DOI: 10.19650/j.cnki.cjsi.J2005998

# 基于改进深度稀疏自编码器及 FOA-ELM 的 电力负荷预测<sup>\*</sup>

张淑清<sup>1</sup>,要俊波<sup>1</sup>,张立国<sup>1</sup>,姜安琦<sup>1</sup>,穆 勇<sup>2</sup>
(1. 燕山大学河北省测试计量技术及仪器重点实验室 秦皇岛 066004;
2.国网冀北电力有限公司唐山供电公司 唐山 063000)

摘 要:智能电网的发展使得电网获取的数据逐渐增多,为了从多维大数据中获取有用信息并对短期内电力负荷进行准确的预测,提出了一种基于改进的深度稀疏自编码器(IDSAE)降维及果蝇优化算法(FOA)优化极限学习机(ELM)的短期电力负荷预测方法。将 L1 正则化加入到深度稀疏自编码器(DSAE)中能够诱导出更好的稀疏性,用 IDSAE 对影响电力负荷预测精度的高维数据进行特征降维,消除了指标间的多重共线性,实现高维数据向低维空间的压缩编码。采用 FOA 优化算法优化 ELM 的权值和阈值,得到最优值,能够克服因极限学习机随机选择权值和阈值导致预测精度低的缺点。首先将气象因素通过 IDSAE 降维,得到稀疏后的综合气象因素特征指标,协同电力负荷数据作为 FOA 优化的 ELM 预测模型的输入向量进行电力负荷预测。通过与 DSAE-FOAELM、DSAE-ELM 和 IDSAE-ELM 等模型的对比实验,证明了提出的预测模型能有效提高预测精度,经计算得出预测精度提升大约 8%。

关键词:短期电力负荷预测;深度稀疏自编码器(DSAE);降维;果蝇优化算法;极限学习机中图分类号:TH17 文献标识码:A 国家标准学科分类代码:520.2099

## Power load forecasting based on improved deep sparse auto-encoder and FOA-ELM

Zhang Shuqing<sup>1</sup>, Yao Junbo<sup>1</sup>, Zhang Liguo<sup>1</sup>, Jiang Anqi<sup>1</sup>, Mu Yong<sup>2</sup>

(1.Key Laboratory of Measurement Technology and Instrumentation of Hebei Province, Yanshan University, Qinhuangdao 066004, China; 2.Tangshan Power Supply Company, State Grid Jibei Electric Power Co. Ltd., Tangshan 063000, China)

Abstract: The development of smart grid makes the data obtained from the grid gradually increasing. In order to obtain useful information from multi-dimensional big data and accurately predict the short-term power load, this paper proposes a short-term power load forecasting method based on dimension reduction with improved deep sparse auto-encoder (IDSAE) and extreme learning machine (ELM) optimized with fruit fly optimization algorithm (FOA). Adding L1 regularization to the deep sparse auto-encoder (DSAE) can induce better sparsity, and the improved deep sparse auto-encoder is used to reduce the dimensionality of high-dimensional data that affects the accuracy of power load prediction, which eliminates the multi-collinearity among the indexes and realizes compression coding from high-dimensional data to low-dimensional space. The fruit fly optimization algorithm (FOA) is used to optimize the weights and thresholds of the extreme learning machine (ELM), and the optimal weights and thresholds are obtained, which can overcome the shortcomings of low prediction accuracy caused by the extreme learning machine randomly selecting the weights and thresholds. In this paper, the meteorological factors are first dimension reduced by the IDSAE to obtain the sparse comprehensive meteorological factor characteristic indexes, and the coordinated power load data are used as the input vector of the FOA optimized ELM prediction model to perform power load prediction. The comparison experiments with DSAE-FOAELM, DSAE-ELM, IDSAE-ELM and other models prove that the proposed

收稿日期:2020-01-07 Received Date:2020-01-07

\*基金项目:国家重点研发计划(2018YFB0905500)、河北省自然科学基金(F2020203058,F2015203413)、河北省科技计划中央引导地方科技发展专项资金(199477141G)、河北省重点研发计划(18211833D)、国网冀北电力有限公司唐山供电公司技术开发项目(SGJBTS00FZJS1902093) 资助 prediction model can effectively improve the prediction accuracy, and the improved accuracy is about 8% after calculation. **Keywords**:short-term power load forecasting; deep sparse auto-encoder (DSAE); dimension reduction; fruit fly optimization algorithm (FOA); extreme learning machine (ELM)

## 0 引 言

电力负荷预测尤其是短期电力负荷预测在电网的 规划和运行中发挥着很重要的作用。随着智能电网的 发展和建设以及电力系统日趋复杂化给精确的电力负 荷预测带来了巨大的挑战<sup>[1-2]</sup>。随着智能电网及能源 互联网的发展,电力负荷数据及影响负荷的气象因素 逐渐增长,电网大数据特性慢慢显现出来<sup>[3]</sup>。在电力 负荷预测中,气象因素对负荷预测产生重要的影响,过 多的气象因子往往使得网络维数过高,造成维数灾难 问题,增加了数学建模难度,影响负荷预测模型的速率 和预测精度<sup>[4]</sup>。本文基于深度学习的思想,提出改进 的深度稀疏自编码器(improved deep sparse autoencoderencoder, IDSAE)方法进行降维,并提取有效的特征信 息<sup>[5]</sup>。首先构建稀疏自编码器模型,根据稀疏理论可 知 L1 正则化可以诱导出更好的稀疏性,将 L1 正则化 加入到模型中构建基于 L1 正则化的稀疏自编码器模 型<sup>[6]</sup>。用该模型对数据进行处理,获得新气象数据的 稀疏特征。其次将多个稀疏自编码器堆叠成深度稀疏 自编码器(DSAE),并通过逐层学习的方式学习每一层 的特征,得到原始数据的深度特征。

传统电力负荷预测方法有趋势外推法、时间序列法、 线性回归分析法等。在处理大量数据以及数据之间复杂 的非线性关系时难以求得最优解,导致负荷序列预测的 精度往往不是很高。随着人工智能的发展,人工神经网 络方法在负荷预测中的应用越来越广泛。常见的人工神 经网络方法多为 BP 神经网络,该网络对于负荷的不确 定性、非线性具有强大的学习能力和适应能力,但其训练 时间较长且容易陷入局部极小值,以至于限制了预测的 精度。极限学习机(extreme learning machine,ELM)以其 具有学习速率快、泛化性能好等优点广泛的运用在各个 领域,其所存在的问题是随机设置权值和阈值,容易使得 算法陷入局部最优解。本文采用果蝇优化算法(fruit fly optimization algorithm, FOA)去优化 ELM 的权值和阈值, 提高模型对负荷的预测精度<sup>[7-8]</sup>。

首先对影响负荷预测的气象数据用 IDSAE 进行降 维;然后将降维后的原始数据输入到由 FOA 算法优化 ELM 的负荷预测模型中。通过降维对比实验,表明了经 过 IDSAE 降维处理后数据的重叠现象消失、混乱程度有 所降低,为之后的预测实验提供了有效的数据集;通过对 Schaffer 测试函数进行寻优对比粒子群优化算法(particle swarm optimization, PSO)、FOA 算法,实验结果表明,FOA 算法具有强大的全局寻优能力,寻优速度快于 PSO 算 法;采用美国南部地区电力负荷数据进行实验,对比分析 表明本文所提方法提高了电力负荷预测的精度,具有一 定的优越性。在冀北电网唐山供电公司负荷预测实际应 用,得到了日负荷预测曲线和预测结果准确率分析曲线 以及月负荷预测结果准确率曲线,为发电厂制定发电计 划以及检修计划提供重要依据。

## 1 DSAE 及改进方法

#### 1.1 自编码器

自编码器是一种人工神经网络,可以通过无监督学 习算法将数据从高维空间转到低维空间表示,包括编码 器和解码器两部分<sup>[9]</sup>。

自编码器是一种3层前馈神经网络,分别为输入层、 隐藏层、输出层。该神经网络由两部分组成,输入层到隐 藏层的部分为编码器:

 $h = f(W_x + b)$  (1) 式中:x 为输入数据;W 为编码权值矩阵;b 为编码偏置

值;f为激活函数一般为 sigmoid 函数;h 为编码输出。 隐藏层到输出层的部分为解码器:

 $r = g(W'h + b') \tag{2}$ 

式中: W'为解码权值矩阵;b'为解码偏置值;g 为激活函数;r 为解码输出。

通过设置自编码器神经网络隐藏层节点的个数,使 之少于输入层节点个数,可以达到任意维度的降维。

## 1.2 DSAE

为了使模型学习到更多的样本特征以及具有更强的 表达能力,通常使用更多的隐含层节点数,但是在这种情况下训练时容易出现过拟合现象,为了解决这一问题,在 自编码器的隐藏层加入一些稀疏性限制,使得大部分隐 藏层神经元处于抑制状态,这就构成了稀疏自编码 器<sup>[10-11]</sup>。其中稀疏是指数据中0的个数,0的个数越多, 数据就越稀疏。当使用 sigmoid 函数作为激活函数时,如 果当隐藏层神经元输出接近于1时,可以认为它处于激 活状态;当其输出接近于0时,可以认为它的状态为被抑 制状态。

当自编码神经网络输入为 x 时,令  $a_j^{(2)}(x)$  表示其隐藏层神经元 j 的活跃度;m 表示隐藏层神经元的个数,则 其平均活跃度为:

$$\hat{\rho}_{j} = \frac{1}{m} \left[ a_{j}^{(2)} x^{(i)} \right]$$
(3)

然后使用 $\rho$ 表示稀疏性参数,通常 $\rho$ 是一个接近于0的数, $\hat{\rho}_{j} = \rho$ ,来对 $a_{j}^{(2)}$ 的稀疏度进行限制。

为了让 $\hat{\rho}_{j}$ 和 $\rho$ 尽可能地接近,引入惩罚因子来对这两者有显著差异的情况进行惩罚,并使用 KL 散度 (kullback-leibler divergence)来选择惩罚因子。

KL 散度表达式为:

$$\sum_{j=1}^{s_1} KL(\rho \| \hat{\rho}_j) = \sum_{j=1}^{s_2} \rho \log \frac{\rho}{\hat{\rho}_j} + (1-\rho) \log \frac{1-\rho}{1-\hat{\rho}_j}$$
(4)

则优化后的目标函数为:

$$J_{\text{sparse}}(\boldsymbol{W}, \boldsymbol{b}) = J(\boldsymbol{W}, \boldsymbol{b}) + \beta \sum_{j=1}^{3_2} KL(\rho \parallel \hat{\rho}_j)$$
(5)

式中: $\beta$ 为惩罚因子; $KL(\rho \parallel \hat{\rho}_j)$ 为惩罚项;J(W,b)为优 化前的目标函数; 当 $\rho = \hat{\rho}_j$ 时 KL 散度的值为0, 当 $\rho = \hat{\rho}_i$ 成 之间的差异增大时, KL 散度的值相应会单调递增。故 这一惩罚因子会调节这两个值之间的距离,让它们尽可 能相近。

深度自编码器是把多层稀疏自编码器堆叠起来,其 采用逐层贪婪的方法来进行训练,上一层编码器提取到 的特征作为输入传递给下一层编码器,相比自编码器而 言 DSAE 可以学到更复杂的特征。

#### 1.3 DSAE 的改进

传统的深度稀疏自编码器虽然将 KL 散度作为损失 函数的惩罚项取得了不错的效果,但是也有如下局限性。

1)在 DSAE 中,KL 散度对于那些远离激活值的惩罚 效果一般,泛化能力比较差。

2) KL 散度在做惩罚时需要提前给稀疏目标一个期 望值,使待学习超参的数目变多,增加了学习任务。

因此,针对以上局限性,基于 L1 正则化可以诱导出 更好的稀疏性的理论,将 L1 正则化加入到目标函数中。 L1 产生稀疏模型的原理如下:

$$J = J_0 + \lambda \sum_{i} |w_{i,j}| \tag{6}$$

由式(6)可知当在原始损失函数后面加入 L1 正则 化后,相当于对它做了一个约束。此时的任务变为在这 个约束条件下求 J<sub>0</sub> 的最小值。图 1 所示为在考虑二维 情况下对 L1 产生稀疏性的原理解释。

图 1 中等值线为  $J_0$  的等值, 令  $L = \lambda \sum_{i,j} |w_{i,j}|$ ,则在 二维情况下 L 图形为图中菱形。图 1 中等值线与菱形相 交的点即为最优值解, 因为 L 函数有很多这种突出的角 (多维情况下),且在这些角上会有很多权值等于 0,所以 这就是为什么 L1 正则化可以更好地诱导出稀疏性。

加入 L1 正则化后原式变为:

$$J_{\text{sparse}}(\boldsymbol{W}, \boldsymbol{b}) = J(\boldsymbol{W}, \boldsymbol{b}) + \lambda \sum_{i,j} |W_{i,j}|$$
(7)



图 1 L1 稀疏性原理解释 Fig.1 Explanation of L1 sparsity principle

将 L1 正则化加入到损失函数,数据更容易稀疏,学 习任务的难度有所降低,以及有利于实现特征的自动选择,使模型具有可解释性,为预测实验提供了很好的 数据<sup>[12]</sup>。

## 2 DSAE 及 IDSAE 降维实验对比

本文数据选取 2012 年高教社杯全国大学生数学建 模竞赛数据。研究脑卒中发病率与气温、气压、相对湿度 间的关系,一共有 8 个影响因素指标:  $L_1$  平均气压、 $L_2$  最 高气压、 $L_3$  最低气压、 $L_4$  平均气温、 $L_5$  最高气温、 $L_6$  最低气 温、 $L_7$  平均湿度、 $L_8$  最小湿度。为了说明改进后的 DSAE (IDSAE) 对数据降维处理的优越性,本文进行了两组实 验。首先对不同层数的 IDSAE 降维效果进行对比,确定 出 IDSAE 的最佳层数,然后分别使用 IDSAE 和 DSAE 以 及主成分分析(principal component analysis, PCA)进行 降维处理,将降维后的数据进行可视化分析。

#### 2.1 不同层数的 IDSAE 降维效果对比

深层网络可以通过逐层学习的方式学习到原始数据 的多种特征表达,一般情况下层数越多提取到的特征越 抽象,越能表达出原始数据的绝大多数信息,但是模型层 数并不是越多越好,当模型层数增加时数学建模难度增 加,训练时间变长,影响降维效果。

为了确定 DSAE 的最佳层数,本文采用 IDSAE 模型, IDSAE 模型理论上可以降维到任意维数,只要比原先的 维数小即可。为了能将数据可视化,从而对数据的分布 有直观的了解,选择降维到三维,然后设计了 6 种 IDSAE,分别对以上数学建模数据进行降维,降维后的结 果如图 2 所示。

由图2可知,不同层数的 IDSAE 降维效果不同,不同 颜色的样本点代表不同的类别。当 n=1、2、5、6时,降维 后数据的不同类别样本点聚合在一起,效果较差;当 n=3 时降维后的数据虽然效果有一定改善,但仍有一部分数 据重叠在一起;当 n=4 时 IDSAE 降维后数据不同类别的 样本点分散开来,分类效果最好。



## 2.2 IDSAE 降维效果对比

PCA 是一种使用最广泛的数据降维算法,其核心是 计算不同数据特征之间的相关性,根据相关性的强弱提 取主要特征<sup>[13-15]</sup>。

在使用 PCA 降维时,一般当前 n 个主成分的累计贡献率在 85%~95%时,就能包含原始变量的绝大部分信息。本文将累计贡献率设置为 94%时,在对数据进行降维处理后,取 3 个主成分时 PCA 的累计贡献率达到了 94%,则此时 PCA 处理时把数据降为 3 维,当累计贡献率 设置为 92%时,取 2 个主成分就满足了要求,此时 PCA 把数据降到了二维。

对于设置 DSAE 和 IDSAE 的降维维数来说,虽然降 到二维和三维不一定是最佳降维维数,但是为了使其与 PCA 降维的外部条件一致,所以将 DSAE 和 IDSAE 维数 同样降到二维和三维。依据 2.1 节, DSAE 和 IDSAE 选 择了4层降维模型。上述3种方法的可视化降维结果如 图3所示。

图 3 所示分别为 PCA、DSAE、IDSAE 对数据处理后 降维到二维和三维的可视化散点图,图 3 中不同颜色的 样本点代表不同的类别。由图 3 可知,降到二维和三维 时经 PCA 方法处理后数据的不同颜色样本点聚合在一 起,没有明显分散开来,说明使用 PCA 处理后的数据分 类不明显:使用 DSAE 降维处理后,相对于 PCA 降维来 说,数据不同颜色的样本点有所分散开来;而经过 IDSAE 降维处理后,数据不同类的样本点很好地分散开,说明 IDSAE 算法成功的从数据集中提取了有用的信息,揭示 了数据的隐含特性<sup>[16]</sup>。

## **3** FOA 优化 ELM 神经网络

与传统方法相比,ELM 是一种单隐含层前馈神经网



Fig.3 Effect diagram of dimension reduction

络,具有训练速度快、调节参数少的优点。但在训练过程 中 ELM 随机产生的输入层权值和隐含层阈值容易导致 网络不稳定。为了克服此缺陷,采用 FOA 算法优化 ELM 的权值和阈值,得到最优解,建立 FOA-ELM 模型,提高预 测精度<sup>[17-18]</sup>。

## 3.1 FOA 算法

FOA 算法是一种基于果蝇觅食行为推演出寻求全局 优化的元启发式算法。与其他群智能寻优算法如 PSO 算法、鱼群算法相比,其具有参数设置少、运算速度快、算 法寻优精度高、全局寻优能力强等优点,更容易被运用于 解决实际问题<sup>[19-20]</sup>。

FOA 算法的具体步骤如下:

1) 随机初始化果蝇种群的位置  $X_{axis}$ ,  $Y_{axis}$ 。

2) 赋予果蝇利用嗅觉搜索时的飞行方向和距离:

$$X_i = X_{\text{axis}} + L_0 \times rand() \tag{8}$$

 $Y_i = Y_{\text{axis}} + L_0 \times rand() \tag{9}$ 

式中:L<sub>0</sub>为初始步长。

3)食物的位置是未知的,因此先估算与原点的距离 *Dist<sub>i</sub>*,再求出味道浓度值 *Si*:

$$Dist_i = \sqrt{X_i^2 + Y_i^2} \tag{10}$$

$$Si = 1/Dist_i$$
 (11)

4)将味道浓度值代入味道浓度判定函数(fitness function),求出果蝇位置的味道浓度(smelli),并找出群 体中味道浓度最高的果蝇。

5)保留最佳味道浓度值和最佳位置坐标,此时果蝇 群体飞向该最佳位置

6)进入迭代寻优,重复执行步骤2)~4),并判断当前味道浓度是否优于前一个味道浓度,若是则执行步骤5)。

#### 3.2 寻优对比

为了验证 FOA 算法的优越性。使用 FOA 算法对 Schaffer 测试函数进行寻优,并用 PSO 算法进行对比实 验。Schaffer 函数表达式为:

$$f(x) = 0.5 + \frac{\sin^2(x_1^2 - x_2^2) - 0.5}{\left[1 + 0.001 (x_1^2 + x_2^2)\right]^2}$$
(12)

为了方便研究 FOA 算法和 PSO 算法的寻优效果,将 两种寻优算法的基本参数设置为相同的数。其中种群大 小为 30,最大迭代次数为 100。然后将测试函数分别代入 到两种算法中进行寻优。FOA 寻优过程如图 4 所示。



由图 4 可知,当 FOA 算法迭代到第 3 代时函数值达 到了 0.999,当迭代到第 5 代时函数值达到了 1,也就是 说 FOA 算法只需迭代 5 次就可以求得 Schaffer 函数的最 大值,图 5 所示为果蝇算法三维寻优图取得一个最大值 时 x,y 的值,由图 6 所示寻优过程可知,当 PSO 算法迭代 到第 5 代时函数值达到了 0.996,当迭代到第 10 代时达 到了 0.999,直到迭代到第 23 代时才达到了最大值 1。 图 7 所示为 PSO 算法三维寻优图取得一个最大值时 x,y 的值。综合以上实验可知,相对于 PSO 算法来说 FOA 算 法可以更快速地寻优到最佳值。







Fig.6 Particle swarm algorithm optimization process



## 3.3 FOA 优化 ELM 神经网络

FOA 算法优化 ELM 的过程中,先初始化 FOA 的参数,包括种群数目、最大迭代次数、初始位置等。然后将 ELM 训练得到的均方误差作为 FOA 的适应度,求出 FOA 的最佳味道浓度值和最佳位置。接下来进行迭代寻优, 直到满足条件为止。

将 FOA 优化得到的最佳输入权值和阈值代入到 ELM 模型中进行预测。FOA 算法优化 ELM 模型的流程 如图 8 所示。

## 4 实验及分析

本文数据采用美国南部某地区 2006 年 1 月 1 日~1 月 8 日的负荷数据以及 7 个气象因子(SO<sub>2</sub> 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  $X_7$ )进行 预测,每隔 1 h 采样一次,一共 192 个点。首先设定在数 据集中训练集与测试集的比例,本文实验中一共取 8 d 的负荷数据以及 8 d 的气象数据,训练集与测试集的比



图 8 FOA 优化 ELM 流程 Fig.8 Flow chart of FOA optimizing ELM

例设置为7:1。为了说明本文所提出的模型预测精度 高,在选取训练集和测试集上没有选取同一天的负荷数 据和气象数据,选取负荷数据的日期比气象数据日期超 前一天,所以选取1月1日~1月7日的负荷数据以及1 月2日~1月8日的气象数据作为训练集,1月8日24个 点的负荷数据作为测试集。

## 4.1 FOA-ELM 电力负荷预测模型对比实验

本文实验中将1月1日~1月7日的负荷数据以及1 月2日~1月8日的气象数据作为训练样本,1月8日24 个点的负荷数据作为测试样本。对训练样本不作任何数 据处理直接导入到 ELM 和改进的 ELM 模型中进行电力 负荷预测。图9所示为负荷预测拟合曲线,图 10所示为 相对误差曲线。







图 10 ELM 和改进的 ELM 误差曲线 Fig.10 ELM and the improved ELM error diagram

对 ELM 隐含层节点个数确定时,采用上一段训练样本和测试样本,将数据输入到 ELM 中进行预测,设置隐含层节点数从 1~30,分别进行预测得出平均相对误差,比较每个隐含层节点数对应的相对误差大小,经测试得到节点数为7 时相对误差最小,则 ELM 机隐藏层节点数设置为7。FOA 算法的参数设置为:迭代次数 100、种群规模 30、步长 0.02。

由图 9 可知,经过 FOA 优化后的 ELM 模型拟合度高 于经过 PSO 优化后的 ELM 模型以及未经优化的 ELM 模 型,说明 FOA 优化 ELM 提高了预测模型的准确度。由 图 10 可知,FOA-ELM 预测模型的单点误差最小,相对误差 曲线在 0 值上下浮动,相对于 PSO-ELM 和 ELM 预测模型 来说误差有所降低。分别从平均相对误差和均方根误差 两个角度进行评价,3 种方法误差结果如表 1 所示。

| 表1 3种方法误差结果 |                          |             |   |  |
|-------------|--------------------------|-------------|---|--|
| Table 1     | The error results of the | ree methods | % |  |
| 预测模型        | 平均相对误差                   | 均方根误差       |   |  |
| FOA-ELM     | 2. 585 3                 | 277.251 6   |   |  |
| PSO-ELM     | 3.771 9                  | 446.6546    |   |  |
| ELM         | 4.3214                   | 455.3683    |   |  |

由表1可知,FOA-ELM 预测模型的平均相对误差为 2.5853%,均方根误差为277.2516%,相对于其他模型 来说该模型效果更好。

#### 4.2 降维对比实验及分析

本文采用1月1日~1月7日的负荷数据以及1月2 日~1月8日的气象数据作为训练样本,1月8日24个点 的负荷数据作为测试样本。首先,设置 IDSAE 模型的层 数为4层, IDSAE 模型降维后的维度设置为2。将1月2 日~1月8日共7个指标的气象数据使用 IDSAE 降维方 法处理,得到了2个指标的气象因子,最后将这2个指标 的气象数据与1月1日~1月7日的负荷数据一同作为 建模数据输入到 FOA-ELM 和 ELM 预测模型中进行预测。为了说明 DSAE 改进后降维的优越性,将经过 DSAE 降维方法处理过的数据分别输入到 FOA-ELM、ELM 预测模型当中与 IDSAE 降维方法进行对比,预测结果如图 11、12 所示。









图 12 DSAE 和 IDSAE 降维后的预测误差曲线 Fig.12 Prediction error diagram after DSAE and IDSAE dimensionality reduction

由图 11 可知, IDSAE-FOAELM 预测模型的曲线拟合效果 要 优于 其 他 预 测 模 型, 由 图 12 可 知, IDSAE-FOAELM 的预测误差相对较小,充分验证了 IDSAE 提高了降维效果,通过对比这几种方法的拟合曲线和预测误差说明了本文所提方法预测效果良好。表 2 所示为对误差进行定量分析结果。

表 2 各方法误差结果 Table 2 The error results of various methods %

| 预测模型         | 平均相对误差  | 均方根误差      |
|--------------|---------|------------|
| DSAE-FOAELM  | 1.703 1 | 160. 736 3 |
| DSAE-ELM     | 2.576 2 | 255.760 1  |
| IDSAE-FOAELM | 0.863 9 | 100. 699 7 |
| IDSAE-ELM    | 1.609 2 | 186. 743 8 |

由表 2 所示,本文使用 IDSAE-FOAELM 预测模型的 误差最小,平均相对误差仅为 0.863 9%,对比可知经过 IDSAE 降维后预测模型的预测结果优于 DSAE,说明本文 提出的 IDSAE 降维方法有效降低了数据维数。

## 5 电网系统负荷预测实际应用

本文应用于国网冀北电力有限公司的电力负荷预测。取国网冀北电力有限公司2019年5月6日~5月13日的电力负荷数据以及7个气象指标(日最高温度L1、日最低温度L2、日最大相对湿度L3、日最小相对湿度L4、日最大气压L5、日最小气压L6、节假日L7)。按照7:1的比例划分训练样本和测试样本,将6日~12日的电力负荷数据以及7日~13日的气象负荷数据作为训练样本,第13日的电力负荷数据作为测试样本。使用本文所提方法 IDSAE 对气象数据降维得到2个指标的气象数据,然后与7d的负荷数据一起作为建模数据输入到预测模型中得负荷预测曲线和预测结果准确率分析曲线。预测结果如图13所示。



Fig.13 Daily load forecast result charts

图 13(a) 所示为冀北电网系统日负荷预测拟合,图 13(b) 所示为负荷预测结果准确率。由图 13 可知一天中 0~12 时总体的趋势是曲线先上升后下降,曲线波动较 大,从 13 时开始曲线逐渐上升,直到 21 时达到峰值,之 后曲线呈下降趋势,表现为 21 时后居民用电减少,总的 用电量下降。图 13 中负荷预测曲线在实际负荷曲线上 下波动,拟合情况较好,准确率都在 96% 以上,说明本文 所提方法可以有效实现短期电力负荷预测。

## 6 结 论

本文基于深度学习的思想提出一种 IDSAE 模型,与

传统的模型相比,将 L1 正则化作为模型损失函数的惩罚 项,可以诱导出更好的稀疏性。与改进前相比,改进后的 模型解决了数据结构复杂度高以及数据计算量大的问 题,提高了数据的处理能力,使得预测模型的输入维数大 大降低,从而完成了对高维数据的降维处理;FOA 算法具 有设置参数少、运算速度快、寻优精度高等特点,改善了 ELM 因随机产生输入层权值和隐含层阈值导致网络不 稳定的缺点,提高了模型的预测精度。通过对美国南部 某地区负荷数据实验分析以及对国网冀北电力有限公司 电力负荷的预测,证明了本文方法可提高短期电力负荷 预测的速度和精度。

#### 参考文献

- [1] 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 S X, ZHAO B ZH, W F Y, et al. Short-term power load prediction based on massive data[J]. Chinese Journal of Electrical Engineering, 2015,35(1):37-42.
- [2] ALI M, ADNAN M, TARIQ M. Optimum control strategies for short term load forecasting in smart grids[J]. International Journal of Electrical Power & Energy Systems, 2019, 113: 792-806.
- [3] LEI J, JIN T, HAO J, et al. Short-term load forecasting with clustering - regression model in distributed cluster[J]. Cluster Computing, 2019, 22 (4): 10163-10173.
- [4] 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 with improved RBF network based on big data minimization and PCA [J]. Journal of
- [5] WANG Y, YAO H, ZHAO S. Auto-encoder based dimensionality reduction [J]. Neurocomputing, 2016, 184: 232-242.

metrology, 2018, 39(3): 392-396.

- [6] ZHANG M, DESROSIERS C. High-quality image restoration using low-rank patch regularization and global structure sparsity [J]. IEEE Transactions on Image Processing, 2018, 28(2): 868-879.
- [7] ZHANG CH, ZHOU J ZH, LI CH SH, et al. A compound structure of ELM based on feature selection and parameter optimization using hybrid backtracking search algorithm for wind speed forecasting [J]. Energy Conversion and Management, 2017, 143: 360-376.

- [8] FU W L, WANG K, LI CH SH, et al. Multi-step shortterm wind speed forecasting approach based on multiscale dominant ingredient chaotic analysis, improved hybrid GWO-SCA optimization and ELM [J]. Energy Conversion and Management, 2019, 187: 356-377.
- [9] 尚文利, 闫腾飞, 赵剑明, 等. 工控通信行为的自编 码特征降维和双轮廓模型异常检测方法[J]. 小型微 型计算机系统, 2018,39(7):1405-1409.
  SHANG W L, YAN T F, ZHAO J M, et al. Self-coding feature reduction and dual-contour model anomaly detection method for industrial control communication behavior[J]. Miniature Microcomputer System, 2018, 39(7):1405-1409.
- [10] YANG D H, LYU J G, ZHANG D L, et al. Extracting multi-features and optimizing feature space with sparse auto-encoder over WorldView-2 images[J]. International Journal of Remote Sensing, 2019, 40 (15-16): 6418-6443.
- [11] JIANG Q, SHAO F, LIN W, et al. Learning a reference less stereopair quality engine with deep nonnegativity constrained sparse autoencoder[J]. Pattern Recognition, 2018, 76:242-255.
- [12] WANG S, SELESNICK I, CAI G, et al. Nonconvex sparse regularization and convex optimization for bearing fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2018, 65(9): 7332-7342.
- [13] 聂栋栋,贺悦悦,马勤勇.基于 PCA\_LDA 和协同表示 分类的人脸识别算法[J].燕山大学学报,2019, 43(2):176-181.
  NIE D D, HE Y Y, MA Q Y. Face recognition algorithm based on PCA\_LDA and collaborative representation classification[J] Journal of Yanshan University, 2019, 43(2):176-181.
- [14] 张淑清,宿新爽,陈荣飞,等. 基于变分模态分解 FABP 的短期电力负荷预测[J]. 仪器仪表学报, 2018, 39(4):67-73.
  ZHANG SH Q, SU X SH, CHEN R F, et al. Short-term power load forecasting based on variational mode decomposition and FABP [J]. Chinese Journal of
- [15] 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.

Scientific Instrument, 2018, 39 (4): 67-73.

ZHANG SH Q, REN SH, SHI 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.

- [16] 洪文学,王金甲.可视化和可视化分析学[J].燕山大学 学报,2010,34(2):95-99,105
  HONG W X, WANG J J. Visualization and visualization analysis [J]. Journal of Yanshan University, 2010, 34(2):95-99,105.
- [17] YAO L, GE Z. Deep learning of semisupervised process data with hierarchical extreme learning machine and soft sensor application [J]. IEEE Transactions on Industrial Electronics, 2017, 65(2): 1490-1498.
- [18] LIU H, MI X, LI Y. An experimental investigation of three new hybrid wind speed forecasting models using multi-decomposing strategy and ELM algorithm [J]. Renewable energy, 2018, 123: 694-705.
- [19] 王慧莹,吴亮红,梅盼盼,等.果蝇优化广义神经网络的风电功率短期预测[J].电子测量与仪器学报,2019, 33(6):177-183.

WANG H Y, WU L H, MEI P P, et al. Short-term prediction of wind power in drosophila optimization of generalized neural networks [J]. Journal of electronic measurement and instrumentation, 2019, 33 (6): 177-183.

[20] DARWISH S M, ELMASRY A, IBRAHIM S H. Optimal shortest path in mobile ad-hoc network based on fruit fly optimization algorithm [C]. International Conference on Advanced Machine Learning Technologies and Applications. Springer, Cham, 2019: 91-101.

#### 作者简介



**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

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



**要俊波**,2017年于华北理工大学获得学 士学位,现为燕山大学硕士研究生,主要研 究方向为短期电力负荷预测。

E-mail:321507448@ qq.com

Yao Junbo received B. Sc. degree from North China University of Science and Technology in 2017. Now, he is a M. Sc. candidate at Yanshan University. His main research interests include short-term power load forecasting.



**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、电力系统分 析、故障诊断等。

E-mail:zlgtime@163.com

Zhang Liguo (Corresponding author) received doctor degree from Yanshan University in 2009. Now, he is an associate professor in Yanshan University. His main research interests include intelligent information processing, power system analysis, fault diagnosis, etc.