

DOI:10.16544/j.cnki.cn43-1494/u.202107230001

文章编号:1674-599X(2023)03-0060-07

引用格式:柳厚祥,李子意.基于MSR算法的公路隧道围岩分级方法[J].交通科学与工程,2023,39(3):60-66,97.

Citation:LIU Houxiang, LI Ziyi. Classification method for surrounding rock of highway tunnels based on MSR algorithm [J]. J. Transp. Sci. Eng., 2023, 39(3): 60-66, 97.

基于MSR算法的公路隧道围岩分级方法

柳厚祥, 李子意

(长沙理工大学 土木工程学院, 湖南 长沙 410114)

摘要:隧道围岩分级是隧道设计与施工的基础,直接影响隧道安全与运行。为实现对隧道围岩进行快速、准确地分级,基于机器学习中softmax回归线性分类模型,构建多分类softmax回归分级方法(MSR)。首先,综合考虑岩石坚硬程度、岩体完整程度、结构面产状、地下水状况、节理风化状况及初始地应力状态6项分级指标,并对其进行量化;其次,采用argmax函数作为决策函数,建立多分类器;然后,给定专家修正训练样本,利用python语言编写程序,学习最优判别函数,同时比较不同学习率下模型的精度;最后,导入测试集数据,经过模型自动演算,得出合理的围岩分级结果。结合那丘隧道BQ法对围岩进行分级。研究结果表明:①该算法具有可行性和较高的准确率,证实了将机器学习应用到隧道工程中可以提高工程施工效率;②与二分类器相比,多分类器能更好地解决围岩分级问题;③当学习率为0.01时,模型的分类性能最佳。

关键词:公路隧道;MSR算法;围岩分级;机器学习;多分类器

中图分类号:U451.2

文献标志码:A

Classification method for surrounding rock of highway tunnels based on MSR algorithm

LIU Houxiang, LI Ziyi

(School of Civil Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: The classification of tunnel surrounding rock is the basis of tunnel design and construction, which directly affects the safety and operation of the tunnel. In order to realize the rapid and accurate classification of tunnel surrounding rock, a multi-classification softmax regression classification method (MSR) was established based on the softmax regression linear classification model in machine learning. First, the six classification indexes, including rock hardness, rock mass integrity, discontinuity plane occurrence, groundwater condition, joint weathering condition, and initial in-situ stress state, are comprehensively considered and quantified. Second, the argmax function is used as the decision function to establish a multi-classifier. Then, the training samples were corrected by experts and the program is written in Python language to learn the optimal discriminant function. Meanwhile, the accuracy of the model under different learning rates is compared. Finally, the test set data is imported, and the model is automatically calculated to obtain a reasonable classification result of the surrounding rock. Combined with the surrounding rock classification of the Naqiu Tunnel BQ method, the research results show that: ① This algorithm is feasible and has high accuracy, which proves that applying machine learning to tunnel engineering can improve the construction efficiency; ② Compared with the binary classifier, multi-classifiers are better suitable for the classification of

收稿日期:2021-07-23

基金项目:湖南省水利科技项目(XSKJ2019081-39);湖南省教育厅科学研究重点项目(19A025);土木工程优势特色重点学科
创新性基金资助项目(17ZDXK01)

作者简介:柳厚祥(1965—),男,长沙理工大学教授,博士。

surrounding rocks; ③ When the learning rate is 0.01, the classification performance of the model is the best.

Key words: highway tunnel; MSR algorithm; rock mass classification; machine learning; multi-class classifier

现阶段隧道围岩分级主要采用Q法、BQ法、RMR法等传统方法来确定围岩级别。在进行分级时,岩体性质复杂,参数的实测值存在现场提取困难、测试数量有限等问题,导致数据的代表性和确定性均存在局限。

随着多领域学科间的交叉发展,统计学^[1-3]、计算机等基本理论被广泛应用于工程岩体质量评价。柳厚祥等^[4]结合深度学习和图像识别技术,通过卷积神经网络提取围岩分级判别因子,并将其转换为BQ值进行围岩分级。郑帅等^[5]基于机器学习与可靠度算法,提出了一种围岩动态分级方法。牛文林等^[6]通过运用支持向量机算法,较好地解决了小样本围岩分级问题。张研等^[7]利用高斯过程机器学习方法,建立了隧道围岩分类的高斯过程的二元分类方法(gaussian process for binary classification, GPC)。李天斌等^[8]采用改进自适应共振理论(adaptive resonance theory, ART1)神经网络模型,实现了实时学习的围岩分类。SANTOS等^[9]采用多元统计和人工智能技术对岩体进行分类,优化变量的选取,减少了主观性的影响。HOU等^[10]根据隧道施工过程中隧道掘进机(tunnel boring machine, TBM)的现场运行数据,提出了一种基于随机森林(random forest, RF)算法的岩体质量分类预测模型。多分类softmax回归分级方法(multi-class softmax regression, MSR)是基于机器学习中softmax回归线性分类模型构建的一种多分类机器学习算法,相较于其他机器学习分级方法,其具有模型结构简洁、影响因素少和分类效率高等优点。本研究采用在训练过程中学习大量隧道掌子面数据特征的MSR算法,不断地迭代,优化参数,对隧道围岩等级进行准确判定。

1 基本原理

1.1 机器学习的基本原理

机器学习利用计算机在已知数据中自主学习得到某种规律,利用该规律构建模型,并对未知数据进行预测^[11]。本文将其应用到隧道围岩分级中,

随机选取隧道桩号,列出每个桩号上围岩掌子面的岩石坚硬程度、岩体完整程度、结构面产状、地下水状况、节理风化状况及初始地应力状态的特征,构建6项分级指标和需要预测的标签(即I~V级分级结果)。每个桩号的标签可以通过试验和经验公式获得,也可以通过专家系统进行标记。将一个标记好的特征以及标签的掌子面看作一个样本,一组样本构成的集合称为数据集,其可分为训练集和测试集两部分。

通过样本特征的线性组合,构建预测的线性模型,用6维列向量 $\mathbf{x}=(x_1, x_2, x_3, x_4, x_5, x_6)^T$ 表示掌子面的6项分级指标所构成的向量,并称之为特征向量。其中,每个分量表示一个特征,而掌子面的分级结果标签用标量 y 来表示,则其线性组合函数为:

$$y = f(\mathbf{x}; \mathbf{w}) = w_1x_1 + w_2x_2 + \cdots + w_6x_6 + b \quad (1)$$

$$= \mathbf{w}^T \mathbf{x} + b$$

式中: $\mathbf{w}=(w_1, w_2, w_3, w_4, w_5, w_6)^T$ 为权重矩阵; b 为偏置矩阵。

机器学习的关键就在于算法通过给定的训练集,学习到最优的函数 $f^*(\mathbf{x}; \mathbf{w})$ 来近似每个样本的特征向量 \mathbf{x} 和标签 y 之间的映射关系。对于未知围岩级别的桩号,可以根据掌子面的特征,由学习到函数 $f^*(\mathbf{x}; \mathbf{w})$ 来判定围岩等级。

在给定由 N 个样本组成的训练集 D 后,通过学习算法 A 从一个函数集合 $F=\{f_1(\mathbf{x}; \mathbf{w}), f_2(\mathbf{x}; \mathbf{w}), \cdots, f_n(\mathbf{x}; \mathbf{w})\}$ 中自动寻找一个最优的函数 $f^*(\mathbf{x}; \mathbf{w})$ 。以预测结果的准确率 A_{cc} 来反馈学习算法 A 的合理性和模型的精度。

$$A_{cc}(f^*(\mathbf{x}; \mathbf{w})) = \frac{1}{|D|} \sum_{(\mathbf{x}, y) \in D} I(f^*(\mathbf{x}; \mathbf{w}) = y) \quad (2)$$

式中: $I(x)$ 为指数函数; $|D|$ 为测试集大小。

机器学习的基本流程如图1所示。对于某一掌子面围岩等级的预测,输入已知样本的特征向量 \mathbf{x} (分级指标),输出标签为 y (分级结果),选择一个函数集合 F ,通过学习算法 A 和训练样本 D ,从 F 中学习得到函数 $f^*(\mathbf{x}; \mathbf{w})$ 。这样对新的输入 \mathbf{x} ,就可以用函数 $f^*(\mathbf{x}; \mathbf{w})$ 进行预测,并得出合理的输出 y 。

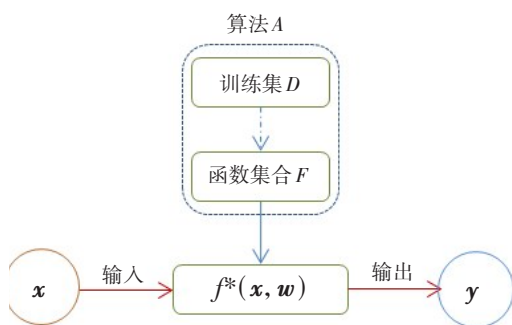


图1 机器学习基本流程图

Fig. 1 Basic flow chart of machine learning

1.2 MSR分级方法的基本原理

在隧道围岩分级过程中,由于输出目标 y 是I~V级5个离散的标签,由式(1)可知,函数 $f(x; w)$ 的值域为实数,因此,无法直接用 $f(x; w)$ 进行预测,需要引入一个非线性的决策函数 $g(x)$ 来预测输出目标:

$$y = g(f(x; w)) \quad (3)$$

其中, $f(x; w)$ 也称为判别函数。

马俊杰等^[12]提出了多分类支持向量机(multiclass support vector machine, MSVM)分级法,通过组合多个二分类器来构建多分类器,对于每两个围岩级别之间都进行一次预测,设置决策函数 $g(x)$ 为符号函数,其表达式为:

$$g(f(x; w)) = \text{sgn}(f(x; w)) = \begin{cases} +1, & f(x; w) > 0 \\ -1, & f(x; w) \leq 0 \end{cases} \quad (4)$$

当 $f(x; w)$ 大于零时,取前一等级;反之,为后一等级。

公路隧道围岩等级分为5个级别,且每个级别之间都是互斥的。如果直接采用简单的二分类法,则需要设置10个二值分类器,分别进行(I, II)、(I, III)、...、(IV, V)10组分类,统计各个等级出现的频率,以出现次数最高的等级作为围岩的最终级别。该方法分类组数繁多,分类步骤冗长,且当多个等级出现的次数相同时,需要进行二次计算。

因此,将其扩展到多分类问题,采用softmax回归多分类模型,设置决策函数 $g(x)$ 为argmax函数,其表达式为:

$$g(\text{softmax } f(x; w)) = \arg \max (\text{softmax } (f(x; w))) \quad (5)$$

先输入某一桩号掌子面的特征向量 x ,通过判

别函数计算出该掌子面的 5×1 维矩阵,再计算各个级别的概率,最后通过argmax函数判定分类模型取最大概率时 x 所属级别,计算原理如图2所示。

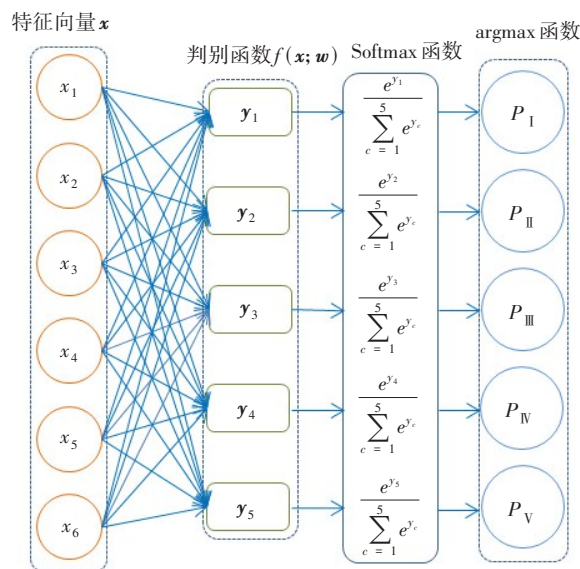


图2 MSR算法基本原理

Fig. 2 Basic principle of MSR

从图2可以看出,相较于多个二分类器,组合构建多分类器,其所采用的softmax函数可一次计算出该桩号掌子面围岩属于各个级别的概率。当计算样本量较大时,softmax函数便可体现其计算速度快、分类效率高的优势。

1.3 softmax回归多分类模型

softmax回归是一种特殊的广义线性模型,可用于解决多分类问题,目标标签 $y_1 \in \{1, 2, \dots, k\}$ 有 k 个取值。对于隧道围岩分级问题,类别标签 $y_2 \in \{I, II, \dots, V\}$ 有5个取值,分别为模型的5个节点。给定一个分级指标样本 x ,softmax回归预测属于级别 c 的条件概率为:

$$p(y = c | x) = \text{softmax}(w^T x + b)_c = \frac{\exp(w^T x + b)_c}{\sum_{c=1}^5 \exp(w^T x + b)_c} \quad (6)$$

由式(6)可知,softmax函数可以将输入值转化为(0,1)区间内的非负数输出值,且预测结果之和为1,满足概率分布特征。

当掌子面围岩的某些定性特征符合2个相邻级别的共同特征时,若采用max函数,则围岩等级判别结果只能取其中一个,而采用softmax函数则会判别出2个概率值相近的级别,再对其进行进一步分析,确定围岩的最终等级。

2 MSR 分级方法

2.1 分级指标量化

影响围岩稳定的因素众多,选取岩石坚硬程度、岩体完整程度、结构面产状、地下水状况、节理风化状况及初始地应力状态作为6项分级指标,参照BQ法划分标准^[13],对其作量化处理,以便用于模型计算。

由于softmax函数需要进行指数运算,为防止指数较大时产生的变化量过大,故控制指标量化值为0~1。同时,由于在每个分级指标内各划分等级所占的权重相同,因此,对其量化值作等差递增处理。

1) 岩石坚硬程度。

采用平均回弹值 R_m ^[14]代替单轴饱和抗压强度 R_c ^[13]作为定量评定指标进行分级,见表1。

表1 岩石坚硬程度指标量化表

Table 1 Quantification table of rock hardness index

定量评定 R_m / MPa	划分等级	量化值
>49.3	坚硬岩	0.2
(21.4, 49.3]	较坚硬岩	0.4
(10.1, 21.4]	较软岩	0.6
(3.2, 10.1]	软岩	0.8
≤3.2	极软岩	1.0

2) 岩体完整程度。

由于岩体体积节理数 J_v 值在勘察及施工阶段均容易获得,故将 J_v 值作为定量评定指标,见表2。

表2 岩体完整程度指标量化表

Table 2 Quantification table of rock integrity index

定量评定 J_v / (条·m ⁻²)	划分等级	量化值
<3	完整	0.2
[3, 10)	较完整	0.4
[10, 20)	较破碎	0.6
[20, 35)	破碎	0.8
≥35	极破碎	1.0

3) 结构面产状。

将结构面走向与洞轴线的夹角 θ 和结构面的倾角 β 作为定量评定指标,见表3。

4) 地下水状况。

通过目测法对地下水状况进行定性等级划分,见表4。

表3 结构面产状指标量化表

Table 3 Quantitative table of structural surface yield indicators

定量评定 $\theta, \beta / (^\circ)$	划分等级	量化值
$\theta > 60, \beta > 75$	极好	0.2
$\theta > 60, \beta \leq 75$	较好	0.4
$30 \leq \theta \leq 60$	一般	0.6
$\theta < 30, \beta > 75$	较差	0.8
$\theta < 30, 30 < \beta \leq 75$	极差	1.0

表4 地下水状况指标量化表

Table 4 Quantitative table of groundwater status indicators

定性评定	划分等级	量化值
岩体表面无水分	干燥	0.2
岩体表面有水分	潮湿	0.4
岩体表面水流呈点滴状	点滴状出水	0.6
岩体表面水流呈淋雨状	淋雨状出水	0.8
岩体表面水流呈涌流状	涌流状出水	1.0

5) 节理风化状况。

根据岩石结构构造及矿物色泽进行定性评定,见表5。

表5 节理风化状况指标量化表

Table 5 Quantification table of nodal weathering condition indicators

定性评定	划分等级	量化值
结构构造未变, 岩质新鲜	未风化	0.2
结构构造、矿物色泽基本未变	微风化	0.4
结构构造部分破坏, 矿物色泽较明显变化	弱风化	0.6
结构构造大部分破坏, 矿物色泽明显变化	强风化	0.8
结构构造全部破坏	全风化	1.0

6) 初始地应力状态。

根据岩体的变形特征及自稳性进行定性评定,见表6。

表6 初始地应力状态指标量化表

Table 6 Quantitative table of initial ground stress state indicators

定性评定	划分等级	量化值
岩体无较大变形, 自稳性较好	低地应力	0.25
岩体产生一定变形, 自稳性受影响	中地应力	0.50
岩体产生剥离, 有较大变形, 自稳性较差	高地应力	0.75
岩体产生流动变形, 无自稳性	极高地应力	1.00

2.2 分类模型训练

由式(6)可知,训练softmax回归多分类模型为学习最优参数矩阵。导入经过专家修正过的数据集,通过python语言编写计算机程序,让softmax回归多分类模型学习最优参数矩阵,包括权重矩阵 w 和偏置矩阵 b 。其中,权重矩阵 w 用于计算输入数据占各个分类级别的比重,偏置矩阵 b 用于修正预测结果。由于特征向量 x 为 6×1 维矩阵,则权重矩阵 w 为 6×5 维矩阵,偏置矩阵 b 为 5×1 维矩阵。

用于模型训练的200组训练集和50组测试集样本,均取自于湖南省永顺县那丘隧道。以桩号ZK11+530为例,该处掌子面围岩坚硬,岩体较破碎,结构面产状较好,地下水状况为点滴状出水,节理风化状况为微风化,初始地应力状态为中地应力,现场实测围岩等级为Ⅲ级。因此,输入特征向量 $x=(0.2, 0.6, 0.4, 0.6, 0.4, 0.5)^T$,输出标签 $y=(0, 0, 1, 0, 0)^T$,将其代入公式(1)计算参数矩阵,如式(7)所示。

为寻求模型的最佳分类性能,分别设置学习率 α 为0.001、0.005、0.010、0.050、0.100、0.500,根据式(8)进行2万次迭代。

$$\begin{bmatrix} a_1 & a_2 & a_3 & a_4 & a_5 & a_6 \\ c_1 & c_2 & c_3 & c_4 & c_5 & c_6 \\ d_1 & d_2 & d_3 & d_4 & d_5 & d_6 \\ e_1 & e_2 & e_3 & e_4 & e_5 & e_6 \\ f_1 & f_2 & f_3 & f_4 & f_5 & f_6 \end{bmatrix} \begin{bmatrix} 0.2 \\ 0.6 \\ 0.4 \\ 0.6 \\ 0.4 \\ 0.5 \end{bmatrix} + \begin{bmatrix} b_1 \\ b_2 \\ b_3 \\ b_4 \\ b_5 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \end{bmatrix} \quad (7)$$

$$W_{t+1} \leftarrow W_t + \alpha \left[\frac{1}{N} \sum_{n=1}^N x^{(n)} (y^{(n)} - y_{W_t}^{(n)})^T \right] \quad (8)$$

式中: α 为学习率; t 为迭代次数; N 为训练样本总数; $y_{W_t}^{(n)}$ 表示参数为 W_t 时,softmax回归模型的输出。

再根据式(2)计算不同学习率下softmax回归模

型的精度,并对结果进行数据可视化,如图3所示。




图3 精度与学习率的关系

Fig. 3 The relationship between accuracy and learning rate

学习率的大小决定了softmax回归模型的精度。随着学习率增大,精度提高,在学习率为0.01处达到峰值。但随着学习率继续增大,精度开始降低,意味着模型分类性能减弱。因此,设置学习率为0.01。

2.3 围岩等级判定

由图2及式(6)可知,softmax回归模型先将学习判别函数 $f(x; w)$ 在分类节点进行以 e 为底的指数运算,再除以各个输出节点运算结果的总和,作归一化处理,最后输出该桩号掌子面围岩各等级的概率。

该模型学习最优判别函数及判定围岩等级的过程均由计算机程序完成。在实际工程操作中,只需将某一掌子面围岩的特征作定量化处理,再输入自开发的围岩分级系统中,便可直接得到围岩分级结果,如图4所示。

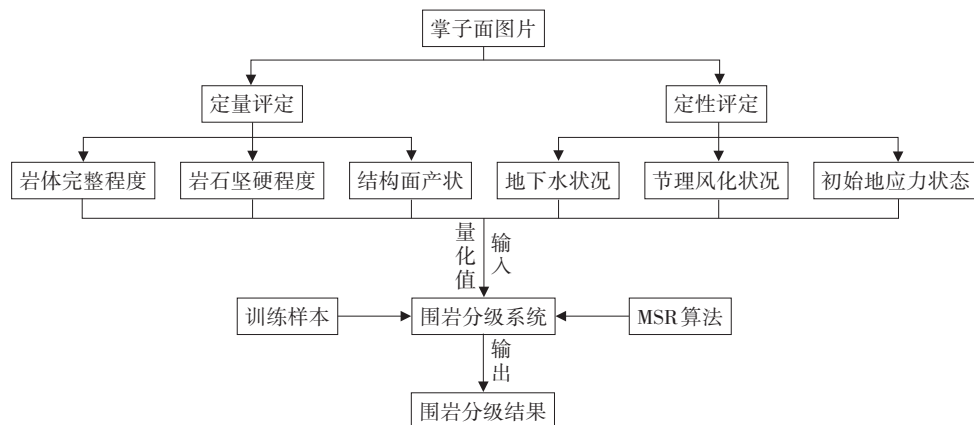


图4 MSR算法围岩分级流程

Fig. 4 Flow chart of rock mass classification based on MSR

3 工程验证

3.1 工程概况

那丘隧道位于湖南省湘西永顺县境内,为双洞单向交通隧道,埋深180 m,高程400~600 m。隧道处于岩溶发育区,沿线属于山地丘陵和河流地区。隧道围岩由微风化灰岩组成,以Ⅲ级围岩为主,局部岩溶发育地段的围岩等级为Ⅳ级,结构面产状多为中厚层结构,局部稳定性较差,易受地下水影响。

3.2 基于MSR方法进行围岩分级

选取那丘隧道开挖段掌子面,采集ZK11+140、ZK11+210、ZK11+330、ZK11+550、ZK11+800、YK10+510、YK10+530、YK10+550、YK10+570、YK10+590共10个桩号掌子面图像,提取围岩分级影响因素,并做量化处理,利用MSR法进行围岩分级,计算结果见表7。

表7 围岩分级不同方法对比表

Table 7 Comparison table of different grading methods

桩号	BQ法	MSR法	
		级别	判别准确率
ZK11+140	Ⅳ级	Ⅳ级	90%
ZK11+210	Ⅲ级	Ⅲ级	
ZK11+330	Ⅲ级	Ⅳ级	
ZK11+550	Ⅲ级	Ⅲ级	
ZK11+800	Ⅲ级	Ⅲ级	
YK10+510	Ⅳ级	Ⅳ级	
YK10+530	Ⅳ级	Ⅳ级	
YK10+550	Ⅲ级	Ⅲ级	
YK10+570	Ⅲ级	Ⅲ级	
YK10+590	Ⅲ级	Ⅲ级	

以桩号ZK11+140为例,该处掌子面围岩较坚硬,岩体较破碎,结构面产状较差,地下水状况为点滴状出水,节理风化状况为弱风化,初始地应力状态为高地应力。由于定量评定指标值需在现场测得,故仅展示掌子面围岩的局部图片,如图5所示。



(a) 地下水状况 (b) 节理风化状况 (c) 岩体破碎状态

图5 ZK11+140掌子面局部

Fig. 5 Partial view of the tunnel face

故得到一组特征向量 $\mathbf{x}=(0.40,0.60,0.80,0.60,0.60,0.75)^T$,代入式(1)运算,输出一个 5×1 维度的矩阵,即判别函数 $f(\mathbf{x};\mathbf{w})=(0.058,0.767,1.651,1.922,1.703)^T$ 。最后将 $f(\mathbf{x};\mathbf{w})$ 代入式(6)进行围岩等级判定,得到各围岩等级的概率: $P_I=5.1\%$, $P_{II}=10.4\%$, $P_{III}=25.1\%$, $P_{IV}=32.9\%$, $P_V=26.5\%$,因此该桩号掌子面围岩等级判定为Ⅳ级,见表8。

表8 示例桩号计算表

Table 8 Calculation table of example pile numbers

桩号	特征向量 \mathbf{x}	判别函数 $f(\mathbf{x};\mathbf{w})$	softmax 函数	argmax 函数	围岩 等级
ZK11+140	$\begin{bmatrix} 0.40 \\ 0.60 \\ 0.80 \\ 0.60 \\ 0.60 \\ 0.75 \end{bmatrix}$	$\begin{bmatrix} 0.058 \\ 0.767 \\ 1.651 \\ 1.922 \\ 1.703 \end{bmatrix}$	$\begin{bmatrix} 0.051\ 07 \\ 0.103\ 77 \\ 0.251\ 19 \\ 0.329\ 38 \\ 0.264\ 59 \end{bmatrix}$	32.9%	Ⅳ

同理,可以得到剩余9个桩号的掌子面围岩等级,分别为Ⅲ级、Ⅳ级、Ⅲ级、Ⅲ级、Ⅳ级、Ⅳ级、Ⅲ级、Ⅲ级、Ⅲ级。

3.3 与BQ法对比

BQ法是我国《工程岩体分级标准》规定的规范分级方法,其主要步骤是:

- 1) 根据岩石的坚硬程度和岩体完整程度两个基本因素,计算岩体基本质量指标BQ值,进行初步分级。
- 2) 根据地下水、软弱结构面以及初始应力3个修正因素确定修正系数,进行详细分级。
- 3) 按修正后的岩体基本质量指标BQ值,结合岩体的定性特征,综合评判围岩级别。

MSR法是基于机器学习原理建立的智能分级方法,其主要步骤是:

- 1) 采集指定桩号掌子面围岩分级的影响因素,将其经过量化处理后的结果作为一组6维的输入特征向量 \mathbf{x} 。
- 2) 将输入向量代入式(1)进行运算,得到一组5维的输出列向量。其中,参数矩阵通过样本训练获得。
- 3) 将输出列向量代入式(6)进行运算,得出各个围岩等级概率,概率最大类即为最终判定围岩等级。

对比结果见表7。由表7可知,MSR法的判别准确率为90%,具有较高的精度,可用于该隧道掌子面围岩等级的分类。

对于桩号 ZK11+330, MSR 算法出现了误判。其原因主要是该桩号掌子面围岩主要定性特征符合Ⅲ级、Ⅳ级围岩的共同特征,导致输出概率值 $P_{\text{Ⅲ}}$ 、 $P_{\text{Ⅳ}}$ 的差值较小。

4 结论

本研究在那丘隧道围岩分级工作的基础上,引入 softmax 回归算法,提出了隧道施工期围岩智能分级的 MSR 算法,得出结论:

1) MSR 算法在公路隧道围岩分级中具有一定的可行性和适用性。通过采用定性评定与定量评定相结合的办法,快速提取掌子面围岩分级参数,并将其量化。经过模型自动演算,得出各个级别的概率,实现了快速、准确地分级。

2) 在 softmax 回归模型学习最优参数矩阵的过程中,应选取合适的学习率,达到最优的分类性能,并设置合理的迭代次数,防止模型出现欠拟合及过拟合现象。

3) 训练样本的有限性导致了算法模型适用范围的局限性。本研究模型学习最优参数矩阵的样本仅取自永顺县那丘隧道。若能丰富训练样本的类型,可更好地优化参数矩阵和偏置矩阵,拓展其适用范围。

参考文献(References):

- [1] 张亦飞,程传国,张海丰,等.公路隧道围岩的区间数组合分类法[J].岩土工程学报,2008,30(12):1915-1920.
ZHANG Yifei, CHENG Chuanguo, ZHANG Haifeng, et al. Interval numbers-based integrated classification method for surrounding rock of highway tunnel [J]. Chinese Journal of Geotechnical Engineering, 2008, 30 (12): 1915-1920.
- [2] 张琦,朱合华,黄贤斌,等.基于 Mamdani 模糊推理的山岭隧道围岩 RMR14 分级[J].岩土工程学报,2017,39(11):2116-2124.
ZHANG Qi, ZHU Hehua, HUANG Xianbin, et al. A new rock mass rating method based on Mamdani fuzzy inference for rock tunnels [J]. Chinese Journal of Geotechnical Engineering, 2017, 39(11): 2116-2124.
- [3] 王迎超,孙红月,尚岳全,等.基于特尔菲-理想点法的隧道围岩分类研究[J].岩土工程学报,2010,32(4): 651-656.
WANG Yingchao, SUN Hongyue, SHANG Yuequan, et al. Classification of surrounding rock based on Delphi method and ideal point method [J]. Chinese Journal of Geotechnical Engineering, 2010, 32(4): 651-656.
- [4] 柳厚祥,李汪石,查焕奕,等.基于深度学习技术的公路隧道围岩分级方法[J].岩土工程学报,2018,40(10): 1809-1817.
LIU Houxiang, LI Wangshi, ZHA Huanyi, et al. Method for surrounding rock mass classification of highway tunnels based on deep learning technology [J]. Chinese Journal of Geotechnical Engineering, 2018, 40 (10) : 1809-1817.
- [5] 郑帅,姜谟男,张峰瑞,等.基于机器学习与可靠度算法的围岩动态分级方法及其工程应用[J].岩土力学,2019,40(S1):308-318.
ZHENG Shuai, JIANG Annan, ZHANG Fengrui, et al. Dynamic classification method of surrounding rock and its engineering application based on machine learning and reliability algorithm [J]. Rock and Soil Mechanics, 2019, 40(S1): 308-318.
- [6] 牛文林,李天斌,熊国斌,等.基于支持向量机的围岩定性智能分级研究[J].工程地质学报,2011,19(1):88-92.
NIU Wenlin, LI Tianbin, XIONG Guobin, et al. Support vector machines based intelligent rock mass classification method [J]. Journal of Engineering Geology, 2011, 19 (1): 88-92.
- [7] 张研,苏国韶,燕柳斌.基于高斯过程机器学习方法的隧道围岩分类模型[J].现代隧道技术,2011,48(6):32-37.
ZHANG Yan, SU Guoshao, YAN Liubin. Classification of rocks surrounding tunnel based on Gaussian process for machine learning [J]. Modern Tunnelling Technology, 2011, 48(6): 32-37.
- [8] 李天斌,王睿. ART1 神经网络在隧道围岩分类中的应用[J].成都理工大学学报(自然科学版),2006,33(5): 455-459.
LI Tianbin, WANG Rui. The application of ART1 neural network to the classification of surrounding rocks in tunnels [J]. Journal of Chengdu University of Technology (Science & Technology Edition), 2006, 33(5): 455-459.
- [9] SANTOS A E M, LANA M S, PEREIRA T M. Rock mass classification by multivariate statistical techniques and artificial intelligence [J]. Geotechnical and Geological Engineering, 2021, 39(3): 2409-2430.
- [10] HOU S K, LIU Y R, LI C Y, et al. Dynamic prediction of

(下转第97页)

- Science), 2005, 6(5): 447-450.
- [7] 杨仁树, 左进京, 李永亮, 等. 不同切缝管材质下切缝药包爆炸冲击波传播特性研究[J]. 中国矿业大学学报, 2019, 48(2): 229-235.
- YANG Renshu, ZUO Jinjing, LI Yongliang, et al. Experimental study of slotted cartridge explosion shock wave propagation characteristic with different cutting seam pipe material [J]. Journal of China University of Mining & Technology, 2019, 48(2): 229-235.
- [8] 杨国梁, 杨仁树, 佟强. 切缝药包掏槽爆破研究与应用[J]. 煤炭学报, 2012, 37(3): 385-388.
- YANG Guoliang, YANG Renshu, TONG Qiang. Research and application of cut blasting with slotted charge[J]. Journal of China Coal Society, 2012, 37(3): 385-388.
- [9] 杨仁树, 佟强, 杨国梁. 切缝药包掏槽爆破试验研究[J]. 煤矿安全, 2010, 41(10): 11-14.
- YANG Renshu, TONG Qiang, YANG Guoliang. Experimental study on cut blasting with slotted cartridge [J]. Safety in Coal Mines, 2010, 41(10): 11-14.
- [10] 周凯, 赵新琛, 张庆彬. 一种基于爆轰波波形调制的环向狭缝无药型罩气隙聚能爆破装药方法: CN110243244A[P]. 2019-09-17.
- ZHOU Kai, ZHAO Xincheng, ZHANG Qingbin. Annular slit non-shaped-charge-cover type air gap energy concentration blast charging method based on detonation wave waveform modulation: CN110243244A [P]. 2019-09-17..
- [11] 彭松. 切缝管狭缝聚能效应铅管模拟与隧道爆破试验研究[D]. 长沙: 长沙理工大学, 2017.
- PENG Song. Experimental study on the slit gathering energy effect in slotted pipe by means of lead-tube test and tunnel blasting [D]. Changsha: Changsha University of Science & Technology, 2017.
- [12] SONG Y Q, LI X S, GUO D Y, et al. Study on the decoupled charge effect in deep-hole cumulative blasting of coal seam [J]. Advances in Civil Engineering, 2019, 2019: 1-9.
- [13] WANG Y B. Study of the dynamic fracture effect using slotted cartridge decoupling charge blasting [J]. International Journal of Rock Mechanics and Mining Sciences, 2017, 96: 34-46.
- [14] YU Y, LU Y, LU Y. Numerical simulation of controlled perimeter blasting and field test on the fracture zones in Guanjiao tunnel [M]//Rock Mechanics: Achievements and Ambitions: CRC Press, 2011: 57-63.
- [15] SHU Y, SHAO P, DONG C, et al. Influence of rock strength on the propagation of slotted cartridge blasting-induced directional cracks [J]. Advances in Civil Engineering, 2019, 2019: 1-12.

(责任编辑:欧兆虎;校对:罗容;英文编辑:陈璐)

(上接第66页)

- rock mass classification in the tunnel construction process based on random forest algorithm and TBM in situ operation parameters [J]. IOP Conference Series: Earth and Environmental Science, 2020, 570(5): 52056.
- [11] PUNIA S K, KUMAR M, STEPHAN T, et al. Performance analysis of machine learning algorithms for big data classification: ML and AI-Based algorithms for big data analysis [J]. International Journal of E-Health and Medical Communications, 2021, 12(4): 60-75.
- [12] 马俊杰, 李天斌, 孟陆波, 等. MSVM在汶马高速公路隧道围岩分级中的应用[J]. 成都理工大学学报(自然科学版), 2019, 46(3): 373-380.
- MA Junjie, LI Tianbin, MENG Lubo, et al. Application of MSVM to the classification of surrounding rock in Wenchuan-Barkam Highway tunnels, Sichuan, China [J]. Journal of Chengdu University of Technology (Science & Technology Edition), 2019, 46(3): 373-380.
- [13] 长江科学院. 工程岩体分级标准: GB/T 50218—2014 [S]. 北京: 中国计划出版社, 2015.
- ChangJiang River Scientific Research Institute. Standard for engineering classification of rock mass: GB/T 50218—2014 [S]. Beijing: China Planning Press, 2015.
- [14] 方昱, 刘开云, 刘保国. 公路隧道施工期围岩快速分级的一种新方法[J]. 工程地质学报, 2013, 21(2): 190-198.
- FANG Yu, LIU Kaiyun, LIU Baoguo. Fast classification method for rock mass surrounding highway tunnel during construction [J]. Journal of Engineering Geology, 2013, 21(2): 190-198.

(责任编辑:罗容;校对:李脉;英文编辑:栗森)