

基于 VMD-SHO-LSTM 模型的短期电力负荷预测研究

冯洋洋¹ 王刚² 朱信宜²

1. 辽宁省能源研究会, 辽宁 沈阳 110000

2. 沈阳工程学院, 辽宁 沈阳 110136

[摘要]为电力公司更好地预测电力需求的变化, 本文开发一套科学稳健的预测模型来进行准确的短期负荷预测, 提高电力系统规划和运行管理。模型以变分模式分解(VMD)、海马优化器(SHO)和长期短期记忆(LSTM)的预测模型为组成, 选取某市的历史数据为例对 VMD-SHO-LSTM 模型进行合理优化, 并与 RBF、LSTM 和 SHO-LSTM 等其他模型进行参数比较得出最优方案, 为提高电力系统负荷预测的准确性和稳定性提出新的预测方法。

[关键词]电力系统; 长短期记忆; 负荷预测

DOI: 10.33142/hst.v7i10.13894

中图分类号: TM715

文献标识码: A

Research on Short term Power Load Forecasting Based on VMD-SHO-LSTM Model

FENG Yangyang¹, WANG Gang², ZHU Xinyi²

1. Liaoning Energy Research Society, Shenyang, Liaoning, 110000, China

2. Shenyang Institute of Engineering, Shenyang, Liaoning, 110136, China

Abstract: In order to better predict changes in electricity demand for power companies, this article develops a scientifically robust forecasting model for accurate short-term load forecasting, improving power system planning and operation management. The model consists of Variational Mode Decomposition (VMD), Sea-Horse Optimizer (SHO), and Long Short Term Memory (LSTM) prediction models. Taking historical data from a certain city as an example, the VMD-SHO-LSTM model is optimized and compared with other models such as RBF, LSTM, and SHO-LSTM to obtain the optimal solution. A new prediction method is proposed to improve the accuracy and stability of power system load forecasting.

Keywords: power system; long short term memory; load forecasting

引言

随着全国对电力供应需求的不断增加, 负荷预测是电力系统规划和管理中的一个关键环节, 它帮助电力公司更好地理解并预测电力需求的变化, 从而制定相应的发电和输电计划。电力公司利用这些方法和数据, 结合实时监控系统和先进的信息技术, 来提高负荷预测的准确性。进行负荷预测的方法包括: 使用历史数据来预测未来的趋势的时间序列分析法, 分析不同变量对负荷的影响, 建立数学模型的回归分析法, 利用机器学习技术来识别复杂的非线性关系神经网络法和一种适用于数据不足时的灰色预测等。

本文提出了一种基于 VMD-SHO-LSTM 的预测方法, 是一种结合了多种技术的综合预测模型, 适用于电力负荷预测等场景。使用 VMD 对原始负荷数据进行分解, 提取出主要的信号成分, 并减少噪声。通过 AHA 算法对 LSTM 模型的参数进行优化, 找到最佳的神经元数量和学习率, 并将 VMD 分解后的数据输入到优化后的 LSTM 模型中进行预测。最后将预测结果进行重组, 得到最终的负荷预测值。这种方法的优势在于综合利用了信号处理、优化算法和深度学习技术, 能够更好地处理电力负荷数据的复杂性和非线性特征。通过分解信号并减少噪声, 提取出主要的负荷变化趋势, 提高预测的准确性。通过 AHA 算法优化 LSTM 模型

参数, 进一步提高模型的性能和泛化能力。实际运行过程中 VMD 和 LSTM 模型的选择和参数设置可能对预测结果产生影响, 需要根据实际情况进行调整。算法的计算复杂度可能较高, 需要考虑实际的计算资源和时间限制。模型在面对新的电力负荷数据时, 需要进行更新和优化, 以保持预测的准确性。

1 长时记忆网络的原理和步骤

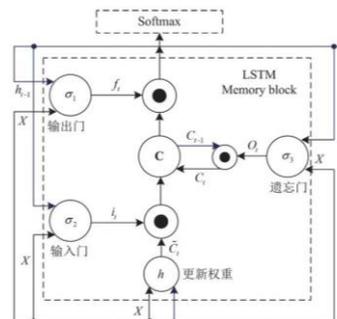


图1 LSTM 内部结构原理图

长时记忆网络的原理和步骤 LSTM 是在递归神经网络 (recurrent neural networks, RNN) 的基础上发展起来的, 以解决 RNN 处理长序列时的梯度消失和梯度爆炸问题。与 RNN 相比, LSTM 内部包含输入门、遗忘门、输出

门、记忆单元以及信息传送单元，从而实现在处理时序问题过程中对关键的信息进行记忆与更新^[1]。其结构如图1所示。

LSTM 神经网络的工作原理如下。遗忘门：决定 t-1 时刻细胞中信息的保留和遗忘。相关公式如式(1)所示。

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

式中：f_t 为遗忘门参数；σ 为 Sigmoid 函数；W_f 为遗忘门权重；h_{t-1} 为 t-1 时刻隐藏层输出信号；x_t 为输入信号；b_f 为遗忘门的偏置矩阵。

输入门：用于确定哪些新信息输入到记忆单元中以更新细胞状态。相关公式如式(2)一式(4)所示。

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (4)$$

式中：i_t 为输入门参数；W_i 为输入门权重；W_c 为细胞状态权重；tanh 为双曲正切激活函数；b_i 为输入门的偏置矩阵；b_c 为记忆单元的偏置矩阵；C_{t-1} 为 t-1 时刻细胞状态；C_t 为当前细胞状态。

输出门：用于过滤记忆单元中的信息，并输出最需要的信息，以预测未来的值。相关公式如式(5)一式(6)所示。

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t \times \tanh(C_t) \quad (6)$$

式中：O_t 为输出门参数；W_o 为细胞状态权重；b_o 为输出门的偏执矩阵；h_t 为 t 时刻隐藏层输出信号。

在时间序列预测中经常使用的循环神经网络结构中哪些信息进入单元状态由输入门管理。遗忘门清楚地表明从单元状态中删除了哪些信息。来自单元状态的哪些数据被输出到下一个时间步长由输出门控制。通过使用这些门机制，从而在序列数据预测中取得了良好的效果^[2]。

尽管 LSTM 更能处理序列数据，但它在短期电力负荷预测中可能存在重大缺陷，其中包括 LSTM 需要大量的数据来训练模型，且对数据质量要求较高，数据中的噪声和异常值可能会影响模型的预测准确性。模型的参数较多，包括隐藏层的神经元数量、学习率等，这些参数的选择对模型性能有显著影响，但找到最优参数组合往往需要大量的实验和时间。模型在训练过程中需要消耗大量的计算资源和时间，特别是当数据集较大或模型较复杂时，这可能会限制其在实时预测场景中的应用。在实际应用中，如果将所有特征都输入到 LSTM 中，不仅影响算法的运行速度，同时还会降低负荷预测的准确度。LSTM 可能在捕捉短期波动和突变方面存在局限，尤其是当电力负荷受到突发事

件或非规律性因素影响时。为了克服这些缺陷，使用改进的 LSTM 模型结构来提高预测精度和效率^[3]。

2 VMD-SHO-LSTM 模型构建

本文预测研究先对原始数据进行预处理，包括缺失值处理、异常值处理和数据归一化，输入原始数据，并使用 VMD 算法将其分解为多个模态分量。VMD 分解，使用变分模态分解 (VMD) 对时间序列数据进行分解，得到若干个固有模态函数 (IMF) 分量^[4]。在 LSTM 模型中，使用 SHO 优化方法来计算隐藏层的最有效神经元数量和学习率。对 VMD 分解后的 IMF 分量，应用同步霍尔特-奥尔德罗伊德 (SHO) 方法进行特征提取。通过特征选择方法，筛选出与预测目标最相关的特征。应用 SHO 优化的 LSTM 预测模型预测 VMD 分解生成的模态分量^[5]。将优化后的特征集输入到长短期记忆网络 (LSTM) 中进行训练。利用训练好的 LSTM 模型对新的输入数据进行预测，并将预测结果进行重构，得到最终的预测输出。图 2 显示了 VMD-SHO-LSTM 工作结构。

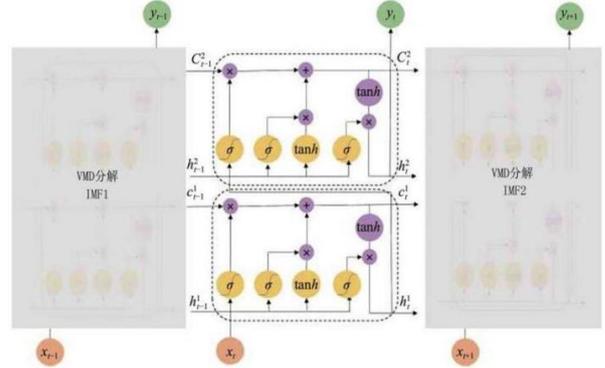


图 2 VMD-SHO-LSTM 结构图

2.1 变分模态分解

变分模态分解 (VMD) 方法代表了一种先进的自适应模态变分和信号处理方法。VMD 提供了一种非递归技术，允许将原始数据分解为许多模态分量。通过这个分解过程，VMD 有效地满足了一组约束，实现了精确和准确的信号分析：

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \hat{\partial}_k \left[(\delta(t) + j/\pi t) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (7)$$

$$s.t. \sum_{k=1}^K u_k = f \quad (8)$$

其中：u_k 是分解后获得的第 k 个模态分量；ω_k 是所获得的模态分量的中心；δ(t) 是狄拉克分布和 f(t) 原始加载顺序。

在方程(7)中引入二次惩罚因子 α 和拉格朗日乘数 λ，将约束问题转化为无约束问题求解。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \hat{\partial}_k \left[(\delta(t) + j/\pi t) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (9)$$

使用交替方向乘子、交替更新 u_k^{n+1} , ω_k^{n+1} , 和 λ^{n+1} 的方法求解方程 (8) 的变分问题, 以找到拉开方程的“鞍点”。

$$\hat{u}_k^{n+1}(\omega) \leftarrow \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega) / 2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (10)$$

$$\omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (11)$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \gamma \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (12)$$

2.2 海马优化算法

海马优化算法 (SHO) 是一种具有启发式的全局优化算法, 可用于解决广泛的现实世界问题, 包括机器学习、图像处理和其他领域的问题。它基于海马在自然界中的行为, 模拟它们的运动、捕食和繁殖行为。SHO 分别模拟了前两个阶段的各种海马运动模式和捕食概率机制。海马有两种不同的运动方式: 受海洋涡流影响的螺旋运动和受洋流和波浪影响的漂移。它以一定的概率模仿掠夺性策略捕获猎物的成功或失败。由于雄性怀孕的独特特征, SHO 在第三阶段繁殖后代, 并保持父本的积极特征, 这有助于确保种群多样性。海马优化过程的关键是位置的更新和修改。在位置更新过程中, 通过考虑关于当前理想解、个体历史最优解和全局历史最优解的信息, 使搜索更好的解变得更简单。

2.3 长期和短期记忆网络

在时间序列预测中经常使用的循环神经网络结构是 LSTM^[14]。LSTM 引入了三种门机制——输入门、遗忘门和输出门。哪些信息进入单元状态由输入门管理。遗忘门清楚地表明从单元状态中删除了哪些信息。来自单元状态的哪些数据被输出到下一个时间步长由输出门控制。通过使

用这些门机制, 从而在序列数据预测中取得了良好的效果。

尽管 LSTM 更能处理序列数据, 但它在短期电力负荷预测中可能存在重大缺陷: (1) 尽管 LSTM 旨在处理序列数据中的长期依赖关系, 但在某些情况下捕获长期依赖关系仍然存在问题, 这可能会导致模型预测负载变化的准确性降低。(2) LSTM 模型有各种必要的超参数, 它们的选择更加复杂。不合理的选择可能会导致模型结果不佳或缺乏通用性。因此, LSTM 模型需要进行调整, 以提高其性能和负载预测精度。

2.4 VMD-SHO-LSTM 模型构建

VMD-SHO-LSTM 组合方法包括以下步骤: (1) 输入原始数据, 并使用 VMD 算法将其分解为多个模态分量。(2) 在 LSTM 模型中, 使用 SHO 优化方法来计算隐藏层的最有效神经元数量和学习率。(3) 应用 SHO 优化的 LSTM 预测模型预测 VMD 分解生成的模态分量。(4) 为了完成最终的预测结果, 重建并合并每个模态分量的预测。

3 实例分析

本文共选取某市 3 个月真实负荷数据, 2880 组监测间隔为 15 分钟的数据作为样本, 每日 96 条, 共计 2976 条负荷数据。所选数据波动在 VMD 分解的影响下逐渐稳定, 残差分量显示了负载序列的长期变化规律, 从而产生了更一致的整体变化趋势。分别预测每个局部特征会产生互不干扰, 降低预测难度。

优化网络的学习率和隐层神经元数量分别为 159 和 0.0014, LSTM 模型使用 SHO 进行优化。SHO-LSTM 模型独立地应用于每个模态分量, 并将得到的预测值相加以产生最终的预测值。将结果与 RBF、LSTM、SHO-LSTM 和真实值进行比较, 每个模型的预测结果如图 3 所示。

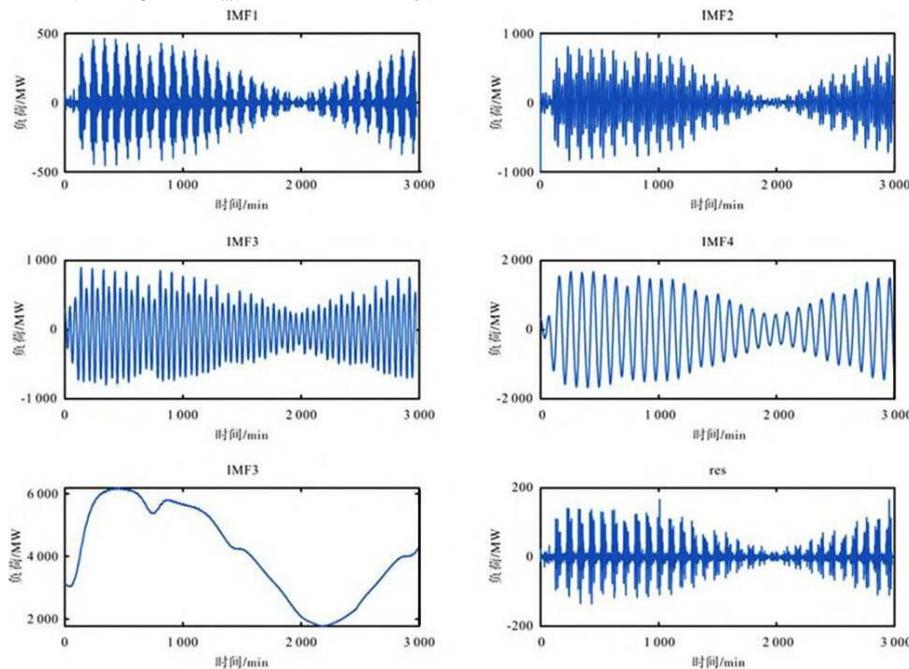


图3 VMD 数据分解

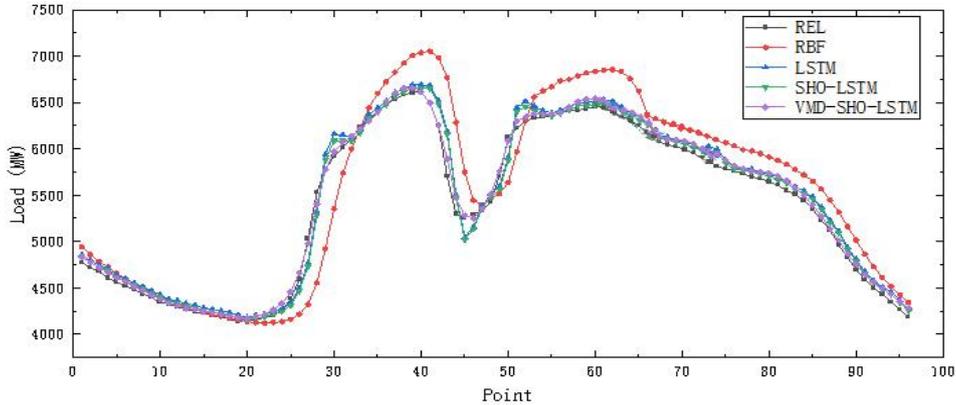


图4 各模型预测结果

从每个模型预测的结果中明显看出,本研究中提供的负荷预测值更准确,更适合实际值。MAE、RMSE 和 MAPE 被用作评估指标,以检查所提出的模型预测结果的能力。各模型的评价指标结果如表 1 所示。

表 1 预测结果评估

模型	MAE(MW)	RMSE(MW)	MAPE(%)
RBF	306.984	402.7823	5.7342
LSTM	105.072	145.998	1.9814
SHO-LSTM	110.734	123.7298	1.6114
VMD-SHO-LSTM	72.541	69.8923	0.9007

从表中清楚地看出,RBF、LSTM、SHO-LSTM、VMD-SHO-LSTM 四组模型相比,VMD-SHO-LSTM 模型在各项指标的比较中效果最佳,误差最小,精度最高,预测值最接近实际值。与最大数值 RBF 模型相比,VMD-SHO-LSTM 模型在 MAE 和 RMSE 中均有下降,下降值为 234.443 兆瓦,332.89 兆瓦,在 MAPE 中降低了 4.8335%。

4 结论

本研究创建了一个基于 VMD SHO LSTM 的短期电力负荷预测模型,旨在解决当前的困难,例如复杂的原始负荷数据导致的预测精度差。总的来说,基于 VMD-SHO-LSTM 的负荷预测方法是一种综合利用多种技术的有效预测模型,提高负荷预测的准确性和稳定性。然而,在实际应用

中还需考虑各种因素,实际应用中可能需要考虑算法的计算复杂度和实际运行效率,以及模型的泛化能力,根据实际情况进行调整和优化,提高了预测的准确性和鲁棒性。

基金项目:沈阳市科技计划项目(22-322-3-29)。

[参考文献]

- [1]王延峰,曹育晗,孙军伟.基于多策略改进金豺算法优化 LSTM 的短期电力负荷预测[J].电力系统保护与控制,2024,52(14):95-102.
- [2]刘文杰,刘禾,王英男.基于完整自适应噪声集成经验模态分解的 LSTM-Attention 网络短期电力负荷预测方法[J].电力建设,2022,43(2):98-108.
- [3]杨书强,王涛,檀晓林.基于长短期记忆的图像化短期电力负荷预测方法[J].全球能源互联网,2023,6(3):282-288.
- [4]狄曙光,刘峰,孙建宇.基于改进 ABC 和 IDPC-MKELM 的短期电力负荷预测[J].智慧电力,2022,50(9):74-81.
- [5]张淑清,李君,姜安琦.基于 FPA-VMD 和 BiLSTM 神经网络的新型两阶段短期电力负荷预测[J].电网技术,2022,46(8):3269-3279.

作者简介:冯洋洋(1991.4—),毕业于沈阳农业大学,农业生物环境与能源工程专业,就职于辽宁省能源研究会,能源和碳排放管理师。