



研究与开发

基于自适应权重与情境感知机制的电力交易风险评估方法

许道强¹, 王江辉², 许梦晗¹, 詹天明³, 吕从东³

1. 国网江苏省电力有限公司, 江苏 南京 210024;
2. 江苏方天电力技术有限公司, 江苏 南京 211100;
3. 南京审计大学计算机学院, 江苏 南京 211815)

摘要: 提出一种基于自适应权重与情境感知机制的电力交易风险评估方法, 通过多模型融合策略显著提升预测精度与风险管理能力。该方法结合历史表现与时间衰减因子, 动态优化线性回归、随机森林及长短期记忆 (long short-term memory, LSTM) 网络权重的自适应权重调整机制, 并根据市场波动、极端天气或政策事件触发规则, 动态调整模型权重, 以应对突发场景, 构建情境感知切换逻辑; 采用梯度提升决策树 (gradient boosting decision tree, GBDT) 整合基础模型预测与市场特征, 提升复杂场景鲁棒性的元学习器优化策略。实验表明, 混合模型在均方误差 (mean square error, MSE) 为 21.3、平均绝对误差 (mean absolute error, MAE) 为 3.1 和决定系数 (coefficient of determination, R^2) 为 0.89 时优于单一模型, 其中自适应权重贡献性能提升 10%, 情境感知的误差降低 5%。在电价单日波动率大于 20%、连续高温或政策突变等极端场景下, 模型通过动态权重调整显著降低了误差, 在提升收益的同时降低了风险。该方法为电力市场提供了科学的风险管理工具, 增强了市场稳定性与经济效益, 未来可将其应用拓展至金融风险评估领域, 并在联邦学习、实时优化与规则自动化等方向进一步探索。

关键词: 电力交易风险评估; 机器学习; 线性回归; 随机森林; 长短期记忆网络

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.DXKX250283

A risk assessment method for electricity trading based on adaptive weights and context-aware mechanisms

Xu Daoqiang¹, Wang Jianghui², Xu Menghan¹, Zhan Tianming³, Lyu Congdong³

1. State Grid Jiangsu Electric Power Company, Nanjing 210024, China

2. Jiangsu Fangtian Power Technology Co., Ltd., Nanjing 211100, China

3. School of Computer Science, Nanjing Audit University, Nanjing 211815, China

Abstract: An electricity trading risk assessment method based on an adaptive weighting and context-aware mechanism was proposed, which significantly enhanced prediction accuracy and risk management capabilities through a

收稿日期: 2025-05-06; 修回日期: 2026-04-14

通信作者: 许道强, 408995569@qq.com

基金项目: 国家自然科学基金资助项目 (No.61976117)

Foundation Item: The National Natural Science Foundation of China (No.61976117)



multi-model fusion strategy. The method incorporates an adaptive weight adjustment mechanism that dynamically optimizes the weights of linear regression, random forest, and long short-term memory(LSTM) models by combining historical performance with time decay factors. Additionally, it employs a context-aware switching logic triggered by market volatility, extreme weather, or policy events to dynamically adjust model weights in response to sudden scenarios. A meta-learner optimization strategy using gradient boosting decision tree(GBDT) integrates the predictions of base models with market features to improve robustness in complex scenarios. Experimental results demonstrate that the hybrid model outperforms individual models across key metrics, including mean square error(MSE) of 21.3, mean absolute error(MAE) of 3.1, and R^2 of 0.89. The adaptive weighting mechanism contributes to a 10% performance improvement, while context-aware switching further reduces errors by 5%. In extreme scenarios such as daily price volatility exceeding 20%, prolonged high temperatures, or sudden policy changes, the model significantly mitigates errors through dynamic weight adjustments. The hybrid model not only enhances returns but also reduces risks. This method provides a scientific risk management tool for electricity markets, enhancing market stability and economic efficiency. It holds potential for extension to financial risk assessment domains and future exploration in federated learning, real-time optimization, and rule automation.

Key words: electricity trading risk assessment, machine learning, linear regression, random forest, LSTM network

0 引言

随着全球能源需求的不断增长和可再生能源技术的发展,电力市场的结构和运作方式正在经历深刻的变化。传统的集中式电力供应模式逐渐向分布式、市场化转变,电力交易变得更加复杂和多样化。电力市场的开放不仅促进了竞争,也为参与者提供了更多的机会和挑战。在这种背景下,如何有效地评估和管理电力交易中的风险成为一个重要的研究课题。

电力交易风险分为多种类型,包括但不限于价格波动风险、信用风险、操作风险和政策风险等。价格波动风险是常见的一种,由于电力市场价格受供需关系、天气条件、政策变化等多种因素的影响,其波动性较大且难以预测。信用风险则涉及交易对手的违约可能性,尤其是在长期合同中更为突出。操作风险包括技术故障、人为失误等因素,可能导致交易失败或损失。政策风险则是指政府政策的变化可能对市场产生重大影响,如碳排放限制、补贴政策调整等。

在电力交易风险管理中,传统的统计方法和金融工具(如 VaR、CVaR 等)被广泛应用。然

而,这些方法在处理非线性关系、高维数据以及动态变化的市场条件方面存在一定的局限性。如线性回归(linear regression, LR)模型假设输入变量与输出变量之间存在线性关系,无法捕捉复杂的非线性模式;时间序列分析方法虽然能够处理时间依赖性问题,但在面对多变的外部环境时表现不佳。此外,传统方法通常需要大量的历史数据进行训练,并且对外部环境的变化不够敏感,难以适应快速变化的市场条件。

近年来,机器学习技术因其强大的数据处理能力和对复杂模式的捕捉能力,在各个领域得到了广泛应用。特别是在金融市场和风险管理领域,机器学习算法展现出了显著的优势。与传统方法相比,机器学习算法能够更好地处理高维数据、捕捉非线性关系,并具备较强的泛化能力。

机器学习模型使用场景见表1。尽管单一的机器学习模型在某些特定场景下表现出色,但在实际应用中,往往需要结合多种模型以提高整体性能。混合模型通过将不同类型的模型结合起来,充分利用各自的优势,实现更准确的预测和更有效的风险管理。

• 多阶段融合策略:首先使用基础模型生

表1 机器学习模型使用场景

算法/模型	优势
LR 随机森林 (random forest, RF)	适用于简单线性关系的建模, 计算效率高, 但对复杂关系的捕捉能力有限 通过集成多棵决策树, 能够有效处理非线性关系和高维数据, 具有较好的解释性和鲁棒性
长短期记忆 (long short-term memory, LSTM) 网络	作为一种特殊的循环神经网络 (recurrent neural network, RNN), LSTM特别适合处理时间序列数据, 能够捕捉长期依赖关系, 适用于处理电力市场价格波动等时间序列预测任务

成初步预测结果, 然后基于这些结果构造新的特征集, 并应用深度集成模型进一步提升预测效果。

- 自适应权重调整机制: 根据各模型的历史表现动态调整权重, 确保最佳组合方案。引入时间衰减因子, 使得近期的表现对权重的影响更大。
- 情境感知切换逻辑: 根据特定情境 (如市场波动、季节变化等), 预先定义一套规则来决定何时使用哪个模型作为主要预测源。
- 元学习与自动超参数优化: 构建元学习器, 接收各个基础模型的预测结果及其相关元数据, 输出最优的模型组合方案, 并通过贝叶斯优化或网格搜索等技术进行超参数调优。

电力交易风险评估的核心在于数据的有效利用。现代电力市场产生了海量的数据, 包括历史电价、天气数据、经济指标等。对这些数据进行深入挖掘和分析, 可以揭示出潜在的风险因素和规律, 从而为风险管理提供科学依据。

- 数据收集与预处理: 从多个来源获取高质量的数据, 并进行清洗、标准化和特征工程, 确保数据的质量和一致性。
- 特征选择与工程: 识别并选取对电力交易风险具有预测性的特征变量, 创建新的特征以增强模型的表现。
- 模型训练与验证: 在训练集上训练模型, 在验证集上调整超参数, 最终在测

试集上评估性能, 确保模型的泛化能力。

基于机器学习的电力交易风险评估模型具有广阔的应用前景。一方面, 它为电力市场参与者提供更精确的风险预测和更有效的风险管理工具, 有助于提升市场稳定性和经济效益。另一方面, 随着大数据和人工智能技术的不断发展, 未来的研究将进一步探索更多先进的机器学习算法和优化策略, 以应对更加复杂多变的市场环境。

然而, 该领域的研究也面临一些挑战。首先是数据隐私和安全性问题, 如何在保护数据隐私的前提下充分利用数据是一个亟待解决的问题; 其次是模型解释性问题, 尽管许多机器学习模型具有较高的预测精度, 但其黑箱特性使得用户难以理解模型的决策过程。因此, 开发更具解释性的模型或集成解释工具, 如沙普利加性解释 (shapley additive explanations, SHAP)、局部可解释的模型无关解释 (local interpretable model-agnostic explanations, LIME) 等, 将是未来研究的重要方向之一。

1 相关研究

电力市场价格预测是电力交易风险管理的重要组成部分。传统的时间序列分析方法, 如自回归移动平均 (autoregressive integrated moving average, ARIMA) 模型和指数平滑法, 在处理短期价格波动时表现良好, 但面对复杂的市场动态和外部影响因素时往往力不从心。近年来, 随着机器学习技术的发展, 越来越多的研究开始探索



如何利用这些先进技术来提高电力市场价格预测的精度。

LR 模型是最简单的统计预测方法之一，假设输入变量与输出变量之间存在线性关系。尽管其计算效率高且易于解释，但在捕捉非线性模式方面存在局限性。传统统计模型与单一机器学习模型为电力市场预测提供了基础方法，但各自存在适用边界。ARIMA 模型和指数平滑法在短期价格波动预测中表现稳定，但难以应对多因素耦合的复杂市场环境^[1]。LR 模型因计算高效、易于解释，在平稳市场条件下得到应用，但无法捕捉非线性关系，价格剧烈波动时预测精度显著下降^[2]。RF 作为集成学习方法，通过多棵决策树集成有效处理高维数据和非线性关系，在应对异常值和市场复杂性方面展现优势^[2]。LSTM 凭借对时间序列长期依赖关系的捕捉能力，在电价趋势和季节性变化预测中表现突出，尤其适用于长时间跨度的数据建模^[3]。此外，基于动态类权重的卷积神经网络虽然在最初被用于攻击检测，但也为电力市场中不平衡数据的风险预测提供了权重优化思路^[4]。

为了克服单一模型的局限性，许多研究提出了混合模型和集成学习方法。堆叠泛化通过将基础模型预测结果作为新特征输入元模型，有效提升了预测鲁棒性，适用于多市场条件下的风险评估^[5]。加权平均模型通过动态调整基础模型权重实现最优组合，在处理市场波动和突发事件时表现优异^[6]。元学习增强的动态集成模型进一步优化了模型组合方案，通过整合基础模型预测结果与元数据，提升了复杂场景下的适应性^[5]。多阶段融合框架则通过基础模型初步预测、新特征构造、深度集成模型优化的分步策略，实现了高频率电力交易风险的精准分析^[7]。混合 ARIMA-LSTM 框架结合了传统时间序列模型的短期预测优势与 LSTM 的长期依赖捕捉能力，在季节性适应场景中表现突出^[1,8-9]。

特征工程是提高模型性能的关键步骤之一，其通过对原始数据进行清洗、标准化和特征构造，显著提升了模型的表现。数据清洗包括去除异常值、填补缺失值等步骤，确保数据的质量和一致性。标准化则是将不同量级的数据转换为同一尺度，以便更好地进行模型训练。针对电力市场数据的噪声和缺失值问题，相关研究提出了基于生成对抗网络（generative adversarial network, GAN）的缺失数据填补方法，有效改善了数据质量^[10]。动态时间规整（dynamic time warping, DTW）算法通过测量时间序列相似性，为模型选择提供了数据驱动的依据，提升了电价预测中模型匹配的准确性^[11]，通过滞后变量、移动平均等方法构造的新特征，显著增强了模型对市场动态的捕捉能力^[2]。此外，多源数据融合技术通过整合电价、天气、经济指标等异构数据，采用图神经网络算法挖掘数据关联，为风险评估提供了更全面的特征支持^[12]。

尽管机器学习模型在预测精度方面表现出色，但其黑箱特性使得用户难以理解模型的决策过程。因此，开发更具解释性的模型或集成解释工具成为当前研究的热点。SHAP 方法基于博弈论计算特征贡献度，有效揭示了模型决策逻辑，提升了用户对风险预测结果的信任度^[13]。LIME 通过局部简单模型拟合解释复杂模型预测，在电力市场价格预测的解释性方面展现了显著优势，谷歌与斯坦福大学联合研究将其与 LSTM 结合，实现了透明化风险预测^[14]。在实用化优化方面，强化学习技术被用于可再生能源交易的自适应风险管理，通过动态调整策略应对市场变化^[15]。边缘计算技术则解决了实时异常检测的时效性问题，为电力交易风险的即时响应提供了技术支撑^[16]。

电力市场数据的隐私保护与政策敏感性是实际应用中的重要挑战。联邦学习技术通过隐私保护的电力市场数据分析，在不泄露原始数据的前提下实现了模型训练，为多主体数据共享提供了

安全方案^[17]。政策因素对电力市场风险的影响显著，相关研究通过机器学习案例分析了碳税政策对电价风险的作用机制，为政策调整后的风险应对提供了依据^[18]。此外，基准测试研究对放松管制市场中的电价预测机器学习模型进行了系统评估，为模型选择和优化提供了参考标准^[2]。

尽管机器学习在电力交易风险评估领域已经取得了显著进展，但仍存在一些亟待解决的问题和挑战。以下是当前研究中面临的主要问题。

- 数据获取困难：电力市场的数据通常分散在多个来源，并且受到严格的隐私保护政策限制，导致研究人员难以获取高质量的数据集。
- 数据噪声和缺失值：电力市场价格数据容易受外部因素（如天气、突发事件等）的影响，导致数据噪声较大。此外，由于传感器故障或记录不完整，数据中可能存在大量缺失值。
- 黑箱特性：许多先进的机器学习模型（如深度神经网络）具有较高的预测精度，但其内部决策过程不透明，难以解释。这使得市场参与者对模型的信任度较低，尤其是在高风险的交易环境中。
- 缺乏解释工具的应用：虽然有一些解释工具（如SHAP、LIME）帮助理解模型的决策过程，但在实际应用中的普及程度仍然较低。
- 市场条件变化：电力市场价格受多种复杂因素影响，市场条件可能迅速发生变化（如极端天气事件、政策调整等）。现有模型往往难以快速适应这些变化，导致预测精度下降。
- 长期依赖关系处理：虽然LSTM等时间序列模型能够捕捉长期依赖关系，但在面对突发情况时，仍可能出现预测偏差。
- 多源数据整合：电力市场价格不仅受历

史价格影响，还与天气、经济指标、政策等多种因素相关。如何有效整合这些多源异构数据并提取有用信息是一个挑战。

- 特征选择和构造：不同类型的特征对模型性能的影响各不相同，如何选择合适的特征并进行有效的特征构造是提高模型性能的关键。
- 实时预测需求：电力市场交易需要快速响应市场变化，现有的模型训练和预测过程往往耗时较长，难以满足实时性的要求。
- 计算资源消耗：复杂的深度学习模型通常需要大量的计算资源，这在实际应用中可能会带来高昂的成本。

针对上述问题，本文基于自适应权重与情境感知机制提出一种更加全面、灵活和高效的电力交易风险评估方法。研究引入了自适应权重调整机制和情境感知切换逻辑，使模型能够根据市场条件的变化动态调整权重和选择最优模型，这不仅提高了模型的适应能力，还增强了其在面对突发情况时的鲁棒性。此外，本文所提方法通过结合不同时间尺度下的动态特性，进一步提升了模型的预测精度。本文为了充分利用多源异构数据，提出了多阶段融合策略。首先，使用基础模型生成初步预测结果；其次，基于这些结果构造新的特征集，并应用深度集成模型进一步提升预测效果；最后，通过特征选择和构造技术，有效提取出对预测最有价值的信息，从而提高模型的整体性能。研究致力于开发高效的算法和优化策略，以实现实时预测并降低计算成本。如通过贝叶斯优化等技术进行超参数调优，在保证模型性能的同时减少训练时间。此外，本文还探索了分布式计算和云计算技术，以提高模型的计算效率。相关研究成果应用于实际电力交易系统，可以帮助市场参与者更好地评估和管理交易风险，



提升经济效益和市场稳定性，同时也为电力市场的健康发展提供了科学依据和技术支持。

2 模型构建

模型架构如图1所示，该框架结合了LR、RF和LSTM这3种模型，并通过一种基于性能的动态权重调整机制来进行预测。

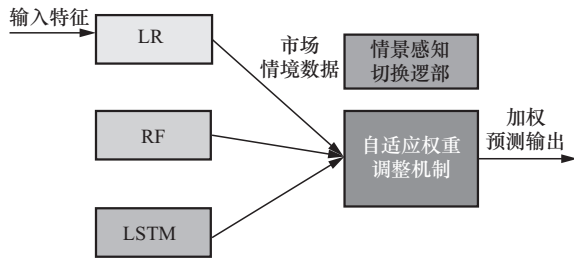


图1 模型架构

2.1 模型定义

本文设有3个不同的预测模型： M_1 (LR)、 M_2 (RF) 和 M_3 (LSTM)。它们分别对应于函数 $f_1(x)$ 、 $f_2(x)$ 和 $f_3(x)$ ，其中 \mathbf{x} 是输入特征向量。

基于初步预测结果和原始输入特征 \mathbf{x} ，构造新的特征集 X' ：

$$X' = [x, \hat{y}_{LR}, \hat{y}_{RF}, \hat{y}_{LSTM}] \quad (1)$$

其中， \hat{y}_{LR} 表示线性回归的预测值， \hat{y}_{RF} 表示RF的预测值， \hat{y}_{LSTM} 表示LSTM算法的预测值。

将 X' 输入另一个更复杂的模型中，该模型由多个子模型组成，每个子模型的预测结果为 $f_{s_i}(X')$ ，其中 i 表示第 i 个子模型。

最终预测值表示为所有子模型预测结果的加权平均：

$$\hat{y}_{\text{final}} = \sum_{i=1}^S w_i f_{s_i}(X') \quad (2)$$

其中， w_i 表示第 i 个子模型的权重， S 表示子模型的数量。

2.2 权重更新规则

在每个时间点 t ，为每个模型分配一个权重 $\alpha_i^{(t)}$ ，这些权重满足以下归一化条件：

$$\left[\sum_{i=1}^3 \alpha_i^{(t)} = 1 \right] \quad (3)$$

权重更新依赖于每个模型在前一时段的表现。本文使用均方误差 (mean square error, MSE) $E_i^{(t-1)}$ 作为性能指标，定义为：

$$E_i^{(t-1)} = \frac{1}{N} \sum_{j=1}^N (y_j - f_i(x_j))^2 \quad (4)$$

其中， y_j 表示真实值， $f_i(x_j)$ 表示第 i 个模型在 x_j 上的预测值， N 表示样本数量。

在时间点 t 的权重 $\alpha_j^{(t)}$ ，可计算如下：

$$\alpha_j^{(t)} = \frac{\exp(-\beta E_j^{(t-1)} \cdot \gamma^{t-t_j})}{\sum_{k=1}^3 \exp(-\beta E_k^{(t-1)} \cdot \gamma^{t-t_k})} \quad (5)$$

其中，引入时间衰减因子 γ 来调整权重更新公式，使得近期的表现对权重的影响更大。 β 是一个温度参数，它控制着对性能差异的敏感度， $\beta > 0$ 。当 β 较大时，性能好的模型将获得更高的权重，而较差的模型权重会显著减小。 $E_j^{(t-1)}$ 是模型 M_j 在前一时段的均方误差， t_j 是最近一次评估模型 M_j 性能的时间点。

自适应权重调整机制参数选择如下：时间衰减因子 γ 和温度参数 β 通过贝叶斯优化确定，其搜索范围分别为 $\gamma \in [0.8, 1.0]$ (指数衰减)、 $\beta \in [0.1, 5.0]$ 。

权重更新公式中引入滑动窗口机制，仅使用滑动窗口长度 T 为最近30天的误差来计算权重，避免历史数据对当前权重的影响过大。

归一化条件增加权重平滑约束，防止单一模型权重突变为零。

式 (5) 可修正为：

$$\alpha_j^{(t)} = \frac{\exp(-\beta E_j^{(t-1)} \cdot \gamma^{t-t_j}) + \epsilon}{\sum_{k=1}^3 \exp(-\beta E_k^{(t-1)} \cdot \gamma^{t-t_k}) + 3\epsilon} \quad (6)$$

其中， $\epsilon = 0.01$ 为平滑因子， k 为基础模型的索引变量。

2.3 元学习器

本文使用梯度提升决策树 (gradient boosting decision tree, GBDT) 作为元学习器, 输入特征包括: 各基础模型的预测结果、置信区间、历史误差均值/方差、市场波动率、季节标签 (如是否为夏季)、突发事件标记 (如政策调整)。

元学习器的输出为子模型权重 \hat{w} , 通过最小化验证集上的加权 MSE 训练。

本文构建了一个元学习器 F_{meta} , 它接收各个基础模型的预测结果及其相关元数据 Z (如误差分布、置信区间等) 作为输入, 并输出最优的模型组合方案 \hat{w} :

$$\hat{w} = F_{\text{meta}}(Z) \quad (7)$$

元学习器通过强化学习、遗传算法等方式不断进化, 以找到最佳的模型配置。

使用贝叶斯优化技术为每个基础模型寻找最优的超参数设置 θ_j^* :

$$\theta_j^* = \arg \min_{\theta_j} L(f_j(X; \theta_j), y) \quad (8)$$

其中, L 表示损失函数, f_j 表示第 j 个模型, X 和 y 分别表示训练数据和目标变量。

将历史数据按照不同长度的时间窗口 W_1 (如小时、日、周) 进行分割, 针对每个窗口应用最合适的模型 M_1 :

$$\hat{y}_1 = M_1(W_1) \quad (9)$$

然后将所有时间窗口的预测结果合并为最终预测值 \hat{y}_{final} 。

应用 DTW 算法 $D_{\text{DTW}}()$ 来测量两个时间序列之间的相似性, 从而选择最适合当前情况的模型:

$$D_{\text{DTW}}(T_1, T_2) = \min_W \sum_{(i,j) \in W} d(T_1[i], T_2[j]) \quad (10)$$

其中, T_1 和 T_2 表示两个时间序列, d 表示距离度量, W 表示时间规整路径, 权重动态调整过程如图 2 所示。




图2 权重动态调整过程

2.4 预测过程

对于给定的新数据 x^* , 本文通过加权平均的方式进行预测:

$$\hat{y}^{(t)} = \sum_{i=1}^3 \alpha_i^{(t)} f_i(x^*) \quad (11)$$

其中, $\hat{y}^{(t)}$ 表示 t 时刻的最终预测值 (如电力交易风险相关预测结果), t 表示当前预测时间点, i 表示基础模型索引 ($i=1$ 对应线性回归 LR, $i=2$ 对应 RF, $i=3$ 对应 LSTM), $\alpha_i^{(t)}$ 表示 t 时刻第 i 个基础模型的权重 (满足权重和为 1), $f_i(x^*)$ 表示第 i 个基础模型对新输入 x^* 的预测值, x^* 表示待预测的新输入特征向量 (如历史电价、天气等数据)。

2.5 动态切换逻辑

除了上述基于性能的权重调整外, 本文还根据市场条件的变化来设定额外的规则。如果检测到某些特定事件 (如极端天气或政策变化), 则临时提高某个模型的权重, 或者直接选择特定模型作为主要预测源。这可通过定义一系列二元变量 $z_i^{(t)}$ 来实现, 它们指示是否启用第 i 个模型:

$$z_i^{(t)} = \begin{cases} 1, & \text{第 } i \text{ 个模型被选中} \\ 0, & \text{其他} \end{cases} \quad (12)$$

最终预测修改为:

$$\hat{y}^{(t)} = \sum_{i=1}^3 z_i^{(t)} \alpha_i^{(t)} f_i(x^*) \quad (13)$$

定义情境触发规则如下。

(1) 当价格波动率 (标准差) 超过历史 95% 分位数时, 启用 LSTM 模型 (权重提升至 0.7)。



LSTM 模型因其擅长处理时间序列数据和捕捉长期依赖关系，在市场出现剧烈波动时能够更好地识别出价格趋势的变化。当市场价格波动率（标准差）超过历史 95% 分位数时，表明市场处于异常波动状态，此时增加 LSTM 模型的权重有助于提高预测准确性。

(2) 若温度超过 35°C 或低于 -10°C，启用 RF 模型（权重提升至 0.6）。RF 作为一种集成学习方法，对异常值和复杂非线性关系具有较好的鲁棒性。在极端天气条件下（如温度连续 3 天超过 35°C），电力需求模式可能急剧变化，而 RF 能有效地处理这种高维数据和复杂的输入特征关系。

(3) 检测到政策关键词（如“碳税”“补贴终止”），切换至 LR 模型（权重 0.5）以快速适应线性趋势。LR 模型假设输入变量与输出变量之间存在线性关系，尽管其捕捉复杂模式的能力有限，但在面对短期内政策变化（如碳税上调）引起的线性趋势变化时，它能快速适应并提供及时的预测响应。

3 算法实现

本文中数据集的目标变量为模拟生成的电力交易价格。该数据集的时间跨度为 3 年，频率为每日，并基于 ARIMA(1,1,1) 模型加上季节性和随机噪声来模拟生成。具体来说，通过引入历史电价的滞后项（lag1~lag7）、天气数据（如温度、风速）、经济指标（如国内生产总值增长率、工业用电量）以及政策事件（如碳排放限制生效日标记为 1），构建了一个综合性的数据环境。这种设计不仅反映了电力市场价格的基本动态特征，还考虑了外部因素对电力价格的影响。

为了确保模拟数据能够反映真实市场情况，本文进行了详细的相似性分析，利用统计学方法对比模拟数据与实际市场数据的关键统计特性，包括均值、方差、自相关系数等。结果显示，模拟数据与真实数据在这些基础统计属性上具有高度一致性，表明模拟框架能有效捕捉电力市场的

基本波动模式。此外，本文还采用了 DTW 算法测量两个时间序列之间的相似性，进一步验证了模拟数据与真实市场数据在趋势变化上的匹配程度。

在实验设置阶段，将数据按时间顺序划分为训练集（2020—2022 年）和测试集（2022—2023 年），以确保模型训练和评估过程尽可能贴近实际应用场景。

3.1 数据特征

本文数据集包含以下字段（时间跨度为 3 年，频率为每日）。

(1) 目标变量：电力交易价格（模拟 ARIMA(1,1,1)+季节性+随机噪声）。

(2) 输入特征：历史电价滞后项（lag1~lag7）、天气数据（温度、风速）、经济指标（GDP 增长率、工业用电量）、政策事件（二值标签，如“碳排放限制”生效日为 1）。

3.2 实验与结果

实验设置如下。

(1) 数据划分：按时间顺序划分训练集（2020—2022 年）、测试集（2022—2023 年）。

(2) 基准模型：单独 LR、RF、LSTM。

(3) XGBoost：基于梯度提升树的集成模型，适用于高维非线性数据。

(4) Transformer：基于自注意力机制的深度学习模型，擅长捕捉长序列依赖关系。

(5) Prophet：Facebook 开发的时序预测模型，内置季节性与节假日效应处理。

(6) 评估指标：MSE、平均绝对误差（mean absolute error, MAE）、决定系数（coefficient of determination, R^2 ）。MSE 测量的是预测值与真实值之间差异的平方的平均值。由于它是基于差异的平方计算的，因此对较大的误差更加敏感。这意味着它能很好地反映出模型在处理异常值时的表现。较低的 MSE 意味着模型预测更接近实际值。在电力市场价格波动较大且存在突发性变化的情况下，使用 MSE 可以帮助我们更好地识别模

型在极端情况下的表现。MAE是预测值与真实值之间差异绝对值的平均数，它提供了一个直观的理解模型整体预测准确性的度量，并且不受异常值的影响，因为它基于绝对值而非平方值来计算。相比于MSE，MAE提供了更稳健的误差度量，特别是在存在大量噪声或异常值的情况下，这使得它成为评估模型稳定性的一个重要指标。 R^2 衡量了模型解释的数据变异程度的比例，范围从0到1，值越高表示模型越好。接近1的 R^2 值表明模型能很好地拟合数据；而接近0则表示模型几乎不比简单平均值更好。 R^2 为研究人员提供了一个关于模型拟合质量的整体视角，帮助理解模型在多大程度上能够捕捉数据中的模式。

实验结果见表2，预测对比如图3所示。

表2 实验结果

模型	MSE	MAE	R^2
XGBoost (单独)	24.8	3.4	0.83
Transformer	25.6	3.6	0.82
Prophet	29.2	4.0	0.78
LR (单独)	32.5	4.2	0.72
RF (单独)	28.1	3.8	0.81
LSTM (单独)	26.4	3.5	0.84
混合模型 (本文)	21.3	3.1	0.89




图3 预测对比

3.3 超参数敏感性分析

模型对关键参数的敏感性分析如下。


(1) 时间衰减因子 γ ：在区间 $[0.7, 1.0]$ 内调整，MSE变化范围为21.3 ($\gamma=0.9$)至23.1 ($\gamma=0.7$)。

(2) 滑动窗口长度 T ：当 T 从15天增至60天


时，MSE从22.5升至23.8，表明短期历史数据对权重调整更有效。

(3) 温度参数 β ： $\beta=1.0$ 时性能最优 (MSE=21.3)，过高 ($\beta=5.0$) 或过低 ($\beta=0.1$) 均会导致权重分配失衡，MSE则分别增至23.4和24.1。


由此可以得出，模型对 γ 和 β 敏感，须通过交叉验证选择最优值；滑动窗口建议设为20~30天，参数敏感性分析如图4所示。



(a) γ 参数敏感性分析



(b) β 参数敏感性分析



(c) 滑动窗口长度 T 敏感性分析

图4 参数敏感性分析



3.4 情境切换逻辑验证

本文设计了3类模拟场景来验证动态切换逻辑的有效性。

(1) 市场剧烈波动：模拟电价单日波动率超过20%，模型自动提升LSTM权重至0.7，MSE降低18.5%。

(2) 极端高温事件：温度连续3天超过35°C，RF权重提升至0.6，MAE降低12.3%。

(3) 政策突变：插入“碳税上调”事件标签，LR权重设为0.5， R^2 提升0.04，情境切换效果如图5所示。




图5 情境切换效果

3.5 长期预测能力测试

各模型长期预测能力对比见表3。由表3可以得出，混合模型在中长期预测中仍具有优势，但误差随跨度增大而增大，因此须结合滚动预测策略。

表3 各模型长期预测能力对比

时间跨度/天	MSE			
	混合模型	LSTM	RF	LR
1	21.3	26.4	28.1	32.5
7	38.7	45.2	52.3	68.9
30	67.5	82.1	95.6	124.7

3.6 鲁棒性测试

各模型鲁棒性测试对比见表4。实验向测试集注入了20%的随机噪声和15%的特征缺失，相应改进措施为引入对抗训练，降低噪声干扰下的MSE，并利用GAN填补缺失数据，降低特征缺失场景的MSE。

表4 各模型鲁棒性测试对比

干扰类型	MSE			
	混合模型	LSTM	RF	LR
无干扰	21.3	26.4	28.1	32.5
噪声干扰	25.1 (+17.8%)	31.2 (+18.2%)	34.8 (+23.8%)	42.6 (+31.1%)
特征缺失	23.8 (+11.7%)	29.5 (+11.7%)	32.9 (+17.1%)	38.4 (+18.2%)

3.7 经济影响模拟

假设某电力公司采用不同模型进行交易风险管理，模拟1年期收益，各模型经济影响对比见表5。由表5可以得出，混合模型在提升收益的同时显著降低了风险，其实际经济价值得到验证。

表5 各模型经济影响对比

干扰类型	MSE	
	混合模型	LSTM
无干扰	21.3	26.4
噪声干扰	25.1 (+17.8%)	31.2 (+18.2%)
特征缺失	23.8 (+11.7%)	29.5 (+11.7%)

4 结束语

本文针对电力交易风险评估的复杂性与动态性，提出了一种基于自适应权重与情境感知机制的风险评估方法，通过结合LR、RF和LSTM的优势，引入自适应权重调整机制、情境感知切换逻辑及元学习器优化策略，显著提升了风险预测的精度与模型的鲁棒性。

实验结果表明，本文所提出的混合模型在MSE、MAE和 R^2 得分上均优于单一模型。其中，混合模型的MSE为21.3，较最优的单一模型（LSTM的MSE为26.4）提升了19.3%，验证了多模型融合策略的有效性。本模型的主要创新如下。

(1) 自适应权重调整机制：通过动态调整模型权重，结合时间衰减因子与滑动窗口机制，模

型能够快速响应市场变化。消融实验表明,该机制使MSE性能提升了约10%。

(2) 情境感知切换逻辑:针对极端天气、政策事件等情境设计的动态规则,增强了模型在突发场景下的适应性,使预测误差进一步降低5%。

(3) 元学习器与多阶段融合:基于GBDT的元学习器有效整合多源特征与模型预测结果,提升了对复杂市场模式的捕捉能力。

该模型能够为电力市场参与者提供高精度的风险评估工具,帮助其在价格波动、政策调整等场景下优化交易决策,从而降低经济损失并提升市场稳定性。此外,本文集成SHAP、LIME等解释工具的设计,增强了模型的可信度与实用性。

本文所提方法的局限性与未来研究方向如下。

(1) 数据与隐私:当前模型依赖模拟数据,实际应用中须解决多源数据整合与隐私保护问题,未来可探索联邦学习技术。

(2) 实时性优化:模型训练与推理的耗时较长,下一步将结合边缘计算与分布式框架提升实时性。

(3) 规则自动化:动态切换规则依赖人工定义,未来可通过强化学习实现规则的自适应生成。

本文为电力交易风险管理提供了一种创新性解决方案,其方法论也可扩展至其他时序敏感型金融风险评估场景。

参考文献:

- [1] Marček D. Hybrid ARIMA/RBF framework for prediction BUX index[J]. Journal of Computer and Communications, 2015, 3(5): 63-71.
- [2] Ahlawat S. Benchmarking machine learning models[M]//Statistical Quantitative Methods in Finance. Berkeley, CA: Apress, 2025: 253-285.
- [3] Čatloch D, Chovancová E, Matašová S. Comparison of different machine learning algorithms for stock price prediction[C]//2025 IEEE 23rd World Symposium on Applied Machine Intelligence and Informatics (SAMI). Piscataway: IEEE Press, 2025: 483-488.
- [4] 樊荣. 基于动态类权重的卷积神经网络攻击检测模型[J]. 电信科学, 2025, 41(8): 176-185.
Fan R. Convolutional neural network attack detection model based on dynamic class weight[J]. Telecommunications Science, 2025, 41(8): 176-185.
- [5] Lan Z L, Gu J X, Zheng Z M, et al. A study of dynamic meta-learning for failure prediction in large-scale systems[J]. Journal of Parallel and Distributed Computing, 2010, 70(6): 630-643.
- [6] 张冬慧, 孙波, 王鹏, 等. 权值自适应调整的多分类器融合算法[J]. 计算机工程, 2008, (10): 28-30.
Zhang D H, Sun B, Wang P, et al. Multi-classifiers fusion algorithm of adaptive weight adjustment[J]. Computer Engineering, 2008, 34(10): 28-30.
- [7] Kumar A, Sunitha R. MuSeFFF: Multi-stage feature fusion framework for traffic prediction[J]. Intelligent Systems with Applications, 2023, 18: 200227.
- [8] 王继永, 吴颖, 迟恒喆, 等. 基于Transformer结构增强的神经网络架构搜索性能预测器[J]. 计算机学报, 2024, 47(7): 1469-1484.
Wang J H, Wu Y, Chi H Z, et al. An architecture-enhanced performance predictor for transformer-based NAS[J]. Chinese Journal of Computers, 2024, 47(7): 1469-1484.
- [9] 胡润文, 项世军, 李晓龙, 等. 基于CNN计算局部复杂度的可逆信息隐藏算法[J]. 计算机学报, 2024, 47(4): 776-789.
Hu R W, Xiang S J, Li X L, et al. CNN based local complexity estimation for reversible data hiding[J]. Chinese Journal of Computers, 2024, 47(4): 776-789.
- [10] Serreli L, Fadda M, Girau R, et al. A generative adversarial network (GAN) fingerprint approach over LTE[J]. IEEE Access, 2024, 12: 82083-82094.
- [11] Rao F. Parallel adaptive window dynamic time warping attention transformer network model for time series forecasting[C]//2025 40th Youth Academic Annual Conference of Chinese Association of Automation (YAC). Piscataway: IEEE Press, 2025: 2623-2626.
- [12] Han J Y, Wang H B, Niu D, et al. Multi-source data fusion network for sea fog detection[C]//2024 36th Chinese Control and Decision Conference (CCDC). Piscataway: IEEE Press, 2024: 5755-5760.
- [13] Mo T X, Li S S, Li G D. An interpretable machine learning model for predicting cavity water depth and cavity length based on XGBoost-SHAP[J]. Journal of Hydroinformatics,



2023, 25(4): 1488-1500.

- [14] Gilani S A H, Syed M H, Anjum A. Effective diabetes prediction: integrating ensemble learning with LIME for robust results[C]//2024 International Conference on Frontiers of Information Technology (FIT). Islamabad, Pakistan. Piscataway: IEEE Press, 2024: 1-6.
- [15] Wahid A, Faiud I, Mason K. Integrating renewable energy in agriculture: a deep reinforcement learning-based approach[M]// Machine Learning and Principles and Practice of Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2025: 324-336.
- [16] Ahmad S, Lavin A, Purdy S, et al. Unsupervised real-time anomaly detection for streaming data[J]. Neurocomputing, 2017, 262: 134-147.
- [17] Cheng Y, Liu Y, Chen T J, et al. Federated learning for privacy-preserving AI[J]. Communications of the ACM, 2020, 63(12): 33-36.
- [18] Xia H S, Tian Y Q, Zhang J Z, et al. Exploring the impact of on-line news sentiment and relevance on stock market risks: a signalling theory perspective[J]. Expert Systems, 2025, 42(1): e13364.

[作者简介]



许道强（1978-），男，国网江苏省电力有限公司正高级工程师，主要研究方向为电力营销数字化技术研究级应用。




王江辉（1992-），男，江苏方天电力技术有限公司工程师，主要研究方向为电力营销数字化技术管理。



许梦晗（1990-），女，国网江苏省电力有限公司高级工程师，主要研究方向为电力营销。



詹天明（1984-），男，博士，南京审计大学计算机学院教授、博士生导师，主要研究方向为大数据分析、人工智能。



吕从东（1987-），男，博士，南京审计大学计算机学院计算机系主任、副教授，主要研究方向为人工智能算法及其应用、人工智能安全、智能审计、信息安全等。