

基于深度学习 LSTM-Attention 模型的超短期电力负荷预测研究

彭振国¹ 吴让乐¹ 张兆师¹ 尉颖¹
PENG Zhengguo WU Rangle ZHANG Zhaoshi YU Ying

摘要

因现有电力负荷预测方法在负荷值的变动上存在较大的波动性,导致预测结果往往存在一定的滞后现象,这在实际应用中可能会带来一些不便和误差。因此,文章探索了一种基于深度学习技术的 LSTM-Attention 模型,以实现更为精确的超短期电力负荷预测。通过深度学习的方法,将 LSTM-Attention 混合模型在源域中积累的知识和经验有效地迁移到短期电力负荷预测的目标域。这种方法显著提高了在有限数据条件下的模型学习效果,使得模型能够更好地捕捉到负荷数据中的关键信息和特征。为了提高预测的准确性,采用了区域最优预测值的方法。具体来说,将通过模型计算得到的区域最优预测值加到模型当前的预测值上,以此来达到短期负荷精准预测的效果。此方法能够充分利用历史数据和实时数据,从而直接输出更为准确的预测结果。实验结果表明,采用 LSTM-Attention 模型的实验组在负荷曲线的变化上表现得更为平稳。预测结果的数值主要维持在 5000~6000 MW 的范围内,这表明该模型能够有效捕捉电力负荷的总体变化趋势,可以提供更为准确的总体趋势预测,为电力系统的调度和管理提供有力的支持。

关键词

深度学习; LSTM; Attention; 超短期; 电力负荷

doi: 10.3969/j.issn.1672-9528.2025.01.036

0 引言

随着电力市场的不断发展和进步,超短期电力负荷预测在电力调度和实时控制中变得越来越重要。这种预测不仅要求预测结果具有高度的准确性,还强调预测的实时性和快速响应能力。在电力系统的日常运行中,超短期负荷预测能够帮助调度人员快速掌握未来短时间内的负荷变化趋势,从而合理调整发电计划、优化资源配置,确保电网的供需平衡和稳定运行。此外,随着可再生能源的大规模接入和分布式电源的不断发展,电力系统的负荷特性变得日益复杂多变,对超短期负荷预测技术提出了更高的要求。因此,研究适用于复杂电力系统的超短期负荷预测方法,对于提高电力系统的整体运行效率和可靠性具有重要的意义。

在分析过程中,文献[1]利用多层门控循环单元(GRU)构建神经网络,通过训练优化网络参数,学习电力负荷序列的时空特性。利用训练好的 GRU 神经网络对子序列进行预测,将预测结果叠加还原,得到最终的电力负荷预测值。然而,训练过程中需要较高的计算资源,使得预测时耗过长,影响预测的实时性。文献[2]利用时间序列分析技术,将周期性

信息融入时序分析中。通过建立预测模型,能够捕捉负荷变化的复杂模式,并生成预测结果。然而,多维时序信息融合方法涉及多个维度的数据处理和模型训练,计算复杂度较高。在处理大规模数据集时,需要高性能的计算资源来支持,在一定程度上限制了该方法的广泛应用。文献[3]提出一种时频尺度下的多元短期电力负荷组合预测方法,利用组合预测模型在时频域上分解电力负荷数据成频率特征不同的本征模态分量,采用皮尔逊系数筛选与电力负荷高度相关的特征,实现对短期电力负荷波动的预测。但是,该方法在面对跨度较大的时间序列时,其模型无法充分学习到长程依赖特征,使得随机项预测容易出现偏差。文献[4]提出结合贝叶斯自回归变换器(autoregressive transformers, Autoformer)的多维自适应短期电力负荷概率预测方法,通过基于贝叶斯 Autoformer 的预测模型,捕获负荷数据中重要子序列特征以及不确定性,实现概率预测分布和参数分布的动态更新。但是,该方法采用的捕捉高波动性特征机制,在应对工业事故引发的用电骤变等情况时,预测精度会降低。

因此,基于上述研究成果,以超短期电力负荷预测为研究对象,运用深度学习中的长短期记忆网络(LSTM)结合注意力机制(Attention)模型,结合实际情况进行实验与分析,

1. 甘肃同兴智能科技发展有限公司 甘肃兰州 730050

成为了一个重要的研究方向。LSTM-Attention 模型能够有效捕捉时间序列中的长距离依赖关系,通过注意力机制对关键信息进行加权,从而提高预测的准确性和实时性。该方法可以在保证预测准确性的同时,提高预测的实时性和快速响应能力,更好地满足电力系统运行的需求。为了克服上述方法的局限性,本文提出了一种基于深度学习 LSTM-Attention 模型的超短期电力负荷预测方法。该方法通过引入注意力机制 (attention mechanism),能够更加有效地捕捉电力负荷数据中的关键信息,同时减少不必要的数据干扰。LSTM 网络因其在处理时间序列数据方面的优势,被广泛应用于电力负荷预测领域。结合注意力机制,LSTM 网络能够更加精准地识别和利用影响负荷变化的重要因素,从而提高预测的准确性和效率。本文首先构建了包含历史负荷数据、天气信息、节假日等特征的预测特征集,设计并搭建了相应的实验环境,通过对比实验验证了所提模型在超短期电力负荷预测中的优越性能。实验结果表明,该模型不仅在预测精度上有所提升,而且在计算效率上也表现出色,能够满足实时预测的需求。

1 超短期电力负荷预测

1.1 构建预测特征集

为构建高效且全面的特征集,深入分析影响短期电力负荷的众多因素,从中选择日期、时间序列和天气 3 个核心因素作为主要考量点。具体来说,选取了与预测目标相近的负荷值作为输入,通过这些数据构建了不同维度的特征向量^[5]。通过综合考虑这些关键因素,成功构建了一个包含多种不同维度特征向量的候选输入集,该集合全面反映了影响短期电力负荷的各种信息,为分析和预测工作提供坚实基础。具体影响因素如表 1 所示。

表 1 预测因素特征集

因素	因素特征	因素描述
日期	季节	1a 为一个周期,1/4 周期代表一个季节
	月	1a 为一个周期,1/12 周期代表一个月
	小时	1d 为一个周期,1/24 周期代表 1 h
	休息日	工作日用 1 表示,休息日用 -1 表示
	工作时间	工作时间用 1 表示,其他时间用 -1 表示
	节假日	节假日用 1 表示,非节假日用 -1 表示
时间序列	滞后	滞后 1 表示将整体负荷值延迟 1 h,以此类推
天气	温度	每小时的温度,单位为℃
	天气描述	根据不同天气进行不同标记
	风速	每小时风的速度,单位为 m/s
	湿度	每小时的大气干燥度,单位为 %

将混合预测模型应用于短期电力负荷预测中,在特征向量中,各特征对电力负荷的影响强度存在显著差异,并非所有特征都与电力负荷紧密相关。在建模过程中,如果直接纳

入所有特征,可能会导致模型受到高方差的影响,进而引发过度拟合的问题^[6]。一旦发生过度拟合,混合预测模型会过度学习训练数据中的随机波动,虽然模型在训练集上表现的准确率较高,但在面对未知测试数据时,混合预测模型的性能会大幅度下降,导致预测结果与实际电力负荷的偏差较大。为了避免过度拟合情况的出现,需要选取合适的相关性分析方法。电力负荷数据呈现非线性特征,受多种因素交互影响,距离相关系数可有效捕捉到复杂的非线性依赖关系,为此,运用距离相关系数来分析每个特征向量与电力负荷之间的相关性程度。通过衡量两个任意维度的随机向量之间的依赖性,筛选预测向量。其距离相关系数计算公式为:

$$d(X,Y)=\frac{d^2(X,Y)}{\sqrt{s(X)s(Y)}} \quad (1)$$

式中: X 为维特征向量; Y 为电力负荷; $d^2(X,Y)$ 为特征向量与输出标签之间的距离相关系数; s 为距离方差。当 $d(X,Y)=0$ 时,表示两者无相关性;而当 $d(X,Y)=1$ 时,则表示两者具有强相关性。

1.2 深度学习 LSTM-Attention 模型中模态二次分解

针对短期电力负荷预测,通过深度学习的方式将 LSTM-Attention 混合模型在源域中积累的知识 and 经验有效地迁移至短期电力负荷预测的目标域,显著增加在有限数据条件下的模型学习效果^[7]。在 LSTM-Attention 混合模型中,LSTM 部分负责提取输入数据的空间特征,而 Attention 部分则专注于捕捉序列数据中的长期依赖关系。为了筛选出对电力负荷预测有重要影响的特征向量,设定一个筛选阈值 w ,利用以下规则进行特征选择:

$$V^k=\begin{cases} d(X,Y)>w \\ d(X,Y)<w \end{cases} \quad (2)$$

式中: V^k 为特征向量的筛选判别值。当第 k 维特征向量与电力负荷之间的距离相关系数大于阈值 w 时, $V^k=1$,表示该特征被保留;反之,当距离相关系数的绝对值小于阈值 w 时,该特征向量被剔除。完成特征筛选后,对保留下的特征向量进行规范化处理,以确保模型训练的稳定性和效率。利用深度学习方法对负荷序列进行初步的自适应分解,削弱序列的波动性。然而,分解后的高频分量仍然保持高度复杂性^[8]。因此,为了进一步提升预测精度,针对这些高复杂度的子序列,采用变分模态分解 (variational mode decomposition, VMD) 进行精细分解^[9]。与传统的经验模态分解 (empirical mode decomposition, EMD) 相比,VMD 可将复杂信号分解为具有中心频率、带宽有限的模态分量,有效避免电力负荷数据处理过程中的模态混叠问题,分解后的分量均能清晰反映原始信号在不同频率段的特征。通过分析分解损失,获取

重构信号与原始信号之间的差值，其大小直接关系到被忽略的序列信息量。因此，设定分解损失信息指标 L ，其计算公式为：

$$L=\frac{1}{T}\sum|f(t)-f'(t)| \tag{3}$$

式中： $f'(t)$ 为重构序列； $f(t)$ 为原始序列。在 LSTM-Attention 模型中通过遗忘门、输入门和输出门结构，在长序列处理中消除梯度。为充分利用序列的双向信息，通过门控机制增强了长期记忆能力，但遗忘门的存在仍可能导致部分重要信息丢失。通过计算 L 的平均值，能够直观反映分解过程中的信息损失情况。

1.3 电力负荷预测

在预测过程中，将注意力机制引入模型中，通过为不同输入分配不同权重的注意力神经元，实现对关键信息的有效预测。首先，通过添加一层神经元，能够将资源按照预测对象的重要程度进行重新分配，得到相应的权重配比。在注意力机制中，通过计算权重用于确定在生成最终输出时每个输入。在计算注意力权重时，设定 LSTM 层中输入序列中的每个时间步 t 都生成了一个前向隐藏状态 h_i 和一个后向隐藏状态 h_r 。将两个隐藏状态拼接形成一个完整的隐藏状态，表示为：

$$h=[h_i;h_r] \tag{4}$$

式中：分号表示向量拼接。在注意力机制中，对于每个时间步，使用 softmax 函数将这些分数归一化为概率分布，即注意力权重，通过注意力权重来对隐藏状态进行加权求和，以生成一个上下文向量，其公式为：

$$c=\sum_{i=1}a_ih_i \tag{5}$$

式中： a_i 为注意力权重。通过计算上下文向量 c 可以被用作最终预测的输入。通过计算每个输入元素的注意力权重，并根据这些权重对输入进行加权求和，从而实现了重要信息的聚焦。在模型中为能够更加智能地处理序列数据，提高预测的准确性。通过不断迭代，同时考虑序列数据的前后文信息，选择最优的上下文向量 C_r 为最优预测值。通过区域中分析电荷元素，将其最优预测值加到模型当前的预测值上，以此来达到短期负荷精准预测，其公式为：

$$C_r=n\sum w_iv_i \tag{6}$$

式中： v_i 为元素注意力值； w_i 为元素权重。直接输出预测结果。这样就可以得到短期电力负荷的预测结果。

2 实验测试与分析

2.1 搭建实验环境

在实验测试过程中，搭建测试所用的环境。实验在

Windows 操作系统环境下进行，具体的实验配置环境如表 2 所示。

表 2 实验环境

环境	参数
CPU	3.5 GHz
GPU	GTX142i
内存	6 GB
操作系统	Windows 11
Python	3.6
深度学习框架	cuda5.6+tensorflow1.1

为提升模型在预测时的准确性，设定模型参数：模型第一层为包含 128 个节点的双向 LSTM 层；第二层为具有 32 个节点的全连接层；第三层为包含 10 个节点的输出层，用于最终的预测。此外，为了控制过拟合，在不同层的 dropout 参数分别设置为 0.4、0.3 和 0.1，以增强模型的泛化能力。

2.2 设计数据集

为验证本预测模型的有效性，采用两个数据集 A 和 B 进行实验。数据集 A 包含某地区 2020—2024 年的每小时电力负荷数据，数据集 B 则是另一地区在 2024 年度内的每小时电力负荷数据。在实验中，将数据集 A 数据作为训练集，2024 年数据作为测试集。由于数据集 A 的数据量较大，将其视为源域；而数据集 B 由于数据量较小，被设定为目标域，用于进一步评估模型在不同数据集间的学习能力。

2.3 测试结果与分析

为了详细对比不同模型在特定预测任务中的性能，构建 3 种模型，其中本文方法构建的模型设置为实验组，文献 [1] 基于 CEEMD-GRU 模型的短期电力负荷预测方法为对照组 1；文献 [2] 基于多维时序信息融合的短期电力负荷预测方法为对照组 2。图 1 即对每种模型中针对数据集进行电力负荷预测结果。




图 1 模型部分预测结果情况比较

由图1结果可知,通过对比分析3个小组对短期电力负荷数据的预测效果后,实验组模型更具显著优势。实验组的负荷曲线变化较为平稳,数值维持在5000~6000 MW范围内,能有效捕捉电力负荷的总体变化趋势,使得LSTM在处理时间序列数据方面具有强大的潜力。而两个对照组的负荷值变动较大,无法提供较为准确的总体趋势预测,预测结果存在一定的滞后现象,在需要高时间分辨率的预测场景中尤其明显。

综上所述,运用本文模型预测能够更有效地处理电力负荷数据中的非线性和非平稳特性。将复杂的时间序列分解为一系列具有不同时间尺度的本征函数,显著提高了模型对异常值的响应能力,表现出了相对更优的预测效果,其预测曲线更接近真实值,避免了过度拟合或欠拟合的问题。

3 结语

本文深入探讨了电力负荷预测这一重要课题,并采用了深度学习算法作为研究工具。具体而言,重点研究了基于深度学习中的LSTM-Attention模型在超短期电力负荷预测中的应用。电力负荷预测是一个复杂且重要的任务,直接关系到电力系统的稳定运行和资源的合理分配。在传统的电力负荷预测方法中,往往难以准确捕捉到历史负荷数据中的关键信息,在很大程度上限制了预测的准确性。为了解决这一问题,本文在研究中引入了Attention机制,并将其与LSTM模型相结合。通过这种结合方式,LSTM模型能够更加有效地识别和利用历史负荷数据中的关键信息,兼顾实时性与快速响应能力,从而显著提高了预测的准确性。

虽然本文方法在一定程度上提高了预测的准确性,但仍存在一些不足之处。LSTM-Attention模型具备处理非线性与非平稳特性的能力,但面对极端复杂的电力负荷场景时,模型对负荷突变的适应性有限,预测精度会随之降低。未来的研究中,可探索引入强化学习机制,增强模型应对复杂工况的自适应能力,提升其对罕见模式的识别精度,从而适应不同时间尺度和不同影响因素下的电力负荷变化。

随着深度学习技术的不断发展和进步,基于LSTM-Attention模型的电力负荷预测方法将在未来取得更加显著的成果。不仅将为电力系统提供更加准确的负荷预测,还将为电力行业的决策者提供有力的数据支持,从而优化电力资源的配置和管理。

参考文献:

[1] 朱伟,孙运全,钱尧,等.基于CEEMD-GRU模型的短期电力负荷预测方法[J].电测与仪表,2023,60(1):16-22.

- [2] 李丹,孙光帆,缪书唯,等.基于多维时序信息融合的短期电力负荷预测方法[J].中国电机工程学报,2023,43(S1):94-106.
- [3] 李楠,姜涛,隋想,等.一种时频尺度下的多元短期电力负荷组合预测方法[J].电力系统保护与控制,2024,52(13):47-58.
- [4] 周师琦,王俊帆,赖俊升,等.结合贝叶斯Autoformer的多维自适应短期电力负荷概率预测方法[J/OL].电子与信息学报,2024,46(12):1-9[2024-01-12].<https://jeit.ac.cn/cn/article/doi/10.11999/JEIT240398>.
- [5] 唐贤伦,陈洪旭,熊德意,等.基于极端梯度提升和时间卷积网络的短期电力负荷预测[J].高电压技术,2022,48(8):3059-3067.
- [6] 杨海柱,田馥铭,张鹏,等.基于CEEMD-FE和AOA-LSSVM的短期电力负荷预测[J].电力系统保护与控制,2022,50(13):126-133.
- [7] 李玲玲,任琦瑛,宁楠,等.基于ISHO-ELM模型的短期电力负荷预测[J].天津工业大学学报,2023,42(3):73-80.
- [8] 樊江川,于昊正,王冬生,等.基于PLESN和LESQRN概率预测模型的短期电力负荷预测[J].燕山大学学报,2024,48(1):54-61.
- [9] 朱其新,刘梦园.基于VMD和KELM的空调超短期负荷预测[J].计算机仿真,2023,40(8):518-523.

【作者简介】

彭振国(1984—),男,甘肃正宁人,本科,工程师,研究方向:电网数字化。

吴让乐(1989—),男,甘肃兰州人,本科,工程师,研究方向:信息安全。

张兆师(1989—),男,甘肃白银人,研究生在读,工程师,研究方向:信息技术、能源科学与技术。

尉颖(1989—),女,甘肃兰州人,本科,工程师,研究方向:电网数字化。

(收稿日期:2024-10-12)