

<https://doi.org/10.3799/dqkx.2022.147>



基于人工智能变形预测隧道坍塌失效概率评估方法

吴波^{1,2,3}, 丘伟兴^{1,6}, 徐世祥^{1*}, 蔡俊华⁴, 李贻材⁵, 张耀⁵

1. 广西大学土木建筑工程学院, 广西南宁 530004
2. 东华理工大学土木与建筑工程学院, 江西南昌 330013
3. 广州城建职业学院建筑工程学院, 广东广州 510925
4. 三明莆炎高速公路有限责任公司, 福建三明 365000
5. 中铁十一局集团第一工程有限公司, 湖北襄阳 441104
6. 中南大学土木工程学院, 湖南长沙 410075

摘要: 当隧道坍塌事故发生时, 决策者往往没有足够的反应时间去采取相应的加固措施. 超前预测隧道坍塌失效概率已成为隧道工程建设的关键问题. 为了超前评估隧道坍塌失效概率并及时预警, 本研究提出了一种多数数据融合方法. 该方法将云模型(CM)、多输出高斯过程回归(MOGPR)和改进的 D-S 理论相结合. 通过融合多项监测数据(拱顶位移、水平收敛位移), 减少数据的不确定性, 提高评估结果的准确性和鲁棒性. 此外, 利用人工智能预测的围岩变形作为信息源, 得到超前的坍塌失效概率评估. 并将该方法运用于金珠帕隧道, 为决策者提供更多的响应时间. 最终, 围岩支护只产生少量的变形裂缝, 避免了隧道坍塌的发生.

关键词: 隧道坍塌; 失效概率评估; 云模型; D-S 理论; 多输出高斯过程回归; 安全工程; 工程地质.

中图分类号: P64

文章编号: 1000-2383(2024)11-4204-12

收稿日期: 2022-04-18

A Method for Assessing Probability of Tunnel Collapse Based on Artificial Intelligence Deformation Prediction

Wu Bo^{1,2,3}, Qiu Weixing^{1,6}, Xu Shixiang^{1*}, Cai Junhua⁴, Li Yicai⁵, Zhang Yao⁵

1. College of Civil Engineering and Architecture, Guangxi University, Nanning 530004, China
2. School of Civil and Architectural Engineering, East China University of Technology, Nanchang 330013, China
3. School of Architectural Engineering, Guangzhou City Construction College, Guangzhou 510925, China
4. Sanming Traffic Construction Group Co., Ltd., Sanming 365000, China
5. The 1st Engineering Ltd. of China Railway 11th Bureau Group, Xiangyang 441104, China
6. School of Civil Engineering, Central South University, Changsha 410075, China

Abstract: When a tunnel collapse occurs, decision makers often do not have enough reaction time to take appropriate reinforcement measures. Advance prediction of tunnel collapse failure probability has become a key issue in tunnel engineering construction. As for assessing the tunneling collapse failure probability and providing basic risk-controlling strategies, in this study it proposes a novel multi-source information fusion approach that combines the cloud model (CM), the multi-output gaussian

基金项目: 国家自然科学基金项目(Nos.52168055, 51678164); 江西省自然科学基金项目(No. 20212ACB204001); 广西自然科学基金项目(No. 2018GXNSFDA138009).

作者简介: 吴波(1971-), 男, 教授, 主要从事隧道及地下工程安全风险智慧防控与管理研究. E-mail: wubo@gxu.edu.cn

* 通讯作者: 徐世祥, E-mail: 603559081@qq.com

引用格式: 吴波, 丘伟兴, 徐世祥, 蔡俊华, 李贻材, 张耀, 2024. 基于人工智能变形预测隧道坍塌失效概率评估方法. 地球科学, 49(11): 4204-4215.

Citation: Wu Bo, Qiu Weixing, Xu Shixiang, Cai Junhua, Li Yicai, Zhang Yao, 2024. A Method for Assessing Probability of Tunnel Collapse Based on Artificial Intelligence Deformation Prediction. *Earth Science*, 49(11): 4204-4215.

process regression (MOGPR), and the improved D-S evidence theory. The fusion of multiple monitoring data (vault displacement, horizontal convergence displacement) reduces data uncertainty and improves the accuracy and robustness of assessment results. In addition, the surrounding rock deformation predicted by artificial intelligence is used as a source of information to obtain an advanced collapse failure probability assessment. As a result, decision makers have a longer response time before the collapse occurs. Applying the method to the Jinzhupa tunnel provides decision makers with more response time. In the end, only a small amount of deformation cracks were generated in the surrounding rock support, avoiding the tunnel collapse.

Key words: tunnel collapse; failure probability assessment; cloud model; D-S evidence theory; multi-output gaussian process regression; safety engineering; engineering geology.

高速公路对我国来说是极其重要的基础设施.它保证了不同地区之间的交流和发展,特别是在山区和丘陵地区.当高速公路穿越山区时,隧道的建设将是一个巨大的挑战.相较于隧道掘进机法(TBM),钻爆法在投资和技术上具有无可比拟的优势,因此在山岭隧道开挖中通常采用钻爆法施工.然而,它涉及的风险因素众多,施工程序复杂,导致坍塌事故发生率较高(Zhang *et al.*, 2020).为了减少对基础设施、人类和环境的破坏,人们付出了巨大的努力来控制灾害.然而,由于在触发机制中存在潜在的多重危险因素及其相互关系,导致隧道坍塌的机理尚不清楚.现有评估方法在确定事故发生的关键时间和主要危险因素方面仍存在不足(Chen *et al.*, 2019).

在隧道施工过程中,隧道坍塌的发生往往具有前兆,例如围岩变形过大导致支护结构出现裂缝.因此将围岩变形控制在合理的范围内是保证施工安全进行的前提.故许多学者对围岩的变形规律进行了研究,主要通过数值模拟(Li *et al.*, 2012;陈福勇和仇文岗, 2022)、理论研究(Chen and Zhang, 2021)、现场试验(Huang *et al.*, 2018)和室内实验(严孝海等, 2022)等方法去研究隧道结构和围岩间的相互作用、隧道开挖对临近建筑的影响和开挖掌子面的变形规律等.近年来,人工智能方法大量运用岩土工程研究领域.在围岩变形规律研究方面,许多学者运用人工智能方法对围岩变形进行预测.例如:Adoko *et al.* (2013)提出了基于人工神经网络的隧道水平收敛位移预测模型,该模型预测的隧道水平收敛位移与实测数据相符.Xue and Xiao(2017)结合粒子优化群算法和支持向量机对围岩变形进行了预测,预测结果与实测值相符,验证了该方法具有准确预测位移变形位移的潜力.

然而单个监测数据往往难以反映隧道开挖的实际情况.为此学者们提出了多信息融合方法,通过考虑多信息提高评估的准确性和鲁棒性.例如:

Yang *et al.*(2007)提出了一种基于D-S证据理论和主观贝叶斯算法的混合结构多模态数据融合方法.Zhang *et al.*(2013b)提出了一种多度量学习算法,联合学习一组最优的同质或异构度量,从而融合多个传感器收集的数据进行联合分类.Cai *et al.* (2014)提出了一种利用Bayes网络模型进行故障检测的数据融合方法,并将该方法应用于并行仿真,提高了地源热泵系统的诊断精度.Gravina *et al.*(2017)介绍了多传感器数据融合的动机和优势以及影响数据融合的参数,并进一步讨论了不同层次参数对数据融合设计的影响.Li *et al.*(2017)提出了一种基于同质观测的多源数据聚类方法,用于复杂背景下的多目标检测.Saadi *et al.*(2018)提出了一个多源信息融合框架,允许智能合并多个数据源,并应用于城市交通.Guo and Zhang (2021)提出了一种结合BIM在数据处理和可视化方面的优势以及D-S证据理论在处理信息的模糊性和不确定性方面的优势的混合方法,以支持地下隧道的系统风险评估和可视化.在上述信息融合方法中,D-S证据理论是信息融合领域中一种有效且常用的方法.然而,D-S证据理论有两个假设可能并不适用于实际情况.(1)概率分布是基于用户定义的函数或分布,这对实际情况来说太理想了;(2)假设每个判断具有相等的可靠性和重要性权重,忽略了判断的质量.

针对上述问题,本研究提出了一种结合多输出高斯过程回归方程、正态云模型(CM)和改进的D-S证据理论的多信息失效概率评估方法.该模型旨在实现以下目标:(1)对实时的监测数据进行预测,反映隧道支护情况,为施工方提供更长的决策时间.(2)融合多个监测数据信息,提高坍塌失效概率预测的准确性和鲁棒性.

1 方法

为了提高隧道坍塌失效概率评估的可信度和鲁棒性,提出了一种新的混合多信息融




图 1 多数据融合评估方法流程

Fig.1 Flow chart of the proposed hybrid method for multi-source data fusion decision

合方法. 图 1 为本文隧道坍塌失效概率分析方法流程图. 在提出的方法中, 通过多输出高斯过程回归对多个监测数据进行预测. 然后根据云模型得到坍塌各等级的失效概率. 最后利用改进的 D-S 证据理论融合多个预测数据的失效概率, 得到整体的坍塌失效概率值.

1.1 围岩位移预测

隧道开挖的拱顶位移与水平收敛位移间存在相互关系 (Liu and Liu, 2019). 然而已有的机器学习预测方法往往是单输出, 并未考虑输出数据间的相互关系. 由于忽略了输出数据间的关系, 可能会导致预测结果存在偏差. 因此本文将采用多输出高斯过程回归 (MOGPR) 进行围岩位移的预测, 并将结果与支持向量机的计算结果进行比较, 证明了该方法具有更高的准确性.

1.1.1 多输出高斯过程回归 (Multi-output Gaussian process regression) 通过多输出高斯过程回归 (MOGPR) 对测试样本 $f(t)$ 的退化时间

序列建模, 并假设函数上的高斯概率分布如式 (1) (Duong *et al.*, 2018) 所示.

$$f(t) \sim N(m(t), \kappa_{\text{MOGP}}), \tag{1}$$

其中 $m(t)$ 是由测试时间序列的平均值估计的函数平均值, κ_{MOGP} 是由标签协方差和时间协方差的乘积导出的:

$$\kappa_{\text{MOGP}} = \kappa_c(\lambda, \lambda', \theta_c) \times \kappa_t(t, t', \theta_t), \tag{2}$$

其中 $\kappa_t(t, t', \theta_t)$ 是测试时间序列的时间协方差矩阵, $\kappa_c(\lambda, \lambda', \theta_c)$ 是标签协方差矩阵, λ 是所用每个时间序列的标签输入, θ_c 和 θ_t 分别是标签和时间协方差的超参数向量. 为简单起见, 我们采用了 $\kappa_t(t, t', \theta_t)$ 的公共平方指数 (SE) 协方差:

$$\kappa_t = \kappa_{\text{SE}} = \sigma_f e^{-\frac{(t-t')^2}{2\theta_t^2}}, \tag{3}$$

$\kappa_c(\lambda, \lambda', \theta_c)$ 是一个半正定协方差矩阵. Cholesky 分解的自由形式参数化提供了下三角矩阵的元素 (Lim *et al.*, 2020):

$$\kappa_c = LL^T \begin{bmatrix} \theta_{c,1} & 0 & \cdots & 0 \\ \theta_{c,1} & \theta_{c,1} & & 0 \\ \vdots & & \ddots & \vdots \\ \theta_{c,k-m+1} & \theta_{c,k-m+2} & \cdots & \theta_{c,k} \end{bmatrix}, \quad (4)$$

其中 $k=m \times (m+1)/2$ 是相关超参数的个数. 对角线元素表示时间序列与其自身的相关性, 而非对角线元素表示不同时间序列之间的相关性. 通过最大化对数似然表达式来优化超参数.

1.1.2 GA 和 MOGPR 耦合算法 由式(4)可知, 运用共轭梯度法计算训练样本的最大似然值, 可以得到 MOGPR 的最佳超参数. 然而, 共轭梯度法也有许多缺点, 如对初始值依赖性强, 难以确定所需的迭代次数. 为解决该问题, 本文将采用遗传算法(GA)来寻找 MOGPR 的最佳超参数. 遗传算法作为一种仿生全局优化算法, 其目标函数不需要可微, 不依赖于优化结果的初始值和隐式并行搜索. 目前, 遗传算法已被广泛用于解决多参数、多变量和多目标问题, 并可用于解决连通性较差的 N_p 难优化问题. 本文采用十进制遗传算法来搜索 MOGPR 的最优超参数, 并发展了遗传算法和 MOGPR 算法的耦合算法. 如图 2 所示, GA 和 MOGPR 耦合算法的计算过程如下:

步骤(1)训练样本可以分为两组: MOGPR 算法的学习样本和用于测试 MOGPR 学习性能的样本.

步骤(2)对遗传算法进行初始化, 随机生成包括 N_p 个体在内的 MOGPR 算法超参数的初始种群. 每个个体代表 MOGPR 算法的一组超参数, 生成计数器设置为 $g=1$.

步骤(3) MOGPR 算法读取训练样本和测试样本. 同时, 读取初始种群的每个个体 MOGPR 算法超参数, 并进行相应的样本训练. MOGPR 算法通过机器学习从学习样本中获取知识, 并使用该知识对测试样本进行预测.

步骤(4)测试样本的每个单独的 MOGPR 算法的结果被传送到遗传算法. 然后, 通过遗传算法适应度函数计算每个个体 MOGPR 算法的适应度值.

步骤(5)如果已经达到指定的 GA 进化代数, 则终止计算, 返回适应度值最高的个体 MOGPR 算法. 否则, 开始下一个计算步骤.

步骤(6)选择算子选择初始种群中适应度最高的 MOGPR 个体; 然后, 进行杂交和突变. 生成具有 N_p 个体的 MOGPR 算法的超参数的后代群体, 并且计数器被设置为 $g=g+1$. 然后, 计算返回到步骤(3).

步骤(7)重复步骤(3)~(6), 直到达到指定的进化代数. 然后, 终止计算并返回 MOGPR 算法的最优超参数.

1.1.3 滚动预测算法 本文采用滚动预测法对围岩位移进行预测. 假设 $\{x_i, y_i\}$ 用来描述位移, 预测步长为 t , 训练数据最佳天数为 p . 具体描述如下.

(1) 假设已经获得位移时间序列 $\{x_i, y_i\} (i=0, \dots, p-1)$. 前 p 天的数据 $\{x_i, y_i\} (i=0, \dots, p-1)$ 作为学习样本. 围岩变形的第一轮预测, 对后面 t 天进行围岩变形的预测 $\{x_i, y_i\} (i=p, \dots, p+t-1)$.

(2) 第二轮预测, 位移时间序列 $\{x_i, y_i\} (i=t, \dots, t+p-1)$ 作为学习样本, 并对后续 t 天的围岩位移 $\{x_i, y_i\} (i=t+p, \dots, p+2t-1)$ 进行预测.

在下一步骤中, 在获得下一个 t 天的测量位移之后, 通过上述步骤获得用于模型训练的学习和测试样本. 在每个步骤中, 每个训练过程中学习和测试样本的数量应该保持不变. MOGPR 和 SVR 模型通过使用最新的位移测量数据更新训练样本数据库来学习最新的变形发展趋势. 图 3 详细说明了滚动预测方法的原理.

1.2 基于云模型的基本概率分布构建

正态云模型是李德毅院士提出的一种新的不确定性认知模型(Li *et al.*, 2009). 它能综合描述元素的随机性和模糊性, 实现定性概念与定量值之间的不确定性转换. 正态云模型可由数值特征(期望 Ex , 熵 En , 超熵 He)确定. 正态云的定义如下:

在给定定量论域 X 时, 若 B 是 X 上的一个定性概念, x 满足: (1) $x \in X$, (2) x 是概念 B 的随机实例化; (3) x 满足公式(5), x 属于概念 B 的确定度可由式(6)求得.

$$\begin{cases} x \sim N(Ex, En'^2), \\ En' \sim N(En, He^2), \end{cases} \quad (5)$$

$$\mu(x) = e^{-\frac{(x-Ex)^2}{2(En')^2}}, \quad (6)$$

在决策过程中分析了各种隧道坍塌风险因素 B_i . 为了从多个来源挖掘有用信息, 每个风险因素应进一步划分为不同的风险状态 $B_{ij} (i=1, 2, \dots, M; j=1, 2, \dots, N)$. 每个风险状态可以对应一个特定的双极限区间, 记为 $[b_{ij}(L), b_{ij}(R)]$. 通过式(7)将双极限区间 $[b_{ij}(L), b_{ij}(R)]$ 转化为正态云模型 $(Ex_{ij}, En_{ij}, He_{ij})$.




图2 GA和MOGPR耦合算法流程

Fig.2 Flow chart of GA and MOGPR coupling algorithm

$$\begin{cases} Ex_{ij} = \frac{b_{ij}(L) + b_{ij}(R)}{2}, \\ En_{ij} = \frac{b_{ij}(R) - b_{ij}(L)}{6}, \quad (i=1, 2, \dots, M; j=1, 2, \dots, N) \\ He_{ij} = h, \end{cases}$$

(7)

式中, “ Ex_{ij} ”为期望; “ En_{ij} ”是“ Ex_{ij} ”的熵, “ He_{ij} ”是超熵. 常数“ h ”的取值范围为“ $0 \sim En_{ij}$ ”, 适用于反映这些因素的不确定性程度. 根据文献 (Zhang *et al.*, 2013a) 本文“ h ”取 0.002.

在 CM 框架中, 相关性可以度量因子 B_i 的观测值 b_{ij} 与特定风险状态 B_j 的云模型之间的相对隶属度. 影响因素在不同风险状态下的基本概率分布 (BPA) 可由式 (8) 得到.

$$\begin{cases} m_i(B_j) = \exp\left(-\frac{(x_i - Ex_{ij})^2}{2(En_{ij}')^2}\right), \quad (i=1, 2, \dots, M; j=1, 2, \dots, N), \\ m_i(\Phi) = 1 - \sum_{j=1}^N m_i(A_j), \end{cases}$$

(8)

式中, $m_i(B_j)$ 表示影响因素在不同风险状态下的 BPA 值, En' 表示满足条件 $En' \sim N(En, He^2)$ 的随机数, $m_i(\Phi)$ 表示不确定情况下的 BPA 值, 即在 B_i 指标下无法确定的焦点元素, 所有元素都包含在内.

1.3 改进的 D-S 证据理论

本文结合 D-S 理论和加权平均规则, 融合多信息, 得出隧道坍塌失效概率值. 利用公式 (9) (Zhang *et al.*, 2017) 计算多项证据的 Dempster 组合规则.




图 3 滚动预测方法原理

Fig. 3 Schematic diagram of the rolling prediction method

$$m(B) = \begin{cases} \frac{1}{1-K} \sum_{B_i \cap B_j \cap \dots \cap B_l = B} m_1(B_i) m_2(B_j) \dots m_l(B_l), & \forall B \subseteq \Theta, B \neq \emptyset, \\ 0, & B = \emptyset, \end{cases}$$

$$K = \sum_{B_i \cap B_j \cap \dots \cap B_l = \emptyset} m_1(B_i) m_2(B_j) \dots m_l(B_l) < 1, \quad (9)$$

其中冲突因子 K 被定义为归一化因子. l 为组合过程中的证据个数, i, j, k 分别表示第 i 、第 j 、第 k 个假设.

当 K 的值接近于 1 时, 会产生较大的冲突, 这意味着 Dempster 的证据聚集规则将失去意义. 针对高冲突证据的处理问题, 将加权平均规则和 Dempster 规则相结合, 提出了一种混合组合规则. 本文将使用阈值 ξ 值来表示证据冲突高. 当 K 大于 ξ 时, 存在高度证据冲突, D-S 证据理论将被加权平均数规则取代, 如公式 (10) 所示 (Zhang *et al.*, 2017). 根据文献 (Zhang *et al.*, 2017), 本研究将阈值 ξ 值定为 0.90.

$$\left\{ \begin{aligned} d &= \sum_{j=1}^l \sqrt{\sum_{k=1}^L (m_i(B_k) - m_j(B_k))^2}, \\ w_i &= \frac{d_i^{-1}}{\sum_{i=1}^l d_i^{-1}}, \\ \begin{cases} m_i^*(B_k) = w_i \cdot m_i(B_k), \\ m_i(\Theta) = 1 - \sum_{k=1}^L m_i^*(B_k), \end{cases} \end{aligned} \right. \quad (10)$$

其中 l 和 L 分别是证据个数和假设个数, k 是指第 k 个假设.

2 工程案例

2.1 工程概况

金珠帕隧道是一条双管公路隧道, 位于福建省三明市. 左线长 711 m, 右线长 771 m. 本文以右线 (K242+548~K243+319) 为研究对象. 沿隧道左线的断层构造如图 4 所示. V 级围岩段 316 m, IV 级围岩段 455 m. 岩体主要由残余粉质粘土、花岗岩全风化层和破碎的强风化层组成. 在 K243+139~K243+160 段存在断裂破碎带. 在施工过程中, 极易造成隧道坍塌. 因此, 迫切需要对该隧道段进行坍塌失效概率评估, 以减少坍塌造成的损失.

2.2 监测数据

测量数据包括浅埋段地表沉降、拱顶位移、水平收敛位移等, 这些数据可以反映初始衬砌后隧道支护的稳定性. 在深埋隧道中, 往往不需考虑地表沉降的影响, 只选取拱顶位移和水平收敛位移进行坍塌失效概率分析. 根据国家标准《公路隧道施工技术规范》(JTG/T 3660-2020) 和《公路隧道监测测量技术规范》(DB 35/T 1067-2010), 选取监测数据的日变化率和累积变形量作为判定指标. 监测点距离掌心面越远, 累积位移极限值越大. 因此, 累积位移值需要乘以一个因子 ζ . 这两个判断指标分为 4 个层次, 如表 1 所示. 隧道采用台阶法开挖, 监测点、测点布置如图 5 所示. 围岩位移监测早晚各一次, 取其平均值作为当天的监测值. 随着上下台阶的顺序开挖, 水平收敛的测点需要水平向下移动.




图 4 金珠帕隧道右线纵截面
Fig. 4 Longitudinal section of the right line of Jinzhupa Tunnel

表 1 监控量测数据的分类

Table 1 Classification of monitoring measurement data

隧道坍塌等级	I (安全)	II (变形)	III (小规模坍塌)	IV (大规模坍塌)
每日变形速率(mm/d)	$0 \leq x < 2$	$2 \leq x < 5$	$5 \leq x < 10$	$10 \leq x \leq 20$
累计变形(mm)	$0 \leq y < 50$	$50 \leq y < 100$	$100 \leq y < 200$	$200 \leq y \leq 300$

注: 累积变形量(y)应根据测点与掌子面距离(D)乘以系数(ζ), ζ 根据规范《公路隧道监测测量技术规范》(DB 35/T 1067-2010)确定, 如表 2 所示.

表 2 累积变形量(y)的系数(ζ)

Table 2 Coefficient (ζ) of cumulative deformation (y)

测点到掌子面的距离(D)	1B	2B	3B	4B~6B
ζ	0.5	0.75	0.85	1

注: B 为开挖隧道的跨度.




图 5 监测点布置示意
Fig. 5 Monitoring point layout

2.3 围岩位移预测

与人工神经网络不同,多输出高斯过程回归和支持向量回归都是小样本机器学习算法.经过 9 个以上 15 个以下有效样本的训练,可以建立泛化性能优异的高斯过程回归或支持向量机模型.所以,当围岩位移监测持续十几天时,位移监测数据可以形成训练 MOGPR 或 SVR 算法所需的样本.可以直接利用实测位移数据训练 MOGPR 或 SVR 算法,建立 MOGPR 或 SVR 的智能模型进行围岩位移预测.

以隧道 K242+880 断面的数据作为训练样本.

根据滚动预测法,假设 $p=9$, $t=3$, K242+880 段位移预测如表 3 所示.在水平收敛方面,MOGPR 和 SVR 算法的平均相对误差分别为 1.26% 和 3.44%,MOGPR 算法和 SVR 算法的最大相对误差分别为 6.85% 和 18.92%.在拱顶位移方面,MOGPR 和 SVR 算法对拱顶沉降的平均预测相对误差分别为 2.29% 和 3.43%,最大相对误差分别为 8.45% 和 11.86%.无论是对于拱顶位移还是水平收敛位移,MOGPR 算法的预测精度都高于 SVR 算法.这是由于 MOGPR 考虑两个输出数据间的相互关系,使得预测结果更加准确.

2.4 结合位移预测的多数据坍塌失效概率评估

根据式 (7) 和表 1 得出两个监测指标的云模型参数值 (Ex , En , He),如表 4 所示.收集拱顶位移和水平收敛位移代入公式 (8) 即可求得隧道坍塌各等级的 BPA 值.

每日变形速率和累计沉降量将得到两组坍塌失效概率,为了更好的安全储备,本文采用较大的失效概率等级作为最终失效概率等级结果.最后运用改进的 D-S 证据理论将拱顶位移和水平收敛位移的失效概率值进行融合得到最终坍塌失效概率值.

为了说明融合过程,在挖掘断面 K242+900~K242+925 每隔 5 m 选取训练样本,选取 5 个隧道断面作为测试样本,结果如表 5 所示.可以得到以下结论:

(1)单一信息源在评估坍塌失效概率时,由于

表 3 K242+880 监测段围岩位移预测结果										
Table 3 Prediction results of surrounding rock displacement in K242+880 monitoring section										
监测时间 (d)	实测拱顶 位移 (mm)	MOGPR 预 测值 (mm)	SVR 预 测值 (mm)	MOGPR 相 对误差(%)	SVR 相 对误差 (%)	实测水平收敛值 (mm)	MOGPR 预 测值(mm)	SVR 预 测值 (mm)	MOGPR 相 对误差(%)	SVR 相 对误差
10	12.3	12.00	11.40	2.45	7.29	10.7	10.36	10.34	3.14	3.38
11	12.9	12.38	12.00	4.04	6.98	11.3	11.00	10.31	2.65	8.73
12	13.8	12.77	13.00	7.45	5.80	12.2	12.00	9.89	1.64	18.92
13	14.6	14.65	14.43	0.33	1.18	12.9	12.74	12.72	1.25	1.38
14	15.3	15.63	15.10	2.15	1.29	13.7	13.33	13.30	2.70	2.94
15	15.8	16.66	15.68	5.42	0.79	14.4	13.88	13.83	3.60	3.98
16	16.2	16.58	15.92	2.36	1.71	15.1	15.09	14.63	0.05	3.08
17	16.8	17.27	15.81	2.78	5.88	15.9	15.80	14.63	0.62	7.96
18	17.5	17.94	15.42	2.51	11.86	16.5	16.50	14.32	0.02	13.20
19	18.1	17.76	17.76	1.90	1.87	17.0	17.13	16.78	0.76	1.29
20	18.7	18.06	17.73	3.41	5.21	17.5	17.68	16.91	1.05	3.37
21	19.2	18.29	17.30	4.76	9.89	17.9	18.17	16.80	1.53	6.15
22	19.7	19.41	19.30	1.46	2.02	18.1	18.23	18.07	0.73	0.16
23	20.3	19.38	19.19	4.51	5.47	18.4	18.47	18.21	0.38	1.05
24	20.9	19.13	18.82	8.45	9.94	18.7	18.62	18.24	0.40	2.47
25	21.4	21.36	21.23	0.21	0.82	19.1	18.98	18.78	0.62	1.68
26	21.9	21.82	21.54	0.38	1.65	19.3	19.32	18.81	0.08	2.53
27	22.6	22.24	21.77	1.59	3.69	19.5	19.68	18.72	0.91	3.98
28	23.2	23.18	23.00	0.09	0.88	19.7	19.49	19.55	1.07	0.75
29	23.9	23.81	23.36	0.39	2.27	20.1	19.31	19.41	3.93	3.41
30	24.5	24.44	23.56	0.24	3.82	20.4	19.00	19.15	6.85	6.14
31	25.1	25.15	24.84	0.21	1.06	20.6	20.60	20.59	0.00	0.07
32	25.3	25.81	25.03	2.02	1.07	20.8	20.85	20.81	0.22	0.07
33	25.5	26.48	24.99	3.84	1.99	20.9	21.08	21.03	0.88	0.61
34	25.7	25.40	25.42	1.18	1.08	21.1	21.10	20.87	0.01	1.10
35	25.8	25.11	25.11	2.69	2.66	21.4	21.22	20.75	0.85	3.04
36	25.9	24.66	24.58	4.78	5.10	21.6	21.31	20.52	1.36	4.98
37	26.0	26.00	25.94	0.02	0.24	21.7	21.71	21.62	0.04	0.37
38	26.2	26.10	25.98	0.39	0.82	21.9	21.85	21.50	0.25	1.83
39	26.3	26.18	25.97	0.47	1.25	22.1	21.96	21.26	0.61	3.81
40	26.5	26.38	26.21	0.45	1.11	22.4	22.25	22.34	0.65	0.25
41	26.6	26.38	25.98	0.82	2.34	22.6	22.41	22.62	0.83	0.10
42	26.8	26.29	25.70	1.89	4.10	22.99	22.56	22.80	1.86	0.84
位移预测的平均相对误差(%)				2.29	3.43				1.26	2.29

表 4 两个监控指标的云模型参数值												
Table 4 Cloud model parameter values of two monitoring indicators												
指标	I			II			III			IV		
	<i>Ex</i>	<i>En</i>	<i>He</i>	<i>Ex</i>	<i>En</i>	<i>He</i>	<i>Ex</i>	<i>En</i>	<i>He</i>	<i>Ex</i>	<i>En</i>	<i>He</i>
每日速率	1	0.333	0.002	3.5	0.5	0.002	7.5	0.833	0.002	12.5	0.833	0.002
累计沉降	25	8.333	0.002	75	8.333	0.002	150	16.777	0.002	250	16.777	0.002

数据的不确定性,评估结果往往会出现偏差.本文提出的多数据融合,将拱顶位移和水平收敛

位移进行融合,对隧道围岩状况有全面的认识,从而降低数据的不确定性,提高评估的准确性.

表 5 五个测试样本的融合结果
Table 5 Fusion results of five test samples

隧道断面	评估模型	等级 I 的失效概率	等级 II 的失效概率		等级 III 的失效概率	等级 IV 的失效概率	评估值	实际值
No.1	拱顶位移	0.80	0.20	0.00	0.00		I	I
	水平收敛	0.45	0.55	0.00	0.00		II	I
Improve D-S		0.77	0.23	0.00	0.00		I	I
No.2	拱顶位移	0.50	0.50	0.00	0.02		--	I
	水平收敛	0.60	0.40	0.00	0.00		I	I
Improve D-S		0.70	0.30	0.00	0.00		I	I
No.3	拱顶位移	0.00	0.80	0.20	0.00		II	II
	水平收敛	0.19	0.81	0.00	0.00		II	II
Improve D-S		0.00	1.00	0.00	0.00		II	II
No.4	拱顶位移	0.00	0.30	0.70	0.00		III	III
	水平收敛	0.00	0.56	0.44	0.00		II	III
Improve D-S		0.00	0.35	0.65	0.00		III	III
No.5	拱顶位移	0.00	0.15	0.85	0.00		III	II
	水平收敛	0.86	0.14	0.00	0.00		I	I
Improve D-S		0.43	0.15	0.42	0.00		I	I

表 6 隧道围岩位移预测
Table 6 The prediction of tunnel surrounding rock displacement

天数	训练数据(mm)						预测数据(mm)					
	1	2	3	4	5	6	7	8	9	10	11	12
拱顶位移	3.1	6.6	8.2	9.4	10.2	11.2	13.2	16.8	21.1	26.5	36.5	47.3
水平收敛	2.7	5.1	6.5	7.2	8.1	9.3	11.4	14.4	19.5	25.1	30.6	35.1
实际拱顶位移	3.1	6.6	8.2	9.4	10.2	11.2	13.2	16.8	21.1	25.8	34.4	38.1
实际水平位移	2.7	5.1	6.5	7.2	8.1	9.3	11.4	14.4	19.5	24.6	31.1	33.4

(2)当监测值位于失效概率等级边界时,其失效概率分布往往难以确定明确的坍塌失效等级.如隧道截面 No.2 拱顶位移所示,其位移坍塌失效等级 I 和 II 的概率都同为 0.50.这难以为现场施工提供明确的建议.本文提出融合多个监测数据,减少了评估结果的不确定性,提高了评估的准确性和鲁棒性.

3 结果分析

金珠帕隧道在施工初期未采用本文提出的坍塌失效概率评估方法指导施工.当隧道穿越破碎断裂带时,由于隧道衬砌支护强度不足导致隧道坍塌,如图 6 所示.这是因为当拱顶位移沉降过大时,已经来不及进行围岩支护的加固了.最终导致了坍塌的发生,造成经济损失和工期延误.为了能有充分的时间进行坍塌预防措施.本文提出将围岩变形

预测作为信息源进行坍塌失效概率评估.这样可以提前预测坍塌失效等级,从而让决策者有足够的时间采取围岩加固的相应措施.将该方法运用于开挖断裂破碎带的坍塌失效概率预测.开挖至破碎断面时(K243+160),采用 MOGPR 对围岩位移进行预测,结果如表 6 所示.将围岩位移预测值作为信息源进行多数据融合分析得到坍塌失效概率值,结果如表 7 所示.未来 3 d 内,坍塌失效等级将达到 III 级,有可能发生小规模坍塌.应根据现场情况采取相应措施,减少拱顶位移和水平收敛位移的增加.首先,应停止隧道施工,避免爆破作业对围岩造成扰动.由于围岩等级较差,节理裂隙较多,应加强初次衬砌强度等级.采取上述措施后,围岩每日变形率降至安全水平后方可继续施工.

从表 6 中可知,第 10 d、11 d 的位移预测值与实际值误差较小,第 12 d 的实测围岩变形速率得到降

表 7 预测坍塌失效概率值
Table 7 The prediction of the collapse failure probability

	监测数据(mm)								预测数据(mm)			
天数	1	2	3	4	5	6	7	8	9	10	11	12
预测坍塌等级	I	I	I	I	I	I	I	II	II	III	III	III
实际坍塌等级	I	I	I	I	I	I	I	II	II	III	III	II



图 6 隧道坍塌
Fig.6 Tunneling collapse




图 7 隧道开挖周期的失效等级评估
Fig.7 Failure level assessment of tunnel excavation cycle

低(失效等级为II级),这是由于采取了围岩加固措施,提高了围岩支护等级,从而降低了围岩位移速率.本文采用预测的位移作为信息源进行坍塌失效等级预测,为决策者提供更多的响应时间.最终,围岩支护只产生少量的变形裂缝,避免了隧道坍塌的发生.该结果证明了该评估方法的有效性,能为后续隧道开挖提供超前的坍塌失效概率值.

为了让决策者对现场施工情况有更好的了解,

本文对一个完整的开挖施工周期的坍塌失效概率进行预测,以 K243+140 隧道断面(位于断裂破碎带)为例,该截面的整个开挖周期的失效等级评估结果如图 7 所示.由图可知,第 13 d 和第 24 d 隧道坍塌失效等级预测值上升到 III 级(处于小规模坍塌失效状态).当时隧道施工正值雨季,下着大暴雨(250 mm/h).由于雨水侵蚀和冲击,围岩松动,加速了围岩位移,使其拱顶位移速率超过了阈值,此时围岩稳定性处于危险水平.根据评估结果,决策者需要紧急暂停施工,及时对隧道初次支护进行加固,并及时排水,使围岩位移速率回归到安全水平.在坍塌失效等级评估结果下降到 II 级水平之前,不进行施工.该失效概率评估方法为决策者在事故发生前提供了更多的反应时间,能及时降低坍塌失效等级和减少坍塌事故的发生.

4 结论

本研究提出了基于围岩位移预测的隧道坍塌失效概率评估方法.结合高斯过程回归和遗传算法对围岩位移进行预测.并运用改进的 D-S 证据理论将拱顶位移失效概率值和水平收敛位移失效概率值进行融合,得到总体概率失效概率值.预测位移作为信息源进行多数据融合,可以预测几天后的坍塌失效情况,为施工人员提供充足的反应时间,让决策者充分了解现场施工情况,对造成坍塌的主要风险因素有初步认识,并针对具体问题采取相应的措施,实现对症下药,大大提高了施工的效率.本文将提出的失效概率评估方法运用于金珠帕隧道得到以下结论:

(1)本方法综合了拱顶位移和水平收敛位移的监测数据,获得更加准确的隧道坍塌失效概率评估结果.由于隧道坍塌影响因素众多,失效概率评估是一个多属性决策问题.单一的监测数据难以充分反映隧道围岩情况,导致预测结果存在偏差.融合评估结果优于单监测数据评估结果,具有较高的准确性和鲁棒性.

(2) 将围岩位移预测值作为融合分析的信息源, 预测隧道坍塌失效概率. 这为决策者提供一个超前的坍塌预警信号, 使决策者有足够的时间采取补救措施, 减少坍塌事故的发生.

(3) 采用该方法对金珠帕隧道进行坍塌失效概率预测, 减少了坍塌发生的次数. 在使用该坍塌失效概率评估之前, 平均每 100 m 的挖掘就会发生一到两起小型坍塌事故. 采用后, 每 250 m 的挖掘深度中, 平均只有 1 次轻微的塌陷, 不仅减少了经济的损失和人员的伤亡, 而且还大大加快了施工进度. 本研究假设失效等级随围岩位移值的增加呈线性关系. 失效等级分布可能不是线性的. 在未来, 可以应用其他标记机制来更好地捕获坍塌失效水平.

References

- Adoko, A. C., Jiao, Y. Y., Wu, L., et al., 2013. Predicting Tunnel Convergence Using Multivariate Adaptive Regression Spline and Artificial Neural Network. *Tunnelling and Underground Space Technology*, 38: 368–376. <https://doi.org/10.1016/j.tust.2013.07.023>
- Cai, B., Liu, Y., Fan, Q., et al., 2014. Multi-Source Information Fusion Based Fault Diagnosis of Ground-Source Heat Pump Using Bayesian Network. *Applied Energy*, 114: 1–9. <https://doi.org/10.1016/j.apenergy.2013.09.043>
- Chen, F., Zhang, W., 2021. Influence of Spatial Variability on the Uniaxial Compressive Responses of Rock Pillar Based on 3D Random Field. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering*, 7(3): 04021035. <https://doi.org/10.1061/AJRUA6.0001162>
- Chen, F. Y., Zhang, W. G., 2022. Reliability Analysis of Lijiaping Metro Tunnel Based on Conditional Random Field, Chongqing. *Journal of Basic Science and Engineering*, 30(1): 166–182 (in Chinese with English abstract).
- Chen, X., Li, L., Wang, L., et al., 2019. The Current Situation and Prevention and Control Countermeasures for Typical Dynamic Disasters in Kilometer-Deep Mines in China. *Safety Science*, 115: 229–236.
- Duong, P.L.T., Park, H., Raghavan, N., 2018. Application of Multi-Output Gaussian Process Regression for Remaining Useful Life Prediction of Light Emitting Diodes. *Microelectronics Reliability*, 88–90: 80–84. <https://doi.org/10.1016/j.microrel.2018.07.106>
- Gravina, R., Alinia, P., Ghasemzadeh, H., et al., 2017. Multi-Sensor Fusion in Body Sensor Networks: State-of-the-Art and Research Challenges. *Information Fusion*, 35: 68–80. <https://doi.org/10.1016/j.inffus.2016.09.005>
- Guo, K., Zhang, L., 2021. Multi-Source Information Fusion for Safety Risk Assessment in Underground Tunnels. *Knowledge-Based Systems*, 227: 107210. <https://doi.org/10.1016/j.knosys.2021.107210>
- Huang, X., Liu, Q., Liu, H., et al., 2018. Development and In-Situ Application of a Real-Time Monitoring System for the Interaction between TBM and Surrounding Rock. *Tunnelling and Underground Space Technology*, 81: 187–208. <https://doi.org/10.1016/j.tust.2018.07.018>
- Li, C., Xu, J., Pan, J., et al., 2012. Plastic Zone Distribution Laws and Its Types of Surrounding Rock in Large-Span Roadway. *International Journal of Mining Science and Technology*, 22: 23–28. <https://doi.org/10.1016/j.ijmst.2011.06.002>
- Li, D., Liu, C., Gan, W., 2009. A New Cognitive Model: Cloud Model. *International Journal of Intelligent Systems*, 24: 357–375. <https://doi.org/10.1002/int.20340>
- Li, T., De la Prieta Pintado, F., Corchado, et al., 2017. Multi-Source Homogeneous Data Clustering for Multi-Target Detection from Cluttered Background with Mis-detection. *Applied Soft Computing*, 60: 436–446. <https://doi.org/10.1016/j.asoc.2017.07.012>
- Lim, S.L.H., Duong, P.L.T., Park, H., et al., 2020. Assessing Multi-Output Gaussian Process Regression for Modeling of Non-Monotonic Degradation Trends of Light Emitting Diodes in Storage. *Microelectronics Reliability*, 114: 113794. <https://doi.org/10.1016/j.microrel.2020.113794>
- Liu, K., Liu, B., 2019. Intelligent Information-Based Construction in Tunnel Engineering Based on the GA and CCGPR Coupled Algorithm. *Tunnelling and Underground Space Technology*, 88: 113–128. <https://doi.org/10.1016/j.tust.2019.02.012>
- Saadi, I., Farooq, B., Mustafa, A., et al., 2018. An Efficient Hierarchical Model for Multi-Source Information Fusion. *Expert Systems with Applications*, 110: 352–362.
- Xue, X., Xiao, M., 2017. Deformation Evaluation on Surrounding Rocks of Underground Caverns Based on PSO-LSSVM. *Tunnelling and Underground Space Technology*, 69: 171–181. <https://doi.org/10.1016/j.tust.2017.06.019>
- Yan, X. H., Guo, C. B., Liu, Z. B., et al., 2022. Physical Simulation Experiment of Granite Rockburst in a Deep-

- Buried Tunnel in Kangding County, Sichuan Province, China. *Earth Science*, 47(6): 2081—2093 (in Chinese with English abstract).
- Yang, Y., Jing, Z., Gao, T., et al., 2007. Multi-Sources Information Fusion Algorithm in Airborne Detection Systems. *Journal of Systems Engineering and Electronics*, 18: 171—176. [https://doi.org/10.1016/S1004-4132\(07\)60070-X](https://doi.org/10.1016/S1004-4132(07)60070-X)
- Zhang, G. H., Chen, W., Jiao, Y. Y., et al., 2020. A Failure Probability Evaluation Method for Collapse of Drill-and-Blast Tunnels Based on Multistate Fuzzy Bayesian Network. *Engineering Geology*, 276: 105752. <https://doi.org/10.1016/j.enggeo.2020.105752>
- Zhang, L., Wu, X., Ding, L., et al., 2013a. A Novel Model for Risk Assessment of Adjacent Buildings in Tunneling Environments. *Building and Environment*, 65: 185—194. <https://doi.org/10.1016/j.buildenv.2013.04.008>
- Zhang, Y., Zhang, H., Nasrabadi, N. M., et al., 2013b. Multi-Metric Learning for Multi-Sensor Fusion Based Classification. *Information Fusion*, 14: 431—440. <https://doi.org/10.1016/j.inffus.2012.05.002>
- Zhang, L., Wu, X., Zhu, H., et al., 2017. Perceiving Safety Risk of Buildings Adjacent to Tunneling Excavation: An Information Fusion Approach. *Automation in Construction*, 73: 88—101. <https://doi.org/10.1016/j.autcon.2016.09.003>

中文参考文献

- 陈福勇, 仇文岗, 2022. 基于条件随机场的重庆李家坪地铁隧道可靠度分析. 应用基础与工程科学学报, 30(1): 166—182.
- 严孝海, 郭长宝, 刘造保, 等, 2022. 四川康定某深埋隧道花岗岩岩爆物理模拟实验研究. 地球科学, 47(6): 2081—2093.