

機械学習の価値を 計算する

ML Enablement Series: Business Understanding

AWS Black Belt Online Seminar

久保 隆宏

Developer Relation Machine Learning

尾原 颯

Solutions Architect

Technical Support: 呉 和仁

Machine Learning Specialist Solutions Architect



本動画のゴール

- プロダクトにおける機械学習の価値を計算式で示せるようになる
- プロダクトマネージャーらと会話し価値の方向性を定められるようになる

本動画のゴール

- プロダクトにおける機械学習の価値を計算式で示せるようになる。
- プロダクトマネージャーらと会話し価値の方向性を定められるようになる。

ML Enablement Seriesの特徴

ML Enablement Series のゴール

データサイエンティストを含むプロダクト開発チームが、
機械学習モデルの開発において
足りないスキルを補い合い
顧客に価値を届けられるようになること

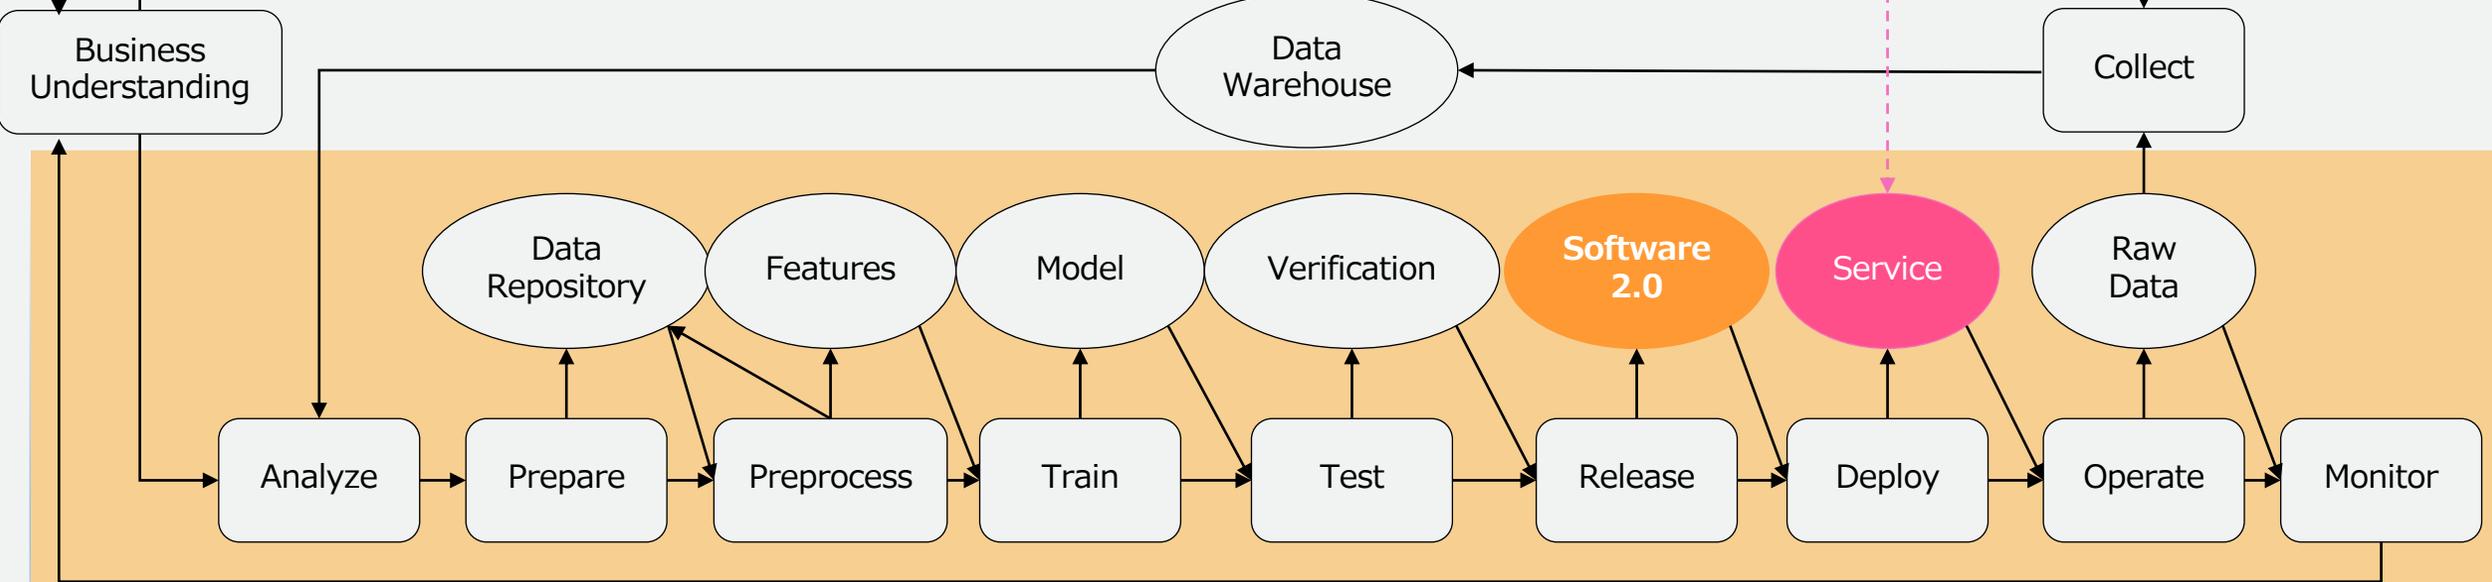
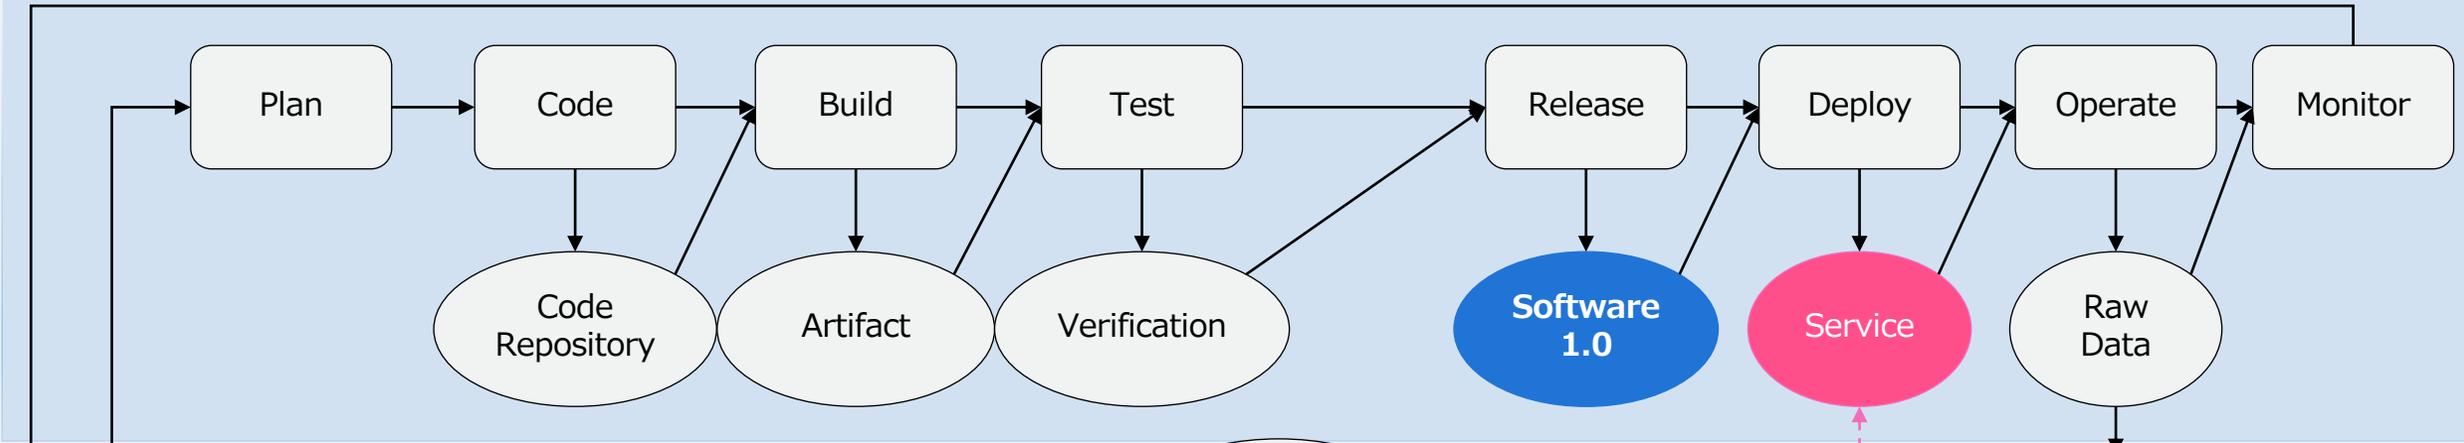
ML Enablement Series のゴール

データサイエンティストを含むプロダクト開発チームが、
機械学習モデルの開発において
足りないスキルを補い合い
顧客に価値を届けられるようになること

チームでの
コミュニケーションが
不可欠

機械学習モデルを活用するプロダクトでは、 DevOpsチームとMLOpsチームが連携する必要がある。

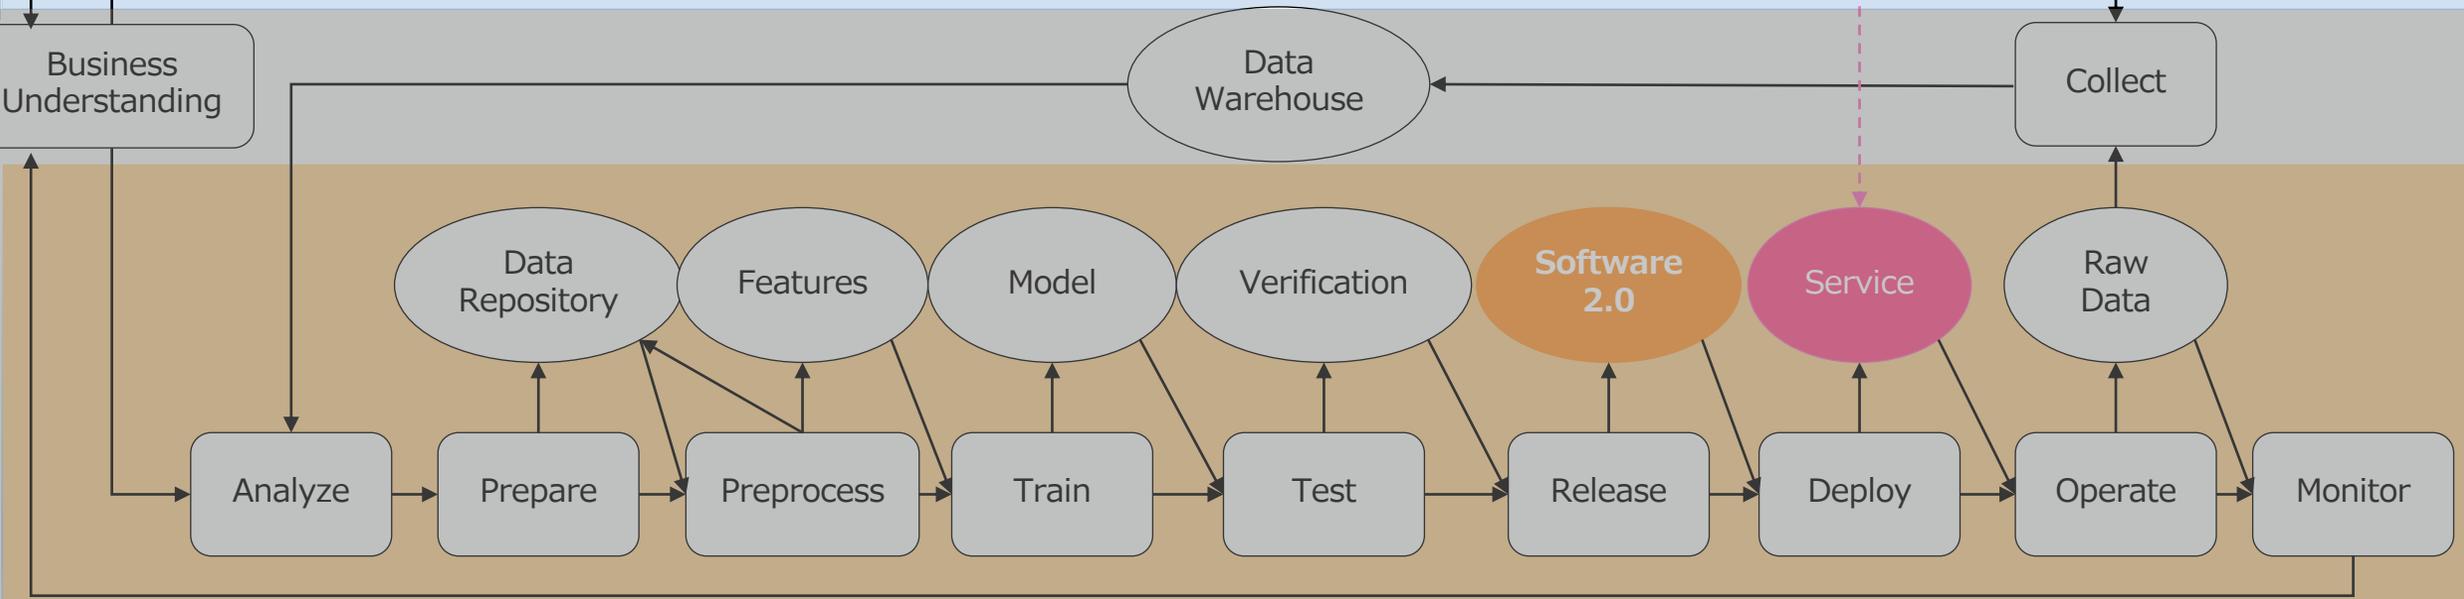
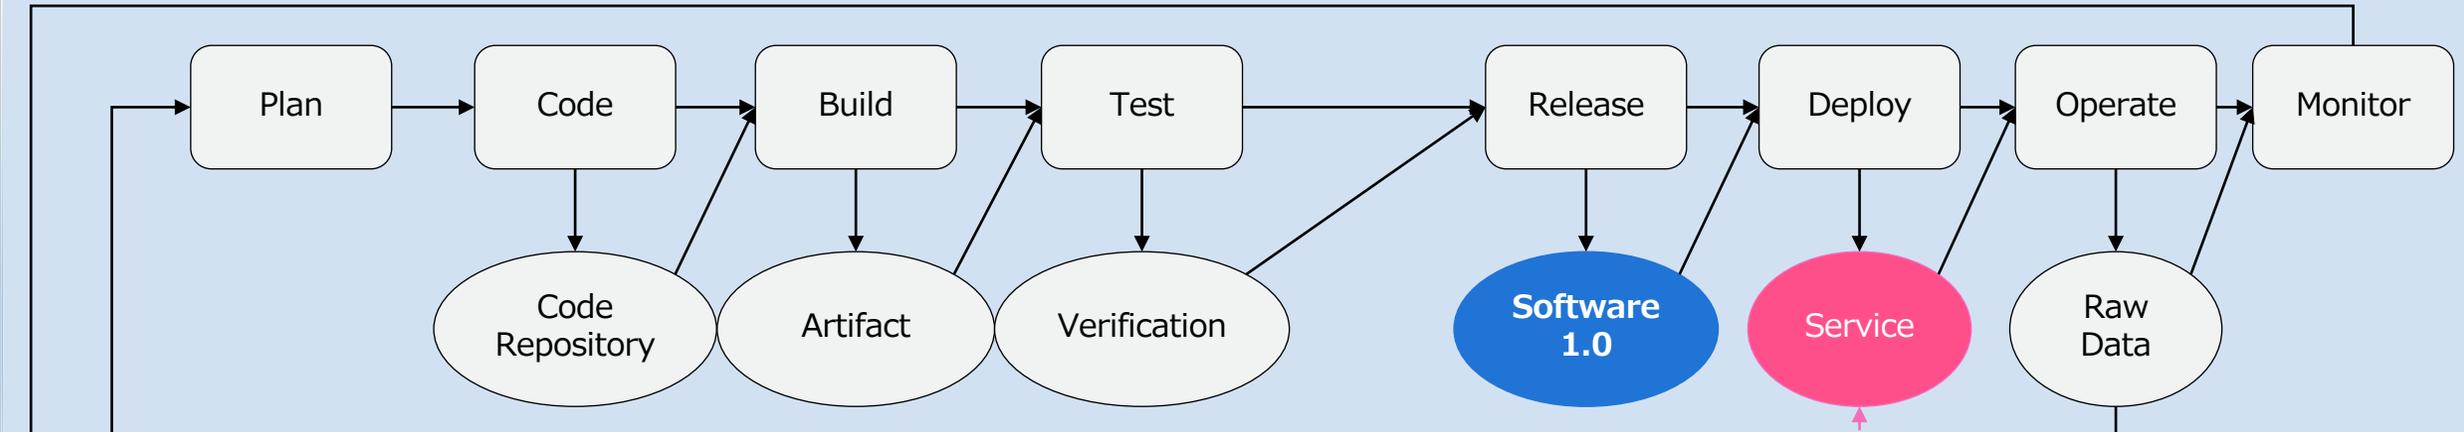
DevOps



MLOps

機械学習モデルを活用するプロダクトでは、
DevOpsチームとMLOpsチームが連携する必要がある。

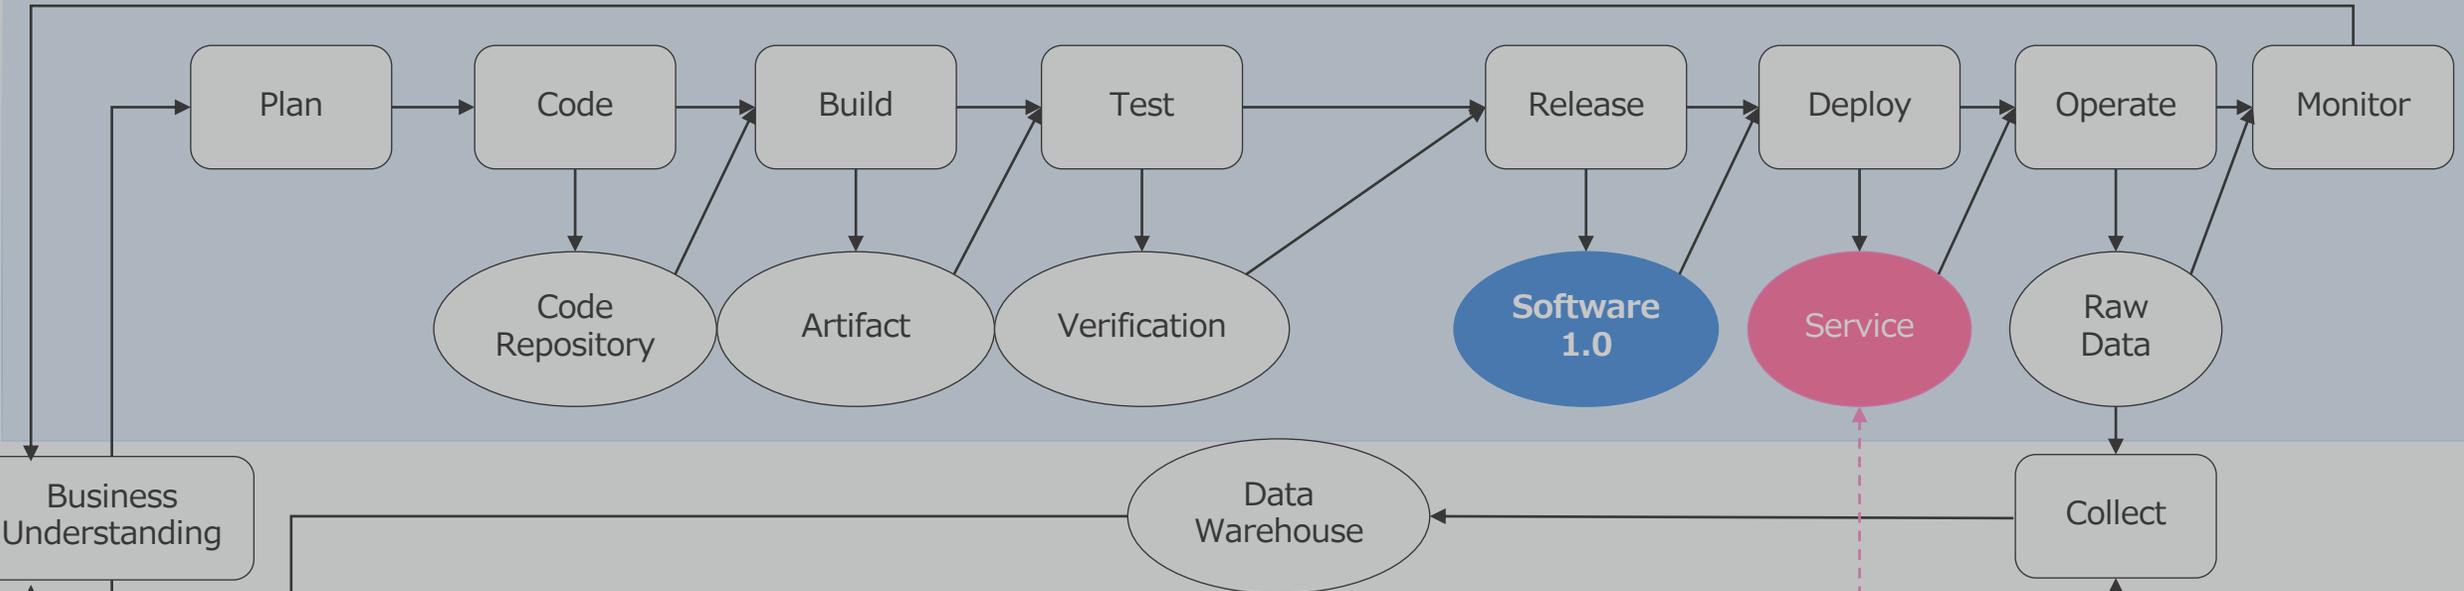
DevOps



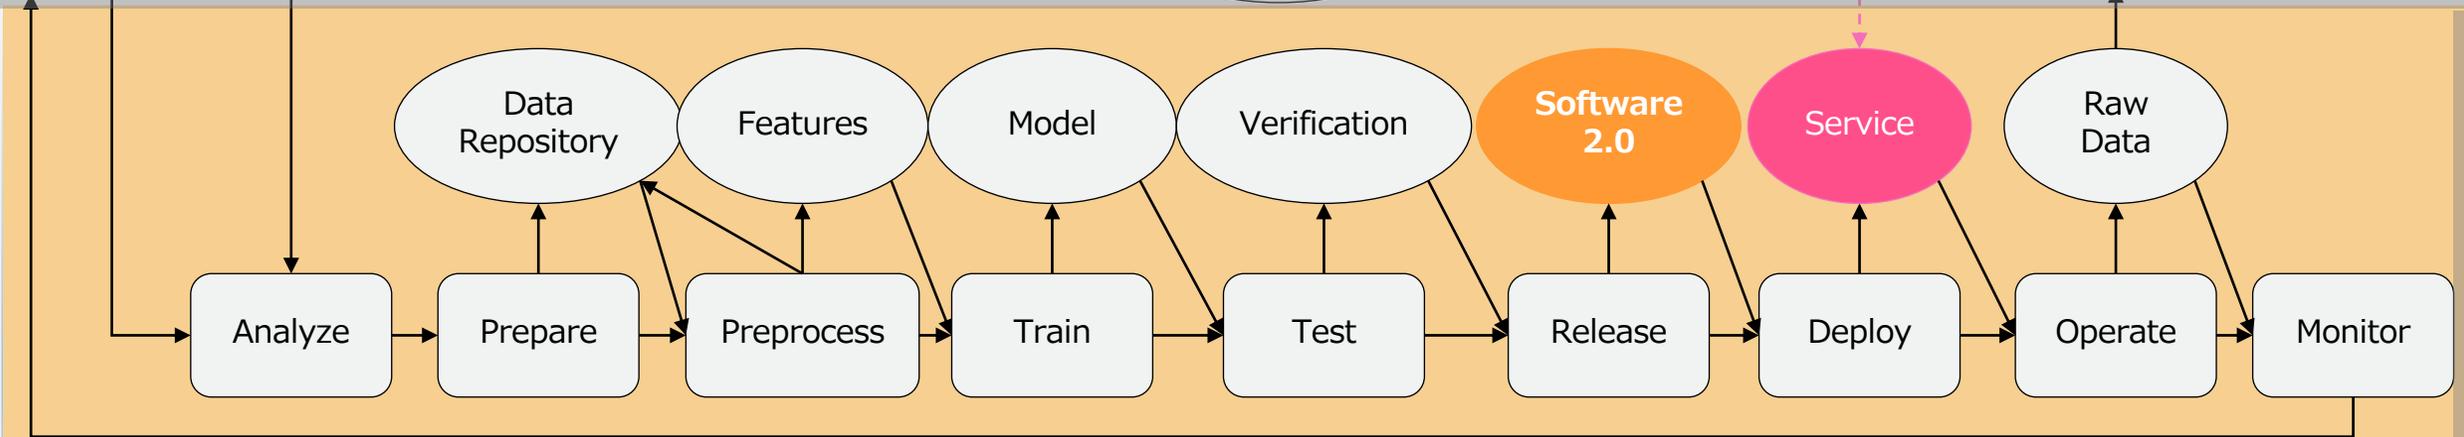
MLOps

機械学習モデルを活用するプロダクトでは、
DevOpsチームとMLOpsチームが連携する必要がある。

DevOps

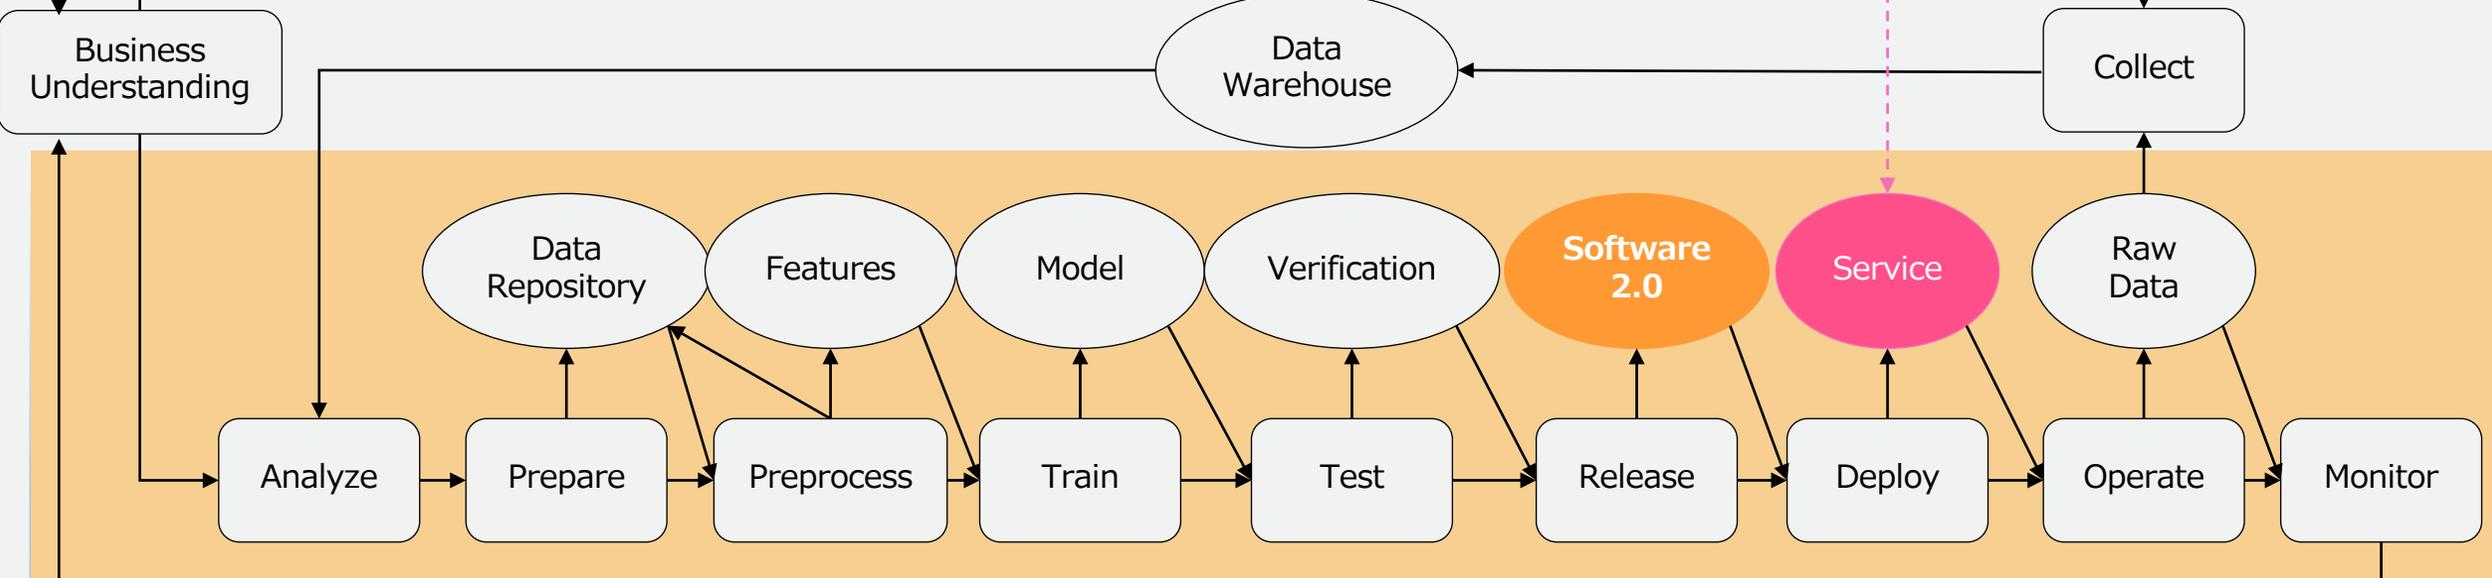
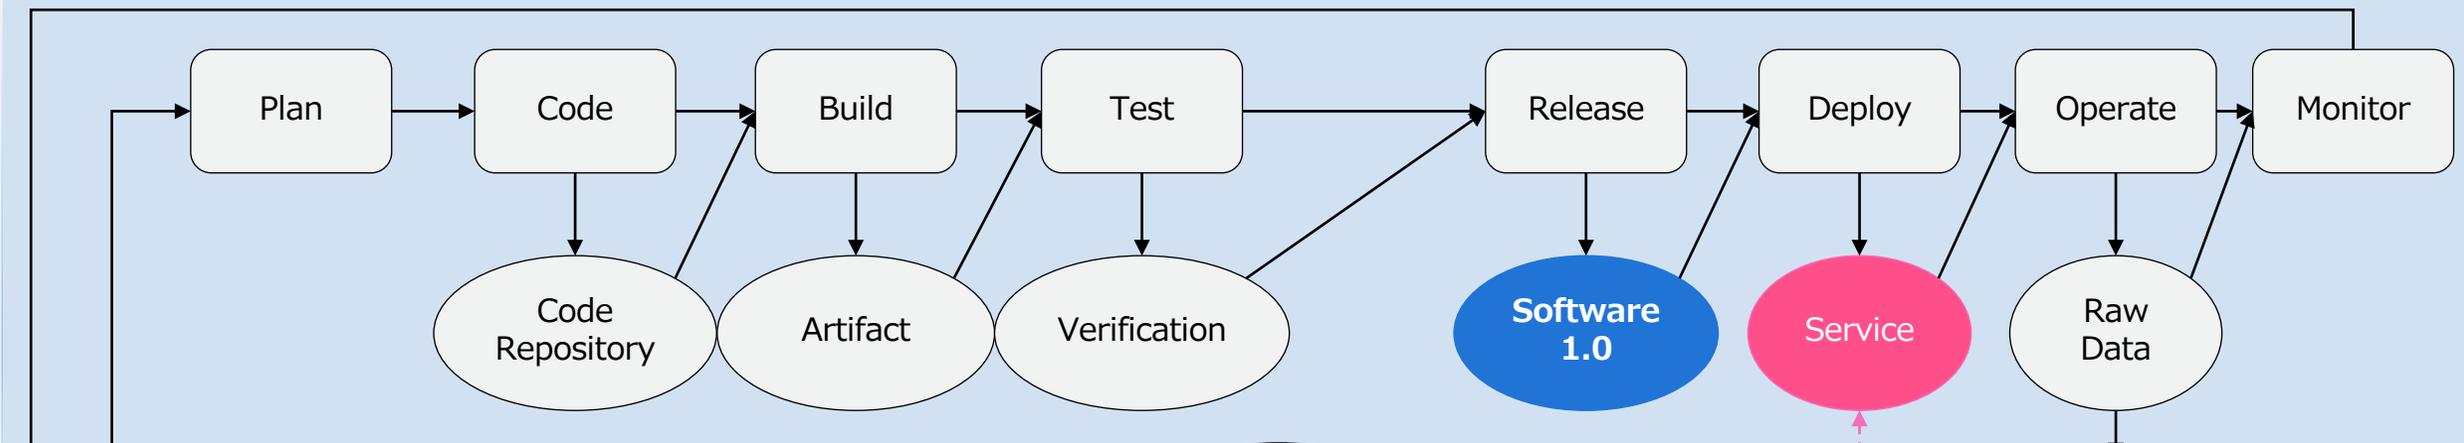


MLOps



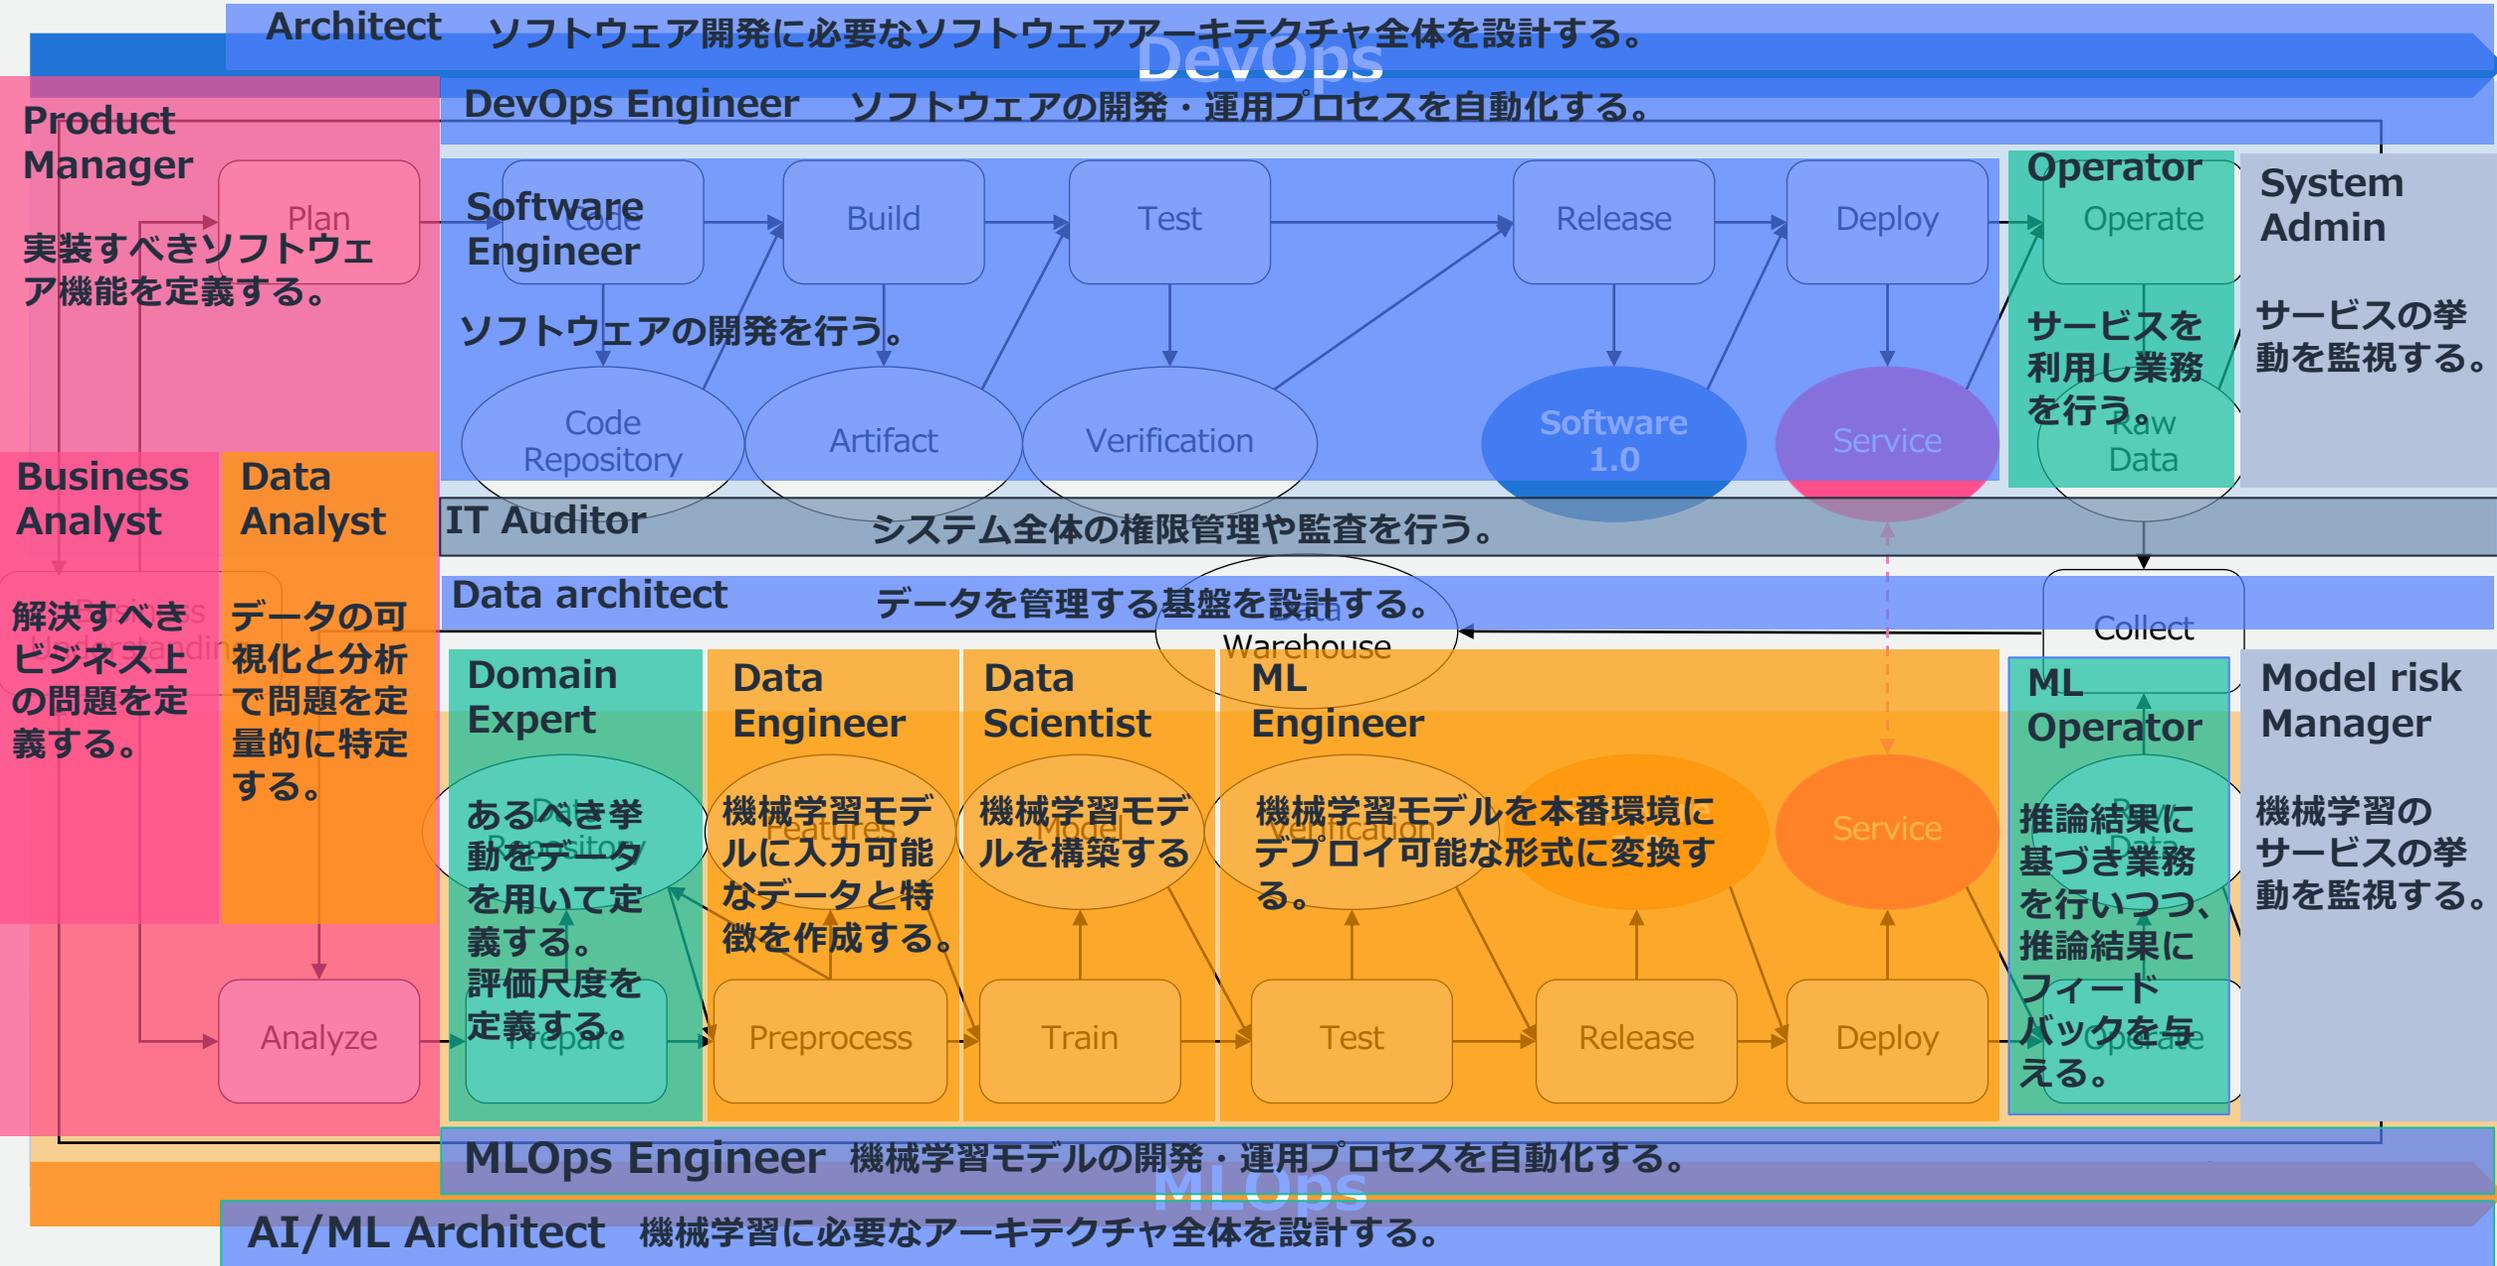
機械学習モデルを活用するプロダクトでは、
DevOpsチームとMLOpsチームが連携する必要がある。

DevOps



MLOps

プロダクトのリリースまでには多くのロールが関わる。



プロダクトのリリースまでには多くのロールが関わる。

Architect ソフトウェア開発に必要なソフトウェアアーキテクチャ全体を設計する。

DevOps Engineer ソフトウェアの開発・運用プロセスを自動化する。

Product Manager

実装すべきソフトウェア機能を定義する。

Plan

Software Engineer

Build

Test

Release

Deploy

Operator
Operate

System Admin

サービスの挙動を監視する。

Business Analyst

解決すべきビジネス上の問題を定義する。

Analyze

定義する。
評価尺度を定義する。
Prepare

特徴を作成する。

Preprocess

Train

Test

Release

Deploy

推論結果にフィードバックを与える。
Operate

Model risk Manager

機械学習のサービスの挙動を監視する。

MLOps Engineer 機械学習モデルの開発・運用プロセスを自動化する。

AI/ML Architect 機械学習に必要なアーキテクチャ全体を設計する。

さまざまなロール間で
密なコミュニケーションを
取ることが重要

ML Enablement Series の解説の流れと役立つポイント

1. What : なにをするのか?

2. Why : なぜやるのか?

3. How : どうやるのか?

3.1 プログラミング演習

3.2 コミュニケーション演習



チームでの認識合わせに役立つ



具体的な開発方法を学ぶのに役立つ

会議体などを設計するのに役立つ

ML Enablement Series の解説の流れと役立つポイント

1. What : なにをするのか?

2. Why : なぜやるのか?

3. How : どうやるのか?



チームでの認識合わせに役立つ

3.1 プログラミング演習



具体的な開発方法を学ぶのに役立つ

3.2 コミュニケーション演習



会議体などを設計するのに役立つ

機械学習モデルを実装する方法に興味がある方 ⇒ 3.1

ML Enablement Series の解説の流れと役立つポイント

1. What : なにをするのか?

2. Why : なぜやるのか?

3. How : どうやるのか?

3.1 プログラミング演習

3.2 コミュニケーション演習



チームでの認識合わせに役立つ



具体的な開発方法を学ぶのに役立つ



会議体などを設計するのに役立つ

機械学習モデルを実装する方法に興味がある方 ⇒ 3.1

開発プロジェクトのマネジメントに興味がある方 ⇒ 1, 2, 3.2

ML Enablement Series の解説の流れと役立つポイント

1. What : なにをするのか?

2. Why : なぜやるのか?

3. How : どうやるのか?

3.1 プログラミング演習

3.2 コミュニケーション演習



チームでの認識合わせに役立つ



具体的な開発方法を学ぶのに役立つ

会議体などを設計するのに役立つ

機械学習モデルを実装する方法に興味がある方 ⇒ 3.1

開発プロジェクトのマネジメントに興味がある方 ⇒ 1, 2, 3.2

ML Enablement Series の解説の流れと役立つポイント

1. What : なにをするのか?

2. Why : なぜやるのか?

3. How : どうやるのか?

3.1 プログラミング演習

3.2 コミュニケーション演習



チームでの認識合わせに役立つ



具体的な開発方法を学ぶのに役立つ

会議体などを設計するのに役立つ

機械学習モデルを実装する方法について

今回の動画については全て見ていただきたい！！

1, 2, 3.2

機械学習の価値を計算する方法を解説

- プログラミング演習 (※実際のプログラムはしません)

機械学習プロジェクト例 3 つについて計算式を作る演習

- コミュニケーション演習

価値計算の方向性を決めるために行うべき

コミュニケーションの演習

Analyze

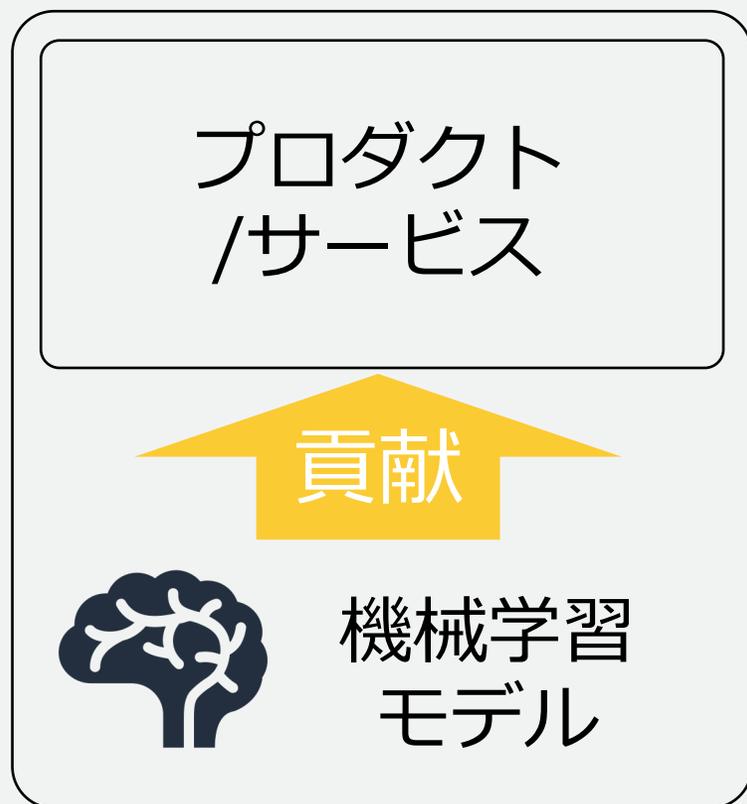
Plan

Business Understanding

What: なにをするのか?

Business Understanding のゴール

プロダクトの顧客が理解できる言葉で
機械学習後の価値を定義する

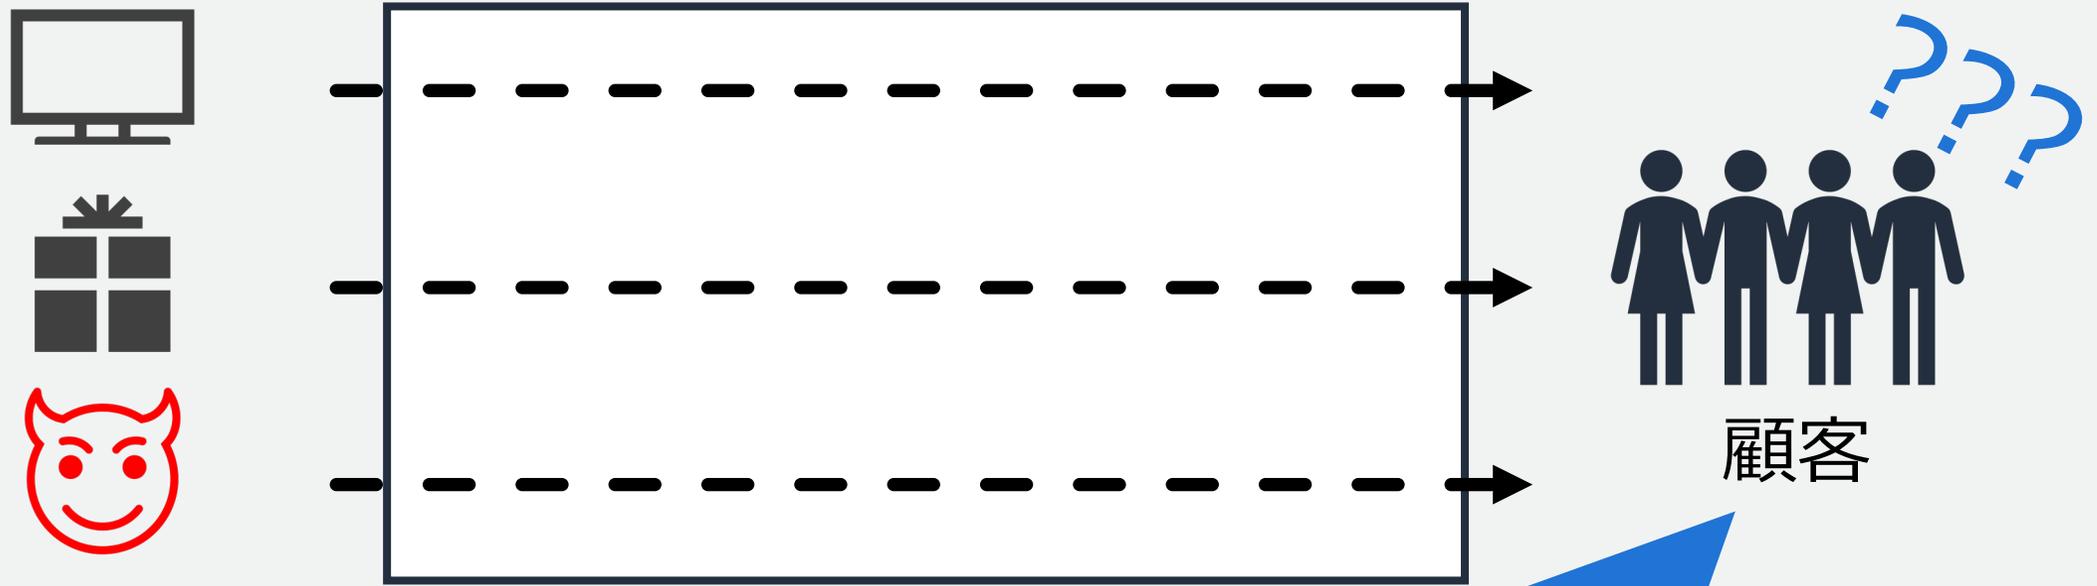


Business Understanding のゴール

Point!

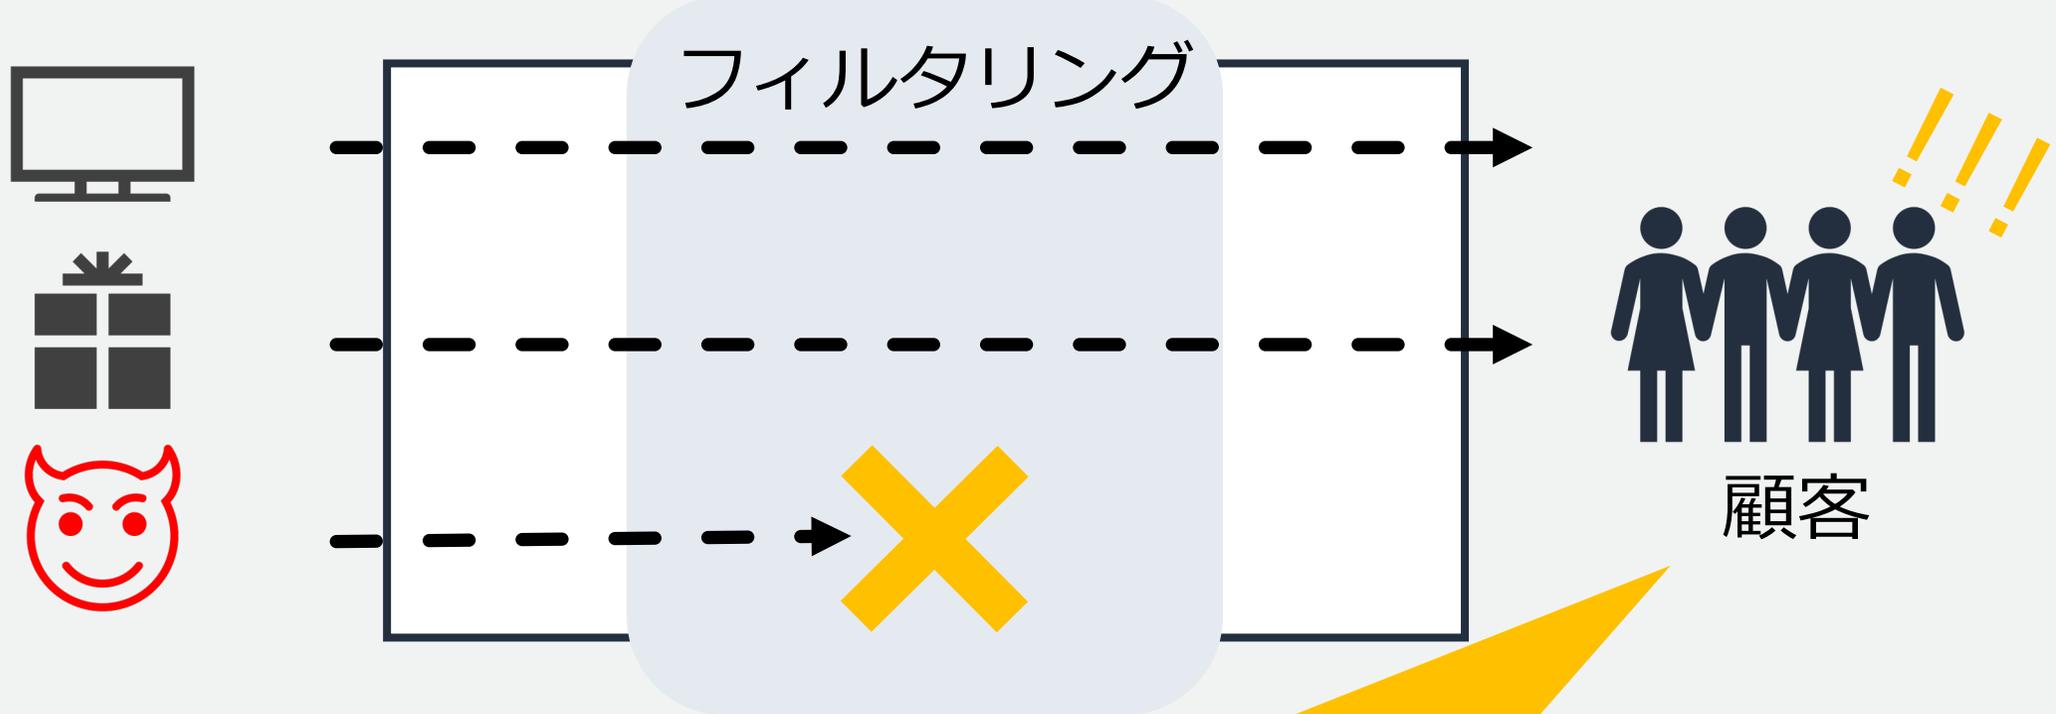
- 顧客に提供する価値にフォーカス
- 機械学習などの実現手段にこだわらない

例: フリーマーケットのサービスで価値を定義する



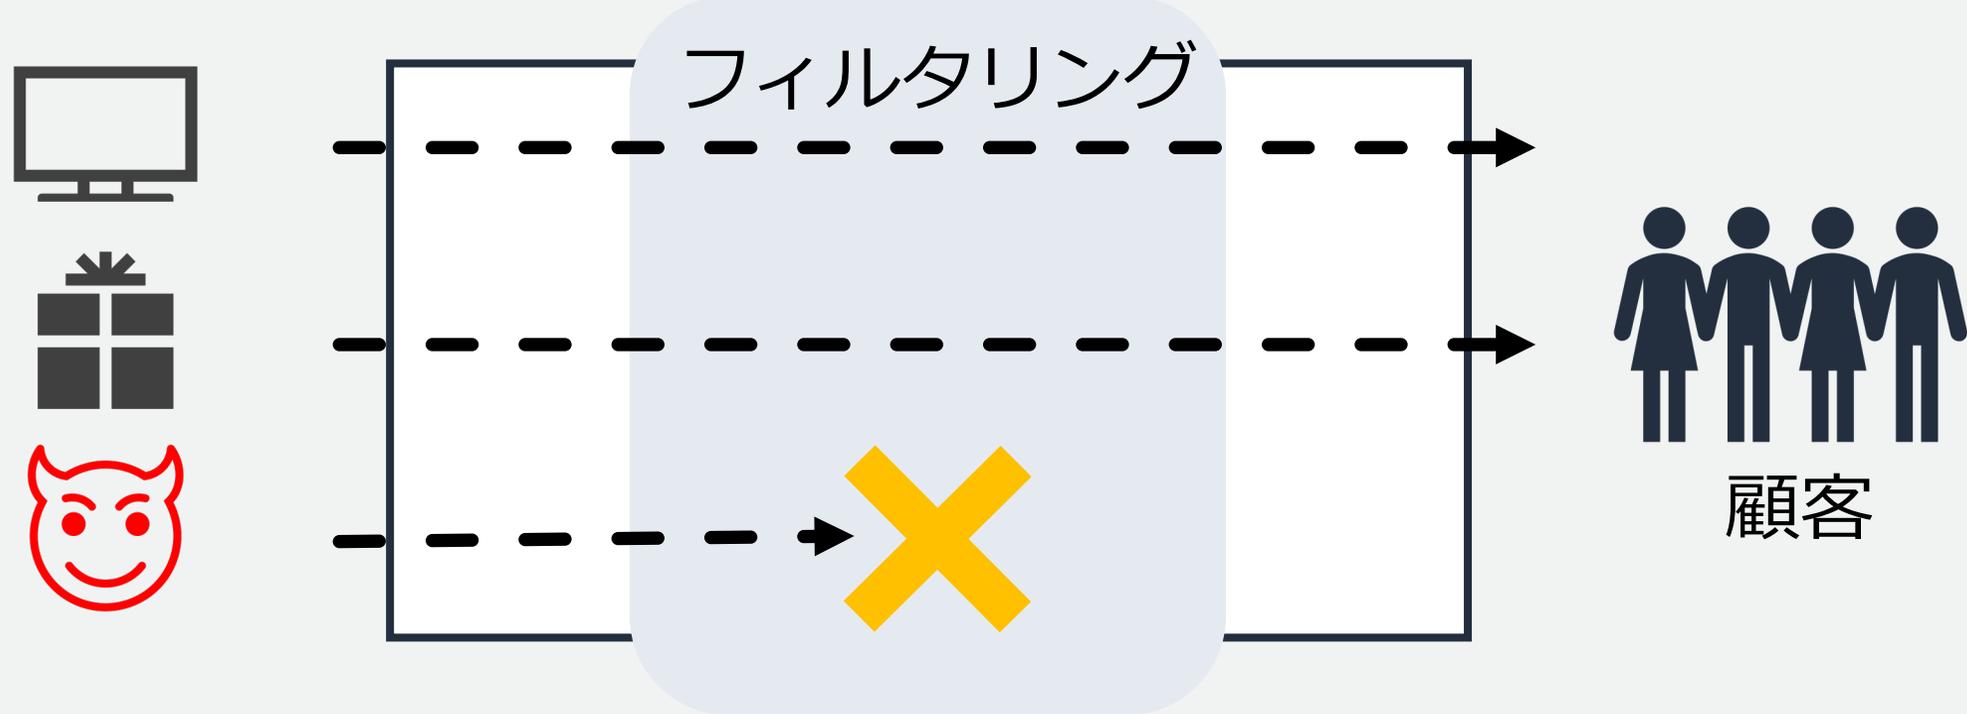
どれが正規品か分からず、
なかなか購入に踏み切れない。。

例：フリーマーケットのサービスで価値を定義する



非正規品を誤って
購入せずにする！！

例: フリーマーケットのサービスで価値を定義する



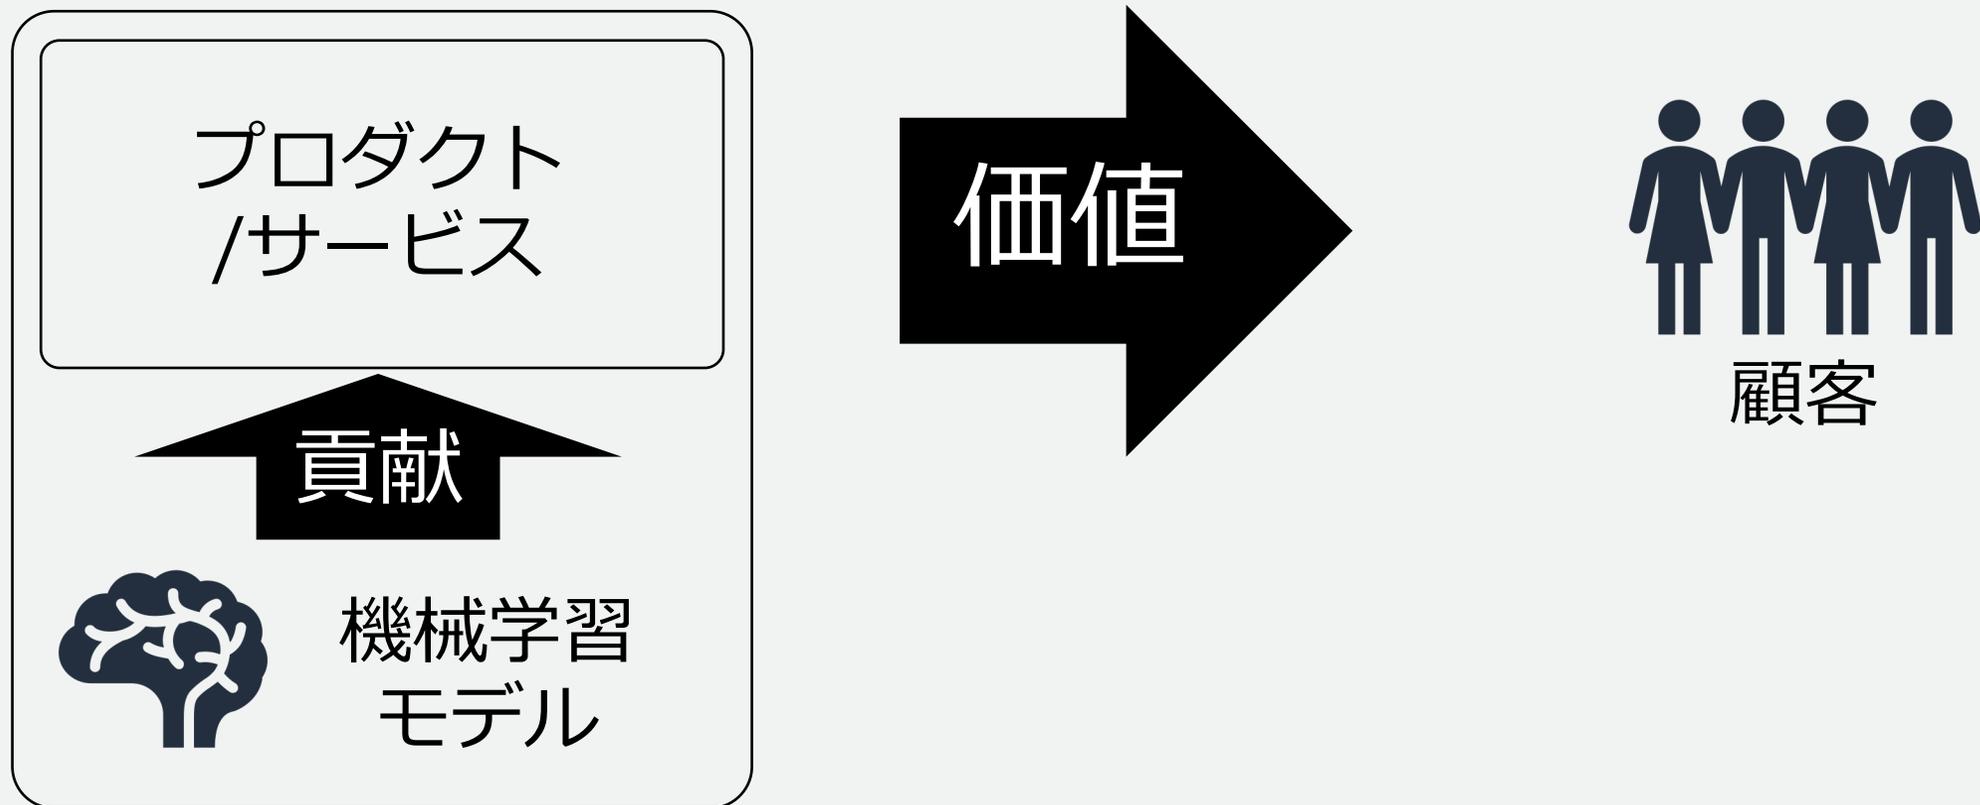
- ①顧客にとっては正規品の表示が価値
- ②実現は手動でもできる

Business Understanding で最も重要な成果物

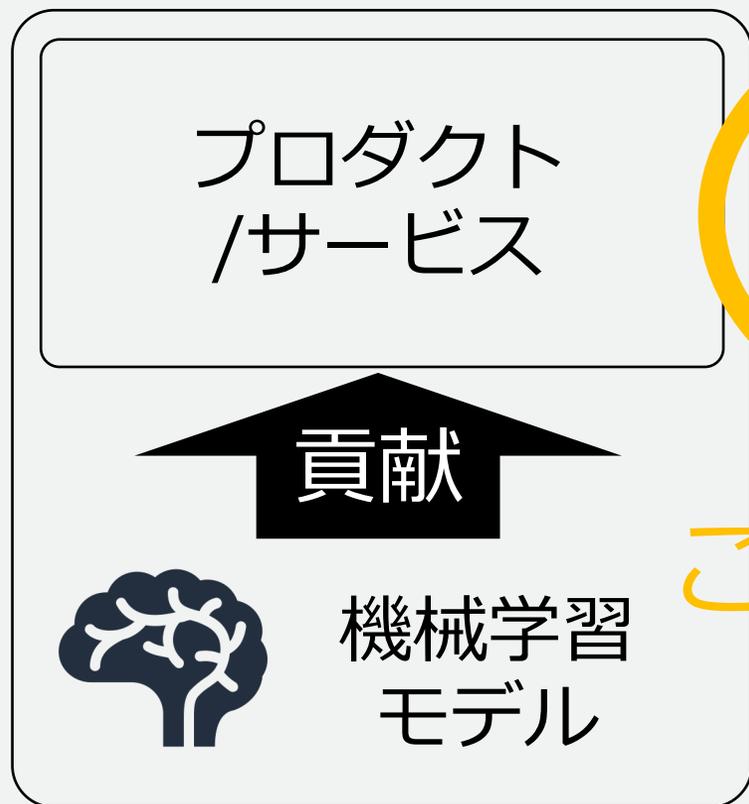
「プロダクトの顧客」にとっての
機械学習後の価値を表した文

機械学習の価値を計算する式

「プロダクトの顧客」にとっての 機械学習後の価値を表した文



「プロダクトの顧客」にとっての 機械学習後の価値を表した文



顧客

この部分を明文化！！

例：フリーマーケットのサービスの場合

商品の購入者が、
すべての商品カテゴリで非正規品が
取り除かれた状態で
正規品のみを閲覧できる

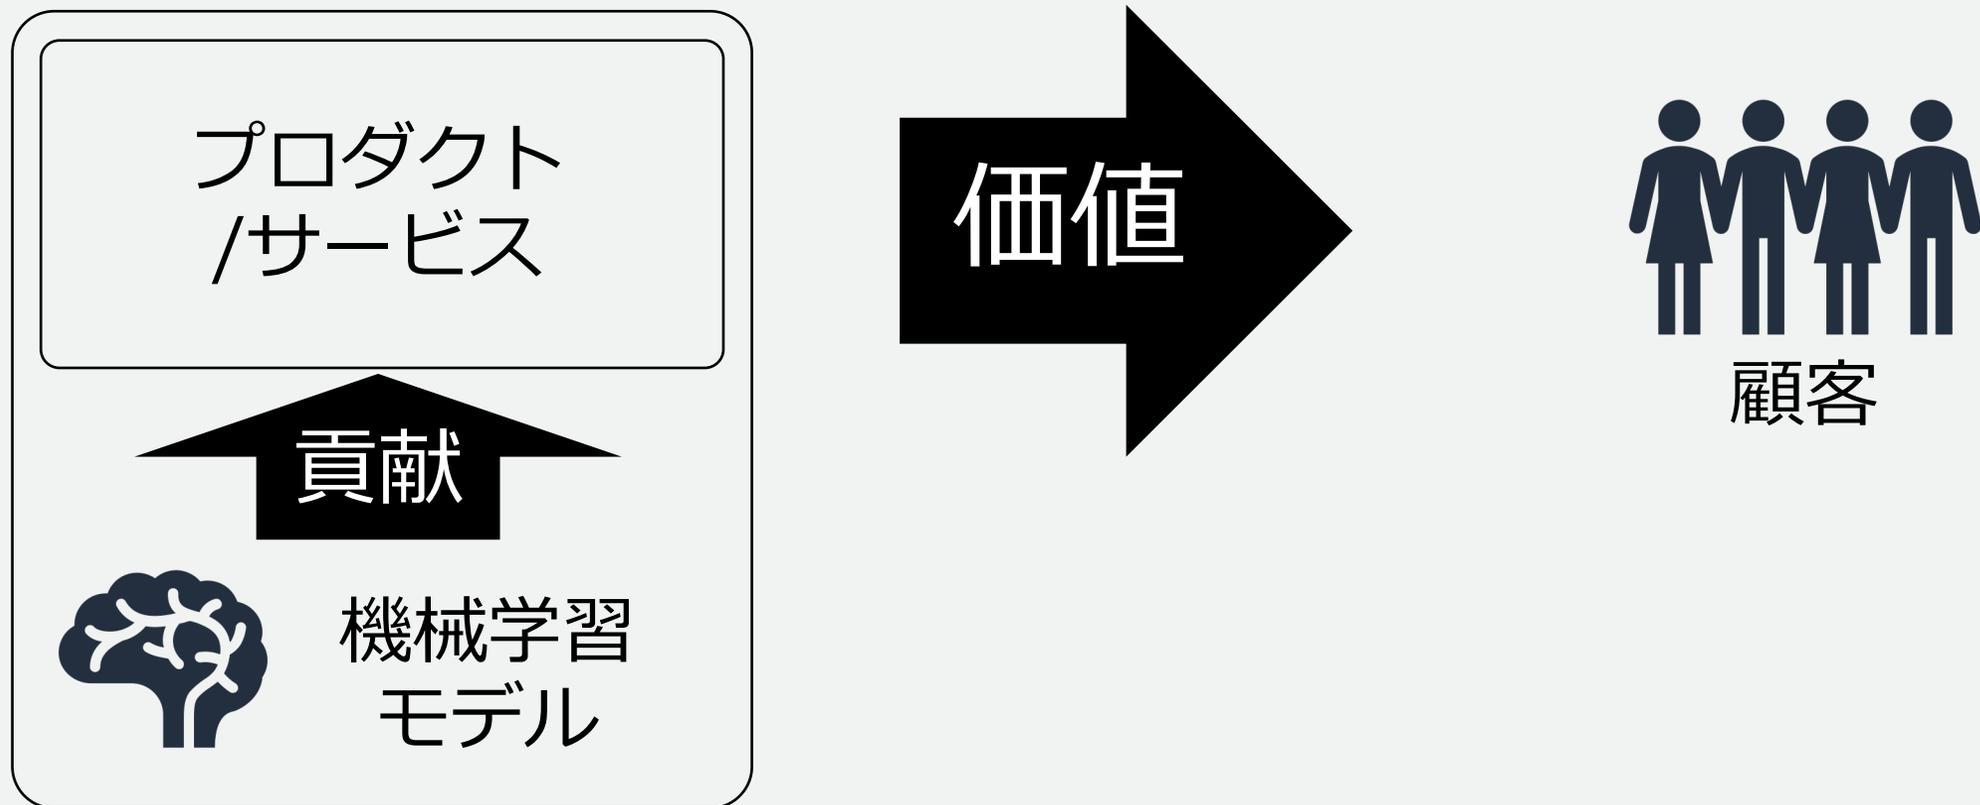
例: フリーマーケットのサービスの場合

商品の購入者が、
すべての商品カテゴリで非正規品が
取り除かれた状態で
正規品のみを閲覧できる

ユーザーへリリースする時の文面を意識

- 機械学習を導入する前と後の**ユーザー体験の差**にフォーカス
- 価値の実現方法が**機械学習でなくても成立**するように

機械学習の価値を計算する式

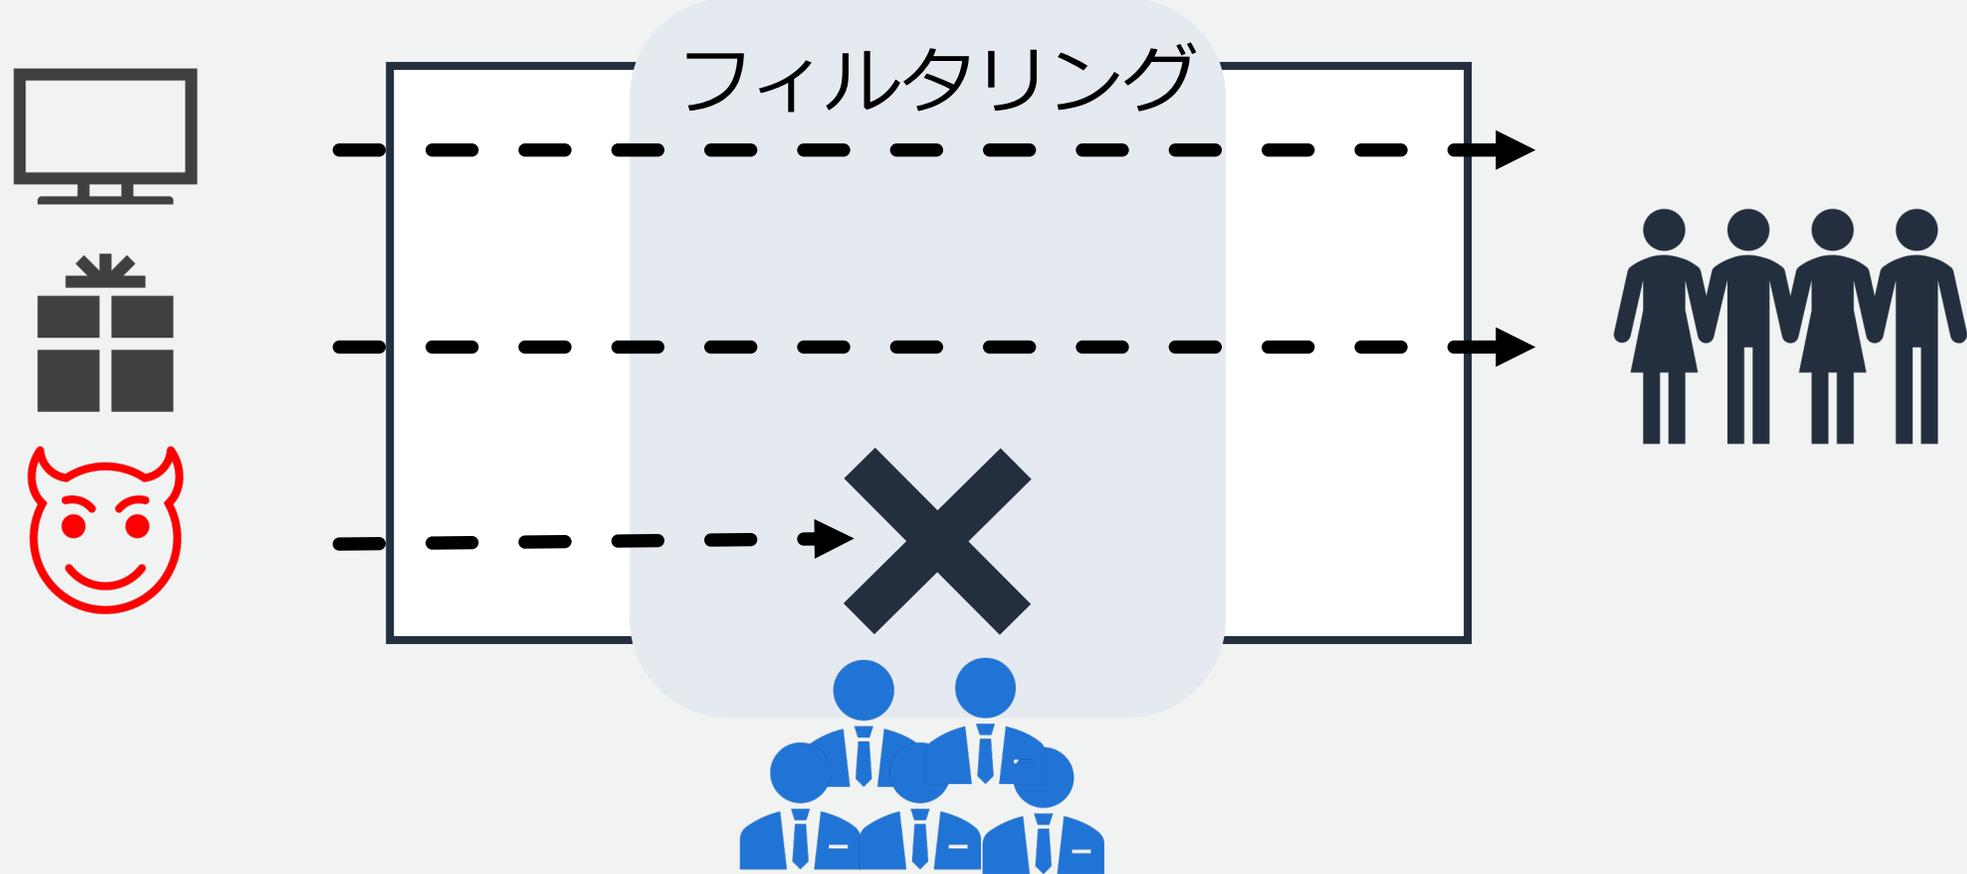


機械学習の価値を計算する式



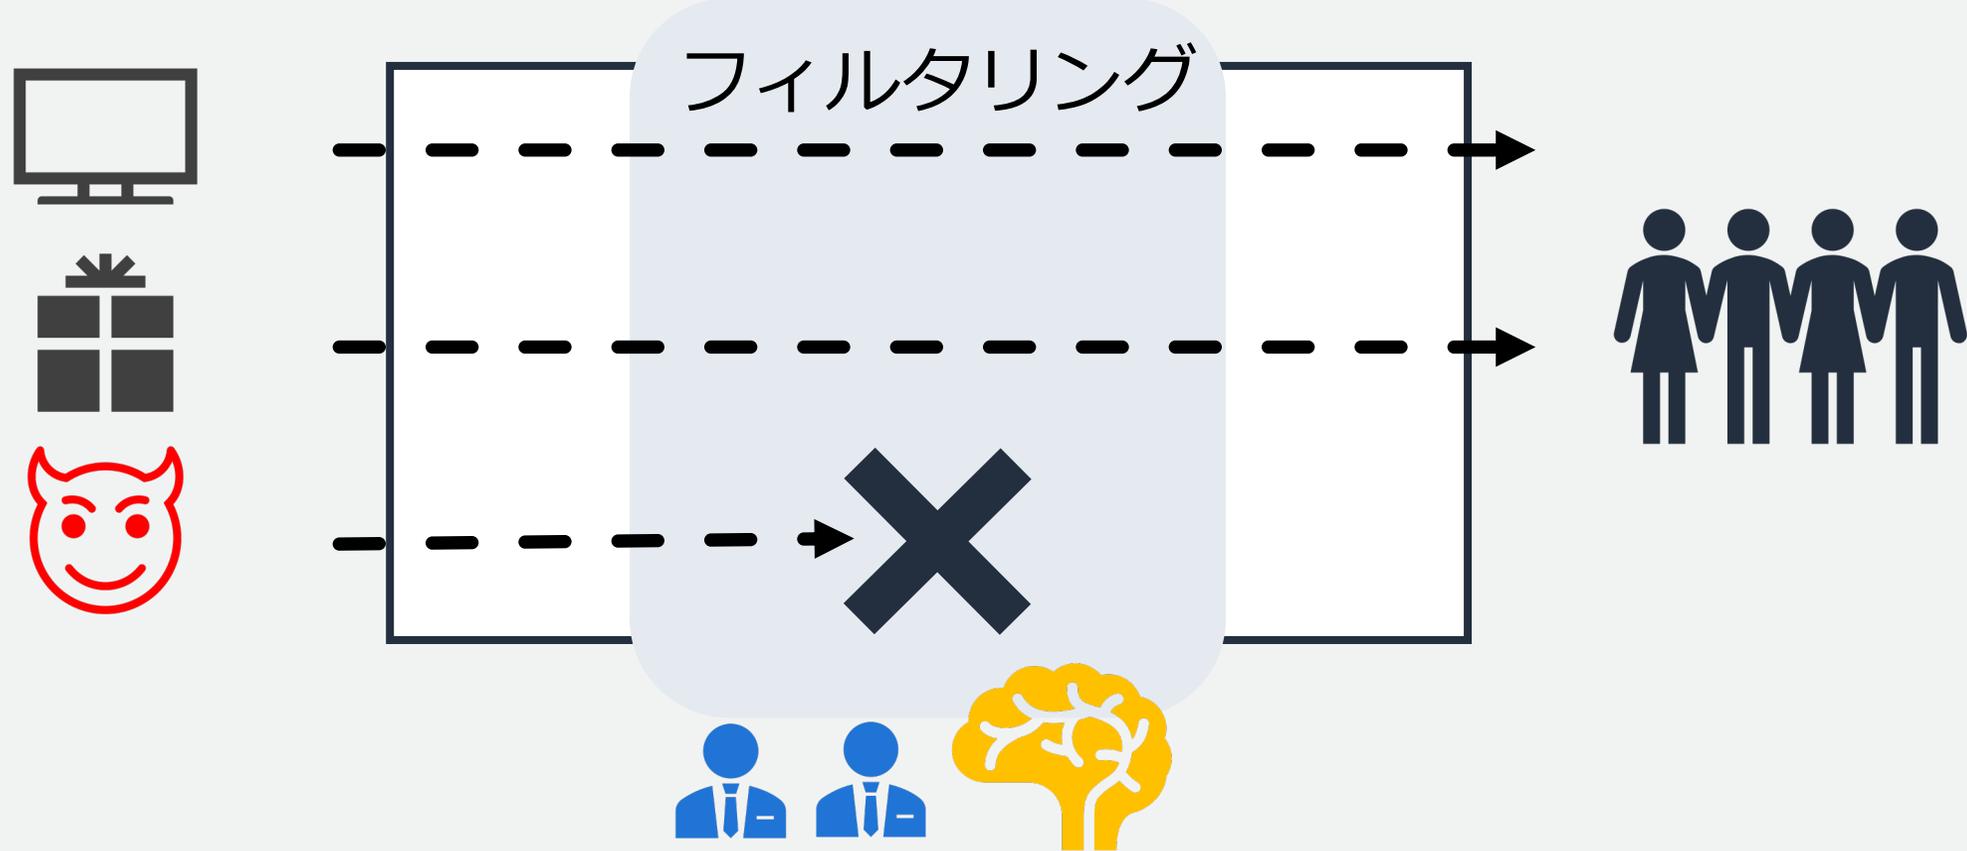
この部分を式で表現！！

例：フリーマーケットのサービスの場合



全て手動だと 20 人必要。
2 人で行えるようにしたい。

例：フリーマーケットのサービスの場合



機械学習を活用することで 2 人での
チェックが実現できるか？

例: フリーマーケットのサービスの場合

(チェックに必要な人数 - 機械学習を導入した場合に必要な人数)

X

1日のチェック時間 (h/日)

X

時給 (円/h)

||

機械学習の価値/日

例: フリーマーケットのサービスの場合

(チェックに必要な人数 - 機械学習を導入した場合に必要な人数)

X

1日のチェック時間 (h/日)

X

時給 (円/h)

||

機械学習の価値/日

例: フリーマーケットのサービスの場合

(チェックに必要な人数 - 機械学習を導入した場合に必要な人数)

(20人 - 2人)
×

1日のチェック時間 (h/日)

×

時給 (円/h)

||

機械学習の価値/日

例: フリーマーケットのサービスの場合

(チェックに必要な人数 - 機械学習を導入した場合に必要な人数)

(20人 - 2人)
×

1日のチェック時間 (h/日)

7.5 h/日
×

時給 (円/h)

||

機械学習の価値/日

例: フリーマーケットのサービスの場合

(チェックに必要な人数 - 機械学習を導入した場合に必要な人数)

(20人 - 2人)
×

1日のチェック時間 (h/日)

7.5 h/日
×

時給 (円/h)

x 1200円/時



機械学習の価値/日

例：フリーマーケットのサービスの場合

(チェックに必要な人数 - 機械学習を導入した場合に必要な人数)

(20人 - 2人)
×

1日のチェック時間 (h/日)

7.5 h/日
×

時給 (円/h)

x 1200円/時



機械学習の価値/日

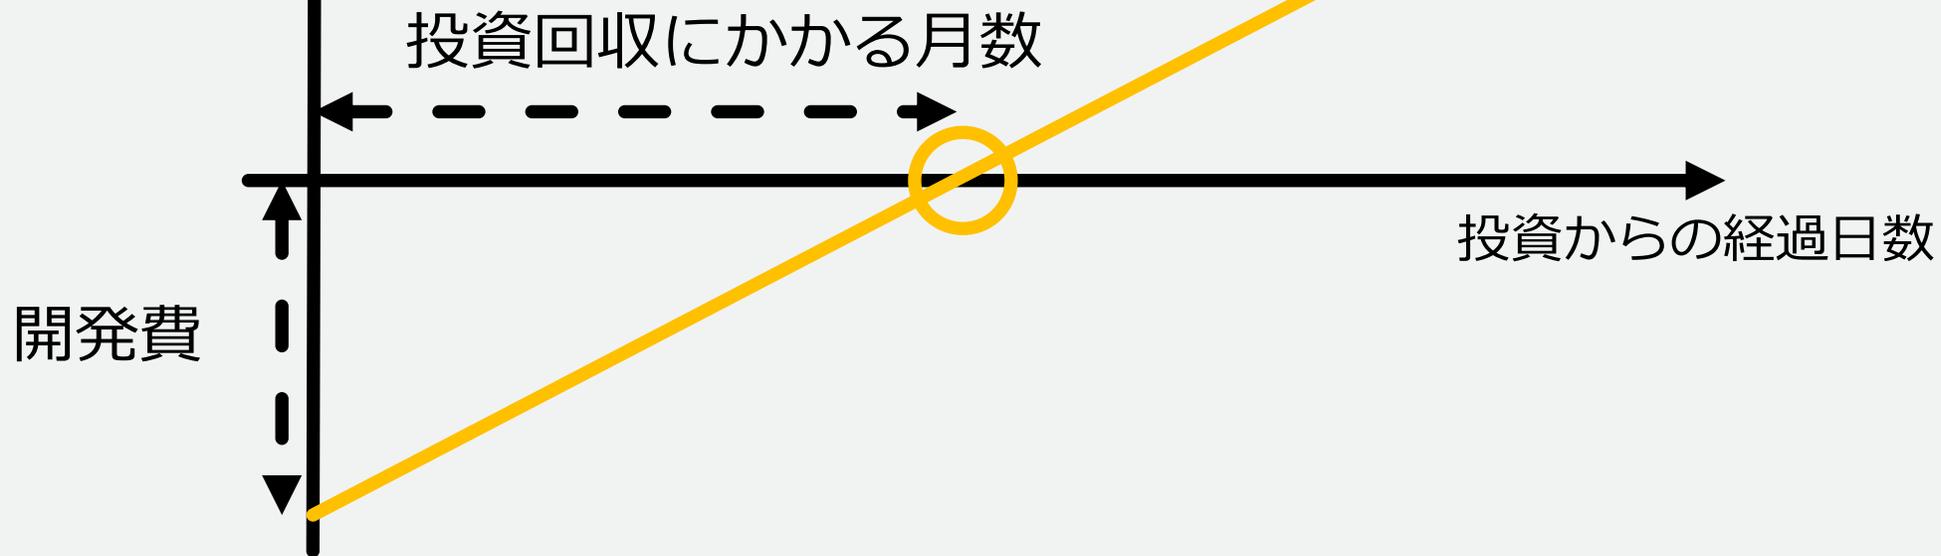
約16.2万/日

価値が計算できれば投資対効果を見通せる

回収金額 - 投資金額

$$(20人 - 2人) \times 7.5時間 \times 1200円 - 開発費 (円)$$

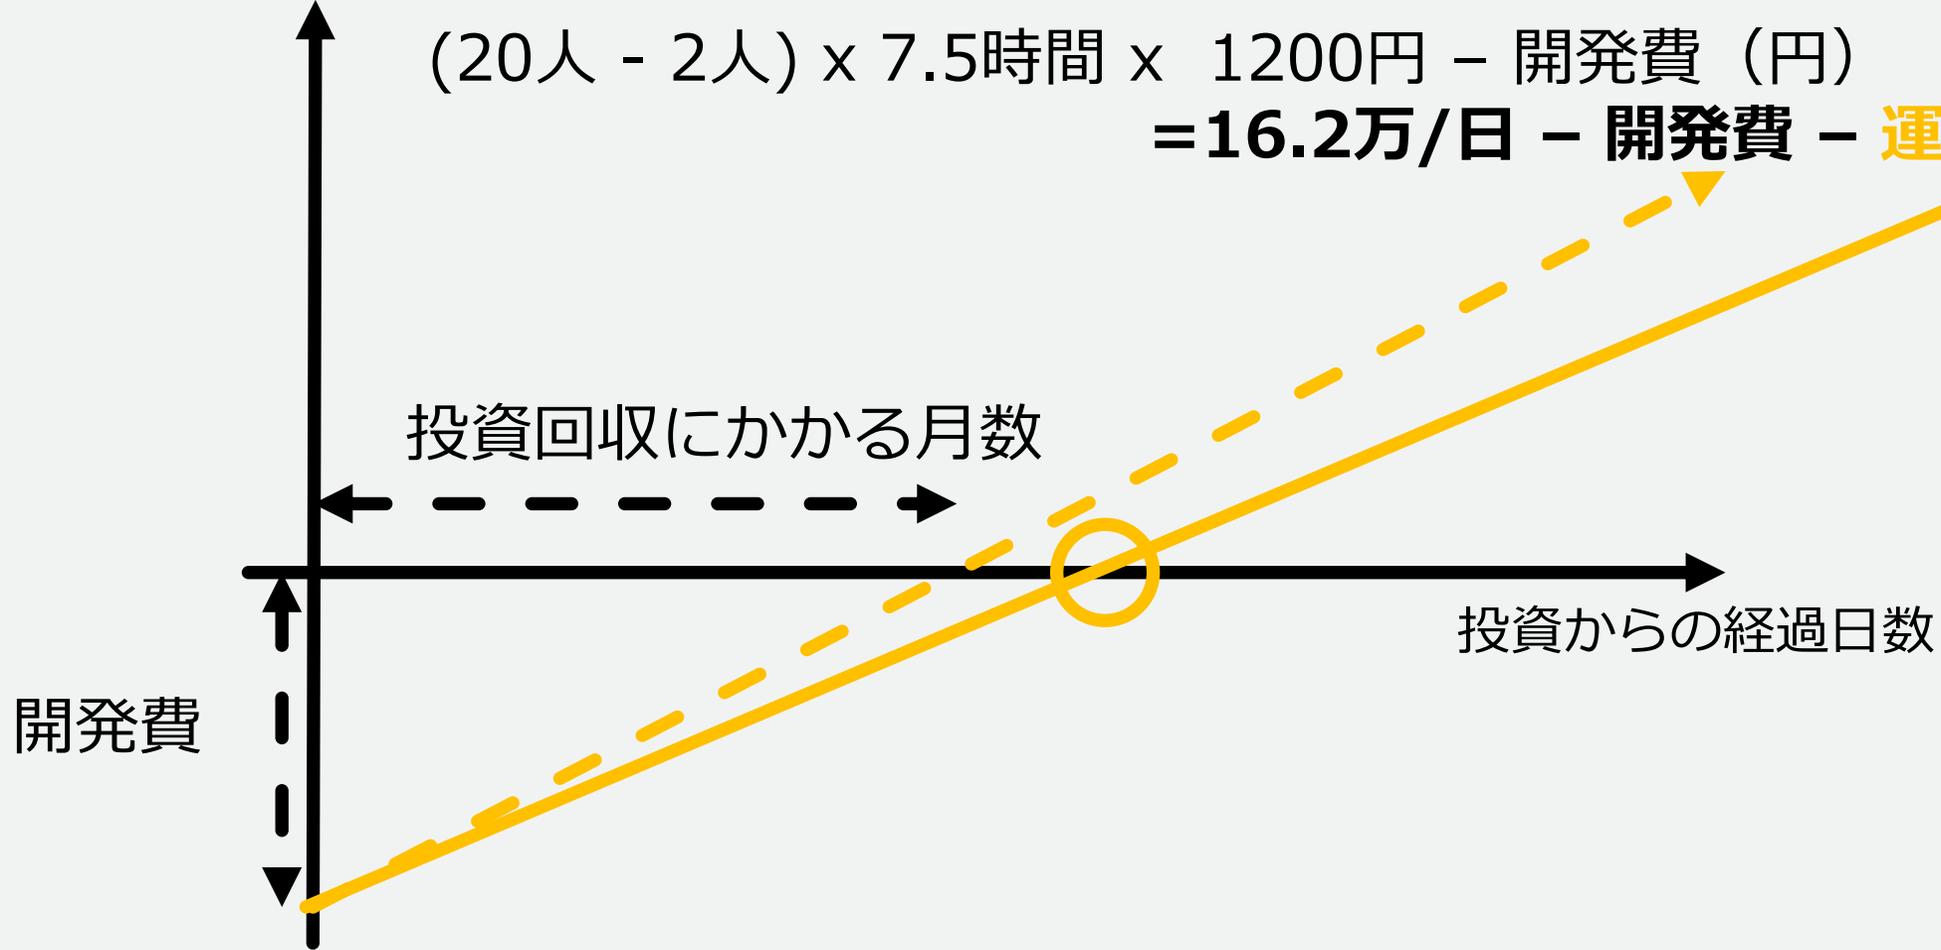
$$= 16.2万/日 - 開発費 (円)$$



価値が計算できれば投資対効果を見通せる

回収金額 - 投資金額

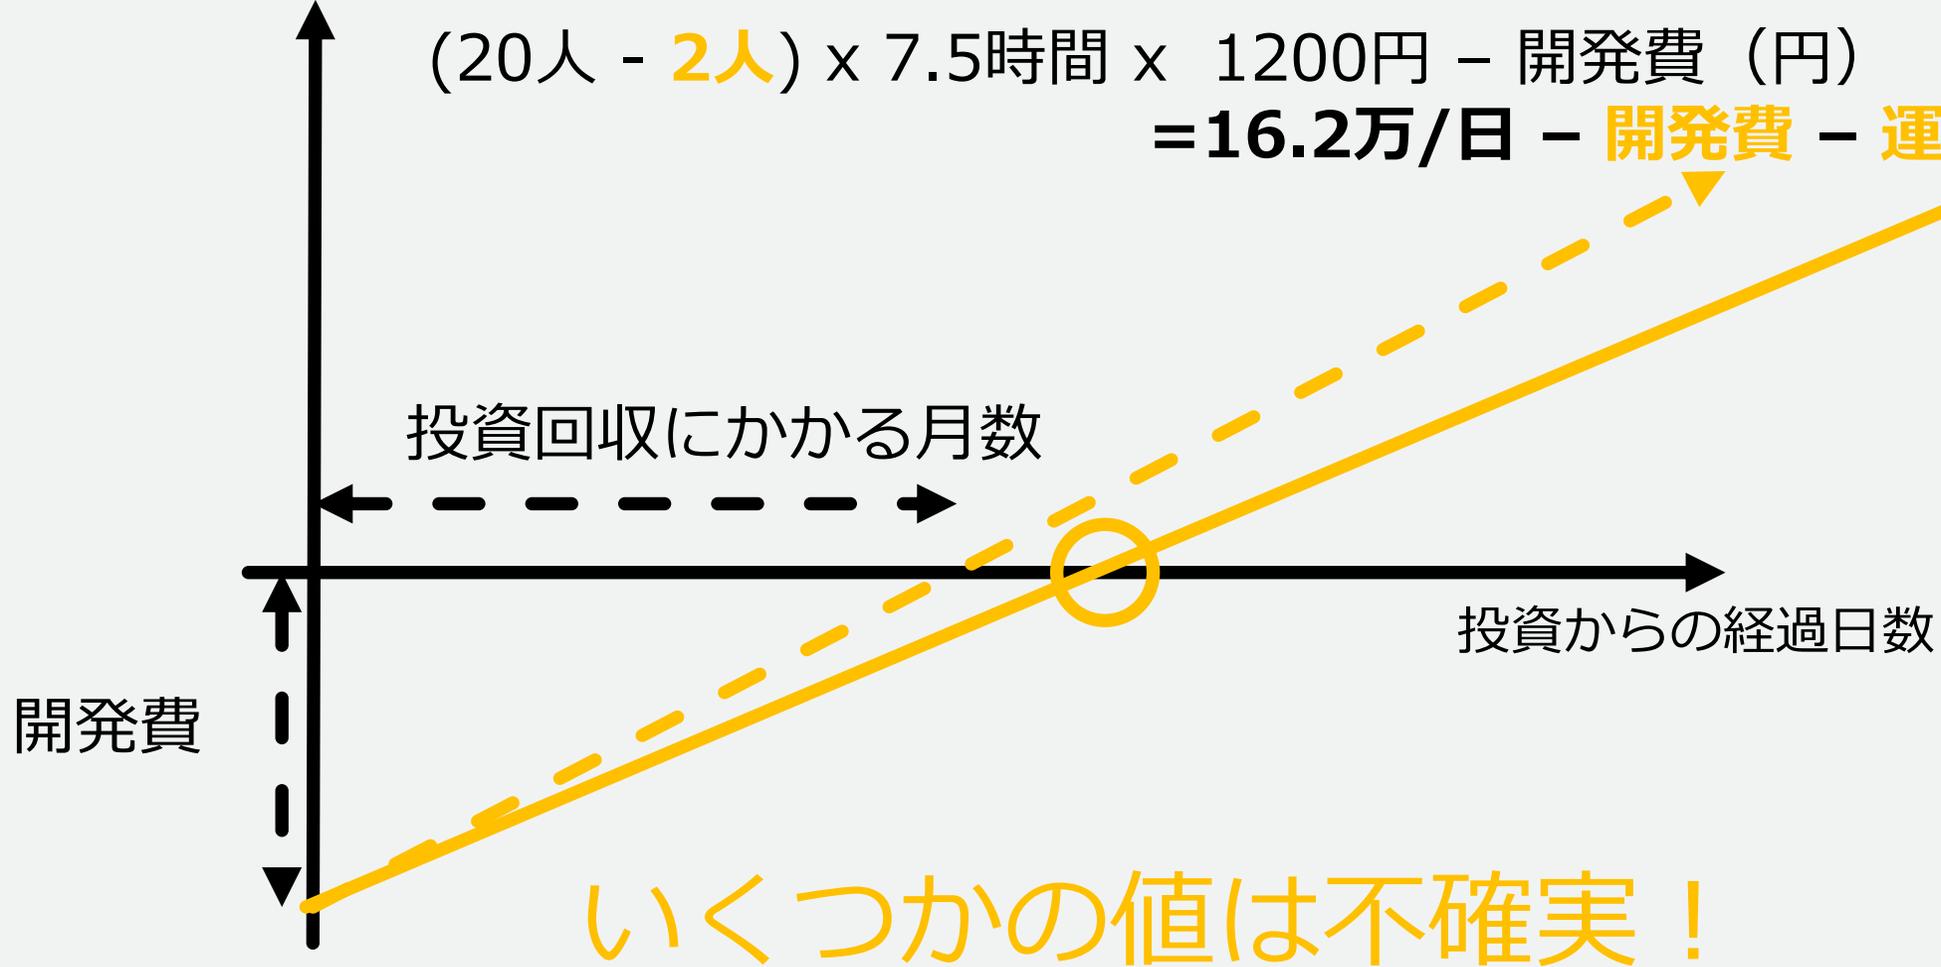
$$(20人 - 2人) \times 7.5時間 \times 1200円 - 開発費 (円) \\ = 16.2万/日 - 開発費 - 運用費 (円)$$



価値が計算できれば投資対効果を見通せる

回収金額 - 投資金額

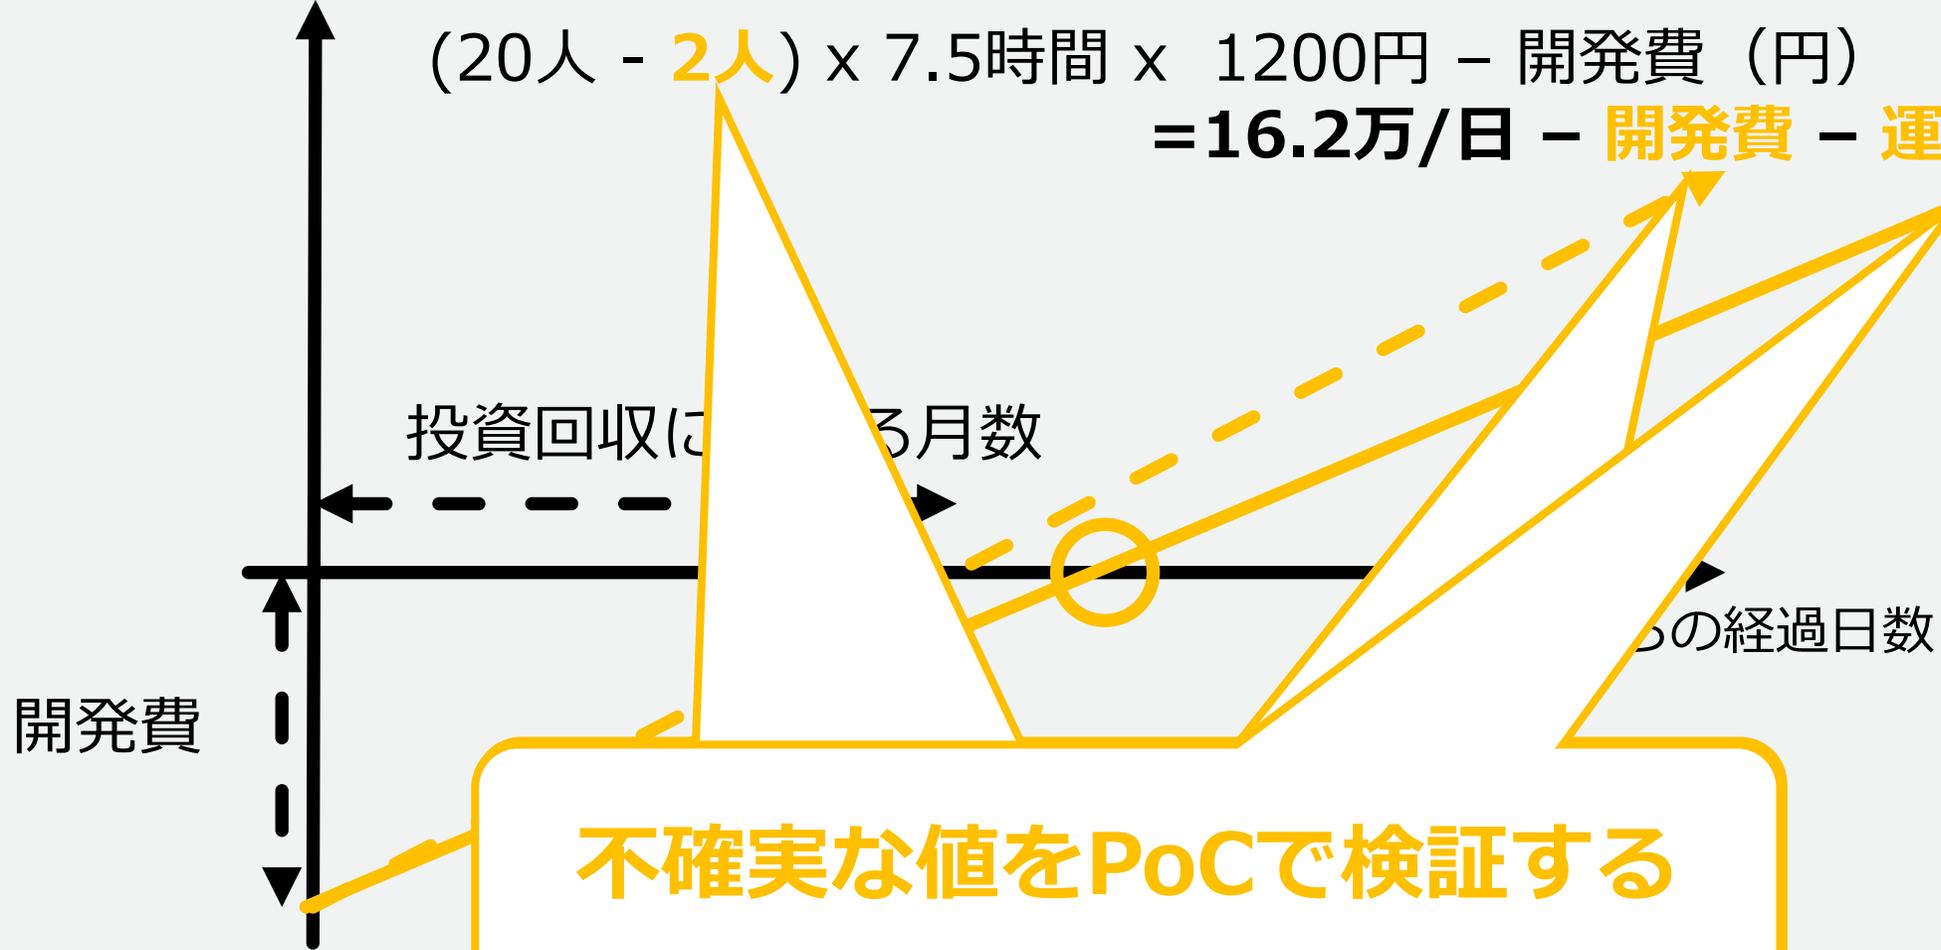
$$(20人 - 2人) \times 7.5時間 \times 1200円 - 開発費 (円) \\ = 16.2万/日 - 開発費 - 運用費 (円)$$



価値が計算できれば投資対効果を見通せる

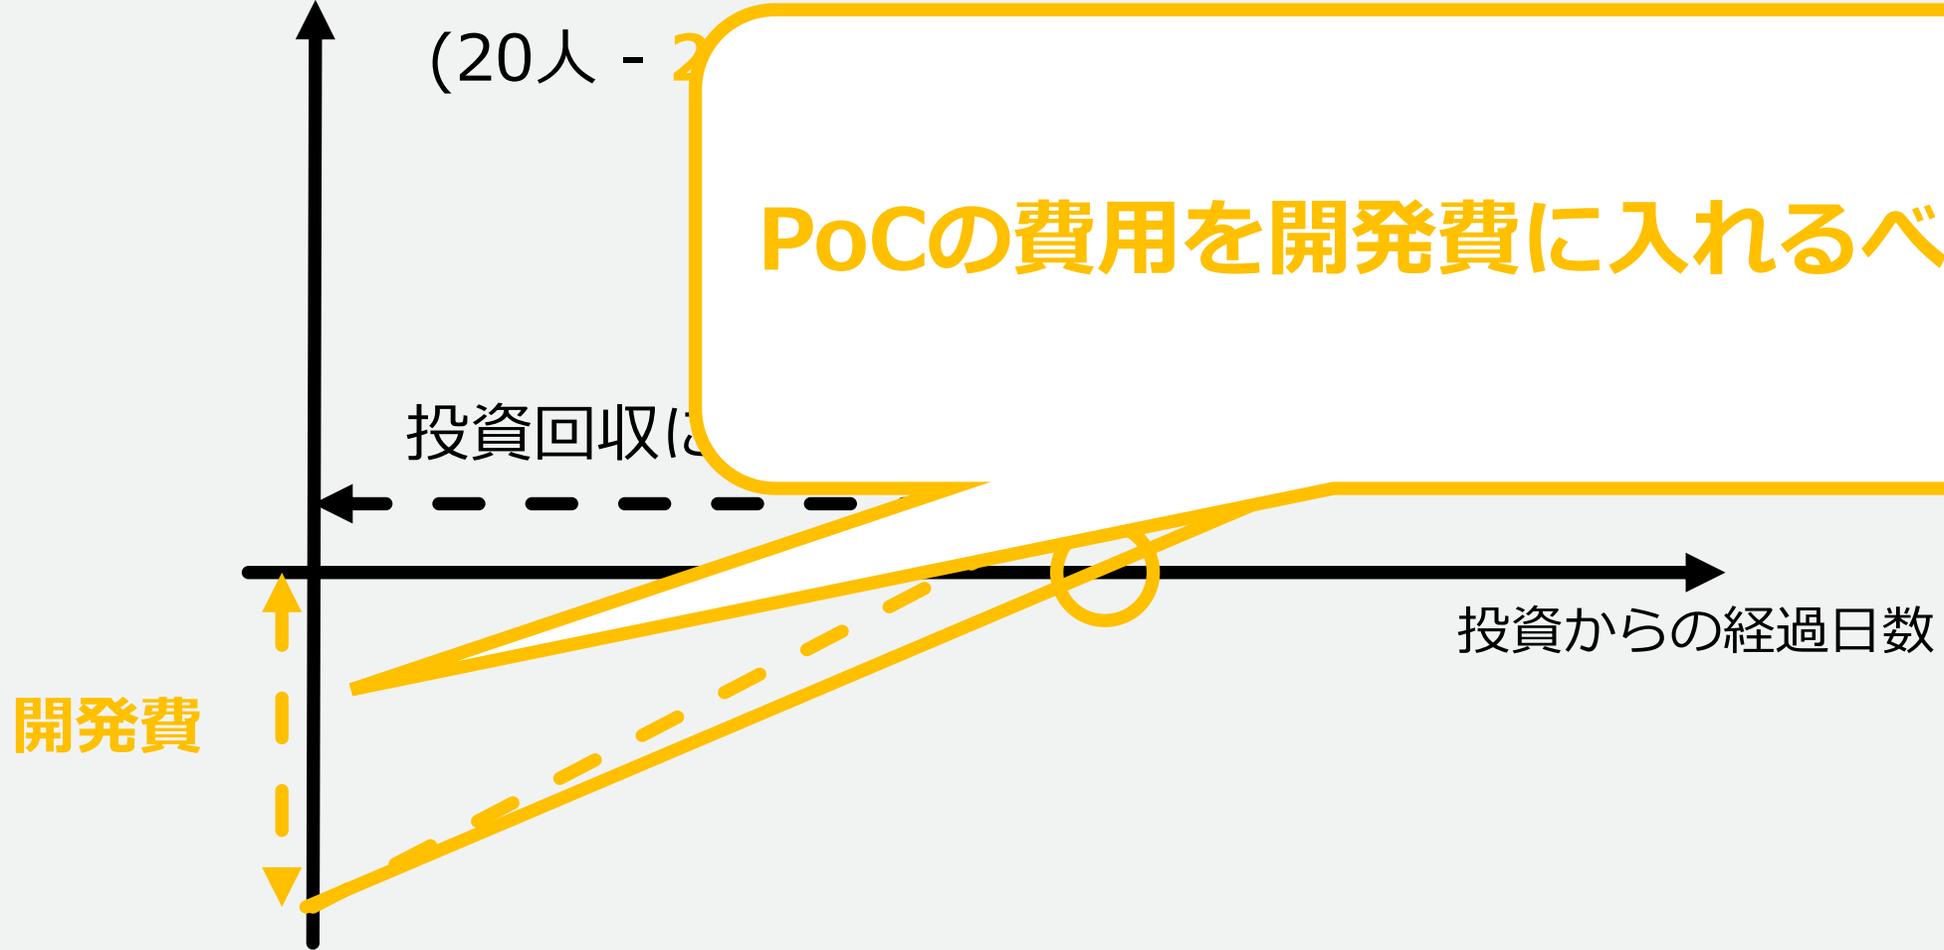
回収金額 - 投資金額

$$(20人 - 2人) \times 7.5時間 \times 1200円 - 開発費 (円) \\ = 16.2万/日 - 開発費 - 運用費 (円)$$



価値が計算できれば投資対効果を見通せる

回収金額 - 投資金額



**価値と計算式は
プロジェクトメンバー内で共有する**

Why: なぜするのか?

**機械学習で目標精度が達成できないことを、
失敗に直結させないため**

機械学習プロジェクトの
80% は
失敗するといわれている

出典 <https://www.gartner.com/en/newsroom/press-releases/2018-02-13-gartner-says-nearly-half-of-cios-are-planning-to-deploy-artificial-intelligence>



機械学習活用プロジェクトの80%は失敗する

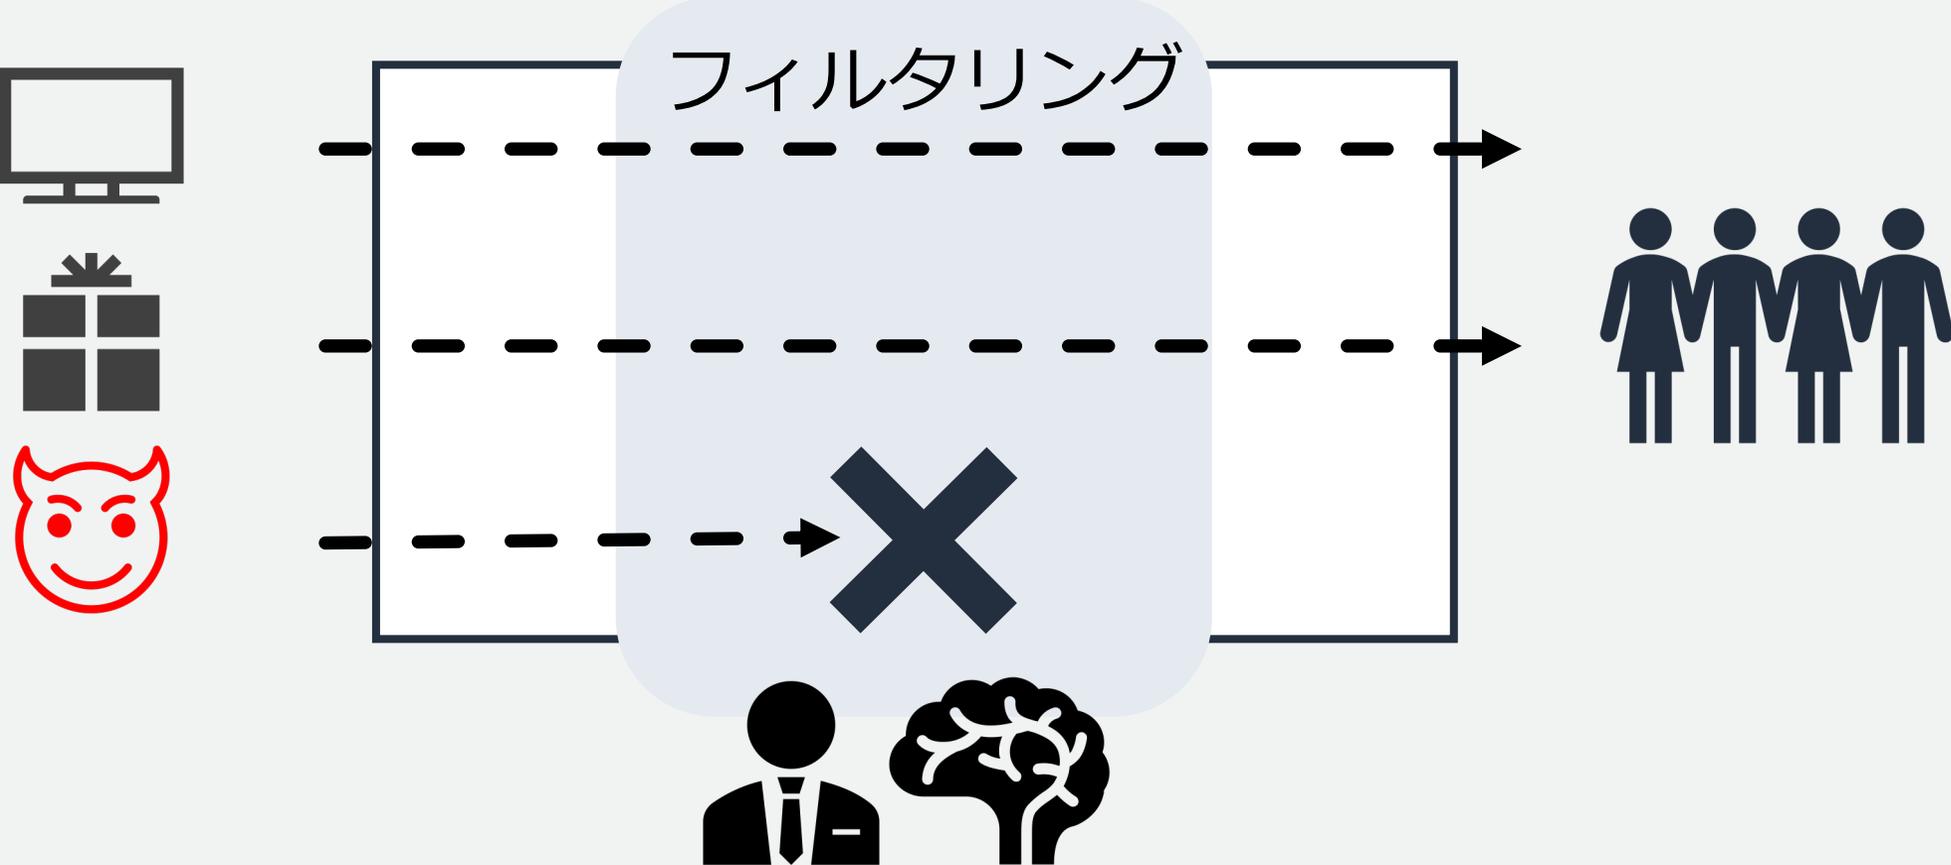
失敗する理由Top5

1. **ビジネスの目標がはっきりしていない**
2. データの品質が不十分
3. プロジェクトのスポンサーが不在
4. **チーム間の連携が不十分**
5. データサイエンティストなどの専門職の不在

**提供価値文と計算式をすることで
ビジネス目標と成功に必要な関係者が明確になる**

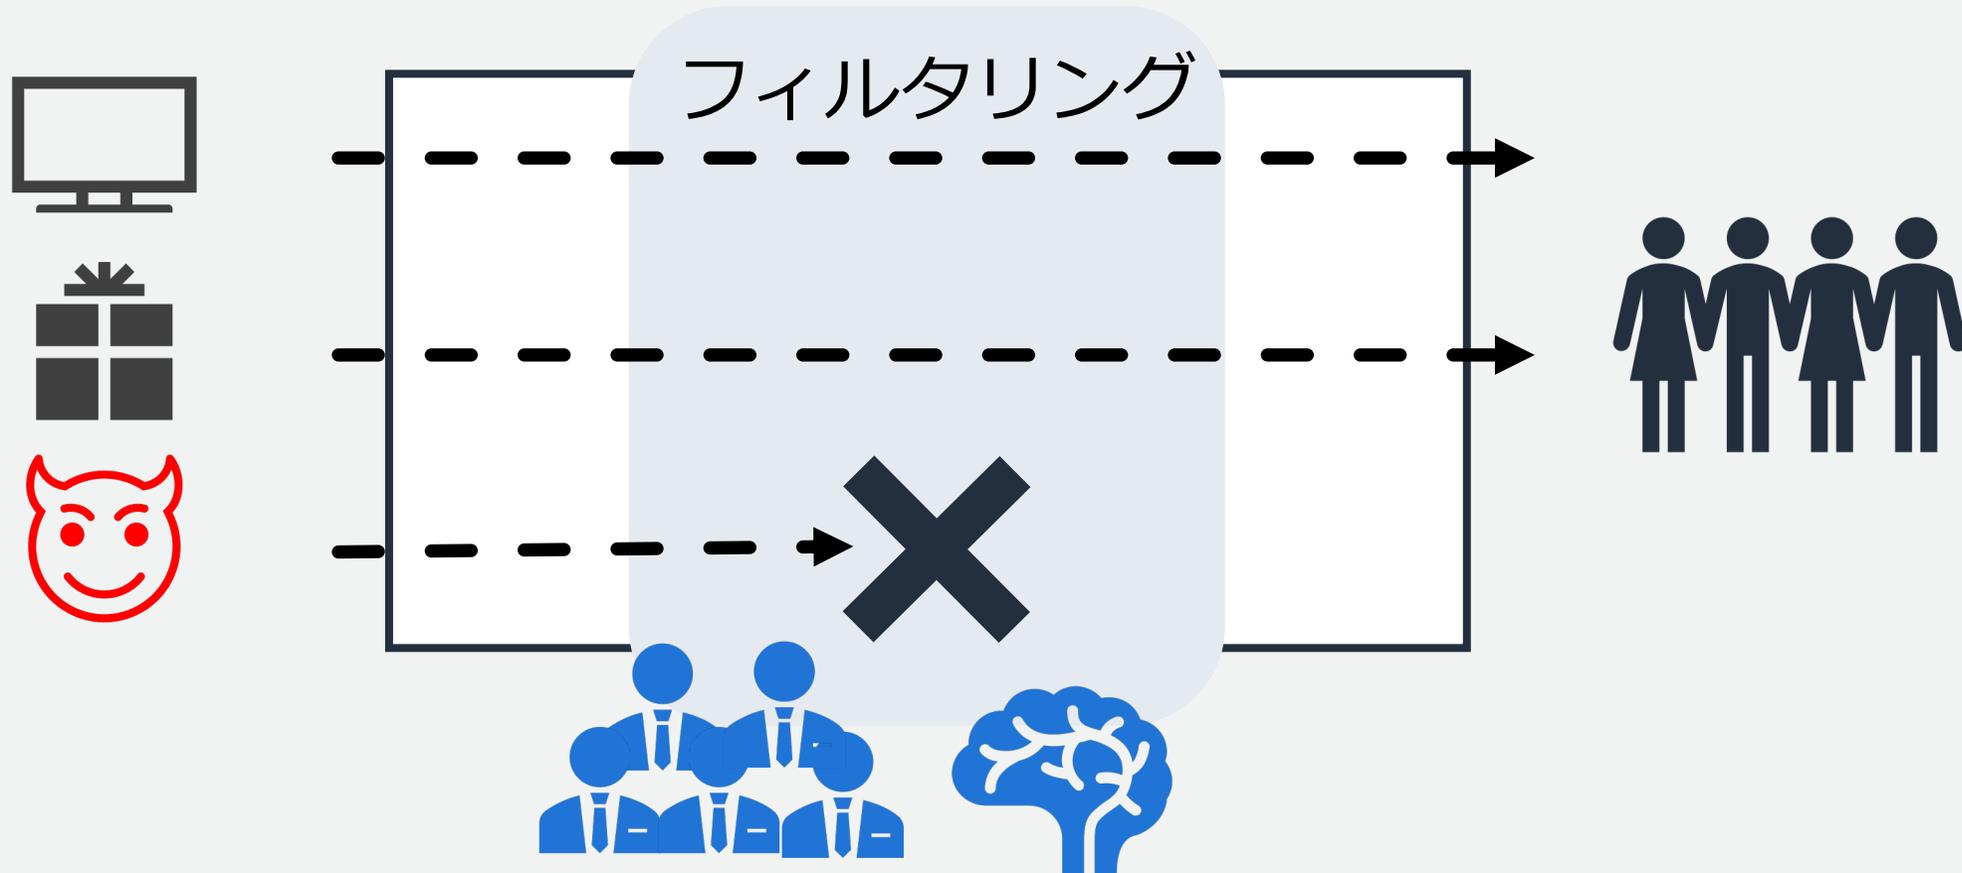
機械学習で目標精度が達成できない状態

例: フリーマーケットのサービスの場合



機械学習で目標精度が達成できない状態

例: フリーマーケットのサービスの場合



2人ではなく 10人必要!

機械学習で目標精度が達成できない状態

例：フリーマーケットのサービスの場合



失敗???

2人ではなく10人必要！

作成した計算式で考えてみる

$$\frac{(20人 - 2人) \times 7.5時間 \times 1200円}{\text{Before人数} - \text{After人数} \quad \text{1日のチェック時間} \quad \text{時給}}$$

$$= 16.2 \text{ 万/日}$$

作成した計算式で考えてみる

$$\frac{10 \text{ 人} \times 7.5 \text{ 時間} \times 1200 \text{ 円}}{\text{Before人数} - \text{After人数} \quad \text{1日のチェック時間} \quad \text{時給}}$$

~~= 16.2 万/日~~

9.0 万/日

作成した計算式で考えてみる

10人

$$\frac{(20人 - 2人) \times 7.5時間 \times 1200円}{2時間}$$

Before人数 - After人数

1日のチェック時間

時給

2時間

機械学習モデルの
予測結果の活用で、
時間短縮

~~= 16.2万/日~~

9.0万/日

作成した計算式で考えてみる

$$\begin{aligned} & \underline{(20人 \times 7.5時間 - 10人 \times 2時間) \times 1200円} \\ & = \underline{15.6万/日} \quad (\blacktriangle 0.6万) \\ & \quad \underline{16.2万/日} \end{aligned}$$

チェック担当チームでカテゴリの兼任を進めることで
1年後 2人にできる見込み。

作成した計算式で考えてみる

(2) 人件費が許容範囲内に収まったので、
顧客への提供価値は実現できる！！
= 失敗とはいえない

チェック担当チームでカテゴリの兼任を進めることで
1年後 2人にできる見込み。

作成した計算式で考えてみる

(2) 人件費が許容範囲内に収まらない
= 失敗

チェック担当チームでカテゴリの兼任を進めることで
1年後 2人にできる見込み。

ビジネス目標（顧客への提供価値）と
機械学習の価値計算式を明確にする



目標を達成するためのパラメータと
パラメータをコントロールする関係者が
明らかになる



**機械学習で目標精度が達成できないことが
失敗に直結しない**

目標を達成するためのパラメータと パラメータをコントロールする関係者が明らかにする

例: フリーマーケットのサービスの場合

(チェックに必要な人数 - 機械学習を導入した場合に必要な人数)

チェック担当チーム 1日のチェック時間 (h/日)

x 時給 (円/h)

- 運用費

= 機械学習の価値/日

目標を達成するためのパラメータと パラメータをコントロールする関係者が明らかにする

例: フリーマーケットのサービスの場合

(チェックに必要な人数) - 機械学習を導入した場合に必要な人数)

チェック担当チーム 1日のチェック時間 (h/日)

x 時給 (円/h)

採用担当チーム

- 運用費

= 機械学習の価値/日

目標を達成するためのパラメータと パラメータをコントロールする関係者が明らかにする

例: フリーマーケットのサービスの場合

(チェックに必要な人数 - 機械学習を導入した場合に必要な人数)

チェック担当チーム 1日のチェック時間 (h/日)

x 時給 (円/h)

採用担当チーム

- 運用費

システム運用チーム

= 機械学習の価値/日

多くの場合、**機械学習が目標精度を達成できるかは不確実**

目標を達成の関係者が明らかになることで、

目標精度の達成可否が

プロジェクト成否に直結することを回避できる

How: どうやるのか?

演習の概要

3.1 プログラミング演習 ※実際にプログラムはしません。

- 3つの機械学習プロジェクト例について計算式を作る演習

3.2 コミュニケーション演習

- 価値計算の方向性を決めるために行うべき
コミュニケーションの演習

3.1 プログラミング演習

事例1: 飲料メーカー A 社での機械学習プロジェクト プロジェクトの要件

製造担当者として、飲料を入れる瓶が割れてしまっていないか
どうか効率的に検品したい。現状は人手で検品しており、
コスト・時間がかかり検品精度にばらつきもある。

機械学習で出来るだけ自動化したい。また検品精度も向上させたい。



事例1: 飲料メーカー A 社での機械学習プロジェクト プロジェクトの要件

製造担当者として、飲料を入れる瓶が割れてしまっていないか
どうか効率的に検品したい。現状は人手で検品しており、
コスト・時間がかかり検品精度にばらつきもある。

機械学習で出来るだけ自動化したい。また検品精度を向上させたい。

どのような計算式で価値を定義する?



フレ



フレ

事例1: 飲料メーカー A 社での機械学習プロジェクト

戦略:

漏れ・重複がない観点から価値の計算を行う(例: QCD)

1. (Quality: 品質) 製造後の工程(出荷や販売)におけるクレームの数

- **機械学習の Q の価値**
= (Before のクレーム数 - After のクレーム数) x 損失額

2. (Cost: コスト) 検品コスト

- **機械学習の C の価値**
= (Before の検品人数 - After の検品人数) x 時間 x 時給

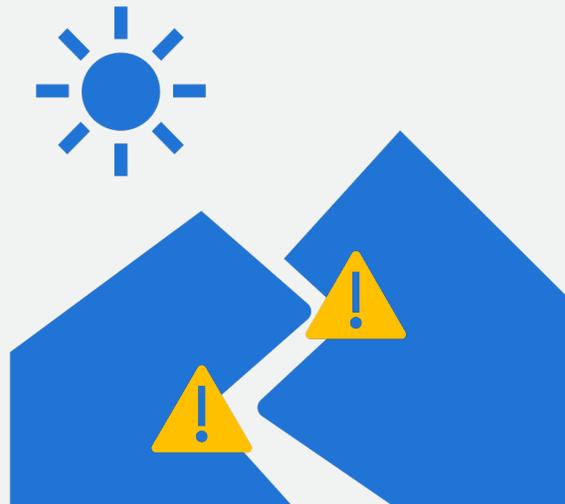
3. (Delivery: 納期) 検品時間

- **機械学習の D の価値**
= Before の時間 - After の時間

事例2: 道路のひび割れを検出する機械学習プロジェクト

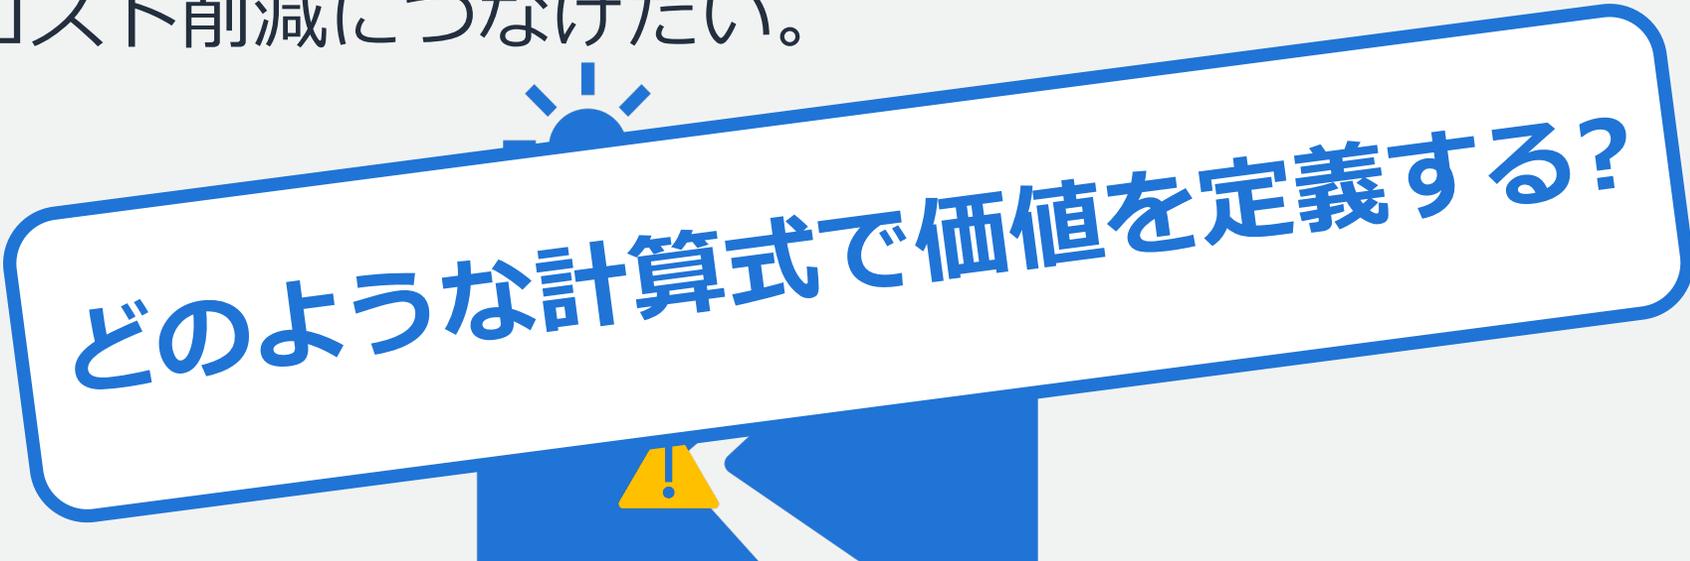
プロジェクトへの要件

道路点検の担当者として、道路のひび割れの見逃しをなくしたい。点検は車からの目視で行っており、熟練度によってひび割れが検出できる数に差異がある。熟練とまではいかななくても、**そこそこの人員の代替になれば**活用しコスト削減につなげたい。



事例2: 道路のひび割れを検出する機械学習プロジェクト プロジェクトへの要件

道路点検の担当者として、道路のひび割れの見逃しをなくしたい。点検は車からの目視で行っており、熟練度によってひび割れが検出できる数に差異がある。熟練とまではいかななくても、**そこそこの人員の代替になれば**活用しコスト削減につなげたい。



どのような計算式で価値を定義する?

事例2: 道路のひび割れを検出する機械学習プロジェクト

戦略:

どの程度の検出数であれば価値を達成できるか、人間の能力値の上限と下限を目安に機械学習の達成目標を設定する。

1. 導入基準: 「そこそこの人員の代替」

- 素人の検出数 < モデルの検出数 < 玄人の検出数

具体的な目標値は、決めておきましょう！

2. 検出コスト

- 機械学習の C の価値
= (Before担当者数 - After担当者数) x 時間 x 時給

事例3: ゲームのチャット欄における誹謗中傷コメント検知プロジェクトの要件

ゲーム運営の担当者として、誹謗中傷となるようなコメントを**100%の精度で検知したい**。

誹謗中傷となるコメントが放置されると、プラットフォーム側からゲームの配信そのものが停止され大きな損害が出るため。

現状は人が目視してチェックしているが、配信しているタイトル全てをくまなく見ていくには限界がある。



事例3: ゲームのチャット欄における誹謗中傷コメント検知プロジェクトの要件

ゲーム運営の担当者として、誹謗中傷となるようなコメントを**100%の精度で検知したい**。

誹謗中傷となるコメントが放置されると、プラットフォーム側からゲームの配信そのものが停止され大きな損害が出るため。

現状は人が目視してチェックしているが、配信しているタイトル全てをくまなく見ている人は限られている。

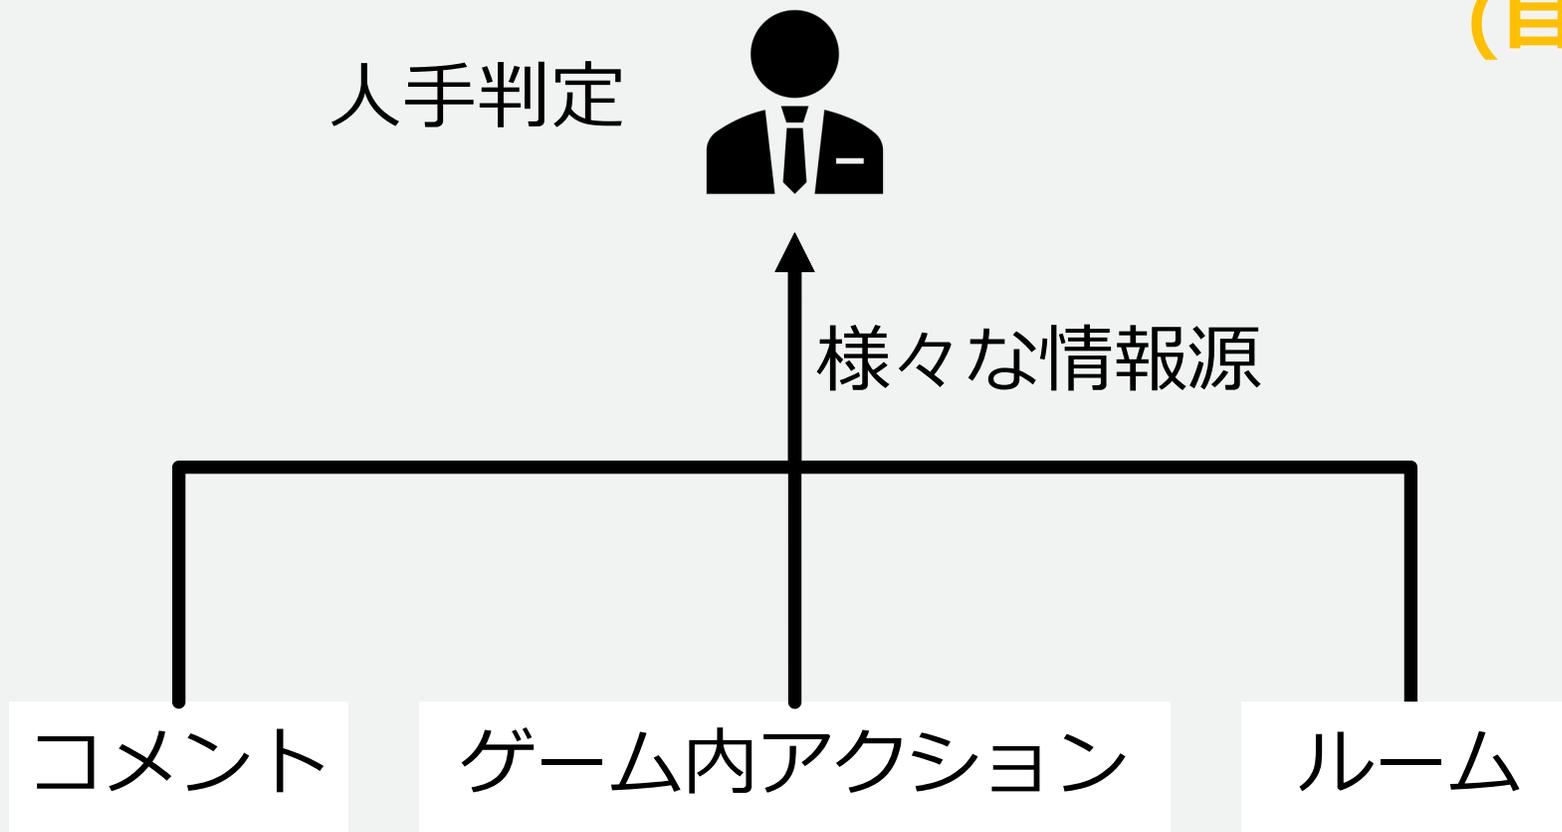
どのような計算式で価値を定義する?

事例3: ゲームのチャット欄における誹謗中傷コメント検知

戦略:

機械学習モデル単品でなく、システム全体で100%を目指す
その中でのオペレーション価値を算出

システム全体
(目標精度100%)

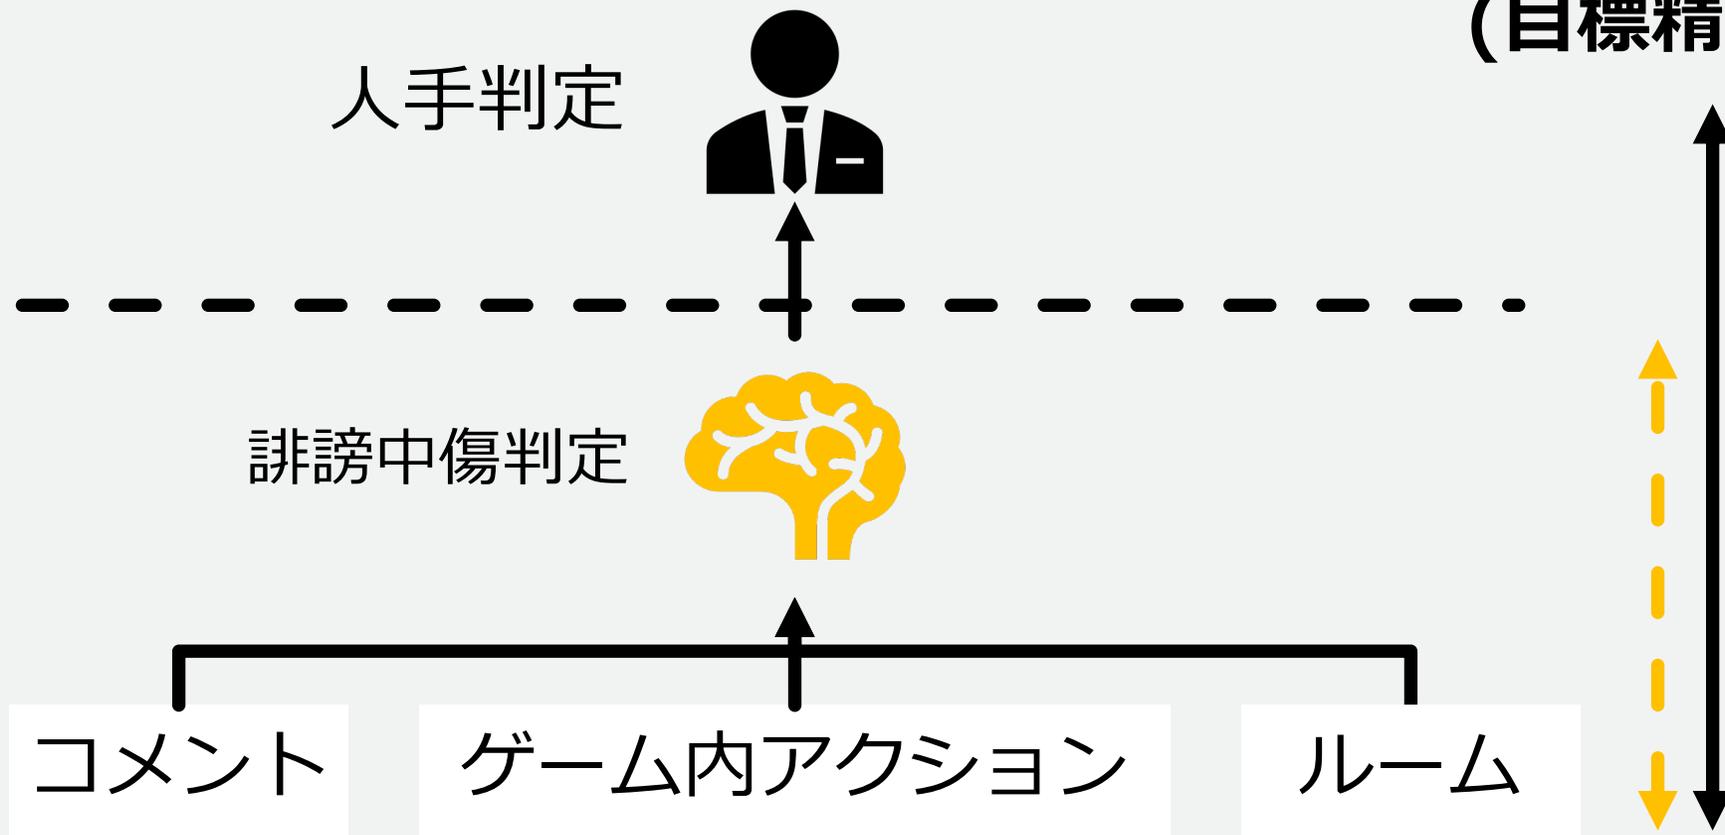


事例3: ゲームのチャット欄における誹謗中傷コメント検知

戦略:

機械学習モデル単品でなく、システム全体で100%を目指す
その中のオペレーション価値を算出

システム全体
(目標精度100%)



事例3: ゲームのチャット欄における誹謗中傷コメント検知

戦略:

機械学習モデル単品でなく、システム全体で100%を目指す
その中でのオペレーション価値を算出

機械学習のオペレーション価値 (量 × 単価)

= フィルタしたコメント数 × 確認単価 (/円)

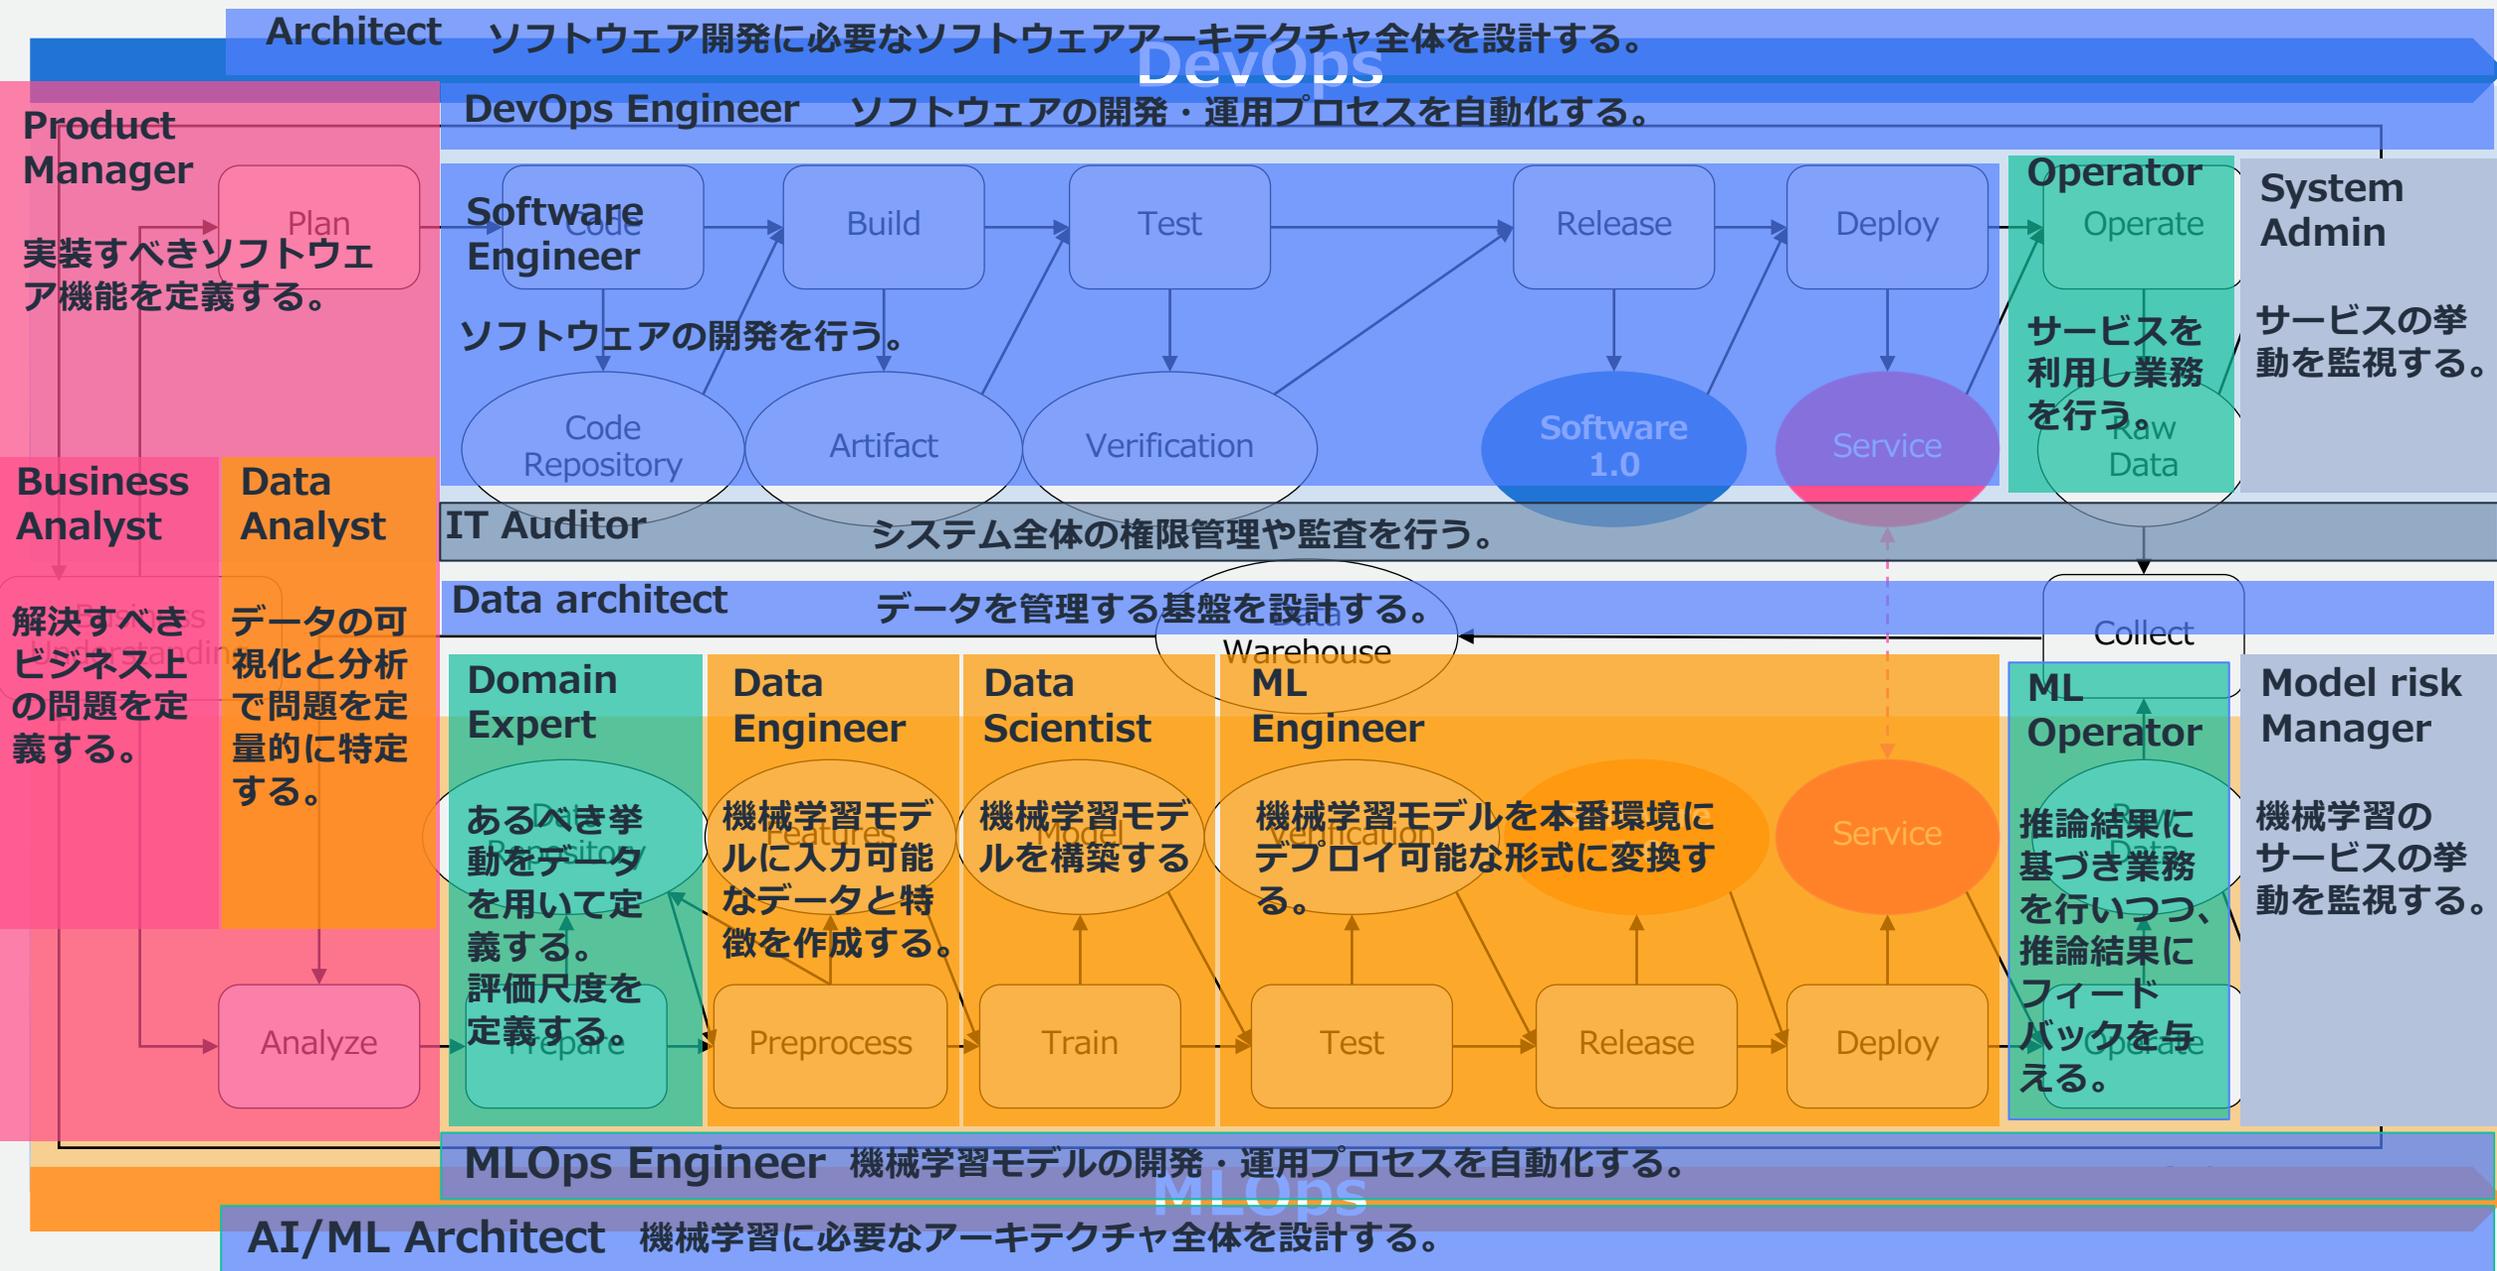
= X 万回/日 × 確認単価

3.2 コミュニケーション演習

コミュニケーション演習で学ぶこと

誰に何を依頼すべきか？

ロールから「誰」を選ぶ



依頼する内容を選ぶ

- 情報共有
- 作業
- レビュー
- 承認

依頼する内容を選ぶ

- 情報共有

開発に必要な情報/ドキュメントの提供を依頼

- 作業

- レビュー

- 承認

依頼する内容を選ぶ

- 情報共有

開発に必要な情報/ドキュメントの提供を依頼

- 作業

開発に必要な作業を分担(依頼)

- レビュー

- 承認

依頼する内容を選ぶ

- 情報共有

開発に必要な情報/ドキュメントの提供を依頼

- 作業

開発に必要な作業を分担(依頼)

- レビュー

作業の確度を上げるためレビューを依頼

- 承認

依頼する内容を選ぶ

- 情報共有

開発に必要な情報/ドキュメントの提供を依頼

- 作業

開発に必要な作業を分担(依頼)

- レビュー

作業の確度を上げるためレビューを依頼

- 承認

権限の獲得を目的に承認を依頼する

プログラミング演習で行ったこと

1. 漏れ・重複がない観点から価値の計算を行う(例: QCD)
2. 人間の上限と下限の能力値から機械学習の導入基準を設定する
3. 機械学習モデル単品でなく、システム全体で100%を目指す

その中でのオペレーション価値を算出する

**計算式を作成する活動を行うとき、
誰に何を依頼すべきか?**

コミュニケーション演習①: toビジネスチーム



Who: ビジネス要求に詳しい人

英語名	日本語名	役割
Product Manager	プロダクトマネージャー	ユーザー体験を向上させるために実装すべきソフトウェア機能を定義する。
Business Analyst	ビジネスアナリスト	解決すべきビジネス上の問題を定義する
Data Analyst	データアナリスト	データの可視化と分析で問題を定量的に特定する。
Domain Expert	業務有識者	深い業務知識を持ちデータの意味やあるべき状態について定義する。

What: 何を依頼すべきか?

- 情報共有 : 開発に必要な情報/ドキュメントの提供を依頼する
- 作業 : 開発に必要な作業を分担(依頼)する
- レビュー : 作業の確度を上げるためレビューを依頼する
- 承認 : 権限の獲得を目的に承認を依頼する



コミュニケーション演習①: toビジネスチーム



Who: ビジネス要求に詳しい人

英語名	日本語名	役割
Product Manager	プロダクトマネージャー	ユーザー体験を向上させるために実装すべきソフトウェア機能を定義する。
Business Analyst	ビジネスアナリスト	解決すべきビジネス上の問題を定義する
Data Analyst	データアナリスト	データの可視化と分析で問題を定量的に特定する。
Domain Expert	業務有識者	深い業務知識を持ちデータの意味やあるべき状態について定義する。

What: 何を依頼すべきか?

誰に何を依頼すべきか?

- 情報共有 : 開発に必要な情報/ドキュメントの提供を依頼する
- 作業 : 開発に必要な作業を分担(依頼)する
- レビュー : 作業の確度を上げるためレビューを依頼する
- 承認 : 権限の獲得を目的に承認を依頼する



コミュニケーション演習①: toビジネスチーム

回答例

Who: ビジネス要求に詳しい人

英語名	日本語名	役割
Product Manager	プロダクトマネージャー	ユーザー体験を向上させるために実装すべきソフトウェア機能を定義する。
Business Analyst	ビジネスアナリスト	解決すべきビジネス上の問題を定義する
Data Analyst	データアナリスト	データの可視化と分析で問題を定量的に特定する。
Domain Expert	業務有識者	深い業務知識を持ちデータの意味やあるべき状態について定義する。

プロダクトのオーナーか、その業界（ドメイン）に詳しい人

コミュニケーション演習①: toビジネスチーム

What: 何を依頼すべきか?

レビュー

- ビジネス的目標（顧客への提供価値）を表現した文が間違っていないか
- 価値計算式が間違っていないか
- 機械学習の価値計算の中で、方向性を確認

承認

- **上位のステークホルダー(スポンサー)からの承認・合意**
 - 提案書、稟議書 など

コミュニケーション演習①: toビジネスチーム

回答例

What: 何を依頼すべきか?

機械学習の価値計算の中で、方向性を確認

- どの観点を優先すべきか

道路のひび割れ検知の場合

- **Q 優先: ひび割れ検知率を優先 (モデル精度)**
 - **C 優先: ひび割れ検知にかかるコストを優先 (オペレーションコスト)**
 - **D 優先: ひび割れ検知にかかる時間を優先 (短縮時間)**
- 機械学習導入後の業務フローやユーザー体験が間違っていないか

コミュニケーション演習①: toビジネスチーム

What: 何を依頼すべきか?

機械学習の価値計算の中で、方向性を確認

- どの観点を優先すべきか

道路のひび割れ検知の場合

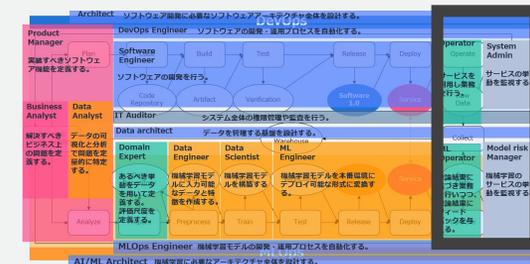
- Q 優先: ひび割れ検知率を優先 (モデル精度)
 - C 優先: ひび割れ検知にかかるコストを優先 (オペレーションコスト)
 - D 優先: ひび割れ検知にかかる時間を優先 (短縮時間)
- 機械学習導入後の業務フローやユーザー体験が間違っていないか

悪質なコメント検知の場合

- 全自動: 適用範囲を限定して全て自動的に行う
- 一部手動: 全てのコメントで適用。最終チェックは人手で

コミュニケーション演習toシステム管理チーム

Who: ITインフラを管理している人



英語名	日本語名	役割
System Admin	システム管理者	サービスの挙動を監視する。
IT Auditor	IT監督者	システムや会社全体の権限管理や監査を行う。
Operator	業務担当者	ソフトウェアを利用し業務を行う。
ML Operator	業務担当者(機械学習側)	推論結果に基づき業務を行いつつ、フィードバックを与える。
Model risk Manager	機械学習モデルリスク管理者	機械学習モデルの推論の挙動を監視する。


What: 何を依頼すべきか?

- 情報共有 : 開発に必要な情報/ドキュメントの提供を依頼する
- 作業 : 開発に必要な作業を分担(依頼)する
- レビュー : 作業の確度を上げるためレビューを依頼する
- 承認 : 権限の獲得を目的に承認を依頼する



コミュニケーション演習toシステム管理チーム

Who: ITインフラを管理している人



英語名	日本語名	役割
System Admin	システム管理者	サービスの挙動を監視する。
IT Auditor	IT監督者	システムや会社全体の権限管理や監査を行う。
Operator	業務担当者	ソフトウェアを利用し業務を行う。
ML Operator	業務担当者(機械学習側)	推論結果に基づき業務を行いつつ、フィードバックを与える。
Model risk Manager	機械学習モデルリスク管理者	機械学習モデルの推論の挙動を監視する。

誰に何を依頼すべきか?

- 情報共有 : 開発に必要な情報/ドキュメントの提供を依頼する
- 作業 : 開発に必要な作業を分担(依頼)する
- レビュー : 作業の確度を上げるためレビューを依頼する
- 承認 : 権限の獲得を目的に承認を依頼する



コミュニケーション演習toシステム管理チーム

回答例

Who: ITインフラを管理している人

英語名	日本語名	役割
System Admin	システム管理者	サービスの挙動を監視する。
IT Auditor	IT監督者	システムや会社全体の権限管理や監査を行う。
Operator	業務担当者	ソフトウェアを利用し業務を行う。
ML Operator	業務担当者(機械学習側)	推論結果に基づき業務を行いつつ、フィードバックを与える。
Model risk Manager	機械学習モデルリスク管理者	機械学習モデルの推論の挙動を監視する。

コミュニケーション演習toシステム管理チーム

回答例

What: 何を依頼すべきか?

情報共有

- 過去のシステム開発投資の資料
(開発費・運用費の目安にするため)
- 開発/運用を委託しているパートナー、また調達先

機械学習プロジェクトの現実

投資合理性があってもステークホルダーを説得できるとは限らない

- 現場で発言権を持つ業務エキスパートが機械学習モデルを信用しない
- システム関連予算から開発費を捻出できない
- (既存の開発/運用委託先が機械学習を扱えないため) 新規パートナーと契約を締結することへの忌避感がある
- 既存システムが密結合であり、機械学習を組み込むことが困難になっている

Never Give Up!

機械学習プロジェクトの現実

投資合理性があってもステークホルダーを説得できるとは限らない



活路の例

主語にしたユーザーを切り替えることで
新たな価値にピボットできる

Never Give Up!

主語にしたユーザーを切り替えることで 新たな価値にピボットできる

例：道路点検の場合

- ユーザーを「道路点検の品質管理者」から「道路の保守点検を依頼する自治体」に切り替えると、「道路の補修計画を立てるため迅速にひび割れの多い箇所を特定できる」という価値定義ができるかもしれない

主語にしたユーザーを切り替えることで 新たな価値にピボットできる

例：道路点検の場合

- ユーザーを「道路点検の品質管理者」から「道路の保守点検を依頼する自治体」に切り替えると、「道路の補修計画を立てるため迅速にひび割れの多い箇所を特定できる」という価値定義ができる
- ひび割れ検出という技術はそのまま、**対象を衛星画像など広域の写真にすることで**「衛星画像を扱う団体」などに新たな提案が可能になる

AWSで提供しているプログラム

《参考1》前臨床試験のための腎臓画像解析 

ビジネス課題

- 前臨床試験の腎臓損傷評価（目視作業）の効率化
- 腎臓内の糸球体（glomeruli）を事前に定義した損傷クラスに分類

使用データ

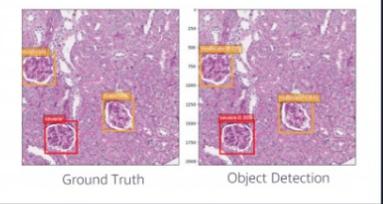
- 糸球体情報（ラベル付 bounding box）を含む腎臓画像データ

ML活用方法

- Amazon SageMaker Ground Truth で学習データを収集
- カスタムモデルで糸球体を抽出 →ラベル付与

得られた成果

- 科学的知見を得るまでのプロセスを効率化
- 人手による分析の精度改善
- 作業コスト削減



© 2020 Amazon Web Services, Inc. or its affiliates. All rights reserved | 15

[ML Discovery Workshop](#)

お客様のビジネス課題に対しAI/MLの適用可否と難易度を発見するワークショップ。アマゾンの代表的なイノベーションメカニズムである「ワーキングバックワーズ（Working Backwards）」の5つの質問などを用い機械学習のユースケースを特定する。（リンクはAstra Zeneca様の事例）

Amazon ML Solutions Lab を使用したお客様の導入事例



[Amazon Machine Learning Solutions Lab](#)

AWSの機械学習エキスパートと連携し、モデル開発を含めたMVPを短期間で開発する。

おわりに

(再掲) 本動画のゴール

- プロダクトにおける機械学習の価値を計算式で示せるようになる
- プロダクトマネージャーらと会話し価値の方向性を定められるようになる

Let's Challenge!!

(再掲) Business Understanding のゴール

プロダクトの顧客が理解できる言葉で
機械学習後の価値を定義する



(再掲) Business Understanding で最も重要な成果物

「プロダクトの顧客」にとっての
機械学習後の価値を表した文

機械学習の価値を計算する式

(再掲) Why?

機械学習で目標精度が達成できないことを、失敗に直結させないため

ビジネス目標（顧客への提供価値）と
機械学習の価値計算式を明確にする



目標を達成するためのパラメータと
パラメータをコントロールする関係者が
明らかになる

(再掲) How 演習の概要

3.1 プログラミング演習 ※実際にプログラムはしません。

- 3つの機械学習プロジェクト例について計算式を作る演習

3.2 コミュニケーション演習

- 価値計算の方向性を決めるために行うべき
コミュニケーションの演習

資料はすべてオープンな場所で公開しています
動画はYouTube、ハンズオンはGitHubに掲載。

<https://github.com/aws-samples/aws-ml-enablement-handson>

aws-samples / aws-ml-enablement-handson Public

<> Code ① Issues ② Pull requests ③ Discussions Actions Projects Wiki Security Insights Settings

main 1 branch 0 tags Go to file Add file Code

icoxfog417 Update README.md 797ac75 5 days ago 3 commits

- .github/ISSUE_TEMPLATE Add hands-on contents 5 days ago
- docs Add hands-on contents 5 days ago
- moder
- notebooks
- .giti

① プログラミング演習でエラーが発生したときはIssuesへ
② Notebookなどの修正はPull requestsへ
③ 内容についての感想や質問はDiscussionsへ

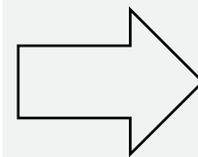
ML Enablement Seriesの動画

機械学習モデルをビジネス価値につなげる方法を全力で解説！

Light Part (本動画シリーズ)

製品やサービスに機械学習を導入するプロジェクトの進め方

<https://bit.ly/3M1F9as>



Step Up!!

Dark Part

機械学習モデルの開発や運用をマネージドサービスで効率的に行う方法

<https://bit.ly/3927PCN>



資料集・お問合せ・Special Thanks

AWSの日本語資料の場所: 「AWS 資料」で検索



お問合せ

[技術的なお問合せ](#)

[料金のお問合せ](#)

[個別相談会のお申込み](#)

AWSのハンズオン資料の場所: 「AWS ハンズオン」で検索



Special Thanks

- 音楽素材: [PANICPUMPKIN様](#)

参考文献

1. 木田浩理, 伊藤豪, 高階勇人 and 山田紘史. [データ分析人材になる。目指すは「ビジネスストラ
ンスレーター」](#). 2020.
2. 有賀康顕, 中山心太 and 西林孝. [仕事ではじめる機械学習 第2版](#). 2021.
3. 河本薫. [データ分析・AIを実務に活かす データドリブン思考](#). 2022.
4. 藤井亮宏. [現場で活用するための機械学習エンジニアリング](#). 2021.



Thank you!