

Machine Learning Project Canvas







**Begin with this
framework!**



**How should we start a
machine learning
project?**

機械学習プロジェクトキャンバス

Machine Learning Project Canvas

目的・目標 Purpose/Goal		展開性・副次的な効果 Expansion/Secondary Goal			
データ Data <ul style="list-style-type: none"> • Labeled • Unlabeled 		検討時の計算手法・インフラ Algorithms/Infrastructure for Trial	成功の指標 Metrics of Success	予測の利用法 Actions Based on the Prediction	利用者 User Segments
		データ補強 Data Enhancement <ul style="list-style-type: none"> • Annotation • Simulation 		最終システム形 UI/Systems for End Users	
オープン戦略 Open Strategy <ul style="list-style-type: none"> • Open data • Trained models • Communities 		過去の知見・アドバイザー Past Knowledge/Professional Advisors		モデル更新・メンテナンス Model Update/Maintenance	
					

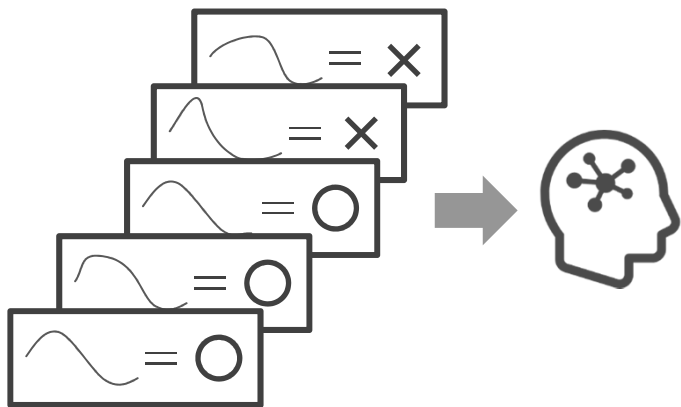
Introduction

機械学習とは?

What is machine learning?


学習

過去のデータからパターンを学習します。データサイエンスの専門家と速い計算機が必要です。



推論

過去のパターンに照らして予測します。ユーザの実情に合わせた回答や使い方が要求されます。



特徴

機械学習はデータからパターンを学ぶ手法です。データが多いほど細かなパターンの違いを精妙に学習することができます。一方で、物理法則や言語学などの理論が入っていませんので、人間にとって当たり前のことも全てデータから学ぶ必要がありますし、推論の根拠を筋道立てて説明することもできません。



機械学習に向いているプロジェクト・向いていないプロジェクト

Fitness of machine learning

機械学習向きのプロジェクト

人が処理をするのに比べて高速処理・低コストの運用ができます。ただし正解率は100%ではありません。

- 予測の速度が上がるとメリットが出る
- 予測のコストが下がるとメリットが出る
- システムに組み込みたい
- 予測に誤りがあっても許容できる
- 現場の専門家の数が足りない

人間が苦手な問題や、人によって予測が一致しない問題に適用できることがあります。

- データが多すぎて人間では処理しきれない
- 専門家でも予測が難しい (正解が後で分かる)
- 属人性が高く人によって予測が一致しない

他の方法では難しいときに、機械学習を試す価値があります。

- 理論ベースの方法論で行き詰った
- 複雑系で理論の精緻化が難しい

機械学習に向いていないプロジェクト

目的や成功基準が曖昧だと、機械学習プロジェクトの遂行は困難です。

- “予測”ではなく“理解”をしたい
- 成功のクライテリアが決められない
- 機械学習を試したいだけで必要とはしていない

従来の方法で十分な場合や、機械学習に不向きな状況もあります。

- シミュレーションで事足りている
- 基本的な統計解析で十分
- データの可視化ができれば十分
- データがない
- デジタルデータにできない
- 予測の中身を完全に説明できないと適用できない
- 精度100%でないと適用できない
- 本質的に系がどんどん変化する

機械学習プロジェクトにおける典型的な落とし穴

Typical pitfalls of machine learning projects

予測モデルの精度が上がらない

機械学習をうまく進めるために、しばしば見落としている要素があります。

- データ数が足りない
- データの中身が特定の要素に大きく偏っている
- 「これを予測したい」という正解データがない
- 正解データを作るのが大変すぎる
- 計算機が圧倒的に足りない
- 目的に応じたアルゴリズムを選べない
- その課題に関して詳細を聞ける人がいない
- 当初の目標に固執しすぎた
- 公開データを転用できることに後で気付いた
- 実はシミュレーションでデータを作れた
- 想定したよりコストと期間が掛かり頓挫した

検証試験の先に進まない／現場で定着しない

小規模のPoC (Proof of Concept) では良好な結果が出たものの、実際の現場で活用するに至らないことはよくあります。その原因は以下のことが多いのではないのでしょうか。

- 実はユーザがいなかった
- 機械学習の推論結果の活用方法がピンと来なかった
- 実は今のやり方で何の問題もなかった
- 使いにくくて放棄された
- 検証試験の「成功」の基準が独りよがりだった
- 試験が小規模すぎて現実の問題を反映していなかった
- 小規模試験のテストユーザが現実のユーザを代表していなかった
- 現場の意思決定者がプロジェクトに参加していなかった
- 検証の間に現場の状況が変化していた
- 予測モデルのメンテナンスが大変すぎた
- 運用システムの面倒を見る人がいなかった
- 今のやり方と違いすぎて変更のリスクを評価できなかった
- 確率的な考え方が理解されなかった

理想的な機械学習プロジェクトの進め方

Ideal steps of machine learning projects

1

キャンバスを埋める

- みんなで埋める
- リアリティを重視する
- 不確定でも書いてみる

2

小さく始める

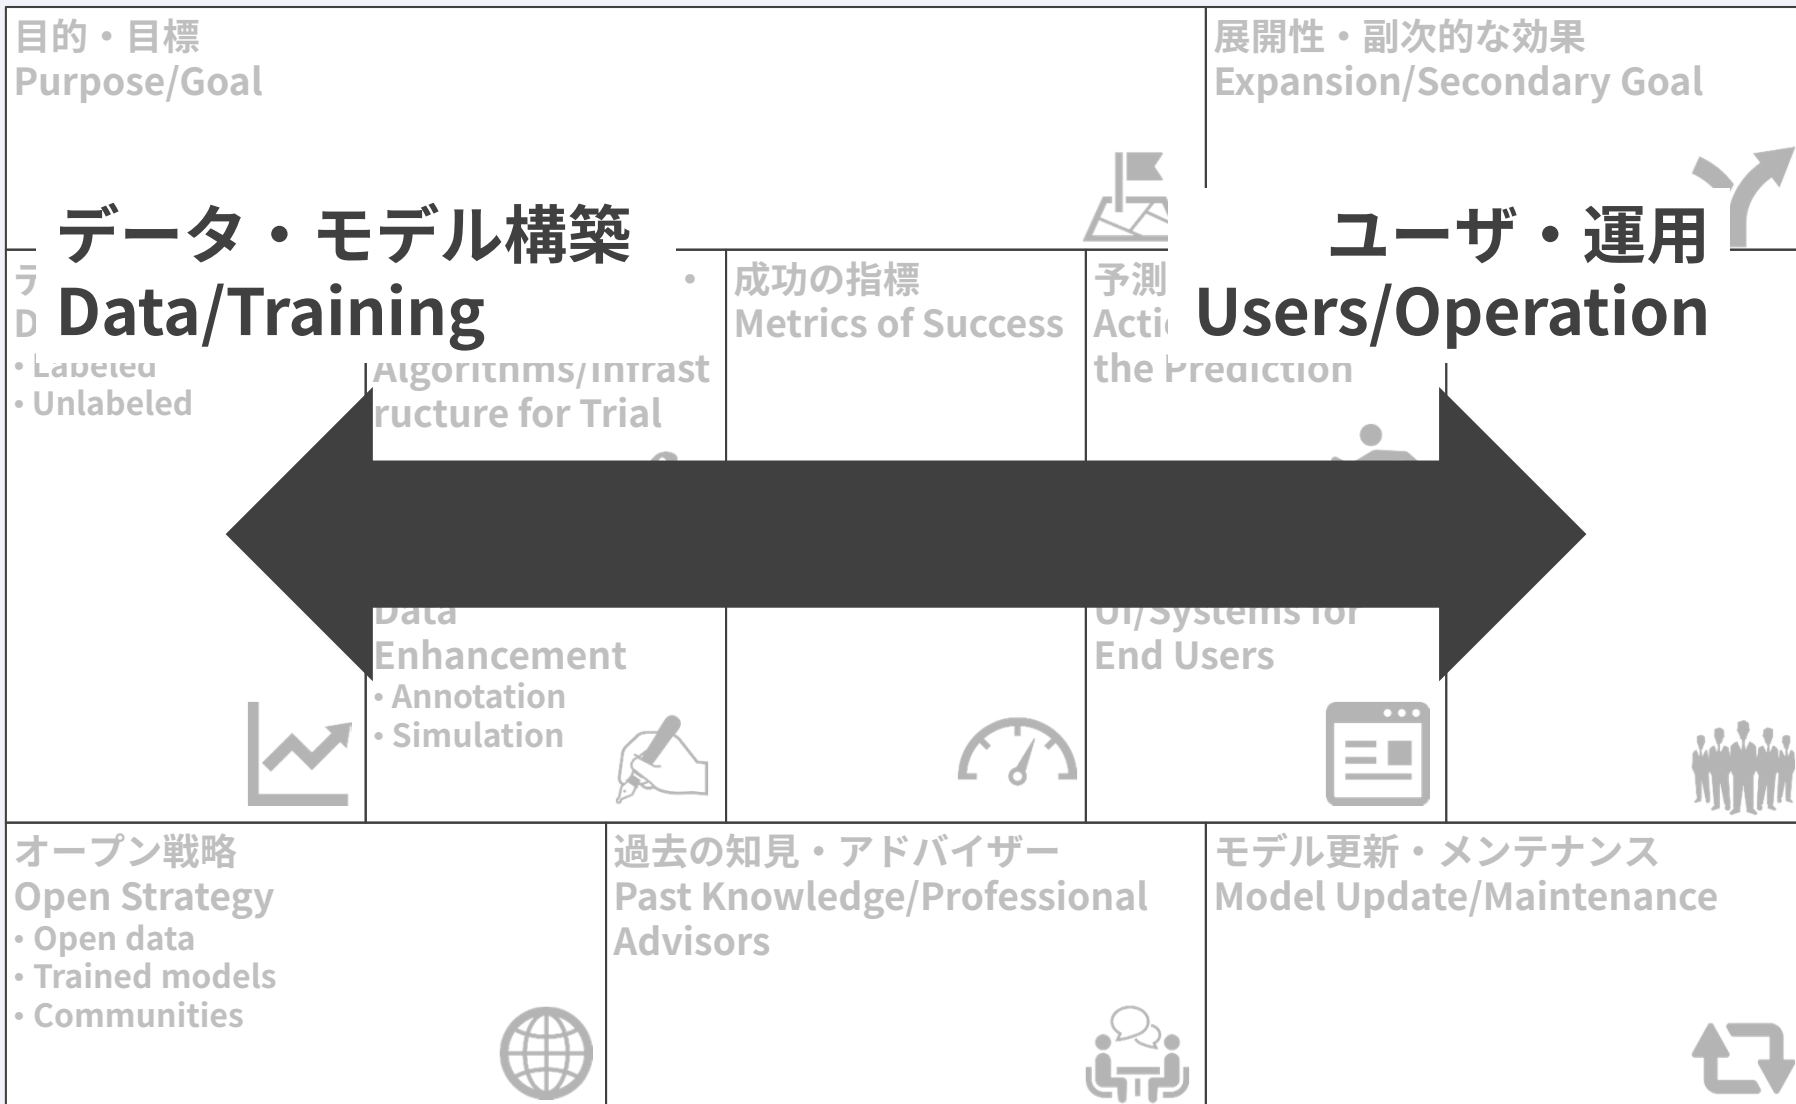
- コントロールできる範囲で試す
- こまめにフィードバックする
- ときどきキャンバスを修正する

3










実問題で運用する

- ユーザ中心の運用を行う
- 短期で効果を実感するように
- 運用計画を織り込む

機械学習プロジェクトキャンバス Machine Learning Project Canvas



埋める順番 Order to fill in

目的・目標 Purpose/Goal		展開性・副次的な効果 Expansion/Secondary Goal		
				
データ Data • Labeled • Unlabeled	検討時の計算手法・インフラ Algorithms/Infrastructure for Trial	成功の指標 Metrics of Success	予測の利用法 Actions Based on the Prediction	利用者 User Segments
				
		Enhancement • Annotation • Simulation		
オープン戦略 Open Strategy • Open data • Trained models • Communities		過去の知見・アドバイザー Past Knowledge/Professional Advisors		モデル更新・メンテナンス Model Update/Maintenance
				

Each cell



目的・目標 Purpose/Goal

内容

ほとんどのケースで異分野の専門家が協業する機械学習のプロジェクトでは、客観的で誤解のない目的・目標を定めることが重要です。目的・目標は後に変更されても構いません。本項目に書かれた内容を通じて**コミュニケーションが成立することが必須要件**になります。

機械学習における位置付け

機械学習とは、情報を入力したときに情報を返す技術です。また、技術の性格上かならず誤差を含みます。よくできた機械学習によってここで定めた目標にどれだけ到達できるのかを議論することは非常に重要です。

例

- 異常が起こる48時間前までに予兆検知に成功する。
- 目視チェックに掛かる人間の工数を90%以上削減する。



展開性・副次的な効果 Expansion/Secondary Goal

内容

プロジェクトの目標は、あくまでプロジェクトが成功することです。しかしこの取り組みを通じて学びたい事柄や他のケースに展開できそうな項目があれば記載します。

機械学習における位置付け

機械学習は本質的に分野横断的な技術なので、少しの抽象化をすることで展開可能性が大きく増します。

また、新しい技術の導入を通じて得られる学びそのものが、副次的な目的としてしばしば挙げられます。

例

- 品質検査の画像解析に用いた学習済みモデルを、類似の製品の検査に転用する
- 機械学習を取り入れたR&Dから、データ管理の在り方を逆に設計する



成功の指標 Metrics of Success

内容

先に定めた目的・目標を評価するための客観的な指標です。機械学習プロジェクトにおける成功を判断するには、可能な限り定量的で、かつ計算機で評価できる指標である必要があります。

機械学習における位置付け

機械学習プロジェクトの指標は自明ではありません。しばしば変更が入りますし、それは自然なことです。しかし、この指標を目指してデータサイエンティストはチューニングを行いますので、よく議論して決める必要があります。

例

- 過去の異常をROC曲線のAUC値0.85以上で48時間前に検知できる。
- 不良品を100%検知できる閾値において、良品の偽陽性率を10%以内に抑える。



予測の利用法 Actions Based on the Prediction

内容

機械学習システムが完成し、実際に予測が行われたときにユーザが起こすアクションを記載します。大きく分けると、予測結果を人間が受け取り実行に移す場合と、機械が受け取り自動的にアクションを起こす場合があります。

機械学習における位置付け

予測結果の利用法から逆算することで、必要な精度や所要時間のイメージが見えてきます。

例

- 品質検査の画像診断を行い、機械学習モデルが不良と判断したもののみ専門家が目視チェックする



データ Data

内容

プロジェクトに用いるデータを記載します。

データには2種類あります。例えば画像解析であれば、画像(説明変数, Xと表記されることも多い)と、それが表す内容(目的変数, ラベル, Yなどと表記されます)です。

機械学習における位置付け

機械学習プロジェクトの成否の95%以上はデータで決まります。データの量が多い方が精度が上がります。一般的に、データが多すぎることはありません。

目的変数Yが不足していたり質が悪かったりする場合にはデータ補強(Data Enhancement)で増やすのも重要なアプローチです。

また、半教師付き学習や転移学習などの手法で、目的変数Xと紐付けられていない説明変数Xが大量にあるのが有利に働く場合があります。ですので、XとYの数が合わなくてもデータを捨ててはいけません。

例

- 品質検査の画像(説明変数X)
- 各画像に紐付いた良／不良のラベル(目的変数Y)



オープン戦略 Open Strategy

内容

公開されている情報など、社外のリソースとのかかわり方を記載します。開始時にはオープンデータなど、運用時には開発者コミュニティなどインターネットを介した関わり方が中心です。

機械学習における位置付け

特にディープラーニングでは学習済みモデルがオープンにされており、画像解析プロジェクトの多くは公開モデルの転移を試すところから始めます。

また、オープンソースを利用したり、ソフトウェアを公開してコミュニティに改良を委ねたりと、機械学習とオープンは切っても切れない関係にあります。

例

- 公開された学習済みモデルの利用



内容

プロジェクトに用いるアルゴリズムや計算資源、通信インフラなどを記載します。

市販の手法で対処可能かどうか、既知の手法で対応できそうかは資金と時間に大きく影響しますので、事前にイメージを持っておくことが重要です。

また、解釈性とアルゴリズム、機密性とクラウド利用などは密接な関係があるため、事前に制約を明らかにする必要があります。

機械学習における位置付け

機械学習で最も話題になっている活動はここです。アルゴリズムの選択、必要な計算機と通信インフラ、ストレージなどによって実行可能な環境が変わります。通常は複数の手法を試すため、詳細は不要でしょう。

例

- 画像データの分類にCNNを用いる。既存手法の応用。社内計算機 (GPU 4枚)
- 工場プロセスデータの異常検知。既知の線形モデル, AWS

内容

元のデータを補強するために何ができるかという要素をここに挙げます。データに注釈を付ける、シミュレーションでデータを検証するといった、プロジェクト全体から見て重要な活動が含まれます。

機械学習における位置付け

機械学習ではデータが全てです。従って、データの量と共に質が重要になります。また機械学習とは別の原理でアウトプットを検証することで、予測結果の信頼性は飛躍的に向上します。

例

- 画像データ内の物体認識に関し手動で正解データを作る
- 機械学習モデルの予測結果をシミュレーションで検証する



利用者 User Segments

内容

プロジェクトが成功した暁に、最終的に使うユーザです。予測能がいくら高くても使われないシステムは無価値ですので、完成後に利用されるだけでなく、当初よりユーザを想定し早期にテストに加わってもらう必要があります。

機械学習における位置付け

他の製品やサービスと同様に、機械学習でも良いものを作るためにはユーザと近い距離にいることが重要です。

例

- 工場の製造管理者
- 品質検査のオペレータ
- 営業担当者



過去の知見・アドバイザー Past Knowledge /Professional Advisors

内容

ほとんどのプロジェクトは過去に何らかの取り組みがなされており、過去の知見をあらかじめ得ておくのは成功への近道です。また、知見は文書になっていなくても専門家の頭の中にあることもあります。何でも聞けるアドバイザーを見つけるのは非常に重要です。

機械学習における位置付け

大抵の機械学習では過去の知見を直接モデルに組み込むことはできません。しかし、問題の理解が深まることでユーザの求めていることを想像できたり、よくある序盤の勘違いを減らしたりというメリットがあります。

例

- 過去に化学工学のモデリングで苦戦し諦めたことがある
- 定年した再雇用の専門家が週一で相談に乗ってくれる



最終システム形 UI/System for End Users

内容

最終ユーザが用いるためのインタフェースやインフラなどを記載します。

機械学習における位置付け

予測能が実用レベルに達しても、ユーザが使い続けるとは限りません。直感的で生産性の高いインタフェース、安価で安定したインフラなどが求められます。

例

- 製造システムからデータを取得し、機械学習、結果をブラウザで定期的に更新・表示する



モデル更新・メンテナンス Model Update/Maintenance

内容

機械学習の予測モデルの更新が必要か、長く使うにあたってメンテナンスが必要な要素は何かを記載します。

機械学習における位置付け

機械学習ではデータの更新に対して、新しいデータを取り込むことで精度が向上しますし、場合によっては古いデータを捨てる必要もあります。また、問題が変わるのに伴い予測モデルの作り方をユーザが微修正する必要もあるかもしれません。

例

- データを1日に1回付け足し予測モデルを更新する
- 製造設備の工事が行われた際には、予測能が維持されているか詳細な検証を行う

Examples

石油化学プラント 予兆検知の機械学習プロジェクトキャンバス

目的・目標 1年に1-2回程度起こる特定の異常現象に関し、事前に検知することで準備期間を設け損失を防ぐ。		展開性・副次的な効果 ・同様の現象があるプラントに展開する ・機械学習の結果を解釈することでプラントへの理解が深まる	
データ Data ・プロセスデータ: 約1,000項目, 1分刻み, 5年分 ・異常な時期と正常な時期	検討時の計算手法・インフラ ・線形回帰 ・メモリ大きめの計算機	成功の指標 ・72時間前にある程度正確*にプラント異常の予知ができる *異常を8割程度見つけ, かつ偽陽性は年に数度以下に抑える	予測の利用法 試薬を準備し, 異常開始と同時に追加添加する
	データ補強 (なし)	モデルはプラントの専門家の解釈が可能なものとする	最終システム形 製造システムの計器に組み込み日々表示
オープン戦略 Open Strategy (なし)		過去の知見・アドバイザー ・化学工学で数年間の取り組みの結果, 複雑すぎる系のモデリングを断念 ・外部ベンダーにデータ解析を依頼したが, あまりにブラックボックスで現場導入不可と判断	
		モデル更新・メンテナンス モデル更新が必要かもしれないが, 現時点では判断できず	

工場の設備劣化検出の機械学習プロジェクトキャンバス

目的・目標 化学工場の配管劣化を検出し安全の担保，製造トラブルの回避を行う		展開性・副次的な効果 ・他の工場に展開する ・他の設備に展開する	
データ Data ・配管画像約5,000枚 ・それぞれ配管の劣化度(3段階)	検討時の計算手法・インフラ ・社内GPUサーバ	成功の指標 ・即時要対応な状態の見逃しは0%に抑え，かつ偽陽性率が10%以下	予測の利用法 劣化と判定された配管に専門家を派遣し精密検査する
データ補強 (なし)	最終システム形 ・設備管理者が写真を撮影するとシステムが自動的に判定し結果を返す ・将来はAR化し通常パトロール員でも検出可能に	利用者 設備管理者 定期的に設備の点検を行い，システムの結果に応じて精密検査を行う 将来：パトロール員 ARデバイスやアクションカメラなどを装着しパトロールを行う	
オープン戦略 Open Strategy 一般的な学習済み画像認識モデルの利用	過去の知見・アドバイザー ・誤判定した画像に関し，画像のみから判断できる例なのか専門家をアサイン	モデル更新・メンテナンス 継続的に新データを取り込み，バッチでモデル更新	

質問応答システムの機械学習プロジェクトキャンバス

目的・目標 過去の専門家の応答を学び、顧客の質問に回答するシステムを構築する		展開性・副次的な効果 ・多言語化し海外展開 ・他商材への展開		
データ Data ・専門家のQA履歴約4,000件 ・社内で作成した教科書上下2冊	検討時の計算手法・インフラ ・古典NLP+機械学習 ・オンプレ/クラウドのVM	成功の指標 ・質問文をクエリとし、正解がスコア上位5つの中に含まれる確率が95%以上	予測の利用法 システムの回答候補から正解を選択し、文章化して顧客に回答する	利用者 技術サービススタッフ 基本的な商品知識があり、時間を掛けて調べれば分かる。 精度が向上すれば代理店の担当者様に使って頂く 商品知識は広く浅いが、顧客の専門的な質問に即座に答えたい
	データ補強 ・辞書作成 ・回答結果のランキング評価		最終システム形 ・Webベースの検索システム ・精度が向上すればChatbot化も考慮	
オープン戦略 Open Strategy ・化学用語辞書はWikipediaなどのオープンデータも利用		過去の知見・アドバイザー ・コールセンターの案件に類似		モデル更新・メンテナンス ユーザのフィードバックを用いリアルタイムにモデル更新 QA履歴もバッチで追加

Tetsu Isomura, Risa Nishiyama, Yu Ito
Digital Transformation Group
Mitsubishi Chemical Holdings Corporation
2019/04/17 (1st edition)