

doi:10.11835/j.issn.1000-582X.2017.12.011

矿井突水水源判别的改进 ESN 神经网络模型

李垣志, 牛国庆, 张轩轩

(河南理工大学 安全科学与工程学院, 河南 焦作 454000)

摘要:针对水化学特征相似的水源类型,采用传统的预测模型难以准确判别。运用水化学成分分析法和 FCM 聚类分析法对 26 个典型的水源样本进行相似度分析,并提取了 4 个相似度较高的水源样本作为待测样本,将其载入一种基于阻尼最小二乘正则化方法的 GA_ESN 判别模型,并与改进的 GA_BP 和标准 GA_ESN 模型的判别结果进行对比。结果表明:改进的 GA_BP 判别模型效果最差,预测准确率只有 50%;标准 GA_ESN 模型的回判准确率和预测准确率均达到 100%,但其判别精度对模型的复杂程度要求较高,且易出现过拟合问题;而改进的 GA_ESN 判别模型能够弥补上述模型的不足,不仅简化模型训练过程,还能提高水源的判别精度。因此,该模型可作为一种快速有效判别矿井突水来源的新方法。

关键词:突水水源判别;回声状态网络;BP;FCM;GA_BP

中图分类号:X936

文献标志码:A

文章编号:1000-582X(2017)12-087-10

Improved ESN neural network model for mine water inrush identification

LI Yuanzhi, NIU Guoqing, ZHANG Xuanxuan

(School of Safety Science and Engineering, Henan Polytechnic University,
Jiaozuo 454000, Henan, P.R.China)

Abstract: It is difficult to judge the type of water source with similar water chemistry characteristics by the traditional water prediction model. The similarity analysis of 26 typical water samples is carried out by using water chemical composition analysis and FCM (fuzzy C-means) cluster analysis method. Four samples with higher similarity are extracted as samples to be tested and loaded into the GA_ESN discriminant model based on damped least squares regularization method, and the GA_ESN discriminant model of the regularization method is compared with the improved GA_BP and the standard GA_ESN model. The results show that the improved GA_BP discriminant model has the worst effect and the prediction accuracy is only 50%. The back estimation rates and prediction accuracy of the standard GA_ESN model are 100%, however, the accuracy of the model requires a high degree of complexity of the model, and it's prone to have overfitting problem. And the improved GA_ESN discriminant model can make up for the shortage of

收稿日期:2017-07-04

基金项目:教育部创新团队发展计划项目(IRT_16R22)。

Supported by Program for Innovation Research Team in University(IRT_16R22).

作者简介:李垣志(1991—),男,硕士研究生,从事矿山灾害防治理论与技术研究工作,(E-mail)251101819@qq.com。

牛国庆(联系人),男,博士,河南理工大学硕士生导师,教授,从事矿山安全技术及工程等方面研究,(E-mail)343697125@qq.com。

the above model, which can not only simplify the model training process, but also improve the accuracy of water source identification. Therefore, the model can be used as a fast and effective method to identify the source of mine water inrush.

Keywords: water inrush; echo state network; BP; FCM; GA_BP

煤炭工业是关系国家经济命脉的重要基础产业,支撑着国民经济持续快速健康发展^[1]。矿井水害是煤矿的主要灾害之一,是制约煤炭资源开发和影响煤炭企业安全的重要因素^[2]。随着中国煤炭开采深度和强度的不断增大,在开采过程中产生的剧烈扰动使地下涌水通道相互贯通,含水层的完整性遭到严重地破坏,增加了突水的危险性。一旦发生矿井突水,必须快速、准确地查明突水来源,为后续展开防治水工作提供理论依据和指导。由于地下水的水化学特征能够准确、有效地反映含水层的物化特性,所以,根据水化学特征来判断突水来源具有快速、准确、经济的特点^[3]。但地下涌水通道错综复杂,水化学特征随时间和空间会发生一定的变化,所以地下水的水化学特征表现出高度的非线性关系,采用传统的数学模型难以准确判别。

近年来,随着人工智能在数据挖掘方面的飞速发展,已被广泛应用于各科领域,尤以神经网络^[4-5]、支持向量机(SVM, support vector machine)^[6]、遗传算法(GA, genetic algorithm)^[6-7]和微粒群算法(PSO, particle swarm optimization)^[8]等模型为研究热点。目前,已有不少学者将其应用于矿井突水水源的判别,并取得了一些成果^[6-7, 9]。回声状态网络(ESN, echo state network)是近年来新兴的一种递归神经网络,独特而简单的训练方式以及高精度的训练结果已使其成为当前研究的热点之一^[10]。罗轶^[11]将 ESN 应用于交通流的预测并与 Elman 神经网络进行对比,结果表明:二者在预测精度相当的情况下,前者的训练速度较后者有了极大的提高。乔俊飞等^[12]采用 PSO 算法对 ESN 神经网络输出权值进行训练,并对污水的生化需氧量(BOD, biochemical oxygen demand)进行预测,结果证明了该模型能够有效预测污水处理关键水质参数。然而,ESN 神经网络在矿井突水水源判别方面的研究较为匮乏。由于模型的判别精度一定程度上取决于样本的选取,而大多数有关水源判别的文献并没有对水源样本进行分析,所选取的待测样本特征较为明显,判别相对容易,虽然得到较高的判别精度,但不能充分检验模型的判别能力。因此,笔者对某矿含水层的水化学成分进行了统计分析和聚类分析,选取了具有代表性的样本作为训练样本,水化学特征与之近似的样本作为待测样本,将其载入基于阻尼最小二乘奇异分解法(DSVD, damped singular value decomposition)的 GA_ESN 判别模型,并与融合了全局动量因子和 Dropout 技术的 GA_BP 神经网络进行对比,以检验改进的 GA_ESN 模型的学习能力和预测能力,旨在针对水化学特征相近的水源,寻求一种能够快速有效判别突水来源的新方法。

1 样本的选取

1.1 样本特征分析

本文中所选取的水源样本来自文献^[13]中某矿 26 个典型突水样本,该样本包含了 11 个水化学特征组分:Ca²⁺, Mg²⁺, K⁺, Na⁺, HCO₃⁻, Cl⁻, SO₄²⁻, 总硬度、碱度、pH、总矿化度(TDS, total degree of salinity)。其中 1~6 和 X1~X3 号样本为 4-6 煤顶板水,属于第 1 类水源;7~13 和 X4~X5 号样本为奥灰水,属于第 2 类水源;14~20 和 X6 号样本为 6 煤底至奥灰砂岩水,属于第 3 类水源。采用 Rock Ware AqQa 软件对该样本的 6 大常规离子和 pH, TDS 绘制了 Durov 图,如图 1 所示。

图 1 中 2 个三角区域为阴阳离子相对质量浓度分布,中间方形区域为 6 大离子质量浓度综合分布情况,2 个矩形区域分别为 pH 和 TDS 分布。从方形区域可以看出,第 2 类水源分布较为集中,结合三角区域阴阳离子分布可初步得出该水源的水质类型为 SO₄·Cl—K+Na 型,从 pH 和 TDS 矩形区域可以看出 7 号样本出现偏离现象。第 1, 3 类水源分布较为分散且相近,水质类型难以确定,通过观察可以发现 4, 17, 18 和 X3, 7, 16 号样本的空间分布较为相近,但它们分属于不同的水源类型,表明了其水质在一定程度上受到了外界的干扰,仅从空间分布角度分析,难以断定样本类型。

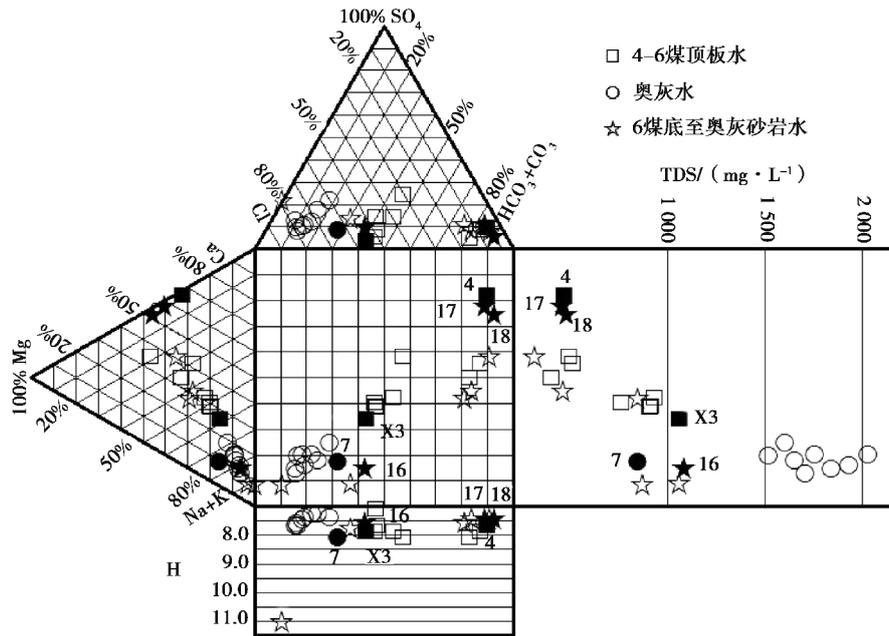


图 1 含水层水化学特征 Durov 图

Fig.1 Durov diagram of hydrochemical characteristics of aquifer

图 2 是结合硬度和碱度特征分别对 4,17,18 和 X3,7,16 号样本绘制 Schoeller 图。从图 2 中可以看出,4,17,18 号样本的 11 个特征指标极为相近,尤其是 HCO_3^- , Cl^- , 总硬度、碱度、pH 特征指标几乎没有差异;X3,7,16 号样本相似度有所降低,但 3 条样本曲线均有不同程度的交叉重叠,因此采用上述统计的方法很难区分水源类型。为了进一步将样本的近似程度量化,采用模糊 C 均值聚类法对 26 个样本进行聚类分析。

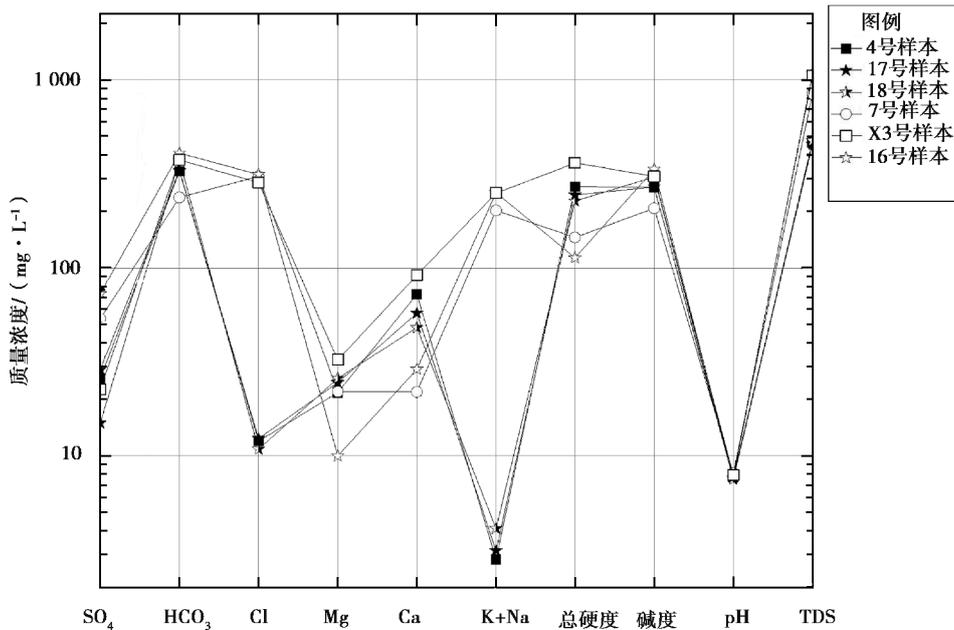


图 2 含水层水化学特征 Schoeller 图

Fig.2 Schoeller diagram of hydrochemical characteristics of aquifer

1.2 FCM 聚类分析

模糊 C 均值聚类^[14](FCM, fuzzy C-means)是用隶属度确定每个数据点属于某个聚类程度的一种聚类算法,其思想是使得被划分到同一类的对象之间相似度最大,而不同类之间相似度最小,是一种柔性的模糊聚

类方法,其结果会给出每个样本点归属为某一类别的概率,通常选取概率较大者作为该样本的类别归属。

使用 Matlab 软件中 fcm 函数对 26 个样本数据进行 FCM 聚类分析,迭代次数为 1 000,分类数为 3 类,其他参数采用默认值,计算得到的隶属矩阵如表 1 所示,分类结果如图 3 所示。

表 1 隶属矩阵
Table 1 Membership matrix

类别	1	X1	X2	2	3	4	5	6	7	8	9	10	X4
C1	0.696	0.913	0.934	0.036	0.012	0.015	0.118	0.917	0.838	0.117	0.147	0.024	0.041
C2	0.025	0.016	0.012	0.005	0.001	0.002	0.016	0.016	0.030	0.842	0.802	0.964	0.943
C3	0.279	0.071	0.054	0.958	0.986	0.983	0.866	0.067	0.132	0.042	0.051	0.011	0.016

类别	11	12	13	14	15	16	17	18	19	20	X3	X5	X6
C1	0.008	0.055	0.038	0.619	0.643	0.875	0.014	0.007	0.046	0.070	0.896	0.021	0.794
C2	0.988	0.918	0.944	0.048	0.113	0.050	0.002	0.001	0.008	0.009	0.037	0.970	0.092
C3	0.003	0.027	0.018	0.334	0.244	0.075	0.984	0.992	0.947	0.922	0.067	0.009	0.114

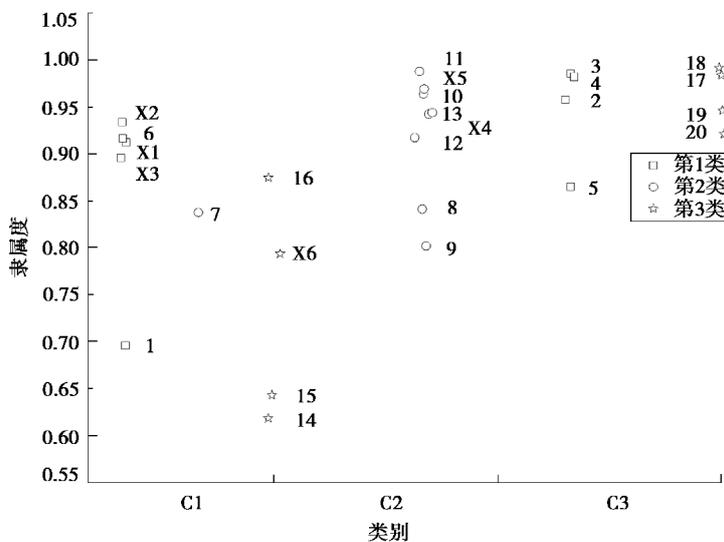


图 3 FCM 分类结果

Fig.3 FCM classification results

由图 3 可以看出,FCM 对第 2 类水源的划分与原始分类基本吻合,只有 7 号样本被划分为 C1 类,与 1.1 节的分析相一致。而第 1,3 类水源中有近 50% 的样本出现了与原始分类不相符的情况,表明了从空间距离角度分析样本的相似性与实际结果相违背。以 4 和 17 号样本为例,它们的隶属度最为接近,表明从空间距离角度来看,二者具有极高的相似性,但实际二者来自不同的含水层,出现这种差异,一方面表明了水源之间发生了一定的水力联系;另一方面表明采用图示法和聚类分析法无法找到样本与目标之间更为深层的映射关系。空间相似但分属不同含水层的样本是最能体现这种映射关系的代表性样本;同时,由于空间的相似性,使模型无法从距离相似这一特征来直接判别水源类型,增加了模型的判别难度。因此,应选取具有代表性的特征样本作为模型的训练样本,供模型学习其内在特征,选取与之空间近似样本作为待测样本,最大限度地检验模型的学习能力和预测能力。结合表 1 和图 3 的分析结果,在同一簇类中,选取不同突水来源但隶属度最为相近的样本作为训练样本,与之近似的样本作为待测样本。样本筛选结果见表 2。

表 2 样本选取
Table 2 Sample selection

样本分类	第 1 类水源	第 2 类水源	第 3 类水源
训练样本	1,2,4~6,X2,X3	8~13,X4,X5	14~17,19,20,X6
测试样本	X1,3	7	18

2 改进的 ESN 神经网络

2.1 ESN 神经网络

ESN 是一种新型递归神经网络^[15],其网络结构如图 4 所示。

储备池状态更新方程:

$$\mathbf{x}(n+1) = f_{\text{inter}}[\mathbf{W}_{\text{in}}\mathbf{u}(n+1) + \mathbf{W}\mathbf{x}(n) + \mathbf{W}_{\text{back}}\mathbf{y}(n)], \quad (1)$$

式中: $\mathbf{u}(n) \in \mathbf{R}^K$ 为输入变量; K 为样本特征维度; $\mathbf{y}(n) \in \mathbf{R}^L$ 为输出变量, L 为样本输出维度; $\mathbf{x}(n) \in \mathbf{R}^N$ 为状态变量, N 为储备池神经元个数; n 为样本数量; f_{inter} 为储备池激活函数; $\mathbf{W}_{\text{in}} \in \mathbf{R}^{K \cdot N}$, $\mathbf{W} \in \mathbf{R}^{N \cdot N}$, $\mathbf{W}_{\text{back}} \in \mathbf{R}^{N \cdot L}$ 分别为输入层、中间层、反馈层连接权重。

收集每个样本 $[\mathbf{u}(n), \mathbf{x}(n)]$ 到状态矩阵 $\mathbf{M} \in \mathbf{R}^{n \cdot (K+N)}$,并计算与之对应的输出矩阵 $\mathbf{Y} \in \mathbf{R}^{n \cdot L}$,最后根据式(2)计算出输出权重 $\mathbf{W}_{\text{out}} \in \mathbf{R}^{(K+N) \cdot L}$ 。

$$\mathbf{W}_{\text{out}} = \mathbf{M}^+ \mathbf{Y} = (\mathbf{M}^T \mathbf{M})^{-1} \mathbf{M}^T \mathbf{Y}, \quad (2)$$

式中: \mathbf{M}^+ 为矩阵 \mathbf{M} 的伪逆。

式(2)为标准 ESN 计算 \mathbf{W}_{out} 的方法,在实际应用中, \mathbf{M} 的法矩阵条件数通常比较大,直接采用伪逆法会产生不稳定解,将会导致待测样本的计算结果被放大。即模型学习精度高,预测能力差,出现过拟合。另外,由于矿区所保留的突水样本相对有限,因此所建立的模型参数不宜过多,否则会使得过拟合问题更为严重。故引入了正则化方法来解决这一问题。

2.2 阻尼最小二乘奇异分解法

阻尼最小二乘法^[16]又称 Levenberg-Marquardt 法,是解算病态问题较为有效的一种正则化方法。马奎特提出给式(2)系数矩阵 $\mathbf{M}^T \mathbf{M}$ 的对角矩阵加上一个正常数,以改善方程的条件,见式(3)。

$$\mathbf{W}_{\text{out}} = (\mathbf{M}^T \mathbf{M} + \alpha \mathbf{I})^{-1} \mathbf{M}^T \mathbf{Y}. \quad (3)$$

根据式(4)对 \mathbf{M} 进行奇异值分解:

$$\mathbf{M} = \mathbf{U} \boldsymbol{\Sigma} \mathbf{V}^T = \sum_{i=1}^q \mathbf{u}_i \sigma_i \mathbf{v}_i^T, \quad (4)$$

式中: $\mathbf{U} \in \mathbf{R}^{n \cdot l}$ 和 $\mathbf{V} \in \mathbf{R}^{(K+N) \cdot l}$ 为正交阵; $\boldsymbol{\Sigma} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_l) \in \mathbf{R}^{l \cdot l}$, $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_l > 0$ 为矩阵 \mathbf{M} 的奇异值; $\mathbf{u}_i, \mathbf{v}_i$ 分别表示 \mathbf{U}, \mathbf{V} 的列向量。

联立(3)、(4),整理后可得:

$$\mathbf{W}_{\text{out}} = \sum_{i=1}^q f_i \frac{\mathbf{u}_i^T \mathbf{Y}}{\sigma_i} \mathbf{v}_i, \quad (5)$$

式中: $f_i = \frac{\sigma_i}{\sigma_i + \alpha}$ 。

由式(5)可以看出引入的阻尼因子 α 可以对奇异值的大小进行调整,来削弱奇异值对解的影响程度,从而减弱病态问题。

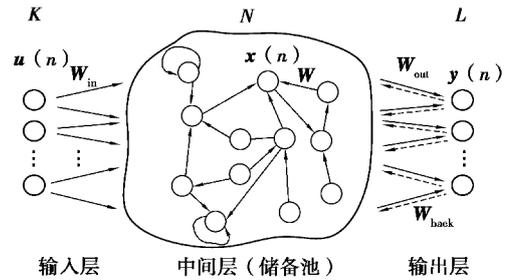


图 4 ESN 神经网络结构

Fig. 4 ESN neural network structure

2.3 改进的 ESN 模型算法流程

改进的 ESN 模型搭建步骤如下：

Step 1 样本预处理。为了消除量纲、降低样本维度及噪声，将原始样本数据归一化至 $[0,1]$ ，然后对其进行主成分分析(PCA, principal component analysis)，并保留 95% 的原始信息。

Step 2 构建 DSVD_ESN 神经网络框架。采用 DSVD 正则化方法计算 W_{out} ，并由 L 曲线法确定阻尼因子 α ；预留 ESN 网络中需要寻优的关键参数接口(比例因子、激活函数、稀疏度 D 和储备池规模 N)，以备遗传算法调用。

Step 3 遗传算法接口设定。初始化种群规模、最大迭代次数和遗传操作等参数；调整相关接口与 DSVD_ESN 模型进行对接。将 K 折交叉验证法嵌入 GA 算法中，以确保进化方向的正确性^[7]。

Step 4 将 Step1 得到的样本数据载入 Step 2 和 Step 3 所建立的 GA_DSVD_ESN 模型中，通过全局搜索得到最优的 DSVD_ESN 模型。此时，该模型可用于判别该矿区其他突水样本。

GA_DSVD_ESN 模型流程如图 5 所示。

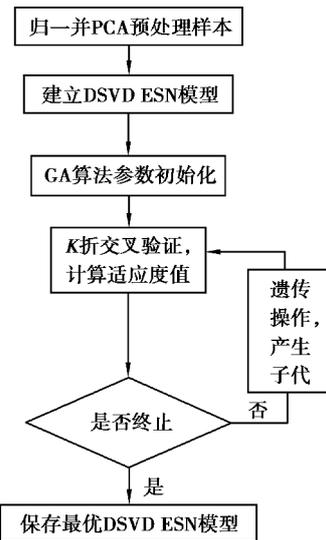


图 5 GA_DSVD_ESN 模型流程图

Fig. 5 Flow chart of GA_DSVD_ESN model

3 实例分析

以表 2 中的水源样本为例，将 3 种突水类型分别编码为“1”，“2”，“3”，并建立了 4 种水源判别模型，如表 3 所示。

表 3 4 种判别模型

Table 3 Four kinds of discriminant model

模型	备注
N_BP	嵌入动量因子和 Dropout 技术，防止网络陷入局部最小和过拟合
GA_N_BP	GA 算法对 N_BP 神经网络参数进行寻优，进一步增强模型的稳定性和准确性
GA_ESN	GA 算法对标准 ESN 关键参数进行寻优，确定最优的 ESN 神经网络模型
GA_DSVD_ESN	本文中所提出的方法

3.1 基于 BP 的判别模型

GA 和 BP 算法参数设定见表 4 和表 5。

表 4 遗传算法参数设定

Table 4 Parameter setting of GA algorithm

种群规模	迭代次数	变量长度	代沟	交叉	变异
40	50	5	0.95	0.8	0.01

表 5 BP 模型参数

Table 5 The parameters of BP model

模型	网络结构	隐层函数	输出层函数	动量因子	学习率	训练次数	Dropout
N_BP	5×6×1	tanh	sigm	0.50	0.25	1 000	0.5
GA_N_BP	5×6×1	tanh	sigm	0.96	0.74	1 000	0.1

由表 5 中的网络结构可以看出,经过对样本归一化和 PCA 处理后,样本维度由 11 降为 5,即模型输入维度为 5;N_BP 模型参数根据经验和反复测试得到;GA_N_BP 模型参数通过 GA 算法对 BP 神经网络初始权重、动量因子、学习率和 Dropout 分数进行全局搜索得到。2 种模型的判别结果见表 6。

表 6 BP 模型判别结果

Table 6 Discriminant results of BP model

模型	回判				预测			
	误判样本	实际输出	期望输出	误判率/%	误判样本	实际输出	期望输出	误判率/%
N_BP	13	1	3	22.73	7	1	2	50
	15	1	3					
	16	1	3					
	17	1	3					
	18	1	3					
GA_N_BP	4	3	1	4.55	3	3	1	50
					7	1	2	

从表 6 可以看出,N_BP 模型回判误判率为 22.73%,将部分第 3 类水源错判为第 1 类水源,待测样本中,将 7 和 18 号样本错判为第 1 类水源;而 GA_N_BP 模型的预测效果有了较大的提高,回判误判率降低为 4.55%,但仍对 3,7 号样本出现误判,由 1.2 节分析可以看出 3 号样本特征分布与 17 号样本极其相似,这是由于 GA_N_BP 模型没有很好学习 4 与 17 号样本间除空间相似之外其他内在特征,故模型的学习能力有待提高。

3.2 基于 ESN 的判别模型

采用 GA 算法分别对标准 ESN 和 DSVD_ESN 模型的关键参数进行全局寻优,结果见表 7 所示。

表 7 ESN 模型参数

Table 7 The parameters of ESN model

模型	结构	f_{inter}	f_{out}	R	$S_{in, out}$	D
GA_ESN	$5 \times 987 \times 1$	tanh	sigmoid	0.297	[0.297 0.425]	5.90
GA_DSVD_ESN	$5 \times 187 \times 1$	tanh	sigmoid	0.968	[0.010 0.202]	3.61

由表 7 可以看出,GA_ESN 和 GA_DSVD_ESN 模型最大的不同在于网络结构,GA_DSVD_ESN 模型储备池规模和稀疏度均明显小于 GA_ESN 模型,表明采用 DSVD 正则化方法可以有效的简化模型结构,减少隐层神经元个数和连接权值,从而降低了模型的连接关系;从模型所选取的激活函数可以看出,无论采用哪种权值训练方法对激活函数的选择没有影响,表明该激活函数能很好的表达这种输入—输出的映射关系。它们的判别结果如表 8 所示。

表 8 ESN 模型判别结果

Table 8 Discriminant results of ESN model

模型	实际输出	期望输出	残差	是否正确
GA_ESN	1.08	1.00	0.08	是
	1.05	1.00	0.05	是
	2.27	2.00	0.27	是
	3.02	3.00	0.02	是
GA_DSVD_ESN	0.98	1.00	0.02	是
	1.02	1.00	0.02	是
	1.96	2.00	0.04	是
	3.09	3.00	0.09	是

从表 8 可以看出,2 种判别模型均能正确的判别突水来源, GA_DSVD_ESN 模型的残差分布相对较低, 维持在 $1E-2$ 量级。

图 6 为模型判别结果与目标值的对比曲线。可以看出,GA_DSVD_ESN 模型曲线与目标曲线更为接近, 上下浮动较小; 而 GA_ESN 模型对 7 号样本的预测出现了较大的波动, 拟合效果不如前者。

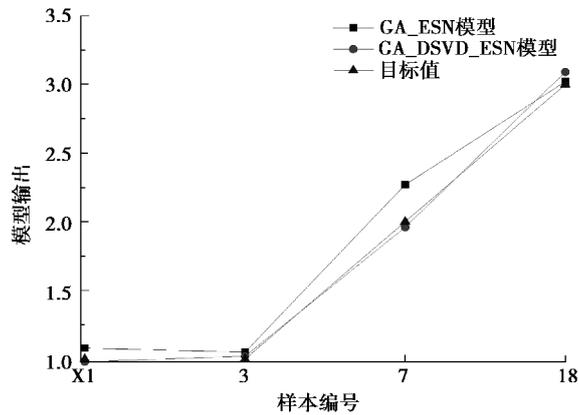


图 6 模型输出对比曲线

Fig. 6 Comparison of model output curves

表 9 是对 2 种模型判别结果的评估, 不难看出, 二者的回判正确率均达到了 100%, 但从回判结果的标准均方根误差(NRMSE, normalized root mean squared error)来看, GA_ESN 模型达到了 $1E-14$ 量级, GA_DSVD_ESN 模型只有 $1E-2$ 量级, 这是由于 GA_ESN 模型采用伪逆法计算 W_{out} , 是一种无偏估计, 导致模型的回判精度极高, 但这种方法计算出的权值浮动较大, 模型敏感度增强, 从而导致模型的泛化能力降低。因此, 该模型虽能正确预测突水来源, 但其精度远不如前者, 然而, GA_DSVD_ESN 模型能将回判 NRMSE 控制在 $1E-2$ 量级, 且准确率为 100%, 表明了 DSVD 正则化方法能够将 ESN 模型的学习能力控制在有效范围内, 以牺牲不必要的训练精度来提高模型的泛化能力, 有效解决了过拟合问题; 同时结合表 7 和第 1 节的分析结果可以得出, 在待测样本极为相似的情况下, GA_DSVD_ESN 模型能够大幅简化储备池神经元个数及其连接权值, 优化了网络的映射关系, 提高了模型的训练速度, 同时获得满意的预测效果, 充分证明了该模型对于空间相似的水源样本具有较强的学习能力和预测能力。

表 9 ESN 模型结果评估

Table 9 Evaluation of results of ESN model

名称	GA_ESN 模型	GA_DSVD_ESN 模型
回判正确样本数	22	22
回判正确率/%	100	100
回判 NRMSE	$2.65E-14$	$1.06E-02$
预测正确样本数	4	4
预测正确率/%	100	100
预测 NRMSE	0.141 5	0.048 9

4 结 论

1)采用 Durov 图和 Schoeller 图对某矿 26 个典型突水样本中的 11 种特征组分进行成分分析,结果发现:该矿区奥灰水含水层的水化学特征组分分布较为集中,而 4-6 煤顶板水和 6 煤底至奥灰水砂岩水特征组分分布较为分散且相似,给水源判别带来很大的困难。

2)采用 FCM 法对水源样本进行聚类分析,得到了与结论 1)一致的结果,并根据隶属矩阵确定了每个样本分属不同类别的概率,量化了样本间的相似程度。

3)选取隶属度较高的样本作为待测样本,用以评估模型的判别能力。实验结果表明:融合动量因子和 Dropout 技术的 N_BP 模型判别效果最差;而 GA_N_BP 模型的判别效果较 N_BP 模型有了很大的提高,但仍不能满足实际要求;而 GA_DSVD_ESN 模型能够准确判别相似水源样本,较 GA_ESN 模型具有建模速度快,准确度高,泛化能力强的特点,同时该模型耦合了 PCA 主成分分析法和 K 折交叉验证法,使建模过程更具合理性,判别结果更具可靠性。因此,针对水化学特征相似的水源样本,GA_DSVD_ESN 模型可作为一种快速有效判别方法。

参考文献:

- [1] 申宝宏,雷毅,郭玉辉.中国煤炭科学技术新进展[J].煤炭学报,2011,36(11):1779-1783.
SHEN Baohong, LEI Yi, GUO Yuhui. Progress of coal science and technology in China[J]. Journal of China Coal Society, 2011, 36(11): 1779-1783. (in Chinese)
- [2] 张海鹏.浅析煤矿中的水灾害防治[J].中国安全生产科学技术,2008,4(5):100-103.
ZHANG Haipeng. Probe into prevention and control of water disaster in coal mine[J]. Journal of Safety Science and Technology, 2008, 4(5): 100-103. (in Chinese)
- [3] 钱家忠,吕纯,赵卫东,等.Elman 与 BP 神经网络在矿井水源判别中的应用[J].系统工程理论与实践,2010,30(1):145-150.
QIAN Jiazhong, LYU Chun, ZHAO Weidong, et al. Comparison of application on Elman and BP neural networks in discriminating water bursting source of coal mine[J]. Systems Engineering-Theory & Practice, 2010, 30(1): 145-150. (in Chinese)
- [4] 毛健,赵红东,姚婧婧.人工神经网络的发展及应用[J].电子设计工程,2011,19(24):62-65.
MAO Jian, ZHAO Hongdong, YAO Jingjing. Application and prospect of artificial neural network[J]. Electronic Design Engineering, 2011, 19(24): 62-65. (in Chinese)
- [5] 焦李成,杨淑媛,刘芳,等.神经网络七十年:回顾与展望[J].计算机学报,2016,39(8):1697-1716.
JIAO Licheng, YANG Shuyuan, LIU Fang, et al. Seventy years beyond neural networks: retrospect and prospect[J]. Chinese Journal of Computers, 2016, 39(8): 1697-1716. (in Chinese)
- [6] 阳富强,刘广宁,郭乐乐.矿井突水水源辨识的改进 SVM 和 GA-BP 神经网络模型[J].有色金属(矿山部分),2015,67(1):87-91.
YANG Fuqiang, LIU Guangning, GUO Lele. Improved SVM and GA-BP neural network model of mine water inrush sources identification[J]. Nonferrous Metals(Mining Section), 2015, 67(1): 87-91. (in Chinese)
- [7] 李垣志,牛国庆,刘慧玲.改进的 GA-BP 神经网络在矿井突水水源判别中的应用[J].中国安全生产科学技术,2016,12(7):77-81.
LI Yuanzhi, NIU Guoqing, LIU Huiling. Application of improved GA-BP neural network in the identification of mine water inrush sources[J]. Journal of Safety Science and Technology, 2016, 12(7): 77-81. (in Chinese)
- [8] 秦波,吴庆朝,张娟娟,等.基于 PSO 优化 SVM 的转炉炼钢用氧量预测研究[J].测控技术,2014,33(12):121-124.
QIN Bo, WU Qingchao, ZHANG Juanjuan, et al. Blowing oxygen volume prediction of BOF steelmaking based on PSO-SVM[J]. Measurement & Control Technology, 2014, 33(12): 121-124. (in Chinese)

- [9] 徐星,郭兵兵,王公忠.神经网络在矿井多水源识别中的应用[J].中国安全生产科学技术,2016,12(1):181-185.
XU Xing, GUO Bingbing, WANG Gongzhong. Application of artificial neural network in recognition mine multiple water sources[J]. Journal of Safety Science and Technology, 2016, 12(1): 181-185. (in Chinese)
- [10] 罗熊,黎江,孙增圻.回声状态网络的研究进展[J].北京科技大学学报,2012(2):217-222.
LUO Xiong, LI Jiang, SUN Zengqi. Review on echo state networks[J]. Journal of University of Science and Technology Beijing, 2012(2): 217-222. (in Chinese)
- [11] 罗轶.基于ESN和Elman神经网络的交通流预测对比研究[J].湖南工业大学学报,2013(6):67-72.
LUO Yi. Comparative study on traffic flow prediction based on ESN and Elman neural networks[J]. Journal of Hnnnan University of Technology, 2013(6): 67-72. (in Chinese)
- [12] 乔俊飞,李瑞祥,柴伟,等.基于PSO-ESN神经网络的污水BOD预测[J].控制工程,2016,23(4):463-467.
QIAO Junfei, LI Ruixiang, CHAI Wei, et al. Prediction of BOD based on PSO-ESN neural network[J]. Control Engineering of China, 2016, 23(4): 463-467. (in Chinese)
- [13] 聂凤琴,许光泉,关维娟,等.马氏距离判别模型在矿井突水水源判别中应用[J].地下水,2013,35(6):41-42.
NIE Fengqin, XU Guangquan, GUAN Weijuan, et al. Application of Ma distance discriminant model on water source identification of mine water inrush[J]. Ground Water, 2013, 35(6): 41-42. (in Chinese)
- [14] 周子闵,周坚华.FCM聚类的软划分:以遥感图像城镇下垫面聚类为例[J].华东师范大学学报(自然科学版),2016(4):150-157.
ZHOU Zimin, ZHOU Jianhua. Soft partition of FCM clustering results :a case study on the clustering of urban underlying surface from remotely sensed imagery[J]. Journal of East China Normal University(Natural Science), 2016(4): 150-157. (in Chinese)
- [15] 吴佳东.基于回声状态网络的网络流量预测研究[D].兰州:兰州大学,2016.
WU Jiadong. Research on network traffic forecasting based on echo state network[D]. Lanzhou: Lanzhou University, 2016. (in Chinese)
- [16] GUNAWAN F. E. Levenberg-Marquardt iterative regularization for the pulse-type impact-force reconstruction[J]. Journal of Sound & Vibration, 2012, 331(25): 5424-5434. (in Chinese)

(编辑 郑洁)