

DOI: 10.19650/j.cnki.cjsi.J1905058

基于弹性网降维及花授粉算法优化 BP 神经网络的短期电力负荷预测*

张淑清¹, 杨振宁¹, 张立国¹, 苑世钰¹, 王志义²

(1. 燕山大学电气工程学院 河北省测试计量技术及仪器重点实验室 秦皇岛 066004; 2. 93046 部队 青岛 266111)

摘要: 电力负荷预测为电力系统规划和运行提供可靠的决策依据。随着智能电网的全面发展, 数据采集与监视控制系统 (SCADA) 获取数据量增加, 数据的结构也更加复杂, 负荷的频繁变化以及地区性的气象因素等都将影响负荷的预测的准确性。提出一种弹性网 (EN) 进行大数据降维以及花授粉算法 (FPA) 优化 BP 神经网络的短期电力负荷预测方法。首先采用弹性网对负荷和气象等高维大数据进行选择 and 降维。弹性网通过在惩罚项中添加 L_1 范数和 L_2 范数, 兼具了最小绝对值收缩及变量选择 (LASSO) 和岭回归的优点, 克服了 LASSO 降维时因为数据内部存在共线性和群组效应而影响降维效果的问题; 然后, 考虑到 BP 神经网络权值和阈值容易受到初值的影响、收敛速度慢以及容易陷入局部最优, 引入花授粉算法 (FPA) 优化 BP 神经网络, 通过与粒子群算法 (PSO) 对比得出花授粉算法寻优速度更快, 效果更好。本文方法应用于实际电力负荷预测, 结果表明能有效提高预测精度。

关键词: 短期电力负荷预测; 大数据变量选择及降维; 最小绝对值收缩及变量选择; 弹性网; 花授粉算法优化 BP 神经网络

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 520.2099

Short-term power load forecast based on dimension reduction by elastic network and flower pollination algorithm optimized BP neural network

Zhang Shuqing¹, Yang Zhenning¹, Zhang Ligu¹, Yuan Shiyu¹, Wang Zhiyi²

(1. Institute of Electrical Engineering, Key Laboratory of Measurement Technology and Instrumentation of Hebei Province, Yanshan University, Qinhuangdao 066004, China; 2. The 93046th Troop, Qingdao 266111, China)

Abstract: Power load prediction can provide reliable decision-making basis for power system planning and operation. With the development of smart grid, the amount of data collected by supervisory control and data acquisition increases largely, and the structure of data becomes more complex. Frequent changes of load and regional meteorological factors have influence on the accuracy of load forecasting. A short-term load forecasting method is proposed in this study, which is based on elastic network (EN) for large data dimension reduction and flower pollination algorithm (FPA) for BP neural network optimization. By adding norms and norms to penalty items, the elastic network has the advantages of least absolute shrinkage and selection operator (LASSO) and ridge regression. It can solve the problem of dimension reduction effect, which is affected by collinearity and group effect in LASSO dimension reduction. Then, FPA is introduced to optimize BP neural network, in which the weights and thresholds are easily affected by initial values, slow convergence speed and easy to fall into local optimum. Compared with particle swarm optimization method, the optimization speed of flower pollination algorithm is faster and the effect is better. The proposed method has been applied for predicting power load. Experimental results show that the prediction accuracy can be effectively improved.

Keywords: short-term load forecasting; large data variable selection and dimension reduction; least absolute shrinkage and selection operator; elastic network; flower pollination algorithm optimizing BP neural network

收稿日期: 2019-04-28 Received Date: 2019-04-28

* 基金项目: 国家重点研发项目 (2018YFB0905500)、国家自然科学基金 (51875498)、河北省自然科学基金 (E2018203439, E2018203339)、河北省专业学位研究生教学案例库建设项目 (KCJSZ2017022) 资助

0 引言

准确可靠的电力负荷预测为电力系统规划和运行提供可靠的决策依据,为电力系统安全经济运行提供保障,如何提高预测精度一直是国内外研究的热点^[1-3]。研究表明,短期电力负荷预测与天气因素和历史负荷有关^[4-5]。随着智能电网全面发展,历史负荷数据与天气数据呈指数增长^[6-8],趋于大数据化而且数据中存在严重的共线性和群组效应,给历史负荷数据和天气数据的降维带来了困难。目前国际上广泛使用的是最小绝对值收缩及变量选择方法(least absolute shrinkage and selection operator, LASSO),它在最小二乘的基础之上针对无影响或弱影响的变量数据,通过构造惩罚函数,约束回归模型系数,实现有偏估计,使得残差平方最小化^[9-10]。然而,LASSO 算法在数据内部存在共线性和群组效应时,会影响降维效果。本文提出利用 LASSO 改进算法—弹性网(elastic network)对负荷和气象等高维大数据进行选择 and 降维弹性网可以克服原始数据中的共线性和群组效应,并且在变量数大于变量维数时有很好的表现^[11-14]。通过对比实验验证了弹性网在处理共线性强以及群组效应明显的效果时效果更好。

电力负荷预测模型是提高预测精度的关键。随着时代发展,人工神经网络(artificial neural network, ANN)方法在负荷预测中得到了广泛的应用。其中应用最多的就是 BP 神经网络,但是其具有学习收敛速度较慢,容易陷于局部极小点的缺点^[15]。学者一直寻找 BP 的优化算法,目前优化效果较好的有 L-M 算法优化 BP 神经网络^[16]、粒子群算法优化 BP 神经网络^[17-18]。粒子群算法是从随机解出发,通过跟踪两个极值来迭代寻找最优解^[18]。本文提出花授粉算法(flower pollination algorithm, FPA)优化 BP 神经网络的权值和阈值,通过自花授粉和异花授粉更新花朵信息,寻找最优解,改善 BP 容易陷于局部最小值的缺点,提高了预测精度。花授粉算法具有参数少、易实现以及寻优效果好的优点^[19-22],通过与粒子群算法对比实验,花授粉算法比粒子群算法优先找到最大值点,证明其寻优速度更快,寻优效果更好。

最后通过对美国南部某地区实际电力负荷数据的预测分析和比较,证明该方法的有效性和优越性。

1 基于弹性网的数据简约和变量选择

在所有线性无偏估计类中,最小二乘估计(LS)因为其方差最小得到了广泛应用。但如果预测变量之间存在线性关系,会导致 LS 估计不稳定且精度较差。学者提出

许多基于最小二乘估计的改进方法,例如有偏估计,即以很小的偏倚为代价,大幅度降低了总体的期望预测误差,从而提高估计的精度与稳定性。LASSO 回归也是有偏估计的一种,其原理是在最小二乘法的基础上,添加了 p 范数作为正则项^[9-10]。

1.1 LASSO 回归及存在的问题

假设样本容量为 n , 观察变量的个数为 p , 响应变量为 $y_i (i=1, 2, \dots, n)$, 预测变量为 $x_{ij} (j=1, 2, \dots, p)$ 。假设响应变量已经中心化, 预测变量也已经标准化。即:

$$\sum_{i=1}^n y_i = 0, \sum_{i=1}^n x_{ij} = 0, \sum_{i=1}^n x_{ij}^2 = 1 \quad (1)$$

LASSO 回归系数的表达式为:

$$\hat{\beta}_{\text{Lasso}} = \operatorname{argmin} \left\{ \|Y - X\beta\|^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (2)$$

式中:惩罚项为 $\lambda \sum_{j=1}^p |\beta_j|$ 。

LASSO 回归虽然大大降低了预测方差,完成了系数收缩和变量选择,但是也有一定的局限性:

1) 在 LASSO 回归中,对于 $n \times p$ 的预测变量,最多只能选出 $\min(n, p)$ 个变量。当 $p > n$ 的时候,最多只能选出 n 个预测变量,不能够很好地选出真实的模型。

2) 如果预测变量具有群组效应,则只能选出具有群组效应的预测变量中的一个,而不能全部选出。

3) 如果预测变量中存在很强的共线性,LASSO 的预测表现受控于岭回归。

1.2 弹性网回归

基于以上几点 LASSO 回归的局限性,2005 年 Zou 等^[11]在 LASSO 回归的基础上又添加了 L_2 范数作为正则项,提出了一种新的变量选择方法—弹性网。

假设响应变量已经中心化,预测变量也已经标准化。弹性网回归系数表达式为:

$$\hat{\beta}_{\text{EN}} = \operatorname{argmin} \left\{ \|Y - X\beta\|^2 + \lambda_1 \sum_{j=1}^p |\beta_j| + \lambda_2 \sum_{j=1}^p \beta_j^2 \right\} \quad (3)$$

令 $\alpha = \frac{\lambda_1}{\lambda_1 + \lambda_2}$, $\lambda = \lambda_1 + \lambda_2$, 简化后的表达式为:

$$\hat{\beta}_{\text{EN}} = \operatorname{argmin} \left\{ \|Y - X\beta\|^2 + \lambda \left[\alpha \sum_{j=1}^p |\beta_j| + (1 - \alpha) \sum_{j=1}^p \beta_j^2 \right] \right\} \quad (4)$$

弹性网的惩罚项为 $\alpha \sum_{j=1}^p |\beta_j| + (1 - \alpha) \sum_{j=1}^p \beta_j^2$, 是 LASSO 罚函数和岭回归罚函数的一个凸组合,当 $\alpha = 0$ 时弹性网为岭回归,当 $\alpha = 1$ 时为 LASSO。

定义相对约束 s 为:

$$s = \frac{\sum_j |\hat{\beta}_j|}{\sum_j |\hat{\beta}_j^0|} \quad (5)$$

式中: $\hat{\beta}_j$ 是回归参数的模型估计值, $\hat{\beta}_j^0$ 是回归参数的最小二乘估计值。当 $s = 0$ 时,所有预测变量都没有进入模型;当 $0 < s < 1 + \lambda_2$ (λ_2 为 L_2 范数的系数) 时,预测变量逐步进入模型,这时候根据最小信息准则 (akaike information criterion, AIC) 得出最优 s 值,即 AIC 值最小时就是最佳 s 值。此时最优 s 值处的回归系数为 0 的预测变量被剔除模型,从而实现变量选择的目的;当 $s = 1 + \lambda_2$ 时, LASSO 估计就是最小二乘估计,所有预测变量均被选择进入模型,此时没有实现变量筛选。

AIC 值的计算公式如下:

$$AIC = 2K - 2\ln(L) \tag{6}$$

式中: K 是参数的数量; L 是似然函数。

弹性网回归兼有岭回归和 LASSO 回归的优点,既具有较好的特征选择能力,也具有较好的群组效应,对强共线性的特征也具有更好的特征选择能力,可以有效地处理高维数据。

1.3 弹性网回归步骤

- 1) 对响应变量中心化,预测变量标准化。
- 2) 设置 L_2 范数的系数 λ_2 。
- 3) 使用最小角回归算法得出整个回归过程,并根据 AIC 准则得出最优 s 值。
- 4) 根据最优 s 值得出预测变量的回归系数,将回归系数为 0 的预测变量剔除模型,实现数据降维。

1.4 实验对比

为说明弹性网的实现过程及其变量选择特性,以工资分配总额 X 预测为例,采用 LASSO 和弹性网对 X 有影响的经济指标进行降维。本文数据采用 2018 年河北省数学建模数据,共有 16 个指标:地域人口 X_1 、城乡居民人均收入 X_2 、城乡人均消费支出 X_3 、城镇居民数 X_4 、城镇居民收入 X_5 、城镇居民人均可支配收入 X_6 、GDP X_7 、其他国有企业在岗职工平均工资 X_8 、商品房平均销售价格 X_9 、业务总收入 X_{10} 、业务总成本 X_{11} 、生产用固定资产 X_{12} 、净资产收益率 X_{13} 、人事成本费用率 X_{14} 、劳动生产率 X_{15} 、成本费用率 X_{16} 。

LASSO 变量选择如图 1 所示。由图 1 可知,根据 LASSO 回归的参数估计结果,回归过程一共有 21 步,在第 20 步时 AIC 达到最小值,此时 $s = 0.9566$,最终选取了 15 个变量,剔除了业务总收入 X_{10} 1 个变量。由于 16 个经济指标具有很强的共线性,尤其是后面 4 个预测变量如净资产收益率 X_{13} ,都是由前几个变量计算得出,导致 LASSO 降维效果不好。

弹性网变量选择如图 2 所示。由图 2 可知,当 λ_2 (L_2 范数系数) 为 0.035 时,弹性网共需要 19 步回归过程,在第 7 步时 AIC 达到最小值,此时 s 为 0.6713 (如图 2 中

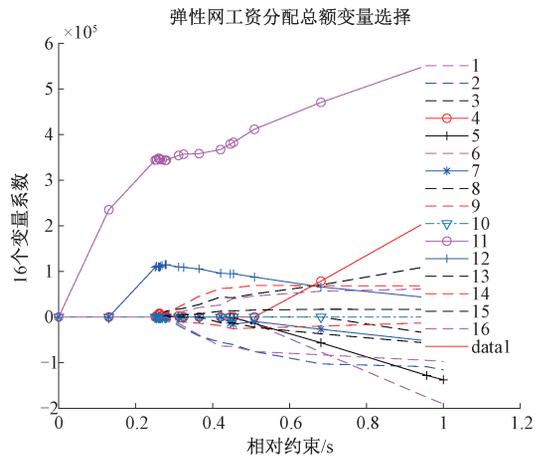


图 1 LASSO 算法变量选择

Fig.1 Variable selection of LASSO algorithm

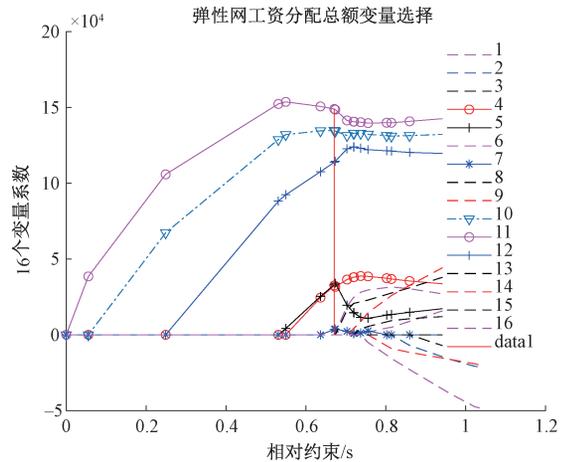


图 2 弹性网算法变量选择

Fig.2 Variable selection of elastic net algorithm

红线 data1 所示),此时 16 个经济指标的回归系数为 $[0, 0, 0, 32\ 534, 33\ 013, 0, 3\ 620, 0, 0, 134\ 684, 148\ 932, 113\ 800, 0, 0, 0, 0]$,即保留了 $X_4, X_5, X_7, X_{10}, X_{11}$ 和 X_{12} (图 2 中带标记的实线)即城镇居民数、城镇居民收入、GDP、业务总收入、业务总成本、生产用固定资产这 6 个影响因素,而其余 10 个因素(图 2 中虚线部分)的回归系数变为 0,不再保留。证明了弹性网回归在预测变量具有较强共线性的情况下,仍然具有较好的变量选择功能。

AIC 变化趋势如图 3 所示。由图 3 可知,当 $\lambda_2 = 0.035$ 时,AIC 值随着相对约束 s 的变化曲线。可以看出,当在 $s < 0.5312$ 时,AIC 值下降较快;当 $s = 0.6713$ 时,AIC 值达到最小值;当 $s > 0.6713$ 时,AIC 值缓慢上升。综上所述,最佳 s 值即是 0.6713。

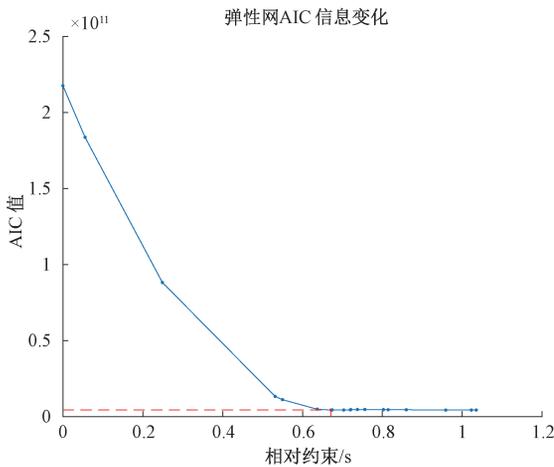


图3 AIC变化趋势

Fig.3 Trend chart of AIC change

2 FPABP 神经网络

在实际应用中, BP 神经网络的初始连接权值、阈值是随机给出的,若初始连接权值、阈值选取不当,则容易导致 BP 神经网络收敛速度慢和易陷入局部极值^[15-18]。为了克服传统缺陷,本文引入了 FPA 来优化 BP 神经网络的权值和阈值。

2.1 FPA

FPA 是剑桥大学学者 Yang^[19]于 2012 年提出的一种新型智能算法,具有参数少、易实现及寻优效果好等优点^[20-22]。FPA 算法的具体步骤如下。

1) 随机产生包含 N 个个体的种群 $p(t) = \{X_i^t\}$

$$X_i^t = [x_{i,1}^t, \dots, x_{i,j}^t, \dots, x_{i,D}^t] \quad (j = 1, 2, \dots, D; i = 1, 2, \dots, N)$$

式中: N 是种群的大小; D 是优化问题的维数; t 是当前迭代次数。并且设置转换概率 p_c 、最大迭代次数 Maxgen 以及种群规模。

2) 对当前种群中的个体进行适应度计算并找出适应度最优化个体,将其保存为当前全局最优解 g^* 。适应度函数为

$$fitness = \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

式中: \hat{y}_i 为第 i 个样本实际输出; y_i 为第 i 个样本期望输出; $i = 1, 2, \dots, n, n$ 为样本数量。

3) 对种群中所有 N 个花进行授粉;随机生成一个随机数 $rand$,若 $rand < p_c$,则进行交叉授粉;否则进行局部授粉。

交叉授粉是传粉者通过 levy 飞行进行的全局授粉过程,其过程如下:

$$X_i^{t+1} = X_i^t + \gamma L(X_i^t - g^*) \quad (8)$$

式中: X_i^t 表示第 t 次迭代时花粉 i 的位置; g^* 表示的是当前群体的最优解; γ 为控制步长的缩放因子;参数 L 为步长,服从 Levy 分布。

自花授粉即局部授粉过程,其过程如下:

$$X_i^{t+1} = X_i^t + \varepsilon (X_j^t - X_i^t) \quad (9)$$

式中:变异因子 ε 是 $[0, 1]$ 上服从均匀分布的随机数, X_j^t 和 X_i^t 表示的是同一类植物的不同花朵的花粉。

4) 利用式(7)中的适应度函数评价新解,若新解优于当前解,则新解进入下一代种群;否则当前解进入下一代种群,并且找到并保存当前最优解 g^* 。

5) 判断是否满足终止条件或最大迭代次数 Maxgen,若满足,则算法结束,输出全局最优解 g^* ;否则转入步骤 3)。

2.2 花授粉寻优效果

先构建一个函数为:

$$f(x, y) = \frac{\sin(\sqrt{x^2 + y^2})}{\sqrt{x^2 + y^2}} + \exp\left(\frac{\cos(2\pi x) + \sin(2\pi y)}{2}\right) - 2.71289 \quad (10)$$

该函数具有多个最大值点,直接寻找十分困难,所以我们通过粒子群算法(PSO)和 FPA 来寻找该函数的最大值,根据寻优次数来评估算法的寻优效果。

首先使用 PSO 对该函数进行最大值寻优,参数设置如下, $c_1 = c_2 = 1.49$,种群规模设置为 20,迭代次数为 300 次。第 1 代找到最大值为 0.921 2,在 11~38 代找到最大值一直处于 1.005 1,39~105 代找到最大值一直处于 1.005 3,直到第 106 代才找到最大值 1.005 4,图 4 所示为其中一个最大值点的 x 值和 y 值。PSO 的寻优过程和寻优效果如图 4 和 5 所示。

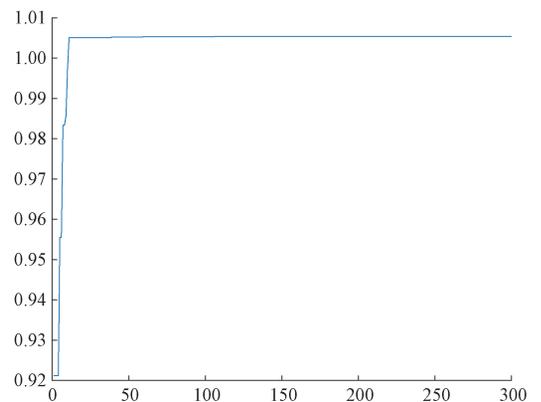


图4 PSO 寻优过程(最优函数值:1.005 4)

Fig.4 Optimizing process of PSO(optimal function value:1.005 4)

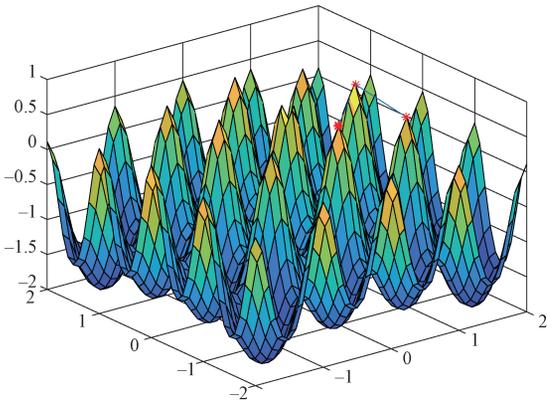


图 5 PSO 寻优效果(最优解:1.164 9e-05,-0.994 37)
Fig.5 Optimizing effect chart of PSO (optimal solution: 1.164 9e-05,-0.994 37)

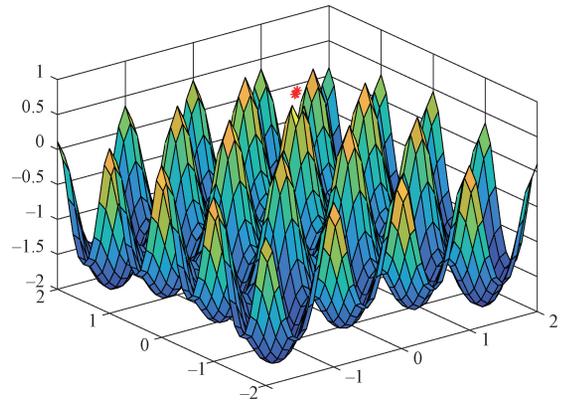


图 7 FPA 寻优效果(最优解:-1.210 8e-09,-1.912 6e-09)
Fig.7 Optimizing effect chart of FPA (Optimal solution: -1.210 8e-09,-1.912 6e-09)

然后使用 FPA 对该函数进行最大值寻优,本次使用的 FPA 转换概率 $p_c = 0.5$,种群规模设置为 20,迭代次数为 300 次。第 1 代找到最大值为 0.975 8,并且在第 14 代就找到了最大值点,图 6 所示为其中一个最大值点的 x 值和 y 值。FPA 的寻优过程和寻优效果图如图 6 和 7 所示。

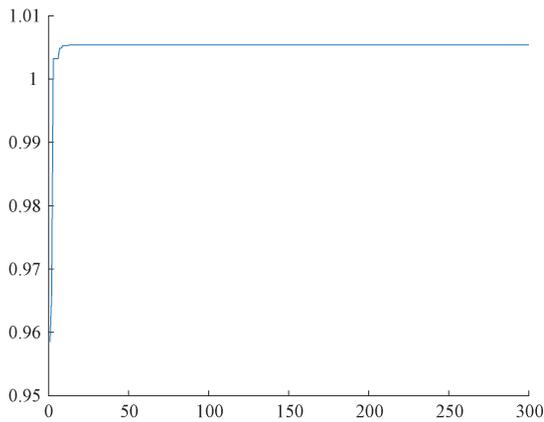


图 6 FPA 寻优过程(最优函数值:1.005 4)
Fig.6 Optimizing process of FPA (Optional function value:1.005 4)

PSO 和 FPA 的参数设置一致,但在最大值寻优过程中,FPA 在第 106 代才找到最大值点,而 PSO 仅需 14 代便找到了最大值点。综上所述,FPA 比 PSO 优先找到最大值点,所以 FPA 优速度更快,寻优效果更好。

3 实验及分析

本文数据采用美国南部某地区的 2016 年 1 月 1 日~1 月 8 日负荷及 7 个天气因素(SO_2 浓度 X_1 、降水量 X_2 、

温度 X_3 、风速 X_4 、湿度 X_5 、云量 X_6 、气压 X_7),每 1 h 取一个点,每天 24 个点。采用预测日前 6 d 的历史负荷以及预测日当天的 7 种气象为预测变量,预测日负荷为响应变量。

3.1 FPABP 预测步骤

- 1) 选取训练样本和预测样本,并确定隐藏层节点数。
- 2) 对权值和阈值进行编码,其中编码长度 S 按下式进行计算:

$$S = RS_1 + S_1S_2 + S_1 + S_2 \quad (11)$$

式中: R 为输入层节点数; S_1 为隐层节点数; S_2 为输出层节点数。

- 3) 使用 FPA 算法获得 BP 神经网络初始权值和阈值,即全局最优解 g^* 。

- 4) 输出最优解 g^* ,并将其作为 BP 神经网络的初始权值和阈值,训练 BP 神经网络进行预测。

3.2 电力负荷预测实例分析

- 1) BP 神经网络和 FPABP 神经网络预测效果对比
本文 BP 神经网络隐藏层节点数都为 8,首先将不经过处理的全部数据作为预测变量,分别输入 BP 神经网络和 PSOBP 神经网络以及 FPABP 神经网络得出预测变量和预测误差(转换概率 $p_c = 0.5$)。其预测结果和预测误差分别如图 8 和 9 所示。

由图 8 和图 9 可以看出,经过花授粉算法优化的 BP 神经网络更加接近实际负荷,误差更小,并且单点最大误差为 4.7%,比 BP 的单点最大误差 8.6% 以及 PSOBP 的单点最大误差 6.1% 有所降低,而且就绝对平均误差而言,BP 为 3.56% 以及 PSOBP 为 2.50%,而 FPABP 降到了 2.04%。

- 2) 引入 LASSO 和弹性网的预测效果对比
采用预测日前 6 d 的历史负荷以及预测日当天的 7 种气象为预测变量,预测日负荷为响应变量。

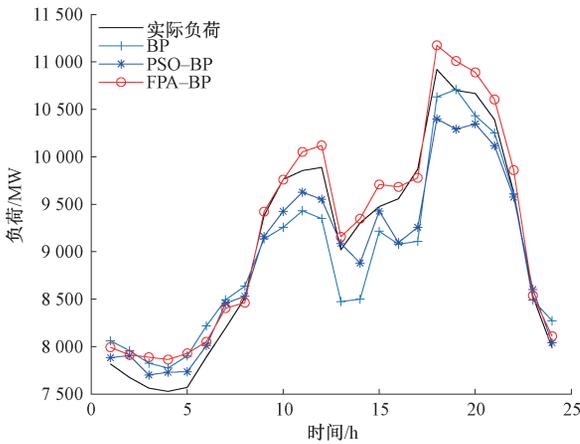


图8 BP和FPABP神经网络预测

Fig.8 Prediction chart of BP and FPABP

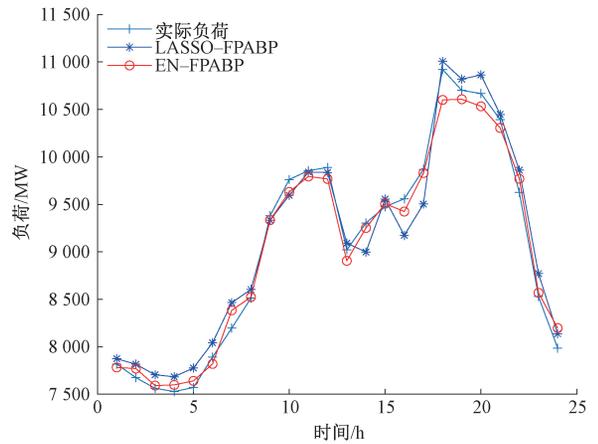


图10 LASSO-FPABP和EN-FPABP预测

Fig.10 Prediction chart of LASSO-FPABP and EN-FPABP

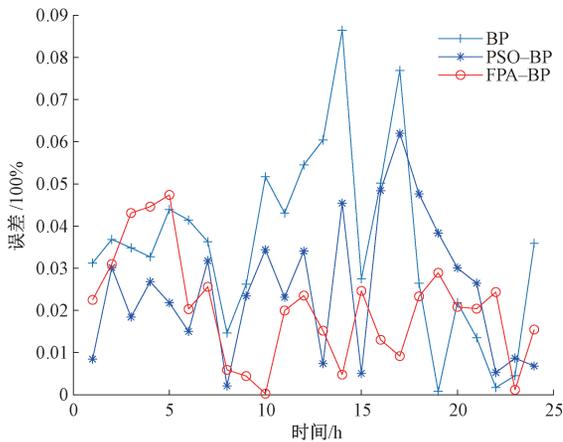


图9 BP和FPABP神经网络误差

Fig.9 Error chart of BP and FPABP

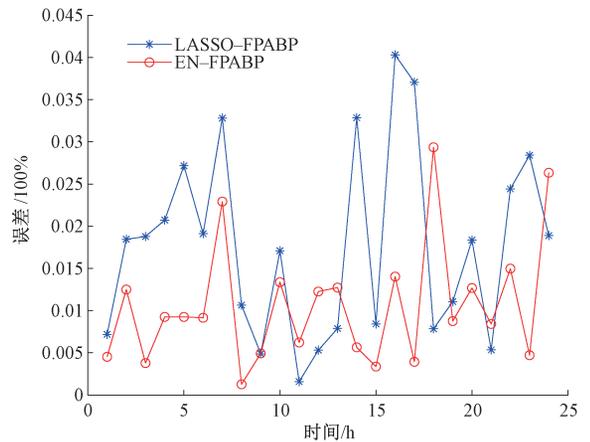


图11 LASSO-FPABP和EN-FPABP误差

Fig.11 Error chart of LASSO-FPABP and EN-FPABP

(1) 经过 LASSO 降维得到 5 d 的历史负荷(如预测 8 日选取 2、3、5、6 以及 7 日的历史负荷)和 5 种气象因素包括 SO_2 浓度 X_1 、降水量 X_2 、温度 X_3 、风速 X_5 以及气压 X_7 为预测变量;

(2) 经过弹性网降维得到 6 d 的历史负荷和以及 4 种气象包括降水量 X_2 、温度 X_3 、风速 X_4 、湿度 X_5 。

(3) 将上述两种降维方法得到的变量分别作为预测变量输入 FPABP 神经网络得出 LASSO-FPABP 预测结果和 EN-FPABP 预测结果,如图 10 所示。

(4) 两种数据筛选方法 FPABP 神经网络预测误差如图 11 所示。预测结果误差对比如表 1 所示。

由图 10、11 和表 1 看出,经过数据降维处理后的模型与不进行数据降维处理的模型相比精度有了明显提高。此时 LASSO-FPABP 神经网络的相对平均误差为 1.77%,而 EN-FPABP 神经网络降到了 1.06%,说明 LASSO 和弹性网都可以剔除大数据中坏数据,完成数据

误差指标	BP	PSOBP	FPABP	LASSO-FPA	EN-FPA
平均相对误差	3.56	2.50	2.04	1.77	1.06
相对误差 $\leq 1\%$ 的比例	12.5	29.2	25	33.3	58.3
相对误差 $\leq 3\%$ 的比例	37.5	58.3	83.3	83.3	100
相对误差 $\leq 5\%$ 的比例	75	95.8	100	100	100

降维,并且弹性网在预测变量具有共线性和群组效应时效果更好。本文使用的方法预测精度有了明显提升。

4 结 论

与 LASSO 回归相比,弹性网回归解决了数据内部存在的共线性以及群组效应的问题,可以从大量数据提取中重要的预测变量并且剔除坏数据,从而完成了高维数

据特征提取。FPA 具有参数少、寻优效果好等优点,改善了BP神经网络容易陷入局部最小值的问题,提高了网络的收敛速度。经过美国南部某地区实例分析,本文方法提高了短期电力负荷预测的预测速度和精度,为电力负荷预测提供了一种有效的新途径。

参考文献

- [1] 杨博宇,陈仕军. 电力负荷预测研究综述及预测分析[J]. 四川电力技术, 2018, 41(3): 56-60, 91.
YANG B Y, CHEN SH J. Overview of electrical load forecasting researches and forecasting analysis [J]. Sichuan Electric Power Technology, 2018, 41 (3): 56-60, 91.
- [2] ZHOU X H, GUO T J, JIAO J. Application of trend extrapolation method to spectrum analysis of microtremor signal [J]. Lecture Notes in Electrical Engineering, 2012, 128: 653-658.
- [3] 钟清,孙闻,余南华,等. 主动配电网规划中的负荷预测与发电预测 [J]. 中国电机工程学报, 2014, 34(19): 3050-3056.
ZHONG Q, SUN W, YU N H, et al. Load and power forecasting in active distribution network planning [J]. Proceedings of the CSEE, 2014, 34(19): 3050-3056.
- [4] 张淑清,任爽,师荣艳,等. 基于多变量气象因子的LMBP 电力日负荷预测 [J]. 仪器仪表学报, 2015, 36(7): 1646-1652.
ZHANG SH Q, REN SH, SH R Y, et al. Daily load forecasting of LMBP power based on multivariable meteorological factor [J]. Chinese Journal of Scientific instrument, 2015, 36(7): 1646-1652.
- [5] HOR C L, WATSON S J, MAJITHIA S. Analyzing the impact of weather variables on monthly electricity demand [J]. IEEE Transactions on Power Systems, 2005, 20(4): 2078-2085.
- [6] 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 D W, SUN ZH W. Big data analysis and parallel load forecasting of electric power user side [J]. Proceedings of the CSEE, 2015, 35(3): 527-537.
- [7] 宋亚奇,周国亮,朱永利. 智能电网大数据处理技术现状与挑战 [J]. 电网技术, 2013, 37(4): 927-935.
SONG Y Q, ZHOU G L, ZHU Y L. Present status and challenges of big data processing in smart grid [J]. Power System Technology, 2013, 37(4): 927-935.
- [8] 张淑清,任爽,陈荣飞,等. 基于大数据简约及PCA改进RBF网络的短期电力负荷预测 [J]. 计量学报, 2018, 39(3): 392-396.
ZHANG SH Q, REN SH, CHEN R F, et al. Short-term power load forecasting based on large data reduction and PCA improved RBF network [J]. Acta Metrologica Sinica, 2018, 39(3): 392-396.
- [9] CAVALCANTE L, BESSA R J, REIS M, et al. LASSO vector autoregression structures for very short-term wind power forecasting [J]. Wind Energy, 2017, 20 (4): 657-675.
- [10] 王金甲,陈春,洪文学. 基于序lasso的时间序列分析方法 [J]. 燕山大学学报, 2015, 39(1): 31-34, 41.
WANG J J, CHEN CH, HONG W X. Time series analysis method based on ordered lasso [J]. Journal of Yanshan University, 2015, 39(1): 31-34, 41.
- [11] ZOU H, HASTIE T. Regularization and variable selection via the elastic net [J]. Journal of the Royal Statistical Society: Series B, 2005, 67(2): 301-320.
- [12] 梁丽军,刘子先,王化强. 基于弹性网-SVM的疾病诊断关键特征识别 [J]. 计算机应用研究, 2015, 32(5): 1301-1304, 1308.
LIANG L J, LIU Z X, WANG H Q. Identification of critical features for disease diagnosis based on elastic net and SVM [J]. Application Research of Computers, 2015, 32(5): 1302-1304, 1308.
- [13] CAO M, CHEN G D, WANG L N, et al. Computational prediction and analysis for tyrosine post-translational modifications via elastic net [J]. Journal of Chemical Information and Modeling, 2018, 58(6): 1272-1281.
- [14] ZOU H, ZHANG H H. On the adaptive elastic-net with a diverging number of parameters [J]. Annals of statistics, 2009, 37(4): 1733-1751.
- [15] AMJADY N, KEYNIA F. A new neural network approach to short term load forecasting of electrical power systems [J]. Energies, 2011, 4(3): 488-503.
- [16] 李雪芝,周建平,许燕,等. 基于L-M算法的BP神经网络预测短电弧加工表面质量模型 [J]. 燕山大学学报, 2016, 40(4): 296-300, 318.
LI X ZH, ZHOU J P, XU Y, et al. Analysis of surface quality model of short arc machining based on BP network with L-M algorithm [J]. Journal of Yanshan University, 2016, 40(4): 296-300, 318.
- [17] 王葛,李珊,张瑞忠,等. 基于粒子群优化的神经网络漏钢预报模型研究 [J]. 燕山大学学报, 2014, 38(3): 221-225, 251.
WANG G, LI SH, ZHANG R ZH, et al. Breakout prediction model based on particle swarm optimized neural network in continuous casting [J]. Journal of Yanshan University, 2014, 38(3): 221-225, 251.

- [18] 王志芳,王书涛,王贵川. 粒子群优化 BP 神经网络在甲烷检测中的应用[J]. 光子学报, 2019, 48(4): 147-154.
WANG ZH F, WANG SH T, WANG G CH. Application of particle swarm optimization BP neural network in methane detection [J]. Acta Photonica Sinica, 2019, 48(4): 147-154.
- [19] YANG X SH. Flower pollination algorithm for global optimization [C]. International Conference on Unconventional Computing and Natural Computation, 2012: 240-249.
- [20] 卞京红,贺兴时,范钦伟,等. 基于自适应花授粉算法的 BP 神经网络结构优化[J]. 计算机工程与应用, 2018, 54(3): 50-56, 130.
BIAN J H, HE X SH, FAN Q W, et al. New BP neural network based on adaptive flower pollination algorithm[J]. Computer Engineering and Applications, 2018, 54(3): 50-56, 130.
- [21] 肖辉辉,万常选,段艳明,等. 基于模拟退火的花朵授粉优化算法[J]. 计算机应用, 2015, 35(4): 1062-1066, 1070.
XIAO H H, WAN CH X, DUAN Y M, et al. Flower pollination algorithm based on simulated annealing[J]. Journal of Computer Applications, 2015, 35(4): 1062-1066, 1070.
- [22] BIAN J H, HE X SH, FAN Q W, et al. New BP neural network based on adaptive flower pollination algorithm[J]. Computer Engineering&Applications, 2018, 10(3): 919-929.

作者简介



Zhang Shuqing received doctor degree from Yanshan University in 2003. Now she is a professor in Yanshan University. Her research areas include large data dimension reduction and intelligent information processing, power load forecasting and fault diagnosis, etc.



Yang Zhenning received B. Sc. degree from Shijiazhuang University in 2018. He is currently a master student at Yanshan University. His research interests include large data dimension reduction and power load forecasting.



Zhang Ligu (Corresponding author) received his Ph. D. degree from Yanshan University in 2009. He is currently an associate professor at Yanshan University. His research interests include intelligent information processing, fault diagnosis, etc.

张淑清, 2003 年于燕山大学获得博士学位, 现为燕山大学教授, 博士生导师, 主要研究方向为大数据降维与智能信息处理、电力负荷预测、故障诊断等。

E-mail: zhshq-yd@163.com

杨振宁, 2018 年于石家庄学院获得学士学位, 现为燕山大学硕士研究生, 主要研究方向为大数据降维、负荷预测。

E-mail: 1015357236@qq.com

张立国 (通信作者), 2009 年于燕山大学获得博士学位, 现为燕山大学副教授, 主要研究方向为智能信息处理、故障诊断等。

E-mail: zlgtime@163.com