现代电力
MODERN ELECTRIC POWER
■ 中国高校优秀科技期刊 ■ 全国中文核心期刊
■ 中国科技核心期刊 ■ 中国知网收录期刊
■ 万方数据收录期刊 ■ 《CAJ-CD规范》执行优秀期刊

基于小波包分解与最小二乘支持向量机的用户侧净负荷预测

吴浩 齐放 张曦 刘友波 向月 刘俊勇

User-side Net Load Forecasting Based on Wavelet Packet Decomposition and Least Squares Support Vector Machine

WU Hao, QI Fang, ZHANG Xi, LIU Youbo, XIANG Yue, LIU Junyong

引用本文:
吴浩, 齐放, 张曦, 等. 基于小波包分解与最小二乘支持向量机的用户侧净负荷预测[J]. 现代电力, 2023, 40(2): 192–200. DOI: 10.19725/j.cnki.1007–2322.2021.0279
WU Hao, QI Fang, ZHANG Xi, et al. User–side Net Load Forecasting Based on Wavelet Packet Decomposition and Least Squares Support Vector Machine[J]. Modern Electric Power, 2023, 40(2): 192–200. DOI: 10.19725/j.cnki.1007–2322.2021.0279

在线阅读 View online: https://doi.org/10.19725/j.cnki.1007–2322.2021.0279

您可能感兴趣的其他文章

Articles you may be interested in

基于自组织特征神经网络和最小二乘支持向量机的短期电力负荷预测方法
Short–Term Load Forecasting Method Based on Self–Organizing Feature Mapping Neural Network and GA–Least Square SVC Model
现代电力. 2021, 38(1): 17–23 https://doi.org/10.19725/j.cnki.1007–2322.2020.0201

计及多能源分频互补的新能源并网调度优化
Dispatching Optimization of Renewable Energy Integrated Grid Considering Multi–energy Frequency Division Complementation
现代电力. 2020, 37(2): 145–151 https://doi.org/10.19725/j.cnki.1007–2322.2019.0209

可再生能源参与电力现货市场关键问题的研究
Discussion on Key Issues of Renewable Energy Participation in the Electricity Spot Market and Its Application on A Case Study
现代电力. 2022, 39(2): 203–211 https://doi.org/10.19725/j.cnki.1007–2322.2020.0388

电力市场环境下考虑可再生能源保障性消纳的电价风险评估
Market Price Risk Analysis Under Background of Renewable Energy Assumption Guarantee
现代电力. 2022, 39(6): 631–639 https://doi.org/10.19725/j.cnki.1007–2322.2021.0111

支持向量机优化的线性插值法在变压器油温预处理中的应用
Application of Prediction Accuracy Interpolation Method Based on Support Vector Machine Optimization in Transformer Oil Temperature Preprocessing
现代电力. 2020, 37(6): 591–597 https://doi.org/10.19725/j.cnki.1007–2322.2019.1112

基于支持向量回归和K均值聚类的降温负荷组合测算模型
Combined Cooling Load Estimation Model Based on Support Vector Regression and K–means Clustering
现代电力. 2019, 36(3): 51–57 http://xddl.ncepujournal.com/article/Y2019/I3/51

第 40 卷 第 2 期
2023 年 4 月

现 代 电 力
Modern Electric Power

Vol.40 No.2
Apr. 2023

文章编号：1007-2322(2023)02-0192-09 文献标志码：A 中图分类号：TM715

基于小波包分解与最小二乘支持向量机的用户侧净负荷预测

吴浩[1]，齐放[2]，张曦[1]，刘友波[1]，向月[1]，刘俊勇[1]

（1. 四川大学 电气工程学院，四川省 成都市 610065；2. 中国广核新能源控股有限公司电力营销部，北京市 丰台区 100072）

User-side Net Load Forecasting Based on Wavelet Packet Decomposition and Least Squares Support Vector Machine

WU Hao[1]，QI Fang[2]，ZHANG Xi[1]，LIU Youbo[1]，XIANG Yue[1]，LIU Junyong[1]

（1. School of Electrical Engineering, Sichuan University, Chengdu 610065, Sichuan Province, China；
2. CGN New Energy Holdings Co.,Ltd., Fengtai District, Beijing 100072, China）

摘要：随着分布式可再生能源在用户侧逐步接入，电表监测得到的用户净负荷曲线形态相对于原有实际负荷曲线更加不稳定，因而极大降低了用户的净负荷预测精度。针对此问题，提出基于小波包分解 (wavelet packet decomposition，WPD) 与最小二乘支持向量机 (least squares support vector machine，LSSVM) 的用户侧净负荷预测方法，通过对用户净负荷时序数据作小波包分解，得到信号特征更为明显的高频分量与低频趋势部分，筛选剔除波动性大、噪声信号多的高频细节分量。同时考虑气象因素，利用最小二乘支持向量机对小样本非线性信号的训练效率高、泛化能力强的特点，采用其模型对其余包含更多有效负荷数据信息的低频分量分别进行预测重构，叠加得到最终的净负荷预测值。通过对可再生能源高度渗透的某地区用户实际净负荷数据进行实例分析，结果表明所提预测方法在此物理场景下相比于传统预测方法有更高的预测精度。

关键词：净负荷预测；可再生能源；小波包分解；最小二乘支持向量机

Abstract：Along with the gradual grid-connection of distributed renewable energy at the user side, relative to original actual load curve the form of users' net load curve monitored by electric meter becomes more unstable, so that the predicted accuracy of users' net load is extremely decreased. For this reason, based on the wavelet packet decomposition (abbr. WPD) and least squares support vector machine (abbr. LSSVM) a method to predict user side net load was proposed. Through the WPD of users' net load time series data the high frequency components and the low frequency trend with more evident signal features were obtained, and the high-frequency detail components, which evidently fluctuated and contained many noise signals, were screened and rejected. Meanwhile, considering meteorological factors and such characteristics of LSSVM as high training efficiency and strong generalization ability, the trained LSSVM model was used to respectively predict and reconstruct other low-frequency components containing more effective load data information, and then superposed them to obtain final predicted value of net load. Results of instance analysis on users' actual net load data of a certain region with high penetration of renewable energy show that under such a physical scene a higher load prediction accuracy can be obtained than by traditional prediction method.

Keywords：net load prediction；renewable energy；wavelet packet decomposition；least squares support vector machine

DOI：10.19725/j.cnki.1007-2322.2021.0279

0 引言

短期负荷预测是电力系统安全稳定运行的重要内容，其对电力系统规划运营、电力市场发展具有重要意义[1-2]。随着电力系统能源转型的需要，可再生能源大量接入电网是时代所需。但是可再生能源的接入使得配电网网络结构由原来的单电源辐射型供电网络变为多电源复杂网络，由此对电网的传统安全造成了较大影响。而且由于可再生能源的波动性，风电与光伏在用户表后大量接入，使用户净负荷曲线展现出极大的不确定性，对原有负荷预测精度适用新物理场景下的净负荷

基金项目：国家自然科学基金资助项目 (51977133)。
Project Supported by the National Natural Science Foundation of China (51977133).

预测造成较大影响，有必要对原有的负荷预测方法做出改进创新。

电力系统短期负荷预测方法主要分为传统方法与智能方法。其中传统方法包含趋势外推法[3]、回归分析法[4]、卡尔曼滤波法[5]等。智能方法包含灰色数学理论[6]、专家系统方法[7]、神经网络理论[8]、模糊负荷预测[9]、小波分析法[10]等。负荷预测随着电力系统管理信息系统的建立及天气预报预测精度的不断提高，获取地区负荷的历史信息及未来天气数据已较为容易，关键在于模型的预测水平高低。在实际应用中，单一预测模型不可能包含所有的影响参数，许多情况下为提升负荷预测精度，需要同时采用多种预测方法，对具体的负荷预测情况进行分析比较，实现多种预测方法的优势互补，并拥有更大的系统信息利用度，从而达到更高的负荷预测精度。在实际应用中，对预测算法模型的优选组合相比单一模型往往能取得更高的预测精度。

当前组合预测方法主要分为两种类型。一种是先分别采用几种单一预测方法分别进行预测，得到各自的预测结果后，再选择适当的权重对预测结果进行加权平均。文献 [11] 结合线性回归模型、趋势外推模型、灰色模型、支持向量机利用模计算方法进行组合预测。文献 [12] 基于长短期记忆 (long short term memory, LSTM) 网络和轻梯度提升机 (light gradient boosting machine, LightGBM) 建立了组合预测模型，以上文献通过优选组合法预测在算例分析中均取得了良好的效果。但加权平均的组合预测方法权重的确定较为困难，且虽同时使用不同预测方法考虑的信息较为全面，但亦不可能将所有影响因素全包含于模型之中，而这也一定程度上限制了预测精度的提高。

另一种是在建模过程中，将负荷时间序列数据利用分解算法进行分离得到性质不同的负荷分量，再利用不同原理的预测方法对分量进行分别预测重构，得到最终的预测结果。文献 [13] 利用小波变换方法对负荷时间序列数据进行分解，进而对负荷子序列采用纵横交叉算法优化神经网络进行预测，组合重构得到负荷数据的预测值。文献 [14] 通过对主动配电网负荷以小波分解方法分解为季节性基荷与需求响应部分，对其采用不同预测方法建立组合预测模型得到预测总负荷。但小波分解并不对时序数据高频信息进行细致分析，无法充分提取负荷全部细节信息。文献 [15] 采用集合经验模态分解算法与最小二乘支持向量机组合建模预测，将预测分量叠加得到最终负荷预测值。最小二乘支持向量机 (least squares support vector machine, LSSVM) 有训练时间短、精度高、泛化性好等优点，对非线性系统有较好的预测精度[16]。尽管集成经验模态分解有利于克服经验模态分解存在的模态混叠问题，但其算法理论依据仍不够完善。相对而言，小波包分解理论更为完备，且相对小波分解可有效提取负荷数据信息，是新物理场景下负荷数据分析的有效方法。

用户侧净负荷数据中包含了光伏、风电数据信息，相对于用户实际负荷其净负荷曲线更不规则、周期性更差，与气象因素有相对更大的关联性。针对用户表后光伏风电接入以致负荷曲线不规则而导致的原有负荷预测精度下降问题，本文采用小波包分解结合 LSSVM 预测方法，利用小波包分解对非线性信号较好的拟合能力与最小二乘支持向量机对小样本非线性信号训练效率高、泛化能力强的特点，实现复杂不确定场景下非侵入式负荷精准预测。首先对用户净负荷曲线进行聚类划分，提取相似日的用户负荷曲线相似特征，有效排除用户行为等影响因素，同时排除了因为不明偶然因素造成的不合理负荷数据。其次对负荷时序数据进行小波包分解，对其中的高频分量进行筛选剔除，有效减少了计算时间。最后结合风力与温度、光照强度等气象因素，利用 LSSVM 模型对低频趋势分量进行回归预测，对各预测分量合成得到用户侧净负荷预测值。对比多元线性回归 (multiple linear regression, MLR)、支持向量回归 (support vector regression, SVR)、高斯过程 (Gaussian process, GP)、深度信念网络 (deep belief network, DBN) 这些已有负荷预测方法预测结果，对某区域的实际用户净负荷算例测试结果验证了所提方法的有效性，提高了用户侧净负荷预测精度，为支撑配电网净负荷预测提供了有效的手段。

1　用户侧净负荷特性

由于用户用电行为及气候因素，传统用户负荷也存在一定的不确定性，但其日负荷曲线整体上呈现出一定的规律性。在此物理场景下，传统负荷预测方法已能达到较好的预测精度。随着可

再生能源在用户表后的逐渐接入，电表监测得到的用户负荷已由用户传统实际负荷转变为净负荷。净负荷的公认定义为总的负荷功率与可再生能源发电功率的差值[17-18]。不同类型负荷中光伏、风电接入示意图如图 1 所示。其用户侧净负荷表达式可表示为

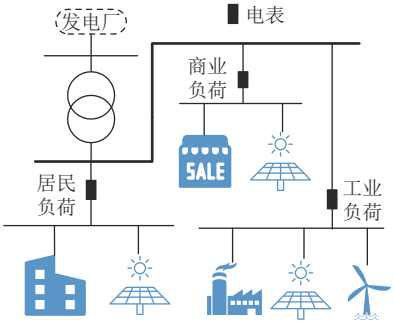

图 1 不同类型负荷可再生能源表后接入示意图

Fig. 1 Sketch map of behind-meter grid-connection of different types of load and renewable energy

$$S = S' + P + W \tag{1}$$

式中：S 为用户净负荷；S' 为用户实际负荷；P 为表后接入光伏功率的相反数；W 为表后接入风电功率的相反数。由于光伏与风电与用户实际负荷一样具有较大不确定性，光伏与风电功率可等同于用户的“负负荷”。光伏、风电的波动性与间歇性增加了用户电表监测得到的用户净负荷曲线的不确定性。

随着全球用户住宅中光伏发电的大量使用，迫切需要将可再生能源大量渗透下传统负荷预测的内容过渡为用户侧净负荷预测[17]。基于此情景，对用户净负荷进行预测研究是一个较新的课题。文献 [18] 在表后仅有光伏接入下对用户净负荷时序数据进行分解独立预测，相对于直接预测方法有更高的预测精度。特别是在光伏渗透率较高的情况下其预测优势更加明显。可见分解预测在用户侧净负荷预测中有较大应用价值。

2 小波包分解算法

小波包分解是由小波分析（wavelet analysis）发展而来，也称为小波包或子带树以及最佳子带树结构。其用分析树表示小波包，利用小波变换的多次叠代从而实现对输入信号的精细分析。相对于小波分解，小波包可对输入信号的高频子带作进一步分解，将高频信号的不同频率成分投影至不同频率空间，克服了小波分解中高频分辨率低的问题[19]。从本质上讲，小波包分解就是将小波分解中高频部分作进一步分解，从而实现对信号更细致的分析。并且，小波包分解能够根据信号特性自适应地选择对应频带匹配信号的频谱，对于波动性较大的净负荷时序数据，能够较好地达到对负荷信号细节的精细分析，提高时频分辨率，在时序信号分析上小波包分解具有广泛的应用价值[20]。

利用小波包分解算法对一般时序数据信号进行分析，可有效提取信号的不同频率成分。得到的各信号分量具有更大的平稳性与周期性，其信号特征更加明显。此外，负荷预测模型往往对波动性大的高频分量具有较低的预测精度，利用小波包分解可提取负荷信号中的高频分量进行筛选，可有效过滤负荷信号高频噪声。

对负荷时序信号进行三层小波包分解，可得到 8 个小波包子空间。其分解小波包树结构图如图 2 所示。其中，S 为输入信号，其分解结果是将信号 S 映射至 $2i$ 个（i 为分解层数）小波包子空间中，其分解公式可表示为

$$\begin{cases} d_l^{j,2n} = \sum_k h_{k-2l} d_k^{j-1,n} \\ d_l^{j,2n+1} = \sum_k g_{k-2l} d_k^{j-1,n} \end{cases} \tag{2}$$

式中：$d_l^{j,2n}$ 和 $d_l^{j,2n+1}$ 为小波包分解第 j 层节点 (j,n) 分解系数，j 为小波尺度参数，其取值范围为 $j \in \{1, 2,\ldots,i\text{-}1,i\}$；$l$、$k$ 为平移参数；n 为频率参数，对应节点所在的频率区间，其取值范围为 $n \in \{0,1,\ldots,2^j\text{-}1\}$；$h^{k\text{-}2l}$、$g^{k\text{-}2l}$ 分别为小波包分解中对应的低通、高通滤波器组；$d_k^{j-1,n}$ 为小波包分解

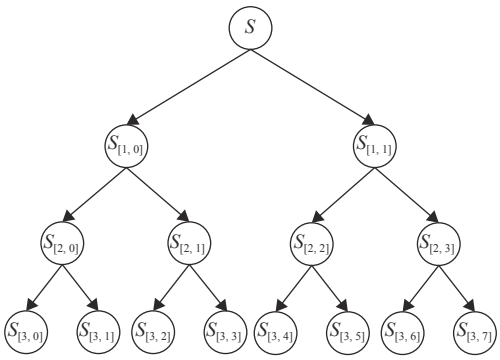

图 2 三层小波包分解结构图

Fig. 2 Structural diagram of three-layer wavelet packet decomposition

第 j-1 层内节点 (j-1,n) 的分解系数。

对时序负荷数据小波包分解系数进行重构，可得到分解后负荷信号的各频段信号。从而实现对原始净负荷数据的频率分解。小波包分解重构算法公式可表示为

$$\bar{d}_l^{j,n} = \sum_k (\bar{h}_{l-2k} d_k^{j+1,2n} + \bar{g}_{l-2k} d_k^{j+1,2n+1}) \tag{3}$$

式中：$\bar{d}_l^{j,n}$为小波包重构第 j 层节点 (j,n) 重构系数；$\bar{h}_{l-2k}$、$\bar{g}_{l-2k}$是小波包重构中对应的低通、高通滤波器组。

3　最小二乘支持向量机原理

最小二乘支持向量机是由支持向量机改进而来，其引入了损失函数与核函数方法，将支持向量机的不等式约束优化问题转化为了等式约束的求解线性方程问题，相对于支持向量机具有更小的计算复杂度与更快的收敛速度[21]。相对于一般神经网络算法采用经验风险最小化原理，最小二乘支持向量机采用结构风险最小化准则，在小样本的情况下也有极好的拟合度，在原始时间序列数据非线性、非高斯的情况下也取得了较好的预测效果，泛化性较强，避免了样本数据太少训练过程过拟合问题。在小样本负荷预测中有较好的回归预测效果。

设用户净负荷训练样本数据为 S，其取值为 S=($\boldsymbol{x}_i$,$\boldsymbol{y}_i$),i=1,2,…,m，其中，m 为训练集样本数量。$\boldsymbol{x}_i$、$\boldsymbol{y}_i$ 为训练集输入与输出矩阵。为实现对未知函数的估计，构造下述线性回归函数：

$$y = \boldsymbol{\omega}^{\mathrm{T}} \varphi(x) + b \tag{4}$$

其中：$\varphi(x)$为映射函数，实现将训练样本数据映射至高维空间；$\boldsymbol{\omega}$ 为对应权值向量；b 为偏置常量。

最小二乘支持向量机基于结构风险最小化准则，在对训练样本集作训练时，其目标函数及等式约束条件为

$$\min J(\boldsymbol{\omega}, e) = \frac{1}{2}\|\boldsymbol{\omega}\|^2 + \frac{1}{2} C \sum_{i=1}^{N} e_i^2 \tag{5}$$

$$y_i = \boldsymbol{\omega}^{\mathrm{T}} \varphi(x_i) + b + e_i, i = 1, 2, \cdots, m \tag{6}$$

其中：J 为惩罚函数；e_i 为训练样本数据偏差；e 为输出误差；C 为正则化参数，可调节对误差项的惩罚力度，y_i 为输出向量元素。求解上述线性方程，构造拉格朗日函数为

$$L(\boldsymbol{\omega}, b, e, \beta) = J(\boldsymbol{\omega}, e) + \sum_{i=1}^{m} \beta_i [y - \boldsymbol{\omega}^{\mathrm{T}} \varphi(x_i) - b - e_i] \tag{7}$$

其中 β_i 为拉格朗日乘数。

拉格朗日函数分别对各变量求偏导，由 KTT 条件，计算消除变量 $\boldsymbol{\omega}$ 和 e，得到预测模型如式 (8) 所示。

$$y(\boldsymbol{x}) = \sum_{i=1}^{m} \beta_i K(\boldsymbol{x}, x_i) + b \tag{8}$$

其中：$\boldsymbol{x}$ 为支持向量；$\boldsymbol{x}_i$ 为第 i 个支持向量输入元素，K($\boldsymbol{x}$,$\boldsymbol{x}_i$) 为对应核函数，文中选取 RBF 核函数，其表达式如式 (9) 所示。

$$K(\boldsymbol{x}, x_i) = \exp\left(-\frac{\|x_i - \boldsymbol{x}\|^2}{2\sigma^2}\right) \tag{9}$$

4　小波包分解与 LSSVM 组合预测过程

在信号高频部分的分解保证了小波包分解在整个频带上有相同的频率分辨率。其分解的层数影响总体预测时间。三层小波包分解从理论上可以拟合一切非线性函数，具有较强的工程实用性。本文将分解层数设定为 3 层，首先对用户侧净负荷数据作预处理，然后采用小波包分解，得到不同频段的净负荷信号信息。分解后不同频段的负荷信息能呈现出较强的规律性与周期性，在此基础上便可实现负荷预测误差的降低，达到更高的预测精度。对一维信号进行小波包分解后，可对信号分量按频率不同从小到大进行排序，进而利用 LSSVM 模型预测各负荷分量。

4.1　整体思路

首先对净负荷数据作预处理，得到均值为零的净负荷时间序列数据。净负荷训练数据的零均值化处理可消除负荷序列中直流分量影响，凸显负荷数据信号特征。第二步对得到的零均值负荷时序数据进行三层小波包分解与重构，8 个小波包子空间对应净负荷数据 8 个不同频段的时序分量，将其按频率大小排序，各分量具有更明显的时序特征。在此基础上，对幅值较低、波动性较大的高频分量进行筛选剔除，最终得到低频趋势部分，有效去除了负荷噪声，解决了一般负荷预测方法对高频分量预测精度不佳的问题。对所有低频分量分别利用最小二乘支持向量机模型进行

预测并合成，最终得到用户侧净负荷预测结果。可通过相关评价指标将预测值与真实值进行比较分析，检验预测精度。

基于小波包分解与 LSSVM 的用户侧净负荷预测整体思路如图 3 所示。

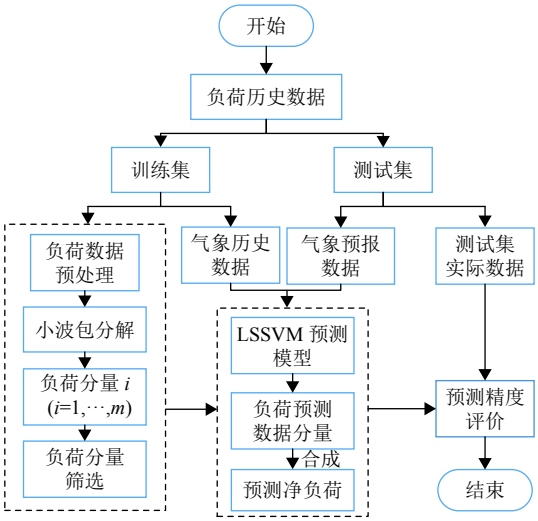

图 3 基于 WPD 与 LSSVM 的净负荷预测思路

Fig. 3 Net load forecasting based on WPD and LSSVM

4.2 数据预处理

用户侧净负荷数据与天气数据呈现一定的周期性，但负荷数据和天气数据的周期性变化通常是相互独立的。比如晚上负荷一般比较重，主要是用户的日常行为，而不是天气变化的原因。因此，当匹配它们的变化特征时，可以只检查其非周期性变化，以便识别不同数据集之间的相关性。

为消除负荷时序数据的长期周期性，本文采用 K-means 聚类算法[22]，将相似的日负荷曲线整理划分成一个簇。然后，周期数据采用特定集群的平均日负荷曲线表示为

$$\overline{S_D^i(t)} = \frac{1}{D_k} \cdot \sum_{j=1}^{D_k} S_D^j(t) \tag{10}$$

其中：D_k 为第 k 个聚类的天数；$\overline{S_D^i(t)}$ 是第 i 个聚类的净负荷周期数据；$S_D^j(t)$ 是第 j 天的时间序列数据。预处理对应非周期变化的数据可由式 (11) 计算。

$$S^i(t) = S_D^i(t) - \overline{S_D^i(t)} \tag{11}$$

其中 $S^i(t)$ 为第 i 个聚类预处理后的净负荷序列。文中净负荷数据均以此方法作预处理，从而提取它们的偏差特征。由此建立均值为 0 的净负荷时间序列特征库，消除了数据中占比较大的直流周期分量，以便后续作小波包分解。

4.3 评价指标

为评价本文所提算法的负荷预测效果，选取了平均绝对百分误差 (mean absolute percentage error，MAPE) 和均方根误差 (root mean square error，RMSE) 作为预测模型的评价指标，其计算公式表示如下：

$$e_{\mathrm{MAPE}} = \frac{1}{n} \sum_{i=1}^{n} \frac{|y_i - y_i^*|}{y_i} \times 100\% \tag{12}$$

$$e_{\mathrm{RMSE}} = \sqrt{\frac{\sum_{i=1}^{n} (y_i - y_i^*)^2}{n}} \tag{13}$$

其中：n 为测试集负荷样本个数；y_i 与 y_i^* 表示净负荷需求的实际值与预测值。e_{MAPE} 代表了预测结果偏差的百分比，e_{RMSE} 代表了预测结果偏差的绝对值，它们的值越小，代表预测结果与实际负荷值越接近。

5 算例分析

为解决用户侧可再生能源波动带来的传统负荷预测精度下降问题，本文提出了基于小波包分解与最小二乘支持向量机的用户侧净负荷预测方法，将用户净负荷历史时序数据作小波包分解，对幅值较低的高频分量进行筛选剔除，对剩下的幅值更大的低频分量分别进行预测合成，将预测出的各部分数据综合便得到用户净负荷预测数据。

采用某区域实际年负荷数据中一个季度作为整体数据集，选取 3—5 月 3 个月的负荷数据，聚类划分提取相似日特征，得到 36 天的负荷数据作为用户负荷数据集，以每小时为数据采样间隔总计 864 个小时数据，其中包含用户实际负荷、净负荷、光伏、风电等功率数据以及太阳辐射强度、风速、温度等气象参数数据。以 17:1 比例划分数据集，即以前 34 天负荷及气象数据为训练集，最后两天数据作为测试集。以太阳辐射强度、风速、温度这 3 个维度数据作为输入自变量。天气因素与用户实际负荷大小紧密相关，风速与风电功率、太阳辐射强度与光伏功率分别有直接的相关关系。在此算例用户年实际负荷数据中，可再生能源发电功率平均占用户实际负荷功率 21% 左右。选取前 34 天每时刻数据作为训练集进行训练分析，其中 4 天的负荷曲线及其功率成分如图 4 所示。

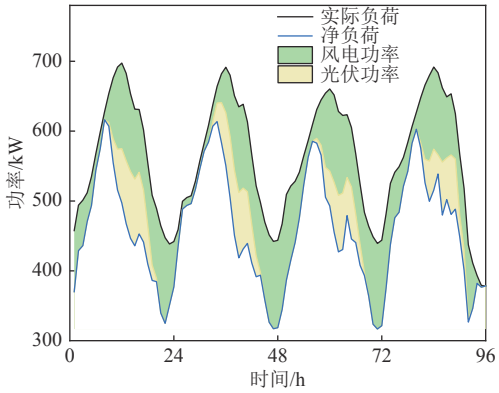

图 4　用户负荷曲线及功率成分

Fig. 4　Users' load curve and the composition of power

由图 4 可知，在光伏、风电在用户侧表后大量渗透下，用户净负荷曲线虽然还保留有一定日负荷曲线的周期性，但由于风电与光伏功率的存在使其波动性更为明显以及曲线形态更不规则。

5.1　净负荷原始曲线的小波包分解与重构

将用户侧净负荷训练集数据作数据预处理后，得到一均值为 0 的时间序列信号。取采样频率为 512 Hz，对时序信号作 Fourier 时频变换分析，得到包含净负荷偏差特征的 0~256 Hz 上的信号频谱图如图 5 所示。由图可知，净负荷数据各频率成分主要集中于低频部分，高频分量中信号波动性大，但其幅值较小，在整个输入信号中占比极小。

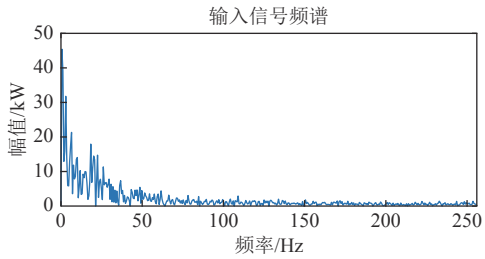

图 5　净负荷输入信号频谱

Fig. 5　The spectrum of net load input signal

尽管多层小波包可实现对信号更细致的分析，但多层小波包分解会增加输出信号维数，增大算法复杂度并增加算法运行时间。三层小波包分解从理论上可以达到对一般信号较好的拟和分析[23]。利用三层小波包对非线性信号强大的拟和能力，对负荷信号进行处理训练，可分解得到 S(3,0)、S(3,1)、S(3,2)、S(3,3)、S(3,4)、S(3,5)、S(3,6)、S(3,7) 这 8 个小波包子空间。对应 1~32 Hz、33~64 Hz、65~96 Hz、97~128 Hz、129~160 Hz、161~192 Hz、193~224 Hz、225~256 Hz 这 8 个不同频段的用户净负荷时序数据分量。负荷曲线中低频分量相对于高频成分占比较大，前 2 个频段信号集中了净负荷信号中主要成分，其能量总和占总净负荷数据达到 97.31%。后 6 个频率较高的频段信号能量总和仅占 2.69%。

时序负荷数据通过小波包分解重构后的不同频段信号随时间变化波形图如图 6 所示。

由图 6 可知，小波包分解重构后不同频段时间序列数据更具规律性和平稳性，其中一些时段变化趋势基本相同。从各频段分量整体来看，频率越高，其分量幅值越小。

5.2　面向净负荷时序分量的 LSSVM 模型预测

对用户净负荷时序数据作小波包分解得到各个不同频段的负荷分量，再利用 LSSVM 模型对各分量进行预测合成。本文在小波包分解得到各净负荷频段分量基础上，建立用户净负荷 LSSVM 预测模型。在训练集数据中以太阳辐射强度、温度、风速历史时序数据作为自变量，净负荷分量数据作为输出变量，对 LSSVM 模型进行训练，其训练过程如图 7 所示。

净负荷数据小波包分解分量中高频分量幅值较小，在净负荷总成分中占比极小，同时其波动性较大，且含有较大信号噪声，单独预测精度较差。通过对高频历史负荷分量逐步进行筛选剔除，以平均绝对百分误差 e_{MAPE} 和均方根误差 e_{RMSE} 作为预测结果评估指标，进而确定预测效果最好时净负荷分量的输入阶次。其结果如表 1 所示。

由表 1 可知，输入负荷分量为 1~5 时平均绝对百分误差为 4.78%，均方根误差为 34.996 kW，此时两项评价指标均达到最小值。故确定模型输入分量阶次为 5，剔除 3 个频率最大的高频分量。由于高频分量整体在总净负荷量中的占比较小，故而利用不同数量负荷分量预测最终均方根误差值相差不大。而通过对低幅值的高频负荷分量进行筛选剔除，可以大幅降低预测算法的运行时间。

在净负荷数据三层小波包分解得到 8 个小波包分量后，通过评价筛选剔除 3 个高频分量，将剩下的 5 个低频时序分量各自训练 LSSVM 模型，利用测试集中两天总计 48 h 的温度、风速、太阳辐射强度 3 项气象数据作为模型输入，得到各负荷分量预测结果。对各分量进行叠加合成，便得到用户净负荷预测值。

5.3　预测方法效果对比

为验证基于小波包分解与 LSSVM 预测方法

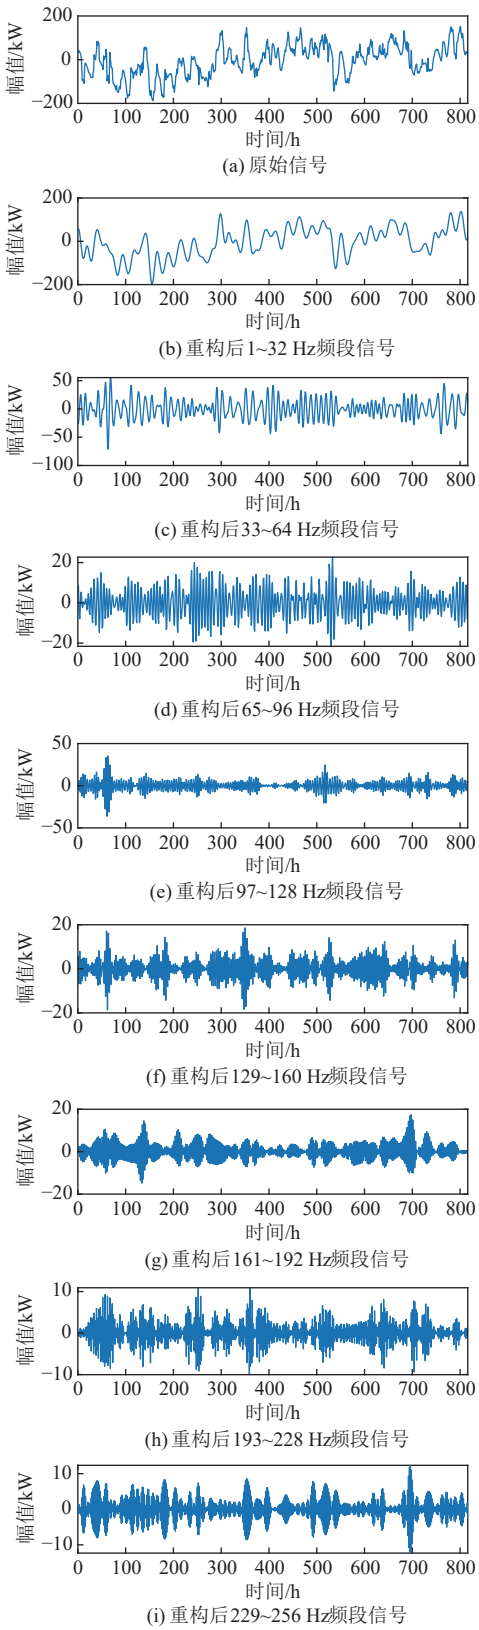

图 6 小波包分解净负荷分量信号波形图

Fig. 6 Waveform of net load component decomposed by wavelet packet

表 1 WPD-LSSVM 方法预测误差

Table 1 Forecasting errors by WPD-LSSVM

分量	MAPE/%	RMSE/kW
1~8	4.99	36.1982
1~7	4.91	35.7546
1~6	4.93	35.83
1~5	4.78	34.996
1~4	4.86	35.5732
1~3	5.07	37.2023
1~2	4.94	35.77
1	5.13	38.4095

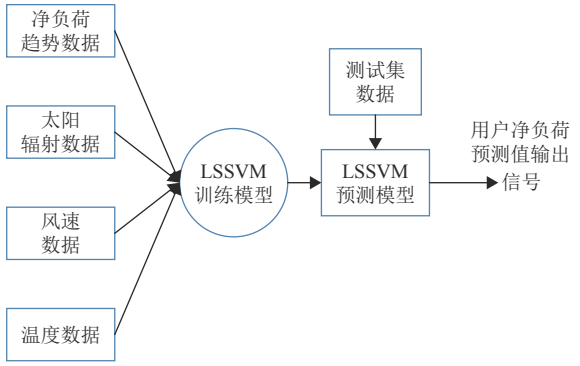

图 7 LSSVM 模型训练过程

Fig. 7 The training process of LSSVM model

的有效性，本文另外研究了 MLR、SVR、GP、DBN4 种常见的传统预测方法与机器学习预测方法，通过对比这些方法的直接预测效果以及对应与小波包分解算法组合的预测效果的性能提升，验证本文所提方法的有效性。其中前 4 种方法最终的用户净负荷需求预测结果如图 8 所示。

在机器学习算法中，一般参数的选取都是通过尝试得来。DBN 学习过程较慢，参数选取的不恰当会使得模型局部收敛于最优解，而 DBN 模型至今没有极为成熟的调参方法。算例中 DBN 直接预测方法相对于许多传统直接预测方法有更好的负荷预测精度，但由于其参数调节的不确定性，其与小波包分解组合预测方法相对于直接预测并没有取得较好的效果提升，反而有较大下降。且最终预测结果波形为近似正弦波，与实际值波形相差较远，说明小波包分解算法不宜与 DBN 模型结合作短期负荷预测。各种算法的直接预测效果与分解预测效果及其性能提升如表 2 所示。

由表 2 可以看出，采用 LSSVM 直接预测的误差 e_{MAPE} 值为 5.18%，均优于其他各种直接预测算法。采用小波包分解与 LSSVM 组合预测最

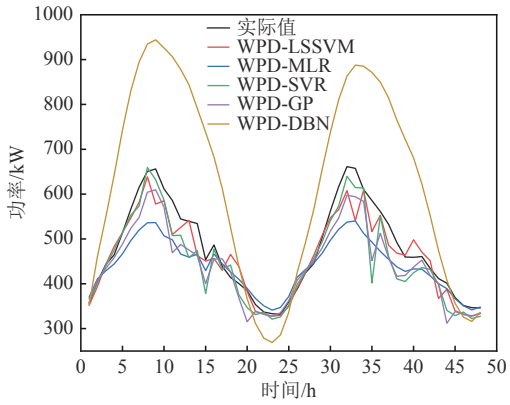

图 8　不同分解预测算法预测结果

Fig. 8　The forecasting results of different decomposition prediction algorithms

表 2　不同方法预测误差

Table 2　Forecasting errors by different methods

方法	直接预测/%	WPD组合预测/%	性能提升/%
MLR	8.25	7.91	4.12
SVR	6.31	5.95	5.71
GP	7.48	7.29	2.54
DBN	5.78	29.34	—
LSSVM	**5.18**	**4.78**	**7.72**

终的预测误差 e_{RMSE} 值为 4.78%，相对 LSSVM 直接预测结果将 e_{MAPE} 值降低了 7.72%，达到了较好的预测效果，相对优于其他各种组合预测算法。

除 DBN 外的各种预测模型与小波包分解算法组合预测相对于直接预测在预测性能上均有所提升。这是由于对净负荷数据进行小波包分解后得到的负荷分量中低频分量有较大的幅值，其在净负荷总量中占比绝大部分，而负荷模型对波动性较小的低频分量有更好的预测精度。此外，对高频分量的筛选处理，使得预测方法较好避免了高频信号预测精度不佳的问题，减少输入变量维数减少了算法复杂度，同时消除了不必要的高频噪声误差。

6　结论

随着国家碳达峰、碳中和目标的明确提出，分布式可再生能源在用户表后渗透将更为普遍。本文针对用户表后光伏、风电大量接入时负荷直接预测精度下降情况下提出基于小波包分解与 LSSVM 的净负荷预测方法，建立了负荷预测组合模型，从数据层面出发，充分利用了小波包分解与 LSSVM 对非线性信号的良好处理效果，将原始净负荷数据分解为若干个频率、幅值不一的时序分量并作组合预测。通过对某地区实际净负荷数据作算例分析，相对传统方法具有更好的预测优势，表明本文方法更适用于不确定场景下的负荷预测。

本文提出的用户侧净负荷预测方法是从信号数据分析的角度对用户净负荷时序数据进行分析，取得了较好的预测精度，具有一定的实用价值。在未来的研究中可进一步考虑太阳辐射强度与风速等因素对光伏风电功率的直接影响，并与其他分解预测算法相结合，通过集成预测进一步提高预测精度。

参考文献

[1] 李闯, 孔祥玉, 朱石剑, 等. 能源互联环境下考虑需求响应的区域电网短期负荷预测[J]. 电力系统自动化, 2021, 45(1): 71−78.
LI Chuang, KONG Xiangyu, ZHU Shijian, *et al*. Short-term load forecasting of regional power grid considering demand response in energy interconnection environment[J]. Atomation of Electric Power Systems, 2021, 45(1): 71−78(in Chinese).

[2] 李焱, 贾雅君, 李磊, 等. 基于随机森林算法的短期电力负荷预测[J]. 电力系统保护与控制, 2020, 48(21): 117−124.
LI Yan, JIA Yajun, LI Lei, *et al*. Short term power load forecasting based on a stochastic forest algorithm[J]. Power System Protection and Control, 2020, 48(21): 117−124(in Chinese).

[3] WANG J, JIA R, ZHAO W, *et al*. Application of the largest Lyapunov exponent and non-linear fractal extrapolation algorithm to short-term load forecasting[J]. Chaos, Solitons & Fractals, 2012, 45(9-10): 1277−1287.

[4] 彭曙蓉, 黄士峻, 李彬, 等. 基于深度学习分位数回归模型的充电桩负荷预测[J]. 电力系统保护与控制, 2020, 48(2): 44−50.
PENG Shurong, HUANG Shijun, LI Bin, *et al*. Charging pile load prediction based on deep learning quantile regression model[J]. Power System Protection and Control, 2020, 48(2): 44−50(in Chinese).

[5] 赵峰, 孙波, 张承慧. 基于多变量相空间重构和卡尔曼滤波的冷热电联供系统负荷预测方法[J]. 中国电机工程学报, 2016, 36(2): 399−406.
ZHAO Feng, SUN Bo, ZHANG Chenghui. Cooling, heating and electrical load forecasting method for CCHP system based on multivariate phase space reconstruction and kalman Filter[J]. Proceedings of the CSEE, 2016, 36(2): 399−406(in Chinese).

[6] SREEKUMAR S, SHARMA K C, BHAKAR R. Grey sys-

tem theory based net load forecasting for high renewable penetrated power systems[J]. Technology and Economics of Smart Grids and Sustainable Energy, 2020, 5(1): 1−14.

[7] BUI D K, NGUYEN T N, NGO T D, *et al*. An artificial neural network (ANN) expert system enhanced with the electromagnetism-based firefly algorithm (EFA) for predicting the energy consumption in buildings[J]. Energy, 2020, 190: 116370.

[8] SINGH P, DWIVEDI P. Integration of new evolutionary approach with artificial neural network for solving short term load forecast problem[J]. Applied Energy, 2018, 217: 537−549.

[9] LI C. A fuzzy theory-based machine learning method for workdays and weekends short-term load forecasting[J]. Energy and Buildings, 2021, 245: 111072.

[10] HU Y, YE C, DING Y, *et al*. Short - term load forecasting utilizing wavelet transform and time series considering accuracy feedback[J]. International Transactions on Electrical Energy Systems, 2020, 30(7): e12455.

[11] 白杨, 赵冠, 窦金延, 等. 基于并行膜计算的短期电力负荷组合预测[J]. 电力系统保护与控制, 2017, 45(7): 35−42.
BAI Yang, ZHAO Guan, DOU Jinyan, *et al*. Short-term power load combination forecasting based on parallel membrane computing[J]. Power System Protection and Control, 2017, 45(7): 35−42(in Chinese).

[12] 陈纬楠, 胡志坚, 岳菁鹏, 等. 基于长短期记忆网络和LightGBM组合模型的短期负荷预测[J]. 电力系统自动化, 2021, 45(4): 91−97.
CHEN Weinan, HU Zhijian, YUE Jingpeng, *et al*. Short-term load prediction based on combined model of long-short-term memory network and light gradient boosting machine[J]. Automation of Electric Power Systems, 2021, 45(4): 91−97(in Chinese).

[13] 孟安波, 胡函武, 刘向东. 基于纵横交叉算法优化神经网络的负荷预测模型[J]. 电力系统保护与控制, 2016, 44(7): 102−106.
MENG Anbo, HU Hanwu, LIU Xiangdong. Short-term load forecasting using neural network based on wavelets and crisscross optimization algorithm[J]. Power System Protection and Control, 2016, 44(7): 102−106(in Chinese).

[14] 苏小林, 刘孝杰, 阎晓霞, 等. 计及需求响应的主动配电网短期负荷预测[J]. 电力系统自动化, 2018, 42(10): 60−66+134.
SU Xiaolin, LIU Xiaojie, YAN Xiaoxia, *et al*. Short term load forecasting of active distribution network based on demand response[J]. Automation of Electric Power Systems, 2018, 42(10): 60−66+134(in Chinese).

[15] 王新, 孟玲玲. 基于EEMD-LSSVM 的超短期负荷预测[J]. 电力系统保护与控制, 2015, 43(1): 61−66.
WANG Xin, MENG Lingling. Ultra-short-term load forecasting based on EEMD-LSSVM[J]. Power System Protection and Control, 2015, 43(1): 61−66(in Chinese).

[16] 方必武, 刘涤尘, 王波, 等. 基于小波变换和改进萤火虫算法优化LSSVM的短期风速预测[J]. 电力系统保护与控制, 2016, 44(8): 37−43.
FANG Biwu, LIU Dichen, WANG Bo, *et al*. Short-term wind speed forecasting based on WD-CFA-LSSVM model[J]. Power System Protection and Control, 2016, 44(8): 37−43(in Chinese).

[17] RAZAVI S E, AREFI A, LEDWICH G, *et al*. From load to net energy forecasting: short-term residential forecasting for the blend of load and PV behind the meter[J]. IEEE Access, 2020, 8: 224343-224353.

[18] WANG Y, ZHANG N, CHEN Q, *et al*. Data-driven probabilistic net load forecasting with high penetration of behind-the-meter PV[J]. IEEE Transactions on Power Systems, 2017, 33(3): 3255−3264.

[19] 叶瑞丽, 郭志忠, 刘瑞叶, 等. 基于小波包分解和改进Elman神经网络的风电场风速和风电功率预测[J]. 电工技术学报, 2017, 32(21): 103−111.
YE Ruili, GUO Zhizhong, LIU Ruiye, *et al*. Wind speed and wind power forecasting method based on wavelet packet decomposition and improved elman neural network[J]. Transactions of China Electrotechnical Society, 2017, 32(21): 103−111(in Chinese).

[20] 朱刘柱, 王绪利, 马静, 等. 基于小波包分解与循环神经网络的综合能源系统短期负荷预测[J]. 电力建设, 2020, 41(12): 131−138.
ZHU Liuzhu, WANG Xuli, MA Jing, *et al*. Short-term load forecast of integrated energy system based on wavelet packet decomposition and recurrent neural network[J]. Electric Power Construction, 2020, 41(12): 131−138(in Chinese).

[21] 杨旭琼. 基于最小二乘支持向量机的超短期风功率组合预测模型研究[D]. 长沙: 湖南大学, 2017.

[22] YANG S, SHEN C. A review of electric load classification in smart grid environment[J]. Renewable and Sustainable Energy Reviews, 2013, 24: 103−110.

[23] 徐冬梅, 张一多, 王文川. 基于小波包分解的LS-SVM-ARIMA组合降水预测[J]. 南水北调与水利科技(中英文), 2020, 18(6): 71−77.

收稿日期：2021−10−16

作者简介：

吴浩 (1995)，男，硕士研究生，研究方向为电力系统负荷预测，E-mail:wuhao3@stu.scu.edu.cn；

齐放 (1983)，男，硕士，工程师，从事电力系统运行与运营工作；

张曦 (1990)，男，博士研究生，通信作者，研究方向为主动配电网规划与运行，E-mail：zx1800@126.com。