

基于 Markov-BP 神经网络的短期电力负载预测研究

袁 靖¹ 蒋志飞¹ 陈鸿飞² 吴叙锐²
YUAN Jing JIANG Zhifei CHEN Hongfei WU Xurui

摘 要

在电力系统中, 电力负载受到多种复杂因素的综合影响, 这些因素之间存在复杂的非线性相互作用, 传统的线性模型难以准确地描述这种关系, 当电力负载数据短期内出现一些突发变化或者波动时, 无法提取出能够反映电力负载本质特征的信息, 导致预测准确性和稳定性欠佳。为此, 提出一种基于 Markov-BP 神经网络的短期电力负载预测方法。通过对电力负载数据进行预处理, 包括数据清洗、缺失值的填补以及执行归一化操作, 以确保数据的质量和一致性。将预处理后的电力负载数据作为输入, 运用时间序列分析和信号处理技术构建电力负载时间序列模型, 对数据进行时序分析与特征筛选。基于 Markov-BP 神经网络, 利用由时间序列模型按时间组织的电力负载数据, 通过网络隐藏层对数据进行处理, 提取出能够反映电力负载本质特征的信息。在相空间内建立电力负载的预测模型, 该模型通过学习电力负载本质特征, 经训练和优化过程确定合适的嵌入状态向量和参数值。最后, 通过异步迭代进行电力负载的短期预测。实验结果表明, 此方法在预测准确性和稳定性方面表现优异, 为电力系统的优化调度和能源管理提供了有力支持。

关键词

Markov-BP 神经网络; 电力负载预测; 数据预处理; 时间序列分析; 模型优化

doi: 10.3969/j.issn.1672-9528.2025.02.012

0 引言

随着全球能源需求的不断增长, 电力系统的稳定运行和高效管理显得尤为重要。然而, 由于电力负荷数据受到多种因素的影响, 使得电力负荷预测成为一项极具挑战性的任务^[1]。准确的短期电力负载预测能够为电力系统的规划、调度、运行和控制提供关键的决策依据。对于电力系统的规划者而言, 精确的预测有助于合理安排发电容量, 避免过度建设或者电力供应不足的情况。在电力调度方面, 预测结果能够指导电力的分配, 确保在不同时间段内各个区域都能得到稳定的电力供应, 提高电力系统的可靠性和稳定性。同时, 对于电力市场的参与者, 如发电企业、售电企业等, 短期电力负载预测能够帮助他们制定合理的生产和销售策略, 降低运营风险, 提高经济效益。鉴于短期电力负载预测的重要性以及电力负载本身的复杂性, 开展针对短期电力负载预测的研究

具有深远的理论和现实意义。

在当前研究中, 已有多种方法被应用于短期电力负荷预测。其中, 文献[2]提出一种基于经验模态分解和 ISSA-LSTM 的短期电力负荷预测。然而, 当电力负荷数据遭遇突发变化或波动时, EMD 在分解过程中难以精确把握数据的内在特性, 进而影响了后续预测的准确性。文献[3]提出一种结合 EMD、时间卷积网络(TCN)与门控循环单元(GRU)的超短期电力负荷预测方法。尽管该方法利用 EMD 对电力负荷数据进行预处理, 但面对具有突发变化或波动的数据时, EMD 仍可能遭遇模态混叠或分解不充分的问题, 导致提取的本征模态函数(IMF)无法真实反映原始数据的特征, 从而影响了后续预测模型的准确性。文献[4]则提出了一种结合 EMD、时间卷积网络(TCN)与门控循环单元(GRU)的超短期电力负荷预测方法。尽管该方法利用 EMD 对电力负荷数据进行预处理, 但面对具有突发变化或波动的数据时, EMD 仍可能遭遇模态混叠或分解不充分的问题, 导致提取的本征模态函数(IMF)无法真实反映原始数据的特征, 从而影响了后续预测模型的准确性。同时, 融合了 EMD、TCN 与梯度提升机(GBM)算法, 旨在提高配电网线路负载预测的准确性和稳定性。该方法虽用 EMD 预处理电力负荷数据, 但数据突发变化或波动时, EMD 可能模态混叠或分解不充分,

1. 商丘工学院信息与电子工程学院 河南商丘 476000

2. 华能新能源股份有限公司广东分公司 广东广州 510610

[基金项目] 商丘工学院 2024 年教育教学改革研究与实践项目“专创融合视域下电类专业课程教学改革与实践”(2024JGXM05); 河南省教育厅“豫东黄泛区乡村振兴耦合协调度时空演化趋势及障碍度研究”(25B790017)

使 IMF 无法反映原始数据特征,影响后续预测准确性。

针对上述方法的不足,本文基于 Markov-BP 神经网络提出了一种新的短期电力负荷预测方法,该方法结合了 Markov 链的随机过程特性与 BP 神经网络的非线性建模能力,旨在提升预测的准确性和稳定性,为电力系统的稳定运行和能源的高效利用提供坚实的技术支撑。

1 基于 Markov-BP 神经网络的短期电力负载预测研究

电力负荷数据作为时间序列数据,受天气、节假日、各类活动等多种因素的影响,表现出复杂性和不确定性。数据中可能存在的错误、不一致性和缺失值会对模型的预测性能产生不利影响。Markov 模型在处理具有随机性和时间依赖性的数据方面表现出色,而 BP 神经网络则以其强大的非线性建模能力,常用于解决复杂的预测问题。因此,本文结合 Markov 和 BP 神经网络的优势,构建了一种既考虑时间序列特性又具备强大非线性建模能力的预测模型,即 Markov-BP 神经网络。通过该神经网络构建的预测模型最终实现了对未来短期内电力负载状态的准确预测。

1.1 电力负载数据预处理

在短期电力负载预测过程中,由于电力负载数据来源广泛且复杂,可能存在数据噪声、缺失值等问题。通过数据预处理,如数据清洗去除异常值、填补缺失值以及进行数据归一化操作,可以提高数据的质量和可用性^[5]。为此,本文提出先对电力负载数据进行预处理,通过识别并修复数据中的不一致和缺失问题,同时保留数据的时序特性,确保为后续构建电力负载时间序列模型提供干净、准确的数据基础。

假设有一个原始电力负载数据集 $D = \{x_1, x_2, \dots, x_n\}$,则数据清洗过程中所使用的计算方式为:

$$\hat{x}_j = \frac{x_{j-1} + x_{j+1}}{2} \quad (1)$$

式中: x_i 表示第 i 个时间点的负载数据。输出清洗后的数据集 $\hat{D} = \{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_n\}$ 。对于过大或过小的异常数值予以删除,删除后用平均插值技术填补空缺以确保数据合理分布与完整性^[6]。

分配数据集为训练集和测试集时,要考虑时间序列数据的时序特性,按时间顺序操作^[7]。本文根据 3 个城市电力负载数据的时间顺序,按 7:3 的比例将数据有序分为训练集和测试集,训练集用于模型训练,测试集用于评估模型对未来电力负载数据的预测性能。

使用最大最小归一化方法来处理来自 3 个城市的数据,计算公式为:

$$\max \min(x) = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2)$$

最大最小归一化的目的是将数据集集中的最大值转换为 1,

最小值转换为 0,从而确保整个数据集的值域被限定在 0 到 1 的范围内^[8]。当模型完成训练并输出预测值后,需要对这些预测结果进行反归一化处理,以便将它们恢复到原始数据的量级。计算公式为:

$$x = \max \min(x) \cdot (\max(x) - \min(x)) + \min(x) \quad (3)$$

通常,在使用这些数据之前,会进行一种数据转换处理,目的是将数据值调整 [0,1] 区间范围内,计算公式为:

$$x'_{ik} = \frac{x_{ik} - \bar{x}}{S_k}$$

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_{ik}$$

$$S_k = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{ik} - \bar{x}_k)^2}$$
(4)

式中: S_k 表示样本标准差; x'_{ik} 表示经过平移标准差数据变换后的数据; x_{ik} 表示原始数据。如果在应用前面的变换步骤后,得到的 x'_{ik} 值未能落在 [0, 1] 区间内,需要采用公式进行数据变换。

$$x''_{ik} = \frac{\max x'_{ik} - \min(x'_{ik})}{\max\{x'_{ik}\} - \min\{x'_{ik}\}} \quad (5)$$

运用上述公式可以将数据转换至 [0,1] 的范围内,并且能够消除数据因量纲不同而产生的差异或影响。

1.2 构建电力负载时间序列模型

电力负载数据通常具有明显的时间依赖性,可以将其视为时间序列进行分析和建模。时间序列分析作为一种从历史数据中挖掘信息的方法,能够有效地揭示电力负荷的周期性和趋势性特征,为构建精确的预测模型奠定坚实基础。鉴于此,本文提出结合时间序列分析和信号处理技术构建电力负载时间序列模型。在模型构建过程中,将预处理后的电力负载数据作为输入,对电力负载时间序列数据进行时序分析及特征筛选,使得后续 Markov-BP 神经网络能够更好地学习负载数据在不同时间点的变化趋势和周期性等特征,从而提高预测的准确性和可靠性^[9]。

首先,基于预处理后的电力负载数据构建时间序列模型。电力负载信息的交互框架如图 1 所示。




图 1 电力负载信息的交互框架

在图 1 所描绘的电力负载的时间序列模型中,实施时间序列的数据采集,对电力网络中的负载节点进行剖析。随后,

进行时间序列的迭代处理,旨在揭示电力负载的周期性和趋势性特征。在 SN 与数据汇聚点之间的连接路径上,进行适应度的计算,以确保相邻两个节点间用户接入的控制精度达到最优状态。在这种情况下,电力网络用户接入的最优分布式路径长度可以被视为快照时段 $[d, d_0]$ 内的聚类群组,它反映了电力负载数据的空间分布特性。对于电力负载数据的相空间路径中心距离进行量化,其计算公式为:

$$d_0 = n_0 \sqrt{\frac{\alpha_1 + \beta}{(n_0 - 1)\alpha_2}} \quad (6)$$

式中: n_0 表示负载数据分布的交互作用系数; β 表示负载的功率水平; α_1 、 α_2 表示双通道数据采样的平衡因子。这些参数共同描述了电力负载在相空间中的动态行为。

在电力负载数据的信息流动序列中,使用非线性时间序列分析技术来计算电力负载的离散样本频谱特征 $X_p(u)$ 。这些特征反映了多层向量预测域内对应的离散样本的频域特性。该特性可表示为:

$$X_p(u) = s_c(t) e^{j2\pi f_0 t} = \frac{1}{\sqrt{T}} r \left(\frac{t}{T} \right) e^{j2\pi (f_0 t + K t^2)/2} \quad (7)$$

式中: $s_c(t)$ 表示类别 b_i 的概率分布; $e^{j2\pi f_0 t}$ 表示电力负载聚类的独立关联因子; r 表示离散度参数。

在电力负载预测的流程中,会涉及数据的聚类分析,此时,时间窗聚类数据集可以表述为集合 $\{D_1, D_2, \dots, D_n\}$,其中每个 D 代表一个数据集。

在上述构建的电力负载时间序列模型框架内,对这些数据集进行时序分析及特征筛选,从而为电力负载预测任务准备精确无误的测试数据集。

1.3 基于 Markov-BP 神经网络提取电力负载特征

构建好电力负载时间序列模型后,基于 Markov-BP 神经网络进行电力负载特征提取。Markov-BP 神经网络具有强大的非线性映射能力和学习能力。它利用时间序列模型提供的按时间组织的电力负载数据,通过网络的隐藏层对数据进行处理,从而提取出能够反映电力负载本质特征的信息。

假设短时电力负载的非线性时序数据并非简单地由一个具有非线性多元特性的线性等式表示,而是包含复杂的动态行为和模式。为了处理这些数据,引入了一个最小冲突异步迭代方程:

$$x_n = x(t_0 + n\Delta t) = h[z(t_0 + n\Delta t)] + \omega_n \quad (8)$$

式中: $h(\cdot)$ 表示观测电力负荷标量时序的多元量化函数,该函数能够捕捉电力负荷数据的非线性特性; ω_n 表示测定偏差,用于衡量模型预测与实际观测之间的差异。

假定所获取的电力负载时间序列数据为:

$$U = \{U_1, U_2, \dots, U_N\} \quad (9)$$

式中: U_i 表示在 d 维的随机矢量,代表在某一时刻观测到的电力负载状态。

为了从这些数据中提取有用的特征,基于 Markov-BP 神经网络,对负载数据进行特征抽取。在特征抽取的过程中,构建了电力负载数据的矢量状态图像。在 m 维状态空间中,存在一个 d 维的滑动时间窗口 M ,该窗口用于捕捉电力负载数据随时间变化的动态行为。同时,定义一个在 M 上的平滑函数 h ,该函数在 m 维状态空间中描述了电力负载数据的有序传输结构。

基于上述特征抽取的结果,构建了电力负载预估的概率分布函数,公式为:

$$\begin{aligned} p(U|\Theta) &= \sum_{k=1}^K \frac{K}{K} \alpha_k G(U|u_k, \sum_k) \\ \Theta &= [\alpha, u, \sum] \\ \alpha_k &\geq 0, \sum_{k=1}^K \alpha_k = 1 \\ G(U|u_k, \sum_k) &= (2\pi)^{-d/2} |\sum_k|^{-1/2} \exp\left[-\frac{1}{2}(U-u_k)^T \sum_k^{-1} (U-u_k)\right] \end{aligned} \quad (10)$$

式中: $G(U|u_k, \sum_k)$ 表示异步迭代中的每一步增量,反映了电力负载数据随时间变化的速率; $p(U|\Theta)$ 表示多个预测误差的加权累积。

利用相空间重构技术,获取了电力负载数据的时频特性提取值:

$$CW^l M_{\min} = CW^l M_{\min} - 1 \times (1 + \bar{D}_{l_{M-1}}) \chi \quad (11)$$

上述公式代表了当短时电力负载时序的时间度量序列为特定值 $\{x(t_0 + i\Delta t)\}$, $i = 0, 1, \dots, N-1$ 时,所对应的行属性矢量经过时频特性提取过程后得到的结果:

$$X = K[s_1, s_2, \dots, s_K]_n = K[x_n, x_{n-\tau}, \dots, x_{n-(m-1)\tau}] \quad (12)$$

式中: $K = N - (n-1)\tau$ 表示电力负载时序在 Markov-BP 神经网络的嵌入维度; τ 表示时间滞后。

依据异步迭代原理,在相空间内确定电力负载时间序列的几何稳定量,并据此预测节点与负载流的信息特性。

1.4 预测短期电力负载状态

基于 Markov-BP 神经网络提取的电力负载特征为依据,利用神经网络已经学习到的模式和关系,对未来短期内的电力负载状态进行预测。在此过程中,定义了一个矩阵来表示电力负载序列在多维状态域中的特性,并利用 Markov-BP 神经网络在相空间内建立了电力负载的预测模型。通过选取合适的嵌入状态向量和值,确保电力负载时间序列的异步预测算法满足条件。最后,通过异步迭代进行电力负载的预测,并得出预测结果。

定义一个矩阵,其维数用于表示电力负载序列在 $d \times L$ 维的广域子空间中的特性,在 m 维的多维状态域中,利用

Markov-BP 神经网络，在相空间内建立电力负载的预测模型。其中 $s_i = (x_i, x_{i+\tau}, \dots, x_{i+(m+1)\tau})^T$ 为短时电力负载非线性时序的嵌入状态向量，它包含了电力负载在某一时刻的完整状态信息，其计算公式为：

$$\frac{dz(t)}{dt} = F(z) \tag{13}$$

结合上述公式，需要选取合适的嵌入状态向量 m 和相应的 τ 值，以确保电力负载时间序列的异步预测算法能够满足条件：即父节点相较于其子节点，具有更高的特征分布的可能性密度。此时，电力负载中节点出现的可能性密度特性可以表述为：

$$R_1 = \{X_1, X_2, X_3, \dots, X_d\} \tag{14}$$

基于上述步骤和选取的参数，进行异步迭代来进行电力负载的预测。异步迭代意味着在预测过程中，每个时间点的预测结果都会基于前一个时间点的预测结果进行更新，从而逐步逼近真实的电力负载状态。最终得出了预测结果：

$$\begin{aligned} D_k &= D_{k-1} - N_{k-1}^2 / D_{k-1} \\ \phi_{kk} &= N_k / D_k \\ \phi_{kj} &= \phi_{k-1,j} - \phi_{kk} \phi_{k-1,k-j} \end{aligned} \tag{15}$$

综上所述，通过定义矩阵来表示电力负载序列在多维状态域中的特性，利用 Markov-BP 神经网络建立预测模型，并选取合适的参数进行异步迭代预测，能够实现了对未来短期内电力负载状态的准确预测。

2 实验结果与分析

为了验证基于 Markov-BP 神经网络的短期电力负载预测研究的可靠性，本文选取文献 [2] 提出的基于经验模态分解和 ISSA-LSTM 的短期电力负荷预测方法、文献 [3] 提出的基于 EMD-TCN-GRU 超短期电力负荷预测方法以及文献 [4] 提出的融合 EMD-TCN-GBM 算法的配电网线路负载预测方法作为对比，并设计了以下对比实验。

2.1 实验对象

实验选用了来自 3 个不同城市的电力负载数据集。这些数据集记录了各自城市在一段时间内的电力负载记录，具有时间序列特性。这些数据被用于训练和测试基于 Markov-BP 神经网络的短期电力负载预测模型。通过对比不同文献中的预测方法和本文提出的方法，旨在评估本方法在预测准确性、稳定性和适应性方面的性能。经过网络搜索和数据集遍历，确定了最佳的数据集组合，并设置了各个模型的参数，如表 1 所示。

表 1 模型参数设置

模型名称	参数名称	参数值
文献 [2] 方法	hidden_size	50
文献 [3] 方法	num_layers	3
文献 [4] 方法	hidden_size	64
本文方法	n_endocer_layers	2

这些参数确保了各模型在相应数据集上能够达到最佳或接近最佳的预测性能。

2.2 实验准备

实验准备阶段，确保所有必要的软件和硬件资源已配置妥当，包括安装了适用于深度学习的编程环境，如 Python 及其相关库，以及必要的计算资源。对 3 个不同城市的电力负载数据集进行了预处理，包括数据清洗、缺失值填补、归一化处理等步骤，以确保数据的质量和一致性。此外，根据表 1 中列出的参数设置，为各个对比方法进行了初始化配置，包括设置隐藏层大小、层数等关键参数。最后，设计了详细的实验流程，明确了训练集和测试集的划分，以及模型训练和评估的具体步骤，为后续的对比实验做好充分准备。

2.3 结果分析

为了评估预测性能的差异，将本文提出的预测方法与传统的预测方法进行了预测准确度对比，对比结果如图 2 所示。




图 2 预测准确度对比图

观察图 2 可知，运用本文所述的方法能够显著提升电力负载预测的准确度，展现出卓越的预测性能。在本文方法中，Markov 链的引入使得模型能够捕捉电力负载数据中的随机过程和动态变化，而 BP 神经网络的非线性建模能力则使得模型能够准确拟合复杂的非线性关系。本文方法不仅利用了时间序列分析的结果，还通过网络的隐藏层对数据进行深度处理，提取出能够反映电力负载本质特征的信息。这种结合使得模型在预测电力负载时具有更高的准确性和稳定性。

为了更直观地展示这一点，下文通过图 3 呈现了本文提

出的预测方法相较于传统预测方法,在预测电力负载走势上与真实值的对比结果。




图3 电力负载预测曲线

根据图3可知,本文方法预测的负载值展现出清晰的趋势性和周期性特征,数据波动相对平稳,且整体数据量丰富,能够较好地拟合真实负载的变化情况。相比之下,文献[2]、文献[3]以及文献[4]中呈现的电力负载预测值则存在较为明显的不规则波动,数据平稳性较差,且在某些时段与真实值的偏差较大。本文采用的 Markov-BP 神经网络结合了 Markov 链的随机过程特性和 BP 神经网络的非线性建模能力,能够更有效地提取电力负载数据中的本质特征。这些特征不仅反映了电力负载的趋势性和周期性,还能够捕捉到数据中的复杂非线性关系。使得模型能够学习到更丰富的信息,从而提高了预测的准确性和稳定性。

3 结语

本文所研究的基于 Markov-BP 神经网络的短期电力负载预测方法,在增强预测精度和确保预测稳定性上取得了显著成效,为电力系统的优化调度与能源管理提供了坚实的支撑。尽管如此,仍存在一些局限性。具体而言,在面对极端天气条件下的电力负载预测时,该模型的适应性尚需提升。同时,尽管该方法在处理非线性特征方面已展现出一定优势,但在面对更为复杂多变的电力负载数据时,其泛化能力仍有待加强。针对这些不足,未来的研究将致力于优化模型架构,以增强其对极端条件的适应能力,并深入探索更多高效的特征提取技术,以期进一步提升模型的泛化性能。

参考文献:

- [1] 何洋洋. 基于权重分配的电力短期负荷分布预测方法研究[J]. 仪器仪表用户, 2024, 31(10): 44-46.
- [2] 曾进辉, 苏旨音, 肖锋, 等. 基于经验模态分解和 ISSA-LSTM 的短期电力负荷预测[J/OL]. 电子测量技术, 1-7[2024-02-22]. <http://kns.cnki.net/kcms/detail/11.2175>.

TN.20241018.1837.033.html.

- [3] 徐灵. 基于 EMD-TCN-GRU 超短期电力负荷预测[J]. 船电技术, 2024, 44(10): 50-54.
- [4] 叶炜, 吴桂联, 唐露, 等. 融合 EMD-TCN-GBM 算法的配电网线路负荷预测方法研究[J]. 制造业自动化, 2024, 46(4): 102-106.
- [5] 郭渊, 张雪成, 董振标, 等. 基于 TCN-BiLSTM-AM 的居民住宅短期电力负荷预测[J]. 现代电子技术, 2024, 47(19): 100-108.
- [6] 杨玺, 陈爽, 彭子睿, 等. 基于鱼群优化算法和 Elman 神经网络的短期电力负荷预测[J]. 电气自动化, 2024, 46(5): 15-18.
- [7] 康亚鹏. 电气盒设备供电阶段保护与电力负载管理[J]. 电气技术与经济, 2024(3): 147-148.
- [8] 吴青筱, 王合宁, 仇浩宇, 等. 基于深度聚类的居民用户电力负载模式识别[J]. 科技创新与应用, 2022, 12(24): 29-33.
- [9] 杨继革, 严俊, 陈丽春, 等. 基于智能电表的住宅短期电力负载预测[J]. 沈阳工业大学学报, 2022, 44(3): 255-258.

【作者简介】

袁靖(1988—), 女, 河南商丘人, 硕士, 讲师, 研究方向: 电力系统。

蒋志飞(1987—), 男, 河南商丘人, 硕士, 讲师, 研究方向: 控制系统与自动化。

陈鸿飞(1989—), 男, 河南商丘人, 本科, 中级工程师, 研究方向: 新能源发电。

吴叙锐(1982—), 男, 广东汕头人, 硕士, 高级工程师, 研究方向: 新能源发电。

(收稿日期: 2024-11-11)