

K – means 聚类神经网络在边坡稳定性评价中的应用探究

徐 哲¹, 胡焕校², 邓 超²

(1. 中南大学 软件学院, 湖南 长沙 410075; 2. 中南大学 地球科学与信息物理学院, 湖南 长沙 410083)

摘要: 边坡稳定性研究内容具有非线性、复杂性、影响因素繁杂等特点,为了寻求对于边坡稳定性更加准确的评价,提出基于 K – means 聚类及神经网络的边坡稳定性评价模型,并发现 K – means 神经网络运用在边坡稳定性分析中具有可行的预测性及良好的精确度。针对 K – means 聚类对数据内在结构高效分层归并能力及神经网络自学能力的优缺点,选定 45 组实验数据,并选择其中容重、内摩擦角、黏聚力、坡角、坡高、孔隙水压力比 6 个影响因素,通过改进的 K – means 聚类方法进行分析并筛选出有效数据,再通过神经网络对输入的数据进行大量训练不断调整权值,输出稳定性评价安全系数。预测结果显示,此模型对边坡稳定性评价预测能力高于同类型分析方法。

关键词: K – means; 聚类分析; 神经网络; 边坡稳定性

中图分类号:TV861 文献标识码: A 文章编号: 1672- 643X(2017)03- 0198- 07

Study on the application of K – means clustering algorithm and neural network in slope stability evaluation

XU Zhe¹, HU Huanxiao², DENG Chao²

(1. School of Software, Central South University, Changsha 410075, China;

2. School of Geosciences and Info - Physics, Central South University, Changsha 410083, China)

Abstract: The study of the slope stability has the characteristics of non – linearity, complexity and complicated influence factors. In order to find a more accurate evaluation of slope stability, a slope stability evaluation model based on K – means clustering algorithm and neural network is proposed. It is found that the K – means neural network is feasible and accurate in slope stability analysis. By comparing the advantages and disadvantages of K – means clustering on the high efficient inherent hierarchical merging ability and self – learning ability of neural network , 45 groups of experimental data were selected, and 6 groups of influencing factors, which were bulk density, internal friction angle, cohesion, slope angle, slope height, pore pressure ratio , were analyzed and filtered out valid data through the improved K – means algorithm method Then the input data were put into a large number of training and adjustment of weight through the neural network , in order to output the safety factors of stability evaluation. Prediction results show that the predictive ability of the model to the stability of the slope is higher than that of the same type analysis method.

Key words: K – means; clustering algorithm; neural network; slope stability

滑坡、泥石流等灾害是严重危害人民群众生命财产安全和社会经济可持续发展的地质灾害。边坡防治与加固是一项复杂且具有挑战性的任务。由于影响因素复杂多变且获取完备资料难度较大,土体

介质不确定性,边界条件复杂,传统的力学方法论无法完全精准描述边坡稳定状态。在岩土工程领域,传统问题解析分析是以结构力学、弹塑性力学理论为基础的,计算机技术的迅速发展,越来越多的工程

技术难题可以用先进的计算机技术来解决^[1]。目前,大数据理论及人工智能领域较为活跃^[2]。

基于黑箱理论的模糊神经网络方法,由于其对数据强调输入量和输出量的精确要求,但对数据处理过程隐性化,并且对于数据具有自我学习和组织能力因而受到学界的重视和普遍应用^[3],薛新华等^[4]、Mo Lianguang 等^[5]将神经网络应用于岩土领域进行分析取得了良好的效果,国外也有其在煤炭开发的岩层稳定方面的研究^[6],国内也已将其应用于白云鄂博矿区的边坡稳定分析治理^[7]。但神经网络对于数据处理规则依赖于数据本身,数据质量好坏会对训练结果产生重要影响,但对此研究相对缺乏。因此,对于神经网络的优化显得尤为重要^[8]。针对此问题,本文以边坡参数为研究对象,使用 Matlab 工具以 45 组实例为基础,建立 K-means 神经网络基础评价模型,即应用 K-means 聚类按照参数差异性将数据划分为紧凑且独立的簇,对数据进行分类筛选进而提高神经网络拟合效果,对土坡进行稳定性评价。

1 人工神经网络

人工神经网络是以拓扑理论及生物学中神经网络为基础,模拟抽象人脑对外界刺激反应及信息处理功能的高度非线性及自学习能力的数学模型。神经网络是模拟人神经网络自学习能力所产生的一种人工智能算法,主要用于求解那些解空间较大且难于求得最优解的问题。模型将对内部权值(w)和阙值做一些调整以符合预期,如此反复,其掌握了样本及需求规律,再处理一些没有期望输出的样本来自行预测。神经网络是由大量神经元处理单元组成,分为输入单元、隐单元、输出单元这 3 类。

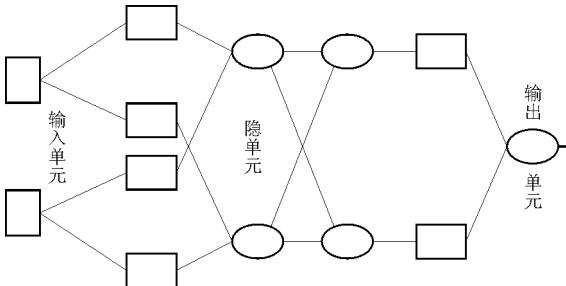


图 1 神经网络模型

如图 1 所示即为一个拥有五层系统的神经网络。其输出均方误差可以表示为:

$$E_c = \frac{1}{2} \sum_{p=1}^P \sum_{i=0}^{m-1} (d_i^{(p)} - y_i^{(p)})^2 \quad (1)$$

式中: m 为输出节点的个数; p 为训练样本个数; $y_i^{(p)}$ 为期望输出值; $d_i^{(p)}$ 为计算输出值; i 为具体变量。为了增加神经网络的收敛性,需要以最小化 E_c 为目标进行改进,可以分为两步进行切入,对于神经网络内部结构而言须要对权值(w)不断调整,对于输入系统而言要对初始输入参数进行优化,基于此,本文将对初始数据进行优化并使权值得到进一步调整。

2 基于 K-means 神经网络稳定性评价模型

2.1 K-means 算法

K-means 算法是一种基于划分的无监督学习聚类算法,其广泛应用于数据统计、机器学习及数据挖掘中,是一种较为经典的聚类算法,是一种硬类算法。K-means 算法简单速度快,并且不依赖于预先定义好的类,因此,选取 K-means 算法对神经网络数据进行初始优化。其思想是选择几个聚类中心,然后将样本数据代入其中计算其与聚类中心的距离,不断重复直至满足收敛要求。最终如果迭代结果值保持不变,那么最终满足迭代要求。K-means 算法与其他聚类算法的不同之处是需要事先给出原始数据所含的类数。具体步骤如下:

(1) 首先给定一个训练集 $\{x^{(1)}, \dots, x^{(m)}\}, (x^{(i)} \in R^n)$ 这些数据是没有被标记的,随机地将 k 个数据 $\mu_1, \mu_2, \dots, \mu_k (\mu_1, \mu_2, \dots, \mu_k \in R^n)$ 初始为类簇中心点;

(2) 重复迭代以下过程直至收敛:

对于每个样本 i ,计算与其距离最近的类簇 $c^{(i)}$, i 的值是 1 到 k 中的任意一个:

$$c^{(i)} = \arg \min_k \|x^{(i)} - \mu_k\|^2 \quad (2)$$

对于每个类簇 $c^{(i)}$,计算其样本容量改变后的簇类中心 μ_j :

$$\mu_j = \frac{\sum_{i=1}^m \mathbb{1}\{c^{(i)} = j\} x^{(i)}}{\sum_{i=1}^m \mathbb{1}\{c^{(i)} = j\}} \quad (3)$$

对于上述算法, k 为事先定义的聚类个数; $x^{(i)}$ 为任意一点。公式(2)是求出每个点所属的类,用 \arg 标识。公式(3)是不断重新计算各个类簇的类簇中心。最终,类簇中心不再变化或变化很小,即可停止计算。

2.2 相似度评价方法

两组数据 X, Y 都是由 n 个特征元素组成,设 $X = \{x_1, x_2, \dots, x_n\}, Y = \{y_1, y_2, \dots, y_n\} \in R$,那么 X 、

Y 的相异度可以定义为: $d(X, Y) = f(X, Y) \rightarrow R$ 。可以看出, X, Y 的相异度可以理解为一组映射。可以基于空间距离计算相异度。欧几里得距离评价算法, 是多维空间两点之间距离, 其公式表示为:

$$D(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4)$$

在求出各簇距离类簇中心之前, 要对数据进行标量规格化。之所以要将标量规格化, 主要原因是有些标量取值范围远大于一些取值范围较小的标量, 其对距离影响也较高。为了平衡各个因素对距离的影响, 我们将它使用映射公式(5) 映射到 $[0, 1]$ 区间。

$$a'_i = \frac{a_i - \min(a_i)}{\max(a_i) - \min(a_i)} \quad (5)$$

2.3 选取初始类簇中心

最简单的中心点选择法是随机选择 k 个点作为初始类簇中心点, 这种方法简单但可能误差较大。本文通过选择距离最远批次点作为聚类中心点, 即先选择一个点作为第一个类簇中心点, 然后选择距离此点最远点作为第二个类簇中心点, 然后将第三个类簇中心点选取距离该两点最远的点, 以此类推, 直至选出 K 个类簇中心点。

2.4 K-means 算法的最佳实践

K-means 算法在选取好拟定 k 值范围后, 取得最小开销函数值, 可结合 k -开销函数散点图, 有明显拐点的位置即为最佳 k 值。但 k 值选取要依赖于具体场景, 而不能仅仅依靠评估参数的选取。本文选用 Calinski-Harabasz 准则:

$$VRC_k = \frac{SSB}{SSW} \cdot \frac{N-k}{k-1} \quad (6)$$

式中: SSB 类间方差; SSW 是类内方差, $(N-k)/(k-1)$ 是复杂度; VRC_k 值越大, 证明分离度越大。

2.5 构造 K-means 神经网络改进模型

由于最基础 K-means 算法对噪声和离群点敏感, 而且初始类簇点选取过于影响神经网络权值 (w) 的选定, 因此按照前述思想通过 Matlab 工具对 K-means 算法改进并建立 K-means 神经网络模型^[9-15]。改进流程如下:

(1) 根据公式(5)初始化数据, 应用公式(4)计算各个元素之间的距离, 把相互之间距离最小的找出来, 求出数据矩阵的加权平均值, 将噪声点暂时除去。

(2) 根据公式(7)

$$M_i = \frac{\sum_{j=1}^r d(x_i \cdot x_j)}{A-1} \quad (i = 1, 2, \dots, A) \quad (7)$$

求出数据矩阵第 i 个列向量的均值 M_i , 其中 A 为数据总数, $d(x_i \cdot x_j)$ 为各个数据点之间的间距, 再求出所有列向量的均值:

$$\bar{M} = \frac{\sum_{i=1}^r M_i}{T} \quad (8)$$

最后计算出数据高密度半径:

$$M = \bar{M} + \min d(x_i \cdot x_j) \quad (9)$$

式中: $\min d(x_i \cdot x_j)$ 为数据间的最小间距。

(3) 根据公式(2)(3)求出类簇归并半径 m , m 为 M 加上数据点间的最小间距, 并可知两簇之间的最小归并距离为两倍的 m , 各个边界点间的最大距离为两倍的数据点间的最小距离。

(4) 按照 2.3 所述, 计算数据点的密度, 将初始簇类中心设置为高密度区域距离已有簇类中心最远的点, 如果之前没有簇类中心, 选择最远的点。

(5) 依次划分样本, 直至所有的数据都分布在不同的簇类中心。

(6) 依据公式(6)求解出最佳 k 值。并筛选出簇类点过于远离簇类中心均值的簇, 约占全部样本的 20%。

(7) 根据公式(1)不断调整权值, 并应用 Matlab 的 neural Network Toolbox 工具箱进行神经网络的拟合。

3 边坡稳定性因素分析

边坡稳定性影响因素主要集中于岩土体本身性质, 地质地形特征构造, 以及其他外界影响因素^[16]。K-means 及神经网络是以对数据判断为依据, 需要提供有效的参数来判定。影响边坡稳定性因素繁多, 输入参数过多会使最终表达的稳定性分析无规律而且数据收集困难, 选取参数过少则无法正确反映边坡稳定性内容, 因此要慎重选择需要的边坡稳定影响因素。本文选取以下 6 个参数作为研究的输入类型。

(1) 容重 γ 。容重是指物体单位体积的重量。土体容重反映土体特性及孔隙度和水气三相比例关系。随着降雨或地震土体边坡含水量含气量及孔隙度值都会发生改变, 这种情况下, 容重值会影响边坡稳定性评价。

(2) 内摩擦角 φ 。内摩擦角是土颗粒在滑动时与剪切面的临界自稳夹角, 大于这个角度, 土颗粒就能发生滑动, 小于这个角度, 土颗粒状态稳定。内摩擦角是土体抗剪强度的反应, 库仑公式证明其反映了土体的强度。

(3) 黏聚力聚力 c 。黏聚力是黏性土的特性指标。黏聚力分为 3 种：土颗粒分子引力见的原始黏聚力，土中化合物胶结的固化黏聚力，以及土壤分子间形成的毛细黏聚力。根据摩尔库伦公式，内摩擦角和黏聚力是影响土壤摩擦能力的重要力学指标。

(4) 坡角 α 。边坡角是指上一个台阶坡顶与下一个坡底线所假设的倾斜面与水平面的夹角。由极限条分法可知, 土体的力学性质分析时, 需要考虑边坡角的影响。

(5) 坡高 H 。边坡高度反映了边坡的体积和重量。即边坡越高体积越大, 体积越大重量越大。重量的增加导致土体的稳定性趋于降低。

(6) 孔隙水压力比 u 。孔隙水压力会使土体的

当 $k = 2$ 时第 1 组样本至 45 组样本所属类为: 2 2 2 2 2 1 1 1 1 2 2 2 1 1 1 1 1 2 1 2 2 1 1 1 1 2 2 2 1 1 1 2 2 2 2 1 1 1 1 2 2 2。

当 $k = 3$ 时第 1 组样本至 45 组样本所属类为: 3 3 3 3 2 1 1 1 1 3 3 2 1 1 1 1 1 2 1 3 3 1 1 1 1 3 3 3 2 2 1 1 3 3 3 3 3 1 1 1 1 3 3 3。

当 $k = 4$ 时第 1 组样本至 45 组样本所属类为: 4 2 2 2 3 1 1 1 1 4 2 3 1 1 1 1 1 3 1 2 2 1 1 1 1 4 2 2 2 1
3 1 1 4 4 4 4 4 1 1 1 1 2 2 4。

当 $k = 5$ 时第 1 组样本至 45 组样本所属类为: 3 5 5 5 4 1 1 1 1 3 5 4 1 1 1 1 1 4 1 5 3 1 1 1 1 3 3 5 5 1 4 1 1 2 2 2 2 2 1 1 1 1 5 5 2。

当 $k = 6$ 时第 1 组样本至 45 组样本所属类为: 4 6 6 6 2 1 1 1 1 4 6 5 1 1 1 1 1 2 1 6 6 1 1 1 1 4 6 6 6 3
3 3 3 4 4 4 4 4 1 1 1 1 6 6 4。

经过多次实验发现,所有类簇分类编号分配都是随机的,对其结果进行降维处理,以期全部数值聚类的类簇中心点为中心选定为原点,并将其坐标映射在(0,1)坐标系内可以直观的得到其类簇模拟分布图。如图 2 所示分别为 k 值为 3 ~ 4 的分布图。再分析求解最佳聚类数 k 值。

按照公式(3)求得所有簇类中心的参数值，并求出其平均值，根据公式(10)求出的为类间方差即SSB。

$$SSB = \sum_{i=1}^k n_i \| m_i - m \|^2 \quad (10)$$

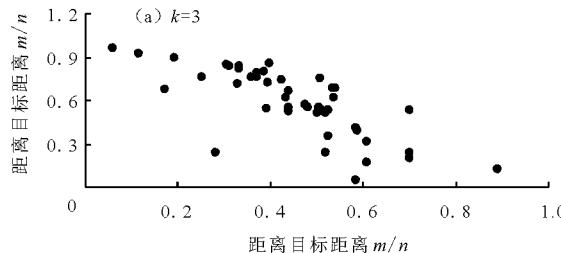


图 2 k 值为 3~4 类簇模拟分布图

抗滑能力降低，并且可以抵消一部分有效应力，还会增加土滑动能力，孔隙水压力比可以反映土水内部的作用效果。

4 应用实例

本文利用文献[12]中收集的45个边坡稳定性数据进行运用分析。

4.1 优化输入变量

将所有样本作为一个矩阵进行处理,即将所有参数作为一个 45 乘以 6 的双精度矩阵。将 k 值及此矩阵作为输入参量,期望输出分类结果的数据集合以及中心点集合。经过程序运行 1,2,3,4,5,6 分别为样本所属的类簇标号,其得到模拟结果如下。

式中: m_i 为某类的中心点; m 为所有点的中心点。

表 2 中的值分别是 k 为 2 ~ 6 时最终形成的中心点数据, 仅从 SSB 数据可以观察到当 $k = 5$ 之前其类间方差是在下降, 而当 $k = 6$ 时数据出现了类似失焦现象, 陡然增大。SSW 依据其计算方法可以知道按照分类的增多 SSW 值一定逐渐减小。根据(6)式可知, 后项的乘量是一个趋近于 1 的整数。由此验证, VRC_k 的值在 5 时出现拐点, 因此选取 5 为其最佳聚类个数。按照聚类结果不同分别对不同聚类类型组进行神经网络处理。

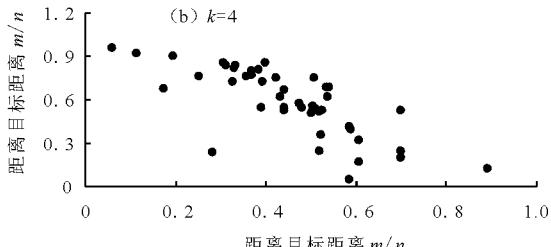


图 2 k 值为 3~4 类簇模拟分布图

表 2 不同 k 值下簇类分类中心点数据

k 值	组别	容重/($\text{kN} \cdot \text{m}^{-3}$)	黏聚力/kPa	内摩擦角/(°)	坡角/(°)	坡高/m	孔隙水压力比
2	第一组中心点	20.7455	10.0136	30.0245	38.0909	37.6136	0.2932
	第二组中心点	27.0478	48.1348	36.6522	43.8565	349.9348	0.25
	SSB	19.8594	726.6129	21.9632	16.621	48772	0.00093
3	第一组中心点	20.7455	8.74	29.992	37.8	29.125	0.2975
	第二组中心点	28.64	66.3	35.94	41.6	171.7	0.25
	第三组中心点	26.675	41.055	36.2	44.135	371.75	0.25
4	SSB	16.89	832.4538	12.3309	10.1664	29623	0.00075
	第一组中心点	20.4333	8.9905	30.04	37.9524	32.9762	0.2952
	第二组中心点	27.0545	47.0091	35.6364	44.8818	313.0909	0.25
5	第三组中心点	28.975	79.375	37.175	41.75	187.125	0.25
	第四组中心点	25.6684	42.2881	34.935	41.9516	244.1591	0.2613
	SSB	13.5185	1153.8612	11.0961	8.7449	30772	0.00051
6	第一组中心点	20.4333	8.9905	30.04	37.9524	32.9762	0.2952
	第二组中心点	28.975	79.375	37.175	41.75	187.125	0.25
	第三组中心点	25.46	47.8	36.4	43.8	389	0.25
7	第四组中心点	26.15	28	37	43	461.8333	0.25
	第五组中心点	27.70	46.0111	35.5556	45.0778	302.1111	0.25
	SSB	10.6785	683.0601	8.831713	7.4147	28733	0.0004
8	第一组中心点	19.2889	7.3333	30.0467	36.4444	22.2222	0.3028
	第二组中心点	31.30	68	37	48	206.75	0.25
	第三组中心点	27.30	22.075	29.925	45.5	106.875	0.25
9	第四组中心点	26.2111	33.7778	36.8889	43.2222	443.4444	0.25
	第五组中心点	26	150	45	30	200	0.25
	第六组中心点	27.0545	47.0091	35.6364	44.8818	313.0909	0.25
10	SSB	15.1506	2612.772	30.9786	46.0621	22191	0.00046

4.2 预测与决策

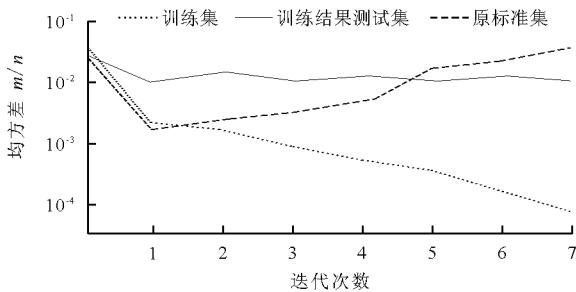
选取第 $k = 5$ 时的数据, 其中 $n = 3, n = 4$ 时无关性最大, 根据改进的稳定性分析模型, 将无关性最大的数据剔除, 通过公式(5)将数据标准化, 在 Matlab 里建立网络并设定参数。其中输入数据为 36 乘以 6 的矩阵, 经过多次不断调整权值(w)以后以期获得最佳的训练效果, 最终选择隐藏神经数设为 15 层, 训练数设置为数据的 60%, 另 20% 作为验证集, 最后 20% 作为测试一个模型在新数据上性能表现的数据。训练次数为 1000 次。

图 3(a)为单纯使用神经网络进行数据处理的均方差曲线, 图 3(b)使用 K-means 神经网络改进模型数据的均方差曲线。可以发现, 随着迭代次数

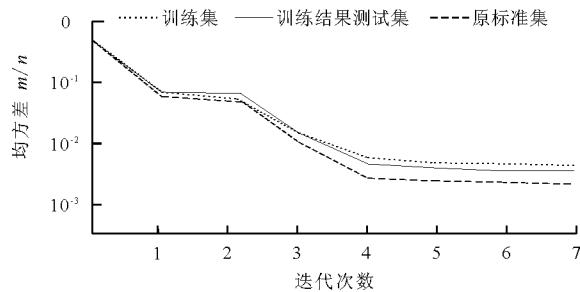
的增加, 其均方差曲线在不断迭代的过程中经过改进模型处理的数据不断趋于稳定, 神经网络在第 8 次迭代以后就建立起了稳定的判断模型。而单纯使用神经网络处理的数据具有明显不确定性, 神经网络的学习效果很不明显。

图 4(a)为单纯使用神经网络处理的拟合曲线, 图 4(b)为使用改进模型处理的拟合曲线。

由图 4 可以看出, 样本使用改进模型处理的拟合效果大大增强。且拟合线更接近于 $Y = T$ 曲线, 其数据处理过程更稳定。为了验证对于具体的数据判断的精确性是否提升, 随机选取 4 组数据分别与文献[12]中通过传统神经网络方法得到的数据进行对比, 结果见表 3。

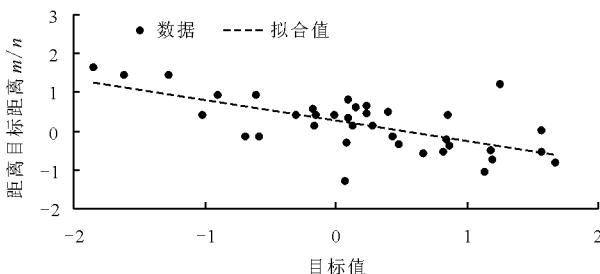


(a) 单纯神经网络数据处理均方差曲线

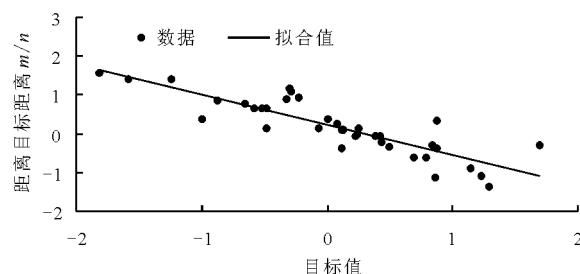


(b) K-means神经网络改进模型数据均方差曲线

图3 样本数据均方差图(纵坐标为对数坐标)



(a) 单纯神经网络处理拟合曲线



(b) K-means神经网络改进模型处理的拟合曲线

图4 样本拟合效果曲线图

表3 随机选取样本对比测试数据表

编号	容重/ (kN · m ⁻³)	黏聚力 c / kPa	内摩擦角 φ	坡角 β	坡高 H / m	孔隙水压力比 u	稳定系数 k	神经网络 判别法	聚类后的神经 网络判别法
23	24	0	40	33	8	0.30	1.58	1.595	1.578
25	18	5	30	20	8	0.30	2.05	1.704	1.890
39	22.4	10	35	30	10	0.25	2.00	1.645	1.860
40	21.4	10	30.34	30	20	0.25	1.70	1.557	1.769

从表3可以发现,仅仅使用普通神经网络判别法精确度较低,对数据聚类以后,精确度会有一定的提升,证明数据聚类在数据优化处理方面能力很强,且和神经网络运用在边坡土体的决策中具有很强的拟合能力,并且是可行的。

5 结 论

边坡稳定性分析因其具有参数不确定性,数据高度非线性,动态性和模糊性的特点,因而对于神经网络而言具有良好的适用性。且其数据采集困难,数据有效性和精确性都会影响稳定性评价。本文对传统神经网络方法在边坡稳定性评价中的运用进行分析和研究后,结合聚类划分有良好效果的K-means来构造新的基于K-means神经网络边坡稳定性评价模型,并结合实例与传统神经网络方法进行比较,表明此方法有效且拟合效果及评价精确度大大提高。并得到以下结论:

(1)要合理选择参数量,且参数数量适当,要调整对边坡稳定性分析影响的合理参数权重以达到良好效果。

(2)要通过计算并结合实际情况选择K-means的k值才能提高稳定性安全系数的精度。

(3)通过建立K-means神经网络模型可以使整个数据结构进行提升,数据质量及容错性提高,最终提高神经网络收敛速度和强度,进而提高判断能力。

(4)神经网络隐藏层数及训练方式可以借助Matlab工具箱进行调节,经过多次测试之后发现改进模型的处理效率及拟合能力均高于传统模型。

(5)K-means神经网络运用在边坡稳定性分析中具有可行的预测性及良好的精确度。

参考文献:

- [1] Jiang Minhui, Wang Shuangtao, Mei Jun, et al. Finite -

- time synchronization control of a class of memristor – based recurrent neural networks. [J]. Neural Networks, 2015, 63 (1) :133 – 140.
- [2] Armaghani D J, Mohamad E T, Hajihassani M, et al. Evaluation and prediction of flyrock resulting from blasting operations using empirical and computational methods [J]. Engineering with Computers, 2016, 32(1) :109 – 121.
- [3] Gordan B, Jahed Armaghani D, Hajihassani M, et al. Prediction of seismic slope stability through combination of particle swarm optimization and neural network [J]. Engineering with Computers, 2016, 32(1) :85 – 97.
- [4] 薛新华, 张我华, 刘红军. 基于遗传算法和模糊神经网络的边坡稳定性评价 [J]. 岩土力学, 2007, 28(12) : 2643 – 2648.
- [5] Mo Lianguang, Xie Zheng. Analysis on the stability of reservoir soil slope based on fuzzy artificial neural network [J]. Research Journal of Applied Sciences Engineering & Technology, 2013, 5(2) :465 – 469.
- [6] Rahul Khandelwal M, Rai Rajesh, Srivastva B K, et al. Evaluation of dump slope stability of a coal mine using artificial neural network [J]. Geomechanics and Geophysics for Geo – Energy and Geo – Resources, 2015, 1(3) :69 – 77.
- [7] Wang C Y, Zhang F, Han W D. A study on the application of RBF neural network in slope stability of Bayan Obo East Mine [J]. Advanced Materials Research, 2014, 1010 – 1012 (1) : 1507 – 1510.
- [8] Yang Z, Zhang D, Deng B, et al. Application of optimization model based on neural network in softening slope stability by strong rainfall infiltration [C]//. Fourth International Conference on Intelligent Control and Information Processing, IEEE, 2013 :289 – 292.
- [9] Afshar M, Gholami A, Asoodeh M. Genetic optimization of neural network and fuzzy logic for oil bubble point pressure modeling [J]. Korean Journal of Chemical Engineering, 2014, 31(3) :496 – 502.
- [10] Chai R, Ling S H, Hunter G P, et al. Brain – computer interface classifier for wheelchair commands using neural network with fuzzy particle swarm optimization. [J]. IEEE Journal of Biomedical & Health Informatics, 2014, 18 (5) :1614 – 1624.
- [11] Wang C, Wang L. Research on the ant colony optimization fuzzy neural network control algorithm for ABS [J]. Communications in Computer & Information Science, 2014, 483 :130 – 139.
- [12] Cao Y, Li Y. A two – stage approach of forecasting spare parts demand using particle swarm optimization and fuzzy neural network [J]. Journal of Computational Information Systems, 2014, 10(15) :6785 – 6793.
- [13] Hou Runmin, Hou Yuanlong, Wang Chao, et al. A hybrid wavelet fuzzy neural network and switching particle swarm optimization algorithm for AC Servo System [J]. Mathematical Problems in Engineering, 2016 :1 – 9. Doi. org/10.1155/2016/9724917.
- [14] Azad C, Jha V K. Fuzzy min – max neural network and particle swarm optimization based intrusion detection system [J]. Microsystem Technologies, 2017, 23(4) :907 – 918.
- [15] Ye J B, Lin G X. Fuzzy reliability optimization of automotive transmission shaft based on chaotic neural network [C]//. International Conference on Design, Manufacturing and Mechatronics, 2015 :813 – 817.
- [16] Shan Yinghua, Li Zhongfu. An improved fuzzy neural network model evolved by particle swarm optimization for construction supply chain performance evaluation [J]. ICIC Express Letters, 2014, 8(9) :2545 – 2550.