

# データ解析・AI を使ってみよう

トルヴェ アントワン

trouve@aibod.com  
(株)AIBOD CTO

2016/10/26



## (株)AIBODの紹介

- ・住所：福岡市中央区大名
- ・活用：
  - ・解析案件を受ける
  - ・カスタム解析ソリューションを実装
  - ・会社向けセミナー（3日間AI合宿）

興味のある企業は  
ご連絡ください



## 自己紹介

**名字**：トルヴェ (Trouvé) **名前**：アントワン (Antoine)

**出身**：ポワチエ (フランス)

**大学**：ボルドー大学 (修士) ・九州大学 (博士)

**職歴**：九州大学助教 (旧) ・株式会社AIBOD CTO (現)

講義

(1時間)

+

ハンズオン

(2時間半)

# 概要

## ① データ解析・AIをビジネスに活用する

- いい活用のためのヒント

## ② データ解析の基本

- データ解析のフロー
- 用語：モデル、説明変数・・・
- 基本的なアルゴリズムのイメージ

## ③ Rについて

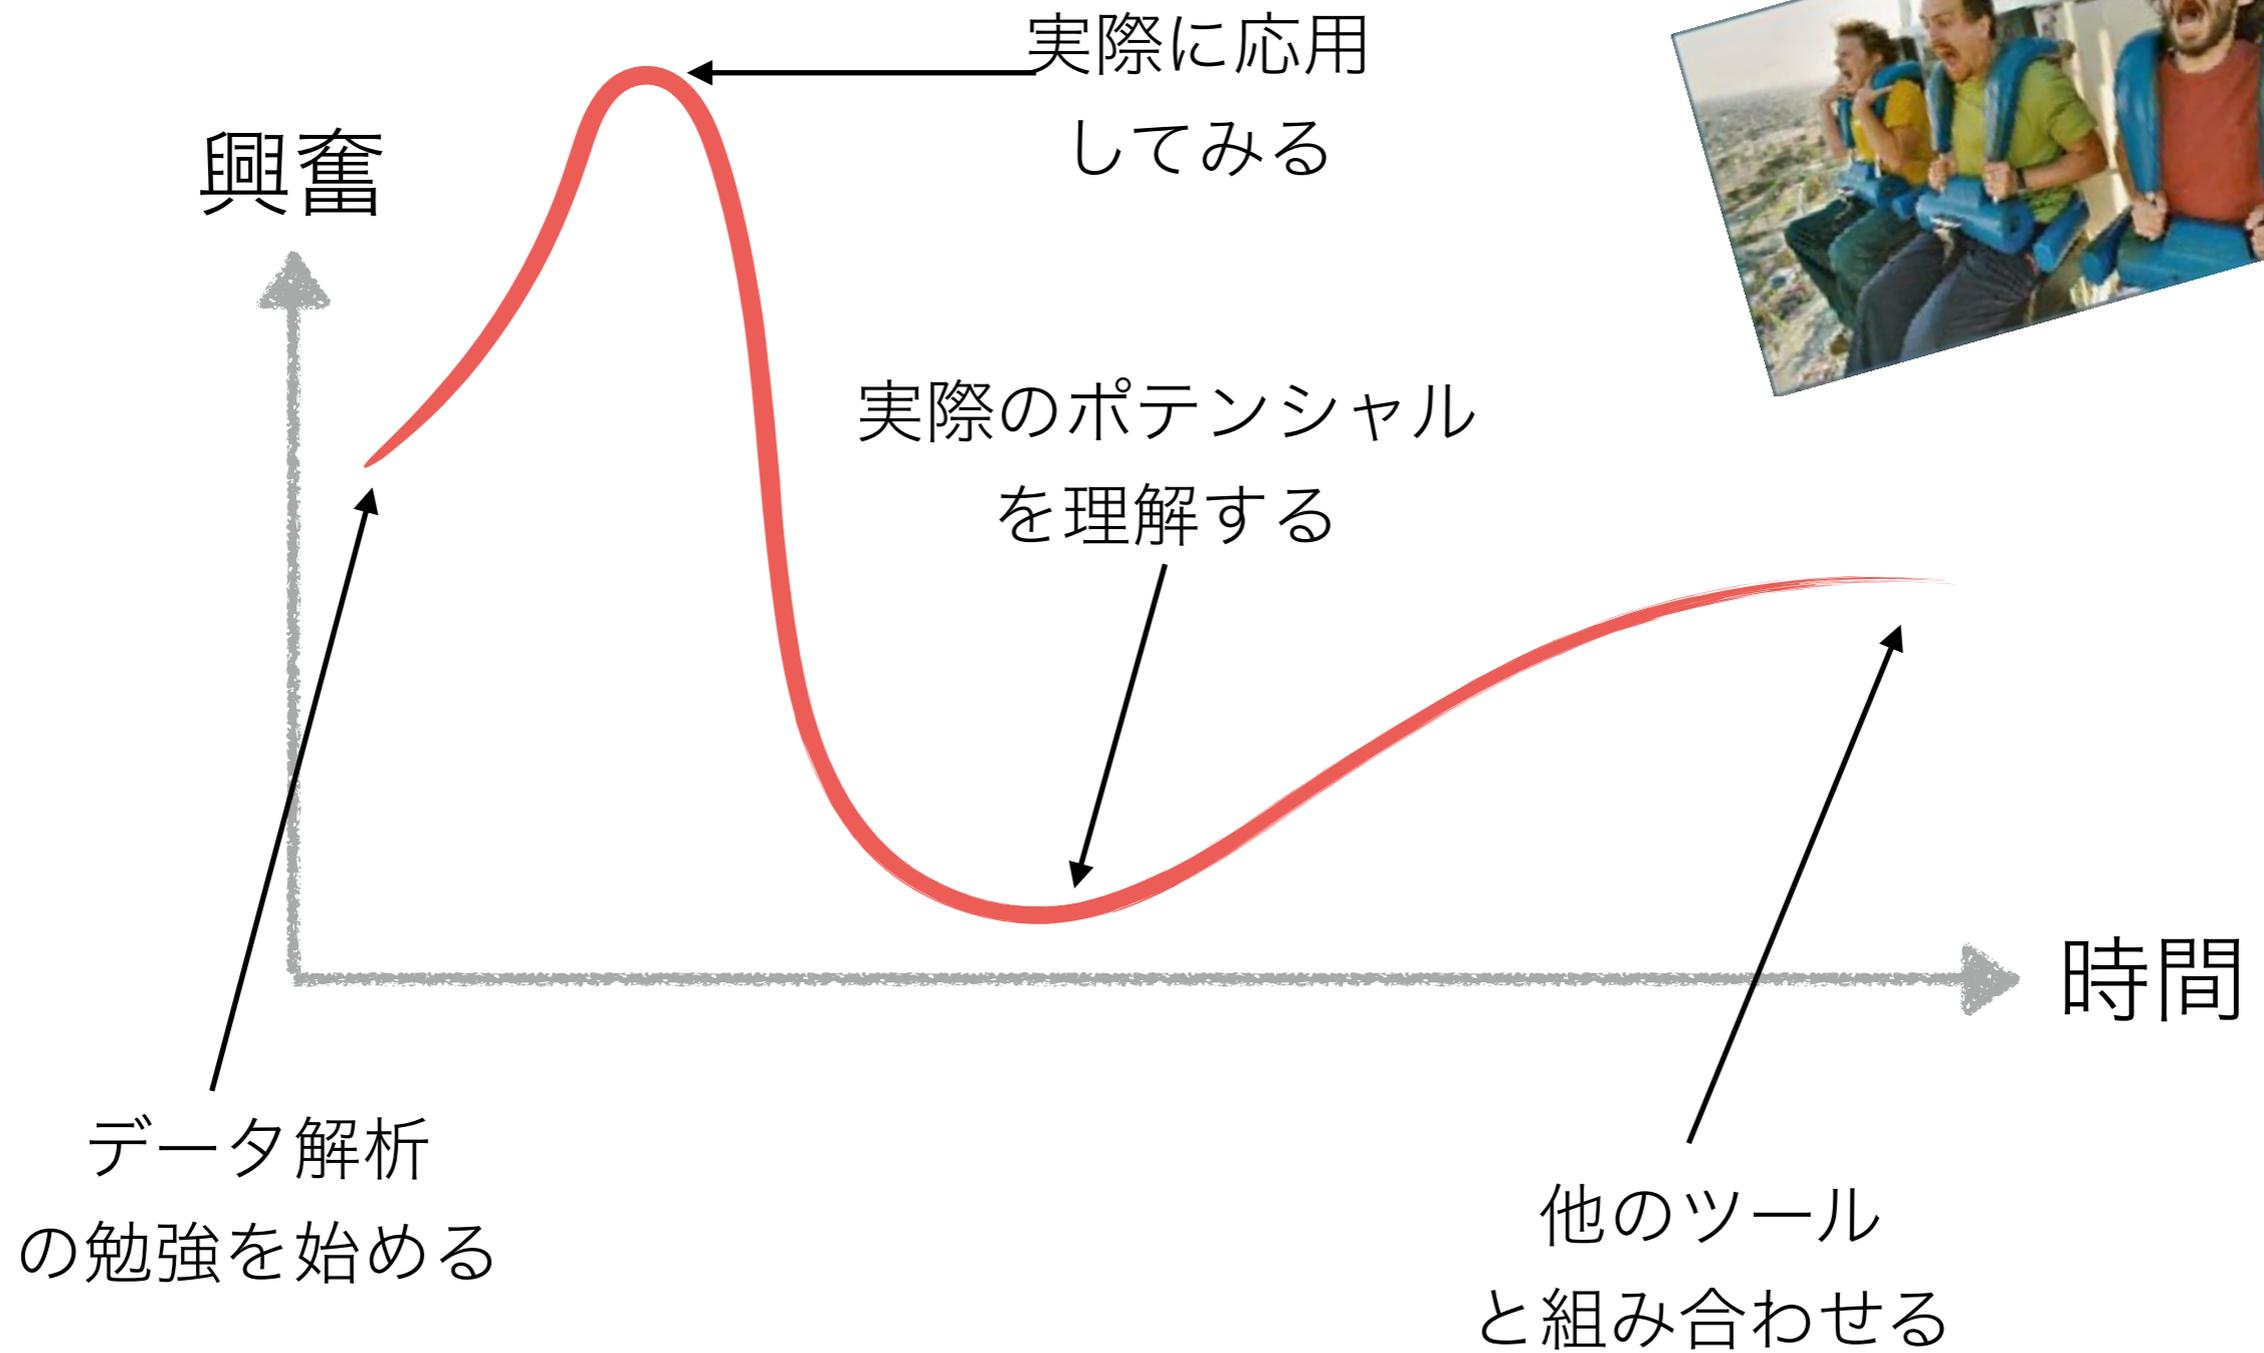
- 機械学習用ツールについて
- Rとは

# ① データ解析・AI をビジネスに活用する

# 応用事例

- マーケティング
  - LTV(リピーターなど)予測
  - 客の解約確率予測
  - マーケットセグメント分析
  - キャンペーンターゲティング
- セールス
  - 売買成功確率予測
- 売り上げ予測
- サプライ管理
  - 焦点ニーズ予測
- リスク管理
  - 不正行動検出
- 人事
  - ターンオーバー
  - 履歴書分類
  - 研修推薦 (人材育成)

# データ解析のジェットコースター



# ジェットコースター

## 原因①

魔法ではない

アルゴリズムが魔法のように  
答えを見つけてくれる

# データ解析は簡単にみえる

未経験者の想像



# データ解析は簡単にみえる

未経験者の想像



実際は  
問題



# ジェットコースター 原因②

**VALUEに繋がる必要がある**

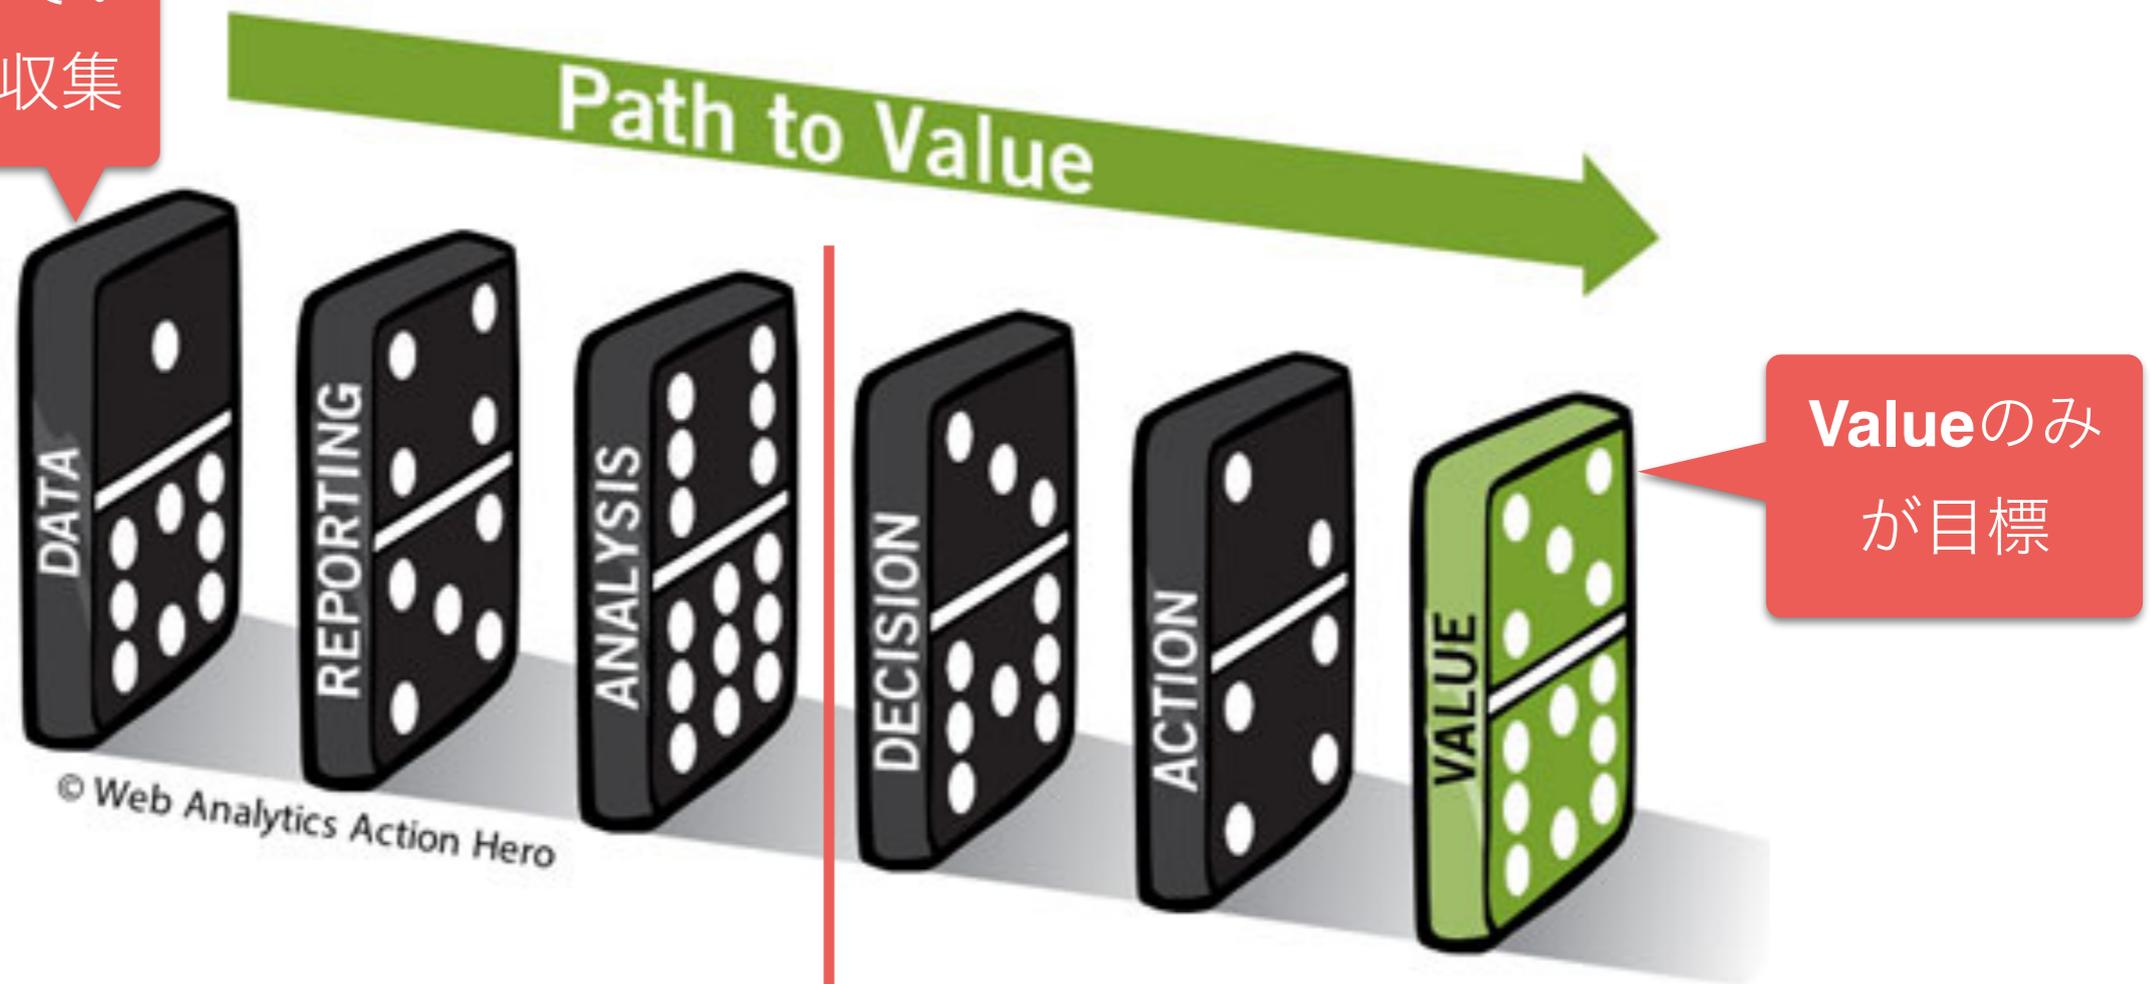
多くの企業が持っているデータ応用のイメージはこれ



# 解析は**Value**と繋ぐ必要がある

最初からValueと解析の関係を明らかにする必要がある

Valueと繋がっているデータのみ収集



技術者の責任

マネージャーの責任

データソリユーション

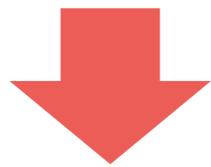
構築のフロー

# 問題からシステムへ

- 「Setupland」：Valueと繋がっている解析フローを設計し、プロトタイプを納品する場所
- 「Actionland」：実際Valueを作る場所



新しい問題  
(+データ)



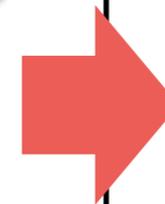
解析フローを設計

データ探索と  
も言う



プロトタイプ

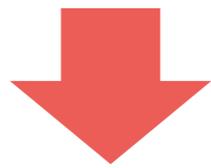
POC



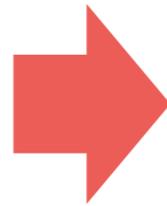
本番システム

# 問題からシステムへ 必要なソフト

新しい問題  
(+データ)



解析フローを設計



POC



本番システム

- ・ 使うソフト：R、Matlab、Python、BIツール
- ・ 貴重な知見：数学、統計学、情報学、応用分野(e.g.保険など)
- ・ 課題：精度向上

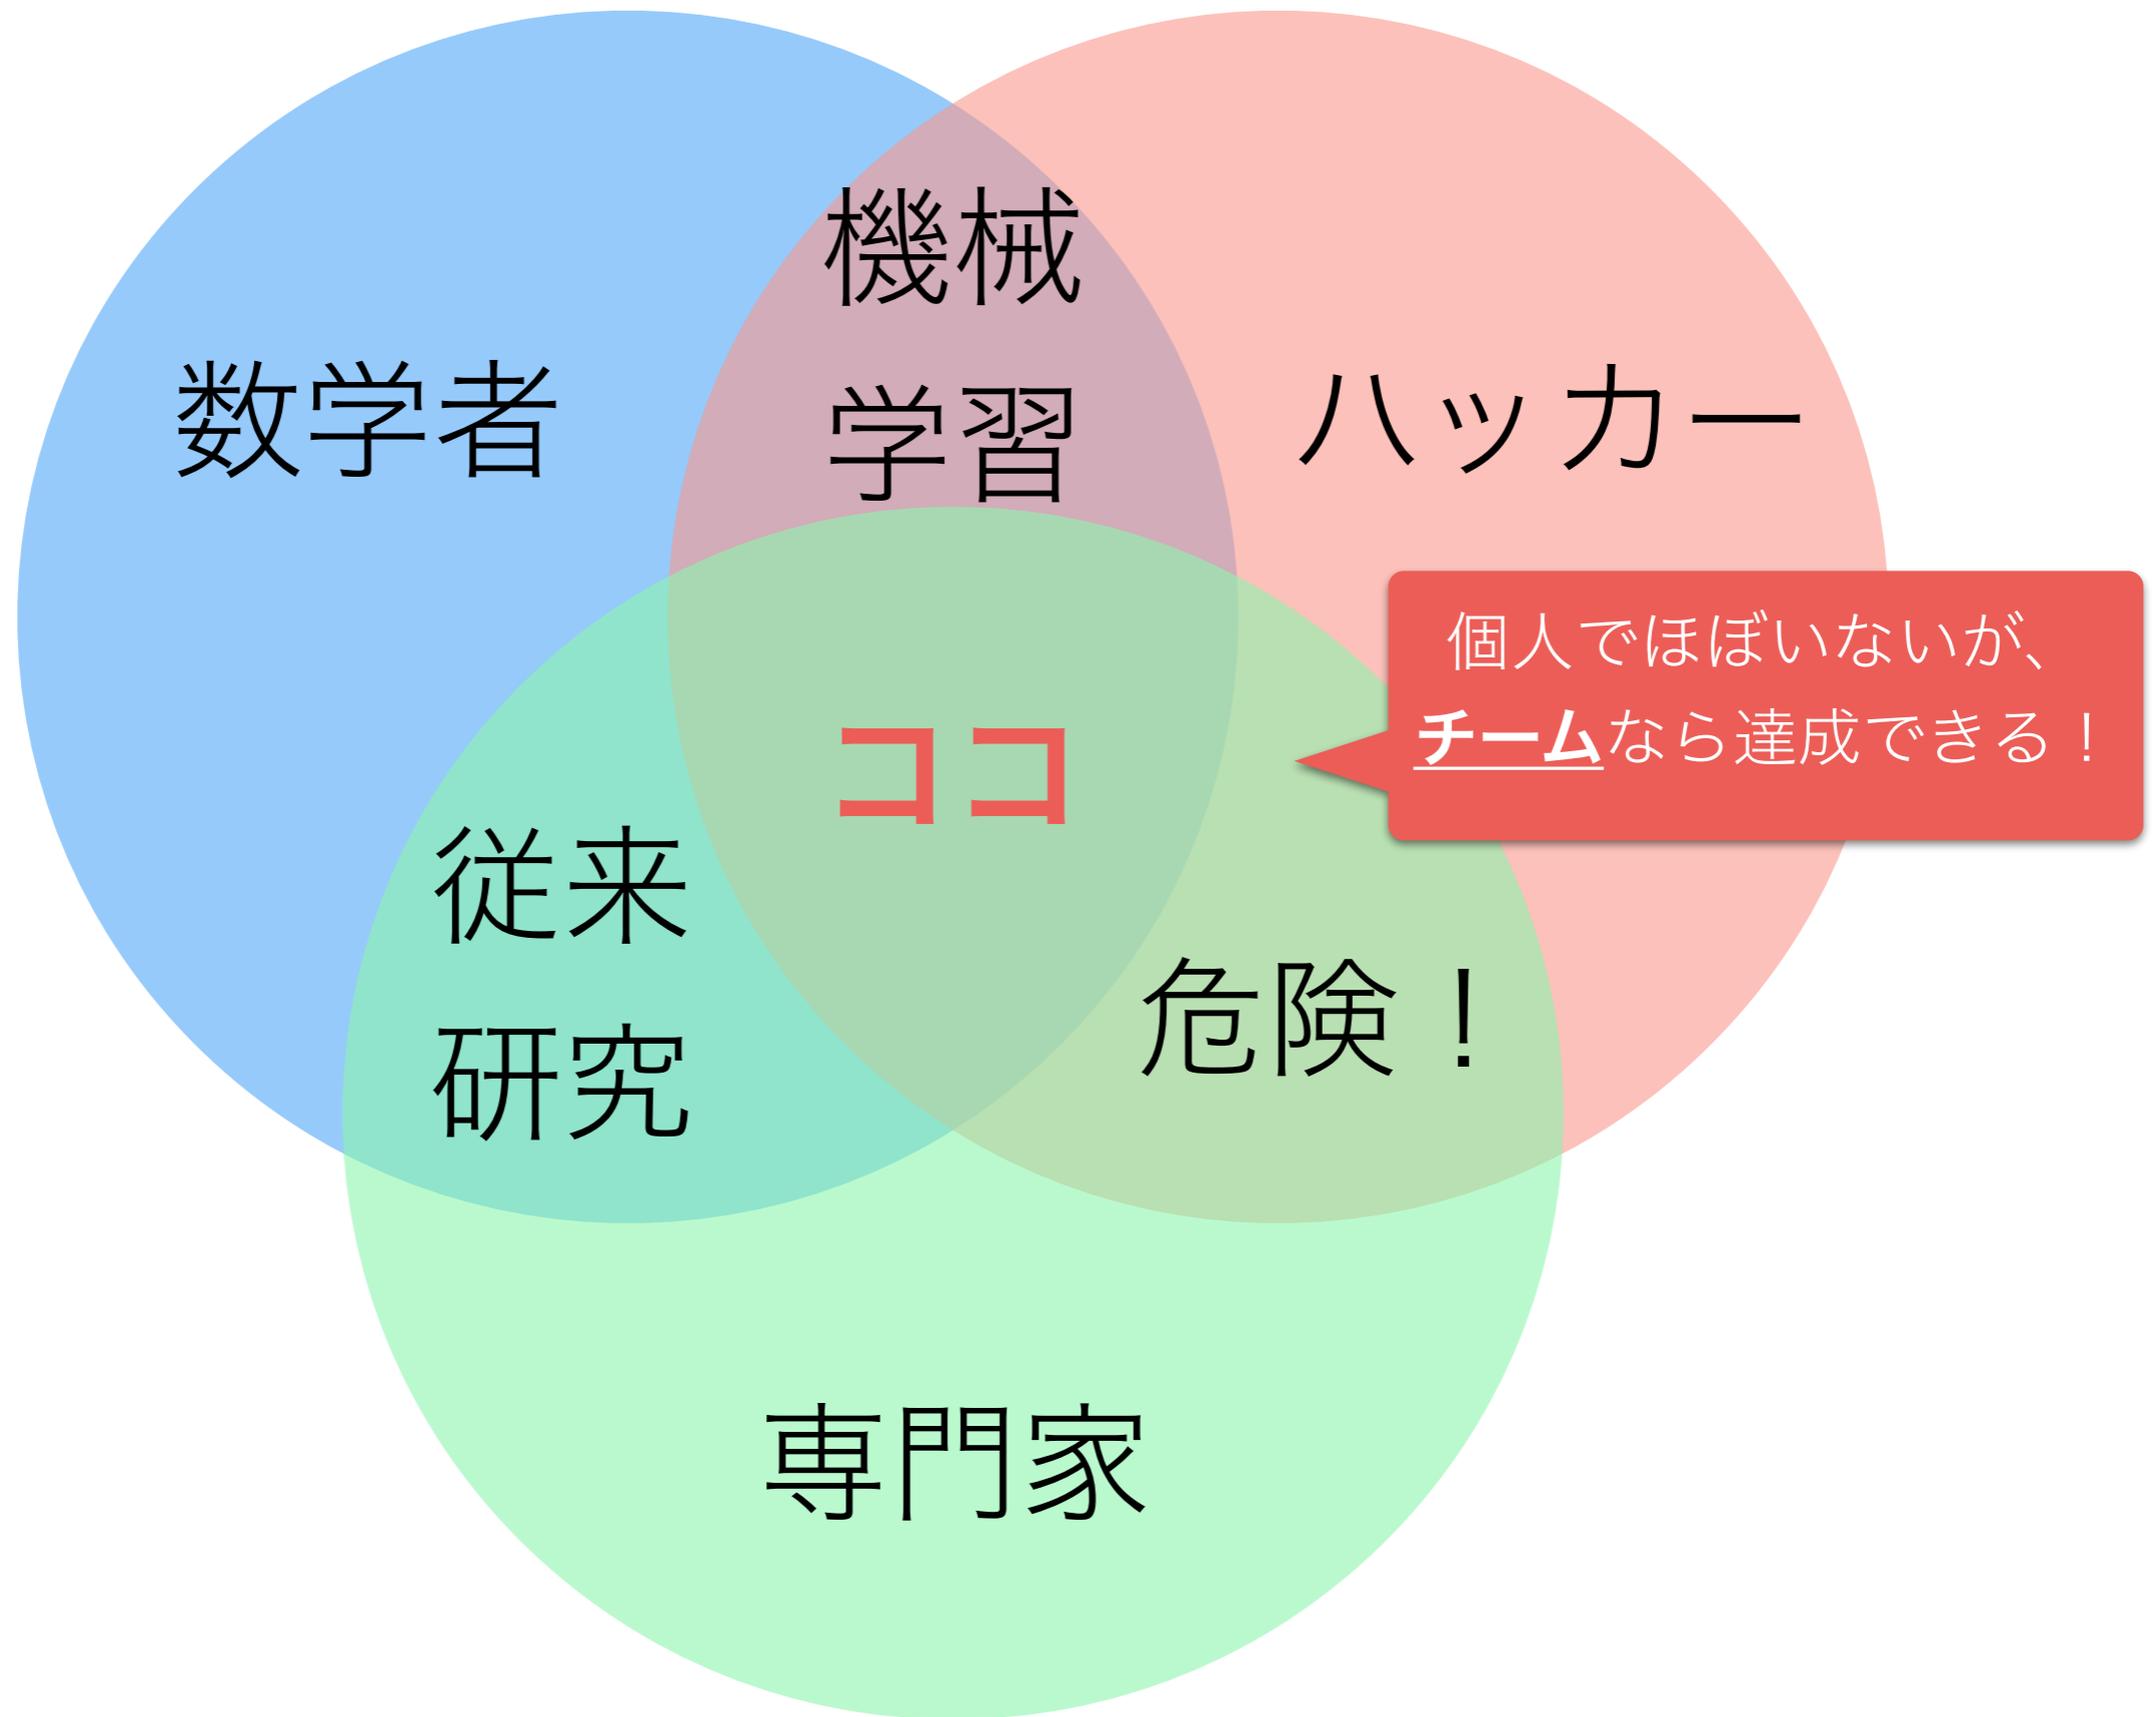
- ・ 使うソフト：Hadoop、Spark、クラウド(AWSなど)
- ・ 貴重な知見：情報学、応用分野(e.g.保険など)、システムインテグレーション
- ・ 課題：精度と性能の妥協

データ解析・AIの活用に必要な人材

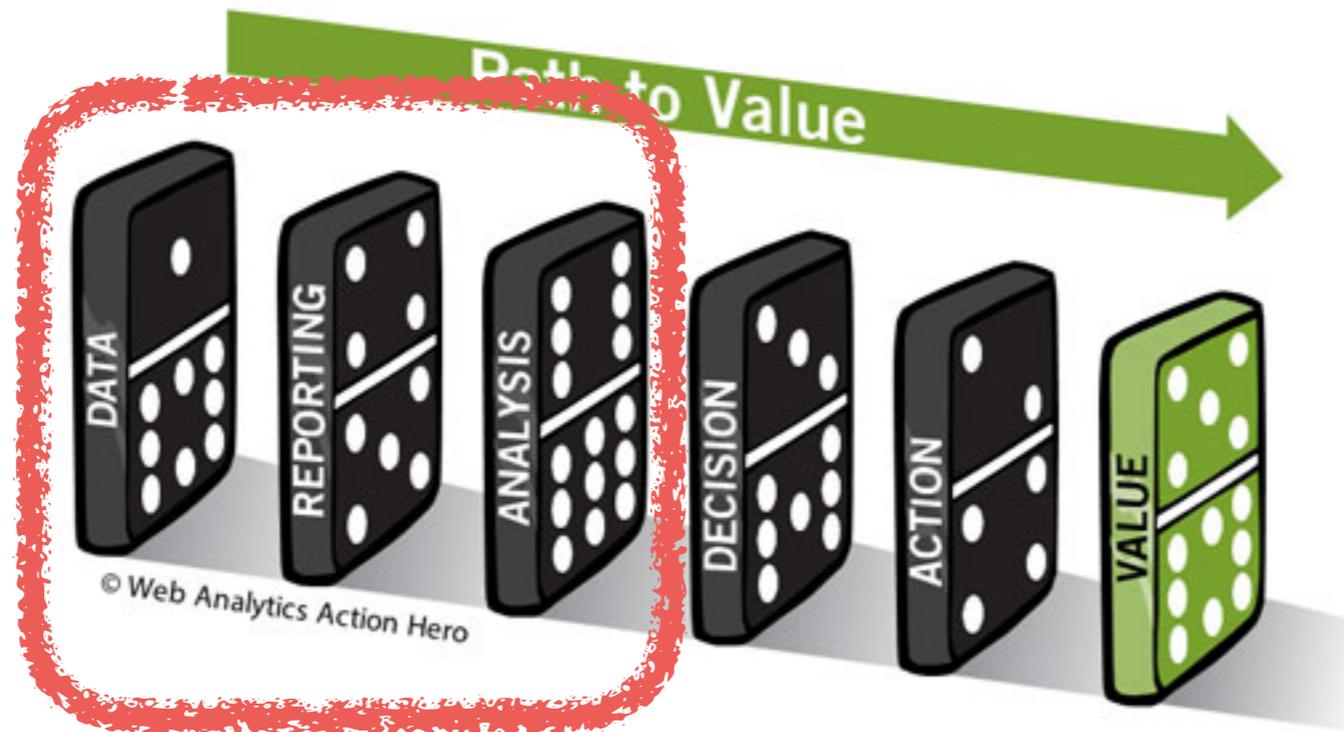
**機械学習の専門家**

**+**

**VALUEを理解する人**

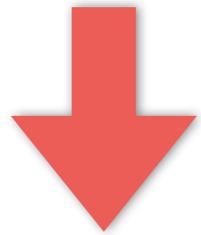


## ② データ解析の基本

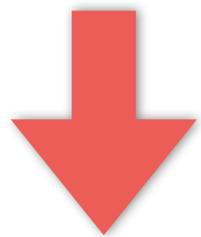


# データ利活用フロー

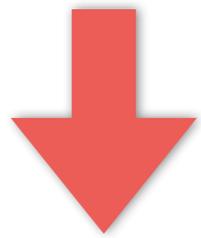
問題設定



データ取得



データ解析

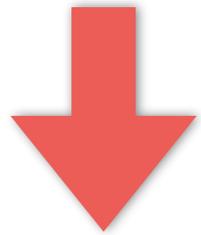


評価・結果説明

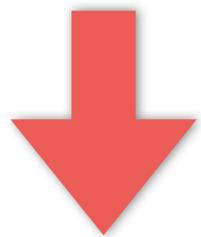
- データを収集する前に問題を設定する  
(VALUEから定義する)
- データの説明には2種類ある
  - 他の専門家に対して：誰でもできる
  - マネージャに対して：チャレンジング

# データ解析フロー

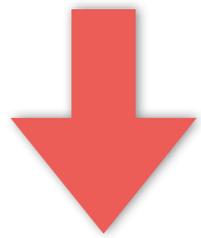
クレンジング



探索



モデル化



モデル学習

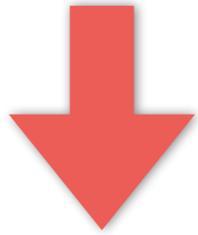
- **クレンジング**には役割が2つある：
  - 異常値の削除
  - 探索やモデル化の為のデータ変換
- **モデル化**は問題を表現すること
  - どの数値を使う？
  - どの問題の種類を使う？（回帰、分類）
  - モデル化は解析の半分以上を占める
- **モデル学習**とは
  - 実際に機械学習アルゴリズムを走らせて、精度を計算する
  - 機械学習アルゴリズムの選択はポイントではない：  
データの質（クレンジングとモデル化後）が一番重要

# 可視化について

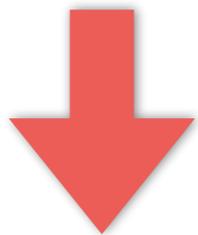
- クレンジング・解析・レポートに貴重な技術
- 可視化することによってパターンや異常値を質的に検出できる
  - 解析の方針を決めるため
  - 最終的に定量的な方法を使う
- 可視化ツールのチャレンジ：
  - 探索しながら思いついた可視化を簡単に作れるか
  - 混雑などを解決できる（例：色などを使う、対話型にする）
- 最近ではウェブテクノロジーによる可視化が人気
  - 特に「D3js」(<http://d3js.org>をご参考) ライブラリを使って
  - 対話型可視化は簡単に作れる
- 可視化はレポートにも貴重な技術
  - おすすめサイト：<http://www.informationisbeautiful.net>

# 機械学習モデルとは

説明変数



機械学習  
モデル



目的変数

- **目的変数**
  - 数字か列挙で表現する
  - 予測したい情報
- **説明変数**
  - 数字か列挙で表現する
  - 持っている情報。この情報を使って、目的変数を求めたい
- **モデル**
  - 説明変数と目的変数を結ぶ「箱」
  - 「箱」の中に数式であったり、コンピュータプログラムであったりする

# データ型・回帰問題・分類問題

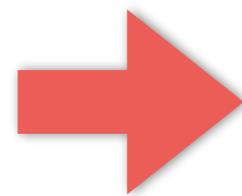
- 2種類の変数がある：数値とID型（列挙型）
- ID型の例：Yes/No、Blue/Red/Yellow、Slow/Fast
- 目的変数の型に応じて問題の種類が違ってくる：
  - 目的変数は**数値型**：回帰問題（数値を求める）
  - 目的変数は**ID型**：分類問題（クラスを求める）
- 問題の種類に応じて使える機械学習アルゴリズムも限られてくる

# 回帰問題の例：売り上げ予測

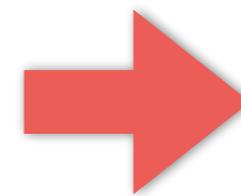
回帰モデル。アルゴリズム：

- ・ 数式型：従来回帰分析、MARS分析
- ・ アルゴリズム式：回帰木、SVR、k近傍法

説明変数  
ビジネス  
データ



機械学習  
モデル



目的変数  
売り上  
の絶対値

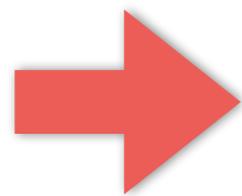
例：昨年度売り上げ（数値）、新商品個数、各商品の値段（数値）、中国マーケットを狙うかどうか（Yes/NoのID型）

# 分類問題の例：常連になるか 予測

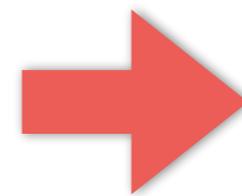
分類モデル。アルゴリズム：

- ・ 決定木、SVR、ニューラルネットワーク、k近傍法

説明変数  
客データ



機械学習  
モデル



目的変数  
常連になる？  
Yes/No

例：来店時間帯（ID型）、お店で過ごした時間（数値）、買い物の額（数値）、Pontaカードの有無（ID型）

# ID型と数値型の関係

- IDは数値へ変換できるが、おすすめしない
  - 例：Yes→0、No→1
  - しかし、選択した数値によって解析結果が違ってくる：気持ちがよくない
- 数値型はID型に変換できる
  - 例： $0 \leq x \leq 10 \rightarrow \text{Low}$ 、 $10 < x \rightarrow \text{High}$
  - しかし、情報量が減るので、注意が必要
  - 目的変数の場合は問題を単純化する（回帰が失敗した時に）
  - 説明変数の場合は雑音をなくすためにありえる

僕はよくする。問題は回帰問題から分類問題になる

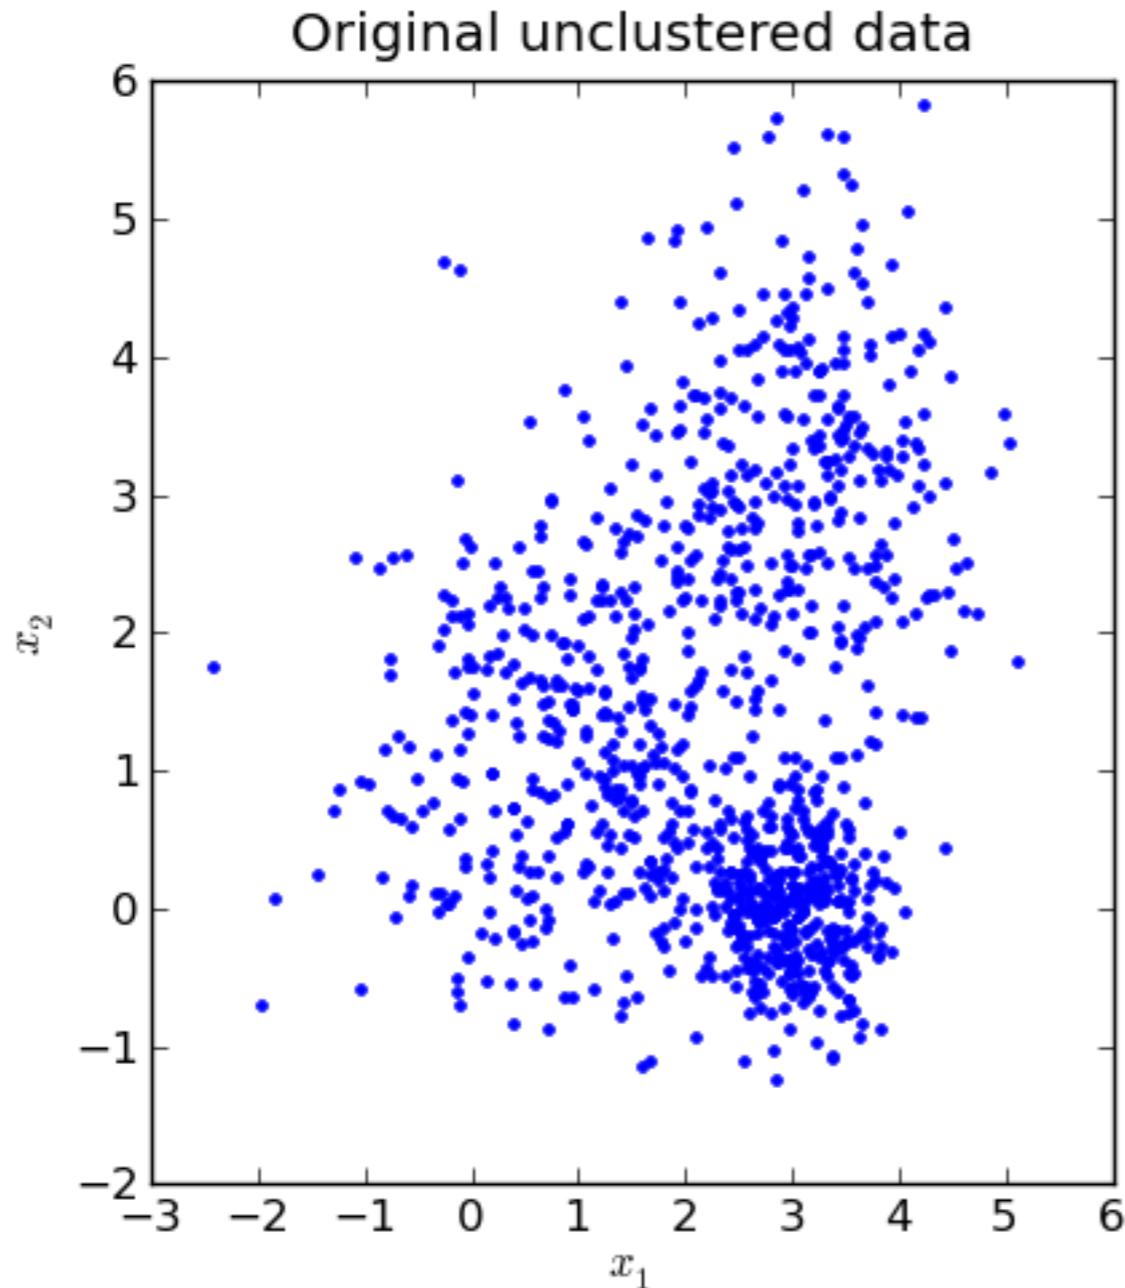
おすすめしない：  
僕はしたことない。

# 教師なし学習について

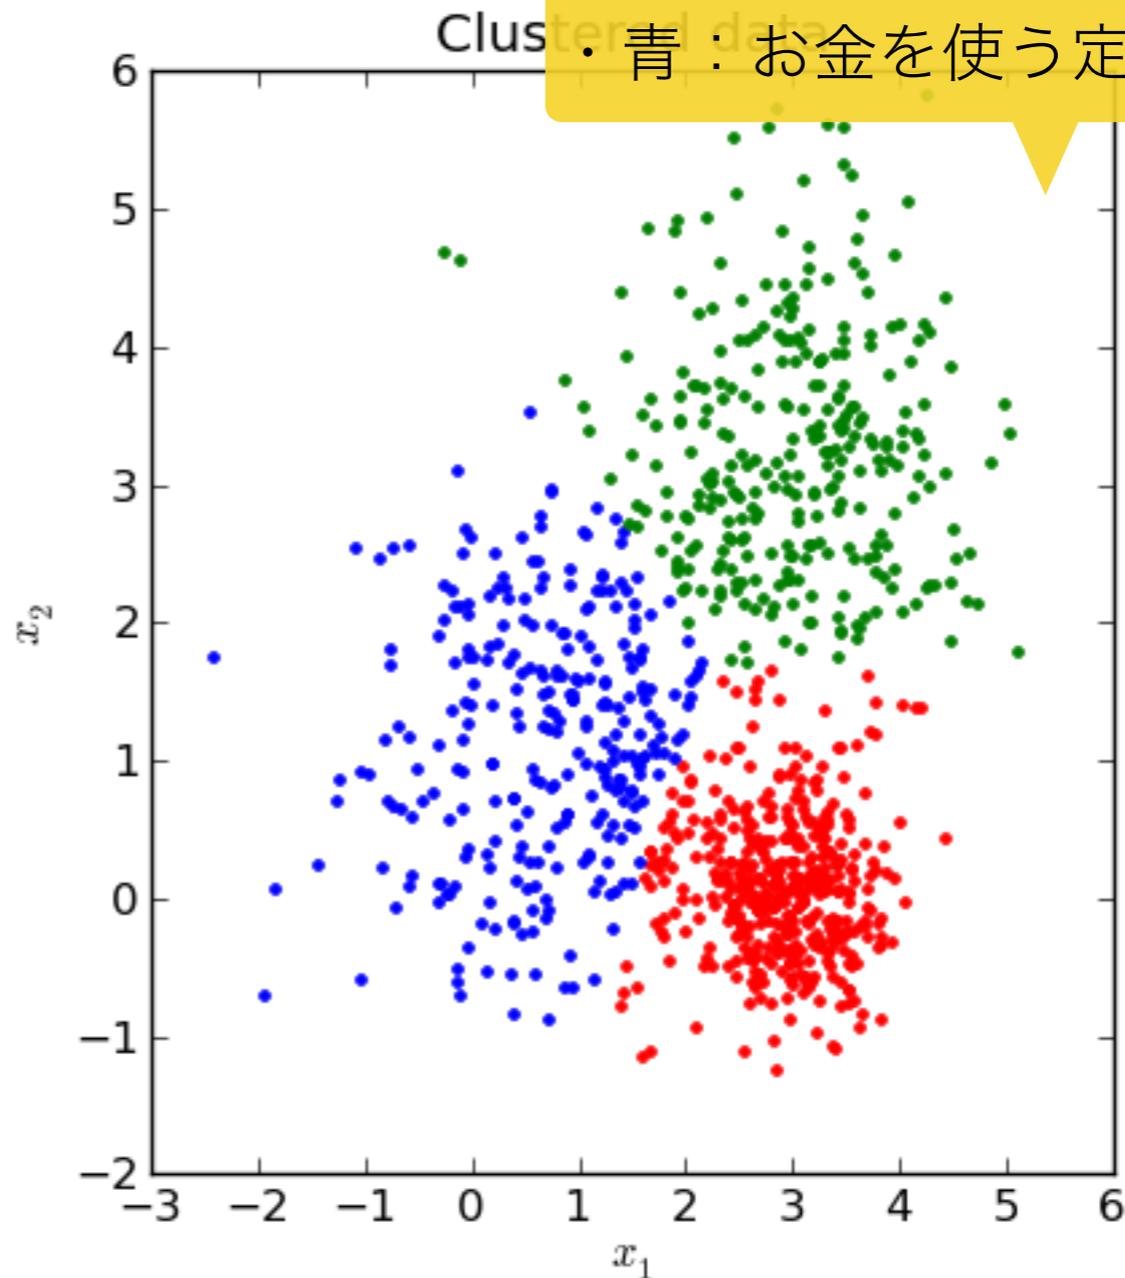
- 目的変数の有無に応じて機会学習は2種類で分ける
  - 目的変数がある：**教師あり**学習。正解があって、機械学習モデルで求める
  - 目的変数がない：**教師なし**学習。データにパターンを見つきたいが、どのパターンがあるかどうか以前にわからない
- 教師なし学習の主な種類：
  - クラスター分析。例：カスタマーのセグメント化など
  - 異常検出。例：クレジットカード不正利用検出

# クラスタ分析の例

- 例えば：
- ・赤：定連にならない客
  - ・緑：定連になるが、お金が使わない客
  - ・青：お金を使う定連になる客

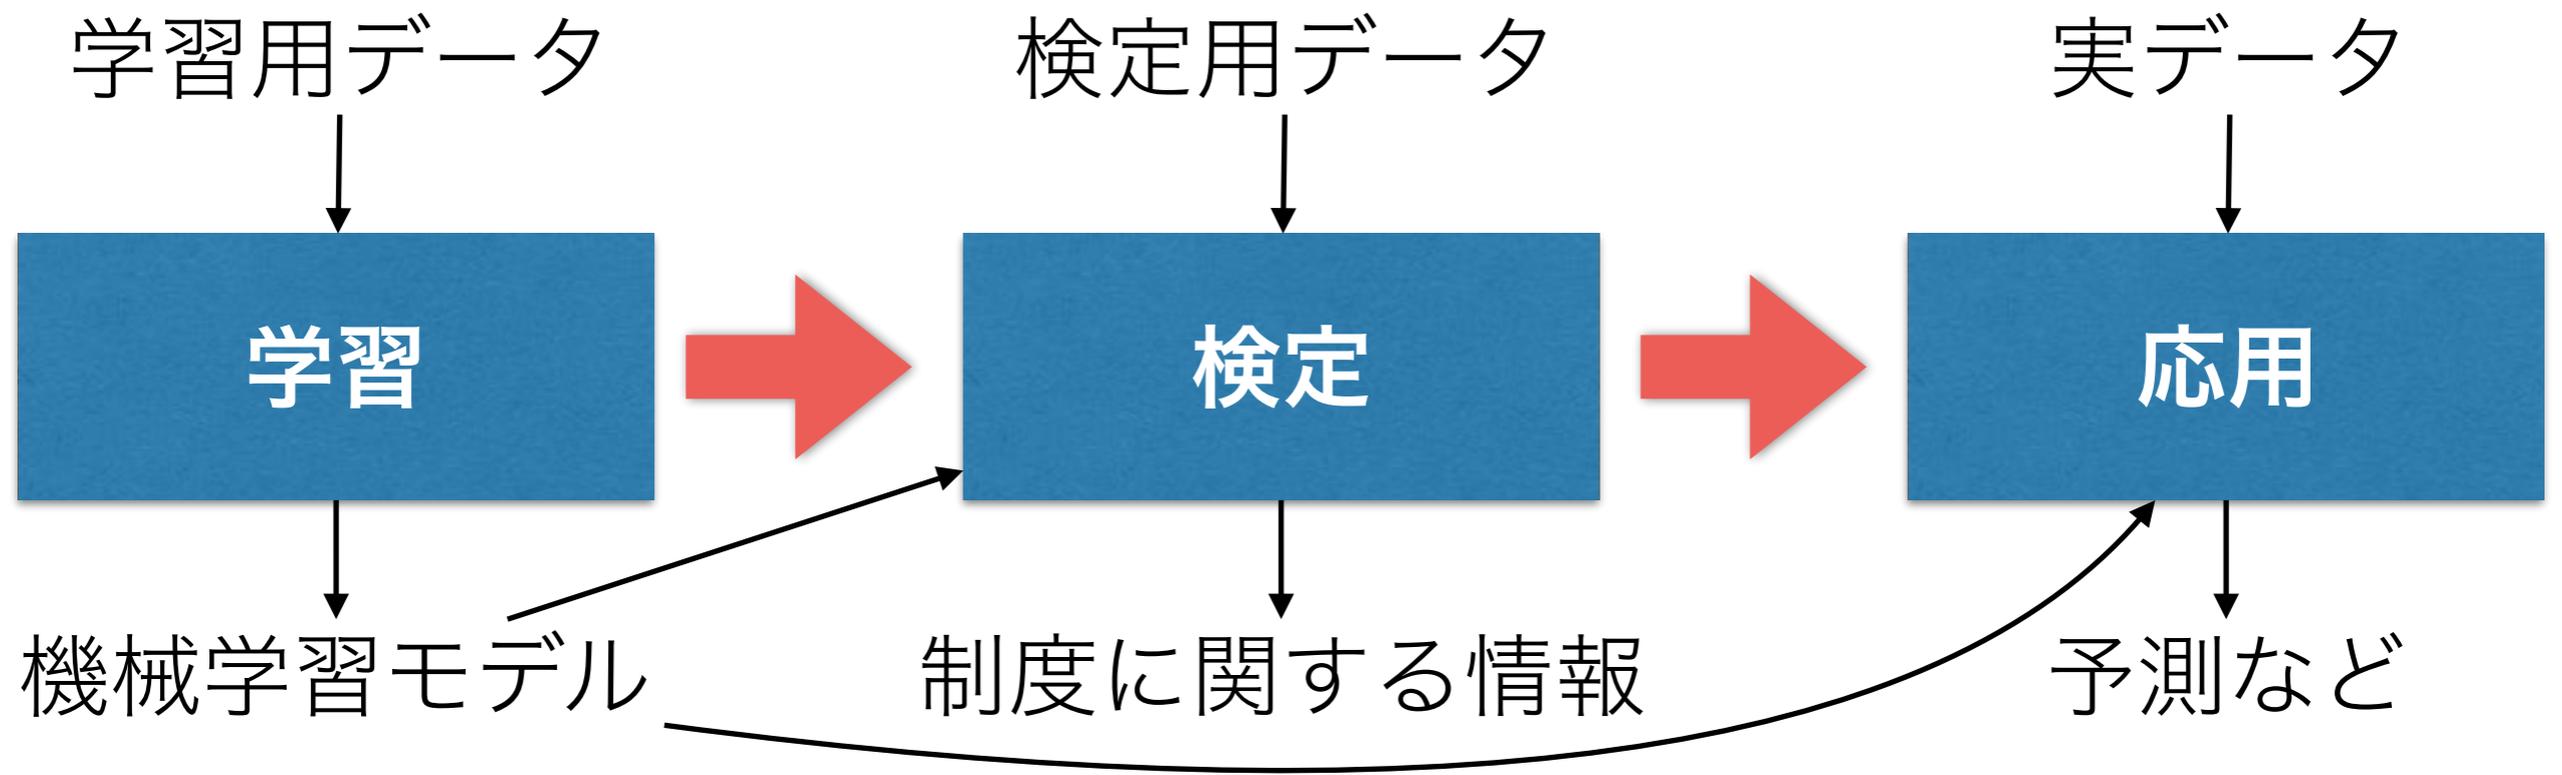


クラスタ分析前  
色付けなし



クラスタ分析後  
色付けあり

# モデル学習と検定とは



- **学習**：モデルを作る。教師あり学習の場合は説明変数と目的変数の両方は学習アルゴリズムに与える
- **検定**：モデルを確認する。モデルを使って予測し、正解と比較する（説明変数と目的変数を両方持っている）
- **応用**：実際にビジネスの場でモデルを使う（目的変数の実際値は未知）

# データ：学習用、検定用

- データは三種類がある：
  - 学習用データ、検定用データ、実データ
- 教師あり学習の場合：
  - **学習データ**と**検定データ**は説明変数と目的変数を含む
  - **実データ**は説明変数のみを含む
- **学習データと検定データの分け方**について
  - 異なるデータ：**予測モデル**を作る
  - 同じ：**再現モデル**を作る
- 再現モデルは価値が低い：オーバーフィットの可能性は高い

オーバーフィット問題は演習中に学ぶ

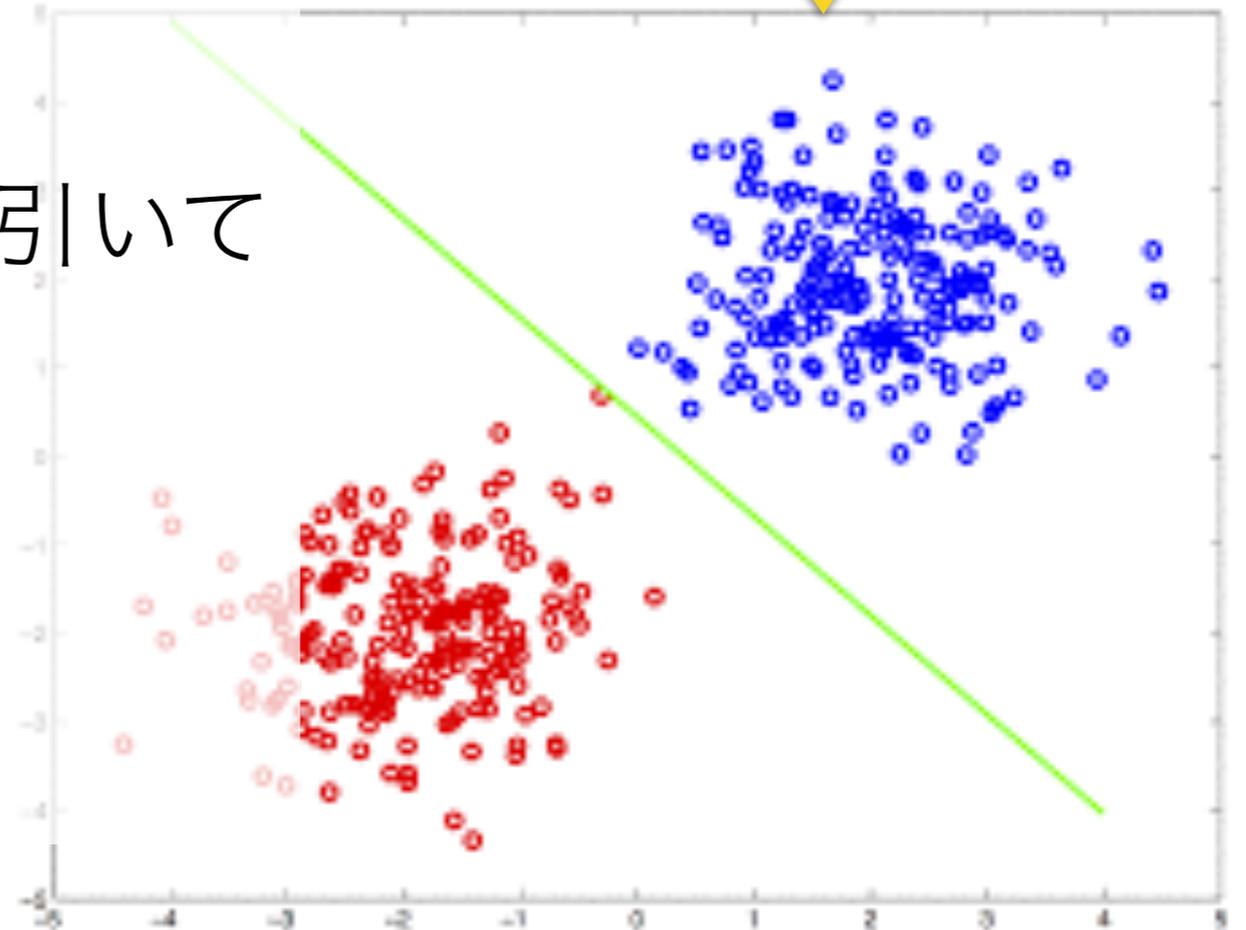
# データ解析の2つの目的

- 解析目的は説明か予測である
- 目的1：**データ説明**
  - 教師あり学習：目的変数と説明変数の関係を理解したい
  - 教師なし学習：説明変数の中にあるパターンを理解したい
- 目的2：**データ予測**（教師あり学習のみ）
  - 説明変数をもって、精度高く目的変数を求めたい

# 線形・非線形

- 線形という言葉はよく出るが、「線で解ける」と意味する
- **回帰の場合**：目的変数対説明変数のグラフを書くと線になる
- **分類の場合**：クラスは線を引いて分けられる
- 線形問題は一番簡単な問題

この分類問題は線で解ける：赤と青は線で分離できる。このデータは**線形分離可能**という



線は2次元の場合、 $n$ 次元の場合は超平面をいう

# ③ Rについて



# GUI型対プログラミング型

利点

欠点

例

GUI

使いやすい

決められた解析のみ可能

SPSS、BIツール

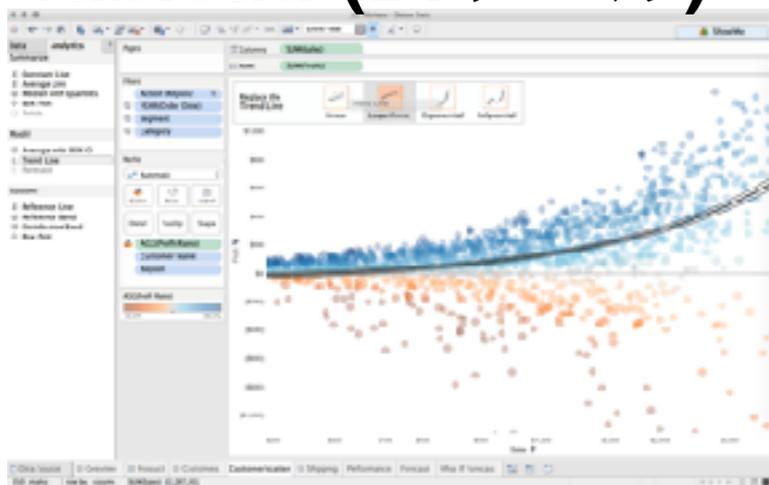
プログラミング言語

どの解析でも可能

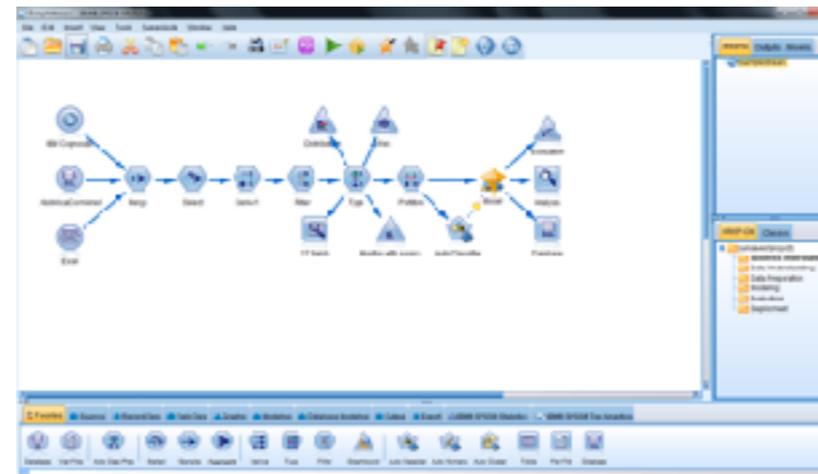
学びにくい

次のスライドを  
ご参考

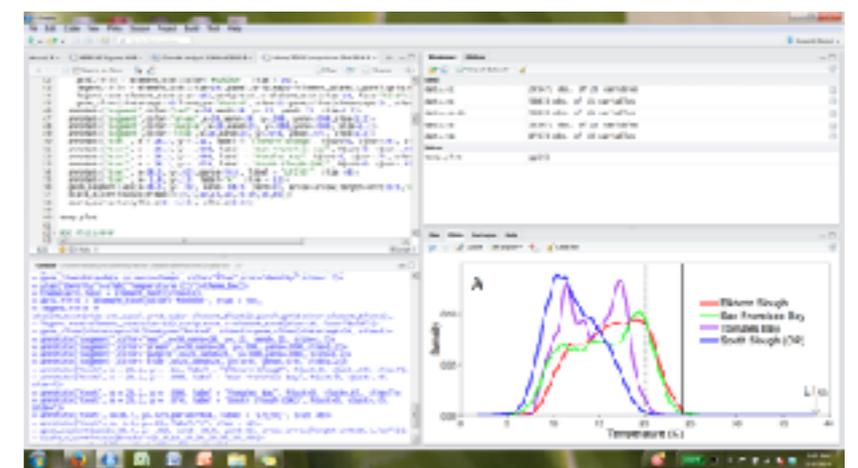
## Tableau (BIツール)



## IBM SPSS



## R Studio



# 必要に応じてプログラミング言語が決まる

プログラミング言語について	利点	欠点	例
解析用言語	<ul style="list-style-type: none"><li>可視化まで可能</li><li>探索に最適</li></ul>	<ul style="list-style-type: none"><li>解析以外は難しい</li></ul>	R、Julia
一般言語 (スクリプト)	<ul style="list-style-type: none"><li>解析以外も楽（クレンジングなど）</li><li>POCに最適</li></ul>	<ul style="list-style-type: none"><li>探索に固い場合もある</li><li>ライブラリは解析用言語ほど充実していない</li></ul>	Python
一般言語 (コンパイル式)	<ul style="list-style-type: none"><li>高性能ライブラリが充実</li><li>本番環境に最適</li></ul>	<ul style="list-style-type: none"><li>POCや探索には固い</li></ul>	Java、C#

## 言語周りも大きなポイント。例：

- R：パッケージが多い。「R Studio」というIDEはすごく便利。
- Python：Rと連携する。深層学習ライブラリはだいたいPythonが一番利用しやすい
- Java：HadoopやSparkはJavaで実装されている

機械学習専用  
ライブラリーを使う

今日はRを使う

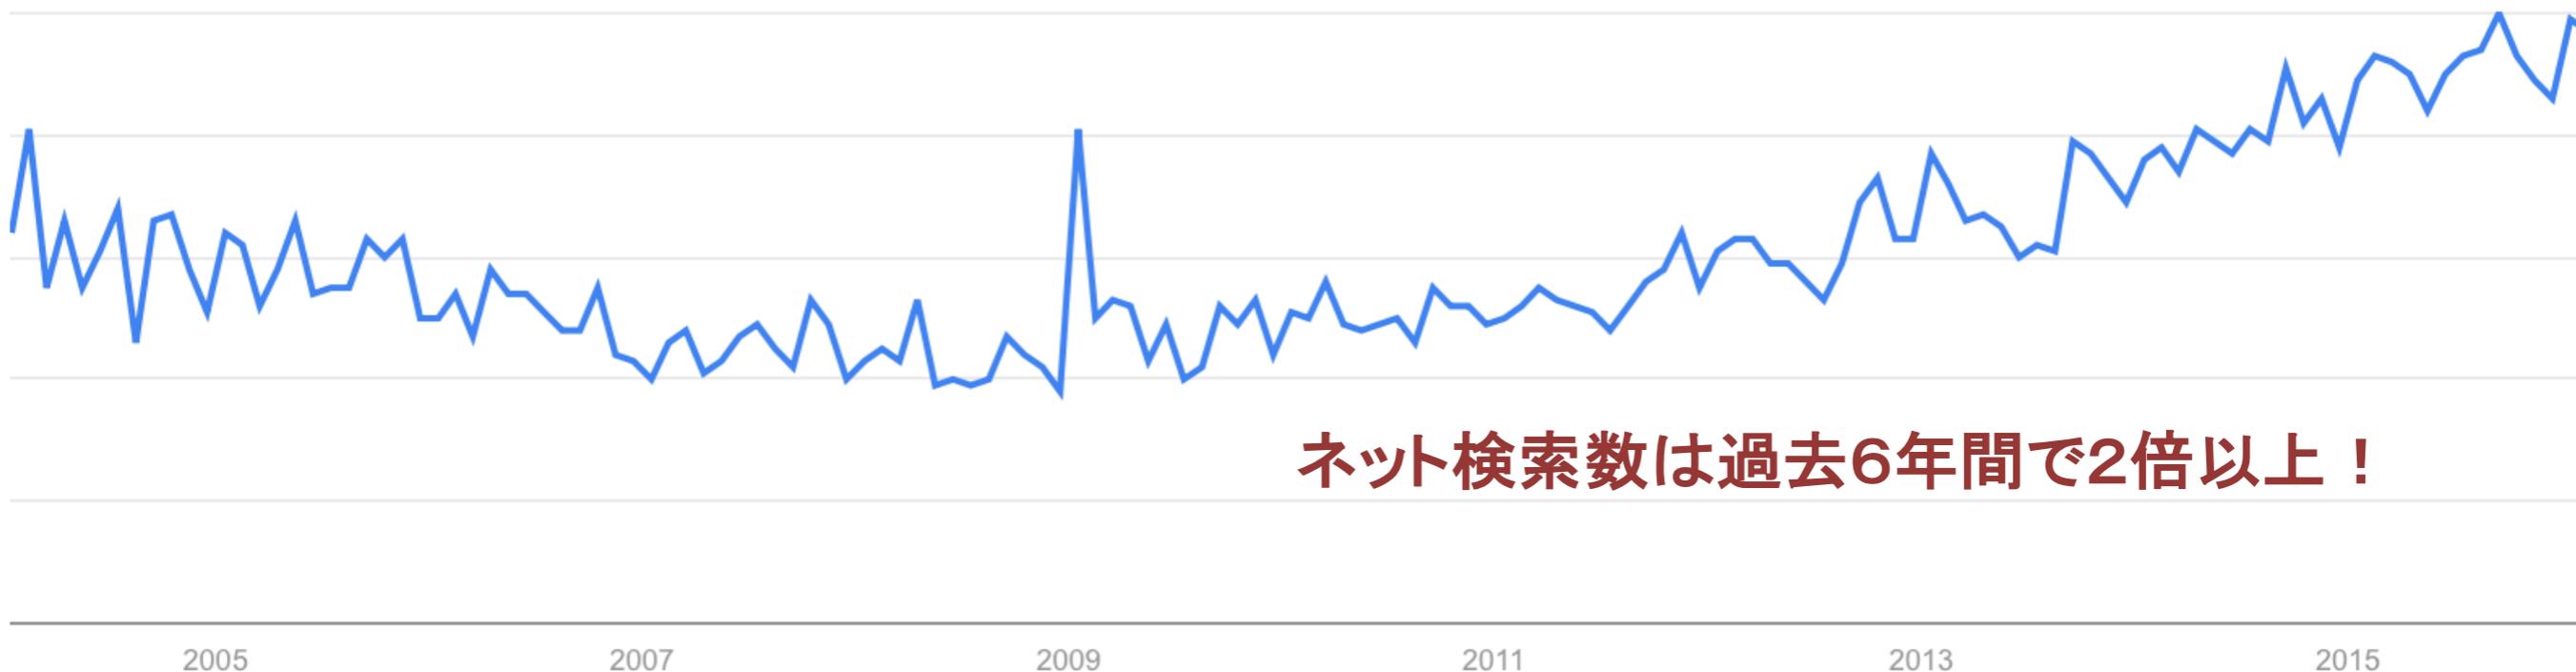
# Rは言語だけではない

- **言語**である
  - 1993にベル研究所から公開（C言語やUNIXの発祥地）
  - 当時人気のS言語のオープン版として開発された（S言語はほぼなくなりました）
  - コンパイラと標準ライブラリも充実
- データ解析**ツール**である
  - クレンジング、統計解析、機械学習、データ可視化など
- **エコシステム**である
  - パッケージが充実（“There’s a package for that”）
- **コミュニティ**である
  - 統計学者と機械学習学者は皆使っている

# Rは人気？

- アメリカで一番給料の高いITスキル(dice.comのサーベイ,2014)
- データ科学分野においてRはSQLの次に一番使われている言語(O'Reilly Survey,2014)
- Rユーザは2億人を超えてしまう(Oracle社によるサーベイ)

# Google Trends より



# Rのユーザーインターフェイス

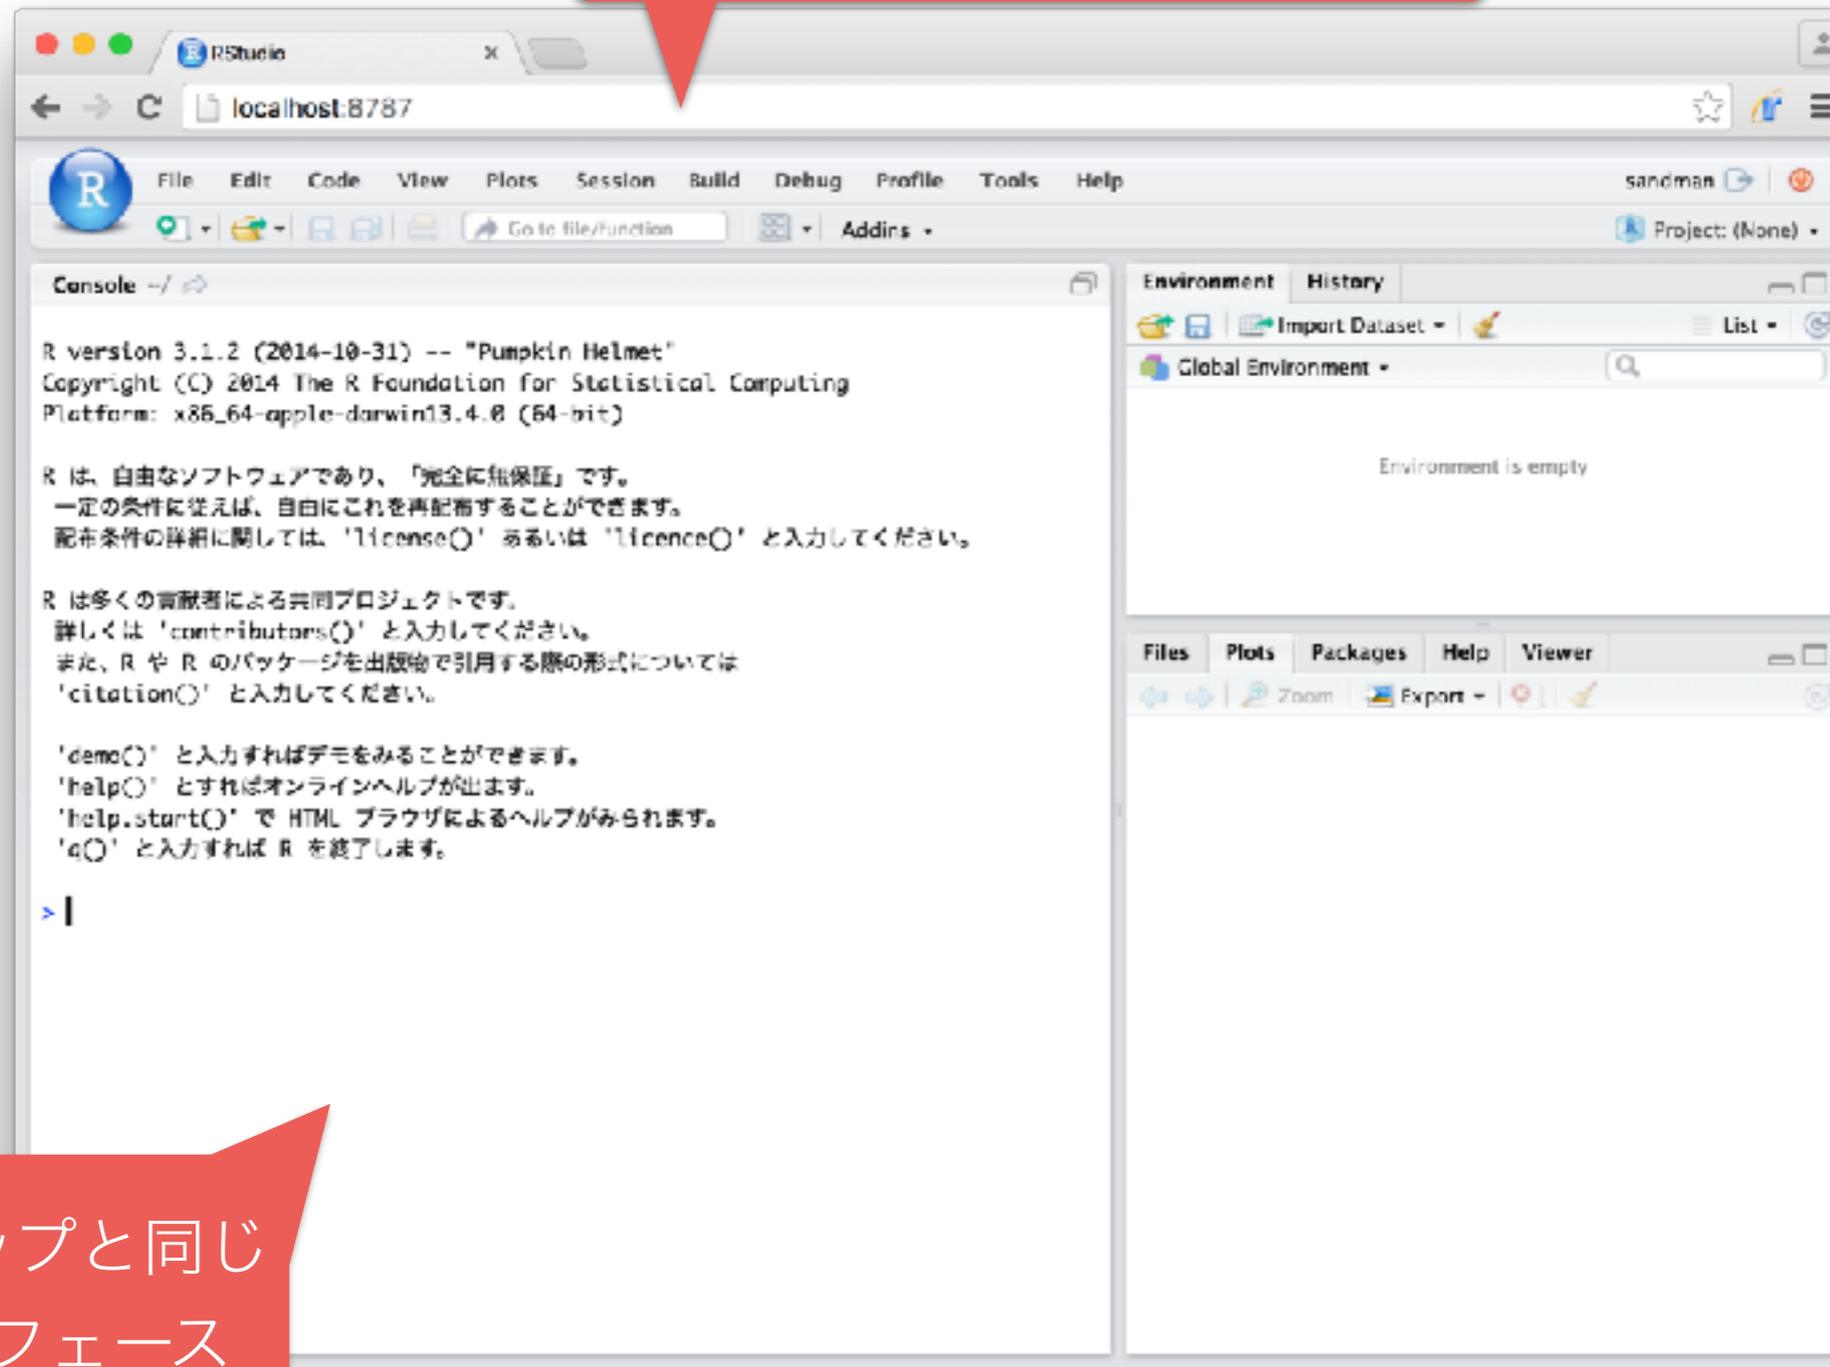
- R言語で書かれたコマンドを実行する
  - 裏はRコンパイラがマシンコードへ変換してプロセッサ上で実行する
- Rコマンドの実行方法
  - 方法①：Rプログラム（スクリプト）をファイルに保存してRコンパイラ（RScript）に渡す
  - 方法②：REPLインターフェイスを使う。ちなみに、REPLはRead Eval Print Loopの略で、ターミナルにコマンドを書いて、すぐに結果が表示される。
- 通常はロカルでRプログラムを実行するが、下記のやり方もある
  - 遠隔実行：「R Server」というソフトを使うと、重い計算を他のマシンで実行できる
  - 分散実行：R Serverや通常のロカルR実行環境をネットワークを通じて協調するように設定できる

# Rスタジオについて

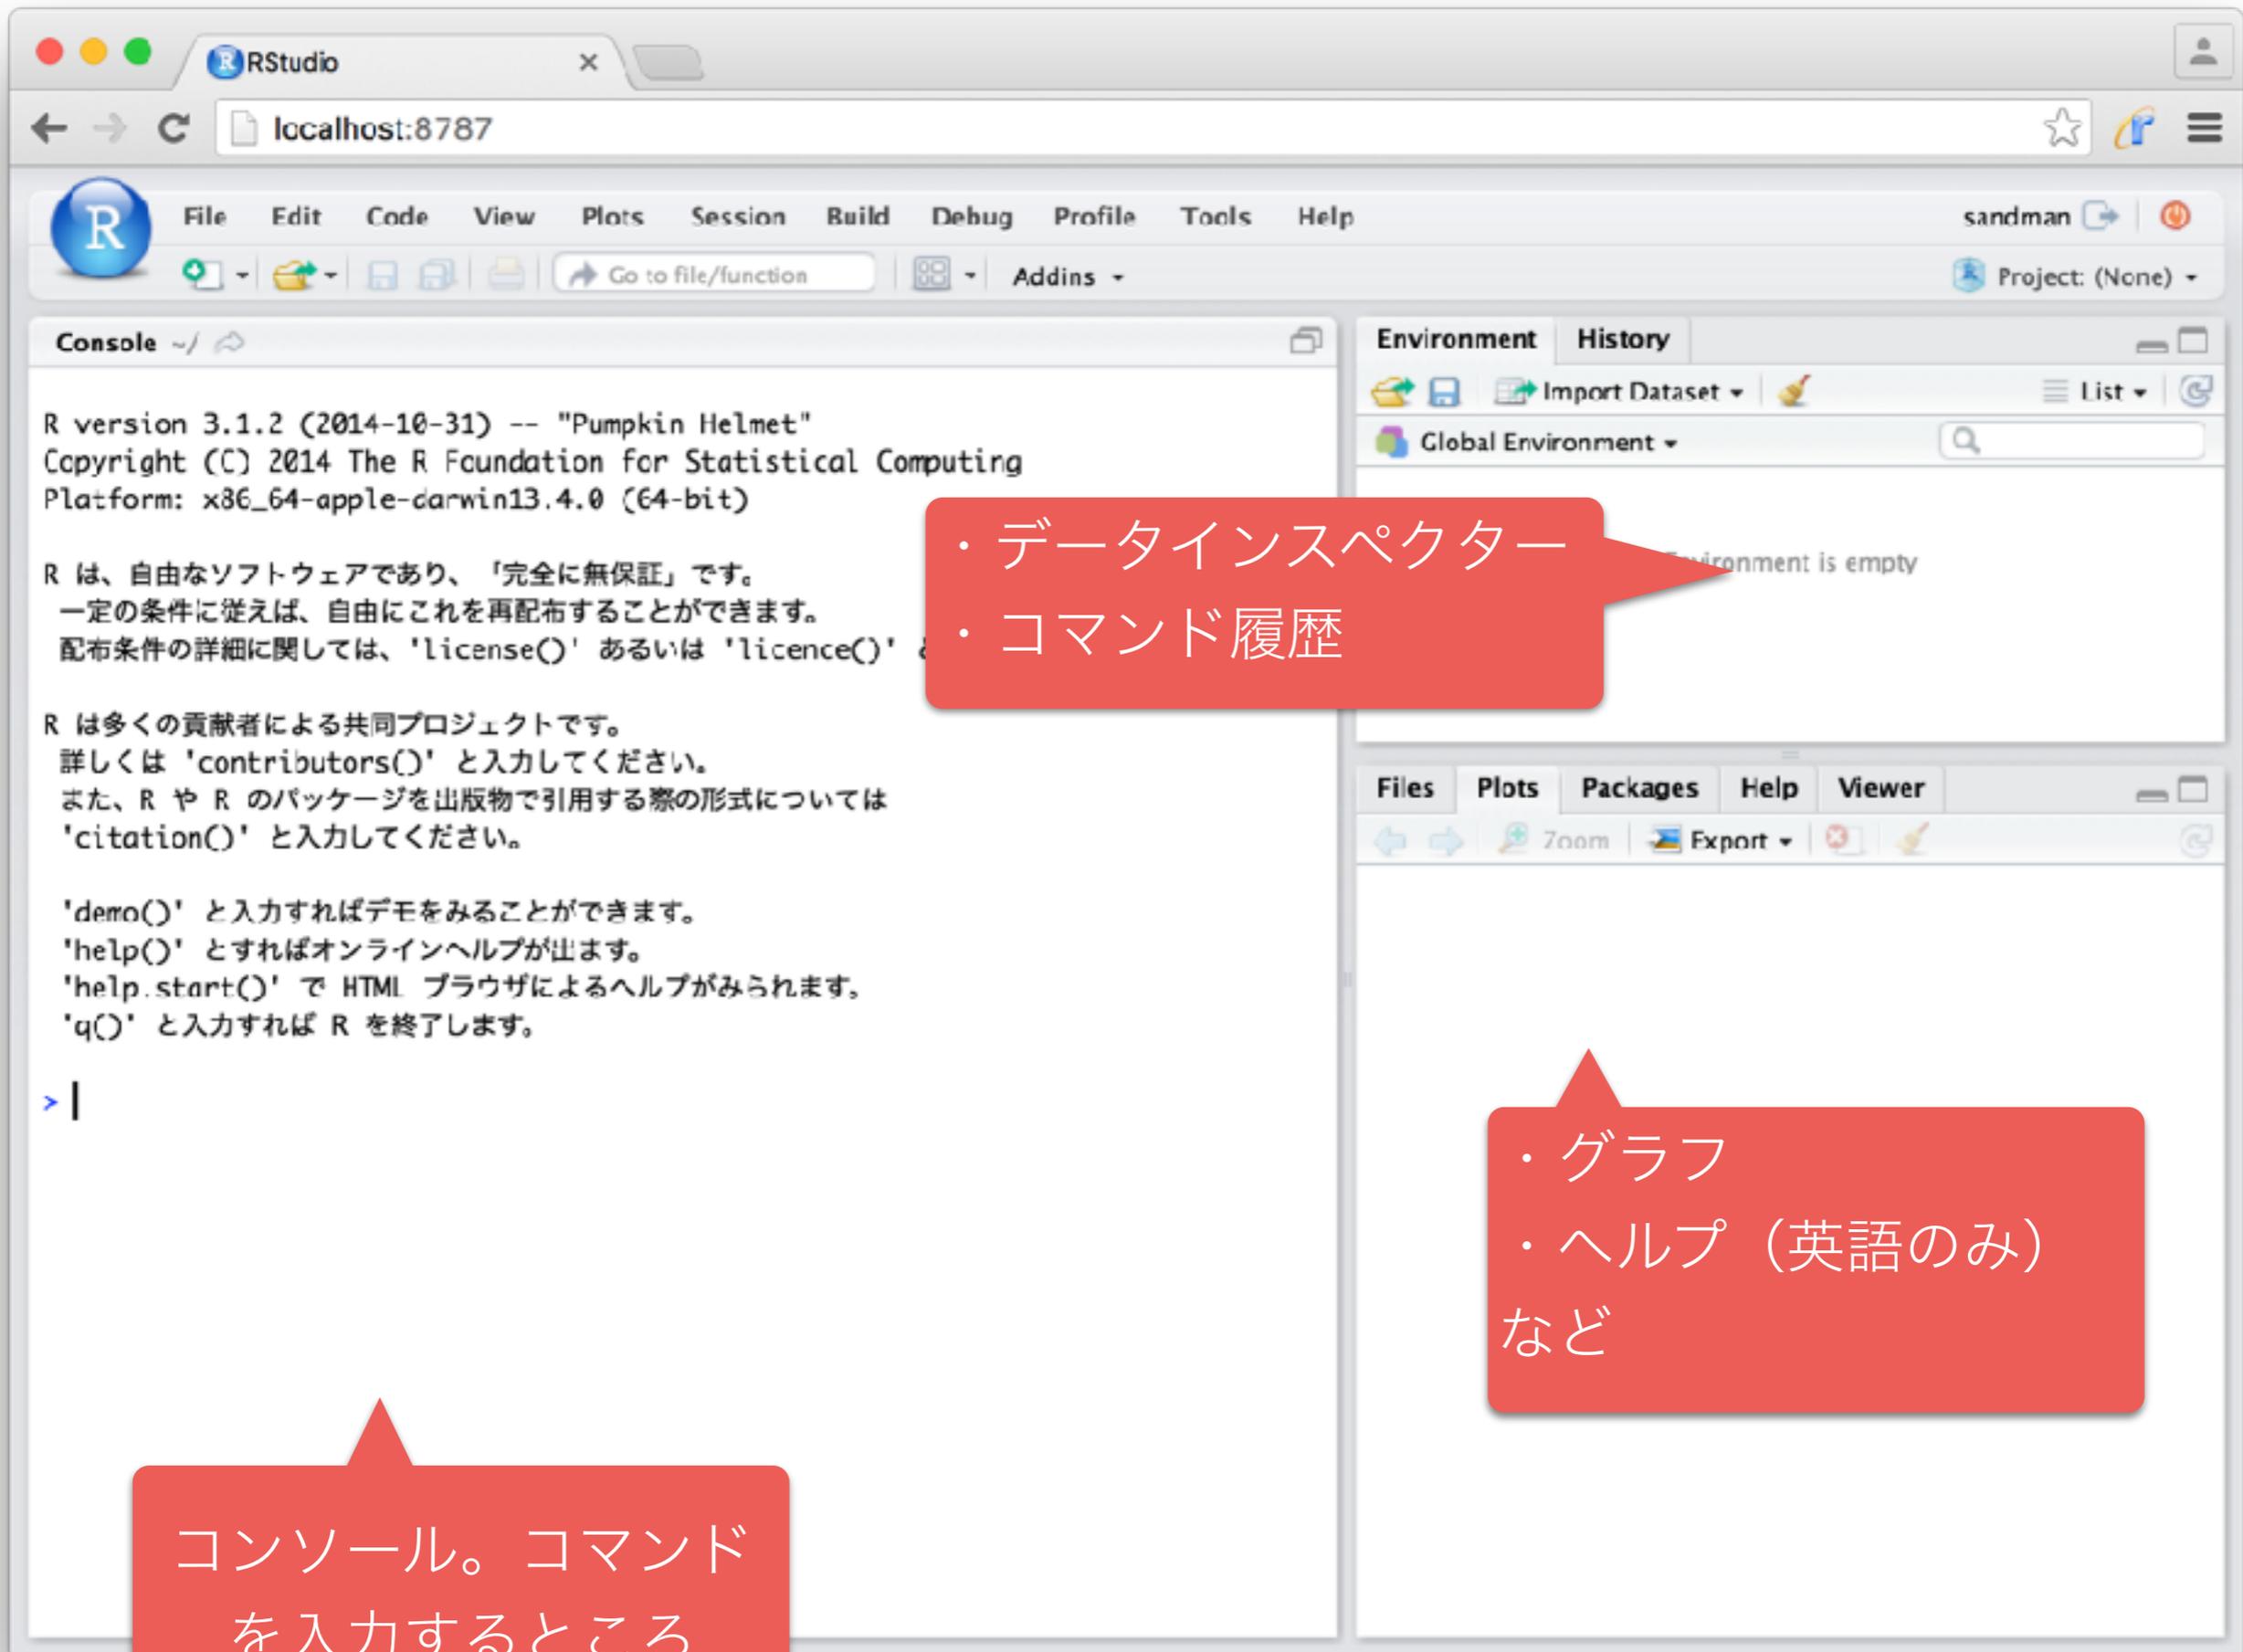
- RStudioはRのグラフィックインターフェース
- コマンドラインを使うところは変わらないが、便利機能が沢山！
  - ベストIDEランキングによく出る
- デスクトップアプリケーションに加えてサーバーもある
  - サーバーはRStudioのWebサービス版。計算はサーバー側に行わせる
- 今回は僕のパソコンにインストールしているRStudioサーバーに接続してもらおう

# RStudioの画面（ウェブバージョン）

URLはボードをご参考



デスクトップと同じ  
インターフェース



- ・データインスペクター
- ・コマンド履歴

- ・グラフ
  - ・ヘルプ（英語のみ）
- など

コンソール。コマンド  
を入力するところ

今からRハンズオン