

基于层次分析的ELM方法及在乙烯装置生产预测中的应用

耿志强, 秦琳, 韩永明

北京化工大学 信息科学与技术学院, 北京 100029; 智能过程系统工程教育部工程研究中心, 北京 100029

E-mail: hanym@mail.buct.edu.cn

摘要: 极限学习机是一种快速有效的单隐层前馈神经网络学习算法, 已广泛应用于多个领域。为提高极限学习机对高维度、多噪声数据的建模能力, 本文提出了一种基于熵权关联层次分析的ELM建模方法, 该方法通过熵权关联层次分析模型过滤数据中的冗余信息, 提取特征分量, 并将融合后的数据作为ELM神经网络的输入进行建模。通过UCI标准数据集验证所提模型的有效性, 同时应用到乙烯生产预测建模分析中, 并与传统的BP神经网络、ELM网络对比。结果表明, 基于熵权关联层次分析的ELM网络在处理复杂的高维数据时具有收敛速度快, 鲁棒性强, 预测精度高等优点, 为神经网络指导复杂工业生产提供了新方法。

关键词: 极限学习机; 熵权层次分析法; 过程建模; 乙烯生产预测

ELM Neural Network Based on AHP and its Application in Prediction of Ethylene Plants' Production

Geng Zhiqiang, Qin Lin, Han Yongming

College of information science and technology, Beijing university of chemical technology, Beijing 100029, China; Engineering

Research Center of Intelligent PSE, Ministry of Education in China, Beijing 100029, China

E-mail: hanym@mail.buct.edu.cn

Abstract: Extreme Learning machine(ELM), a simple single-hidden-layer feed-forward neural network with fast implementation, has been successfully applied in many fields. In order to improve the modelling ability of extreme learning in high-dimensional and multi-noisy data, this paper proposes the ELM predictive modelling method based on Entropy Weight-Analytic Hierarchy Process. This method works by filtering redundant information, extracting characteristic component through Entropy Weight-Analytic Hierarchy Process, and then blended data would be used as the input of ELM to do predictive modelling. Through the effectiveness and stabilization of modelling verified by UCI standard data set and application of it into ethylene production data forecast modeling analysis, and compared with traditional BP neural network and ELM network, ELM network based on Entropy Weight-Analytic Hierarchy Process proved to have more advantages in terms of faster convergence, stronger generalization and higher modeling accuracy which provides a new method for neural network's guidance in complex industrial production.

Key words: extreme learning machine; analytic hierarchy process; process modeling; ethylene production prediction

1 引言

神经网络作为一种黑箱模型, 无需考虑内部机理, 通过调整内部大量节点之间相互连接的关系, 就能达到信息处理的目的, 具有响应速度快, 能充分逼近复杂的非线性函数等特点, 被广泛应用到化工^[1]、能源^[2]等领域。如BP, RBF, ELM等。BP是一种基于梯度下降的误差逆向传播算法^[3], 是目前最常见的神经网络建模算法, 但它收敛速度慢, 且易陷于局部最优, 不适用于复杂工业建模。RBF神经网络相比于BP网络, 其训练速度快, 不存在学习的局部最优问题且具有全局最佳逼近性能^[4], 但它对典型训练样本提取要求高, 训练难度大^[5]。ELM神经网络不需要不断地根据误差函数调整权值, 其隐含层神经元的学习参数是随机产生的, 输出权重由广义逆方法计算、确定。其训练速度快, 泛化精度高, 鲁棒性强且不容易出现局部最优解^[6-7]。

然而, 由于复杂工业数据具有高维度、强耦合、包含大量冗余信息等特点, 导致了ELM网络在其生产预测中建模复杂, 无法准确的预测其生产状况。因此, 有必要先对高维数据样本进行特征提取, 过滤噪声, 去除冗余信息。常用的特征提取方法有主成份分析法(principal component analysis, PCA)^[8], 输入训练神经网络^[9], 自联想神经网络^[10], 层次分析法(AHP)等^[11]。其中层次分析法是一种定性和定量相结合的系统化、层次化的分析方法, 在数据处理中得到了广泛的应用^[12]。

基于此, 本文提出一种基于AHP的ELM神经网络预测建模方法, 采用基于熵权的AHP模型对复杂高维数据进行降维、去噪处理, 将处理后的数据作为ELM神经网络的输入, 通过训练得到学习性能优良的AHP-ELM神经网络预测模型。并通过UCI标准数据集验证了所提预测模型的有效性, 同时将其应用于乙烯生产预测建模分析中。实验表明, 相对于BP、ELM神经网络, 本文提出的AHP-ELM神经网络在处理复杂的高维度、强耦合数据时, 具有良好的泛化精度、学习效率, 能够指导

作者简介: 耿志强 (1973—), 男, 博士研究生, 教授。联系人: 韩永明。hanym@mail.buct.edu.cn

基金项目: 国家自然科学基金 (61374166, 6153303), 中央高校基本业务费 (YS1404)

乙烯生产。

2 极限学习机(ELM)

极限学习机由 Huang 等提出^[13]，主要由输入层，隐含层和输出层构成，其网络结构如图 1 所示。不同于其他前馈神经网络，ELM 不需要不断地根据误差函数调整权值，其隐含层神经元的学习参数是随机产生的，输出权重由广义逆方法计算、确定。




图 1 ELM 结构图

假设 ELM 中有 N 个学习样本，其集合表示为 $N = \{(X_n, Y_n) | n = 1, 2, \dots, N; X_n \in \mathbb{R}^{d_1}; Y_n \in \mathbb{R}^{d_2}\}$ ，如果该网络结构有 K 个隐含层节点，则其网络模型输出为：

$$Y_n = \sum_{k=1}^K \beta_k G(\omega_k \cdot x_n + b_k) \quad (1)$$

其中， $\omega_k = [\omega_{k1}, \omega_{k2}, \dots, \omega_{kd_1}]^T$ 与 $\beta_k = [\beta_{k1}, \beta_{k2}, \dots, \beta_{kd_2}]^T$ 分别表示输入层节点、输出层节点与隐含层第 k 个节点之间的连接权值向量， b_k 表示隐含层第 k 个节点的阈值， $G(\omega_k \cdot x_n + b_k)$ 代表隐含层第 k 个节点的输出，其中 $G(\cdot)$ 是隐含层的激活函数，其表达式为：

$$G(X) = \frac{1}{1+e^{-X}} \quad (2)$$

公式 (1) 可以写成更为紧凑的形式如下：

$$H\beta = Y \quad (3)$$

其中， H 为

$$H = \begin{bmatrix} G(\omega_1 \cdot x_1 + b_1) & \cdots & G(\omega_K \cdot x_1 + b_K) \\ \vdots & \ddots & \vdots \\ G(\omega_1 \cdot x_N + b_1) & \cdots & G(\omega_K \cdot x_N + b_K) \end{bmatrix}_{N \times K}$$

$$\beta = [\beta_1^T, \beta_2^T, \dots, \beta_K^T]^T_{K \times d_2}$$

$$Y = [Y_1^T, Y_2^T, \dots, Y_N^T]^T_{N \times d_2}$$

计算式 (3) 的极小 2-范数最小二乘解，由此，解得隐含层神经元与输出层神经元之间的连接权值 β

$$\hat{\beta} = H^+ Y \quad (4)$$

所以，在给定训练样本集 N ，隐含层激活函数 $G(\cdot)$ 以及隐含层节点数 K 之后，建立一个 ELM 模型需要以下 3 步：

- (1) 随机设置输入层神经元与隐含层神经元之间的权值 ω_k 和隐含层神经元的偏置 b_k ；
- (2) 计算隐含层的输出矩阵 H ；
- (3) 由广义逆方法计算输出权重 β 。

3 基于层次分析法的ELM网络(AHP-ELM)

为了有效处理高维度、多噪声、强耦合的数据样本，解决 ELM 网络存在的问题，本文提出了一种基于熵权的 AHP 算法，对高维数据样本进行加权融合、提取数据特征，去除冗余信息、过滤噪声，达到数据压缩的目的。将经过 AHP 融合的数据作为 ELM 网络的输入，建立适用于复杂数据建模的 AHP-ELM 网络模型。

3.1 基于熵权的层次分析模型(AHP)

定义 1: 设装置的 j 参数的关联函数为 $k_{ij}(x)$ (i 指第 i 次采样)

$$k_{ij}(x) = \begin{cases} 0 & x \notin [x_j(1), x_j(4)] \\ \frac{x_{ij}-x_j(1)}{x_j(2)-x_j(1)} & x \in [x_j(1), x_j(2)] \\ 1 & x \in [x_j(2), x_j(3)] \\ \frac{x_j(4)-x_{ij}}{x_j(4)-x_j(3)} & x \in [x_j(3), x_j(4)] \end{cases} \quad (5)$$

$$i = 1, 2, \dots, n; j = 1, 2, \dots, m$$

称此关联函数为标准关联函数，称 $x_j(1), x_j(2), x_j(3), x_j(4)$ 为 $k_{ij}(x)$ 的节点。

若标准关联函数 $k_{ij}(x)$ 的第二和第三个节点 $x_j(2), x_j(3)$ 重合，

$$k_{ij}(x) = \begin{cases} 0 & x \notin [x_j(1), x_j(4)] \\ \frac{x_{ij}-x_j(1)}{x_j(2)-x_j(1)} & x \in [x_j(1), x_j(2)] \\ \frac{x_j(4)-x_{ij}}{x_j(4)-x_j(2)} & x \in [x_j(2), x_j(4)] \end{cases} \quad (6)$$

$$i = 1, 2, \dots, n; j = 1, 2, \dots, m$$

称此关联函数 $k_{ij}(x)$ 为下侧关联函数。

设预处理后能效时序数据 $X = [X(1) X(2) \dots X(n)]^T$ ，其中， $X(i)$ 为 $t=i$ 时乙烯装置的能效价值数据，在此采用的是下侧关联函数，且 $x_j(2)$ ($j = 1, 2, \dots, m$) 值为平均值。得到信息阵 $K_{n \times m}$ 如下：

$$K_{n \times m} = \begin{bmatrix} k_{11} & k_{12} & \cdots & k_{1m} \\ k_{21} & k_{22} & \cdots & k_{2m} \\ \cdots & \cdots & \cdots & \cdots \\ k_{n1} & k_{n2} & \cdots & k_{nm} \end{bmatrix} \quad (7)$$

中心归一： $k'_{ij} = (k_{ij} - \bar{k}_j) / S_j$ ($i = 1, 2, \dots, n; j = 1, 2, \dots, m$)。其中， $\bar{k}_j = \frac{1}{n} \sum_{i=1}^n k_{ij}$

($j = 1, 2, \dots, m$)，然后把负数迁移到零点 (并采用正零，零加一个正小数 ε) $r_{ij} = k'_{ij} - t_j + \varepsilon$ ($i = 1, 2, \dots, n; j = 1, 2, \dots, m$) 其中 $t_j = \min(k'_{ij}) < 0$

($j = 1, 2, \dots, m$)。

得到正矩阵 $R^j_{n \times m}$:

$$R^j_{n \times m} = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1m} \\ r_{21} & r_{22} & \dots & r_{2m} \\ \dots & \dots & \dots & \dots \\ r_{n1} & r_{n2} & \dots & r_{nm} \end{bmatrix} \quad (8).$$

利用 $R^j_{n \times m}$ 得到 n 维的矩阵

$$COR = RR^T = \begin{bmatrix} o_{11} & o_{12} & \dots & o_{1m} \\ o_{21} & o_{22} & \dots & o_{2m} \\ \dots & \dots & \dots & \dots \\ o_{n1} & o_{n2} & \dots & o_{nm} \end{bmatrix} \quad (9).$$

对于 n 阶对称矩阵 COR , 计算各指标的熵:

$e_i = -\frac{1}{\ln n} \sum_{j=1}^n (r_{ij} \ln r_{ij})$ ($i = 1, 2, \dots, n$) 熵是表示对称矩阵 COR 中指标数据差异性的量度, 若 $r_{i1} = r_{i2} = \dots = r_{ij} = \frac{1}{n}$ ($j = 1, 2, \dots, n$), 此时 e_i 取最大值 1。显然, 指标熵值越小, 数据差异越大, 则该指标在综合评价中的重要程度就越大; 指标熵值越大, 数据差异越小, 则该指标的重要程度越小。各指标的重要程度即为其权值:

$$w_i = \frac{1 - e_i}{\sum_{i=1}^n (1 - e_i)}$$

使用 W 对方案融合, 得到装置能效价值融合数据 X_{ref} :

$$X^T W = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix}^T \begin{bmatrix} w_1 \\ w_2 \\ \dots \\ w_n \end{bmatrix} \quad (10).$$

3.2 AHP-ELM网络

给定 M 个具有高维输入的训样本集合示为:

$$M = \{(X_m, Y_m) | m = 1, 2, \dots, M; X_m \in R^{d_1}; Y_m \in R^{d_2}\}$$

其中, 每个训练输入有 d_1 个属性, 输出有 d_2 个属性。对于训练样本 M , 建立基于熵权关联层次分析的 ELM 网络模型 (AHP-ELM) 步骤如下:

步骤 1: 建立熵权关联层次分析模型。将训练样本集 M 中的高维输入向量: $X_m =$

$[x_{m1}, x_{m2}, \dots, x_{md_1}]^T$, $m = 1, 2, \dots, M$; 作为层次分析模型的输入向量。利用该模型得到输入数据的特征分量, 进而得到经过特征融合的新的训练样本集:

$$M' = \{(X'_m, Y_m) | m = 1, 2, \dots, M; X'_m \in R^{d'_1}; Y_m \in R^{d_2}\}$$

其中, 每一训练样本的输入向量为 $X'_m =$

$[x_{m1}, x_{m2}, \dots, x_{md'_1}]^T$, $m = 1, 2, \dots, M$; 包含 d'_1 个属性;

步骤 2: 将 1 中经特征融合的训练样本集合 M' 作为 ELM 网络的训练样本集, $X'_m =$

$[x_{m1}, x_{m2}, \dots, x_{md'_1}]^T$, $m = 1, 2, \dots, M$; 为 ELM 网络的输入向量, $Y'_m = [y_{m1}, y_{m2}, \dots, y_{md_2}]^T$, $m = 1, 2, \dots, M$; 则是 ELM 网络的期望输出。由此, ELM 网络的输入层节点数、输出层节点数分别为 d'_1 、 d_2 ;

步骤 3: 初始化 ELM 网络, 随机设定输入权值矩阵、隐含层节点数及阈值;

步骤 4: 数据归一化。由于数据中各个属性变量的量纲不同, 则特征变量之间的数值没有可比性, 因此要根据公式 (11) 进行归一化处理,

$$x_{ij} = \frac{x_j^{max} - x_{ij}}{x_j^{max} - x_j^{min}} \quad (11).$$

若 $x_j^{max} = x_j^{min}$, $x_{ij} = -1$ 。

其中 $x_j^{max} = \max\{x_{1j}, x_{2j}, \dots, x_{mj}\}$, $x_j^{min} = \min\{x_{1j}, x_{2j}, \dots, x_{mj}\}$, $i = 1, 2, \dots, M$; $j = 1, 2, \dots, d'_1$ 。得到归一化后的训练样本集: $M'_{nor} = \{(X'_m, Y_m) | m = 1, 2, \dots, M; X'_m \in R^{d'_1}; Y_m \in R^{d_2}\}$;

步骤 5: 根据公式 (4) 计算输出权值矩阵 β , 并记录;

步骤 6: 根据公式 (1) 计算 AHP-ELM 网络的实际输出;

步骤 7: 将实际输出与期望输出进行比较, 计算 AHP-ELM 网络的训练相对误差;

步骤 8: 选择一组不同于训练样本的数据集合作为 AHP-ELM 网络的泛化样本, 返回步骤 6, 计算网络的泛化相对误差。

AHP-ELM 网络算法流程如图 2 所示:

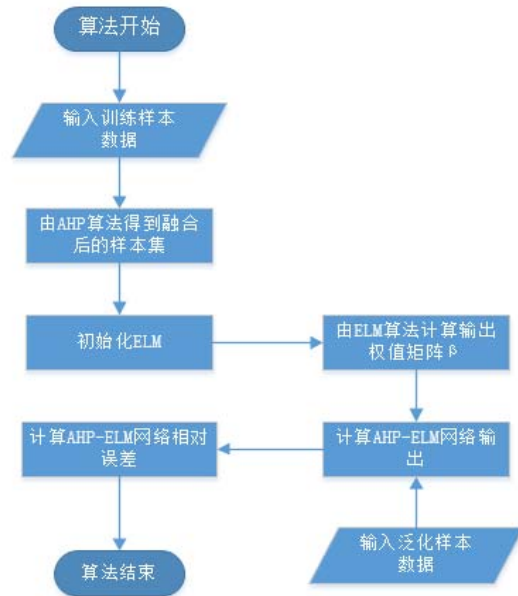


图 2 AHP-ELM 网络算法流程图

4 UCI标准数据集测试

为了验证本文提出的基于熵权关联层次分析的

ELM 网络的有效性 & 稳定性, 选取 UCI 数据库中 WINE、Parkinsons telemonitoring 数据集进行测试。上述两种数据集信息如表 1 所示。

表1 UCI数据集

测试数据集	样本数(训练/泛化)	输入节点	输出节点
WINE	150 (100/50)	11	1
Parkinsons	341 (250/91)	18	1

选取WINE及Parkinsons telemonitoring数据集样本, 首先利用模糊C均值算法^[14]对输入属性进行划分, 分别将两种数据集的输入属性划分为5类与7类; 然后根据第3节描述的建模流程进行网络测试。同时用 ELM、BP 神经网络对上述实验数据建模, 比较 AHP-ELM网络与这两种神经网络的测试性能。表2、表3分别记录了3种网络对2种数据集的测试结果。

表2 WINE标准数据集测试结果

	AHP-ELM	ELM	BP
泛化相对误差	0.061	0.097	0.083
泛化标准差	0.045	0.080	0.065

表3 Parkinsons标准数据集测试结果

	AHP-ELM	ELM	BP
泛化相对误差	0.052	0.063	0.059
泛化标准差	0.049	0.067	0.053

由表2、表3可以看出, 在WINE及Parkinsons数据集上, AHP-ELM网络相比于ELM、BP神经网络具有更高的泛化精度, 且标准差更小, 稳定性更佳。由此初步验证了AHP-ELM网络的有效性 & 稳定性。

5 乙烯工业生产预测建模与分析

乙烯作为极其重要的石油化工产品, 在石化工业中有着举足轻重的作用, 其生产水平的高低往往是判断一个国家工业发展水平的主要标志之一, 其能耗状况已成为衡量装置技术性能的重要综合性指标^[15]。为验证 AHP-ELM 网络的实用价值, 将其应用于乙烯生产中, 通过 AHP-ELM 网络建模预测产品产量, 分析乙烯装置生产状况。

5.1 乙烯投入产出数据分析

在乙烯生产中, 不同的乙烯能效分析界区和计算方法被不同企业所采用。因此, 本文参照乙烯行业标准DB 37/751-2007和GB/T 2589-2008^[16-17]进行乙烯生产装置界区的划分。

对于乙烯装置而言, 与生产效率直接相关的因素主要包括: (1) 原料; (2) 燃料、动力消耗; (3) 产品。由乙烯生产能量界区可知: 原油 (石脑油、轻柴油、抽余油、加氢尾油1、加氢尾油2、碳三碳四、其他)、燃料 (轻质油、重质油、燃料气)、蒸汽 (超高压蒸汽、高压蒸汽、中压蒸汽、低压蒸汽)、水 (循环水、工业水、锅炉积水、其他水)、电作为乙烯生产的投入指标, 而主要生产的乙烯、丙烯、碳四的产量为产出指标。同时表示乙烯装置能耗水平比较通用的方法是按照《石油化工设计能量消耗计算方法》(SH/T3110-2001) 中的表3.0.2和表3.0.3的换算关系将能耗相关参数中的燃料、蒸汽、水、电的计量单位统一换算成GJ, 原油、乙烯、丙烯、碳四生产单位以吨计量。故本文将燃料、蒸汽、水、电, 再加上原油作为AHP-ELM网络的输入, 乙烯、丙烯及碳4产量之和作为AHP-ELM网络的输出。

5.2 乙烯装置生产预测分析

为了验证本文提出的基于熵权关联层次分析的ELM神经网络的可行性和有效性, 本文选取全国七种主要乙烯生产技术中19个乙烯生产装置2010~2014年的月生产数据为分析对象。首先, 选取某生产装置2010年原油(石脑油、轻柴油、抽余油、加氢尾油1, 加氢尾油2, 碳三四五、其他)、燃料(轻质油、重质油、燃料气)、蒸汽(超高压蒸汽、高压蒸汽、中压蒸汽、低压蒸汽)、水(循环水、工业水、锅炉积水、其他水)、电这五大类原料作为AHP-ELM网络的输入, 将产物乙烯、丙烯、碳产量之和作为网络的输出, 由上所述最终构成19输入-1输出的训练样本数据集。然后, 利用基于熵权的关联层次分析模型分别对原油、燃料、蒸汽、水这四大类输入原料进行数据融合提取, 提取之后的数据与电消耗构成ELM网络的输入数据, 由此网络输入数据属性由原来的19个变成了5个。最后, 建立ELM网络预测模型进行乙烯生产装置生产分析预测。

选用2010年228组真实统计数据建立模型, 并对2011年的72组乙烯装置产出作出预测, 同时用传统的BP、ELM神经网络对上述实验数据建模, 比较AHP-ELM网络与这2种神经网络的预测性能。3种网络参数初始值设置情况、预测相对误差曲线分别如表4、图3所示:

表4 网络参数初始值设置

网络参数	BP	ELM	AHP-ELM
输入层节点数	19	19	5
隐含层节点数	40	40	19
输出层节点数	1	1	1
学习因子	0.01	--	--
动量因子	0.7	--	--
最大迭代次数	1000	--	--

激活函数	S函数	--	--
------	-----	----	----

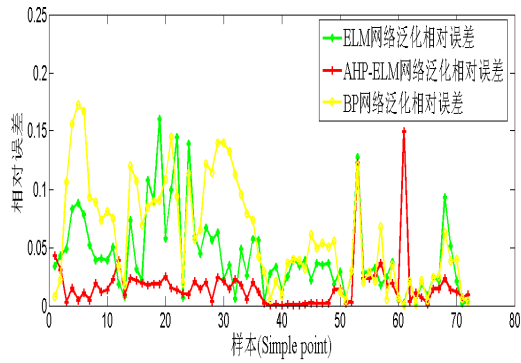


图3 ELM、AHP-ELM、BP网络预测误差曲线

表5记录了这3种网络的训练、泛化误差及所需时间。

表5 BP, ELM, AHP-ELM训练、泛化结果

实验结果	BP	ELM	AHP-ELM
训练时间	0.28s	0.048s	0.0156s
训练相对误差	0.0481	0.0358	0.0165
泛化时间	0.34s	0.0936s	0.0312s
泛化相对误差	0.0716	0.0556	0.0275

由表 5 可以看出 AHP-ELM 的训练、泛化结果较 BP 和 ELM 更接近真实值, AHP-ELM 网络泛化相对误差为 2.75%; 而 BP 神经网络和 ELM 神经网络的训练相对误差分别为 7.16% 和 5.56%。同时, 就 3 种网络训练泛化过程所需的时间而言, AHP-ELM 网络明显更快, 它的训练时间分别为 BP 神经网络的 9.2%, ELM 网络的 33.3%。

利用 AHP-ELM 网络模型预测 2011 年的产出数据与实际产出数据进行对比结果如图 4 所示。

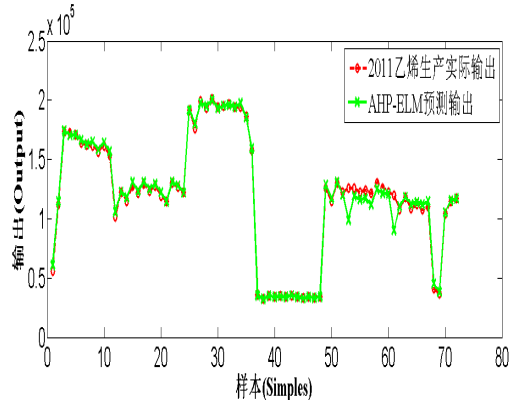


图4 AHP-ELM网络泛化曲线

由图 4 可以看出, AHP-ELM 网络的预测结果与 2011 年乙烯装置的实际产出非常接近, 验证了 AHP-ELM 网络模型的可行性。

5.3 乙烯装置生产预测分析

本文选用相同规模(80万吨级)不同技术下的某两个乙烯装置 2012 年的能效相关统计资料建立预测模型, 并对 2013 年乙烯、丙烯和碳四的总产量进行预测。两个装置产量的预测结果及泛化误差对比情况如表 6、图 5 所示。

表6 不同乙烯装置生产预测平均相对误差对比

	装置1	装置2
预测相对误差	0.052	0.017

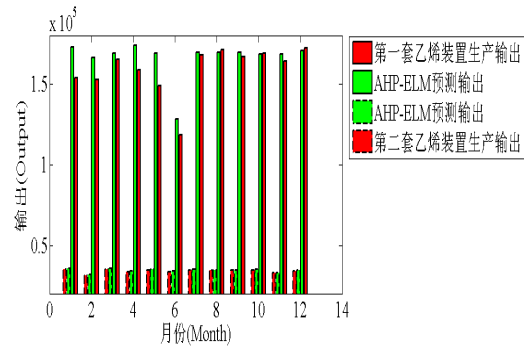


图5 不同技术的乙烯生产装置的预测结果

由图 5 和表 6 可以看出, 乙烯生产装置 2 的泛化相对误差小于装置 1, 说明装置 2 生产比较稳定, 生产状况良好, 而第一种技术下的乙烯生产波动较大, 说明该生产装置出现生产能效低下的状况, 可以根据生产状况调整乙烯投入量或者引入装置 2 的生产技术, 改进乙烯生产状况, 提高能效。例如第一个装置 2013 年 5 月投入原油 297096 吨, 燃料 19.23GJ, 蒸汽 0.49GJ, 水 2.90GJ, 电 0.72GJ, 而实际乙烯、丙烯、碳四的产出总量为 145377 吨, 预测模型产出量为 170425 吨, 说明 5 月份中该装置未达到预测生产规模, 装置未满足负荷生产, 能效较低, 在以后生产中应该调整投入产出, 提高能效。第 2 个生产装置 2013 年 6 月投入原油 58901 吨, 燃料 18.81GJ, 蒸汽 2.78GJ, 水 1.77GJ, 电 1.91GJ, 乙烯、丙烯、碳四的产出总量为 36535 吨, 预测模型产出为 37005 吨, 表明本月, 该装置满负荷运行, 在后续生产中该装置可维持该生产状况。

6 结论

本文针对复杂工业数据的特点, 提出了一种 AHP-ELM 网络建模方法, 基于熵权的 AHP 算法能够对高维度、强耦合且包含大量冗余信息的工业生产数据去噪、降维, 同时可以提取数据的特征变量; 并基于 ELM 神经网络对融合后的数据进行训练, 简化了 ELM 网络结构, 优化了网络的学习性能。通过 UCI 标准数据集测试以及乙烯生产过程建模的应用验证了本文所提方法相比于传统的 BP 网络、ELM 网络, 具有收敛速度更快, 学习精度更高, 泛

化能力更强等优点。基于AHP-ELM的建模方法能够准确的预测乙烯生产，合理配置乙烯投入产出，提高乙烯生产能效。同时对其他复杂工业预测建模也有着重要的理论意义和实用价值。

参考文献

- [1] Zhang Y, Zhang P. Optimization of nonlinear process based on sequential extreme learning machine[J]. Chemical Engineering Science, 2011, 66(20): 4702-4710.
- [2] Huang T, Wang X, Li L, et al. Ultra-short term prediction of wind power based on multiples model extreme leaning machine[M]//Advances in Neural Networks-ISNN 2011. Springer Berlin Heidelberg, 2011: 539-547.
- [3] Rumelhart D.E, Hinton G.E, Williams R.J. Learning Representations by Back-propagating Errors[J]. Nature, 1986, 323: 533-536.
- [4] Xie T T, Yu H, Wilamowski B. Comparison between Traditional Neural Networks and Radial Basis Function Networks[A]. Proceedings of the IEEE International Symposium on Industrial Electronics[C], 2011, 1194-1199.
- [5] 徐圆, 冯晶, 朱群雄. 基于可拓理论的RBF神经网络研究及其应用[J]. 控制与决策, 2011, 26(11): 1721-1725.
- [6] Huang G B, Zhou H, Ding X, et al. Extreme learning machine for regression and multiclass classification[J]. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on, 2012, 42(2): 513-529.
- [7] Zong W, Huang G B. Learning to rank with extreme learning machine[J]. Neural processing letters, 2014, 39(2): 155-166.
- [8] Jong-Min Lee, ChangKyoo Yoo, Sang Wook Choi, Peter A Vanrolleghem, In-Beum Lee. Nonlinear process monitoring using kernel principal component analysis[J]. Chem. Eng. Sci., 2004, 59(1): 223-234.
- [9] Geng Zhiqiang, Zhu Qunxiong. Multiscale nonlinear principal component analysis(NLPCA) and its application for chemical process monitoring[J]. Ind. Eng. Chem. Res., 2005, 44(10): 3585-3593.
- [10] Ravi V, Krishna M. A new online data imputation method based on general regression auto associative neural network[J]. Neurocomputing, 2014, 138: 106-113.
- [11] 耿志强, 石晓赞, 顾祥柏, 朱群雄. 层次线性优化融合及在乙烯行业能耗指标提取中的应用. 化工学报, 2010, 61(8): 2056-2060.
- [12] 耿志强, 朱群雄, 顾祥柏. 基于关联层次模型的乙烯装置能效虚拟对标及应用[J]. 化工学报, 2011, 62(8): 2372-2377.
- [13] Huang Guangbin, Zhu Qinyu, Siew Chee-kheong. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1): 489-501.
- [14] Ding Y, Fu X. Kernel-Based Fuzzy C-Means Clustering Algorithm Based on Genetic Algorithm[J]. Neurocomputing, 2015.
- [15] 宗言恭. 我国乙烯工业现状及发展对策[J]. 中国石油和化工经济分析, 2008 (7): 44-47.
- [16] DB37/751-2007, the Limitation of Energy Consumption for Ethylene Product [S].
- [17] GB/T2589—2008, the General Computing Guide of Special Energy Consumption [S].