

知能システム開発特論: 第2回

データマイニングの基礎2: データセット

ダビド (david@iwate-pu.ac.jp)

IPU

15 December 2016

データ(Data)

- すべてのデータセットはデータ行列ではなく、順列、テキスト、時系列、画像、音声、ビデオ、などもある。
- 特徴抽出による上記のデータはデータ行列に変換できる。
- データ分析はエンティティごとに独立ということ想定している。実世界にはそれぞれのエンティティはさまざまな関係もある。データグラフのモデルも考えられる。

属性の種類: 量的変数 vs 質的変数

- 量的変数(quantitative or numeric):

例: 重さ、温度、物の数

- 質的変数(qualitative or categorical): 演算不可能

例: 人間の目の色、郵便番号、IPアドレス、
数字の桁{0,1,...,9}、

Iris花のクラス{Setosa, Versicolor, Virginica}

目標変数(target variable): 二つのカテゴリの表現が多い。

アイリスデータセットのサンプル

	Sepal.Length [↕]	Sepal.Width [▼]	Petal.Length [↕]	Petal.Width [↕]	Species [↕]
12	4.8	3.4	1.6	0.2	setosa
25	4.8	3.4	1.9	0.2	setosa
7	4.6	3.4	1.4	0.3	setosa
125	6.7	3.3	5.7	2.1	virginica
145	6.7	3.3	5.7	2.5	virginica
101	6.3	3.3	6.0	2.5	virginica
57	6.3	3.3	4.7	1.6	versicolor
24	5.1	3.3	1.7	0.5	setosa
50	5.0	3.3	1.4	0.2	setosa
126	7.2	3.2	6.0	1.8	virginica
51	7.0	3.2	4.7	1.4	versicolor
121	6.9	3.2	5.7	2.3	virginica

データの代数的な視点

- データ行列(Data Matrix)

行:レコード、サンプル、エンティティ、オブジェクト、
特徴ベクター、

5-タプル

$$x_1 = (5.9, 3.0, 4.2, 1.5, \textit{versicolor})$$

列:属性、プロパティ、特徴、変数、フィールド

データ行列(DATA MATRIX)

$n \times d$ データ行列 (data matrix), n 行(rows) and d 列(columns)

行 (rows) = データセットのエンティティ(entities in the dataset)

列 (columns) = 属性、プロパティ(attributes or properties)

$$D = \begin{pmatrix} \mathbf{x}_{11} & \mathbf{x}_{12} & \cdots & \mathbf{x}_{1d} \\ \mathbf{x}_{21} & \mathbf{x}_{22} & \cdots & \mathbf{x}_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_{n1} & \mathbf{x}_{n2} & \cdots & \mathbf{x}_{nd} \end{pmatrix}$$

\mathbf{x}_i : i -th row d -tuple : $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{id})$

X_j : j -th column n -tuple : $X_j = (x_{1j}, x_{2j}, \dots, x_{nj})$




row=={instance, example, record, transaction, object, point, feature-vector, tuple}

column=={attribute, property, feature, dimension, variable, field}

n : データのサイズ (size of the data)

d : データの次元 (dimensionality of the data)

幾何学の観点：3次元、2次元、1次元の投影



離散属性 vs 連続属性

離散属性 (Numeric attribute)

属性の領域: $\text{domain}(\text{Age}) = \mathbb{N}$, $\text{domain}(\text{petal length}) = \mathbb{R}^+$

種類: 離散、連続、バイナリ

カテゴリ型属性 (Categorical attribute)

属性の領域: $\text{domain}(\text{血液型}) = \{A, B, AB, O\}$, $\text{domain}(\text{性別}) = \{M, F\}$

アイリスデータセットの統計結果

```
> summary(iris)
```




```
 Sepal.Length  Sepal.Width  Petal.Length  Petal.Width
Min.   :4.300  Min.   :2.000  Min.   :1.000  Min.   :0.100
1st Qu.:5.100  1st Qu.:2.800  1st Qu.:1.600  1st Qu.:0.300
Median :5.800  Median :3.000  Median :4.350  Median :1.300
Mean   :5.843  Mean   :3.057  Mean   :3.758  Mean   :1.199
3rd Qu.:6.400  3rd Qu.:3.300  3rd Qu.:5.100  3rd Qu.:1.800
Max.   :7.900  Max.   :4.400  Max.   :6.900  Max.   :2.500

 Species
setosa   :50
versicolor:50
virginica :50
```

サンプリング Univariate

f, F, μ, σ, r : 母集団の確率分布, 累積分布関数, 平均, 標準偏差, レンジ





$\hat{f}, \hat{F}, \hat{\mu}, \hat{\sigma}, \hat{r}$: サンプルの内容




サンプリング Univariate

f, F, μ, σ, r : 母集団の確率分布, 累積分布関数, 平均, 標準偏差, レンジ

$\hat{f}, \hat{F}, \hat{\mu}, \hat{\sigma}, \hat{r}$: サンプルの内容




アイリスデータセットの属性の可視化 4次元の属性を2次元のプロット (Draftsman's display)



アイリスデータセットの属性の可視化

4次元の属性とピアソン相関性(相関係数)




$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\left(\left(\sum_{i=1}^n (x_i - \bar{x})^2 \right) \left(\sum_{i=1}^n (y_i - \bar{y})^2 \right) \right)^{1/2}}$$


アイリスデータセットの属性の可視化

Boxplot


Sepal.Length




Sepal.Width



Petal.Length



Petal.Width



確率変数の変換 (Probabilistic Data view)

- 量的変数を離散変数に変換する
 - ビンの対応と作成
- 確率的な機械学習 (ベイズ学習モデル) のデータを利用するために、量的変数を確率変数に変換必要ある

サンプリング

- 質的属性の扱い、一つの変数(univariate)
- ベルヌーイ変数

$$X = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = (x_1 \ x_2 \ \dots \ x_n)^T$$

$$x_i \in \text{dom}(X) = \{a_1, a_2, \dots, a_m\}$$

$$m = 2$$

$$\text{ベルヌーイ変数: } X(v) = \begin{cases} 1 & \text{if } v = a_1 \\ 0 & \text{if } v = a_2 \end{cases}$$

$$\text{確率質量関数 (Probability mass function PMF): } P(X = x) = f(x) = \begin{cases} p_1 & \text{if } x = 1 \\ p_0 & \text{if } x = 0 \end{cases}$$

サンプリング Univariate

f, F, μ, σ, r : 母集団の確率分布, 累積分布関数, 平均, 標準偏差, レンジ

$\hat{f}, \hat{F}, \hat{\mu}, \hat{\sigma}, \hat{r}$: サンプルの内容

サンプリング

- 質的属性の扱い、一つの変数(univariate)
- ベルヌーイ変数

$$p_1 + p_0 = 1$$

$$P(X = x) = f(x) = p^x (1 - p)^{1-x}, \text{ where } p_0 = p \text{ and } p_1 = 1 - p$$

$$\hat{\mu} = \hat{p}$$

$$\hat{\sigma} = \text{var}(X) = \hat{p}(1 - \hat{p})$$

Iris dataset: $\text{dom}(\text{sepal_length}) = \{\text{Long}, \text{Short}\}$

$$\text{Long} = [7, +\infty), \text{Short} = (-\infty, 7)$$

平均: $\hat{\mu} = \hat{p} = 13/150 = 0.087$

分散: $\hat{\sigma} = \text{var}(X) = \hat{p}(1 - \hat{p}) = 0.087(1 - 0.087) = 0.079$

出現数N: $E[N] = n\hat{p} = 150 \times 0.087 = 13$

出現数Nの分散: $\text{var}(N) = n\hat{p}(1 - \hat{p}) = 150 \times 0.079 = 11.9$

サンプリング

- 質的属性の扱い、一つの変数(univariate)
- 複数ベルヌーイ変数

複数ベルヌーイ変数:

$$e_i = (0 \ \dots \ 0 \ 1(\text{成分}i) \ 0 \ \dots \ 0)^T$$

$$X(v) = e_i \text{ if } v = a_i$$

確率質量関数 (Probability mass function PMF): $P(X = e_i) = f(e_i) = p_i, \sum_{i=1}^m p_i = 1$

- 共分散行列

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1m} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1m} & \sigma_{2m} & \dots & \sigma_m^2 \end{pmatrix} = \begin{pmatrix} p_1(1-p_1) & -p_1p_2 & \dots & -p_1p_m \\ -p_1p_2 & p_2(1-p_2) & \dots & -p_2p_m \\ \vdots & \vdots & \ddots & \vdots \\ -p_1p_m & -p_2p_m & \dots & p_m(1-p_m) \end{pmatrix}$$

$$\widehat{\Sigma} = \widehat{\mathbf{P}} - \widehat{\mathbf{p}} \cdot \widehat{\mathbf{p}}^T \quad \text{where } \widehat{\mathbf{P}} = \text{diag}(\widehat{\mathbf{p}}), \text{ and } \widehat{\mathbf{p}} = \widehat{\boldsymbol{\mu}} = (\widehat{p}_1, \widehat{p}_2, \dots, \widehat{p}_m)^T$$

サンプリング

- 質的属性の扱い、一つの変数(univariate)
- 複数ベルヌーイ変数

Table 3.1. Discretized sepal length attribute

Bins	Domain	Counts
[4.3, 5.2]	Very Short (a_1)	$n_1 = 45$
(5.2, 6.1]	Short (a_2)	$n_2 = 50$
(6.1, 7.0]	Long (a_3)	$n_3 = 43$
(7.0, 7.9]	Very Long (a_4)	$n_4 = 12$


$\{a_1 = \text{VeryShort}, a_2 = \text{Short}, a_3 = \text{Long}, a_4 = \text{VeryLong}\}$

$$\mathbf{X}(v) = \begin{cases} \mathbf{e}_1 = (1, 0, 0, 0) & \text{if } v = a_1 \\ \mathbf{e}_2 = (0, 1, 0, 0) & \text{if } v = a_2 \\ \mathbf{e}_3 = (0, 0, 1, 0) & \text{if } v = a_3 \\ \mathbf{e}_4 = (0, 0, 0, 1) & \text{if } v = a_4 \end{cases}$$

サンプリング

- 質的属性の扱い、一つの変数(univariate)
- 複数ベルヌーイ変数

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i = \sum_{i=1}^m \frac{n_i}{n} \mathbf{e}_i = \begin{pmatrix} n_1/n \\ n_2/n \\ \vdots \\ n_m/n \end{pmatrix} = \begin{pmatrix} \hat{p}_1 \\ \hat{p}_2 \\ \vdots \\ \hat{p}_m \end{pmatrix} = \hat{\mathbf{p}}$$



$$\begin{aligned} \hat{p}_1 &= 45/150 = 0.3 \\ \hat{p}_2 &= 50/150 = 0.333 \\ \hat{p}_3 &= 43/150 = 0.287 \\ \hat{p}_4 &= 12/150 = 0.08 \end{aligned}$$

Figure 3.1. Probability mass function: sepal length.

サンプリング

- 質的属性の扱い、一つの変数(univariate)
- 複数ベルヌーイ変数

$$\begin{aligned}\hat{\Sigma} &= \hat{\mathbf{P}} - \hat{\mathbf{p}} \cdot \hat{\mathbf{p}}^T \\ &= \begin{pmatrix} 0.3 & 0 & 0 & 0 \\ 0 & 0.333 & 0 & 0 \\ 0 & 0 & 0.287 & 0 \\ 0 & 0 & 0 & 0.08 \end{pmatrix} - \begin{pmatrix} 0.3 \\ 0.333 \\ 0.287 \\ 0.08 \end{pmatrix} (0.3 \quad 0.333 \quad 0.287 \quad 0.08) \\ &= \begin{pmatrix} 0.3 & 0 & 0 & 0 \\ 0 & 0.333 & 0 & 0 \\ 0 & 0 & 0.287 & 0 \\ 0 & 0 & 0 & 0.08 \end{pmatrix} - \begin{pmatrix} 0.09 & 0.1 & 0.086 & 0.024 \\ 0.1 & 0.111 & 0.096 & 0.027 \\ 0.086 & 0.096 & 0.082 & 0.023 \\ 0.024 & 0.027 & 0.023 & 0.006 \end{pmatrix} \\ &= \begin{pmatrix} 0.21 & -0.1 & -0.086 & -0.024 \\ -0.1 & 0.222 & -0.096 & -0.027 \\ -0.086 & -0.096 & 0.204 & -0.023 \\ -0.024 & -0.027 & -0.023 & 0.074 \end{pmatrix}\end{aligned}$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)

$$\mathbf{D} = \begin{pmatrix} X_1 & X_2 \\ x_{11} & x_{12} \\ x_{21} & x_{22} \\ \vdots & \vdots \\ x_{n1} & x_{n2} \end{pmatrix}$$

$$\text{dom}(X_1) = \{a_{11}, a_{12}, \dots, a_{1m_1}\}$$

$$\text{dom}(X_2) = \{a_{21}, a_{22}, \dots, a_{2m_2}\}$$

$$P(\mathbf{X}_1 = \mathbf{e}_{1i}) = f_1(\mathbf{e}_{1i}) = p_i^1 = \prod_{k=1}^{m_1} (p_i^1)^{e_{ik}^1}$$

$$P(\mathbf{X}_2 = \mathbf{e}_{2j}) = f_2(\mathbf{e}_{2j}) = p_j^2 = \prod_{k=1}^{m_2} (p_j^2)^{e_{jk}^2}$$

$$\mathbf{X}((v_1, v_2)^T) = \begin{pmatrix} \mathbf{X}_1(v_1) \\ \mathbf{X}_2(v_2) \end{pmatrix} = \begin{pmatrix} \mathbf{e}_{1i} \\ \mathbf{e}_{2j} \end{pmatrix}$$

共分布、条件:

$$P(\mathbf{X} = (\mathbf{e}_{1i}, \mathbf{e}_{2j})^T) = f(\mathbf{e}_{1i}, \mathbf{e}_{2j}) = p_{ij} = \prod_{r=1}^{m_1} \prod_{s=1}^{m_2} p_{ij}^{e_{ir}^1 \cdot e_{js}^2} \quad \sum_{i=1}^{m_1} \sum_{j=1}^{m_2} p_{ij} = 1$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)
- 平均、共分散行列

$$\hat{\boldsymbol{\mu}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i = \frac{1}{n} \begin{pmatrix} \sum_{i=1}^{m_1} n_i^1 \mathbf{e}_{1i} \\ \sum_{j=1}^{m_2} n_j^2 \mathbf{e}_{2j} \end{pmatrix} = \frac{1}{n} \begin{pmatrix} n_1^1 \\ \vdots \\ n_{m_1}^1 \\ n_1^2 \\ \vdots \\ n_{m_2}^2 \end{pmatrix} = \begin{pmatrix} \hat{p}_1^1 \\ \vdots \\ \hat{p}_{m_1}^1 \\ \hat{p}_1^2 \\ \vdots \\ \hat{p}_{m_2}^2 \end{pmatrix} = \begin{pmatrix} \hat{\mathbf{p}}_1 \\ \hat{\mathbf{p}}_2 \end{pmatrix} = \begin{pmatrix} \hat{\boldsymbol{\mu}}_1 \\ \hat{\boldsymbol{\mu}}_2 \end{pmatrix}$$

$$\hat{\boldsymbol{\Sigma}} = \begin{pmatrix} \hat{\boldsymbol{\Sigma}}_{11} & \hat{\boldsymbol{\Sigma}}_{12} \\ \hat{\boldsymbol{\Sigma}}_{12}^T & \hat{\boldsymbol{\Sigma}}_{22} \end{pmatrix}$$

$$I_{ij}(\mathbf{x}_k) = \begin{cases} 1 & \text{if } \mathbf{x}_{k1} = \mathbf{e}_{1i} \text{ and } \mathbf{x}_{k2} = \mathbf{e}_{2j} \\ 0 & \text{otherwise} \end{cases}$$

$$\hat{\boldsymbol{\Sigma}}_{11} = \hat{\mathbf{P}}_1 - \hat{\mathbf{p}}_1 \hat{\mathbf{p}}_1^T \quad \hat{\mathbf{P}}_1 = \text{diag}(\hat{\mathbf{p}}_1) \text{ and } \hat{\mathbf{P}}_2 = \text{diag}(\hat{\mathbf{p}}_2)$$

$$\hat{\boldsymbol{\Sigma}}_{22} = \hat{\mathbf{P}}_2 - \hat{\mathbf{p}}_2 \hat{\mathbf{p}}_2^T \quad \hat{\mathbf{P}}_{12}(i, j) = \hat{f}(\mathbf{e}_{1i}, \mathbf{e}_{2j}) = \frac{1}{n} \sum_{k=1}^n I_{ij}(\mathbf{x}_k) = \frac{n_{ij}}{n} = \hat{p}_{ij}$$

$$\hat{\boldsymbol{\Sigma}}_{12} = \hat{\mathbf{P}}_{12} - \hat{\mathbf{p}}_1 \hat{\mathbf{p}}_2^T$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)

$dom(X_1) = \{a_{11} = \text{VeryShort}, a_{12} = \text{Short}, a_{13} = \text{Long}, a_{14} = \text{VeryLong}\}$

$dom(X_2) = \{a_{21} = \text{Short}, a_{22} = \text{Medium}, a_{23} = \text{Long}\}$

Table 3.3. Discretized sepal width attribute

Bins	Domain	Counts
[2.0, 2.8]	Short (a_1)	47
(2.8, 3.6]	Medium (a_2)	88
(3.6, 4.4]	Long (a_3)	15

$$\hat{\mu}_1 = \hat{\mathbf{p}}_1 = \begin{pmatrix} 0.3 \\ 0.333 \\ 0.287 \\ 0.08 \end{pmatrix} \quad \hat{\mu}_2 = \hat{\mathbf{p}}_2 = \frac{1}{150} \begin{pmatrix} 47 \\ 88 \\ 15 \end{pmatrix} = \begin{pmatrix} 0.313 \\ 0.587 \\ 0.1 \end{pmatrix}$$

$$\hat{\mu} = \begin{pmatrix} \hat{\mu}_1 \\ \hat{\mu}_2 \end{pmatrix} = \begin{pmatrix} \hat{\mathbf{p}}_1 \\ \hat{\mathbf{p}}_2 \end{pmatrix} = (0.3, 0.333, 0.287, 0.08 \mid 0.313, 0.587, 0.1)^T$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)

Table 3.4. Observed Counts (n_{ij}): sepal length and sepal width

		X_2		
		Short (e_{21})	Medium (e_{22})	Long (e_{23})
X_1	Very Short (e_{11})	7	33	5
	Short (e_{22})	24	18	8
	Long (e_{13})	13	30	0
	Very Long (e_{14})	3	7	2

$$\begin{aligned} E[\mathbf{X}_1]E[\mathbf{X}_2]^T &= \hat{\boldsymbol{\mu}}_1 \hat{\boldsymbol{\mu}}_2^T = \hat{\mathbf{p}}_1 \hat{\mathbf{p}}_2^T \\ &= \begin{pmatrix} 0.3 \\ 0.333 \\ 0.287 \\ 0.08 \end{pmatrix} (0.313 \quad 0.587 \quad 0.1) \\ &= \begin{pmatrix} 0.094 & 0.176 & 0.03 \\ 0.104 & 0.196 & 0.033 \\ 0.09 & 0.168 & 0.029 \\ 0.025 & 0.047 & 0.008 \end{pmatrix} \end{aligned}$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)

$$\hat{\Sigma}_{11} = \begin{pmatrix} 0.21 & -0.1 & -0.086 & -0.024 \\ -0.1 & 0.222 & -0.096 & -0.027 \\ -0.086 & -0.096 & 0.204 & -0.023 \\ -0.024 & -0.027 & -0.023 & 0.074 \end{pmatrix} \quad \hat{\Sigma}_{22} = \begin{pmatrix} 0.215 & -0.184 & -0.031 \\ -0.184 & 0.242 & -0.059 \\ -0.031 & -0.059 & 0.09 \end{pmatrix}$$

$$E[\mathbf{X}_1 \mathbf{X}_2^T] = \hat{\mathbf{P}}_{12} = \frac{1}{150} \begin{pmatrix} 7 & 33 & 5 \\ 24 & 18 & 8 \\ 13 & 30 & 0 \\ 3 & 7 & 2 \end{pmatrix} = \begin{pmatrix} 0.047 & 0.22 & 0.033 \\ 0.16 & 0.12 & 0.053 \\ 0.087 & 0.2 & 0 \\ 0.02 & 0.047 & 0.013 \end{pmatrix}$$

$$\begin{aligned} \hat{\Sigma}_{12} &= \hat{\mathbf{P}}_{12} - \hat{\mathbf{p}}_1 \hat{\mathbf{p}}_2^T \\ &= \begin{pmatrix} -0.047 & 0.044 & 0.003 \\ 0.056 & -0.076 & 0.02 \\ -0.003 & 0.032 & -0.029 \\ -0.005 & 0 & 0.005 \end{pmatrix} \end{aligned}$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)

$$\hat{\Sigma} = \begin{pmatrix} \hat{\Sigma}_{11} & \hat{\Sigma}_{12} \\ \hat{\Sigma}_{12}^T & \hat{\Sigma}_{22} \end{pmatrix}$$
$$= \begin{pmatrix} 0.21 & -0.1 & -0.086 & -0.024 & -0.047 & 0.044 & 0.003 \\ -0.1 & 0.222 & -0.096 & -0.027 & 0.056 & -0.076 & 0.02 \\ -0.086 & -0.096 & 0.204 & -0.023 & -0.003 & 0.032 & -0.029 \\ -0.024 & -0.027 & -0.023 & 0.074 & -0.005 & 0 & 0.005 \\ -0.047 & 0.056 & -0.003 & -0.005 & 0.215 & -0.184 & -0.031 \\ 0.044 & -0.076 & 0.032 & 0 & -0.184 & 0.242 & -0.059 \\ 0.003 & 0.02 & -0.029 & 0.005 & -0.031 & -0.059 & 0.09 \end{pmatrix}$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)




Figure 3.2. Empirical joint probability mass function: sepal length and sepal width.

サンプリング

- 質的属性の扱い、二つの変数(bivariate)
- 属性の独立性: 2つの変数間の「付随性」

Table 3.5. Contingency table: sepal length vs. sepal width

Sepal length (X_1)	Sepal width (X_2)			Row Counts
	Short	Medium	Long	
Very Short (a_{11})	$a_{21} = 7$	$a_{22} = 33$	$a_{23} = 5$	$n_1^1 = 45$
Short (a_{12})	24	18	8	$n_2^1 = 50$
Long (a_{13})	13	30	0	$n_3^1 = 43$
Very Long (a_{14})	3	7	2	$n_4^1 = 12$
Column Counts	$n_1^2 = 47$	$n_2^2 = 88$	$n_3^2 = 15$	$n = 150$

$$\mathbf{N}_{12} = n \cdot \hat{\mathbf{P}}_{12} = \begin{pmatrix} n_{11} & n_{12} & \cdots & n_{1m_2} \\ n_{21} & n_{22} & \cdots & n_{2m_2} \\ \vdots & \vdots & \ddots & \vdots \\ n_{m_1 1} & n_{m_1 2} & \cdots & n_{m_1 m_2} \end{pmatrix}$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)
- 仮説検定、カイニ統計、 q 自由度,

$$\chi^2 = \sum_{i=1}^{m_1} \sum_{j=1}^{m_2} \frac{(n_{ij} - e_{ij})^2}{e_{ij}} \quad e_{ij} = n \cdot \hat{p}_{ij} = n \cdot \hat{p}_i^1 \cdot \hat{p}_j^2 = n \cdot \frac{n_i^1}{n} \cdot \frac{n_j^2}{n} = \frac{n_i^1 n_j^2}{n}$$

$$f(x|q) = \frac{1}{2^{q/2} \Gamma(q/2)} x^{q/2-1} e^{-x/2} \quad \Gamma(k > 0) = \int_0^{\infty} x^{k-1} e^{-x} dx$$

$$e_{11} = \frac{n_1^1 n_1^2}{n} = \frac{45 \cdot 47}{150} = \frac{2115}{150} = 14.1$$

$$q = (m_1 - 1) \cdot (m_2 - 1) = 3 \cdot 2 = 6$$

$$\chi^2 = 21.8.$$

サンプリング

- 質的属性の扱い、二つの変数(bivariate)
- 仮説検定、カイニ統計、q自由度,

Table 3.6. Expected counts

		X_2		
		Short (a_{21})	Medium (a_{22})	Short (a_{23})
X_1	Very Short (a_{11})	14.1	26.4	4.5
	Short (a_{12})	15.67	29.33	5.0
	Long (a_{13})	13.47	25.23	4.3
	Very Long (a_{14})	3.76	7.04	1.2

F検定を行う

サンプリング

- 質的属性の扱い、二つの変数(bivariate)
- 仮説検定、カイニ統計、 q 自由度,




Figure 3.3. Chi-squared distribution ($q = 6$).


サンプリング

- 質的属性の扱い、二つ以上の変数 (multivariate)

サンプリング Multivariate

\hat{f} , \hat{F} , $\hat{\mu}$, $\hat{\sigma}$, $\hat{\Sigma}$: ベクトル平均、共分散、行列共分散

問題定式化



- 入力:
- C: クラス (classes)
- F: 特徴 (Features)
- 出力:
- 特徴データとクラスの分類

データセット例(Iris dataset)

Setosa



D1:{PL=1.4,PW=0.2,SL=5.1,SW=3.5}

D2:{PL=1.4,PW=0.2,SL=4.9,SW=3.0}

D3:{PL=1.3,PW=0.2,SL=4.7,SW=3.2}

...



D51:{PL=4.7,PW=1.4,SL=7.0,SW=3.2}

D52:{PL=4.9,PW=1.5,SL=6.4,SW=3.2}

D53:{PL=4.0,PW=1.5,SL=6.9,SW=3.1}

...




D101:{PL=6.0,PW=2.5,SL=6.3,SW=3.3}

D102:{PL=5.1,PW=1.9,SL=5.8,SW=3.1}

- 3つのクラスに50サンプル毎に収集
- 特徴
 - PW: Petal Width
 - PL: Petal Length
 - SW: SepalWidth
 - SL: Sepal Length



データセットの分類(Iris dataset)




- 特徴
- PW: Petal Width
- PL: Petal Length




分類器/クラスタ分析器/回帰など

scikit-learn
algorithm cheat-sheet




文書の自動分類

- 単純ベイズ分類器を文書分類問題に適用した例を示す。文書群をその内容によって分類する問題であり、例えば、電子メールをスパムとスパムでないものに分類する。



まとめ

- データ
- オントロジー
- 理論
- データマイニング
- データセット例
- 分類例
- Python Scikit-learnパッケージ
- データテキストの分類器



EXAMPLE




データ例: コーヒのテストを分析する

月	昨年の実測気温	スタンダード	スイート	ビター
1	4	43	46	42
2	3	45	44	43
3	5	41	47	40
4	10	42	40	47
5	16	44	38	49
6	21	47	33	55
7	27	48	32	59
8	28	45	31	58
9	26	43	34	56
10	19	42	37	52
11	11	44	41	44
12	7	46	45	41

回帰分析の例

気温と販売数量の相関関係



気温予測に基づく販売数量

本年の予測気温	スイート	ビター
8	42.99529	43.93098
10	41.8115	45.38353
9	42.4034	44.65725
14	39.44392	48.28863
16	38.26013	49.74118
23	34.11686	54.8251
28	31.15739	58.45647
29	30.56549	59.18275
26	32.34118	57.00392
20	35.89255	52.64627
9	42.4034	44.65725
6	44.17908	42.47843

	前年比	
月	スイート	ビター
1	-7%	5%
2	-5%	6%
3	-10%	12%
4	-1%	3%
5	1%	2%
6	3%	0%
7	-3%	-1%
8	-1%	2%
9	-5%	2%
10	-3%	1%
11	3%	1%
12	-2%	4%

1年間の販売数量の予測

気温予測に基づく販売数量前年比

