

DOI: 10.7667/PSPC152069

# 配电网大数据环境下的多点负荷预测算法与应用研究

雷正新<sup>1</sup>, 韩蓓<sup>1</sup>, 聂萌<sup>2</sup>, 甄颖<sup>2</sup>, 汪可友<sup>1</sup>, 李国杰<sup>1</sup>

(1. 上海交通大学电子信息与电气工程学院, 上海 200240; 2. 国网山东省菏泽电力公司, 山东 菏泽 274000)

**摘要:** 随着配网规模日益庞大、负荷类型日趋多样化、数据数量与类型的快速增加, 将具有小规模特征明显的负荷与大规模整合性质的负荷进行联合预测工作, 形成有效的上下级预测网络, 对配网规划运行具有重要作用。考虑配网测量设备数量对负荷预测的数据量限制, 提出一种“从整体到节点”的多点负荷预测方式。针对AR无法接纳多源数据与BP神经网络算法结果受相似日影响大等弊端, 提出一种优势互补的AR-ANN算法。最后, 分别通过普通单节点负荷预测、传统“从节点到整体”多点负荷预测与新多点负荷预测的算例研究, 结果验证了AR-ANN在数据处理速度、预测误差等方面的优势。

**关键词:** 多点负荷预测; BP神经网络; AR; 大数据; 配电网

## Research and application of multi-node load forecasting algorithm under the environment of distribution network's big data

LEI Zhengxin<sup>1</sup>, HAN Bei<sup>1</sup>, NIE Meng<sup>2</sup>, ZHEN Ying<sup>2</sup>, WANG Keyou<sup>1</sup>, LI Guojie<sup>1</sup>

(1. School of Electric Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;

2. State Grid Heze Power Supply Company, Heze 274000, China)

**Abstract:** With the increasing scale of distribution network, more diversity of load types, larger volume and more types of data, forming an effective up-and-down forecast network, which means to combine small-scale and characteristically obvious load forecast with large-scale and integrated load forecast, is important to distribution network planning and operation. Considering the limitation of the data quantity for the lack of distribution network measurement equipment, this paper proposes a multi-node load forecasting method of “from the whole to the nodes”. Because AR is not able to accept multiple source data and the outcome of BP neural network algorithm is severely affected by the similar day, this paper proposes a novel algorithm, AR-ANN, with complementary advantages of the previous two. Finally, the strength of AR-ANN in data processing speed and prediction error is validated respectively by tests of an ordinary single node load forecast, a traditional multi-node load forecast by the method of “from the nodes to the whole” and the new way of multi-node load forecast.

This work is supported by National Natural Science Foundation of China (No. 51407116 and No. 51477098).

**Key words:** multi-node load forecast; BP-ANN; AR; big data; distribution network

## 0 引言

随着中国负荷总量快速增长、配网结构不断变化, 以潮流分析、 $N-1$ 分析、紧急供电恢复转移为主的各类系统分析需要更详尽的负荷数据支持, 这需要对结构规模快速变化的配网进行大数据多点负荷预测。传统多点负荷预测因节点特征比整体更显著,

故能有效减小预测误差。当下, 随着多类新型用户发用电设备的接入, 主动用户的特性变得随机性更强, 在保证主动配电网规划可行性等方面<sup>[1]</sup>, 对某些终端节点或用户的负荷预测变得尤为必要。而快速发展的配电网涉及范围广、数据量大, 软件层面, 就地快速处理数据不仅符合传统多点负荷预测方式也同时符合大数据并行处理的思想; 硬件层面, 用加装硬件数据采集设备来获取各节点信息的方法经济上不适用, 由此需要根据已有变电站、专线或智能电表等数据, 对分区或配网下层各支路或

**基金项目:** 国家自然科学基金资助项目(51407116, 51477098); 国家科技部科技支撑项目(2015BAA01B02)

节点进行多点负荷预测。

已有多点负荷预测文献就分布式快速处理等特点对经典负荷预测方法进行优化修正。文献[2]提出了一种改进的广义回归神经网络短期负荷预测方法, 并以减少计算时间为目的提出了一种减少输入变量的方法; 文献将以上两种方法与传统广义回归神经网络方法作为对比方法应用于新西兰多点配网负荷预测; 除此之外, 文献将多点配网负荷预测方法分为配网整体负荷预测、分地区负荷预测与参与比例负荷预测。文献[3]将负荷预测分为有功、无功 2 部分, 就超短期多点负荷预测提出了一种将“等级”与分区概念应用在自适应动态负荷模型中的新方法。文献[4]为提高基于神经网络负荷预测变量选取的合适度, 将 RS(Rough Set)理论引入前期预处理步骤。

预测算法方面, 考虑到时间序列 AR(Auto-Regressive Model, 自回归滑动平均模型)短期预测精度高却无法处理多源数据, BP-ANN(Back Propagation Artificial Neural Network, 反向传播人工神经网络)可容纳多源数据但预测精度受相似日等设定值影响大, 本文优势互补提出了一种将 AR 作为 BP-ANN 改进环节的 AR-ANN 负荷预测算法; 负荷需求方面, 本文从配网硬件层面数据采集数量限制出发, 提出一种“从整体到节点”的大数据多点负荷预测方式, 有效缓解当前数据采集数量限制与配网内各节点负荷预测需求的矛盾。

本文正文部分分为 3 部分, 第 1 部分为多点负荷预测模型介绍与新预测方式的提出, 第 2 部分为 AR 与 BP-ANN 预测方法的介绍, 第 3 部分为 AR-ANN 整体负荷预测与两类多点负荷预测的仿真算例。本文通过整体负荷预测验证了 AR-ANN 较 BP-ANN 在预测误差层面的优势, 通过传统多点负荷预测算例证实了 AR-ANN 多点负荷预测较整体负荷预测的时间优势性。本文在第 3 个算例中将 AR-ANN 应用在新多点负荷预测中, 算例显示 AR-ANN 较 BP-ANN 预测效果更优。

## 1 多点负荷预测模型

根据已有相关文献<sup>[2-4]</sup>以及本文的研究体会, 可将多点负荷预测定义总结如下: 多点负荷预测是考虑所涉及电网范围内多种负荷类型及电价、气象、交通等多源数据, 将网内具有共性的区域(单个用户、整条或部分馈线、变电站等)视为单个节点, 以节点为单位的分布式负荷预测。

结构方面, 多点负荷预测中各“节点”之间为互斥关系, 节点集合构成上一级即“整体”。多点负

荷预测结构示意图如图 1 所示, 自上而下呈分支状, 根据分叉次数可分为若干层, 根据具体负荷需求, 可设置单层或多层节点。

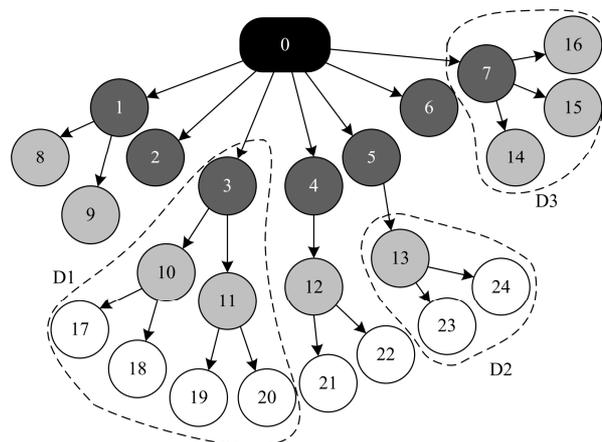


图 1 多点负荷预测结构示意图

Fig. 1 Schematic diagram of the structure of multi-node load forecast

在实际电网负荷预测中, 该结构往往由区域电网、省市级电网、各级主变线路、35 kV 专线、10 kV 线路等层次组成。图 1 从整体到节点分别用不同符号代替对应层次, 其中底层白色圈代表 35 kV 专线与 10 kV 线路。如何选择“整体”与“节点”则由具体需解决的负荷预测问题而定。以图 1 为例, 我们可选择区域电网作为整体、省市级电网作为节点; 也可选择类似 D1-D3 的部分区域作为待预测区域, 选取区域内的最高级别节点作为整体, 区域内次级或再次级节点作为节点。

传统负荷预测大多采用“从节点到整体”的方式, 从单个节点测量的数据出发, 分布式预测各节点负荷变化情况, 再融合区域内各节点预测结果, 得到整体负荷预测结果。数学表达式可概括为

$$F(X_1, X_2, \dots, X_m) = \eta \sum_{i=1}^n f(x_{i,1}, x_{i,2}, \dots, x_{i,m}), i=1, \dots, n \quad (1)$$

其中:  $F$  代表整体负荷预测算法;  $f$  代表节点负荷预测算法;  $X_1, \dots, X_m$  代表整体负荷预测输入量;  $m$  代表单节点预测输入量数目;  $i$  代表网络中第  $i$  个节点;  $n$  代表节点数目总数;  $x_{i,1}, \dots, x_{i,m}$  代表节点  $i$  负荷的预测输入量;  $\eta$  代表因线路损耗等产生的节点和值与整体值比例系数。

本文提出的另一种多点负荷预测方式源于实际配网运行需求。由于配电管理系统中不同层级的配电网使用独立数据库、权限级别不同、测量设备铺设不全或工作不稳定等各种因素, 往往造成居于下

层或电网终端的节点数据不完整或难以实时取得。基于这种情况，提出“从整体到节点”的多点负荷预测方式，在缺失各节点实时数据的情况下，使用历史节点数据，将整体负荷预测作为节点负荷预测的辅助方式，进行各节点的负荷预测。数学表达式概括为

$$f(x_{i,1}, x_{i,2}, \dots, x_{i,m}) = \beta_i \cdot F(X_1, X_2, \dots, X_m), i = 1, \dots, n \quad (2)$$

其中： $\beta_i$ 代表节点负荷占整体负荷预测比例对角矩阵；其余参数均与式(1)同意义。

可以看出式(1)、式(2)并没有指定预测算法，也没有指定预测时间跨度，下面就本文提出的AR-ANN方法在日前负荷预测的多点负荷预测方式下进行完整建模。

负荷预测根据预测时间跨度分为超短期负荷预测<sup>[5]</sup>、短期负荷预测<sup>[6]</sup>与长期负荷预测<sup>[7]</sup>。超短期负荷预测为实时预测，预测密度多为15 min/次；短期负荷预测多以小时、日为单位；长期负荷预测则以月、年为单位。日前负荷预测<sup>[8]</sup>隶属于短期负荷预测，具有短期负荷预测中以小时或半小时为密度的特征；特别之处在于，日前负荷预测时间跨度为自然日全日，即零点至24时。因日前负荷预测属于短期负荷预测，故短期预测方法常直接用于日前负荷预测。但日前负荷预测的特殊性又衍生出基于相似日的负荷预测方法，相似日选择算法研究层出不穷<sup>[8-10]</sup>。考虑到大数据快速处理要求，本文选择以日类型为基础的经验相似日<sup>[11]</sup>，不将相似日选择过程复杂化。

负荷预测算法根据历史负荷推导待预测负荷的方式可分为外推法与相关法。ARMA<sup>[12]</sup>作为外推法中的常用方法之一，待预测负荷与历史负荷、历史误差值建立起线性关系。相关法如ANN人工神经网络<sup>[13]</sup>，通过将待预测负荷与历史负荷、历史气温等多源数据建立非线性关系进行预测。负荷预测算法根据预测模型复杂度又可划分为统计预测法与智能预测法。统计预测法包括回归分析法<sup>[14]</sup>、时间序列法、指数平滑模型法<sup>[15]</sup>、卡尔曼滤波法<sup>[16]</sup>、状态估计法<sup>[17]</sup>等；智能预测法包括人工神经网络法、模糊逻辑理论法<sup>[14]</sup>、灰色理论法<sup>[18]</sup>、支持向量机法<sup>[19]</sup>、极限学习机法<sup>[20]</sup>等。

日前负荷预测是短期负荷预测的特殊情况，本文中相似日选择包含季节等属性的经验化考量，故在建立时间序列负荷预测模型时不存在季节差别。文献[21]说明，在不考虑季节变化时，阶段ARMA模型的建立无需包括MA部分，故仅需要建立相应

AR模型。AR虽具有超短期负荷预测误差低的优势，但模型无法容纳多源数据，且预测误差随时间累积，难以直接用于日前预测；BP-ANN具有处理多源数据、可以用于日前负荷预测的优势，但预测误差受相似日、网络参数影响大。我们将AR预测结果用于调整BP-ANN的训练输入量，从而构成本文所提出的新算法AR-ANN。

图2是多点负荷预测方式应用AR-ANN算法的基本流程图。

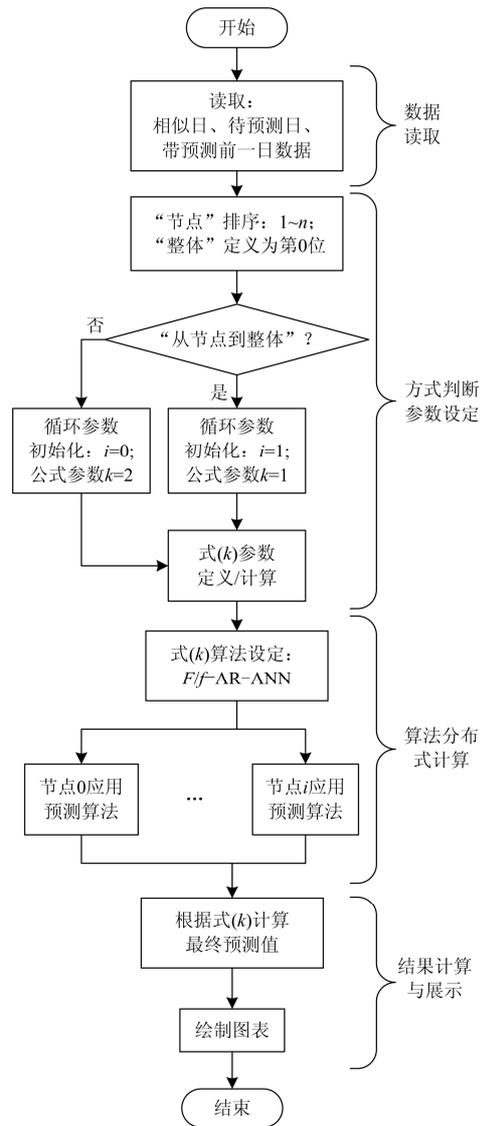


图2 AR-ANN 多点负荷预测基本流程图

Fig. 2 Basic flow chart of AR-ANN multi-node load forecast

根据式(1)、式(2)等式右侧计算步骤的相似性，可得到如图2所示两种预测方式下相同的日前多点负荷预测流程。

整个预测流程可分为数据读取、方式判断与参

数设定、AR-ANN 循环计算、最终结果计算与展示 4 个步骤。数据读取步骤中, 根据图 1 将“整体”视为级别较高的节点, 排序时设定为第 0 位, 且由于 AR-ANN 需要将 AR 预测数据连同同时段其他类型数据作为 BP-ANN 训练数据, 故读取数据时需要预测前一日的数据。方式判断与参数设定一方面为下一步 AR-ANN 循环计算次数与最终公式选择作设定, 一方面确定最终公式中的参数; 为简化大数据下负荷预测的时间消耗, 将式(1)中  $\eta$  设定为 1, 式(2)中  $\beta_i$  设定为相似日依时间先后排序的待预测节点负荷占整体负荷比例对角矩阵。AR-ANN 循环计算则根据预测方式不同分为 2 类: “从节点到整体”的预测分布式计算节点 0 至  $i$  的 AR-ANN 结果; “从整体到节点”的预测只需直接对整体进行 AR-ANN 计算。最后进行的是最终结果计算与展示步骤, 因 AR-ANN 是 BP-ANN 的改进算法, 故可将图 2 中 AR-ANN 替换为 BP-ANN 进行仿真计算进而得到对比结果, 具体过程可参考 2.2 节。

图 2 中 AR-ANN 详细预测步骤如下:

**Step1:** 对于日前负荷预测, 根据前一日负荷曲线, 使用时间序列 AR 算法得到带预测日第 1 时间点负荷预测值, 具体 AR 算法可参考 2.1 节内容。对于非日前负荷预测, 随着待预测日当日测量点的真实负荷数据的获取, AR 算法可预测的时间点不再是当日第 1 个时间点; 将这种随真实数据量不断增加的情况设定为一种短期负荷预测情形, 相应算例可见 3.1 节。

**Step2:** 将 AR 算法预测值连同同时段其他类型数据(如电价、气象数据等)作为一组新训练样本点, 将此训练样本点替换原 BP-ANN 中同时间一组样本, 最后经过 BP-ANN 运算完成负荷预测; BP-ANN 计算具体过程参考 2.2 节。

**Step3:** 记录预测数据, 计算预测误差等。

## 2 预测算法

由于 1.1 节中 AR-ANN 方法基于 ARMA 与 BP-ANN, 本章就两种方法在多点负荷预测中的步骤做具体展开。

### 2.1 AR 预测算法

AR 算法将不同时间的负荷数据视为时间序列, 根据稳定时间序列的平稳特性, 可建立 AR 时间序列模型, 通过对模型的定阶与参数求取得到具体模型进行下一时间点预测。由于负荷受气象与社会因素影响大, 故负荷时间序列只在短时间内具有稳定特性, AR 法一般仅用于短期或超短期负荷预测。该算法可划分为 3 个步骤。

**Step1:** 数据预处理。对于那些短时间仍然不够平稳的负荷时间序列, 通过差分处理增加序列的稳定性。一般情况下, 经过 2 次差分处理即可。之后对差分后的时间序列求取其均值与方差, 并进行标准化处理。

**Step2:** 模型定阶与参数估计环节。

AR 模型如式(3)所示。

$$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (3)$$

式中:  $\varepsilon_t$  代表时间点  $t$  时白噪声序列值;  $c$  代表模型自相关系数常量, 默认为 0;  $\phi_p$  分别代表各阶系数。由模型式(3)可知, AR 模型的建立需求取  $\varepsilon_t$ 、阶数  $p$  与系数  $\phi_p$ 。 $\varepsilon_t$  常用其均值 0 代替; 阶数  $p$  可根据偏相关函数截尾性初步判断, 再计算模型残差方差, 应用 AIC 准则<sup>[22]</sup>为模型定阶; 最后, 根据所求特定阶数下的偏相关函数值得到相应系数  $\phi_1, \dots, \phi_p$ 。

**Step3:** 最终, 得到可以替换部分 BP-ANN 训练样本的预测值。根据所求 AR 具体模型, 经过反差分处理, 得到待预测时间点负荷预测值  $Y_t$ 。

### 2.2 BP-ANN 多点负荷预测算法

BP-ANN 负荷预测算法是基于人工神经网络结构、通过对模型中权值参数的若干次反向矫正得到输入与输出量的非线性负荷关系函数的负荷预测算法。该方法具有 AR 所不具有的非线性关系建立、可大规模并行计算、可处理多源数据源<sup>[23]</sup>的优势, 故应用较 AR 更加广泛, 可覆盖中长期预测。但该方法在日前负荷预测中影响预测效果受相似日选取影响较大。

图 3 是 ANN 的三部分网状式结构示意图, 从左至右依次为输入层 I、隐层 J、输出层 K。网状式有向线段表示每层节点与左侧所有节点的非线性关系, 该非线性关系由线性部分层间权值之和与非线性部分激励函数组成。输入层 I 与隐层 J 线性关系如式(4)所示。

$$y_i = f\left(\sum_j w_{ij} x_j\right) \quad (4)$$

式中:  $y_i$  代表节点  $i$  的输出值;  $x_j$  代表上层节点  $j$  的输出值;  $w_{ij}$  代表节点  $i$  与节点  $j$  的层间权值;  $f$  为激励函数。

同理, 隐层 J 与输出层 K 之间的线性关系式与式(4)类似, 相应的权值为图 3 中的  $w_{jk}$ 。

常用的激励函数有多种, 本文选择最为常用的标准 sigmoid 函数。公式(4)在 sigmoid 激励函数函数下的表达式如式(5)所示。

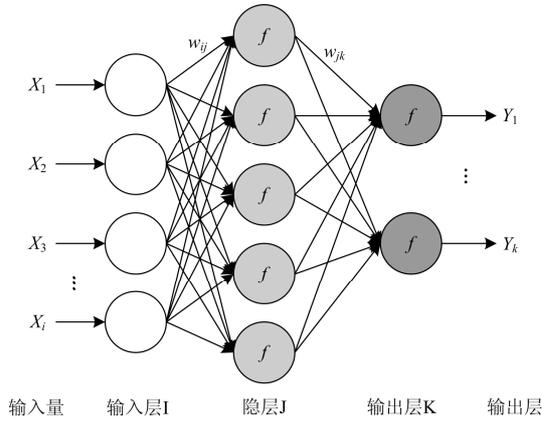


图 3 ANN 结构示意图

Fig. 3 Schematic diagram of ANN structure

$$y_i = \frac{1}{1 + \exp(-\sum_j w_{ij} x_j)} \quad (5)$$

有了图 3 样式的 ANN 结构，求取权值就是 BP 方法所做之事。简而言之，BP-ANN 的通用流程分为数据预处理、数据训练、数据预测 3 部分。考虑到大数据缩短处理数据时间要求，本文的 ANN 结构均取 3 层，隐层节点数目则由 kolmogorov 定理<sup>[24]</sup>确定。数据训练部分通过不断重复计算各层局部梯度与权值向量，逆向迭代直到 MSE 达到允许最小误差或迭代次数达到上限，以达到修正权值的目的。数据预测部分将归一化的输入参数代入参数计算完毕的 ANN 结构，计算出归一化的输出值；再通过反归一化处理得到最终负荷预测值。

图 4 的流程图即为 BP-ANN 通用流程图。特别地，针对多点负荷预测，BP-ANN 所需训练数据限定为各节点相似日待预测相同时间段的所有类型数据，待预测数据也相应为各节点待预测日待预测时段其他类型数据。完整的 BP-ANN 多点负荷预测类似图 2，区别在于各节点预测算法是 BP-ANN，且无需预测前一日数据。

### 3 仿真算例

根据式(1)、式(2)的描述，多点负荷预测是单节点负荷预测线性叠加的结果。由于误差在线性计算中是累加的，故可通过对比 AR-ANN 与 BP-ANN 在单节点负荷预测结果去验证 AR-ANN 的预测误差减小能力。对应算例为算例 1。

针对多点负荷预测中的传统“从节点到整体”的预测方式，通过比较使用 AR-ANN 的方法与直接将整体负荷视为单节点的 AR-ANN 预测结果，说明“从节点到整体”的多点负荷预测方式的必要性，

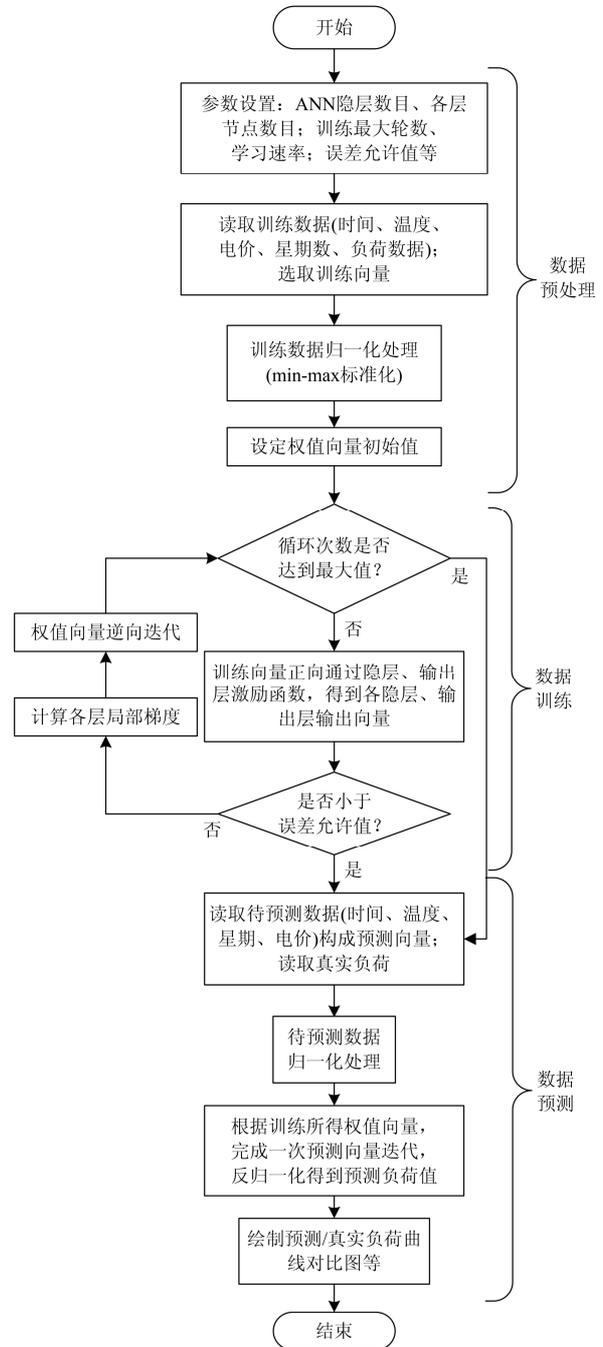


图 4 BP-ANN 流程图

Fig. 4 Flow chart of BP-ANN

也从侧面说明 AR-ANN 适用于此类多点负荷预测。对应算例为算例 2。

最后，将 AR-ANN 应用于“从整体到节点”的多点负荷预测，并将 BP-ANN 作为对比算法，用以验证“从整体到节点”多点负荷预测需求的必要性与 AR-ANN 的预测优势。

为更好地验证 AR-ANN 预测算法的应用优势，

以下各算例均包含普通工作日与元旦等特殊日期的预测结果, 结果分析则分别由最大相对误差、平均相对误差、均方根误差表示。

算例仿真平台为 Matlab。

### 3.1 算例 1: AR-ANN & BP-ANN 单节点负荷预测

现有大数据结构类型复杂、数据量庞大<sup>[25]</sup>, 且数据库更新速度快、单次更新数量巨大<sup>[26]</sup>, 大数据负荷预测往往可以根据最新历史数据进行实时预测。AR-ANN 中 AR 环节可利用大数据数据库中最新的负荷气象等数据, 更新预测结果。

结合以上大数据环境, 以日前负荷预测为基础, 不断增加已知前若干小时负荷测量值, 预测全日余下若干时间断面负荷, 共 24 种情形。

数据来源方面, 本算例采用美国 PJM 电力交易平台<sup>[27]</sup>, 选取 AP 公司运行区域整体负荷预测作为数据来源。特殊预测日设定为 2015 年元旦, 相似日为 2014 年元旦; 待预测普通工作日设定为 2015 年 1 月 13 日, 相似日设定为同为周二的同年 1 月 6 日。PJM 平台提供每小时负荷与电价数据, 即一日 24 个负荷数据点。除此之外, 通过其他渠道获得了 AP 公司负荷中心城市近 2 年日最高温、最低温的气象数据。

参数设置方面, 以日前负荷预测为例, ANN 结构中输入层节点数目为 96(24×4), 隐层节点数目为 193(96×2+1), 输出层节点数目为 24; 最大循环次数为 1 000 次, 最小允许误差为 0.001。

将以上 24 种预测情形分别使用 BP-ANN 与 AR-ANN 算法, 特殊日期与普通工作日的预测误差结果分别由图 5—图 10 所示。由这些结果可知, 在绝大多数情形下, AR-ANN 预测结果无论最大相对误差、平均相对误差还是均方根误差均小于 BP-ANN 结果。这说明, 在应用最为广泛的单点负荷预测层面, 较传统 BP-ANN, AR-ANN 不仅能在日前负荷预测中减小误差, 更能灵活地随着每日数据的更新不断调整预测结果, 且大多数预测结果均优于 BP-ANN; 误差的减小同时对电网运行方式安排、经济安全运行有重要意义。

### 3.2 算例 2: AR-ANN “从节点到整体” 多点负荷预测

负荷预测中的所有数据往往分散在各个不同的数据库<sup>[28]</sup>。大数据负荷预测可以以这些数据库为单位, 采用“分而治之”<sup>[25]</sup>的思想进行分布式负荷预测。“从节点到整体”多点负荷预测正是大数据环境下分布式的预测应用之一。

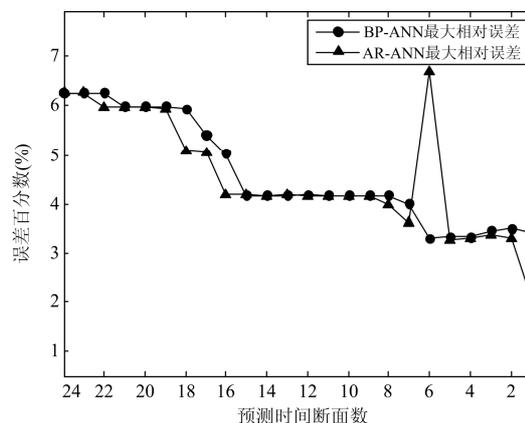


图 5 AP 公司 2015 年元旦多情形负荷预测最大相对误差图  
Fig. 5 Comparison of load forecast maximum relative error of AP company on Jan. 1 2015 under multiple scenarios

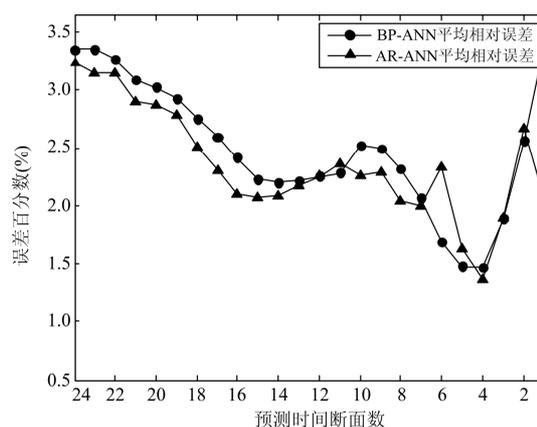


图 6 AP 公司 2015 年元旦多情形负荷预测平均相对误差  
Fig. 6 Comparison of load forecast average relative error of AP company on Jan. 1 2015 under multiple scenarios

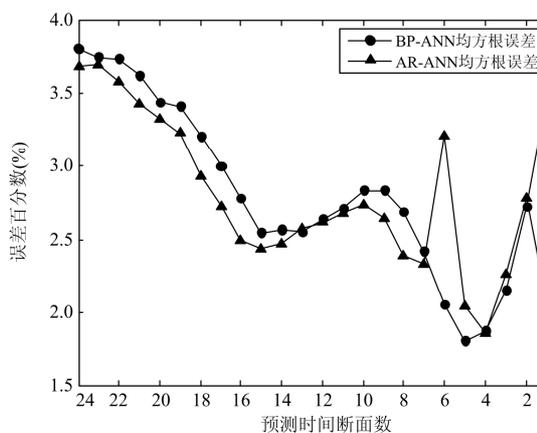


图 7 AP 公司 2015 年元旦多情形负荷预测均方根误差  
Fig. 7 Comparison of load forecast root mean square error of AP company on Jan. 1 2015 under multiple scenarios

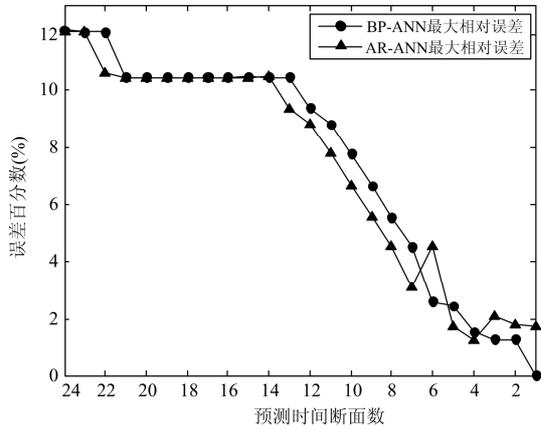


图 8 AP 公司普通工作日多情形负荷预测最大相对误差图  
Fig. 8 Comparison of load forecast maximum relative error of AP company on an ordinary workday under multiple scenarios

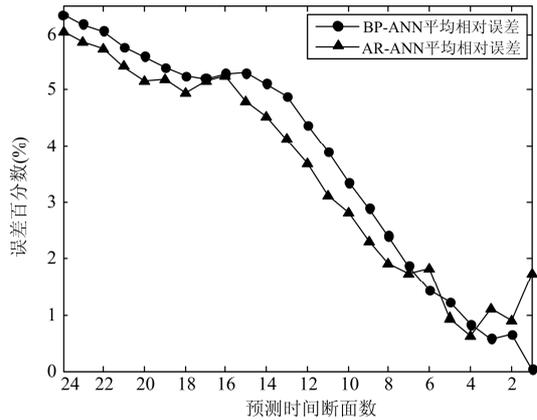


图 9 AP 公司普通工作日多情形负荷预测平均相对误差  
Fig. 9 Comparison of load forecast average relative error of AP company on an ordinary workday under multiple scenarios

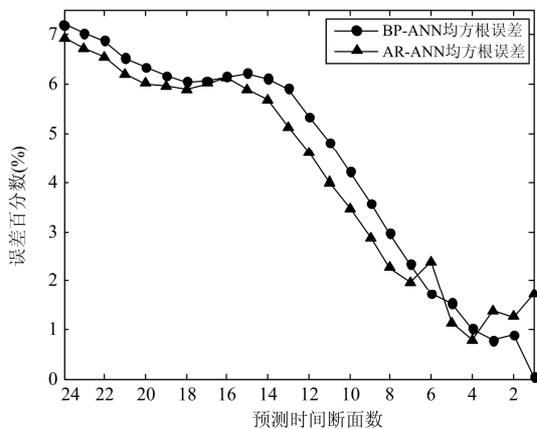


图 10 AP 公司普通工作日多情形负荷预测均方根误差  
Fig. 10 Comparison of load forecast root mean square error of AP company on an ordinary workday under multiple scenarios

本算例在算例 1 的基础上进行“从节点到整体”多点负荷预测。“整体”选取含 AP 的 PJM-WEST 区域，AP 公司所辖区域负荷视为其中 1 节点，PJM-WEST 共 8 节点。此外，算例 2 预测日期、相似日、多源数据类型与 ANN 参数设置与算例 1 相同。

算例 2 预测结果分别由图 11、图 12 所示，相应误差结果统计由表 1、表 2 所示。由误差统计结果可知，AR-ANN 可有效用于“从节点到整体”多点负荷预测，且此类多点预测结果略优于整体负荷预测。即便在两者预测值十分接近的部分时段，由于多点负荷预测继承了大数据分布式处理的理念，理论上可缩短数据处理时间。实际应用中，AR-ANN 算法从提高大电网整体负荷预测角度出发，利用譬如母线等下一级各节点历史负荷数据值进行就地负荷预测，不仅能直接缩短大电网负荷预测时间，而且能更精确地把握不同节点负荷变化规律、提高大电网整体负荷预测精度，能更好地服务于电网整体层面的调度运行计划安排。

表 1 算例 2 元旦预测结果统计

Table 1 Forecast statistics of case 2 on New Year's Day

结果统计方式	AR-ANN 整体预测	AR-ANN 多点预测
最大相对误差	3.50%	3.33%
平均相对误差	1.95%	1.84%
均方根误差	2.29%	2.17%

表 2 算例 2 普通工作日预测结果统计

Table 2 Forecast statistics of case 2 on an ordinary workday

结果统计方式	AR-ANN 整体预测	AR-ANN 多点预测
最大相对误差	6.41%	6.20%
平均相对误差	2.35%	2.39%
均方根误差	2.89%	2.89%

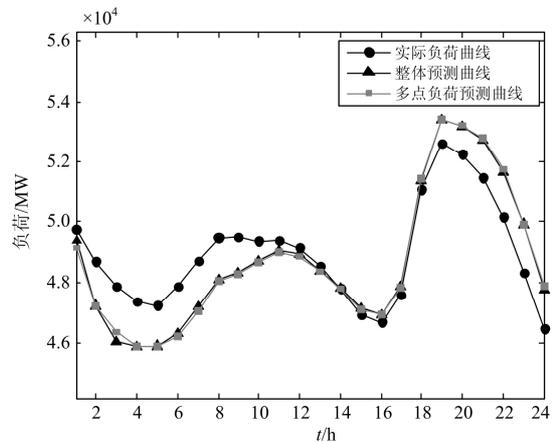


图 11 PJM-WEST 区域元旦两种预测方式结果比较图  
Fig. 11 Comparison between two forecasting methods on New Year's Day in PJM-WEST

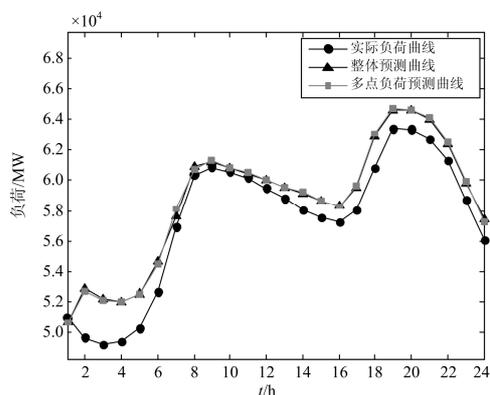


图 12 PJM-WEST 区域普通工作日两种预测方式结果比较图

Fig. 12 Comparison between two forecasting methods on an ordinary workday in PJM-WEST

### 3.3 算例 3: “从整体到节点”多点负荷预测

大数据环境下, 由于不同数据库的权限差异、数据结构相异、接口不稳定等因素, 各个数据库之间实现快速访问<sup>[29]</sup>的效果尚未达到理想状态。加之, 配网规模愈发庞大、采集密度逐步增大, 硬件测量端故障导致的数据缺失或异常情况也在增加。以上问题对多点负荷预测的有效实施提出了更高要求, 为此本文提出了“从整体到节点”的多点负荷预测。

算例 3 数据来源为菏泽市电网 SCADA 系统。我们将 35 kV 市府 I 线所带负荷视为“整体”, 下属配变 I 所接专线负荷为“节点”之一。由于非所有配变下专线都安装了测量装置, 部分线路负荷只能从更底层的用户电表数据离线计算获取, 故我们在预测这些线路负荷时, 需借助上一级“整体”的预测来完成。

本算例中特殊预测日选择 2015 年 8 月 15 日, 同为周六的当月 8 日作为相似日; 普通工作日选取当月 11 日, 相似日设定为同为周二的 8 月 4 日, 预测结果统计如表 3、表 4 所示。市府 I 线负荷测量数据囊括了含预测前一日内所有时间段, 但下属配变 I 只提供相似日数据。基于以上数据与菏泽市 8 月分时电价政策、菏泽市每日最高与最低温度, 建立与算例 1 类似的 ANN 结构, 采用相同的参数设定方式, 分别用 AR-ANN 多点负荷预测算法与 BP-ANN 算法预测 8 月 15 日配变 I 线路全日每整点所带负荷值。

具体市府 I 线配变 I 预测情况如图 13 与图 14 所示, 且 AR-ANN 多点预测平均相对误差为 7.96%, BP-ANN 平均相对误差为 8.36%。以上对比结果说明, AR-ANN “从整体到节点”多点负荷预测较 BP-ANN 直接预测误差更小; 虽然随着线路所带用户数量的减小, 随机因素的增加、特殊情况的发生会导致预测值偏离真实值较大, 譬如第 20 h、21 h 处;

但在绝大多数时间段, 相对误差仍能保持 10% 以内。

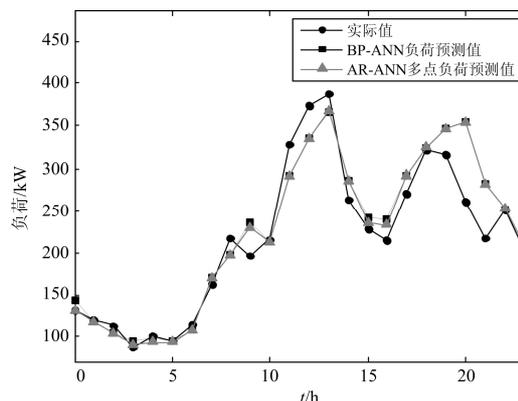


图 13 市府 I 线配变 I 周六预测与实际负荷值对比图

Fig. 13 Comparison between forecast and actual load amount of distribution transformer I of Shifu line I on one Saturday

表 3 算例 3 周六预测结果统计

Table 3 Forecast statistics of case 3 on one Saturday

结果统计方式	BP-ANN 负荷预测	AR-ANN 多点预测
最大相对误差	35.99%	35.78%
平均相对误差	8.36%	7.96%
均方根误差	11.63%	11.59%

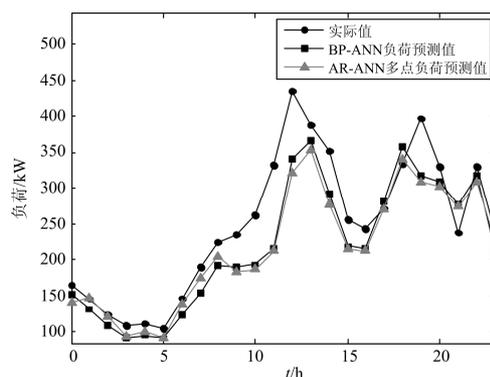


图 14 市府 I 线配变 I 周二预测与实际负荷值对比图

Fig. 14 Comparison between forecast and actual load amount of distribution transformer I of Shifu line I on one Tuesday

表 4 算例 3 周二预测结果统计

Table 4 Forecast statistics of case 3 on one Tuesday

结果统计方式	BP-ANN 负荷预测	AR-ANN 多点预测
最大相对误差	34.75%	36.04%
平均相对误差	14.23%	12.83%
均方根误差	15.88%	15.73%

以上结果说明 AR-ANN 在此类多点预测中, 能够从近大远小的预测角度出发, 时间层面利用 AR 环节就近选择能够快速访问的数据库进行“整体”负荷预测, 在通过比例关系预测出“节点”负荷; 同时在测量硬件限制等因素导致的数据缺失或异常

情况下, AR-ANN 同样可以借助“整体”数据库的预测完成“节点”负荷预测, 为系统潮流分析、安全校验、经济运行等提供更好的保障。

#### 4 结论

本文将 ARMA 时间序列预测算法与 BP-ANN 非线性预测算法优势互补, 提出了 AR-ANN 负荷预测算法。由单点负荷预测算例验证可知, 在绝大多数情况下该算法较 BP-ANN 方法可有效减小预测误差; 对“从节点到整体”的多点负荷预测而言, 该算法不仅能在部分时间段减小预测误差, 而且分布式处理方式较整体负荷预测在处理多源数据的大数据情况下能够有效缩短数据处理时间。

同时, 本文基于 AR-ANN 提出了一种从“整体到节点”的多点预测方式, 进行了节点负荷数据有限情况下的多点预测。算例结果表明, 该方法能够有效解决数据库难以快速访问、数据缺失等问题; 但少数时间点误差较大, 说明预测算法尚有改进空间。

附表 1 算例 1 元旦预测部分结果统计  
Appendix 1 Partial forecasting result statistics of case 1  
on New Year's Day

预测时间断面数	BP-ANN 最大相对 误差(%)	AR-ANN 最大相对 误差(%)	BP-ANN 平均相对 误差(%)	AR-ANN 平均相对 误差(%)
24	6.262 5	6.264 3	3.350 4	3.236 0
23	6.272 0	6.264 1	3.347 6	3.155 3
22	6.262 6	5.995 2	3.272 3	3.151 5
21	5.993 8	5.994 9	3.097 2	2.896 8
20	5.995 0	5.983 9	3.026 2	2.868 3
19	5.988 6	5.950 6	2.923 4	2.789 7
18	5.952 6	5.085 2	2.750 6	2.510 1
17	5.407 7	5.044 1	2.591 3	2.311 8
16	5.026 7	4.179 7	2.410 1	2.111 3
15	4.177 5	4.183 1	2.228 3	2.074 2
14	4.165 6	4.170 1	2.203 1	2.089 1
13	4.177 4	4.181 1	2.216 1	2.179 5
12	4.179 7	4.174 5	2.258 2	2.254 8
11	4.174 5	4.159 9	2.282 5	2.364 4
10	4.174 9	4.174 2	2.524 7	2.259 6
9	4.162 8	4.169 8	2.494 0	2.294 6
8	4.165 0	3.994 7	2.322 5	2.043 8
7	3.989 4	3.628 8	2.063 2	1.997 3
6	3.297 5	6.702 6	1.692 8	2.339 1
5	3.316 7	3.276 6	1.482 3	1.640 8
4	3.323 8	3.297 6	1.471 3	1.374 3
3	3.458 0	3.374 2	1.885 4	1.898 5
2	3.499 3	3.304 9	2.555 9	2.670 4
1	3.399 4	2.043 5	3.399 4	2.043 5

附表 2 算例 1 元旦预测部分结果统计  
Appendix 2 Partial forecasting result statistics of case 1  
on New Year's Day

预测时间断面数	BP-ANN 均方根误差(%)	AR-ANN 均方根误差(%)
24	3.806 0	3.684 7
23	3.750 8	3.699 6
22	3.733 1	3.579 7
21	3.621 2	3.424 6
20	3.442 4	3.325 5
19	3.411 9	3.231 6
18	3.207 1	2.938 0
17	2.999 8	2.727 5
16	2.782 7	2.488 8
15	2.543 0	2.429 6
14	2.562 9	2.470 8
13	2.548 6	2.570 8
12	2.637 5	2.617 7
11	2.711 9	2.679 9
10	2.832 3	2.731 9
9	2.835 2	2.641 6
8	2.269 0	2.391 4
7	2.414 6	2.326 7
6	2.050 2	3.212 3
5	1.807 0	2.034 7
4	1.870 8	1.857 3
3	2.146 1	2.263 3
2	2.726 8	2.781 4
1	3.484 2	2.051 9

附表 3 算例 1 普通工作日预测部分结果统计  
Appendix 3 Partial forecasting result statistics of  
case 1 on an ordinary workday

预测时间断面数	BP-ANN 最大相对 误差(%)	AR-ANN 最大相对 误差(%)	BP-ANN 平均相对 误差(%)	AR-ANN 平均相对 误差(%)
24	12.142 0	12.075 2	6.340 9	6.055 2
23	12.069 1	12.074 0	6.175 4	5.855 2
22	12.064 6	10.645 8	6.056 5	5.726 6
21	10.476 3	10.474 3	5.775 4	5.421 8
20	10.470 4	10.474 7	5.592 3	5.170 2
19	10.474 3	10.489 0	5.402 8	5.189 0
18	10.479 7	10.475 4	5.258 4	4.976 0
17	10.484 8	10.490 3	5.219 6	5.179 4
16	10.482 6	10.483 3	5.290 2	5.274 5
15	10.494 1	10.476 7	5.310 4	4.790 0
14	10.478 8	10.497 8	5.130 7	4.538 1
13	10.485 0	9.365 6	4.899 8	4.131 1
12	9.390 3	8.848 9	4.382 5	3.697 6
11	8.841 9	7.810 1	3.905 7	3.127 7
10	7.791 7	6.686 9	3.347 0	2.824 9
9	6.678 2	5.574 6	2.890 4	2.310 1
8	5.566 2	4.549 3	2.404 4	1.910 6
7	4.543 3	3.123 3	1.874 9	1.733 0
6	2.614 1	4.532 4	1.443 0	1.839 8
5	2.468 2	1.739 5	1.230 8	0.947 1
4	1.527 6	1.266 4	0.824 0	0.643 9
3	1.268 8	2.076 0	0.583 6	1.118 5
2	1.263 6	1.795 5	0.649 0	0.911 6
1	0.024 4	1.737 4	0.024 4	1.737 4

附表 4 算例 1 普通工作日预测部分结果统计

Appendix 4 Partial forecasting result statistics of case 1 on an ordinary workday

预测时间断 面数	BP-ANN 均方根误差(%)	AR-ANN 均方根误差(%)
24	7.206 2	6.937 3
23	7.030 2	6.736 8
22	6.875 6	6.549 2
21	6.532 6	6.215 5
20	6.353 6	6.020 5
19	6.171 2	5.954 6
18	6.046 3	5.885 9
17	6.057 9	6.030 1
16	6.156 1	6.160 0
15	6.225 9	5.881 0
14	6.099 1	5.698 7
13	5.919 4	5.140 9
12	5.350 9	4.624 7
11	4.810 0	4.008 9
10	4.193 7	3.458 3
9	3.567 2	2.860 6
8	2.943 8	2.263 0
7	2.325 7	1.967 7
6	1.726 6	2.373 5
5	1.518 8	1.122 1
4	1.022 2	0.788 8
3	0.778 2	1.401 9
2	0.893 9	1.269 8
1	0.024 4	1.737 4

## 参考文献

- [1] 张建华, 曾博, 张玉莹, 等. 主动配电网规划关键问题与研究展望[J]. 电工技术学报, 2014, 29(2): 13-23.  
ZHANG Jianhua, ZENG Bo, ZHANG Yuying, et al. Key issues and research prospects of active distribution network planning[J]. Transactions of China Electrotechnical Society, 2014, 29(2): 13-23.
- [2] NOSE-FILHO K, LOTUFO A D P, MINUSSI C R. Short-term multinodal load forecasting using a modified general regression neural network[J]. IEEE Transactions on Power Delivery, 2011, 26(4): 2862-2869.
- [3] HAN X S, HAN L, GOOI H B, et al. Ultra-short-term multi-node load forecasting—a composite approach[J]. IET Generation, Transmission & Distribution, 2012, 6(5): 436-444.
- [4] WANG Z Y, GUO C X, CAO Y J. A new method for short-term load forecasting integrating fuzzy-rough sets with artificial neural network[C] // Power Engineering Conference, 2005. IPEC 2005. The 7th International. IEEE, 2005: 1-173.
- [5] 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.
- [6] 马哲, 舒勤. 基于 ESPRIT 分解算法的短期电力负荷预测[J]. 电力系统保护与控制, 2015, 43(7): 90-96.  
MA Zhe, SHU Qin. Short term load forecasting based on ESPRIT integrated algorithm[J]. Power System Protection and Control, 2015, 43(7): 90-96.
- [7] 鲁宝春, 赵深, 田盈, 等. 优化系数的 NGM(1,1,k)模型在中长期电量预测中的应用[J]. 电力系统保护与控制, 2015, 43(12): 98-103.  
LU Baochun, ZHAO Shen, TIAN Ying, et al. Mid-long term electricity consumption forecasting based on improved NGM (1,1,k) gray model[J]. Power System Protection and Control, 2015, 43(12): 98-103.
- [8] 莫维仁, 张伯明, 孙宏斌, 等. 短期负荷预测中选择相似日的探讨[J]. 清华大学学报(自然科学版), 2004, 44(1): 106-109.  
MO Weiren, ZHANG Boming, SUN Hongbin, et al. Method to select similar days for short-term load forecasting[J]. Journal of Tsinghua University (Science and Technology), 2004, 44(1): 106-109.
- [9] 林辉, 刘晶, 郝志峰, 等. 基于相似日负荷修正的节假日短期负荷预测[J]. 电力系统保护与控制, 2010, 38(7): 47-51.  
LIN Hui, LIU Jing, HAO Zhifeng, et al. Short-term load forecasting for holidays based on the similar days' load modification[J]. Power System Protection and Control, 2010, 38(7): 47-51.
- [10] 黎灿兵, 李晓辉, 赵瑞, 等. 电力短期负荷预测相似日选取算法[J]. 电力系统自动化, 2008, 32(9): 69-73.  
LI Canbing, LI Xiaohui, ZHAO Rui, et al. A novel algorithm of selecting similar days for short-term power load forecasting[J]. Automation of Electric Power Systems, 2008, 32(9): 69-73.
- [11] 杨正瓴, 田勇, 张广涛, 等. 相似日短期负荷预测的非线性理论基础与改进[J]. 电网技术, 2006, 30(6): 63-66.  
YANG Zhengling, TIAN Yong, ZHANG Guangtao, et al. Nonlinear theoretical foundation and improvement of similar days method for short term load forecasting[J]. Power System Technology, 2006, 30(6): 63-69.
- [12] 叶瑰响, 罗耀华. 基于 ARMA 模型的电力系统负荷预测方法研究[J]. 信息技术, 2002(6): 74-76.  
YE Guiyun, LUO Yaohua. Research on method of power system load forecasting based on ARMA model[J]. Information Technology, 2002(6): 74-76.
- [13] 张鑫, 韦钢, 周中明, 等. ANN 在电力系统中期负荷预测中的应用[J]. 电力系统及其自动化学报, 2003, 15(2): 36-39.  
ZHANG Xin, WEI Gang, ZHOU Zhongming, et al. The application of ANN in middle term load forecasting of power system[J]. Proceedings of the CSU-EPSCA, 2003, 15(2): 36-39.

- [14] 贺静, 韦钢, 熊玲玲. 负荷预测线性回归分析法的模糊改进[J]. 华东电力, 2004, 31(11): 21-23.  
HE Jing, WEI Gang, XIONG Lingling. Fuzzy improvement of linear regression analysis for load forecasting[J]. East China Electric Power, 2004, 31(11): 21-23.
- [15] 连加典, 刘宏立, 谢海波, 等. 基于预测机制的分级负载均衡算法[J]. 计算机工程与应用, 2015, 51(11): 67-71.  
LIAN Jiadian, LIU Hongli, XIE Haibo, et al. Classified load balancing algorithm based on prediction mechanism[J]. Computer Engineering and Applications, 2015, 51(11): 67-71.
- [16] 张民, 鲍海, 晏玲, 等. 基于卡尔曼滤波的短期负荷预测方法的研究[J]. 电网技术, 2003, 27(10): 39-42.  
ZHANG Min, BAO Hai, YAN Ling, et al. Research on processing of short-term historical data of daily load based on Kalman filter[J]. Power System Technology, 2003, 27(10): 39-42.
- [17] 陈刚, 闫飞, 龚啸, 等. 基于参数优化的最小二乘支持向量机状态估计方法[J]. 电力系统保护与控制, 2011, 39(19): 83-88.  
CHEN Gang, YAN Fei, GONG Xiao, et al. State estimate based on parameter-optimized least square support vector machines[J]. Power System Protection and Control, 2011, 39(19): 83-88.
- [18] 张俊芳, 吴伊昂, 吴军基. 基于灰色理论负荷预测的应用研究[J]. 电力自动化设备, 2004, 24(5): 24-27.  
ZHANG Junfang, WU Yiang, WU Junji. Application of gray system theory in load forecasting[J]. Electric Power Automation Equipment, 2004, 24(5): 24-27.
- [19] 王东, 史晓霞, 尹交英. 不同核函数的支持向量机用于空调负荷预测的对比研究[J]. 电工技术学报, 2015, 30(增刊 1): 531-535.  
WANG Dong, SHI Xiaoxia, YIN Jiaoying. Prediction on hourly load of air conditioning by RBF support vector machine[J]. Transactions of China Electrotechnical Society, 2015, 30(S1): 531-535.
- [20] 刘念, 张清鑫, 刘海涛. 基于核函数极限学习机的微电网短期负荷预测方法[J]. 电工技术学报, 2015, 30(8): 218-224.  
LIU Nian, ZHANG Qingxin, LIU Haitao. Online short-term load forecasting based on ELM with kernel algorithm in micro-grid environment[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 218-224.
- [21] TAYLOR J W, MCSHARRY P E. Short-term load forecasting methods: An evaluation based on European data[J]. IEEE Transactions on Power Systems, 2007, 22(4): 2213-2219.
- [22] 郭艳鹏. 多维 ARMA 模型的谱估计及预测方法[D]. 成都: 西南交通大学, 2008.  
GUO Yanli. The methods of spectrum density estimation and prediction of multidimensional ARMA (p,q) models[D]. Chengdu: Southwest Jiaotong University, 2008.
- [23] 吕婵. 基于 BP 神经网络的短期负荷预测[D]. 武汉: 华中科技大学, 2007.  
LÜ Chan. Short-term load forecasting based on BP artificial neural network[D]. Wuhan: Huazhong University of Science & Technology, 2007.
- [24] 邵莹. 基于神经网络的电力系统短期负荷预测研究[D]. 哈尔滨: 哈尔滨理工大学, 2005.  
SHAO Ying. Research on electric power system short-term load forecasting using a neural network[D]. Harbin: Harbin University of Science and Technology, 2005.
- [25] 张素香, 赵丙镇, 王风雨, 等. 海量数据下的电力负荷短期预测[J]. 中国电机工程学报, 2015, 35(1): 37-42.  
ZHANG Suxiang, ZHAO Bingzhen, WANG Fengyu, et al. Short-term power load forecasting based on big data[J]. Proceedings of the CSEE, 2015, 35(1): 37-42.
- [26] 王德文, 孙志伟. 电力用户侧大数据分析并行负荷预测[J]. 中国电机工程学报, 2015, 35(3): 527-537.  
WANG Dewen, SUN Zhiwei. Big data analysis and parallel load forecasting of electric power user side[J]. Proceedings of the CSEE, 2015, 35(3): 527-537.
- [27] PJM markets & operations database[EB/OL]. [2015-10-14]. <http://www.pjm.com/markets-and-operations.aspx>.
- [28] 刘科研, 盛万兴, 张东霞, 等. 智能配电网大数据应用需求和场景分析研究[J]. 中国电机工程学报, 2015, 35(2): 287-293.  
LIU Keyan, SHENG Wanxing, ZHANG Dongxia, et al. Big data application requirements and scenario analysis in smart distribution network[J]. Proceedings of the CSEE, 2015, 35(2): 287-293.
- [29] 宋亚奇, 周国亮, 朱永利, 等. 云平台下输变电设备状态监测大数据存储优化与并行处理[J]. 中国电机工程学报, 2015, 35(2): 255-267.  
SONG Yaqi, ZHOU Guoliang, ZHU Yongli, et al. Storage optimization and parallel processing of condition monitoring big data of transmission and transforming equipment based on cloud platform[J]. Proceedings of the CSEE, 2015, 35(2): 255-267.

收稿日期: 2015-11-26; 修回日期: 2016-03-01

作者简介:

雷正新(1991-), 男, 硕士研究生, 研究方向为配电网短期负荷预测; E-mail: leizhengxin@sjtu.edu.cn

韩蓓(1984-), 女, 通信作者, 博士, 研究方向为含新能源接入的电力系统分析、微电网分析与控制; E-mail: han\_bei@sjtu.edu.cn

聂萌(1976-), 男, 本科, 工程师, 研究方向为电力系统运行与控制。

(编辑 周金梅)