

丁宏¹ 陶晓峰¹ 陆春艳¹ 张士成¹

基于 RWT-SVM 的台区配电网日前负荷预测研究

摘要

日前负荷预测对于制定合理的调度计划,保证电力系统安全可靠具有重要意义.电力负荷时间序列通常存在随机误差,而基于智能算法的预测模型为了充分提取负荷信息,结构复杂、计算量大.为此,本文利用台区配电网的历史电力负荷时间序列,提出一种基于重复小波变换-支持向量机(RWT-SVM)混合模型的日前电力负荷预测方法.该方法利用小波变换技术将台区配电网电力负荷时间序列分解为多个子序列;利用平均绝对误差(MAE)计算每个子序列的预报误差贡献度;对MAE最大的序列进一步分解,从而提升模型的预测能力,得到精度更高的预测结果.仿真结果表明,RWT-SVM混合模型的预测精度高于三种对比方法.

关键词

负荷预测;小波变换;支持向量机;配电网

中图分类号 TM743

文献标志码 A

收稿日期 2022-05-31

资助项目 国家电网公司科技项目(524608210006)

作者简介

丁宏,高级工程师,主要研究方向为台区负荷预测等.3582296810@qq.com

1 南瑞集团有限公司(国网电力科学研究院),南京,211000

0 引言

电力系统调度中心担负着制定电网运行计划、确定运行方式的重要责任,对于确保电网安全稳定运行起着关键作用.调度中心根据负荷预测结果制定第二天调度计划,因此需要对次日负荷进行预测,即日前负荷预测^[1].准确的负荷预测是电网安全经济运行的前提.

针对配电网日前负荷预测问题,文献[2]以当日负荷曲线为基值进行动态滚动建模,提出一种基于逐日分段气象算法的日前电力负荷预测方法.该方法能够对基础负荷增长引入误差进行有效修正.文献[3]针对售电商不同区域售电情况下偏差考核问题,提出一种反馈迭代优化的自适应组合预测模型,进一步提升了日前负荷预测的准确性.随着人工智能技术^[4-5]的快速发展,将智能算法用于预测研究引起了众多学者的关注^[6-7].文献[8]提出一种基于多模糊相似日和多门控循环神经网络单元(GRU)的微电网系统负荷日前精准预测模型,负荷预测区间覆盖率以及区间平均宽度效果较好.然而,基于智能算法的预测模型都需要大量历史数据进行训练,针对样本规模较小的问题,文献[9]提出一种基于pinball损失函数的深度长短时记忆网络概率预测方法.文献[10]通过提取小样本特征给出特征相似度和时间遗忘因子的特征融合策略,进而提出一种基于迁移学习的负荷预测方法,能够有效进行小样本电力负荷预测.文献[11]在GRU的基础上引入噪声辅助复数据经验模态分解(NACEMD)方法对日前负荷数据进行分解,提出一种基于NACEMD-GRU的组合型日前负荷预测方法,能够进一步降低分解结果的模态混叠度,有效提高日前负荷预测精度.除了NACEMD外,小波变换技术(WT)也是一种被广泛应用的数据分解技术^[12].为了提高滤波灵敏度和辨识频率精度,文献[13]利用小波变换技术与奇异值分解在线估计频率,采用先验信息对估计结果做进一步处理,并据此调整中心频率,提出一种基于小波变换技术与奇异值分解相结合的自适应陷波滤波方法.为了提升电力系统稳态和时变间谐波信号的检测精度,文献[14]将小波变换和小波包变换技术应用到电力系统稳态和暂态情况下谐波的相位和幅值的检测问题,结果表明该方法具有良好的时频局部化特性,能够更好地聚焦信号细节,提高检测精度.

上述基于智能算法的负荷预测模型为了能够充分提取负荷时间序列的有效信息,模型结构通常十分复杂,模型训练过程计算量十分巨大.此外,负荷时间序列通常为测量数据,难免存在测量误差,这也会影响模型训练效果和负荷预测精度,解决该问题的一个有效方法是对历史负荷数据进行特征分解.特征分解不但具有滤波性能,同时还能够提取出更有价值的负荷信息.本文通过小波变换技术对负荷时间序列先进行特征提取,再通过智能算法利用提取到的特征对负荷进行预测,从而有效提取并利用负荷数据信息,提高预测精度.利用小波变换技术对电力负荷时间序列进行分解,得到多个子序列,利用平均绝对误差(MAE)计算每个子序列的预报误差贡献度,对平均绝对误差最大的序列进一步分解,本文提出一种基于重复小波变换-支持向量机(RWT-SVM)混合模型的日前台区配电网电力负荷预测方法,可以提升预测能力.

1 小波变换-支持向量机

1.1 小波变换

台区配电网电力负荷为一组时间序列,负荷序列的特征能够通过小波变换进行获取.小波变换通过频率分解提取负荷时间序列中不同频率成分的特征信息.小波变换可分为连续小波变换和离散小波变换.与连续小波变换相比,离散小波变换内存需求低,更适用于电力负荷预测.对某离散信号进行小波变换能够得到不同分辨率下的信号集合.目前常用的离散小波变换为极大重叠离散小波变换(Maximum Overlap Discrete Wavelet Transform, MODWT).MODWT能够处理任意抽样尺寸,分辨率高,同时还具有平移不变性,此外,MODWT能够产生更加渐近有效的方差估计量^[15].

对于电力负荷时间序列,采用MODWT进行分解能够有效降低数据信息的损失.MODWT的小波系数和尺度系数定义如下:

$$\begin{cases} P_{1,k} = \sum_{m=0}^{T-1} p_m X_{k-m}, \\ S_{1,k} = \sum_{m=0}^{T-1} s_m X_{k-m}, \end{cases} \quad k = 0, 1, \dots, N, \quad (1)$$

其中: $P_{1,k}$ 和 $S_{1,k}$ 分别为MODWT的首层小波系数和尺度系数; X_{k-m} 为原始的离散时间序列的第 $k-m$ 个元素,时间序列长度为 N ; p_m 和 s_m 分别为小波滤波器和尺度滤波器; T 为变换宽度. p_m 和 s_m 有下列性质:

$$\begin{cases} \sum_{m=0}^{T-1} p_m = 0, \sum_{m=0}^{T-1} p_m^2 = 0.5, \sum_{m=0}^{T-1} p_m p_{m+2n} = 0, \\ \sum_{m=0}^{T-1} s_m = 0, \sum_{m=0}^{T-1} s_m^2 = 0.5, \sum_{m=-\infty}^{+\infty} s_m s_{m+2n} = 0, \\ \sum_{m=-\infty}^{+\infty} s_m p_{m+2n} = 0. \end{cases} \quad (2)$$

对于第 i 层MODWT的小波系数和尺度系数,其定义为

$$\begin{cases} P_{i,k} = \sum_{m=0}^{T-1} p_{i,m} X_{k-m}, \\ S_{i,k} = \sum_{m=0}^{T-1} s_{i,m} X_{k-m}, \end{cases} \quad k = 0, 1, \dots, N, \quad (3)$$

其中: $P_{i,k}$ 和 $S_{i,k}$ 分别为第 i 层MODWT小波系数和尺度系数向量的元素; $p_{i,m}$ 和 $s_{i,m}$ 分别为第 i 层MODWT小波滤波器和尺度滤波器.

1.2 支持向量机

对于给定的数据集 $\{(x_1, y_1), (x_2, y_2), \dots\}$, \mathbf{x} 和 \mathbf{y} 分别为输入和输出变量,回归分析就是要通过一个估计模型 $f(\mathbf{x})$, 通过函数关系 $\mathbf{y} = f(\mathbf{x})$ 由输入变量 \mathbf{x} 得到输出 \mathbf{y} . 回归分析可以由估计模型 $f(\mathbf{x})$ 的属性进行分类. 如果 $\mathbf{y} = f(\mathbf{x})$ 为线性方程, 则该回归问题为一个线性回归问题. 线性回归分析的模型形式为 $\mathbf{y} = f(\mathbf{x}) = \mathbf{w}\mathbf{x} + \mathbf{b}$, \mathbf{w} 为权重向量, \mathbf{b} 为偏置向量. 支持向量机模型(Support Vector Machine, SVM)本质上为一个优化问题. 对于如下非线性估计模型:

$$\hat{\mathbf{y}} = f(\mathbf{x}) = \boldsymbol{\omega}^T \boldsymbol{\phi}(\mathbf{x}_i) + \mathbf{b}, \quad \forall i \in \{1, 2, \dots, l\}, \quad (4)$$

其中: $\hat{\mathbf{y}}$ 为输出量预测值; \mathbf{x} 为输入量; \mathbf{w} 为权重向量; \mathbf{b} 为偏置向量; $\boldsymbol{\phi}$ 为一个高维的特征空间. 支持向量机回归就是将式(4)所示的估计问题转化为如下的凸优化问题:

$$\min J = \boldsymbol{\omega}^T \boldsymbol{\omega}, \quad (5)$$

$$\text{s.t.} \quad \begin{cases} \mathbf{y}_i - (\boldsymbol{\omega}^T \boldsymbol{\phi}(\mathbf{x}_i) + \mathbf{b}) \leq \varepsilon, \\ \mathbf{y}_i - (\boldsymbol{\omega}^T \boldsymbol{\phi}(\mathbf{x}_i) + \mathbf{b}) > \varepsilon, \end{cases} \quad (6)$$

其中: \mathbf{x}_i 和 \mathbf{y}_i 分别为第 i 个输入和输出量; ε 为实际值和预测值之间的最大允许偏差.

为了避免优化问题的解落入不可行域内, 引入松弛因子 ξ , 将优化模型进行如下改进:

$$\min J = \boldsymbol{\omega}^T \boldsymbol{\omega} + C \sum_{i=1}^l (\xi_i^+ + \xi_i^-), \quad (7)$$

$$\text{s.t.} \quad \begin{cases} \mathbf{y}_i - (\boldsymbol{\omega}^T \boldsymbol{\phi}(\mathbf{x}_i) + \mathbf{b}) \leq \varepsilon + \xi_i^+, \\ \mathbf{y}_i - (\boldsymbol{\omega}^T \boldsymbol{\phi}(\mathbf{x}_i) + \mathbf{b}) > \varepsilon + \xi_i^-, \\ \xi_i^+, \xi_i^- \geq 0, \end{cases} \quad (8)$$

其中: C 为一个大于 0 的惩罚因子; ξ_i^+ , ξ_i^- 均为松弛因子. 为求解该优化问题, 通常构造拉格朗日函数, 并求解拉格朗日函数的解, 最终得到优化模型 (7) 和 (8) 的解.

1.3 小波变换-支持向量机模型

基于支持向量机的回归模型需要选择合适的时间窗长和输入输出数据集. 日前负荷预测的输出数据集是由输入数据集统一转化生成的, 然后由基于支持向量机的回归模型预测未来的时间序列. 输入输出数据集的生成如图 1 所示.




图 1 输入输出数据集

Fig. 1 Input and output datasets

基于小波变换-支持向量机 (Wavelet Transform-Support Vector Machine, WT-SVM) 模型以合适的时间窗长度生成输入输出数据集. 数据集通过小波变换分解为不同的子序列. 通过分解, 输入和输出子序列是由细节小波系数和近似小波系数构成的. 每一对输入输出子序列对应一个分解级数. 支持向量机回归模型就是利用这些输入输出子序列进行预测. 图 2 给出了基于小波变换-支持向量机模型的电力负荷预测算法流程.

2 重复小波变换-支持向量机负荷预测

电力用户用电行为使得电力负荷呈现重复趋势, 但是并没有确定的周期, 而小波变换能够有效获取负荷信息. 小波变换的输出是负荷子序列的集合. 通过极大重叠离散小波变换对负荷时间序列进行 n 级分解得到细节小波系数 d_1, d_2, \dots, d_n 和近似小波系数 a_n . 电力负荷时间序列是离散的, 为了对预测模型进行估计, 需要确定时间窗长 n . 若负荷采样周期为 1 h, 则一个时间窗内的负荷数据点数量为 $24 \times n$. 输入和输出数据集分别利用小波变换进行分解, 得到相应的子序列集合. 支持向量机利用子序列集合估计每一对子序列的回归模型, 进而就可以利用该回归模型分别预测各自的子序列.

在对每个子序列进行预测时需要计算平均绝对

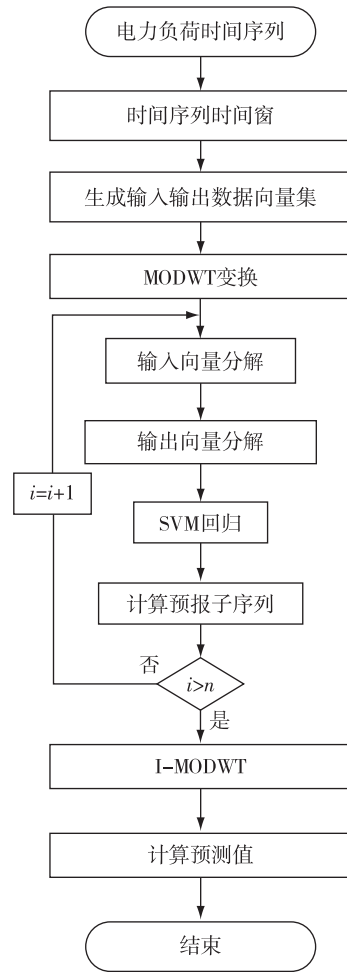


图 2 小波变换-支持向量机用电负荷预测算法流程

Fig. 2 Flowchart of power load prediction based on WT-SVM

误差 (MAE), MAE 值最高的子序列就需要做进一步分解, 分解后得到的输入和输出值用来对回归模型进行估计. 利用估计结果对子序列进行预测, 该预测过程就是小波逆变换. 基于重复小波变换支持向量机混合模型的电力负荷预测流程如图 3 所示.

3 仿真研究

采用某地区电网 3 个台区配电网 A、B 和 C 两年的实际负荷数据对所提出的预测方法进行日前负荷预测, 负荷数据采样周期为 1 h. 配电网 A、B 和 C 的负荷均有不同的特性. 配电网 A 负荷主要为居民生活生产负荷, 夜间和午休休息时间负荷明显下降; 配电网 B 负荷除了居民负荷外还包括一定比例的工业负荷, 午间低估并不明显; 配电网 C 的负荷为某些重工业负荷, 由于生产过程设备运行的不确定性, 负荷呈现出较大的随机波动特点. 在进行预测之前, 首先要确定合适的时间窗长. 时间窗长是用于对模型

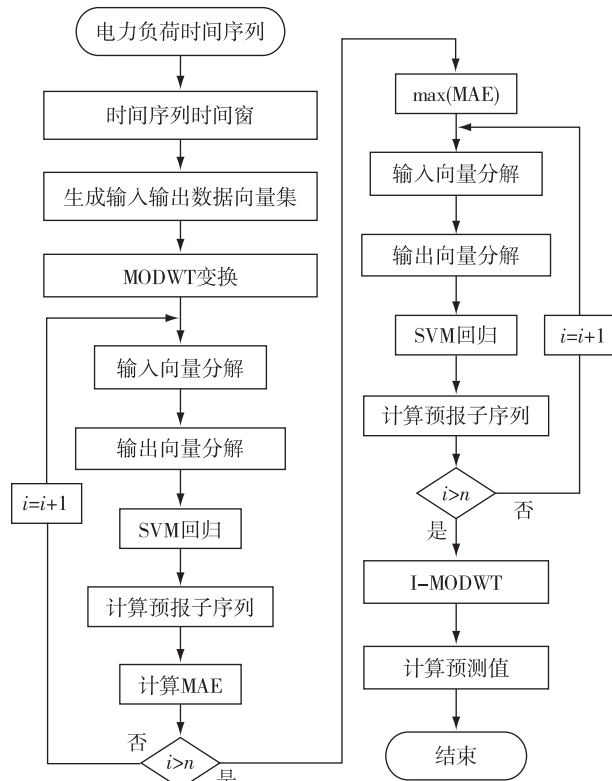


图3 重复小波变换支持向量机电力负荷预测算法流程

Fig. 3 Flowchart of power load prediction based on RWT-SVM

进行训练的负荷天数.一天中不同时刻的负荷数据作为输入数据,这些数据通过小波变换进行分解,每一个子序列采用自回归移动平均模型进行建模,自回归移动平均模型用来对给定的时间窗进行子序列预测.小波逆变换用来对一天中特定时刻的负荷进行预测.对于一天中每个小时都需要进行上述过程,并计算平均绝对误差.最小和最大时间窗长是任意选取的,本文中,最小时间窗长选为 20 h,最大时间窗长选为 50 h.

采用本文提出的基于重复小波变换支持向量机算法的负荷预测方法以及基于支持向量机的预测方法对配电网 A、B 和 C 负荷进行预测的结果以及预测误差如图 4 所示.可见基于重复小波变换支持向量机算法的负荷预测方法精度明显高于基于支持向量机的预测方法.此外,配电网 A 和 C 的负荷预测值能够较好地与实际负荷值趋势相吻合,而对于配电网 B 的随机波动性较强的负荷,预测结果与实际负荷相比变化趋势存在较大偏离.由预测误差曲线可见,配电网 C 的预测误差相对较小,这是因为负荷变化范围相对较小,并且负荷相对平稳.配电网 A 和 B 的预测误差与配电网 C 相比较,这是由于配电网

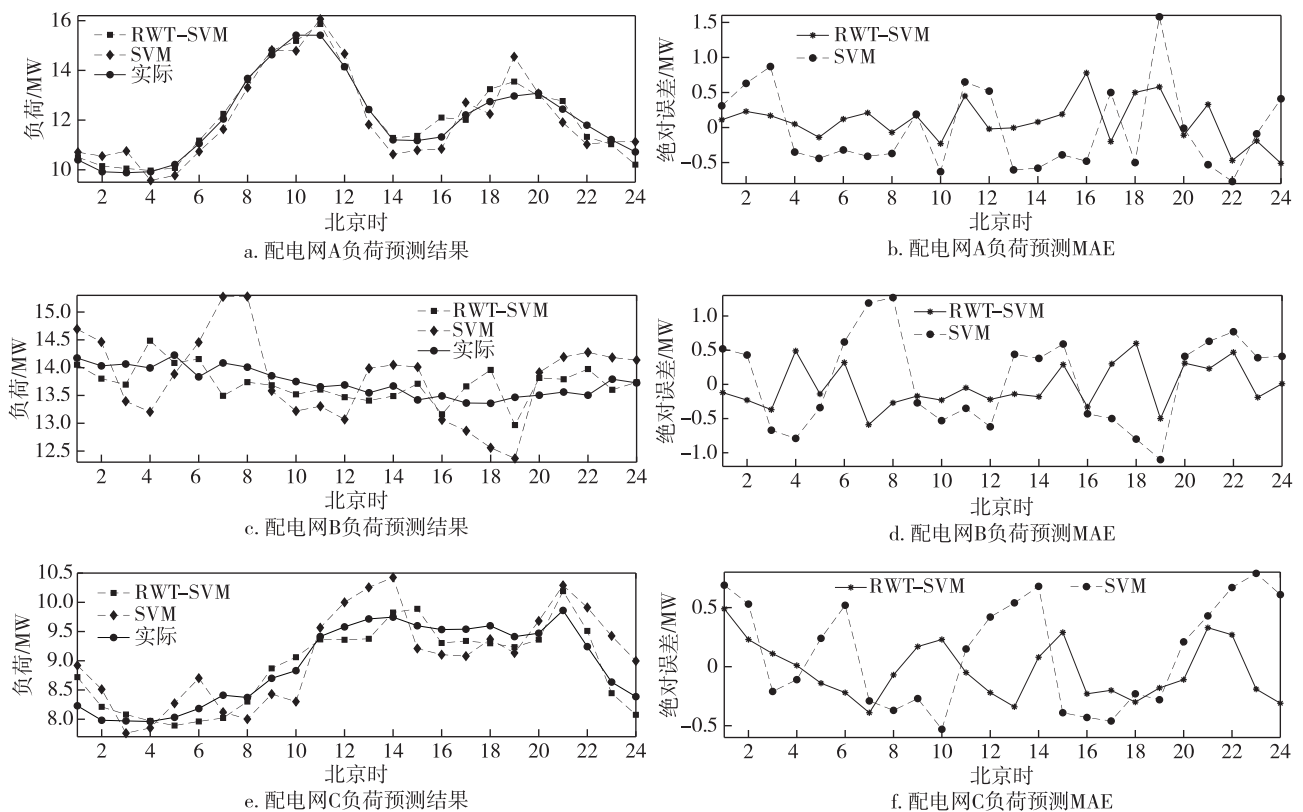


图4 配电网负荷预测结果

Fig. 4 Power load predicting results for distributed networks

A 的负荷变化范围更大,而配电网 B 的负荷随机性较强,这两方面原因导致负荷预测结果精度较差.由此可见,负荷的变化范围和随机性是影响负荷预测精度的两方面因素.

为了对预测结果进行定量分析,定义如下 4 个评价指标对负荷预测精度进行评价:

1) 平均绝对误差(MAE)

$$E_{MA} = \frac{1}{n} \sum_{j=1}^n |x_j - \hat{x}_j|, \quad (9)$$

其中: x_j 为第 j 个实际负荷; \hat{x}_j 为负荷的预测值.

2) 均方根误差(RMSE)

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{j=1}^n (x_j - \hat{x}_j)^2}. \quad (10)$$

3) 相对误差平均值(MAP)

$$P_{MA} = \frac{1}{n} \sum_{j=1}^n \left| \frac{x_j - \hat{x}_j}{x_j} \right| \times 100\%. \quad (11)$$

4) 误差平方和(SSE)

$$E_{SS} = \sum_{j=1}^n (x_j - \hat{x}_j)^2. \quad (12)$$

分别采用基于 RWT-SVM(本文)、WT-SVM、SVM^[16]和长短期记忆(Long Short-Term Memory, LSTM)网络模型^[17]预测方法进行日前负荷预测.表 1 给出了采用上述 4 种预测方法对 3 个台区配电网 A、B 和 C 的预测精度评价指标值.可见,采用 LSTM 的预测方法的 4 个指标均大于其他 3 种方法.尽管 LSTM 是一种深度神经网络,但其预测结果精度仍然是 4 种方法中最差的.SVM 预测方法的评价指标小于 LSTM,估计效果更好.然而,这 2 种方法均是通过对大量负荷数据进行直接训练,难以有效提取能够充分反映负荷发展趋势的有价值信息.通过对 SVM 进行改进,基于 WT-SVM 的预测方法 4 个指标值均小于基于 SVM 和 LSTM 的预测方法,表明基于 WT-SVM 的预测方法精度较高.这是由于 WT-SVM 利用小波变换技术对负荷时间序列数据进行分解,得到多个子序列,子序列中负荷变化趋势信息得到了进一步提取,并对每个子序列赋予了不同的权重.因此,利用这些赋予权值后的子序列对负荷进行预测精度更高.基于 RWT-SVM 的预测方法 4 个指标值小于基于 WT-SVM 的预测方法,表明本文方法的预测精度最高.这是因为重复小波变换根据子序列的 MAE 对各个子序列进一步进行筛选,该过程能够提取与负荷变化趋势相关性最高的子序列,因此,基于 RWT-SVM 的预测方法精度更高.

表 1 预测精度指标

Table 1		Comparison of predicting accuracy			
配电网	预测方法	MAE/kW	RMSE/kW	MAP	SSE/GW
A	SVM	2 218.39	2 701.28	6.93	2 394.90
	LSTM	3 023.49	4 829.01	8.41	5 839.27
	WT-SVM	1 480.11	2 412.90	3.29	1 290.38
	RWT-SVM	1 293.38	2 011.46	2.90	1 059.39
B	SVM	3 691.39	3 901.24	7.39	3 990.10
	LSTM	3 900.12	4 192.00	8.91	4 403.29
	WT-SVM	1 934.21	2 201.47	4.29	1 730.27
	RWT-SVM	1 429.57	1 590.35	3.21	1 103.57
C	SVM	2 018.28	2 489.14	5.28	3 894.25
	LSTM	2 459.39	2 847.16	7.26	4 357.19
	WT-SVM	1 748.51	2 347.10	3.79	1 537.12
	RWT-SVM	1 127.56	1 248.23	2.54	957.24

4 结语

电力系统负荷预测是保证电网安全稳定运行的前提,为电网运行控制和规划提供了重要依据.为了提高电网调度中心日前负荷预测方法的精度,本文提出一种基于重复小波变换-支持向量机模型的台区配电网日前负荷预测方法.通过小波变换对负荷数据进行分解能够降低数据误差;对分解后的子序列采用支持向量机进行建模能够进一步提升预测能力;对预测误差贡献度大的分解层进一步通过小波变换进行分解,从而高效获取分解子序列的特有趋势.采用某地区 3 个台区配电网连续 2 年的负荷数据对所提出的方法进行仿真计算,结果显示不同性质的负荷预测精度并不相同.影响精度的因素包括负荷波动范围和随机性.随机性越强并且负荷波动范围越大则预测精度越低.通过平均绝对误差、误差均方根、相对误差平均值和误差平方和对预测精度进行评价.结果表明利用本文提出的基于重复小波变换支持向量机模型的预测方法对配电网 A、配电网 B 和配电网 C 进行负荷预测的相对误差平均值分别为 2.90、3.21 和 2.54,精度均高于基于支持向量机模型、长短期时间记忆网络和小波变换支持向量机模型的预测方法.

数据可用性申明

本数据集真实可靠,读者如果需要,请访问网站: <https://www.nationalgridus.com/Upstate-NY-Business/Supply-Costs/Load-Profiles>.

参考文献

References

- [1] 廖剑波,陈清鹤,监浩军,等.主动配电网的日前-日内两阶段优化调度[J].现代电力,2020,37(1):27-34
LIAO Jianbo, CHEN Qinghe, JIAN Haojun, et al. Day-ahead and intraday two-stage optimal dispatch of active distribution network[J]. Modern Electric Power, 2020, 37(1):27-34
- [2] 吴迪,王正风.基于逐日分段气象算法的日前负荷预测[J].电气应用,2020,39(6):61-67
WU Di, WANG Zhengfeng. Day-ahead whether sensitive power load forecasting based on daily segmentation meteorological algorithm [J]. Electrotechnical Application, 2020, 39(6):61-67
- [3] 李杰.面向售电商的电力负荷日前预测模型研究[D].北京:华北电力大学,2019
LI Jie. Research on day-ahead load forecasting model for electricity sellers [D]. Beijing: North China Electric Power University, 2019
- [4] 陈莹,黄永彪,谢瑾.人工智能辅助下人机交互隔空手势识别模型[J].计算机仿真,2021,38(3):360-364
CHEN Ying, HUANG Yongbiao, XIE Jin. Human-computer interaction gesture recognition model based on artificial intelligence [J]. Computer Simulation, 2021, 38(3):360-364
- [5] 祝毅鸣.面向图像角点特征取证的人工智能检测仿真[J].计算机仿真,2021,38(1):486-490
ZHU Yiming. Artificial intelligence detection simulation for image corner feature forensics [J]. Computer Simulation, 2021, 38(1):486-490
- [6] 吴香华,华亚婕,官元红,等.基于CNN-Attention-BP的降水发生预测研究[J].南京信息工程大学学报(自然科学版),2022,14(2):148-155
WU Xianghua, HUA Yajie, GUAN Yuanhong, et al. Application of CNN-Attention-BP to precipitation forecast [J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2022, 14(2):148-155
- [7] 郭佳丽,邢双云,栾昊,等.基于改进的LSTM算法的时间序列流量预测[J].南京信息工程大学学报(自然科学版),2021,13(5):571-575
GUO Jiali, XING Shuangyun, LUAN Hao, et al. Prediction of time series traffic based on improved LSTM algorithm [J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2021, 13(5):571-575
- [8] 张净杰.基于门循环单元神经网络的微电网日前电力负荷预测[D].徐州:中国矿业大学,2020
ZHANG Zhengjie. Day-ahead load forecasting of microgrid based on GRU network [D]. Xuzhou: China University of Mining and Technology, 2020
- [9] 王玥,张宇帆,李昭昱,等.即插即用能量组织日前负荷概率预测方法[J].电网技术,2019,43(9):3055-3060
WANG Yue, ZHANG Yufan, LI Zhaoyu, et al. Day-ahead probability load forecasting of energy tissues with plug-and-play function [J]. Power System Technology, 2019, 43(9):3055-3060
- [10] 孙晓燕,李家钊,曾博,等.基于特征迁移学习的综合能源系统小样本日前电力负荷预测[J].控制理论与应用,2021,38(1):63-72
SUN Xiaoyan, LI Jiazhao, ZENG Bo, et al. Small-sample day-ahead power load forecasting of integrated energy system based on feature transfer learning [J]. Control Theory & Applications, 2021, 38(1):63-72
- [11] 李正浩.基于NACEMD-GRU的组合型日前负荷预测方法[J].电网与清洁能源,2021,37(6):43-50
LI Zhenghao. A combined method of day-ahead load forecasting based on NACEMD-GRU [J]. Advances of Power System & Hydroelectric Engineering, 2021, 37(6):43-50
- [12] 尚帅,韩立国,周晨光,等.基于时频能量重排的改进小波变换谱分解[J].地球物理学进展,2015,30(5):2206-2211
SHANG Shuai, HAN Liguang, ZHOU Chengguang, et al. Improved wavelet spectral decomposition using energy reassignment in time-frequency map [J]. Progress in Geophysics, 2015, 30(5):2206-2211
- [13] 张玩乐,王小虎,张志健.基于小波变换与奇异值分解的航空器弹性自适应陷波方法[J].航天控制,2018,36(4):59-64,71
ZHANG Wanle, WANG Xiaohu, ZHANG Zhijian. AWT & SVD based adaptive Notch filter for aircraft elastic constraint [J]. Aerospace Control, 2018, 36(4):59-64, 71
- [14] 肖勇,李博,尹家悦,等.基于小波变换和小波包变换的间谐波检测[J].智慧电力,2022,50(1):101-107,114
XIAO Yong, LI Bo, YIN Jiayue, et al. Interharmonic detection based on wavelet transform and wavelet packet transform [J]. Smart Power, 2022, 50(1):101-107, 114
- [15] 隋新,何建敏,李亮.时变视角下基于MODWT的沪深300指数现货与期货市场间波动溢出效应[J].系统工程,2015,33(1):31-38
SUI Xin, HE Jianmin, LI Liang. The volatility spillover effects between HS300 stock index future and spot market based on MODWT from a time-varying perspective [J]. Systems Engineering, 2015, 33(1):31-38
- [16] Emhamed A A, Shrivastava J. Electrical load distribution forecasting utilizing support vector model (SVM) [J]. Materials Today: Proceedings, 2021, 47:41-46
- [17] Brauns K, Scholz C, Schultz A, et al. Vertical power flow forecast with LSTMs using regular training update strategies [J]. Energy and AI, 2022, 8:100143

Day-ahead load forecasting of distributed power grids based on RWT-SVM

DING Hong¹ TAO Xiaofeng¹ LU Chunyan¹ ZHANG Shicheng¹

¹ NARI Group Corporation (State Grid Electric Power Research Institute), Nanjing 211000

Abstract Day-ahead load forecasting is an important task for the power dispatching center to formulate reasonable dispatching plans thus to ensure the safety and reliability of power system operation. However, random errors exist in time series of power loads, and the intelligent algorithm based prediction models are complex in structure and incapable of fully extracting load information enough for load calculation and load forecasting. Here, we propose a day-ahead power load forecasting approach based on Repeated Wavelet Transform-Support Vector Machine (RWT-SVM) by using the historical power load time series of distributed power grids. The approach uses wavelet transform to decompose the power load time series of distributed power grids into multiple subsequences, then applies the Mean Absolute Error (MAE) to calculate the prediction errors contributed by each subsequence, and further decomposes the sequence with the largest MAE to improve the prediction ability of the model. The simulation results show that the proposed RWT-SVM approach outperforms other methods in forecasting accuracy.

Key words load forecasting; wavelet transform; support vector machine (SVM); distributed power grids