

DOI: 10.13382/j.jemi.2017.02.015

平行堆栈式自编码器及其在过程建模中的应用*

李荣雨 徐宏宇

(南京工业大学 计算机科学与技术学院 南京 211816)

摘要:在流程工业存在的多参数、强非线性和富含复杂机理等问题时浅层算法的学习能力有限,故将深度学习理论引入过程工业预测建模中。而针对单个深层网络对多样性数据的特征挖掘困难,本文提出一种改进的堆栈式自编码器。该方法首先通过聚类算法对输入数据属性进行聚类,按结果将数据分类后输入并行的稀疏自编码器中进行特征的模块式提取,并行输出经整合后输入至叠加的深度网络中,联合这些特征再进行逐层学习得到拟合结果。为减轻过拟合带来的预测误差,将“dropout”方法引入网络训练中。在加氢裂化的预测建模研究中,所提出的算法具有比其他方法更好的预测水平和泛化能力。

关键词:深度学习;自动编码器;加氢裂化;预测

中图分类号: TP181; TP273 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Parallel stacked autoencoder and its application in process modeling

Li Rongyu Xu Hongyu

(School of Computer Science and Technology, Nanjing Tech University, Nanjing 211816, China)

Abstract: The problem of multiparameter, nonlinearity and complex mechanism in process industry limits the performance of shallow algorithm, and therefore the deep learning is introduced into the processing industry predictive modeling. However, feature mining is insufficient for diversity data by single deep network, so an improved stacked autoencoder is proposed. Firstly, attribute of input is divided into several classes by clustering algorithm, and then the parallel sparse autoencoder is entered to detect feature locally. The parallel output is integrated into the following deep networks to extract feature layer by layer and get the fitting results. To overcome predictive error due to the overfitting, the “dropout” technique is introduced. In the prediction modeling of hydrocracking, the presented algorithm has better prediction level and generalization ability.

Keywords: deep learning; autoencoder; hydrocracking; prediction

1 引言

随着测量技术和DCS等系统的普及,使得可以获得过程工业中时间与空间上两个维度上不同尺度的大容量数据^[1]。传统过程工业数据建模方法多采用多元统计建模^[2-3],但在样本数量或参数增大时使用难度大。而从大数据中挖掘信息可依靠机器学习或数据挖掘算法来实现。而对产品的预测建模而言,过程工业中产品的产量和质量信息由装置的操作过程决定,但产率和质量数据

的测量具有严重的时间滞后性,无法及时反馈到生产过程中,所以对其有效的预测具有重要意义^[4]。其中经常使用的预测分析方法有诸如与智能优化算法结合的机器学习算法^[5-7]。然而浅层算法难以实现对数据表征的充分学习,无法自主获得合适的表征。这时需要借用人为干预,根据经验人工分析数据,从而获得较为合适的表征。当前新兴的深度学习理论^[8]可以彻底摆脱人工经验的支撑而自动的提取数据中的特征,得到分布式表示从而抓住数据变动的主要因素方向。其模型包含多层非线性转换单元,相对浅层学习算法,深层网络模型可以挖

掘更潜在的信息,并已在图像语音等领域取得突破性进展^[9-12]。

然而,深度学习并不是任何情况下都可以完美挖掘数据特征。很多情况下,将具有多样性、多特征的数据输入网络的最直接的方法是将多个输入堆叠成更高维的数据,此方法在每个输入都具有很高统一性和相关性时才有更好的性能。深度学习的大部分应用邻域的输入模式是具有同维度单类型的数据特征,如语音图像等领域。然而当数据集是来自不同渠道的多类型数据时,如过程工业中产生的数据,这些数据不是每一维都与其他所有数据都具有很强的相关性,这时无监督训练过程便很难学习到对结果有用的特征。针对类似问题,文献[13]将图像数据经过小波变换后的近似系数和细节系数两部分不同数据分别作为独立输入并行地输入 MIMT 深度自编码器进行独立计算后再进行叠加。而在自监督学习中, Noroozi 等人^[14]将输入的数据分成多个数据块模块输入网络,而代替以往整体图像的像素点输入,取得了更好的网络性能。从而说明分模块提取局部特征后再进行整体重构的方法是可行的。所以在针对进行建模时的输入数据具有多类型特征的集合时,可以通过多个平行的自编码器预提取局部信息后再联合这些特征,经过转换后叠加映射到主空间再进行计算。根据这一思想本文构建出平行堆栈式自编码器(parallel stacked auto-encoder, PSAE)模型并将此方法在过程工业的建模中进行了试验。

本文在训练深层网络前提出使用高斯混合模型(Gaussian mixture model, GMM)对训练样本属性聚类之后输入相应的自编码器(AE)中,之后将得到的特征整合输入堆栈式自编码器中逐层学习。此外,为了减少特征提取过程中的过拟合问题,网络的训练过程中引入了“dropout”技术。为验证方法的有效性,将该模型运用到加氢裂化过程的各油品产率和质量信息的预测建模中,实验结果表明该模型具有较好的预测性能和泛化能力。

2 深度学习理论

深度学习理论指出,只要通过足够多的转换和组合,数据中非常复杂的机理也可以被学习^[8]。深度学习的网络模型有包括卷积神经网络^[10](deep convolutional neural networks, CNNs)、深度信念网络^[15](deep belief networks, DBNs)和堆栈式自编码器(stacked auto-encoder, SAE)等多种网络模型,其中以 DBN 为代表的概率模型网络在训练离散数据时具有更好的性能,然而针对类似过程工业这样的数值型数据,SAE 这类数值模型更具优势。

2.1 自编码器

自编码器是包含 3 层神经元的前馈对称网络,结构

如图 1 所示。网络将输入数据 $\mathbf{v} = \{v_1, v_2, \dots, v_n\}$ 转换成隐层数据 $\mathbf{h} = \{h_1, h_2, \dots, h_m\}$ 的形式进行表示的过程称为编码,隐层矢量 \mathbf{h} 再通过解码网络映射到输出层。而 AE 就是要最小化隐层对输入数据的重构误差,这样便可使得隐层数据成为输入数据的一种特征表示。用数学描述可表示为:

$$\mathbf{h} = \sigma(\mathbf{W}_1 \mathbf{v} + \mathbf{b}_1) \quad (1)$$

$$\tilde{\mathbf{v}} = \sigma(\mathbf{W}_2 \mathbf{v} + \mathbf{b}_2) \quad (2)$$

式中: σ 是一种非线性映射,通常取 Sigmoid 函数 $\sigma(\mathbf{v}) = 1/1 + e^{-\mathbf{v}}$, \mathbf{W}_1 和 \mathbf{b}_1 分别是编码网络的权重矩阵和偏置向量,解码网络的权重矩阵 \mathbf{W}_2 可以通过权重绑定约束成 \mathbf{W}_1 的转置形式。网络的训练过程也就是通过优化权值和偏置参数来最小化重构误差 $E(\mathbf{v}, \tilde{\mathbf{v}}) = \|\mathbf{v} - \tilde{\mathbf{v}}\|^2$ 的过程。




图 1 自编码器结构

Fig. 1 The structure of autoencoder

编码的过程中如果 AE 的隐层节点数小于输入层节点数时,这样的编码在对原始数据提取特征的同时也进行了降维处理。但是 Bengio 等人^[16]证明当网络具备隐层神经元数远大于输入层这样的过完备状态时,运用随机梯度下降法训练后的网络会形成更有效的表达,这时则需要向隐层中加入稀疏性限制从而学习相对稀疏简明的数据特征。此时自编码器的代价函数中稀疏性惩罚项。若用 a_j 表示隐层单元的激活度,训练集中共有 K 个训练样本,那么隐层单元的平均激活度可表示为:

$$\rho_j = \frac{1}{K} \sum_{i=1}^K [a_j(\mathbf{v}^{(i)})] \quad (3)$$

由于稀疏限制条件,希望平均激活度可以趋向于一个较小的值 ρ ,即稀疏性参数。通过向代价函数中增添的稀疏惩罚项来增加稀疏性限制,惩罚项的形式有很多种合理的选择,这里选择交叉熵来达到惩罚的效果。其公式如下:

$$KL(\rho || \rho_j) = \rho \ln \frac{\rho}{\rho_j} + (1 - \rho) \ln \frac{1 - \rho}{1 - \rho_j} \quad (4)$$

此时整个网络的代价函数写成:

$$J_s(\mathbf{W}, \mathbf{b}) = J(\mathbf{W}, \mathbf{b}) + \beta \sum_{j=1}^m KL(\rho_j \parallel \rho_j) \quad (5)$$

式中: β 是稀疏因子的权重系数, $J(\mathbf{W}, \mathbf{b})$ 是自编码器的代价函数, 其公式如下:

$$J(\mathbf{W}, \mathbf{b}) = \frac{1}{K} \sum_{i=1}^K \left[\frac{1}{2} \|o(\mathbf{v}^{(i)}) - d^{(i)}(\mathbf{v}^{(i)})\|^2 \right] + \frac{\lambda}{2} \sum_{l=1}^2 \sum_{j=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ji}^{(l)}) \quad (6)$$

其中 $o(\mathbf{v}^{(i)})$ 和 $d^{(i)}(\mathbf{v}^{(i)})$ 分别是对于输入数据 $\mathbf{v}^{(i)}$ 的网络实际输出和理想输出。通过优化网络的代价函数便可从隐层得到较好的输入数据的特征表达。

2.2 构建深度网络结构

为构建深度学习算法的逐层提取输入数据特征, 将多个自编码器进行堆叠, 并且将前一层学习到的特征作为后一层输入, 组成堆栈式自编码器。最后再根据不同的需求叠加网络的输出层, 如 Softmax 分类器、支持向量机(SVM)或者神经网络等等, 网络模型如图 2 所示。




图 2 堆栈自编码器结构

Fig. 2 The structure of stacked autoencoder

而深度网络的训练算法无法直接使用反向传播算法, 由于网络的层数增加, 误差从输出层反向传播时逐层稀释以致误差校正信息越来越小。Hinton 等人^[17]提出了一种训练深度神经网络的学习算法, 网络参数的优化策略分为预训练和微调两个过程。预训练算法核心是将无标记的数据通过无监督学习来进行模型参数的初始化, 逐层地训练自编码器得到一个多层网络。运用反向传播算法来优化自编码器的过程可以描述为:

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \alpha \frac{\partial}{\partial W_{ij}^{(l)}} J_s(\mathbf{W}, \mathbf{b}) \quad (7)$$

$$b_i^{(l)} = b_i^{(l)} - \alpha \frac{\partial}{\partial b_i^{(l)}} J_s(\mathbf{W}, \mathbf{b}) \quad (8)$$

式中: α 表示学习速率。当足够的自编码器训练完成之后将其进行堆叠, 运用有标签数据对整个网络进行有监督训练。

3 基于 PSAE 的建模方法

3.1 PSAE 网络结构

面对诸如过程工业产出的多样性多特征类型数据, 为更好挖掘出数据中的特征和特征间的相关性, 可先通过聚类算法或人工经验将数据特征分成不同的属性簇模块地输入并行的自编码器中重构, 再联合这些特征进一步逐层学习。

PSAE 模型的结构如图 3 所示, 其前向传播过程可以概括为对原数据集 X 的特征属性进行聚类(以两类为例)后, 每个输入数据 $x(1)$ 被分成 $x_1(1)$ 和 $x_1(2)$, 即输入样本集被分成 $X_1 = \{x_1(1), x_1(2), \dots, x_1(k_1)\}$ 和 $X_2 = \{x_2(1), x_2(2), \dots, x_2(k_2)\}$ 。 X_1 和 X_2 按序分别通过平行的稀疏自编码器得到各自的特征输出 $F1$ 和 $F2$ 。若用 $\mathbf{u}^{(l)}$ 表示第 l 层的网络输入, 经过两个独立的网络输出的结果在 Gate 层处进行叠加组合后输入堆栈式自编码器中, 其过程可描述为:

$$\mathbf{u}_{share}^{(2)} = \mathbf{W}_{gate} \cdot \sigma[\sigma(\mathbf{W}_1^{(2)} \mathbf{F}_1(k) + \mathbf{b}_1^{(2)}) + \sigma(\mathbf{W}_2^{(2)} \mathbf{F}_2(k) + \mathbf{b}_2^{(2)}) + \mathbf{b}_{gate}] \quad (9)$$




图 3 PSAE 结构

Fig. 3 The structure of PSAE

SAE 部分联合两部分的特征 $F1$ 和 $F2$ 进行高阶特征的提取, 将最后的特征输入依据需求堆叠的最后一层神经网络中而得到最终的输出结果。

训练过程中, 稀疏自编码器和堆栈式自编码器先进行无监督的预训练。而在利用反向传播算法进行微调的过程中, 根据叠加的输出层选取不同的误差函数。这里面对过程工业的建模, 需要对数值型数据进行非线性拟合, 所以将输出层选为 BP 神经网络, 则网络输出层(第 l 层)的单元残差可表示如下:

$$\delta_i^l = \frac{1}{2} \frac{\partial}{\partial u_i} \|d_i(\mathbf{x}(k)) - o_i(\mathbf{x}(k))\|^2 \quad (10)$$

并反向传递回堆栈稀疏自编码器调整网络参数, 但当经过 Gate 层传向平行的自编码器时则也须按式(11)和(12)所示并行传播残差而保留局部化信息。

$$\delta_{i_{min}}^{(k)} = \left(\sum_{j=1}^{N_{min}} W_{j_{min}} \cdot \delta_j^{(k+1)} \right) \quad (11)$$

$$\delta_{i_{\text{out}}}^{(k)} = \left(\sum_{j=1}^{N_{\text{out}}} W_{ji_{\text{out}}} \cdot \delta_j^{(k+1)} \right) \quad (12)$$

3.2 利用 GMM 划分数据特征

GMM 是一种常用的聚类算法^[18]。本文将待聚类的数据看成来自多个高斯分布的混合分布,每个高斯分布便代表不同的类。模型可以表达成 d 维数据 \mathbf{x} 由 K 个高斯分布混合组成,则概率密度函数可写为:

$$p(\mathbf{x}) = \sum_{k=1}^K \pi_k p(\mathbf{x} | k) = \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \quad (13)$$

式中: π_k 为混合比, $\boldsymbol{\mu}_k$ 和 $\boldsymbol{\Sigma}_k$ 分别是第 k 个高斯分布的均值和协方差矩阵。分类过程便是样本中的数据分别在 k 个高斯分布上进行投影,就分别得到了它们属于这几个类的概率值,最后依据概率值作为类别的判决结果。估计出每个类别即每个高斯分布的参数一般采用 EM 算法^[19]。

针对建模输入数据集中的大量多样性数据,随机选择足够的数据,将按数据的特征属性对选出的数据划分成不同的属性向量。初始化 K 值(这里初始化范围为 3~5)和各分布的参数,运用 EM 算法进行迭代至收敛。最终得到 K 簇属性类别,并将每一簇作为 PSAE 的一个并行输入。

3.3 利用 dropout 防止过拟合

过程工业的建模过程中涉及到诸多参数,在这种情况下,出现训练数据不足或训练过度时往往会导致过拟合。Hinton 等人^[20]于近年提出了一种防止网络过拟合的方法。将其运用在本文模型中的全连接的低层部分即 SAE 模块的前两层的训练过程中,来尽可能减少因隐层神经元之间的相互适应而导致提取到重复的特征,从而提高泛化能力。

该方法并不是通过修改代价函数向其中增添正则项,而是直接修改网络的训练过程。可概括为:网络训练时随机按照一定比例使隐层的部分节点的权重失效,而使得这些节点不参与这次传播过程,这里将这个比例称为 dropout 系数同样地,在按照 BP 算法更新网络权值时它们的权值也是不变的。再下一次迭代过程中,又再次随机选择隐元(与前一次选择的节点不同)使它们失效并保持权值不变。在测试阶段运用均值网络的思想使隐元的输出值也按照 dropout 系数衰减,最终达到防止深度网络过拟合的效果。

3.4 建模方法

本文的建模方法可总结如下:

1) 采集现场数据,按比例分成训练集和测试集;

2) 设置 GMM 的参数 K ,从训练集数据中随机选取足够的数,预处理后进行特征聚类。调整 GMM 的参数 K 重复聚类,直至达到较好的分类(各特征簇数量相差不要过大);

3) 设置各平行的稀疏自编码器的训练学习率,稀疏参数 ρ_j ,权值初始化到范围 $[-r, r]$ 中,其中 r 的计算公式如下:

$$r = \sqrt{\frac{6}{h_k + h_{k+1}}} \quad (14)$$

其中, h_k 与 h_{k+1} 分别表示权值向量之前和之后的隐层神经元个数;

4) 将训练集数据属性按特征簇类型分别输入平行的稀疏自编码器中进行预训练;

5) 用步骤 4) 中得到的各编码器提取的原始数据特征进行维度叠加后作为连接的 SAE 的输入;

6) 初始化 SAE 的网络权值矩阵和偏置向量,确定网络深度和 dropout 系数后逐层预训练;

7) 对已得网络模型按照需求堆叠输出层,并使用反向传播算法微调整个网络;

8) 用测试集数据按照与训练集相同的方式输入深度网络执行前向传播算法,将网络输出与真实值对比,计算预测误差来评估网络性能。

4 实验验证与结果分析

4.1 实验背景

为了验证本文建模方法的有效性,选择对加氢裂化生产过程进行软测量建模来预测各产品的产率和产品性质。加氢裂化是石化炼油企业中的常用技术,是典型的过程工业,其生产流程中受到多方面影响,涉及到进料性质、反应器参数和催化剂等多种因素,其输入参数具备典型的高维度多类型的特性。目前对该工艺的建模方法,基于“集总”理论的建模研究与运用最广,但整个生产流程受制于其选取原料、设备状况、工艺和催化剂特性等诸多因素影响,整个过程具有很高的非线性和耦合性,当模型引入参数过多,会导致拟合的难度和方程的求解难度很大。因此采用人工智能的建模方法也是很重要的方向。本文以某石化公司的加氢裂化装置为研究对象,其装置流程如图 4 所示。该套装置共包含两系列反应器,每个反应器部分由精制器和裂化器串联构成。进料通过反应床层与催化剂反应,再经过高低压分离器,进入脱戊烷塔,最后经过两个分馏塔分馏得到各产品,该装置产品包括轻石脑油,重石脑油,航煤和尾油等。

4.2 实验与结果分析

通过对现场数据进行采集,整理出该厂半年现场各位号的实时数据,并从每个月中随机抽取五天数据组成测试集,其余用来训练网络。将训练数据的属性运用 GMM 进行聚类,在对现场工况和历史数据分析后确定高斯模型个数 K 候选集为 $\{2, 3, 4\}$,实验结果显示当 K 取 3 时各类数据较均匀,故将数据属性分为 3 类(C_1 、 C_2 和

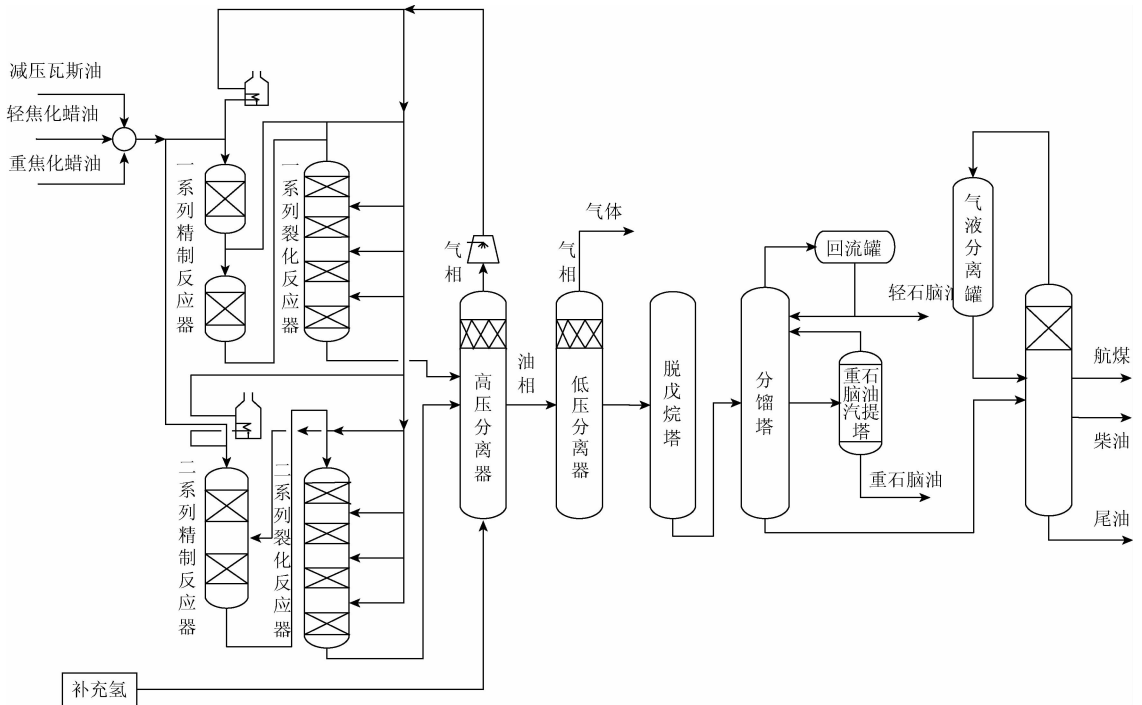


图 4 加氢裂化流程

Fig. 4 The process of the hydrocracking plant

C3), 并且各类中的属性具有明显的相似性, C1 中以各反应器和分离器的温压值等参数为主, C2 中主要是有关进料的数据参数, 而 C3 中以床层中催化剂参数为主。经过分析, 装置中补充氢的各成分含量体积比例参数和反应器中催化剂填充相关参数 (直径、密度、负荷等) 都相对稳定, 性能差异基本可忽略, 因此本次建模不考虑这些因素的影响, 最后决定将聚类结果不明确的氢气参数归纳入 C2 中并排除 C3 类, 此时从输入数据筛选出的 50 个属性被分成 28 维和 22 维, 将其输入并行自编码器中, 后接串联的 SAE 包含两个隐含层, 最后叠加 BP 神经网络作为模型输出层。作为对比, 使用堆栈式自编码器和结构相同的多层感知器 (multi-layer perceptron, MLP) 进行试验, 此外, 训练中设置 dropout 的参数为 0.15。

各方法对测试集中各产品产量的预测结果示于表 1 中。为更加直观地显示各方法的预测性能, 选取顶气测试集中后 3 个月的预测精确率如图 5 所示。

表 1 各产品产量预测精确率

Table 1 Prediction accuracy of products yield (%)

产品	本文方法	栈式自编码器	多层感知器
顶气	95.23	91.39	76.13
低分气	96.27	91.12	88.66
尾油	95.89	92.07	83.78
轻石脑油	93.74	92.83	79.57
重石脑油	95.21	93.17	90.76
航空煤油	96.74	92.49	89.49




图 5 各算法产量预测情况对比

Fig. 5 Comparison of yield prediction of each algorithm

结合表 1 和图 5 可看出各方法的在测试集中的预测结果与误差分布。本文方法的预测准确率平均在 95% 以上, 在预测能力和稳定性上相比其他方法具有一定提高的。单一的 SAE 在面对高维多类型数据时在深度不够的情况下无法充分挖掘, 而深度过大时计算成本是一大问题。而具有同样层次和神经元数目的 MLP 表现最差, 并且从测试集误差分布来看该方法也最不稳定, 最大误差接近 50%。

说明虽然网络结构相同, 但同时进行无监督和有监督学习的方法才能发挥深层网络自适应提取特征的优势。而无监督学习中模块化的特征提取和整合更能发掘

原始数据的信息。为具体分析,绘制出3种方法的训练误差曲线如图6所示。




图6 各算法训练误差对比

Fig. 6 Comparison of training error of each algorithm

可以看到,MLP的训练误差很快停留在0.2左右,而对于两个基于深度学习的方法,本文的方法在非监督的预训练阶段取得了更好的表现并最终收敛到更低的训练误差。以上结果说明,虽然深度模型可以发挥逐层学习的特点,但是性能受学习算法的影响很大,单纯的BP算法无法有效的训练多层结构,很容易陷入局部最优。而本文的方法可以更好将网络初始化在更好的位置,反向迭代初期因网络的具有平行结构的原因而有微小的波动,但最终的训练误差比收敛速度略快的SAE更小。

为进一步对模型的拟合性能进行评价,将对各产品的质量信息(这里选取产品的恩氏蒸馏数据代表产品质量信息)进行预测。使用每组预测结果相对误差的平均值对模型准确性进行分析,各方法的性能示于表2中。并从平均拟合误差最高的轻石脑油(LN)测试集中随机选取一例馏程预测结果如图7所示,更直观的展示各方法的拟合性能。

表2 各产品恩氏蒸馏数据预测误差

Table 2 Prediction error of the Engler distillation data of products

产品	本文方法	栈式自编码器	多层感知器
轻石脑油	0.021	0.038	0.112
重石脑油	0.018	0.033	0.107
航空煤油	0.014	0.029	0.154
尾油	0.016	0.026	0.105

可以看出,由非深度学习算法训练的深层网络其预测性能和泛化性能都不够稳定。SAE的拟合值其整体馏程趋势基本与实际值一致,但是对具体数值的近似,本文




图7 各算法轻石脑油馏程信息预测性能对比

Fig. 7 Comparison of LN's distillation range predictive performance of each algorithm

使用的方法预测结果的相对误差更小,拟合性能更稳定,更好的反映了轻石脑油馏程的变化趋势。本文提出的方法对于各产品的整体预测相对误差为0.017左右,显示出更高的拟合精度和泛化能力。

5 结论

过程工业的数据维数高,非线性与不确定性严重,针对传统建模方法面对大量参数与样本数时的费时费力,浅层机器学习算法特征挖掘有限,所以将深度学习理论引入过程建模中。为适应过程工业建模时的多样性数据而调整以往堆栈式自编码器的结构提出平行堆栈式自编码器。通过聚类算法对输入数据预处理后通过平行的自编码器进行特征局部化提取,再联合各模块特征通过深度网络得到最终的拟合结果。

将该方法在加氢裂化反应的预测建模研究中,与其他算法对比,本文的方法在预测能力、泛化能力和稳定性都有更好的表现,适合各产品产率和质量的在线预报,对工业生产过程具有一定的指导意义。

参考文献

[1] 刘强,秦泗钊. 过程工业大数据建模研究展望[J]. 自动化学报, 2016(2):161-171.
LIU Q, QIN S ZH. Perspectives on big data modeling of process industries [J]. Acta Automatica Sinica, 2016(2):161-171.

[2] 叶永伟,陆俊杰,钱志勤,等. 基于LS-SVM的机械式温度仪表误差预测研究[J]. 仪器仪表学报, 2016, 37(1):57-66.
YE Y W, LU J J. Study on the temperature error prediction of mechanical temperature instrument based on LS-SVM[J]. Chinese Journal of Scientific Instrument,

- 2016, 37(1):57-66.
- [3] 常鹏, 王普, 高学金, 等. 基于统计模式分析的 MKPLS 间歇过程监控与质量预报[J]. 仪器仪表学报, 2014, 35(6):1409-1416.
- CHANG P, WANG P, GAO X J, et al. Batch process monitoring and quality prediction based on statistics pattern analysis and MKPLS [J]. Chinese Journal of Scientific Instrument, 2014, 35(6):1409-1416.
- [4] 苏鑫, 吴迎亚, 裴华健, 等. 大数据技术在过程工业中的应用研究进展[J]. 化工进展, 2016, 35(6):1652-1659.
- SU X, WU Y Y, PEI H J, et al. Recent development of the application of big data technology in process industries [J]. Chemical Industry and Engineering Progress, 2016, 35(6):1652-1659.
- [5] 谢苗, 刘治翔, 毛君. 基于改进型 ANFIS 的矿用空压机故障诊断系统[J]. 电子测量与仪器学报, 2015, 29(4):500-507.
- XIE M, LIU ZH X, MAO J. Fault diagnosis system of mine air compressor based on improved ANFIS [J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(4):500-507.
- [6] 程剑, 宋淑群, 张凌波, 等. 基于 PLS-混合 Pi-Sigma 模糊神经网络模型的甲醇合成装置变换工序 CO 变换率软测量建模[J]. 华东理工大学学报:自然科学版, 2015, 41(1):66-71.
- CHENG J, SONG S Q, ZHANG L B, et al. PLS-hybrid Pi-Sigma fuzzy neural network method and its application in methanol conversion purification process about CO conversion rate[J]. Journal of East China University of Science and Technology: Natural Science Edition, 2015, 41(1):66-71.
- [7] 梁炎明, 张鹏, 李琦, 等. 基于模糊支持向量机的空气预热器温度预测[J]. 电子测量与仪器学报, 2014, 28(12):1348-1354.
- LIANG Y M, ZHANG P, LI Q, et al. Temperature prediction of air pre-heater based on fuzzy support vector regression[J]. Journal of Electronic Measurement and Instrumentation, 2014, 28(12):1348-1354.
- [8] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553):436-44.
- [9] HINTON G, DENG L, YU D, et al. Deep neural networks for acoustic modeling in speech recognition[J]. IEEE Signal Processing Magazine, 2012, 29(6):82-97.
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Image net classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25(2):2012.
- [11] 李新国, 黄晓晴. 一种基于 DBN 的高光谱遥感图像分类方法[J]. 电子测量技术, 2016, 39(7):81-86.
- LI X G, HUANG X Q. Deep neural networks based on hyperspectral image classification [J]. Electronic Measurement Technology, 2016, 39(7):81-86.
- [12] 曲景影, 孙显, 高鑫. 基于 CNN 模型的高分辨率遥感图像目标识别[J]. 国外电子测量技术, 2016, 35(8):45-50.
- QU J Y, SUN X, GAO X. Remote sensing image target recognition based on CNN [J]. Foreign Electronic Measurement Technology, 2016, 35(8):45-50.
- [13] ZHAO X, NUTTER B. Content based image retrieval system using Wavelet Transformation and multiple input multiple task deep autoencoder [C]. IEEE Southwest Symposium on Image Analysis & Interpretation (SSIAI), 2016: 97-100.
- [14] NOROOZI M, FAVARO P. Unsupervised learning of visual representations by solving jigsaw puzzles[C]. 14th European Conference, 2016: 69-84.
- [15] HINTON G E, OSINDER O S, THE Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7):1527-1554.
- [16] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks[C]. Advances in Neural Information Processing Systems 19 (NIPS19), 2007:153-160.
- [17] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786):504-507.
- [18] BISHOP C, BISHOP C M. Pattern recognition and machine learning [J]. Journal of Electronic Imaging, 2006, 16(4):140-155.
- [19] 张燕杰. 基于混合高斯模型的聚类分析[D]. 武汉: 华中科技大学, 2014.
- ZHANG Y J. Cluster analysis based on the mixture gaussian models [D]. Wuhan: Huazhong University of Science and Technology, 2014.
- [20] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. Computer Science, 2012, 3(4):212-223.

作者简介



李荣雨, 1999 年于山东工业大学获得学士学位, 2002 年于山东大学获得硕士学位, 2007 年于浙江大学获得博士学位, 现为南京工业大学计算机科学与技术学院副教授, 主要研究方向为流程工业的统计监控与先进控制、面向流程工业的机器学习。

E-mail: ruli@njtech.edu.cn

Li Rongyu received B. Sc. from Shandong University in 1999, M. Sc. from Shandong University in 2002, and Ph. D. from Zhejiang University in 2007, respectively. Now he is associate professor in Nanjing Tech University. His main research interest includes statistical monitoring of process industry and advanced control, and machine learning for process industry.



徐宏宇, 2010 年于江西理工大学获得学士学位, 现为南京工业大学在读研究生, 主要研究方向为机器学习和深度学习。

E-mail: HY_Xu0826@163.com

Xu Hongyu received B. Sc. from Jiangxi University of Science and Technology in 2010.

Now he is M. Sc. candidate in Nanjing Tech University. His main research interest includes machine learning and deep learning.

是德科技推出 10 款 PXIe 仪器, 为 5G、航空航天和国防以及量子技术研究保驾护航

新型 PXIe 任意波形发生器、数字化仪和示波器提供高达 1 GHz 的带宽, 能够方便地执行复杂的基带 IQ 信号生成和分析

是德科技公司 (NYSE: KEYS) 发布了 10 款新 PXIe 仪器, 包括任意波形发生器 (AWG) 和全能型 PXI 示波器。新款任意波形发生器具有三个高度同步的通道, 可以精确调谐 IQ 波形并进行包络追踪。任意波形发生器和示波器均具有高达 1 GHz 的带宽, 能够轻松胜任复杂的基带 IQ 信号生成和分析, 可用于评测新兴的 5G 和航空航天及国防宽带技术。

新 PXI 产品包括任意波形发生器和数字化仪, 这些产品使得工程师能在仪器上构建核心功能, 或将自定义算法插入板载 FPGA。图形设计环境使其能轻松添加新兴技术、研究和设计所需的定制功能, 同时发挥 FPGA 的全部性能和速度。M3xxxA 任意波形发生器和数字化仪采用 FPGA 和 PXI 参考时钟提供实时序列和多通道/多模块同步, 能够支持先进的多通道应用, 如多用户波束赋形技术和量子计算。

是德科技 5G 项目经理 Roger Nichols 表示: “研发工程师们一直在想方设法地推进技术发展, 实现新的性能水平。我们的新型高性价比 PXIe 解决方案不仅在性能上能够达到这些目标要求, 而且还能提供灵活的、更轻松的定制能力, 以便创建和处理实时和确定性信号。”

如需创建用于宽带通信系统的数字调制波形, 以及用于雷达和卫星测试的高分辨率波形, M9336A PXIe 任

意波形发生器是您的理想选择。它拥有多路独立或同步的信号输出, 并且在单插槽 PXIe 模块中提供了卓越的性能, 包括 16 位分辨率、高达 1 GHz 的调制带宽, 以及单独控制通道增益、偏置和偏移的能力。工程师可以使用 Signal Studio、MATLAB、Waveform Creator 或其他工具为任意波形发生器生成行业标准波形和自定义波形, 并轻松集成到多种应用开发环境中。

M9243A PXIe 示波器采用 Keysight InfiniiVision 示波器技术构建, 提供高达 1 GHz 的带宽, 可用于快速分析宽带信号并进行故障诊断。凭借每秒 1 000 000 个波形的更新速率和先进的探测技术, 示波器可以对随机和间歇性信号进行故障诊断, 而使用数字化仪技术很难看到这些信号。示波器的强大功能包括游标和标记、高级触发、波形平均、模板和 31 种可选的测量项目。如果将示波器与 89600 矢量信号分析仪软件结合使用, 工程师可以利用 1 GHz 完整带宽解调和评测复杂的 IQ 波形。

是德科技的维修周转时间短, 具有业界领先的校准能力, 核心交换策略和标准的三年保修, 都能最大限度地延长系统正常运行时间, 降低总体拥有成本。

关于 Keysight PXIe 仪器的更多信息, 请访问 www.keysight.com/find/pxi。产品图像可从 www.keysight.com/find/pxi-images 处获得。