

DOI: 10.13718/j.cnki.xdzk.2018.04.022

基于 GA-Elman 神经网络的煤矿突水水源判别^①

徐 星, 田坤云, 李凤琴, 赵新涛

河南工程学院 安全工程学院, 郑州 451191

摘要: 煤矿突水是矿井生产过程中产生的自然灾害之一, 而准确判别突水来源是突水防治工作的重要基础. 以煤矿各含水层水化学成分的差异性为依据, 选取 $K^+ + Na^+$, Ca^{2+} , Mg^{2+} , Cl^- , HCO_3^- , SO_4^{2-} 6 个常量组分作为突水水源的判别因子. 为克服 Elman 神经网络采用梯度下降法所带来的易陷入局部最小值的缺点, 采用具有全局搜索能力的遗传算法(GA)通过选择、交叉和变异等步骤训练优化 Elman 神经网络, 建立了收敛速度更快、泛化性更强的 GA-Elman 神经网络判别模型, 结果表明: 将具有全局寻优功能的 GA 和局部精确寻优的 Elman 神经网络相结合, 克服了 Elman 神经网络初始权值与阈值的随机性、易陷入局部最优的缺点, 能够提高 Elman 神经网络的判别输出精度, 为准确、有效判别突水来源提供了可靠的决策依据; 经过 GA 优化过的 Elman 神经网络在训练过程中的均方误差收敛速度、收敛精度都有很大的提高, 在网络模型的判别输出上, 判别结果更为稳定、泛化性更好, 为该模型在其他领域的推广提供了一定的借鉴性; 为进一步确保突水水源判别的准确性、有效性, 在密切结合煤矿水文地质条件的前提下, 应选取具有代表性和准确性高的水化资料, 有效发挥该判别方法对煤矿水害防治及措施制定的指导作用.

关键词: 煤矿突水; 水源判别; Elman 神经网络; 遗传算法; GA-Elman 神经网络; 泛化性

中图分类号: TD745

文献标志码: A

文章编号: 1673-9868(2018)04-0170-10

我国煤矿床水文地质条件较为复杂, 水害问题日趋严重, 突水事故的频发严重制约着高产、高效矿井的建设, 亦严重威胁着矿井的安全生产. 一旦矿井发生突水, 如何快速地判断突水成因、查找突水水源, 是解决和进一步预防矿井突水灾害的关键, 目前, 判别突水水源的水化学方法有灰色关联分析法、模糊综合评判法、Fisher 判别法、人工神经网络法等^[1-3], 这些方法各有其优势, 亦具有其一定的局限性.

针对突水水源类型之间具有很大的模糊性, 不易建立确定相关模型的特点, 有研究^[4-7]认为, 采用 BP 神经网络可以建立水化指标与水源类型之间的非线性映射关系及其判别模型, 从而达到对矿井突水水源准确、有效的判别^[4-7]. 为了寻求运算速度更快、泛化性更强的神经网络, 钱家忠等^[8]以谢一煤矿突水水质资料为例, 经过反复训练, 分别建立了 $7 \times 15 \times 3$ 的 BP 神经网络、 $7 \times 10 \times 3$ 的 Elman 神经网络, 发现最优的 Elman 神经网络在样本训练过程中的收敛速度以及测试样本的判别精度均要高于最优的 BP 神经网络; 徐星等^[9]以焦作矿区水化数据为例, 经过参数优选与设置, 建立了最优的 $6 \times 6 \times 4$ 的 BP 神经网络, 考虑到 2 种网络间的公平比较原则, 仍采用 $6 \times 6 \times 4$ 的 Elman 神经网络对二者的训练与输出进行比较, 发现仅有训练的收敛速度前者优于后者, 认为在隐含层的基础上增加一个承接层的 Elman 神经网络, 增强了网络本身对历史状态数据的敏感性, 使 Elman 神经网络具有较强的非线性映射能力. 笔者认为虽然

① 收稿日期: 2017-02-13

基金项目: 国家自然科学基金项目(51604091); “煤矿灾害预防与控制河南省高校重点实验室培育基地”建设经费项目(200925); 河南省高等学校重点科研项目(16A440001); 河南省高等学校重点科研项目(18A440010); 河南省高校科技创新团队支持计划经费资助(16IRTSTHN013); 河南省科技攻关计划项目(172102310738); 河南省科技攻关计划项目(182102310743).

作者简介: 徐 星(1979-), 男, 山东烟台人, 讲师, 博士研究生, 主要从事矿山水害防治及安全评价教学与科研工作.

Elman 神经网络泛化性更好,能够对突水水源进行有效的判别,但 Elman 神经网络仍采用梯度下降法进行权值和阈值的更新,这给求得全局最优解带来了困难,为克服 Elman 神经网络易陷入局部最优的缺点,本文拟使用能够极大概率寻求全局最优解的遗传算法(GA)对 Elman 神经网络的初始阈值与权值进行优化,从而建立 GA-Elman 神经网络判别模型,以期进一步提高 Elman 神经网络的非线性动态特性以及突水水源判别的准确性.虽然在其他领域有关学者已经将 GA 应用于 Elman 神经网络的优化,进行了氧化还原电位预测、机床热误差建模、交通流短时预测、电池劣化程度预测、网络流量预测等方面的研究^[10-14],但大多数仅在拟合及预测的输出结果上进行优化过的和未优化的 Elman 神经网络比较,并以此为据,认为 GA-Elman 神经网络具有更高的精度和泛化性;同时,鉴于在煤矿水害防治领域及突水水源的判别中还未见过有关 GA-Elman 神经网络的相关参考文献,为此,笔者拟使用 GA 优化 Elman 神经网络并将其应用到突水水源判别中,从训练过程中的均方误差收敛速度、收敛精度以及判别输出精度上进行 Elman 神经网络和 GA-Elman 神经网络的对比,从而说明后者具有更高的准确性和泛化性.

1 Elman 神经网络结构与算法

Elman 神经网络是一种局部递归的神经网络,与前馈型 BP 神经网络相比,它除了包含输入层、隐含层和输出层外,还有一个特别的隐含层,即承接层.承接层可以认为是一个一步时延算子,用来接收反馈信号并记忆隐含层前一刻的输出状态,这些状态与外部输入信号一起作为当前时刻隐含层的输入^[15],其网络拓扑结构如图 1.这种自联方式使 Elman 神经网络具有适应时变特性的能力,并对历史状态的数据具有敏感性.由此可见,采用 Elman 网络可以大大减少节点数,减少计算量的同时亦提高了算法的实时性.

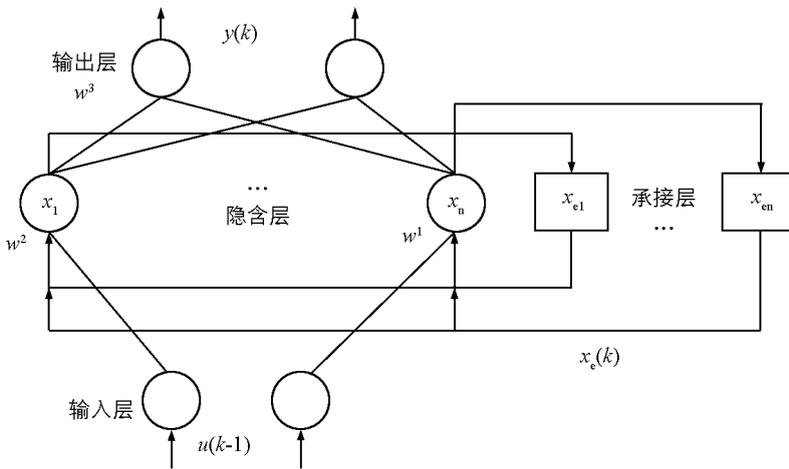


图 1 Elman 神经网络拓扑结构

Elman 神经网络的非线性数学模型为:

$$y(k) = g(w^3 x(k)) \quad (1)$$

$$x(k) = f(w^1 x_c(k) + w^2(u(k-1))) \quad (2)$$

$$x_c(k) = x(k-1) \quad (3)$$

其中: w^1, w^2, w^3 分别表示承接层到隐含层、输入层到隐含层、隐含层到输出层的连接权值矩阵; $f(\cdot)$ 为中间层神经元的传递函数; $y(k)$ 为 k 时刻 m 维输出层输出量; $x(k)$ 为 k 时刻 n 维隐含层输出量; $x_c(k)$ 为 k 时刻 n 维承接层反馈量; $u(k)$ 为 k 时刻 r 维输入层输入量.

Elman 神经网络采用标准 BP 网络算法来更新权值与阈值,其学习指标函数采用误差平方和函数,表达式为:

$$E(\omega) = \sum_{k=1}^n (y_k(\omega) - \hat{y}_k(\omega))^2 \quad (4)$$

式中 $\hat{y}_k(\omega)$ 为目标输出值.

该表达式使得网络学习指标函数的误差平方和最小, 以满足实际应用要求。

2 GA-Elman 神经网络模型的建立

由于 Elman 网络仍是采用标准 BP 算法梯度下降法进行权值和阈值的修正, 因此存在学习过程收敛速度慢、易陷入局部最小值的缺点。近年来新发展的遗传算法(Genetic Algorithm, GA)是模拟生物进化过程的人工智能方法^[16-17], 遗传算法将 Darwin 的“物竞天择、适者生存”生物进化思想应用到优化搜索算法中, 将搜索空间映射为遗传空间, 以适应度函数作为评价依据, 借助自然遗传学的遗传算子对编码群体进行交叉和变异, 实现群体中个体位串的选择和遗传, 建立起一个产生新解集种群的迭代过程。群体的个体在迭代过程中不断进化, 最后收敛到一个最适应环境的个体上, 从而求得问题的最优解。利用遗传算法的全局搜索能力和自身广泛的适应性, 对 Elman 神经网络的初始权值和阈值进行全局寻优, 然后将优化过后的初始权值和阈值反馈给 Elman 神经网络, 再利用 Elman 神经网络进行局部精确寻优, 做到二者的优势互补, 从而建立二者相结合的 GA-Elman 神经网络模型。GA 优化 Elman 神经网络的算法流程如图 2 所示。

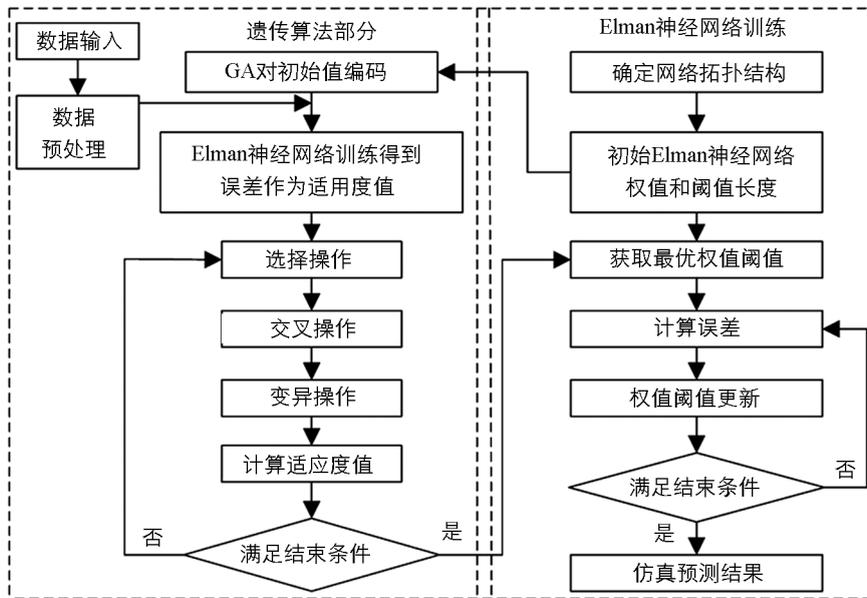


图 2 GA 优化 Elman 神经网络算法流程

其具体实现步骤如下：

步骤 1 初始化种群 P , 包括交叉概率 P_c 、变异概率 P_m 、终止代数 T 、代沟 G 等。采用二进制编码方法对 Elman 神经网络的权值和阈值进行编码, 确定初始种群规模 M , 随机生成初始种群。

步骤 2 计算个体的适应度函数, 并进行排序, 根据 $P_i = \frac{f_i}{\sum f_i}$ 选择网络个体, f_i 为第 i 个体适应度值, 用误差平方和 E_i 进行衡量, E_i 为第 i 个体的网络总误差, 即:

$$f_i = \frac{1}{E_i} \quad (5)$$

$$E(i) = \sum_k \sum_o (d_o - ro_o)^2 \quad (6)$$

式中: i 为染色体个数, $i=1,2,\dots,n$; k 为学习样本数, $k=1,2,\dots,m$; o 为 Elman 神经网络输出节点数, $o=1,2,L,q$; ro 为目标输出值; d 期望输出值。

步骤 3 以交叉概率 P_c 进行交叉操作, 交叉是遗传算法获取新优良个体的主要操作过程, 没有进行交叉操作的个体则进行复制。

步骤 4 以变异概率 P_m 进行变异操作, 这是为了保持个体的多样性, 确保遗传算法的有效性。

步骤 5 将新产生的个体插入原种群从而生成新种群,并计算新个体的适应度值.

步骤 6 若找到符合要求的个体,则算法结束;否则,重复步骤 2~5 的步骤,直到当前种群中的某个个体对应的网络结构满足要求.通过遗传算法对 Elman 神经网络进行种群生成、交叉和变异等操作,最终将优化后的网络权值和阈值赋值于 Elman 神经网络进行训练与判别.

3 实例分析

3.1 数据来源

以文献[18]中的矿井水化学数据为依据,在不破坏原始数据的前提下,对原始数据中 Na^+ , K^+ 质量浓度进行求和处理;仅选取 $\text{Na}^+ + \text{K}^+$, Ca^{2+} , Mg^{2+} , Cl^- , HCO_3^- , SO_4^{2-} 6 种离子作为判别水源的指标依据,以前 20 组水化数据作为训练样本,剩下的 6 组数据作为待测样本,为了更好地分析结果,将该矿突水水源类型进行二进制编码,其中(001),(010),(100)分别对应 4-6 煤顶板水、奥灰水、6 煤底至奥灰砂岩水 3 类水源.矿井水化数据如表 1(对于 6 组待测样本而言,右侧为真实水源类型的二进制编码,作为神经网络模型的期望输出).

表 1 矿井水化数据

mg/L

编号	$\text{Na}^+ + \text{K}^+$	Ca^{2+}	Mg^{2+}	Cl^-	SO_4^{2-}	HCO_3^-	水源类型
1	81.65	41.3	16.5	234.96	30.66	356.64	0 0 1
2	34.68	29.05	17.22	28.37	11.38	275.81	0 0 1
3	42.08	48.44	19.39	21.37	26.41	351.93	0 0 1
4	2.81	72.46	21.78	11.98	25.84	327.18	0 0 1
5	16.32	18.76	15.39	78.29	84.24	204.1	0 0 1
6	175.69	79.34	33.27	221.29	49.28	349.64	0 0 1
7	202.34	21.92	21.99	307.02	53.73	237.2	0 1 0
8	380.97	64.31	23.51	739.96	95.62	212.37	0 1 0
9	340.41	77.58	30.69	564.82	268.65	322.7	0 1 0
10	485.4	54.55	23.3	893.58	188.05	195.83	0 1 0
11	457.97	78.91	28.18	722.44	163.01	308.91	0 1 0
12	502.83	88.21	31.65	941.37	165.29	303.39	0 1 0
13	648.35	84.34	29.22	860.65	160.62	300.5	0 1 0
14	95.9	50.99	33.22	55.17	56.01	554.38	1 0 0
15	318.41	23.9	0	387.4	137.97	0	1 0 0
16	251.71	28.93	9.98	314.37	72.85	408.2	1 0 0
17	3.13	57.47	24.57	12.37	28.82	328.89	1 0 0
18	4.11	48.16	25.89	10.85	14.94	371.91	1 0 0
19	38.6	49.5	25.98	10.97	20.22	330.8	1 0 0
20	87.76	55.45	30.23	35.45	30.3	435.3	1 0 0
待测 1	133.73	73.92	32.16	192.18	93.34	405.44	0 0 1
待测 2	161.5	75.75	32.33	202.08	83.58	355.12	0 0 1
待测 3	249.86	91.54	32.42	284.47	22.55	375.29	0 0 1
待测 4	532.22	78.02	29.2	643.7	223.78	290.89	0 1 0
待测 5	596.17	56.45	23.4	800.56	123.34	209.78	0 1 0
待测 6	396.63	25.65	6.78	348.35	110.25	340.56	1 0 0

3.2 数据预处理

由于采集到的 26 组水化学数据样本各项指标值有大有小, 过大或过小的输入值将使节点的输出进入饱和区, 因此, 为防止某些数值低的特征被淹没, 且保留其原始意义, 需将各指标进行归一化处理. 采用 Matlab 的 `mapminmax` 函数将输入量归一化至 $[0, 1]$, 对数据进行线性变换、压缩, 可以为后面的数据处理提供方便, 亦可以保证程序运行时加快收敛速度.

3.3 Elman 神经网络模型的建立

Robert Hecht-Nielson 证明具有一个中间层的神经网络能够以任意精度逼近非线性关系. 增加网络中间层数能够进一步降低误差, 提高精度, 同时也会使网络复杂化, 牺牲其训练时间^[19-20]. 因此, 本文选用具有一个中间层的 Elman 神经网络, 以 $\text{Na}^+ + \text{K}^+$, Ca^{2+} , Mg^{2+} , Cl^- , HCO_3^- , SO_4^{2-} 6 种离子质量浓度值作为输入, 以 3 种突水类型的二进制编码作为输出, 输入层节点数为 6, 输出层节点数为 3. 网络的训练函数为具有 Levenberg-Marquardt 最快速算法 `trainlm` 函数, 该函数它同时具有梯度法和牛顿法的优点, 隐含层和输出层传递函数分别为 S 型的 `tansig` 和 `logsig`. 训练参数设定如下: 目标误差 $1\text{E}-10$, 最大训练次数 1 000, 学习速率 0.04, 结果显示周期 50. 根据 Kolmogorov 定理, 采用公式 $m = \sqrt{U+L} + a$ (其中 U 为输入层节点数; L 为输出层节点数; a 为 1~10 之间的随机整数.). 经试错法进行隐含层节点数的优选, 当节点数为 6 时 Elman 神经网络误差较小、效果较好, 使用 `newelm(minmax(pn), [6, 3], {'tansig', 'logsig'}, 'trainlm')` 语句建立了 $6 \times 6 \times 3$ 的 Elman 神经网络结构模型, 其模型结构图如图 3, 其训练过程如图 4, 训练结果如图 5.

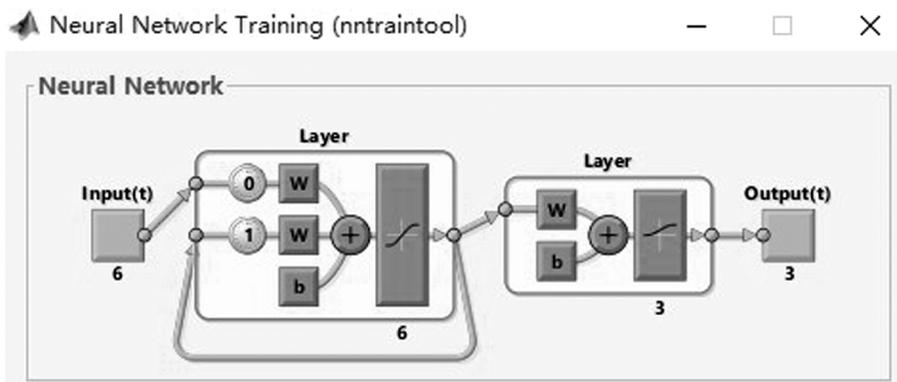


图 3 Elman 神经网络结构图

3.4 GA-Elman 神经网络模型的建立

遗传算法采用的是谢菲尔德 (Sheffield) 遗传算法工具箱, 这里的 Elman 神经网络权值与阈值总数为 69, 变量长度 R 为 5, 则遗传算法个体的长度 L 为 345, 其他参数设定为: 种群规模 M 为 50, 迭代终止次数 T 为 50, 代沟 G 为 0.95, 交叉概率 P_c 为 0.8, 变异概率 P_m 为 0.1, 按照 GA 优化 Elman 神经网络算法流程建立 GA-Elman 神经网络模型 (模型中的 Elman 神经网络参数设置与 3.3 相同). 其优化过程的适应度进化曲线如图 6.

图 6 的适应度进化曲线记录了每一代适应度值随进化代数变化的情况, 由此可以看出在第 5 代之后出现了种群适应度较大的进化, 平方和误差为 $2\text{E}-05$, 相比前 5 代, GA 算法的优化效果较为明

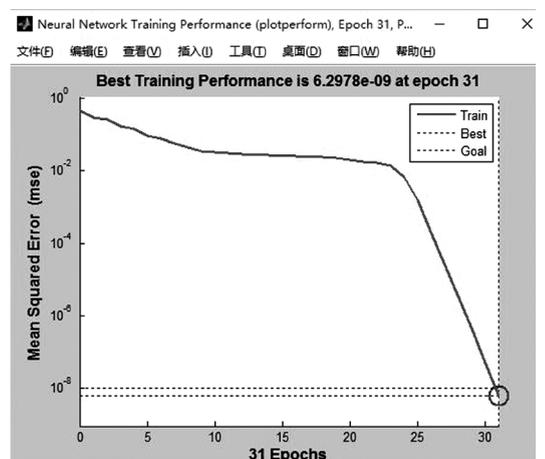


图 4 Elman 神经网络 MSE 收敛曲线

显, 能够使 Elman 神经网络快速收敛, 提高输出结果的精度; 随着遗传代数的增加, 在第 25 代出现了适应度的进一步进化, 呈递减趋势, 表明网络平方和误差的继续减小, Elman 神经网络输出结果精度进一步提高, 在第 26 代之后网络平方和误差基本趋于稳定, 在第 50 代时 GA 算法满足迭代终止要求, 寻优结束, 网络平方和误差达到最小值, 为 $1.8719E-05$. 此时, 将 GA 优化算法所得到的权重和阈值作为 Elman 神经网络的初始参数, 进行 Elman 神经网络的训练, 其训练过程如图 7, 训练结果如图 8, 从而建立 GA-Elman 神经网络判别模型.

Progress			
Epoch:	0	31 iterations	1000
Time:		0:00:00	
Performance:	0.450	6.30e-09	1.00e-08
Gradient:	0.0449	7.13e-08	1.00e-07
Mu:	0.00100	1.00e-13	1.00e+10
Validation Checks:	0	0	6

图 5 Elman 神经网络训练结果

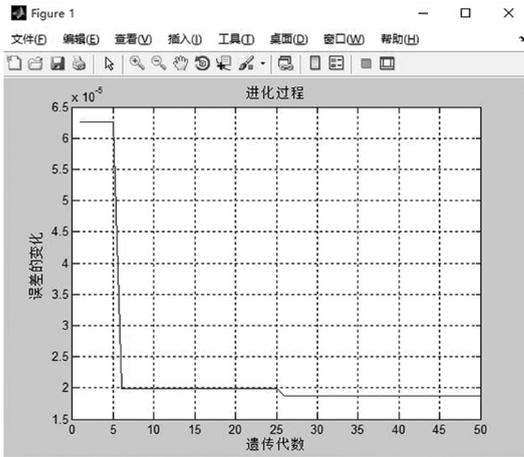


图 6 适应度进化曲线

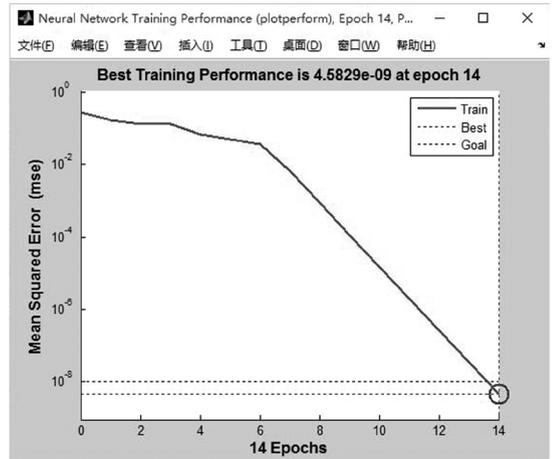


图 7 GA-Elman 神经网络 MSE 收敛曲线

Progress			
Epoch:	0	14 iterations	1000
Time:		0:00:00	
Performance:	0.283	4.58e-09	1.00e-08
Gradient:	0.121	2.88e-08	1.00e-07
Mu:	0.00100	1.00e-14	1.00e+10
Validation Checks:	0	0	6

图 8 GA-Elman 神经网络训练结果

由图 4 和图 7, 即 Elman 神经网络训练过程和经 GA 优化过的 Elman 神经网络训练过程对比可知, 前者在第 31 步达到收敛, 收敛曲线在前 24 步收敛较为缓慢, 之后收敛迅速, 网络均方误差 (Mean Squared Error, MSE) 最终为 $6.2978E-09$; 后者在第 14 步就达到收敛, 在第 6 步之前收敛较为缓慢, 之后快速收敛, 网络 MSE 最终为 $4.5829E-09$. MSE 是衡量“平均误差”的一种较方便的方法, 可以评价数据的变化程度, MSE 的值越小, 说明预测模型描述实验数据具有更好的精确度. 由此可以看出, 未优化的 Elman 神经

网相比与优化过的 Elman 神经网络, 后者在训练过程中具有收敛速度快、网络输出误差小的优点, 进一步发现后者的 MSE 收敛曲线减幅较为均匀, 这说明经 GA 优化过的 Elman 神经网络在约束过的局部范围内根据函数的梯度信息逐渐接近最小值, 而前者 MSE 收敛曲线减幅一开始较为缓慢在第 24 步之后则较为陡然, 从侧面反映出该收敛的最小值极有可能不是网络的最小值, 从而可以推测 Elman 神经网络在训练过程中存在一定随机性, 网络易陷入非全局最优的最小值. 由图 5 和图 8 可知, 二者采用 Levenberg-Marquardt 最快速算法的梯度求解最小值, 误差曲面的梯度均达到了预设值, 前者结束的梯度值大于后者的, 即前者仍具有潜力进入并接近误差曲面的最小值, 此时已经停止 Elman 神经网络的训练, 相比于后者, 这充分体现了 Elman 神经网络的易陷入局部最小值的缺点. 因此, 将 GA 与 Elman 神经网络进行结合可以发挥混合算法的优势, 提高网络的学习性和输出泛化性.

使用所建立的 Elman 神经网络模型和 GA-Elman 神经网络模型对表 1 的 6 组待测样本进行水源类型判别, 判别结果见表 2.

表 2 判别结果

待测样本	Elman 神经网络	GA-Elman 神经网络	Elman 误差	GA-Elman 误差	判别 结果	判别 准确性
	0.000 310	0.004 471				
1	0.000 003	0.000 018	$1.42E-04$	$2.67E-06$	4—6 煤顶板水	正确
	0.999 886	0.996 479				
	0.000 087	0.000 508				
2	0.000 007	0.000 006	$7.63E-05$	$5.91E-07$	4—6 煤顶板水	正确
	0.999 865	0.998 742				
	0.000 337	0.000 000				
3	0.000 001	0.000 004	$1.28E-04$	$2.17E-09$	4—6 煤顶板水	正确
	0.999 955	0.999 998				
	0.000 000	0.000 000				
4	0.999 996	1.000 000	$5.69E-06$	$1.94E-09$	奥灰水	正确
	0.000 013	0.000 006				
	0.000 000	0.000 000				
5	0.999 996	1.000 000	$1.87E-06$	$6.82E-11$	奥灰水	正确
	0.000 002	0.000 000				
	0.999 999	0.999 996				
6	0.000 018	0.000 008	$5.93E-06$	$4.78E-9$	6 煤底至奥灰砂岩水	正确
	0.000 000	0.000 002				

由表 2 可知, Elman 神经网络模型和 GA-Elman 神经网络模型均能对 6 组待测样本进行准确判别, 而且精度都很高. 可以看出, 任何一组待测样本的判别输出, 后者都要优于前者, 特别是第 3, 第 5 组的判别输出, GA-Elman 平方和误差远低于 Elman 平方和误差, 相差 5 个数量级. 经计算可知 Elman 神经网络判别模型输出的平均平方和误差为 $6.00E-05$, GA-Elman 神经网络模型输出的平均平方和误差为 $5.45E-07$, 平均误差精度相差 2 个数量级, 因而后者的判别输出精度更高, 泛化性更强. 二者输出的误差折线对比图见图 9.

图 9 显示, GA-Elman 神经网络判别模型在 6 组待测样本的输出上平方和误差更为平缓, 这表明 GA-Elman 神经网络判别模型输出较为稳定, 其误差折线均在 Elman 神经网络判别模型误差折线之下, 说明 GA-Elman 神经网络判别模型输出精度更高、泛化性更强.

另外, 前 3 组 2 种模型的折线距离相差较大, 后 3 组折线距离则相差较小, 究其原因, 可以给出这样的

推断: Elman 神经网络在训练过程中易陷入局部最优, 虽然收敛误差精度(相比于 BP 神经网络)有所提高, 但是网络输出的泛化性相比于 GA-Elman 神经网络仍是较弱, 在个别样本输出精度上出现一定的、较大的误差浮动。

此外, 结合表 1 的矿井水化学原始数据可以看出, 待测样本的前 3 组样本均来自于 4—6 煤顶板水水源, Elman 神经网络模型在判别这 3 组样本输出的结果均要低于后 3 组, 即经 GA 优化的 Elman 神经网络模型在前 3 组的判别输出中呈现: 第 1, 2 组样本的判别输出平方和误差均大于

第 4, 5, 6 组的判别输出平方和误差, 虽然第 3 组样本的判别输出平方和误差较第 1, 2, 6 组样本的的判别输出平方和误差要小, 但是仍然大于第 4, 5 组样本(均来自于奥灰水水源)的判别输出平方和误差。除此之外, 对于第 1, 2, 3 组样本的判别输出平均平方和误差为 $1.98E-07$, 第 4, 5 组样本的判别输出平均平方和误差为 $1.00E-09$, 6 煤底至奥灰砂岩水水源的样本仅有第 6 组, 其判别输出的平均平方和误差暂且认为是 $4.78E-9$, 则可以得知, GA-Elman 神经网络判别模型对奥灰水突水水源判别最为精确, 对于 6 煤底至奥灰砂岩水突水水源判别精度次之, 对于 4—6 煤顶板水突水水源判别精度最差; 同时发现表 1 的矿井水化数据中, 4—6 煤顶板水水源的样本为 6 组, 奥灰水水源的样本为 7 组, 6 煤底至奥灰砂岩水水源的样本为 7 组, 第一组的样本数量小于后两者, 由此可推知: ① 样本的数量与突水水源的准确判别有一定的关系, 也就是样本的多少对于模型的训练以及应用的适用性有一定的影响, 为发挥神经网络特有的学习和模拟能力优势、建立更好的突水水源非线性映射关系, 应尽量丰富样本的数量; ② 在收集工程实例资料时候应收集一手原始资料并注意水化学数据采集过程操作的准确度, 从而确保样本水化学数据具有代表性和准确性。这与文献[21—23]所得结论较为相符, 其中文献[21]建立 DDA 突水水源判别分析模型, 文献[22]建立了线性和典型的 FDA 突水水源判别模型, 文献[23]建立了多组逐步 Bayes 突水水源判别模型, 但均对来自于文献[24]的 1 号学习样本均做出了错误回判, 针对误判, 文献[21—23]均提到了选取样本数据要具有代表性, 建立样本数据库, 从而增强所建立判别模型的适用性。

4 结 论

1) 与文献[18]使用的 Fisher 和距离判别法相比, Elman 神经网络模型具有较强的自组织、自学习和容错能力。针对矿井突水水源类型之间具有很大的模糊性, 不易建立确定的相关模型的特点, 本文采用 Elman 神经网络通过选取常用的 6 种水化学离子及其质量浓度值作为依据建立水化指标与水源类型的非线性映射关系, 即建立了具有非线性动态特性的 Elman 神经网络突水水源判别模型, 发挥 Elman 神经网络对历史数据具有敏感性, 以及具有适应时变特性的能力的特点, 这为准确地判断突水来源、探寻地下水运移规律提供一定的借鉴价值。

2) Elman 神经网络训练过程中在第 31 步达到收敛, 网络的 MSE 为 $6.2978E-09$, GA-Elman 神经网络训练过程中在第 14 步达到收敛, 网络的 MSE 为 $4.5829E-09$; 前者所建立的判别模型输出平均平方和误差为 $6.00E-05$, 后者所建立的判别模型输出平均平方和误差为 $5.45E-07$ 。使用遗传算法通过初始化、适应度评价、选择交叉和变异等步骤对 Elman 神经网络的初始权值与阈值进行全局寻优, 克服了 Elman 神经网络的早熟收敛特性, 建立了高精度的 GA-Elman 神经网络判别模型, 相比较, 经过遗传算法优化过的 Elman 神经网络在训练过程中收敛性更好, 应用中泛化性更强、稳定性更高, 这为准确、有效判别突水来源提供了可靠的决策依据。

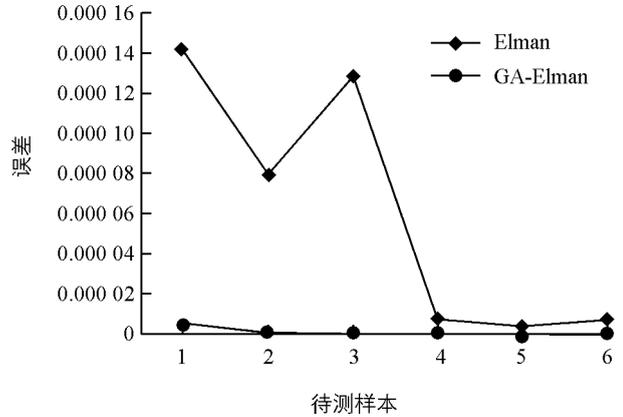


图 9 误差折线对比图

3) 本文建议,为进一步确保模型建立的有效性,应选取具有代表性、正确性的相关水质离子并建立完善的训练样本数据库;为进一步增加模型判别的准确性,应收集大量矿井的原始水质地质资料,理论与实际相结合,互相验证进行综合判别。密切结合矿井的水文地质条件,从而确保突水水源判别的准确性,发挥突水水源的确定对煤矿水害防治的指导作用。

参考文献:

- [1] 武 强. 我国矿井水防控与资源化利用的研究进展、问题和展望 [J]. 煤炭学报, 2014, 39(5): 795—805.
- [2] 鲁金涛, 李夕兵, 宫凤强, 等. 基于主成分分析与 Fisher 判别分析法的矿井突水水源识别方法 [J]. 中国安全科学学报, 2012, 22(7): 109—115.
- [3] 温廷新, 张 波, 邵良杉. 矿井突水水源识别预测研究——以新庄孜矿为例 [J]. 中国安全科学学报, 2014, 24(2): 100—106.
- [4] 杨永国, 黄福臣. 非线性方法在矿井突水水源判别中的应用研究 [J]. 中国矿业大学学报, 2007, 36(3): 283—286.
- [5] 徐忠杰, 杨永国, 汤 琳. 神经网络在矿井水源判别中的应用 [J]. 煤矿安全, 2007, 38(2): 4—6.
- [6] 祝 翠, 钱家忠, 周小平, 等. BP 神经网络在潘三煤矿突水水源判别中的应用 [J]. 安徽建筑工业学院学报(自然科学版), 2010, 18(5): 35—38.
- [7] 刘 猛. 基于 BP 神经网络的矿井水源判别模型 [J]. 矿业工程研究, 2015, 30(4): 17—20.
- [8] 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.
- [9] 徐 星, 郭兵兵, 王公忠. 人工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.
- [10] 蔡 鑫, 南新元, 孔 军. 改进 Elman 神经网络在氧化还原电位预测中的应用 [J]. 安徽大学学报(自然科学版), 2014, 38(2): 27—32.
- [11] 黄玉春, 田建平, 杨海栗, 等. 基于遗传算法优化 Elman 神经网络的机床热误差建模 [J]. 组合机床与自动化加工技术, 2015(4): 74—77.
- [12] 张秋余, 朱学明. 基于 GA-Elman 神经网络的交通流短时预测方法 [J]. 兰州理工大学学报, 2013, 39(3): 94—98.
- [13] 韩 丽, 戴广剑, 李 宁. 基于 GA-Elman 神经网络的电池劣化程度预测研究 [J]. 电源技术, 2013, 37(2): 249—250, 309.
- [14] 党小超, 郝占军. 基于改进 Elman 神经网络的网络流量预测 [J]. 计算机应用, 2010, 30(10): 2648—2652.
- [15] 李 胜, 韩永亮, 杨宏伟, 等. 露天矿边坡变形的 LMD-Elman 时序滚动预测研究 [J]. 中国安全科学学报, 2015, 25(6): 22—28.
- [16] 可华明, 陈朝镇, 张新合, 等. 遗传算法优化的 BP 神经网络遥感图像分类研究 [J]. 西南大学学报(自然科学版), 2010, 32(7): 128—133.
- [17] 陈 磊, 霍永亮. 利用改进的遗传算法求解非线性方程组 [J]. 西南师范大学学报(自然科学版), 2015, 40(1): 23—27.
- [18] 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(06): 41—42, 68.
- [19] 郑龙生, 杨晓霞. 基于 BP 神经网络模型的商务型饭店微观选址研究——以重庆市为例 [J]. 西南大学学报(自然科学版), 2011, 33(4): 162—165.
- [20] 温金梅, 李德龙, 周 军, 等. 基于人工神经网络的地下水动态预测模型的建立——以重庆东温泉为例 [J]. 西南大学学报(自然科学版), 2013, 35(6): 142—148.
- [21] 周 健, 史秀志, 王怀勇. 矿井突水水源判别的距离判别分析模型 [J]. 煤炭学报, 2010, 35(2): 278—282.
- [22] 陈红江, 李夕兵, 刘爱华, 等. 用 Fisher 判别法确定矿井突水水源 [J]. 中南大学学报(自然科学版), 2009, 40(4): 1114—1120.
- [23] 陈红江, 李夕兵, 刘爱华. 矿井突水水源判别的多组逐步 Bayes 判别方法研究 [J]. 岩土力学, 2009, 30(12): 3655—3659.
- [24] 张许良, 张子戊, 彭苏萍. 数量化理论在矿井突(涌)水水源判别中的应用 [J]. 中国矿业大学学报, 2003, 32(3): 251—254.

Discriminating Mine Water Inrush Sources Based on GA-Elman Neural Network

XU Xing, TIAN Kun-yun, LI Feng-qin, ZHAO Xin-tao

School of Safety Engineering, Henan Institute of Engineering, Zhengzhou 451191, China

Abstract: Coal mine water inrush is one of the natural disasters in mine safety production, and accurate discrimination of water inrush sources is an important foundation for water inrush prevention and control. Based on the difference in hydro-chemical composition of various aquifers, six major components ($K^+ + Na^+$, Ca^{2+} , Mg^{2+} , Cl^- , HCO_3^- and SO_4^{2-}) were selected as the discrimination factors of water inrush sources in a study reported in this paper. In order to overcome the disadvantages that Elman neural network is prone to fall into the local minimum value caused by the gradient descent method, a genetic algorithm (GA) with global search ability was adopted to train the Elman neural network by selecting, crossover and mutation. A GA-Elman neural network discriminant model with faster convergence speed and stronger generalization was established. The application results showed that the global optimization function of GA and the local precision optimization of Elman neural network were combined to overcome the randomness of the initial weights and threshold of Elman neural network and its proneness to fall into the local optima, thus improving the discrimination accuracy of Elman neural network output. It was a reliable basis for decision making for accurate and effective discrimination of the water inrush source. The mean square error convergence rate and accuracy of Elman GA neural network optimization were greatly improved in the training process, resulting in greater stability and better generalization in the discrimination output of the network model. It provided a reference for the model to be extended in other areas. In order to further ensure the water inrush discrimination accuracy and validity, in the premise of closely combining the hydrogeological conditions of the coal mine, representative and accurate hydration data should be selected so that this discrimination method may play a guiding role in the prevention and control of coal mine water disasters.

Key words: mine water inrush; water source discrimination; Elman neural network; genetic algorithm; GA-Elman neural network; generalization

责任编辑 胡 杨

