



人事データ分析の現状と AIガバナンス・ガイドラインへの期待

DataRobot ディレクター 小川幹雄

The information contained in this presentation is proprietary and only for the intended recipient. It may not be reproduced, distributed or otherwise disclosed without the prior written consent of DataRobot, Inc. ©2021 DataRobot, Inc. All rights reserved. All third party marks referenced herein are the property of their respective holders and are used for identification purposes only.

DataRobot



小川幹雄(オガワミキオ)

Director Data Science Practice @ DataRobot Japan

DataRobot Japan 3番目のメンバーとして参加。現在は、金融業界を担当するディレクター兼リードデータサイエンティストとして、金融機関のお客様でのAI導入支援からCoE構築の支援を行いながら、イベント、大学機関、金融庁での講演を多数実施。

初期はインフラからプロダクトマネジメント業、パートナーリング業までDataRobotのあらゆる業務を担当。前職はデータマネジメント系の外資ベンダーで分析ソリューション・ビッグデータ全般を担当。

2021 - 金融チームディレクター、DataRobot AI Legends Awards受賞

2018 - 金融チームリードデータサイエンティスト、DataRobot CFDS Awards受賞

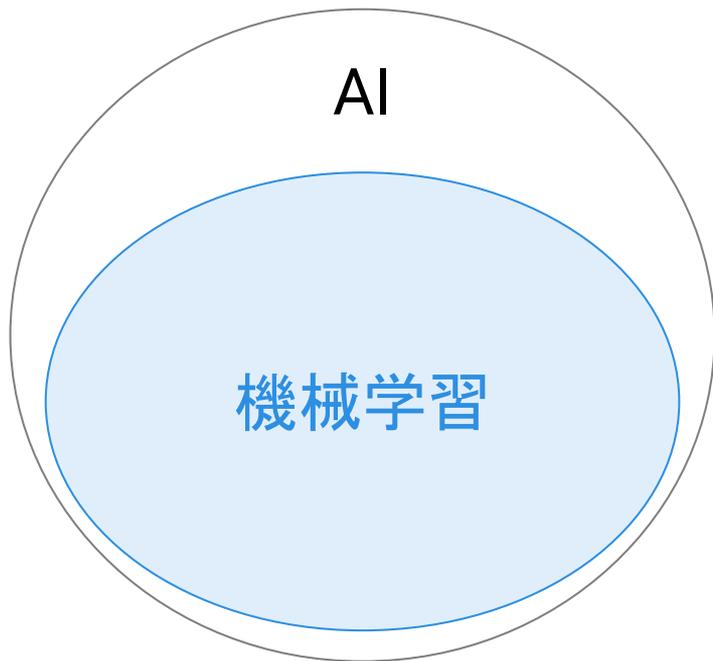
2016 - DataRobot Japan 3番目のメンバーとして参加

代表的なAIプロジェクト

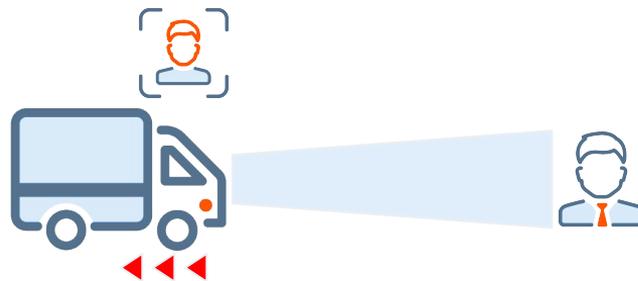
- ・ メガバンク、メガバンクグループ各社におけるAI活用支援
- ・ 金融機関におけるAI推進CoE組織構築支援
- ・ 大手HRテックカンパニーにおけるAI民主化推進



AIとは？機械学習との関係性について



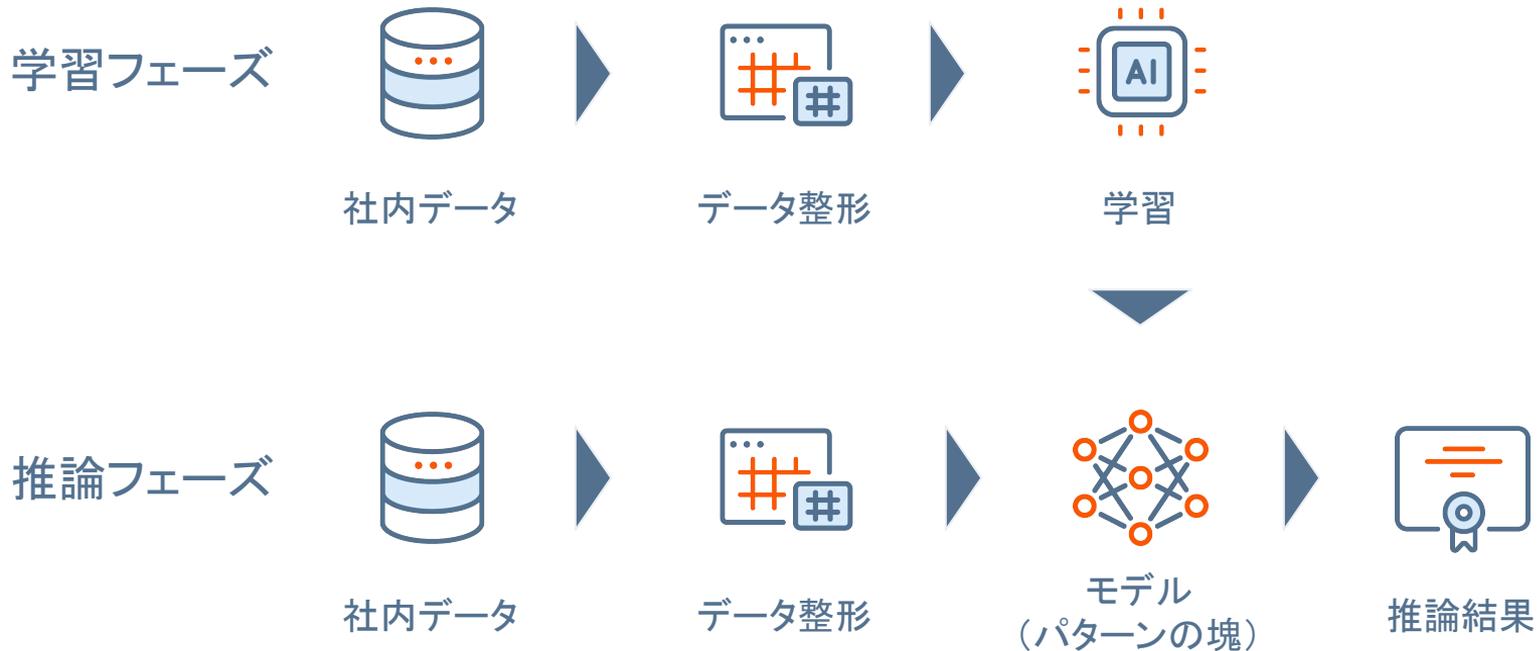
機械学習によって
人を認識



AI: 人を認識したため
自動でブレーキを制御

機械学習はAIの一部であり、機械学習の結果を
アクションに繋げることをAIと捉えられる

機械学習の基本的な流れ



人事領域におけるAI活用の可能性を持つ領域



採用企画

- イベント出店効果予測
- 広告出稿効果予測

採用計画

- 目標採用人数予測
- 採用リードタイム予測

新卒採用

- 応募人数予測
- 書類選考時の足切り
・優先順位付け

面接通過予測

- 内定承諾予測

中途採用

- 募集内容別応募数予測
- 面談キャンセル予測
- ヘッドハンティング対象候補者リスト作成

研修プランニング

- 継続率予測
- 研修評価分析

スキルアップ

- 資格習得効果測定
- 資格獲得率予測

人事評価

- 昇給対象者選別
- パフォーマンス予測

退職対応

- 退職予測
- 休職予測

人材管理

- 残業時間予測
- 有給消化率予測
- ハラスメント発生予測

現実的に日本の人事領域においてAI活用が見られる領域



企画・計画

採用活動

研修・教育

評価・管理

採用企画

- イベント出店効果予測
- 広告出稿効果予測

採用計画

- 目標採用人数予測
- 採用リードタイム予測

新卒採用

- 応募人数予測
- 書類選考時の足切り
・優先順位付け

面接通過予測

内定承諾予測

中途採用

- 募集内容別応募数予測
- 面談キャンセル予測
- ヘッドハンティング対象候補者リスト作成

研修プランニング

- 継続率予測
- 研修評価分析

スキルアップ

- 資格習得効果測定
- 資格獲得率予測

人事評価

- 昇給対象者選別
- パフォーマンス予測

退職対応

- 退職予測
- 休職予測

人材管理

- 残業時間予測
- 有給消化率予測
- ハラスメント発生予測

HR領域におけるAI導入の3つの課題



テーマの難しさ

秘匿性

人材の欠乏



センシティブさと実現難易度

定義の不確定
公平性とバイアス
データのゆらぎ

高いレベルの
AI構築スキルが求められる

データとテーマの秘匿性

テーマ実施自体の秘匿
データアクセス権利
モデルロジックの秘匿

少数の特定人物でしか
AIモデル構築が行えない

技術力とリソース

AIの専門家が少ない
単純なリソース不足

求められるハードルに
対してのギャップが巨大

HR領域におけるAI導入の3つの課題



テーマの難しさ



センシティブさと実現難易度

定義の不確定
公平性とバイアス
データのゆらぎ

高いレベルの
AI構築スキルが求められる

秘匿性



データとテーマの秘匿性

テーマ実施自体の秘匿
データアクセス権利
モデルロジックの秘匿

少数の特定人物でしか
AIモデル構築が行えない

人材の欠乏



技術力とリソース

AIの専門家が少ない
単純なリソース不足

求められるハードルに
対してのギャップが巨大



テーマ創出アイデアシート

名前

データ太郎

予測対象(ターゲット)

将来の高パフォーマンス人材を予測

を予測
を検知
を分類

予測できるとどんなアクションを取るか

- 高パフォーマンス人材に対して優先的な昇格や昇給を実施する
- 低パフォーマンス人材を追加研修等でフォローする
-

アクションからどんなメリットがあるのか

- 社内人材の高度化 _____ (収益・コスト・その他)
- 優秀人材の退職率提言 _____ (収益・コスト・その他)
- _____ (収益・コスト・その他)

重要度

実現性



予測モデルができた後の業務における実運用フロー

1. 社員全員に対して四半期に一度予測を実施
2. AIで高パフォーマンス人材を分類
3. 候補リストを上長に連携

要素

- 人件費
- 一人当たり生産性
-
-
-
-
-
-

インパクトの計算式

???

実現性結果

平均 2.2点

ビジネスインパクト

???



テーマ創出アイデアシート

名前

データ太郎

予測対象(ターゲット)

将来の高パフォーマンス人材を予測

そもそも何をもって高パフォーマンスと定義するのか。その定義は組織や年ごとに変化しているのではないか

を予測を検知を分類

予測できるとどんなアクションを取るか

- 高パフォーマンス人材に対して優先的な昇格や昇給を実施する
- 低パフォーマンス人材を追加研修等でフォローする
-

アクションからどんなメリットがあるのか

- 社内人材の高度化 (収益・コスト・その他)
- 優秀人材の退職率提言 (収益・コスト・その他)
- _____ (_____)

重要度

センチメントデータなどは主観的でデータの扱いが難しい

実現性



予測モデルができた後の業務における実運用フロー

- 社員全員に対して四半期に一度予測を実施
- AIで高パフォーマンス人材を分類
- 候補リストを上長に連携

要素

- 人件費
- 一人当たり生産性
-
-
-
-
-
-
-

イン

予測したところで、アクションが上長頼みになることが多い。また、AIに差別的な判断が含まれていないか確認が必要

???

定量的なインパクト算出が難しいため、予算投入が難しい

インパクト

平均 2.2点

???

DataRobotにおける公平性とバイアスへの対応



選択の目安: 公正さ指標

1. エラーの平等性と予測の平等性のどちらでモデルの公正さを測定したいですか？
エラーの平等性 予測の平等性

2. モデルの元の予測スコアとモデルの二値による決定値のどちらに基づいて公平にしたいですか？
バイナリ決定 元のスコア

3. 保護された各クラスについて、予測行の数と予測行の割合のどちらで好ましい結果を確保したいですか？
数の平等性 割合の平等性

推奨される公正さ指標

推奨

割合の平等性 同数の平等性 予測バランス True Positives率とTrue Negatives率の平等性 陽性的中率と陰性的中率の平等性

クラスごとのバイアス: クラス間のデータの相違
クラスごとのバイアス: 割合の平等性

保護されている特徴量: 性別
バイアス許容値: 0.8 好ましいターゲット結果: Yes 相対値を表示 絶対値を表示

割合の平等性

■ 値がしきい値を下回っています ■ 値がしきい値を超えています ■ データが不十分です

データの相違と特徴量の重要性
FemaleとMaleの間のデータの相違(上位10の特徴量)

● Minor Impact ● Moderate Impact ● Major Impact

特徴量の詳細:

採用可否

FemaleとMaleの分布の違い

■ Female (139レコード) ■ Male (3061レコード) 特徴量ごとの作用を表示

性別	Yes (%)	No (%)
Female (139レコード)	~5%	~95%
Male (3061レコード)	~15%	~85%

DataRobotでは公平性を測定したい特徴量と公平性の評価方法を選択することによって、モデルがその特徴量においてバイアスを持っているかの測定が可能

HR領域におけるAI導入の3つの課題



テーマの難しさ



センシティブさと実現難易度

定義の不確定
公平性とバイアス
データのゆらぎ

高いレベルの
AI構築スキルが求められる

秘匿性



データとテーマの秘匿性

テーマ実施自体の秘匿
データアクセス権利
モデルロジックの秘匿

少数の特定人物でしか
AIモデル構築が行えない

人材の欠乏



技術力とリソース

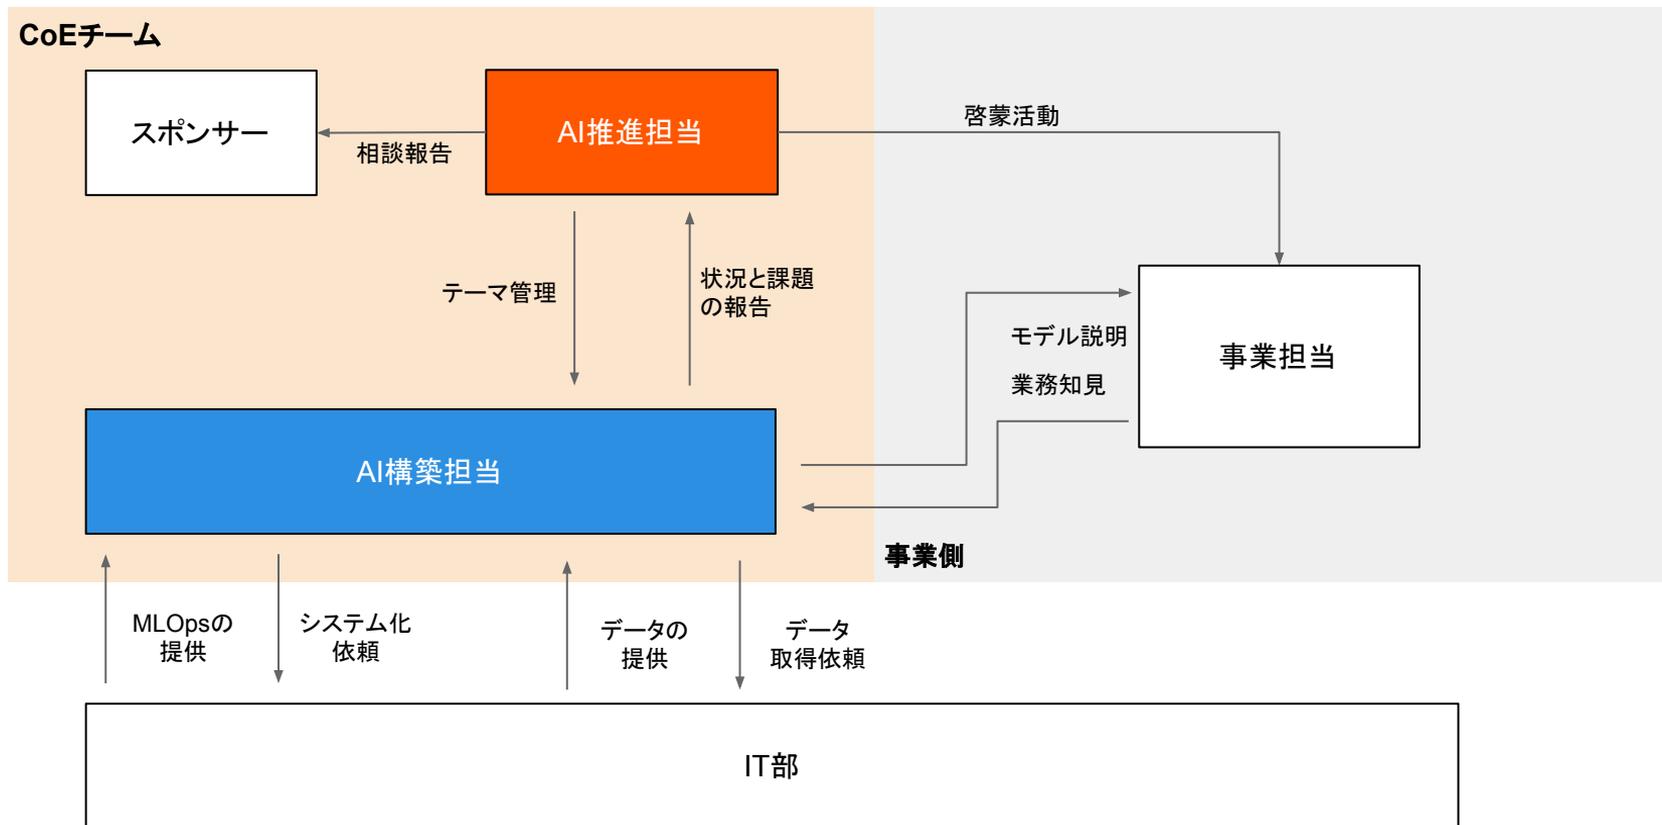
AIの専門家が少ない
単純なリソース不足

求められるハードルに
対してのギャップが巨大

一般的なAIプロジェクトの推進体制

市民データサイエンティスト

データサイエンティスト

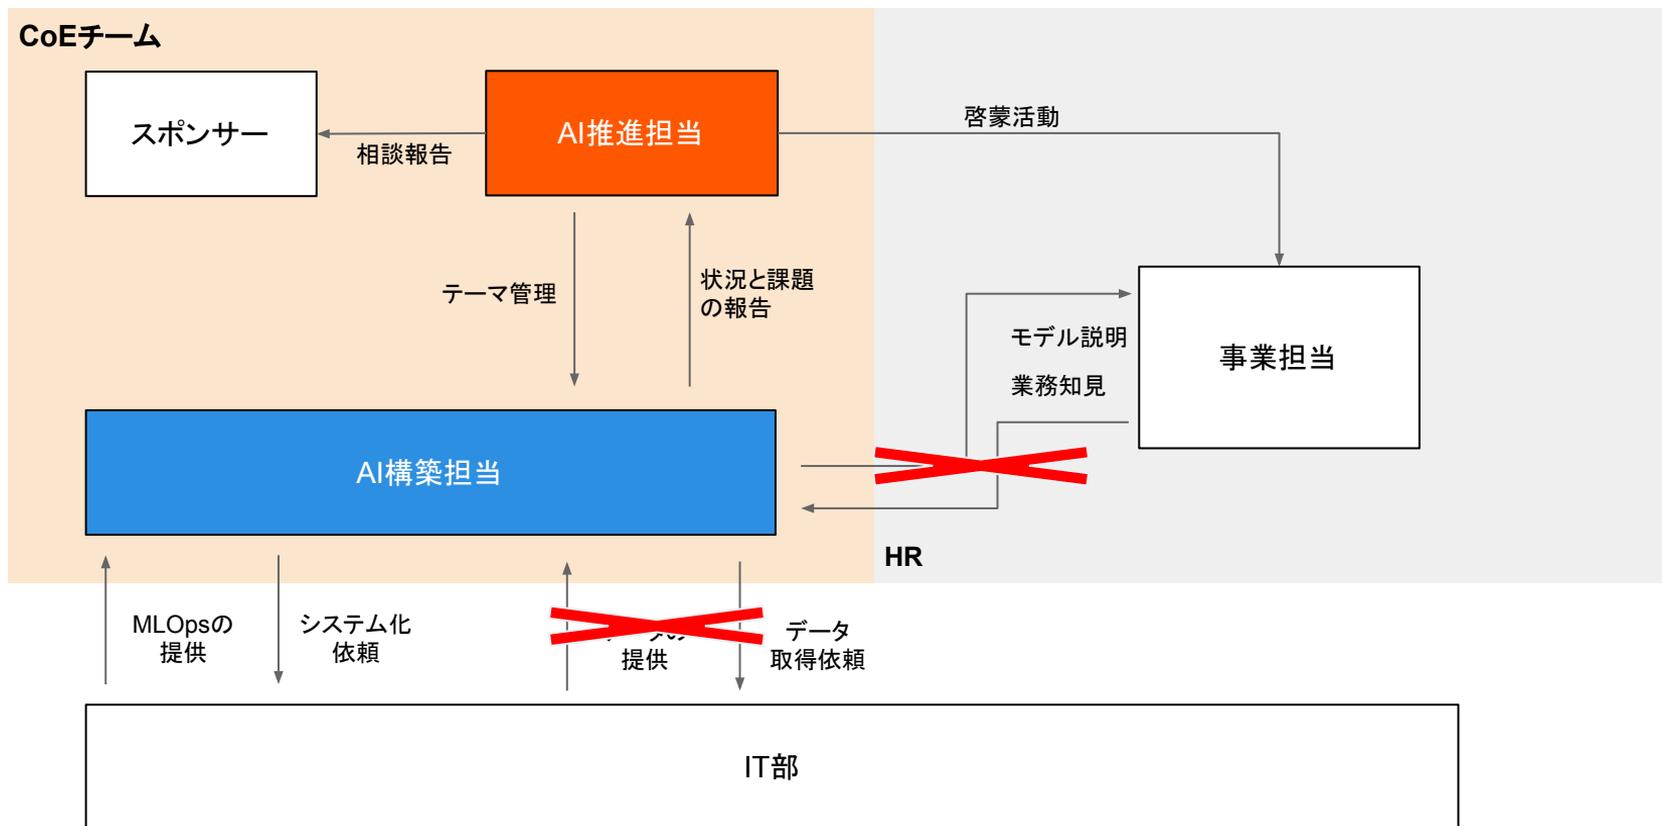


秘匿性の影響による体制の制約

市民データサイエンティスト



データサイエンティスト

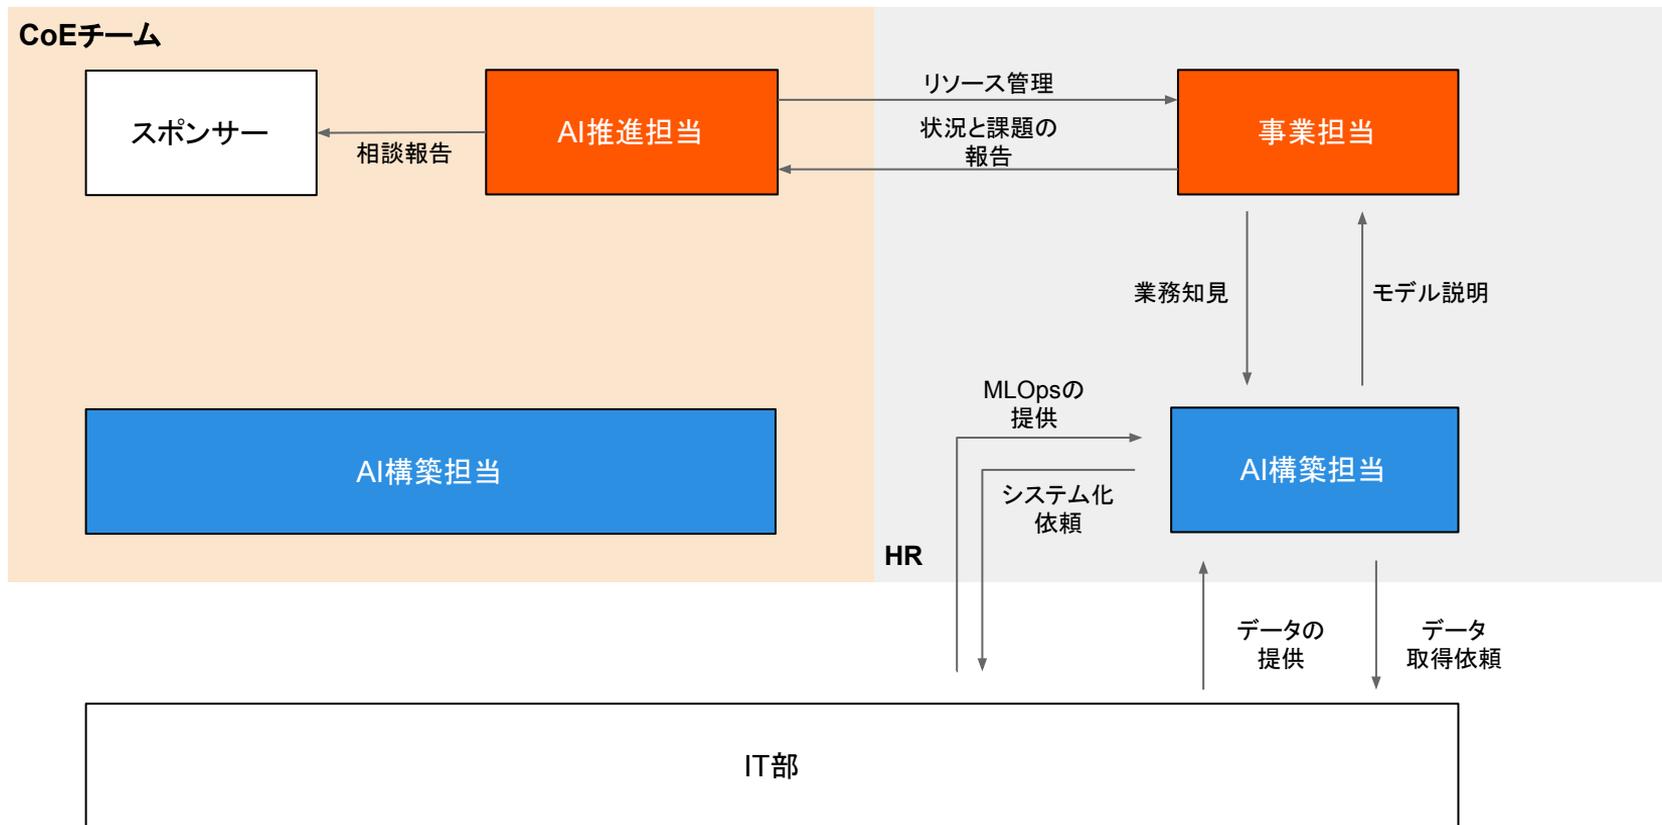


HRチーム内で構築を完結する必要がある

市民データサイエンティスト



データサイエンティスト



機械学習の今の状況



機械学習研究



テーブルデータへの精度向上の頭打ち
動画や音声などの領域へ

AutoMLというものの位置付け

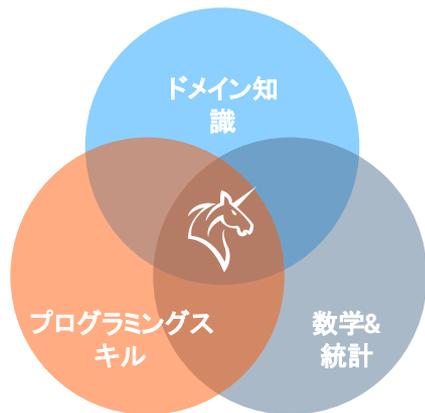


誰でも簡単に高精度なモデルを作成
よりシンプルに早く簡単に

AutoMLの登場によってAI内製化のハードルが下がった

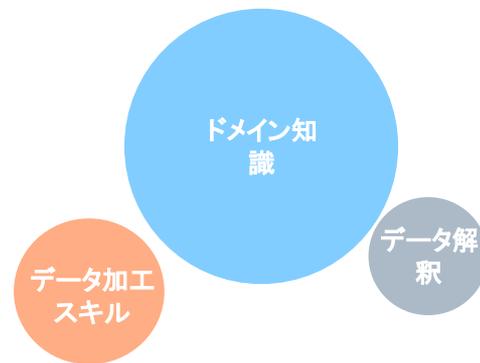


これまでのデータサイエンティスト



求められる全ての要件を一定のレベルで持つ必要があった
特に数学とプログラミングと取得難易度(5~10年程度)の高いスキル二つを求められるのが厳しかった

AutoMLありのデータサイエンティスト



求められる業務知識のレベルは変わらないが、プログラミングや数学に求められたスキルは最低限のデータ加工と解釈能力(1~2年)に置き換わった



AIガバナンス・ガイドラインへの期待

HRテーマにおける全体デザインの重要性

HRテーマにおける全体デザインの重要性:採用AI



自動採用パターンは良い候補者を見逃す傾向が強いため、
足切り用途で使う採用AIのほうがダイバーシティーを目指す企業にとっては望ましい

候補者ID	順位	結果	Best of the Best	Worst of the Worst
41	1	合格	正例	正例
32	2	合格	正例	正例
39	3	合格	正例	正例
15	4	補欠	不例	正例
28	5	補欠	不例	正例
21	6	補欠	不例	正例
42	7	補欠	不例	正例
38	8	不合格	不例	不例
31	9	不合格	不例	不例
48	10	不合格	不例	不例

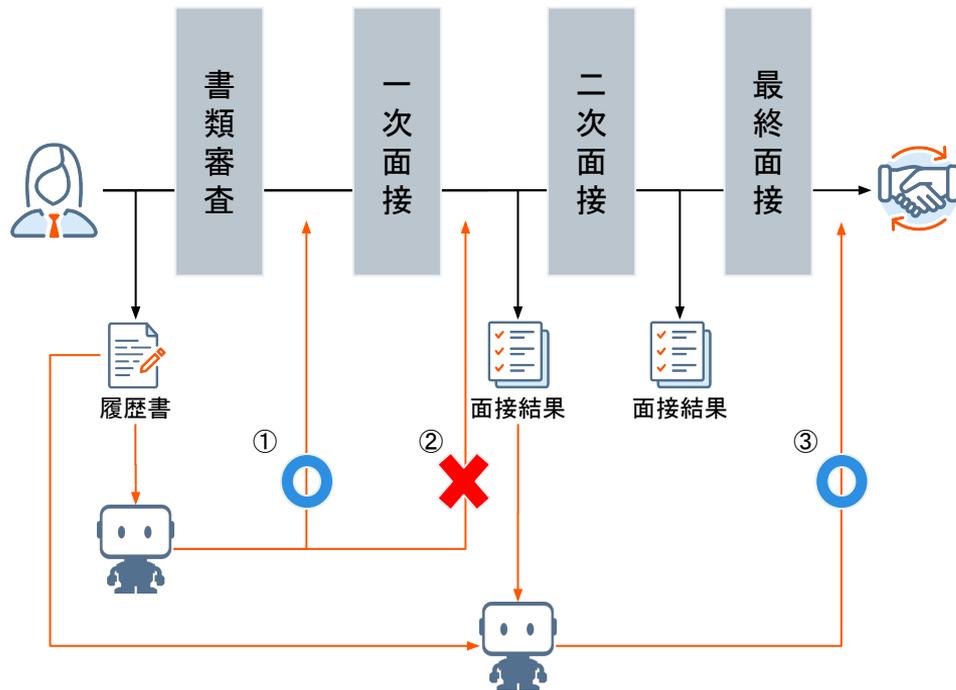
Best of the Best: 最高のプレイヤーを学習

最高のプレイヤーを正例と学習する。
予測を適用する場合には、最高のプレイヤーから
もっとも遠い存在を足切りする

Worst of the Worst: 最低のプレイヤーを学習

最低のプレイヤーのみを不例として学習する。
予測を適用する場合には、最低のプレイヤーとと
ても近い存在のみを足切りする

HRテーマにおける全体デザインの重要性:採用AI



①履歴書データ:書類審査通過予測 AI

実現可能。一般的に人が行っている書類審査を同じデータから判断をAIに置き換えるだけ

②履歴書データ:面接通過予測 AI

実現不可能。基本的に書類審査を履歴書から行っており、そこで判断できない内容を面接で聞いているため、面接通過予測をこのデータでは行うことができない

③履歴書+面接データ:最終面接通過予測 AI

実現可能。複数回の面接の内容と求められるものが面接ごとに似通っているという条件が必要だが、フェーズで必要なデータが揃っている

まとめ



- 人事領域におけるAI活用はまだ他の業種に比べてバラエティは少ない
- 人事領域の抱える構造的な課題がAI適用のブレーキとなっている
- 人事領域に限らず、特定の業務領域ごとにAI活用のチェックポイントは異なるため、汎用的なアプローチだけでなく、業界・業務に特化したアプローチを抑える必要がある



誰でも運転できる車(AI)はできたので、交通ルールが重要なフェーズ
AIガバナンス・ガイドラインの業界・業務特化版への期待

DataRobot