

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20220639

基于贝叶斯网络的避雷器缺陷诊断

田雨鑫, 樊友平

(武汉大学电气与自动化学院, 湖北 武汉 430072)

摘要: 在实际工程中, 避雷器缺陷的样本较少, 利用神经网络之类的智能算法难以得出精准的判断。为此提出一种基于贝叶斯网络的避雷器缺陷诊断方法, 该方法首先通过主成分分析法提取了 21 个影响避雷器运行的特征参量, 随后考虑提取后的特征参量建立两层信息架构的缺陷诊断模型, 根据已有的实时数据计算不同类别下的分类概率, 若第一次分类结果表明避雷器异常, 则补充新的检测证据进行二次诊断。最后选用某地区同一电压等级下的 6 台避雷器, 分析和验证了所提方法的有效性和正确性。

关键词: 氧化锌避雷器; 多维度分析; 主成分分析; 贝叶斯网络; 缺陷诊断

中图分类号: TM86 **文献标志码:** A **文章编号:** 1000-7709(2023)01-0202-05

1 引言

避雷器是电网中重要的过电压保护设备, 其正常运行关系着电力系统的安全稳定运行和经济效益^[1]。目前, 氧化锌避雷器(MOA)因其优良的电气性能已普遍取代了传统的碳化硅阀片避雷器。但 MOA 仍会因为缺陷导致电气性能的降低甚至爆炸^[2]。为此, MOA 缺陷诊断对电网的安全稳定运行具有重要意义。在避雷器缺陷预警研究中, 早期采用单一特征量进行诊断, 后随着传感器和人工智能技术的发展, 采用智能算法进行分析逐渐成为主流。虽基于多维度、采用智能算法的方法准确率较高但智能算法对数据量有一定的要求。而在工程实际中 MOA 缺陷样本很少, 因此利用需大量样本的神经网络智能算法在 MOA 的缺陷诊断中局限性很大。为此, 本文提出了一种基于贝叶斯网络的避雷器缺陷诊断方法, 扩展了数据维度并采用智能分析算法, 进一步提高了避雷器缺陷诊断的准确性。

2 缺陷诊断整体框架

考虑到 MOA 缺陷样本的稀疏性, 综合在线监测、带电检测及设备台账等多源数据, 根据历史经验划分缺陷类型, 采用主成分分析法(PCA)^[3]

提取特征参量, 随后利用贝叶斯网络建立缺陷诊断模型。

由于实际工程中, 有些特征参量无法同时获取, 如检测和试验数据就存在时滞性。为解决此问题, 本文设计了两层信息框架^[4]的诊断模型, 见图 1。第一层根据实时信息做推理, 第二层输入非实时信息作为补充证据, 以第一次推理结果为先验信息, 计算后验概率, 更新诊断结果。




图 1 缺陷预警整体框架

Fig. 1 Overall framework of defect early warning

3 缺陷类型划分及主要特征量

3.1 缺陷类型及特征参量

根据实际电网中 MOA 的历史缺陷样本, 将 MOA 缺陷类型归纳为 4 个类型, 分别为受潮、老化、污秽和其他类型。影响 MOA 运行状态的特征参量及其来源见表 1。

3.2 主要特征参量

由于不同特征参量之间存在相关性会导致问题分析的复杂化, 且检测、试验等数据来源需耗费

收稿日期: 2022-03-02, 修回日期: 2022-04-15

基金项目: 南方电网科技项目(CGYPJXM20190372)

作者简介: 田雨鑫(1998-), 男, 硕士研究生, 研究方向为电力设备智能运维, E-mail: 1779276100@qq.com

表 1 特征量及其来源

Tab. 1 Data sources and feature quantities

编号	数据来源	特征量	编号	数据来源	特征量
X ₁	实时监测	泄漏电流全电流	X ₁₂	运维经验	缺陷类型
X ₂		阻性电流	X ₁₃	台账信息	设备生产商
X ₃		泄漏电流趋势变化量	X ₁₄		设备类型
X ₄		三相泄漏电流差异量	X ₁₅		投运时长
X ₅		动作次数	X ₁₆		设备外套类型
X ₆		动作次数增量	X ₁₇	天气	环境温度
X ₇	带电检测	红外是否异常发热	X ₁₈		空气湿度
X ₈		是否存在局部放电	X ₁₉		是否雾霾
X ₉	线下试验	直流 1 mA 参考电压/kV	X ₂₀		是否下雨
X ₁₀		75%U _{1mA} 下电流/μA	X ₂₁		是否有雷
X ₁₁		绝缘电阻			

大量人力、物力。为此,本文采用 PCA 提取 21 个特征量,尽可能采用一组关联程度小的特征量对缺陷进行诊断预警,在保证准确性的同时减少工作量。

采用 SPSS 软件对表 1 中的 21 个特征参量进行 PCA 分析,具体分析结果见表 2。

表 2 PCA 分析结果(特征值、贡献率和累计贡献率)

Tab. 2 PCA analysis results (eigenvalue, contribution rate and cumulative contribution rate)

主成分 编号	特征参量	特征值	贡献率	累计 贡献率
1	泄漏电流全电流	3.314	17.83	17.83
2	阻性电流占比	2.663	14.32	32.15
3	动作次数	2.147	11.55	43.70
4	红外是否发热	1.931	10.39	54.09
5	是否存在局部放电	1.746	9.39	63.48
6	是否有雷	1.227	6.60	70.08
7	设备生产商	1.019	5.48	75.56
8	设备外套类型	0.974	5.24	80.80
9	是否有雨	0.932	5.01	85.81
10	是否雾霾	0.781	4.20	90.01
11	绝缘电阻	0.416	2.24	92.25
12	直流 1 mA 参考电压	0.365	1.96	94.21
13	75%U _{1mA} 下电流	0.349	1.88	96.09
14	环境温度	0.231	1.24	97.33
15	空气湿度	0.222	1.19	98.52
16	投运时长	0.146	0.79	99.31
17	动作次数增量	0.127	0.69	100
18	泄漏电流趋势变化量	0	0	100
19	三相泄漏电流差异量	0	0	100
20	设备类型	0	0	100
21	缺陷类型	0	0	100

综合考虑精度要求和工作量后决定选取累计贡献度大于 90%。由表 2 可看出,在对避雷器进行缺陷诊断时,只需使用泄漏电流、阻性电流占比、动作次数等 10 个特征变量进行分析便可满足精度要求。

4 基于贝叶斯网络的预警模型

4.1 贝叶斯分类基本原理

假设现有一个待分类样本 $X_a = \{t_1, t_2, \dots, t_m\}$, 其中 t 为 X_a 的 m 个特征参量; 历史样本集中含有 n 个样本, $X = \{X_1, X_2, \dots, X_n\}$; 样本集内共有 k 个类别, 则分类标签集合即为 $C = \{C_1, C_2, \dots, C_k\}$ 。根据样本集内的历史信息, 统计每一类下各特征出现的概率, 并作为该类别下出现此特征的概率估值, 记为 $P(t_j | C_i)$, 待分类样本 X_a 属于 C_i 类别的概率记为 $P(C_i | X_a)$, 则根据贝叶斯公式可得:

$$P(C_i | X_a) = \frac{P(X_a | C_i)P(C_i)}{P(X_a)} \quad (1)$$

因为朴素贝叶斯假设各特征量独立, 则:

$$P(X_a | C_i)P(C_i) = P(C_i) \prod_{j=1}^m P(t_j | C_i) \quad (2)$$

由于对同一样本数据进行计算, 故 $P(X_a)$ 为一个定值, 式(1)可简化为:

$$P(C_i | X_a) = P(C_i) \prod_{j=1}^m P(t_j | C_i) \quad (3)$$

根据式(3)以此计算待分类样本属于各类别下概率, 若:

$$\max\{P(C_1 | X_a), \dots, P(C_n | X_a)\} = P(C_i | X_a) \quad (4)$$

则 $X_a \in C_i$, 即样本属于第 i 个类别。

由于朴素贝叶斯分类的一个重要假设是各特征量相互独立, 而 MOA 的各个特征量并不独立^[5]。为解决该问题, 采用贝叶斯网络进行分析, 摒弃特征量之间独立的假设, 充分考虑特征量之间的影响。

4.2 贝叶斯网络

贝叶斯网络在贝叶斯分类的基础上加入图表的形式来表征特征量之间的因果关系, 是一个有向无环图^[6]。图 2 为一个简单的 4 节点贝叶斯网




图 2 贝叶斯网络例图

Fig. 2 Example of Bayesian network

络, 节点代表各特征量; 两节点之间的线段表示两个节点之间的因果关系; 利用贝叶斯网络求解 X_1, X_2, X_3, X_4 的联合概率分布为:

$$P(X_1, X_2, X_3, X_4) = P(X_1)P(X_2)P(X_3)P(X_4 | X_1, X_2, X_3) \quad (5)$$

贝叶斯网络分为贝叶斯结构和条件概率表两

部分,结合 MOA 缺陷机理^[7]和样本数据集构建对 MOA 缺陷进行分析的贝叶斯网络,贝叶斯网络结构见图 3。




图 3 贝叶斯网络结构图

Fig. 3 Bayesian network structure diagram

4.3 MOA 缺陷诊断算法

MOA 缺陷诊断算法见图 4,具体实现流程如下。

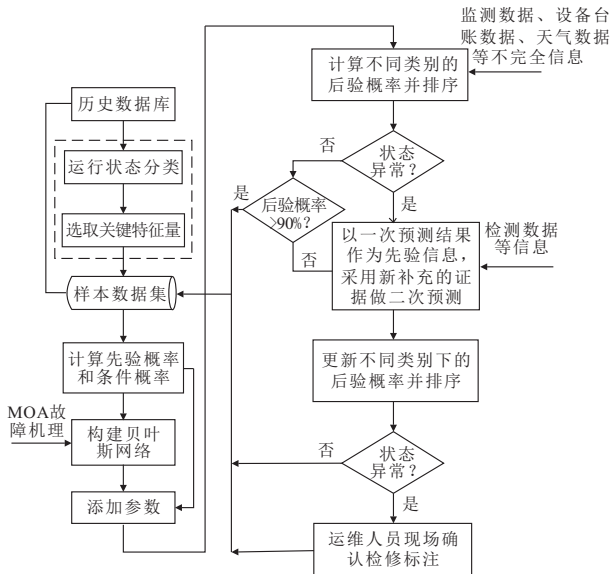


图 4 MOA 缺陷诊断算法

Fig. 4 MOA defect diagnosis algorithm

步骤 1 划分运行状态类别,选取关键特征量。

步骤 2 计算不同运行类别在样本集中出现的概率(即先验概率 $P(C)$):

$$P(C_i) = s(C_i) / L \quad (6)$$

步骤 3 计算不同类别下各特征量各取值的条件概率,对离散型特征量采用古典概型计算,计算公式为:

$$P(t = a | C_i) = \frac{s(t = a | C = C_i)}{s(C_i)} \quad (7)$$

对连续型特征量假设其服从高斯分布,用概率密度函数代替条件概率,从样本集中统计计算出各运行状态下特征量的均值 μ_i 和方差 σ_i^2 ,概率密度函数为:

$$P(t = a | C_i) = \frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{(t-\mu_i)^2}{2\sigma_i^2}} \quad (8)$$

步骤 4 结合 MOA 缺陷机理构建贝叶斯网络。

步骤 5 将监测数据、设备台账、天气数据等不完全信息输入贝叶斯网络,求出待分类样本的后验概率并排序,取概率最大的分类作为一次预测结果,若运行状态正常且后验概率大于 90% 则反馈到样本数据集,若运行状态异常或运行状态正常且后验概率小于 90% 进入下一步。

步骤 6 将第一次预测结果作为先验信息,补充检测数据等新证据做二次预测并排序,取概率最大的分类作为第二次预测结果,若运行状态正常反馈到样本数据集,若运行状态异常则通知现场运检人员。

步骤 7 运检人员现场确认结果并检修标记,形成新的样本存入样本数据集,更新修正上述步骤的先验信息。

5 实例验证

5.1 预备工作

统计某地变电站避雷器在线监测系统中的监测数据,结合该变电站的气象数据、避雷器台账数据和检修数据形成样本集 D ,样本集 D 中共计包含 2 000 条样本信息,样本集中含有 5 个类别 $C = \{正常运行,老化,受潮,污秽,其他\}$,数目分别为 1 860、45、42、31、22。

根据式(6)计算样本集中不同类别的先验概率,计算结果见表 3。

表 3 MOA 样本集中不同状态类型的先验概率
Tab. 3 Prior probabilities of different state types in the MOA sample set

状态类型	先验概率	状态类型	先验概率
正常	0.930 0	污秽	0.015 5
老化	0.022 5	其他	0.011 0
受潮	0.021 0		

统计样本集中各类别下各离散变量的数目(当数目为 0 时自动加 1),根据式(7)计算离散特征量特征变量 t_i 的条件概率 $P(t | C_i)$,计算结果见表 4。

通过高斯分布表示不同运行状态下连续特征量的条件概率分布,通过样本集计算得到连续特征量的样本均值和标准差,计算结果见表 5。

5.2 案例分析

选取某地区同一电压等级下 6 台避雷器的运行记录进行验证,6 台避雷器的运行状态分别为 {受潮;正常;受潮;老化;正常;污秽}。首先根据设备信息数据、天气数据和监测数据对 6 台避雷器做一次预测,再根据一次预测结果获取检测数

表 4 离散特征量条件概率

Tab. 4 Discrete feature quantity conditional probability

状态 类型	红外是否发热		局部是否放电		厂家类型		近 3 日雷情		近 3 日雾霾		近 3 日雨情			外套类型	
	是	否	是	否	A	其他	是	否	是	否	无	小	大	A	其他
正常	0.002	0.998	0.044	0.956	0.819	0.181	0.133	0.867	0.096	0.904	0.572	0.311	0.117	0.397	0.603
老化	0.842	0.158	0.330	0.670	0.220	0.780	0.653	0.347	0.176	0.824	0.467	0.329	0.204	0.413	0.587
受潮	0.897	0.103	0.713	0.287	0.200	0.800	0.213	0.787	0.217	0.783	0.072	0.345	0.583	0.732	0.268
污秽	0.945	0.055	0.187	0.812	0.125	0.875	0.424	0.576	0.714	0.286	0.671	0.227	0.102	0.186	0.814
其他	0.984	0.016	0.200	0.800	0.130	0.870	0.127	0.873	0.164	0.836	0.667	0.167	0.167	0.472	0.528

表 5 连续特征量样本均值和标准差

Tab. 5 Sample mean and standard deviation of continuous feature quantities

状态 类型	泄漏电流		动作次数		阻性电流占比	
	均值	标准差	均值	标准差	均值	标准差
正常	2.35	0.860	40	1.73	15	1.73
老化	3.20	0.285	44	3.00	23	3.00
受潮	4.53	4.660	41	1.07	30	2.14
污秽	2.60	0.870	40	1.47	22	1.07
其他	3.70	4.910	33	1.70	33	1.47

据做二次预测。选取的 6 台避雷器具体数据见表 6。

表 6 各避雷器具体数据

Tab. 6 Specific data of each arrester

避 雷 器	特征量							
	t_1 /mA	t_2 /%	t_3	t_6	t_7	t_8	t_9	t_{10}
1	2.15	27.44	38	Yes	厂家 A	其他类型	大雨	No
2	4.45	10.77	41	No	厂家 A	其他类型	大雨	No
3	1.52	29.34	44	No	其他厂家	其他类型	无雨	No
4	3.74	45.00	42	No	其他厂家	类型 A	无雨	No
5	4.61	10.21	38	No	厂家 A	其他类型	小雨	Yes
6	6.34	15.14	31	No	厂家 A	其他类型	无雨	No

以避雷器 1 的受潮运行状态计算为例,将表 5 中泄漏电流的标准差和样本均值代入式(8),可得到当泄漏电流取值为 2.15 时避雷器 1 受潮的概率为 $P(t_1=2.15|C_2)=0.0751$ 。

同理,阻性电流、动作次数条件下的避雷器 1 受潮概率分别为 0.091 1、0.007 32,根据式(3)可得到避雷器 1 受潮的分类概率为 2.247×10^{-9} 。得到各类别的分类概率后,对 6 台避雷器的分类概率进行排序得到分类结果,具体结果见表 7。

表 7 一次预测结果

Tab. 7 The first prediction results

项目	MOA1	MOA2	MOA3	MOA4	MOA5	MOA6
$P(C_1)$	3.22×10^{-16}	6.67×10^{-8}	5.85×10^{-20}	1.12×10^{-21}	1.03×10^{-7}	1.42×10^{-33}
$P(C_2)$	4.12×10^{-9}	7.92×10^{-13}	4.6×10^{-13}	1.48×10^{-4}	3.13×10^{-15}	5.02×10^{-37}
$P(C_3)$	2.25×10^{-8}	1.33×10^{-21}	2.87×10^{-8}	1.23×10^{-5}	1.32×10^{-26}	4.68×10^{-26}
$P(C_4)$	1.01×10^{-11}	6.66×10^{-31}	2.37×10^{-11}	6.97×10^{-5}	9.79×10^{-27}	4.11×10^{-26}
$P(C_5)$	5.51×10^{-10}	1.92×10^{-59}	1.88×10^{-9}	1.62×10^{-7}	3.81×10^{-59}	2.18×10^{-37}
分类	C_3	C_1	C_3	C_2	C_1	C_3
后验概率/%	82.77	99.99	93.78	64.31	99.99	53.24

此时当避雷器 1 发生受潮故障对应的后验概率为 $P(C_2 | X(t_1, t_2, t_3, t_6, t_9, t_{10}, t_{12}, t_{13})) = 82.77\%$ 。

由表 7 可看出,在以泄漏电流、阻性电流占比、动作次数、雷情、雨情、雾霾、设备生产商和设备外套类型为证据情况下,6 台避雷器的一次诊断结果和后验概率分别为{潮湿, 82.77%; 正常 99.99%; 潮湿, 93.78%; 老化, 64.31%; 正常 99.99%; 潮湿 53.24%}。由于 MOA2、MOA5 诊断结果为正常且后验概率为 99.99%,因此可不用补充证据进行二次诊断。

根据一次预测结果,现场对 MOA1、MOA3、MOA4、MOA6 进行带电检测,补充新的特征信息{红外发热,局外不放电;红外不发热,局外不放电;红外发热,局外不放电;红外发热,局外放电},进行二次预测,预测结果见表 8。

表 8 二次预测结果

Tab. 8 Secondary prediction results

项目	MOA1	MOA3	MOA4	MOA6
$P(C_1)$	2.83×10^{-19}	5.58×10^{-20}	2.14×10^{-24}	2.72×10^{-36}
$P(C_2)$	1.14×10^{-9}	4.87×10^{-14}	8.35×10^{-5}	2.83×10^{-37}
$P(C_3)$	1.44×10^{-8}	8.49×10^{-10}	3.17×10^{-6}	1.21×10^{-26}
$P(C_4)$	1.79×10^{-12}	1.06×10^{-12}	5.35×10^{-6}	3.16×10^{-26}
$P(C_5)$	1.08×10^{-10}	2.41×10^{-11}	1.28×10^{-7}	1.72×10^{-37}
分类	C_3	C_3	C_2	C_4
后验概率/%	92.01	97.12	90.62	72.31

由表 8 可看出,再补充证据后 MOA6 的诊断结果由潮湿变为污秽且后验概率由 53.24% 提升为 72.31%。其余 3 个避雷器诊断结果未变,但后验概率均有提升。最后诊断结果为{潮湿; 正常; 潮湿; 老化; 正常; 污秽}。对照 6 台避雷器的运维记录,诊断结果正确,由此验证了该方法的有效性和正确性。

6 结论

为提高 MOA 的缺陷诊断精度,本文提出了一种基于贝叶斯网络的避雷器缺陷诊断方法。与传统的缺陷诊断方法相比,该方法利用 PCA 尽可能地考虑更多的特征参量,面对有些特征参量存在时滞性的问题设计了两层信息框架,首先根据实时数据进行一次诊断,若诊断结果异常或正常未超过阈值则补充证据进行二次诊断更新诊断结果。最后利用 6 台实际避雷器的多源数据验证了

所提方法的有效性。

参考文献:

[1] 张金凤,郭洁,李可伦,等. 特高压无间隙金属氧化物避雷器均压电容柱电位分布研究[J]. 高压电器, 2018,54(1):170-175.

[2] Y HAN,Z LI,H ZHENG, et al. A decomposition method for the total leakage current of MOA based on multiple linear regression[J]. IEEE transactions on power delivery,2016,33(4):1422-1428.

[3] 赵伟静,王红瑞,丁小萌,等. 基于聚类与主成分分析的城市节水型社会建设差异性分析[J]. 水电能源科学,2020,38(2):56-60.

[4] 彭红霞,文艳,王磊,等. 基于两层知识架构的电力设备差异化运维技术[J]. 高压电器, 2019, 55(7): 221-226.

[5] 李亚锦,刘英男,于大洋. 基于小样本及贝叶斯推理的避雷器缺陷分类技术[J]. 电工电能新技术, 2021, 40(11):56-63.

[6] 段志昌,王建有,王特,等. 基于贝叶斯网络的水面蒸发评估模型研究[J]. 水电能源科学, 2021,39(3): 1-4.

[7] 张古尧,马爱清. 基于随机失活 LSTM 网络的避雷器阻性电流预测方法[J]. 水电能源科学, 2020, 38(10):159-162,98.

Arrester Defect Diagnosis Based on Bayesian Network

TIAN Yu-xin , FAN You-ping

(School of Electrical and Automation, Wuhan University, Wuhan 430072, China)

Abstract: In practical engineering, there are few samples of arrester failures, and it is difficult for intelligent algorithms such as neural networks to make accurate judgments. To this end, a fault diagnosis method of arrester based on Bayesian network was proposed. Firstly, the principal component analysis was used to extract 21 characteristic parameters that affect the operation of arrester. And then the extracted characteristic parameters was chosen to establish two-layer information architecture defect diagnosis model. The classification probability of different categories was calculated according to the existing real-time data. If the first classification result indicated that the arrester is abnormal, new detection evidence was added for the second diagnosis. Finally, 6 arresters under the same voltage level in a certain area were selected to analyze and verify the validity and correctness of the proposed method.

Key words: Zinc oxide arrester; multi-dimensional analysis; principal component analysis; Bayesian network; defect diagnosis

(上接第 115 页)

[2] 王大伟,沈鹏. 高速公路改扩建工程路堑高边坡支护机理与效果[J]. 长安大学学报(自然科学版), 2017,37(3):39-46.

[3] 秦凤艳,杨富莲,刘洪波,等. 常见边坡支护形式的地震稳定性对比分析[J]. 地震工程学报, 2017, 39(3):460-466.

[4] 艾胜军,梁庆国,赵涛,等. 黄土隧道洞口段坡—隧系统地震动力响应振动台试验研究[J]. 地震工程与工程振动,2020,40(6):168-177.

[5] 徐光兴. 地震作用下边坡工程动力响应与永久位移分析[D]. 成都:西南交通大学,2011.

[6] 江卫华,熊峰,刘乳燕,等. 强度折减法在三维有限元边坡稳定分析中的应用[J]. 水电能源科学, 2018, 36(3):145-149.

[7] 中华人民共和国水利部. 水利水电工程边坡设计规范: SL386-2007[S]. 北京:中国水利水电出版社,2007.

[8] 全国地震标准化技术委员会. 中国地震动参数区划图:GB18306-2015 [S]. 北京:中国标准出版社, 2016.

Analysis of Slope Support Effect and Seismic Resistance of Tunnel Opening Section of Hami Pumped Storage Power Station in Northwest China

ZHANG Yan-fei¹, REN Jian-min¹, YIN Kun², XIANG Jun-long²

(1. School of Civil Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China;
2. Sinohydro Bureau 5 Co., LTD., Chengdu 610066, China)

Abstract: In order to analyze the dynamic response law of geotechnical slope, support and cavity structure under strong earthquake, taking a cavity section project in northwest China as an example, this paper firstly proposed a comprehensive management plan and then analyzed the management effect by combining field monitoring and FLAC^{3D} numerical simulation. Finally, the effect of support structure and cavern chamber on the dynamic response of rocky soil slope was analyzed under strong seismic load, and some suggestions for seismic protection of cavern section were discussed. The results show that after the treatment, the stability coefficient increases from 1.140 to 1.473, an increase of 29.2%; The imposition of the support structure effectively reduces the acceleration and displacement of the slope and cave roof axis; The presence of the cave chamber has a greater impact on the cave axis compared with the impact of the slope dynamic amplification effect; By analyzing the acceleration of the slope and the tunnel axis vault lining, the maddle is very important for the slope seismic resistance. It is suggested that the seismic protection length of the project should take the range of 3.4 and 4.8 times the diameter of the cave.

Key words: cave section; geotechnical slopes; prestressed anchors; dynamic response; seismic protection length