

『入門 機械学習による異常検知 — Rによる
実践ガイド —』（コロナ社、2015）
第7刷正誤表

井手剛

<https://ide-research.net/jpn/book/>

March 11, 2024

Chapter 1

異常検知の基本的な考え方

- p.19 2.2.2 最初のパラグラフ（坂内匠様のご教示に感謝いたします）。
 - 誤: 単に式(2.3)の対数を計算すると
 - 正: 単に式(2.3)の対数を計算して符号を変えると

Chapter 2

正規分布に従うデータからの異常検知

- p.34 式(2.28)の導出に関し、 y_2, \dots, y_N の期待値がゼロになるという事実を明示的に書いていなかったのが若干わかりにくかったと思います。下記のように更新します (中西惇様のご指摘に感謝します)。
 - 旧: 最後に、定理 2.4 の 3. ですが、定理 2.3 と式 (2.24) により
 - 新: 最後に、定理 2.4 の 3. ですが、 $p(\mathbf{Y})$ の式によれば y_n の期待値が $\mathbf{u}_n^\top \mathbf{u}_1$ に比例していること、したがって固有ベクトルの直交性から $n = 2, \dots, N$ に対しゼロになることに注意します。このことと、定理 2.3 と式 (2.24) により
- p.43 実行例2.5、4行目。これは間違いではありませんが、実行例のすぐ上の説明と矛盾しているので訂正します。大塚誠様のご教示に感謝いたします。
 - 誤: `a <- rowSums((Xc %*% solve(Sx)) * Xc) # 異常度`
 - 正: `a <- colSums(t(Xc) * solve(Sx,t(Xc))) # 異常度`
- p.46 式 (2.42) およびその上の式 (藤本望夢様のご教示に感謝します)。
 - 誤:
$$dz^{(1)} \dots dz^{(N)} = dv \ 2^{-1} |v|^{-(N-2)/2} dS_{1,N}$$
$$dz^{(1)} \dots dz^{(N)} = dV \ 2^{-M} |V|^{-(N-M-1)/2} dS_{M,N}$$
 - 正:
$$dz^{(1)} \dots dz^{(N)} = dv \ 2^{-1} |v|^{(N-2)/2} dS_{1,N}$$
$$dz^{(1)} \dots dz^{(N)} = dV \ 2^{-M} |V|^{(N-M-1)/2} dS_{M,N}$$
- p.47 式(2.44) (藤本望夢様のご教示に感謝します)。

– 誤:

$$p(\mathbf{A}) = f(\mathbf{A}) \times 2^{-M} |\mathbf{A}|^{-(N-M-1)/2} \times \frac{2^M \pi^{MN/2}}{\Gamma_M(N/2)}$$

– 正

$$p(\mathbf{A}) = f(\mathbf{A}) \times 2^{-M} |\mathbf{A}|^{(N-M-1)/2} \times \frac{2^M \pi^{MN/2}}{\Gamma_M(N/2)}$$

- p.55 下から6行目（真田明様のご教示に感謝します）。
 - 誤: $\hat{\mu}$ は式(2.19)で示したとおり、平均 0、分散 $\sigma^2(N+1)/N$ の正規分布に従います。
 - 正: $x' - \hat{\mu}$ は式(2.19)で示したとおり、平均0、分散 $\sigma^2(N+1)/N$ の正規分布に従います。

Chapter 3

非正規データからの異常検知

- p.63 実行例3.1、3行目（濱田慧様のご教示に感謝いたします）。
 - 誤: `si <- sd(Davis$weight)*(N-1)/N #標準偏差`
 - 正: `si <- sd(Davis$weight)*sqrt((N-1)/N) #標準偏差`
- p.69 3.2.3 節の冒頭4行（遠藤秀和様のご教示に感謝いたします）。(3.16)式は(3.18)式の誤り。また、 $z_i^{(n)}$ ではなくて $\delta(z^{(n)}, i)$ の期待値。
 - 誤: 最尤推定に使う尤度 $L(\boldsymbol{\theta} | \mathcal{D})$ は(3.16)式のようなすっきりした形になっています。問題は仮想的変数が未知だったことですが、今やわれわれは、(3.20)式に基づき数値として計算済みと想定しています。 $z_i^{(n)}$ を $q_i^{(n)}$ に置き換えた上で素朴に(3.16)式をパラメータで微分すると、次のような式を得ます。
 - 正: 最尤推定に使う尤度 $L(\boldsymbol{\theta} | \mathcal{D})$ は(3.18)式のようなすっきりした形になっています。問題は仮想的変数が未知だったことですが、今やわれわれは、(3.20)式に基づき数値として計算済みと想定しています。 $\delta(z^{(n)}, i)$ を $q_i^{(n)}$ に置き換えた上で素朴に(3.18)式をパラメータで微分すると、次のような式を得ます。
- p.88 式 (3.51)（藤本望夢様のご教示に感謝します）。
 - 誤:

$$L(\boldsymbol{\theta} | \mathcal{D}) = \ln \prod_{i=1}^N p(\mathbf{x}^{(n)} | \boldsymbol{\theta}) = \sum_{n=1}^N \ln \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}^{(n)} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$

– 正:

$$L(\boldsymbol{\theta} | \mathcal{D}) = \ln \prod_{n=1}^N p(\mathbf{x}^{(n)} | \boldsymbol{\theta}) = \sum_{n=1}^N \ln \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}^{(n)} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$

Chapter 4

性能評価の方法

現時点で判明している誤りはありません。

Chapter 5

不要な次元を含むデータからの異常検知

- p.128 式(5.13)およびその下の式（福永裕子様、岩田和太様のご教示に感謝いたします）。

– 誤: 正規直交基底 $\mathbf{u}_1, \dots, \mathbf{u}_m$ を求めるためには

$$\mathbf{u}_i = \frac{1}{\sqrt{\lambda_i}} \tilde{\mathbf{X}} \mathbf{v}_i \quad (5.13)$$

とすればいいことが直ちにわかります。なぜなら

$$\mathbf{u}_i^\top \mathbf{u}_j = \frac{1}{\sqrt{\lambda_i \lambda_j}} \mathbf{v}_i^\top \tilde{\mathbf{X}}^\top \tilde{\mathbf{X}} \mathbf{v}_j = \frac{1}{\sqrt{\lambda_i \lambda_j}} \lambda_j \mathbf{v}_i^\top \mathbf{v}_j = \frac{1}{\sqrt{\lambda_i \lambda_j}} \lambda_j \delta_{i,j} = \delta_{i,j}$$

となるからです。

– 正: 正規直交基底 $\mathbf{u}_1, \dots, \mathbf{u}_m$ を求めるためには

$$\mathbf{u}_i = \frac{1}{\sqrt{\nu_i}} \tilde{\mathbf{X}} \mathbf{v}_i \quad (5.13)$$

とすればいいことが直ちにわかります。なぜなら

$$\mathbf{u}_i^\top \mathbf{u}_j = \frac{1}{\sqrt{\nu_i \nu_j}} \mathbf{v}_i^\top \tilde{\mathbf{X}}^\top \tilde{\mathbf{X}} \mathbf{v}_j = \frac{1}{\sqrt{\nu_i \nu_j}} \nu_j \mathbf{v}_i^\top \mathbf{v}_j = \frac{1}{\sqrt{\nu_i \nu_j}} \nu_j \delta_{i,j} = \delta_{i,j}$$

となるからです。

- p.132 上から4行目。吉川岳様のご指摘に感謝いたします。

– 誤: $N \times N$ の中心化グラム行列の上位 r 個の規格化された固有ベクトル $\mathbf{v}_1, \dots, \mathbf{v}_m$ を求め

- 正: $N \times N$ の中心化グラム行列の上位 m 個の規格化された固有ベクトル $\mathbf{v}_1, \dots, \mathbf{v}_m$ を求め

- p.143 式(5.45) (藤本望夢様のご教示に感謝します)。

- 誤:

$$p(\mathbf{z}^{(n)}|\mathbf{x}^{(n)}, \Theta) = \mathcal{N}\left(\mathbf{z}^{(n)} \mid \mathbf{M}^{-1}\mathbf{W}^\top(\mathbf{x} - \bar{\mathbf{x}}), \sigma^2\mathbf{M}^{-1}\right)$$

- 正:

$$p(\mathbf{z}^{(n)}|\mathbf{x}^{(n)}, \Theta) = \mathcal{N}\left(\mathbf{z}^{(n)} \mid \mathbf{M}^{-1}\mathbf{W}^\top(\mathbf{x}^{(n)} - \bar{\mathbf{x}}), \sigma^2\mathbf{M}^{-1}\right)$$

となるからです。

- p.154 上から2行目 (辻善夫様のご教示に感謝します)。

- 誤: \mathcal{D} にしたのと同じの非線形変換 $\mathbf{x} \leftarrow \phi(\mathbf{x})$ を施して、
- 正: \mathcal{D} にしたのと同じの非線形変換 $\mathbf{x} \rightarrow \phi(\mathbf{x})$ を施して、

- p.155 式 (5.69) (真田明様のご教示に感謝します)。

- 誤:

$$a_{m=1}(\mathcal{D}, \mathcal{D}') = 1 - \frac{\mathbf{v}_1^\top \mathbf{H}_N \mathbf{B} \mathbf{H}_{N'}}{\sqrt{\lambda_1}} \frac{\mathbf{r}_1}{\sqrt{\gamma_1}}$$

- 正:

$$a_{m=1}(\mathcal{D}, \mathcal{D}') = 1 - \left(\frac{\mathbf{v}_1^\top \mathbf{H}_N \mathbf{B} \mathbf{H}_{N'}}{\sqrt{\lambda_1}} \frac{\mathbf{r}_1}{\sqrt{\gamma_1}} \right)^2$$

Chapter 6

入力と出力があるデータからの異常検知

- p.167 式(6.20) (平田大貴様のご教示に感謝します)。

– 誤:

$$e(\lambda) = \frac{1}{N} \left\| \text{diag}(\mathbf{I}_M - \mathbf{H})^{-1} (\mathbf{I}_M - \mathbf{H}) \tilde{\mathbf{y}}_N \right\|^2$$

– 正:

$$e(\lambda) = \frac{1}{N} \left\| \text{diag}(\mathbf{I}_N - \mathbf{H})^{-1} (\mathbf{I}_N - \mathbf{H}) \tilde{\mathbf{y}}_N \right\|^2$$

- p.168 1行目 (平田大貴様のご教示に感謝します)。

– 誤: また、 $\text{diag}(\mathbf{I}_M - \mathbf{H})^{-1}$ は、第 i 対角要素が $(1 - H_{i,i})^{-1}$ となる対角行列である。

– 正: また、 $\text{diag}(\mathbf{I}_N - \mathbf{H})^{-1}$ は、第 i 対角要素が $(1 - H_{i,i})^{-1}$ となる対角行列である。

- p.189の2つ目の式 (藤本望夢様のご教示に感謝します)。なお、 M_ϕ の定義は p.185 の式(6.51)の下にあります。

– 誤:

$$\left| \sigma^2 \mathbf{I}_N + \frac{\sigma^2}{\hat{\lambda}} \Phi^\top \Phi \right| = (\sigma^2)^N \hat{\lambda}^{-M} |\mathbf{A}|$$

– 正:

$$\left| \sigma^2 \mathbf{I}_N + \frac{\sigma^2}{\hat{\lambda}} \Phi^\top \Phi \right| = (\sigma^2)^N \hat{\lambda}^{-M_\phi} |\mathbf{A}|$$

- p.189 式(6.66) (森川浩司様、藤本望夢様のご教示に感謝します)。

– 誤:

$$\begin{aligned} \ln E(\sigma^2) &= \frac{N}{2} \ln(2\pi) - \frac{1}{2} \ln \left[(\sigma^2)^N \hat{\lambda}^{-M} |\mathbf{A}| \right] \\ &\quad - \frac{1}{2\sigma^2} \mathbf{y}_N^\top (\mathbf{1}_{M_\phi} - \Phi^\top \mathbf{A}^{-1} \Phi) \mathbf{y}_N \end{aligned}$$

– 正:

$$\begin{aligned} \ln E(\sigma^2) &= -\frac{N}{2} \ln(2\pi) - \frac{1}{2} \ln \left[(\sigma^2)^N \hat{\lambda}^{-M_\phi} |\mathbf{A}| \right] \\ &\quad - \frac{1}{2\sigma^2} \mathbf{y}_N^\top (\mathbf{1}_N - \Phi^\top \mathbf{A}^{-1} \Phi) \mathbf{y}_N \end{aligned}$$

Chapter 7

時系列データの異常検知

- p.200 下から4行目（真田明様のご教示に感謝します）。
 - 誤: ただし、 $\mathbf{v}^{(t)} = [v_1^{(t)}, v_2^{(t)}, \dots, v_k^{(t)}]^\top$ です。
 - 正: ただし、 $\mathbf{v}^{(t)} = [v_k^{(t)}, v_{k-1}^{(t)}, \dots, v_1^{(t)}]^\top$ です。
- p.202 手順 7.2（真田明様のご教示に感謝します）。
 - 誤:
 - * a) 履歴行列とテスト行列: 式(7.4) と式(7.5)から $H_1^{(t)}$ と $H_2^{(t)}$ を作る。
 - * b) 特異値分解: $H_1^{(t)}, H_2^{(t)}$ を特異値分解し、左特異ベクトルの行列 $U_m^{(t)}, Q_m^{(t)}$ を求める。
 - 正:
 - * a) 履歴行列とテスト行列: 式(7.4) と式(7.5)から $X_1^{(t)}$ と $X_2^{(t)}$ を作る。
 - * b) 特異値分解: $X_1^{(t)}, X_2^{(t)}$ を特異値分解し、左特異ベクトルの行列 $U_m^{(t)}, Q_m^{(t)}$ を求める。
- p.203 上から4行目。辻善夫様のご指摘に感謝いたします。
 - 誤: 過去側に主部分空間への射影
 - 正: 過去側の主部分空間への射影
- p.208 下から2行目の式（平田大貴様のご教示に感謝します）。

– 誤:

$$\frac{\partial L}{\partial \mathbf{A}} = \mathbf{YX}^\top - \mathbf{AXX}^\top$$

– 正:

$$\frac{\partial L}{\partial \mathbf{A}} = \Sigma^{-1}(\mathbf{YX}^\top - \mathbf{AXX}^\top)$$

- p.219 上から6行目。辻善夫様のご指摘に感謝いたします。
 - 誤: 改めててデータを
 - 正: 改めてデータを
- p.220 手順7.4の 2) (真田明様のご教示に感謝します)。
 - 誤: 先に状態変数の推定値 $Z' = \{\hat{z}^{(1)}, \dots, \hat{z}^{(T')}\}$ を用意する ($T' = T - w$)。
 - 正: 先に求めた状態変数の推定値から $Z' = \{\hat{z}^{(1)}, \dots, \hat{z}^{(T')}\}$ を用意する ($T' = T - w$)。
- p.221。下から3行目 (藤本望夢様のご教示に感謝します)。
 - 誤: 分子はモデル (7.28) および式(7.29) そのものですが
 - 正: 分子はモデル (7.27) および式(7.29) そのものですが

Chapter 8

よくある悩みとその対処法

- p.232 式(8.3)の下から (8.4)まで (真田明様のご教示に感謝します)。

- 誤: 例えば共分散行列の場合は、 $\Sigma_t = (1/t) \sum_{n=1}^t \mathbf{x}^{(n)} \mathbf{x}^{(n)\top} - \bar{\mathbf{x}}_t \bar{\mathbf{x}}_t^\top$ なので、第1項について $f_{\text{共分散}}^{(t)} = \mathbf{x}^{(t)} \mathbf{x}^{(t)\top}$ とおいて更新式を作り、その後第2項を加えることで次のように計算できます。

$$\begin{aligned}\tilde{\Sigma}_{t+1} &= (1 - \beta) \tilde{\Sigma}_t + \beta f_{\text{共分散}}^{(t+1)} \\ \Sigma_{t+1} &= \tilde{\Sigma}_{t+1} - \bar{\mathbf{x}}_{t+1} \bar{\mathbf{x}}_{t+1}^\top\end{aligned}\tag{8.4}$$

- 正: 例えば共分散行列の場合は、 $\Sigma_t = (1/t) \sum_{n=1}^t \mathbf{x}^{(n)} \mathbf{x}^{(n)\top} - \bar{\mathbf{x}}_t \bar{\mathbf{x}}_t^\top$ なので、第1項について $f^{(t)} = \mathbf{x}^{(t)} \mathbf{x}^{(t)\top}$ とおいて $F_t = (1/t) \sum_{n=1}^t f^{(n)}$ に対して更新式を作り、その後第2項を加えることで次のように計算できます。

$$\begin{aligned}F_{t+1} &= (1 - \beta) F_t + \beta f^{(t+1)} \\ \Sigma_{t+1} &= F_{t+1} - \bar{\mathbf{x}}_{t+1} \bar{\mathbf{x}}_{t+1}^\top\end{aligned}\tag{8.4}$$

付録

現時点で判明している誤りはありません。

索引

現時点で判明している誤りはありません。