

# 基于人工智能的新能源风力发电功率预测与智能调度研究

池家乐

国华巴彦淖尔(乌拉特中旗)风电有限公司 内蒙古 巴彦淖尔 015300

**摘要:** 本文介绍了三种用于风力发电功率预测的人工智能模型。神经网络模型借鉴生物结构,靠多层神经元拟合非线性关系,能自动学习复杂规律,短期预测效果佳。支持向量机模型基于统计学习理论,通过找最优超平面实现分类与回归,适合小样本、高维数据场景。LSTM和GRU深度学习模型针对时序数据处理,解决了传统模型难捕捉长时间依赖的问题,在风速波动大时预测优势明显,能显著提升预测精度与稳定性。

**关键词:** 人工智能; 风力发电; 功率预测; 智能调度

## 1 基于人工智能的新能源风力发电功率预测理论基础

### 1.1 风力发电原理及功率影响因素

风力发电先利用风力机把风能转成机械能,再经发电机将机械能转为电能。叶片在风力下旋转,带动主轴等运转,驱动发电机切割磁感线,经变流器等设备转换电能并入电网。其功率受多因素影响。风速是核心,功率与风速三次方近似成正比,低于切入或高于切出风速时功率为零,额定风速内功率稳步升至额定值。风向影响叶片迎风角度,偏离最优风向会降低功率。空气密度与温度、气压相关,密度增大,相同风速下发电功率更高<sup>[1]</sup>。风力机自身参数也关键,叶片长度决定扫风面积,气动设计影响转换效率,传动系统损耗会降低输出功率。湍流强度使风速波动,导致功率瞬时波动,影响电网稳定运行。

### 1.2 人工智能技术概述

人工智能技术模拟人类智能活动,通过学习、推理和决策解决复杂问题,在风力发电功率预测优势明显。其核心包括机器学习、深度学习、强化学习等。机器学习挖掘数据规律构建映射关系;深度学习基于多层神经网络,适配高维非线性数据;强化学习通过交互试错优化决策策略。人工智能技术有强大非线性拟合能力,能处理风力发电中各因素与功率的复杂关系;自适应学习特性可实时适配环境变化;对多源数据融合处理能力突出,能整合气象、设备运行等多类型信息,提升预测全面性与准确性,为风力发电功率预测提供有力支撑。

### 1.3 功率预测在风力发电中的重要性

功率预测对风力发电行业至关重要,关乎电网安全、企业效益和能源配置。电网运行方面,风能间歇波动使风电功率随机变化,大量风电上网会打破功率平

衡。准确预测能为调度部门提供依据,制定调度方案,平抑波动,避免弃风,保障电网稳定与供电可靠。发电企业角度,精准预测可助其制定发电计划,优化运行参数,减少设备损耗,延长寿命,降低成本。在电力市场,企业能依据预测参与交易、合理报价,提升竞争力,增加收益。能源战略上,风力发电是清洁能源关键,功率预测能提升风电消纳能力,促进多能源协同互补,推动能源结构转型,实现能源资源高效优化配置。

## 2 基于人工智能的新能源风力发电功率预测模型构建

### 2.1 数据采集与预处理

数据采集与预处理是构建人工智能风力发电功率预测模型的基础环节,数据质量直接决定模型预测精度,需建立完善的数据采集体系并实施系统的预处理流程。数据采集方面,需构建多源数据采集网络,气象数据通过气象站、卫星遥感和数值天气预报系统获取,包括风速、风向、温度、气压、湿度等核心指标,采集频率根据预测时间尺度设定,短期预测采用分钟级采集,中长期预测采用小时级采集;设备运行数据通过风力机SCADA系统采集,涵盖转速、桨距角、偏航角、发电机温度、实际输出功率等参数,实现设备运行状态的实时监测;另外,还需收集地形地貌数据、历史运维数据等辅助信息,为模型构建提供全面支撑。预处理环节首先进行数据清洗,采用 $3\sigma$ 准则、箱型图法识别并剔除风速异常突变、功率为负等异常值,通过线性插值、滑动平均法填补缺失数据;然后进行数据标准化处理,采用Min-Max标准化或Z-Score标准化将不同量纲的指标转化为统一尺度,消除量纲差异对模型训练的影响;最后进行特征工程,通过相关性分析筛选与功率强相关的特征,采用小波变换、傅里叶变换等方法提取数据时序特

征, 构建适配模型输入的特征向量, 为后续模型训练奠定高质量数据基础<sup>[2]</sup>。

## 2.2 常用人工智能功率预测模型

### 2.2.1 神经网络模型

神经网络模型在风力发电功率预测中应用广泛, 它借鉴生物神经网络结构, 靠多层神经元协同拟合非线性关系。其核心结构有输入、隐藏和输出层, 输入层接收预处理后的风速、风向等特征数据; 隐藏层用激活函数对输入做非线性转换, 可设多层提升特征提取能力, 常用激活函数有Sigmoid函数、ReLU函数等, ReLU能缓解梯度消失、提升训练效率; 输出层输出预测功率值, 用线性激活函数适配连续值输出需求。反向传播算法是其核心训练方法, 通过计算误差反向传播, 调整权值和阈值使误差收敛。该模型能自动学习复杂规律, 无需人工建模, 对非线性映射拟合效果好。实际应用中, 可调整超参数优化性能, 针对短期预测, 单或双隐层神经网络就能有较高精度, 是早期主流预测模型之一。

### 2.2.2 支持向量机模型

支持向量机模型基于统计学习理论, 通过找最优分类超平面实现分类与回归, 在小样本、高维数据的风力发电功率预测中表现出色。其原理是将输入特征用核函数映射到高维空间, 构建最优回归超平面, 让预测与实际值误差最小且保证泛化能力。常用核函数有线性、多项式和径向基核函数, 径向基核函数处理非线性数据效果好, 应用最广。该模型采用结构风险最小化准则, 平衡拟合与泛化能力, 避免过拟合, 适合数据少的场景。构建模型时, 要选好核函数并优化惩罚参数C和核函数参数 $\sigma$ , 用交叉验证确定最优组合。它对数据预处理要求高, 在中短期预测中, 能捕捉风速等因素与功率的复杂关系, 预测稳定性优于传统统计模型。

### 2.2.3 深度学习模型(如LSTM、GRU)

LSTM和GRU模型针对时序数据处理设计, 解决了传统模型难捕捉长时依赖关系的问题, 提升了风力发电功率预测精度。LSTM通过输入、遗忘和输出门的门控机制, 控制信息流动, 缓解梯度问题, 捕捉长期变化规律; GRU简化LSTM结构, 合并输入与遗忘门为更新门, 保留重置门, 在保证精度同时降低复杂度, 提升训练效率, 适合实时预测。二者以时序数据为输入, 将历史风速等按时间序列组织样本, 多层网络自动提取时序特征。预测时, 可根据时间尺度调整时序步长。训练中, 用Adam等优化算法优化损失函数, 用Dropout层防过拟合, 结合早停策略。它们处理高维、长时序数据优势明显, 在风速波动大时, 预测稳定性和精度远超传统神经

网络模型。

## 2.3 模型训练与优化

模型训练与优化是提升人工智能风力发电功率预测精度的关键环节, 通过科学的训练策略和系统的优化方法, 使模型充分学习数据规律并具备良好泛化能力。训练数据划分需遵循时序性原则, 避免数据泄露, 将预处理后的数据集按时间顺序划分为训练集、验证集和测试集, 通常训练集占比70%~80%, 用于模型参数学习; 验证集占比10%~15%, 用于超参数调整和模型选择; 测试集占比10%~15%, 用于评估模型最终预测性能<sup>[3]</sup>。训练过程采用迭代式训练方法, 将训练集数据按批次输入模型, 通过前向传播计算预测值, 采用均方误差、平均绝对百分比误差等作为损失函数, 衡量预测值与实际功率值的偏差, 再通过反向传播算法更新模型参数, 直至损失函数收敛。模型优化从多维度展开, 超参数优化采用网格搜索、随机搜索或贝叶斯优化方法, 针对学习率、隐藏层数量、神经元数量等关键超参数, 寻找最优组合; 结构优化通过增加注意力机制提升关键特征权重, 如在LSTM模型中加入注意力层, 强化风速等核心因素的影响; 正则化优化采用L1/L2正则化、Dropout层等方法, 抑制过拟合; 迁移学习优化将已训练好的模型参数迁移至新场景, 减少数据量不足时的训练成本。训练完成后, 通过测试集验证模型性能, 若未达预期则重复优化流程, 直至满足实际应用要求。

## 3 新能源风力发电智能调度策略研究

### 3.1 智能调度系统架构与关键技术

新能源风力发电智能调度系统架构采用分层分布式结构, 分为感知层、传输层、数据层、决策层和执行层, 各层协同实现调度过程的自动化、智能化。感知层作为数据采集终端, 由风力机SCADA传感器、气象监测设备、电网监测装置等组成, 实时采集风电功率、风速、电网频率、电压等运行数据, 为调度决策提供基础数据支撑; 传输层采用5G、工业以太网、物联网等通信技术, 构建高速、可靠的数据传输通道, 实现感知层数据向数据层的实时传输, 保障数据传输的时效性和完整性; 数据层由数据仓库、数据库和数据处理模块组成, 对传输层数据进行存储、整合、清洗和分析, 构建调度专用数据集, 同时实现数据的备份与安全管理; 决策层是系统核心, 采用人工智能算法库、调度模型库和决策引擎, 结合数据层提供的数据进行分析推理, 生成最优调度方案; 执行层由风力机控制器、电网调度终端、储能设备控制器等组成, 接收决策层指令并执行, 调整风力机运行状态、电网接入方式和储能设备充放电策略。

系统关键技术包括数据融合技术,通过多源数据融合提升数据可靠性;人工智能决策技术,利用神经网络、强化学习等算法实现调度方案的智能生成;实时通信技术,保障调度指令的快速传输;安全防护技术,通过加密认证、访问控制等手段保障系统数据安全;数字孪生技术,构建风电系统虚拟模型,实现调度过程的模拟与优化,提升调度系统的稳定性和可靠性。

### 3.2 智能调度策略目标与原则

新能源风力发电智能调度策略的核心目标围绕电网安全、经济运行和能源高效利用展开,形成多层次目标体系。首要目标是保障电网安全稳定运行,通过合理调度风电功率输出,维持电网功率供需平衡,控制电压、频率在允许范围内,避免风电功率剧烈波动导致的电网故障,提升电网对风电的接纳能力;经济运行目标旨在降低风电调度成本,通过优化风力机运行参数减少设备运维成本,合理安排储能设备充放电降低购电成本,优化风电并网方式提升发电收益,实现调度过程的经济性最大化;能源高效利用目标聚焦提升风电消纳率,减少弃风现象,通过风电与光伏、水电等其他能源的协同调度,实现清洁能源的全额消纳,推动能源结构转型;另外,还包括环保目标,通过优先调度风电等清洁能源,减少化石能源消耗,降低碳排放,助力“双碳”目标实现。调度策略需遵循四大核心原则,安全性原则优先保障电网和设备安全,所有调度指令需满足安全约束条件;经济性原则在安全前提下追求调度成本最低化;协调性原则实现风电与电网、储能设备、其他能源的协同运行;灵活性原则能根据风速变化、电网负荷波动等动态调整调度方案;公平性原则在多风电场上网调度中,合理分配上网电量,保障各发电企业权益;预测性原则基于精准的功率预测结果制定调度方案,提升调度的前瞻性和有效性。

### 3.3 基于人工智能的智能调度算法

基于人工智能的智能调度算法通过模拟人类决策过程,结合风电调度场景特性,实现调度方案的智能生成与动态优化,主要包括强化学习算法、神经网络算法、遗传算法等类型。强化学习算法是风电智能调度的核心算法之一,通过构建智能体、环境、奖励函数的交互模型,使智能体在与风电调度环境的持续交互中学习最优

调度策略。环境以风电功率预测值、电网负荷、储能状态等为状态空间,智能体的动作空间包括风力机功率调整、储能充放电控制等,奖励函数综合电网安全约束、经济成本、消纳率等指标设计,通过Q-Learning、深度强化学习等方法训练智能体,实现动态场景下的实时调度优化。神经网络算法通过构建多层神经网络模型,学习历史调度数据中的功率输出与调度效果间的映射关系,输入风电功率预测值、电网负荷等数据,输出最优调度方案。可结合注意力机制强化关键因素影响,提升调度精度,适用于中短期调度场景<sup>[4]</sup>。遗传算法作为进化算法的代表,通过模拟生物遗传变异过程,将调度方案编码为染色体,通过选择、交叉、变异操作迭代优化种群,以调度成本最低、消纳率最高等为适应度函数,筛选最优调度方案。该算法全局搜索能力强,能有效避免局部最优解,适用于复杂约束条件下的中长期调度规划。实际应用中,常采用多算法融合策略,如强化学习结合神经网络提升决策精度,遗传算法优化神经网络初始参数,形成兼具实时性和全局优化能力的调度算法体系。

### 结束语

随着风力发电行业的蓬勃发展,精准的功率预测愈发关键。神经网络、支持向量机以及LSTM、GRU等深度学习模型,凭借各自独特的优势,在风力发电功率预测领域发挥着重要作用。未来,随着技术的不断进步与创新,这些模型将进一步优化与完善,为风力发电的高效利用和电网的稳定运行提供更有力的支持,推动清洁能源产业迈向新的发展阶段。

### 参考文献

- [1]张伟.人工智能在抽水蓄能电站优化调度中的应用研究[J].低碳世界,2025,15(08):64-66.
- [2]谢振钟.新能源电力系统智能调度优化方法研究[J].光源与照明,2025,(07):245-247.
- [3]胡海青,姚健,俞雪蕾.基于人工智能的风电功率预测与优化调度综述[J].电力系统保护与控制,2021,49(6):94-102.
- [4]陈尚扬,陈晓娇.基于深度学习和智能优化算法的风电功率预测与优化调度研究[J].电力系统保护与控制,2020,48(9):112-119.