

再構成誤差のシャープレイ値による異常検知の説明


Explaining anomaly detection using Shapley value of reconstruction errors

武石 直也 (理研AIP)

arXiv:1909.03495


概要 異常検知におけるプラクティスとして、正常データに対してPCAなどの生成モデルを学習し、その再構成誤差を監視する方法がある。このとき、どの特徴が異常なのかを特定する手がかりとして、各特徴の再構成誤差を比較することがよくある。しかし、異常特徴の再構成誤差だけが常に大きくなるとは限らない。そこで本稿では、シャープレイ値を用いて異常特徴特定の手がかりを得ることを提案する。

背景 再構成誤差による異常検知 (detection)



例 確率的主成分分析 (PCA) [Tipping&Bishop 99]

生成モデル: $p(\mathbf{x} | \mathbf{z}) = \mathcal{N}_{\mathbf{x}}(\mathbf{W}\mathbf{z}, \sigma^2 \mathbf{I})$
 $p(\mathbf{z}) = \mathcal{N}_{\mathbf{z}}(\mathbf{0}, \mathbf{I})$
最適な再構成: $\hat{\mathbf{x}} = \mathbf{W}(\mathbf{W}^\top \mathbf{W})^{-1} \mathbf{W}^\top \mathbf{x}$



単純だが、(ベースラインとして) よく用いられる。

アイデア シャープレイ値 (Shapley value) の利用

各特徴の再構成誤差そのものではなく、再構成誤差のシャープレイ値を見るとよいのではないかと。

シャープレイ値 協力ゲームの利得を各プレイヤーに 公正に分配する方法のひとつ [Shapley 53]。いくつかの良い性質をもつ。

利得を表す特性関数 v : subsets of $\{1, \dots, d\} \rightarrow \mathbb{R}$ のもと、プレイヤー i のシャープレイ値は次のように定義される:


$$\phi_i(v) = \sum_{S \subseteq \{1, \dots, d\} \setminus \{i\}} \frac{|S|!(d - |S| - 1)!}{d!} (v(S \cup \{i\}) - v(S))$$

つまり、提携 S (プレイヤーの部分集合) に i が参加する影響の平均。

本研究のアイデア 「再構成誤差 = 利得、各特徴 = プレイヤー」と考えて、再構成誤差の各特徴への分配を異常特徴特定に利用する。

模擬異常データによる数値実験

2004 New Car and Truck Data (JSE Data Archive). データサイズ $n = 428$. 欠損のない $d = 11$ 個の特徴を利用。 価格・重量・サイズ・排気量など。 訓練・テストデータに分割後、テストデータ中の各データ点の各特徴をそれぞれテストデータ中での 最小値 or 最大値 に置き換えて異常を模擬。



	MAX		MIN	
	Hits@1	Hits@3	Hits@1	Hits@3
reconstruction error	.316	.605	.271	.471
Shapley values	.484	.801	.484	.710

← 異常特徴特定の Hits@n (指標の上位n個によって異常特徴が正しく特定される割合)

シャープレイ値によってよりよく異常特徴を特定できる (かもしれない)。

目的 異常特徴の特定 (localization)


検知だけでなく、どの特徴が原因で異常となったのか特定したい。

※ 正しいモデルがないと「真の」原因 (因果) は特定できない。
機械学習による方法では、近似的に原因の見当をつけるという問題。

再構成誤差による異常特徴特定 各特徴の再構成誤差の大小を比べる。再構成誤差の計算時に必ず出てくるので、大雑把な近似としては便利。

$$e(\mathbf{x}) = \|\hat{\mathbf{x}} - \mathbf{x}\|_2^2 = (\hat{x}_1 - x_1)^2 + \dots + (\hat{x}_d - x_d)^2$$

どの特徴について再構成誤差が大きいか比べる



しかし、異常特徴の再構成誤差 (だけ) が大きくなるとは限らない。

シャープレイ値の計算にあたって

ポイント① 特性関数の定義 v をどのように定義すればよいのか？
「特徴集合 S のもとでの再構成誤差」では再訓練が必要になり不便。
→ 「 S にない特徴について再構成誤差を周辺化」したものとして定義。
cf. [Štrumbelj&Kononenko 14; Lundberg&Lee 17]

$$v(S) \Big|_{\mathbf{x}} = d^{-1} \mathbb{E}_{p(\mathbf{x}_{S^c} | \mathbf{x}_S)} [\|\hat{\mathbf{x}} - \mathbf{x}\|_2^2]$$

ただし、 S^c は S の補集合で、 S, S^c による添字は部分ベクトル・部分行列。

ポイント② 条件付き分布に関する期待値計算

ひとまず、確率的PCAについては厳密に計算できる (他は要研究)。

$$d \cdot v(S) \Big|_{\mathbf{x}} = \text{tr}((\mathbf{I} - \mathbf{B}_{S^c})(\mathbf{V} + \mathbf{m}\mathbf{m}^\top)) - 2 \text{tr}(\mathbf{B}_{S^c, S} \mathbf{x}_S, \mathbf{m}^\top) + \text{tr}((\mathbf{I} - \mathbf{B}_S) \mathbf{x}_S \mathbf{x}_S^\top)$$

ただし、 $\mathbf{B} = \mathbf{W}(\mathbf{W}^\top \mathbf{W})^{-1} \mathbf{W}^\top$, $\mathbf{C} = \sigma^2 \mathbf{I} + \mathbf{W}\mathbf{W}^\top$
 $\mathbf{m} = \mathbf{C}_{S^c, S} \mathbf{C}_S^{-1} \mathbf{x}_S$, $\mathbf{V} = \mathbf{C}_{S^c, S} \mathbf{C}_S^{-1} \mathbf{C}_{S^c, S}^\top$

議論① 再構成誤差と何が違うのか？

きわめて単純な例として、 $\mathbb{R}^2$ 上の (正常) データ $\mathbf{x}$ の真の生成プロセスが右式で与えられる場合を考える ($z \in \mathbb{R}$ は潜在変数)。

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix} z$$

これに対して、次のような異常発生パターンを考える (いずれも 特徴#2 が異常)。

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} w_1 \\ w_2 \end{bmatrix} z + \begin{bmatrix} 0 \\ \eta \end{bmatrix} \quad \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & \eta \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \end{bmatrix} z \quad \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} w_1 \\ w_2 + \eta \end{bmatrix} z$$

パターンA (加法的) パターンB (乗法的) パターンC (プロセス)

再構成誤差の比 e_2/e_1 およびシャープレイ値の比 $|\phi_2|/|\phi_1|$ (> 1 となるべき) は次のようになる。

$\frac{e_2}{e_1} \Big _{\eta}$	A	B	C
	w_1^2/w_2^2	w_1^2/w_2^2	w_1^2/w_2^2
$\frac{\phi_2(v)}{\phi_1(v)} \Big _{\eta}$	$\frac{\eta^2 \alpha + (\beta(\eta + w_2 z)^2 - \gamma - \delta)}{\eta^2 \alpha - (\beta(\eta + w_2 z)^2 - \gamma - \delta)}$	$\frac{w_2^2 z^2 \alpha (\eta - 1)^2 + (w_2^2 z^2 \beta \eta^2 - \gamma + \delta)}{w_2^2 z^2 \alpha (\eta - 1)^2 - (w_2^2 z^2 \beta \eta^2 - \gamma + \delta)}$	$\frac{z^2 \alpha \eta^2 + (z^2 \beta (\eta + w_2)^2 - \gamma + \delta)}{z^2 \alpha \eta^2 - (z^2 \beta (\eta + w_2)^2 - \gamma + \delta)}$

※ $\alpha = (\sigma^2 + w_1^2)(\sigma^2 + w_2^2)^2$, $\beta = \sigma^4(\sigma^2 + w_1^2)^2$, $\gamma = w_2^2(\sigma^4 z^2 + \sigma^2 w_1^2 + w_1^4)(\sigma^2 + w_2^2)^2$, $\delta = w_2^4(\sigma^2 + w_1^2)(\sigma^2 + w_2^2)$

議論② VAEなどの場合どうするか？

どうすればいいですか？ 例えばモデルがVAE $p(\mathbf{x} | \mathbf{z}) = \mathcal{N}_{\mathbf{x}}(\boldsymbol{\mu}(\mathbf{z}), \boldsymbol{\Sigma}(\mathbf{z}))$ のとき、

$$p(\mathbf{x}_{S^c} | \mathbf{x}_S, \mathbf{z}) = \mathcal{N}_{\mathbf{x}_{S^c}}(\boldsymbol{\mu}_{S^c} + \boldsymbol{\Sigma}_{S^c, S} \boldsymbol{\Sigma}_S^{-1} (\mathbf{x}_S - \boldsymbol{\mu}_S), \boldsymbol{\Sigma}_{S^c} - \boldsymbol{\Sigma}_{S^c, S} \boldsymbol{\Sigma}_S^{-1} \boldsymbol{\Sigma}_{S^c, S}^\top)$$

→ うまく $\mathbf{z}$ を追い出してください。 または、何か別のうまい方法？

DNN出力のシャープレイ値を近似する方法も議論されている [Ancona+ 19 など]。