

# 予測のはなし

## — 予測の基礎からニューラル ネットワークによる予測まで —

豊橋創造大学 経営学部

教授 今井 正文

E-mail:mimai@sozo.ac.jp

# 本日のトピック

- \* 予測の基礎  
質的予測と量的予測  
時系列データと変動
- \* コンピューティングの分類と問題点  
ハードコンピューティングとソフトコンピューティング
- \* ニューラルネットワーク入門

# 予測の基礎：質的予測と量的予測

- \* 予想と予測は何が違うのか？（というより必要なの？）
- \* 経営（経営工学や経営システム工学）から  
（回帰分析だって予測はできる、..）
- \* 質的予測と量的予測、どちらが大事？
- \* 予測を困難にする環境の変化  
3つの〇〇構造の変化（+技術革新等）は予測を困難にしてしまう

# 予測の基礎：時系列データと変動

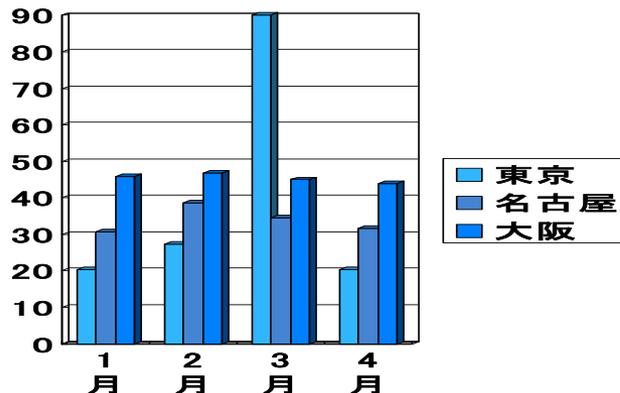
- \* **時系列とは**  
時間とともに不規則な変動をする現象の観測値
- \* **時系列の変動を構成する四つの要素（従来の考え方）**  
四つの要素：傾向変動（トレンドカーブ）、...  
解析には時系列解析（指数平滑法、移動平均、etc）
- \* **カオス理論とカオス時系列データの話**  
自然に発生するこれらの現象は、従来の手法を適用してもあまり良い結果を得られない。

# コンピュータに求められること

- 人間の作業を補助する。  
データを集積、分析すること（労力の軽減、様々な計算を高速に行なう）

- 人間の思考を補助する。  
（支援、訂正、発見など）  
→従来のコンピューティングとは異なる手法が必要となる。

	1月	2月	3月	4月
東京	20.4	27.4	90	20.4
名古屋	30.6	38.6	34.6	31.6
大阪	45.9	46.9	45	43.9



データベース、売上集計の計算などは作業を補助する例の代表。  
グラフ化は作業と思考を補助の両方の役割をする。  
→これをもっと進めるには？

# コンピューティングの分類と問題点

- \* ハードコンピューティング → 厳密な計算 (計算時間やコストが増大する傾向がある)
- \* ソフトコンピューティング → 過度の厳密性を避ける事により実用性を向上させる。  
代表的な理論：  
ファジィ理論、ニューロコンピューティング、  
遺伝的アルゴリズム、カオス理論、etc

# ソフトコンピューティング

- \* **ファジィ理論**

人間の言語のような曖昧さを取り扱う事ができる(柔軟かい制御などが得意)。

- \* **ニューロコンピューティング**

神経回路網の応用、学習や予測を行うことができる。

- \* **遺伝的アルゴリズム (GA: Genetic Algorithms)**

生物進化のメカニズムを利用、解の発見などに有効。

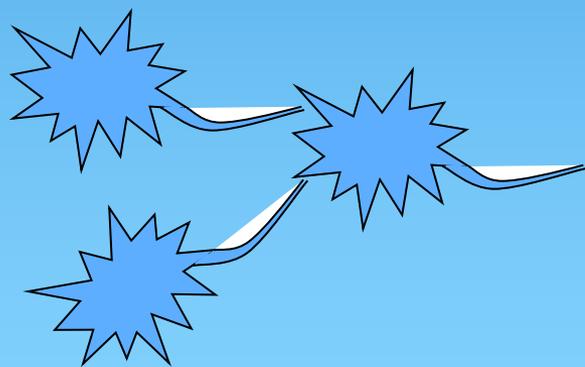
- \* **カオス理論、etc**

自然界にみられる複雑な現象を取り扱う。非線形理論。

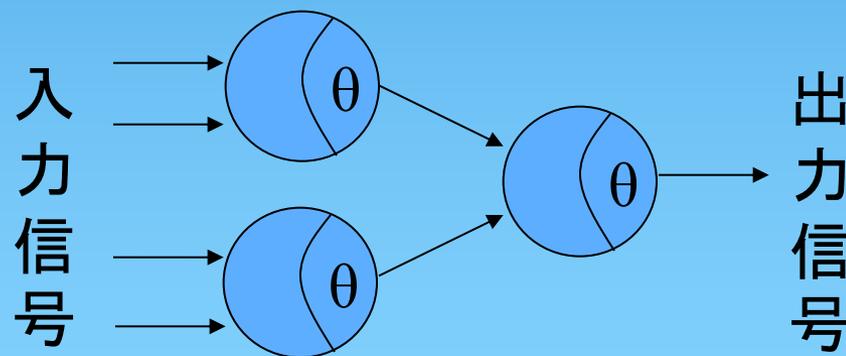
# 神経回路網とニューラルネット

- ・ニューラルネットワークとは

人間の脳を構成する神経回路網をニューロンとそのつながりであるニューラルネットワークとしてコンピュータ上に再現し、問題に適用しようとする新しいアルゴリズムである。



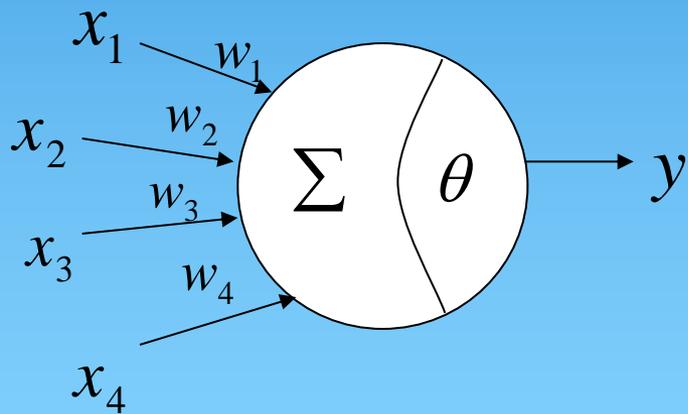
実際の神経回路網  
(生物の脳や神経)



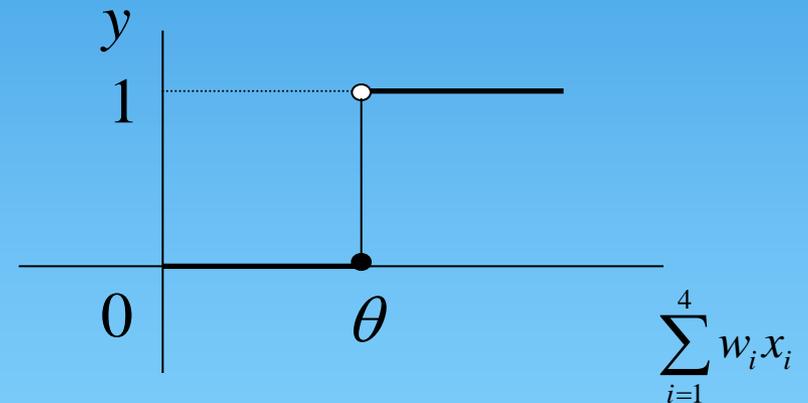
ニューラルネットワーク(コン  
ピュータ上に神経網を再現)

# ニューロンモデルの基本動作

ニューロンは基本的に多入力多出力だが簡単のため4入力1出力かつ閾値モデルの場合を考える



注: 実際の生物ニューロンは生体パルスの頻度で発火し、閾値も個々に異なる。

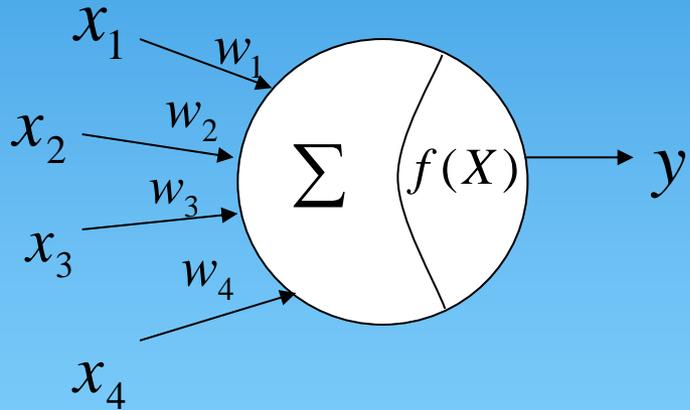


$$y = 0 \quad \sum_{i=1}^4 w_i x_i \leq \theta$$

$$y = 1 \quad \sum_{i=1}^4 w_i x_i > \theta$$

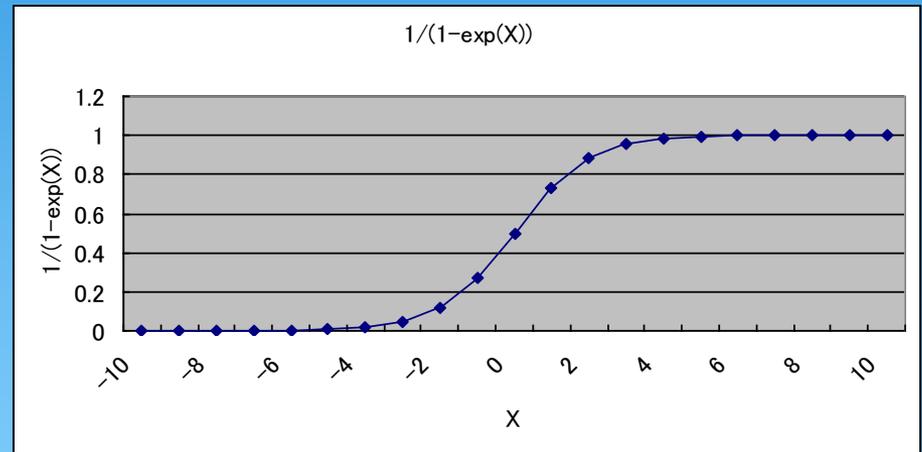
# その他のニューロンモデル

他にもいろいろなニューロンのモデル(応答関数、出力関数の型)がある。以下はシグモイド関数



$$X = \sum_{i=1}^n w_i x_i \quad \text{として}$$

$$y = f(X) = \frac{1}{1 + \exp(-X)}$$



学習は、教師信号と出力との誤差から結合係数を修正して行われる。

(一般デルタ則、BP法)

# ニューラルネットワークの特徴

## ・長所

与えられた数値データから学習や認識を行う。  
非線形関係や対象の構造が未知でも学習できる  
可能性を持つ。(応用例:パターン認識、音声認  
識や文字認識、家電製品等の制御など)

## ・短所

学習や認識の過程、または学習した結果の構  
造の解析が困難である。

# 分類について

## 代表的なニューロンのタイプ

- ・閾値関数、線形関数、シグモイド関数、etc

## 代表的なニューラルネットワークのタイプ

- ・パーセプトロン、ポップフィールドネットワーク、ボルツマンマシンなど。

ネットワークトポロジー(形態)による分類も注意

## 代表的な学習則

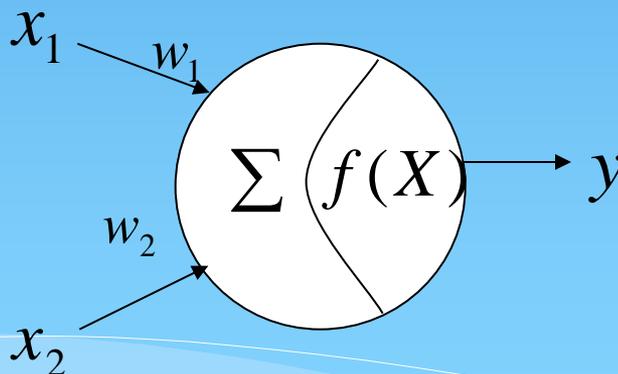
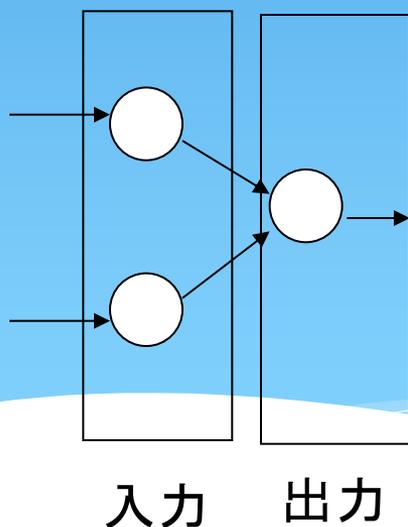
- ・教師なしと教師あり学習、標準デルタ則と一般デルタ則、学習の方向(前向き後向き)など。

特に教師ありの一般デルタ則やフィードバック型のバックプロパゲーション法(BP法)が有名

# パーセプトロン

- 最初に提案されたニューラルネットワークのモデル
- 基本は2層のニューラルネットワーク(本来は3層)

例:2入力のANDを学習するには以下のような2層のニューラルネットワークを考えれば良い



x1	x2	Y
0	0	0
1	0	0
0	1	0
1	1	1

# パーセプトロン (ANDの学習)

## 結果の例

Form1

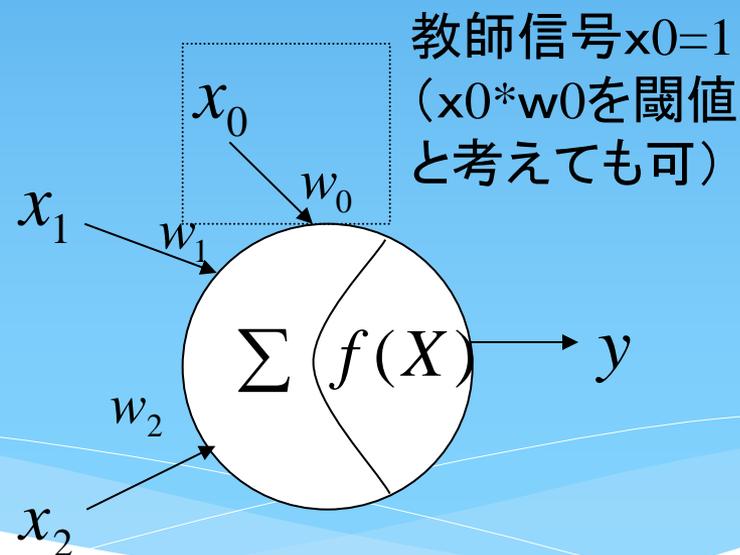
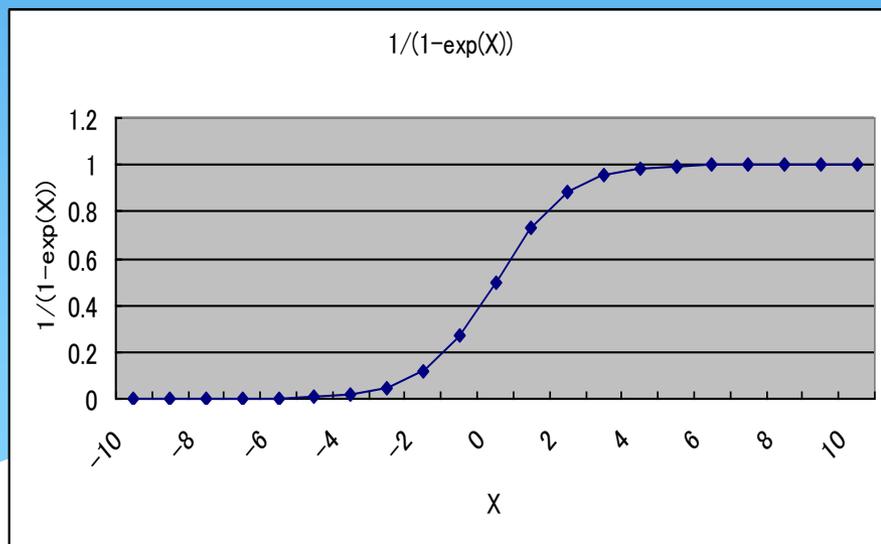
学習係数  学習回数  誤差  data.dat

cnt=0000.	gosa0=0.63518	w=0.23154	0.03307	0.12448	z=0.60135	0.61726	0.63879	0.65407
cnt=0100.	gosa0=0.11977	w=-2.87612	1.81052	1.81321	z=0.05413	0.25712	0.25765	0.67735
cnt=0200.	gosa0=0.06532	w=-4.04217	2.61074	2.61094	z=0.01741	0.19333	0.19336	0.76428
cnt=0300.	gosa0=0.04329	w=-4.79418	3.11956	3.1196	z=0.00826	0.15808	0.15809	0.80889
cnt=0400.	gosa0=0.03179	w=-5.34023	3.48749	3.4875	z=0.00479	0.13574	0.13574	0.8366
cnt=0500.	gosa0=0.02487	w=-5.76488	3.77303	3.77303	z=0.00314	0.12019	0.12019	0.85568
cnt=0600.	gosa0=0.0203	w=-6.11039	4.00506	4.00506	z=0.00222	0.10868	0.10868	0.86974
cnt=0700.	gosa0=0.01708	w=-6.40061	4.19978	4.19978	z=0.00166	0.09976	0.09976	0.88059
cnt=0800.	gosa0=0.01471	w=-6.65022	4.36715	4.36715	z=0.0013	0.0926	0.0926	0.88927
cnt=0900.	gosa0=0.01289	w=-6.86882	4.51366	4.51366	z=0.00104	0.08671	0.08671	0.89639
cnt=1000.	gosa0=0.01145	w=-7.06304	4.64377	4.64377	z=0.00086	0.08176	0.08176	0.90237
w=-7.06304	4.64377	4.64377						
z=0.00086	0.08176	0.08176	0.90237					

# パーセプトロン (結果の検討)

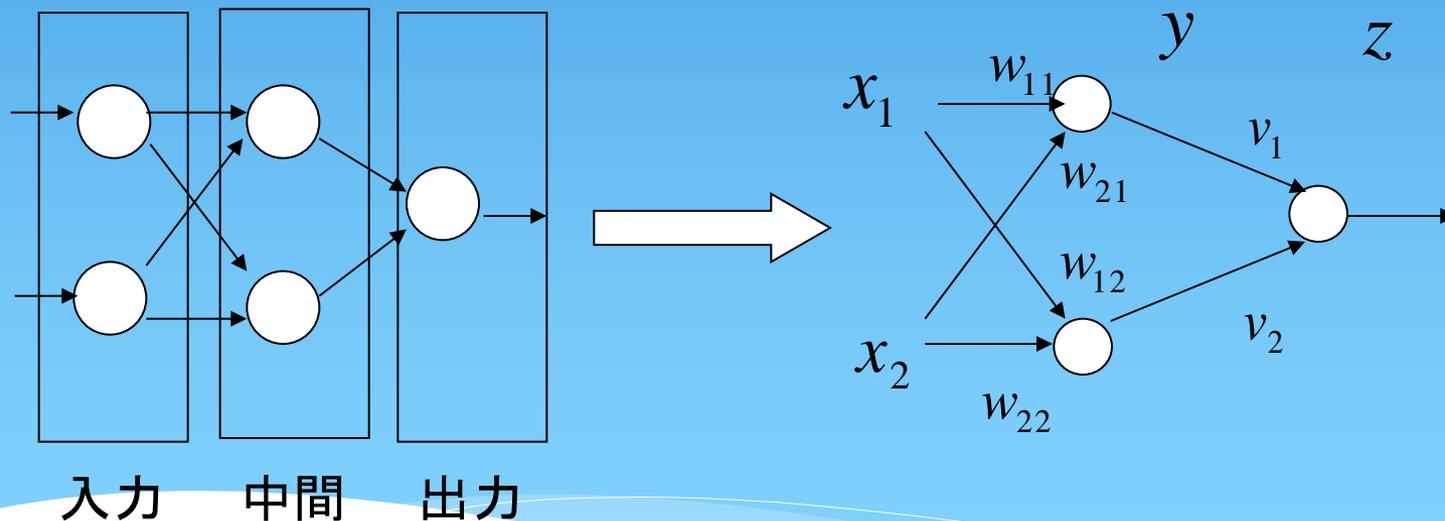
$W_0 = -7.06304$ 、  $W_1 = 4.64377$ 、  $W_2 = 4.64377$

	-7.06304	4.64377	4.64377	$x_0 * w_0$	$x_1 * w_1$	$x_2 * w_2$	$X = \sum(x)$	$\exp(-X)$	$1 + \exp(-X)$	$1 / (1 + \exp(-X))$
pattern1	1	0	0	-7.06304	0	0	-7.06304	1167.99	1168.99	0.000855439
pattern2	1	1	0	-7.06304	4.64377	0	-2.41927	11.23765	12.23765	0.081715016
pattern3	1	0	1	-7.06304	0	4.64377	-2.41927	11.23765	12.23765	0.081715016
pattern4	1	1	1	-7.06304	4.64377	4.64377	2.2245	0.108121	1.108121	0.902428146



# 3層ニューラルネットワーク

パーセプトロンは簡単なルールしか学習できない。入力層と中間層、出力層の3階層構造のネットワークを使うとより複雑な学習ができるようになる。



# 3層ニューロ(EXORの学習)

Form1

学習係数  学習回数  誤差  dataexor.dat

```
cnt=0000. gosa0=0.50156
  u=-0.42043 -0.39428 0.54789 . y=0.39631 0.30641 0.53211 0.43352
  u=-0.97247 0.52156 0.62878 . y=0.27449 0.38924 0.41508 0.5445
  v=0.42162 -0.90651 -0.17098 . z=0.50263 0.51813 0.46577 0.48257
cnt=1000. gosa0=0.46774
  u=-0.28424 -0.57548 -0.48423 . y=0.4295 0.29825 0.31778 0.20821
  u=-2.81684 1.48843 1.47059 . y=0.05677 0.20985 0.2069 0.53513
  v=0.70351 -0.84351 -1.70631 . z=0.56087 0.52364 0.52079 0.40539
cnt=2000. gosa0=0.01053
  u=1.7167 -4.86196 -4.86072 . y=0.84765 0.04129 0.04134 0.00033
  u=-6.54516 4.18368 4.18313 . y=0.00144 0.08618 0.08614 0.86073
  v=3.39311 -7.11279 -6.90458 . z=0.06627 0.92441 0.9244 0.07232
cnt=3000. gosa0=0.0039
  u=1.95287 -5.29384 -5.29304 . y=0.87574 0.0342 0.03422 0.00018
  u=-7.05523 4.52652 4.5262 . y=0.00086 0.07388 0.07386 0.88052
  v=3.89018 -8.05241 -7.91615 . z=0.04038 0.9539 0.9539 0.04388
u=1.952866 -5.293839 -5.293039
u=-7.055225 4.526517 4.526201
v=3.890177 -8.052414 -7.916148
z=0.04038 0.9539 0.9539 0.04388
```

# 3層ニューラルネット(結果の検討2)

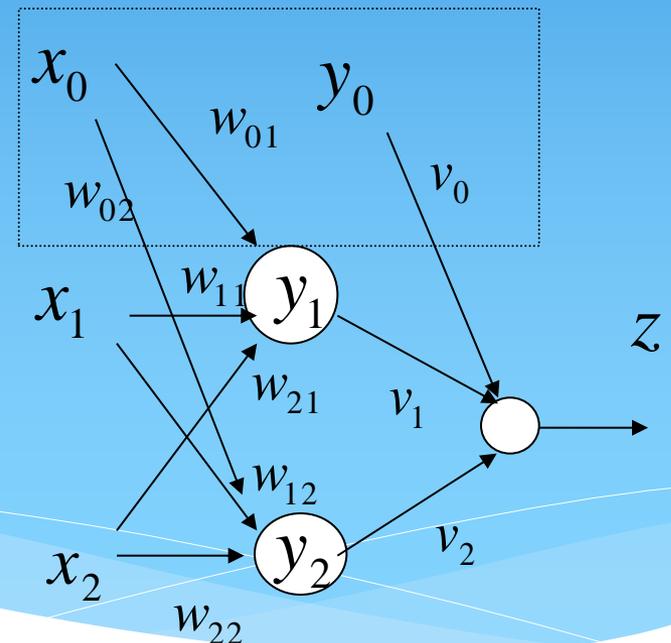
正解

x1	x2	z
0	0	0
1	0	1
0	1	1
1	1	0

ニューラルネットの解答

x1	x2	y1	Y2	z
0	0	0.87575	0.00086	0.04036
1	0	0.03419	0.07386	0.95391
0	1	0.03421	0.07384	0.95391
1	1	0.00017	0.88053	0.04386

教師信号

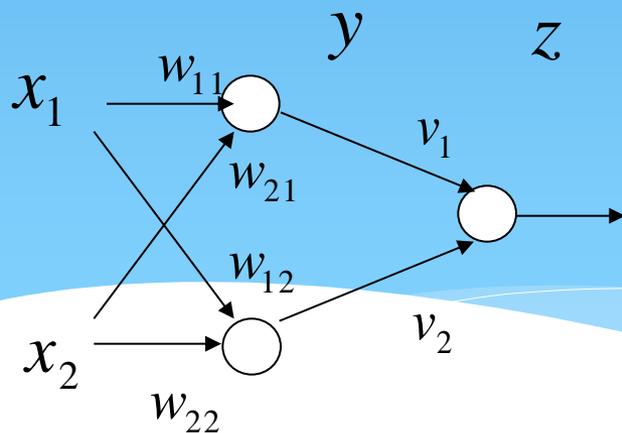


# 3層ニューラル(結果の検討3)

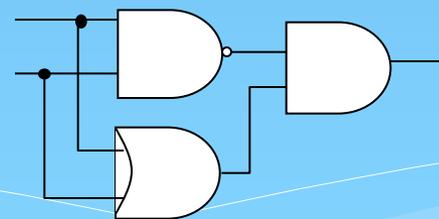
x1	X2	y1	Y2	z
0	0	0.8757588	0.0008621	0.0403638
1	0	0.0341920	0.0738679	0.9539155
0	1	0.0342184	0.0738463	0.9539137
1	1	0.0001779	0.8805304	0.0438699



x1	X2	y1	Y2	z
0	0	1	0	0
1	0	0	0	1
0	1	0	0	1
1	1	0	1	0



電子回路に直すと



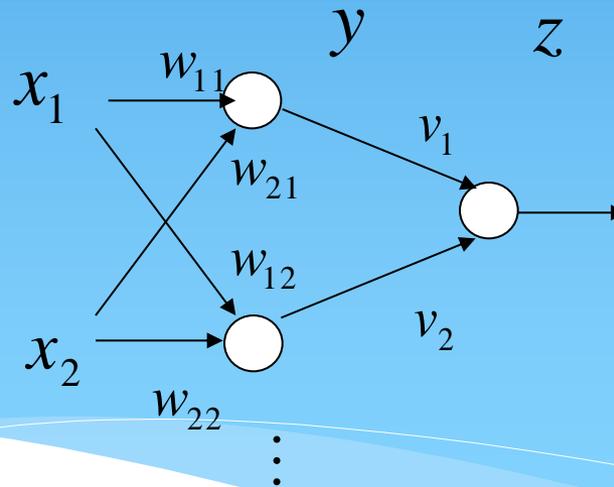
# 時系列データに対する適用

一般的な3層ニューロとバックプロパゲーションだけで時系列データの予測が可能

一昨日の為替  
のデータ

昨日の為替  
のデータ

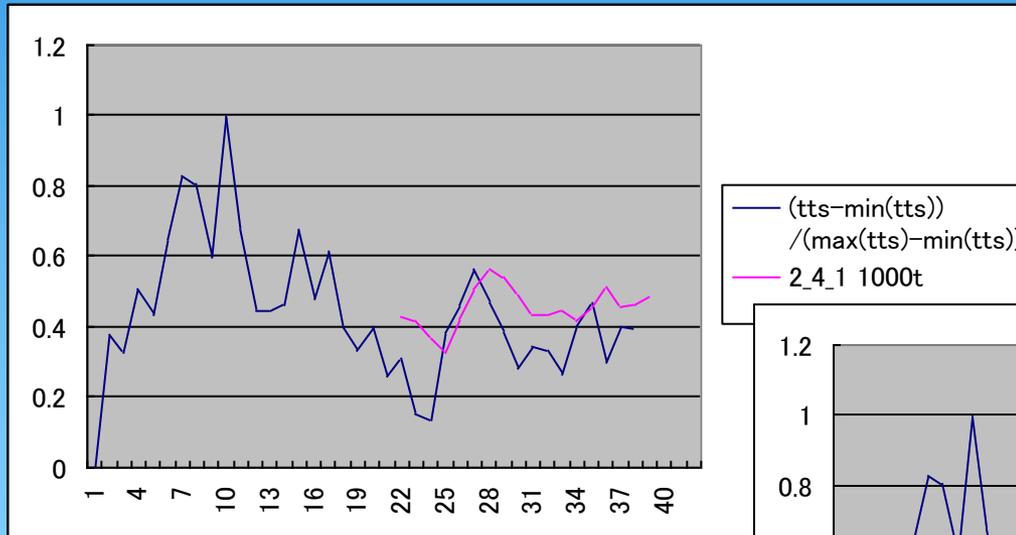
⋮



今日の為替  
の予測値

# 時系列データに対する適用例

入力数(利用する過去のデータ数)によって予測が変化



←入力2、中間層4、  
出力1、学習1000回

入力4、中間層4、 →  
出力1、学習1000回

