

AE-RL Driven GSTC-GAN Model for Ultra-Short-Term Wind Power Forecasting

Zhiyou Zhang¹ Zhirui Zhang^{2*} Yunlei Feng³ Shiwen Yang⁴

1. Jinhai Biotechnology Co., Ltd., Xinjiang Ili Kazakh, China, 835219, China

2. Xuchuan Chemical (Fujian) Co., Ltd., Fuqing, Fujian, 350309, China

3. Changji University, Changji, Xinjiang, 831100, China

4. Gansu Industry Polytechnic University, Tianshui, Gansu, 741025, China

Abstract

Ultra short term forecasting of wind power has profound significance for precise scheduling and stable operation of the power grid, but the volatility and instability of wind power pose many challenges to its integration into the grid. This article innovatively proposes a spatiotemporal attention generative adversarial network (GSTC-GAN) driven by autoencoder (AE) and reinforcement learning (RL) for wind power ultra short term prediction models. This model mainly utilizes AE denoising and data feature extraction to reduce the complexity of wind power data. Then, the GSTC-GAN generator is used to mine the spatiotemporal correlation of wind power data through spatiotemporal attention mechanism to generate prediction data. The discriminator distinguishes between real and generated data, and the two are used for anti training to improve the prediction performance of the generator; RL dynamically adjusts the parameters of GSTC-GAN based on prediction error feedback to achieve intelligent network optimization and enhance model adaptability. Experiments have shown that the AE-RL driven GSTC-GAN fusion model outperforms traditional models such as LSTM, GRU, and DBN in evaluation metrics such as MAE, RMSE, MAPE, and R2, providing effective new ideas and methods for improving the accuracy of ultra short term wind power forecasting.

Keywords

ultra short term wind power forecasting; Autoencoder; Reinforcement learning; Spatiotemporal attention generative adversarial network

AE-RL 驱动的 GSTC-GAN 风电超预模型

张志有¹ 张志睿^{2*} 冯韞蕾³ 杨世文⁴

1. 金海生物科技有限公司, 中国 · 新疆 伊犁哈萨克 835219

2. 旭川化学(福建)有限公司, 中国 · 福建 福清 350309

3. 昌吉学院, 中国 · 新疆 昌吉 831100

4. 甘肃工业职业技术大学, 中国 · 甘肃 天水 741025

摘要

风电超短期预测对电网精准调度和稳定运行具有深刻的意义,但风电的波动性及不稳定性对风电并网具有诸多挑战。本文创新性地提出了一种基于自编码器(AE)和强化学习(RL)驱动的时空注意力生成对抗网络(GSTC-GAN)用于风电超短期预测模型。该模型主要利用AE降噪和提取数据特征,降低风电数据复杂性,然后利用GSTC-GAN的生成器借助时空注意力机制挖掘风电数据时空关联从而生成预测数据,判别器区分真实与生成数据,二者进行对抗训练提升生成器的预测性能;RL按照预测误差反馈进行动态调整GSTC-GAN的参数,实现网络智能化优化,增强模型适应性。实验表明,AE-RL驱动的GSTC-GAN融合模型在MAE、RMSE、MAPE、R2等评价指标上均优于LSTM、GRU、DBN等传统模型,为提高风电超短期预测精度提供了有效的新思路与新方法。

关键词

风电超短期预测; 自编码器; 强化学习; 时空注意力生成对抗网络

【作者简介】张志有(2000-),男,本科,从事控制工程领域,风电功率预测研究。

【通讯作者】张志睿(2002-),男,本科,从事印刷媒体研究。

1 引言

在全球积极推进绿色能源转型、全力迈向“双碳”目标的进程中,风能作为清洁且可再生的能源,在全球能源格局中的地位日益重要。据国际能源署(IEA)统计,截至

2024 年末，全球风电装机容量成功突破 800GW，较上一年增长 12%。我国风电发展成绩卓著，2024 年底风电装机规模迅速攀升至 340GW，占全球总量的 42.5%，在全球风电领域发挥着引领作用。

然而，风电具有间歇性、波动性和随机性的特点，这给电网的稳定运行带来诸多挑战。在实际运行中，这些特性易引发电压大幅波动、频率偏差以及功率失衡等问题^[1]。

风电超短期预测技术的出现为解决以上问题带来了希望。凭借风电的精准预测结果，相应的电网调度部门能够提前合理安排发电计划，减少旋转备用容量，降低发电成本。同时，还能显著提升电力系统对风电的消纳能力，促进风电资源的高效利用。深入开展高精度风电超短期预测模型的研究，对于提升电网运行的安全性和经济性、推动风电产业健康发展具有极为重要的现实意义，已成为能源领域攻克的关键问题。

2 相关理论基础

2.1 自编码器原理

自编码器 (Autoencoder, AE) 是一类结构独特的神经网络，在数据降维、特征提取与数据重构等领域表现出色，因其创新设计和强大功能，逐渐成为深度学习研究的热点^[2]。

AE 架构主要由编码器和解码器组成^[3]。编码器负责将高维度的输入数据压缩，转化为低维度的潜在特征表示。在这个过程中，编码器通过构建映射函数，对输入数据进行层层抽象，提取关键特征信息，实现数据维度的降低^[4]。

重构误差通常采用均方误差 MSE 等损失函数度量，表达式为：

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (1)$$

其中， x_i 为原始输入数据， \hat{x}_i 为重构数据， n 为数据样本数量。

解码器将潜在 z 还原为重构数据 \hat{x}_i ，表达式如下：

$$\hat{x} = g_{\phi}(z) = \sigma_2(W_2 z + b_2) \quad (2)$$

其中， W_2 为编码器权重矩阵， b_2 为偏置向量， σ_2 为激活函数。

2.2 强化学习原理

强化学习 (Reinforcement Learning, RL) 是机器学习的一个重要分支，强调智能体 (Agent) 如何在环境中采取一系列行动，以最大化累积奖励。智能体在环境中感知状态 (State)，根据策略 (Policy) 选择动作 (Action)，环境根据智能体的动作反馈奖励 (Reward) 和新的状态。由图 1 可知，智能体的目标是通过不断尝试，学习到最优策略，使得长期累积奖励最大化^[5]。

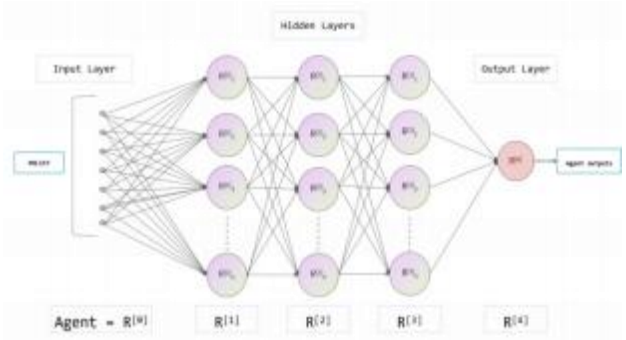


图 1 Agent 交互架构图

Fig.1 Agent interaction architecture diagram

常用的强化学习算法包括 Q 学习 (Q-Learning)、深度 Q 网络 (Deep Q Network, DQN) 及其扩展等^[6]。Q 学习通过构建 Q 值表来存储在不同状态下采取不同动作的预期奖励，智能体根据 Q 值表选择当前状态下 Q 值最大的动作。DQN 则结合了深度学习和 Q 学习，利用深度神经网络来逼近 Q 值函数，从而能够处理高维状态空间和连续动作空间的问题^[7]。

若 RL 调整 GSTC-GAN 的学习率 η ，基于预测误差 e_t 的自适应调整公式表示为如下：

$$\eta_{t+1} = \eta_t \cdot e^{-\lambda|e_t|} \quad (3)$$

其中， λ 为衰减系数，通过误差来反馈动态降低学习率以对模型进行稳定训练。在强化训练过程中，其学习奖励变化曲线如图 2 可知。

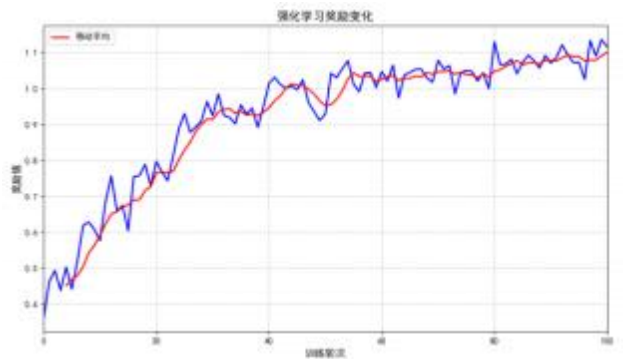


图 2 强化学习奖励变化曲线

Fig. 2 Reinforcement Learning Reward Variation Curve

在风电超短期预测模型中，强化学习主要用于根据预测误差反馈，对 GSTC-GAN 的参数进行动态调整。智能体通过不断尝试不同的参数调整策略，学习到能够使预测误差最小化的参数调整方式，实现网络的智能化优化，提升模型的适应性和预测性能。

2.3 生成对抗网络原理

生成对抗网络 (Generative Adversarial Network, GAN) 由生成器 (Generator) 和判别器 (Discriminator) 组成。生成器的任务是根据输入的随机噪声生成假数据，尽量使其与真实

数据相似；判别器则负责区分生成器生成的假数据和真实数据。二者相互对抗训练，在这个过程中，生成器不断提高生成数据的质量，使其更接近真实数据，判别器则不断提高辨别真假数据的能力。

具体来说，生成器 G 接收随机噪声 z 作为输入，通过其内部的神经网络结构生成数据 $G(z)$ 。判别器 D 接收生成器生成的数据 $G(z)$ 和真实数据 x ，并输出一个概率值，表示输入数据是真实数据的可能性。生成器的目标是最小化 $D(G(z))$ ，即让判别器难以区分生成数据和真实数据；判别器的目标是最大化 $D(x)-D(G(z))$ ，即正确区分真实数据和生成数据。

对于标准的 GAN 的对抗训练过程则可以表示为极小极大的博弈，目标函数则为：

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (4)$$

其中， $p_{data}(x)$ 表示为真实的数据分布； x 表示为真实的风电数据； $p_z(z)$ 为随机噪声分布， z 表示为生成器输入； $G(z)$ 表示为生成器的输出预测数据； $D(x)$ 表示为判别器对于输入数据的真实性的概率判断。

在训练过程中，生成器和判别器交替进行优化。生成器根据判别器的反馈调整自身参数，以生成更逼真的数据；判别器根据生成器生成的数据和真实数据调整自身参数，以提高辨别能力。最终，能够生成高质量的、与真实数据相似的数据。判别器在输入同时包含生成真实数据 x 和生成数据 $G(z)$ 时所输出的联合判别概率公式为：

$$D(x, G(z)) = \sigma(W_d \cdot [x; G(z)] + b_d) \quad (5)$$

其中， $[x; G(z)]$ 表示的是真实数据于生成数据的特征拼接； W_d ， b_d 均表示的是判别器的参数。

在风电超短期预测中，GSTC-GAN 的生成器融入时空注意力机制，深入挖掘风电数据在时间与空间维度的内在关联，生成预测数据；判别器对真实数据与生成数据进行区分，通过二者间的对抗训练，持续提升生成器的预测性能。

3 多模态数据融合策略

3.1 融合方式创新

在采用基于 Transformer 架构的多模态融合网络。编码过程中的表达式为：

$$E_{geo} = Encoder_{geo}(G_{geo}) \quad (6)$$

其中， G_{geo} 为输入的地理信息数据， E_{geo} 为编码后的空间特征向量。

而在微观的地形变化时，通过卷积神经网络 (CNN) 进行转化为特征图 (F_{ter}) 的表达式如下：

$$F_{ter} = CNN(G_{ter}) \quad (7)$$

在电力市场数据 G_{ele} ，利用循环神经网络 (RNN) 对时间序列进行处理得到 S_{ele} ，其相应的表达式为：

$$S_{ele} = RNN(G_{ele}) \quad (8)$$

将这些特征量组合为然后再输入到 Transformer 网络中，Transformer 中的自注意力机制的表达式为：

$$A = \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) \quad (9)$$

其中， A 为注意力分数， Q 为查询向量， K 为键向量， V 值向量， d_k 为键向量的维度。图 3 为各个模型的分量拓扑图。

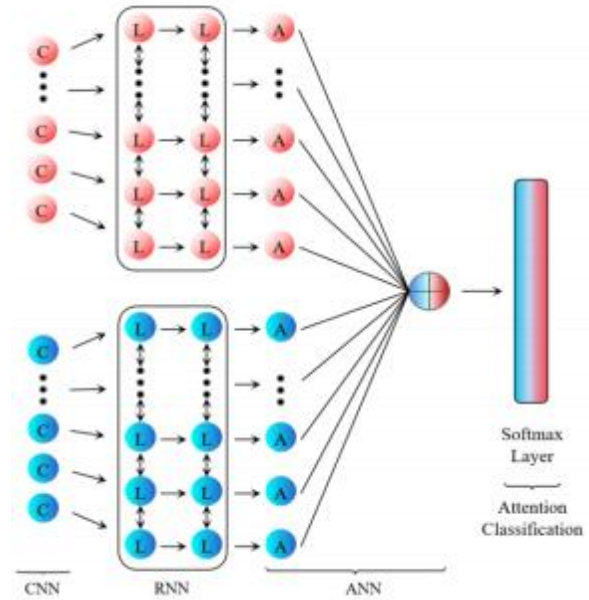


图 3 CNN、RNN 与 ANN 的分类模型拓扑图

Fig.3 Topology diagram of classification models for CNN, RNN, and ANN

Transformer 的自注意力机制可在不同模态数据之间自动学习长序列依赖关系，无需预先设定融合权重。首先，对不同模态数据进行特征提取，将地理信息数据编码为空间特征向量，微观地形数据通过卷积神经网络转化为特征图，电力市场数据利用循环神经网络处理为时间序列特征。然后，将这些特征输入 Transformer 网络，网络会根据预测任务需求，动态计算不同模态特征之间的关联权重，实现自适应的多模态数据融合。

3.2 基于强化学习的权重调整优化

在基于强化学习调整 GSTC-GAN 参数的基础上，需要构建分层式强化学习智能体。不同模型的权重变化曲线则由图 4 可见。

图中可知，随着训练次数的不断迭加，不同模型之间的权重值会有不同的变化，整体的强化学习优化过程中，GSTC-GAN 和 AE-RL 的权重呈上升的变化趋势，此模型正在进行有效学习。




图 4 强化学习过程中的各模型权重变化曲线

Fig. 4 Weight variation curves of each model during the reinforcement learning process

设高层策略智能体观测到的模型的整体预测性能为 R_{total} ，根据策略 π_{high} 生成高层的动作 a_{high} 其所形成的表达式为：

$$a_{high} = \pi_{high}(R_{total}) \quad (10)$$

设底层执行智能体根据高层动作 a_{high} 以及自身观测到的局部状态 S_{total} ，由策略 π_{low} 生成底层的动作 a_{low} 其所形成的表达式为：

$$a_{low} = \pi_{low}(a_{high}, S_{low}) \quad (11)$$

该智能体分为高层策略智能体和底层执行智能体。高层策略智能体根据模型整体预测性能制定长期权重调整策略，确定不同时间段内哪些网络层的权重需要重点调整以及调整方向。底层执行智能体根据高层策略智能体指令，结合当前时间步的预测误差，具体执行权重调整操作，精确控制权重更新的步长和幅度。根据奖励信号优化策略来调整 GSTC-GAN 的参数。

4 AE-RL 驱动的 GSTC-GAN 风电超预模型构建

4.1 GSTC-GAN 网络结构设计

GSTC-GAN 的生成器融入时空注意力机制，主要是在深入挖掘风电数据在时间与空间维度的内在联系，进而生成精准的预测数据。生成器首先对输入数据进行初步特征提取，将风电历史功率数据、气象数据以及融合后的多模态数据进行整合与编码。在时间维度上，通过循环神经网络(RNN)或其变体 LSTM^[8]、GRU 对数据的时间序列特征进行学习，捕捉风电功率随时间的变化趋势和周期性规律。在空间维度上，利用卷积神经网络(CNN)对地理信息数据、微观地形数据等反映的空间特征进行提取，分析风电场不同位置之间的关联以及地形对风电的影响^[9]。由图 5 可知不同地理对风电的影响状况。




图 5 各模型在不同地理位置的预测对比图

Fig. 5 Comparison of predictions of various models in different geographical locations

而对于本文所提出的 GSTC-GAN 的模型的学习率及其权重变化如图 6 所示。

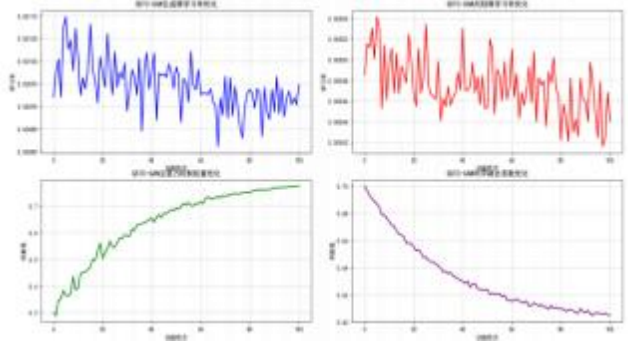


图 6 GSTC-GAN 模型学习率与权重优化曲线图

Fig.6 Learning rate and weight optimization curves of each model

时空注意力机制的引入是生成器的关键创新点。该机制通过计算不同时间步和空间位置数据的注意力权重，能够自适应地聚焦于对预测结果影响较大的关键信息。在强对流天气影响风电场部分区域时，注意力机制可自动提高受影响区域相关数据的权重，使生成器更准确地捕捉风电功率的异常变化。生成器根据学习到的时空特征和注意力权重，生成与真实风电功率数据相似的预测数据，为后续的预测任务提供基础^[10]。

4.2 AE 与 GSTC-GAN 的融合方式

AE 在模型中主要就是和数据进行预处理和特征提取，与 GSTC-GAN 紧密融合，为提高预测精度奠定基础。而图 7 则可以直观呈现出融合的关系，图中通过不同的风电场历史数据及气象数据等相关信息，将流入的 AE 模块通过自身的编码-解码结构对数据进行降噪处理，并且可以更好对数据进行提取，最后全部进入到 GSTC-GAN 模块，利用这些经过处理后的特征数据，结合时空注意力机制可以更好挖掘数据的时空关联，从而来提高风电功率超短期的预测精度。

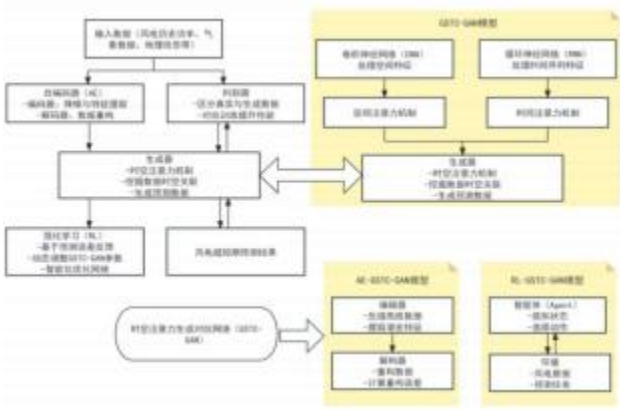


图 7 各模型融合关系图

Fig. 7 Fusion Relationship Diagram of Various Models

首先，将原始的风电数据（包括风电历史功率数据、气象数据等）输入 AE。AE 的编码器对这些高维度、复杂的数据进行降噪处理和特征提取，将其压缩为低维的潜在特征表示。通过这种方式，去除数据中的噪声和冗余信息，降低数据复杂性，同时保留对风电预测至关重要的关键特征。




图 8 各模型训练变化损失图

Fig.8 Loss graph of training changes for each model

然后，将 AE 编码器输出的低维特征向量输入 GSTC-GAN 的生成器。生成器利用这些经过 AE 处理的特征数据，结合自身的时空注意力机制和网络结构，生成预测数据。这种融合方式使得 GSTC-GAN 能够在更优质的数据基础上进行预测，充分发挥 AE 在数据处理方面的优势，提高生成器生成预测数据的准确性和可靠性，进而提升整个模型的预测性能。

4.3 RL 对 GSTC-GAN 的参数优化机制

RL 在模型中发挥着动态优化 GSTC-GAN 参数的核心作用，通过不断调整参数，使模型更好地适应不同的风电数据和预测任务需求。当模型的预测结果与真实风电功率之间存在误差时，RL 智能体根据误差的大小和方向，确定对 GSTC-GAN 参数的调整策略。图 9 则是强化学习 RL 对模型数据处理的一个重要环节，直观展示了 RL 对复杂的风电数据进行特征提取的反映，可以进一步对模型进行优化处理

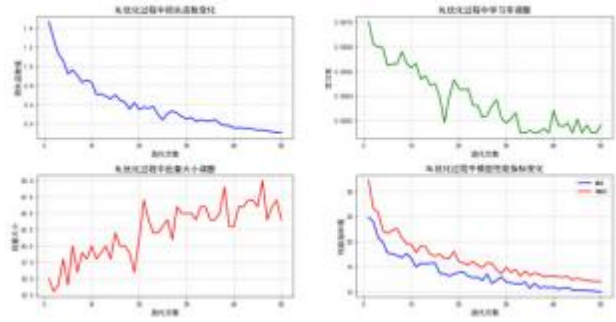


图 9 RL 优化模型数据分解曲线图

Fig.9 RL Optimization Model Data Decomposition Curve

RL 在模型优化过程中，可以深层次分析不同环境的复杂数据，很好地去掌握风电功率的变化趋势，提高长期的风电预测准确性，进一步实现了对 GSTC-GAN 模型的动态参数优化，最终提升风电超短期的预测精度与稳定性。图 10 则是 GSTC-GAN 与各模型在学习率方面的变化曲线对比图。

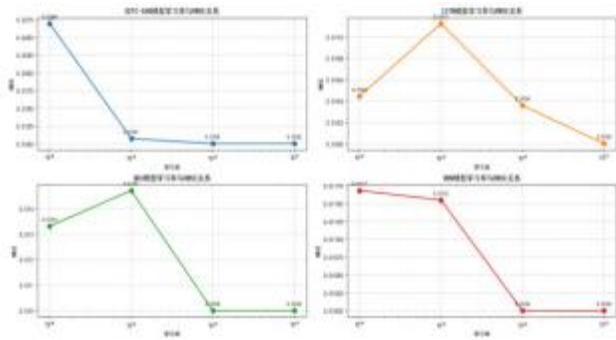


图 10 GSTC-GAN 与各模型学习率性能变化曲线图

Fig. 10 Performance Change Curve of GSTC-GAN and Learning Rates of Various Models

图 10 展示了 GSTC-GAN 与基准模型学习率敏感性对比曲线，通过比较 GSTC-GAN 与 LSTM、GRU、DBN 等传统模型在不同学习率下的 RMSE 指标变化趋势，验证了本文提出模型的性能优势。GSTC-GAN 模型在不同学习率设置下均展现出卓越的性能表现，其均方根误差指标显著优于其他对比模型。实验数据表明，该模型在同等训练条件下能够实现更精确的数据拟合效果，生成结果的准确性明显提升。这种性能优势主要源于模型架构中的创新性设计，特别是时空注意力机制的引入，该机制能够有效捕捉数据中的时空关联特征，从而显著提升预测精度，充分展现了该模型在算法创新方面的突破性进展。

采用基于策略梯度的强化学习算法，智能体通过探索不同的参数调整动作，观察调整后模型预测误差的变化，从而学习到能够使预测误差最小化的参数调整策略。通过不断积累经验，智能体逐渐找到最优的参数调整策略，实现对 GSTC-GAN 参数的动态优化，提高模型的适应性和预测精度^[11]。

4.4 模型训练过程

模型构建与训练过程具有高度的系统性和复杂性，主要包括数据预处理、超参数配置以及模型性能优化等核心模块。具体而言，自编码器承担数据去噪和特征表示学习功能，为下游任务提供高质量输入；时空生成对抗网络（GSTC-GAN）专注于捕捉数据中的时空依赖关系并生成预测结果；强化学习（RL）则通过评估预测误差实现对 GSTC-GAN 参数的动态优化。这三个模块通过协同作用形成闭环优化机制，持续提升模型的整体性能表现。图 11 则是 GSTC-GAN 的模型数据进行分解时所呈现出来的曲线图。

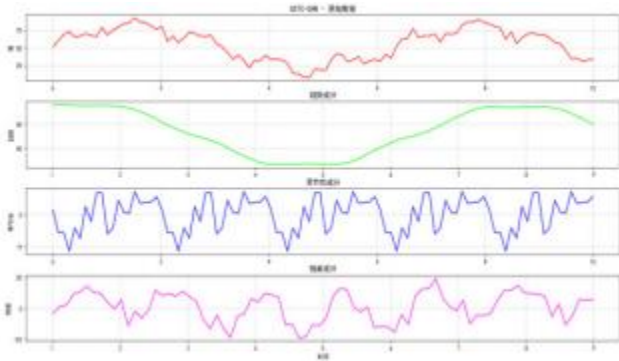


图 11 GSTC-GAN 模型数据分解曲线图

Fig.11 Data Decomposition Curve of GSTC-GAN Model

如图 11 所示，GSTC-GAN 模型数据分解曲线图通过多维度特征解析，充分展现了该模型在风电超短期功率预测领域的突出性能。从趋势分量曲线可以观察到，该模型能够准确捕捉风电数据随时间演变的长期规律，包括持续上升、平稳波动或逐步下降等不同形态，这种对长期趋势的精确识别能力为风电场运营数据的分析提供了重要支撑，有助于预测未来功率变化趋势。同时，模型提取的季节性分量清晰地反映出风电数据受季节因素影响的周期性特征，通过对这种规律的深入挖掘，可以在风能资源充沛的季节提前预测功率峰值，为电网调度提供前瞻性指导，显著提升电力系统对风电的接纳效率。

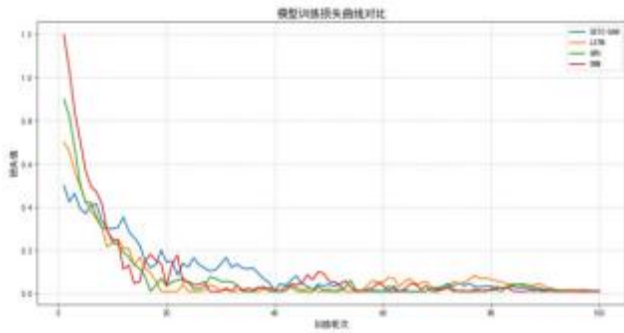


图 12 不同模型损失曲线对比图

Fig. 12 Comparison of loss curves for different models

图 12 展示了基于 AE-RL 框架的 GSTC-GAN 模型与对比模型在训练阶段的损失函数变化轨迹。通过损失曲线的对

比分析可以发现，GSTC-GAN 模型的生成器和判别器损失值均呈现稳定下降态势，反映出模型参数在迭代过程中持续优化，生成样本质量逐步提升，判别性能不断增强。这一结果表明，GSTC-GAN 模型凭借其创新的网络架构和训练策略，展现出更优的收敛特性和学习效率，能够更有效地捕捉数据的内在规律，从而为提升风电超短期功率预测精度提供了可靠的技术支撑。不同模型的趋势变化曲线图如图 13 所示。

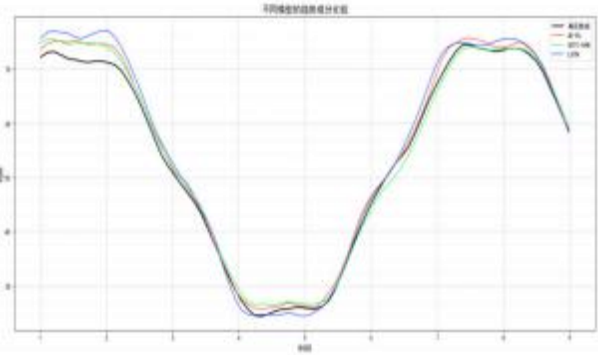


图 13 不同模型趋势成分变化曲线图

Fig. 13 Trend component variation curves of different models

从不同模型趋势成分变化曲线图中系统性地对比分析了各类模型在风电数据趋势特征提取方面的性能表现。研究表明，基于 AE-RL 算法构建的 GSTC-GAN 模型相较于 LSTM 等传统时序模型展现出更优异的趋势捕捉能力。具体而言，传统模型输出曲线存在明显波动，易受短期数据扰动影响；而 GSTC-GAN 生成的趋势曲线不仅平滑稳定，且能准确反映风电功率的长期变化规律（包括持续增长、平稳波动或逐步下降等趋势特征），这对电力系统的中长期调度规划具有重要参考价值。通过定量评估各模型输出曲线的稳定性和与真实趋势的吻合程度，本研究为深度学习模型在时序数据分析领域的优化提供了理论依据，同时也验证了 GSTC-GAN 在处理长期趋势特征方面的优越性能。在模型训练过程中其损失变化曲线图如图 14 所示。

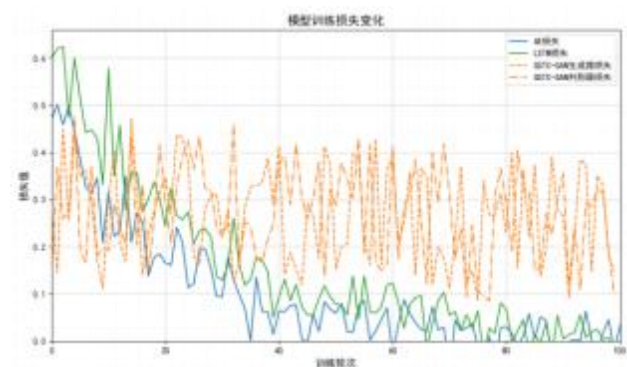


图 14 不同模型训练损失变化曲线图

Fig. 14 Curve of Training Loss Changes for Different Models

本研究通过模型训练损失对比分析图系统展示了自编

码器、长短期记忆网络以及 GSTC-GAN 生成器 / 判别器在训练阶段的损失函数变化趋势。实验结果表明，相较于传统 LSTM 等模型，GSTC-GAN 框架中的生成器和判别器展现出更为显著的损失下降趋势，且收敛过程更为平稳。这一现象充分验证了对抗训练机制在参数优化方面的有效性，表明该模型具备更强的特征提取能力和学习效率，其优异的收敛特性和训练稳定性为后续预测任务提供了可靠保障。在不同的数据当中所展示的关系图见图 15 所示。

多源数据集关联关系矩阵图谱采用可视化矩阵形式，系统性地展示了风电功率预测研究中涉及的风速、温度等气

象参数、地理空间信息、微观地形特征以及电力市场数据之间的相关性强度。该图谱通过色阶变化和数值标注两种方式，清晰地呈现了不同变量间的统计关联程度，例如风速与风电功率呈现显著正相关相关系数超过 0.8，而温度与功率的相关性则相对较弱。这种可视化分析方法不仅为构建多源数据融合模型提供了科学依据，在风速 - 功率关系设计时空注意力机制来优化特征提取策略，还能深入解析数据间的内在关联规律在特定地形条件下风速对功率的影响程度，从而有效解释预测模型能够准确捕捉风电数据特征的内在机理，为提升预测精度奠定了坚实的数据基础。




图 15 不同数据集的关联关系矩阵图谱

Fig.15 Matrix diagram of correlation relationships between different datasets

5 实验与结果分析

为全面评估 AE-RL 驱动的 GSTC-GAN 模型的性能，进行了一系列实验，并与 LSTM、GRU、DBN 等传统模型进行对比分析。

盖不同地理区域、气象条件和风电装机规模的风电场。将数据集按照一定比例划分为训练集、验证集和测试集，其中训练集用于模型训练，验证集用于调整模型超参数和防止过拟合，测试集用于评估模型的最终性能。




图 16 风电超预模型结构图

Fig.16 Structural diagram of wind power super prediction model

实验选取多个风电场的实际运行数据作为数据集，涵




图 17 风电功率预测误差分布概率密度图

Fig.17 Probability density map of wind power prediction error distribution




图 18 不同模型预测结果对比图

Fig. 18 Comparison of Prediction Results of Different Models




图 19 不同预测步长的误差分析图
Fig.19 Error Analysis of Different Prediction Steps



图 23 各天的预测误差对比图
Fig.23 Comparison of prediction errors for each day




图 20 不同模型季节性成分曲线图
Fig.20 Seasonal component curves of different models

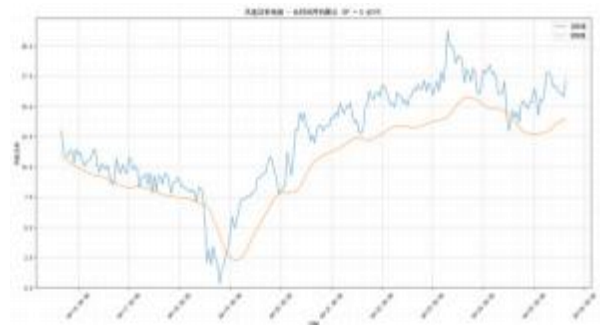


图 24 实际值与预测值曲线图
Fig.24 Curve of Actual and Predicted Values

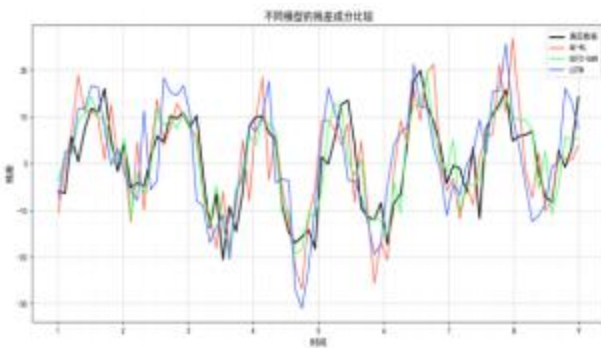


图 21 不同模型残差比较图
Fig.21 Comparison of residuals between different models

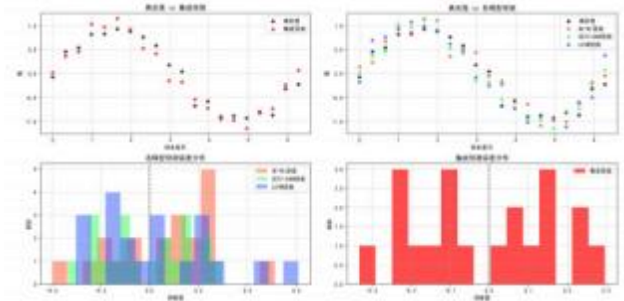


图 25 不同模型误差结果对比图
Fig.25 Comparison of Error Results of Different Models




图 22 不同时间段的预测误差对比图
Fig.22 Comparison of prediction errors at different time periods




图 26 不同时间段的风电功率预测结果对比图
Fig.26 Comparison of wind power prediction results at different time periods

以上图 17-26 可知从多维度验证了模型的预测性能优

势，其中图 17 通过风电功率预测误差分布概率密度图显示本文模型误差更集中于 0 值附近，稳定性优于传统模型；图 21、24、25 从时间维度体现模型在不同时间段及极端时段状况下的鲁棒性；图 19 验证了模型在不同预测步长下的泛化能力和动态适应性，最后再结合图 5、11、22、23 等对时空特征与季节性的分析，共同说明了本文模型在预测精度、鲁棒性及可解释性等方面的优势。

表 1 不同模型的评价指标对比

Table 1 Comparison of evaluation indicators for different models

各模型评价指标对比			
	RMSE	MAPE	R2
LSTM	0.2873	15.1018	0.9951%
GRU	0.4447	23.3091	0.9883%
DBN	0.6385	29.7133	0.9759%
本文模型	0.1152	6.0917	0.9992%




图 27 不同模型的风电功率预测结果对比图

Fig.27 Comparison of Wind Power Prediction Results of Different Models

图 27 可以很明显看出，不同模型在同一时间下其模型的稳定性不一样。LSTM 在一定时刻下与实际功率较相近，在一定程度上可以学习风电场功率随时间变化的状况，但是其曲线偏离实际功率曲线较大，而总体的曲线变化程度来看，GSTC-GAN 在对抗模型训练时，可以很好捕捉时空相关性，对风电的预测结果不断进行优化，并且曲线最接近于实际功率，在准确预测方面比其他模型最具有显著的优势。

6 结论

本文提出了一种基于 AE-RL 驱动的 GSTC-GAN 风电超短期预测模型，并基于不同风电场的实际数据进行实验验证，得出以下结论：

将 AE 与 RL 融入到 GSTC-GAN 的模型当中，通过 AE 对风电数据进行降噪与特征提取，结合 GSTC-GAN 的时空注意力机制对数据进行挖掘，再利用 RL 基于预测误差动态对模型的参数进行优化，实现全领域特征增强与预测性能的

总体提升。实验表明，该模型与 LSTM 和 GRU 等传统的模型方法相比较，RMSE 和 MAE 误差绝对值百分比分别降低 59.8% 至 82.0% 和 52.3% 至 68.1%，准确验证了该模型在提升预测精度方面具有显著的有效性。

针对风电数据的波动性与极端场景，该模型通过 RL 动态调整参数与 GSTC-GAN 的对抗训练机制，增强了对异常数据的适应性。在对于强对流天气等极端场景下，该模型的最差评估指标相较于传统方法提升了 3.27MW，表明了复杂的环境下仍能够保持稳定的预测性能，鲁棒性显著优于其他的传统模型。

总体而言，该模型通过多种机制融合实现了高精度预测，在常规场景与极端状况下均能表现出较好的优势，为风电并网调度提供了可靠的技术支撑。在未来研究中将聚焦动态模态分解与多尺度进行特征融合，进一步挖掘气象 - 地形 - 功率之间的非线性关系，并探索多能源协同预测与碳交易经济性优化，为新能源的高效消纳与电网的灵活性调度提供了综合的解决方案。

参考文献

- [1] 张扬帆,李奕霖,叶林,等.低温天气下考虑风机运行状态聚类的短期风电功率预测方法[J].发电技术, 2025,46(02):326-335.
- [2] 陈仪,刘春元.基于聚类集合的EMD-CNN-BiLSTM自注意力机制短期电力负荷预测[J].软件工程,2025,28(03):1-5+46.
- [3] 王建军,潘佳音,赵珍珠,等.基于特征时间双注意力机制的短期光伏发电预测深度学习模型研究[J].智慧电力,2025,53(04):81-87.
- [4] 郭韶昕,陈祥,周枫.基于CEEMD-IDA-SVM的风电功率短期预测[J].上海电机学院学报,2022,25(06):339-345.
- [5] 王光华,李晓影,宋秉睿,等.基于深度强化学习的配电网负荷转供控制方法[J].电力自动化设备,2022,42(07):253-260.
- [6] 冯昌森,汤飞霞,王国烽,等.基于融合经验安全强化学习的配电网电压控制[J].电力系统自动化, 2025,49(08):169-177.
- [7] 郑晨,刘书铭,李琼林,等.基于多场景的配电网电压序列协调技术发展研究[J].自动化与仪器仪表,2025,(04): 274-277+282.
- [8] 逯静,张燕茹,王瑞.基于BWO优化VMD和TCN-BiGRU的短期风电功率预测[J].工程科学与技术,2025,57(03):31-41.
- [9] 陈梦娇,陈为真,张岳.差分进化优化的风电功率混合预测模型[J].重庆理工大学学报(自然科学), 2025,39(04):217-226.
- [10] 黄娇.基于VMD和改进CNN-LSTM的短期电力负荷组合预测方法研[D].燕山大学,2022.
- [11] Bilin L ,Huaiyuan W ,Yang Z , et al. Real-time power system generator tripping control based on deep reinforcement learning [J]. International Journal of Electrical Power and Energy Systems, 2022, 141.