

DOI:10.19651/j.cnki.emt.2005435

# 基于栈式混合编码器的水质传感器数据融合算法\*

王照丽<sup>1</sup> 杨一伟<sup>2</sup> 黄凤辰<sup>2</sup> 肖 坚<sup>2</sup> 徐立中<sup>2</sup>

(1.成都市环境保护科学研究院 成都 610072; 2.河海大学 计算机与信息学院 南京 211100)

**摘要:** 由于浅层神经网络网络结构和训练方式的限制,网络学习能力和泛化能力在大样本条件下没有深度学习网络强,为此,提出了一种基于栈式混合编码器的水质传感器数据融合算法。该算法通过堆叠自动编码器和稀疏自动编码器形成深度学习网络模型,实现对样本数据的特征挖掘和稀疏表示。经过大规模样本训练后的网络模型能够拟合复杂非线性函数,对低质量的样本数据有一定的泛化能力,并提高预测分类的精度。仿真结果证明,提出的算法取得了更高的评价分类准确率。

**关键词:** 水质传感器;数据融合;栈式混合编码器;非线性函数;评价分类

**中图分类号:** TP391 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Data fusion algorithm of water quality sensor based on stack hybrid encoder

Wang Zhaoli<sup>1</sup> Yang Yiwei<sup>2</sup> Huang Fengchen<sup>2</sup> Xiao Jian<sup>2</sup> Xu Lizhong<sup>2</sup>

(1.Chengdu Academy of Environmental Sciences, Chengdu 610072, China;

2.School of Computer and Information, Hohai University, Nanjing 211100, China)

**Abstract:** Due to the limitation of network structure and training mode for shallow neural network, network learning ability and generalization ability are weaker than deep learning network under large sample conditions. Therefore, a data fusion algorithm of water quality sensor based on stacked hybrid encoder is proposed. The algorithm forms a deep learning network model by stacking automatic encoder and sparse automatic encoder, which realizes the feature mining and sparse representation of sample data. The network model can fit the complex nonlinear function after large-scale sample training, and has generalization ability for low quality sample data. It can improve the accuracy of prediction classification. Simulation results show that the proposed algorithm achieves higher classification accuracy.

**Keywords:** water quality sensor; data fusion; stacked hybrid encoder; nonlinear function; evaluation classification

### 0 引言

水资源控制着生态环境的变化和国家经济发展,当前面临着恶化和污染等问题,所以需要在水资源进行水质监测,为水资源的水质评价、预测提供参考性数据和基本手段。根据水质监测系统中传感器检测的数据特点,引入数据融合技术,对其进行多源的数据融合处理,得到综合性的评价结果,能够为维护和管理当前水质状况提供了重要依据。因此为了更好的对水资源进行水质监测和保护,探究水质传感器的数据融合算法具有重大意义。

近年来水质传感器数据融合领域取得了一些研究成果。Du等<sup>[1]</sup>提出一种聚类灰色融合的预测模型对水质浊度的变化趋势进行预测,该模型采用聚类融合方法和灰色

预测算法对传感器所采集的数据进行处理,将聚类融合处理后的数据作为灰色预测控制的输入数据,灰色预测控制的输出数据与融合数据进行对比分析,确定预测浊度值。Najah等<sup>[2]</sup>基于WQP的数据融合模块,提出了基于神经模糊推理系统(WDT-ANFIS)的增强小波去噪技术,该技术可对含噪声的水质数据进行融合处理,对水质参数进行预测,有助于决策者报告水质状况。He等<sup>[3]</sup>提出了基于自回归模型和模糊C均值聚类相结合的融合算法,对多种传感器监测的水质指标进行融合来检测水质异常。Taormina等<sup>[4]</sup>使用深度学习模型对管网供水系统遭受的物理攻击进行检测,传感器数据用来训练自动编码器,从而对网络状态进行映射,使整个模型对攻击过程中记录的传感器数据敏感。

收稿日期:2020-11-25

\* 基金项目:广东省水利科技创新项目(2020-04)资助

深度学习不仅可构造出并行处理信息的网络模型,而且具有自组织性和自适应性强、鲁棒性好等突出特点,这对于处理水质传感数据含不完全信息和有噪声问题具有其优越性,能够很好地实现水质数据融合。因此本文利用深度学习在大样本数据优势下能使用深层网络拟合复杂非线性函数,提出了基于栈式混合编码器的水质传感器数据融合算法。仿真实验证明提出算法对水质传感器数据评价分类取得更好的效果。

## 1 水质因子和分类标准

### 1.1 水质因子选取

指明水质状况的标准有单项指标和综合指标之分,本文通过融合多种类型水质传感器测量的数据来获得综合指标,实现对水质评价分类。本文研究的数据来源于浙江省地表水水质自动监测数据系统,选取总磷、溶解氧、氨氮和高锰酸钾作为 4 个融合因子。

### 1.2 水质分类标准

本文采用的分类标准基于《地表水环境质量标准》(GB 3838-2002),根据地面水使用目的和保护目标,地面水可分为 5 大类,每一类对应相应的功能和用途。地表水每一个基本项目的标准值分为 5 类,不同的功能类别执行对应类别的标准值。本文采用的融合因子总磷、溶解氧、氨氮和高锰酸钾的标准限值如表 1 所示。

表 1 地表水环境质量标准

参数	类别				
	I	II	III	IV	V
总磷	0.02	0.1	0.2	0.3	0.4
溶解氧	7.50	6.0	5.0	3.0	2.0
氨氮	0.15	0.5	1.0	1.5	2.0
高锰酸钾	2.00	4.0	6.0	10.0	15.0

将此标准作为多水质传感器数据融合的基础标准,并且每一类别对应神经网络的一个输出单元。

## 2 基于栈式混合编码器的水质传感器数据融合算法

利用深度学习在大样本数据优势下能使用深层网络拟合复杂非线性函数,提出了基于栈式混合编码器的水质传感器数据融合算法。

### 2.1 自动编码器

Rumelhart 等<sup>[5]</sup>在 1986 年首次提出了自动编码器(AutoEncoder, AE),并将其用于高维复杂数据处理,促进了神经网络的发展。自动编码器是一种无监督的学习算法,作为深度学习的重要组成部分,被广泛的应用到许多研究领域<sup>[6]</sup>。

#### 1) 自动编码器

自动编码器是由输入层、隐藏层和输出层组成的典型

3 层对称神经网络,输入层与隐藏层之间的作用是对输入数据样本进行编码,隐藏层与输出层之间主要作用是对隐藏层输出数据进行解码。自动编码器的网络结构如图 1 所示。

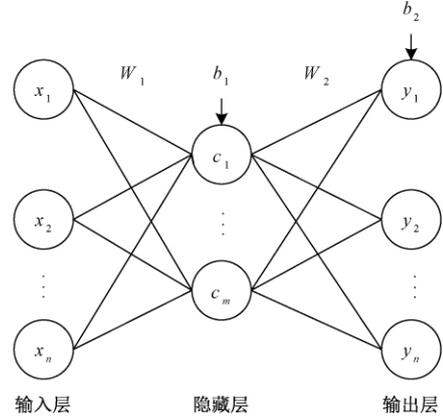


图 1 数据集样本

输入层到隐藏层为编码过程,实现输入  $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$  到隐藏层输出  $\mathbf{C} = [c_1, c_2, \dots, c_m]^T$  的映射转换,编码函数如式(1)所示。

$$\mathbf{C} = f_{\theta_1}(\mathbf{X}) = s_f(\mathbf{W}_1\mathbf{X} + \mathbf{b}_1) \quad (1)$$

式中:模型参数  $\theta_1 = \{\mathbf{W}_1, \mathbf{b}_1\}$ ;  $s_f$  为编码器的激活函数,一般为 sigmoid 函数或者 tanh 函数;  $\mathbf{W}_1$  为  $m \times n$  维的权值矩阵;  $\mathbf{b}_1$  为  $m$  维的偏移向量。

隐含层到输出层的解码过程,实现隐藏层输出表征  $\mathbf{C}$  逆向映射回  $n$  维输入空间,得到重构输出  $\mathbf{Y} = [y_1, y_2, \dots, y_n]^T$ ,解码函数为:

$$\mathbf{Y} = g_{\theta_2}(\mathbf{C}) = s_g(\mathbf{W}_2\mathbf{C} + \mathbf{b}_2) \quad (2)$$

式中:模型参数  $\theta_2 = \{\mathbf{W}_2, \mathbf{b}_2\}$ ;  $s_g$  为解码器的激活函数,一般为 sigmoid 函数或者恒等函数;  $\mathbf{W}_2$  为  $n \times m$  维的权值矩阵;  $\mathbf{b}_2$  为  $n$  维的偏移向量。式(1)和(2)中权值矩阵参数  $\mathbf{W}_1$  和  $\mathbf{W}_2$  满足  $\mathbf{W}_2 = \mathbf{W}_1^T$  的关系,因此自动编码器需要求解的参数为  $\theta = \{\mathbf{W}_1, \mathbf{b}_1, \mathbf{b}_2\}$ 。

输出层的输出  $\mathbf{Y}$  可看作是对输入数据  $\mathbf{X}$  的预测,自动编码器算法通过使输出  $\mathbf{Y}$  尽可能接近输入  $\mathbf{X}$  来训练整个网络参数。可以用重构误差函数  $L(\mathbf{X}, \mathbf{Y})$  来表示  $\mathbf{Y}$  与  $\mathbf{X}$  的接近程度,当  $s_g$  为 sigmoid 函数时,选用交叉熵(cross-entropy)作为误差函数,则重构误差函数为:

$$L(\mathbf{X}, \mathbf{Y}) = - \sum_{i=1}^n [x_i \ln(y_i) + (1 - x_i) \ln(1 - y_i)] \quad (3)$$

对于包含  $N$  个训练样本数据的集合  $S = \{X_i \in R^n, i = 1, 2, \dots, N\}$ ,自动编码器的损失函数为:

$$J(\theta) = \frac{1}{2N} \sum_{i=1}^N L(X_i, g_{\theta_2}(f_{\theta_1}(X_i))) \quad (4)$$

为了解决传统自动编码器中存在过拟合的问题,通常会增加一个权重衰减项(即 L2 正则项)来优化代价函数,权

重衰减项的作用就是对网络的权值矩阵做一定的限制,因此代价函数变为:

$$J(\theta)_{AE} = J(\theta) + \frac{\lambda}{2} (\|W_1\|^2 + \|W_2\|^2) \quad (5)$$

自动编码器的训练过程就是使损失函数最小化的过程,可以通过各种优化函数对对损失函数做最小化处理,这样就能够求解出最优化的自动编码器参数 $\theta$ 。

### 2) 稀疏自动编码器

由于自动编码器输入和输出具有同样的维度,只需通过训练学习得到一个恒等函数就能实现输入数据的完美重构,而在实际应用中则希望训练学习得到复杂的非线性函数,因此产生了稀疏编码器(sparse AutoEncoder, SAE)。稀疏编码器是对自动编码器进行了改进,具有更优的数据特征学习能力<sup>[7]</sup>。

稀疏编码器通过寻找一组“超完备”基向量来更有效的重构输入样本数据,发现隐藏在输入数据内部的模式与结构。在自动编码器的基础上加上了稀疏性约束,即通过对隐藏层每个单元的响应添加约束条件,使隐藏层单元只有少数节点处于活跃状态的,而大多数节点处于抑制状态。稀疏性约束的数学表达式为:

$$\hat{\rho}_j = \frac{1}{N} \sum_{i=1}^N C_j(X_i) \quad (6)$$

式中: $C_j(X_i)$ 表示第*i*个输入样本数据在隐藏层的第*j*个节点上的激活度。

为了使隐藏层的节点满足稀疏性约束的要求,要求满足式(7):

$$\hat{\rho}_i = \rho \quad (7)$$

式中: $\rho$ 为稀疏性参数,一般是一个很小的值,当 $\hat{\rho}_i$ 与 $\rho$ 相差太大的时候就采用基于KL散度(KL divergence)<sup>[8]</sup>的方法进行惩罚,表达式如下:

$$KL(\rho \parallel \hat{\rho}_i) = \rho \log \frac{\rho}{\hat{\rho}_i} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_i} \quad (8)$$

$KL(\rho \parallel \hat{\rho}_i)$ 有随着 $\hat{\rho}_i$ 与 $\rho$ 之间的差值增大而单调递增的特性;当 $\hat{\rho}_i = \rho$ 时, $KL(\rho \parallel \hat{\rho}_i)$ 达到最小值0。因此将 $KL(\rho \parallel \hat{\rho}_i)$ 函数加入到损失函数中,则稀疏自动编码器的损失函数为:

$$J(\theta)_{SAE} = J(\theta)_{AE} + \beta \sum_{j=1}^m KL(\rho \parallel \hat{\rho}_j) \quad (9)$$

式中: $m$ 表示隐藏节点数量; $\beta$ 表示稀疏性惩罚项的权重系数。

## 2.2 网络结构

本文算法的网络模型总共有5层,第1层为输入层,中间3层为自动编码器和稀疏自动编码器组成的栈式混合编码器,实现对输入数据的特征挖掘和提取;第5层为Softmax分类器<sup>[9]</sup>,实现对栈式混合编码器提取特征后的分类输出。如图2所示,网络模型由输入层、栈式混合编码

器和Softmax分类器构成。其中, $n$ 表示层数, $h$ 表示每一层编码器的维数, $m$ 表示输出层维数。

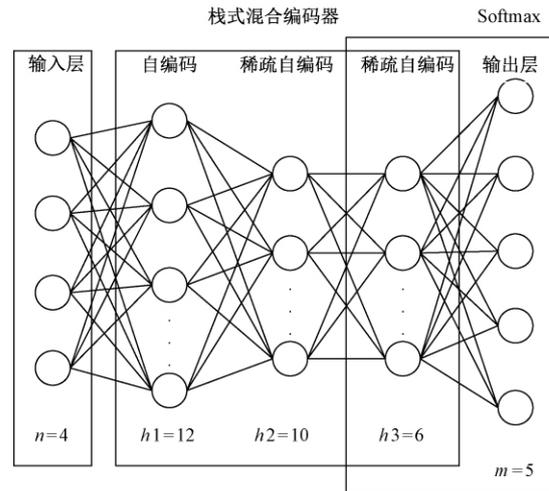


图2 栈式混合编码器结构

Softmax分类器主要解决多分类问题,是在Logistic回归的基础上进行了功能扩展。Softmax分类器不仅能给出数据样本的分类结果,而且同时还给出结果对应的概率。

假设1个带标签的训练样本为 $\{(x^1, y^1), \dots, (x^l, y^l)\}$ ,经过栈式混合编码器特征提取后训练样本变为 $\{(C_3^1, y^1), \dots, (C_3^l, y^l)\}$ ,样本输入 $C_3$ 的维度为6。类别标签 $y$ 可以取5种不同的值,因此对于训练样本的标签有 $y^l \in \{1, 2, 3, 4, 5\}$ 。

假设 $p(y = j | C_3)$ 表示在输入 $C_3$ 的情况下,数据样本被判定为类别*j*的概率。当属于某类别的概率最大时,就判定为该类别。因此对于本文提出网络模型的分器,输出将是一个5维的向量,输出结果为:

$$h_{\phi}(C_3^i) = \begin{bmatrix} p(y^i = 1 | C_3^i; \phi) \\ p(y^i = 2 | C_3^i; \phi) \\ \vdots \\ p(y^i = 5 | C_3^i; \phi) \end{bmatrix} \quad (10)$$

式中: $C_3^i$ 表示第*i*个训练样本在第3层隐藏层的输出; $\phi$ 为Softmax分类器的模型参数,由5种类别所对应的分类器参数组成,关系如式(11)所示。

$$\phi = [\phi_1^T, \phi_2^T, \phi_3^T, \phi_4^T, \phi_5^T]^T \quad (11)$$

输出结果经过归一化处理为:

$$h_{\phi}(C_3^i) = \frac{1}{Z} \begin{bmatrix} \exp(\phi_1^T C_3^i) \\ \exp(\phi_2^T C_3^i) \\ \vdots \\ \exp(\phi_5^T C_3^i) \end{bmatrix} \quad (12)$$

其中 $Z$ 表达式为:

$$Z = \sum_{j=1}^5 \exp(\phi_j^T C_3^i) \quad (13)$$

Softmax 分类器的损失函数为:

$$J(\phi) = -\frac{1}{l} \sum_{i=1}^l \sum_{j=1}^5 s\{y^i = j\} \lg \frac{\exp(\phi_j^T C_3^i)}{\sum_{k=1}^5 \exp(\phi_k^T C_3^i)} + \frac{\tau}{2} \sum_{i=1}^5 \sum_{j=1}^6 \phi_{ij}^2 \quad (14)$$

其中  $s\{y^i = j\}$  为指示性函数,如果大括号中的值为假则输出结果为 0,如果值为真则输出结果为 1。第 2 项为 L2 正则项,即权重衰减项,用来惩罚权值过大的参数,使参数收敛于全局最优值, $\tau$  为权重系数。

2.3 网络训练

训练学习时分为无监督的预训练和有监督学习两个阶段<sup>[10]</sup>。无监督的预训练阶段表示学习过程,通常是利用无标签的数据集对隐藏层进行逐层的预训练,训练时保持其它层参数不变,将前一层的输出特征表示作为当前层的输入,完成该层网络的训练后,将该层网络输出特征又作为下一层的输入。有监督学习阶段可分为有监督分类学习和有监督网络微调,有监督分类学习是使用带标签的数据对 Softmax 分类器进行训练,将样本数据经过栈式混合编码器部分处理后的输出数据作为分类器的输入,然后使用 BP 算法对 Softmax 网络进行训练学习。有监督网络微调将无监督的预训练和有监督分类学习获得的网络参数作为整个网络模型的初始化系数,然后通过有监督的目标学习对整个网络进行微调,最后能够训练出带有预测目标的深度学习网络模型。

2.4 算法实现步骤

本文算法的实现流程主要可以分为两个阶段,第 1 阶段首先通过训练样本对网络进行训练学习,确定整个网络模型的参数;第 2 阶段使用训练好的网络模型进行水质数据进行综合预测分类。栈式混合编码器网络模型的算法实现步骤如下:

1) 无监督预训练

(1) 确定网络模型的整体结构,并对网络参数以随机初始化的方式进行初始化,确定训练样本数据集;

(2) 将训练样本数据不使用标签作为输入,利用自动编码器方法训练第 1 个隐藏层的网络参数,并使用训练好的网络参数计算出第 1 个隐藏层的输出;

(3) 将经过步骤(2)处理后的输出数据作为第 2 个隐藏层的输入,利用稀疏自动编码器方法训练第 2 个隐藏层的网络参数,使用训练好的网络参数计算出前两个隐藏层的输出结果;

(4) 将步骤(3)的输出作为第 3 个隐藏层的输入,使用与步骤(3)相同的方法对隐藏层进行网络参数训练;

2) 有监督分类学习

(5) 将步骤(4)的输出作为 Softmax 多分类器的输入,然后利用样本数据的标签对 Softmax 分类器的网络参数进行训练;

3) 有监督网络微调

(6) 将步骤(2)~(5)训练得到的网络参数作为整个深度学习网络(3 个隐藏层和 1 个 Softmax 输出层)参数初始化的值,然后使用带标签样本数据对整个网络参数进行网络微调,最后得到最优的网络参数值;

4) 网络模型测试分类

(7) 使用训练好的网络模型对测试样本数据进行预测综合分类。图 3 所示为本文算法的流程。

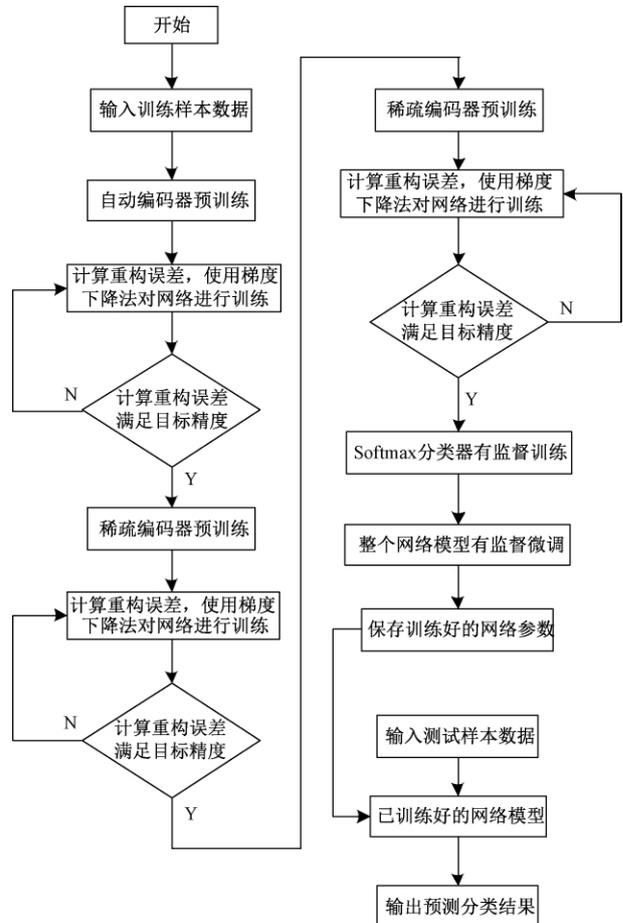


图 3 本文算法流程

3 实验结果与分析

实验数据选取来自浙江省地表水水质自动监测数据系统监测的 5 000 组水质传感器数据记录,每组数据包括总磷、溶解氧、氨氮和高锰酸钾 4 个指标元素。选择其中 4 000 组数据记录对本文提出的网络模型进行训练学习,而另外 1 000 组数据记录作为测试样本集。

为了验证本文提出的基于栈式混合编码器(stack hybrid encoder)的水质传感器数据融合算法的有效性,将该算法与基于 BP 神经网络的分类算法、基于 RBF 神经网络的分类算法、基于深信度网络(DBN)模型的分类算法和基于栈式稀疏编码器(stack sparse encoder)的分类算法进

行比较分析。

将基于BP神经网络的分类算法记为BP,将基于RBF神经网络的分类算法记为RBF,基于栈式混合编码器的水质传感器数据融合算法记为SHE,将基于栈式稀疏编码器的分类算法记为SSE,基于深信度网络模型的分类型算法记为DBN。

### 3.1 参数设置

栈式混合编码器部分中自动编码器的激活函数设置为sigmoid函数,权重衰减项系数 $\lambda = 0.03$ 。稀疏自动编码器激活函数和权重衰减项系数与前一层的自动编码器保持一致<sup>[11]</sup>。

稀疏自动编码器能够学习到有用的数据特征表达并同

时对输入的高维数据进行有效降维<sup>[12]</sup>。稀疏惩罚项的权重系数 $\beta$ 的主要作用是控制整个网络模型对稀疏性的要求,稀疏性参数 $\rho$ 的主要作用是调节隐藏层神经元的激活概率,控制每个神经元只对某一类型数据或特征才会有响应<sup>[13]</sup>。因此选取合适的参数对于发挥整个稀疏自动编码器的性能十分重要,为了找到适合的参数,将采用组合实验的方式,选取最高预测分类准确率对应的参数组合作为最优参数<sup>[14]</sup>。由于 $\beta$ 与 $\rho$ 只对输入样本数据的类型敏感,而对训练样本数量敏感性较低,所以为了提高实验效率,选取500组训练样本进行训练和100组测试样本进行预测分类。每组参数组合进行5次实验,对分类准确率进行取平均值。不同的参数组合,对应的测试结果如表2所示。

表2 模型参数选取对分类准确率影响结果

参数	$\beta = 1$	$\beta = 1.5$	$\beta = 2$	$\beta = 2.5$	$\beta = 3$	$\beta = 3.5$	$\beta = 4$
$\rho = 0.10$	58.6	57.8	62.0	58.4	61.4	59.4	49.6
$\rho = 0.15$	61.0	61.6	64.6	69.6	78.8	70.8	69.0
$\rho = 0.20$	70.4	73.0	76.4	70.6	75.8	73.4	72.4
$\rho = 0.25$	83.2	84.2	84.6	85.0	86.4	83.6	82.6
$\rho = 0.30$	74.8	75.6	73.2	73.4	74.6	81.4	75.4

从表2中可以看出基于栈式混合编码器网络模型的预测准确率随着 $\beta$ 与 $\rho$ 的不同组合而不断变化,当稀疏性参数 $\rho = 0.25$ 和稀疏性惩罚项的权重系数 $\beta = 3$ 时,网络模型的预测准确率达到最大值,因此选择此参数组合作为网络模型的最优参数。

### 3.2 实验分析

#### 1) 有监督网络微调时损失函数值

首先设计实验比较本文提出的算法和栈式稀疏编码器算法在进行有监督网络微调时损失函数值的变化情况,设置网络微调的目标精度为,当迭代时前后两次输出结果误差小于设置的目标精度就停止迭代训练,损失函数值变化曲线如图4所示,从图4中可以看出SSE方法进行网络微调时,经过858次迭代达到目标精度,此时损失函数值为0.0123。本文提出SHE方法进行网络微调时,当迭代次数达到391次时,它的损失函数值开始小于SSE方法的损失函数值,经过865次迭代后,满足设置的目标精度,此时损失函数值为0.0094。虽然SSE方法一开始收敛速度较快,但是最终达到的损失函数值比本章提出算法模型的损失函数值大。由于损失函数值表示的是样本目标输出和实际输出之间的误差<sup>[15]</sup>,所以可以得出SHE方法在进行样本数据训练时,具有更好的样本学习能力,能够更好的拟合样本内部特征关系,即输入和输出之间的复杂非线性映射能力更强。

#### 2) 测试样本预测分类准确率指标

3种模型的预测分类准确率如表3所示。

从表3中可以看出提出的SHE方法对水质传感器样

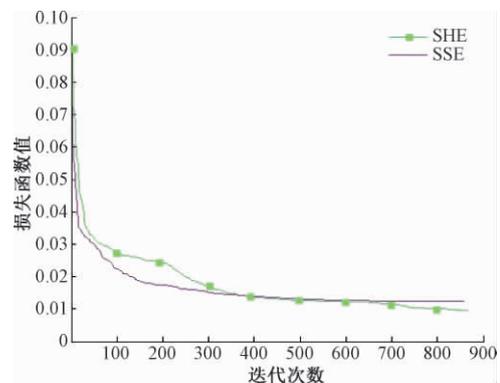


图4 损失函数值变化曲线

表3 测试样本的预测分类准确率

方法	BP	RBF	SSE	DBN	SHE
微调前准确率	无	无	84.30	21.50	89.80
准确率	88.70	94.90	98.20	97.60	98.60

本数据的预测分类准确率在网络微调之前为89.80%,经过微调之后达到98.60%,说明有监督网络微调对于提高网络模型的预测准确率有积极、重要的影响。提出的算法比SSE方法的预测分类准确率高0.40%,比DBN方法的预测分类准确率高1%,而且从表中可以看出深度学习方法比BP和RBF等浅层神经网络在大样本条件下取得更高的分类准确率。所以提出的SHE方法在大样本水质据样下取得的分类效果更好。

## 4 结 论

为解决浅层神经网络学习能力和泛化能力的局限问题,本文采用一种基于栈式混合编码器的水质传感器数据融合算法,通过堆叠自动编码器和稀疏自动编码器形成深度学习网络模型,实现对样本数据的特征挖掘和稀疏表示,解决了浅层神经网络在大样本条件下学习能力不足的问题,能够很好拟合数据内部复杂非线性函数关系,而且可以避免过拟合问题,仿真实验结果验证了该算法在样本较多情况下预测分类的准确性。本文尚有不足之处,下一步可针对不同传感器数据类型融合编码,结合深度学习网络提高表示方法的普适性。

### 参考文献

- [1] DU Y, WEI K, SHI Y, et al. Infrared detection and clustering grey fusion prediction model of water quality turbidity[J]. *Infrared & Laser Engineering*, 2016, 45(10): 1028002.
- [2] NAJAH A A, EL-SHAFIE A, KARIM O A, et al. Water quality prediction model utilizing integrated wavelet-ANFIS model with cross-validation[J]. *Neural Computing & Applications*, 2012, 21(5): 833-841.
- [3] HE H M, HOU D B, ZHAO H F, et al. Multi-parameters fusion algorithm for detecting anomalous water quality [J]. *Journal of Zhejiang University*, 2013, 47(4): 735-740.
- [4] TAORMINA R, GALELLI S. Realtime detection of cyber-physical attacks on water distribution systems using deep learning [C]. *World Environmental and Water Resources Congress*, 2017: 469-479.
- [5] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors [J]. *Nature*, 1986, 323(6088): 533-534.
- [6] JIANG X, ZHANG Y, ZHANG W, et al. A novel sparse autoencoder for deep unsupervised learning[C]. *Sixth International Conference on Advanced Computational Intelligence*, IEEE, 2013: 256-261.
- [7] SUN W, SHAO S, ZHAO R, et al. A sparse auto-encoder-based deep neural network approach for induction motor faults classification [J]. *Measurement*, 2016, 89: 171-178.
- [8] GUO R, SHEN M, HUANG D, et al. Recursive estimation of transition probabilities for jump Markov linear systems under minimum Kullback-Leibler divergence criterion[J]. *IET Control Theory & Applications*, 2015, 9(17): 2491-2499.
- [9] CHEN M, WEINBERGER K, SHA F, et al. Marginalized denoising auto-encoders for nonlinear representations [C]. *International Conference on Machine Learning*, 2014: 1476-1484.
- [10] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18(7): 1527-1554.
- [11] 杨一伟.水质传感器数据融合算法研究[D].南京:河海大学, 2018.
- [12] 李征,房宏才,柯熙政,等.滑动平均法在 MEMS 陀螺信号趋势项提取中的应用[J].*电子测量与仪器学报*, 2019,33(7):43-49.
- [13] 韩晓微,岳高峰,崔建江,等.四旋翼无人机陀螺阵列数据融合算法[J].*仪器仪表学报*,2019,40(8):213-221.
- [14] 景冬,郭恒林,王利华,等.背包式移动测量系统传感器间数据融合研究[J].*电子测量技术*,2020,43(10):48-52.
- [15] 王瑞,王岳.基于多传感器数据融合的档案存放安全性预警系统研究[J].*国外电子测量技术*,2020,39(3):58-64.

### 作者简介

王照丽,高级工程师,主要研究方向为数据融合处理、模式识别。

E-mail:15150681569@163.com

杨一伟,硕士研究生,主要研究方向为电子信号处理、信道编码。

E-mail:1097023730@qq.com

黄凤辰,副教授,主要研究方向为嵌入式控制、机器学习。

E-mail:1103674925@qq.com