DOI:10.20033/j.1003-7241.(2026)08-0066-06

基于变分自编码器与迁移学习的源网荷储态势感知方法

袁 丁[1],付 饶[1],王 凯[2],张文龙[1],张 毅[2]

(1.国网徐州供电公司,江苏 徐州 221005;2.国电南瑞南京控制系统有限公司,南京 211106)

摘 要:在新型电力系统加速演进背景下,源网荷储各环节呈现多源异构、高维动态、强不确定性特征,传统数据处理与态势感知方法存在维度灾难、泛化能力弱、跨场景迁移成本高、实时性不足等瓶颈,难以满足高比例新能源接入下电网精准感知与高效优化运行需求。为全面提升源网荷储系统多源异构数据处理效率、态势感知精度与跨场景适应能力,提出一种基于变分自编码器与迁移学习的源网荷储态势感知优化方法。该方法首先利用变分自编码器(variational autoencoder,VAE)强大的非线性特征学习能力,对源网荷储系统中新能源出力、电网运行、负荷特性、储能状态等多维动态数据进行高效特征提取与低维重构,实现高维数据降维与关键信息保留;在此基础上引入迁移学习机制,将成熟运行场景下训练得到的模型特征、决策知识与控制经验迁移至新拓扑、新运行条件或未知扰动场景,大幅降低模型在新环境下的重训练时间、计算资源与数据依赖度,显著提升方法的泛化性与落地性。通过将高精度态势感知结果与智能调度、储能优化、负荷调控等运行优化机制深度耦合,系统可实时感知运行态势、快速识别异常状态、动态优化调度策略、精细化管理储能充放电,实现源网荷储协同互动与整体能效提升。算例与实验结果表明,所提方法在多源异构数据处理速度、态势感知准确率、系统鲁棒性与实时性等方面均优于传统方法,有效提升新能源消纳水平与能源利用效率,为高比例可再生能源电力系统的安全稳定、经济高效运行提供可靠技术支撑。

关键词:变分自编码器;迁移学习;源网荷储;态势感知;智能优化;多源异构数据;数据降维;电力系统运行

中图分类号:TP18;TM73 **文献标志码**:A **文章编号**:1003-7241(2026)08-0066-06

Situation awareness method for source-network-load-storage based on variational autoencoder and transfer learning

Yuan Ding[1], Fu Rao[1], Wang Kai[2], Zhang Wenlong[1], Zhang Yi[2]

(1. State Grid Xuzhou Power Supply Company, Xuzhou 221005, Jiangsu, China;
2. NARI Nanjing Control Systems Co., Ltd., Nanjing 211106, China)

Abstract: Against the background of the rapid evolution of the new power system, the source-grid-load-storage system presents the characteristics of multi-source heterogeneity, high-dimensional dynamics, and strong uncertainty. Traditional data processing and situation awareness methods suffer from dimensional catastrophe, weak generalization ability, high cross-scenario migration cost, and insufficient real-time performance, which are difficult to meet the requirements of accurate perception and efficient optimal operation of power grids with high penetration of renewable energy. To comprehensively improve the multi-source heterogeneous data processing efficiency, situation awareness accuracy, and cross-scenario adaptability of the source-grid-load-storage system, this paper proposes an optimized situation awareness method for source-grid-load-storage based on variational autoencoder and transfer learning. Firstly, the variational autoencoder (VAE) with strong nonlinear feature learning capability is used to extract features and reduce dimensions for the multi-dimensional dynamic data such as renewable energy output, power grid operation, load characteristics and energy storage status in the source-grid-load-storage system, so as to realize high-dimensional data dimensionality reduction and retain key information. On this basis, the transfer learning mechanism is introduced to migrate the model features, decision knowledge and control experience trained in mature operation scenarios to new topologies, new operating conditions or unknown disturbance scenarios, which greatly reduces the retraining time, computing resources and data dependence of the model in the new environment, and significantly improves the generalization and application of the method. By deeply coupling high-precision situation awareness results with operation optimization mechanisms such as intelligent dispatching, energy storage optimization and load regulation, the system can perceive operation status in real time, quickly identify abnormal states, dynamically optimize dispatching strategies, and finely manage energy storage charging and discharging, so as to realize the coordinated interaction of source-grid-load-storage and the improvement of overall energy efficiency. Example and experimental results show that the proposed method outperforms traditional methods in multi-source heterogeneous data processing speed, situation awareness accuracy, system robustness and real-time performance, effectively improves the level of new energy consumption and energy utilization efficiency, and provides reliable

收稿日期:2025-07-20;**录用日期**:2025-08-21

基金项目:国家电网有限公司华东分部大修项目(459923296652L)

作者简介:袁 丁(1978—),男,硕士,高级工程师,研究方向为电力系统保护与控制等。

引用本文:袁丁,付饶,王凯,等.基于变分自编码器与迁移学习的源网荷储态势感知方法[J].自动化技术与应用,2026,45(8):66-71.(Yuan Ding,Fu Rao,Wang Kai,et al. Situation awareness method for source-network-load-storage based on variational autoencoder and transfer learning[J]. Techniques of Automation and Applications,2026,45(8):66-71.)

technical support for the safe, stable, economic and efficient operation of power systems with high proportion of renewable energy.
Keywords: variational autoencoder; transfer learning; source-grid-load-storage; situation awareness; intelligent optimization; multi-source heterogeneous data; data dimensionality reduction; power system operation

随着新型电力系统的不断发展,源网荷储系统逐渐成为智能电网的重要组成部分。在此背景下,如何高效处理源网荷储系统中多源异构数据、准确感知系统运行态势成为当前研究的关键问题[1-3]。

在源网荷储系统态势感知与优化领域,现有研究方法主要包括:机器学习算法、深度学习模型以及基于迁移学习的技术[4]。这些方法在处理多源异构数据及实现高效态势感知优化方面存在一定的局限性,体现如下[5-7]:

1) 传统的机器学习算法在处理源网荷储系统中大量的多维动态数据时表现出明显的不足。这些算法通常依赖于手工特征提取,难以捕捉数据中的复杂模式和潜在特征,导致态势感知的准确性和实时性较低[8]。

2) 深度学习模型虽然在特征提取和模式识别方面具有显著优势,但其训练过程通常需要大量标注数据和计算资源[9-11],难以满足实际应用中的实时性需求[12]。

3) 现有的迁移学习方法在处理源网荷储系统的多源异构数据时,仍存在一定的局限性[13-14]。迁移学习方法在应对电力系统环境的动态变化和不确定性方面仍需进一步提升。

变分自编码器(variational autoencoder, VAE)作为一种生成模型,能够有效地对高维数据进行特征提取和降维处理,生成潜在的分布模型,从而捕捉系统状态中的关键特征与变化趋势[15-16]。通过 VAE 对源网荷储系统的多维动态数据进行处理,可显著提升数据处理效率和态势感知的准确性。然而,单纯依靠 VAE 模型在面对复杂多变的运行环境时,可能难以应对数据的不确定性和波动性。迁移学习(transfer learning,TL)作为一种机器学习方法,通过将已知场景中训练的模型知识迁移至新的电力系统或运行环境中,能够增强模型的泛化能力和适应性,减少在不同场景下重新训练模型的时间和资源消耗。迁移学习的引入,使得源网荷储系统在面对不同负荷、储能管理及电网结构的情况下,能够快速适应并提供高效的运行态势感知。

针对上述问题,本文提出了一种基于变分自编码器和迁移学习的源网荷储态势感知优化方法,通过特征提取和降维提高了多源异构数据的处理效率。迁移学习能够将已知场景的知识迁移至新环境,减少重新训练的时间和资源消耗。

1 源网荷储系统的动态特征

本文旨在提升电力系统中源网荷储多源异构数据处理效率、态势感知准确性及运行优化能力,结合实时态势感知与智能化运行优化机制,实现源网荷储系统的高效运行。为了实现这一目标,需要对研究对象,即源网荷储系统的动态特征进行深入分析。

1.1 系统动态特征分析

源网荷储系统是一个复杂的动态系统,其运行状态受多个因素影响,包括但不限于发电、输电、配电、用电和储能等多个环节。每个环节都具有不同的动态特征,且这些特征之间存在复杂的耦合关系。为了有效地感知和优化系统的运行状态,需要对这些动态特征进行建模和分析。

首先,源网荷储系统中的发电部分具有显著的动态特性。发电设备的输出功率随时间变化,且受到负荷需求、设备状态、燃料供应等多种因素的影响。为了描述发电设备的动态特性,可以采用状态空间模型。假设发电设备的状态向量为 $\boldsymbol{x}(t)$,输入为 $\boldsymbol{u}(t)$,输出为 $\boldsymbol{y}(t)$,则系统的动态特性可以表示为以下状态空间方程,即

$$\dot{\boldsymbol{x}}(t) = \boldsymbol{A}\boldsymbol{x}(t) + \boldsymbol{B}\boldsymbol{u}(t) \tag{1}$$

$$\boldsymbol{y}(t) = \boldsymbol{C}\boldsymbol{x}(t) + \boldsymbol{D}\boldsymbol{u}(t) \tag{2}$$

式中:$\dot{\boldsymbol{x}}(t)$ 表示状态变量的导数;$\boldsymbol{A}$、$\boldsymbol{B}$、$\boldsymbol{C}$ 和 $\boldsymbol{D}$ 为系统矩阵,描述了系统的动态特性。

其次,电力网络的电压和电流分布随时间变化,受负荷波动、故障和控制策略等因素的影响。假设节点电压向量为 $\boldsymbol{V}$,节点注入功率向量为 $\boldsymbol{S}$,则电力流方程可以表示为

$$\boldsymbol{S} = \boldsymbol{Y}\boldsymbol{V} \tag{3}$$

式中,$\boldsymbol{Y}$ 为网络导纳矩阵,描述网络的拓扑结构和电气特性。

用电部分的动态特性主要体现在负荷需求的变化上。负荷需求具有显著的时间特性和随机性,受用户行为、天气条件、经济活动等多种因素的影响。可以采用时间序列模型来描述负荷需求的动态特性。假设负荷需求为 $L(t)$,则时间序列模型可以表示为

$$L(t) = f(L(t-1), L(t-2), \cdots, \epsilon(t)) \tag{4}$$

式中,$f(.)$ 为时间序列模型函数,$\epsilon(t)$ 为随机扰动项。

储能系统的动态特性主要体现在储能设备的充放电行为上。储能设备的充放电行为受电池容量、充放电效率、控制策略等因素的影响。可以采用差分方程来描述储能设备的动态特性。假设储能设备的状态为 $E(t)$,充放电功率为 $P(t)$,则差分方程可以表示为

$$E(t+1) = E(t) + \eta P(t) \tag{5}$$

式中,η 为充放电效率。

综上所述,源网荷储系统的动态特征复杂多样,需要采用多种模型和方法进行描述和分析。本文通过结合变分自编码器与迁移学习的方法,对源网荷储系统的多源异构数据进行处理,从而实现系统态势的实时感知和智能优化,提高系统的运行效率和稳定性。

1.2 多源异构数据特性

多源异构数据是指来自不同来源、具有不同结构和特性的数据集合。在源网荷储系统中,这些数据包括但不限于实时监测数据、历史运行数据、天气信息以及用户负荷

特征等。为了确保系统的智能化水平与响应能力,必须深入理解这些数据的特性。

首先,实时监测数据具有高频率和高动态性。实时监测数据通常来自传感器网络,涵盖电力系统的各个部分,如发电、输电、配电和用电。其特点是数据流量大、更新频率高,且数据质量可能受到传感器故障、通信延迟等因素的影响。

其次,历史运行数据具有时间序列特性和长期性。历史运行数据记录了电力系统在不同时间段的运行状态和性能指标,具有较强的时间相关性。为了充分利用这些数据,本文结合了迁移学习技术,通过将历史数据中的知识迁移到当前系统中,能够提高系统在不同运行条件下的适应性和鲁棒性。

此外,天气信息具有空间和时间的多维特性。天气信息包括温度、湿度、风速等多个维度,这些因素直接影响电力负荷和发电量的变化。为了处理这些多维数据,本文采用了多任务学习(multi-task learning, MTL)的方法,通过构建多个相关任务的联合模型,能够同时学习和优化多个天气因素对系统的影响,从而提升预测的准确性和可靠性。

最后,用户负荷特征具有个性化和多样性。不同用户的用电行为和负荷特征存在显著差异,这些差异源于用户生活习惯、用电设备和用电需求等。为了准确捕捉用户负荷特征,本文采用了聚类分析和个性化建模的方法,通过对用户进行细分和分类,能够针对不同用户群体进行个性化的负荷预测和优化控制。

2 VAE与迁移学习优化策略

为了实现源网荷储系统的态势感知与智能优化,本文建立了一个结合变分自编码器(VAE)与迁移学习的数学模型,用于提高系统对多源数据的适应能力。

2.1 多源数据的联合损失函数

考虑到源网荷储系统的数据特性,使用变分自编码器来进行数据降维和特征提取。变分自编码器通过最大化边缘似然估计,能够有效地捕捉数据的潜在特征,即

$$\mathcal{L}(\theta,\varphi;x) = -\mathbb{E}_{q_\varphi}(z\mid x)[\log p_\theta(x\mid z)] + D_{\mathrm{KL}}(q_\varphi(z\mid x)\parallel p(z)) \tag{6}$$

式中,x 表示输入数据,z 表示潜在变量,$q_\varphi(z\mid x)$ 是编码器,$p_\theta(x\mid z)$ 是解码器,D_{KL} 表示 Kullback-Leibler 散度;$\mathbb{E}_{q_\varphi}$ 表示在编码器给出的潜在分布上的期望。

在实现态势感知的过程中,系统需要对多源数据进行实时分析和处理。为此,引入迁移学习的技术框架,通过预训练模型在不同数据源之间进行知识迁移,从而提高系统的泛化能力。通过在源任务和目标任务之间共享部分模型参数,实现知识的迁移和复用。假设源任务的模型参数为 θ_{s},目标任务的模型参数为 θ_{t},则迁移学习的目标是最小化源任务和目标任务的联合损失函数,即

$$\mathcal{L}_{\mathrm{transfer}} = \mathcal{L}(\theta,\varphi;x_{\mathrm{s}}) + \lambda\cdot\mathcal{L}(\theta,\varphi;x_{\mathrm{t}}) \tag{7}$$

式中,x_{s} 和 x_{t} 分别表示源域和目标域数据,λ 是权重参数,用于平衡源域和目标域损失。

此外,关键变量和参数的选择至关重要。首先,定义输入变量 x,包括能源生产数据、负荷需求数据、储能状态数据和网络拓扑数据。其次,定义潜在变量 z,用于捕捉输入数据的潜在特征。VAE 模型的目标是通过最大化证据下界(evidence lower bound, ELBO),使得生成的潜在变量能够有效地表示输入数据的分布。

2.2 迁移学习态势感知精度提升

首先,变分自编码器(VAE)是一种生成模型,通过学习数据的潜在表示来捕捉复杂的概率分布。VAE 的结构包括编码器和解码器两个部分,编码器将输入数据映射到潜在空间,解码器则从潜在空间重构输入数据。假设输入数据为 x,潜在变量为 z,则编码器和解码器的过程可以表示为

$$q(z\mid x) = N(z;\mu(x),\sigma^2(x)) \tag{8}$$

$$p(x\mid z) = N(x;\mu'(z),\sigma'^2(z)) \tag{9}$$

式中,$\mu(x)$ 和 $\sigma^2(x)$ 表示潜在变量均值和方差,$\mu'(z)$ 和 $\sigma'^2(z)$ 表示重构数据均值和方差,N 表示标准正态分布。

其次,迁移学习能够将预训练模型在源领域中的知识迁移到目标领域,从而在数据量有限或标注成本高昂的情况下,显著提升模型的泛化能力和训练效率。具体而言,采用预训练的 VAE 模型对源网荷储系统的数据进行特征提取,并通过迁移学习将这些特征应用于不同的子系统或新环境中。系统能够快速适应新的数据分布和运行条件,从而提高态势感知的准确性和实时性。

为了进一步提升优化能力,本文结合了强化学习算法,通过与环境的交互学习最优策略。假设状态为 s_t,动作为 a_t,奖励为 r_{t+1},下一状态为 s_{t+1},则 Q-learning 算法的更新公式为

$$Q(s_t,a_t) \leftarrow \alpha[r_{t+1} + \gamma Q(s_{t+1},a_{t+1}) - Q(s_t,a_t)] \tag{10}$$

式中,α 为学习率,γ 为折扣因子,Q 表示动作价值函数。

通过不断迭代更新,系统能够找到最优的运行策略,从而实现智能优化。

3 算法执行与实现

首先,定义输入数据为 $x\in\mathbb{R}^d$,其中 d 为数据的维度。编码器将输入数据映射到潜在空间 $z\in\mathbb{R}^k$,其中 k 为潜在空间的维度,通常 $k<d$。编码器的输出包括潜在空间的均值 $\mu(x)$ 和方差 $\sigma^2(x)$,其表示为

$$z\sim N(\mu(x),\sigma^2(x)) \tag{11}$$

解码器通过对潜在变量 z 进行重构,生成与输入数据 x 相似的输出数据 $\hat{x}$。解码器的目标是最大化输入数据与重构数据间的相似度。损失函数由重构误差和 KL 散度(kullback-leibler divergence, KLD)组成,如下:

$$\mathcal{L} = \mathbb{E}_q(z\mid x)[\log p(x\mid z)] - D_{\mathrm{KL}}(q(z\mid x)\parallel p(z)) \tag{12}$$

式中，$q(z \mid x)$ 是编码器的近似后验分布，$p(z)$ 是潜在变量的先验分布，为标准正态分布，$p(x \mid z)$ 表示给定潜在变量 z 时生成输入数据 x 的条件概率分布。

在特征提取阶段，通过优化上述损失函数，编码器能够学习到输入数据的低维特征表示 z，这些特征不仅包含了输入数据的主要信息，还具有较好的生成能力。在生成阶段，利用解码器可以从潜在空间中的任意点生成新的数据样本，从而实现对输入数据的重构和生成。这一过程不仅提高了特征提取的效率，还为后续的智能优化提供了丰富的特征信息。

本文的基本方案包括以下几个关键部分：基于 VAE 的源网荷储系统态势感知模型构建、迁移学习在跨场景中的应用与优化以及智能优化策略的设计与实现。

首先，基于 VAE 的源网荷储系统态势感知模型构建，利用 VAE 来捕捉源网荷储系统中的复杂动态特性。其次，迁移学习在跨场景中的应用与优化。迁移学习旨在将一个领域（源领域）的知识迁移到另一个领域（目标领域），以提高目标领域的学习效率和模型性能。在源网荷储系统中，不同场景之间的数据分布可能存在显著差异，这会导致模型在目标场景中的适应性较差。

为了克服这一问题，本文提出了一种基于对抗训练和域适应的迁移学习方法。给定源领域数据 X_s 和目标领域数据 X_t，首先训练一个共享的特征提取器 φ，然后分别训练源领域分类器 C_s 和目标领域分类器 C_t。为了实现域适应，引入了一个域判别器 D，其目标是区分源领域和目标领域的特征表示。通过对抗训练，使特征提取器 φ 生成的特征在域判别器上不可区分从而实现域适应，其目标函数为

$$\mathcal{L}_{\text{total}} = \mathcal{L}_s + \mathcal{L}_t + \lambda \mathcal{L}_d \tag{13}$$

式中，$\mathcal{L}_s$ 和 $\mathcal{L}_t$ 分别为源领域和目标领域的分类损失，$\mathcal{L}_d$ 为域判别损失，λ 为权重系数。

本文提出的基于变分自编码器与迁移学习优化策略，其总体架构流程图如图 1 所示。首先，系统通过数据采集模块（节点 A）从各种数据源收集多维动态数据。接着，利用变分自编码器（VAE）对采集的数据进行特征提取（节点 B），生成潜在分布模型（节点 C），以捕捉系统状态的关键特征。之后，通过迁移学习模块（节点 D），将已知场景中的模型知识迁移到新的电力系统或运行环境中，以增强模型的泛化能力。基于生成的模型和迁移学习的结果，系统能够实时感知电力系统的运行态势（节点 E），并根据实时态势感知的结果，动态调整电力调度策略和优化储能管理（节点 F）。数据处理模块包含 VAE 特征提取和生成潜在分布模型两个步骤，学习与适应模块包括迁移学习，操作与反馈模块涵盖实时态势感知和智能优化控制输出。

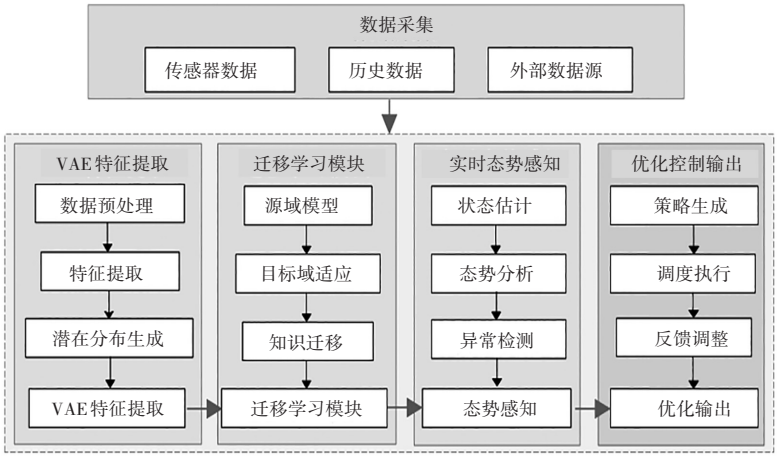


图 1　基于变分自编码器与迁移学习优化策略

Fig. 1　Optimization strategy based on variational autoencoder and transfer learning

4　案例分析

为了验证本文在源网荷储系统中的应用效果，进行了基于具体实施例的测试与验证。测试环境包括硬件配置和软件工具，确保测试的全面性和准确性。

4.1　测试环境

用 MATLAB/Simulink 平台对源网荷储系统态势感知与智能优化方法进行模拟测试，验证控制策略和优化算法的效果。仿真模型包括多源数据采集与预处理模块、变分自编码器（VAE）特征提取模块、迁移学习模块、实时态势感知模块和智能优化控制输出模块等主要组件。仿真模型的参数设置参考源网荷储系统的技术规范和运行数据。

4.2　测试参数

数据采集与预处理模块以 1 Hz 的频率采集电压、电流、功率和频率等数据。变分自编码器（VAE）模块由 3 层编码器构成，每层分别包含 128、64 和 32 个神经元，使用 ReLU 作为激活函数，潜在空间维度设置为 16。迁移学习模块使用已知的电力系统运行数据（50 000 条记录）作为初始模型训练数据集，新场景数据集则包含新电力系统运行数据（10 000 条记录），学习率为 0.001，训练轮数为 100 轮。

实时态势感知模块以 1 Hz 的频率更新电网稳定性、负荷平衡度和储能状态等指标。智能优化控制模块旨在通过粒子群优化（particle swarm optimization，PSO）算法最

小化电力损耗并最大化储能利用率,该模块配置了 50 个粒子和 200 次迭代。通过上述仿真环境,能够全面测试和验证基于变分自编码器与迁移学习的源网荷储系统态势感知与智能优化方法的有效性和鲁棒性。仿真关键参数的设置如表 1 所示。

表 1 仿真模型参数设置

Tab. 1 Simulation model parameter settings

模块	参数	参数取值
电源模块	额定功率	100 MW
	输出电压	11 kV
负载模块	最大负荷	80 MW
	最小负荷	20 MW
储能模块	储能容量	50 MWh
	充放电效率	90%
变压器模块	变压比	110 kV/11 kV
电网模块	线路阻抗	(0.01+j0.05) Ω

图 2 给出了不同控制方法下的源网荷储系统态势感知性能。由图可知,基于变分自编码器与迁移学习的方法在源网荷储系统态势感知任务中的表现显著优于传统方法。通过多次实验,VAE+迁移学习方法的预测准确度在五次实验中均保持在 91%以上。相比之下,传统的卷积神经网络(convolutional neural network,CNN)和长短期记忆网络(long short-term memory,LSTM)的表现明显逊色。CNN 在五次实验中的预测准确度徘徊在 86%~87%之间,但总体波动较大,反映出其在处理复杂多源异构数据时的局限性。LSTM 的表现则更加不稳定,准确度在 85%左右波动,表明其在态势感知任务中处理复杂时间序列时存在明显不足。

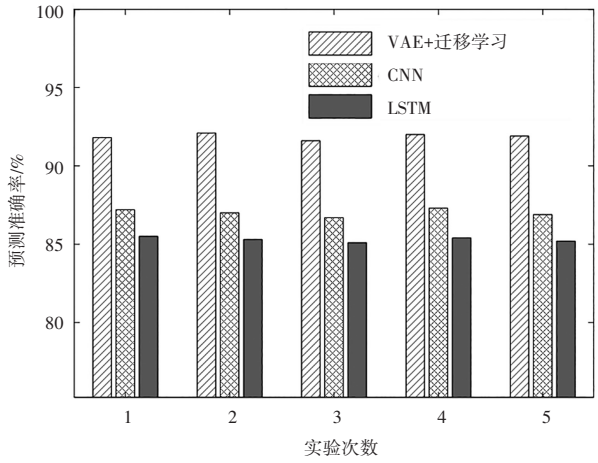


图 2 不同方法下的源网荷储系统态势感知性能

Fig. 2 Situation awareness performance of source-grid-load-storage system under different methods

图 3 给出了系统在电力调度和储能管理优化前后的 3 个关键指标的变化,分别为系统运行效率、储能利用率和能源成本。首先,优化后系统运行效率从优化前的 82.5%提升至 91.2%,表明智能优化方法能够减少系统运行中的冗余和不必要的能量消耗,从而提高了系统的整体效率。其次,储能利用率也表现出显著的提升,优化后从 70.0%增长到 88.5%,这一结果充分验证了智能优化模块在储能管理中的优越性,特别是在面对多变的电网负荷条件下,优化后的储能调度能够更加灵活、高效地调节电力供需平衡。最后,能源成本的变化也证明了智能优化的经济效益。

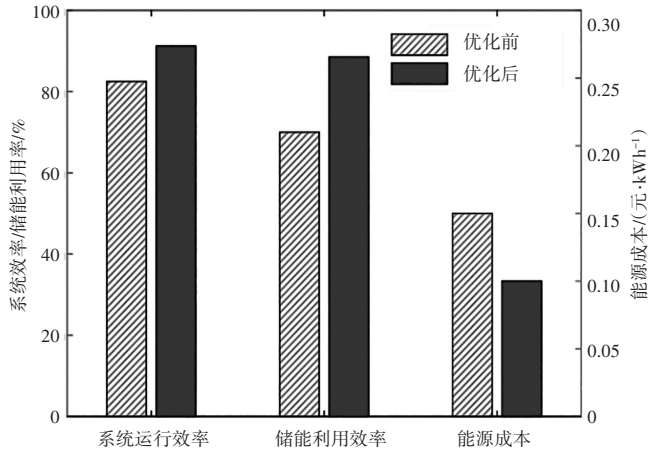


图 3 源网荷储优化前后的 3 个关键指标变化

Fig. 3 Changes in three key indicators before and after optimization of source network load storage

图 4 对比了本文的优化系统与传统系统的响应时间对比。根据图 4,优化系统在不同时段内的响应时间明显优于传统系统,尤其是在动态变化较大的时间段内,优化系统的实时性和稳定性更为显著。优化系统的响应时间随着时间的变化保持在较低水平,证明了该系统在高负荷及动态变化情况下的良好适应性和稳健性。

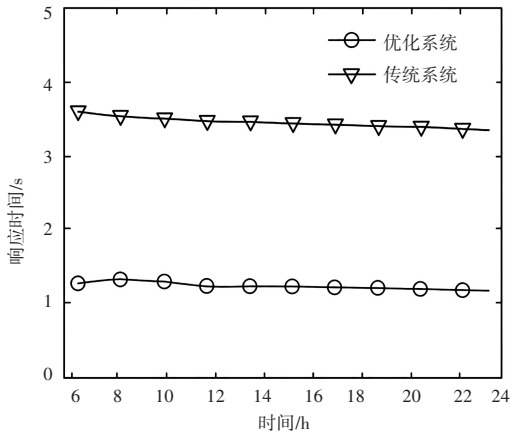


图 4 源网荷储系统优化前后的时间响应对比

Fig. 4 Comparison of time responses before and after source-grid-load-storage system optimization

图 5 给出了 VAE(变分自编码器)在复杂多维态势数据降维后的潜在空间分布。通过该图可知,正常态势和异常态势在二维潜在空间中呈现出明显的分离状态,证明了 VAE 模型在复杂数据处理中的优越特征生成能力和异常检测能力。

正常态势的数据点集中分布在二维潜在空间的右上

区域,表现为较为紧密的聚集,展现了良好的特征提取效果。同时,异常态势的数据点则集中分布在左下区域,与正常态势之间存在显著的空间分离。通过这种分离现象可以推测,VAE 能够在数据特征提取过程中准确识别出潜在的异常态势,并将这些异常数据点映射到潜在空间中远离正常态势的数据区域。

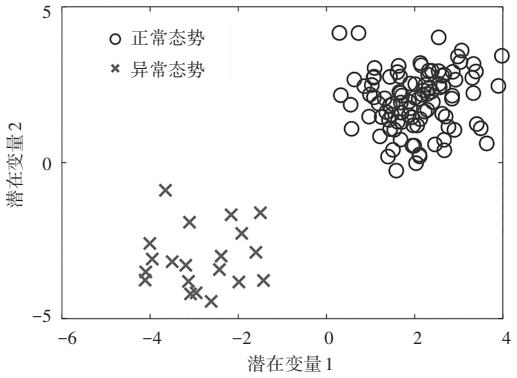


图 5　源网荷储系统的特征生成与异常检测结果

Fig. 5　Feature generation and anomaly detection results of the source-grid-load-storage system

5　结论

本文提出了一种基于变分自编码器与迁移学习的源网荷储态势感知优化方法,以提升电力系统中多源异构数据的处理效率。通过结合实时态势感知与智能化运行优化机制,能够动态调整电力调度策略并优化储能管理,显著减少了模型训练的时间和资源消耗。方法在不同电网结构和负荷条件下表现出优异的态势感知能力及优化效果,显著提升了系统的鲁棒性、实时性和能源利用效率。

参考文献

[1]王伟胜,林伟芳,何国庆,等. 美国得州 2021 年大停电事故对我国新能源发展的启示[J]. 中国电机工程学报,2021,41(12):4033-4042.
[2]林伟芳,易俊,郭强,等. 阿根廷“6. 16”大停电事故分析及对中国电网的启示[J]. 中国电机工程学报,2020,40(9):2835-2841.
[3]汪涛,武传涛,随权,等. 计及故障维修与网络重构的灾后配电网综合调度策略[J]. 中国电机工程学报,2024,44(5):1764-1777.
[4]丁涛,牟晨璐,别朝红,等. 能源互联网及其优化运行研究现状综述[J]. 中国电机工程学报,2018,38(15):4318-4328.
[5]蒲天骄,陈盛,赵琦,等. 能源互联网数字孪生系统框架设计及应用展望[J]. 中国电机工程学报,2021,41(6):2012-2028.
[6]Dou Z L,Zhang C Y,Dai R J,et al. Resilience enhancement strategy of multi-energy coupling distribution network considering movable energy storage equipment[J]. Journal of Physics:Conference Series,2023,2418(1):1-8.
[7]Chen C,Wang I H,Ton D. Modernizing distribution system restoration to achieve grid resiliency against extreme weather events:an integrated solution [J]. Proceedings of the IEEE,2017,105(7):1267-1288.
[8]李更丰,孙少华,别朝红,等. 面向新型电力系统弹性提升的储能优化配置与灵活调度研究综述[J]. 高电压技术,2023,49(10):4084-4095.
[9]汪伟,谢民,邵庆祝,等. 特高压换流站监视云边协同计算优化研究[J]. 自动化技术与应用,2024,43(6):82-85,170.
[10]宿洪智,郑少明,董鹏,等. 融合深度学习与云计算的智能调度系统优化策略[J]. 自动化技术与应用,2026,45(4):140-145.
[11]司羽飞,谭阳红,汪泓,等. 面向电力物联网的云边协同结构模型[J]. 中国电机工程学报,2020,40(24):7973-7979.
[12]王晓辉,季知祥,周扬,等. 城市能源互联网综合服务平台架构及关键技术[J]. 中国电机工程学报,2021,41(7):2310-2320.
[13]秦博雅,刘东. 电网信息物理系统分析与控制的研究进展与展望[J]. 中国电机工程学报,2020,40(18):5816-5826.
[14]吴新华,杨杰,吴雨霏,等. 基于共享储能和电-碳耦合的配电网多平衡区协同低碳运行方法研究[J]. 电测与仪表,2025,62(6):11-23.
[15]金萍,侯娟. 面向新型电力系统的粗糙集和双流网络自动化物联设备故障诊断方法研究[J]. 电测与仪表,2024,61(9):166-171.
[16]张璐,黄睿,王照琪,等. 考虑恢复力与经济性均衡的配电网移动储能优化配置策略[J]. 电力系统自动化,2020,44(21):23-31.