深度学习风功率预测方法提升陆上风电场短期出力预报精度

吴佳鹏

北京京能清洁能源电力股份有限公司西北分公司 宁夏 银川 750000

【摘　要】：陆上风电场短期出力受气象变化及机组运行状态影响，功率序列具有较强的非线性和波动性，传统预测方法难以充分提取复杂时序特征。针对多源数据关联不足、动态特征提取不充分和预测误差累积等问题，提出融合卷积神经网络、门控循环单元及注意力机制的短期风功率预测方案，并从数据融合、时序特征提取、动态权重分配和多时效误差评价四个环节说明模型训练与验证方法，为复杂风况下的短期出力预报提供技术依据。

【关键词】：深度学习；陆上风电场；短期风功率预测；CNN-GRU；注意力机制

DOI:10.12417/2705-0998.26.14.038

1 陆上风电场短期出力预测技术特征

1.1 短期风功率预测数据构成

短期风功率预测数据主要由历史有功功率、气象观测信息、数值天气预报及机组运行参数构成。历史功率数据通常采用 15 分钟采样间隔，记录风电场实际出力变化；气象数据涵盖不同高度的风速、风向、气温、气压及空气密度，反映风能输入条件。数值天气预报提供未来气象变化信息，SCADA 系统则采集机组转速、桨距角、运行状态及限功率指令。数据处理需统一时间戳、采样频率及功率计量口径，识别故障停机、异常测点和主动限电记录。考虑气象变量的时间滞后特性，还需建立历史观测窗口、预报发布时间及目标预测时段之间的对应关系，防止未来信息泄露影响模型训练。

1.2 风电出力波动规律及影响因素

陆上风电场出力变化具有非平稳性、非线性及多时间尺度特征，风速变化是影响有功功率的主要因素。额定风速以下，机组功率随风速增加呈明显非线性增长；接近额定功率区间时，控制策略使功率响应逐渐趋于平缓。地形起伏、地表粗糙度及尾流效应改变局部风场分布，导致不同机组出力存在空间差异。阵风、风向突变及湍流强度变化容易引发短时功率爬坡，天气系统演变则形成持续性出力波动。机组启停、变桨控制及限电调度进一步改变功率序列的统计特征，增加历史功率和未来出力之间的映射复杂度。

1.3 传统风功率预测技术应用特点

传统短期风功率预测主要采用持续性预测、时间序列统计模型及常规机器学习方法。持续性预测以当前功率近似未来出力，计算简单、响应迅速，但预测时效延长后误差容易增大。自回归移动平均模型依赖序列平稳性及线性相关关系，对突发风速变化的适应能力有限。支持向量回归和随机森林可以处理非线性关系，但预测性能较大程度取决于特征选择、参数配置和训练样本分布。面对多源气象变量耦合和连续功率爬坡过程，传统方法通常需要人工构造滞后特征，难以充分刻画长期时间依赖及局部动态变化，复杂风况下的预测稳定性仍受限制。



图 1 传统风功率预测技术及其应用局限示意图

2 陆上风电场短期出力预测精度制约因素

2.1 多源气象数据关联利用不足

多源气象数据存在采样频率、空间分辨率及预报更新时间不一致的问题，容易造成气象输入与实际功率响应错位。测风塔数据侧重局部风场变化，数值天气预报反映区域气象演变，两类数据的空间尺度差异影响特征关联精度。部分预测模型采用简单拼接方式组织输入变量，未充分识别风速、风向及空气密度之间的耦合关系，冗余信息容易干扰有效特征提取。气象预报偏差及测点缺失还会改变输入数据分布，使模型难以准确建立气象条件与短期出力之间的动态映射关系。

2.2 非线性时序特征提取不充分

风电功率序列同时包含短时随机扰动、周期性变化及持续性趋势，单一时间尺度的特征提取难以完整识别不同频率成分[1]。局部卷积结构虽然能够捕捉相邻时刻的功率变化，却容易忽略较长时间跨度内的状态依赖；循环网络处理连续序列时，历史信息的有效保留程度受网络结构及输入窗口限制。不同气象条件下，功率变化的关键时间节点并不固定，采用静态特征权重容易弱化突变前后的重要信息，导致预测曲线出现峰谷识别偏差、变化幅度低估及时间响应滞后。

2.3 复杂风况下预测误差累积

复杂地形形成的风速切变、局部湍流及尾流叠加效应，使陆上风电场实际出力偏离常规气象条件下的变化规律。强风扰动期间，气象预报偏差可能经功率非线性转换进一步放大，造成预测值与实际出力出现明显偏离。多步预测采用递推输出时，前一时刻的预测偏差会进入后续计算过程，增加远端预测误差；直接多步预测虽可避免递推误差传递，仍可能受到预测跨度增加及极端样本不足的影响。功率爬坡时段的误差集中分布，还会降低模型对出力突变幅度及发生时刻的判断精度。

3 深度学习短期风功率预测模型优化方法

3.1 多源气象数据融合及输入优化

针对气象数据时间尺度不统一及变量关联不足的问题，建立历史功率、SCADA 运行参数及数值天气预报的多源融合输入体系。以 15 分钟为统一时间步长，对高频观测数据实施窗口聚合，对低频气象预报采用符合变量物理属性的时间插值，保留预报发布时间，避免未来信息进入训练样本。数据清洗采用物理阈值约束及滑动窗口异常检测，区分设备故障、限电运行和真实功率爬坡，缺失数据依据连续缺测长度选择插补或剔除。风向变量转换为正弦、余弦分量，减少角度周期边界造成的数值跳变；结合互信息及特征重要度筛选有效输入，降低冗余变量干扰。针对风速变化向功率响应传递的时间差异，设置多阶滞后特征及滚动统计量，并按训练集参数完成标准化处理。利用时间对齐后的气象特征矩阵构建滑动样本窗口，使历史动态信息及未来气象预报形成明确的预测输入关系。

3.2 CNN-GRU 时序特征提取模型构建

针对短时功率扰动及长期状态依赖难以同步识别的问题，采用 CNN-GRU 混合网络构建陆上风电场短期出力预测模型。输入层接收历史 16 个时间步的多变量特征矩阵，对应 15 分钟采样条件下的 4 小时观测窗口。卷积模块设置不同尺度的一维卷积核，分别提取局部风速梯度、功率爬坡及气象变量协同变化特征，利用批量归一化和非线性激活提高特征表达能力。卷积输出经维度转换后输入双层 GRU 网络，借助更新门及重置门调节历史状态保留程度，识别功率变化的时间依赖关系[2]。模型采用残差连接缓解深层特征传递损失，配合 Dropout 抑制训练过拟合。输出层采用多步直接预测结构，同时生成未来 16 个时刻的功率估计值，避免递推预测引起的误差逐级传递。训练阶段采用 AdamW 优化器更新网络参数，结合验证集损失实施学习率调整及早停控制，输入窗口长度、隐藏单元数量和卷积核配置依据验证结果确定。

3.3 注意力机制驱动的预测误差优化

复杂风况下不同历史时刻对未来出力的贡献存在明显差异，可在 GRU 隐藏状态输出端引入时间注意力机制，动态识别影响预测结果的关键序列片段。利用可训练映射计算各时间步的注意力得分，经 Softmax 归一化获得权重系数，对隐藏状态进行加权聚合，增强功率突变前后有效信息的表达强度。针对不同预测时效设置独立查询向量，使 15 分钟、1 小时及 4 小时预测任务分别关注相应时间尺度的变化特征。损失函数采用平均绝对误差及均方误差的加权组合，并依据历史功率变化率设置爬坡时段样本权重，提高模型对快速升降功率过程的敏感度。为避免极端样本过度主导训练，对权重实施上限约束，并采用梯度裁剪控制参数更新幅度。模型输出结合机组装机容量进行物理边界约束，减少无效预测值；利用独立验证集调整损失权重及正则化参数，控制精度提升过程中的过拟合风险。

表 1 陆上风电场短期功率预测模型技术参数及验证配置表

配置项目	技术参数	设置值或范围	验证要求
数据采样	时间分辨率	15 min	时间戳连续
历史输入	观测窗口	16 步（4 h）	验证集调优
预测输出	预测步数	16 步（4 h）	逐时效统计
数据划分	训练/验证/测试	70%/15%/15%	按时间顺序
CNN 模块	卷积核尺寸	3、5	多尺度消融
CNN 模块	输出通道数	32、64	比较计算开销
GRU 模块	隐藏单元数	64、128	比较收敛性能
GRU 模块	网络层数	2 层	检查过拟合
注意力模块	权重归一化	Softmax	分析权重分布
正则化	Dropout 比例	0.1~0.3	验证集选择
参数优化	初始学习率	0.001	动态衰减
模型训练	批量大小	32、64	比较训练稳定性
误差评价	MAE、RMSE、nRMSE	MW、MW、%	同口径计算
功率约束	输出范围	0～额定容量	检查越界预测

表 1 中的时间分辨率、预测时效和误差评价口径参照国家标准《调度侧风电或光伏功率预测系统技术要求》（GB/T 40607—2021）及国家能源局东北监管局发布的风电功率预测技术指标与考核规定[3]；卷积核尺寸、隐藏单元数、Dropout 比例和学习率属于模型待验证参数，应结合验证集结果与消融试验确定。

4 深度学习风功率预测模型评价方案

4.1 陆上风电场预测模型训练及测试方案

模型训练与测试可采用陆上风电场连续运行数据，并按照

时间先后划分训练集、验证集和测试集，比例分别设置为 70%、15%和 15%，避免随机划分造成时序信息泄露。训练样本以 15 分钟为时间间隔构建滑动窗口，历史输入长度设为 16 个时间步，预测范围覆盖未来 4 小时。采用 AdamW 优化算法更新网络参数，设置早停机制监测验证集损失变化，防止模型过度拟合训练样本。测试阶段固定最优模型参数，恢复功率数据原始量纲，逐时刻计算预测值和实测值之间的偏差。针对不同季节及风速区间分别统计误差分布，检查训练样本覆盖程度对模型泛化性能的影响。模型收敛情况依据训练损失、验证损失及梯度变化综合判断，同时记录训练耗时、推理延迟及参数规模，评估预测精度和计算资源消耗之间的匹配程度。

4.2 不同预测模型误差指标对比方法

预测精度评价选取持续性预测、LSTM、GRU 及 CNN-GRU 作为基准模型，统一数据来源、输入窗口、预测时效及测试样本，保证不同模型之间具有可比性。采用平均绝对误差（MAE）、均方根误差（RMSE）及归一化均方根误差（nRMSE）衡量预测性能，其中 MAE 反映平均偏差水平，RMSE 突出较大误差的影响，nRMSE 以风电场装机容量为基准消除功率规模差异[4]。分别统计 15 分钟、1 小时、2 小时及 4 小时预测时效的误差指标，分析预测跨度变化引起的精度衰减。结合实际功率曲线与预测曲线的峰谷位置、爬坡斜率及残差分布，判断混合网络对动态出力特征的识别程度。采用多次独立训练记录误差均值及标准差，并设置去除注意力模块的消融试验，检验各网络结构对预测性能改善的实际贡献。

4.3 复杂风况下预测精度及稳定性评价方法

复杂风况测试依据风速变化率、湍流强度及功率爬坡幅度划分运行样本，重点考察模型面对快速气象扰动时的预测响应能力。按照统一时间窗口识别功率突升、突降及持续波动过程，分别计算各类工况的 MAE、RMSE 及最大绝对误差，避免整体平均指标掩盖局部预测偏差。针对功率爬坡事件，采用幅值误差、发生时刻偏差及变化方向识别准确率评价模型对出力突变的捕捉能力。稳定性检验采用不同季节测试集及多次重复训练结果，统计误差标准差、95%误差分位数及高误差样本占比，识别模型性能波动范围。进一步分析气象预报偏差扩大时的预测残差变化，检查注意力机制对异常扰动的适应程度，并结合单次推理耗时判断模型能否满足陆上风电场短期功率滚动预测的运行要求。

5 结语

本文围绕陆上风电场短期出力预报，梳理了多源气象数据融合、CNN-GRU 时序特征提取及注意力权重分配的实现要点，并给出多时效误差评价和复杂风况稳定性检验方案。上述设计可用于检查模型对功率波动及爬坡过程的识别能力，并检验预测时效的误差变化，为后续参数调优和滚动预测部署提供技术依据。

参考文献：

[1] 杨航.基于深度学习的风电场超短期风功率预测研究[D].华北电力大学(北京),2024.

[2] 刘璐,葛丽娟,李攀峰,等.基于深度学习的风电场短期功率预测[J].电工技术,2022,(20):69-71+120.

[3] 国家市场监督管理总局,国家标准化管理委员会.调度侧风电或光伏功率预测系统技术要求:GB/T 40607—2021[S].2021.

[4] 程凯,彭小圣,徐其友,等.基于特征选择与多层级深度迁移学习的风电场短期功率预测[J].高电压技术,2022,48(2):497-503.