The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 2019

敵対的生成ネットワークを用いた集団型異常検知

Collective Anomaly Detection using Generative Adversarial Networks

丸　千尋 *1　　小林 一郎 *1
Chihiro Maru　　Ichiro Kobayashi

*1お茶の水女子大学
Ochanomizu University

Generative adversarial network (GAN) is now being applied to anomaly detection. However, the existing approaches to GAN-based anomaly detection cannot detect collective anomalies that change the behavior of some data instances because they deal with individual data instances. This study aims to determine how collective anomalies that are commonly associated with time-series data can be detected using GAN models. We developed a GAN model for time-series data by adopting a decoder side of sequence to sequence (seq2seq) to a generator, an encoder side of seq2seq to an encoder, recurrent neural networks and fully connected neural network to a discriminator. We conducted several experiments on datasets, regarded as anomaly datasets, that we generated by swapping data instances at different time points. The results suggest that our GAN model can compete effectively with existing approaches for detecting collective anomalies.

1.　はじめに

近年，現実世界の高次元分布をモデル化することができる，Generative Adversarial Network (GAN) [Goodfellow 14] が提案されており，異常検知に GAN が適用され始めている [Zenati 18, Li 19]．しかし，GAN を異常検知に用いた既存手法は，複数の観測値を同時に扱うことができないため，観測値自体は正常であるが，その観測値のふるまいが変化する集団型異常を検知することができない．そこで，本研究は，GAN モデルを用いて時系列データに潜む集団型異常を検知することを目的とする．集団型異常を検知するため，Efficient GAN [Zenati 18] の Encoder に sequence to sequence (seq2seq) [Sutskever 14] の Encoder 側，Generator に seq2seq の Decoder 側，そして Discriminator に Recurrent Neural Network (RNN) と全結合 Neural Network (NN) を採用した．この提案する GAN モデルに対して，集団型異常を含むデータセットを用いて評価を行った結果，集団型異常を検知するためには，複数の観測値を扱うネットワークを利用する必要があること，我々の GAN モデルは，複数の観測値を扱うネットワークを採用した既存手法と比較して，高い精度で集団型異常を検知できることが明らかになった．

2.　関連研究

集団型異常とは，観測値自体は正常であるが，その観測値が複数集まった時のふるまいが変化した異常である．例えば，人間の心電図のふるまいが変化した時，その観測値の集まりは集団型異常であると判定される．集団型異常の検知に向けて，Long-Short-Term Memory (LSTM) や AutoEncoder などの NN を用いる手法が提案されている．LSTM を用いた異常検知 [Malhotra 15] は，正常なデータのみから成る訓練データを用いて，入力された d 点の観測値から次の l 点を予測する LSTM を学習する．そして，学習された LSTM から予測された値と実際の値がどの程度異なるかによって，異常の度合い (異常度) を算出する．AutoEncoder を用いた異常検知 [Malhotra 16] は，正常なデータのみから成る訓練データを用いて，入力された部分時系列をそのまま復元する AutoEncoder を学習する．そして，学習された AutoEncoder から復元された値と実際の値がどの程度異なるかによって，異常度を算出する．

連絡先: 丸　千尋，お茶の水女子大学大学院 人間文化創成科学研究科 理学専攻 情報科学コース 小林研究室，〒 112-8610 東京都文京区大塚 2-1-1，03-5978-5708，maru.chihiro@is.ocha.ac.jp

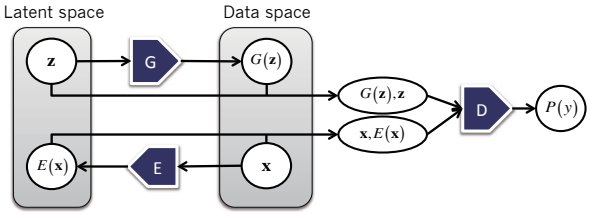

図 1: Efficient GAN の全体像

近年，NN の一つである GAN を異常検知に用いた手法が提案され始めている．特定時点の観測値を扱う Efficient GAN[Zenati 18] は，他の観測値から大きく異なる観測値を検知するために，GAN を用いることが有用であることを明らかにした．しかし，Efficient GAN は，複数の観測値を扱うことができないため，集団型異常を検知することができない．また，MAD-GAN [Li 19] は，時系列データの異常検知のための GAN モデルであるが，時系列データの中の他の観測値から大きく異なる観測値を検知しており，集団型異常を検知することを目的にしていない．そこで，我々は，GAN を用いて時系列データに潜む集団型異常を検知することを目指す．

3.　Efficient GAN

本章では，GAN を異常検知に用いた Efficient GAN と，それが持つ問題点について説明する．

3.1　Efficient GAN の詳細

Efficient GAN は，3 つのネットワーク，Generator，Encoder，そして Discriminator から構成される．Efficient GAN の全体像を図 1 に示す．

Efficient GAN は正常なデータのみから成るデータセットを用いて学習される．Generator (G) は，潜在空間のノイズをデータ空間にマッピングすることにより，実データ $\boldsymbol{x}$ のデータ分布 $p_{data(\boldsymbol{x})}(\boldsymbol{x})$ を学習する．そして，潜在変数 $\boldsymbol{z}$ を与えた時，$p_{data(\boldsymbol{x})}(\boldsymbol{x})$

を用いて実データに近い正常データ $G(z)$ を生成する．Encoder (E) は，Generator の逆の機能を有し，データ $\boldsymbol{x}$ を潜在空間にマッピングし $E(\boldsymbol{x})$ を得る．Discriminator (D) は，データと潜在変数の組から成る入力データ $((\boldsymbol{x}, E(\boldsymbol{x}))$ もしくは $(G(z), z))$ が与えられた時に，それが実データ（本物）であるのか，Generator によって生成されたデータ (偽物) であるのかを識別し，与えられた入力データが本物である確率 $P(y)$ を出力する．

Generator の最終的な目標は，Discriminator に本物と識別されるような，実データに近い正常データを生成することである．Encoder の場合は，Discriminator に実データ $\boldsymbol{x}$ を本物だと信じてもらえるよう，データを潜在空間にマッピングすることである．Discriminator は，Generator に騙されないよう，与えられた入力データが本物であるのか，偽物であるのかを正確に識別することを目標とする．上記の目標を達成するため，以下の目的関数 (1) を Generator，Encoder，Discriminator で共有し，Discriminator に関しては目的関数を最大化，Generator と Encoder に関しては最小化するように交互に学習する．

$$V(D,E,G) = \mathbb{E}_{\boldsymbol{x}\sim p_{data}(\boldsymbol{x})}[\log(D(\boldsymbol{x}, E(\boldsymbol{x})))] + \mathbb{E}_{z\sim p_z(z)}[\log(1 - D(G(z), z))] \quad (1)$$

ここで，$p_{data}(\boldsymbol{x})$ は実データ分布，$p_z(z)$ は潜在変数 z の分布で，訓練データを用いて学習される．$G(z)$ は潜在変数 z を Generator に与えた時に生成されるデータを表す．さらに，$D(\boldsymbol{x}, E(\boldsymbol{x}))$ と $D(G(z), z)$ は，入力データ $(\boldsymbol{x}, E(\boldsymbol{x}))$ もしくは $(G(z), z)$ が Discriminator に与えられた時に Discriminator によって出力される，入力データが本物である確率を表す．

正常データのみを用いて学習された Efficient GAN を用いて，未知の入力データ $\boldsymbol{x}$ に対して，異常度 $A(\boldsymbol{x})$ (式 (2)) を算出する．$A(\boldsymbol{x})$ は，再構築損失 $L_G(\boldsymbol{x})$ (式 (3)) と識別損失 $L_D(\boldsymbol{x})$ (式 (4)) の 2 つの項から構成される．α は係数である．$A(\boldsymbol{x})$ の値が大きくなるほど，$\boldsymbol{x}$ が異常であるということを意味する．

$$A(\boldsymbol{x}) = \alpha L_G(\boldsymbol{x}) + (1-\alpha) L_D(\boldsymbol{x}) \quad (2)$$

$$L_G(\boldsymbol{x}) = \|\boldsymbol{x} - G(E(\boldsymbol{x}))\|_1 \quad (3)$$

$$L_D(\boldsymbol{x}) = \sigma(D(\boldsymbol{x}, E(\boldsymbol{x})), 1) \quad (4)$$

再構築損失 $L_G(\boldsymbol{x})$ は，未知の入力データ $\boldsymbol{x}$ と再構築されたデータ $G(E(\boldsymbol{x}))$ の $L1$ ノルムである．$G(E(\boldsymbol{x}))$ は，Encoder を使って $\boldsymbol{x}$ を潜在変数 $E(\boldsymbol{x})$ にマッピングした後，$E(\boldsymbol{x})$ を Generator に与えることで再構築されたデータである．Encoder と Generator は正常データを用いて学習されているため，$\boldsymbol{x}$ が正常である場合，再構築された $G(E(\boldsymbol{x}))$ は $\boldsymbol{x}$ に似たデータとなるはずである．一方，$\boldsymbol{x}$ が異常な場合は，Encoder と Generator が対応していないため，$G(E(\boldsymbol{x}))$ は $\boldsymbol{x}$ と大きく異なるデータとなる．よって，$L_G(\boldsymbol{x})$ の値が大きくなる．

識別損失 $L_D(\boldsymbol{x})$ は，未知の入力データ $\boldsymbol{x}$ と，それを Encoder を使ってマッピングした潜在変数 $E(\boldsymbol{x})$ の組を Discriminator が本物であると識別する確率と，クラス 1 の交差エントロピー損失 σ である．ここで，クラス 1 は入力データ $\boldsymbol{x}$ が本物であることを意味する．交差エントロピーでは，$D(\boldsymbol{x}, E(\boldsymbol{x}))$ の値が 0 に近くなる，すなわち Discriminator によって入力データ $\boldsymbol{x}$ が偽物であると識別される程，$L_D(\boldsymbol{x})$ の値が大きくなる．Discriminator は正常データの識別を正確に行えるように学習されているため，異常データ $\boldsymbol{x}$ が与えられると，Discriminator は $\boldsymbol{x}$ を偽物だと識別し，$D(\boldsymbol{x}, E(\boldsymbol{x}))$ が 0 に近い値となる．その結果，$L_D(\boldsymbol{x})$ の値が大きくなる．

3.2 Efficient GAN の問題点

Efficient GAN における Encoder，Generator，Discriminator は，観測値を個々に扱うネットワークであるため，特定時点の観測値の異常を検知することはできる．しかし，観測値自体は正常であるが，その観測値のふるまいに異常が存在するような複数の観測値を扱うことによって異常を検知することが可能となる集団型異常を検知することはできない．そこで本研究では，GAN モデルを用いて，時系列データに潜む集団型異常を検知することを目的とする．

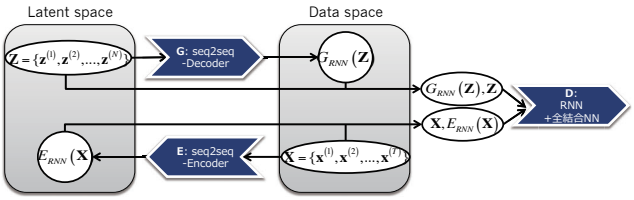

図 2: MARU-GAN の全体像

4. GAN を用いた集団型異常検知

本稿では，長さ T の部分時系列 $\boldsymbol{X} = \{\boldsymbol{x}^{(1)}, \boldsymbol{x}^{(2)}, \cdots, \boldsymbol{x}^{(T)}\}$ を考える．時刻 t_i の観測値 $\boldsymbol{x}^{(i)} \in \mathbb{R}^M$ は，M 個の変数を持つ M 次元ベクトルである．本稿では，このような長さ T の複数の部分時系列 $\boldsymbol{X}$ が時系列データを構成していると仮定する．部分時系列 $\boldsymbol{X}$ を扱うため，Efficient GAN の Encoder，Generator，Discriminator をそれぞれ複数の点を扱えるネットワークに拡張した，Multivariate Anomaly detection with Recurrent Units-GAN (MARU-GAN) を提案する．MARU-GAN の全体像を図 2 に示す．Efficient GAN の Encoder に seq2seq の Encoder 側，Generator に seq2seq の Decoder 側，Discriminator に RNN と全結合 NN を採用する．

4.1 Encoder

Encoder には，seq2seq の Encoder 側を採用する．Encoder のネットワークを図 3 に示す．Encoder は長さ T の固定長の部分時系列 $\boldsymbol{X} = \{\boldsymbol{x}^{(1)}, \boldsymbol{x}^{(2)}, \cdots, \boldsymbol{x}^{(T)}\}$ を入力部分時系列 $\boldsymbol{X}$ として受け取り，Encoder の最後の隠れ状態 $(\boldsymbol{h}_1^{(T)}, \boldsymbol{h}_2^{(T)}, \boldsymbol{h}_3^{(T)})$ を $E_{RNN}(\boldsymbol{X})$ として出力する．この $E_{RNN}(\boldsymbol{X})$ には，入力部分時系列の特徴が圧縮されている．本稿では，Encoder の隠れ層を 3 ユニットとして実装した．Encoder は式 (5) の目的関数を最小化するように学習される．

$$V(E) = \mathbb{E}_{\boldsymbol{X}\sim p_{data}(\boldsymbol{X})}[\log(D_{RNN}(\boldsymbol{X}, E_{RNN}(\boldsymbol{X})))] \quad (5)$$

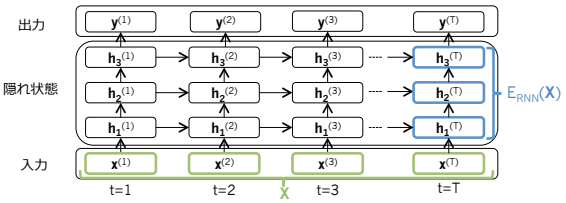

図 3: Encoder の全体像

4.2 Generator

Generator には，seq2seq の Decoder 側を採用する．Generator のネットワークを図 4 に示す．Generator は潜在変数 $\boldsymbol{Z}$ を受け取り，それを Generator の最初の隠れ状態 $(\boldsymbol{s}_1^{(1)}, \boldsymbol{s}_2^{(1)}, \boldsymbol{s}_3^{(1)})$ に設定する．そして，開始を表す入力を与えると，各時刻 t_i で $\boldsymbol{x}^{(i)}$ が出力される．全ての $\boldsymbol{x}^{(i)}$ を結合した部分時系列 $\boldsymbol{X} = \{\boldsymbol{x}^{(1)}, \boldsymbol{x}^{(2)}, \cdots, \boldsymbol{x}^{(T)}\}$ を $G_{RNN}(\boldsymbol{Z})$ とする．本稿では，Generator の隠れ層を 3 ユニットとして実装した．Generator は式 (6) の目的関数を最小化するように学習される．

$$V(G) = \mathbb{E}_{\boldsymbol{Z}\sim p_{\boldsymbol{Z}}(\boldsymbol{Z})}[\log(1 - D_{RNN}(G_{RNN}(\boldsymbol{Z}), \boldsymbol{Z}))] \quad (6)$$

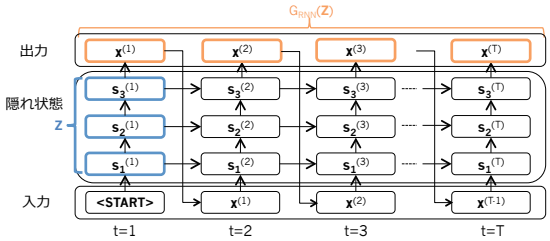

図 4: Generator の全体像

4.3 Discriminator

Discriminator には，RNN と全結合 NN の 2 種類の NN を用いる．Encoder の全体像を図 5 に示す．Discriminator は，データ (部分時系列) と潜在変数を結合したベクトルを入力として受け取る．RNN では，部分時系列 $G_{RNN}(\boldsymbol{Z})$ もしくは，$\boldsymbol{X}$ を入力として，最後の隠れ状態 $\boldsymbol{h}_{dis}^{(T)}$ を得る．この $\boldsymbol{h}_{dis}^{(T)}$ には，入力された部分時系列の特徴が圧縮されている．そして，得られた $\boldsymbol{h}_{dis}^{(T)}$ と，潜在変数 $\boldsymbol{Z}$ もしくは，$E_{RNN}(\boldsymbol{X})$ を結合し，全結合 NN に入力する．全結合 NN は，入力された部分時系列が本物である確率を出力し，これが Discriminator の出力となる．Discriminator は式 (7) の目的関数を最大化するように学習される．

$$V(D) = \mathbb{E}_{X\sim p_{data}(X)}[\log(D_{RNN}(\boldsymbol{X}, E_{RNN}(\boldsymbol{X})))] + \mathbb{E}_{Z\sim p_Z(Z)}[\log(1 - D_{RNN}(G_{RNN}(\boldsymbol{Z}), \boldsymbol{Z}))] \quad (7)$$

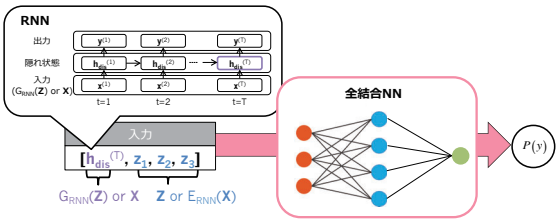

図 5: Discriminator の全体像

4.4 異常度の算出

4.1–4.3 節の Encoder，Generator，Discriminator を正常な部分時系列のみから構成される訓練データを用いて学習した後，各部分時系列 $\boldsymbol{X}$ の異常度 $A_{RNN}(\boldsymbol{X})$ を，式 (2) を拡張した式 (8) を用いて算出する．

$$A_{RNN}(\boldsymbol{X}) = \alpha L_{G_{RNN}}(\boldsymbol{X}) + (1-\alpha) L_{D_{RNN}}(\boldsymbol{X}) \quad (8)$$

$$L_{G_{RNN}}(\boldsymbol{X}) = \|\boldsymbol{X} - G_{RNN}(E_{RNN}(\boldsymbol{X}))\|_1 \quad (9)$$

$$L_{D_{RNN}}(\boldsymbol{X}) = \sigma(D_{RNN}(\boldsymbol{X}, E_{RNN}(\boldsymbol{X})), 1) \quad (10)$$

$L_{G_{RNN}}$ (式 (9)) においては，入力部分時系列 $\boldsymbol{X}$ に含まれる観測値ごとに算出した値を集計して $\boldsymbol{X}$ の $L_{G_{RNN}}$ とする．$L_{D_{RNN}}(\boldsymbol{X})$ (式 (10)) の $D_{RNN}(\boldsymbol{X}, E_{RNN}(\boldsymbol{X}))$ では，Discriminator が部分時系列 $\boldsymbol{X}$ ごとに本物だと識別する確率を出力する．上記の $A_{RNN}(\boldsymbol{X})$ を用いて，全ての未知の入力部分時系列 $\boldsymbol{X}$ に対して異常度を算出し，上位 N%の部分時系列を異常と判定する．

5. 実験

4. 章で提案した MARU-GAN が時系列データに潜む集団型異常を検知可能か，本章で評価する．我々は，正常な観測値のみから構成される SWaT データセット *1 と WADI データセット *2 に，集団型異常を人工的に作成し混ぜることで，新たに生成された 2 種類のデータセットを用いて実験を行った．比較対象として，Efficient GAN [Zenati 18]，EncDec-AD [Malhotra 16]，そして LSTM-AD [Malhotra 15] を採用した．

*1 https://itrust.sutd.edu.sg/testbeds/secure-water-treatment-swat/
*2 https://itrust.sutd.edu.sg/testbeds/water-distribution-wadi/

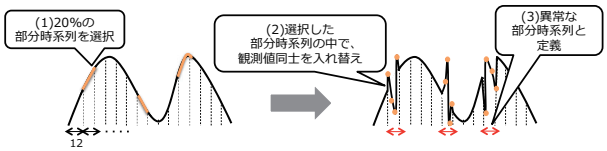

図 6: 疑似集団型異常時系列データの生成方法

5.1 実験データ

SWaT データセットは，最新の水処理プラントを縮小したレプリカから収集された 51 次元のデータから構成される．WADI データセットは，水分散システムから収集された 123 次元のデータから構成される．どちらのデータセットにおいても，データは 1 秒ごとに測定される．本研究では，475,200 点の正常な観測値から成る SWaT データセットと，1,048,560 点の正常な観測値から成る WADI データセットと用いて各手法の評価を行った．

5.2 集団型異常の生成

事前処理として，475,200 点の正常な SWaT データ，1,048,560 点の正常な WADI データを訓練／検証／テストデータとして 8:1:1 に分割し，部分時系列の長さが T=12 のデータセットを生成する．その結果，訓練／検証／テストデータは，SWaT データセットにおいては，31,680 部分時系列，3,960 部分時系列，3,960 部分時系列，WADI データセットにおいては，69,904 部分時系列，8,738 部分時系列，8,738 時系列となった．

訓点データは，モデルを訓練するために使われる．検証データは，各 epoch の学習後の評価に使われ，最終的に F 値が最も高い epoch のモデルを選択するために使われる．テストデータは，検証データを用いて選択された epoch のモデルに対して，異常検知の精度を評価するために使われる．これらのデータのうち，検証・テストデータは評価に使われるため，集団型異常を含む必要がある．

集団型異常とは，観測値自体は正常だが，その観測値のふるまいが変化したタイプの異常である．したがって，正常な観測値と他の正常な観測値を入れ替えることで対応した．具体的な集団型異常の生成方法を下記に示す．生成方法の概要を図 6 に示す．

1. 各データ (検証／テスト) の中で，20%の部分時系列をランダムに選択
2. 選択した部分時系列の中で，観測値同士をランダムに入れ替え
3. 選択した 20%の部分時系列を異常と定義

(2) で選択された 20%の各部分時系列に含まれる T 点を，他の選択された部分時系列の観測値とランダムに入れ替えることで，観測値自体は正常な値であるが，その観測値のふるまいに異常が存在する集団型異常を生成することが可能となる．上記で選択された 20%を異常と定義し，MARU-GAN の異常検知の結果と比較する．

5.3 実験結果と考察

表 1 に MARU-GAN の Encoder，Generator，Discriminator の詳細，表 2 に実験設定を示す．各表のハイパーパラメータは，先行研究に基づいて調節した．実験結果を表 4 に示す．

MARU-GAN は全ての評価値において，他の既存手法よりも高い精度を達成することができた．

Efficient GAN のような特定時点の観測値を扱うモデルでは，観測値自体は正常であるが，その観測値のふるまいが変化した集団型異常を検知することが不可能であった．Efficient GAN

表 1: MARU-GAN のハイパーパラメータ

	ユニット数	層数	ドロップアウト率
Encoder			
$E(\boldsymbol{X})$: RNN	100	3	0.0
Generator			
$G(\boldsymbol{Z})$: RNN	100	3	0.0
Discriminator			
$D(\boldsymbol{X})$: RNN	100	1	0.2
$D(\boldsymbol{X}, \boldsymbol{Z})$: 全結合 NN	1	1	0.0

表 2: 実験設定

勾配法	Adam
ハイパーパラメータ	$\alpha = 1e-5, \beta_1 = 0.5, \beta_2 = 0.999, \varepsilon = 1e-8$
時系列の長さ T	12
バッチサイズ	50
Epoch 数	1000
潜在変数の次元	100

では，F 値が実験データに占める異常の割合 20%と変わらず，つまり，異常をランダムに選択してしまっているのと区別がつかない．従って，集団型異常を検知するためには，複数の観測値を扱うためのネットワークを利用する必要があると考える．

EncDec-AD と LSTM-AD は，複数の観測値を扱うモデルであるにも関わらず，集団型異常を検知することができなかった．

EncDec-AD は，異常データの異常度が正常データの異常度と変わらないため，異常を検知することができなかった．EncDec-AD は，正常データのみから成る訓練データを用いて，入力部分時系列 $\boldsymbol{X} = \{\boldsymbol{x}^{(1)}, \boldsymbol{x}^{(2)}, \cdots, \boldsymbol{x}^{(T)}\}$ と AutoEncoder によって復元される部分時系列 $\boldsymbol{X'} = \{\boldsymbol{x}^{(1)\prime}, \boldsymbol{x}^{(2)\prime}, \cdots, \boldsymbol{x}^{(T)\prime}\}$ に対して，目的関数 $\sum_{i=1}^{T} \|\boldsymbol{x}^{(i)} - \boldsymbol{x}^{(i)\prime}\|^2$ を最小化するように学習される．目的関数を最適化すると，正常データのみを使って AutoEncoder を学習しているにも関わらず，訓練データ (正常データ) に存在しない異常データに対しても，学習した AutoEncoder を使ってほぼ完全に復元することが可能であった．AutoEncoder は，Encoder 側で入力時系列の特徴を圧縮したベクトルを使って Decoder 側で復元を行っている．よって，未来が明らかな状態で復元が行われているため，異常なデータに対してもほぼ完全に復元できてしまうと考えられる．そのため，異常度を算出する際に用いるエラーベクトル $\boldsymbol{e}^{(i)} = |\boldsymbol{x}^{(i)} - \boldsymbol{x}^{(i)\prime}|$ の値が，正常データであっても，異常データであっても，変わらないため，異常を検知することができなかった．一方，MARU-GAN の異常度 $A_{RNN}(\boldsymbol{X}) = \alpha L_{G_{RNN}}(\boldsymbol{X}) + (1-\alpha) L_{D_{RNN}}(\boldsymbol{X})$ においても，EncDec-AD と同様に，再構築誤差 $L_{G_{RNN}}(\boldsymbol{X}) = \|\boldsymbol{X} - G_{RNN}(E_{RNN}(\boldsymbol{X}))\|_1$ を用いて異常の検出を行っている．しかし，MARU-GAN の目的関数 (式 (1)) は EncDec-AD とは異なり，正常な部分時系列を生成するように学習される．つまり，完全な復元を目的にしていない．学習後，異常な部分時系列も正常な部分時系列と判定されるように再構築されるが，MARU-GAN の場合，それを避けることができる．その結果が再構築誤差 $L_{G_{RNN}}$ で得られるため，MARU-GAN は集団型異常を検知することが可能となる．

LSTM-AD は，異常な部分時系列の前半の観測値を異常と識別することができなかった．これは，LSTM に入力される観測値が少ない前半である程，予測のために必要な手がかりが少ないため，上手く予測ができなかったことが原因と考えられる．

表 3: 実験結果 (SWaT データセット)

手法	F 値	Accuracy	False positive 率
Efficient GAN [Zenati 18]	0.20	0.68	0.20
EncDec-AD [Malhotra 16]	0.19	0.68	0.20
LSTM-AD [Malhotra 15]	0.50	0.80	0.12
MARU-GAN	**0.72**	**0.89**	**0.07**

表 4: 実験結果 (WADI データセット)

手法	F 値	Accuracy	False positive 率
Efficient GAN [Zenati 18]	0.19	0.68	0.20
EncDec-AD [Malhotra 16]	0.19	0.68	0.20
LSTM-AD [Malhotra 15]	0.46	0.79	0.13
MARU-GAN	**0.71**	**0.88**	**0.07**

また，複数の観測値 d 点間に異常データのようなランダム性が存在する場合，その後の観測値 l 点を上手く予測することができなかった．その結果，頻繁に l 点が異常だと判定されてしまった．

以上より，集団型異常を検知するためには，複数の観測値を扱うネットワークを利用する必要があること，提案モデルである MARU-GAN は，複数の観測値を扱うネットワークを採用した既存手法と比較して，高い精度で集団型異常を検知できることが明らかになった．

6. おわりに

本稿では，特定時点の観測値を扱う GAN モデルのネットワークを複数の観測値を扱えるネットワークに拡張することによって，時系列データに潜む集団型異常を検知可能な GAN モデルを提案した．提案モデルに対して，時系列データの一部の正常な観測値を他の正常な観測値と入れ替えて生成したデータセットを用いて評価を行った．その結果，集団型異常を検知するためには，複数の観測値を扱うネットワークを利用する必要があること，我々の GAN モデルは，複数の観測値を扱うネットワークを採用した既存手法と比較して，高い精度で集団型異常を検知できることが明らかになった．

参考文献

[Goodfellow 14] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. ”Generative adversarial nets,” In Advances in Neural Information Processing Systems, pp. 2672–2680, 2014.

[Sutskever 14] I. Sutskever, O. Vinyals, and Q. V. Le, ”Sequence to sequence learning with neural networks,” In Advances in Neural Information Processing Systems, pp. 3104–3112, 2014.

[Zenati 18] H. Zenati, C. S. Foo, B. Lecouat, G. Manek, and V. R. Chandrasekhar, ”Efficient GAN-based anomaly detection,” arXiv:1802.06222, 2018.

[Li 19] D. Li, D. Chen, L. Shi, B. Jin, J. Goh, and S. K. Ng, ”MAD-GAN: Multivariate Anomaly Detection for Time Series Data with Generative Adversarial Networks,” arXiv:1901.04997, 2019.

[Malhotra 15] P. Malhotra, L. Vig, G, Shroff, and P. Agarwal, ”Long Short Term Memory Networks for Anomaly Detection in Time Series,” European Symposium on Artificial Neural Networks, pp. 89–94, 2015.

[Malhotra 16] P. Malhotra, A. Ramakrishnan, G. Anand, L. Vig, P. Agarwal, and G. Shroff, ”LSTM-based Encoder-Decoder for Multi-sensor Anomaly Detection,” arXiv:1607.00148, 2016.