



研究与开发

基于CVAE-ReS-GRU算法的电网 调控系统异常检测方法研究

赵瑞锋¹, 仲卫², 卢建刚¹, 郭文鑫¹, 林玥廷¹, 戴月¹

(1. 广东电网有限责任公司电力调度控制中心, 广东 广州 510062;

2. 国电南瑞南京控制系统有限公司, 江苏 南京 211106)

摘要: 针对现有电网调控系统异常检测方法在复杂时序数据处理及特征提取方面的局限, 提出了一种基于条件变分自编码器-残差结构-门控循环单元 (conditional variational autoencoder-residual structure-gated recurrent unit, CVAE-ReS-GRU) 的电网调控系统异常检测方法。首先, 基于电网调控系统的层级化运行架构, 对系统内多源异构数据进行分类与结构化整理。其次, 采用支持向量机 (support vector machine, SVM) 对缺失数据进行智能填补, 并通过归一化消除原始数据的量纲差异。然后, 引入时间监督机制以增强VAE对电网时序特征的建模能力; 将残差结构嵌入GRU网络, 以提升对复杂电力序列的拟合精度; 以改进后的GRU网络代替CVAE中传统的BP神经网络结构, 从而加速特征提取。最后, 设计动态阈值判定机制, 自适应调整阈值评估重构误差, 实现对异常数据的精准识别。仿真实验表明, 所提方法在异常数据识别准确率、检测效率等指标上均展现出显著优势, 为提升电网调度智能化水平、保障电力系统安全稳定运行提供了新的技术路径与理论支撑。

关键词: 电网调控系统; 异常检测; 门控循环单元; 条件变分自编码器; 残差结构

中图分类号: TM73

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2026040

Research on anomaly detection method of power grid control system based on CVE-ReS-GRU algorithm

Zhao Ruifeng¹, Zhong Wei², Lu Jiangan¹, Guo Wenxin¹, Lin Yueting¹, Dai Yue¹

1. Electric Power Dispatching Control Center of Guangdong Power Grid Co., Ltd., Guangzhou 510062, China

2. NARI-TECH Nanjing Control Systems Co., Ltd., Nanjing 211106, China

Abstract: In view of the limitations of existing anomaly detection methods for power grid regulation systems in handling complex time-series data and feature extraction, an anomaly detection method for power grid regulation systems based on conditional variational autoencoder-residual structure-gated recurrent unit (CVAE-ReS-GRU) was proposed. Firstly, based on the hierarchical operation architecture of the power grid regulation system, systematic classi-

收稿日期: 2025-09-09; 修回日期: 2025-12-17

基金项目: 中国南方电网公司科技项目 (No.036000KC23110012)

Foundation Item: The Science and Technology Project of China Southern Power Grid Company (No.036000KC23110012)

fication and structured organization of multi-source heterogeneous data within the system were carried out. Secondly, the support vector machine (SVM) was employed to intelligently fill in missing data, and normalization was used to eliminate the dimensional differences of the original data. Then, a time supervision mechanism was introduced to improve the variational autoencoder (VAE), enhancing its ability to model the time-series characteristics of the power grid. The residual structure was embedded into the GRU network to improve the fitting accuracy for complex power time-series. The improved GRU network replaces the traditional BP neural network structure in CVAE, accelerating feature extraction. Finally, a dynamic threshold determination mechanism was designed to adaptively adjust the threshold for evaluating reconstruction errors, enabling accurate identification of abnormal data. Simulation results demonstrate that the proposed method exhibits significant advantages in terms of abnormal data recognition accuracy and detection efficiency compared with traditional methods, providing a new technical approach and theoretical support for enhancing the intelligent level of power grid dispatching and ensuring the safe and stable operation of the power system.

Key words: power grid regulation and control system, anomaly detection, GRU, CVAE, residual structure

0 引言

电网调度控制系统是保障电网运行与调度管理的重要基础,其运行状态直接影响电网的稳定与安全^[1]。当前,随着能源结构转型的持续推进,大量分布式电源及其具有随机性、波动性的负荷广泛接入电网,智能调控系统所面临的环境日益复杂^[2]。然而,数据质量问题日益凸显,已成为制约智能电网调控系统高效运行的关键风险因素。干扰源的增加、数据采集过程中的误差累积,以及网络传输中的延迟与丢包等现象,均可能导致数据质量下降,甚至引发系统异常。针对这一问题,实时检测并准确识别调控系统中的异常数据,成为保障系统稳定、安全运行的关键环节之一。

目前,国内外在配电网异常数据检测领域已经取得诸多研究成果。传统的异常数据检测方法主要集中在统计学方法、状态评估方法以及各种人工智能算法,如K-means聚类算法^[3]、支持向量机(support vector machine, SVM)^[4]、神经网络^[5]和长短期记忆(long short-term memory, LSTM)网络^[6]等,这些方法已在异常数据检测中得到广泛应用。文献[7]提出采用孤立森林算法对电力大数据进行异常监测;文献[8]提出了一种

结合改进的密度聚类算法和改进的单类支持向量机算法的智能变电站异常数据流检测方法;文献[9]构建了基于极端梯度提升(extreme gradient boosting, XGBoost)的电网过流异常检测模型;文献[10]提出基于粗糙熵加权密度的智能电网调控系统运行异常数据检测方法。

目前,针对电网调控系统运行数据异常识别的研究相对较少,尤其是在智能电网调控系统这一复杂场景中,现有算法的应用存在明显局限。智能电网调控系统因其复杂的体系结构和多样化的功能模块,涉及大量服务区域和硬件设备,且不同类型数据的评价标准差异显著,涵盖硬件设备性能指标、软件进程运行状态、网络传输质量以及业务负载等维度,这进一步加大了异常检测的难度^[11]。

针对上述问题,本文提出基于条件变分自编码器(conditional variational autoencoder, CVAE)与残差结构-门控循环单元(residual structure-gated recurrent unit, ReS-GRU)相结合的电网调控系统异常检测方法。该方法通过在VAE模型中引入时间监督机制,增强VAE模型对时序特征的关注度;利用残差结构优化GRU网络,并用改进的GRU网络替换CVAE中的BP神经网络层,以加强CVAE模型对数据的特征提取能力,进而



提升电网调控系统异常检测的效果。实验对比分析表明，本文所提方法在效果和性能上均具有显著优势。

1 电网调控系统架构

1.1 电网调控系统框架

电网调控系统由数据采集层、在线监视管理层、高级应用管理层和可视化展示层4个主要部分组成，其框架如图1所示。

(1) 数据采集层负责从主站端、调度数据网和变电站等多源终端采集原始运行数据，并进行初步整合与预处理，保障数据的准确性、一致性与时效性，为后续分析提供可靠基础。

(2) 在线监视管理层承担对系统各环节运行状态的实时监控与初步数据分析任务，具备异常趋势识别与预警能力，可为运维人员提供实时风险提示与辅助决策支持。

(3) 高级应用管理层是提升系统智能化水平的核心模块，主要功能包括运行健康度评估、风险预测与调控，以及多源信息融合下的异常智能

检测。该层通常融合人工智能与大数据分析技术，能够从大规模运行数据中自动识别潜在问题，辅助实现精准调控。

(4) 可视化展示层则对分析结果进行图形化与交互式呈现，直观展示电网运行状态、健康指标与异常检测结果，帮助运维人员快速掌握系统全貌，提升故障响应效率与调控决策能力。

该分层架构覆盖了从数据采集、实时监控到智能分析与结果呈现的全过程，构建了高效、智能、可视的智能电网调控系统运行管理体系，为复杂电网环境下的综合管控提供了坚实的技术支撑。

1.2 电网调控系统异常数据类型

电网调控系统的运行数据是保障电网安全稳定运行与高效调控的基础。由于系统结构复杂、功能多样，其运行数据呈现出种类繁多、结构异构的特点。根据数据的来源和功能属性，可将这些数据划分为3大类：硬件设备状态数据、业务进程状态数据与交互状态数据。电网调控系统各类数据的属性分配见表1。

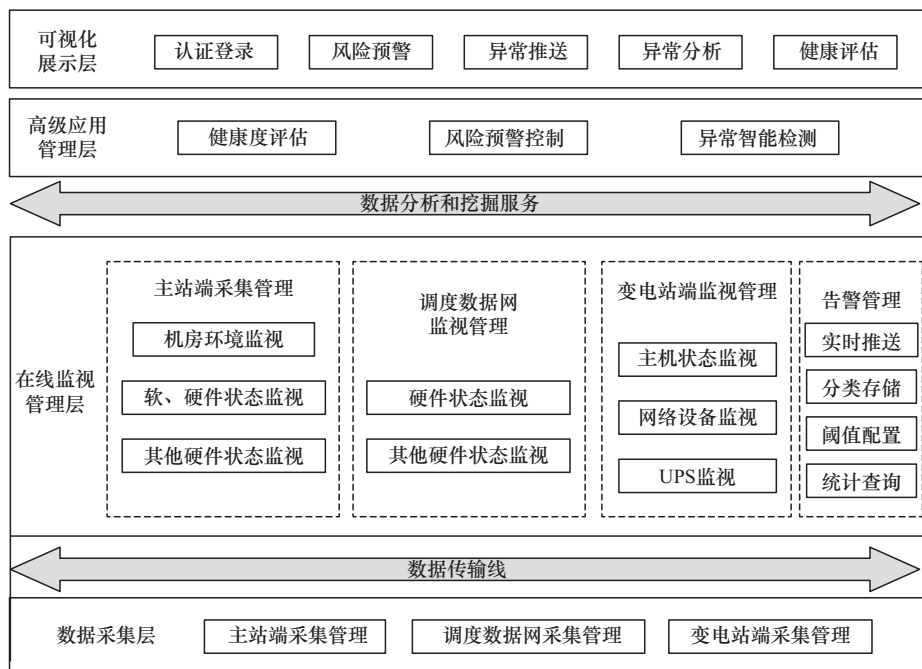


图1 电网调控系统框架

表1 电网调控系统各类数据的属性分配

| 数据类型 | 参数 |
|------|--|
| 硬件设备 | A ₁ : CPU利用率; A ₂ : 内存利用率; A ₃ : 硬盘利用率; A ₄ : 网络连接速率 |
| 业务进程 | B ₁ : 进程占用内存比; B ₂ : 线程个数; B ₃ : 工作时间; B ₄ : 网络连接个数 |
| 交互状态 | C ₁ : CPS指标; C ₂ : 误码率; C ₃ : 越限; C ₄ : 跳变 |

(1) 硬件设备状态数据主要涵盖服务器、存储设备、通信终端等物理硬件的性能指标与运行状态,如CPU使用率、内存占用、设备在线状态、温度、电源状态等,用于反映系统底层设施的稳定性与可靠性。

(2) 业务进程状态数据描述系统内部各类业务逻辑与软件模块的运行情况,包括调度程序执行状态、数据处理流程进度、控制指令响应情况等,能够直观体现调控系统的业务响应能力和任务执行效率。

(3) 交互状态数据反映系统内部模块之间、其与外部通信网络之间的数据交换行为,涵盖报文传输状态、链路延迟、数据包丢失率等,是评估系统通信链路稳定性和实时性的关键依据。

1.3 电网调控系统运行状态分析

电网调控系统面临庞大的数据流,其数据处理能力在负载持续增加时会逐步下降。系统稳定性拐点模型如图2所示。在进行异常检测时,可将采集的数据映射为“数据健康度”指标,并结合不同阶段的权重参数,综合评估系统的运行健康水平。其中,数据健康度 α 被定义为检测出的异常数据数量 x 与该阶段总数据量(x_1 或 x_2)之间的比值。其中, x_1 对应轻度风险阶段的总数据量, x_2 表示系统进入性能拐点阶段的总数据量;一旦系统进入崩溃区域,健康度 α 可直接设为100%,表明系统完全异常。

将系统运行状态分为3个压力区:(1)轻压力区。系统实时数据发生一定幅度变化时,对系统性能影响较弱,系统的稳定性系数维持在1。(2)拐点区。数据量加大,系统运行状态进入拐

点区,由于系统参数变量仍小于阈值,因此系统在此阶段仍可以稳定运行。(3)崩溃区。数据量达到系统处理极限,系统崩溃,稳定性为0,系统不可用。




图2 系统稳定性拐点模型

2 基于CVAE-ReS-GRU的异常检测模型

2.1 数据预处理

考虑调控信号间存在较强相关性,本文采用SVR进行数据填补,选取邻近时刻多维特征作为输入,构建非线性回归模型,用于预测缺失点数值。SVR模型使用径向基函数(radial basis function, RBF)建模特征之间复杂关系,优于传统线性插值方法,能更准确地恢复短时异常丢包或采样缺失点,提高数据完整性和建模鲁棒性。

SVR通过求解优化问题得到支持向量和模型参数。

$$\min_{w, b, \zeta_i, \zeta_i^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\zeta_i + \zeta_i^*) \quad (1)$$

$$\begin{aligned} \text{s.t.} \quad & y_i - f(\mathbf{x}_i) \leq \varepsilon + \zeta_i \\ & f(\mathbf{x}_i) - y_i \leq \varepsilon + \zeta_i^* \\ & 0 \leq \zeta_i, \zeta_i^*, i=1, 2, \dots, N \end{aligned} \quad (2)$$

其中, ε 为容忍误差; ζ_i, ζ_i^* 为松弛变量; C 为惩罚参数; \mathbf{x}_i 为第 i 个样本的输入特征向量; y_i 为第 i 个样本的目标输出值; w, b 为优化变量; N 为样本总量。

通过求解上述对偶问题,得到支持向量和模型参数,预测函数为:



$$f(\mathbf{x}) = \sum_{i=1}^N (\alpha_i + \alpha_i^*) \mathbf{K}(\mathbf{x}_i, \mathbf{x}) + b \quad (3)$$

其中, α_i 、 α_i^* 为拉格朗日乘子, $\mathbf{K}(\mathbf{x}_i, \mathbf{x}) = \phi(\mathbf{x}_i)^\top \phi(\mathbf{x})$ 为核函数。

通过函数输出, 估计缺失值, 实现数据填补。

为解决本文多类型数据对模型训练的影响, 对数据进行归一化处理, 进一步提高算法的收敛速度和精度。本文采用标准差归一化, 归一化后的样本数据为:

$$x' = \frac{x - \mu}{\sigma} \quad (4)$$

其中, x 为样本数据; μ 为样本数据的均值; σ 为样本数据的标准差。

2.2 条件变分自编码器

变分自编码器 (VAE) 是一种无监督神经网络训练的生成模型, 由编码器和解码器组成。该模型将输入数据压缩至潜在空间, 再从潜在空间重构输入数据, 以此进行数据的特征学习^[12]。其具有良好的生成能力和适应性, 特别适用于处理高维、复杂的数据。通过对隐变量空间的正态化约束, VAE能够防止过拟合, 并且能够生成多样化的样本, 在无监督学习、异常检测、图像生成、自然语言处理等领域得到了广泛的应用。

在变分自编码器中, 编码器的主要作用是将复杂的输入数据映射到一个隐变量空间, 这个过程可以由式 (5) 表示:

$$q(z|x) = \mathcal{N}(z|\mu(x), \sigma^2(x)) \quad (5)$$

其中, $q(z|x)$ 为编码器的分布函数, z 为潜在特征, x 为输入数据, $\mu(x)$ 、 $\sigma^2(x)$ 分别是隐变量的均值和方差。

解码器的作用是将隐变量空间中的数据进行重构, 生成与输入数据尽可能相似的数据。解码过程可以表示为:

$$p(x'|z) = \mathcal{N}(X|\hat{\mu}(z), \hat{\sigma}^2(z)) \quad (6)$$

其中, $p(x'|z)$ 为解码器的分布函数, x' 为重构后的

数据, $\hat{\mu}(z)$ 、 $\hat{\sigma}^2(z)$ 分别是根据隐变量 z 生成的重构数据的均值和方差。

由于潜在特征的分布是无法直接观察的, 因此在训练过程中使用变分推断, 通过最大化证据下界 (evidence lower bound, ELBO) 来逼近真实的后验分布。为了使编码器学习的分布与先验分布尽可能接近, VAE使用了KL (Kullback - Leibler) 散度来度量两者之间的差异。KL散度的数学表达式如下:

$$D_{\text{KL}} = \int q(z|x) \log \frac{q(z|x)}{p(z)} dz \quad (7)$$

VAE的总损失函数由两个部分组成: 重构误差和KL散度。重构误差衡量重构数据与原始输入数据之间的差异, 通常使用均方误差 (mean squared error, MSE) 或交叉熵来计算。最终的损失函数可以表示为:

$$L = E_{q(z|x)} [\log p(x'|z)] - D_{\text{KL}} \quad (8)$$

其中: $E_{q(z|x)} [\log p(x'|z)]$ 为重构误差。重构误差与KL散度共同作用, 保证VAE在保持数据生成能力的同时, 还能约束隐变量的分布, 使其尽可能符合标准正态分布。

在电网调控系统中, 数据通常包含时间戳信息, 对于此类时间序列数据, 合理利用时间信息不仅有助于提高数据分析精度, 还能更好地捕捉系统中潜在的动态变化和异常模式。因此, 在VAE的基础上引入条件监督信息, 构建条件变分自编码器 (conditional variational autoencoder, CVAE)。CVAE通过在生成过程中引入外部条件, 能够控制生成数据的特定特征, 并利用监督信息对生成内容进行有效的引导和调整, 从而提高生成结果的针对性和准确性。CVAE框架如图3所示。




图3 CVAE框架

CVAE 模型的整体结构与传统的 VAE 相似，但在 VAE 基础上引入了条件监督信息 (c) 来增强模型的生成能力。编码器的任务是对输入数据 (x) 和监督信息 (c) 进行联合建模，从中学习到潜在变量 (z) 的分布。在解码器部分，潜在变量 (z) 和监督信息 (c) 会被一同输入，解码器根据这些信息生成数据的重构版本，同时基于监督信息调节生成的内容。然而，监督信息并不直接参与最终的计算结果，即在模型训练和优化时，VAE 中的变化即 $q(z|x)$ 变为 $q(z|x, c)$ 、 $p(x|z)$ 变为 $p(x|z, c)$ ，但最终模型的优化求解问题与 VAE 一样。

CVAE 将样本映射到隐变量空间，使样本数据尽量满足正态分布，有效避免过拟合，适用于异常数据检测^[13]。

2.3 ReS-GRU 网络

GRU 是一种能够处理序列数据的循环神经网络，其门控机制被专门设计用于捕捉数据中的长期依赖关系^[14]。尽管 GRU 在处理时序数据上表现良好，但随着网络层数的加深，仍可能出现梯度消失和梯度爆炸等问题，导致模型训练困难。为解决这一问题，本文引入了残差结构^[15]。残差结构通过跳跃连接将输入直接传递至输出，并与经过网络层的特征进行融合，网络学习的不是完整的映射函数，而是输入与输出之间的残差（差异）。这种跳跃连接可以有效防止梯度消失，提高网络的训练效率。

残差结构的基本思想是学习残差函数 $F(x)$ ，而不是直接学习期望的映射函数 $H(x)$ ，通过将输入 x 与输出相加，网络最终的目标函数变为：

$$H(x) = F(x) + x \quad (9)$$

在残差结构优化的 GRU 网络中，每一层的输出 h_t 可以表示为：

$$h_t = \text{GRU}(x_t, h_{t-1}) + h_{t-1} \quad (10)$$

其中， $\text{GRU}(x_t, h_{t-1})$ 表示标准 GRU 单元的输出，通过引入残差连接，隐藏状态 h_t 变为原始 GRU

输出与上一时刻隐藏状态 h_{t-1} 的直接相加。

经残差结构优化后的 GRU 网络结构如图 4 所示。

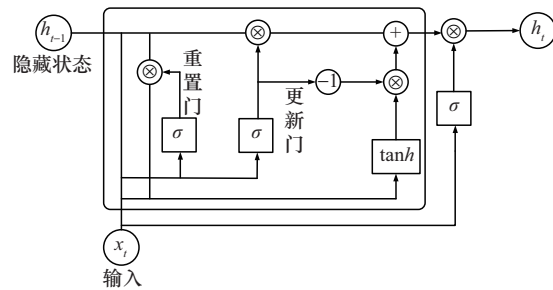


图 4 经残差结构优化后的 GRU 网络结构

2.4 检测方法

将残差结构与 GRU 网络结合，可以有效解决深层网络中的梯度消失问题，提升网络的训练效率和特征学习能力。结合 CVAE 的生成能力，优化后的残差 GRU 网络不仅能够有效捕捉复杂数据的时序特征，还能够提升数据生成和重构的质量^[16]。CVAE-ReS-GRU 模型结构如图 5 所示。




图 5 CVAE-ReS-GRU 模型结构

针对不同类型的检测数据，采用固定阈值容易造成漏检或误报，而动态阈值能够根据数据特点自适应调整判断标准，适用于多类型异常检测。本文采用的动态阈值方法基于正常样本的统计分布进行计算：

$$\lambda = \mu + k\sigma \quad (11)$$

其中， μ 为样本均值， σ 为标准差， k 为灵敏度参数。

为平衡检测数据的正常波动区间与异常突变特征，本文设定灵敏度参数 $k=1.5$ 。若 k 值过小，正常数据的小幅波动可能被判定为异常，导致“误报率”上升，后续需投入大量资源排查“假异常”；若 k 值过大，则只有数据发生极显著偏离时才会被识别为异常，从而遗漏“幅度较小但确



实异常”的数据。 $k=1.5$ ，既允许正常数据存在一定范围的自然波动，又能及时捕捉到“超出正常波动范围”的异常信号，符合多类型异常数据检测的实际需求。

基于CVAE-ReS-GRU算法的异常数据检测流程如图6所示。

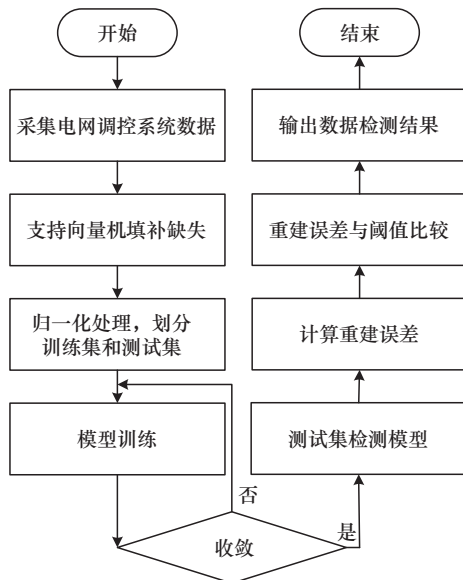


图6 基于CVAE-ReS-GRU算法的异常检测流程

步骤1 采集电网调控系统数据，并采用支持向量机填补少量缺失数据。

步骤2 将数据进行归一化处理，并将数据集划分为训练集和测试集。

步骤3 将处理后的训练集数据输入CVAE-GRU-VAE模型进行训练，当模型收敛后结束训练。

步骤4 将测试集数据输入训练好的模型，计算每个系统数据值的重建误差，并与动态阈值对比，判定数据是否异常，根据异常数据类型判断系统状态。

步骤5 根据判定结果输出数据检测结果。

3 算例分析

为验证所提方法的可行性与有效性，基于某

地调度中心SCADA数据库中的电网历史运行数据，搭建了电网调控系统闭环仿真测试平台，如图7所示。该平台由3台双网工作站构成，实验中使用的硬件配置如下：智能电网调度控制系统为D5000（基础平台版本为V3.0）、金仓数据库管理系统V7.0、凝思安全操作系统V4.2。

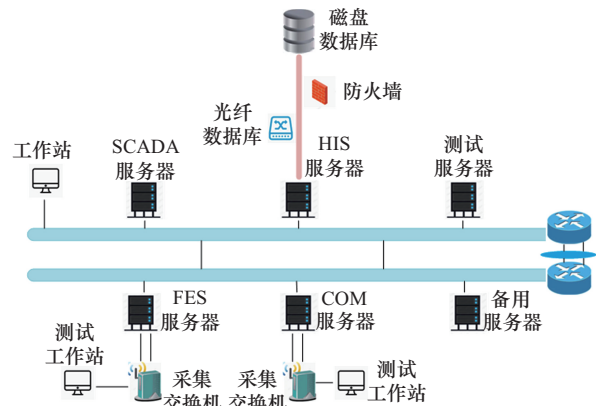


图7 电网调控系统闭环仿真测试平台

在系统仿真测试中，输入的历史数据覆盖736个厂站、1864条通信通道，数据规模具体包括：遥测数据点47万个、遥信状态点85万个、遥控指令5.5万项及遥调指令1800余项。系统实时处理性能需满足：遥测数据接入速率为2000点/秒，常规遥信变位处理能力达10事件/秒，携带事件顺序记录(sequence of events, SOE)的遥信变位处理能力为5事件/秒。

3.1 异常检测评估指标

为满足训练数据的完整性要求，并考虑调控信号间存在的强相关性，本文采用SVR方法对缺失数据进行填补。具体流程为：选取邻近时刻的多维特征作为输入，构建非线性回归模型，预测缺失点的数值。将填补后的样本数据进行归一化处理，并将数据集划分为训练集和测试集，输入检测模型。本文采用准确率评估电网调控系统异常检测性能，主要使用检测率(accuracy, ACC)和误报率(false positive rate, FPR)两个指标。其数学表达式如下：

$$e_{ACC} = \frac{T_n}{T_n + F_p} \times 100\% \quad (12)$$

$$e_{FPR} = \frac{F_n}{T_p + F_n} \times 100\% \quad (13)$$

其中, T_p 为检测与实际都为正常的的数据, T_n 为检测与实际都为异常的数据, F_p 为检测正常但实际异常的数据, F_n 为检测异常但实际正常的的数据。

异常检测模型的性能可通过受试者工作特征曲线 (receiver operating characteristic curve, ROC) 及其曲线下的面积 (area under the curve, AUC) 进行量化评估。AUC 作为综合性指标, 其数值越接近 1, 表明模型区分正常与异常样本的能力越强。ROC 曲线的横轴为误报率 (FPR), 即实际异常样本中被误判为正常的比例; 纵轴为真阳性率 (true positive rate, TPR), 指模型成功识别出正常样本的概率。FPR 和 TPR 的数学表达式如下:

$$F_{pr} = \frac{F_p}{F_p + T_n} \quad (14)$$

$$T_{pr} = \frac{T_p}{T_p + F_n} \quad (15)$$

3.2 仿真结果分析

在高并发环境下, 为保障电网调度系统能够快速、准确地完成异常检测, 维持电网稳定运行, 本文对系统进行了并发能力测试。其中, 用电行为模式数据参照文献[17]设置, 并发用户由 10 人逐渐增加到 100 人, 调度系统并发能力测试结果如图 8 所示。




图 8 系统并发能力测试结果

由图 8 可知, 系统响应时间随并发用户数量的增加呈正相关增长趋势。当并发用户数达到 80 时, 响应时间明显上升至 20 s, 已超过专家评估设定的响应时限。同时, CPU 平均利用率升高至 60%, 接近异常判定的阈值。当并发用户增加至 100 时, 大多数请求出现超时, 错误率显著上升, 且 CPU 利用率持续处于异常水平。因此, 调控系统的并发用户数应控制在 80 以下, 以确保系统保持最佳性能和稳定性。

异常检测率、误报率与并发用户数的关系如图 9 所示。




图 9 异常检测率、误报率与并发用户数的关系

随着并发用户数量的持续增长, 系统的误报率逐步上升, 而检测率则呈下降趋势。当并发用户数达到 80 时, 误报率上升至约 12%, 检测率下降至 82%, 接近系统性能变化的临界阈值。并发数进一步增加至 100 时, 出现大量用户请求超时, 误报率攀升至近 19%, 检测率则跌破 80%, 已低于系统可接受的最低运行标准, 反映出当前系统性能已无法支撑正常的异常检测任务。

为验证本文所提异常数据检测方法在系统总体检测方面的有效性, 随机获取硬件设备状态数据、业务进程状态数据、交互状态数据共计 1 000 个数据样本进行分析, 将数据输入 CVAE-ReS-GRU 模型进行验证, 将计算出的重建误差与动态阈值进行比较, 并根据二者的比值, 判定数据的异常性: 当重建误差超过阈值时, 系统判定该数据为



异常,认为该数据与正常运行模式存在显著偏差;如果重建误差低于阈值,则判定该数据为正常,表明系统运行状态与预期一致。采用本文所提方法的异常数据检测结果如图10所示。




图10 本文所提方法的异常数据检测结果

在模拟调控系统25天运行的过程中,本文所提出的异常数据检测方法对典型数据的每日检测结果如图11所示。实验结果表明,面向电网调控系统在长时间尺度的多类型数据,本文所提出的异常数据检测方法均能有效工作,对各类型异常数据的检测准确率均超过95%。该结果验证了所提方法在长期系统数据检测任务中具有良好的可行性和实用价值。




图11 典型数据的每日检测结果

3.3 不同算法性能对比

为了论证所提异常检测方法的性能,将其与文献[5]、文献[6]、文献[7]的算法进行对比分析,并绘制ROC曲线,如图12所示。

与其他3种模型相比,本文所提模型的ROC曲线AUC最大,表明其在区分异常与正常数据

方面具有更优的分类性能。AUC值接近0.94,进一步验证了该模型的有效性。




图12 4种不同模型的ROC曲线

当调控系统处于不同的阶段,其异常数据量也不相同。在轻压力区,电网处于稳定运行状态,异常数据通常表现为局部、孤立的波动;在拐点区,系统处于临界失稳状态,异常数据的特征明显增强;在崩溃区,电网已发生大规模失稳或解列,异常数据表现出全局性、极端化的特征。

在轻压力区,系统裕量较大,CPU使用率较低,能够处理大量的检测数据,此时系统异常检测误差对比结果如图13所示。




图13 轻压力区系统异常检测误差对比结果

在轻压力区,本文方法的预测误差控制在6%~10%,明显低于其他3种对比算法,表现出较高的检测精度。这得益于所采用的CVAE-ReS-GRU结构提升了系统状态异常识别的全面性。然而,当数据输入速率上升至60点/s后,异常检测误差普遍突破10%,显示该方法在大数据环境下的适应性仍有待提升。

拐点区是系统性能由稳态向过载转变的关键阶段，表现为CPU使用率明显升高，且伴随数据传输延迟，从而影响检测准确性。拐点区系统异常检测误差的对比结果如图14所示。




图14 拐点区系统异常检测误差对比结果

拐点区的系统压力明显高于轻压力阶段。当数据速率达到85点/s时，系统出现严重卡顿，性能迅速下降。由于算法结构较为复杂，在面对高速增长的数据时易出现系统失效。本文所提出的CVAE-ReS-GRU方法具有较强的数据处理能力，在高负载下仍能维持异常检测精度，误差未超过10%，表现出较优的系统适应性。

在调控系统各个阶段中，不同算法的异常检测结果对比见表2，评价指标包括准确率、召回率与F1值。

表2 不同算法的异常检测结果对比

| 模型 | 准确性 | 召回率 | F1值 |
|---------|-------|-------|-------|
| 本文方法 | 95.5% | 94.1% | 94.6% |
| 文献[7]算法 | 90.7% | 87.9% | 91.5% |
| 文献[6]算法 | 90.4% | 89.6% | 90.8% |
| 文献[5]算法 | 93.1% | 94.2% | 92.3% |

由表2可知，本文所提方法在各项指标中均优于对比的方法，表明本文方法在电网调控系统异常检测方面具有明显优势。

4 结束语

本文提出了一种基于CVAE-ReS-GRU的电网

调控系统异常检测方法。仿真实验结果如下。

(1) 本文基于VAE模型引入时间监督机制，增强了VAE模型对时间特征的关注度；进一步采用残差结构优化GRU网络，并将其应用于CVAE中，代替原有的BP神经网络层。这些改进有效增强了CVAE模型对数据的特征提取能力，提升了电网调控系统异常检测的性能。

(2) 将本文所提方法与文献[5]、文献[6]、文献[7]的算法进行对比。对比结果表明，本文所提方法表现出更好的准确性、更高的AUC值，具有一定的实用价值。

需要指出的是，本研究仍存在一定局限与改进空间：目前方法主要基于电网调控系统典型数据进行仿真验证，且所采用的组合算法在结构与参数方面仍有进一步优化的可能。因此，下一步工作将着重提升该方法的实用性和整体性能，推动其在实际系统中的应用。

参考文献：

[1] Ourahou M, Ayrir W, El Hassouni B, et al. Review on smart grid control and reliability in presence of renewable energies: Challenges and prospects[J]. Mathematics and Computers in Simulation, 2020, 167: 19-31.

[2] 谈林涛, 李军良, 任昺, 等. 基于RB-XGBoost算法的智能电网调度控制系统健康度评价模型[J]. 电力自动化设备, 2020, 40(2): 189-198.

Tan L T, Li J L, Ren B, et al. Health evaluation model of smart grid dispatch and control system based on RB-XGBoost algorithm[J]. Electric Power Automation Equipment, 2020, 40(2): 189-198.

[3] 常荣, 徐敏. 基于改进K-Means和DNN算法的电力数据异常检测[J]. 南京理工大学学报, 2023, 47(6): 790-796, 858.

Chang R, Xu M. Power data anomaly detection based on improved K-Means and DNN algorithm[J]. Journal of Nanjing University of Science and Technology, 2023, 47(6): 790-796, 858.

[4] 郭泽阳, 程拥军, 温家铭, 等. 基于支持向量机的光伏电站异常数据序列提取[J]. 中国测试, 2023, 49(7): 156-161.



- Guo Z Y, Cheng Y J, Wen J M, et al. Extraction of abnormal data sequence of photovoltaic power station based on support vector machine[J]. *China Measurement & Test*, 2023, 49(7): 156-161.
- [5] 杨海柱, 田馥铭, 张鹏, 等. 基于CEEMD-FE和AOA-LSSVM的短期电力负荷预测[J]. *电力系统保护与控制*, 2022, 50(13): 126-133.
- Yang H Z, Tian F M, Zhang P, et al. Short-term load forecasting based on CEEMD-FE-AOA-LSSVM[J]. *Power System Protection and Control*, 2022, 50(13): 126-133.
- [6] 陈逸枫, 张大海, 李宇欣, 等. 基于DWT-MOSMA-SVM的多目标优化短期母线负荷预测[J]. *电力建设*, 2023, 44(3): 49-55.
- Chen Y C, Zhang D H, Li Y X, et al. Multi-objective optimization based on DWT-MOSMA-SVM for short-term bus load forecasting[J]. *Electric Power Construction*, 2023, 44(3): 49-55.
- [7] 张鑫, 孙国繁, 高磊, 等. 基于机器学习的变电站故障预测方法研究[J]. *电子器件*, 2024, 47(4): 1047-1052.
- Zhang X, Sun G F, Gao L, et al. The fault prediction of converting station based on big data technology and machine learning[J]. *Chinese Journal of Electron Devices*, 2024, 47(4): 1047-1052.
- [8] 闫梦秋, 杨轶俊, 赵航. 基于改进OCSVM的智能变电站数据流异常检测方法研究[J]. *电力系统保护与控制*, 2022, 50(6): 100-106.
- Yan M Q, Yang Y J, Zhao F. A data stream anomaly detection method based on an improved OCSVM smart substation[J]. *Power System Protection and Control*, 2022, 50(6): 100-106.
- [9] 马智强, 康洁滢, 梁飞, 等. 基于XGBoost的电网过流异常检测模型[J]. *电子测量技术*, 2024, 47(21): 130-137.
- Ma Z Q, Kang J Y, Liang F, et al. XGBoost-based power grid overcurrent anomaly detection model[J]. *Electronic Measurement Technology*, 2024, 47(21): 130-137.
- [10] 田江, 吕洋, 赵奇, 等. 基于粗糙熵加权密度的电网调控系统异常检测[J]. *兵工自动化*, 2024, 43(2): 40-44, 57.
- Tian J, Lyu Y, Zhao Q, et al. Anomaly detection of power grid control system based on weighted density of rough entropy[J]. *Ordnance Industry Automation*, 2024, 43(2): 40-44, 57.
- [11] 王瑾, 裴亮. 基于深度学习的电网调控系统异常检测与多阶段风险预警[J]. *沈阳工业大学学报*, 2021, 43(6): 601-607.
- Wang J, Pei L. Anomaly detection and multi-stage risk pre-warning technology of power grid control system based on deep learning[J]. *Journal of Shenyang University of Technology*, 2021, 43(6): 601-607.
- [12] 荆志朋, 柴林杰, 胡诗尧. 基于改进LSTM-VAE的配电网异常负荷检测方法研究[J]. *电测与仪表*, 2024, 61(9): 71-76.
- Jing Z P, Chai L J, Hu S Y. Research on abnormal load detection method for distribution network based on improved LSTM-VAE[J]. *Electrical Measurement & Instrumentation*, 2024, 61(9): 71-76.
- [13] 李丹, 罗娇娇, 孙光帆, 等. 基于条件变分自编码器和贝叶斯神经网络的短期电力负荷概率预测[J]. *三峡大学学报(自然科学版)*, 2024, 46(5): 68-75.
- Li D, Luo J J, Sun G F, et al. Probabilistic short-term load forecasting based on conditional variational autoencoder and Bayesian neural network[J]. *Journal of China Three Gorges University (Natural Sciences)*, 2024, 46(5): 68-75.
- [14] 陈冰, 唐永旺. 基于Bi-GRU和自注意力的智能电网虚假数据注入攻击检测[J]. *计算机应用与软件*, 2021, 38(7): 339-344, 349.
- Chen B, Tang Y W. False data injection attacks detection in smart grid based on bi-gru and self-attention[J]. *Computer Applications and Software*, 2021, 38(7): 339-344, 349.
- [15] 夏景, 梁薇, 吴珠瑛. 基于移动小波树的电力监控异常数据自动识别算法研究[J]. *电子设计工程*, 2020, 28(18): 148-152.
- Xia J, Liang W, Wu Z Y. Research on automatic recognition algorithm of abnormal data in power monitoring based on mobile wavelet tree[J]. *Electronic Design Engineering*, 2020, 28(18): 148-152.
- [16] 方华强, 颜寒祺, 陈波, 等. 基于自编码网络的移动轨迹异常检测[J]. *地理信息世界*, 2019, 26(5): 41-44, 52.
- Fang H Q, Yan H Q, Chen B, et al. Anomaly detection in mobile trajectory using auto-encoder network[J]. *Geomatics World*, 2019, 26(5): 41-44, 52.
- [17] 胡昌斌, 张亚, 李迎丽, 等. 基于朴素贝叶斯的电网用户行为分析[J]. *沈阳工业大学学报*, 2020, 42(3): 259-263.
- Hu C B, Zhang Y, Li Y L, et al. Analysis of electrical grid user behavior based on Naive Bayesian[J]. *Journal of Shenyang University of Technology*, 2020, 42(3): 259-263.

[作者简介]



赵瑞锋 (1981-), 男, 博士, 广东电网有限责任公司电力调度控制中心正高级工程师, 主要研究方向为调度自动化运行、电力信息系统集成等。



卢建刚 (1970-), 男, 广东电网有限责任公司电力调度控制中心正高级工程师, 主要研究方向为调度自动化运行。



仲卫 (1988-), 男, 国电南瑞南京控制系统有限公司高级工程师, 主要研究方向为调度自动化、平台架构。

郭文鑫 (1985-), 男, 广东电网有限责任公司电力调度控制中心正高级工程师, 主要研究方向为电力系统及其自动化。

林玥廷 (1983-), 女, 广东电网有限责任公司电力调度控制中心高级工程师, 主要研究方向为调度自动化运行。

戴月 (1993-), 女, 广东电网有限责任公司电力调度控制中心高级工程师, 主要研究方向为调度自动化运行。