

知的情報処理

4. ナイーブなベイズ法

櫻井 彰人
慶應義塾大学理工学部

1

今日の目標

- ベイズ推定ということを少し考える
- ナイーブ・ベイズ法の原理と実装を知る
 - 実務でのベイズ推定方法の一つとして

2

目次

- 今日扱う問題の特徴
- 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ナイーブベイズ
 - ナイーブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差

3

今日扱う問題

- 被説明変数値は2値。但し、確率的に決まる場合
 - (正確には) 決定的に決まってもよい
ただ、未観測の変数に依存している
- この事情は

整理しよう

	穴埋め1	穴埋め2	穴埋め3	穴埋め4
穴埋め1	穴埋め2	穴埋め3	穴埋め4	穴埋め5
穴埋め6	穴埋め7	穴埋め8	穴埋め9	穴埋め10
穴埋め11	穴埋め12	穴埋め13	穴埋め14	穴埋め15
穴埋め16	穴埋め17	穴埋め18	穴埋め19	穴埋め20
穴埋め21	穴埋め22	穴埋め23	穴埋め24	穴埋め25
穴埋め26	穴埋め27	穴埋め28	穴埋め29	穴埋め30
穴埋め31	穴埋め32	穴埋め33	穴埋め34	穴埋め35
穴埋め36	穴埋め37	穴埋め38	穴埋め39	穴埋め40
穴埋め41	穴埋め42	穴埋め43	穴埋め44	穴埋め45
穴埋め46	穴埋め47	穴埋め48	穴埋め49	穴埋め50
穴埋め51	穴埋め52	穴埋め53	穴埋め54	穴埋め55
穴埋め56	穴埋め57	穴埋め58	穴埋め59	穴埋め60
穴埋め61	穴埋め62	穴埋め63	穴埋め64	穴埋め65
穴埋め66	穴埋め67	穴埋め68	穴埋め69	穴埋め70
穴埋め71	穴埋め72	穴埋め73	穴埋め74	穴埋め75
穴埋め76	穴埋め77	穴埋め78	穴埋め79	穴埋め80
穴埋め81	穴埋め82	穴埋め83	穴埋め84	穴埋め85
穴埋め86	穴埋め87	穴埋め88	穴埋め89	穴埋め90
穴埋め91	穴埋め92	穴埋め93	穴埋め94	穴埋め95
穴埋め96	穴埋め97	穴埋め98	穴埋め99	穴埋め100

穴埋め101 穴埋め102 穴埋め103 穴埋め104 穴埋め105

穴埋め106 穴埋め107 穴埋め108 穴埋め109 穴埋め110

穴埋め111 穴埋め112 穴埋め113 穴埋め114 穴埋め115

穴埋め116 穴埋め117 穴埋め118 穴埋め119 穴埋め120

穴埋め121 穴埋め122 穴埋め123 穴埋め124 穴埋め125

穴埋め126 穴埋め127 穴埋め128 穴埋め129 穴埋め130

穴埋め131 穴埋め132 穴埋め133 穴埋め134 穴埋め135

穴埋め136 穴埋め137 穴埋め138 穴埋め139 穴埋め140

穴埋め141 穴埋め142 穴埋め143 穴埋め144 穴埋め145

穴埋め146 穴埋め147 穴埋め148 穴埋め149 穴埋め150

穴埋め151 穴埋め152 穴埋め153 穴埋め154 穴埋め155

穴埋め156 穴埋め157 穴埋め158 穴埋め159 穴埋め160

穴埋め161 穴埋め162 穴埋め163 穴埋め164 穴埋め165

穴埋め166 穴埋め167 穴埋め168 穴埋め169 穴埋め170

穴埋め171 穴埋め172 穴埋め173 穴埋め174 穴埋め175


穴埋め176 穴埋め177 穴埋め178 穴埋め179 穴埋め180

穴埋め181 穴埋め182 穴埋め183 穴埋め184 穴埋め185

穴埋め186 穴埋め187 穴埋め188 穴埋め189 穴埋め190

穴埋め191 穴埋め192 穴埋め193 穴埋め194 穴埋め195

穴埋め196 穴埋め197 穴埋め198 穴埋め199 穴埋め200




4

目次

- 今日扱う問題の特徴
- 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ナイーブベイズ
 - ナイーブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差


5

復習: 条件付確率



$$P = \frac{P_{xy}}{P_y} \cdot P_y$$

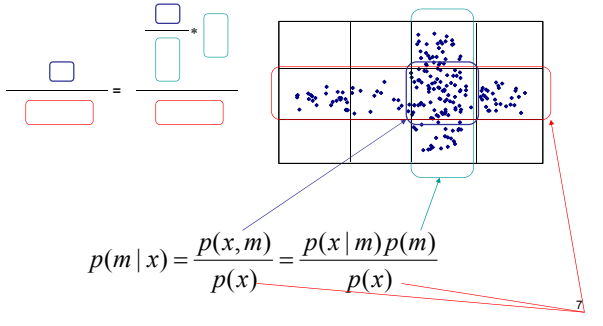
$$P = \frac{P_{xy}}{P_x} \cdot P_x$$



$$p(m|x)p(x) = p(x,m) = p(x|m)p(m)$$

6

Bayesの定理



目次

- 今日扱う問題の特徴
- 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ナイーブベイズ
 - ナイーブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差

8

では、ベイズ推論とは

- ある証拠に基づいて、その原因となった事象を推定するための確率論的方法である。
- Bayesian inference is a method of **statistical inference** in which some kind of **evidence** or observations are used to calculate the **probability that a hypothesis may be true**, or else to update its previously-calculated probability.

$$p(m|x) = \frac{p(x|m)p(m)}{p(x)}$$

Wikipedia より 9


脱線: 一般記事にも

- 「今、話題の自動運転車は、なぜ自動で運転できるのか? その基本メカニズムを「ベイズ理論」にまで遡って解説」
- 小林 雅一. 現代ビジネス、ITトレンド・セレクト.


$$P(B|A) = \frac{P(A|B)P(B)}{P(A)} \quad P(B|A) = (P(A|B) \div P(A)) \times P(B)$$

事後確率 = (実験・測定・観測などの結果) × 事前確率

これをさらに噛み砕いて説明すると、次のようになる。つまり、「まず最初は『いい加減』というか、かなり適当に決めた不正確な確率(事前確率)から出発し、これを何らかの実験や測定、観測などによって、もっと正確な確率(事後確率)へと改良していく」という考え方だ。これがベイズ定理の真意なのである。



【図1】 ベイズ定理は繰り返し、循環的に適用される
<http://gendai.ismedia.jp/articles/-/37143>



【図3】 カルマンフィルターの原理: センサーによる位置測定とベイズ定理の適用を繰り返すことで、誤差を徐々に収束させて、移動体の位置を正確に把握する
 カルマンフィルター (Kalman filter) は、誤差のある観測値を用いて、ある動的システムの状態を推定あるいは制御するための、無限インパルス応答フィルタの一種である

10

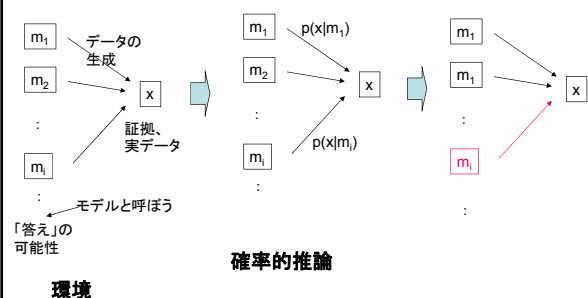
ベイズ推論補足

- 証拠を x で、原因を m で表す
 - 原因の候補を m_i で表す。
- ベイズ推論は、ある方法で、 $p(m_i|x)$ を計算し、(m_i の中から)原因 m を推定すること

$$p(m|x) = \frac{p(x|m)p(m)}{p(x)}$$

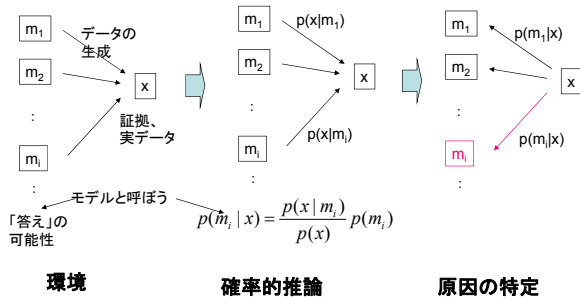
11

(確率的)推論の枠組み



12

(ベイズ)推論の枠組み



$p(m)$ と $p(x|m)$ の推定


$$p(m|x) = \frac{p(x, m)}{p(x)} = \frac{\overbrace{p(x|m)}^{\text{条件付き確率}} \overbrace{p(m)}^{\text{事前確率}}}{\underbrace{p(x)}_{\text{事後確率}}}$$

- $p(m)$ はクラス m の発生度数を用いて推定すればよい
- では、 $p(x|m)$ はどうしたら推定できるだろうか？
 - $p(x|m)$ はモデル m からデータ x が生成される確率を表す。個別の x に対する $p(x|m)$ を知るには、任意の x に対する $p(x|m)$ をしつていればよい(あたりまえ)。通常はモデルの記述そのものである。
- いろいろありうるよなあ。正規分布か、多項分布か、...
- そうしたモデル記述の一つの方法が naïve Bayes である

14

ベイズ推論とナイーブベイズ

• ベイズ推論



• ナイーブベイズ

- ベイズ推論を簡便に行う方法

15

目次

- 今日扱う問題の特徴
- 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ナイーブベイズ
 - ナイーブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差

16

Naïve Bayes なモデル記述

- まず、証拠 x は、複数の属性で記述されているとする
 - これは普通(例外はあるが)。
 - 属性とは、人間であれば、性別、年齢、住所、体重、趣味、...; 販売であれば、商品名、個数、単価、販売日時、顧客の性別、... 身長と体重は独立? 年齢と趣味とは独立? ありえない!
- 各属性は統計的に独立とする
 - 「そんなバカなことするなよ。ありえない!」と言うのが真っ当な人の台詞。しかし、それをあえて仮定するのが、naïve たるゆえん。

17

複数の属性で記述されている

というのは

- 「証拠」 x の属性が $\langle a_1, \dots, a_n \rangle$ であるとすれば、 x と書いても $\langle a_1, \dots, a_n \rangle$ と書いても同じということ
 - 例
 - 「太郎」君は、身長、体重、学科、性別が $\langle 172, 63, \text{管理}, \text{男性} \rangle$ である
 - 「伝票123」は、 $\langle 2013\text{年}10\text{月}15\text{日}18\text{時}30\text{分}, \text{日吉駅前店}, \text{男性}, 20\text{代}, \text{ジュース}, \text{おにぎり} \rangle$ である

18

属性が統計的に独立というのは

- 「証拠」 x の属性が $\langle a_1, \dots, a_n \rangle$ であるとき、

$$p(X=x) = p(A_1=a_1, \dots, A_n=a_n) \\ = \prod_{i=1}^n p(A_i=a_i)$$

- あとで「条件付独立」というのが出てきます。

$$p(X=x|C=c) = p(A_1=a_1, \dots, A_n=a_n|C=c) \\ = \prod_{i=1}^n p(A_i=a_i|C=c)$$

19

Naïve Bayes なモデル記述

とは、

- 「証拠」 x は、その属性で $\langle a_1, \dots, a_n \rangle$ と書け
- 次が成り立つこと

$$p(X=x) = p(A_1=a_1, \dots, A_n=a_n) \\ = \prod_{i=1}^n p(A_i=a_i)$$

$$p(X=x|C=c) = p(A_1=a_1, \dots, A_n=a_n|C=c) \\ = \prod_{i=1}^n p(A_i=a_i|C=c)$$

20

話を戻して

- 欲しいのは、 $p(m|x)$ であった。

$$p(m|x) = \frac{p(x,m)}{p(x)} = \frac{p(x|m)}{p(x)} p(m) = \frac{p(a_1, \dots, a_n|m)}{p(x)} p(m)$$

であるから


$$p(m|x) = \frac{\prod_{i=1}^n p(a_i|m)}{p(x)} p(m)$$

とするのが、naïve Bayes

21

で、それは何がいの？

- それは、属性の数が問題の種だから。
「どんな問題」の種？
- 「属性数が多いと、(確率分布の)パラメータ推定に必要なデータ数が非常に大きくなる」という問題



22


目次

- 今日扱う問題の特徴
- 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ナイーブベイズ
 - ナイーブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差

23




属性数について(続)



- 属性を表す確率変数は離散値をとるものとして。以下、例で考えよう。
- $\langle A_1, A_2, A_3, A_4 \rangle$ は $\langle \text{身長, 体重, 胸囲, 座高} \rangle$ であり、どの変数も、高、中、低の3値(0,1,2と略記する)をとるものとする。
- 特に分布は仮定しない(前提知識なし)。となると、実は、 $3^4=81$ 個の $\langle A_1, A_2, A_3, A_4 \rangle$ の可能な値一組につき一個の確率 $p_{\langle A_1, A_2, A_3, A_4 \rangle}$ が決まれば分布が決まったことになる。総和が1という制約があるので、80個の値が決まればよい。
- この値をデータから決める(推定する)には、データは何個ぐらい必要なのであろうか、考えてみよう(かなりいい加減に)。

24

多項分布



- 各データ(証拠)は互いに独立であるとする。
- $\langle A_1, A_2, A_3, A_4 \rangle$ の発生回数の確率分布は、多項分布となる。
- 多項分布: 事象 e_i が発生する確率を p_i とする (p_i の総和は 1)。総計 n 回繰り返した時に事象 e_i が n_i 回発生する確率は

$$p(n_1, \dots, n_k; n, p_1, \dots, p_k) = \frac{n!}{n_1! \dots n_k!} p_1^{n_1} \dots p_k^{n_k}$$

- なお、期待値、分散、共分散は

$$E(N_i) = np_i, \text{var}(N_i) = np_i(1 - p_i), \text{cov}(N_i, N_j) = -np_i p_j$$


25

属性数について(続々)

- $p_{\langle A_1, A_2, A_3, A_4 \rangle}$ は 81 個あるので、仮に $p_{\langle 0,0,0,0 \rangle} = 1/81$ とし、これだけを推定するものとして。
- $\langle 0,0,0,0 \rangle$ の分布は、2項分布であり、例えば、 $n=8100$ とすれば、平均 $np_{\langle 0,0,0,0 \rangle} = 100$ 、分散 $np_{\langle 0,0,0,0 \rangle}(1 - p_{\langle 0,0,0,0 \rangle}) \approx 98.8$ 、標準偏差 ≈ 9.94 となる。
- ということは、 $p_{\langle 0,0,0,0 \rangle}$ を推定するのに、 $n=8100$ としても、 $\langle 0,0,0,0 \rangle$ の個数が、 100 ± 10 以内 (誤差 10% 以内) となる確率は概算約 68% (ほぼ 1σ だから)。
- 悪い: - (
- ところが、各属性が独立だとすると、 $p_{\langle 0,0,0,0 \rangle} = \prod p_{A_i=0}$ 故、各 $p_{A_i=0}$ を推定すればよく、それぞれに全データ (今の例では $n=8100$ 個) が使える。
- ということは: $p_{A_i=0} = 1/3$ とすると、 $n=8100$ に対し、平均 2700、分散 1800、標準偏差 ≈ 42.4 となる。2700 \pm 270 以内 (誤差 10% 以内) となる確率は概算 $1 - 2/10$ 億 (6σ) 以上
- $n=300$ とすれば、平均 100、分散 ≈ 66.7 、標準偏差 ≈ 8.16 故、 100 ± 10 以内 (誤差 10% 以内) となる確率は 68% よりは大きいが、まあ、同じくらい (1σ より大)

26

```
> x<-dbinom(0:200,8100,1/81)*8100
> plot(x,type="h",xlim=c(70,130))
>
```




27

属性数について(続々々)

ざっと纏めれば

- $p_{\langle A_1, A_2, A_3, A_4 \rangle}$ を、仮定なしに、推定しようとする、 $n=8100$ で誤差 10% 以内となる確率は概算約 68% (ほぼ 1σ)
- 一方、naïve Bayes 的に属性の独立を仮定すると、 $n=300$ で誤差 10% 以内となる確率は 68% よりは大きいが、まあ、同じくらい
- $n=8100$ もあれば、誤差 10% 以内となる確率は $1 - 2/10$ 億 (6σ) 以上



独立ならよいことばかりか？

- 真に独立なら、よいことばかりである。
- しかし、真に独立なわけではない
 - 風邪か否かの診断を考えよう。咳が酷ければ、喉が炎症を起こし、熱が出る。
 - だから、<咳、喉の炎症、熱> という3属性は互いに独立ではない
- 独立でないのに、独立を仮定すると何が起きるか？
- めちゃくちゃになる (何をしているか分からなくなる) はず。
 - 実際、naïve Bayes によって推定した確率値はまったく合っていないといわれている。
- しかし、実際には、naïve Bayes がうまく機能することが多い。これは、
 - 誤った独立性仮定による誤りの増加より、独立性仮定によってパラメータ数を減らしてパラメータの推定精度を向上させたことによる誤りの減少が勝っている
 - 分布を推定しているわけではなく、クラス・分類を推定しているのである。
 - 実際には、独立でなくとも独立として十分近似できることが多いからではないかと考えられる。

29

従って、naïve Bayes

- まあ使ってみよう (と昔の人は考えた)。
- 実際、結構うまくいく。
 - 確率値の推定はだめです。
 - うまくいくのは、分類に使う場合
- では、「分類」に使う方法を以下に。

30

目次

- 今日扱う問題の特徴
- 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ナイーブベイズ
 - ナイーブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差

31


Naïve Bayes 分類器

- 前のスライドに戻って、

$$p(m|x) = \frac{p(x|m)}{p(x)} p(m)$$

において、 m_1 としてクラス1、 m_2 としてクラス2を考える

- 証拠 x は観測（データ1個）の集合で、各データは、属性 $\langle A_1, \dots, A_n \rangle$ で記述される。
 - 各属性は離散値をとる
- 各属性は統計的に独立である
- クラスは、各属性の分布で特徴付けられる
 - 各クラスごと、 A_i のとる値 a_{i1}, \dots, a_{ik} に関する確率 p_{i1}, \dots, p_{ik} が決まっている（これを決めるのが「学習」）




32

Naïve Bayes 分類器 (続)

- 以上の仮定のもと

$$\begin{aligned} p(m_j|x) &= \frac{p(x|m_j)}{p(x)} p(m_j) \\ &\approx p(x|m_j) p(m_j) \\ &= p(a_1, \dots, a_n | m_j) p(m_j) \\ &= p(m_j) \prod_{i=1}^n p(a_i | m_j) \end{aligned}$$

$$m_{\text{MAP}} = \arg \max_j p(m_j | x)$$



Naïve Bayes 分類器 (続々)

- モデル m を記述するパラメータ（この場合は確率 p_{i1}, \dots, p_{ik} です）の推定は次のように行う。
- モデル m から生成されたデータを $\langle y_{j1}, \dots, y_{jn} \rangle$ ($j=1, \dots, N$) としよう
- 属性 A_i ($i=1, \dots, n$) について、 y_{i1}, \dots, y_{iN} のヒストグラムを作る。例えば、1, 2, 3 の3個の値をとるなら、1, 2, 3 の度数を数える。
- これを元に、 p_{i1}, p_{i2}, p_{i3} を推定する。例えば、 $p_{i1}=1$ の度数/ N , $p_{i2}=2$ の度数/ N , $p_{i3}=3$ の度数/ N というようにする。

34

目次

- 今日扱う問題の特徴
- 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ナイーブベイズ
 - ナイーブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差

35

簡単な例で: 天気とテニス



Outlook	Temp.	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Rainy	Cool	Normal	True	No
Overcast	Cool	Normal	True	Yes
Sunny	Mild	High	False	No
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Sunny	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes
Rainy	Mild	High	True	No

（テニスを行う）Play=Yes と（テニスを
行わない）Play=No の2つのクラスが
ある

このとき、下記の（未知、つまり学習
データにない）条件では、Play=Yes
であった（であろう）かPlay=Noであつ
た（であろう）かを推定する。

Outlook	Temp.	Humidity	Windy	Play
Sunny	Cool	High	True	?

Tom Mitchell の Machine Learning という書籍から、よく使われます

36

(回りくどいが)データをクラスに分割

Outlook	Temp.	Humidity	Windy	Play
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Overcast	Cool	Normal	True	Yes
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Sunny	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes

Outlook	Temp.	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Rainy	Cool	Normal	True	No
Sunny	Mild	High	False	No
Rainy	Mild	High	True	No

37

データの数を数えて、推定

	A1=Outlook		A2=Temperature		A3=Humidity		A4=Windy	
度数	Sunny	2	Hot	2	High	3	False	6
	Overcast	4	Mild	4	Normal	6	True	3
	Rainy	3	Cool	3				
	合計	9	合計	9	合計	9	合計	9
確率の推定	Sunny	2/9	Hot	2/9	High	3/9	False	6/9
	Overcast	4/9	Mild	4/9	Normal	6/9	True	3/9
	Rainy	3/9	Cool	3/9				

Outlook	Temp.	Humidity	Windy	Play
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Overcast	Cool	Normal	True	Yes
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Sunny	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes

	A1=Outlook		A2=Temperature		A3=Humidity		A4=Windy	
度数	Sunny	3	Hot	2	High	4	False	2
	Overcast	0	Mild	2	Normal	1	True	3
	Rainy	2	Cool	1				
	合計	5	合計	5	合計	5	合計	5
確率の推定	Sunny	3/5	Hot	2/5	High	4/5	False	2/5
	Overcast	0/5	Mild	2/5	Normal	1/5	True	3/5
	Rainy	2/5	Cool	1/5				

Outlook	Temp.	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Rainy	Cool	Normal	True	No
Sunny	Mild	High	False	No
Rainy	Mild	High	True	No

38

一つの表に纏めておこう

p(m)に関する説明を省きましたが(忘れた、が正しいのだが)、それは、これ

Outlook	Temp.	Humidity	Windy	Play
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Overcast	Cool	Normal	True	Yes
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Rainy	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes

A1=Outlook			A2=Temperature			A3=Humidity			A4=Windy			m=Play		
	Yes	No		Yes	No		Yes	No		Yes	No	Yes	No	
Sunny	2	3	Hot	2	2	High	3	4	False	6	2	9	5	
Overcast	4	0	Mild	4	2	Normal	6	1	True	3	3			
Rainy	3	2	Cool	3	1									
Sunny	2/9	3/5	Hot	2/9	2/5	High	3/9	4/5	False	6/9	2/5	9/14 5/14		
Overcast	4/9	0/5	Mild	4/9	2/5	Normal	6/9	1/5	True	3/9	3/5			
Rainy	3/9	2/5	Cool	3/9	1/5									

39

推論をしよう

$$p(m_i | x) = \frac{p(x | m_i) p(m_i)}{p(x)}$$

$$= \frac{p(a_1, \dots, a_n | m_i) p(m_i)}{p(x)}$$

$$= \left(\prod_{i=1}^n p(a_i | m_i) \right) p(m_i) / p(x)$$

Outlook	Temp.	Humidity	Windy	Play
Sunny	Cool	High	True	?

未知の x

$$p(\text{Play}=\text{yes} | x)$$

$$= p(\text{Outlook}=\text{Sunny} | \text{Play}=\text{yes})$$

$$* p(\text{Temp}=\text{Cool} | \text{Play}=\text{yes})$$

$$* p(\text{Humidity}=\text{High} | \text{Play}=\text{yes})$$

$$* p(\text{Windy}=\text{True} | \text{Play}=\text{yes})$$

$$* p(\text{Play}=\text{yes}) / p(x)$$

$$= (2/9) * (3/9) * (3/9) * (3/9)$$

$$* (9/14) / p(x)$$

$$= 0.0053 / p(x)$$

$$p(\text{Play}=\text{no} | x)$$

$$= p(\text{Outlook}=\text{Sunny} | \text{Play}=\text{no})$$

$$* p(\text{Temp}=\text{Cool} | \text{Play}=\text{no})$$

$$* p(\text{Humidity}=\text{High} | \text{Play}=\text{no})$$

$$* p(\text{Windy}=\text{True} | \text{Play}=\text{no})$$

$$* p(\text{Play}=\text{no}) / p(x)$$

$$= (3/5) * (1/5) * (4/5) * (3/5)$$

$$* (5/14) / p(x)$$

$$= 0.0206 / p(x)$$

言い換えれば、 $p(\text{Play}=\text{yes} | x) < p(\text{Play}=\text{no} | x)$
すなわち、「テニスは行わなかった(行わないだろう)」

注: $1/p(x)$ は気にしないでよいことが分る; 比較すべき相手すべてに共通だから。

40

目次

- ・ 今日扱う問題の特徴
- ・ 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ・ ナイブベイズ
 - ナイブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差

41

Rでは?

```
# package e1071 をインストールした後、
> library(e1071)
> setwd("D:/R/sample")
> xy<-read.csv("04PlayTennis.csv", header=TRUE)
> xyt<-read.csv("04PlayTennisTest01.csv", header=TRUE, as.is=TRUE)
> tt<-data.frame(factor(xyt[,1], levels=levels(xy[,1])))
> for (i in 2:5) {
+   tt<-data.frame(tt, factor(xyt[,i], levels=levels(xy[,i])))
+ }
> names(tt)<-names(xy)
> tt
  Outlook Temp. Humidity windy Play
1  Sunny  Cool   High    True  <NA>
> m <- naiveBayes(xy[, -5], xy[, 5])
> predict(m, tt)
[1] No
Levels: No Yes
>
```

xyt を直接 (as.is=FALSE で) 使うことができないのは、テストデータを factor に変換するとき (read.csv 内) に、xy の levels を参照するような指定ができないためである。上記のように手で変換せざるを得ない。

42

補足1

Forループではなく、applyを使いたいのだが、levels が結合されてしまい、うまくいかない。

```
# package e107 をインストールした後、
> library(e1071)
> setwd("D:/R/sample")
> xy<-read.csv("04PlayTennis.csv", header=TRUE)
> xyt<-read.csv("04PlayTennisTest01.csv", header=TRUE, as.is=TRUE)
> tt<-apply(as.data.frame(1:5),1,
  function(i) factor(xyt[,i],levels=levels(xy[,i])))
> tt
[1] Sunny Cool High True <NA>
Levels: Overcast Rainy Sunny Cool Hot Mild High Normal False True No Yes
```

43

補足2

予測の確率を出力することもできる。type="raw" を加えればよい。
正規化(総和が1)した値が出力される。

```
> predict(m, tt, type="raw")
      No      Yes
[1,] 0.7954173 0.2045827
>
```

44

目次

- 今日扱う問題の特徴
- 復習
 - 条件付確率とベイズの定理
 - ベイズ推論
- ナイーブベイズ
 - ナイーブな記述ということ
 - 属性数について
 - 分類器
 - 簡単な例
 - Rでは
 - 学習誤差

45

パラメータと学習誤差(訓練誤差)

```
> m
Naive Bayes Classifier for Discrete Predictors

call:
naiveBayes.default(x = xy[, -5], y = xy[, 5])

A-priori probabilities:
xy[, 5]
      No      Yes
0.3571429 0.6428571

Conditional probabilities:
      Outlook
xy[, 5] Overcast rainy Sunny
      No 0.0000000 0.4000000 0.6000000
      Yes 0.4444444 0.3333333 0.2222222

      Temp.
xy[, 5] Cool Hot Mild
      No 0.2000000 0.4000000 0.4000000
      Yes 0.3333333 0.2222222 0.4444444

      Humidity
xy[, 5] High Normal
      No 0.8000000 0.2000000
      Yes 0.3333333 0.6666667

      Windy
xy[, 5] False True
      No 0.4000000 0.6000000
      Yes 0.6666667 0.3333333
```

confusion matrix:
(Weka と行・列が逆)

```
> table(predict(m, xy[, -5]), xy[, 5])
      No Yes
Yes 1 9
>
```

Yesと予測した
正解はNo

A1=Outlook	A2=Temperature	A3=Humidity	A4=Windy	outPlay
Yes No	Yes No	Yes No	Yes No	Yes No
Sunny 2 3	Hot 2 2	High 3 4	False 6 2	9 5
Overcast 4 0	Mild 4 2	Normal 6 1	True 3 3	
Rainy 5 2	Cool 5 1			
Sunny 2/9 3/5	Hot 2/9 2/5	High 3/9 4/5	False 6/9 2/5	9/14 5/14
Overcast 4/9 0/5	Mild 4/9 2/5	Normal 6/9 1/5	True 3/9 3/5	
Rainy 5/9 2/5	Cool 5/9 1/5			

46

今日の課題

- Naïve Bayes 法を用いて、下図左の訓練データが与えられたとき、下図右のテストデータの属性「スキー」の値を推定せよ。
- Rを使ってください。データはファイルに用意してあります。「確率」も出してください。

雪	天気	シーズン	体調	スキー
ベタ	霧	ロー	回復	no
新雪	晴	ロー	回復	yes
新雪	霧	ロー	回復	yes
ざらめ	霧	ロー	怪我	no
新雪	晴	ロー	怪我	no
ベタ	晴	ロー	回復	yes
新雪	霧	ロー	回復	yes
ベタ	晴	半ば	回復	yes
新雪	晴	ハイ	回復	yes
新雪	風	ロー	回復	yes
ざらめ	霧	半ば	回復	no
新雪	風	ロー	回復	yes
新雪	晴	半ば	回復	yes
ざらめ	風	ハイ	疲労	no

雪	天気	シーズン	体調	スキー
ベタ	風	半ば	疲労	?

47

今でも研究が

Francesco Sambo, Alberto Malovini, Niina Sandholm, Monica Stavarachi et al. (31 authors)
Novel genetic susceptibility loci for diabetic end-stage renal disease identified through robust naive Bayes classification
Diabetologia, 57(8), 1611-1622, 2014.

Jessica Minnier, Ming Yuan, Jun S. Liu & Tianxi Cai
Risk Classification with an Adaptive Naive Bayes Kernel Machine Model
Journal of the American Statistical Association, online: 08 Apr 2014

Nayyar A. Zaidi, Jesús Cerquides, Mark J. Carman, Geoffrey I. Webb
Alleviating Naive Bayes Attribute Independence Assumption by Attribute Weighting
Journal of Machine Learning Research, 14(Jul):1947–1988, 2013.

Liangxiao Jiang, Zhihua Cai, Harry Zhang & Dianhong Wang
Naive Bayes text classifiers: a locally weighted learning approach
Journal of Experimental & Theoretical Artificial Intelligence, 25(2), 273-286, 2013

Sotiris Kotsiantis
Increasing the accuracy of incremental naive bayes classifier using instance based learning
International Journal of Control, Automation and Systems, 11(1), 159-166, 2013

48

まとめ

- ベイズ推論
 - 証拠を発生させた原因(モデル)の確率(条件付確率)を求め、それに基づき、原因(モデル)を推定する
- 困難点
 - (簡単な形のモデルが仮定できない場合)パラメータを決めるのに必要な学習データ数が膨大にある
- ナイーブベイズ
 - その困難点の解決方法の一つ
 - (データを表現する)属性が統計的に独立だとする
 - 実際には成立し得ない仮定であるが、結構うまく働く
- 今でも改善の研究が！

49