

ディープラーニングの技術は何が凄いのか  
を理解するために、まずは

## 特徴量

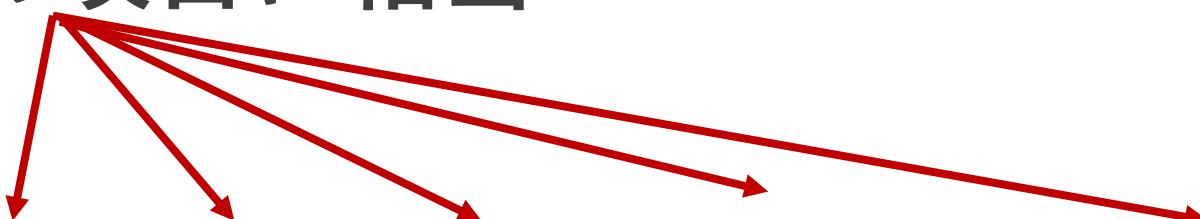
という概念を正しく知りましょう

# 「特徴量」(英 : **feature**) とは

## 分析対象を表現する

## 予測の手掛りとなる変数

列の項目に相当



年齢	性別	年収	家族人数	勤務年数	...
45	1	700	2	2	...
32	0	450	4	3	...
:	:	:	:	:	:

# 【例①】 物件条件から家賃の予測

特徴量の例①

面積	最寄駅(分)	築年数	管理会社Tel	正解	予測
45	10	20	xxx	15	14
32	7	45	xxx	10	9



面積, 最寄駅, 築年数  
は特徴量として  
効きそう

管理会社Tel  
は効かない

## 【例②】個人データから保険契約するかを予測

特徴量の例①

年収	既婚	身長	生年 月日	正解	予測
450	0	176	YYMMDD	0	0
600	1	155	YYMMDD	1	1



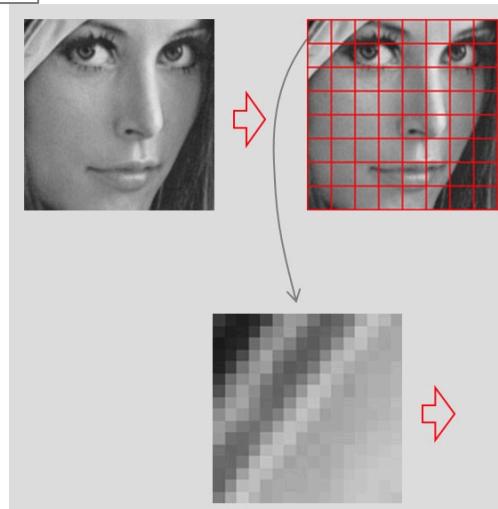
年収,既婚  
は効きそう  
身長は効かない

生年月日は現日付との  
差をとって年齢に変換  
すれば効きそう

# (参考) 非構造化データの場合の特徴量

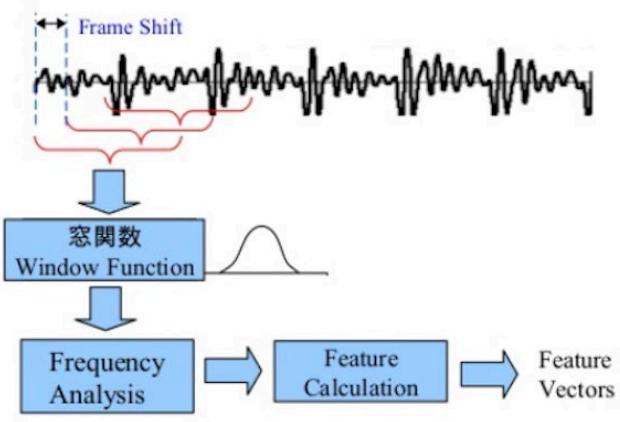
## 画像認識

特徴量 = 画像のピクセル



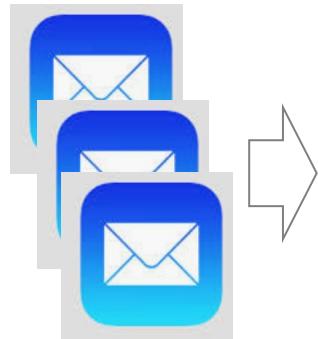
## 音声認識

特徴量 = 音波の波形を処理した結果



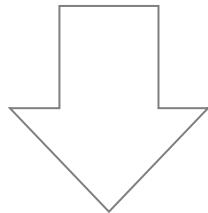
## 自然言語処理

特徴量 = 注目文言の出現頻度



	単語 1	単語 2	単語 3	…	単語 M
文章 1	4	8	0	…	2
文章 2	2	0	1	…	6
文章 3	7	0	8	…	4
文章 4	3	4	3	…	1
⋮	⋮	⋮	⋮	⋮	⋮
文章 N	0	2	5	…	6

生データのままでは、必ずしも理想的な特徴量を得られない  
予測に影響を及ぼす因子を過不足なく含むデータを作りたい



特徴量設計（特徴量エンジニアリング）のプロセスが重要

- ✓ 予測変数として採用する列を選別
- ✓ 元データに**前処理**を施す

# 従来の機械学習では特徴量設計（前処理）が大変

## カテゴリカルデータ の処理

コンピュータは数値しか処理できない為、  
文字列データを数値に変換してから機械学習モデルに入力

初回/リピート
初回
3回目
5回以上
...



「初回」なら1  
それ以外は0に変換

初回フラグ
1
0
0
...



## 欠損値処理

欠損値(歯抜け)の多い場合は良い精度  
を期待できない → 適切な値で補充

性別	年齢	身長	体重
男	35	170	
男		165	60
		159	
男	12	155	40
男		165	62
女		145	35



## 特徴量の変換・追加

予測に効きそうな情報をより効果的な形に編集し、新しい価値を持たせる

- 集計、カウント、データを結合・分割など

会員ID	年月日	購入個数
1	2019/10/11	2
2	2019/10/12	1
1	2019/10/12	1
3	2019/10/12	2
2	2019/10/13	1

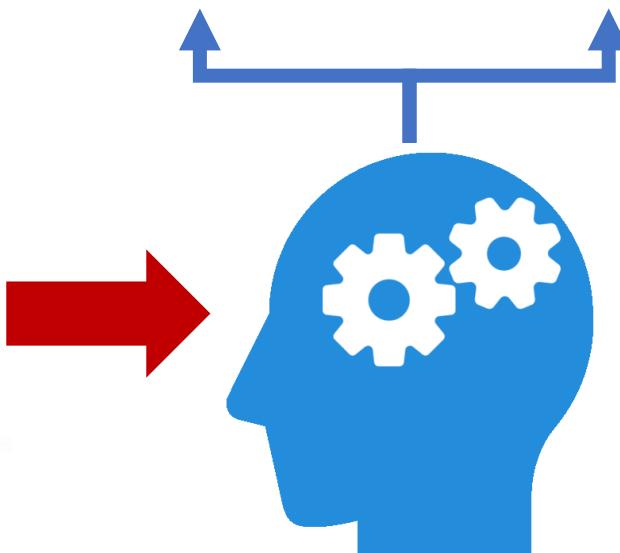
集計

会員ID	総数
1	3
2	2
3	2

# ディープラーニングは、 特徴量をデータから自動的に抽出できる



顔・身体の  
特徴を悩む



大量なデータから  
自動的に特徴を抽出



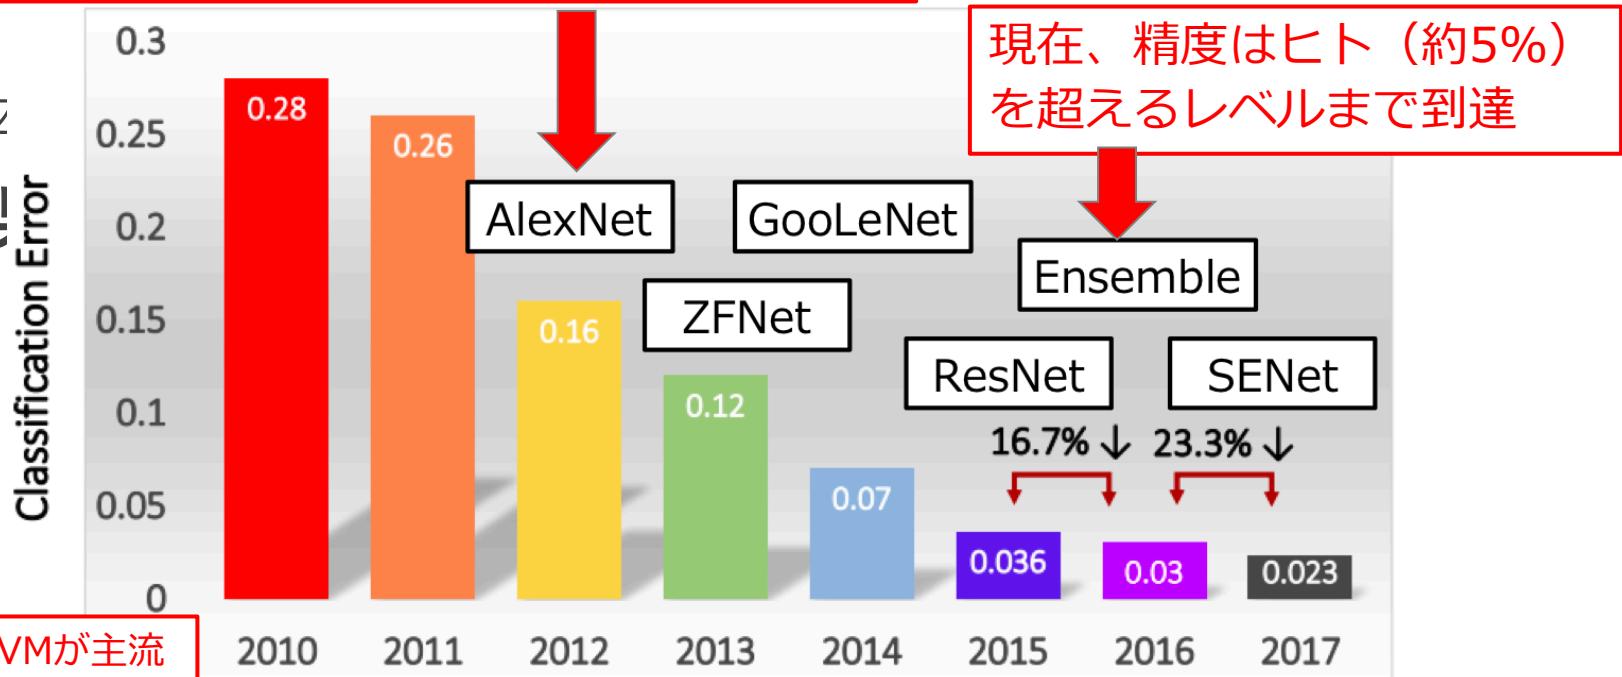
# 画像認識技術の進歩

- ・ディープラーニングが大きく注目されるきっかけは、2012年に開催された国際コンペ **ILSVRC (ImageNet Large Scale Visual Recognition Challenge)**

- ・大半のディープラーニングを利用したモデルがデータを学習し、テストで前年までの誤差率を10%以上改善

- ・具体的に

「誤分類率」  
Classification Error



[http://image-net.org/challenges/talks\\_2017/ILSVRC2017\\_overview.pdf](http://image-net.org/challenges/talks_2017/ILSVRC2017_overview.pdf)