



陈武选,任鹏辉,刘子煜,等. 基于 PSO-DBN-ELM 的管道流型辨识算法研究[J]. 矿业安全与环保,2024,51(2):146-152.
CHEN Wuxuan,REN Penghui,LIU Ziyu,et al. Research on pipeline flow pattern identification algorithm based on PSO-DBN-ELM[J]. Mining Safety & Environmental Protection,2024,51(2):146-152.
DOI: 10.19835/j.issn.1008-4495.20221099

扫码阅读下载

机电与智能化

基于 PSO-DBN-ELM 的管道流型辨识算法研究

陈武选¹,任鹏辉¹,刘子煜²,申昱瞳²,李明桥²,秦学斌²

(1. 韩城矿业有限公司,陕西 韩城 715499; 2. 西安科技大学,陕西 西安 710054)

摘要: 电容层析成像技术(Electrical Capacitance Tomography, ECT)是一种基于电容敏感场的过程层析成像技术,该技术通过传感器测量所需电容数据,实现充填管道流型检测,从而满足管道流型可控性。传统 ECT 流型辨识方法识别速率较低、运算较为复杂,成像结果也存在误差。为了改善传统方法存在的问题,提出一种基于粒子群优化算法(Particle Swarm Optimization, PSO)优化深度置信网络—极限学习机(Deep Belief Networks-Extreme Learning Machine, DBN-ELM)的流型识别算法,电容数据采集模块采集电容数据并制作相应数据集,经过 DBN 网络提取电容数据特征,在 DBN 网络顶层添加 ELM 完成对抽象电容流型数据的辨识;DBN 隐含层神经元个数影响着整个模型的学习能力和信息处理能力,因此引入 PSO 优化算法首先计算出每层玻尔兹曼机(Restricted Boltzmann Machine, RBM)的最优神经元个数。与其他流型辨识算法相比,所需时间短,成像效果较好,对加快工业智能化发展有着重要的意义。

关键词: 电容层析成像;充填管道;流型辨识;PSO;视觉检测;重构算法

中图分类号: TD853.34; TP18 **文献标志码:** A **文章编号:** 1008-4495(2024)02-0146-07

Research on pipeline flow pattern identification algorithm based on PSO-DBN-ELM

CHEN Wuxuan¹,REN Penghui¹,LIU Ziyu²,SHEN Yutong²,LI Mingqiao²,QIN Xuebin²

(1. Hancheng Mining Co., Ltd., Hancheng 715499, China;

2. Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: Electrical Capacitance Tomography (ECT) is a process tomography technique based on capacitance-sensitive field, which can achieve the flow pattern detection of filled pipes by measuring the required capacitance data with sensors to meet the controllability of pipe flow patterns. The traditional ECT flow pattern recognition method has the disadvantages of low recognition rate, more complicated operation and error in imaging effect. In order to solve the problems of traditional methods, this paper proposes a flow pattern recognition algorithm based on PSO (Particle Swarm Optimization) optimized DBN-ELM (Deep Belief Networks-Extreme Learning Machine), in which the capacitance data acquisition module collects data and creates the corresponding data set, extracts the capacitance data features through DBN network, and adds ELM at the top layer of DBN to identify the abstract capacitive data to complete the number of neurons in the hidden layer of DBN affects the learning ability and information processing ability of the whole model, so the PSO optimization algorithm is introduced to calculate the optimal number of neurons for each layer of Restricted Boltzmann Machine (RBM) first, which takes less time and has better imaging effect compared with other flow pattern recognition algorithms. It is of vital importance to accelerate the development of industrial intelligence.

Keywords: electrical capacitance tomography; filling pipeline; flow pattern identification; PSO; visual detection; reconstruction algorithm

收稿日期:2022-10-31;2024-01-25 修订

基金项目:国家自然科学基金项目(51904224);陕西省自然科学基金项目(2022JM-314)

作者简介:陈武选(1974—),男,陕西韩城人,硕士,高级工程师,主要从事机电装备研究与管理工作。E-mail: 2846459934@qq.com。

煤炭是我国的主要能源。煤炭开采使地下应力发生变化,导致原有煤岩层、土层出现位移和变形,这些地下空间的改变和破坏会直接传导至地面,引发地表沉降、河流改道、房屋损伤、建筑物倒塌等一系列较为严重的问题。为了防止煤炭开采后地面出现塌陷,需要对采空区进行充填,其中膏体充填是一种有效的充填方法^[1-3]。膏体材料主要由粉煤灰、水泥、矸石等结合其他化学试剂等多种材料混合制成^[4],由于混合后的料浆颗粒大、黏稠性高,往往存在充填管道被堵塞的隐患,若不及时处理堵塞部位管道则会发生爆裂,造成巨大损失。因此,需要对充填管道内部流型有一个较为清晰的判断,通过多相流检测技术定量判断管道内充填流体的特征。流型是管道内流体运动变化时的主要特征信息,也是多相流检测工作中亟待解决的问题^[5]。但由于多相流运动时存在随机变化的相截面,导致相流流型复杂多样,典型的流型包括心流、泡流、层流等,流型辨识难度较大。

近年来,随着深度学习技术的快速发展,数据的特征提取更为高效且快速,通过神经网络模型提取数据特征向量^[6-7],可以有效避免相流之间由于相互作用所产生的影响,并便于在众多特征中抽象出合适的特征向量。目前,国内结合深度学习模型对流型数据进行特征提取的相关研究较少,需要寻找和尝试新的辨识方法应用在充填管道流型辨识领域,从而补充和完善流型辨识手段。

1 ECT 系统理论基础及实验平台

一般情况下 ECT 系统涵盖了电容传感器、电容采集模块、成像计算机模块,传感器阵列根据应用场景不同分为 6 极板、8 极板、12 极板和 16 极板等。笔者采用 12 极板系统,将 12 个电极板均匀分布在待测管道周围,任意 2 个电极板可以构成 1 个电容,如图 1 所示,以 12 个电极中的任意一个为 1 号电极板,依次顺时针为其余 11 个电极板编号,即分别为 2, …, 12 号电极板。

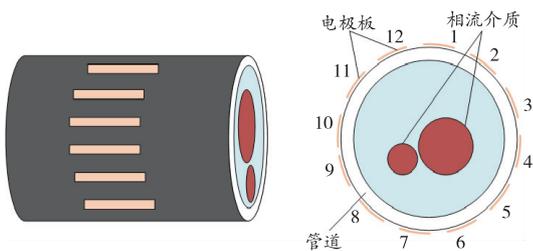


图 1 电容传感器阵列安装示意图

Fig. 1 Capacitance sensor array installation diagram

第一圈测量以 1 号电极板为激励极板,分别与

另外 11 个电极板形成电容,即电极对 1-2, 1-3, …, 1-12, 测量 11 个电容数据值;第二圈以 2 号电极板为激励极板,分别与另外 10 个电极板形成电容,即电极对 2-3, 2-4, …, 2-12。以此类推,直至完成 11-12 电极对的电容数据测量,共测得 66 组独立投影数据。图 2 为极板激励示意图,其中 V_0 表示激励电压, φ 表示极板电势。

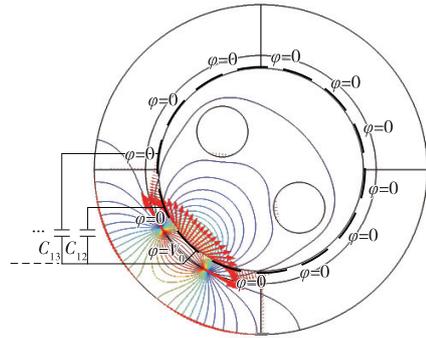


图 2 极板施加激励示意图

Fig. 2 Diagram of plate excitation

每对电极构成的测量电容狭窄区域一般称之为正灵敏区。每个电极对之间的电容值测量原理是对管道横截面的多相流体进行扫描,正灵敏区可被视为扫描区域。测量得到的电容数据就是管道内多相流体在某个电极对角度的投影数据,完成一次管道横截面的扫描即可从 66 个方向对管道横截面的多相流体进行测量,每个测量数据反映相应测量电容正灵敏区域内介质分布的信息。

在 COMSOL Multiphysics 软件中对电容传感器进行仿真实验,12 电极 ECT 传感器在 COMSOL Multiphysics 有限元软件中的仿真模型如图 3 所示。将电极板与管道完美贴合,最外层添加屏蔽罩始终接地,以起到屏蔽外界干扰的作用。管道材料选用材料库中 Glass,相对介电常数为 5.0;介质 1 选用材料库中 Air,相对介电常数为 1.0;介质 2 选用混合材料,相对介电常数为 4.2。

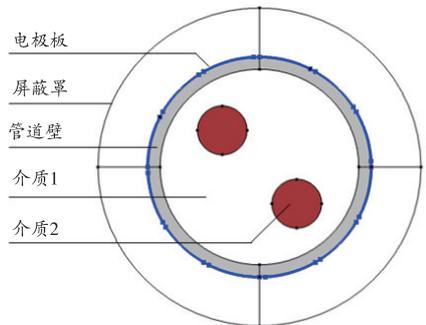
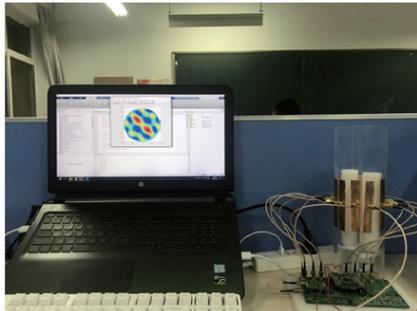


图 3 12 电极 ECT 传感器仿真模型

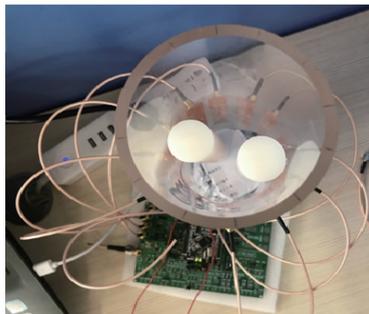
Fig. 3 12-electrode ECT sensor simulation model

依据 COMSOL 有限元仿真模型设计 ECT 静态系统,管道采用亚克力材质定制,传感器采用厚度

0.01 mm 的铜箔通过金属导电胶粘贴在管道周围,导线采用 SMA 屏蔽线连接至电容采集模块。以双泡流为例,在传感器内用 2 根聚酰胺纤维棒模拟双泡流,通过电容采集模块采集双泡流电容数据,电容数据由 USB 串口传输至上位机。ECT 静态实验系统如图 4 所示。



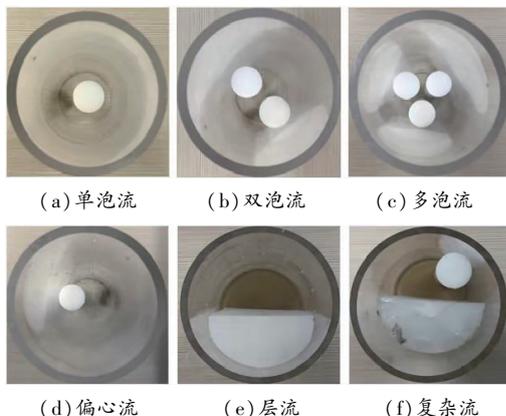
(a) 上位机



(b) 传感器

图 4 ECT 静态实验系统
Fig. 4 ECT static experimental system

将聚酰胺纤维棒放置于管道内不同位置模拟多相流的不同流型,通过 ECT 静态实验系统分别测量不同模拟流型电容数据。本次实验主要模拟多相流流型中的单泡流、双泡流、多泡流、偏心流、层流及复杂流。静态实验中各流型测量如图 5 所示。



(d) 偏心流 (e) 层流 (f) 复杂流

图 5 各流型测量示意图
Fig. 5 Flow pattern measurement diagram

采用 Landwber 图像重建算法的成像图如图 6 所示。

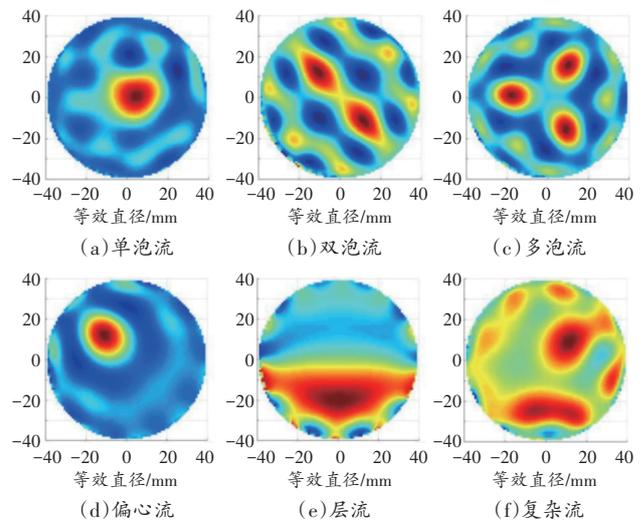


图 6 各流型重建图像
Fig. 6 Reconstruction images of each flow

由图 6 可见,对于简单流型,经过图像重建可以更清楚、更精确地展示流型的位置和大小。然而,在复杂流型的图像重建中,尤其是尾影部分,与其他流型相比,其位置和大小确认的准确性有所下降。这主要是因为复杂流型的各个相之间的间隙较小,导致电容值的变化不够明显,从而影响图像重建的准确性。整体看来,设计系统表现出了良好的性能,满足流型辨识的基本要求。

2 基于 PSO-DBN-ELM 的管道流型辨识

电容层析成像管道流型辨识主要分为两部分:一部分为下位机采集管道流型电容数据;另一部分为将采集到的数据发送至上位机通过特定的方法对管道流型进行辨识。管道流型辨识可对流型做出提前控制及调整,从而保证充填过程的安全。ECT 流型识别方法主要有 2 种:其一,通过图像重建方法进行流型辨识;其二,运用神经网络“黑箱”模型对输入数据特征进行提取实现流型辨识^[6-7]。由于后者无需进行复杂的运算及成像过程,因此在流型辨识速度上有较大的优势,同时是一种较为便捷的流型辨识方法。通过对比目前管道流型辨识方法并结合机器学习技术现状,考虑管道流型的多变性、复杂性,以及辨识的实时性,提出建立深度置信网络—极限学习机(Deep Belief Networks-Extreme Learning Machine, DBN-ELM)流型辨识模型。

2.1 DBN 网络对电容数据的特征提取

结合 ECT 系统数据的非线性及复杂性的特点,选用深度置信网络(Deep Belief Networks, DBN)作为充填管道流型辨识模型。DBN 模型的训练实质是受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)的训练^[8-9],主要分为两步:进行基于 RBM 的无监

督预训练,逐层充分训练,重复任意多次完成无监督训练步骤;有监督的反向调参,在顶层 RBM 的训练结束后添加分类模型,通过有标签数据实现对模型辨识效果的判定。将 RBM 网络堆叠实现 DBN 网络搭建,Hinton 在 2002 年发明了对比散度算法,并且该算法成为训练 RBM 的标准算法。通过对比散度(Contrastive Divergence, CD)算法对模型进行初始化训练^[10],采用非监督贪婪逐层方法预训练网络从而获得网络权值。

无监督训练过程主要有以下几个步骤:

1) 初始化参数:训练集数据 x , 可见层 v , 可见层偏置值 b , 隐含层 h , 隐含层偏置值 c , 可见层和隐含层之间的权重 w , 学习率 η , 隐含层神经元个数 y , 可见层神经元个数 k , 激活函数 sigmoid。

2) 计算隐含层中各神经被激活的概率:

$$P(h_j^1 = 1 | v^1) = \text{sigmoid}(c_j + \sum v_i^1 w_{ij}) \quad (1)$$

3) 计算可见层各神经被激活的概率:

$$P(v_i^2 = 1 | h^1) = \text{sigmoid}(b_i + \sum h_j^1 w_{ji}) \quad (2)$$

4) 计算下一层各隐含层神经被激活的概率:

$$P(h_j^2 = 1 | v^1) = \text{sigmoid}(c_j + \sum v_i^1 w_{ij}) \quad (3)$$

5) 更新参数:

$$\bar{w} = w + \eta [P(h^1 = 1 | v^1) (v^1)^T - P(h^2 = 1 | v^2) (v^2)^T] \quad (4)$$

$$\bar{b} = b + \alpha (v^1 - v^2) \quad (5)$$

$$\bar{c} = c + \beta [P(h^1 = 1 | v^1) - P(h^2 = 1 | v^2)] \quad (6)$$

6) 重复以上步骤直到迭代完成,逐层训练 RBM,完成 DBN 网络的构建。

综上所述,将 ECT 系统下位机采集到的电容数据以向量的形式传输到可见层,RBM 根据公式(1)计算出每层隐含层神经被激活的概率,随意抽取(0,1)之间的数作为激活阈值,大于该值则隐含层神经被激活,小于该值则不被激活。每个 RBM 训练完成后,可以从原始信号中逐层提取深度特征,实现抽象表达。经过迭代训练后,隐含层抽象出的数据特征,通过底层 RBM 模型实现原始数据的降维,当隐含层神经个数小于可见层神经个数时,则产生“数据压缩”,类似于自动编码器。

2.2 基于 DBN-ELM 的辨识模型构建及优化

由于传统的 DBN 模型顶层采用反向传播 BP 神经网络作为分类器,在理论上 BP 神经网络拥有实现复杂非线性映射的能力,但是在实际解决问题时存在些许不足,例如网络结构选择不一、容易陷入局部最优、样本依赖性强、收敛速度慢等。为了解决 BP 神经网络的不足,将顶层 BP 神经网络替换为极限学习机(Extreme Learning Machine, ELM)网络,避免参数的微调、容易陷入局部最优、收敛速度慢、辨识能

力差等诸多问题^[11-12]。

DBN-ELM 网络模型分为两部分:其一为 DBN 网络模型,其作用是提取下位机测量到的多种流型电容数据特征;其二为将抽象后的特征数据传输至顶层 ELM 网络,进行数据分类辨识。该方法同时具备 DBN 无监督学习数据特征,以及 ELM 学习速度快并且泛化能力强等特点,可提高模型的训练速度及辨识的准确性。设 n 代表整个网络模型的隐含层数目,假设 DBN 隐含层截至第 $n-1$ 层,顶层分类器 ELM 则由第 n 层隐含层表示,ELM 的输入层由 DBN 网络的最后一层隐含层构成,输出层为第 n 层隐含层,如图 7 所示。

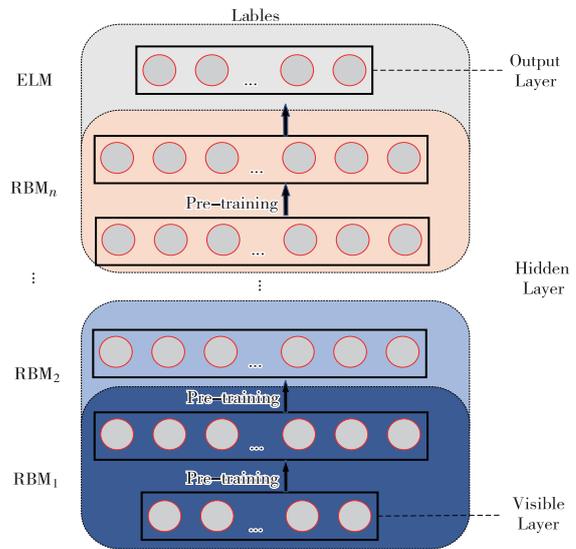


图 7 ELM-DBN 模型结构图

Fig. 7 ELM-DBN model structure diagram

在确定了 DBN-ELM 网络模型的隐含层数 n 后,先通过无监督训练的方式训练 DBN 模型部分,再计算出 ELM 模型的输出层的权重和偏置。将该网络表示如下:

$$\sum_{i=1}^N \beta_i g(w_i h_{n-1} + b_i) = o_j, j = 1, 2, \dots, M \quad (7)$$

式中: $g(x)$ 为激活函数; w_i, b_i 分别为第 $n-1$ 个隐含层到第 n 个隐含层的权重和偏置; β_i 为第 n 层隐含层到输出层的权重; h_{n-1} 为第 $n-2$ 层隐含层到第 $n-1$ 层隐含层的输出; M 为第 $n-1$ 层隐含层神经元个数; N 为第 n 层隐含层神经元个数。

最小输出误差可表示如下:

$$\left\{ \begin{array}{l} \sum_{j=1}^M \| o_j - t_j \| = 0 \\ t_j = \sum_{i=1}^N \beta_i h_{nj}, j = 1, 2, \dots, M \end{array} \right\} \quad (8)$$

最终问题转化为求 $h_n \beta = T$,其中 h_n 为第 $n-1$ 层隐含层到第 n 层隐含层的输出:

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}, T = \begin{bmatrix} T_1^T \\ \vdots \\ T_N^T \end{bmatrix} \quad (9)$$

$$h(w_1, w_2, \dots, w_N, b_1, b_2, \dots, b_N, h_{(n-1,1)}, h_{(n-1,2)}, \dots, h_{(n-1,m)}) = \begin{bmatrix} g(w_1 h_{(n-1,1)} + b_1) & \dots & g(w_N h_{(n-1,1)} + b_N) \\ \vdots & & \vdots \\ g(w_1 h_{(n-1,m)} + b_1) & \dots & g(w_N h_{(n-1,m)} + b_N) \end{bmatrix} \quad (10)$$

问题的求解等价于求解 w_i, b_i, β , 即:

$$\|h_n(w_i, b_i)\beta - T\| = \min_{w, \beta} \|h_n(w_i, b_i)\beta - T\| \quad (11)$$

根据 ELM 算法, 第 $n-1$ 层隐含层到第 n 层隐含层权重 w_i 和偏置 b_i , 通过随机初始化可得到唯一的输出矩阵 h_n , 将 DBN-ELM 模型的训练结果最终等效成了线性系统问题 $h_n \beta = T$ 的求解, 则:

$$\beta = h_n^+ T \quad (12)$$

2.3 引入 PSO 算法优化 DBN-ELM 模型

如果 DBN 中 RBM 的隐含层神经元个数过少, 则网络不具有必要的学习能力和信息处理能力^[13-15]; 反之, 若过多, 则不仅会大大增加网络结构的复杂性, 网络在学习过程中更易陷入局部极小点, 而且会使网络的学习速度变得很慢。因此, 隐含层神经元个数的选择问题一直受到神经网络研究工作者的重视^[15-18]。在 RBM 中的可见层的神经元个数由输入数据的维度所确定, 而隐含层的神经元个数可以根据实验设置或者通过智能算法寻找出最优个数。通过引入 PSO 寻找 RBM 各隐含层的神经元个数。PSO 算法在众多智能算法中有计算速度快、更好的全局搜索能力, 更符合 ECT 充填管道实时预测流型的短时间要求, 同时 PSO 算法需要调节的参数少, 更易实现。PSO 优化 DBN-ELM 的流程如下:

1) 初始化 PSO 参数, 群体大小、最大迭代次数、粒子速度和粒子位置范围。设定群体大小为 20, 最大迭代次数为 10。

2) 建立适应度函数。根据适应度函数计算各个粒子的适应度值, 求出个体和群体的极值。设定适应度函数:

$$F = \frac{\sum_{i=1}^K \sum_{j=1}^L (t_{ij} - p_{ij})^2}{10} \quad (13)$$

式中: t_{ij} 为第 j 个测试集的实际值; p_{ij} 为模型重构值; K 为数据多折交叉验证次数; L 为测试集的数据个数。

3) 比较每个粒子的适应度值和个体极值 (P_{best}), 若适应度值大于极值则将粒子适应度值替换为个体极值, 反之则保持不变。

4) 比较每个粒子的极值和当前种群极值 (G_{best}), 若粒子极值大于当前种群极值, 则将粒子极值替换

为当前种群极值, 反之则保持不变。

5) 更新粒子的速度及位置:

$$V_i^{k+1} = \omega V_i^k + c_1 r_1 (X_{P_{best}}^k - X_i^k) + c_2 r_2 (X_{G_{best}}^k - X_i^k) \quad (14)$$

$$X_i^{k+1} = X_i^k + V_i^{k+1} \quad (15)$$

式中: ω 为惯性权重, $\omega = 0.9$; c_1, c_2 为学习因子, 取值为 2; r_1, r_2 为 0~1 内的随机数。

6) 判断迭代是否终止。当迭代次数达到设定值, 或种群极值变化足够小时, 停止迭代。

将 PSO 最终优化群体极值作为隐含层神经元个数。通过优化得到的 4 层 RBM 隐含层神经元个数分别为 39、42、33、28。

3 基于 PSO-DBN-ELM 辨识方法的实现与验证

将不同形状的聚酰胺纤维棒放在不同位置、变换管道中聚酰胺纤维棒个数, 通过多次训练制作数据集。制作 600 个训练数据共 4 类, 其中包括: 150 个单泡流电容数据; 150 个双泡流电容数据; 150 个多泡流电容数据; 150 个层流电容数据。从 600 个数据集中抽取 120 个作为测试集 (每个类别 30 个)。每个样本的 66 个电容数据作为模型的输入, 4 种流型类别的输出分别对应编号为 1、2、3、4。

首先需要确定 DBN 网络模型的隐含层数量及每层神经元个数, 这些参数影响模型的收敛性和性能等, 对确保模型辨识的准确性至关重要。隐含层的层数越多模型越复杂, 数据特征提取能力越强, 但计算时间会增加, 且容易造成误差累积。隐含层神经元任务是对输入数据进行特征抽象, 同时学习输入数据特征, 因此当隐含层神经元个数不足, 输入数据特征抽象能力较差, 会直接影响输出辨识精度; 反之, 如果神经元个数过多, 模型训练时间则会相应增加, 容易造成过拟合问题。

DBN 模型隐含层不同层数对辨识结果的影响如图 8 所示。实验过程分别选取隐含层数量 3、4、5、6 层作为对比, 每层神经元个数设置为 50, 迭代次数设置为 200, 学习率设置为 0.001。

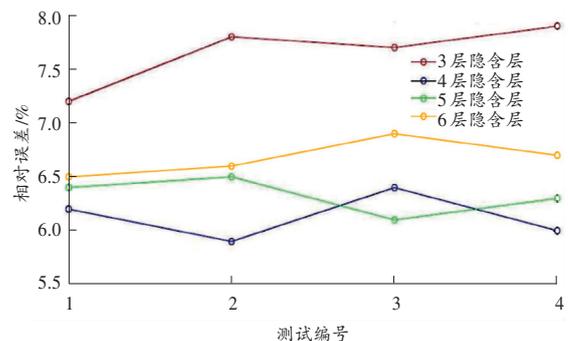


图 8 不同层数隐含层辨识误差
Fig. 8 Identification error of different hidden layers

由图 8 可见,当隐含层数量超过 4 层后,辨识误差趋于稳定,变化较小,且过多的层数会导致模型搭建复杂度加大,训练时间增加,因此设定隐含层层数为 4。

为验证优化隐含层神经元个数方法的有效性,开展实验对比由 PSO 优化算法和经验法计算得出的神经元个数对辨识准确率的影响,实验包括手动设置神经元个数和 PSO 自动设置神经元个数,结果见表 1。可以看出,经过 PSO 优化后神经元个数在辨识精度上有较好的效果。

表 1 隐含层不同神经元个数辨识准确率
Table 1 Identification accuracy rate of different neuron numbers in hidden layer

方法	训练集数量	测试集数量	隐含层结构	平均辨识准确率/%
PSO-DBN-ELM	600	120	89-103-94-43	97.5
经验法	600	120	55-65-33-24	95.7
经验法	600	120	95-110-70-65	93.6
经验法	600	120	20-30-42-22	92.5

因此最终模型结构定为 66-89-103-94-43。而对于顶层的极限学习机的隐含层则根据 Kolmogorov 中的定义可得,极限学习机的输入层神经元数目(k)和输出层神经元数目(m)之间的数学表达式为 $k=2m+1$,因此,极限学习机的隐层神经元数为 $2 \times 43 + 1 = 87$ 。

由表 1 可见,隐含层神经元个数和辨识准确率并非呈正相关关系,在实际辨识中,模型会随着神经元个数的增多其训练时间增加,因此选择合适隐含层神经元个数极为重要。模型整体参数见表 2。

表 2 模型整体参数
Table 2 Overall model parameters

PSO-DBN-ELM 参数名称	参数值
输入层神经元个数	66
隐含层 1 神经元个数	89
隐含层 2 神经元个数	103
隐含层 3 神经元个数	94
隐含层 4 神经元个数	43
ELM 隐含层神经元个数	87
输出层神经元个数	4

通过表 2 确定了模型层数及神经元个数后,将训练集输入到优化后的 DBN 网络。

为了进一步证明模型性能,将所提出的算法与基于 ELM、DBN-BP 算法的流型辨识准确率进行对

比,结果见表 3。

表 3 流型辨识准确率
Table 3 Flow pattern identification accuracy rate

流型	辨识准确率/%		
	ELM	DBN-BP	PSO-DBN-ELM
单泡流	94.10	96.60	97.50
双泡流	93.70	94.60	95.00
多泡流	91.50	92.40	93.20
层流	93.90	94.50	98.60
平均	93.30	94.80	96.15

由表 3 可见,3 种方法都具有较高的辨识准确率,但基于 PSO-DBN-ELM 算法模型的管道流型辨识准确率最优。

综上所述,所提出的方法虽然有较好的管道流型辨识率,但依然存在误差。其原因是电容数据值较小,受外界干扰较大,在电容数据中可能会出现不确定的杂散电容或者其他导致电容数据波动,从而影响最终的辨识精度。

4 结论

提出了基于 PSO 优化 DBN-ELM 的管道流型辨识算法。通过下位机采集到电容数据并将其制作成数据集,其中包含单泡流、双泡流、多泡流、层流 4 种流型,经过 DBN 网络提取电容数据特征,在 DBN 网络顶层添加 ELM 分类器完成对抽象电容数据的辨识;引入 PSO 优化算法计算出每层 RBM 的最优神经元个数,与经验法设置神经元个数相比,所需时间短且准确率较高。

参考文献 (References):

- [1] 高小艳. 煤矿采空区粉煤灰膏体充填材料性能实验研究[D]. 廊坊: 华北科技学院, 2021.
- [2] 刘鹏亮. 矽石充填材料应力应变特征实验研究[J]. 矿业安全与环保, 2019, 46(4): 13-16.
LIU Pengliang. Experimental study on stress-strain characteristics of gangue filling materials [J]. Mining Safety & Environmental Protection, 2019, 46(4): 13-16.
- [3] 刘东海, 邓念东, 姚婷. 潞安矿区煤炭开采沉陷主要控制因素分析[J]. 矿业安全与环保, 2020, 47(5): 103-107.
LIU Donghai, DENG Niandong, YAO Ting. Analysis of main control factors of coal mining subsidence in Lu'an mining area [J]. Mining Safety & Environmental Protection, 2020, 47(5): 103-107.
- [4] 林庆博. 煤矿采空区粉煤灰膏体充填材料配比试验研究[D]. 包头: 内蒙古科技大学, 2020.
- [5] OKORO E E, RACHAEL J E, SANNI S E, et al. Liquid holdup measurement in crude oil transportation using capacitance sensors and electrical capacitance tomography: Concept review [J]. IOP Conference Series: Earth and Environmental Science, 2021, 655(1): 012037.

- [6] 陈宇,许莉薇,黄仲洋,等. SADE-ELM 电容层析成像流型辨识算法[J]. 哈尔滨理工大学学报,2014,19(6):32-37.
CHEN Yu, XU Liwei, HUANG Zhongyang, et al. A self-adaptive different evolution extreme learning algorithm for electrical capacitance tomography system[J]. Journal of Harbin University of Science and Technology, 2014, 19(6): 32-37.
- [7] 张立峰,朱炎峰. 基于 MO-PLP-ELM 及电容层析成像的两相流流型辨识[J]. 计量学报,2021,42(3):334-338.
ZHANG Lifeng, ZHU Yanfeng. Identification of two-phase flow based on MO-PLP-ELM and electrical capacitance tomography[J]. Acta Metrologica Sinica, 2021, 42(3): 334-338.
- [8] 张立峰,佟彤. 基于 GA-ELM 及电容层析成像的两相流流型辨识[J]. 电力科学与工程,2020,36(8):37-41.
ZHANG Lifeng, TONG Tong. Identification of two-phase flow based on genetic algorithm-extreme learning machine and electrical capacitance tomography[J]. Electric Power Science and Engineering, 2020, 36(8): 37-41.
- [9] 胡叶容. 基于 GA-BP 神经网络的电容层析成像图像重建[J]. 电子技术与软件工程,2018(23):83-84.
HU Yerong. Image reconstruction of electrical capacitance tomography based on GA-BP neural network[J]. Electronic Technology & Software Engineering, 2018(23): 83-84.
- [10] 陈霄,居荣. 基于 PSO-DBN 的配电网单相接地故障选线方法[J]. 电工技术,2021(5):29-31.
CHEN Xiao, JU Rong. Single phase ground fault line selection method in distribution network based on PSO-DBN[J]. Electric Engineering, 2021(5): 29-31.
- [11] 曹琦. 基于 DBN-ELM 的脑血管病复发预测系统的研究[D]. 北京:北京交通大学,2020.
- [12] 魏思政,刘厚泉,赵志凯. 基于 DBN-ELM 的入侵检测研究[J]. 计算机工程,2018,44(9):153-158.
WEI Sizheng, LIU Houquan, ZHAO Zhikai. Research on intrusion detection based on DBN-ELM[J]. Computer Engineering, 2018, 44(9): 153-158.
- [13] WANG L L, LIU X, CHEN D Y, et al. ECT image reconstruction algorithm based on multiscale dual-channel convolutional neural network[J]. Complexity, 2020: 4918058.
- [14] 张立峰,王化祥. 基于 SVM 及电容层析成像的两相流流型识别[J]. 仪器仪表学报,2009,30(4):812-816.
ZHANG Lifeng, WANG Huaxiang. Identification of two-phase flow regime based on support vector machine and electrical capacitance tomography technique[J]. Chinese Journal of Scientific Instrument, 2009, 30(4): 812-816.
- [15] PELEGRINA G D, DUARTE L T, ROMANO J M T. Application of independent component analysis and TOPSIS to deal with dependent criteria in multicriteria decision problems[J]. Expert Systems with Applications, 2019, 122(C): 262-280.
- [16] TIAN W B, SUO P, LIU D, et al. Simultaneous shape and permittivity reconstruction in ECT with sparse representation: Two-phase distribution imaging[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 4500414.
- [17] 魏鹏飞,樊小朝,史瑞静,等. 基于改进麻雀搜索算法优化支持向量机的短期光伏发电功率预测[J]. 热力发电,2021,50(12):74-79.
WEI Pengfei, FAN Xiaochao, SHI Ruijing, et al. Short-term photovoltaic power generation forecast based on improved sparrow search algorithm optimized support vector machine[J]. Thermal Power Generation, 2021, 50(12): 74-79.
- [18] WANG M, LIU P, SHANG S Y, et al. Numerical and experimental studies on the cooling performance of backfill containing phase change materials[J]. Building and Environment, 2022, 218: 109155.

(责任编辑:熊云威)

=====

(上接第 145 页)

- [16] 潘思东,崔周达. 山西沁水盆地南部煤层气储层特征及成藏主控因素研究[J]. 煤矿开采,2016,21(6):11-14.
PAN Sidong, CUI Zhouda. Accumulation main control factors and reservoir characters of coalbed gas in southern part of Qinshui Basin of Shanxi Province[J]. Coal Mining Technology, 2016, 21(6): 11-14.
- [17] 高玉巧,李鑫,何希鹏,等. 延川南深部煤层气高产主控地质因素研究[J]. 煤田地质与勘探,2021,49(2):21-27.
GAO Yuqiao, LI Xin, HE Xipeng, et al. Study on the main controlling geological factors of high yield deep CBM in Southern Yanchuan Block[J]. Coal Geology & Exploration, 2021, 49(2): 21-27.
- [18] 陆小霞,张兵,吴见,等. 柿庄北区块深部煤层气产能特征及影响因素分析[J]. 煤炭科学技术,2018,46(6):92-100.
LU Xiaoxia, ZHANG Bing, WU Jian, et al. Analysis on production features and influence factors of coalbed methane in deep section of North Shizhuang Block[J]. Coal Science and Technology, 2018, 46(6): 92-100.
- [19] 韦涛,张争光,牛志刚,等. 深部与浅部煤层气储层物性及开发工程差异分析[J]. 煤炭技术,2018,37(2):58-60.
WEI Tao, ZHANG Zhengguang, NIU Zhigang, et al. Analysis of physical properties and engineering difference between deep coal seam and shallow coal seam[J]. Coal Technology, 2018, 37(2): 58-60.
- [20] 姚成林,熊云威,宋春香. 煤层气地面开发及利用趋势探讨[J]. 矿业安全与环保,2017,44(6):79-82.
YAO Chenglin, XIONG Yunwei, SONG Chunxiang. Discussion on surface exploitation and utilization trend of coalbed methane[J]. Mining Safety & Environmental Protection, 2017, 44(6): 79-82.

(责任编辑:樊淑兰)