> Salesforce では「Einstein AI」という機械学習機能を提供始めている。離反顧客を事前に予測し、それに対するアクションを促すリコメンドを営業担当者に通知するなどの特定アクティビティを対象にした取り組みが始まっている。

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

一連のアクティビティの流れである営業活動全般を対象にしたリコメンドの研究事例については学術分野で報告がない。一方で、実企業では失敗事例が複数報告されており[23]，その原因は、営業活動における意思決定には予め明確なルールが存在せず、営業担当者の経験や判断にもとづいて実施されることから意思決定パターンが極めて多岐にわたることや、意思決定が顧客反応を見ながら連続で実施され、受注可否の結果は最後までわからないなどの問題にある[6]。

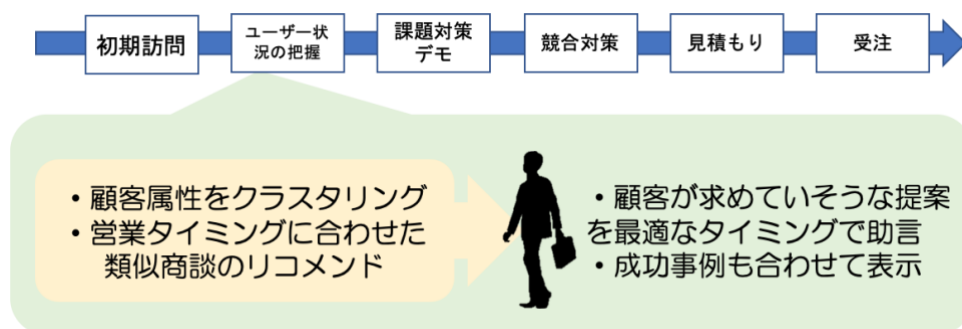


図 2.6 限定的な営業活動の意思決定支援

### 2.3 プロセスモデルに基づく営業活動意思決定支援システムの構築

法人向けの営業活動には、初期訪問からヒヤリング、プレゼンテーション、見積りなどの各ステップを順番に通過して受注に至るまでの一連の営業プロセスがある[24]。本論文では、この営業プロセス全般に渡り意思決定を支援する仕組みを構築する。具体的には、顧客反応に対するアクティビティを選択した結果が記録されているメールや営業支援システム(SFA)などの営業日報の履歴から、受注確率の高いアクティビティの選択履歴をプロセスとして抽出することができれば、営業活動の全般に渡って受注確率の高いリコメンドの可能なプロセスモデルを構築することが可能となる。これにより、営業担当者をリコメンドを通じて効率的に受注に誘導し高い売上を実現することが可能となる。そこで本節では、まずプロセスモデルとそれを構築する技術であるプロセスマイニングの解説から始めていく。

#### 2.3.1 プロセスモデルとプロセスマイニング

## 第 2 章 プロセスモデルに基づく営業活動の意思決定支援

ここで、プロセスモデル[25]とは、ビジネスプロセスモデルのことを指し、企業の仕事の仕方のモデルである。プロセスモデルは、仕事の仕方や手順の全体像を抽象化して構造的に定義したものであり、手続き型言語である BPMN<sup>9</sup>で記述されることが多い。

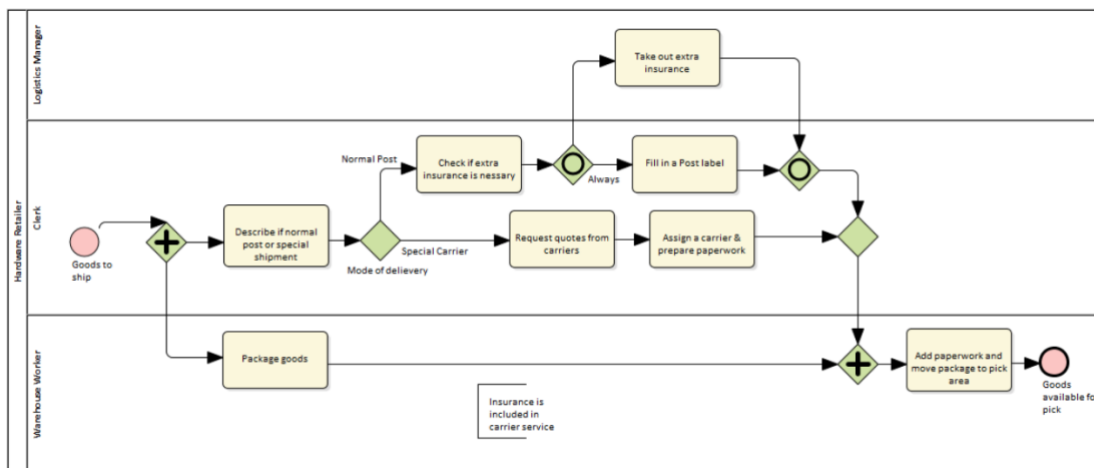


図 2.7 BPMN で記述されたプロセスモデルの例

これまでプロセスモデルを構築するには、仕事の仕方や手順を担当者へヒヤリングしたり、ストップウォッチなどを使って業務の時間計測を行うなど、たいへんな労力が必要であった。また労力がかかる割には正確性や網羅性を欠くことが多く、実用に耐えるプロセスモデルの構築は困難であった。しかし、その困難さを解消する手法として、近年、プロセスマイニング[26][27]という技術が実際の場面でも活用されるようになってきた。ERP/CRM などの既存システムのイベントログなどからプロセスの規則性を自動抽出してプロセスモデルを構築する技術「プロセスマイニング」は、主に 2000 年前半から研究開発が活発化し、実用的な普及が始まろうとしている<sup>10</sup>[26],[27]。

プロセスマイニングは、企業内部に蓄積記録された業務活動の実績データ(既存システムから出力されるイベントログなど)から業務活動の流れをプロセスとして自動抽出して、それを満たすプロセスモデルを手軽に構築する技術であり、現実実施された業務の実施手順を時系列で網羅的に抽出し可視化できる。

これは、あらかじめ全ての意思決定のルールが網羅され、決められたルールに基づいてプロセスが進行する定型プロセスを対象とした技術であり、主には経理や人事などの事務業務で多くの実績がある[30]。一度、プロセスモデルを構築できると、現実の業務実施結果がグラフなどでビジ

<sup>9</sup> BPMN とは、Business Process Model Notation の略。OMG (Object Management Group) で標準化が進められているビジネスプロセスの表記法のこと。表記が簡易なため、ユーザーにわかりやすいことが利点である [28][29]。

<sup>10</sup> プロセスマイニングの代表的な事例として、ドイツ製造業大手シーメンスがある。シーメンスでは、物流、財務、調達、販売の各部門にプロセスマイニングを導入し、業務自動化率を 24% 向上、また不必要な手戻り率を 11% 削減、年間 1000 万回の手作業を排除した (<https://www.celonis.com/jp/customers/siemens>)。



リアルに可視化できるため、プロセスの分析と改善を現場部門主導で推進していくことが可能となる。

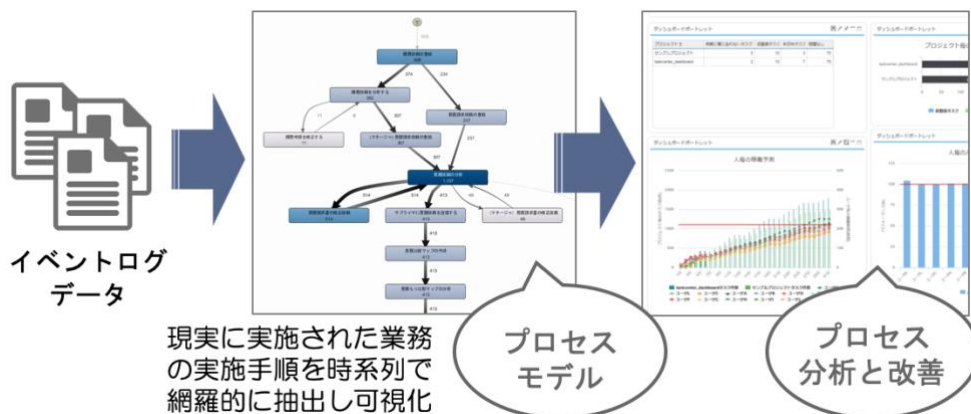


図 2.8 プロセスマイニングの概略1

現状の業務プロセスの実施回数と処理時間に基づいたアクティビティのすべての流れをプロセスマイニングで抽出することができるため、そこから標準化されたプロセスを策定できる。例えば、ボトルネック(実施回数多く処理時間がかかるプロセス)やイレギュラー(実施回数は少ないが処理時間がかかるプロセス)、ルール逸脱(実施してはいけないプロセス)を排除することで、業務プロセスの効率化と統制の強化に利用することができる。

プロセスマイニングを実施するために、入力データのイベントログとして最低限必要となるデータは、日時、実施担当者、イベント(営業活動では案件名に該当する)、アクティビティである。

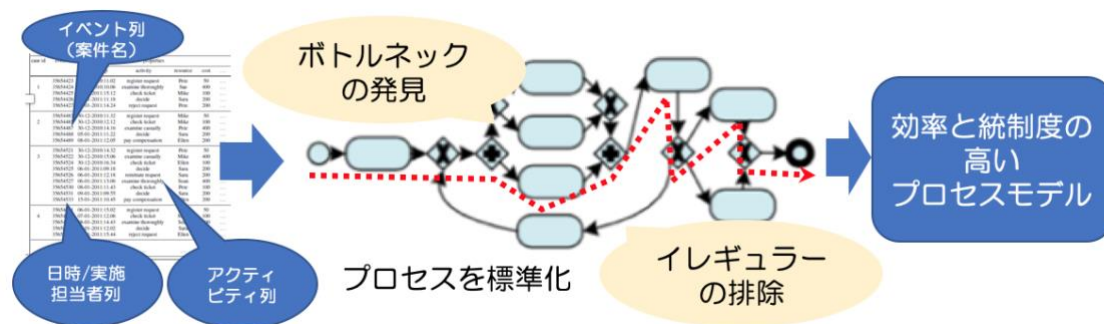


図 2.9 プロセスマイニングの概略2

### 2.3.2 プロセスモデルに基づく営業活動意思決定支援システムの全体像

本論文においても、このプロセスマイニングの手法を応用することでプロセスモデルを構築する。イベントログに代わって営業日報の履歴データから、受注確率の高いアクティビティの選択履歴をプロセスとして抽出し、営業活動の全般に渡って受注確率の高いリコメンドの可能なプロセスモデルを構築する。特に、営業活動の意思決定支援システムには、受注確率の高い営業担当者の意思決定の流れを営業プロセスとして抽出して、営業担当者の複雑な意思決定を確率的に表現したプロセスモデルを構築することが必要である。

しかし、従来のプロセスマイニングは、実施回数が多い標準的な営業プロセスの抽出を行うものであり、営業成果をあげるプロセスとは限らないことからその適用には課題がある。例えば、未知の競合先が出現した際にはその競合先を調査するプロセスへと分岐する、といったあらかじめ意思決定ルールを事前に定義できる場面には、営業活動においても従来のプロセスマイニングを利用することができる。しかし、顧客の反応により営業担当者が次のアクティビティを選択する際に、受注確率の高いアクティビティをリコメンドする意思決定支援においては、プロセスマイニングを応用した新たなプロセス抽出手法が必要となる。これまで営業活動を対象としたプロセスマイニングの適用についてはいまだ研究途上であり[31]、その具体的手法や適用事例については報告されていない。

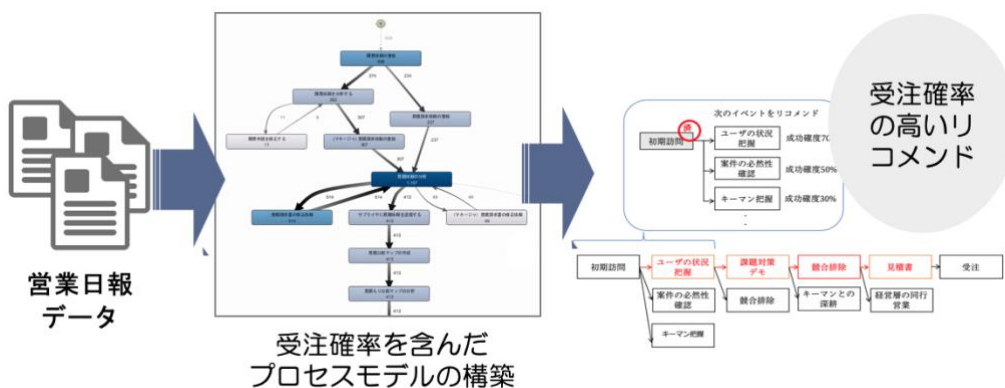


図 2.10 営業活動意思決定支援システムにおけるプロセスモデルの構築

### 2.3.3 従来のプロセスマイニングとの違い

まず、従来のプロセスマイニングと本研究における対象領域の違いについて述べる(図2.11)。プロセスマイニングは、管理部門を対象として業務効率化や業務統制の強化を目的とし、ERPなどの既存システムからのイベントログを入力データとしてプロセスモデルを構築する技術である。これまで、イベントログは、機械故障などの特定のアクティビティを対象として原因解析やアラートなどに用いられてきたが、プロセスマイニングではそのイベントログを業務プロセスの抽出に利用したことが斬新である。

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

それに対して、本論文では、営業部門を対象に、業績向上を目的とした意思決定支援を目的に、営業支援システム(SFA)やメールに蓄積されている営業日報データを入力データとして導入する技術となる。さらにこれまでの営業活動における意思決定支援では、「図2.6 営業活動意思決定支援システムの現状」で述べたように、特定時点の状況だけを考慮したアクティビティのリコメンドであったが、本論文では業務効率化/統制を目的とした従来のプロセスマイニングを応用したプロセス全般を通じたリコメンドであることが異なる。実績データの対象システムとしては、営業支援システム(SFA)導入企業に加え、営業日報報告をメールで実施している企業(全体の約70%)にも適用できるプロセスモデルの構築手法を本論文にて提示する。

導入目的	対象部門	実績データの対象システム	実績データ	意思決定支援 (リコメンド・アラート)	
業績向上が目的	営業	営業支援システム(SFA) (国内では約70%がメールを代替利用)	営業日報	アクティビティ対象	特定時点のリコメンド (みずほ銀行事例)
				プロセス対象	プロセスを通じたリコメンド (本研究の対象分野)
業務効率化/統制が目的	管理部門	ERPなどの基幹システム (会計、人事、生産管理、販売管理など)	イベントログ	アクティビティ対象	特定時点のアラート (保守など)
				プロセス対象	従来のプロセスマイニングの適用分野

図 2.11 本研究の位置付け

次に、従来のプロセスマイニングと本研究のプロセス抽出手法の違いについて図2.12にて整理した。導入の目的は、従来のプロセスマイニングがプロセス標準化による業務効率向上/統制強化であるのに対し、本論文で提案する抽出手法は、プロセス全体を通じたリコメンドによる受注率の向上を目的にしている。

また、入力データでは、従来のプロセスマイニングがイベントログ(日時/営業担当名/案件名/アクティビティ名)を利用しているのに対して、本論文で提案する抽出手法は、営業日報を利用しているため、イベントログの情報に加えて顧客反応/受注情報/失注情報が付加される。

次に、プロセスモデルの構築手法では、従来のプロセスマイニングが全てのログを包含するプロセスモデルを構築するのに対して、本論文で提案する抽出手法は、確率的・統計的に、高い受注率を表現するためのプロセスモデルを構築することになる。

プロセス抽出のアルゴリズムにおいては、従来のプロセスマイニングではタスク間の順序関係から演繹的にモデルを構成する $\alpha$ アルゴリズム[32]の利用が代表的であるのに対して、本論文で提案する抽出手法は、顧客反応と次のアクティビティの情報を含む営業日報から、受注確率の高いプロセスを機械学習により抽出する手法である。

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

モデルの評価観点では、従来のプロセスマイニングはモデルが正確にプロセスを表現しているかを適合性で評価するのに対して、本論文で提案する抽出手法は、モデルが受注率の高いプロセスを表現しているかをリコメンドの妥当性で評価することになる。

	従来のプロセスマイニング	本論文で提案するプロセス抽出手法
導入目的	プロセス標準化による業務効率向上/統制強化	プロセスを通じたりコメンドによる受注率向上
入力データ	イベントログ(日時/営業担当名/案件名/アクティビティ名)を利用	営業日報(イベントログの情報に加えて顧客反応/受注情報/失注情報)を利用。
プロセスモデルの構築手法	全てのログを包含するプロセスモデルを構築	確率的・統計的に、高い受注率を表現するためのプロセスモデルを構築
プロセス抽出のアルゴリズム	タスク間の順序関係から演繹的にモデルを構成する $\alpha$ アルゴリズムが代表的	顧客反応と次のアクティビティの情報を含む営業日報から、受注確率の高いプロセスを機械学習により抽出
モデルの評価観点	モデルが正確にプロセスを表現しているかを適合性で評価	モデルが受注率の高いプロセスを表現しているかをリコメンドの妥当性で評価

図 2.12 従来のプロセスマイニングと本論文で提案するプロセス抽出手法の違い

### 2.3.4 関連研究

近年、プロセスマイニングは新規研究が活発な分野であり、BPM<sup>11</sup>(Business Process Management:ビジネスプロセスマネジメント)関連の研究中でも半分以上を占めるほどになっている。プロセスマイニングは一般的に以下の3つのステップからなる[26][27][33]。

#### (1) プロセス発見 (process discovery)

イベントログを入力として、それを満たすプロセスモデルを出力する技術。いわばトレーニングのステップであり、ルールを抽出することが目的である。

<sup>11</sup> BPMは業務のプロセス(手順、役割分担、ルール)を、役割分担している関係者で共有することで、日々の業務の成果を向上させる経営手法である。この手法は、主に以下の3つから構成されている。

(1) 業務のプロセスを可視化・設計する手法であり、一般的にはBPMNという国際標準のプロセス表記法を使いプロセス設計を行う。

(2) 業務のプロセスを実行・管理する情報システムであり、BPMシステム(またはBPMS)というツールを利用して、可視化・設計した業務プロセスを実行支援・進捗管理する。

(3) 上記に基づく業務改革の活動体系であり、マネジメント手法としてはPDCAサイクルを利用する。

### (2) 適合性評価 (conformance check)

プロセスモデルとイベントログを入力として、出力されたプロセスモデルの適合性を判定する技術。具体的には、(1)で抽出されたプロセスモデルをさまざまなイベントログと突き合わせることで、どれだけの適合性があるかを評価する[34]。

### (3) 強化 (enhancement)

実行されたプロセスモデルから出力された「flow time (処理時間)」や「waiting time (待ち時間)」などのイベントログを入力として、より適合性の高いプロセスモデルを出力する技術。

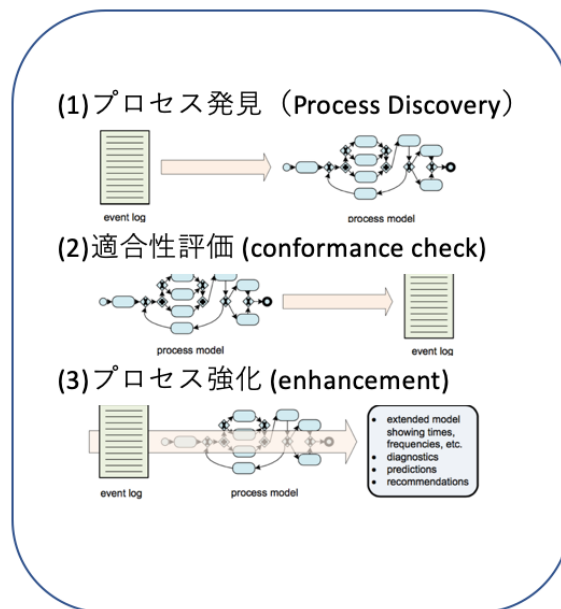


図 2.13 プロセスマイニングの3つのステップ

プロセスマイニングでは近年、以下の3分野に研究が集中している。

#### (1) イベントログからプロセスモデルの構築

イベントログの全てを網羅したプロセスモデルの構築に関する分野である。α アルゴリズムでカバーできない自由選択や階層構造への対応など、不完全性への対処がテーマの一つである。これと同時に、プロセス内でアクティビティの順序を事前に決める必要のない柔軟性ある宣言型の記述言語[35],[36]も登場しており、Declare[37],[38] / Case Management Model and Notation (CMMN)[36]などの形式で記述される。最近では、BPMN の補完としてこれらの宣言型記述言語を組み合わせた Hybrid 手法で柔軟に業務プロセスを表現する技術も進展した



[39].

しかし、この宣言型表記を用いても、意思決定のタイミングで提示された情報によって、ルールにもとづいてイベントの実施順序が決定するような意思決定のプロセスは表記できなかつたため、ディシジョンマイニングが登場した。ディシジョンマイニングでは、意思決定の分岐が静的なディシジョンツリーで表記され、記述形式としては DMN (Decision Model and Notation ) [40] が提唱されている。ディシジョンマイニングにおいてはまず全ルートを網羅するプロセスを作成し、その中から分岐を伴う判断ポイントを見つけ、そこからディシジョンツリー分析のアルゴリズムで判断ルールを抽出して DMN を生成するという手順で進行する[41]。つまり、意思決定の判断ルールが事前に定義できることが当手法を適用するための前提となる。そのため、未知の競合先が出現した際にはその競合先を調査するプロセスへと分岐する、といった予め判断ルールを事前に定義できる場面には営業活動においても利用することができるものの、一般にルールが予めわからない営業活動における意思決定においては、ディシジョンマイニングと異なるアプローチを用いてプロセス発見のための解決策を提示する必要がある。また、複雑なフローから主要プロセスのみ抽出するノイズリダクション [42] も活発な研究分野である。

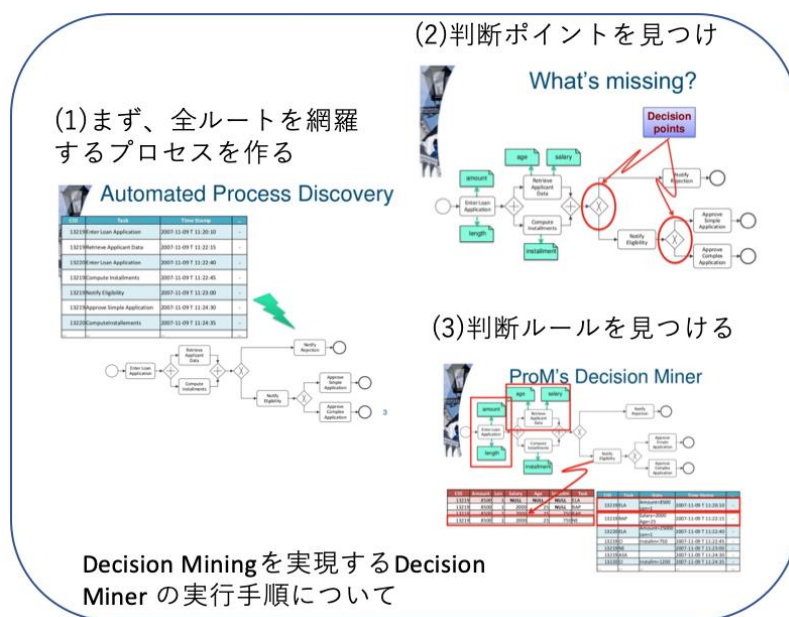


図 2.14 ディシジョンマイニングの概要

(2) 多様な分析視点の提供

プロセスマイニングの結果から、ボトルネックなどの業務分析に活用するための多様な分析視点の提供も活発な分野である。例えば、イベントログに含まれる実施担当者の情報を活用することで、組織的な観点などを分析視点に取り入れるなどの試みが研究されている[43].

(3) オペレーショナルサポート

近年はプロセス実行中に意思決定をサポートするオペレーショナルサポートが進展しており、本研究もこの研究分野の範疇に入る。オペレーショナルサポートでは、プロセスが統制ポイントから外れるとそれをプロセスモデルが検知してアラートを出したり、プロセスの終了時刻を予測して実施担当者に提示したり、またアクティビティの選択肢が複数ある場合には効率面や統制面で一番優れているアクティビティをリコメンド提示することが可能である[44][45][46]。ただし、内部情報であるイベントログに基づいたサポートであるため、提示するリコメンドにも限界がある。近年は、内部情報であるイベントログに加えて、天気予報などの外部情報を取り入れる試みも始まっているが、これらの外部情報の取り込みはこれからのテーマである。本論文でもイベントログに加えて、顧客反応という外部情報を取り入れる試みと位置づけることができ、さらにそれによって営業担当者の複雑な意思決定を確率的に表現したプロセスモデルを構築することで、プロセス実行中の意思決定サポートを可能としている。




図 2.15 オペレーショナルサポートの概要

## 2.4 営業活動におけるプロセスモデル構築の課題

### 2.4.1 営業日報における課題

営業活動におけるプロセスモデル構築においては入力データが営業日報となるため、プロセスマイニング適用時のイベントログにはない特有の課題があり、それについて述べる。

営業日報に最低限含まれるデータは、日時/営業担当者/案件名/活動内容(アクティビティ)/顧客反応であるが、営業支援システムとメールでは蓄積されている形式に違いがある。営業支援システム(SFA)では、すべての項目が画面よりプルダウンで選択する形式となっており、構造化して蓄積されている(図2.15)。それに対して、メールでは、日時(=メール送信日時)/営業担当者(=メール送信者)/案件名(=タイトル)については構造化された形式で抜き出すことができるもの

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

の、活動内容(アクティビティ)と顧客反応が自然文中に埋没して記載されている。そのため、メール利用企業の場合は、プロセスモデル構築の前準備として、自然文中に埋没された非構造化データから、該当するアクティビティを特定することと顧客反応を抽出することが必要となる。図2.16には全体像が記載されているが、営業支援システム(SFA)では案件ごとの営業日報がアクティビティごとに登録されるため、すでにアクティビティが特定された状態になっているが、メールでは自然文中に記載されている内容から該当するアクティビティを推定し自動特定する仕組みと、顧客反応を抽出する仕組みを前処理として導入する必要がある。

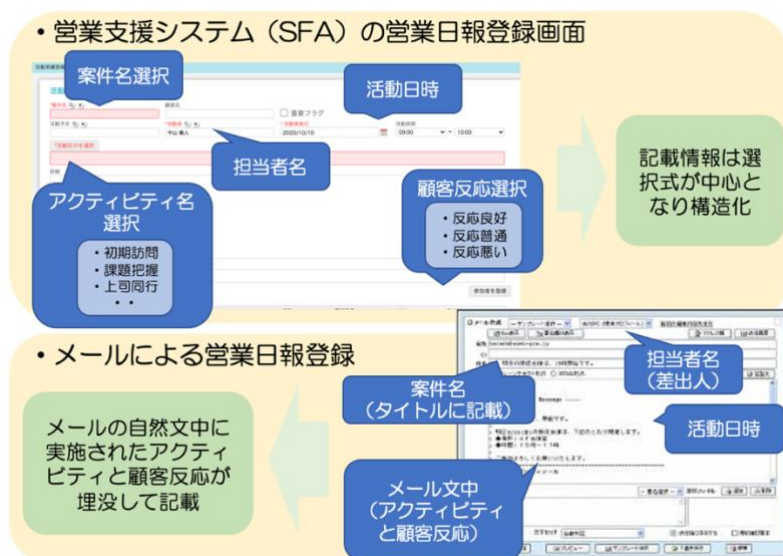


図 2.16 営業支援システム(SFA)とメールによる営業日報の違い(1)

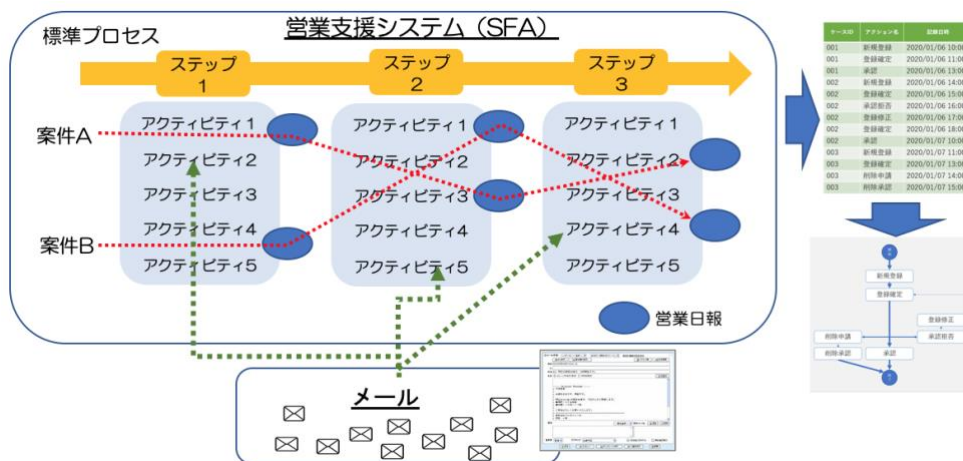


図 2.17 営業支援システム(SFA)とメールによる営業日報の違い(2)



### 2.4.2 顧客反応の抽出における課題

メール利用企業の場合は、プロセスモデル構築の前準備として、自然文中に埋没された非構造化データから、アクティビティを特定することと顧客反応を抽出することが必要であることについて述べた。ここではその中の、顧客反応の抽出について事前に補足する。

顧客反応とは、営業担当者が実施したアクティビティに対する顧客側の反応であり、営業活動のプロセスモデルの構築に必要なのは、「良」「普通」「悪」などに近似された情報である。営業担当者の実施したアクティビティとそれに対する顧客反応の系列情報のデータセットから受注確率を含んだプロセスモデルが構築される事になる。

そこで、本研究においては、メール文中からポジティブ/ネガティブ判定[47]により、顧客反応の抽出を試みた。その結果、単純な「プレゼン反応」アクティビティなどはメール文中に顧客反応がわかりやすく記載されることが多いため、営業日報メールを「反応よし/反応普通/反応悪い」という分類判定ができた。しかし、「顧客の課題把握」アクティビティなどは営業日報メールの文中に顧客課題らしき情報が自然文として記載されているが、そこから顧客課題の有/無/不明などに分類判定することは極めて難易度が高かった。そこで、本論文においては、ポジティブ/ネガティブ判定は採用せず、熟練営業がリアルな営業日報データから顧客反応を手動で抽出することにした。これについては、「4.3.4 フィードバックのルール」で再度説明する。

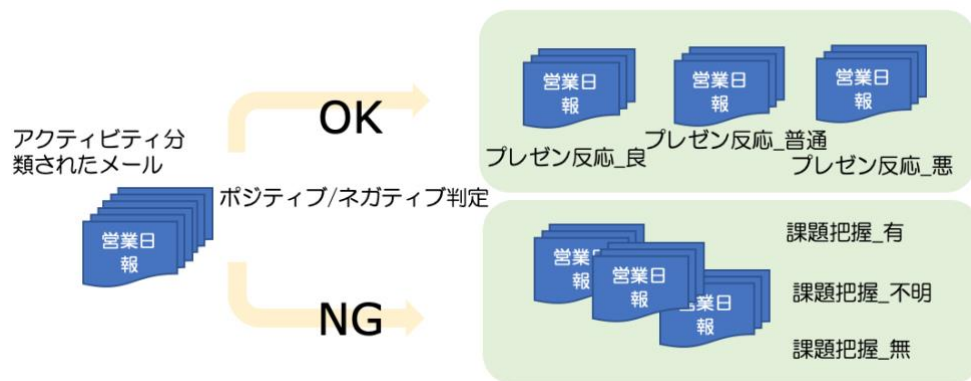


図 2.18 ポジティブ/ネガティブ判定による顧客反応の抽出

### 2.4.3 プロセスモデル構築の2つの課題

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

2.4.1章で述べたメールと営業支援システム(SFA)のそれぞれに蓄積された営業日報データの形式の違いという課題を踏まえ、本論文におけるプロセスモデルの構築を以下の2つの課題で整理する。

### 課題1:

メール利用企業では前処理として自然文のメールから該当するアクティビティを特定し分類する必要がある。これにより、日時/営業担当名/案件名にアクティビティの情報を明示的に追加することができる。メールに記載されている内容から該当するアクティビティを推定し自動特定するために、機械学習を活用する。

### 課題2:

次に、該当するアクティビティに分類された営業日報から熟練営業が顧客反応を抽出し(2.4.2章)、アクティビティとそれに対する顧客反応の系列情報を作成する。この系列情報のデータセットを利用して、そこから機械学習により受注確率の高いプロセスを抽出しプロセスモデルを構築する必要がある。営業支援システムの利用企業では、日時/営業担当名/案件名/アクティビティ/顧客反応がすべて構造化されて蓄積されているため、課題1は省略して課題2から始めることができる。

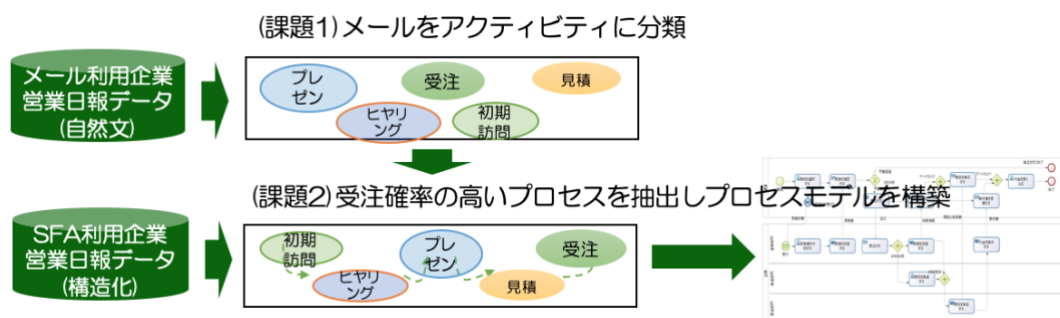


図 2.19 プロセスモデル構築の2つの課題

### 2.4.4 (参考)プロセス抽出後のプロセスモデルの作成

受注率の高いプロセス抽出の結果は XES 形式<sup>12</sup>を通じてプロセスモデルが構築され、その後、BPMN 形式<sup>13</sup>に変換され、BPM ツール<sup>14</sup>に取り込むことが可能となる。プロセス抽出後のこれら一連の処理では従来のプロセスマイニングの手法を踏襲する。具体的には、まずプロセス抽出結果を XES 形式のログとして生成する。このログをプロセスマイニングツールで代表的な OSS である ProM<sup>[48]</sup>に取り込むと、アルファアルゴリズム<sup>[49],[50]</sup>を利用してペトリネット<sup>[51]</sup>を生成する。この結果を BPMN 形式に変換する際には、ProM の BPMN Miner<sup>[52]</sup>を利用する。全てプロセスマイニングの定型的な処理であるため、本論文では詳細は割愛する。

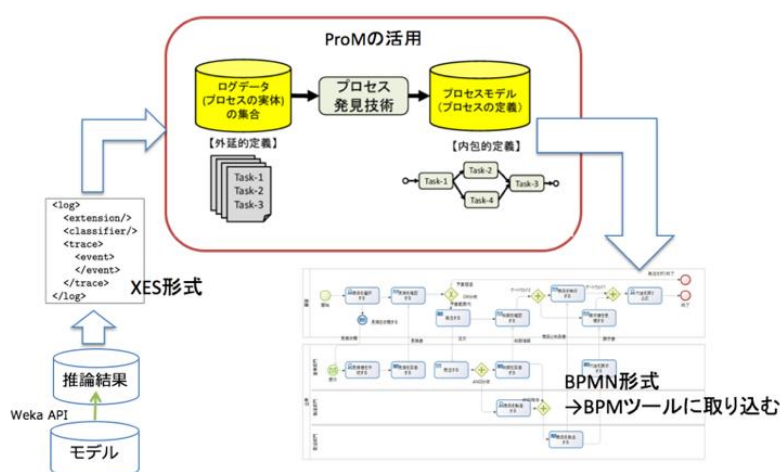


図 2.20 XES 形式から BPMN 形式への変換

## 2.5 むすび

<sup>12</sup> XES 形式<sup>[53]</sup>とは、IEEE CIS Task Force on Process Mining の XES Working Group で策定されつつある、ログデータの標準規格である。

<sup>13</sup> BPMN 形式<sup>[54][55][56][57]</sup>とは、ビジネスプロセスを定義するための標準的な図的な表現の一つであり、プロセスの直観的把握にすぐれている。元々は、複数の企業が標準案の策定を目指して参加していた BPMI(Business Process Management Initiative) から 2004 年 5 月に BPMN 1.0 として公開された標準仕様であり、Business Process Modeling Notation の略語とされていた。その後、BPMI は 2005 年 6 月 29 日に OMG(Object Management Group) との統合がアナウンスされ、BPMN の規格は、1.1, 1.2 という改版を経て、BPMN 2.0 として大きく改訂された。BPMN という名称も 2.0 より、Business Process Model and Notation の略とされている。

<sup>14</sup> BPM ツール<sup>[58][59]</sup>とは、「BPMS (BPM Software/BPM Suite)」とも呼ばれており、ビジネスプロセスを管理することで各プロセスの業務の可視化や改善の支援を目的としている。モデリング、シミュレーション、モニタリングの 3 つのサイクルを繰り返すことで、導入されたプロセスが期待通りに機能しているかどうかを常に監視し、継続的に業務の改善・最適化を行うことができるようにするのが BPM ツールの目的である。消費者ニーズの多様化にともない、「業務プロセスの効率化」が多くの企業の課題となっている昨今、ビジネス上の仕組みを最適化する BPM ツールに対するニーズは高い。

## 第2章 プロセスモデルに基づく営業活動の意思決定支援

---

営業活動の意思決定には属人的な要素が多く、その結果が受注の可否に与える影響も大きいという課題に対して、蓄積した営業日報を活用して、受注確率の高いアクティビティを営業活動プロセスを通じて営業担当者にリコメンドする仕組みを営業活動意思決定支援システムとして構築するという本論文の目的について述べた。これにより、効果の高い営業を組織全体で再現する仕組みを実現できる。

この目的に向けて、プロセスマイニングを応用して過去の営業日報から受注確率の高いプロセスを抽出し、プロセスモデルを構築するというアプローチについても述べた。しかし従来のプロセスマイニングは実施回数や処理時間に基づいたプロセス抽出であり、受注確率の高いプロセスの抽出とは相違がある。そこで、本論文では、プロセスマイニングに確率的な情報処理を応用した新たなプロセスモデルの構築手法を確立し検証する。

具体的には、メールと営業支援システム(SFA)のそれぞれに蓄積された営業日報データの形式の違いを踏まえ、メール/営業支援システム(SFA)のどちらの利用企業にも適用可能なプロセスモデル構築に向け、以下の課題に取り組む。

### (課題 1:メール利用企業)

メールの記載内容から該当するアクティビティを特定し分類する。これについては、第3章「営業日報メールのアクティビティ分類」にて記述する。

### (課題 2:メール/SFA 利用企業)

アクティビティごとに分類された営業日報データから、受注確率の高いプロセスを抽出しプロセスモデルを構築する。これにより、受注確率の高いアクティビティを営業活動プロセスを通じて営業担当者にリコメンドする仕組みが構築できる。これについては、第4章「プロセスモデルの構築と評価」にて記述する。

## 第3章

---

# 営業日報メールのアクティビティ分類

### 3.1 はじめに

営業支援システム(SFA)の普及に伴い、これまでブラックボックスであった営業活動にも科学的なスポットライトがあたるようになってきた。特に、営業支援システムが標準的に持つプロセス管理という管理手法は、これまでの営業活動の捉え方を大きく変えるきっかけになった。まずは、初期折衝からプレゼンテーション、見積もり、受注までのステップごとに実施されるアクティビティを標準化し、さらに営業日報をその標準化されたアクティビティに沿って記載・登録していく仕組みである。これにより、営業マネージャーは案件の進捗が可視化できるようになるため、案件ごとの受注までのリードタイムを予測したり、あるいは期末までの売上予測なども可能となり、営業活動を科学的にマネジメントできるようになった。

しかし一方で、日本国内ではこの営業活動支援システムの普及率は未だ30%にとどまっており、残りはその代替としてメールによる営業日報登録と共有を続けている。その原因として営業支援システムの導入コストの高さもあるが、もう一つ大きい要因は「営業支援システムはマネージャーのためのシステムである」という事実である。先ほど述べたものは営業マネージャーにとっては利点がある仕組みであるが、営業担当者にとってはもっと直接的な支援が欲しい。本論文で提唱する「営業担当者への受注効果の高いリコメンドが可能な意思決定支援システム」は、まさに現場の営業担当者のための仕組みである。そこで、本論文では、日本国内でもいまだに多いメール利用企業を対象にして、活用できる仕組みを目指していく。

まずは、前節の課題1で述べたように、メール利用企業では、メールの記載内容から該当のアクティビティを特定して分類する必要がある。この章では、その概要について述べた後、分類先となる標準アクティビティについて述べる。その後、アクティビティ分類のアルゴリズム選定と、選定したアルゴリズムによる学習モデルの構築の詳細を述べ、最後にその検証結果について述べる。このアクティビティ分類の仕組みを構築できると、以降の運用でどんどんと増えていく営業日報についても、継続的にアクティビティ分類が可能な仕組みを構築することが可能である。

### 3.2 営業日報メールのアクティビティ分類

#### 3.2.1 アクティビティ分類とは

前章の課題1で述べたように、メール利用企業では入力データである営業日報が自然文のメールであるため、メール文面内にアクティビティ名が埋没している。そこで、まずアクティビティ推定に

においては、自然文の営業日報が、営業プロセス内の総計 37 種類のアクティビティ中のどれに属するものなのかを分類する仕組みが必要となる。これにより、日時/営業担当名/案件名にアクティビティの情報を明示的に追加することが可能となり、プロセスマイニング実施に最低限必要な情報を揃えることができる。

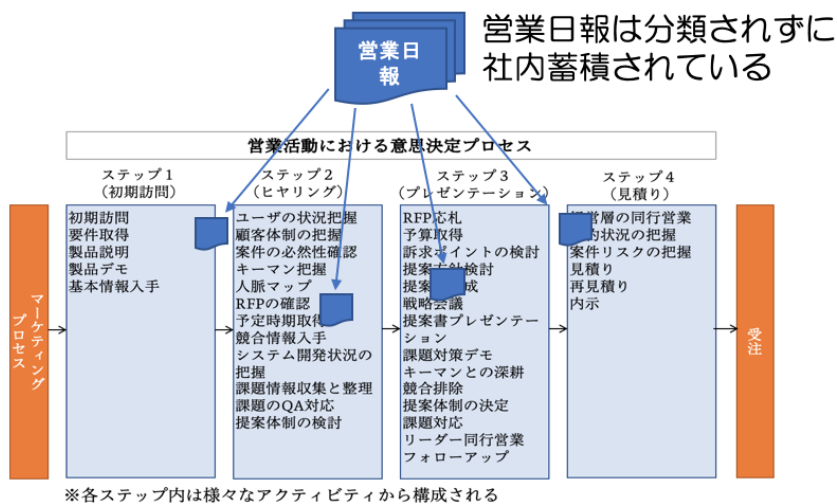


図 3.1 営業日報メールのアクティビティ分類

本論文では、自然文であるメールの営業日報を、該当するアクティビティに分類する分類システムの構築方法について述べる。この分類システムを利用することで、運用時にどんどん追加されてくるメールの営業日報を、それが属するアクティビティに自動分類する運用オペレーションが確立できる。

### 3.2.2 営業活動の標準アクティビティ

このアクティビティ推定において、分類先となる営業活動のアクティビティとして、以下の標準的なアクティビティリストを用いる。法人向けの営業では骨格はほとんど同じであり、営業の一般的な教科書にも掲載されているものである[60]。

アクティビティは大きく4つのステップ(初期訪問, ヒヤリング, プレゼンテーション, 見積り)に分類されており、また系列は一般的に長く、法人営業では20~100系列あることが普通である。また同一アクティビティの繰り返し実施も頻繁にある。会社や製品によってはマイナーチェンジが必要となり、営業支援システム(SFA)を導入する会社ではこの標準アクティビティリストを初期プロセスとして定義し、その後、それぞれの会社独自のプロセスにチューニングしていくことが多い。一方で、この

定義があまりに厳格すぎると、営業担当者が顧客の行動に柔軟に適応できなくなるリスクもある [61][62].

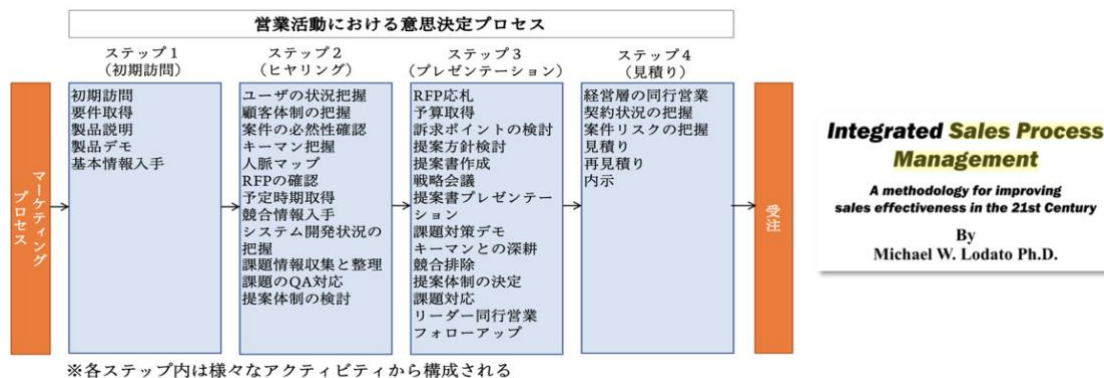


図 3.2 営業活動の標準アクティビティ

### 3.3 アクティビティ分類システムの構築

#### 3.3.1 アクティビティ分類のアルゴリズム選定

アクティビティ分類は文書分類を目的とした自然言語処理である。そのため、学習モデルとしては以下が候補となる。

(1) トピック分類

トピック分類とは、文書が複数の潜在的なトピックから確率的に生成されると仮定したモデルである。また文書内の各単語はあるトピックが持つ確率分布に従って出現すると仮定する。トピックモデルでは、トピックごとに単語の出現頻度分布を想定することで、トピック間の類似性やその意味を解析できる。



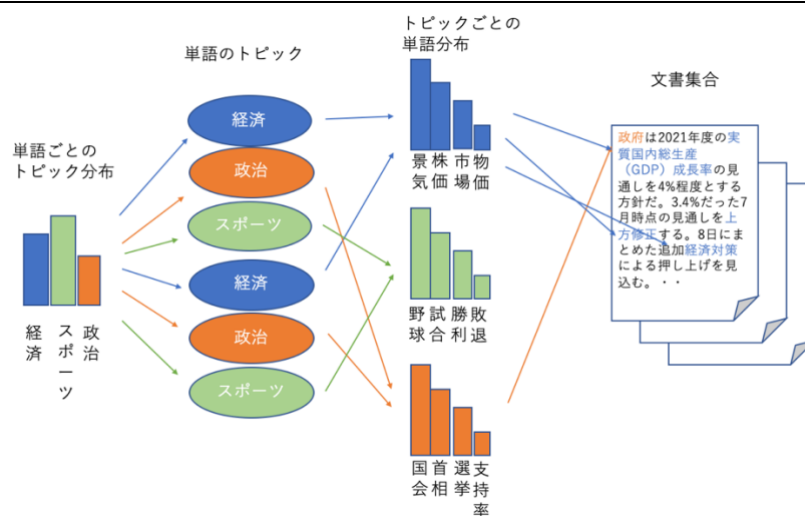


図 3.3 トピック分類

(2) ベクトル化

任意の長さの文書や単語を固定長のベクトルに変換することで文章の分散表現を獲得する。これにより、コサイン類似度による類似度計算などの処理が可能となる。

(3) 深層学習

深層学習とは、ニューラルネットワークを多層に結合して表現・学習能力を高めた機械学習の一手法である。ニューラルネットワークの中間層を複数にすることで、特徴量をコンピューターが判断する。そのため、大量の教師データを必要とする。

一般に営業活動の履歴である営業日報データは大量データではないため、自然言語処理のアルゴリズムから少ない営業日報データでも推定可能な学習モデルとして、Latent Dirichlet Allocation (LDA)[\[63\]](#)[\[64\]](#)によるトピックモデル方式(文章中の潜在的なトピックを推定するトピック分類の代表的なアルゴリズム)と、doc2vec[\[65\]](#)[\[66\]](#)によるクラス分類(文章のベクトル化によるクラス分類の代表アルゴリズム)を選定した。doc2vecでは、Support Vector Machine (SVM) [\[66\]](#)を組み合わせることで、分散表現された学習用サンプルの分離境界面のマージンを最大化する学習を行う。

	LDA	Doc2vec+SVM
メリット	<ul style="list-style-type: none"> <li>モデルの中身が理解可能</li> <li>一つの文章に複数のトピックが含まれる場合に対応可能</li> </ul>	<ul style="list-style-type: none"> <li>短い文章でも高い精度</li> <li>アノテーションが不要</li> <li>類義語も対応可能</li> </ul>
デメリット	<ul style="list-style-type: none"> <li>教師データにない単語は対応不可</li> <li>短い文章では低い精度</li> </ul>	<ul style="list-style-type: none"> <li>モデルの中身が理解不可能</li> </ul>

図 3.4 LDA と Doc2vec+SVM の比較

### 3.3.2 評価データと訓練データの取得

まず、筆者らの所属する(株)NTT データイントラマートから、アクティビティ分類の評価データとして、法人営業の実際の営業日報データ 1722 件を取得した。しかし、自然文を主体とした通常の営業日報データには、ひとつの営業日報内に複数のアクティビティに関する記述がある(一度の訪問で複数のアクティビティを実施するケースがある)。そこで、営業担当者が画面上で該当アクティビティを選択し、入力項目に従って内容を記入していく専用の登録画面を用意することで、営業日報が必ずひとつのアクティビティにラベル付けされるようにした[67]。

この登録画面から取得した営業日報データから、取引先との間で発生した商談である案件データ 16 件(受注/失注を含む)と、それぞれの案件に属する営業日報データ計 324 件を、評価データとは別に訓練データとして用意できた。この訓練データには、受注に繋がった正例データと失注に繋がった負例データが含まれている。この訓練データ 324 件を用いて、LDA を利用した分類システムと、doc2vec+SVM を利用した分類システムを構築し、評価用の営業日報データ 1722 件でそれぞれの分類システムを評価した。

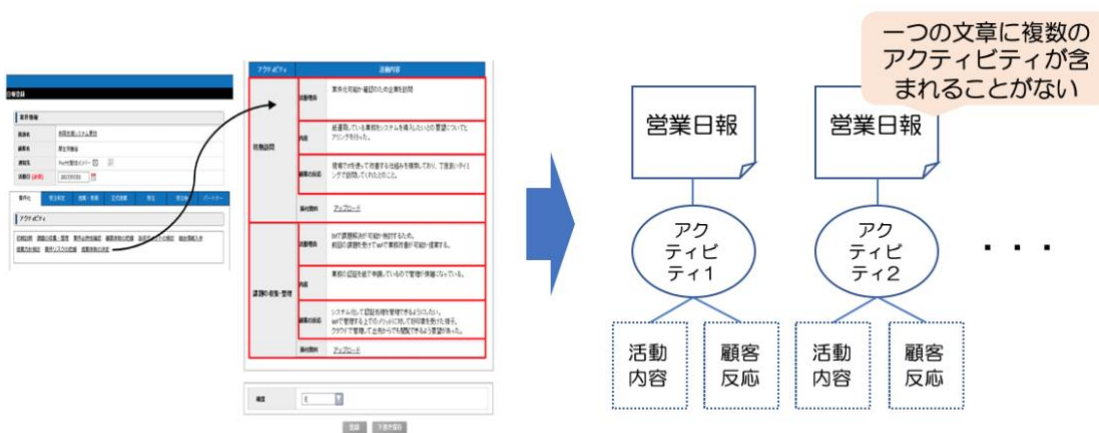


図 3.5 選択されたアクティビティに従って内容を記入する登録画面

### 第3章 営業日報メールのアクティビティ分類

	計	自動車メーカーA	自動車メーカーB	人材派遣サービスC	不動産ディベロッパー	食品卸E	重電メーカーF	建材メーカーG	電力小売業H	公共系外部団体I	精密機械業J	化学メーカーK	重電メーカーL	エネルギー会社M	機械メーカーN	化学メーカーO	重電メーカーP
営業活動(アクティビティ)	324	23	24	24	23	17	22	16	20	25	22	19	15	17	16	18	23
案件基本情報の入手	16	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
企業情報の取得	9	1					1	1	1	1	1	1			1		1
課題の収集・整理	14		1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
案件必然性確認	14	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
顧客体制の把握	11	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
競合情報入手	14	1	1	1	1	1	1	1	1	1	1	1	1	1		1	1
提案方針の検討	13	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
案件リスクの把握	10	1	1				1	1			1	1	1	1	1	1	1
提案体制の決定	6	1				1	1			1	1	1					
提案情報の確認	2						1				1						
競合情報入手	15	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
プロジェクト情報の入手	13	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
契約情報の把握	7	1	1	1						1					1	1	1
システム開発情報	11	1	1	1	1				1	1	1	1	1	1	1	1	1
責任体制の確認	2						1	1									
ユーザ状況把握	14		1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
ステークホルダー情報入手	14	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
製品説明	14	1	1	1	1	1	1	1	1	1	1	1		1	1	1	1
製品イメージデモ	12	1	1	1	1	1	1	1	1	1	1			1	1	1	1
課題情報収集	15	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
課題に対する回答	13	1	1	1	1	1	1	1		1	1	1	1			1	1
RFP対応	3	1		1						1							
提案書作成	11	1	1	1	1	1	1	1	1	1			1	1			1
提案書プレゼンテーション	13	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
同行営業	3		1		1									1			
深耕営業	8	1	1	1	1	1			1	1		1					1
競合排除	14	1	1	1	1	1	1	1	1	1	1	1	1		1	1	1
上位層の同行営業	5	1	1								1	1					1
見積り	10		1	1	1	1			1	1	1	1				1	1
内示	8			1	1		1	1	1	1	1	1					1
受注確定	10			1	1	1	1	1	1	1	1	1			1	1	1

図 3.6 登録画面から取得した訓練データ

### 3.3.3 LDA+熟練営業ノウハウによる分類システムの構築と評価

LDAは、トピック抽出(クラスター化)により出現する単語群をグルーピングするが、教師なし学習であるためトピックの名称(ラベル付け)は人手で行う必要がある。そこで、LDAを用いた分類システムの構築においては、この訓練データ324件を対象にLDAによるトピック抽出を行い、その抽出トピックに熟練営業担当者が正解アクティビティをラベル付けする。例えば、分類されたトピックに、「課長/部長/決裁者」などのキーワードが多く含まれていれば、そのアクティビティを「ステークホルダ把握」と関連づける。その後、評価データである各営業日報データ1722件について1件ごとにトピック抽出を行い、含有率の一番高いアクティビティに分類する。この際、トピックの数が近い場合(例えばステークホルダ把握50件:競合把握50件)は、どちらのアクティビティと判断するか、あるいはノイズとして除外するかという判断を熟練営業担当者が実施する。このようにして分類された評価データを、分類システムの正解率として熟練営業担当者が評価した。ここで熟練営業担当者とは、弊社において10年以上の営業経験を持つベテラン営業を指す。

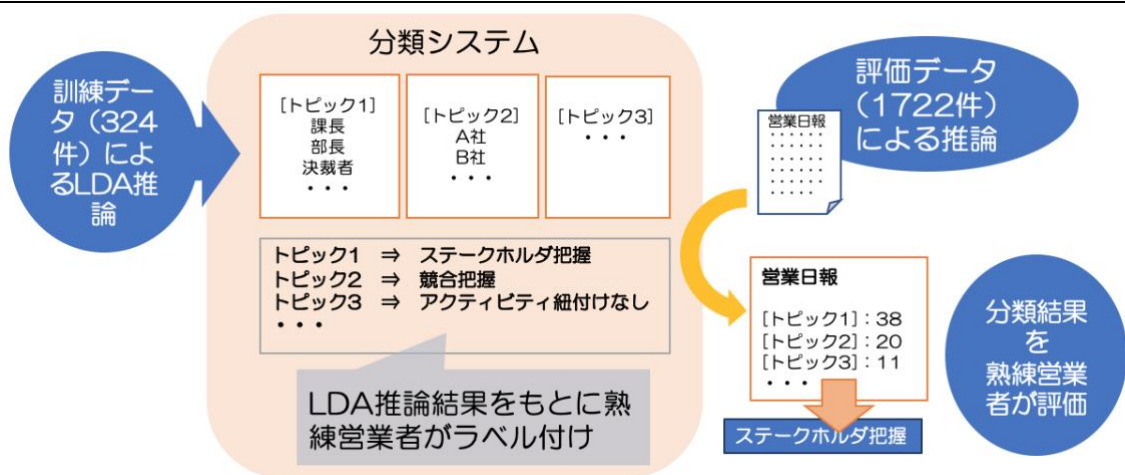


図 3.7 LDA によるモデル構築と評価

### 3.3.4 Doc2vec+SVM によるモデル構築と評価

次に、doc2vec+SVM によるアクティビティ分類では、doc2vec で文章をベクトル化したのち、SVM による教師あり学習となる。そこで、先ほどの訓練データ 324 件を doc2vec でベクトル化した後、SVM による学習モデルで分類システムを構築した。今回は、会社特有の用語の学習を進めるために他の社内システムのコーパスを利用するとともに、Wikipedia や Twitter などのコーパスも利用することで特徴量の抽出を行なった。その後、評価用の営業日報データ 1722 件により、LDA 同様に分類システムの正解率を熟練営業担当者が評価した。

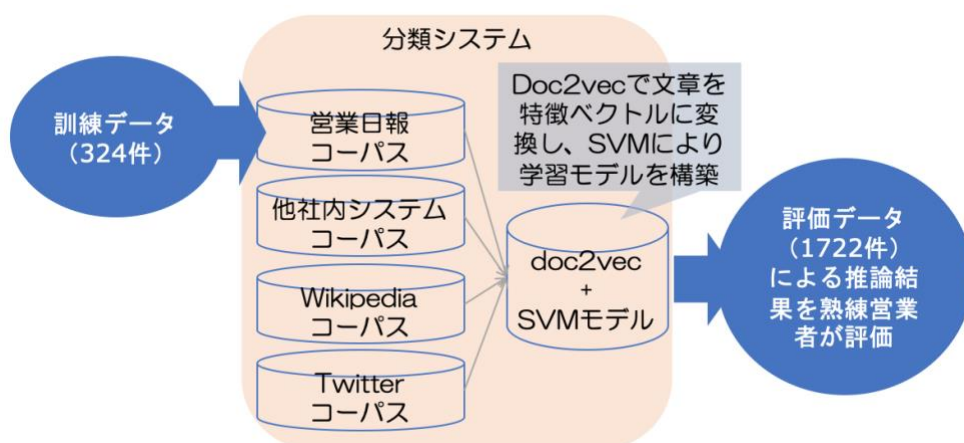


図 3.8 Doc2vec+SVM によるモデル構築と評価

### 3.4 アクティビティ分類の分類システム検証結果

その結果、doc2vec+SVM による分類システムの性能が LDA+熟練営業ノウハウによる分類システムと比較して優れていることを明らかにした[67][68]。Doc2vec+SVM による分類システムが 75%、LDA+熟練営業ノウハウによる分類システムの最大値で 55%となり、doc2vec+SVM による分類システムの方が F 値において高精度であった。

LDA は出現単語数の影響を大きく受けるため、営業日報データが少ない場合は精度が不安定になることが考えられる。また、正解率は熟練営業担当者によるアクティビティのラベル付けの精度に依存してしまう。

さらに、運用に伴い営業日報データが徐々に増える環境では doc2vec+SVM の方がより精度向上を確認した。

#### LDA + 熟練営業ノウハウ

	Recall	Precision	Sensitivity	Specificity	F-measure
LDA 閾値0.002	41.7%	80.6%	41.7%	80.6%	54.9%
LDA 閾値0.005	11.7%	70.0%	11.7%	90.3%	20.0%
LDA 閾値0.01	6.7%	80.0%	6.7%	96.8%	12.3%

#### doc2vec +SVM

	Recall	Precision	Sensitivity	Specificity	F-measure
doc2vec	86.7%	66.7%	86.7%	23.5%	75.4%

図 3.9 アクティビティ分類のアルゴリズム検証結果

### 3.5 むすび

自然文であるメールの営業日報を該当するアクティビティに分類する分類システムの構築方法について述べた。この分類システムを利用することで、運用時にどんどん追加されてくるメールの営業日報を、それが属するアクティビティに自動分類する運用オペレーションが確立できる。

この分類システムの構築にあたり、分類先となる営業活動のアクティビティとして用いた標準的なアクティビティリストについて述べた。次に、アクティビティ推定のアルゴリズムとして、LDA と doc2vec+SVM を比較した。

比較に先立ち、筆者らの所属する(株)NTT データイントラマートから実際の営業日報データ 1722 件を取得した。しかし、自然文を主体とした通常の営業日報データには、ひとつの営業日報

---

内に複数のアクティビティに関する記述があるため、専用の登録画面を用意することで、営業日報が必ずひとつのアクティビティにラベル付けされるようにした。この登録画面から、営業日報データ計 324 件を訓練データとして用意できた。この訓練データ 324 件を用いて、LDA を利用した分類システムと、doc2vec+SVM を利用した分類システムを構築し、評価用の営業日報データ 1722 件でそれぞれの分類システムを評価した。

LDA では、訓練データにより初期分類されたトピックを熟練営業担当者がアクティビティへのラベル付けを実施し、分類システムを構築した。Doc2vec+SVM では、他の社内システムや外部クラウドのコーパスを活用して学習モデルを構築した。

それぞれの分類システムに対して、評価データを活用して熟練営業者が分類結果を評価したところ、営業日報データが少ない環境では、doc2vec+SVM による分類システムが高精度と評価された。

## 第4章

---

# プロセスモデルの構築と評価



## 4.1 はじめに

前章において、営業日報をアクティビティ分類できる仕組みが構築できた。これにより、以降のプロセスモデルの構築を実施するための初期データが用意されたことになる。具体的には、プロセスモデルの構築には、従来のプロセスマイニングを応用し、営業日報から受注確率の高いプロセスを抽出することが必要となる。そのための初期データが前章を通じて準備されたことになる。このようにアクティビティ分類の仕組みが構築できた後は、受注確率の高いアクティビティ推移となるプロセスを推定するフェーズに移る。

4.2章では、まずプロセスモデル構築の概要について述べたのちに、それに必要なプロセス抽出のモデル選定についてその比較を詳細に述べる。その比較結果に基づき、プロセスモデル構築の方針を立てる。プロセスモデルとしては部分観測マルコフ決定過程(POMDP)と深層強化学習の2つを選定した。

その後、4.3章では、部分観測マルコフ決定過程(POMDP)と深層強化学習によるプロセスモデル構築に必要な教師データを大量に準備するための詳細について述べる。具体的には、案件シミュレータというデータオーギュメンテーションの仕組みについて述べる。

その後、4.4章では、部分観測マルコフ決定過程(POMDP)によるプロセスモデルの構築について述べる。隠れマルコフモデルと方策学習による部分観測マルコフ決定過程(POMDP)の近似手法を活用したプロセスモデル構築の詳細について述べたのち、構築したプロセスモデルを実企業に適用した結果について述べる。ここでは、適用環境における評価のモデルを最初に示し、それに基づく検証を行った。

続く第4.5章では、深層強化学習によるプロセスモデルの構築について述べる。まずは、環境モデルの学習とセルフプレイによるプロセスモデル構築の詳細について述べたのち、部分観測マルコフ決定過程(POMDP)によるプロセスモデルとの比較を、熟練営業担当者を対象にしたアンケートで評価を実施した。

## 4.2 プロセスモデルの構築に向けて

プロセスマイニングに必要となる、日時、営業担当者、案件名、アクティビティ名、顧客反応を入力データとして、受注確率の高い系列情報(顧客反応とそれに対するアクティビティ)をプロセスとして抽出する。これにより、営業活動プロセスを通じて、受注率の高い次のアクティビティのリコメン

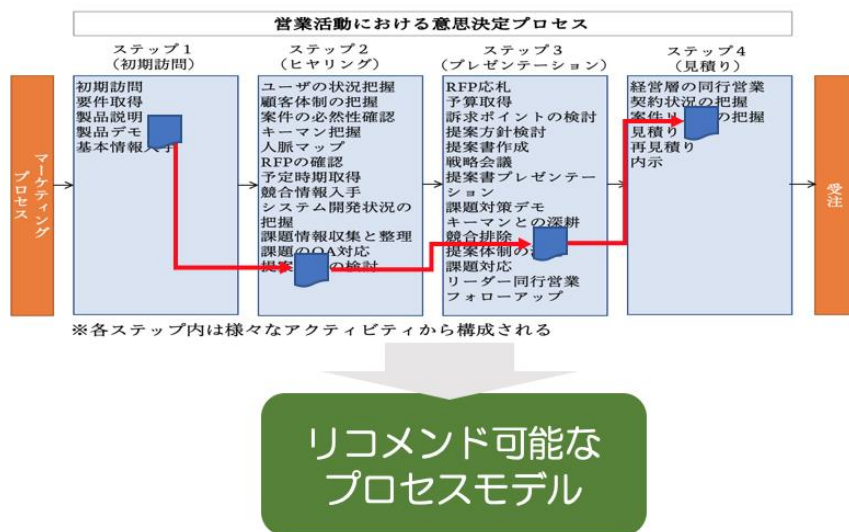


図 4.1 プロセスモデル構築の概要

### 4.2.1 プロセス抽出のモデル選定

プロセス抽出のための学習モデル構築アルゴリズムとして候補を選定する。候補として、リコメンド関連の代表的な以下の5つを選定した。

(1) 協調フィルタリング (Collaborative Filtering) [69][71]

協調フィルタリングは、アイテムに対する他のユーザーの評価に基づいたリコメンドを行う手法である。アイテムの特徴とユーザーのプロファイル情報に基づいてリコメンドを行う内容ベースフィルタリング (Content Based Filtering) [69][70]と異なり、協調フィルタリングでは、多くの営業担当者の活動情報を蓄積し、アクティビティに対する営業担当者の評価を学習し、営業優秀者の活動情報を用いて推論を実施する。

具体的には、ある営業担当者 a が営業活動のある局面でアクティビティ A とアクティビティ B を選択したとする。その後、別の営業担当者 b が同じ局面でアクティビティ A を選択すると、2人の営業担当者は似ている意思決定を持つ営業だと判断される。それにより、営業担当者 b にもアクティビティ B がリコメンドされる仕組みとなる。協調フィルタリングのメリットは、アクティビティの特徴に依存することがないため汎用的な仕組みとなる。その一方で、営業担当者による選択結果を使うので、未だ選択されたことのないアクティビティはリコメンドできない。

(2) 静的ベイジアンネットワーク(Static Bayesian Network) [\[72\]](#)[\[73\]](#)

ベイジアンネットワークは、因果関係を確率により記述するグラフィカルモデルの1つで、複雑な因果関係の推論を有向非巡回グラフ構造により表すとともに、個々の変数の関係を条件つき確率で表す確率推論のモデルである。ベイジアンネットワークは確率推論アルゴリズムとして1980年頃から研究が進められ、既に長い研究と実用化の歴史がある。アクティビティ間の依存関係(因果関係/相関関係)をモデル化することで、データ数が少なくても学習モデルを構築可能である。以下の図では、ノード D1からノード S1へとノード D2からノード S1への因果依存性があり、またノード D1からノード S2へとノード D2からノード S2への因果依存性があることがわかる。




図 4.2 静的ベイジアンネットワーク(SBN)の事例

(3) 動的ベイジアンネットワーク(Dynamic Bayesian Network) [\[74\]](#)

静的ベイジアンネットワーク(SBN)が時系列を明確にモデル化しないのに対して、ネットワークに時間的情報を含むよう拡張したものが動的ベイジアンネットワーク(DBN)である。SBNをDBNに拡張するもっとも簡単な方法は、SBNの複合インスタンス(タイム・スライス)を含み、それらをお互いにリンクさせることである。たとえば、図4.2のネットワークは、図4.3のネットワークの複合インスタンスのリンクによって得られる。




図 4.3 動的ベイジアンネットワーク(DBN)の事例

今日実施したアクティビティは、次回に実施するアクティビティに影響を持つ。したがって、“今日のアクティビティ”を表現するノード(ノード D1 とD2)と“次回のアクティビティ”を表現するノード(ノード D1\* と D2\*)の間にリンクを張ることになる。この新しいネットワークを用いて、時間的情報を持つアクティビティの進捗を予測することができる。

(4) 部分観測マルコフ決定過程 (Partially Observable Markov Decision Process; POMDP)[\[75\]](#)  
[\[76\]](#)[\[77\]](#)

マルコフ決定過程 (MDP)における基本的な問題設定は、現在の状態が与えられたときに意思決定者の取る行動を既定する政策 (policy) を求めることである。政策を求める際に用いられるゴールは、現在時刻から無限先の未来までにおける「割引された」報酬の累積値が用いられる。割引因子 (discount factor) と呼ばれる値であり、現在の報酬と未来の報酬との間における重要度 (importance) の差異を表している。状態が確率的に遷移することから上の値は確率変数となるため、通常はその期待値が用いられる。ある政策を採用した場合における割引報酬和は現在の状態のみに依存し、これを状態価値関数 (state-value function) と呼び、最適ルート満たす政策を最適政策 (optimal policy) と呼ぶ。

上記の定義より、営業活動における顧客の内部状態はマルコフ決定過程であると言える。顧客の内部状態は確率的に遷移するが、営業からのアクティビティによってその遷移確率は変化することになる。

また、マルコフ決定過程 (MDP) では政策を計算する際に現在の状態が既知であることを仮定している。実際には状態観測に不確実性が伴う場合などこの仮定が成り立たない場合が多く、このような場合の一般化として部分観測マルコフ決定過程 (POMDP) が用いられる。営業活動においても、顧客状態は直接観測できないことから、この部分観測マルコフ決定過程 (POMDP) にてモデル化することが可能である。形式的には、部分観測マルコフ決定過程 (POMDP) は隠れマルコフモデル (HMM) に行動および行動を変更する動機を与える報酬を

---

付与したものと解釈することができる。

(5) 深層強化学習 (Deep reinforcement learning) [78][79]

状態遷移確率や報酬関数が未知の場合、環境との相互作用を通じてこれらの情報を得ながら行動を決定する必要があり、このような問題は強化学習の枠組みで議論される。強化学習における代表的な学習アルゴリズムは Q 学習と呼ばれるものであり、行動価値関数 (action-value function) と呼ばれる関数に着目する。強化学習では最適化に必要なパラメータの学習を状態遷移確率・報酬関数を介することなくおこなうことができる (一方で価値反復法や政策反復法ではそれらの明示的な仕様を与える必要がある)。また、「セレンディピティ<sup>15</sup> (営業担当者にとって意外性のあるリコメンドを可能とする)」の観点でも、強化学習の探索を通じて実施可能なリコメンドとして魅力的な要素となる。

状態数 (および行動の選択肢) が膨大な場合、強化学習はしばしばニューラルネットワークなどの深層学習と組み合わせられる (深層強化学習)。この深層強化学習にも多くのバリエーションがあり、状態価値関数または状態行動価値関数の近似に深層学習を使うもの、さらには方策学習において深層学習を使うものもある。

本論文では、深層学習による観測データからの特徴量抽出と時系列データ生成を強化学習に適用して、これまで制御が難しいと考えられていたタスクを制御できるようにする試みを検討する。具体的には、深層学習により環境 (顧客) の特徴量を算出し、その環境に対する営業エージェントの試行的な行動で得られる報酬が最大化される方策 (Policy) を学習する。深層学習は入力されたデータからの自律的な特徴抽出を可能にする一方で、強化学習は外部からの入力に対応して自律的な制御を行うことを可能にする。この自律的な特徴抽出と自律制御の組み合わせである深層強化学習は、Alpha Go の登場に象徴されるように、強化学習に飛躍的なブレイクスルーをもたらした [80]。

## 4.2.2 営業活動意思決定支援システムの特徴とモデル選定

営業活動意思決定支援システムの構築を目的として、その特性を明らかにするとともに、先述の5つの学習モデルを比較した (図4.4)。

---

<sup>15</sup> セレンディピティ [81]: 偶然によって思いがけず価値あるものを発見する能力。セレンディピティな (思いがけず価値のある) アクティビティを営業担当者に提示することが、営業担当者自身にとって、これまでの経験の枠組みにとらわれず、受注可能性の幅を多様に広げるきっかけとなり、その営業担当者の受注率向上につながるできると考える。

特性のひとつめである「営業活動の確率的状態遷移で表現」とは、営業プロセスを通じたアクティビティの選択を確率的に表現できることを要件としてあげている。営業活動意思決定支援システムの目的である受注確率の高いリコメンドの提示には、受注確率を含んだプロセスモデルの構築が必要となるため、この要件は絶対的に必要となる。比較表の通り、この要件を満たすのは強調フィルタリングを除いた4つの学習モデルとなる。強調フィルタリングでは、営業優秀者の活動情報を用いて推論を実施する方式となるため、アクティビティの選択履歴を確率的に表現できない。

次に、特性のふたつめとなる「営業活動における時間連続の意思決定を支援」は、営業活動の時間的推移を考慮可能な学習モデルであることを要件としている。一般的に営業活動は長い系列となるため、この時間的情報が学習モデルとして考慮されている必要がある。比較表の通り、この要件を満たすのは「動的ベイジアンネットワーク(DBN)」「部分観測マルコフ決定過程(POMDP)」「深層強化学習」の3つの学習モデルとなる。

最後の要件である「顧客状態によりリコメンドが変更」は、長い営業活動のプロセスを通じて顧客の状態は変化していくことから、リコメンドもそれに合わせて変更していく必要があることを意味している。直接は観測できない顧客状態を推定することで高い精度のリコメンドを可能とする。比較表の通り、環境である顧客状態を学習モデルとして考慮可能な学習モデルは、「部分観測マルコフ決定過程(POMDP)」「深層強化学習」の2つとなる。動的ベイジアンネットワーク(DBN)でも、因果関係ネットワークの中に顧客状態のノードを追加することで対応は可能であるが、特殊な形態であることと、ベイジアンネットワークは総当たり計算となりかなりの計算量となる[72][73]ことが予想されたため本論文では除外することにした。

以上、営業意思決定支援システムに必要な3つの要件を満たす学習モデルとして、本論文では「部分観測マルコフ決定過程(POMDP)」と「深層強化学習」の2つを選定した。厳密には、「部分観測マルコフ決定過程(POMDP)」は環境のモデル化であり、深層強化学習と直接比較するものではないが、ここでは定量的な比較が目的ではなく、営業活動意思決定支援システムの構築手段の候補として比較していることに注意されたい。あくまでも営業活動ドメインの中で大きな枠組みとして候補を選定している。



営業活動意思決定支援システムの特徴	協調フィルタリング	SBN	DBN	POMDP	深層強化学習
営業活動の確率的状態遷移で表現	×	○	○	○	○
営業活動における時間連続の意思決定を支援	×	×	○	○	○
顧客状態によりリコメンドが変更	×	×	×	○	○

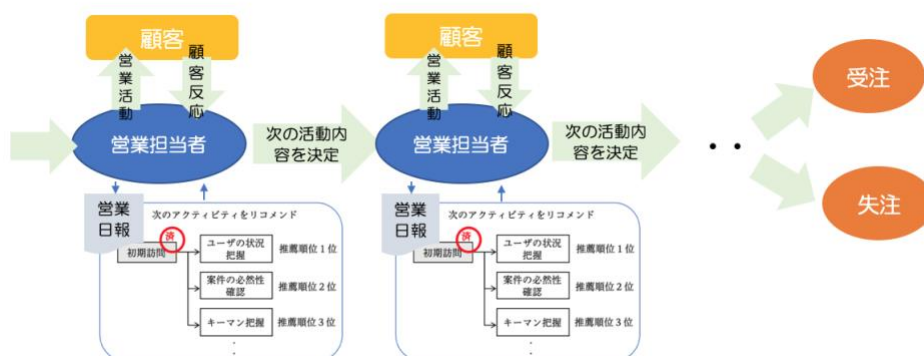


図 4.4 営業活動意思決定支援システムの特徴と学習モデルの比較

### 4.2.3 プロセスモデル構築のステップ

先述のように、本論文では営業活動意思決定支援システムのプロセスモデル構築にあたり、「部分観測マルコフ決定過程(POMDP)」と「深層強化学習」の比較をおこなう。しかし、このふたつの学習モデルはどちらも前処理として大量の教師データを必要とする。第3章のアクティビティ分類で営業日報メールから取得できた評価データ1722件では圧倒的に少ないことから、データオーギュメンテーション [82] による学習データの水増しで教師データを準備しなくてはならない。それを踏まえて以下の章立てについて述べていく。

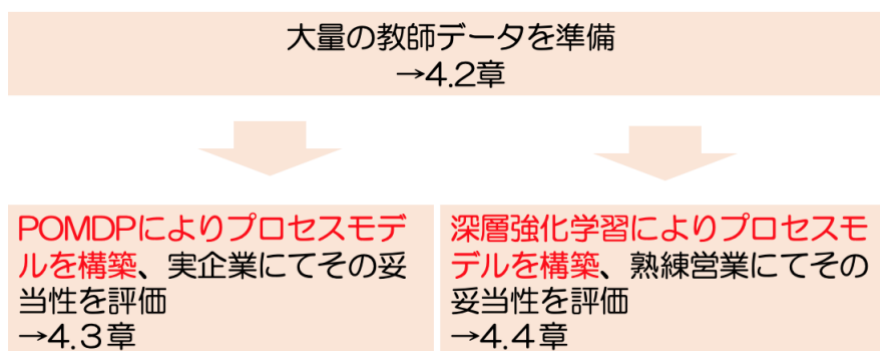


図 4.5 4.3章以降の章立て



まず、第4.2章にて大量の教師データの準備についてその詳細を述べる。その後、用意できた教師データを利用し、4.3章では部分観測マルコフ決定過程(POMDP)によるプロセスモデル構築の詳細と、実企業への適用評価について述べる。4.4章では、同じ教師データを利用して、深層強化学習によるプロセスモデル構築の詳細について述べるとともに、最後に熟練営業担当者へのアンケートにより部分観測マルコフ決定過程(POMDP)と深層強化学習との比較評価を示す。

## 4.3 教師データの準備

### 4.3.1 教師データとは

教師データとは、機械学習の教師あり学習においてあらかじめ与えられる例題と答えのデータであり、本論文においては、顧客反応とそれに対する次のアクティビティの系列情報と、そのデータセットの中でも受注確率の高いプロセスを意味する。この章では、一般的に大量データの取得が難しい営業日報データを、案件シミュレータによりデータオーギュメンテーション [82] した手法について述べる。

### 4.3.2 案件シミュレータによる教師データの準備

部分観測マルコフ決定過程 (POMDP) と深層強化学習による学習モデルの構築においては、時系列を含んだ営業日報データを教師データとして大量に用意する必要がある。この課題に対し、営業をエージェント、顧客を環境と位置付けた案件シミュレータを開発し、ルールベースの営業日報データを自動生成した。

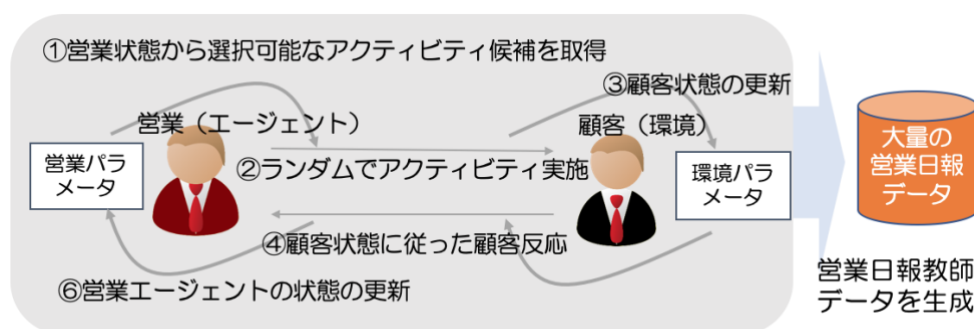


図 4.6 案件シミュレータの概要

案件シミュレータの詳細について述べる。まず、営業パラメータ/顧客パラメータの各項目が正規分布で初期設定された状態からスタートし、その後、営業状態に基づくルールベースのアクティビティ候補の中からランダムにアクティビティが選択実施される。具体的には、図3. 2の各ステップを営業状態とし、その中に属するアクティビティがランダムに選択される。次に顧客側では、正規分布で重み付けされた顧客特性に従い顧客状態が更新される。例えば、アクティビティとして「プレゼン実施」が選択された際に、「実績重視」の特性を持つ顧客ではそのパラメータがより加算して更新される。その後、更新された顧客状態に即した顧客反応が後述するフィードバックルールから選択さ

れ、最後に、顧客反応に対応したルールベースの重み付けにより営業パラメータが更新される。このため、営業側でも顧客状態の推定値を保有することができる。初期値では営業パラメータ/顧客パラメータは異なる値からスタートするが、案件シミュレータの営業(エージェント)と顧客(環境)のやりとりを通じて同じ値に近づくことが、受注をするために必要となる。

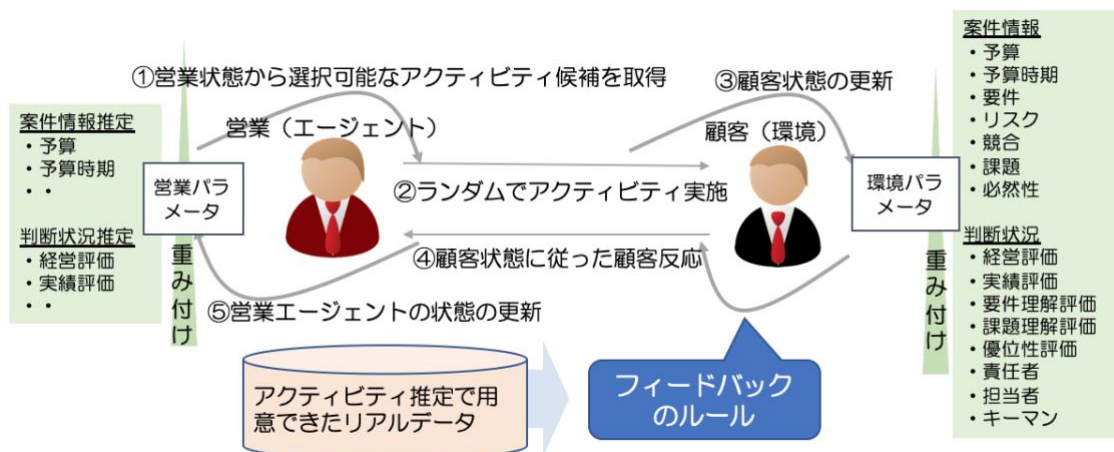


図 4.7 案件シミュレータの詳細

次に、案件シミュレータの中でも重要な位置付けとなるフィードバックルールについて述べる。ここでは、アクティビティ推定を通じて得ることのできた計 2,046 件(訓練データ 1722 件+評価データ 324 件)の営業日報データを用いて、アクティビティと顧客状態の区分ごとに顧客反応のフィードバックルールを、熟練営業担当者が設定した。取得した営業日報データではその後の営業引き継ぎも考慮してかなり細かいレベルまで記述されていたことから、人によるルール設定とはいえ、営業実態をほぼ正確に投影したルールであると言える。

このようにフィードバックルールに熟練営業担当者の判断を入れることで、データオーギュメンテーションで最終的に取得できる営業日報データは、この熟練営業担当者のノウハウを反映したものとなる。

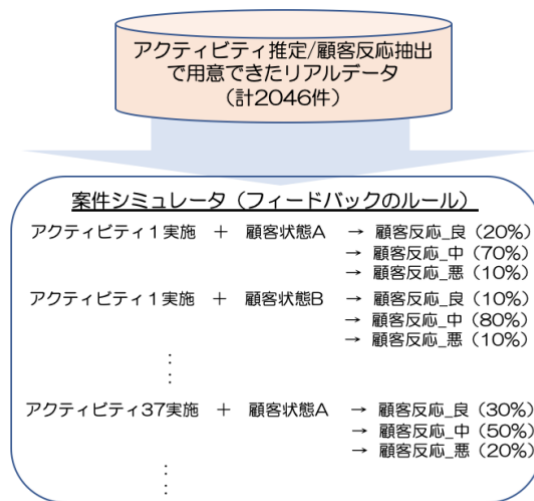


図 4.8 フィードバックルールの詳細

以上述べた案件シミュレータを用いることで、ルールベースの営業日報データを自動生成した。結果として、案件データ総数 10,000 件とそれに属するアクティビティデータ総数 267,000 件の十分なデータ量を確保することができた。アクティビティデータとは営業日報データに相当するものである。

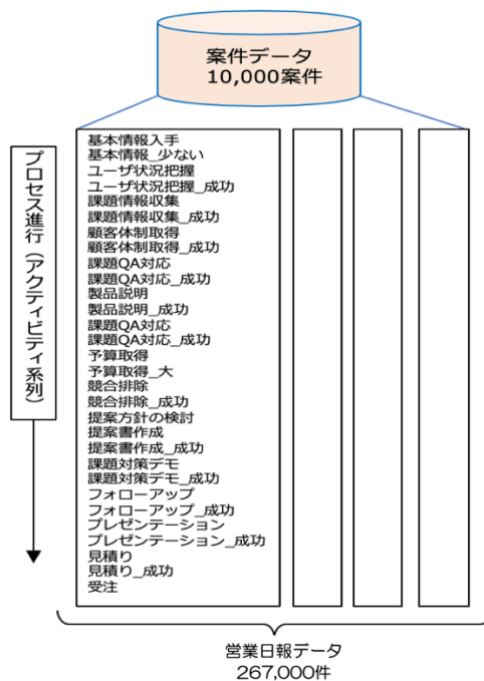


図 4.9 生成された営業日報データ

生成された営業日報データの品質確認を目的として、その被覆性と均一性を調べた。Levenshtein 距離を拡張<sup>16</sup>して、案件に含まれる顧客反応とアクティビティの系列の類似度を全 10,000 案件にわたり測定したところ、ガウス分布(正規分布)に従っていることを確認した。




図 4.10 顧客反応とアクティビティの組み合わせ類似度の測定とガウス分布

産業技術総合研究所の機械学習品質マネジメントガイドライン(2020年6月30日第1版発刊, <https://www.cpsec.aist.go.jp/achievements/aiqm/AIQM-Guideline-1.0.1.pdf>)によると、「AIパフォーマンス」の達成に対応する内部品質<sup>17</sup>として、「データセットの被覆性」と「データセットの均一性」があげられている。データセットの被覆性とは、それぞれの細分化した領域ごとに十分なデータ量が含まれていることであり、十分にリスクなどに対応した学習訓練がされることを担保するものである。また、データセットの均一性とは、データ全体として偏りなく均一にデータが含まれていることであり、モデルの全体性能を向上させることにつながる。ここで生成された営業日報データセットは 10,000 案件とデータ量も十分であり、また顧客反応とアクティビティの組み合わせ類似度も「よくある組み合わせパターン(=王道パターン)」を中心にガウス分布で構成され、さらには37種類のアクティビティが漏れなく含まれていることが確認できた。そこで、機械学習品質ガイドラインの「デ

<sup>16</sup> Levenshtein 距離[100]は通常、文字単位での編集数が対象であるが、本論文ではアクティビティ単位に拡張している。

<sup>17</sup> 機械学習品質マネジメントガイドラインでは、ここで述べた「データの品質」はその前段階の「データ的设计」に依存するとされている。本論文では案件シミュレータ的设计が「データ的设计」に相当する。

一タの品質」にて定義されている品質基準と照らし合わせることで、一定の基準はクリアできていると判断した。

## 4.4 部分観測マルコフ決定過程 (POMDP) によるプロセスモデルの構築と評価

### 4.4.1 部分観測マルコフ決定過程 (POMDP) によるプロセスモデル構築

マルコフ決定過程 (MDP) では政策を計算する際に現在の状態が既知であることを仮定している。実際には状態観測に不確実性が伴う場合などこの仮定が成り立たない場合が多く、このような場合の一般化として部分観測マルコフ決定過程が用いられる。営業活動においても、顧客状態は直接観測できないことから、この部分観測マルコフ決定過程 (POMDP) にてモデル化することが可能である。形式的には、POMDP は隠れマルコフモデル (HMM) に行動および行動を変更する動機を与える報酬を付与したものと解釈することができる。

POMDP における最適制御は、現時刻までに得られた部分的な観測と行動系列から、真の状態に関する確率分布である信念状態を構成し、これに対する価値関数の最適化として実現できる。しかし、一般に信念状態は高次元であるため、信念状態に関する価値関数の学習は困難である。また、状態空間の次元が高くなるにつれて増加する計算量は、MDP の場合よりも甚大である。具体的には、厳密で最適な価値関数や最適政策を求めることは、価値関数を表すためのベクトル集合の要素数が、考慮する期間に対して指数的に増加するため、計算量的に実行不可能である。また、与えられた POMDP の厳密な最適政策を求める計算量は、たとえ有限期間であっても「PSPACE 完全」だと言われている[83]。したがって、従来手法を直接適用して最適解を得ることは難しく、多くの POMDP に関する研究では、近似的に価値関数の最適化を行う手法に取り組んでいる。

POMDP の近似手法について、いくつか紹介していく。事前に環境の知識を持たない強化学習を利用したモデルフリーな手法としては、環境 (状態遷移確率、観測関数) との試行錯誤で Q 値を推定する決定的政策である Q-Learning [84] と、部分観測モンテカルロを利用した確率的政策である POMCP [85] がある。ここで確率的な政策とは観測から行動出力への確率分布であり、平均報酬について局所最適な確率的政策をモンテカルロ法による政策評価で実施する。さらには楽観価値反復法と呼ばれる Sarsa による価値更新の手法もある[86]。

また、環境の事前知識を用いるモデルベースの手法としては、状態空間をグリッドで離散近似して価値反復法を行う Point based value iteration [87] が標準的な手法となっている。このような連

統的な状態空間をいくつかの部分に分節して各々を離散的な状態として扱う手法として、この環境の重要度に応じた分節を学習によって獲得する方法も提案されている。具体的には、強化学習において環境の変化の予測可能性に基づいて状態空間を分割するMOSAICを適用し、適切な状態空間の分節をおこなう手法[88]、さらには隠れマルコフモデルにおいて環境のセンサ値を状態の出力として扱い、行動とセンサ値の変化を予測するように隠れマルコフモデルの学習を行う方法も提案されている[89]。

このようにPOMDPには多くの近似手法が存在するが、本論文では隠れマルコフモデルを用いて行動制御を行う近似手法でPOMDPを構築することとした。理由としては、案件シミュレータの開発の経験から、顧客状態遷移を隠れマルコフモデルで近似的に形式化できていたことが大きい。案件シミュレータにおけるモデルはまさに顧客状態を直接観測できないマルコフ決定過程(MDP)であり、そのモデルをそのままPOMDPの近似手法として利用することは自然な流れであると判断した。

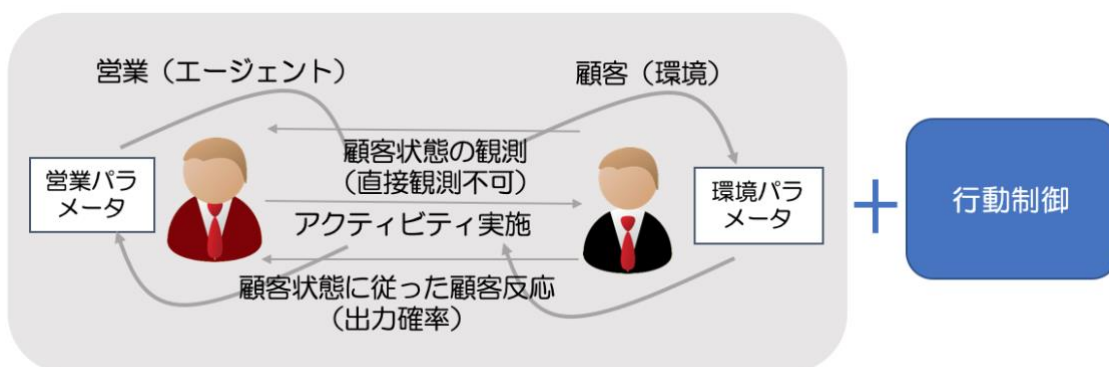


図 4.11 隠れマルコフモデルと行動制御

ここで、隠れマルコフモデル(HMM; hidden Markov model) [90][91][92][93][94][95]について解説しておく。ある時点の状態は1つ前の状態のみに依存するのがマルコフモデルであるが、隠れマルコフモデルでは、状態が直接は観測できず、さらに状態に依存して、観測可能な変数の値(の確率分布)が決まる。また、ある時点の状態は1つ前の状態にのみ依存するというのは一次のマルコフモデルであり、二次以上のマルコフモデルを考えることもできる(高次マルコフ連鎖)。つまり、隠れ状態の遷移確率が2つ前の隠れ状態にも依存する2次の履歴依存性を持たせたモデルも構築可能である。

隠れマルコフモデルは、潜在変数が離散変数である状態空間モデルであり、ある1つの時刻に注目すると、成分密度 $p(x_n|z_n)$ で与えられる混合分布に対応する。






図 4.12 高次マルコフ連鎖

隠れマルコフモデルのパラメータは、状態遷移確率と出力確率の 2 種類である。最も想像しやすいのは、隠れマルコフモデルで隠されている「状態」の推定である。よく使われる例でいえば、マルコフ少年が住む街の天気の状態遷移確率、天気と散歩の関係(出力確率)、マルコフ少年が報告した散歩の結果から、マルコフ母がマルコフ少年の住む街の天気を推測する。その際にはビタビアルゴリズム[96]という動的計画法の一種であるアルゴリズムが使用され、取りうる状態のパターンから最も尤もらしいパターンを選び出すことができる。

隠れマルコフモデルでは、「出力」から状態遷移確率と出力確率を推定することも可能である。その際にはバウム＝ウェルチアルゴリズム[97]というフォワードバックワードアルゴリズムの一種であるアルゴリズムが採用され、主に音声や遺伝子などの系列データを解析するために使用される。




図 4.13 状態遷移確率(丸印)と出力確率(楕円)のイメージ

本論文では、営業をエージェント、顧客を環境と位置づけ、その環境となる顧客の状態を潜在変数としてモデル化し、時系列を加味して状態の変化を予測する。

## 4.4.2 隠れマルコフモデルと方策学習によるプロセスモデルの構築

隠れマルコフモデルを用いて行動制御を行う近似手法で POMDP によるプロセスモデルを構築する。具体的には、営業をエージェント、顧客を環境と位置付けた隠れマルコフモデルに方策学習を組み合わせたプロセスモデルを構築する。

以下に構築手法の概要を述べる。

- 隠れマルコフモデルのパラメータと価値関数(受注率の期待値)を定義
- 営業日報の教師データを利用しパラメータを推測, さらに価値関数を計算
- 計算した価値から方策を学習しパラメータ(出力確率)に反映, プロセスモデルを構築

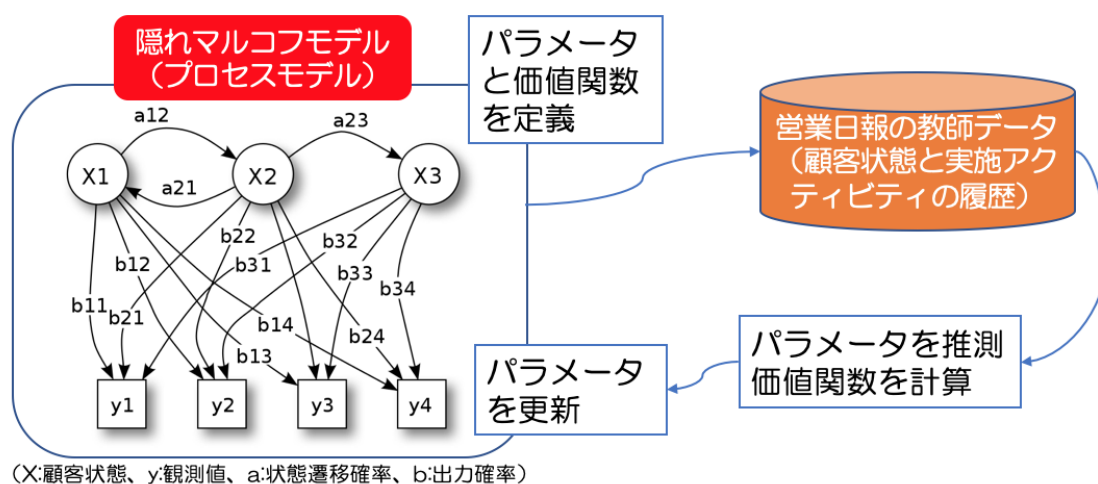


図 4.14 隠れマルコフモデルによるプロセスモデルの構築

まず隠れマルコフモデルのパラメータとして、状態遷移確率を「顧客状態の遷移確率」、出力確率を「顧客状態におけるアクティビティ選択確率」と定義する<sup>18</sup>。また価値関数  $Q^*(s,a)$  について、状態  $s$  で行動  $a$  を選択後、最適方策をとりつづけるときの受注率の期待値と定義する。ここで、状態  $s$  は「推測した顧客状態」であり、過去の実施アクティビティの履歴情報も内包されている。また、行動  $a$  は「営業が次に実施可能なアクティビティ」である。

<sup>18</sup> 出力は「顧客状態におけるアクティビティ」となる。

	状態遷移確率				出力確率				
	顧客状態 Aランク	顧客状態 Bランク	顧客状態 Cランク	顧客状態 ..		プレゼン	課題把握	予算取得	..
顧客状態 Aランク	30%	60%	10%		顧客状態 Aランク	50%	20%	10%	..
顧客状態 Bランク	40%	20%	40%		顧客状態 Bランク	20%	30%	10%	..
顧客状態 Cランク	20%	50%	30%		顧客状態 Cランク	20%	30%	30%	..
顧客状態 ..					顧客状態 ..				

図 4.15 隠れマルコフモデルのパラメータの定義

初期設定の後、プロセスモデルの構築を以下の手順で実施した。

- (1)第4. 3章で確保できた教師データ(案件データ総数 10,000 件とそれに属するアクティビティデータ総数 267,000 件のデータ)から、隠れマルコフモデルのパラメータである状態遷移確率と出力確率を推測し、価値関数を計算する。
- (2)価値反復法(Value iteration)<sup>19</sup>により価値関数の値を最大化するアクティビティの組み合わせ方を学習する。
- (3)学習結果に基づいて、隠れマルコフモデルの出力確率パラメータを更新する。

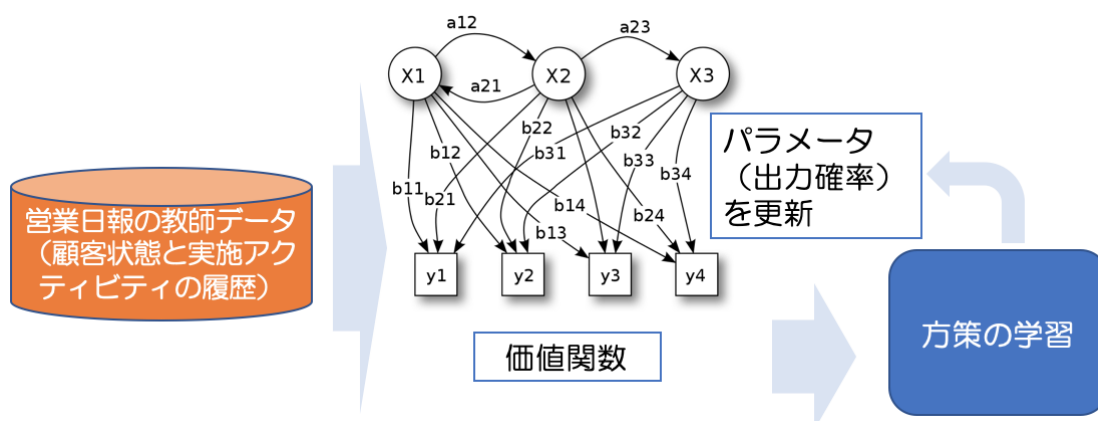


図 4.16 隠れマルコフモデルによるプロセスモデル構築の手順

<sup>19</sup> 価値反復法(Value iteration)は後ろ向き帰納法 (backward induction) とも呼ばれ、ベルマン方程式を満たす価値関数を繰り返し計算により求める。

以上を方策の価値が収束するまで繰り返し実施することでプロセスモデルを構築した。図4.16に POMDP によるモデル構築時のパラメータを掲載する。顧客応答が「受注/失注」、またはアクティビティが「辞退」に到達した場合に終了、さらにイテレーション数が 100 に至った場合には強制終了、減衰率により早く終わるほど高い報酬となるよう設定した。

分類	項目	説明	設定値
HMM	系列数	学習もしくは評価用の系列の数。実運用では、「案件データ数」に相当。	10000
HMM	イテレーション	HMMの学習は、勾配降下法に近いイメージで行われる。本値は勾配降下法の更新ループの繰り返し数に相当。	100
HMM	状態数	HMMの隠れ状態の数。顧客と営業の判断基準の種類数だけ必要。	300
MDP	成功報酬	MDPの最適方策の学習で使用する受注状態になった際に得られる報酬。	100000
MDP	失敗報酬	MDPの最適方策の学習で使用する失注状態になった際に得られる報酬。	5000
MDP	減衰率	MDPの最適方策の学習では系列長が長くなるたびに報酬を減衰する。その減衰率。	0.9
HMM→MDP変換	アクション実行確率の足切	HMMの誤差で、本来は発生しないアクションが非常に低確率で発生する事がある。これをアクションの選択肢に入れると、本来は選べないアクションが選べてしまう。HMMの学習精度が高いほど低い値を設定する。	0.02
HMM→MDP変換	遷移確率の足切	顧客アクションを省く自然遷移の過程ですべての遷移を考慮すると状態の遷移パターンが発散し、MDPの学習が非常に遅くなる。このため、一定確率以下の遷移は無視するように設定。	0.000001

図 4.17 POMDP によるプロセスモデル構築時のパラメータ

上記パラメータの中でも、隠れマルコフモデルの状態数は POMDP の受注率精度に大きな影響を与える。これは営業アクティビティの数が 37種類と多いため、モデルが複雑になることによる。そこで最適な状態数を把握するため、まずは状態数の初期値を 150(37 種類の営業アクティビティごとに4つのバリエーション<sup>20</sup>)とし、整数倍でチューニングすることにした。その結果、状態数 150 の受注率 2.4%が、状態数 300 では受注率 6.6%と増加したものの、学習時間も状態数 150 で 6.3 時間から状態数 300 では 25 時間と大きく増加した。状態数を 300 からさらに増やすことで精度向上の可能性もあるが、学習時間は状態数の倍数の 2 乗に比例するため、これ以上に状態数を増やすことはシステム運用の観点から実用的でないと判断し、状態数の設定値は 300 が妥当と判断した。状態数 300 を大まかに分類すると、受注確度の高い順から A ランク/B ランク/C ランク/D ランクがあり、さらに受注/失注を加えた合計6パターンとなる。

<sup>20</sup> 4つのバリエーションとは、図4.8「フィードバックルールの詳細」にある顧客反応を指す。図中では、顧客反応について「良/中/悪/なし」の4つとなる。




図 4.18 隠れマルコフモデルの状態数比較

構築された学習モデルは、アクティビティを選択する都度、新しいリコmendを出力し直す。つまり、受注までのプロセスを、アクティビティを選択する都度にフォーキャストとして示すことになる。そのため、仮に理想から外れたアクティビティを選択しても、その後可能な限りのリカバリアクションが提示されることになる。このことは、ディシジョンツリー(決定木) [98]で表現されるルールベースの意思決定支援システムでは、いったん間違った選択肢をとるとリカバリーができないことと比べて大きな優位点となる。

### 4.4.3 部分観測マルコフ決定過程(POMDP)によるプロセスモデルの実適用評価

#### (1) 適用環境と評価モデル

開発した営業活動意思決定支援システムを実際の営業現場で評価を実施した。その適用フィールドとして、先述の(株)NTT データイントラマートの法人営業グループを選定した。この会社では法人企業向けの自社製ソフトウェアを販売している。これまで法人営業のベテラン社員を中心とした属人的な営業で継続的に成果を上げてきているが、若手社員の人数も増加していることから、属人性からの脱却とそのノウハウの継承が課題である。

この会社では、2016年4月から2017年3月までの1年間は総勢18名による営業グループで活動していたが、2017年4月よりは営業部隊の増員を理由にAグループ(営業9名)とBグループ(営業15名)の2グループに分割された。構成人数には違いがあるものの、営業経験年数として

はほぼ同等のキャリアバランスとなっており、営業戦力としての偏りはないといつてよい。そこで、この分割された A/B グループを対象にして、営業活動意思決定支援システムを適用した A/B テストを実施することにした。

実適用に先立って営業活動意思決定支援システムを評価するための評価モデルについて述べる。

企業経営における業績指標として受注率の改善は古くから議論されており、受注率に影響を与える要素としては、才能 (Aptitude)、モチベーション (Motivation)、個人の性格 (Personal)、組織と環境 (Organizational & Environmental)、スキル (Skill level) があげられている<sup>21</sup>[3]。本研究における適用環境では、リコメンドにより獲得したスキル (Skill level) で選択するアクティビティにのみ差が生じ、それ以外の要素では A グループ、B グループともに大きな変化はないという想定である。なぜならば、才能、モチベーションや個人の性格という営業担当者の資質に関する項目はグループ間でのメンバー入れ替えがない限り変動はなく、またこの適用期間では組織にも変更がない。景気変動などの外部的な環境変化は常に起きているが、これは双方のグループに同時に影響を与えている。あわせて、販売する製品やターゲット顧客においても変化はない。実際には、スキルの要素には、アクティビティの選択能力以外にも、プレゼンテーション内容や営業知識、対人関係スキルなどがあり[3]、これらが受注率に影響を与えた可能性はあるが、これらに関する変化は確率的にどちらのグループでも起きうると考えた。

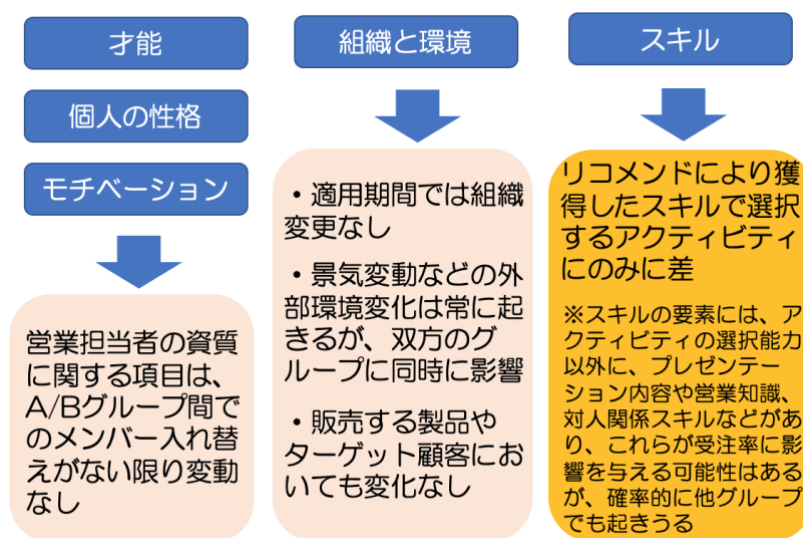


図 4.19 受注率に影響を与える5つの要素

<sup>21</sup> Churchill は、これに「役割」を加えた6要素としている[99]。欧米では営業職の役割が細かく定義・分割されていることが多いが、日本では営業職というとほぼ同一内容を担当することが多いため、本論文ではこの要素を除外している。



まず、2019年1月から3月までの3ヶ月間(ターム1)と2019年4月から6月までの3ヶ月間(ターム2)、Aグループのみに営業活動意思決定支援システムを適用することで、Aグループの営業活動意思決定支援システム適用前後の受注率の比較、さらにはAグループ・Bグループにおける受注率の比較を実施する。

対象：

(株)NTTデータイントラマートの法人営業グループを選定  
(法人企業向けの自社製ソフトウェアの販売)  
総勢24名の営業をAグループとBグループに分割し、Aグループに意思決定支援システムを適用

→Aグループの営業活動意思決定支援システム適用前後の受注率の比較、さらにA/Bグループにおける受注率の比較を実施

適用期間と商談数：

(1)ターム1  
2019年1月から3月までの3ヶ月間  
対象案件数48件

(2)ターム2  
2019年4月から6月までの3ヶ月間  
対象案件数26件

図 4.20 営業活動意思決定支援システムの適用環境

その後、リコメンドが営業担当者の意思決定に与えた影響と、その結果としての受注への影響を評価するため、以下の3つの評価指標を設定する。

### ① 営業担当者ごとのリコメンド採択率と受注率(失注率)の相関性

営業担当者が各アクティビティを行う前に、営業活動意思決定支援システムからリコメンドが提示され、提示されたリコメンドの中のいくつかは実際のアクティビティとして採択される。そこで、リコメンド提示された営業担当者ごとに、リコメンドを実際のアクティビティとして採択したリコメンド採択率と受注率との相関関係を測定する。リコメンド採択率と受注率の間に正の相関があれば、より積極的にリコメンドを採用した営業担当者ほど受注率が高まるという結果を得られる。あわせて、リコメンド採択率と失注率との相関関係も測定する。

### ② 受注案件リコメンド採択率

受注案件リコメンド採択率とは、リコメンド採択率の中でも、特に対象期間の受注案件におけるリコメンド採択率であり、受注案件の意思決定におけるリコメンドの影響を計る指標である。



③ 行動変更受注貢献率

上記のリコメンド採択率には、営業担当者が営業活動として当初想定していたアクティビティが、リコメンドと意図せず同一だったケースも含まれてしまう。そこでリコメンドの影響を明確に測定するための指標として行動変更受注貢献率を設定する。

行動変更受注貢献率とは、行動変更の結果として受注に至ったアクティビティ件数の割合により定義する。言い換えると、営業担当者がリコメンドを見る前に当初想定していたアクティビティと、採択したリコメンドのアクティビティが異なる営業活動の割合であり、リコメンド採択による行動変更が受注率改善に与えた影響を計る指標となる。測定にあたり、営業担当者がリコメンドに基づいて実施アクティビティを初期想定 of アクティビティから変更する際には、その変更結果を記録してもらった。

まず、①営業担当者ごとのリコメンド採択率と受注率(失注率)の相関性について確認する。リコメンド採択率と受注率に正の相関性があるという前提のもとで、次に②受注案件リコメンド採択率を確認する。次に、その中でもリコメンドに基づいた行動変更の割合を、③行動変更受注貢献率として確認する。この期間で A/B グループの差異として受注率に影響を与えた因子はリコメンドによる営業活動の変更のみであるという想定から、この行動変更受注貢献率は直接的に受注率の向上に影響したと判断できる。そこで、この指標を実際の受注率の変化と比較することにより、営業活動意思決定システムの有効性を定量的に示すことができると考えた。また、この比較を、2ターム期間に渡り実施することで、再現性も測定する。

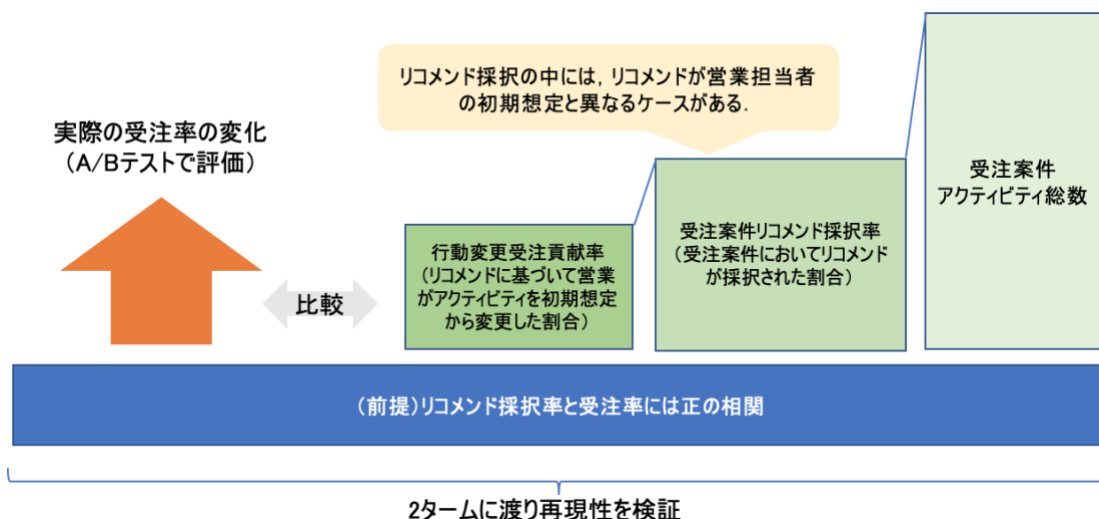


図 4.21 部分観測マルコフ決定過程 (POMDP) によるプロセスモデルの評価モデル

ここで、図 1.2 で示したように、営業活動意思決定支援システムからは、次に実施すべきアクティビティとして推薦度の高いものから順に 13 位まで表示される。図 4.21 が推薦順位(横軸)に対す

る営業担当者の採択数(縦軸)である。すべての採択数の中でも、推薦順位で1位の Recommend が次のアクティビティとして採択されている割合は 24.1%であり、他の推薦順位の採択数よりも一番多かったが、推薦順位で 5 位以内の Recommend が採択されている割合は 51.7%であった。しかし、実適用後に営業担当者らにヒヤリングしたところ、推薦順位で上位 5 位以内のアクティビティしか参考にしていないことが判明した。したがって、Recommend 採択率および行動変更受注案件率を算出する際には、上位 5 位までの Recommend を採択したもののみ Recommend 採択としてカウントし、6 位以下の Recommend については、仮に実施アクティビティと一致していたとしても Recommend は不採択であったものとして取り扱った。




図 4.22 Recommend 順位と採択数

## (2) 評価結果

表1に示すように、営業グループ分割前の 2017 年 1 月から 3 月までの期間で営業日報の登録があった対象商談数 69 件に対して受注数は 23 件、受注率は 33.3%であった。これに対して、営業グループ分割後の 2018 年 1 月から 3 月で営業日報の登録があった A グループの対象商談数 63 件に対して受注数は 20 件、受注率は 31.7%であり、また同一期間の B グループの対象商談数 64 件に対して受注数は 21 件、受注率は 32.8%であった。営業活動意思決定支援システムの適用前の段階では、営業グループは 2 つに分割されたものの、受注率に大きな変化はないことがわかる。しかし、営業活動意思決定支援システムを A グループのみに適用した 2019 年 1 月から 3 月(ターム1)では、営業日報の登録がある対象案件 48 件のうち、受注は 20 件、受注率 41.7%であった。同一期間で営業活動意思決定支援システムを適用していない B グループでは、対象案件 88 件のうち受注数は 29 件、受注率は 33.0%となり、営業活動意思決定支援システム適用前の受注率と変化が見られなかった。つまり、営業活動意思決定支援システムを適用した A グループのみが受注率を 10%程度改善していることがわかる。

またそれに続く2019年4月から6月(ターム2)においても、営業日報の登録がある対象案件26件のうち、Aグループでの受注は12件、受注率46.2%と10%以上の改善が続く一方で、Bグループでの受注率は33.8%と変化がなかった。




図 4.23 A/B テストによる受注率の変化

表 1 : 検証システムの評価結果 (Aグループ、2019年1月~3月、2019年4月~6月が検証システムの適用結果)

Table 1 Evaluation result of the verification system.

	2017/1~3				2018/1~3				2019/1~3				2019/4~6						
	対象商談数	受注数	受注率	受注平均L/T(月)	対象商談数	受注数	受注率	改善幅	受注平均L/T(月)	対象商談数	受注数	受注率	改善幅	受注平均L/T(月)	対象商談数	受注数	受注率	改善幅	受注平均L/T(月)
Aグループ	69	23	33.3%	5.2	63	20	31.7%	-1.6%	5.7	48	20	41.7%	9.9%	5.4	26	12	46.2%	4.5%	5.6
Bグループ					64	21	32.8%	-0.5%	4.0	88	29	33.0%	0.1%	4.4	74	25	33.8%	0.8%	4.2

表 4.1 A/B テストによる受注率の変化

あわせて評価モデルで設定した3つの評価指標について確認した。


① 営業担当者ごとのリコメンド採択率と受注率(失注率)の相関性

ターム1,ターム2において、営業活動意思決定支援システムを適用したAグループの営業担当者全員において、リコメンドを実際のアクティビティとして採択したリコメンド採択率と受注率との相関関係を確認し、あわせてリコメンド採択率と失注率との相関関係も測定した。

リコメンド採択率と受注率との相関関係において、ターム1では相関係数は0.62,ターム2では相関係数は0.70となり、リコメンド採択率と受注率にはともに正の相関があることがわかる。一方で、リコメンド採択率と失注率との相関関係において、ターム1では相関係数は-0.45,ターム2では相関係数は-0.36となり、リコメンド採択率と失注率にはともに負の相関が


あることがわかる。つまり、使用したグループ内では、リコメンド採択と失注率には関係がない一方で、リコメンド採択は受注率に影響を与えているという結果が得られた。

営業担当者	リコメンド採	受注率
A	0	0
B	0	0
C	0.25	0.25
D	0.125	0.25
E	0.6	0.3333333
F	0.5555556	0.6
G	0.08	0.5
H	0.3181818	0.5
I	0.2941176	0.5714286



相関係数 0.621813


営業担当者	リコメンド採	失注率
A	0	1
B	0	0
C	0.25	0
D	0.125	0.25
E	0.6	0
F	0.5555556	0
G	0.08	0.1
H	0.3181818	0.125
I	0.2941176	0.4285



相関係数 -0.454197

図 4.24 営業担当者ごとのリコメンド採択率と受注率(失注率)の相関性(ターム1)

営業担当者	リコメンド採	受注率
A	0	0
B	0	0
C	0	0
D	0.125	0.25
E	0.4	1
F	0.4444444	0.2
G	0.08	0.3
H	0.2727273	0.375
I	0.2352941	0.42857143



営業担当者	リコメンド採	失注率
A	0	1
B	0	0
C	0	0
D	0.125	0.25
E	0.4	0
F	0.4444444	0
G	0.08	0.1
H	0.2727273	0.125
I	0.2352941	0.28571429




図 4.25 営業担当者ごとのリコメンド採択率と受注率(失注率)の相関性(ターム2)

② 受注案件リコメンド採択率

対象期間の受注案件において、営業担当者が実際に営業活動したアクティビティが、リコメンドされたアクティビティから採択された割合を受注案件リコメンド採択率として確認する。まず、ターム1の総案件 27 件の営業担当者の実施アクティビティ総数は 161 件、その中でリコメンド採択件数は 16 件であり、リコメンド採択率は 9.9%であった。そこから、受注案件 20 件に絞ると実施アクティビティ総数は 107 件、その中でリコメンド採択件数は 15 件であり、受注案件リコメンド採択率は 14.0%であった。このリコメンド採択率の差は、受注案件においてリコメンドはより多く採択されている傾向を示している。

同様に、ターム2の総案件 18 件におけるリコメンド採択率は 13.7%であったが、受注案件 12 件に絞ると受注案件リコメンド採択率は 18.4%であった。リコメンド採択率の差にもターム1と同様の傾向が見られる。

	総案件のアクティビティ数	総案件のリコメンド採択件数	リコメンド採択率 (総案件)	受注案件のアクティビティ総数	受注案件のリコメンド採択件数	リコメンド採択率 (受注案件)
ターム1	161	16	9.9%	107	15	14.0%
ターム2	153	21	13.7%	103	19	18.4%

図 4.26 受注案件におけるリコメンド採択率

## ③ 行動変更受注貢献率

次に、営業担当者がリコメンドに基づいて実施アクティビティを初期想定 of アクティビティから変更し、その結果として受注に至った行動変更受注貢献率を確認する。

ターム1の受注案件 20 件において、営業担当者の実施アクティビティ総数は 107 件であるが、そのうち 7 件はリコメンドを参考にして実施アクティビティを変更することで受注に至っており、行動変更受注貢献率は 6.5%であった。ここで、実施アクティビティの実際の変更件数は 8 件であるが、そのうち 2 件は同一の案件 No.28 に属する行動変更となるため、受注への影響を厳密に把握したいことから重複排除した。図4.26において、案件 No.ごとに、営業担当者がリコメンドを見る前に想定していたアクティビティを左欄に、またリコメンドによりアクティビティを変更した場合は、右欄に採択したアクティビティとそのリコメンド推薦順位を記載した。案件 No.が重複しているものは、同一案件の中で複数のアクティビティ変更が実施されていることに注意されたい。

次に、ターム2の受注案件 12 件における営業担当者の実施アクティビティ総数 103 件を対象にして行動変更受注貢献率を分析したところ、そのうち 8 件は、リコメンドを参考にして実施アクティビティを変更することで受注に至っており、行動変更受注貢献率は 7.8%であった。ここでも、同一案件の行動変更は重複排除している。

[ターム1: 2019年1月から3月]

	受注案件のアクティビティ総数	リコメンドにより行動変更したアクティビティ数
件数	107	7 (同一案件のアクティビティは1とカウント)
指標	—	行動変更受注貢献率 6.5%

No	営業担当者の当初想定アクティビティ	リコメンドにより行動を変更 (○内は採択されたアクティビティ のリコメンド推薦順位)
5	見積もり	フォローアップ(3位)
19	顧客課題の把握	競合情報入手(2位)
21	提案体制の変更	提案書プレゼンテーション(1位)
26	訴求ポイントの検討	提案体制の決定(1位)
28	競合情報入手	システム開発状況の把握(2位)
28	ステークホルダー把握	提案体制の検討(4位)
39	課題の整理	提案体制の決定(5位)
47	案件リスクの把握	訴求ポイントの検討(1位)

[ターム2: 2019年4月から6月]

	受注案件のアクティビティ総数	リコメンドによる行動変更で受注に至った案件数
件数	103	8
指標	—	行動変更受注貢献率 7.8%

No	営業担当者の当初想定アクティビティ	リコメンドにより行動を変更 (○内は採択されたアクティビティ のリコメンド推薦順位)
55	ステークホルダー把握	予定時期取得(1位)
55	リスク把握	予算取得(4位)
150	戦略会議	案件リスクの把握(4位)
166	顧客課題の把握	案件必然性の確認(4位)
199	予算取得	リスク確認(3位)
285	提案体制の検討	課題の収集・整理(5位)
307	予定時期取得	顧客課題の把握(1位)
315	競合情報の入手	要件取得(3位)
335	訴求ポイントの検討	予定時期取得(2位)

図 4.27 行動変更受注貢献率

#### 4.4.4 意思決定支援システムの有効性に関する考察

評価結果に示したように、営業活動意思決定支援システムを適用したAグループのみが、ターム1において8.7%、およびターム2において12.4%の受注率改善を実現できた。

この結果に対する営業活動意思決定支援システムの有効性を評価するため、以下で設定した指標を再度整理する。

- (1) 営業担当者ごとのリコメンド採択率と受注率には正の相関がある。また一方で、リコメンド採択率と失注率には関係がないことから、リコメンド採択は受注率に影響を与えている。



- (2) ターム1における受注案件の実施アクティビティに占める受注案件リコメンド採択率は 14.0%, ターム2では 18.4%とともに高い数字ではないものの, 受注案件においてリコメンドはより多く採択される傾向がある.
- (3) あわせて, ターム1において, リコメンドを参考にして実施アクティビティを変更した行動変更受注貢献率は 6.5%, ターム2では 7.8%であった. それに対する受注率の向上は, ターム1で 8.7%, ターム2で 12.4%であり, 受注率向上は2ターム期間に渡り再現性がある. このことから, 適用期間の A/B グループの差異として受注率に影響を与えた因子はリコメンドによる行動変更のみであるという前提において, リコメンドによる行動変更が結果として受注改善に影響を与えたと判断した.




図 4.28 評価モデルに基づいた評価結果

さらに考察を深めるため, リコメンドによる行動変更の詳細について個別事例を追跡して調べた. 詳細については, 「4.4.5章 (参考)行動変更を伴う案件の例」を確認いただきたい.

ひとつめの事例(案件 No. 28), ふたつめの事例(案件 No. 21)ともに, 営業活動意思決定支援システムからのリコメンドを不採択しているものもあるが, 採択により営業担当者の行動が変更されるものもあり, 結果的に受注に至っている. つまり, 特定場面でのリコメンドが適切でなくても, 営業担当者はそのリコメンドを採用せず自分でアクティビティを判断しており, これは営業プロセス全体としてみると有効なリコメンドだけをとりとれていることで受注率をあげていると考えることもできる. またこのことは, 営業活動意思決定支援システムがリコメンドと人の判断を協調させることで, 機械学習の判断結果が事業収益においてマイナスとなるダメージを与えてしまうようなリスクの回避性が備わっていると考えることもできる.

一方で、ふたつめの失注案件(案件 No.179)においては、営業活動意思決定支援システムからのリコメンドが適切であっても、その実施内容に問題があると失注につながる事例となっている。これは、営業活動意思決定支援システムの仕様である「アクティビティのリコメンドのみによる支援」の限界と考えることができ、「2.2.4章 営業活動の意思決定支援システムの現状」で述べたような「営業タイミングに合わせた類似商談や成功事例のリコメンドなど、ある時点のアクティビティに基づいたリコメンド」と組み合わせることで、その実施内容まで踏み込んで営業活動を支援する仕組みが必要であると言える。

また参考であるが、ターム1とターム2を比較すると、行動変更受注貢献率の 6.5%から 8.7%への上昇に伴い、受注率も 8.7%から 12.4%へと上昇している。このことは、ターム1からターム2にかけて、営業担当者の営業活動意思決定支援システムに対する習熟度と信頼が上がったことに起因する可能性もあるが、今後も継続した調査においてその影響を確認すべきである。

### 4.4.5 (参考)行動変更を伴う案件の例

リコメンドの採択により受注までいきついた案件例を2つ紹介する。

一つめは図4.26の案件 No. 28に該当する某生命保険会社の事例であるが、営業担当者の登録した営業日報に対して、タイムリーに次のアクティビティのリコメンドを行なっている。この事例では、計 5 回のリコメンドが実施され、営業担当者はそのリコメンドの中から次のアクティビティを選択することで最終的な受注までいきついている。営業担当者が実際に実施したアクティビティには、営業活動意思決定支援システムからのリコメンドには存在しないものがあるなどの課題はあるが、営業担当者の初期訪問から受注までを効果的に導いている事例と言える。

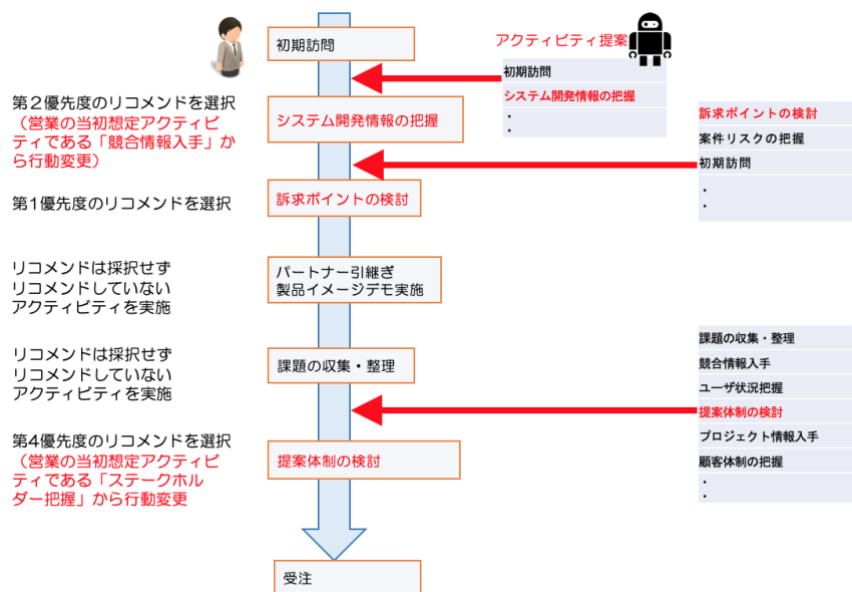


図 4.29 某生命保険会社の受注事例

もう一つの事例は図 4.26 の案件 No.21 に該当する某出版会社向けの案件実施結果である。ここでは、「提案書プレゼンテーション」のリコメンドを推薦順位1位で受けて「プレゼンテーション」を実施したが、その後プレゼンテーション時の顧客反応により「再見積もり」を追加で実施した。しかし、システムからは再度「提案書プレゼンテーション」のリコメンドが推薦順位 1 位で出ており、営業担当者はこのリコメンドに従いアクティビティを変更して実施、その結果として受注に至っている。

営業担当者は、プレゼンテーション時の顧客反応から、「提案体制の検討」を時間をかけてやり直した方が良く当初想定していたようである。しかし、一連のアクティビティ実施後にプレゼンテーションを実施し、その後に再見積もりを実施した場合は、時間をかけずに再度プレゼンテーションを実施することで受注につながっている案件事例が過去にあり、その結果がノウハウとして営業活動意思決定支援システムに学習されていた。そのため、営業担当者はこのリコメンドの背景を理解できたことから、リコメンドに従いアクティビティを変更していることが確認できた。

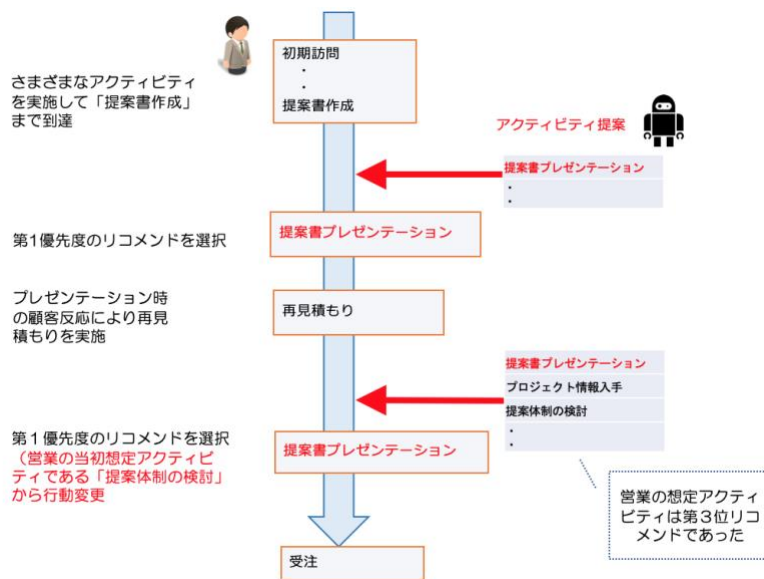


図 4.30 某出版会社の受注事例

あわせて某製造業における失注の事例も2件紹介する(案件 No.9). ひとつめの失注事例は様々なアクティビティを実施して「競合排除」まで到達, その後, リコメンドの中から第3 優先度の「訴求ポイントの検討」を採択した. しかしその後, 第12 優先度である「競合情報入手」を採択したのち失注に至っている(実際には採択したのではなく, 偶然に一致していた). 顧客に確認した失注理由としては, 競合他社が提案をどんどんと進めていたのに対して, 当社は提案に出遅れ躊躇していると捉えられたようである. 一度「競合排除」を実施しているにも関わらず, この段階で「競合情報入手」を実施した理由を担当営業に確認すると, 排除したと考えていた競合の動きが気になりこのアクティビティの実施に至っていた. リコメンドでは, 「提案体制の決定」や「顧客体制の把握」「案件リスクの把握」など, 提案を進めていくためのアクティビティの優先度が高く提示されており, 営業担当者のアクティビティの採択において後悔を残すこととなった. システムによるリコメンドを営業担当者に信用してもらうための運用面での定着も必要であるといえる.

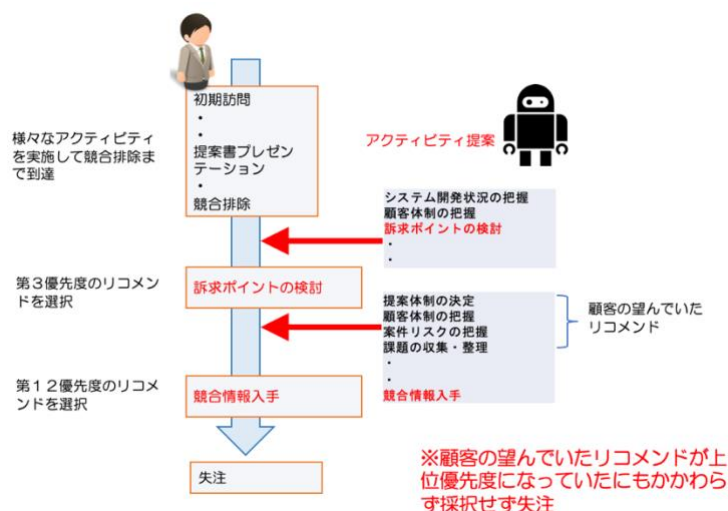


図 4.31 某製造業における失注事例

ふたつめの某流通業の失注事例(案件.179)では、さまざまなアクティビティを実施したのちに「競合情報入手」まで到達、その後、第1優先度のリコメンドである「ステークホルダーの把握」を採択して実施、さらにその後、第1優先度のリコメンドである「見積もり」を採択して実施したが、失注に至っている。営業担当者に確認したところ、競合も同じアクティビティである「ステークホルダーの把握」と「見積もり」を実施したようである。それにもかかわらず失注に至ったのは、ステークホルダーの把握ミス(キーマンを間違えて判断)と見積もり価格において競合との差があり敗退したとのことであつた。例え見積もりの段階で競合との価格差があつても、的確なキーマンを把握していればその後のリカバリーにもつながつたはずであるが、キーマン選定を間違っていたためそのチャンスをもたえなかつたようである。つまり、リコメンドによるアクティビティ選択は適切であっても、その内容が不適切であれば結果として失注につながってしまうという事例である。

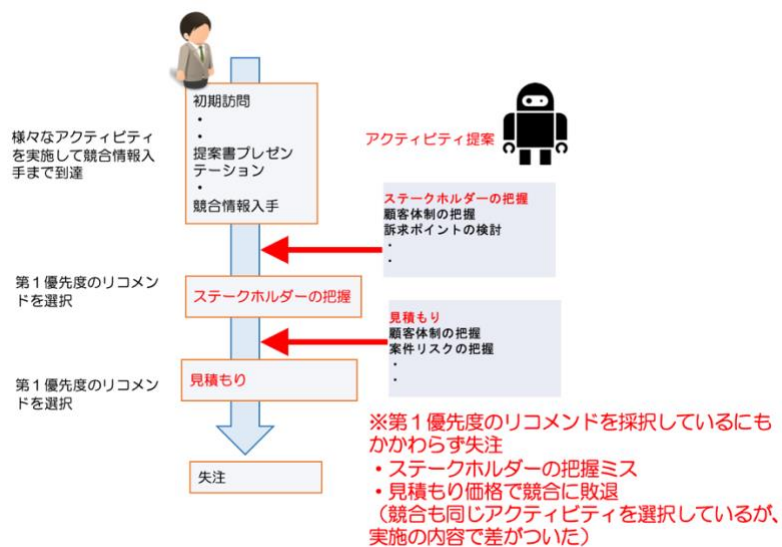


図 4.32 某流通業における失注事例

最後に全案件のサマリデータを参考として掲載する(表4. 2, 表4. 3).

## 第4章 プロセスモデルの構築と評価

No	受注フラグ	受注リードタイム(月)	アクティビティ総数	対象期間アクティビティ総数	リコメンド採択件数	採択リコメンド順位
1	○	9	18	5	1	6
5	○	10	15	3	2	3,10
6	○	10	6	3	1	13
7	○	8	9	8	3	8,1,4
8	○	8	11	3	0	
10	○	7	11	3	1	11
14	○	5	8	8	0	
15	○	8	9	5	3	5,12,7
16	○	4	5	5	0	
19	○	4	9	8	1	2
21	○	4	10	5	2	1,1
22	○	4	6	4	2	1,13
24	○	7	10	8	0	
25	○	3	11	4	0	
26	○	4	9	6	2	6,1
28	○	3	11	11	5	2,11,9,13,4
30	○	2	5	5	0	
39	○	2	4	4	2	13,5
40	○	1	4	4	1	1
47	○	5	5	5	3	5,9,1
2	△	-	5	3	2	
11	△	-	11	6	1	11
13	△	-	11	5	3	9,13,6
18	△	-	7	2	0	
23	△	-	4	3	2	5,8
27	△	-	3	3	0	
29	△	-	3	3	2	1,3
31	△	-	2	2	1	1
32	△	-	1	1	0	
33	△	-	1	1	0	
34	△	-	3	3	2	11,1
35	△	-	3	3	0	
37	△	-	4	4	3	12,13,1
38	△	-	4	4	2	12,13
41	△	-	2	2	1	
42	△	-	1	1	0	
43	△	-	8	8	6	13,11,4,1,3,13
44	△	-	4	4	2	3,4
45	△	-	4	4	2	5,11
46	△	-	2	2	1	1
48	△	-	1	1	0	
3	×	-	16	2	0	
4	×	-	6	2	0	
9	×	-	8	4	2	3,12
12	×	-	8	8	0	
17	×	-	4	2	0	
20	×	-	4	3	0	
36	×	-	8	8	1	12

○受注:△継続:×中断および失注

表 4.2 全案件のサマリーデータ(ターム1:2019/1-3)

No	案件名	受注フラグ	受注リードタイム(月)	アクティビティ総数	対象期間アクティビティ総数	リコメンド採択件数	採択リコメンド順位
13	東ソー	○		8	8	1	1
55	TMJ	○		14	14	5	1,1,4,9,2
91	関西電気保安協会	○		10	10	2	6,7
140	オリックス生命	○		6	6	0	0
150	トヨタ情報システム	○		22	22	9	4,8,1,8,1,8,10,9,13
166	日立物流バンテック	○		11	11	2	4,2
199	帝人	○		6	6	2	3,4
285	全農	○		8	8	6	5,7,9,10,10,1
307	ANA	○		6	6	1	1
314	パナソニックコネク	○		3	3	1	4
315	三菱電機	○		4	4	2	3,3
335	横須賀市役所	○		5	5	1	2

表 4.3 全案件のサマリーデータ(受注データのみ:ターム2:2019/4-6)



#### 4.4.6 妥当性への脅威

##### (1) 内的妥当性(因子関係の確かさに影響を与える事柄)への脅威

本検証において、検証データ数の適格性は内的妥当性として因子関係の確かさに影響を与える。そこで、実適用評価における検証データ数の適性を推定統計により評価する。ここでは、案件シミュレータにより生成された教師データである案件 10,000 件からプロセスモデルが作られているため、10,000 件の教師データがプロセスモデルの近似であり、母集団であると考えることができる。この母集団に対して、本検証における検証データ数であるサンプルサイズはターム1とターム2を合計して 238 案件と考えることができる(営業活動意思決定支援システムを利用した A グループでは 76 案件、システムを非利用の B グループでは 162 案件であり合計 238 案件)。

サンプルサイズが母集団全体の傾向を正確に反映していることをどれだけ確信できるかを信頼水準として表すが、この信頼水準を 90%とした場合の許容誤差は一般的にも適切とされる 5%となった。一般的には信頼係数を 90%~95%に設定して統計を取ることが多いことから、一定レベルの信頼性は満たしていると考えた。今後、信頼水準を厳密なレベルである 95%に引き上げながら許容誤差を 5%とする目標を設定しており、そのためには最低 310 案件が必要となるため(現状より 72 案件の増加)、継続した測定調査においてその有効性を検証する必要がある。

##### (2) 外的妥当性(一般化の可能性に影響を与える事柄)への脅威

本論文の適用環境では、ソフトウェアを販売する法人営業に限定して実施したものであるが、長期に渡るアクティビティを通じて受注率を高めていくタイプの案件型営業においては、本論文で提示した「アクティビティ分類」「プロセス推定」のフェーズを通じたプロセスモデルの構築手法はそのまま適用可能である。

具体的には、受注確率の高いアクティビティ選択のプロセスは、販売する品目の種類や複雑性、さらには対象とする顧客規模などによっても異なるが[101]、「3.3 営業活動の標準アクティビティ」で述べた営業活動のアクティビティ自体を、対象に合わせて新たに設定し、プロセスモデルを再構築することで対応可能である。特に、本論文にて想定している顧客訪問を前提とした営業活動の標準アクティビティは、現在のコロナ環境下においてはリモート営業のアクティビティへと大きく変化するが、これらの変化に対しても同様に対応可能である。図4.27 に示すように、営業対象となる顧客の属性情報(大手企業か、中堅中小企業か)と提案対象製品(売り切り製品か、サービス込みの製品か)によりあらかじめグループ分類しておいた営業日報ごとに、このプロセスモデルを構

築する作業を繰り返していく事になる。これにより適用環境ごとに複数の理想的な営業活動のプロセスモデルが生成できる。

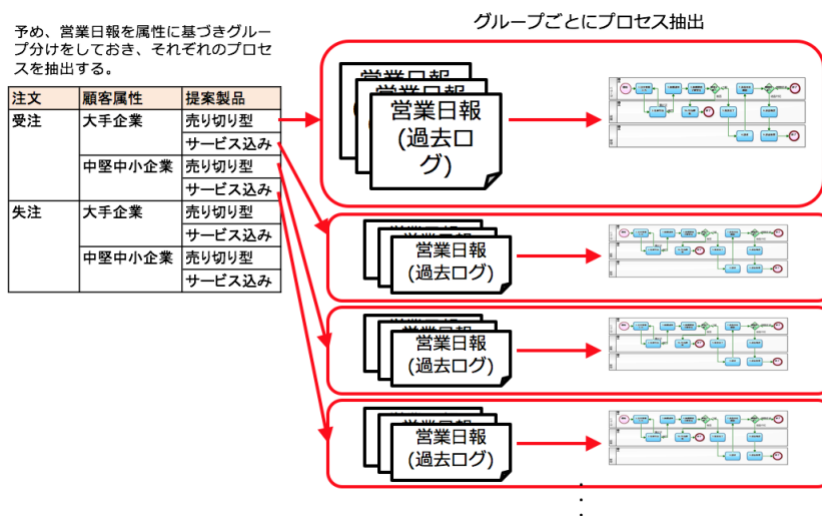


図 4.33 グループ分類ごとのプロセス抽出

また、営業のパターンを分類すると、本手法が適用できないのは、発注頻度の高い商品を中心に特定の顧客を定期的に巡回訪問するルート営業(選択アクティビティに変化がないタイプ)、公共系に多い入札案件(アクティビティ選択よりも特定のアクティビティの中身が受注率に大きく影響するタイプ)、リアル店舗や EC サイトなどの販売業務(長期のプロセスがないタイプ)である。

本手法の適用対象外

	案件営業	ルート営業	入札案件	販売営業
内容	車や家、システム開発などの案件をベースにした営業	発注頻度の高い商品を中心に特定の顧客を定期的に巡回訪問する	公共系に多く、価格競争入札と総合評価入札、プロポーサル入札などがある	リアル店舗や EC サイトなどの販売業務
特性	長期に渡るアクティビティ選択を通じて受注率を上げていくタイプ	選択アクティビティに変化がないタイプ	アクティビティ選択よりも特定のアクティビティの中身が受注率に大きく影響するタイプ	長期のプロセスがないタイプ

図 4.34 本手法の適用対象外の営業タイプ

#### 4.5 深層強化学習によるプロセスモデルの構築と評価

### 4.5.1 深層強化学習によるプロセスモデルの構築

4.4章の POMDP によるプロセスモデルの構築に続いて、深層強化学習によるプロセスモデルの構築を行い、これら2つの学習モデルに基づくプロセスモデルの比較評価を実施する。

まずは、案件の背景、要件、顧客のパーソナリティといった環境自体を深層学習することで現実の顧客反応に沿った環境モデルを構築し、さらにこの構築された環境モデルを利用して、営業エージェントとの間のシミュレーションをセルフプレイ[102][103]で強化学習をおこなう。

探索系のアルゴリズムによるプロセスモデルの構築となるため、リコメンドの選択基準が変更され選択枝が拡大することで、営業の納得性の高いリコメンドが可能なプロセスモデルの構築が可能となる。最後は、熟練営業担当者へのアンケートを通じた経験合致度の調査で、POMDP と深層強化学習のプロセスモデルの比較評価を行う。

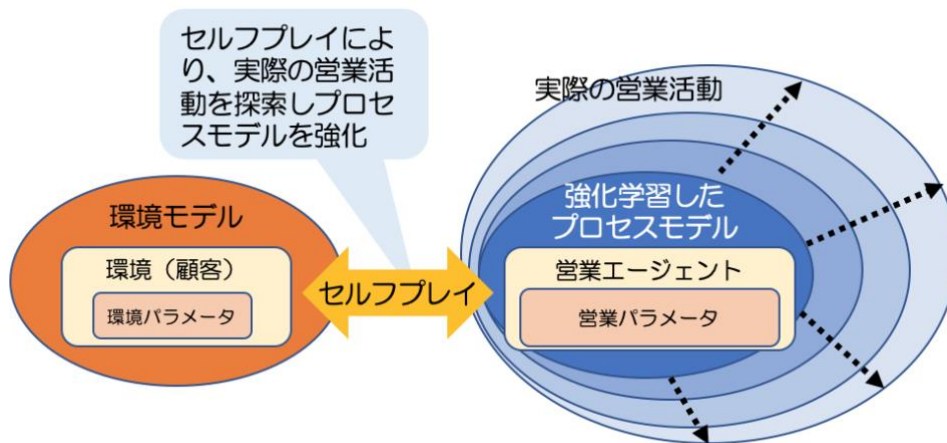


図 4.35 深層強化学習によるプロセスモデルの構築

### 4.5.2 関連研究

マルコフ決定過程(MDP)[104]の環境における強化学習について述べる。

強化学習が注目を集める理由の一つは、不確実性のある環境を扱っている点にある。多くの実世界の制御問題では不確実性の扱いは困難であり、また報酬に遅れが存在するため離散的な状態遷移も含んだ段取りの制御規則の獲得を行う必要がある。つまり、強化学習は探索と活用を繰り返しながら環境の制御を学習する手法である。強化学習では、教師あり学習のように正解が予め用意されていないくても、エージェントの行動に対する評価を環境から報酬として受け取ることによって、エージェントは自らの行動選択ルールを改善することができる。

状態価値関数である「Q値」という概念は、「ある状態 $s$ において、ある行動 $a$ を取った際に得られる価値」である。  $Q^*(s,a)$  が得られれば、最適な政策は簡単に得られる。 Q-learning [105]は環境との試行錯誤的な相互作用の繰り返しを通じて  $Q^*(s,a)$  を推定する代表的な強化学習アルゴリズムである。一方で行動価値関数は、エージェントがランダムな行動“ $a$ ”を実行した後に方策“ $n$ ”を実行した際に得られる価値を計算する。

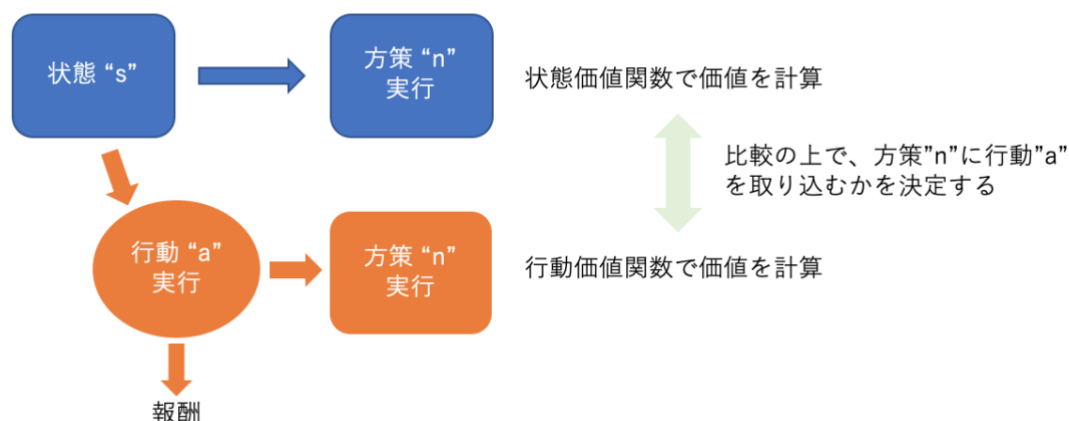


図 4.36 状態価値関数と行動価値関数の計算

状態価値関数と行動価値関数を比較すると、両者とも最終的に方策“ $n$ ”を実行している点では共通である。しかし、行動価値関数のみが途中でランダムな行動“ $a$ ”を実行する。すなわち、両者それぞれが導出する価値を比較することで、行動“ $a$ ”の実行で得られる価値がどれくらい増えるか、もしくは減るのか明確になる。得られる価値が増えるのであれば、行動“ $a$ ”を方策の一部として採用し、方策を修正していく。ある意味でPDCAサイクルを回しているとも言える。強化学習において、これらはモデルフリー強化学習と呼ばれ、環境モデルを学習するということはず、経験から価値関数や方策を学習する[106]。

一方で、現実世界等の複雑な環境においては環境のモデルが未知であることが多いため、事前に環境モデルが判明していない状態から環境のモデルを学習するモデルベース強化学習の研究が行われている[107]。環境モデルを経験から学習し、最適な価値関数や方策をプランニングする。データが乏しく不確実性の高い状態や系列が長い複雑な状態を重点的に探索することが可能であり、最初に環境モデルを学習することは言い換えるとカードゲームのルールを学ぶことに相当する。反面、モデルベース強化学習は環境モデルを推測し、さらに推測したモデルを元にして方策を推測するため、誤差が大きくなる傾向がある[108]。

営業エージェントと環境(顧客)の間の強化学習では最終状態に至るまでの系列が長い場合、モデルフリー強化学習では行動の選択肢が多くなり収束しないことが予想される。そのため、すでに案件シミュレータで生成された案件データを教師データとして利用して、環境モデルのパラメータを最適にする必要があり、それにはモデルベースの強化学習による環境モデルの学習が適してい

る。また、モデルベースの強化学習では、環境の学習とそれを使った方策の学習に分かれるが、方策の学習はMCTS(モンテカルロ木探索)[109][110]によるシミュレーションが用いられることが多い。MCTSはQ学習やSarsa[111]とは違い、Q値の更新のときに「次の時点のQ値」を用いない。代わりに、何らかの報酬が得られるまで行動をしてみて、その報酬値を知ってから辿ってきた状態と行動に対してその報酬を分配していく。そのため、モンテカルロ法では報酬が得られて初めてQ値を更新することができる。逆に言えば、報酬が得られるまでQ値を更新することができない。一方、Q学習やSarsaは、「現在推定中のQ値でも、未来に渡る価値を含むはずだ」という前提で、次の時点でのQ値を使って常に更新をおこなっている。そのため、遠い未来で得られる報酬の学習は遅くなる。MCTSは一度未来を見てから一気にQ値の更新をかけるため、遠い未来の報酬も比較的早く学習できるという特徴がある。さらにもう一つの利点は、選択的な最良優先探索であるという点である。これは、あるイテレーションのパスが良くないと判明した時点で、ルート状態に戻ってアクションを選択し直すということを繰り返すアルゴリズムの結果である。また、動的に個々の状態を評価できるという利点も挙げられる。現在の状態を認識しているので、全ての状態とアクションについて計算する必要がなく、リソースを現在の状態以降のシミュレーションに絞ることができる。サンプルさえあれば学習ができるため、ブラックボックスなモデルに対しても適用可能であることもMCTSの利点である。以上より、MCTSが効率的で適用範囲の広いアルゴリズムであることがわかる。そのほかには、TD Search[112]やDyna-Q[113], Dyna-2[112]などもある。Dynaアーキテクチャーは環境モデルを用いたシミュレーションによる経験を、モデルフリー強化学習に活用することで全体方策の学習を高速化させる手法である。

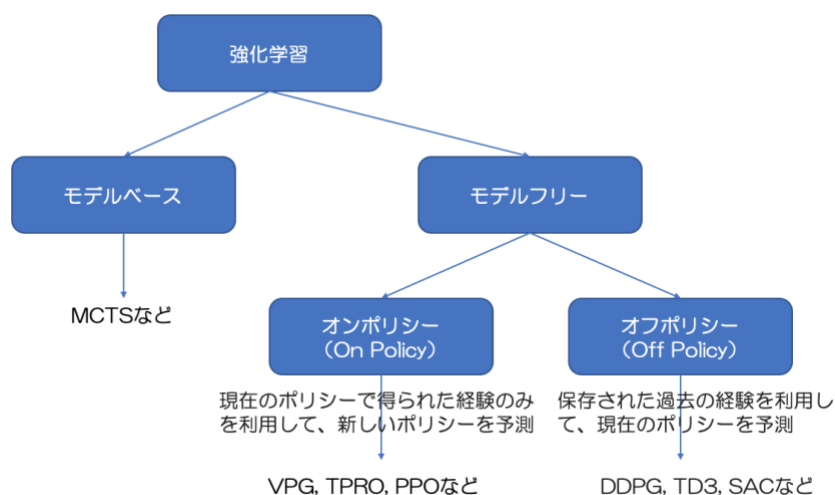


図 4.37 強化学習の分類

近年、Alpha-Goの成功[114]により、モデルベースの強化学習に深層学習を加えることが増えてきている。深層学習が登場する以前のQ値の学習では、ポリシーを状態と行動のマトリクスで保持していた。ある状態に対するある行動の価値はどれくらいかというのをマトリクスで管理し、より価値の



高い行動を選択する。そのため、例えば定量的な状態に座標のような連続した値を持たせると、マトリクスが膨れ上がってしまうため限度があった。深層学習の登場によって、ポリシーをマトリクスの代わりにニューラルネットワークで管理できるようになった。これがDQN(Deep-Q Network)[\[115\]](#)である。深層学習では特徴量を抽出できるため、環境の定量的な状態を人が選定してあげる必要はなく、訓練データをそのまま渡すことができる。つまり、人が視認して学習するのに近い学習の形が可能となる。AlphaGoは、囲碁という巨大な環境であっても深層学習技術を応用して学習に成功させたことで、深層学習と強化学習の融合の可能性を大きく世に示した。

強化学習の適用には、観測データからの特徴量抽出と、予測シミュレーションを可能とする時系列データ生成が必要となるが、深層学習はこれら2つに対しても重要な仕組みを提供する。特徴量の抽出には、CNN(Convolutional Neural Network, 畳み込みニューラルネットワーク)[\[116\]](#)が多く用いられる。生物学的過程から発想を得たCNNは、画像や動画認識に広く使われているモデルである。また環境の時系列データ生成にはRNN(Recurrent Neural Network, 再帰型ニューラルネットワーク)[\[117\]](#)が多く用いられる。リカレントニューラルネットワークは、内部にループを持ち、情報を持続させることができるネットワークである。後続のネットワークに情報を渡していくことができる。さらに、RNNの拡張として1995年に登場したLSTM(Long short-term memory)[\[118\]](#)は、非常に特別な種類のリカレントニューラルネットワークであり、多くのタスクにおいて、標準バージョンよりもはるかに優れた働きをし、長期的な依存関係を学習できる。こうした深層学習による自律的な特徴量抽出と系列データ生成を強化学習に適用して、これまで制御が難しいと考えられていたタスクを制御できるようにする試みが深層強化学習である。

本研究では、モデルベースの強化学習による環境モデルの学習において深層学習を適用した。まずは、案件シミュレータで生成された案件データを利用して時系列データを自動生成(LSTMを利用)し、環境モデルのパラメータを最適にしている。その後、MCTSを利用したセルフプレイ[\[102\]\[103\]](#)による強化学習により自律的な制御を学習する。

### 4.5.3 深層強化学習によるプロセスモデル構築ステップ

深層学習による環境モデルの構築とセルフプレイによる強化学習のステップについて述べる。

まずは、案件シミュレータで生成された案件データ 10,000 件とそれに属するアクティビティデータ総数 267,000 件を利用して、深層強化学習による環境モデルの構築を行う。この案件シミュレータで自動生成される営業日報データは、現実の顧客の反応パターンを全て網羅することはできない。また、その性質上、非現実的なやり取りも含まれてしまう。そのため、案件シミュレータから構築される営業エージェントの学習モデルは現実の営業活動と乖離のあるものになってしまう。そのため学習モデルの精度向上には、深層学習による環境モデルを構築することで、現実の顧客反応をできるだけ網羅できるようにしていく必要がある。営業活動のアクティビティの系列は一般的に 20～

100 系列と長期にわたるため、深層学習のアルゴリズムとしては長期的な依存関係を学習できる LSTM を利用する。

その後、営業エージェントと深層学習による環境モデルのセルフプレイで強化学習を実施することで、探索と活用を繰り返しながら環境の制御を学習する。関連研究でも述べたようにモデルベースの強化学習となるため、MCTS を利用した強化学習により自律的な制御を学習する。

最後に、熟練営業担当者の経験合致度でリコメンド精度をアンケート評価する。POMDP によるプロセスモデルからのリコメンドと、深層強化学習によるプロセスモデルからのリコメンドを比較してもらう。ここで熟練営業担当者とは、3章と同様に 10 年以上の営業経験者を指す。

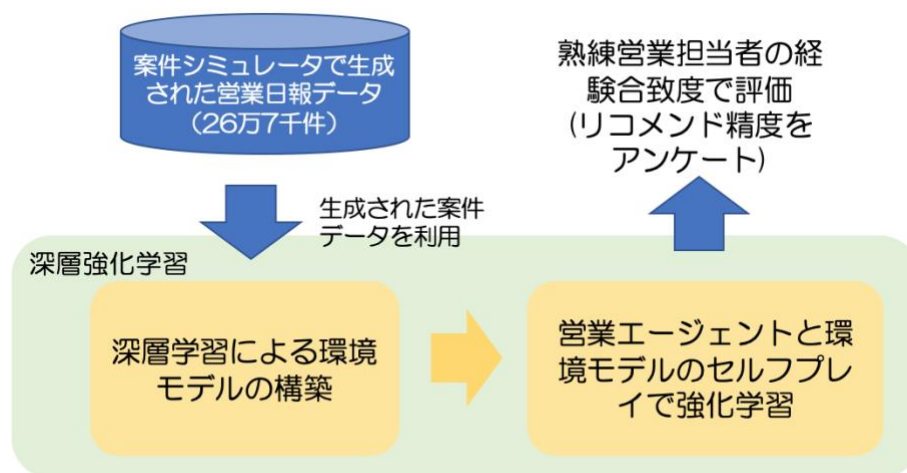


図 4.38 深層強化学習によるプロセスモデル構築ステップ

#### 4.5.4 環境モデルの構築

環境自体を深層学習してそれを学習に活用するという環境モデルの構築により、環境を案件シミュレータの生成する案件データに近づけていく。

具体的には、案件シミュレータにより自動生成された1万件の案件データ(営業のアクティビティを入力、それに対する顧客反応を出力としたアクティビティ系列)を教師データとして、長期的な依存関係を学習することのできる深層学習アルゴリズムであるLSTM(Long Short Term Memory) [118] で環境モデルを構築する。ここでは、アクティビティ系列の最終状態は、「受注/失注/辞退/強制終了」のいずれかになる。LSTMによる深層学習で環境モデルを構築することにより、環境モデルが現実の顧客反応を網羅した状態に近づいていく。構築された環境モデルによる予測結果を図4.40に掲載する。LSTMによる深層学習で、入力されたアクティビティからそれに対応する顧客反応を予測できるようになるが、その正解率は最終的に83.3%となり、予測結果と違うアクティビティは情



報の少ない案件初期段階において発生していたことから、適切に環境モデルの学習がおこなわれ要件を満たす精度が達成できたと判断した。

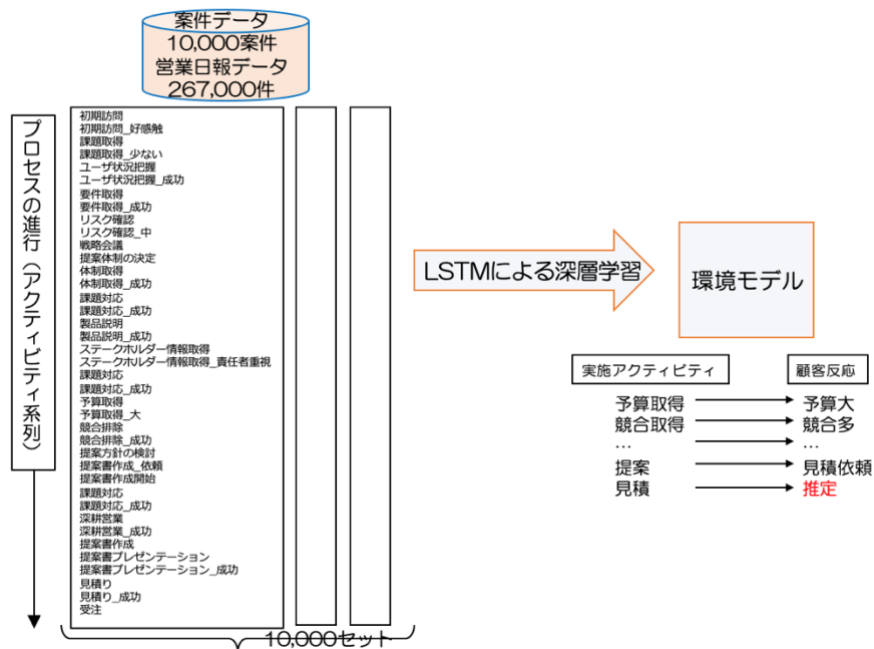


図 4.39 LSTM による環境モデルの構築




図 4.40 構築された環境モデルによる予測結果

### 4.5.5 セルフプレイによる強化学習

さらにこの作成された環境モデルを利用して、営業エージェントとの間のシミュレーションをセルフプレイ[102][103]を用いた強化学習で行い、営業パラメータのポリシーと価値を試行錯誤で獲得する。これにより、現実の営業活動を探索することが可能となり、営業エージェントの学習モデルを強化する。現実の営業活動との乖離が少ない学習モデルが構築でき、営業活動場面でより現実の営業活動に沿ったリコメンドが可能となる手法を確立できる。ここではゲーム分野で多く用いられる強化学習のアルゴリズムである MCTS (モンテカルロ木探索) アルゴリズム[109][110]を使った。ゲーム分野での強化学習では、対戦相手がどのような相手でも勝てる確率が高い手を探索することができる。

具体的には、顧客と営業の対戦という形で、10案件で1サイクルを1万サイクル、双方を対戦させ、学習モデルの精度を向上させる。このセルフプレイを繰り返すことで営業モデルをシミュレートで強化することができ、結果として MCTS による探索で作成されたプロセスモデルは理想的なリコメンドが可能な仕組みとなる。図4.42に示すように、7000 サイクルのセルフプレイが1週間程度で受注率 60%程度に収束することができた。

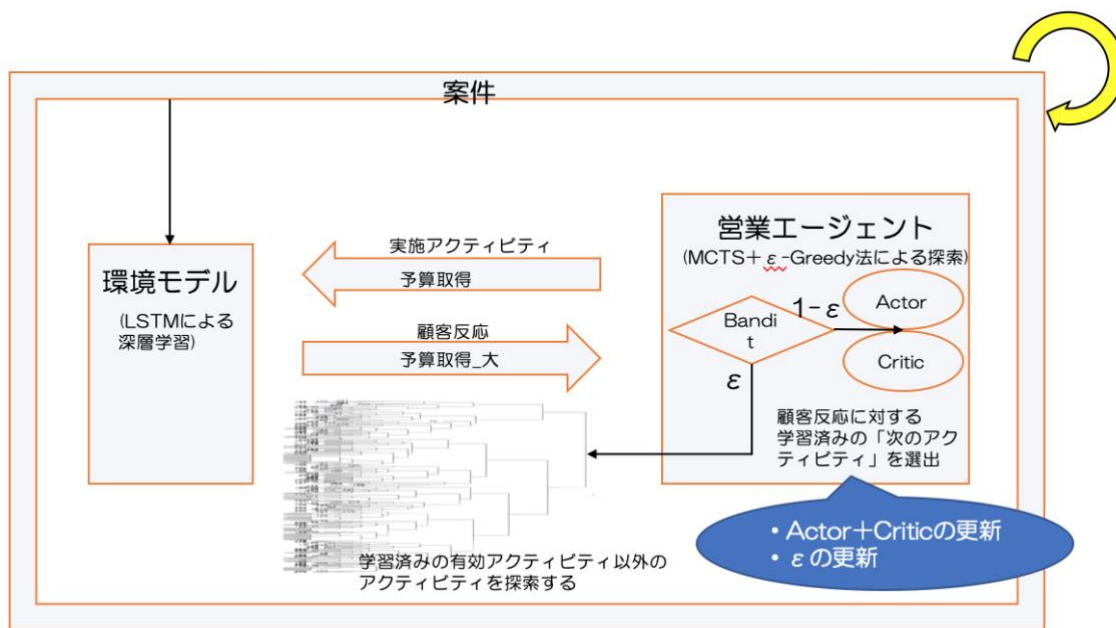


図 4.41 セルフプレイによる強化学習

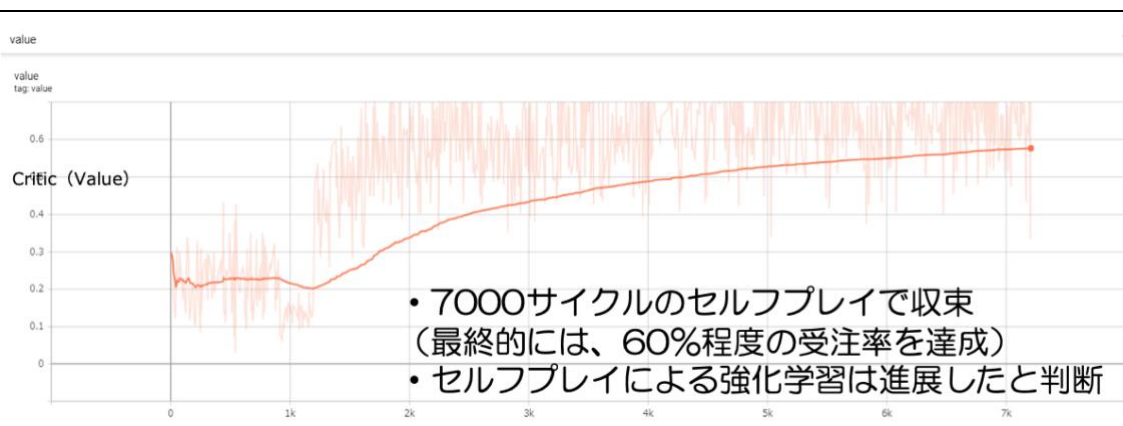


図 4.42 セルフプレイの収束結果

あわせてセルフプレイの初期値(営業エージェントのパラメータ)についても掲載する。

区別	項目	設定値
	イテレーション回数	10,000
Actor-Critic	Actor-Criticの設定(学習率)	5e-3
	Actor-Criticの設定(報酬の減衰率)	0.99
	Actor-Criticの設定(先読み数)	8
	Actor-Criticの設定(価値ロスの影響度)	0.5
	Actor-Criticの設定(エントロピーの影響度)	0.01
$\epsilon$ -greedy	$\epsilon$ -greedyの設定(開始時の確率)	0.2
	$\epsilon$ -greedyの設定(終了時の確率)	0.0
	$\epsilon$ -greedyの設定(ステップ数) ※ランダム選択の確率が開始時の確率から終了時の確率まで ステップ数のイテレーション回で変動する	100,000
MCTS	MCTSの設定(シミュレーション回数) ※環境の状態を一定数にするために、連続量の状態を量子数 の状態に変換する	1,000
	MCTSの設定(量子数)	10
	MCTSの設定(UCTの定数)	10
	MCTSの設定(確率計算時の通過回数の累乗数)	1

表 4.4 セルフプレイの初期値



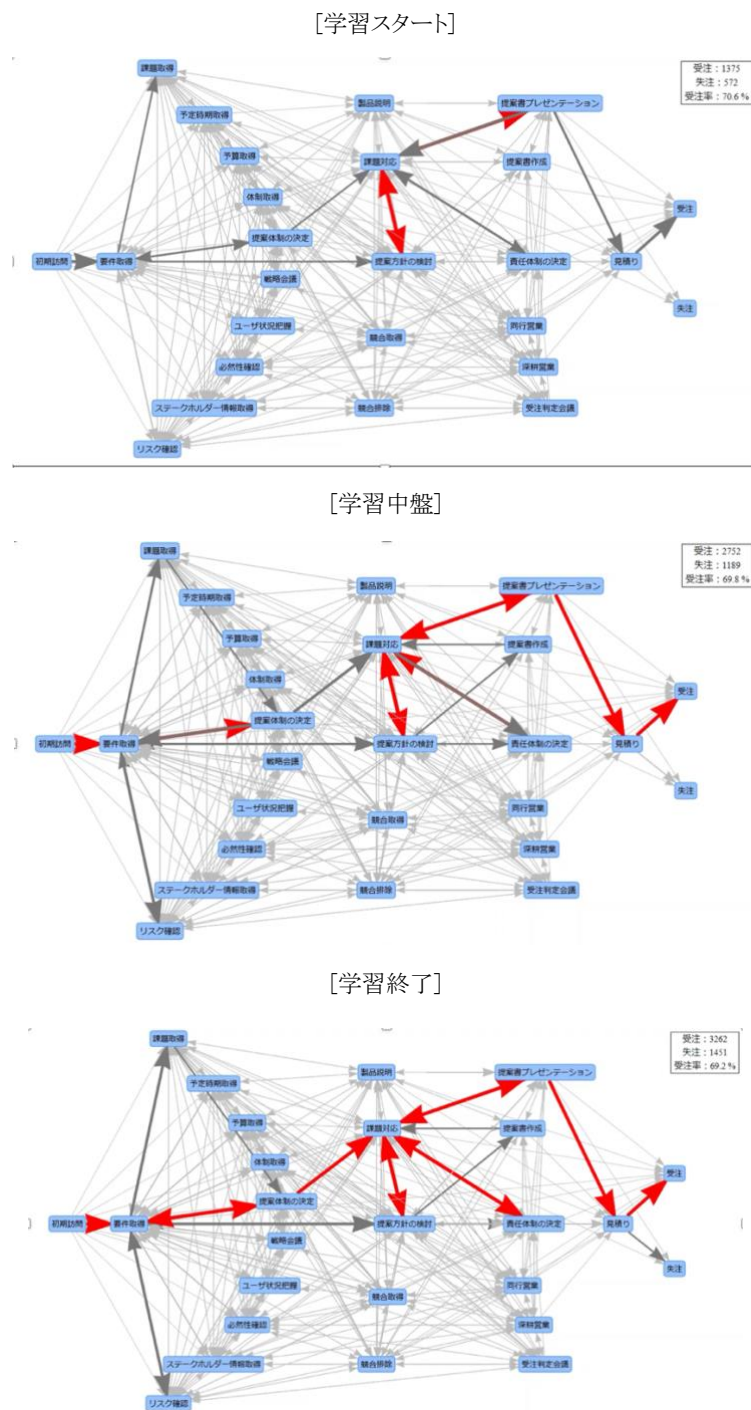


図 4.43 セルフプレイにより学習が進む過程

#### 4.5.7 深層強化学習のプロセスモデルの評価

以上の手法を通して構築した深層強化学習によるプロセスモデルを4.4章で述べた実企業の営業現場で再度評価した。4.4章で実適用評価した POMDP による学習モデルを精度比較の対象とし、それぞれのアルゴリズムによるプロセスモデルからリコメンドされたアクティビティの推移を、営業経験 10 年以上の熟練営業担当者 10 名に確認してもらい、その後、アンケートを実施してリコメンドの納得度を測定した。質問は、POMDP と、深層強化学習によるプロセスモデルのそれぞれについて、営業プロセスの展開推移が自分の営業経験と照らして、合致するか否かで評価した。

具体的には、一人ごとに、2つのアルゴリズムからそれぞれ 10 案件合計 20 案件のリコメンドについて、ランダムにブラインドテストしてもらい、合致しない(=0)、少し合致(=1)、概ね合致(=2)、合致する(=3)の中からどの適合度に該当するかを判断してもらった。それぞれのアルゴリズムの適合度の平均値を縦軸にした 20 人の営業担当者の評価結果が図4.44である。

営業担当者 20 名中 18 名が深層強化学習によるプロセスモデルのリコメンド結果に一番高い評価を与えている。また 20 名の平均値でも深層強化学習によるプロセスモデルは 2.17 と「概ね合致」以上のスコアとなった。深層強化学習によるプロセスモデルでは、過去の受注確率を超えたモデルが構築できるため、顧客の反応に対して提示されるアクティビティが、営業担当者の経験上からも一番理解しやすいという意見が多かった。合わせて、提示されたリコメンドは想定したアクティビティとは異なるものの、受注までの流れを追って確認すると納得性があるという意見も複数あり、これは強化学習によるセレンディピティが評価された可能性もある。一方で、POMDP では、過去実績に基づいたリコメンドとなるため受注確率が過去実績を超えることはない。




図 4.44 深層強化学習のプロセスモデルの評価

あわせて、POMDP と深層強化学習のアンケート結果について、平均の差の検定を実施した。t 値の絶対値が t 値の境界値の絶対値よりも大きく、p 値も 5%(0.05)/1%(0.01)よりも小さいことを確認



できた。このことは、高い統計的有意性を持って、熟練営業担当者の深層強化学習に対する評価（熟練者の経験合致度）は POMDP よりも高いことが説明可能であることを示している。

t-検定：一対の標本による平均の検定ツール		
	POMDP	深層強化学習
平均	1.14	1.61
分散	0.117263158	0.184105263
観測数	20	20
ピアソン相関	0.298027151	
仮説平均との差異	0	
自由度	19	
t	-4.545898103	
P(T<=t) 片側	0.000110473	
t 境界値 片側	1.729132812	
P(T<=t) 両側	0.000220946	
t 境界値 両側	2.093024054	84

図 4.45 アンケート結果の平均の検定

以上から、深層強化学習によるプロセスモデルは、営業活動場面でより現実の営業活動に沿ったリコメンドが可能となり、深層強化学習によるプロセスモデルの有効性について確認することができた。

## 4.6 むすび

第4.2章にて、プロセスモデル構築のためにアルゴリズムを比較した結果、POMDP と深層強化学習が選定された。そこで、第4.3章では、そのための大量教師データの準備を案件シミュレータにより実施した。営業日報のリアルデータをデータオーギュメンテーションすることで、その後のプロセスモデル構築に有効な教師データを作成することができた。

次に、第4.4章では、この案件シミュレータにより、大量に準備された営業日報データを用いて、POMDP によるプロセスモデルの構築をおこなった。その後、POMDP によるプロセスモデルを実企業へ適用、評価を実施した。

具体的には、適用期間で受注率に影響を与えた因子はリコメンドによる営業活動の変更のみという前提で、営業活動意思決定支援システムの有効性を評価指標で評価した。

- ・リコメンド採択は受注率に影響
- ・受注案件においてリコメンドはより多く採択される傾向
- ・行動変更受注貢献率は 6.5～7.8%
- ・営業意思決定支援システムを利用したグループのみが、2タームに渡り 10%前後の受注改善を実現



---

このことから、意思決定支援システムからのリコメンドによる行動変更が受注改善に影響を与えていると推測した。

その後、第4.5章では、第4.3章の教師データを利用して、深層強化学習でプロセスモデルを構築した。まずは、深層学習による環境モデルの構築のあと、営業エージェントと環境モデルのセルフプレイで強化学習を実施した。最終的に、深層強化学習によるプロセスモデルは、熟練営業によるアンケートで POMDP よりも高い評価を得ることができた。深層強化学習によるプロセスモデルは、営業活動場面でより現実の営業活動に沿ったリコメンドが可能であり、深層強化学習によるプロセスモデルの有効性について確認することができた。

## 第5章

---

### 結論

## 5.1 本論文の主たる成果

従来、人の判断が中心であった営業活動の意思決定の過程から、属人性を除外することで、受注確率の高い営業活動を組織全体で実施できるような営業活動意思決定支援システムが求められている。

そこで、本論文では、蓄積した営業日報を活用して、受注確率の高いアクティビティを営業活動プロセスを通じて営業担当者にリコメンドすることで、効果の高い営業を組織全体で再現する仕組みを実現することを目的としている。

そのために、プロセスマイニングを応用して、過去の営業日報から受注確率の高いプロセスを抽出し、プロセスモデルを構築することをアプローチとした。

しかし、従来のプロセスマイニングは実施回数や処理時間に基づいたプロセス抽出であり、受注確率の高いプロセスの抽出とは相違がある。そこで、プロセスマイニングに確率的な情報処理を応用した新たなプロセスモデルの構築手法を検証した。

まずは、メール利用企業向けに、プロセスモデル構築前の準備として、営業日報メールをアクティビティに分類する分類システムを構築する。分類システムのアルゴリズムとして、営業日報データが少ない環境では、LDA+熟練ノウハウに対する doc2vec+SVM の優位性を確認した。

次に、メール/SFA 利用企業向けに、受注確率の高いプロセスを抽出し、プロセスモデルの構築と評価を行った。プロセス抽出のアルゴリズムとしては、複数の候補の中から営業活動の特性に合わせて、部分観測マルコフ決定過程 (POMDP) と深層強化学習を選定した。最初に、アクティビティ分類された営業日報データを用い、大量の教師データを作成する。この教師データを利用して、部分観測マルコフ決定過程 (POMDP) を適用しプロセスモデルを構築した。構築したプロセスモデルを実企業に適用したところ、リコメンドによる行動変更が結果として受注改善に影響を与えたことを確認した。次に同じ教師データを利用して、深層強化学習でプロセスモデルを構築した。構築したプロセスモデルをアンケートで比較評価したところ、深層強化学習によるプロセスモデルは部分観測マルコフ決定過程 (POMDP) より高い評価を得る結果となった。

以上、本論文での重たる成果を述べたが、最終的に効果的な営業活動の意思決定支援の手法が確立できれば、営業活動における意思決定データを組織全体のノウハウとして活用することが可能となり、今後の営業活動の大幅な効率化と受注率向上への寄与が期待できる。

## 5.2 今後の課題と展望

### 5.2.1 能動学習(人間参加型機械学習)によるリコメンド精度向上

環境モデルの深層学習においては、教師データとなる案件データは十分なデータ量を確保しているものの、いまだすべての判断パターンを包含しているわけではなく、また非現実的なやり取りも含まれている。そこで今後は、深層学習による環境モデルの作成時に、人間参加型深層学習(human-in-the-loop) [123]を取り入れることで、より人間と機械知能を組み合わせ、効果的な機械学習アルゴリズムを生成する予定である。深層強化学習で得られた系列情報から案件をクラスタ分類し、不良クラスタをヒューリスティックに除去した場合の効果进行调查していく。人間がアルゴリズム構築の学習段階とテスト段階の両方に関わり、絶え間ないフィードバックループができるため、回を重ねるごとにアルゴリズムの結果は向上する。

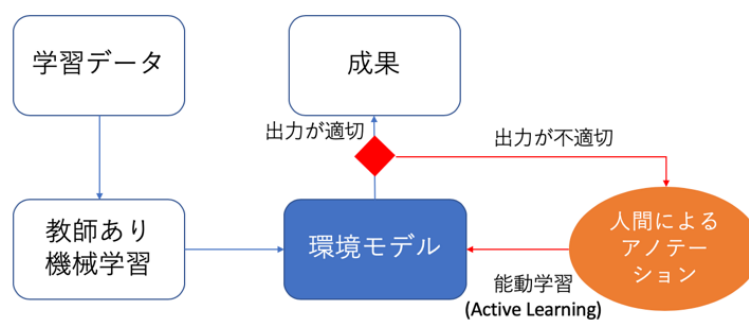


図 5.1 能動学習(人間参加型機械学習)の概要

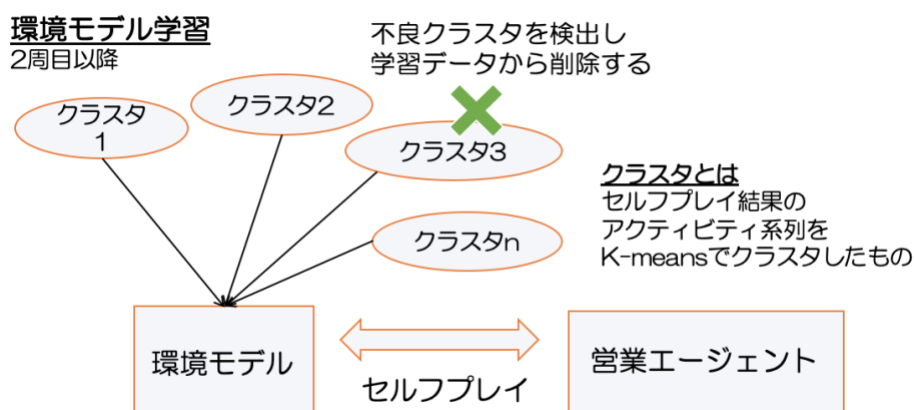


図 5.2 能動学習(人間参加型機械学習)によるリコメンド精度の向上

### 5.2.2 サブゴールの設定によるリコメンド精度の向上

本研究の強化学習によるプロセスモデルの構築においては、営業プロセスの最終にある受注を遅れ報酬として最適方策の学習に利用している。しかし、実際には営業活動のある段階からある段階へと少しずつ順序立てて受注に向かって進行しており、スタートからいきなり受注になるわけではない。そこで、受注につながるまでのステップを分析して、必ず通過するポイントを明確にし、そのポイントごとに即時的な報酬(例えば資料請求を報酬とするなど)で誘導することで、短期的な局所局所で最適な方策を選んでいく手法も有効であると考えられる。つまり、強化学習のサブゴール(通過点と報酬)を設定することでリコメンド精度をさらに向上させる余地がある。特にこの手法は、学習モデル構築のための学習データ(営業日報)を豊富に準備できない営業活動のようなケースに有効であると考えられる。

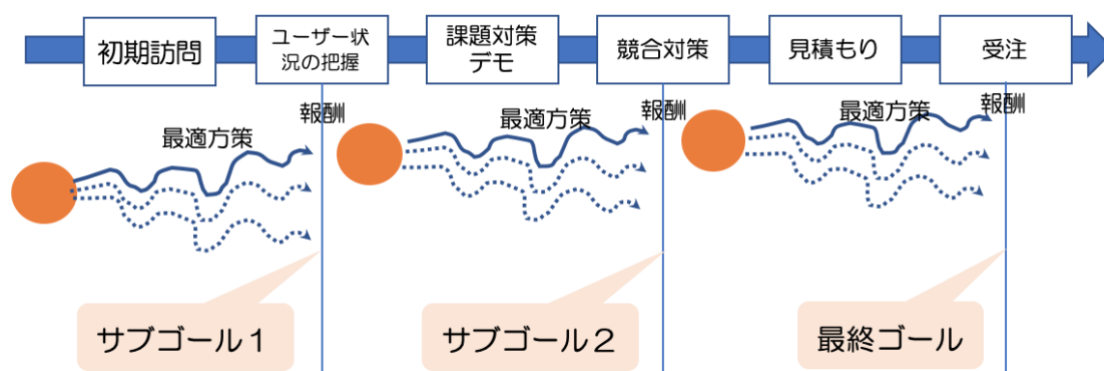


図 5.3 営業プロセスへのサブゴールの設定

### 5.2.3 アクティビティリストの柔軟な変更

今回構築した営業活動意思決定支援システムでは、図3.2で述べた標準のアクティビティリストからリコmendが行われ、また営業担当者の選択も標準のアクティビティリストから行われる。つまり、標準のアクティビティリストに存在しないアクティビティは実施されることがないという前提となっている。実際に営業支援システム(SFA)においても、アクティビティはあらかじめ設定された選択肢からプルダウンで選択される仕様となっている。そのため、営業担当者からの「アクティビティリストにはない新規のアクティビティを実施したい」といった発案を取り入れることができず柔軟性が低い。

そこで、今後は、標準アクティビティリストにない営業活動を営業担当者が実施したい場合は、新規アクティビティとしてシステムに登録してもらうことを検討している。追加された新規アクティビティが他にも含めた営業担当者により何回か実施されると、それをもとにした強化学習でリコmendにも新規アクティビティが新たな選択肢として追加されるようになり、さらにそのリコmendが営業担当者から選択されることで再学習が進んでいく。さらには選ばれなかったアクティビティは同様の仕組みで選択肢から外されることで、従来は固定的であったアクティビティリストが徐々に実際の場面に沿ったリストに変化する仕組みを構築することが可能となる。

例えばコロナ禍では、多くの企業において訪問営業を前提としたアクティビティリストから、リモート営業を主体としたアクティビティリストに変化しているが、この仕組みを取り入れることで現場での成功実績を元にして徐々にリストが変化していく運用を実現することが可能となる。

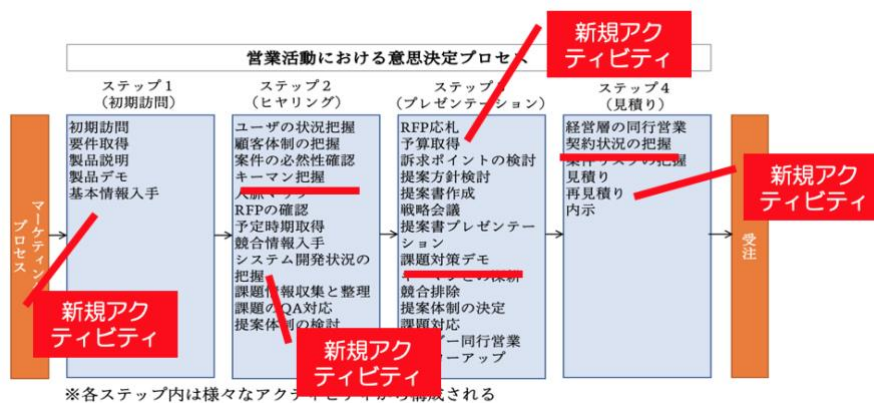


図 5.4 アクティビティリストの柔軟な変更

### 5.2.4 営業活動以外の分野への適用

本論文で述べた手法は、営業活動に限らず、長期にわたるプロセスを通じて、ゴールに向けた確率を高めるための意思決定のリコメンドにも有効である。現在、某鉄道会社と伊豆方面の観光案内リコメンドへの適用を検討している。

営業活動のリコメンドと観光案内のリコメンドの相似について述べる。営業活動のリコメンドにおいては、自然文であるメールをアクティビティに分類することが課題の一つであった。観光案内でも同様に、観光のアクティビティ(海水浴、温泉、ゴルフなど)を定義し、観光客による自然文の SNS データをインプットデータとしてアクティビティに分類することが必要となる。次に、営業活動のリコメンドにおいては、受注確率の高いプロセスを抽出することが課題であった。観光案内でも同様に、満足度の高い観光ルートプロセスとして抽出することとなり、本論文で述べた手法を観光案内のリコメンドでも展開できる可能性がある。



図 5.5 伊豆観光のイメージ  
(阪急交通社 伊豆観光マップより抜粋)

#### 営業活動と観光案内の類似性

	営業活動リコメンド	観光案内リコメンド
課題 1	メールをアクティビティに分類	<ul style="list-style-type: none"> <li>観光活動のアクティビティを定義(海水浴、ゴルフ、温泉など)</li> <li>SNS(自然文)によるインプットデータをアクティビティに分類</li> </ul>
課題 2	受注確率の高いプロセスを抽出	<ul style="list-style-type: none"> <li>満足度の高い観光ルートプロセスとして抽出</li> </ul>

図 5.6 営業活動と観光案内の類似性



## 謝辞

---

本研究を進めるに当たり、直接ご指導頂いた森川博之教授に深く感謝いたします。研究に関する鋭いご指摘はもちろんのこと、文章の書き方からプレゼンテーション技法まで様々な知見を頂きました。多忙にも関わらずいつも笑顔で、穏やかさを湛える様子は私を大いに元気づけてくれました。

成末義哲助教には、論文執筆から博士審査まで親身かつ多くの指導をいただきました。多忙の中、頻繁に相談に乗っていただき、論文の構成など多くの知見を得ることができた。本当に感謝いたします。

森 雅広氏(現 NTT データイントラマート デジタルビジネス推進室)には、本研究の構成から適用実施まで、幅広く貴重なご意見を頂きました。本当に感謝いたします。

斎藤 忍氏(現 NTT ソフトウェアイノベーションセンター)には、プロセスマイニングの関連研究から始まり、本研究の構成内容まで多くのアドバイスをいただくことができました。本当に感謝いたします。

その他、ここで名前を挙げることはいたしません。プロセスモデルの検証において、率先して協力してくれた NTT データイントラマート の社員に感謝いたします。みなさんの理解と支援がなければ、この論文を書き終えることはできなかったでしょう。

ありがとうございました。

2020 年 12 月 1 日

## 参考文献

- [1] J.Costell, “The science of sales success: a proven system for high-profit, repeatable results,” Public Affairs, 2004.
- [2] D.Ledingham, M.Kovac and H.L.Simon, “The new science of sales force productivity,” Harvard Business Review, vol.84, no.9, pp.124-128, 130, 132-133, 2006.
- [3] W.Verbeke, B.Dietz, E.Verwaal, “Drivers of sales performance: A contemporary meta-analysis. Have salespeople become knowledge brokers?,” Journal of the Academy of Marketing Science, vol.39, no.3 pp.407-428, June 2011.
- [4] A.Liu, M.Leach, R.Chugh, “A sales process framework to regain B2B customers,” Journal of Business and Industrial Marketing, vol.30, no.8, pp.906-914, 2015.
- [5] 戦略プロポーザル, “複雑社会における意思決定・合意形成を支える情報科学技術,” 国立研究開発法人 科学技術振興機構 研究開発戦略センター, /CRDS-FY2017-SP-03, 2018.
- [6] 石井淳蔵, “営業をマネジメントする,” (株)岩波書店, 東京, 2012.
- [7] C.Homburg, H.Schäfer and J.Schneider, “Sales excellence: Systematic sales management,” Springer Science & Business Media, 2012.
- [8] N.Rackham, J.DeVincentis, “Rethinking the sales force: Refining selling to create and capture customer value,” Pennsylvania, NY: McGraw-Hill, 1998.
- [9] GA.Churchill Jr, NM Ford, SW.Hartley, et al., “The determinants of salesperson performance: A meta-analysis,” Journal of marketing research, vol.22, no.2 pp.103-118, 1985.
- [10] JO.Rentz, CD.Shepherd, A.Tashchian, et al., “A measure of selling skill: Scale development and validation,” Journal of Personal Selling & Sales Management, vol.22, no.1 pp.13-21, 2002.
- [11] W.Verbeke, B.Dietz and E.Verwaal, “Drivers of sales performance: a contemporary meta-analysis. Have salespeople become knowledge brokers?,” Journal of the Academy of Marketing Science, vol.39, no.3, pp.407-428, 2011.
- [12] JD.Johnson, D.R.Lundberg and M.P.Krebsbach, “Sales force automation and method,” U.S. Patent No.7,516,088. Washington, DC: U.S. Patent and Trademark Office, April 2009.
- [13] JD.Johnson, D.R.Lundberg and M.P.Krebsbach, “Integrated computerized sales force automation system,” U.S. Patent No.6,067,525. Washington, DC: U.S Patent and Trademark office, May 2000.
- [14] RC.Erffineyer, DA.Johnson, “An exploratory study of sales force automation practices: expectations and realities,” Journal of Personal Selling & Sales Management, vol.21, no.2, pp.167-175, 2001.

- 
- [15] M.Bohanec, M.K.Borštnar and M.Robnik-Šikonja, “Explaining machine learning models in sales predictions,” *Expert Systems with Applications*, vol.71, no.1, pp.416–428, 2017.
- [16] K.Siau, Y.Yang, “Impact of artificial intelligence, robotics, and machine learning on sales and marketing,” in *Proc. of Twelve Annual Midwest Association for Information Systems Conference (MWAIS 2017)*, pp.18–19, 2017.
- [17] T.Grigorios, “A survey of machine learning techniques for food sales prediction,” *Artificial Intelligence Review*, vol.52, no.1, pp.441–447, 2019.
- [18] ZL.Sun, TM.Choi, KF.Au, Y.Yu, “Sales forecasting using extreme learning machine with applications in fashion retailing,” *Decision Support Systems*, vol.46, no.1 pp.411–419,2008.
- [19] Y.Kaneko, Y.Katsutoshi, “A deep learning approach for the prediction of retail store sales,” in *Proc. of 2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW)*. IEEE, vol.1, pp.531–537, 2016.
- [20] Y.Huang, F.Zhu, M.Yuan, K.Deng, Y.Li, B.Ni, et al., “Telco Churn Prediction with Big Data,” In *Proc. of Proceedings of the 2015 ACM SIGMOD international conference on management of data*, pp.607– 618, 2015.
- [21] 河村 一輝, 諏訪 博彦, 小川 祐樹, 荒川 豊, 安本 慶一, 太田 敏澄, “飲食店向け不動産営業を支援する申込み顧客推薦モデルの提案,” *人工知能学会論文誌*, vol.32, no.1, WII-O\_1–10, 2017.
- [22] J.Yan, C.Junchi, H.Zha, M.Gong, C.Sun, et al., “On machine learning towards predictive sales pipeline analytics,” In *Proc. of the Twenty-ninth AAAI conference on artificial intelligence*, pp.1945–1951, 2015.
- [23] 多田和市, 吉野次郎, 高橋芳, 竹居智久, 奥平力, 広野彩子, “AI バブル 失敗の法則,” *日経ビジネス*, 5月22日号, pp.28–29, 東京, 2019.
- [24] C.Homburg, J.Christian, H.Schäfer and J.Schneider, “Sales excellence: Systematic sales management,” *Springer Science & Business Media*, 2012.
- [25] Curtis, Bill, M.I.Kellner and J.Over, “Process modeling,” *Communications of the ACM*, vol.35,no.9 pp.75–90,1992.
- [26] W.M.P. van der Aalst, “Process Mining: Discovery, Conformance and Enhancement of Business Processes,” *Springer*, January 2011.
- [27] 飯島 正, 田端 啓一, 斎藤 忍, “プロセスマイニング・サーベイ(第01回: 概要と基本概念),” *情報システム学会誌*, vol.11, No.2, pp.20–22, 2017.
- [28] SA.White, A.Stephen, “Introduction to BPMN,” *Ibm Cooperation*, vol.2.0, 2004.
- [29] A.A. Kalenkova, WMP. Van Der Aalst, I.A. Lomazova and V.A. Rubin, “Process mining using BPMN: relating event logs and process models,” *Software & Systems Modeling*, vol.16, no.4, pp1019–1048, October 2017.

- 
- [30] WMP.Van Der Aalst, MP.Wil, et al. "Business process mining: An industrial application," *Information Systems*, vol.32, no.5 pp.713-732, 2007.
- [31] G. Bernard, T. Boillart, C. Legner and P. Andritsos, "When sales meet process mining: A scientific approach to sales process and performance management," in *Proc. of 37<sup>th</sup> International Conference on Information Systems*, Dublin, Ireland, pp.1-11, December 2016.
- [32] S.Weerapong, P.Porouhan and W.Premchaiswadi, "Process mining using  $\alpha$ -algorithm as a tool (A case study of student registration)," in *proc. of 2012 Tenth International Conference on ICT and Knowledge Engineering. IEEE*, pp.213-220, 2012.
- [33] WMP.Van Der Aalst, "Process mining: Overview and opportunities," *ACM Transactions on Management Information Systems*, No.7, pp.1-17, July 2012.
- [34] J.Munoz-Gama, "Conformance checking and diagnosis in process mining," Springer International Publishing AG, 2016.
- [35] G.D.Giacomo, M.Dumas, F.M.Maggi and M.Montali, "Declarative Process Modeling in BPMN," in *Proc. of International Conference on Advanced Information System Engineering*, Stockholm, Sweden, pp.84-100, May 2015.
- [36] M.Marin, R.Hull and R.Vaculín, "Data centric BPM and the emerging case management standard: A short survey," in *Proc. of International Conference on Business Process Management*, Berlin, Heidelberg, pp.24-30, September 2012.
- [37] WMP. Van Der Aalst, M.Pesic and H.Schonenberg, "Declarative workflows: Balancing between flexibility and support," *Computer Science – Research and Development*, vol.23, no.2, pp.99-113, 2009.
- [38] M.Pesic, H.Schonenberg and WMP. Van Der Aalst, "Declare: Full support for loosely-structured processes," in *Proc. of 11<sup>th</sup> IEEE International Enterprise Distributed Object Computing Conference*, pp.287-287, Annapolis, USA, October 2007.  
DOI:10.1109/EDOC.2007.3
- [39] F.M.Maggi, T.Slaats and H.A. Reijers, "The automated discovery of hybrid processes," in *Proc. of International Conference on Business Process Management (BPM 2014)*, pp.392-399, Eindhoven, The Netherlands, September 2014.
- [40] T.Biard, A.Le Mauff, M.Bigand, JP.Bourey, "Separation of Decision Modeling from Business Process Modeling Using New "Decision Model and Notation" (DMN) for Automating Operational Decision-Making," *Risks and Resilience of Collaborative Networks*, Springer, Cham, December 2015.
- [41] A.Rozinat, WMP. van der Aalst, "Decision mining in ProM," in *proc. of international conference on Business Process Management*, Springer, Berlin, Heidelberg, pp.420-425, 2006.
- [42] A.Rebuge, D.R.Ferreira, "Business process analysis in healthcare environments: A methodology based on process mining," *Information systems*, vol.37, no.2, pp.99-116, 2012.

- 
- [43] M.Song, WMP Van der Aalst, “Towards comprehensive support for organizational mining,” *Decision Support Systems*, vol.46,no.1, pp.300–317, 2008.
- [44] W.Van Der Aalst, A.Adriansyah, et al. “Process mining manifesto,” in *proc. of International Conference on Business Process Management*, Springer, Berlin, Heidelberg, pp.169–194, 2011.
- [45] WMP.Van Der Aalst, “Process mining,” *Communications of the ACM*, vol.55, no.8, pp.76–83, 2012.
- [46] WMP.Van der Aalst, M.H.Schonenberg and M.Song, “Time prediction based on process mining,” *Information systems*, vol.36, no.2, pp.450–475, 2011.
- [47] B.Pang, L.Lee and S.Vaithyanathan, “Thumbs up? Sentiment classification using machine learning techniques,” *arXiv preprint cs/0205070*, 2002.
- [48] WMP.Van der Aalst, BF.van Dongen, CW.Gunther, A.Rozinat, H.Verbeek and A.Weijters, “Prom: The process mining toolkit,” *Proceedings of the BPM 2009 Demonstration Track*, vol.489, no.31, pp.2, 2009.
- [49] WMP.Van del Aslst, A.Weijters, and L.Maruster, “Workflow Mining: Which Processes can be Rediscovered,” *BETA Working Paper Series*, WP 74, Eindhoven University of Technology, Eindhoven, 2002.\_
- [50] W.Van del Aslst, T.Weijters, “Workflow Mining: Discovery Process Models from Event Logs,” *IEEE Transactions on Knowledge and Data Engineering*, vol.16, no.9, pp.1128–1142, 2004.
- [51] T.Murata, “Petri nets: Properties, analysis and applications,” *Proceedings of the IEEE*, vol.77, no.4, pp.541–580, 1989.
- [52] R.Conforti, M.Dumas, L.Garcia–Banuelos, “BPMN miner: automated discovery of BPMN process models with hierarchical structure,” *Information Systems*, vol.56, pp.284–303, 2016.
- [53] H.M.W. Verbeek, J.C.A.M. Buijs, B.F. Dongen and W.M.P. Aalst, “Xes, xesame, and prom 6,” in *proc. of Information Systems Engineering*, Springer, Berlin, Heidelberg, 2010.
- [54] B.Silver, (監訳) 岩田アキラ, *BPMN METHOD & STYLE 第 2 版 BPMN 実装者向けガイド付き*, 日本ビジネスプロセス・マネジメント協会, 2013.
- [55] M.Owen, J.Raj, “BPMN and Business Process Management,” *Introduction to the new business process modeling standard vol.4*, 2003.
- [56] R.M. Dijkman, M. Dumas, and C. Ouyang, “Semantics and analysis of business process models in BPMN,” *Information and Software Technology*, vol.50, no.12, pp.1281–1294, 2008.
- [57] 平石邦彦, “複雑なプロセスのモデル化,” *電子情報通信学会基礎・境界ソサイエティ Fundamentals Review*, vol.6, no.4, pp.257–264, 2013.
- [58] R.K.L.Ko, S.S.G.Lee and E.W.Lee, “Business process management (BPM) standards: a survey,” *Business Process Management Journal*, 2009.
- [59] D.Karagiannis, “BPMS: business process management systems,” *ACM SIGOIS Bulletin*, vol.16, no.1, pp.10–13, 1995.

- 
- [60] R.Brennan, L.Canning and R.McDowell, “Business-to-business marketing,” SAGE Publications Limited, 2020.
- [61] L.Canning, R.Brennan, “Strategy as the management of adaptation,” in proc. of IMP annual conference, 2004.
- [62] P.Viio, C.Grönroos, “Value-based sales process adaptation in business relationships,” *Industrial Marketing Management*, vol.43, no.6, pp.1085-1095, 2014.
- [63] D.M.Blei, A.Y.Ng, M.I.Jordan, “Latent Dirichlet Allocation,” *Journal of Machine Learning Research*, vol.3, pp.993-1022, 2003.
- [64] H.Jelodar, Y.Wang, C.Yuan, X.Feng, X.Jiang, et al. “Latent Dirichlet Allocation (LDA) and Topic modeling: models, applications, a survey,” *Multimedia Tools and Applications*, vol.78, no.11, pp.15169-15211, 2019.
- [65] Q.Le, T.Mikolov, “Distributed Representations of Sentences and Documents,” in proc. of International Conference on Machine Learning, pp.1188-1196, 2014.
- [66] JAK.Suykens, J.Vandewalle, “Least squares support vector machine classifiers,” *Neural processing letters*, vol.9, no.3, pp.293-300, 1999.
- [67] 中山義人, 森雅広, 成末義哲, 森川博之, “営業活動における意思決定のプロセス発見手法: プロセスマイニングの応用アプローチ,” *情報システム学会誌*, vol.14, no.1, pp.26-38, September 2018.
- [68] Y. Nakayama, M. Mori, Y. Narusue, and H. Morikawa, “The process discovery Approaches for decision making in sales activities,” in Proc. of SCIS&ISIS 2018, pp.1394-1399, Okayama, Japan, December 2018.
- [69] 神鷹敏弘, “推薦システムのアルゴリズム (1),” *人工知能学会誌*, vol.22, no.6, pp.826-837, 2007.
- [70] P.Brusilovski, A.Kobsa and W.Nejdl, “The adaptive web: methods and strategies of web personalization,” Springer Science & Business Media, vol.4321, 2007.
- [71] D.Billsus, M.J.Pazzani, “Learning collaborative information filters,” *Icml*, vol.98, pp.46-54, 1998.
- [72] 本村陽一, 佐藤泰介, “ベイジアンネットワーク: 不確定性のモデリング技術,” *人工知能学会誌*, vol.15, no.4, pp.575-582, 2000.
- [73] J.Pearl, “Bayesian networks: A model of self-activated memory for evidential reasoning,” in proc. of Proceedings of the 7th Conference of the Cognitive Science Society, University of California, Irvine, CA, USA, pp.15-17, 1985.
- [74] Z.Ghahramani, “Learning dynamic Bayesian networks,” *Adaptive Processing of Sequences and Data Structures*, pp.168-197, 1997.
- [75] 木村元, “部分観測マルコフ決定過程下での強化学習 (<特集> 強化学習),” *人工知能学会誌*, vol.12, no.6, pp.822-830, 1997.

- 
- [76] 澁谷長史, “《第 4 回》部分観測マルコフ決定過程と強化学習,” 計測と制御, vol.52, no.4, pp.374-380, 2013.
- [77] 藤田肇, 石井信, “部分観測カードゲームのためのモデル同定型強化学習,” 電子情報通信学会論文誌 D, vol.88, no.11, pp.2277-2287, 2005.
- [78] S.Racaniere, D.Reichert, T.Weber, O.Vinyals, D.Wierstra, L.Buesing, P.Battaglia, R.Pascanu, Y.Li, N.Heess, et al, “Imagination-augmented agents for deep reinforcement learning,” In Advances in Neural Information Processing Systems, vol.30, pp.5692-5699, 2017.
- [79] 水谷陽太, 鶴岡慶雅, “モデルベース深層強化学習における隠れ層を用いた環境遷移モデルの提案,” ゲームプログラミングワークショップ 2018 論文集 2018, pp.72-79, 2018.
- [80] Silver, D.Huang, A.Maddison, C.J.Guez, A.L.Sifre, V.D.Driessche and S.Dielemen, “Mastering the game of Go with deep neural networks and tree search,” Nature, vol.529, no.7587, pp.484-489, 2016.
- [81] J.L.Herlocker, J.A.Konstan, L.G.Terveen and J.T.Riedl, “Evaluating collaborative filtering recommender systems,” ACM Transactions on Information Systems (TOIS), vol.22, no.1, pp.5-53, 2004.
- [82] 小田昌宏, “ディープラーニング活用の重要ポイント,” Medical Imaging Technology, vol.36, no.2, pp.72-75, 2018.
- [83] C.H. Papadimitriou, J.N. Tsitsiklis, “The Complexity of Markov Decision Processes,” Mathematics of operations research, vol.12, no.3, pp.441-450, 1987.
- [84] S.P. Singh, T. Jaakkola, M.I. Jordan, “Learning without state-estimation in partially observable Markovian decision processes,” Machine Learning Proceedings 1994, in proc. of the Eleventh International Conference, pp.284-292, July 1994.
- [85] T. Jaakkola, S.P. Singh, M.I. Jordan, “Reinforcement Learning Algorithm for Partially Observable Markov Decision Problems,” Advances in neural information processing systems, pp. 345-352, 1995.
- [86] D.P. Bertsekas, J.N. Tsitsiklis, “Neuro-dynamic programming: an overview,” Proceedings of 1995 34th IEEE Conference on Decision and Control. IEEE, pp. 560-564, 1995.
- [87] R.I. Brafman, “A Heuristic Variable Grid Solution Method for POMDPs,” AAAI/IAAI, pp. 727-733, 1997.
- [88] 長野智晃, 近藤敏之, 伊藤宏司, “強化学習 MOSAIC: 予測性によるシンボル化と見まね学習強化学習,” SICE Symposium on Decentralized Autonomous Systems, vol.18, pp.123-128, 2006.
- [89] I. Noda, “Hidden markov modeling for multi-agent systems,” Pacific Rim International Conference on Artificial Intelligence, Berlin, Heidelberg, pp. 128-137, 2002.
- [90] G.Shani, D.Heckerman, and R.I.Brafman, “An MDP based recommender system,” Journal of Machine Learning Research, vol.6, pp.1265-1295, September 2005.



- 
- [91] L.E.Baum, T.Petrie, “Statistical Inference for Probabilistic Functions of Finite State Markov Chains,” *The Annals of Mathematical Statistics*, vol.37, no.6, pp. 1554-1563, 1966.
- [92] L.E.Baum, J.A.Eagon, “An inequality with applications to statistical estimation for probabilistic functions of Markov processes and to a model for ecology,” *Bulletin of the American Mathematical Society*, vol.73, no.3, 1967.
- [93] L.E.Baum, G.Sell, “Growth transformations for functions on manifolds,” *Pacific Journal of Mathematics*, vol.27, no.2, pp.211-227, 1968.
- [94] L.E.Baum, T.Petrie, G.Soules, N.Weiss, “A Maximization Technique Occurring in the Statistical Analysis of Probabilistic Functions of Markov Chains,” *The Annals of Mathematical Statistics*, vol.41, no.1, pp.164-171, 1970.
- [95] L.E.Baum, “An Inequality and Associated Maximization Technique in Statistical Estimation of Probabilistic Functions of a Markov Process,” *Inequalities*, vol.3, no.1, pp.1-8, 1972.
- [96] G. D. Forney, “The Viterbi algorithm,” *Proceedings of the IEEE*, vol.61, no.3, pp.268-278, March 1973.
- [97] Welch, R.Lloyd, “Hidden Markov Models and the Baum-Welch Algorithm,” *IEEE Information Theory Society Newsletter*, vol.53, no.4, pp.10-13, December 2003.
- [98] T.Menzies, Y.Hu, “Data mining for very busy people,” *Computer*, vol.36, no.11, pp.22-29, 2003.
- [99] G.A. Churchill Jr, N.M. Ford, S.W. Hartley, O.C. Walker Jr, “The determinants of salesperson performance: A meta-analysis,” *Journal of marketing research*, vol.22, No.2, pp.103-118, 1985.
- [100] L. Yujian, L. Bo, “A Normalized Levenshtein Distance Metric,” *IEEE transactions on pattern analysis and machine intelligence*, vol.29, no.6, pp.1091-1095, 2007.
- [101] Viio, Paul, “Strategic sales process adaptation: Relationship orientation of the sales process in a business-to-business context,” *Svenska handelshögskolan*, 2011.
- [102] Silver, D.Hubert, T. Schrittwieser, J.Antonoglou, I.Lai, M.Guez and T.Lillicrap, “Mastering chess and shogi by self-play with a general reinforcement learning algorithm,” *arXiv preprint arXiv:1712.01815*, 2017.
- [103] J.Heinrich, D.Silver, “Deep reinforcement learning from self-play in imperfect-information games,” *arXiv preprint arXiv:1603.01121*, 2016.
- [104] R.A.Howard, “*Dynamic Programming and Markov Processes*,” *The M.I.T. Press*, 1960.
- [105] Myerson, Joel and L.Green, “Discounting of delayed rewards: Models of individual choice,” *Journal of the experimental analysis of behavior*, vol.64, no.3, pp.263-276, 1995.
- [106] Wiering, Marco, Martijn, V.Otterlo, “*Reinforcement Learning State-of-the-Art*,” *Springer-Verlag Berlin Heidelberg*, 2012.

- 
- [107] Sutton, S.Richard, "Integrated architectures for learning, planning, and reacting based on approximating dynamic programming," In Machine Learning Proceedings 1990, pp.216-224, 1990.
- [108] D.Silver, H.V.Hasselt, M.Hessel, T.Schaul, A.Guez, T.Harley, G.D.Arno,ld, D.Reichert, N.Rabino.witz, A.Barreto and T.Degrís, "The prediction : End-to-end learning and planning," In Proceedings of the International Conference on Machine Learning (ICML), pp.3191-3199, 2017.
- [109] Coulom, Rémi, "Efficient selectivity and backup operators in Monte-Carlo tree search," in proc. of International conference on computers and games, Berlin, Heidelberg, pp.72-83, 2006.
- [110] C.B.Browne, Powley, et al, "A survey of monte carlo tree search methods," IEEE Transactions on Computational Intelligence and AI in games, vol. 4, no.1, pp.1-43, 2012.
- [111] Y.H.Wang, T.H.S.Li and C.J.Lin, "Backward Q-learning: The combination of Sarsa algorithm and Q-learning," Engineering Applications of Artificial Intelligence, vol.26, no.9 , pp.2184-2193, 2013.
- [112] R.S.Sutton, A.G.Barto, "Reinforcement learning: An introduction," MIT press, 2018.
- [113] R.S. Sutton, "Integrated architectures for learning, planning, and reacting based on approximating dynamic programming," Machine learning proceedings 1990, Morgan Kaufmann, pp. 216-224, 1990.
- [114] F.Y.Wang, J.J.Zhang, X.Zheng, X.Wang, Y.Yuan, X.Dai, and L.Yang, "Where does AlphaGo go: From church-turing thesis to AlphaGo thesis and beyond," IEEE/CAA Journal of Automatica Sinica, vol.3 no.2, pp.113-120, 2016.
- [115] S.Gu, T.Lillicrap, I.Sutskever and S.Levine, "Continuous deep q-learning with model-based acceleration," in proc. of International Conference on Machine Learning, pp.2829-2838, 2016.
- [116] M.Matusugu, K.Mori, Y.Mitari, Y.Kaneda, "Subject independent facial expression recognition with robust face detection using a convol.utional neural network," Neural Networks, vol.16, no.5-6, pp.555-559, June 2003.
- [117] L.Jinyu, L.Deng, Y.Gong, R.Haeb-Umbach, "An overview of noise-robust automatic speech recognition," IEEE/ACM Transactions on Audio, Speech, and Language Processing, vol.22, no.4, pp.745-777, 2014.
- [118] S.Hochreiter and J.Schmidhuber, "Long shortterm memory," Neural computation, vol.9, no.8, pp.1735-1780, 1997.
- [119] Tokic, Michel, "Adaptive  $\epsilon$ -greedy exploration in reinforcement learning based on value differences," in proc. of Annual Conference on Artificial Intelligence, Berlin, Heidelberg, pp.203-210, 2010.

- 
- [120] Ho, Jonathan, and S.Ermon, “Generative adversarial imitation learning,” Advances in neural information processing systems, pp.4565–4573, 2016.
- [121] Ross, Stéphane, and D.Bagnell, “Efficient reductions for imitation learning,” in proc. of Proceedings of the thirteenth international conference on artificial intelligence and statistics, pp.661–668, 2010.
- [122] V.R.Konda, and J.N. Tsitsiklis, “Actor-critic algorithms,” Advances in neural information processing systems, pp.1008–1014, 2000.
- [123] Karwowski, Waldemar, et al, “International encyclopedia of ergonomics and human factors–3 Volume Set.,” CRC Press, 2006.

# 発表文献

---

## 論文誌

- [1] 中山義人, 森雅広, 成末義哲, 森川博之, “営業活動における意思決定システムの実適用と評価,” 電子情報通信学会論文誌(D), 2020年11月 条件付き採録原稿を投稿済み.
- [2] 中山義人, 森雅広, 成末義哲, 森川博之, “営業活動における意思決定のプロセス発見手法: プロセスマイニングの応用アプローチ,” 情報システム学会誌, vol.14, no.1, pp.26-38, June 2018.

## 国際会議における発表

- [3] Y. Nakayama, M. Mori, Y. Narususe, and H. Morikawa, “The Process Discovery Approaches for Decision Making in Sales Activities,” in Proc. of 10th International Conference on Soft Computing and Intelligent Systems, Okayama, Japan, pp.1394-1399, December 2018.
- [4] Y. Nakayama, M. Mori, Y. Narususe, and H. Morikawa, “Decision-Making in Sales Activity: Applying Process Mining Approach,” in Proc. of Decision CAMP Conference 2018, Luxembourg, Luxembourg, pp.1-5, September 2018.

## 国内学会・研究会

- [5] 中山義人, 森雅広, 成末義哲, 森川博之, “営業活動における意思決定のプロセス発見手法の概要: プロセスマイニングに基づくアプローチ,” 電子情報通信学会研究報告, LOIS2017-84, March 2018.

→2018年ライフインテリジェンスとオフィス情報システム研究賞(LIOS賞)

- [6] 中山義人, 森雅広, 成末義哲, 森川博之, “営業活動における意思決定プロセス発見手法とイベント推定: プロセスマイニングの応用アプローチ,” 情報処理学会研究報告, vol.2018-GN-105, May 2018.
- [7] 中山義人, 森雅広, 成末義哲, 森川博之, “営業活動の意思決定プロセス強化における環境モデルに基づくアプローチ,” 情報処理学会研究報告, vol.2019-GN-107, March 2019.

---

[8] 中山義人, 森雅広, 成末義哲, 森川博之, “ワークフロー型業務意思決定支援システムにおけるアクセスログの活用,” 電子情報通信学会総合大会, D-9-4, March 2017.

[9] 中山義人, 森雅広, 斎藤忍, 成末義哲, 森川博之, “プロセスマイニング手法を活用した業務意思決定支援システムの設計について,” 第13回情報システム学会全国大会, S2-D.1, December 2017.

→ベストペーパー特別賞

[10] 中山義人, 森雅広, 斎藤忍, 成末義哲, 森川博之, “営業活動における意思決定システムの適用と評価,” 情報処理学会第18回情報科学技術フォーラム(FIT2019), CO-003, September 2019.

→FIT 論文賞