

DOI:10.3969/j.issn.1001-4551.2017.02.013

基于高斯模糊信息粒化和改进小波神经 网络的短期负荷区间预测研究

余 鹏^{1,2}, 唐 权³, 张文涛³, 黄民翔^{1*}

(1. 浙江大学 电气工程学院,浙江 杭州 310027;2. 国网江苏省电力公司经济技术研究院,江苏 南京 210008;
3. 国网四川省电力公司经济技术研究院,四川 成都 610041)

摘要:针对现有短期负荷预测方法适应性不足、预测精度不高,WNN 原始连接权值和阈值采取随机赋值并采用梯度学习算法进行修正,存在进化缓慢、易出现陷入局部极小或不收敛等问题,提出了基于高斯 FIG 和改进 WNN 的短期负荷区间预测新方法。用收敛速度更快的函数取代常用的输出层神经元函数,并用粒子群算法寻优取代 WNN 连接权值和阈值随机赋值。把网络连接权值和阈值作为粒子群算法微粒的位置向量,不断调整微粒的速度和位置向量以寻求最优值。选择了合适的数据跨度作为一个粒化窗口,对原始负荷数据进行了高斯模糊粒化处理,得到了对应的高斯 FIG 后的序列值,并用改进后的 WNN 对模糊序列值进行了区间预测。与 WNN 及 SVM 方法的对比研究结果表明,该方法不仅能够获得比单一负荷值更多的区间信息,而且预测精度更高,能够更好地指导电力系统相关决策。

关键词:高斯模糊;信息粒化;改进小波神经网络;短期负荷;区间预测

中图分类号:TM715

文献标志码:A

文章编号:1001-4551(2017)02-0167-06

Short-term load interval forecasting based on gaussian fuzzy information granulation and improved wavelet neural network

YU Peng^{1,2}, TANG Quan³, ZHANG Wen-tao³, HUANG Min-xiang¹

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China;

2. State Grid Jiangsu Electric Power Corporation Economic and Technology Research Institute, Nanjing 210008, China;

3. State Grid Sichuan Electric Power Corporation Economic and Technology Research Institute, Chengdu 610041, China)

Abstract: Aiming at the problem of being lack of adaptability and forecasting accuracy of the current short-term load forecasting methods, and the problem of slow evolution, easy to fall into a local minimum and no convergence because of the random assignment of the original connection weights and threshold and adopting gradient learning algorithm to improve the correction in original WNN method, a new method based on gaussian fuzzy information granulation and improved wavelet neural network was proposed. A faster convergence speed function was proposed to replace the commonly used output layer neuron function and particle swarm algorithm optimization was used to replace the random assignment of the original connection weights and threshold of WNN. The network connection weights and threshold was taken as a particle position vector of particle swarm optimization, the speed of the particles and the position vector was adjusted constantly to find the optimal value. Appropriate data span was selected as a graining window to dispose the original load data by using gaussian fuzzy information granulation method and the corresponding sequence values after gaussian FIG were gotten. Then the improved WNN was used to do interval forecasting of the fuzzy sequence values. The results through comparative study of WNN and SVM indicate that the method proposed can not only gain range information, which is more than single load value, but also achieves higher prediction accuracy, which can better guide the power system related decision-making.

Key words: gaussian fuzzy; information granulation; improved WNN; short-term load; interval forecasting

收稿日期:2016-09-08

作者简介:余鹏(1991-),男,四川广安人,硕士研究生,主要从事电网规划及可靠性研究方面的工作. E-mail:1003112771@qq.com

通信联系人:黄民翔,男,教授. E-mail: huangmx@zju.edu.cn

0 引言

电力系统负荷预测是指从已有的经济社会发展状况和电力系统的实际需求出发,考虑经济、气候、政治等因素,通过对历史数据的内在联系和发展规律的分析和研究,以未来经济和社会发展趋势为依据,对未来电力需求做出预测。电力系统短期负荷预测是电力系统经济运行、安全调度和合理规划的重要依据之一,其准确性和实用性对电力生产和经济发展都意义重大。有文献指出,电力负荷序列是混沌的,可以利用负荷的混沌特性进行短期负荷预测,但这种方法对初值过于敏感,其精确性和实用性欠佳^[1-2]。纵观国内外电力系统短期负荷预测的研究,主要有时间序列法、人工智能法和组合预测法。时间序列法是指以时间轴为基础,通过对历史数据的研究找到数学规律并以此对未来的数据变化趋势进行研究的方法。文献[3]提出广义自回归条件异方差模型有较好描述时间序列波动的能力并把这种方法用在了负荷预测中。此类方法虽然计算量小、速度快,但存在精度不够、自学习能力不足和鲁棒性较差等缺陷。诸如神经网络、模糊理论、粗糙集理论和支持向量机等人工智能法也被广泛应用到负荷预测中^[4-7],文献[8]在传统灰色模型 GM(1,1) (Grey Model) 中引入向量分量,结合蚁群算法,建立了蚁群灰色模型,具有一定的实用价值。但此类方法仍存在训练时间长、收敛速度慢等一系列问题。针对不同方法的优劣,有学者提出了结合多种方法的组合预测法,试图糅合多种方法,优劣互补,以达到较好的预测效果,如文献[9]提出的改进人工蜂群算法。此类方法虽能取长补短,但通常不能准确捕捉负荷变化规律,预测精度仍有待提高。

高斯模糊信息粒化(fuzzy information granulation, FIG)方法将混沌时间序列重构及粒化,且处理后的数据样本能够保持原样本数据特性,是对数据处理的手段之一,本身无法单独进行短期负荷预测。电力系统负荷数据具有混沌特性,经高斯模糊信息粒化模型重构及粒化处理后的负荷数据仍具有处理前负荷数据的数据特征,对应可获取到的海量电网负荷数据,该方法可在保持原始数据特性的情况下把负荷模糊为一系列更小的样本区间,便于数据后续再处理。小波神经网络(wavelet neural network, WNN)由于自身理论及网络结构的特性,其相比于其他神经网络具有更高的预测精度,而小波神经网络本身仍然存在缺陷,本研究在对小波神经网络缺陷进行改进的基础上,把高斯模糊信息粒化模型和改进后的小波神经网络进行有机结合。

合。首先对数据进行高斯模糊处理,把原始的数据模糊成一个数据区间,并对表征区间的 Low, R, Up 值进一步进行区间预测^[10]。其中,Low 和 Up 分别对应预测区间的上确界和下确界,R 包含于区间,表征的含义由隶属函数确定。

针对小波神经网络对初值敏感及收敛速度和容易陷入局部最优等问题^[11],本研究作出改进,并用改进后的模型对模糊数据进行预测。

1 模糊信息粒化

信息粒是相似或具有某种功能元素的集合,信息粒化是研究信息粒的形成、表示、粗细和语义解释,根据某种法则对一个整体进行划分,并对划分结果分别研究的一种方法。信息粒化的主要模型有基于粗糙集理论的模型、基于商空间理论的模型和基于模糊集理论的模型 3 种,本研究选取基于模糊集理论的模型进行研究说明^[12]。

数据粒的命题描述如下:

$$g \triangleq (x \text{ is } G) \text{ is } \lambda \quad (1)$$

式中: x —论域 U 中取值的变量; G — U 的模糊子集,由隶属函数 μ_G 来刻画; λ —可能性概率。通常假设: U —实数集合 R^n , G — U 的凸模糊子集, λ —单位区间的模糊子集。

用模糊集方法对时间序列进行模糊粒化,主要有划分窗口和模糊化两个过程。划分窗口是指将时间序分割成若干子序列,作为操作窗口;模糊化是将产生的每一个窗口模糊化的过程。对给定的时间序列,考虑单窗口问题即把整个时序 x 看成是一个窗口进行模糊化,其任务是在 x 上建立一个模糊粒子,即能够合理描述 x 的模糊概念 G (以 x 为论域的模糊集合),确定了 G 也就确定了模糊粒子。所以模糊化过程本质上是一个确定函数 A 的过程, $A = \mu_G$,即 A 是模糊概念 G 的隶属函数。通常在粒化时先确定模糊概念的基本形式,再确定具体的隶属函数^[13]。数据 FIG 处理后可以得到 Low, R, Up 3 个参数。

2 小波神经网络

小波是一种时域具有紧支集或近似紧支集、直流分量为零、长度有限的波形。小波分析是时频分析的一种,由针对傅里叶变换在信号处理领域无法结合时域特征和频率特征的不足发展而来^[14-15]。

WNN(wavelet neural network) 以 BP(back propagation) 神经网络拓扑为基础,把小波基函数作

为隐含层节点的传递函数,其信号前向传递和误差方向传递同时进行。小波神经网络模型具有以下的结构特点:

- (1) 网络权值学习简单,权值根基函数之间为线性关系,从而在加快收敛速度的基础之上避免了局部最优;
- (2) 小波神经网络结构设计有确切的理论依据,避免了网络结构设计的盲目性;
- (3) 可以根据实际物理意义确定网络结构中的部分参数^[16-17]。

小波神经网络拓扑结构如图1所示。

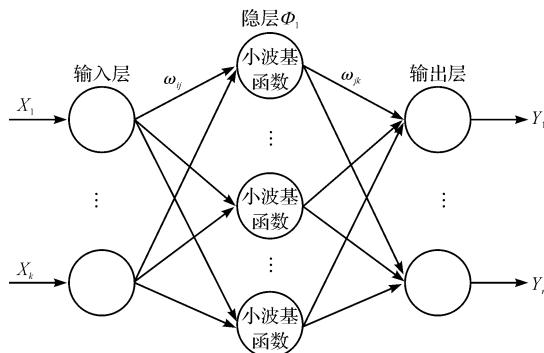


图1 小波神经网络拓扑结构

$X_1 \sim X_k$ —输入参数; $Y_1 \sim Y_m$ —预测输出; ω_{ij} —连接输入层节点*i*和隐含层节点*j*的权重; ω_{jk} —连接隐含层节点*j*和输出层节点*k*的权重

若输入信号的序列为 x_i ($i = 1, 2, \dots, k$) 时, 隐含层输入计算公式为:

$$h(j) = h_j \left(\frac{\sum_{i=1}^k w_{ij} x_i - b_j}{a_j} \right) j = 1, 2, \dots, l \quad (2)$$

式中: $h(j)$ —隐含层第 j 个节点输出值, h_j —小波基函数, b_j — h_j 的平移因子, a_j — h_j 的伸缩因子, w_{ij} —输入层和隐含层的连接权值。

由于电力系统负荷序列具有多重的周期性,通常要求小波基函数具有良好的紧支撑性、 $\psi(t)$ 的 N 阶消失矩越高越好、良好的正则性等特点,常用的小波基函数为 Morlet 母小波基函数,其表达式为:

$$y = \cos(1.75x) e^{-x^2/2} \quad (3)$$

小波神经网络输出层神经元函数通常为:

$$\sigma(x) = \frac{e^x}{(1 + e^x)} \quad (4)$$

输出层表达式为 Sigmoid:

$$y(k) = \sum_{i=1}^l \omega_{ik} h(i) k = 1, 2, \dots, m \quad (5)$$

式中, l —隐含层节点数, m —输出层节点数, ω_{ik} —隐含层到输出层的权值, $h(i)$ —第 i 个隐含层的节点输出。

小波神经网络权值参数的修正通常采用梯度修正法,使小波神经网络的预测输出不断逼近期望输出^[17]。

3 模型建立

3.1 高斯模糊信息粒化

本研究采用高斯模糊的形式,其隶属函数可表示为:

$$A(x, m, \sigma, \mu) = \begin{cases} \exp\left[-\frac{(x-m)}{\sigma^2}\right], & x \leq m \\ \exp\left[-\frac{(x-m)}{\mu^2}\right], & x > m \end{cases} \quad (6)$$

式中: x —论域中的变量, m —对应高斯 FIG 后的 R 。

3.2 改进小波神经网络

常规 WNN 网络的原始连接权值和阈值采取随机赋值并采用梯度学习算法进行修正,存在进化缓慢、易出现陷入局部极小或不收敛等问题,本研究对常规 WNN 做两方面改进,具体如下:

(1) 输出层神经元函数中用收敛速度更快的双曲正切函数取代传统的 Sigmoid 函数,即输出层神经元函数改为^[19]:

$$f(x) = a \frac{1 - e^{-bx}}{1 + e^{-bx}} \quad (7)$$

式中:通常 a 取值 1.716, b 取值 0.667。

(2) 粒子群优化算法是一种高效的并行优化算法,其搜索寻优速度快、效率高,而小波神经网络存在原始连接权值和阈值采取随机赋值的缺陷,故本研究采用粒子群优化算法对 WNN 网络连接权值和阈值进行优化,从而能够改进常规 WNN 原始连接权值和阈值采取随机赋值的不足。笔者把网络连接权值和阈值作为粒子群算法微粒的位置向量,不断调整微粒的速度和位置向量,通过分析微粒最佳位置来确定 WNN 的网络参数最优值^[19]。粒子群算法的适应度函数 f 由网络输出误差 $E(N)$ 确定,对应关系如下:

$$f = \frac{1}{1 + E(N)} \quad (8)$$

$$E(N) = \frac{1}{N} \sum_{i=1}^N (D_i - Y_i)^2 \quad (9)$$

式中: N —训练样本数, D_i —第 i 个输出节点的理想输出值, Y_i —第 i 个输出节点的实际输出值。

3.3 预测模型

本研究基于高斯 FIG 和改进 WNN 的短期负荷预测模型流程图如图2所示。

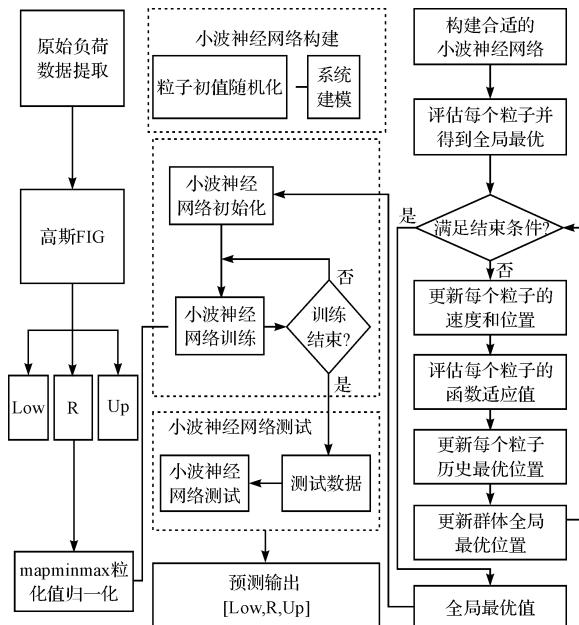


图 2 模型流程图

4 算例分析

笔者选取某地 2015 年 4 月 27 日至 2015 年 6 月 15 日的历史负荷数据作为本研究算例分析基础数据,运用 4 月 27 日至 6 月 14 日共七周的负荷数据预测 6 月 15 日负荷,数据采样频率为 5 分 / 点,每天采样 288 个负荷数据点。

根据高斯 FIG 理论,在对原始数据进行高斯模糊信息粒化时选择 6 个数据点作为一个粒化窗口,每个粒化窗口数据时间跨度为 30 min,则每天对应 48 个粒化窗口,即需要预测 6 月 15 日对应的 48 个负荷区间。其中,4 月 27 日至 6 月 7 日负荷数据作为神经网络输入数据,6 月 8 日至 6 月 14 日负荷数据作为神经网络输出数据,运用输入和输出数据对本研究所提改进 WNN 进行网络训练。设定本研究改进 WNN 网络结构为 4-6-1,即输入层有 4 个节点,隐含层有 6 个节点,输出层有 1 个节点,网络迭代进化次数为 200 次。笔者把本研究方法计算结果与传统 WNN 神经网络与 SVM 神经网络法计算结果进行对比,其中传统 WNN 神经网络的网络结构及迭代次数与本研究方法一致。网络训练原始数据及高斯 FIG 粒化后数据分别如图 3、图 4 所示。

本研究选取平均相对误差、均方根相对误差作为预测精度评价指标,具体定义如下:

$$E_{\text{mape}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{L_i - \hat{L}_i}{L_i} \right| \times 100\% \quad (10)$$

$$E_{\text{mse}} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{L_i - \hat{L}_i}{L_i} \right)^2} \times 100\% \quad (11)$$

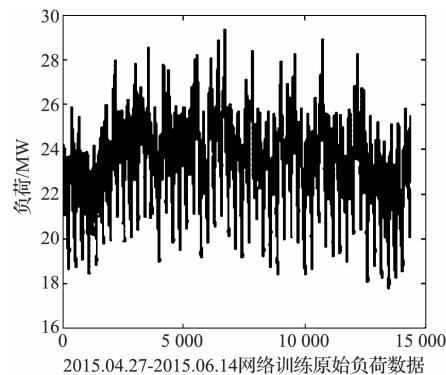


图 3 网络训练原始数据图

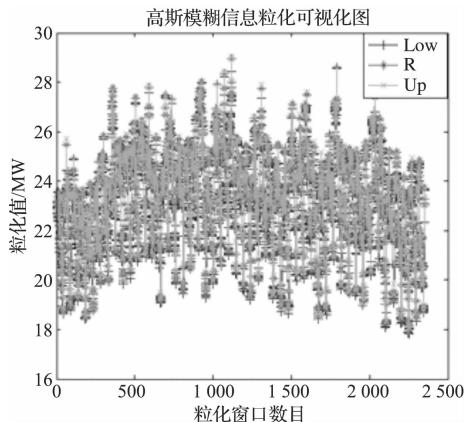


图 4 高斯 FIG 粒化结果图

式中: E_{mape} —平均相对误差, E_{mse} —均方根相对误差, L_i —实际负荷值, \hat{L}_i —预测负荷值。

3 种方法计算结果如表 1 所示,限于篇幅此处只列出高斯 FIG 后 R 前 24 个时间段的预测值和预测误差,时间 0.5 表示 [0,0.5) 时间段。48 个时间段 3 种不同方法计算的 Low、R、Up 的值如图 5 所示。

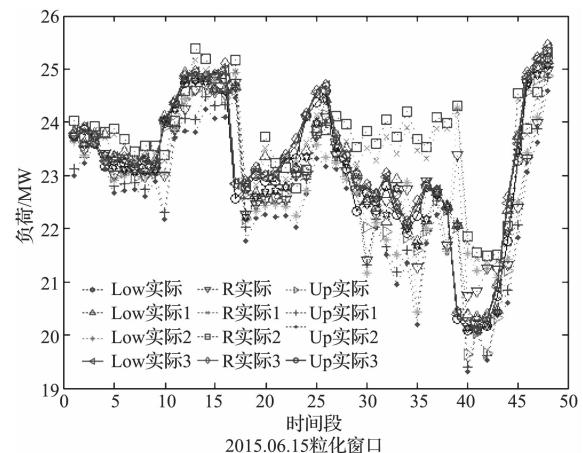


图 5 计算结果对比图

“实际”—原始负荷值;“预测 1, 2, 3”—分别对应着 SVM 预测方法、WNN 预测方法和本研究预测方法预测结果

表1 2015年6月15日0:00~11:30高斯FIG中R实际值与预测值对比

时间/h	实际值/MW	SVM		WNN		本研究方法	
		预测/MW	误差/%	预测/MW	误差/%	预测/MW	误差/%
0.5	23.7925	23.6321	0.6743	23.7330	0.2502	23.7530	0.1662
1	23.8910	23.3857	2.1149	23.4866	1.6926	23.5866	1.2740
1.5	23.6355	23.6172	0.0775	23.7181	-0.3494	23.7181	-0.3494
2	23.2650	23.3012	-0.1558	23.4021	-0.5895	23.3893	-0.5342
2.5	23.3325	22.9080	1.8192	23.0089	1.3868	23.1719	0.6882
3	23.2990	22.9970	1.2964	23.0979	0.8633	23.1216	0.7613
3.5	23.2250	23.1818	0.1859	23.1286	0.4151	23.0676	0.6776
4	23.3110	23.0168	1.2619	22.9636	1.4901	23.0796	0.9925
4.5	23.2040	23.1424	0.2656	23.0892	0.4949	23.1090	0.4095
5	24.0245	23.0437	4.0826	22.9905	4.3041	24.0505	-0.1080
5.5	24.3805	23.9077	1.9394	23.8545	2.1576	24.2545	0.5169
6	24.8215	24.4382	1.5440	24.2380	2.3506	24.8024	0.0770
6.5	24.9395	24.8208	0.4761	24.6206	1.2789	24.7793	0.6423
7	24.8610	24.8953	-0.1381	24.6951	0.6671	24.7698	0.3669
7.5	24.8910	24.7749	0.4665	24.5747	1.2708	24.6111	1.1246
8	24.9795	24.7174	1.0494	24.5172	1.8509	24.5823	1.5902
8.5	22.8370	24.9318	-9.1728	24.7316	-8.2961	24.6442	-7.9137
9	22.8740	22.1489	3.1700	22.2721	2.6314	22.2297	2.8169
9.5	23.1115	22.3374	3.3495	22.4606	2.8164	22.6037	2.1972
10	22.9865	22.4279	2.4300	22.5511	1.8941	22.6942	1.2715
10.5	23.0130	22.4557	2.4218	22.5789	1.8865	22.7220	1.2646
11	23.3495	22.4195	3.9829	22.5427	3.4552	22.7858	2.4141
11.5	23.5635	22.2336	5.6440	22.9881	2.4418	23.1312	1.8345
12	24.1360	22.7186	5.8726	22.9852	4.7681	23.3483	3.2637

根据式(10,11)可计算出3种不同方法预测的平均

相对误差和均方根相对误差,计算结果如表2所示。

表2 不同计算方法计算误差表

指标	SVM/%				WNN/%				本研究方法/%			
	Low	R	Up	Low	R	Up	Low	R	Up	Low	R	Up
E_{mape}	3.7716	3.3615	3.4387	2.9805	2.7146	2.9092	1.7159	1.4611	1.4127			
E_{mse}	4.3773	4.6720	4.7527	3.7012	3.6975	4.2510	2.4866	2.1883	2.1933			

由表2可知,针对Low、R、Up的预测中,SVM方法误差指标均大于WNN方法,WNN方法误差指标均大于本研究方法,即本研究预测方法误差指标为3种预测方法中最小的。

笔者分别取Low、R、Up预测的平均相对误差和均方根相对误差的平均值,SVM方法、WNN方法、本研究方法对应的 \tilde{E}_{mape} 和 \tilde{E}_{mse} 分别为: 3.5239% , 4.601% ; 2.8681% , 3.8832% ; 1.5299% , 2.2894% 。本研究方法相比于SVM和WNN的平均相对误差平均值分别降低了 1.994% 和 1.3382% ,均方根相对误差平均值分别降低了 2.3116% 和 1.5787% ,本研究所提方法在预测精度上显著提高。

笔者根据本研究方法预测得到6月15日48个负荷区间,每个负荷区间跨度0.5 h,对比6月15日实际

288个点负荷数据,以判断实际负荷数据是否包含于预测负荷区间,如图6所示。

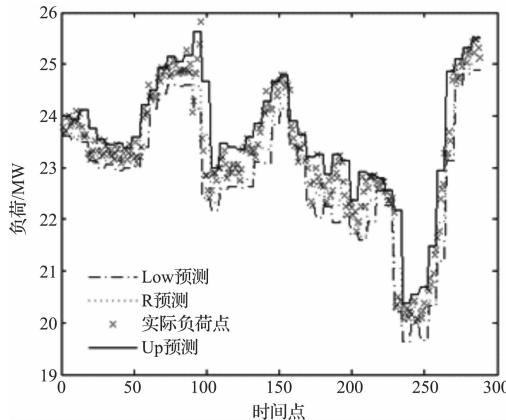


图6 原始负荷与预测区间对比

由图6可知,6月15日实际288个负荷点有8个

负荷点不在预测区间范围内,预测区间对实际数据覆盖准确率达到 97.222%。

5 结束语

本研究在对能将混沌时间序列重构及粒化的高斯 FIG 和常规 WNN 研究的基础之上,把 2 者有机结合,提出了基于高斯 FIG 和改进 WNN 的短期负荷预测新方法。首先笔者对原始负荷数据进行高斯模糊信息粒化处理,得到重构及粒化后的负荷数据序列。笔者通过用收敛速度更快的函数取代常用的输出层神经元函数及用粒子群算法寻优取代 WNN 连接权值和阈值随机赋值两种方法改进现有 WNN,用改进后的 WNN 对模糊粒化序列进行负荷区间预测。

研究结果表明,本研究所提方法不仅能够获得比单一负荷值更多的区间信息,而且相比于常规 WNN 及 SVM 预测方法的预测精度更高,能够为电力决策提供更多、更精确的信息,能够更好地指导电力系统经济运行、安全调度和合理规划。

参考文献(References) :

- [1] DEEPAK KUMAR LAL, SWARUP K S. Modeling and simulation of chaotic phenomena in electrical power systems [J]. *Applied Soft Computing*, 2011, 11(1): 103-110.
- [2] 杨卓,王德章,杨国清. 基于负荷混沌特性和最小二乘支持向量机的短期负荷预测 [J]. 电网技术, 2008, 32(7): 66-71.
- [3] 陈昊. 基于广义自回归条件异方差模型的负荷预测新方法 [J]. 电力系统自动化, 2007, 31(15): 51-54.
- [4] 何耀耀,许启发,杨善林,等. 基于 RBF 神经网络分位数回归的电力负荷概率密度预测方法 [J]. 中国电机工程学报, 2013, 33(1): 93-98.
- [5] ZHANG Shao-min, WANG Jing-yan, WANG Bao-yi. Research on Data Integration of Smart Grid Based on IEC61970 and Cloud Computing [C]. //Proceeding of 2011 international conference on electronic engineering, communication and management and management, Berlin: Springer-Verlag, 2012.
- [6] 孙晓璐,肖先勇,尹星露,等. 基于模型有效度的地区电网母线负荷组合预测与系统实现 [J]. 电力自动化设备, 2014, 34(12): 106-110.
- [7] 刘文霞,徐晓波,周楫,等. 基于支持向量机的纯电动公交车充/换电站日负荷预测 [J]. 电力自动化设备, 2014, 34(11): 41-47.
- [8] 王捷,吴国忠,李艳昌,等. 蚁群灰色神经网络组合模型在电力负荷预测中的应用 [J]. 电力系统保护与控制, 2009, 37(2): 48-52.
- [9] 陈强,金小明,姚建刚,等. 基于改进 ABC 算法的中长期电力负荷组合预测 [J]. 电力系统保护与控制, 2014, 42(23): 113-117.
- [10] 王贺,胡志坚,仉梦林. 基于模糊信息粒化和最小二乘支持向量机的风电功率波动范围组合预测模型 [J]. 电工技术学报, 2014, 29(12): 218-224.
- [11] 杨娜,付强,王淑丽,等. 小波神经网络模型的改进及其应用 [J]. 系统工程理论与实践, 2009, 29(1): 168-173.
- [12] 陈伟,赵庆堂,赵锦萍,等. 基于信息粒化和支持向量机的风电场功率变化趋势和变化空间的预测算法 [J]. 电工技术学报, 2013, 28(1增): 169-173.
- [13] 李洋. 基于信息粒化的机器学习分类及回归预测分析 [D]. 北京:北京师范大学信息科学与技术学院, 2009.
- [14] 张涛. 基于小波神经网络的电力系统负荷预测 [D]. 哈尔滨:哈尔滨理工大学电气与电子工程学院, 2009.
- [15] 郑小洋. 小波神经网络及其应用 [D]. 重庆:重庆大学电气工程学院, 2003.
- [16] 祖哲,毕贵红,刘力,等. 基于小波神经网络的电力系统短期负荷预测模型研究 [J]. 计算机技术与发展, 2012, 22(10): 237-241.
- [17] 刘奎. 基于混沌和小波神经网络的短期电力负荷预测方法研究 [D]. 成都:西南交通大学电气工程学院, 2012.
- [18] 田学民,王强,邓晓刚,等. 一种引入动量项的小波神经网络软测量建模方法 [J]. 化工学报, 2011, 62(8): 2238-2242.
- [19] 张清华. 小波神经网络参数优化及其应用 [D]. 哈尔滨:东北农业大学电气与信息学院, 2009.

[编辑:张豪]

本文引用格式:

余鹏,唐权,张文涛,等. 基于高斯模糊信息粒化和改进小波神经网络的短期负荷区间预测 [J]. 机电工程, 2017, 34(2): 167-172.

YU Peng, TANG Quan, ZHANG Wen-tao, et al. Short-term load interval forecasting based on gaussian fuzzy information granulation and improved wavelet neural network [J]. Journal of Mechanical & Electrical Engineering, 2017, 34(2): 167-172.