

目的

- データの情報集約 (主成分分析)
- データの背後にある要因の解析 (因子分析)
- データの分類, パターンわけ (クラスター分析)
- 市場予測 (重回帰分析)
- 新製品コンセプトの開発 (コンジョイント分析)

手法

- すべては正準相関分析
- データの相関を解析する

キーワード

- 平均, 分散, 標準偏差
- 共分散, 相関
- 固有値, 固有ベクトル

- データ: $x(i)$, $i = 1, \dots, N$
- 平均: $\bar{x} = \frac{1}{N} \sum_{i=1}^N x(i)$
- 平均偏差 (データの平均からのずれ): $x(i) - \bar{x}$
- 分散 (データの散らばり具合 . データセットの平均からのずれの度合い , 標準偏差の2乗):

$$s_x^2 = \frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x})^2$$

- 共分散 (データのずれの関係): $s_{xy} = \frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x})(y(i) - \bar{y})$
- 規準化 (正規化): $x_r(i) = \frac{x(i) - \bar{x}}{s_x}$
- 相関 (規準化されたデータの散らばり具合): $r_{xy} = \frac{s_{xy}}{s_x s_y}$


- ベクトル表現

$$\mathbf{x} = \begin{bmatrix} x(1) \\ \vdots \\ x(N) \end{bmatrix}, \tilde{\mathbf{x}} = \begin{bmatrix} x(1) - \bar{x} \\ \vdots \\ x(N) - \bar{x} \end{bmatrix}, \mathbf{y} = \begin{bmatrix} y(1) \\ \vdots \\ y(N) \end{bmatrix}, \tilde{\mathbf{y}} = \begin{bmatrix} y(1) - \bar{y} \\ \vdots \\ y(N) - \bar{y} \end{bmatrix}$$

- 共分散行列

$$S = \begin{bmatrix} s_x^2 & s_{xy} \\ s_{xy} & s_y^2 \end{bmatrix} = \frac{1}{N} \sum_{i=1}^N [\tilde{\mathbf{x}} \ \tilde{\mathbf{y}}]^T [\tilde{\mathbf{x}} \ \tilde{\mathbf{y}}]$$

基本統計量の例



- 10人の学生 (A から J) の英語と数学の点数が以下のとおりであった．総合成績と文理度の順位をつけよ．また，その根拠を説明せよ．

科目	A	B	C	D	E	F	G	H	I	J
英語	2	1	2	3	5	4	8	6	7	4
数学	3	4	2	2	4	4	5	3	6	5


- データ: $E = [2\ 1\ 2\ 3\ 5\ 4\ 8\ 6\ 7\ 4]^T$, $M = [3\ 4\ 2\ 2\ 4\ 4\ 5\ 3\ 6\ 5]^T$
- 平均: $\bar{E} = 4.2$, $\bar{M} = 3.8$
- 分散: $s_E^2 = 4.76$, $s_M^2 = 1.56$
- 総合成績: $E + M$ による評価はデータを $x = y$ 上に射影して評価 (平均, 分散が考慮されていない)

情報量最大化の概念

- 総合成績 → 2変量のデータを1変量で表す → 軸上への投影
- 軸上への投影: 点の位置ベクトル (x, y) と軸の方向 (a, b) の内積 $z = ax + by$. ただし $a^2 + b^2 = 1$
- 情報量を最大: 軸上に投影されたデータの分散が最大
- 軸 (方向ベクトル (a, b)) に射影するとして, 分散を計算

$$\begin{aligned} s_z^2 &= \frac{1}{N} \sum_{i=1}^N (z(i) - \bar{z})^2 = \frac{1}{N} \sum_{i=1}^N (ax(i) + by(i) - a\bar{x} - b\bar{y})^2 \\ &= \frac{1}{N} \sum_{i=1}^N (a(x(i) - \bar{x}) + b(y(i) - \bar{y}))^2 \\ &= a^2 s_x^2 + 2abs_{xy} + b^2 s_y^2 \end{aligned}$$

[注意:] $ax(i) + by(i) - a\bar{x} - b\bar{y}$ は点 $(x(i), y(i))$ と平均点 (\bar{x}, \bar{y}) を通り方向 (a, b) を持つ直線との距離 .



- Lagrange の未定乗数法

$$F(a, b, \lambda) = a^2 s_x^2 + 2abs_{xy} + b^2 s_y^2 - \lambda(a^2 + b^2 - 1)$$

$$0 = F_a = 2as_x^2 + 2bs_{xy} - 2\lambda a$$

$$0 = F_b = 2as_{xy} + 2bs_y^2 - 2\lambda b$$

$$0 = F_\lambda = -a^2 - b^2 + 1$$

- 固有値問題


$$\begin{bmatrix} s_x^2 & s_{xy} \\ s_{xy} & s_y^2 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \lambda \begin{bmatrix} a \\ b \end{bmatrix}$$

- 対称行列ゆえ固有値 (λ) は実数で正 .

$$s_z^2 = -abs_{xy} + \lambda a^2 - abs_{xy} + \lambda b^2 + 2abs_{xy} = \lambda$$

- 固有値を λ_1, λ_2 ($\lambda_1 > \lambda_2 > 0$) とするとき , 分散の最大値は λ_1 であり , 投影すべき軸の方向は固有ベクトルに等しい .

- 軸への投影だけで評価する場合 , 軸からの距離の情報は無視される .



- データ $(x(i), y(i))$, $i = 1, \dots, N$ を情報量最大化の観点から変量 $(z(i), w(i))$ に変換する .

$$\tilde{\mathbf{x}} = \begin{bmatrix} x(1) - \bar{x} \\ \vdots \\ x(N) - \bar{x} \end{bmatrix}, \tilde{\mathbf{y}} = \begin{bmatrix} y(1) - \bar{y} \\ \vdots \\ y(N) - \bar{y} \end{bmatrix}, \mathbf{z} = \begin{bmatrix} z(1) \\ \vdots \\ z(N) \end{bmatrix}, \mathbf{w} = \begin{bmatrix} w(1) \\ \vdots \\ w(N) \end{bmatrix}$$

- $\mathbf{z} = a\tilde{\mathbf{x}} + b\tilde{\mathbf{y}}$, $\mathbf{w} = c\tilde{\mathbf{x}} + d\tilde{\mathbf{y}}$ とすると , 係数 (a, b) はデータ (\mathbf{x}, \mathbf{y}) の共分散行列

$$S = \begin{bmatrix} s_x^2 & s_{xy} \\ s_{xy} & s_y^2 \end{bmatrix}$$

の最大固有値 λ_1 に対応する固有ベクトル \mathbf{v}_1 ($\|\mathbf{v}_1\| = 1$) にとるのがよい .

$$\mathbf{z} = [\bar{x} \ \bar{y}] \begin{bmatrix} a \\ b \end{bmatrix} \mathbf{z} = X\mathbf{v}_1$$

- 係数 c, d : \mathbf{v}_1 に直交するようにとる . つまり \mathbf{v}_2 とする
 - 第2固有値 λ_2 に対応する固有ベクトル \mathbf{v}_2

- 座標変換

– 共分散行列 S の対角化: $S = V\Lambda V^T$, $V = [\mathbf{v}_1 \ \mathbf{v}_2]$


$$[\mathbf{z} \ \mathbf{w}] = [\bar{x} \ \bar{y}][\mathbf{v}_1 \ \mathbf{v}_2] = XV$$

– 共分散行列 S' :


$$S' = \frac{1}{N}[\mathbf{z} \ \mathbf{w}]^T[\mathbf{z} \ \mathbf{w}] = V^T \frac{1}{N}[\tilde{\mathbf{x}} \ \tilde{\mathbf{y}}]^T[\tilde{\mathbf{x}} \ \tilde{\mathbf{y}}]V = V^T S V = \Lambda$$

- Λ は対角行列: \mathbf{z} と \mathbf{w} は無相関

最小2乗法との違い




- 最小2乗法: 点から縦方向に計った直線との距離を最小化
- 主成分分析:
 - 第一主成分: 軸への投影データ
第一主成分の分散が最大．情報量が最大．
 - 第二主成分: 軸への垂線の足データ ... 無視される
第二主成分の分散が最小．無視されるデータの情報が最小．



- データ: $E = [2 \ 1 \ 2 \ 3 \ 5 \ 4 \ 8 \ 6 \ 7 \ 4]^T$, $M = [3 \ 4 \ 2 \ 2 \ 4 \ 4 \ 5 \ 3 \ 6 \ 5]^T$
- 平均: $\bar{E} = 4.2$, $\bar{M} = 3.8$
- 分散: $s_E^2 = 4.76$, $s_M^2 = 1.56$ 共分散: $s_{EM} = 1.64$
- 対角化

$$\begin{aligned}
 S &= \begin{bmatrix} s_x^2 & s_{xy} \\ s_{xy} & s_y^2 \end{bmatrix} = \begin{bmatrix} 4.76 & 1.64 \\ 1.64 & 1.56 \end{bmatrix} \\
 &= \begin{bmatrix} 0.9215 & -0.38838 \\ 0.38838 & 0.9215 \end{bmatrix} \begin{bmatrix} 5.4512 & 0 \\ 0 & 0.8688 \end{bmatrix} \begin{bmatrix} 0.9215 & 0.38838 \\ -0.38838 & 0.9215 \end{bmatrix} \\
 &= V\Lambda V^T
 \end{aligned}$$

座標変換の例



- データ: $E = [2\ 1\ 2\ 3\ 5\ 4\ 8\ 6\ 7\ 4]^T$, $M = [3\ 4\ 2\ 2\ 4\ 4\ 5\ 3\ 6\ 5]^T$
- 平均からの差: $\tilde{E} = E - \bar{E}$, $\tilde{M} = M - \bar{M}$
- 座標変換: $[E' \ M'] = [\tilde{E} \ \tilde{M}]V$


科目	A	B	C	D	E	F	G	H	I	J
英語	2	1	2	3	5	4	8	6	7	4
数学	3	4	2	2	4	4	5	3	6	5
合計	5	5	4	5	9	8	13	9	13	9
単純順位	7	7	10	7	3	6	1	3	1	3
第1成分	-2.34	-2.87	-2.73	-1.81	0.82	-0.11	3.97	1.35	3.44	0.28
情報最大	8	10	9	7	4	6	1	3	2	5
第2成分	0.12	1.43	-0.80	-1.19	-0.13	0.26	-0.37	-1.44	0.94	1.18
文理度?	6	10	3	2	5	7	4	1	8	9

多次元情報の縮約

- 情報の要約と次元の縮小
 - 情報の要約: 相関関係の整理
 - 次元の縮小: 分散の小さなデータ (情報量が少ない) の棄却
- 共分散行列を用いて主成分分析 (PCA)
- 例:

メーカー \ イメージ	A	B	C	D	E	F	G	H	計
IBM	1	11	3	4	4	3	23	1	50
HP	3	3	1	2	6	1	9	24	49
ルーセント	1	3	0	1	3	1	0	38	47
東芝	3	6	3	8	0	12	13	6	51
NEC	2	7	4	3	4	11	14	6	51
日立	1	13	7	6	1	8	11	3	50
三菱	0	3	0	5	2	6	21	13	50
三洋	6	2	6	3	1	5	5	19	47
シャープ	12	12	5	6	6	0	4	4	49
エプソン	2	7	21	5	4	1	1	8	49
キャノン	1	4	10	10	6	4	5	9	49
ドコモ	1	1	12	4	7	15	5	6	51
J-Phone	14	3	18	3	4	1	0	7	50
AU	6	2	24	6	5	0	0	8	51
計	53	77	114	66	53	68	111	152	


主成分分析1(知名度 vs 伝統)



- | | | |
|----------|----------|-------------|
| 1: IBM | 6: 日立 | 11: キヤノン |
| 2: HP | 7: 三菱 | 12: ドコモ |
| 3: ルーセント | 8: 三洋 | 13: J-Phone |
| 4: 東芝 | 9: シャープ | 14: au |
| 5: NEC | 10: エプソン | |

- | | |
|------------------|------------------|
| 1: ユニークな製品がある | 5: 近代的である |
| 2: 研究開発に熱心 | 6: 安定性がある |
| 3: 宣伝広告に熱心 | 7: 伝統がある |
| 4: 製品(サービス)の質がよい | 8: よい印象がない(知らない) |


主成分分析2(伝統 vs 安定性)



- | | | |
|----------|----------|-------------|
| 1: IBM | 6: 日立 | 11: キヤノン |
| 2: HP | 7: 三菱 | 12: ドコモ |
| 3: ルーセント | 8: 三洋 | 13: J-Phone |
| 4: 東芝 | 9: シャープ | 14: au |
| 5: NEC | 10: エプソン | |

- | | |
|------------------|------------------|
| 1: ユニークな製品がある | 5: 近代的である |
| 2: 研究開発に熱心 | 6: 安定性がある |
| 3: 宣伝広告に熱心 | 7: 伝統がある |
| 4: 製品(サービス)の質がよい | 8: よい印象がない(知らない) |


主成分分析3(安定性 vs 研究指向)



- | | | |
|----------|----------|-------------|
| 1: IBM | 6: 日立 | 11: キヤノン |
| 2: HP | 7: 三菱 | 12: ドコモ |
| 3: ルーセント | 8: 三洋 | 13: J-Phone |
| 4: 東芝 | 9: シャープ | 14: au |
| 5: NEC | 10: エプソン | |

- | | |
|------------------|------------------|
| 1: ユニークな製品がある | 5: 近代的である |
| 2: 研究開発に熱心 | 6: 安定性がある |
| 3: 宣伝広告に熱心 | 7: 伝統がある |
| 4: 製品(サービス)の質がよい | 8: よい印象がない(知らない) |


主成分分析II-1 [知名度の低い4社を除く] (伝統 vs 安定性)



- | | | |
|--------|---------|------------|
| 1: IBM | 5: シャープ | 9: J-Phone |
| 2: 東芝 | 6: エプソン | 10: au |
| 3: NEC | 7: キヤノン | |
| 4: 日立 | 8: ドコモ | |

- | | |
|------------------|------------------|
| 1: ユニークな製品がある | 5: 近代的である |
| 2: 研究開発に熱心 | 6: 安定性がある |
| 3: 宣伝広告に熱心 | 7: 伝統がある |
| 4: 製品(サービス)の質がよい | 8: よい印象がない(知らない) |


主成分分析II-2 [知名度の低い4社を除く](??)



- | | | |
|--------|---------|------------|
| 1: IBM | 5: シャープ | 9: J-Phone |
| 2: 東芝 | 6: エプソン | 10: au |
| 3: NEC | 7: キヤノン | |
| 4: 日立 | 8: ドコモ | |

- | | |
|------------------|------------------|
| 1: ユニークな製品がある | 5: 近代的である |
| 2: 研究開発に熱心 | 6: 安定性がある |
| 3: 宣伝広告に熱心 | 7: 伝統がある |
| 4: 製品(サービス)の質がよい | 8: よい印象がない(知らない) |

主成分分析II-3 [知名度の低い4社を除く](??)



- | | | |
|--------|---------|------------|
| 1: IBM | 5: シャープ | 9: J-Phone |
| 2: 東芝 | 6: エプソン | 10: au |
| 3: NEC | 7: キヤノン | |
| 4: 日立 | 8: ドコモ | |

- | | |
|------------------|------------------|
| 1: ユニークな製品がある | 5: 近代的である |
| 2: 研究開発に熱心 | 6: 安定性がある |
| 3: 宣伝広告に熱心 | 7: 伝統がある |
| 4: 製品(サービス)の質がよい | 8: よい印象がない(知らない) |