

1216583c  
谷 紗耶加

# ニューラル ネットワーク

# ニューラルネットワークとは

- 人間の脳には140億個のニューロン⇒規則に従って結合⇒神経回路
- 神経細胞が結ばれた神経回路をモデル化

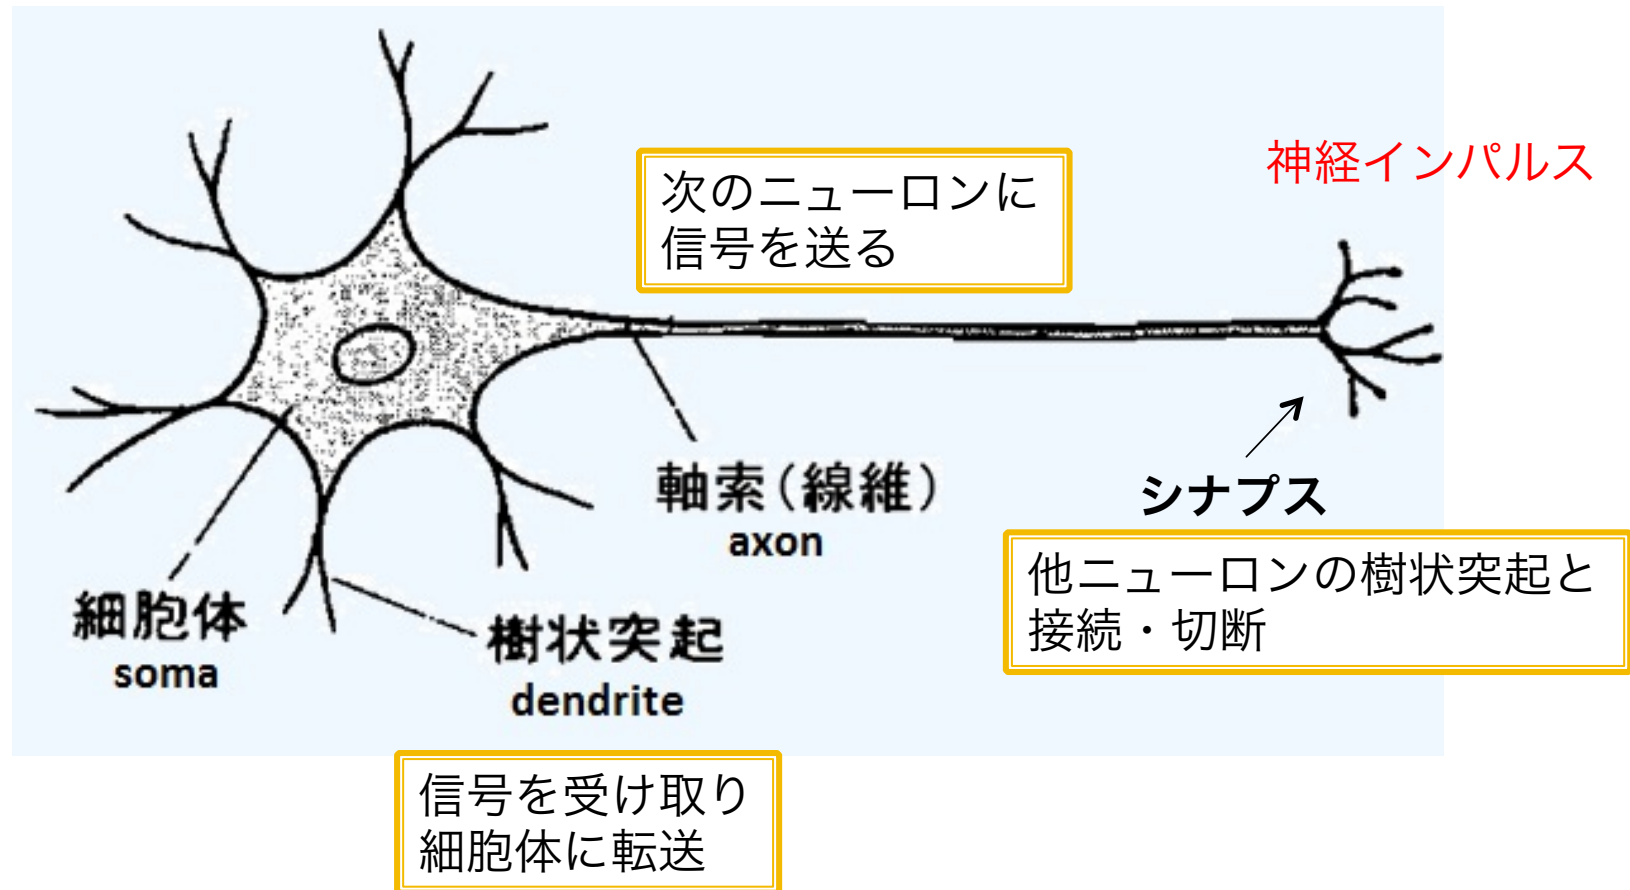
⇒ **ニューラルネットワーク**  
**(neural networks)**

- 非線形回帰分析、非線形判別分析の有力な機械学習の方法

# ニューラルネットワークの基礎

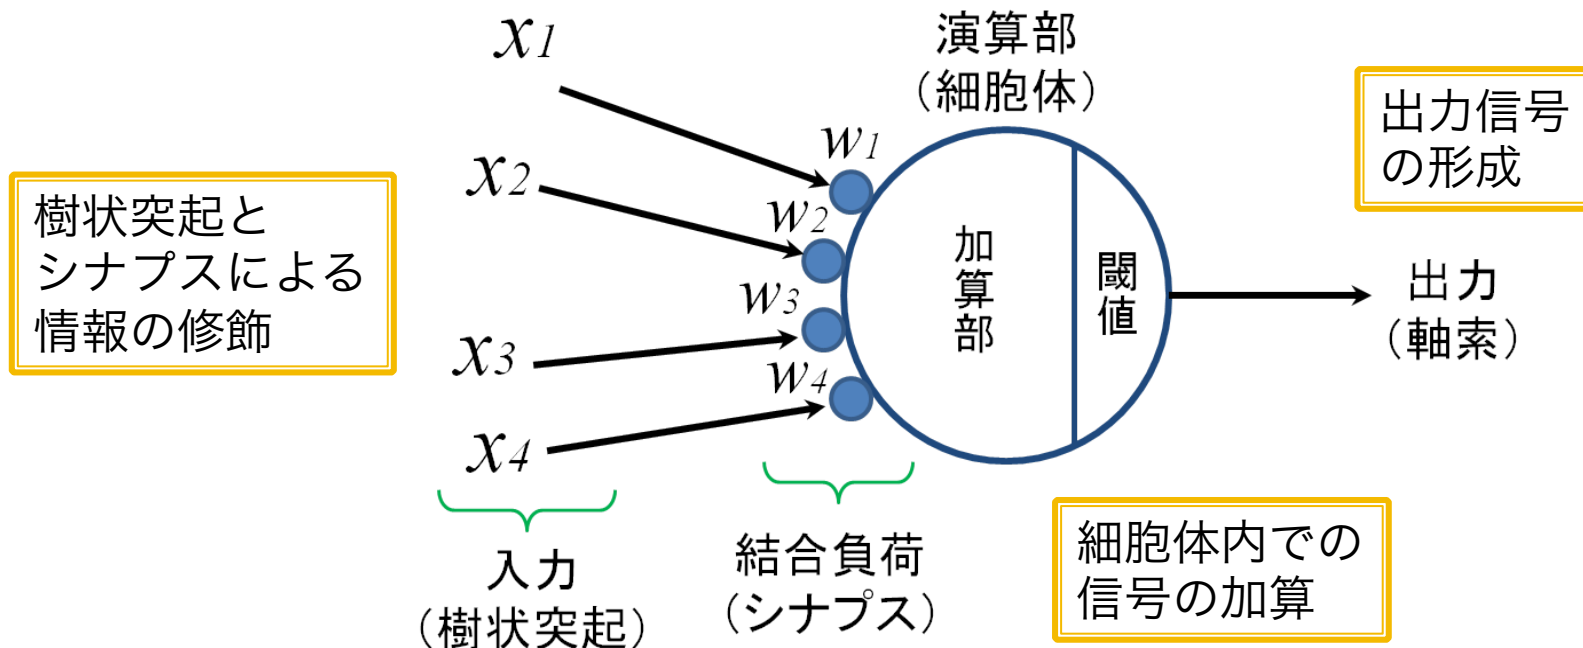
- 1943年 マカロックとピッツ
- 神経細胞（ニューロン）
  - ⇒ 神経回路を構成する最小単位
  - ⇒ 細胞体、軸索、樹状突起、シナプス
- 信号処理、信号伝達

# 神経細胞（ニューロン）の図

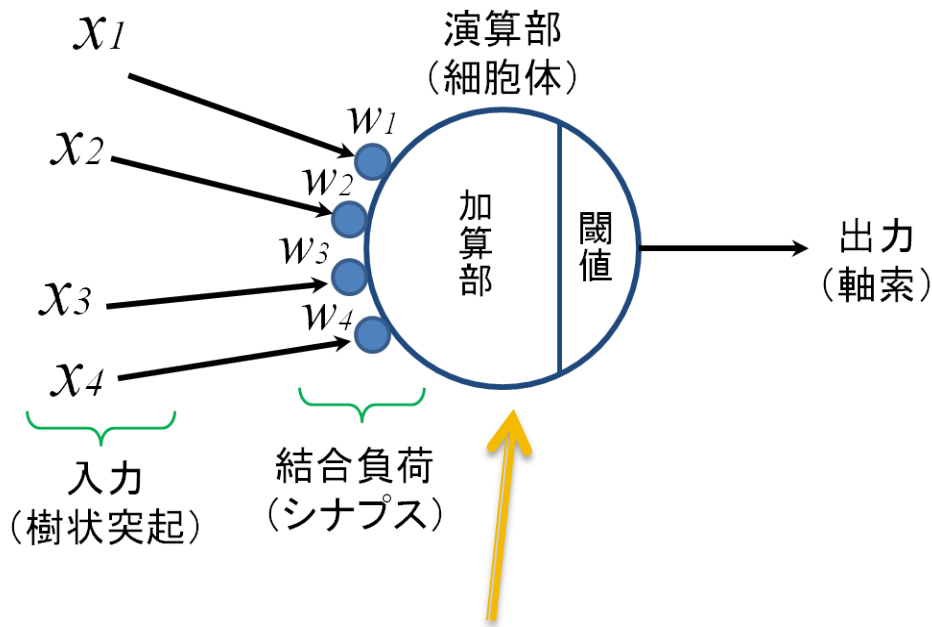


# 形式ニューロンの構造

- ニューロンが多数並列に接続されたシステムを数理的にモデル化  
⇒ ニューラルネットワーク
- 構成要素 ⇒ 形式ニューロン (ユニット)



# 入力と出力の関係



$$y=f(u)=\begin{cases} 1 & u \geq \theta \\ 0 & u < \theta \end{cases}$$

あるいは

$$y=f(u)=1/(1+e^{-u})$$

$$\text{(ただし } u=\sum_{i=1}^p w_i x_i \text{)}$$

入力値  $x_i$  に 重み  $w_i$   
を掛けた代数和  $u=\sum_{i=1}^p w_i x_i$


# モデルの分類 (ネットワークモデル)

## ■ 階層型ネットワーク

- 最も多く使われる
- 信号は一方向

## ■ 非階層型ネットワーク


- 階層型ネットワーク以外
- 信号が任意の方向に流れる  
(逆方向、ループ状もある)



信号の流れ →

相互結合型ネットワーク  
(非階層型)

# 階層型ネットワーク



## ニューロンが階層的に結合

入力層と中間層（隠れ層）の各ユニット出力は次の層のすべてのユニットにリンク  
⇒ **階層的完全結合型**

フィードフォワード型（前向きのみ）

中間層および中間層のニューロンの数が学習の回数および収束に直接影響

計算の負担を考えると少な目がよい  
一般的には3層



# 単一中間層ニューラルネットワーク

$$y_k = \phi(a_k) \quad (a_k = \sum_{h=1}^H w_{hk} \phi(a_h) + \sum_{i=1}^I w_{ih} x_i)$$

(1) 入力データ  $x_1, x_2, \dots, x_p$  をニューラルネットワークに与え、最初の段階では結合の重みとして  $w_1, w_2, \dots, w_p$  に小さいランダム値を与えて出力を求める

(2) 出力結果と学習用のデータを比較し、新しい結合の重み  $w^{(j+1)} = w^{(j)} + n \times \delta \times O_{net}$  を計算する。

(3) 最適な解が得られるまで (2) を繰り返す。

$w^{(j+1)}$   $j+1$ 回目の結合の重み

$w^{(j)}$   $j$ 回目の結合の重み

$n$  定数

$\delta$  ニューロンの出力結果と学習用のデータとの差に関する関数

中間層、出力層によって異なる

$O_{net}$  ニューロンの出力結果

# パッケージと関数

- nnet

- 中間層ありのニューラルネットワークのパッケージ、Rに標準装備
- 教師ありの学習法アルゴリズム

```
nnet(formula, data, weights, size,...)  
nnet(x, y, weights, size,...)
```

- predict

- nnetを学習モデルとし、当てはめて値を返す

```
predict(学習したモデル, データ, type="")
```

# ケーススタディ (1)

- Irisデータを用いて、品種の識別
- 学習用データ (iris.train) とテストデータ(iris.test)を作成

```
> even.n <- 2*(1:75)
> iris.train <- iris[even.n,]
> iris.test <- iris[-even.n,]
```

# ケーススタディ (2)

- 作製した教師（学習、訓練）データを用い、関数nnetによるニューラルネットワークモデルの作製

```
> library(nnet)
> iris.nnet <- nnet(Species~.,size=3,decay=0.1,data=iris.train)
# weights: 27
initial  value 85.657162
iter 10 value 42.310822
iter 20 value 36.658685
iter 30 value 19.230029
iter 40 value 18.460511
iter 50 value 17.455241
final  value 17.432930
converged
```

decay:  
衰退重みのパラメータ

size:  
隠れ層（入力層と中間層）のユニット数

data:  
データセットの名前

# ケーススタディ (3)

- 関数predictを用いてテストデータについて予測・判別

```
predict(学習したモデル, データ, type="")
```

```
> iris.nnetp <- predict(iris.nnet, iris.test[, -5], type="class")
> table(iris.test[, 5], iris.nnetp)
      iris.nnetp
      setosa versicolor virginica
setosa      25         0         0
versicolor  0        23         2
virginica   0         0        25
> |
```

75の個体の中2つが誤識別

# その他

- 自己組織化マップ (第6章)
  - 学習データなしのニューラルネットワークの1つ
- class (パッケージ)
  - R実装、学習ベクトル量子化(LVQ: Learning Vector Quantization)アルゴリズム

```
> library(class)
> cl <- iris.train[,5]
> cd <- lvqinit(iris.train[,1:4],cl)
> cd1 <- lvql(iris.train[,1:4],cl,cd)
> test.re <- lvqtest(cd1, iris.test[,1:4])
> table(iris.test[,5],test.re)
```

	test.re		
	setosa	versicolor	virginica
setosa	25	0	0
versicolor	0	23	2
virginica	0	1	24

(実行例)

LVQは変数の数が多い場合に強み