

基于贝叶斯神经网络的电网超载负荷预测模型优化

电网负荷具有非线性特点，可预测性较差。提出一种基于神经网络的电网负荷超载预测模型，设计了一个由输入层、隐含层以及输出层构成的网络模型，采用该模型对电网负荷超载进行预测，并基于贝叶斯定理训练该预测模型，对预测过程中的超载负荷不确定因素进行全面分析，采用求极大似然估计和迭代算法得到预测模型的最优参数，然后将各步迭代求解得到的神经网络输入当作随机变量输入，最后依据塑造的最佳预测模型得到最优电网负荷超载的预测结果。实验结果说明，所设计模型的预测结果同实际更接近，避免了不确定性对电网负荷超载预测的干扰，具有较高的预测准确度。

冯迎春 庄燕飞 任庆帅 陈仁刚/国网山东省电力集团公司检修公司

0 引言

电力是国民经济的命脉，其对经济建设、国家和社会的稳定起着关键作用。随着经济的快速发展，电力系统负荷逐渐增加，负荷超载问题也越来越多^[1-3]。电力系统出现负荷超载问题，会大大降低电力系统的运行周期和平稳性，同时产生巨大的经济损失。电网负荷超载预测是确保电网安全、稳定和经济运行的前提。因此，设计有效的电网负荷超载预测模型，成为电力领域分析的重点^[4-6]。

文献[7]提出了基于新型粒子群算法的电力超载负荷预测算法，具有速度快、可靠性较高的优势，但是该算法容易出现局部最优解问题。文献[8]利用反馈模糊控制算法进行电网负荷超载预测，通过电力机组电枢电力检测量的模糊处理方法，对电网负荷超载进行预测，虽然运算结果准确度较高，但是该种算法的抗干扰能力较弱，并且需要同

其他算法结合使用。文献[9]提出了通过特性矩阵分层分析法预测电网负荷超载的方法，该方法在理论上可获取最优解，但是存在计算量过大的弊端。文献[10]分析了基于聚类算法的电网负荷超载预测方法，该种算法主要针对电网负荷超载量较小情况，具有较高的局限性。

基于上述分析的问题，提出了基于贝叶斯定理的BP神经网络电网负荷超载预测模型，设计了一个由输入层、隐含层以及输出层构成的BP网络模型，通过BP神经网络对电网负荷超载进行预测，并基于贝叶斯定理训练该预测模型，依据塑造的最佳预测模型，最终获取最优的电网负荷超载预测结果。实验结果表明，所设计模型的预测结果同实际更接近，且具有较高的预测准确度。

1 预测模型的设计与实现

1.1 电网负荷预测模型参数的选择

在电网负荷超载预测中，通常条件下模型参数的选择关系到后期负荷预测的准确度，预测的各参数选择如下。

(1) 历史负荷超载数据的确定

历史负荷超载数据选取预测日之前两个星期的每天24或48个点的平均负荷（对应于日用电量）。

(2) 电网节点数的确定

每天同一个点的平均负荷具有周期特征，因此选取电网中的10个节点。

(3) 模型中隐节点数的确定

选择预测模型中不同层节点数，同



冯迎春/高级工程师

关键词/Keywords

电网负荷·
超载·
预测模型·
贝叶斯定理·

预测结果间具有较高的关联性，因此应合理选择隐含层节点数。对电网负荷超载数据进行多次训练，基于训练结果可知，当隐含层节点为15时，获取的结果最佳。因此本文规定神经网络隐含层节点数为15。

(4) 模型层数的确定

当不同隐含节点都采用S型压缩函数时，一个隐含层则可实现任意判决分类问题，因而使用了三层的BP网络。

(5) 电力数据的归一化处理

在神经网络进行训练和检测前，为了满足网络输入输出对数据的要求，并增强网络的收敛效率，需要将网络输入数据和实际输出数据按式

(1) 转换到 $[-1, 1]$ 区间内，通过BP神经网络预测电网负荷超载后，在输出层按照式(2)换算回负荷值，具体如下

$$y = 2 \times \frac{x - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (1)$$

$$x = 0.5(y + 1)(x_{\max} - x_{\min}) + x_{\min} \quad (2)$$

式中， x 、 y 分别为输入样本归一化前后的值； $x_{\min}$ 、 $x_{\max}$ 分别为样本采集中负荷的最小值和最大值。

(6) 权值初始值

设置合理的初始权值，可确保网络训练误差最小化，进而获取高质量的最优解。本文设置网络的初始权值为 $w = 1.0$ 。

1.2 模型的总体结构设计

模型需要预测电网负荷超载的序列样本后一天24个点的负荷超载值，这些负荷超载值具有不同的幅度值，因此需要用24个不同的神经网络进行训练和预测，该模型的表达式为 $y(x, w)$ ，模型的具体结构如图1所示。




图1 BP神经网络的电网负荷超载预测模型

通过BP神经网络进行预测时，输入因素的选择对预测结果好坏具有较大的影响。本文采用历史电网负荷超载数据，模型输出为预测日的对应小时电网负荷超载值。

2 电网负荷超载预测的模型优化

通过BP神经网络构建的电网负荷超载预测模型，虽然可快速获取电网负荷超载预测值，但是该模型并没有考虑输入和输出电力数值的不确定性和随机性，获取的预测值存在一定的误差。因此，为了提高电网负荷超载预测的准确度，通过贝叶斯定理对BP神经网络电网负荷超载预测模型进行训练学习，获取最佳的电网负荷超载预测结果。

为了考虑上述构造BP神经网络电网负荷超载预测模型 $y(x, w)$ 输入和输出的不确定特征，需要对预测过程中的噪声因素进行充分分析，因此可用变量 y_i 描述电网负荷超载预测值，具体如下

$$y_i = y(x_i, w) + a_i + \sigma^2 \quad (3)$$

式中， a_i 为噪声； σ^2 为优化参数； w 为节点权值。

则电网负荷超载训练样本的似然函数为

$$p(Y|w, \sigma^2) = \prod_{i=1}^n p(y_i|w, \sigma^2) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \|Y - \phi w\|^2\right\} \quad (4)$$

式中， $\phi(x_i) = [1, k(x, x_1), \dots, k(x, x_n)]^T$ ； Y 为预测电网负荷超载输出。

为了增强预测模型的泛化性，需要将权值 w 的先验分布定义成正态分布，具体如下

$$p(w|a) = \prod_{i=1}^n N(0, a_i^{-1}) \quad (5)$$

式中， a 为决定权值 w 的先验分布的超参数。

基于贝叶斯定理准则，能够得到权值 w 的后验分布如下

$$p(w|Y, a, \sigma^2) = \frac{p(Y|w, \sigma^2)p(w|a)}{p(Y|a, \sigma^2)} \quad (6)$$

式中，分母为归一化因子，同权值无关。

由此可以看出该权值后验分布也服从如下的高斯分布

$$p(w|Y, a, \sigma^2) = N(u, \sum) \quad (7)$$

通过式(7)可得,权值的估计需要通过权值的后验分布均值 u 给出,权值最优值的不确定性由 $\sum$ 来决定。为了估计模型权值,通过反复迭代可获取 a 、 σ^2 的最优值为

$$a_i^{\text{new}} = \frac{1 - a_i^{\text{old}} \sum ii}{u_i^2} \quad (8)$$

$$(\sigma^2)^{\text{new}} = \frac{\|Y - \phi u\|}{n - \sum (1 - a_i \sum ii)}$$

式中, $\sum ii$ 用于描述协方差,循环运算式(8)直至收敛,最终获取最佳超参数 a^* 、 σ^{*2} 。

如果上述超参数预测过程收敛,则对新的电网负荷超载输入数据 $\hat{x}$ 进行预测,其预测模型优化后为

$$p(Y'|Y, a^*, \sigma^{*2}) = p \int (Y'|w, \sigma^{*2}) p(w|Y, a^*, \sigma^{*2}) dw \quad (9)$$

3 实验分析

3.1 本文模型有效性分析

为了验证本文模型的有效性,需要进行相关的实验分析。因为电网负荷具有较强的按日计算的特征,每日对应时间段内的用电量具有较强的规律性,因此实验选用用电高峰期(17:30~20:00)的一组负荷数据作为研究对象。对比模型为文献[7]中的新型粒子群模型。

本文模型预测的电网负荷超载值同实际值的对比情况和误差分布如图2、图3所示。




图2 本文模型预测的电网负荷超载值同实际值的对比

分析图2可得,本文模型的输出可很好地拟合实际负荷超载值。从图3中可以看出,本文模型的预测误差在5~40 kW之间变化,误差相对实际负




图3 本文模型的预测误差

荷超载值较小。因此可得,本文模型可实现电网负荷超载的准确预测,具有较高的应用价值。

3.2 电网负荷超载预测结果分析

将1 d中的0.5 h的负荷超载量当作实验对象进行预测,并将负荷超载数据划分成48组,分别塑造本文模型和参考文献[7]模型,按照这些模型,对2012年3月25~31日共7 d对应时刻的电网负荷超载进行预测的结果以及误差分布分别如图4和图5所示。分析图4可得,相比文献[7]模型,本文模型的预测值能够较好地拟合实际超载值。分析图5可得,本文模型的预测误差在0~20 kW上下波动,最大值低于20 kW;而文献[7]模型的预测误差在10~60 kW间波动,因此可以看出本文模型的预测误差远低于文献[7]模型。本文模型的误差统计结




图4 2012年3月25~31日两种模型的电网负荷超载预测结果




图5 2012年3月25~31日两种模型的电网负荷超载预测误差

果如表1所示。由表1可得，本文模型的预测误差都低于3.5%，最大误差仅有3.42%，平均误差最大仅有1.2%，可实现电网负荷超载的合理预测。

表1 本文模型电网负荷超载预测误差统计结果

日期	平均 误差 (%)	最大 误差 (%)	误差 <1% 的点数	误差 <2% 的点数	误差 <3% 的点数	日均 误差 (%)
3月25日	0.66	1.80	28	47	47	0.50
3月26日	1.20	2.40	11	30	43	1.45
3月27日	0.60	1.78	27	44	47	0.22
3月28日	0.52	1.54	38	47	47	0.07
3月29日	0.73	2.34	32	40	47	0.08
3月30日	0.91	3.02	25	40	45	0.54
3月31日	0.98	3.42	25	37	43	1.02

为了说明本文模型的预测准确度，同样以17:30~20:00的负荷数据塑造文献[7]中的新型粒子群模型，分别用两种模型对2012年3月25~31日相应时间的负荷超载情况进行预测，获取的误差结果对比如表2所示。分析表2可得，本文模型具有较高的预测准确度。

表2 两种负荷超载预测模型的预测结果对比

预测模型	平均 误差 (%)	最大 误差 (%)	误差 <1% 的点数	误差 <2% 的点数	误差 <3% 的点数	日均 误差 (%)
文献[7]模型	1.82	4.06	16	30	43	1.35
本文模型	1.05	3.20	13	26	35	1.02

通过上述实验分析可得，本文模型用于电网负荷超载预测，避免了不确定性对电网负荷超载预测的干扰，具有较高的预测准确度。本文模型的电网负荷超载预测效果优于新型粒子群模型，平均预测误差和最大预测误差都远小于新型粒子群模型。

4 结束语

本文提出了基于贝叶斯定理的BP神经网络电网负荷超载预测模型，设计了一个由输入层、隐含层以及输出层构成的BP网络模型，采用该模型对电网负荷超载进行预测，并基于贝叶斯定理训练该预测模型，对预测模型中的不确定因素进行全面分析，采用求极大似然估计和迭代算法得到

预测模型的最优参数，然后将各步迭代求解得到的神经网络输入当作随机变量输入，最后依据塑造的最佳预测模型，得到最优电网负荷超载的预测结果。实验结果说明，所设计模型的预测结果同实际更接近，避免了不确定性对电网负荷超载预测的干扰，具有较高的预测准确度。

参考文献

- [1] 宋丽丽, 石丽. 基于遗传算法优化BP网络的高校师生比预测模型分析[J]. 沈阳理工大学学报, 2013, 32(1): 80-84.
- [2] 张正光, 李国宁, 陈璐. CIPS中基于改进 GANN 的入侵检测模型[J]. 计算机工程, 2013, 39(4): 154-157.
- [3] 王晓兰, 葛鹏江. 基于相似日和径向基函数神经网络的光伏阵列输出功率预测[J]. 电力自动化设备, 2013, 33(1): 100-103.
- [4] Shakouri H, Nadimi R. Outlier detection in fuzzy linear regression with crisp input-output by linguistic variable view[J]. Applied Soft Computing, 2013(13): 734-742.
- [5] 焦润海, 苏辰售, 林碧英, 等. 基于气象信息因素修正的灰色短期负荷预测模型[J]. 电网技术, 2013, 37(3): 720-725.
- [6] 张昀, 周淦, 任海军, 等. 数据挖掘在电力负荷坏数据智能辨识与修正中的应用[J]. 重庆大学学报: 自然科学版, 2013, 36(2): 69-74.
- [7] 刘衍民, 牛奔. 新型粒子群算法理论与实践[M]. 北京: 科学出版社, 2013.
- [8] Chou T Y, Liang G S, Han T C. Application of fuzzy regression on air cargo volume forecast[J]. Qual Quant, 2013(47): 897-908.
- [9] 孙谦, 姚建刚, 金敏, 等. 基于特性矩阵分层分析的短期母线负荷预测坏数据处理策略[J]. 电工技术学报, 2013, 28(7): 226-233.
- [10] 牛东晓, 魏亚楠. 基于FHNN相似日聚类自适应权重的短期电力负荷组合预测[J]. 电力系统自动化, 2013, 37(3): 54-57.

(收稿日期: 2015-09-10) EA