

知能機械と自然言語処理

知能機械部 第4回

ソフトウェア情報学部

Goutam Chakraborty

ヒストグラム(棒グラフ)

小学生500人の体重のデータがあります

<http://www.chishiki.soft.iwate-pu.ac.jp/ISNLP/isnlp.html>

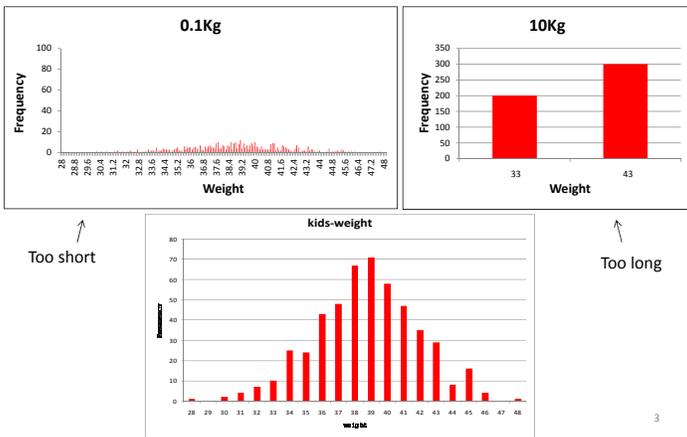
このようなデータから棒グラフを書くとき、最初にデータの最大と最小の値を求めて、全体の範囲(レンジ)を調べる事が重要です。

例えば(レンジ/データ数)の大きさに比例した棒の表示範囲を設定することで、適切なグラフを作る事が出来ます。

下記データのレンジは20Kgです。そのときの棒の表示範囲が0.1Kg, 1Kg, 10Kgであるグラフを次のスライドで比較します。

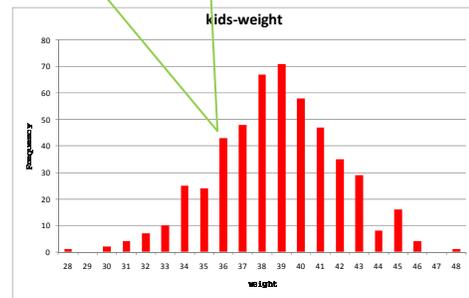
36.48	39.94	42.57	39.53	33.81
43.13	37.97	42.41	39.61	43.30
41.64	39.01	37.77	38.94	41.10
40.37	43.49	37.60	40.14	38.88
38.62	33.43	45.17	42.66	39.98
39.25	41.06	41.17	38.30	38.24
.
.
.

棒の広さによるヒストグラムの形



ヒストグラムから確率を求める

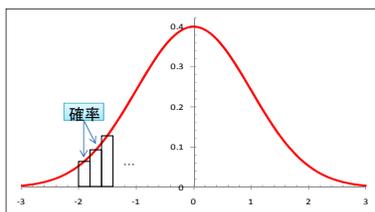
500人の子供の内、35.5~36.5Kgである子供は42人です。よってこの位置の確率は42/500=0.084です。



ヒストグラムから正規分布

離散的データの分布は棒グラフ(ヒストグラム)で表現します。棒グラフの形をまねしてデータの分布を連続関数でも表現出来ます。(たとえば正規分布、指数分布など)

ほとんどの自然のデータは正規分布になってます。データの平均と分散から正規分布の関数を求められますし、その正規分布の関数から確率も求められます。



標準正規分布

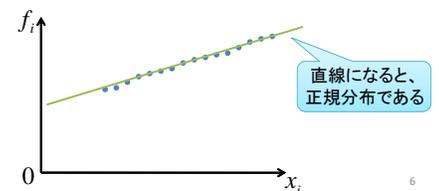
正規分布であることを確かめる方法

ソートを行った後のデータ

i	x_i
1	33.1
2	33.4
3	34.0
⋮	⋮
500	43.7

データ数が少ない場合は、下記の方法で確認できる

1. ソートを行う
2. $f_i = \frac{i-0.375}{n+0.25}$ (n:データ数)
3. グラフにする



正規分布の確率密度関数

正規分布の形は $y(x) = \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$

確率密度関数 $f(x)$ の場合 $\int_{x_{\min}}^{x_{\max}} f(x) dx = 1$

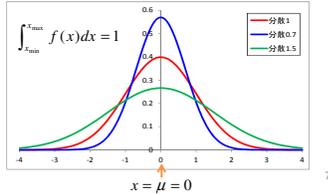
$$\int_{x_{\min}}^{x_{\max}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) dx = \sqrt{2\pi\sigma^2} \Rightarrow \int_{x_{\min}}^{x_{\max}} \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) dx = 1$$

上の結果から正規分布の確率密度関数は

Very Important equation
1-feature normal distribution

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

μ : 平均値 ; σ : 標準偏差



正規分布の場合確率密度関数から確率を求める手法

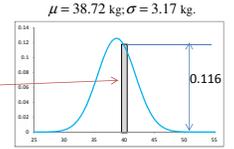
子供500人の内39.5~40.5Kgの人数は58人です。このデータから体重39.5~40.5Kgの確率は $P(39.5 \leq x < 40.5) = \frac{58}{500} = 0.116$

同じ500件のデータの $\mu = 38.72$ kg; $\sigma = 3.17$ kg

正規分布の確率密度関数 $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$ から下記通り確率を求められる。

まず $f(x=40) = \frac{1}{\sqrt{2\pi(3.17)^2}} \exp\left(-\frac{(38.72-40)^2}{2(3.17)^2}\right) = 0.116$ を計算する。

確率を求めたい特色(体重)の幅は (40.5-39.5)=1Kg.です。よって確率は 0.116x1=0.116 で



パラメータ μ と σ の値が分かれば確率を求められます。

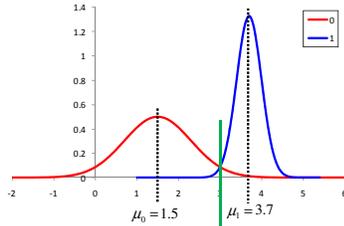
確率密度関数を用いて分類する

(特色一つ; クラス二つの分類問題)

教師データ

特徴量	クラス情報
1.44	0
1.34	0
...	...
2.52	1
2.61	1
...	...

$\mu_0 = 1.5,$
 $\sigma_0 = 0.8$
 $\mu_1 = 3.7,$
 $\sigma_1 = 0.3$



0か1を認識するための教師データ

この特色の値のとき0と1の確率が同じ。よってこの特色の値は境界です。

ベイズの定理(Bayes' Rule)を用いて分類する

0クラスの特色の平均1.5、標準偏差0.8; 1クラスの特色の平均3.7、標準偏差0.3

教師データ

特徴量	クラス情報
1.44	0
1.34	0
...	...
2.52	1
2.61	1
...	...

事前確率 (A prior probability) $P(C_0) = \frac{60}{100}$; $P(C_1) = \frac{40}{100}$

特色の値 $t = 3.0$ 、 t の幅は Δt の場合クラスの条件付き確率は
 $P(3.0 \leq t < (3.0 + \Delta t) | C_0) = \frac{1}{\sqrt{2\pi} \times 0.8} \exp\left(-\frac{(3.0-1.5)^2}{2 \times 0.8^2}\right) \times \Delta t = 0.35 \times \Delta t$
 $P(3.0 \leq t < (3.0 + \Delta t) | C_1) = \frac{1}{\sqrt{2\pi} \times 0.3} \exp\left(-\frac{(3.0-3.7)^2}{2 \times 0.3^2}\right) \times \Delta t = 0.07 \times \Delta t$

特色の値 $t = 3.0$ のときそれぞれクラスの事後確率 (Posterior Probability) は
 $P(C_0 | t = 3.0) = P(3.0 \leq t < (3.0 + \Delta t) | C_0) \times P(C_0) = 0.35 \times \Delta t \times 0.6 = 0.21 \times \Delta t$
 $P(C_1 | t = 3.0) = P(3.0 \leq t < (3.0 + \Delta t) | C_1) \times P(C_1) = 0.07 \times \Delta t \times 0.4 \approx 0.03 \times \Delta t$

よって $t = 3.0$ のときクラス0を判断する。

ベイズの定理(Bayes' Rule)を用いて境界を求める (1)

0クラスの特色の平均1.5、標準偏差0.8; 1クラスの特色の平均3.7、標準偏差0.3

事前確率 (A prior probability) $P(C_0) = \frac{60}{100}$; $P(C_1) = \frac{40}{100}$

教師データ

特徴量	クラス情報
1.44	0
1.34	0
...	...
2.52	1
2.61	1
...	...

特色の値 $t = b$ の時0クラスと1クラスの確率が同じであれば $t = b$ は境界です

$$\left. \begin{aligned} P(b \leq t < (b + \Delta t) | C_0) &= \frac{1}{\sqrt{2\pi} \times 0.8} \exp\left(-\frac{(b-1.5)^2}{2 \times 0.8^2}\right) \times \Delta t \\ P(b \leq t < (b + \Delta t) | C_1) &= \frac{1}{\sqrt{2\pi} \times 0.3} \exp\left(-\frac{(b-3.7)^2}{2 \times 0.3^2}\right) \times \Delta t \end{aligned} \right\} [1]$$

ベイズの定理(Bayes' Rule)を用いて境界を求める (2)

特色の値 $t = b$ の時それぞれクラスの事後確率 (Posterior Probability) は同じですから

$$P(C_0 | t = b) = P(b \leq t < (b + \Delta t) | C_0) \times P(C_0) = P(C_1 | t = b) = P(b \leq t < (b + \Delta t) | C_1) \times P(C_1)$$

前のスライドの式[1]を用いて、クラス条件付き確率の値を代入すると

$$\frac{1}{\sqrt{2\pi} \times 0.8} \exp\left(-\frac{(b-1.5)^2}{2 \times 0.8^2}\right) \times \Delta t \times 0.6 = \frac{1}{\sqrt{2\pi} \times 0.3} \exp\left(-\frac{(b-3.7)^2}{2 \times 0.3^2}\right) \times \Delta t \times 0.4$$

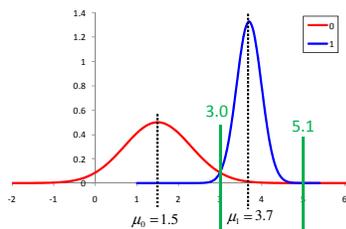
$$\frac{0.6}{2.00} \exp\left(-\frac{(b-1.5)^2}{2 \times 0.8^2}\right) = \frac{0.4}{0.75} \exp\left(-\frac{(b-3.7)^2}{2 \times 0.3^2}\right) \rightarrow \exp\left(-\frac{(b-1.5)^2}{2 \times 0.8^2} + \frac{(b-3.7)^2}{2 \times 0.3^2}\right) = 1.77 \rightarrow$$

$$\left(-\frac{(b-1.5)^2}{2 \times 0.8^2} + \frac{(b-3.7)^2}{2 \times 0.3^2}\right) = \log 1.77 = \ln 1.77 = 0.57 \rightarrow 55b^2 - 447b + 849 = 0 \rightarrow \text{解 } b \text{ は } 3.0 \text{ と } 5.1 \text{ です。}$$

よって $b = 3.0$ と 5.1 が境界の値である。

ベイズの定理(Bayes' Rule)を用いて境界を求める (3)

よって $b = 3.0$ と 5.1 が境界の値である。図を見て分かるように二つの境界点がある。



この特色の値のとき0と1の確率が同じ。
よってこの特色の値は境界です。

この特色の値のとき0と1の確率が同じ。
よってこの特色の値は境界です。

次回の内容

特色増えると下記の図のように重なる部分が無くなって分類制度が増加する。
データの特色が2以上の場合
確率密度関数はどうなりますか？

