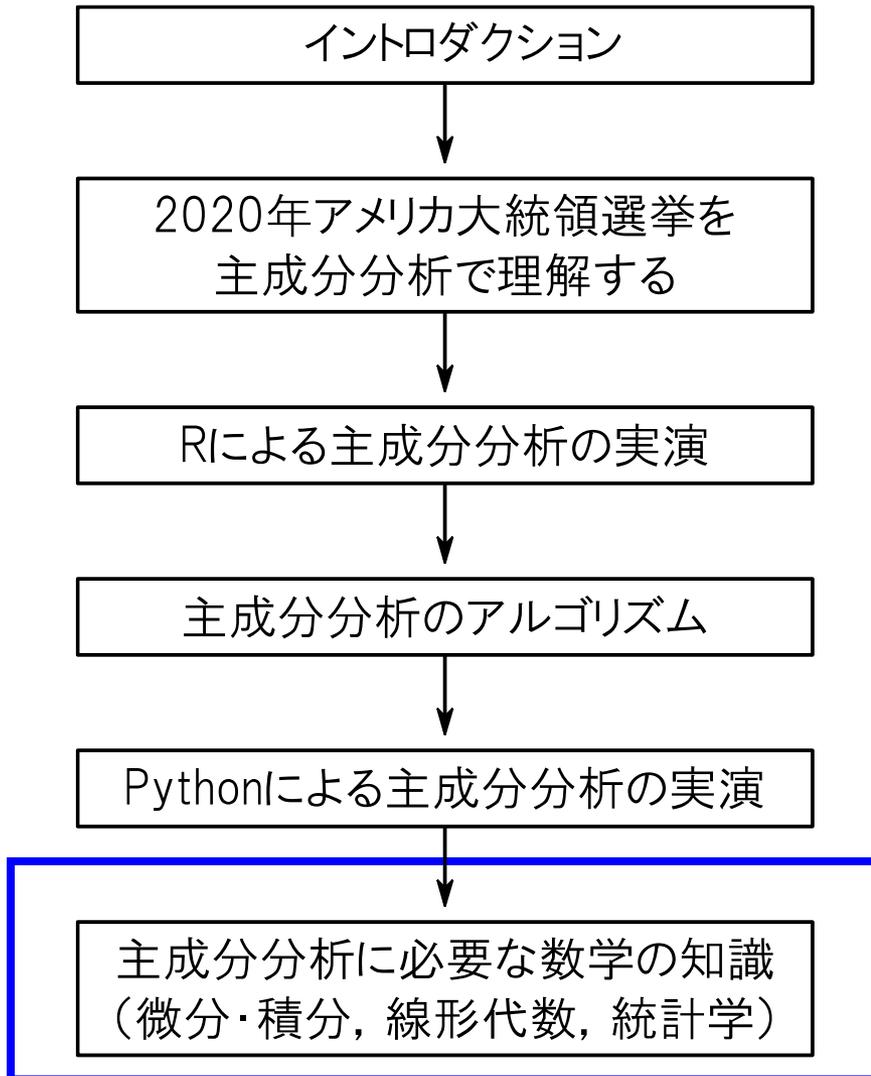


統計数学と主成分分析による ビッグ・データの可視化とパターン認識

Part 3: 原理解説編

リニア・テック 別府 伸耕

linear tec : Nobuyasu Beppu



「Part 3 原理解説編」では
この部分を扱います。

- 多変数関数の微分（偏微分と全微分）
- ラグランジュの未定乗数法
- 線形代数の基礎
- ベクトルの微分
- 主成分分析のアルゴリズムの導出
- Pythonによる実装例の紹介

× 悪い軸の取り方（分散が小さい）

- アーカンソー
- アラバマ
- アラスカ

→ 軸1

○ 良い軸の取り方（分散が大きい）

- アーカンソー
- アラバマ

●アラスカ
→ 軸1

「分散が最も大きく見える状態」が理想的であると言える。

「射影した後のデータ」の分散を求める Sample

ベクトル“ \mathbf{u} ”とデータ・ベクトル“ \mathbf{x}_i ”との内積をとり、スカラ“ y_i ”をつくる。

$$y_i = \mathbf{u} \cdot \mathbf{x}_i = \mathbf{u}^T \mathbf{x}_i$$

スカラ“ y_i ” ($i = 1, 2, \dots, N$) の分散“ σ_y^2 ”を求める。

$$\begin{aligned} \text{スカラ} \rightarrow \sigma_y^2 &= \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2 \\ &= \frac{1}{N} \sum_{i=1}^N (\mathbf{u}^T \mathbf{x}_i - \mathbf{u}^T \bar{\mathbf{x}})^2 \\ &= \frac{1}{N} \sum_{i=1}^N \{\mathbf{u}^T (\mathbf{x}_i - \bar{\mathbf{x}})\} \{\mathbf{u}^T (\mathbf{x}_i - \bar{\mathbf{x}})\}^T \\ &= \frac{1}{N} \sum_{i=1}^N \mathbf{u}^T (\mathbf{x}_i - \bar{\mathbf{x}}) (\mathbf{x}_i - \bar{\mathbf{x}})^T \mathbf{u} \end{aligned}$$

両方ともスカラ。
スカラは転置してもスカラ。

横ベクトル 縦ベクトル 横ベクトル 縦ベクトル