

基于 DAE-BP 神经网络的化工过程质量预测

郭小萍, 马美卉, 李元

(沈阳化工大学 信息工程学院, 沈阳 110142)

摘要: BP 神经网络因具有良好的非线性拟合能力, 在建立预测模型中得到广泛应用; 但化工过程数据不仅存在非线性特征, 而且难以避免受噪声影响, 造成数据波动从而影响预测模型准确性; 为此, 提出一种降噪自编码器融合反向传播算法 (简称为, DAE-BP) 的化工过程质量预测方法; 首先, 采用无监督学习模型降噪自编码器完成初始数据的噪声消除, 其具有噪声鲁棒性的特点, 在数据受到损坏的情况下可尽可能地恢复数据的原始状态, 有利于进一步的质量预测; 在此基础上, 将获取的数据特征作为有监督学习模型 BP 神经网络的输入以获得可靠的预测结果; 在脱丁烷塔化工过程实例上验证方法有效性; 并与单一 BP 算法、主成分分析 (PCA) 及自编码器 (AE) 改进的 BP 算法作为对照; 结果表明, 经过 DAE 改进后的 BP 算法预测误差为 1.2%, 相比单一的 BP 算法提高了 3.2% 精度, 较 PCA-BP 及 AE-BP 预测误差精度分别提高了 2.3%、1.9%, 表现出最好的预测性能。

关键词: 降噪自编码器; BP 神经网络; 非线性相关; 噪声消除; 质量预测

Prediction of Chemical Quality Process Based on DAE-BP Neural Network

GUO Xiaoping, MA Meihui, LI Yuan

(College of Information Engineering, Shenyang University of Chemical Technology, Shenyang 110142, China)

Abstract: Back propagation (BP) neural network is widely used in building prediction model because of its good nonlinear fitting ability. However, the chemical process data not only has nonlinear characteristics, but also is difficult to avoid the influence of noise, which causes the data fluctuation and affects the accuracy of prediction model. Therefore, a denoising auto encoder back propagation (DAE-BP) method for chemical process quality prediction based on DAE fusion is proposed. Firstly, the unsupervised learning model of denoising auto encoder is used to eliminate the noise of initial data, which has the characteristics of noise robustness and can restore the original state of the data as far as possible in the case of the data damage, which is conducive to further the quality prediction. On this basis, the obtained data is used as the input of the BP neural network on the supervised learning model to obtain reliable prediction results. The effectiveness of the method is verified by an example of chemical process of debutanizer column. The results are compared with single BP algorithm, principal component analysis (PCA) and autoencoder (AE) improved BP algorithm. The results show that the prediction error of BP algorithm improved by DAE is 1.2%, which is 3.2% higher than that of the single BP algorithm, 2.3% higher than that of PCA-BP and 1.9% higher than that of AE-BP, which shows the best prediction performance.

Keywords: denoising autoencoder; BP neural network; nonlinear correlation; noise elimination; quality prediction

0 引言

科学技术的飞速发展对化工过程提出了更为严格的要求。保证过程安全、提高产品质量也逐渐成为化工工业过程追求的目标。在化工过程中, 对产品质量进行监测和控制对于安全稳定生产至关重要^[1-2]。快速有效地预测产品质量, 做出准确及时的判断, 对于提高生产质量有决定性作用^[3]。然而, 由于环境恶劣、仪器成本昂贵、测量延迟大等原因, 大多数关键质量变量难以在线测量, 无法为过程控制提供实时反馈消息^[4]。不同的是, 有许多易于测量的常规过程变量, 可以通过传感器轻松测量。因此, 为了解决质量变量难以在线获得的问题, 建立预测模型, 用各种易于测量的过程变量来估计难以测量的质量变量^[5]。近些年

来, 这逐渐成为解决上述问题最有效的方法之一, 并且已成为研究热点^[6]。

然而, 化工过程具有非线性、多变量等特征。针对这些特征, X. Yuan 等人提出核主成分回归预测模型 (KPCR), 之后其基础上又提出一种局部加权核主成分^[7]回归模型 (LWKPCR)。相比之下, 该方法对非线性过程的质量预测更加有效。Kaneko 曾提出一种基于在线支持向量回归 (SVR) 的方法^[8], 建立了工业过程变量间关系快速变化的预测模型。Chen Lu 等人提出一种混合核偏最小二乘 (KPLS) 方法^[9], 对参数及权重进行优化选取从而提高质量预测精度。

Shang et al. 等人首次利用深度信念网络构建原油蒸馏装置的回归模型^[10], 讨论了深度学习在工业过程中的独特

收稿日期: 2022-06-06; 修回日期: 2022-06-30。

基金项目: 国家自然科学基金项目(61673279); 辽宁省教育厅项目(LJ2020021)。

作者简介: 郭小萍(1972-), 女, 山西大同人, 博士, 教授, 主要从事基于数据驱动的复杂过程诊断和质量预测方向的研究。

李元(1964-), 女, 辽宁沈阳人, 博士, 教授, 主要从事基于数据驱动的复杂过程诊断方向的研究。

引用格式: 郭小萍, 马美卉, 李元. 基于 DAE-BP 神经网络的化工过程质量预测[J]. 计算机测量与控制, 2023, 31(1): 181-186, 193.

优势。He Yuliang 等人建立了具有多个输入、单个输出的 BP 神经网络^[11]的预测模型。

化工过程多个变量之间不仅呈现复杂的非线性相关，也避免不了干扰影响，通常伴有噪声。Liu linyue 曾提出基于 PCA-BP 神经网络的预测模型^[12]，基于主成分分析 (PCA) 去除影响因素间的线性相关，将主成分分析结果作为 BP 神经网络的输入。Chen Yan 也曾提出 SAE-BP 神经网络预测方法^[13]，其尝试使用稀疏自编码器 (SAE) 进行非线性特征提取，提取到的特征输入 BP 神经网络进行预测。Wan Liang 提出的已有的 DAE-BP 结构^[14]，其利用深度自编码器降低数据维度，然后基于 BP 神经网络建立了低维编码序列与预测变量之间的回归模型。在股票预测领域验证了该方法的有效性。

基于上述讨论，本文提出一种改进的 BP 神经网络质量预测方法。通过降噪自编码器提取原始数据有效特征，降低其存在的噪声，保证了数据的真实度并提高鲁棒性。将提取的有效特征构成新的输入样本，BP 神经网络可映射任意非线性关系，用其建立质量预测模型。经过不断训练，对网络参数进行调优，直至获得期望效果。将本文方法用于脱丁烷塔过程丁烷浓度预测。更进一步地，为了验证本文方法的优势与有效性，本文引入 BP、PCA-BP、AE-BP 进行对比分析。实证分析显示：本文所使用的 DAE-BP 神经网络能够较好地提取非线性特征并进行预测，其预测精度优于其他方法。

1 基础理论

1.1 自编码器

自编码器 (autoencoder, AE) 是一种神经网络，具有相同的输入和输出。其借助稀疏编码的思想，目标是使用稀疏的一些高阶特征重新组合完成样本重构。AE 是一种数据的压缩算法，属于无监督学习。

图 1 为自编码器的结构图，可见，它分为编码器和解码器两部分。编码器部分将原始数据输入 x 映射为隐藏表示 h ，通常，隐式表示 h 可以通过非线性映射函数 f 获得。

$$h = f_{\theta}(x) = s(Wx + b) \quad (1)$$

在解码器部分中，隐藏表示 h 被映射回重构的向量 \hat{x} ，通过非线性映射函数 g 获得，完成 $\hat{x} = x$ 的重构。

$$\hat{x} = g_{\theta'}(h) = s(W'h + b') \quad (2)$$

其中： x 、 h 与 \hat{x} 分别为输入数据、隐藏表示、输出数据； s 为 sigmoid 激活函数， W 与 b 分别为输入层与隐藏层之间的权重矩阵与偏置； W' 与 b' 分别为隐藏层与输出层之间的权重矩阵与偏置。 $\theta = [W, b]$ 和 $\theta' = [W', b']$ 分别为编码参数和解码参数， $f_{\theta}(x)$ 和 $g_{\theta'}(h)$ 分别为编码函数和解码函数。

通常，隐藏表示 h 的维数小于输入向量的维数，因此自动编码器起到了有效的压缩器的作用。一般来说，训练模型的目的是为了优化模型参数 $[\theta, \theta']$ ，使得 \hat{x} 与 x 更为接近。




图 1 自编码器结构图

1.2 降噪自编码器

降噪自编码器 (denoising autoencoder, DAE) 是自编码器的一个变体。在自编码器基础上，将噪声注入输入信息，然后利用含有噪声的“腐坏”样本重构无噪声的“干净”输入。这就是降噪自编码器 (denoising autoencoder, DAE) 的原理。降噪编码器经过人为破坏输入信号实现两个目的。首先，避免隐藏单元在传统编码器中学习到没有具体意义的恒等函数。其次，加入噪声又降低噪声干扰，迫使网络学习更具鲁棒的不变性特征，以获得更为有效的输入表达。

传统自动编码器单纯依靠最小化输入与重构信号之间的误差来得到输入的隐含层特征表示，但这种训练策略并不能保证数据的本质特征被提取出来，可能导致编码器学习到的特征仅仅是原始输入的复制。而 DAE 就是通过对比和进行学习，尝试着去填充缺失的信息，进而学习到的数据结构，使得提取到的特征更能反映原始输入的特点。




图 2 降噪自编码结构图

DAE 由编码器和解码器两部分构成，主要原理如下。对原始输入数据加入噪声：

$$x \sim D(\hat{x} | x) \quad (3)$$

编码器部分将原始数据输入 x 添加噪声后获得的 \hat{x} 映射为隐藏表示 h , 通常, 隐式表示 h 可以通过非线性映射函数 f 获得。

$$h = f_{\theta}(\hat{x}) = s(W\hat{x} + b) \quad (4)$$

在解码器部分中, 隐藏表示 h 被映射回向量 \hat{x} , 通过非线性映射函数 g 获得。

$$\hat{x} = g_{\theta'}(h) = s(W'h + b') \quad (5)$$

其中: x 、 \hat{x} 、 h 与 \tilde{x} 分别表示为初始数据、输入数据、隐藏表示、输出数据; 其中 $D(\hat{x} | x)$ 为噪声的分布, \hat{x} 为加入噪声后的输入; 输入层与隐藏层之间的权重值与偏置值记为 W 与 b ; 隐藏层与输出层之间的权重值与偏置值记为 W' 与 b' 。表示为 sigmoid 激活函数, $\theta = [W, b]$ 和 $\theta' = [W', b']$ 分别为编码参数和解码参数, $f_{\theta}(x)$ 和 $g_{\theta'}(h)$ 分别为编码函数和解码函数。

对比图 1 与图 2 可发现降噪自编码器与自编码器对输入层的处理不同。自编码器直接将初始信号输入编码解码框架, 而降噪自编码器在原始输入信息上添加噪声, 将加噪后的数据集当成输入信息, 训练整个网络, 在模型训练过程中学习存在噪声数据的规律, 从而把噪声去掉。

降噪编码器的目标是使损失函数最小化。

$$J_{\text{DAE}}(W) = \sum E_{\hat{x} \sim D(\hat{x} | x)} [\| \hat{x} - x \|_2^2] \quad (6)$$

DAE 依据输入信号和重构信号之间的误差来调整网络参数, 以最小化误差。训练过程不需要额外的标签信息, 使用传统的基于梯度的方式进行训练, 求得损失函数的最小值得到网络的最佳参数。由于典型的激活函数是光滑且连续可微的, 因此实现起来较容易。

1.3 BP 神经网络

BP 神经网络是一种成熟的、有组织和学习能力的非线性映射方法, 可大规模并行处理数据, 系统地解决多层神经网络隐含层连接及权值学习的问题。适用于解决传统算法或是计算方法难以解决的问题, 成为处理复杂问题的有效工具^[15]。它能从案例中学习知识, 将各种定量或定性的因素尽可能地作为变量加以输出, 建立变量与输出间的非线性映射^[16]。化工过程数据通常表现出为复杂的非线性, 并且过程变量较多, 线性模型已无法达到预期效果。因此, 基于神经网络的模型开辟了新道路。

BP 神经网络是一种按误差逆传播的多层前向型网络, 学习过程由信号的正向传播和误差的反向传播两个过程组成。结构由输入层、隐含层以及输出层构成, 每一层都有 N 个神经元。每一层与层之间通过权值相互连接, 同一层的神经元相互之间并无连接^[17]。其权值的调整取决于预期输出与实际输出之间的差异。正向传播时, 样本特征从输入层输入, 信号由每个隐藏层处理, 最后样本特征从输出层输出。针对网络的实际的输出与期望输出之间的误差, 从最后一层逐层传递误差信号, 获得各层的误差学习信号, 然后再根据误差学习信号来修正各层神经元的权值, 各层调整权值的过程是周而复始地进行。

BP 神经网络算法首先对网络进行初始化设置, 然后依据给定的输入向量与期望的输出值^[18]。可获得初始预测结果。若输出与期望值之间误差较大, 无法实现功能, 便不断进行权值修正, 网络不断学习训练, 达到预期结果, 此时便认为模型搭建完成^[19-20]。使用 BP 神经网络构建回归模型, 对质量变量进行预测。模型包括三层: 输入层, 隐含层, 输出层, 结构图如图 3 所示。




图 3 BP 神经网络结构图

输入层神经网络接收到归一化的变量后, 向隐含层的方向传递, 然后经过加权求和并使用激活函数将得到的值传递给输出层, 输出层重复加权求和及激活函数的步骤, 最终输出一个结果。设输入层、隐含层及输出层的神经元个数分别为 n 、 m 和 q 则:

$$\text{输入层: } X_i = x_i \quad (7)$$

$$\text{隐含层: } H_j = f\left(\sum_{i=1}^n W_{ji} X_i + b_j\right) \quad (8)$$

$$\text{输出层: } \tilde{y}_k = g\left(\sum_{j=1}^m \omega_{kj} H_j + b_k\right) \quad (9)$$

其中: X 为输入信息, H 为隐含层表示, \tilde{y} 为输出信息, 也是预测值。 ω 为权重, b 为偏置, f 为激活函数, g 为传输函数。

1.4 实验数据归一化处理

由于各个变量的数据范围在实验过程中差异较大, 取值都不属于同一个数量级, 在神经网络的训练的过程中, 可能会引起数据收敛过慢或根本无法收敛等问题。数据归一化的目的就是通过对不同数量级的数据统一到同一数量级, 这样使得比较起来更有意义, 能更好地反映数据本身的特点。

Min-max 归一化通过对原始数据进行线性变换, 使变换结果落到 $[0, 1]$ 区间, 函数为:

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

其中: x_i 代表第 i 个样本对应特征取值; x_{\max} 代表样本对应特征最大值; x_{\min} 代表样本对应特征的最小值; x_i^* 代表样本对应特征 Min-max 标准化后的值。

数据归一化有两大优点: (1) 归一化可以加快迭代过程中, 梯度下降求最优解的速度; (2) 归一化可以提高

精度。

1.5 预测模型评价指标

均方根误差 (root mean square error, $RMSE$) 和决定系数 (R -Square, R^2) 一般用来评估预测性能, 分别描述为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2} \quad (12)$$

其中: n 为测试样本个数, \hat{y} 为预测质量变量, y 为相应的真实质量变量, \bar{y} 为所有真实质量变量的均值。样本均方根误差越小, 代表方法所达到的效果越好。拟合度的数值区间为 $(0, 1)$, R^2 值和 1 的差距越小, 代表模型更具优越性。

2 DAE-BP 质量预测方法

DAE-BP 质量预测算法包括离线建模和在线预测两部分, 流程图如图 4 所示。

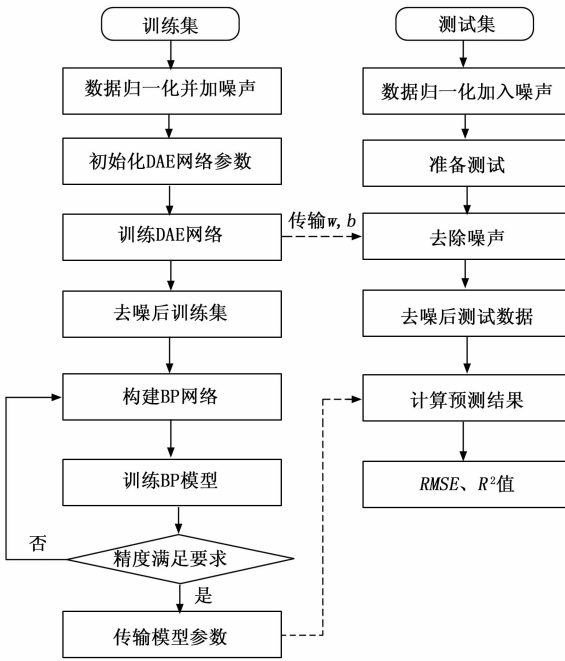


图 4 DAE-BP 神经网络流程图

离线建模主要步骤:

1) 获取样本, 按一定比例分割为训练集与测试集两部分, 为了减少泛化误差, 通过训练集不断训练模型, 测试集用来测试模型准确性。分别对数据归一化处理并添加噪声。

2) 向 DAE 网络输入数据, 输入信号会根据其原理, 采用非监督的逐层训练方法, 预训练各层神经网络, 对网络的隐藏层逐步训练, 获取 DAE 网络中的权值 w 和偏置值 b , 作为初始网络参数。添加噪声后的数据作为训练样本对整体的网络进行微调, 利用反向传播算法得到最优网络参

数完成网络训练。训练完成后, 便得到去噪后的训练数据集并将其输出。

3) 构建 BP 神经网络, 将从 DAE 输出的训练集样本作为新的输入, 微调网络参数, 训练模型。利用训练样本反复训练, 建立输入参数与目标输出之间的非线性关系。若满足精度要求, 将网络中参数传输给测试集; 若不满足, 依据真实和期望之间误差情况修改参数, 重新训练, 直到满足要求。

在线预测主要步骤:

1) 对测试集进行归一化处理, 并人为添加噪声, 将最优网络参数传输给测试集, 处理后的数据输入训练好的 DAE 模型以获得去噪后的干净数据信息, 将其输出。

2) 根据离线建模部分确定的预测模型, 将测试样本导入训练好的网络模型中, 测试神经网络的预测性能。计算新获取的测试数据的质量预测值及评价指标, 对模型预测结果进行评估。

3 脱丁烷塔实验

3.1 数据介绍

本文以化工过程案例为基准, 使用采集的脱丁烷塔数据来验证模型的有效性。脱丁烷塔是炼油过程中脱硫和石脑油分离装置的重要组成部分。其主要任务之一是降低脱丁烷塔底部的丁烷 (C_4) 浓度。然而, C_4 浓度是通过安装在顺序脱异戊烷塔顶部的气相色谱仪测量的, 该塔与脱丁烷塔相距较远^[21-22]。这样, C_4 浓度的测量会有很大的延迟。为了解决这个问题, 使用预测模型实时估计脱丁烷塔底部的丁烷浓度。

整个实验过程共采集到原始数据 2 393 组, 且所有的输入样本都有相应的输出。为了准确预测丁烷浓度, 选择 7 个与其关系最密切、易于测量的辅助变量完成预测。表 1 为过程变量的详细描述:

表 1 脱丁烷塔 7 个过程变量描述

过程变量	介绍
u_1	塔顶温度
u_2	塔顶压力
u_3	塔顶回流量
u_4	塔顶产品流出量
u_5	第六层塔板温度
u_6	塔底温度 A
u_7	塔底温度 B

3.2 模型结构

整个模型使用的过程变量的样本个数和输出变量的样本个数都为 2 393, 即所有的输入样本都有相应的输出。考虑到对多维数据展开实证研究, 故将所有的样本数据按照 7: 3 的权重分为训练集和测试集。整个数据集分为 1 675 组和 718 组, 前一部分为训练数据集, 后一部分为测试数据集。

在神经网络模型中, 隐层节点的选择应考虑两个要求。

选择的节点太少, 网络传输的信息量太少, 学习训练效果达不到要求。节点过多会造成训练时间的浪费, 可能无法提高准确性。

在模型训练过程中, 由于其损失函数中含有正则项, 往往需要选取合适的参数进行调整。降噪自编码器作为一种典型的无监督学习模型, 通过引入噪声来增加编码的鲁棒性。首先对原始数据进行一定程度的破坏, 添加噪声, 然后将损坏后的数据输送到编、解码框架。编码框架负责捕捉数据波形特征, 据此消除噪声; 解码框架能够扩展特征图, 提取数据细节信息, 得到重构后的数据。原始数据集总共 8 个维度, 前七列为过程变量, 最后一列为质量变量。训练样本集为 $1\ 675 \times 8$ 的数据矩阵, 测试样本集为 718×8 的数据矩阵。对其归一化处理后添加大小相同的噪声张量, 将其范围限制在 0 和 1 之间。一个输入层, 一个隐藏层和一个输出层构成了整个 DAE 模型。其中, 隐藏层神经元个数设置为六时, 误差最小, 因此确定 DAE 网络结构为 8-6-8, 分别为各层的神经元个数。输入层与隐藏层、隐藏层与输出层之间的传递函数选取 tanh 激活函数, 网络训练次数及学习率分别设为 600 及 0.1。

为全面考虑可控参数对丁烷浓度的影响, 将塔顶塔底温度、压力等 7 个参数作为 BP 神经网络结构的输入, 以丁烷浓度为 BP 神经网络的输出。由于多层神经网络是一种无需预训练的有监督学习算法, 因此只需使用标记样本进行

训练。BP 神经网络模型结构同样包括输入层、隐含层、输出层, 层数都为一。通过校正各层神经元的权值, 达到误差信号最小化。训练样本集为 $1\ 675 \times 7$ 的数据矩阵, 测试样本集为 718×7 的数据矩阵。利用训练样本反复训练, 建立输入参数与目标输出之间的非线性关系, 输入层与隐藏层、隐藏层与输出层之间的传递函数均采用选取 relu 激活函数。最终确定模型结构为 7-10-1, 分别为各层结点个数。网络训练次数及学习率分别设为 400 及 0.2。整个模型通过 RMSE 及 R^2 的值评判预测结果。

3.3 实验结果及分析

为了进行性能比较, 设置了四组对比实验。预测结果如图 5 所示。

基于 BP、PCA-BP、AE-BP 及 DAE-BP 方法的预测结果如图 5 所示。预测结果主要观察真实值与预测值两条曲线之间的差距, 差距越小即两条曲线越吻合, 表示预测效果越好。为了公平比较不同的网络预测性能, 所有构建的网络都具有相同的结构, 这可以消除不同网络结构造成的性能差异。从图 (a) 可以看出, 采用 BP 方法时, 由于单一的 BP 网络没有考虑数据本身的含噪问题, 仅考虑非线性特征, 导致真实值与预测值存在一定的差距, 没有很好地捕捉到样本实际质量变量的总体趋势, 预测效果不佳。结合图 (b) (c) 分析得, 数据样本利用 PCA 或者 AE 提取有效数据信息, PCA 通过将初始变量降低维度又升高维度的

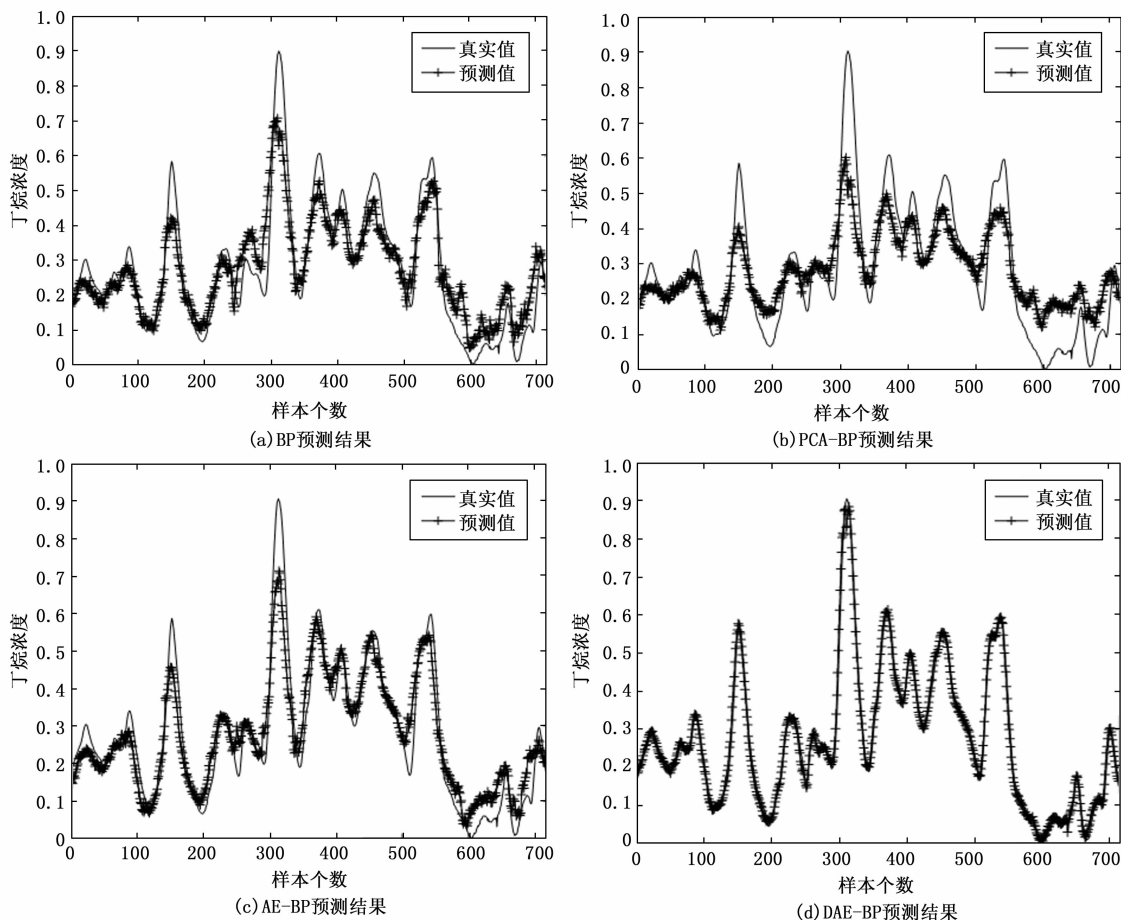


图 5 方法预测效果

原理完成数据重建, 寻找新的基坐标减少自由度, 也保留了原有数据维度。AE 通过将初始变量输入编码解码框架, 对原始数据进行重构, 学习数据规律, 完成基本数据去噪。再将其作为结构相同的 BP 神经网络预测模型的输入, 从图中可看出实际值与预测值大部分吻合, 也可以较准确地预测了烷含量的值, 一定程度上也改善了基本的 BP 存在的问题。综合分析, 图 (d) DAE 在 AE 的基础上改进了性能, 避免了数据简单重构的问题, 使其模仿加噪数据的规律并进行训练学习将噪声去除, 使用 DAE-BP 后质量变量即丁烷含量的预测值基本上跟随实际值的变化而变化, 预测性能有显著提高。综合所有的结果图, 不难看出, DAE-BP 预测更稳定, 没有大的波动, 具有比上述 3 种模型更好的鲁棒性。

为了更清晰地衡量预测效果, 记录了每种方法的 RMSE 和 R^2 的值, 如表 2 所示。越小的 RMSE 和越接近于 1 的 R^2 代表预测效果越好的模型。由于 BP 未经过数据特征提取, 4 种方法中表现最差。PCA-BP 和 AE-BP 经过了网络训练数据处理获得了合适的初始网络参数, 能够对复杂数据获得更好的预测精度。相比之下, 明显优于原来的 BP 预测模型, 预测精度有了提高, 不论在训练集还是测试集 RMSE 的值变小了, R^2 也越来越向 1 靠拢。DAE-BP 通过利用数据信息克服无监督预训练的限制, 可以进一步降低预测 RMSE。可以看出, PCA-BP 和 AE-BP 对单一 BP 模型的预测性能改善低于 DAE-BP, 三者预测性能显著优于 BP。DAE-BP 预测模型的 RMSE 值是最小的, R^2 非常接近于 1。经过 DAE 改进后的 BP 算法预测误差为 1.2%, RMSE 相比单一的 BP 算法提高了 3.2% 精度, 较 PCA-BP 及 AE-BP 预测误差精度分别提高了 2.3%、1.9%; 决定系数 R^2 为 99.5%, 相比单一的 BP 算法提高了 8.7% 精度, 较 PCA-BP 及 AE-BP 预测精度分别提高了 5.1%、3.9%。相比其他模型预测精度有更好的表现, 性能优于其他方法, 表现出最好的预测性能。说明该方法在化工过程质量预测的优越性。

表 2 不同方法结果比较

模型	RMSE		R^2	
	Training	Test	Training	Test
BP	0.045 464 4	0.044 967 3	0.906 882 3	0.908 907 6
PCA-BP	0.036 748 6	0.035 085 7	0.939 162 3	0.944 543 7
AE-BP	0.026 202 7	0.031 150 8	0.969 069 9	0.956 285 2
DAE-BP	0.011 735 3	0.012 305 1	0.993 795 8	0.995 301 8

4 结束语

鉴于化工过程数据多变量非线性、存在噪声干扰从而影响预测精度的问题, 提出了基于降噪自编码器和 BP 神经网络相结合的混合模型。首先, DAE 通过不断训练和学习, 尝试着去改善受损的信息, 使得提取到的特征更能反映原始输入的特点, 有效地利用数据样本进行网络预训练。不仅提高模型的抗干扰能力, 增加噪声鲁棒性约束, 而且可以保持输入数据的保真度。将获取的干净信息输入 BP 神经

网络预测模型进行有监督学习, 建立过程变量与输出质量变量的非线性关系, 克服了单一网络的局限性, 提升了质量预测的准确率。为了验证其效果, 引入了主成分分析和自编码器对数据进行有效信息提取, 并将获取的数据样本输入相同的 BP 神经网络实现质量预测, 构建相同网络是为了公平比较每种方法的预测性能。同时引入了均方根误差、决定系数预测评价指标评价预测效果。实验表明, 降噪自编码器结合 BP 神经网络的预测模型具有相对稳定的预测误差波动, 表现出较小的均方根误差及接近于 1 的决定系数, 因此, 本文提出的方法更能满足质量预测的需求。

本文实验应用的数据来源实际化工工业过程, 对相似工业情况的研究具有借鉴意义, 同时也存在一定的局限性, 因此在今后的研究中, 将继续收集具有代表性的样本数据, 采用更多的新案例验证所建立模型。

参考文献:

- [1] YUAN X, WANG Y, YANG C, et al. Weighted linear dynamic system for feature representation and soft sensor application in nonlinear dynamic industrial processes [J]. IEEE Transactions on Industrial Electronics, 2017, 65 (2): 1508-1517.
- [2] GE Z, CHEN J. Plant-wide industrial process monitoring: A distributed modeling framework [J]. IEEE Transactions on Industrial Informatics, 2015, 12 (1): 310-321.
- [3] REN L, MENG Z, WANG X, et al. A data-driven approach of product quality prediction for complex production systems [J]. IEEE Transactions on Industrial Informatics, 2020, 17 (9): 6457-6465.
- [4] YUAN X, GU Y, WANG Y. Supervised deep belief network for quality prediction in industrial processes [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-11.
- [5] KHATIBISEPEHR S, HUANG B, KHARE S. Design of inferential sensors in the process industry: A review of Bayesian methods [J]. Journal of Process Control, 2013, 23 (10): 1575-1596.
- [6] YUAN X, LI L, WANG Y, et al. Deep learning for quality prediction of nonlinear dynamic processes with variable attention-based long short-term memory network [J]. The Canadian Journal of Chemical Engineering, 2020, 98 (6): 1377-1389.
- [7] YUAN X, GE Z, SONG Z. Locally weighted kernel principal component regression model for soft sensing of nonlinear time-variant processes [J]. Industrial & Engineering Chemistry Research, 2014, 53 (35): 13736-13749.
- [8] KANKEO H, FUNATSU K. Application of online support vector regression for soft sensors [J]. AIChE Journal, 2014, 60 (2): 600-612.
- [9] 陈路, 郑丹, 童楚东. 基于混合核 KPLS 的工业过程质量预测方法 [J]. 无线通信技术, 2020, 29 (4): 41-45.
- [10] SHANG C, YANG F, HUANG D, et al. Data-driven soft sensor development based on deep learning technique [J]. Journal of Process Control, 2014, 24 (3): 223-233.

(下转第 193 页)