

DOI: 10.19783/j.cnki.pspc.210274

基于 GAN 的光伏逆变器数据异常检测技术

周嘉琪¹, 毕利²

(宁夏大学信息工程学院, 宁夏 银川 750021)

摘要: 随着实际环境中实时传感器数据的增加, 定位异常情况变得越来越困难。同时, 在基于图像的异常检测领域, 生成对抗网络因其能够对复杂的高维图像分布进行建模而得到发展。为了能够精准快速地定位光伏发电系统中光伏逆变器的异常, 提出了一种新的基于 GAN 的异常检测和定位框架。并将多变量时间序列利用角场转换为一组二维图像, 以此利用编码器和解码器的结构。特别是在一系列图像中采用卷积长短期记忆网络的编码器, 保证了对每个时间序列数据的时间信息以及各变量之间的相关信息进行提取。最后通过执行异常评分函数来检测和定位异常, 并通过相关实验证明了此方法在实际光伏逆变器数据异常检测任务中的有效性。

关键词: 异常检测; 光伏逆变器; 生成对抗网络; 卷积长短期记忆神经网络

Abnormal detection technology of photovoltaic inverter data based on GAN

ZHOU Jiaqi¹, BI Li²

(School of Information Engineering, Ningxia University, Yinchuan 750021, China)

Abstract: With the increase of real-time sensor data in the actual environment, it becomes more and more difficult to locate an abnormal situation. At the same time, in the field of image-based anomaly detection, generative adversarial networks (GAN) have been developed because of their ability to model complex high-dimensional image distribution. In order to accurately and quickly locate an abnormality of a photovoltaic inverter in a photovoltaic power generation system, a new abnormal detection and location framework based on GAN is proposed. The multi-variable time series is transformed into a series of two-dimensional image using the angle field, and a structure of encoder and decoder is used. Particularly for a series of images, a convolutional long-term and short-term memory network encoder is used to ensure the extraction of the time information of each time series data and the relevant information between variables. Finally, the anomaly can be detected and located by executing the anomaly score function, and the relevant experiments prove the effectiveness of this method in the actual photovoltaic inverter data anomaly detection task.

This work is supported by the Ningxia Natural Science Foundation (No. 2020AAC03034).

Key words: anomaly detection; photovoltaic inverter; GAN; ConvLSTM

0 引言

为应对气候变暖、环境污染等问题, 全球能源消费正逐步迈入以清洁能源和可再生能源替代化石能源的“第三次工业革命”^[1]时代。在中国的电网中, 近 24% 的电力来自水力发电, 其余 76% 的电力仍然来自火力发电。中国拥有丰富的阳光资源, 而丰富的阳光资源绝对有可能代替火力发电。积极发

展太阳能的趋势为进一步利用太阳能的潜力奠定了坚实的基础。然而在光伏发电^[2-4]系统实际运行过程中存在大量异常数据, 产生这些异常数据的原因包括数据传输、传感器故障等, 维护就显得愈发重要^[5]。

光伏逆变器^[6-8]是光伏发电系统中非常重要的组成部分, 其健康状态直接影响电力系统的安全与稳定运行^[9-10]。就现在来看, 光伏逆变器通常采用定时定点维护和发生故障后再维护的维护方式。运维人员几乎没有办法了解光伏逆变器实时的健康或者故障情况。因此, 本文提出的基于 GAN 的异常检测技术能够精准、有实效性地判断出光伏逆变器

基金项目: 宁夏自然科学基金项目资助(2020AAC03034); 西部一流大学科研创新项目资助(ZKZD2017005)

的健康或者故障情况，可以帮助运维人员做出科学合理的检测维修计划，保证整个系统运行平稳，同时还可以大幅度节约维修运行成本。异常检测是发电厂、智能工厂等许多应用领域面临的主要挑战之一。虽然可以通过分析安装的传感器来确定系统中的异常情况，但随着传感器数量的增加，这种情况变得越来越困难。为了提高多变量传感器数据分析的效率，在传统统计故障诊断方法的基础上，发展了基于深度学习的异常检测方法。

一方面，在深度学习中关于异常检测的算法比基于机器学习与统计学方法拥有更多优势，能够提取更多数据特征。通过对文献[11]的学习，对于高维大数据异常检测技术进行了详细和全面的了解。文献[12]针对异物图像特点，提出了一种基于Dense-YOLOv3的深度学习算法用来监测输电线路异物入侵。文献[13]结合YOLOv3框架提出了一种识别电网故障的算法。除了YOLOv3框架，基于生成对抗网络的异常检测方法也已经成为图像和视频领域的主流方法。这是因为它能够模拟复杂的高维图像分布，如文献[14-16]所述。AnoGAN^[17]中的假设是生成模型可以学习正态分布的潜在空间。它可以通过将给定的数据重新映射到学习的潜在向量空间来识别给定的数据是否对应于正态数据分布。此外，GANomaly^[18]在AnoGAN的基础上，还引入了一个额外的编码器网络，以便对正常数据的潜在空间向量进行稳健的编码。

另一方面循环神经网络(Recurrent Neural Network, RNN)和长短期记忆网络(Long Short-Term Memory, LSTM)被认为是通过递归连接处理序列数据的有效方法。然而，这些方法假设变量之间完全连通，因此很难将变量之间的相关性解释为变量数量的增加^[19]。而卷积长短期记忆网络(Convolutional Long Short-Term Memory, ConvLSTM)^[20]在LSTM的基础上加入卷积操作，对于图像的特征提取会更加有效。为了充分利用ConvLSTM结构，直观地呈现多变量时间序列数据，本文研究了将时间序列数据转换为二维图像的方法。例如，格拉姆角场(Gramian Angular Field, GAF)^[21]和马尔科夫转移场(Markov Transition Field, MTF)^[22]可以通过捕获自相关将单变量时间序列数据编码成图像。对于多变量时间序列数据，文献[23]提出了基于变量内积的特征矩阵。

受文献[11-23]启发，本文将光伏逆变器时序数据转换成二维图像，并基于卷积长短期记忆网络重新设计了针对逆变器异常检测的网络结构，可以对逆变器的异常数据进行准确率相当高的检测。网络

结构中的生成器可以学习一系列二维图像到下一个二维图像的映射，从而不仅可以分析时间序列数据的时间关联，还可以通过卷积滤波分析多个变量之间的相关性。本文的其余部分安排如下：首先，提出了一种基于GAN的光伏逆变器多变量时间序列图像异常检测模型，并通过构造特征矩阵将多变量时间序列编码到二维图像中。然后，介绍了模型的训练过程。最后，以实际光伏逆变器多元时间序列数据为例，通过实验验证了该方法的有效性。

1 异常检测框架

因为光伏逆变器运维数据大部分为正常数据，异常数据少，数据样本分布极度不平衡，所以比较适合用生成对抗网络学习正常数据分布来达到异常检测的目的，而基于生成对抗网络的异常检测方法已经成为图像和视频领域的主流方法，它更擅长处理图像数据，于是本文提出将逆变器数据利用角场转化为图像序列数据，同时通过使用卷积长短期记忆网络改造的GANomaly框架来处理数据。GANomaly使用卷积网络来构造框架，但是逆变器的运维数据属于时间序列数据，所以使用长短期记忆网络更为合适，而卷积长短期记忆网络不仅有长短期记忆网络的优点：对时间序列数据处理效率更高，可以提取数据时空特征，同时还利用卷积计算方式提取了数据的空间特征，提高模型的精准度。

1.1 问题陈述

异常样本的定义：如图1所示，使用滑动窗口对时间序列进行预处理，设一个时间节点 t ，该模型将光伏逆变器在 t 时刻之前 w 天的数据作为一个样本，如果该光伏逆变器在 w 个时间点内出现故障，即运维数据出现异常或者光伏逆变器无法正常运行，则定义该样本为异常样本，否则为正常样本。

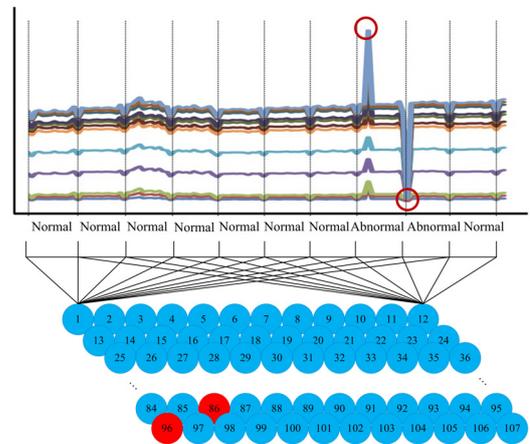


图1 异常点的描述

Fig. 1 Description of outliers

光伏逆变器时序数据异常检测问题描述: 设有一个时序数据集 $D = \{(X_1, y_1), (X_2, y_2), \dots, (X_n, y_n)\}$ 包含 n 个样本, $X_i \in \mathbb{R}^{w \times d}$ 是一个光伏逆变器时间序列数据, d 表示衡量光伏逆变器健康程度的属性, w 表示光伏逆变器数据一个时间序列的长度, $y_i \in \{0, 1\}$ 表示数据的健康或故障标签, 标签等于 0 表示光伏逆变器是健康状态, 标签等于 1 表示光伏逆变器是故障状态。 D 由训练集 D_{train} 和测试集 D_{test} 组成, 其中, 训练集 D_{train} 只包含健康数据, 测试集 D_{test} 含有健康数据和故障数据。在整个实验里, 训练集 D_{train} 的数据样本量远远大于测试集 D_{test} 的数据样本量, 测试集 D_{test} 中光伏逆变器健康数据样本量远远大于故障数据样本量。

训练阶段在训练集 D_{train} 上进行, 通过最小化损失函数, 该模型可以同时学习正常样本在样本空间和深层次空间中的分布。再在测试集 D_{test} 上进行测试。在测试阶段, 如果训练时没有出现过的故障数据样本, 其 $A(X)$ 计算值会更大一些, 使用最优化准则选择阈值 φ , 把 $A(X) \geq \varphi$ 的样本数据判为故障, $A(X) < \varphi$ 的数据样本则判为健康正常, 以此来达到异常检测的最终目的。

1.2 GAF 方法

格拉姆角场^[21]是通过极坐标系代替笛卡尔坐标系来表示时间序列的。文献[21]中原始时间序列到 GAF 的转换步骤如下。

假设时间序列是 $X = \{x_1, x_2, \dots, x_n\}$, 长度是 n , 可以使用归一化方法使用式(1)把时间序列压缩到 $[-1, 1]$ 。

$$\tilde{x}_{-1} = \frac{[x_i - \max(X)] + [x_i - \min(X)]}{\max(X) - \min(X)} \quad (1)$$

接下来可以通过将值编码为角余弦, 将时间戳编码为半径, 用三角函数表示重新缩放的时间序列 \tilde{X} 。

$$\begin{cases} \theta = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i \in N \end{cases} \quad (2)$$

式中: t_i 为时间戳; N 为调整极坐标跨度的常数因子。通过上述变换可以将原始时间序列转换为沿对角线对称的特征图, 由于特征图像蕴含时间相关信息, 因此可以使用特征图对时间序列进行重构。式(3)定义了格拉姆角和场(GASF)。

$$G_s = \begin{bmatrix} \cos(\theta_1 + \theta_1) & \dots & \cos(\theta_1 + \theta_n) \\ \vdots & & \vdots \\ \cos(\theta_n + \theta_1) & \dots & \cos(\theta_n + \theta_n) \end{bmatrix} = \tilde{X}^T \tilde{X} - \sqrt{I - \tilde{X}^2}^T \sqrt{I - \tilde{X}^2} \quad (3)$$

式中: I 为单位向量 $[1, 1, \dots, 1]$; \tilde{X}^T 为 \tilde{X} 的转置向量。

这是一种基于极坐标表示时间序列的新颖方法。随着时间的增加, 相应的值会在跨越圆上的不同角度点之间扭曲, 就像水的涟漪一样。如图 2 所示, 可以将时间序列变换到极坐标系, 再将极坐标系映射为二维图像。式(2)的编码映射有两个重要的性质。首先, 它是双主观性的, 当 $\theta \in [0, \pi]$ 时, $\cos(\theta)$ 是单调的。给定一个时间序列, 在极坐标系中, 所提出的映射仅产生一个结果, 而且只有一个结果具有唯一的逆映射。第二, 极坐标与笛卡尔坐标相反, 极坐标保持时间绝对不变。

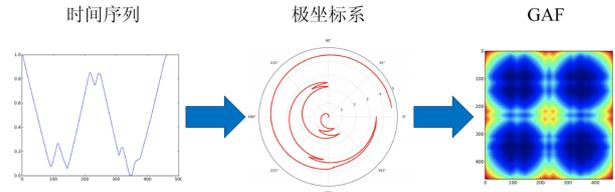


图 2 格拉姆角场编码图说明

Fig. 2 Explanation of Gramian angular field coding pattern

图 3 为利用角场将单个时间的逆变器属性数据映射为二维图像, 由图 3 可以看出, 正常样本与异常样本的角场图像有很大的差异, 这对于使用深度学习来进行异常检测是十分有利的。

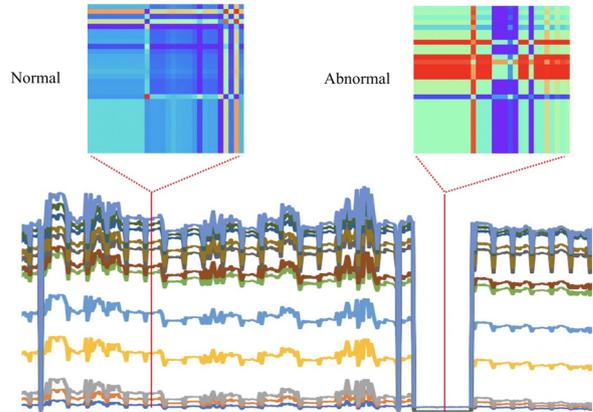


图 3 逆变器数据利用角场映射为二维图像

Fig. 3 Data of inverter is mapped into two-dimensional image by angular field

1.3 ConvLSTM

LSTM 可以将过去的信息传输到当前数据并挖掘相邻序列数据之间的关系。因此, LSTM 可用于提取序列数据之间的相关信息。但是, 传统的 LSTM 网络是逐层完全连接的。而且, 卷积运算可以获得更多的结构信息。为了学习空间信息和局部结构信息, 文献[24]提出了一种将卷积运算和 LSTM 相结

合的网络，称为 ConvLSTM。

ConvLSTM 是通过添加基于 LSTM 的卷积运算构成的，该运算是层与层之间的卷积连接。ConvLSTM 的结构与 FC-LSTM^[25] 相同，LSTM 单元中每个门的卷积运算将完全连接的运算替换为卷积运算。通过卷积运算将相邻输入的结构信息反馈到当前数据。而且，通过卷积提取的特征被传输到下一层可以获得更多信息。ConvLSTM 可以捕获空间特征，并通过遵循更新方程将其传输到相邻的输入，利用三个门限层来控制记忆的存取，内部结构如图 4 所示，公式为

$$i_t = \sigma(W_{xi} * x_t + W_{hi} * H_{t-1} + W_{ci} * C_{t-1} + b_i) \quad (4)$$

$$f_t = \sigma(W_{xf} * x_t + W_{hf} * H_{t-1} + W_{cf} * C_{t-1} + b_f) \quad (5)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * x_t + W_{hc} * H_{t-1} + b_c) \quad (6)$$

$$o_t = \sigma(W_{xo} * x_t + W_{ho} * H_{t-1} + W_{co} * C_t + b_o) \quad (7)$$

$$H_t = o_t \circ \tanh(C_t) \quad (8)$$

式中：“ \circ ”表示 Hadamard 运算；“ $*$ ”表示卷积运算； σ 代表激活函数； x_t 为输入张量； H_t 为隐藏状态张量； C_t 为存储单元张量； W_x 和 W_h 分别是对应于输入和隐藏状态的二维卷积核； b_i 、 b_f 、 b_c 和 b_o 为偏差项。卷积长短时记忆网络使用卷积操作替代 FC-LSTM 中的前馈神经网络操作，通过在输入到状态转换和状态到状态转换中都具有卷积结构来捕获时空，从而扩展了 LSTM，对于时序图像可以进行更好的时序处理。

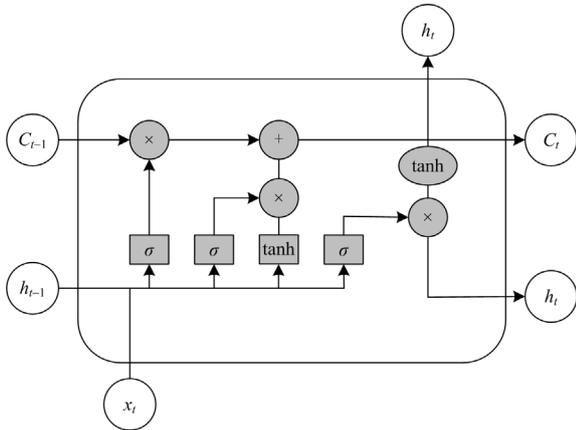


图 4 ConvLSTM 内部结构图

Fig. 4 Internal structure of ConvLSTM

1.4 模型结构

如图 5 所示，提出的模型是由 4 个部分组成，分别是鉴别器(D)、一号编码器(Enc1)、二号编码器(Enc2)和解码器(Dec)。

第一个子网络是一个蝴蝶结自动编码器网络，包含一号编码器(Enc1)和解码器(Dec)，作为模型的

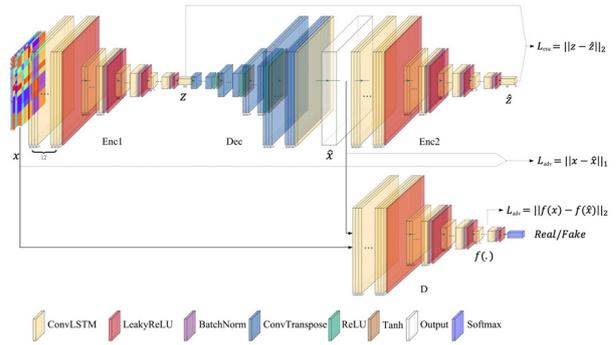


图 5 模型具体结构

Fig. 5 Specific structure of the model

生成器部分(G)。生成器分别通过使用编码器和解码器网络来学习输入数据分布并重建输入图像。子网络的形式化原理如下：发生器 G 首先读取输入图像 x ，其中 $x \in R^{w \times d}$ ，并将其转发给其编码网络 Enc1。通过使用 ConvLSTM 层，然后分别使用 BatchNorm 和 LeakyReLU 激活函数，Enc1 通过压缩 x 到一个向量 z 来缩小 x ，其中 $z \in R$ 。 z 也被称为生成器的瓶颈特征，并假设它是包含 x 最小维数的最佳表示。生成器网络的解码器部分 Dec 采用 DCGAN 生成器的架构，使用卷积转置层、ReLU 激活函数和 BatchNorm 标准化以及末尾的 tanh 层。该方法将矢量 z 放大，将图像 x 重建为 \hat{x} 。因此， x 经由第一个编码器得到 $z = \text{Enc1}(x)$ ， z 再通过解码器网络得到 $\hat{x} = \text{Dec}(z)$ 。

第二个子网络是二号编码器(Enc2)，它是用来压缩由生成器 G 重构的图像 \hat{x} 。它具有与 Enc1 相同的结构细节。Enc2 缩小图像 \hat{x} ，从而找到相应的特征 $\hat{z} = \text{Enc}(\hat{x})$ 。为了一致比较，向量 \hat{z} 的维数与 z 的维数相同。该子网络是所提出方法的独特部分之一。与以往基于自动编码器的方法不同，这种方法通过瓶颈特征来实现潜在向量的最小化，并学习了如何使用最小距离实现特征表示。在推理异常阶段中，由于学习的数据样本都是正常样本，在经历过编码器-解码器-编码器网络后获得的潜在向量和第一次经历编码器得到的潜在向量差距并不太大，但由于模型网络是在正常样本下进行训练的，异常样本通过两次编码得到的差距就比较大，因此，当两次编码得到的潜在向量差距大于一定阈值时，即可判定数据为异常。

第三个子网络是鉴别器网络 D，其目标是将输入 x 和输出 \hat{x} 分别分类为真或假。在生成对抗网络中，鉴别器有着非常重要的地位。正是因为鉴别器网络和生成器网络不断地对抗训练，最后生成器网络才能达到纳什平衡，同时获得最好的参数来模拟

数据的原始分布。假如鉴别器不够稳固或者结构不稳定, 可能导致整个生成对抗网络的失效。该子网络是 DCGAN^[26]中引入的标准鉴别器网络。

其中一号编码器的具体结构, 使用 3 层卷积长短期记忆网络提取样本在时序与空间上的特征, 一号编码器通过包含卷积长短期记忆层和 BatchNorm 层以及 LeakyReLU 激活函数的读取输入 x , 并输出 x 的潜在特征 z , 这也称为瓶颈特征, 它是输入 x 的唯一表示。与一号编码器对称, 解码器网络将潜在特征 z 向上采样, 直到与输入图像维相同, 并重构输出, 表示为 \hat{x} 。二号编码器和鉴别器采用与一号编码器相同的结构, 但各自参数在训练过程中是独立学习的。一号编码器和解码器组成一个广义上的生成器, 这个生成器与鉴别器组成一个生成对抗网络 GAN。

2 模型训练

假设当异常图像正向传递到网络 G 中, 即使 Enc1 设法将输入 X 映射到潜在向量 z , Dec 也无法重建异常, 这是因为网络在训练过程中仅以正常样本为模型, 其参数化不适合生成异常样本。漏掉异常的输出 \hat{x} 可能导致编码器网络 Enc2 将 \hat{x} 映射到同样错过异常特征表示的向量 \hat{z} , 从而导致 z 和 \hat{z} 之间的差异。当输入图像 x 在潜在向量空间中存在这种差异时, 该模型将 x 分类为异常图像。为了验证这一假设, 通过组合三个损失函数来构造目标函数, 每一个损失函数都对单个子网络进行优化。

为了在训练过程中最大限度地提高正常图像 x 的重建能力, 本文利用了文献[15]中提出的对抗性损失。等式(9)中这种损失确保网络 G 尽可能真实地重建正常图像 \hat{x} 到 x , 而鉴别器网络 D 对真实和生成的样本进行分类。这里的任务是最小化生成器 G 、最大化鉴别器 D 从而实现 $\min_G \max_D L_{adv}$, 其中 L_{adv} 可表示为

$$L_{adv} = E_{x \sim p_x} [\log D(x)] + E_{x \sim p_x} [\log(1 - D(\hat{x}))] \quad (9)$$

本文定义的对抗性损失函数迫使模型生成真实的样本, 但并不保证提取到输入的上下文信息。为了明确地学习这些上下文信息以充分捕捉输入数据的分布, 因此在输入 x 和重构输出 \hat{x} 之间应该使用 L_1 损失。使用 L_1 比 L_2 产生更少的模糊结果, 鲁棒性强, 抗噪声能力较强, 其定义为

$$L_{con} = E_{x \sim p_x} \|x - \hat{x}\|_1 \quad (10)$$

有了上面定义的对抗损失和上下文损失, 该模型能够生成真实的与上下文相似的图像。除了这些目标之外, 最主要的目标是重建输入 x 和生成的样

本 \hat{x} 要尽可能相似。因此使用鉴别器 D 的最终卷积层, 并提取 x 和 \hat{x} 的特征来重建它们的潜在表示, 使得 $z = f(x)$ 和 $\hat{z} = f(\hat{x})$ 。潜在的代表性损失变成:

$$L_{enc} = E_{x \sim p_x} \|z - \hat{z}\|_2 \quad (11)$$

最后, 总训练目标成为上述损失的加权和。

$$L = \omega_{adv} L_{adv} + \omega_{con} L_{con} + \omega_{enc} L_{enc} \quad (12)$$

式中: ω 为调整总体目标函数中单个损失分量优势的加权参数。

为了在测试和后续训练过程中检测出异常, 采用了文献[17]中提出的异常评分。对于给定的测试图像 \hat{x} , 其异常分数变为

$$A(x) = \lambda R(\hat{x}) + (1 - \lambda)L(\hat{x}) \quad (13)$$

式中: $R(\hat{x})$ 是根据等式(10)测量输入图像和生成图像之间上下文相似性的重建分数; $L(\hat{x})$ 表示根据等式(11)测量输入图像和生成图像之间差异的潜在表示分数; λ 为控制得分函数相对重要性的加权参数。

基于式(13), 计算测试集中每个测试样本 \hat{x} 的异常分数, 并表示为异常分数 A , 同时还将特征标度应用于 A , 在[0,1]概率范围内对异常分数进行标度。因此, 单个测试样本 \hat{x} 的更新异常分数变为

$$\hat{A}(\hat{x}) = \frac{A(\hat{x}) - \min(A)}{\max(A) - \min(A)} \quad (14)$$

选择不同的阈值, 计算对应的召回率 R 和精确度 P 。均衡分数 $F1$ 的计算式为

$$F1 = \frac{2RP}{R + P} \quad (15)$$

这里, 选择均衡分数最大的阈值作为测试数据集使用的阈值 φ 。

计算异常分数 $A(x)$ 和缩放后的 $\hat{A}(\hat{x})$, 将 $\hat{A}(\hat{x}) \geq \varphi$ 的数据样本判为故障样本, $\hat{A}(\hat{x}) < \varphi$ 的数据则判为健康样本。

3 实验

3.1 对比实验

实验选择孤立森林(Isolation Forest, IForest)^[27]、局部离群因子检测方法(Local Outlier Factor, LOF)^[28]、长短时神经网络框架和文献[18]提出的模型 GANomaly 作为对比实验。局部离群因子检测方法是一种无监督的离群检测方法, 是基于密度的离群点检测方法中一个比较有代表性的算法。该算法会给数据集中的每个点计算一个离群因子 LOF, 通过判断 LOF 是否接近于 1 来判定是否是离群因子。若 LOF 远大于 1, 则认为是离群因子, 接近于 1, 则是正常点。孤立森林是一个基于整体的快速离群

点检测方法, 具有线性时间复杂度和高精度, 是符合大数据处理要求的最高水平算法。孤立森林适用于连续数据的异常检测, 与其他异常检测算法通过距离、密度等量化指标来刻画样本间的疏离程度不同, 孤立森林算法通过对样本点的孤立来检测异常值。具体来说, 该算法利用一种名为孤立树的二叉搜索树结构来孤立样本。由于异常值的数量较少且与大部分样本的疏离性, 因此, 异常值会被更早地孤立出来, 即异常值会距离孤立树的根节点更近, 而正常值则会距离根节点有更远的距离。实验中局部离群因子检测方法和孤立森林使用 skleran^[29]库中的代码实现。

3.2 数据集

光伏逆变器数据采用宁夏某光伏公司 5 个相同规模电站的实时逆变器运维数据, 传感器传来的数据有 A、B、C 三相电压, A、B、C 三相电流, ab、bc、ac 线电压, 逆变器转换效率, 逆变器功率因数以及逆变器的机箱温度等维度。一天从早 8:00 到晚上 6:00 平均每 10 min 获取一组数据, 平均每个逆变器每小时生成 6 组数据。考虑到故障检测的时效性, 将每个逆变器每小时的 6 组数据看作 1 个序列, 获取光伏电站 7 月 21 日至 8 月 1 日共 12 天的数据, 共 18 000 条数据, 3 000 个序列。数据预处理后, 训练集数据 14 400 条, 共 2 400 个序列, 测试集数据 3 600 条, 共 600 个序列, 测试集中的故障数据有 123 条, 18 个序列。

3.3 实验设置

实验在 TensorFlow2.2 上实现, 通过 Adam 优化器进行优化, 初始学习率 $l_r = 2e^{-3}$, 动量 $\beta_1 = 0.5$ 、 $\beta_2 = 0.999$ 。L 的加权参数选择为 $\omega_{adv} = \omega_{con} = \omega_{enc} = 1$, 式(13)中得分函数的加权参数 λ 根据经验选择为 0.9。卷积长短期网络的隐含层设为 $h=250$, 训练的轮数根据经验设为 2 000, 当模型的性能开始下降时, 开始保存网络的参数, 因为这种性能下降是过度拟合的迹象。

3.4 实验结果对比

该模型的性能通过受试者操作特性曲线 (Receiver Operating Characteristic, ROC) 的曲线下面积 (Area Under ROC Curve, AUC) 进行评估, AUC 值越大则表示异常检测模型的准确率越高。以及精确率 (Precision, P), 代表检测是异常实际也是异常的样本数, 占检测是异常的总数比例, P 值越大, 表示异常检测性能越好。同时还有召回率 (Recall, R), 代表检测是异常实际也是异常的样本数, 占实际总异

常数的比例, R 值越大, 表示异常检测性能越好。P 和 R 的加权调和平均是 F1 值, F1 值越大, 表示异常检测性能越好。

光伏逆变器出现故障时通常会产生一些其他损失, 因此在故障检测中, 对于故障数据的召回率 R 更需要加大关注力度。在实验中, 除了对比了各个方法的召回率 R 和精确度 P, 还使用均衡分数 F1 做了综合的评价。表 1 是各种方法得出的实验结果。

表 1 数据集上的实验结果

模型	AUC	P	R	F1
IForest	—	0.171 5	0.358	0.232
LOF	—	0.172 4	0.041	0.066
GANomaly	0.611	0.848	0.228	0.359
LSTM	0.838	0.850	0.548	0.667
ConvLSTM	0.912	0.909	0.625	0.741

局部离群因子检测方法 (LOF) 是基于密度的离群点检测方法, 但由于样本是多维数据, 在高维空间中很难聚合数据, 从表 1 可以看出局部离群因子检测方法的性能并不是很好。孤立森林 (IForest) 不适用于特别高维的数据, 由于每次切数据空间都是随机选取一个维度, 建完树后仍然有大量的维度信息没有被使用, 从表 1 中也可看到检测效果一般。同时孤立森林还会因为异常数据太少而受到数据不均衡的影响。GANomaly 模型在光伏逆变器数据集上的表现是也不是很好, 精确度可达 0.848, 但是召回率只有 0.228, 这是因为光伏逆变器数据是时序数据, 而卷积神经网络更擅长处理图像数据, 即使改变了卷积核的大小, 也不能很好地提取时序数据中的上下文信息, 因此 GANomaly 的实验结果不是最好。在所有方法中, 本文提出的卷积长短时记忆神经网络表现最佳, 长短时神经记忆网络排在第二位, 因为光伏逆变器的数据集是时序数据, 而长短时神经网络擅于提取数据长时间跨度的上下文信息, 卷积长短时记忆神经网络在此基础上还能提取空间信息, 即各个属性维度之间的信息, 因此, 本文提出的模型对于异常检测精确度可达 0.909, 召回率可达 0.625, 对异常检测效果最好。

从图 6 可以看出, 相比三种深度学习模型的感受性曲线, 本文提出的模型感受性曲线是最为光滑和饱满的, 其曲线下的面积 (AUC) 也是最大的, 由此可见, 与表 1 呈现的结果相同, 本文提出的模型异常检测准确率最高。

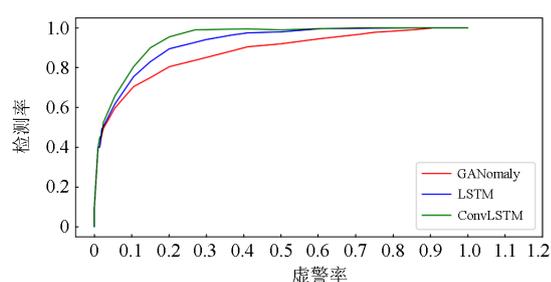


图 6 感受性曲线

Fig. 6 Receiver operating characteristic

4 结论

本文设计了一种基于生成对抗网络的异常检测与定位框架, 并将其与时间序列的成像相结合。本模型在训练时不需要使用故障数据, 同时可以通过卷积长短时神经网络分析多个变量之间的相关性。通过在宁夏某光伏公司逆变器数据集上的实验, 验证了该方法对异常检测任务的有效性。在后续的工作中, 会对如何改进设计网络结构做进一步的思考, 从而提高此模型的精确度和召回率。

参考文献

- [1] RIFKIN J. The third industrial revolution: how lateral power is transforming energy, the economy, and the world[M]. New York, USA: Palgrave MacMillan, 2011.
- [2] 朱大朋, 苏建徽, 汪海宁, 等. 光伏发电双分裂变压器分布电容对逆变器直流电压的影响[J]. 电力系统自动化, 2020, 44(14): 141-147.
ZHU Dapeng, SU Jianhui, WANG Haining, et al. Influence of distributed capacitance of photovoltaic double-split transformer on DC voltage of inverter[J]. Automation of Electric Power Systems, 2020, 44(14): 141-147.
- [3] 车泉辉, 吴耀武, 祝志刚, 等. 基于碳交易的含大规模光伏发电系统复合储能优化调度[J]. 电力系统自动化, 2019, 43(3): 76-82.
CHE Quanhui, WU Yaowu, ZHU Zhigang, et al. Carbon trading based optimal scheduling of hybrid energy storage system in power systems with large-scale photovoltaic power generation[J]. Automation of Electric Power Systems, 2019, 43(3): 76-82.
- [4] 李永刚, 严风, 周一辰. 基于降阶模型的光伏发电系统振荡模式分析[J]. 电测与仪表, 2020, 57(13): 61-68.
LI Yonggang, YAN Feng, ZHOU Yichen. Analysis of oscillation modes based on reduced model of photovoltaic power generation system[J]. Electrical Measurement & Instrumentation, 2020, 57(13): 61-68.
- [5] 时珉, 尹瑞, 胡傲宇, 等. 基于滑动标准差计算的光伏阵列异常数据清洗办法[J]. 电力系统保护与控制, 2020, 48(6): 108-114.
SHI Min, YIN Rui, HU Aoyu, et al. A novel photovoltaic array outlier cleaning algorithm based on moving standard deviation[J]. Power System Protection and Control, 2020, 48(6): 108-114.
- [6] 张博, 唐巍, 蔡永翔, 等. 基于一致性算法的户用光伏逆变器和储能分布式控制策略[J]. 电力系统自动化, 2020, 44(2): 85-93.
ZHANG Bo, TANG Wei, CAI Yongxiang, et al. Distributed control strategy of residential photovoltaic inverter and energy storage based on consensus algorithm[J]. Automation of Electric Power Systems, 2020, 44(2): 85-93.
- [7] 周宇, 胡卫丰, 胥峥, 等. 基于扰动观测器的光伏逆变器鲁棒分数阶 PID 控制[J]. 电测与仪表, 2020, 57(11): 108-114.
ZHOU Yu, HU Weifeng, XU Zheng, et al. Perturbation observer based robust fractional-order PID control for PV inverters[J]. Electrical Measurement & Instrumentation, 2020, 57(11): 108-114.
- [8] 胡子珩, 张华赢, 李艳, 等. 基于 H_∞ 鲁棒控制的多功能光伏逆变器[J]. 电测与仪表, 2020, 57(11): 146-152.
HU Ziheng, ZHANG Huaying, LI Yan, et al. Multifunctional photovoltaic inverter based on H_∞ robust control[J]. Electrical Measurement & Instrumentation, 2020, 57(11): 146-152.
- [9] 周京华, 刘劲东, 陈亚爱, 等. 大功率光伏逆变器的低电压穿越控制[J]. 电网技术, 2013, 37(7): 1799-1807.
ZHOU Jinghua, LIU Jindong, CHEN Ya'ai, et al. Low voltage ride through control of high power photovoltaic inverter[J]. Power System Technology, 2013, 37(7): 1799-1807.
- [10] 陶顺, 姚黎婷, 廖坤玉, 等. 光伏逆变器直流电压扰动引起的间谐波电流解析模型[J]. 电网技术, 2018, 42(3): 878-885.
TAO Shun, YAO Liting, LIAO Kunyu, et al. Analytical model of interharmonic current caused by DC voltage disturbance of photovoltaic inverter[J]. Power System Technology, 2018, 42(3): 878-885.
- [11] THUDUMU S, BRANCH P, JIN J, et al. A comprehensive survey of anomaly detection techniques for high dimensional big data[J]. Big Data, 2020, 42(7): 112-132.
- [12] 杨剑锋, 秦钟, 庞小龙, 等. 基于深度学习网络的输电线路异物入侵监测和识别方法[J]. 电力系统保护与控制, 2021, 49(4): 37-44.

YANG Jianfeng, QIN Zhong, PANG Xiaolong, et al. Foreign body intrusion monitoring and recognition method based on Dense-YOLOv3 deep learning network[J]. Power System Protection and Control, 2021, 49(4): 37-44.

[13] 顾晓东, 唐丹宏, 黄晓华. 基于深度学习的电网巡检图像缺陷检测与识别[J]. 电力系统保护与控制, 2021, 49(5): 91-97.

GU Xiaodong, TANG Danhong, HUANG Xiaohua. Deep learning-based defect detection and recognition of a power grid inspection image[J]. Power System Protection and Control, 2021, 49(5): 91-97.

[14] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C] // Advances in Neural Information Processing Systems, December 7-14, 2014, New York, USA: 2672-2680.

[15] KIRAN B, DILIP T, RANJITH P. An overview of deep learning based methods for unsupervised and semi-supervised anomaly detection in videos[J]. Journal of Imaging, 2018, 4(2): 36-46.

[16] CHALAPATHY R, CHAWLA S. Deep learning for anomaly detection: a survey[D]. Sydney: University of Sydney, 2019.

[17] SCHLEGL T, SEEBCK P, WALDSTEIN S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery[C] // International Conference on Information Processing in Medical Imaging, Springer, Cham, June 25-30, 2017, NC, USA: 146-157.

[18] SAMET A, ATAPOUR-ABARGHOUEI A, BRECKON T P. Ganomaly: semisupervised anomaly detection via adversarial training[C] // Asian Conference on Computer Vision, December 2-6, 2018, Perth, Australia: 622-637.

[19] YI S, JU J, YOON M K, et al. Grouped convolutional neural networks for multivariate time series[J]. arXiv preprint arXiv:1703.09938, 2017.

[20] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[M]. MIT Press, 2015.

[21] WANG Z, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks[C] // Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence, January 25-26, 2015, Texas, USA: 40-46.

[22] HAMILTON J D. A new approach to the economic analysis of nonstationary time series and the business cycle[J]. Econometrica, 1989, 57(2): 357-384.

[23] ZHANG C, SONG D, CHEN Y, et al. A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33: 1409-1416.

[24] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[25] GERS F A, SCHMIDHUBER J. Recurrent nets that time and count[C] // Proceedings of the IEEE INNS ENNS International Joint Conference on Neural Networks, IJCNN 2000, Neural Computing: New Challenges and Perspectives for the New Millennium, July 24-27, 2000, Como, Italy: 189-194.

[26] SALIMANS T, GOODFELLOW I, ZAREMBA W, et al. Improved techniques for training GANs[C] // Advances in Neural Information Processing Systems, December 5-10, 2016, Barcelona, Spain: 2234-2242.

[27] LIU F, TING K M, ZHOU Z H. Isolation forest[C] // Proceedings of the 2008 IEEE International Conference on Data Mining, December 15-19, 2008, Pisa, Italy: 413-422.

[28] BREUNIG M M, KRIEGLER H P, NG R T, et al. LOF: identifying density-based local outliers[C] // ACM Sigmod International Conference on Management of Data, May 15-18, 2000, Texas, USA: 93-104.

[29] Scikit-learn[EB/OL].[2019-06-20].<https://scikit-learn.org/stable/index.html>.

收稿日期: 2021-03-16; 修回日期: 2021-05-26

作者简介:
 周嘉琪(1995—), 女, 硕士研究生, 研究方向为数据挖掘; E-mail: 443847935@qq.com
 毕利(1968—), 女, 通信作者, 硕士, 教授, 硕士生导师, 研究方向为数据挖掘及智能信息系统集成。E-mail: billy1968@163.com

(编辑 许威)