

# AIを14分で徹底理解

- AIの基礎からディープラーニングまで徹底理解

# 目次

1. AIとは？
2. AIの歴史
3. 第2次ブームまで(1980年代まで)のAIイメージ
4. 「機械学習」、「ディープラーニング」の意味と関係性
5. AI学習の種類
6. 機械学習 例1)線形単回帰  
例2)サポートベクトルマシン  
例3)パーセプトロン(人口ニューロン)  
例4)ニューラルネットワーク  
例5)ニューラルネットワーク「ディープラーニング」

# 1. AIとは？

人工知能 (AI:Artificial Intelligence) とは、人間の知的ふるまいの一部をソフトウェアを用いて人工的に再現したもの。

具体的には？

「機械が一度でも判断した物はAI」と言えるのか？

極端なことを言えば、

「5時になればご飯を炊く炊飯器」は5時という判断をしているが、一般的にAI炊飯器とは言わない。

ということで、どれくらいの判断をおこなうとAI家電と言えるのか？

AIの明確な定義がない状況？

## 2. AIの歴史

ブーム	年代	キーワード	機械学習	実例
第一次ブーム	1950～1960年代	論理	×	パズル、迷路ゲーム
第二次ブーム	1980年代	知識	△	ロボット、エキスパートシステム
第三次ブーム	2010年～	深層学習 ディープラーニング	○	画像認識、音声認識

ビッグデータを機械が学習する  
実用化が進んだ

現在の第三次ブームは、2012年の画像認識コンテストで、カナダ・トロント大学ジェフリー・ヒントン教授チームが、**深層学習(ディープラーニング)**を利用して圧倒的な精度を示し勝利したことで、一気に広まった。

## 2. AIの歴史

ChatGPTに「AIブームについて」問いあわせてみたら、現在は第4ブームとのこと。。。



現在のAIブームは何回目ですか？



現在のAIブームは、第4次AIブームと呼ばれています。以下は、過去のAIブームの概要です。

第1次AIブーム（1950年代～1960年代）：AIの創成期であり、ロジックに基づく専門家システムなどが開発されましたが、コンピューターの性能不足などの技術的課題があったため、失速しました。

第2次AIブーム（1980年代～1990年代）：ルールベースのシステムや専門家システム、機械学習などが発展し、ビジネスにおいても利用が広がりましたが、予想されたほどの成果を上げられず、冷え込みました。

第3次AIブーム（2010年代～2015年頃）：ディープラーニング技術の発展により、音声認識、画像認識などで従来の技術を上回る精度が実現され、機械学習の進歩により、AIの性能向上が大きく加速しました。


第4次AIブーム（現在）：AI技術の成熟により、多様な業界や分野での活用が進み、自動運転技術、医療診断、金融、IoTなどでの利用が進んでいます。AIに関する研究開発や投資も増加しています。

### 3. 第2次ブームまで(1980年代まで)のAIイメージ

#### 「エキスパートシステム」イメージ

人間(専門家)がルール(知識)を設定して判定させる。細かくルールを設定するほど精度が上がるが、全てのルールを人が構築する必要がある

例えば



# 4. 「機械学習」、「ディープラーニング」の意味と関係性

AI

人間の知的ふるまいの一部をソフトウェアを用いて人工的に再現。

機械学習

機械自身が（ビッグ）データを学習し、ルールやパターンを法則化する

ディープラーニング

ニューラルネットワークなどを用いて  
データの特徴を自動抽出すること


# 5. AI学習の種類

教師の有無	内容	課題	手法
教師あり	問題と正解をセットで機械に与え学習する	分類	サポートベクトルマシン ディープラーニング (ニューラルネットワーク)
		回帰(予測)	
教師なし	問題のみ機械に学習させAI自身が自ら特徴などを見つけ学習する	クラスタリング (グループ分け)	K平均法 自己組織化マップ ディープラーニング
		データの低次元化	主成分分析(PCA) ディープラーニング
強化学習	AIが自ら試行し報酬を与え、最大の報酬を得るように学習する	将棋や囲碁 運動制御や迷路探索	Q学習 アクタークリティック



# 6-1. 機械学習 例1) 線形単回帰

線形単回帰は、 $x$ 、 $y$ の2変数のデータを一次関数( $y=ax+b$ )で表せるもの



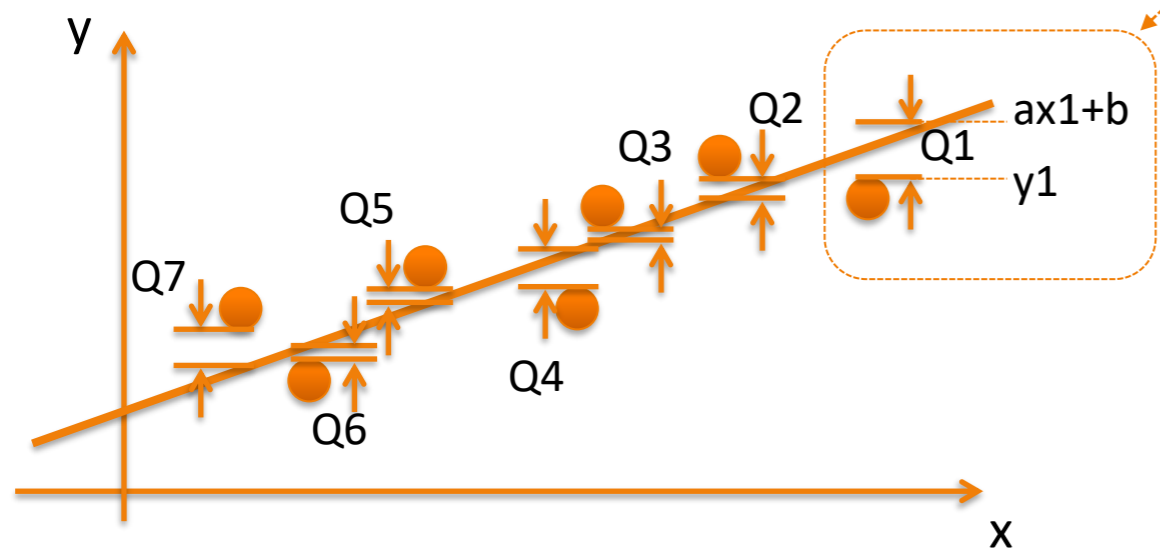
直線で表せるデータがあり、関係式を求めていく。

誤差は「 $Q1 = y1 - (ax1 + b)$ 」

上下に誤差があるので、2乗したものを合計する

誤差の総和 :  $Q_t = Q1 + Q2 + Q3 + \dots$   
 $= \{y1 - (ax1 + b)\}^2 + \{y2 - (ax2 + b)\}^2 + \{y3 - (ax3 + b)\}^2 + \dots$

誤差の総和が最小になるのが求める関係式



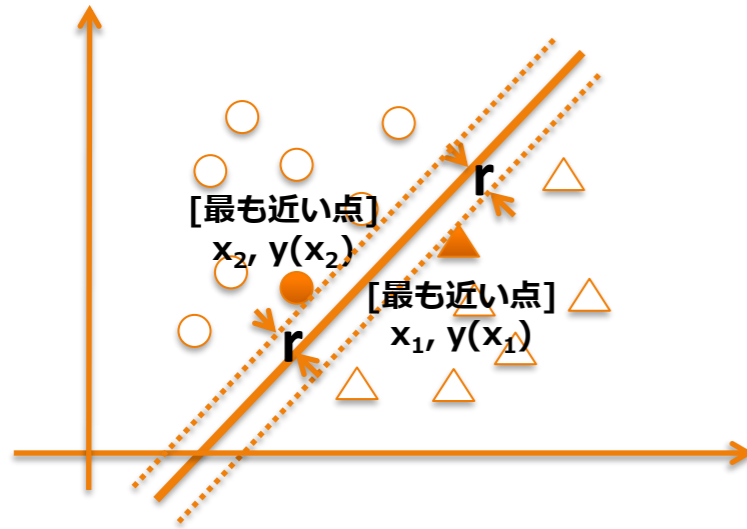
誤差の総和(目的関数)  $Q_t$ が最小になるように $a, b$ のパラメータが決定されます。

⇒ 最小2乗法

誤差の総和(目的関数)が最小(or最大)になるように関係式を求めるのはディープラーニングも同じ考え方

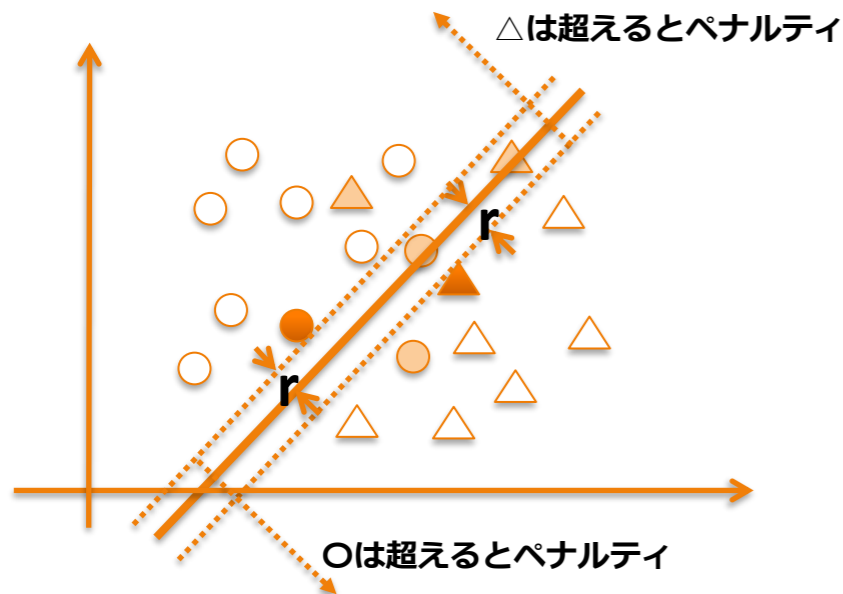
## 6-2. 機械学習 例2) サポートベクトルマシン

線形サポートベクトルマシン(直線で分類可能)の2クラス(2つに分類可能)で理論を学習。  
サポートベクトルマシンはマージンを最大化することで回帰直線[ $y = ax + b$ ]を決定します。  
(ベクトル: 点、サポートベクトル: 境界に最も近い点) (線形関数[一次関数])



最も近い点(サポートベクトル)のマージン $r$ が最大になるように $a, b$ のパラメータを決定。


通常、綺麗に分けられないのでペナルティを与えて計算



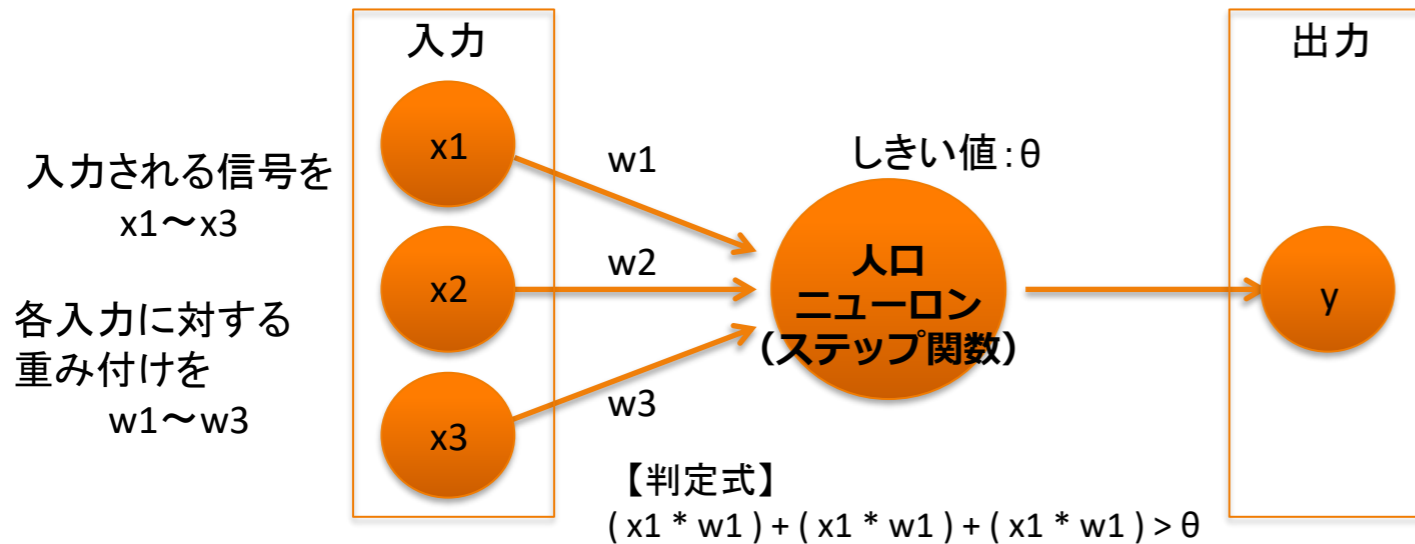
ペナルティが最小となるようにマージン $r$ を最大になるよう $a, b$ のパラメータを決定。

# 6-3. 機械学習 例3)パーセプトロン(人口ニューロン)

人の脳神経細胞をモデル化した、人口ニューロン(パーセプトロン)



参考: <https://aitokuconsult.hatenablog.com/entry/neuralnetwork>



例) 各入力が1, 2, 3、重みは全て1で、しきい値が5の場合

$$(1 * 1) + (2 * 1) + (3 * 1) > 5$$


$$6 > 5$$



正しいので、出力は「1」

出力には多くの関数がある

①活性化関数:ステップ関数




出力は0か1の2値

$$(x1 * w1) + (x1 * w1) + (x1 * w1) > \theta$$

真なら1、偽なら0


②活性化関数:シグモイド関数



出力は0から1の間で任意値

出力  $y = \sigma(a)$  で表します。  
 $\sigma$ はシグモイド関数で $\sigma(x) = 1 / (1 + \text{Exp}^{-x})$   
 $a$ は「入力の線形和」と呼ばれ  
 $(x1 * w1) + (x2 * w2) + (x3 * w3) - \theta$   
となります。  
出力層でよく使われる。

③活性化関数:ランプ関数




出力は0より任意の値

単純で計算しやすい。  
中間層でよく使われる。

# 6-4. 機械学習 例4) ニューラルネットワーク

ニューラルネットワークを理解するため、中間層(隠れ層)が1層モデルで学習  
(3\*3画像の○「まる」と×「ばつ」を判定するニューラルネットワーク)



各ニューロンでは、入力に重みをかけて、しきい値で判定した値が出力される

**【中間層の計算式】**

$$a1 = (x1 * w11) + (x2 * w12) \dots + (x9 * w19) - \theta1$$

$$a2 = (x1 * w21) + (x2 * w22) \dots + (x9 * w29) - \theta2$$

$$a3 = (x1 * w31) + (x2 * w32) \dots + (x9 * w39) - \theta3$$

$$y1 = \sigma(a1), y2 = \sigma(a2), y3 = \sigma(a3)$$

$\sigma$ はシグモイド関数

**【出力層の計算式】**

$$z1 = (y1 * w11) + (y2 * w12) + (y3 * w13) - \theta1$$

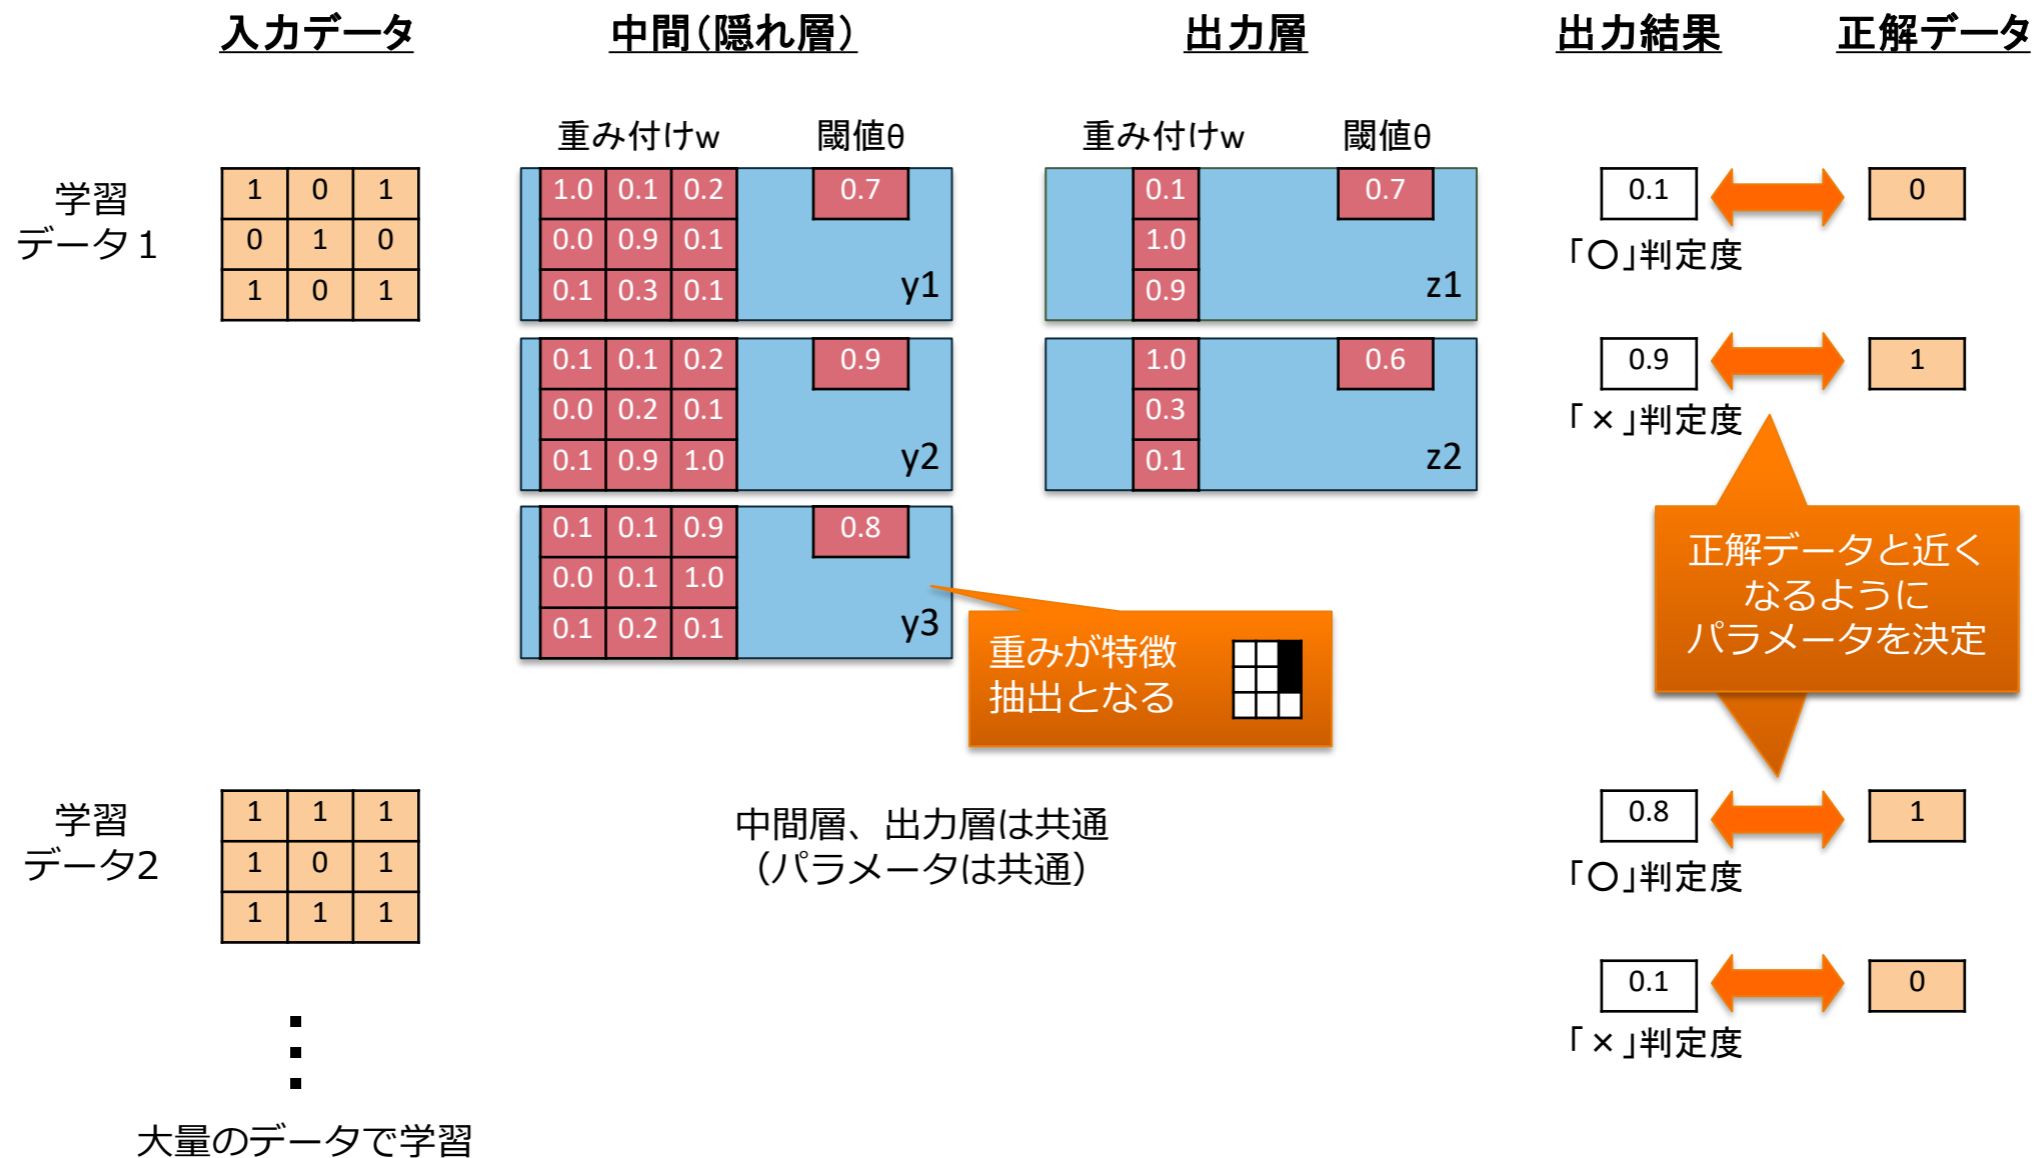
$$z2 = (y1 * w21) + (y2 * w22) + (y3 * w23) - \theta2$$

画像	入力層	中間(隠れ層)	出力層
	入力情報をそのまま全ての隠れ層へ	各隠れ層には検出するパターンがあり特徴抽出を行う	○×判定を行う

# 6-4. 機械学習 例4)ニューラルネットワーク

1.0 :与えるデータ  
1.0 :最適化されるパラメータ


} 与えられたデータから出力が正解データと等しくなるように  
 パラメータが最適化される



# 6-5. 機械学習 例5)ニューラルネットワーク「ディープラーニング」

ディープラーニング : 中間層が2層以上のニューラルネットワーク  
畳み込みニューラルネットワーク : 中間層を小分けにして学習する手法

例) 畳み込みニューラルネットワーク




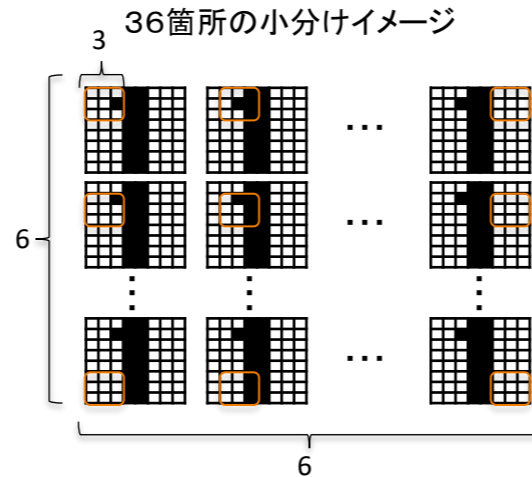
入力層  
8\*8の画素数なので  
64ニューロン

畳み込み層1  
3\*3の枠で36箇所の小分けに  
して32グループを構成

畳み込み層2  
3\*3の枠で16箇所の小分けに  
して64グループを構成

MAXプーリング層  
4\*4を2\*2の枠で縮小  
ズレに強い特徴抽出  
Maxプーリングイメージ

出力層  
入力から閾値で  
判断し各要素を  
判定



畳み込み層1  
の出力(6\*6)

