

基于ASSA-Transformer模型的边坡稳定性预测研究

张世杰

北方工业大学土木工程学院, 北京

收稿日期: 2026年2月6日; 录用日期: 2026年2月27日; 发布日期: 2026年3月10日

摘要

边坡灾害具有突发性及严重危害性, 所以边坡稳定性预测成为边坡工程研究的重点。传统边坡稳定性预测方法存在精度有限、泛化能力不足等问题, 因此本研究提出了一种融合自适应稀疏自注意力机制(ASSA)和Transformer架构的混合智能模型(ASSA-Transformer), 提升算法模型在边坡稳定性分类任务中的预测精度。选取支持向量机(SVM)、轻量级梯度提升机(LightGBM)、Transformer、网格搜索优化Transformer (GS-Transformer)以及粒子群优化Transformer (PSO-Transformer)作为对比模型, 使用准确率、精确度、召回率和F1分数作为评价指标评估模型性能, 并通过混淆矩阵可视化各模型的分类结果。研究表明: ASSA-Transformer模型在训练集与测试集的各项评价指标上均优于其他对比模型, 表现出较强的分类预测性能与泛化能力。基于置换特征重要性(PFI)算法分析得出内摩擦角、坡角及孔隙水压力为关键影响因素, 本研究为边坡稳定性的预测提供了一种新方法, 对边坡工程安全评估与防灾决策具有实际意义。

关键词

边坡稳定性, 深度学习, 自适应稀疏自注意力机制, Transformer模型, 混淆矩阵

Research on Slope Stability Prediction Based on the ASSA-Transformer Model

Shijie Zhang

College of Civil Engineering, North China University of Technology, Beijing

Received: February 6, 2026; accepted: February 27, 2026; published: March 10, 2026

Abstract

Slope disasters often occur suddenly and result in severe consequences, making slope stability

prediction a key focus in slope engineering research. Traditional slope stability prediction methods suffer from limitations such as limited accuracy and insufficient generalization capabilities. To enhance the predictive accuracy of algorithmic models in slope stability classification tasks, a hybrid intelligent model (ASSA-Transformer) integrating an adaptive sparse self-attention mechanism (ASSA) and a Transformer architecture is proposed. Support Vector Machine (SVM), Lightweight Gradient Boosting Machine (LightGBM), Transformer, Grid Search Optimized Transformer (GS-Transformer), and Particle Swarm Optimized Transformer (PSO-Transformer) were selected as comparison models. Model performance was evaluated using accuracy, precision, recall, and F1 score as metrics, with classification results visualized via confusion matrices. The results demonstrate that the ASSA-Transformer model outperforms all comparison models across all evaluation metrics on both the training and test datasets, exhibiting strong classification prediction performance and generalization capability. Analysis based on the Permutation Feature Importance (PFI) algorithm identifies the internal friction angle, slope angle, and pore water pressure as key influencing factors. This study provides a novel approach for predicting slope stability, holding practical significance for slope engineering safety assessment and disaster prevention decision-making.

Keywords

Slope Stability, Deep Learning, Adaptive Sparse Self-Attention Mechanism, Transformer Model, Confusion Matrix

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来,我国基础设施建设的快速发展,露天采矿、交通建设、水利水电及建筑工程等领域的边坡工程的规模和数量不断增加,与此同时边坡失稳现象频发,造成了严重的自然灾害与经济损失[1]。边坡失稳为世界三大地质灾害之一,其稳定性的分析与精准预测预报始终是边坡防治中的关键问题[2],构建准确且有效的边坡稳定性预测模型对于岩土工程以及地质灾害的防治具有重要意义。

现阶段在边坡工程领域对于 transformer 模型的应用研究较少,尤其是对于边坡的稳定性预测方面,因此本文提出融合 ASSA 和 Transformer 的边坡稳定性预测模型 ASSA-Transformer,具体过程如下:将 ASSA 机制融入 Transformer 模型的编码器中,使用融合后的 ASSA-Transformer 模型对边坡的稳定性进行分类预测,最后根据实验目的,将轻量级梯度提升机(LightGBM),支持向量机(SVM)以及未经过优化处理的 Transformer 模型分别设置为对照组来比较其各自分类效果及泛化能力。利用建立的边坡数据库,以准确率、精确率、召回率、F1 分数四个评价指标进行综合比较,并结合 ROC 曲线、AUC 值以及混淆矩阵来更直观系统评估各个模型的性能[3]。通过几种对比模型验证,ASSA-Transformer 在所有评价指标上都表现更优,同时其具备更好的分类预测能力和较强的泛化能力。

2. 模型原理

2.1. 自适应稀疏自注意力机制

自适应稀疏自注意力机制(Adaptive Sparse Self-Attention, 简称 ASSA)是自注意力的一种改进形式[4],其核心思想是通过引入自适应选择策略,使模型能聚焦于输入序列中最相关的部分,降低了注意力矩阵的计算复杂度,从而提升了计算效率,其结构如图 1。

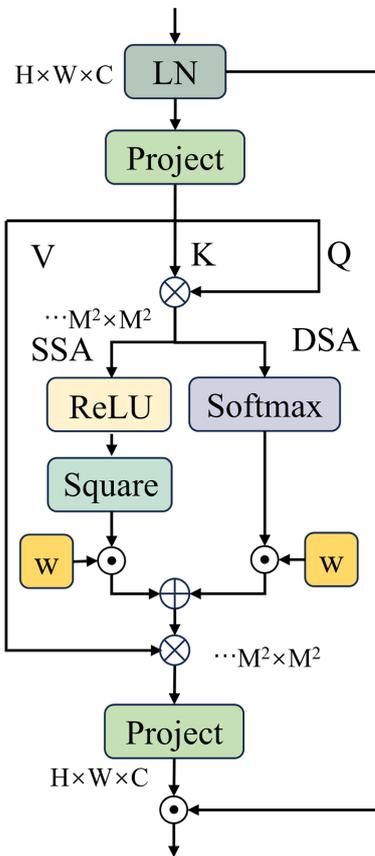


Figure 1. ASSA structural diagram
图 1. ASSA 结构图

ASSA 机制采用双分支结构，包括稀疏自注意力(SSA)与密集自注意力(DSA)两个分支，ASSA 通过动态调整 SSA 和 DSA 的权重，根据具体任务和输入内容有效地平衡信息流，这样既能过滤掉无关特征，又保留必要的信息。具体公式如下：

$$Q = XW_Q, K = XW_K, V = XW_V \tag{1}$$

$$SSA = \text{ReLU}^2(QK^T\sqrt{d} + B) \tag{2}$$

$$DSA = \text{SoftMax}(QK^T\sqrt{d} + B) \tag{3}$$

其中， X 为 $R^{H \times W \times C}$ 的归一化特征的映射， QKV 为 X 生成的查询矩阵 Q 、键 K 和值 V 。 B 是指相对位置偏差。

$$w_n = e^{a_n} / \sum_{i=1}^N e^{a_i}, n = \{1, 2\} \tag{4}$$

$$A = (w_1 \times SSA + w_2 \times DSA)V \tag{5}$$

其中， w_1, w_2 为双分支的两个归一化权重， $\{a_1, a_2\}$ 是可学习参数。

2.2. Transformer 模型

Transformer 模型由 Vaswani 等[5]人于 2017 年首次提出，作为一种创新的深度学习框架，其核心在于自注意力机制(Self-Attention)的应用。该机制通过多头注意力(Multi-Head Attention)的设计，显著提

升了模型的表现力和训练稳定性。Transformer 模型由编码器和解码器两部分构成，每一部分均由多个编码层或解码层堆叠而成，编码器从输入序列中提取特征，而解码器生成相应的输出序列，详细的层结构如图 2。

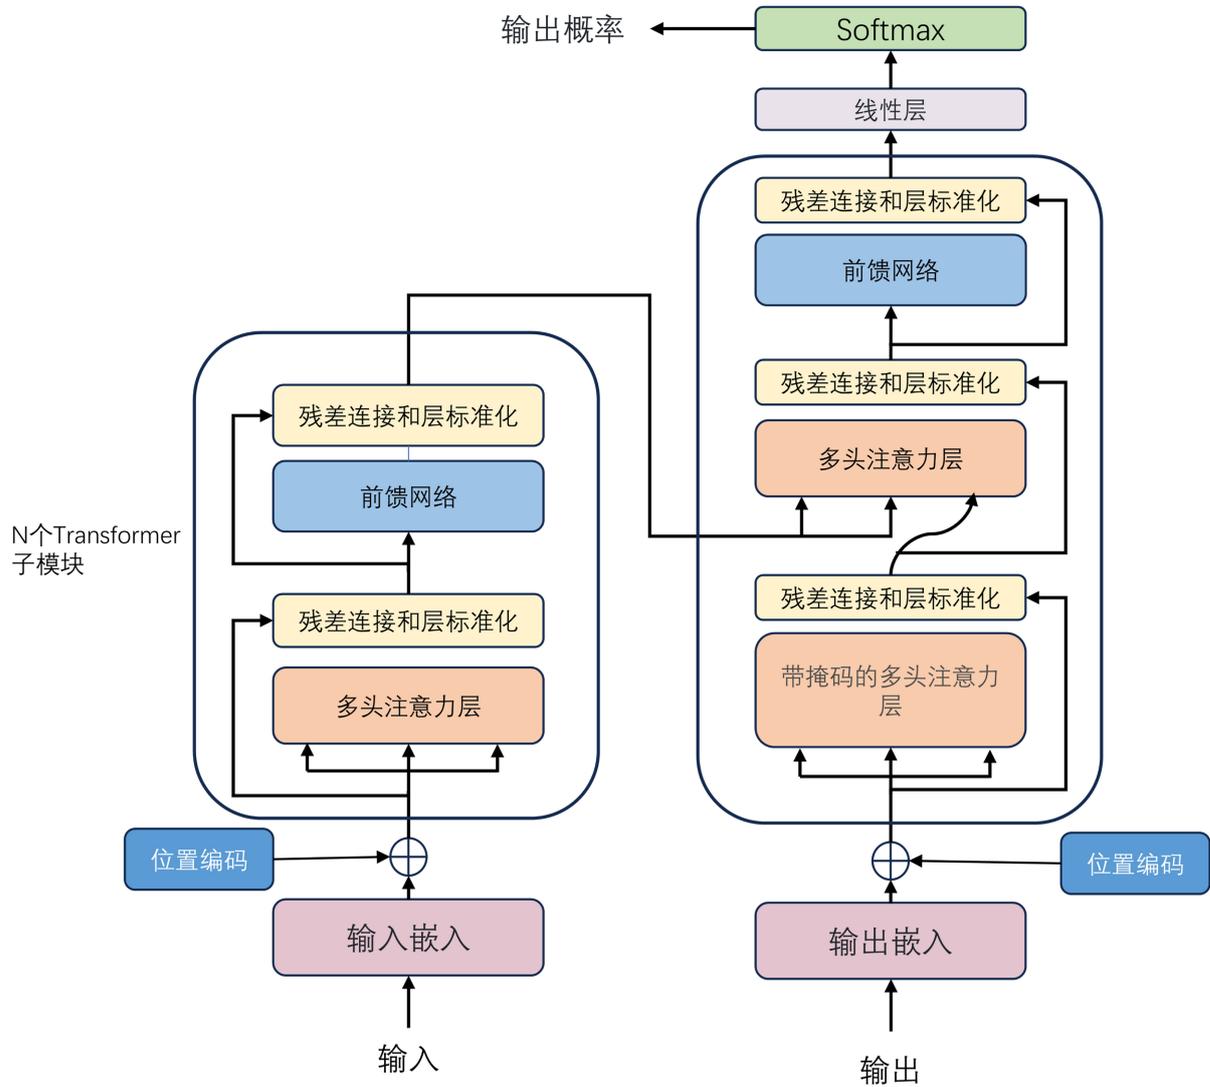


Figure 2. Transformer model architecture diagram
图 2. Transformer 模型结构图

Transformer 中的多头注意力机制允许模型在不同的表示子空间中进行自注意力计算，从而捕捉不同的语义信息。 Q (Query)、 K (Key)和 V (Value)矩阵是自注意力机制的核心组成部分，它们用于计算注意力权重，并在编码器和解码器中进行特征映射和特征提取[6]。Transformer 的注意力机制表示如下：

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) \quad (6)$$

$$MutiHead(Q, K, V) = \text{Concat}(head_1, head_2, \dots, head_n)W^O \quad (7)$$

$$head_n = Attention(QW_i^O, KW_i^K, VW_i^V) \quad (8)$$

其中, Q, K, V 分别为查询(Query)矩阵, 键(Key)矩阵, 值(Value)矩阵, 用于查询向量以计算相似度以及基于注意力权重进行信息聚合。 W_i^Q, W_i^K, W_i^V 为参数矩阵。 QK^T 为点积相似度, 表示查询矩阵与键矩阵之间的相似度, 用于衡量不同元素间的关联程度。 $\sqrt{d_k}$ 为缩放因子, $\text{softmax}()$ 是将点积结果转换为概率分布的归一化函数。

全连接前馈网络由两个线性层和一个介于两者之间的 ReLU 激活函数组成。过程表示如下:

$$\text{FFN}(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (9)$$

Transformer 中的位置编码结构用于捕捉序列中不同位置的关系。位置编码是通过向输入序列中的每个位置添加一个特定的向量来实现的。Transformer 的位置编码计算方式如下:

$$PE_{(pos, 2i)} = \sin(pos/10000^{2i/dmd}) \quad (10)$$

$$PE_{(pos, 2i+1)} = \cos(pos/10000^{2i/dmd}) \quad (11)$$

其中, PE 代表的是位置编码操作得到的矩阵位置编码矩阵, i 代表维度指数, pos 代表位置指数, dmd 代表输入的维度。

2.3. ASSA-Transformer 模型构建

本研究在 Transformer 模型的基础上引入 ASSA 机制, 构建了 ASSA-Transformer 边坡稳定性预测模型, 如图 3 所示。该模型融合了 ASSA 动态分配特征权重的特性, 以及 Transformer 建模长序依赖的能力。构建流程如下:

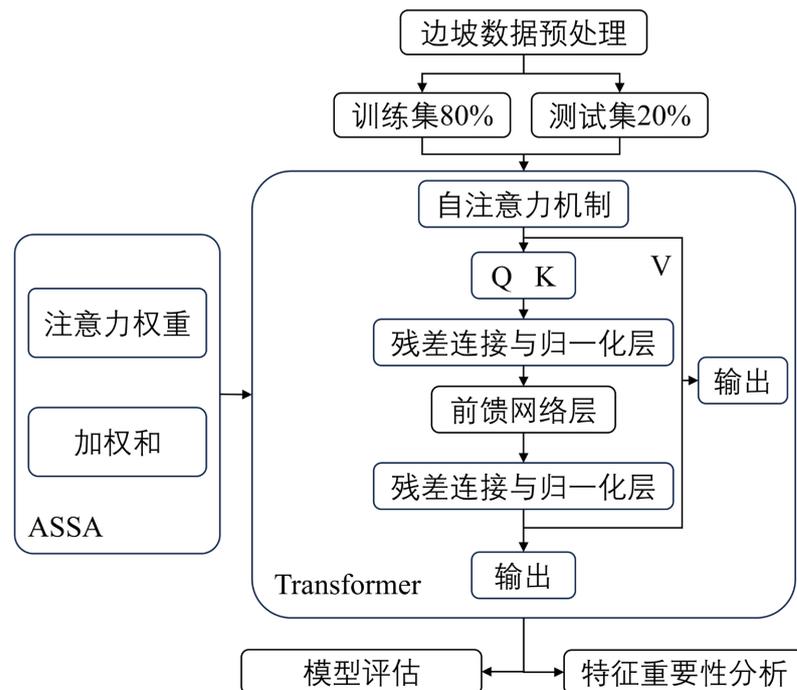


Figure 3. ASSA-transformer model flowchart

图 3. ASSA-transformer 模型流程图

- 1) 对数据归一化, 并将数据 80%分为训练集, 20%分为测试集。

2) ASSA 过滤冗余特征并突出关键依赖关系, Transformer 则捕捉长序交互作用。经优化处理的特征通过全连接输出层映射至边坡稳定性结果。

3) 采用 Adam 优化器, 损失函数设为交叉熵(Cross-entropy)。初始学习率设为 0.001, 采用小批量学习, 批量大小(Batch Size)设置为 128, 前向传播生成预测结果后反向传播梯度更新参数。

4) 采用早停机制(Early Stopping)监控模型在验证集上的性能, 保留测试集损失最小的模型以避免过拟合。

5) 训练完成后, 对模型预测结果进行反归一化转换至原始物理单位, 以确保结果的实际可解释性。

6) 通过准确率(Accuracy)、精确度(Precision)、召回率(Recall)和 F1 分数(F1 Score)多种指标评估模型的预测性能, 通过混淆矩阵可视化各模型的分类结果, 并进行特征重要性分析, 以量化各特征变量对模型预测性能的贡献价值。

3. 数据选取与相关性分析

3.1. 边坡案例数据库

边坡稳定性的影响因素有多种, 包括地质构造、岩性、水文条件和边坡几何形态等多个方面, 通过对国内外边坡工程事故报告、勘察资料、科研文献等广泛调研, 选取土体重度 γ 、黏聚力 c 、内摩擦角 φ 、坡角 β 、边坡高度 h 及孔隙水压力 r_u 作为边坡稳定性评价指标。根据文献[7]-[11]本文构建了包含 280 个边坡案例的数据库, 如表 1 所示。为确保模型的泛化能力, 该数据库包含了矿山、公路及水库等多种工程背景的案例。其中稳定状态边坡案例 146 个, 失稳状态边坡案例 134 个, 表格中“S”表示边坡稳定, “F”表示边坡失稳。为了直观展示各参数的数据分布特征, 采用小提琴图结合箱线图的方法进行呈现, 如图 4 所示。

Table 1. Slope database

表 1. 边坡数据库

编号	边坡参数						边坡状态
	$\gamma /(\text{kN}\cdot\text{m}^{-3})$	$c /(\text{kPa})$	$\varphi /(^{\circ})$	$\beta /(^{\circ})$	$h /(\text{m})$	$r_u /(\text{kPa})$	
1	20	0.1	36	45	50	0.29	F
2	16	10	35	40	115	0.35	S
3	27.3	10	39	41	511	0.29	S
4	31.3	68	37	46	366	0.25	F
5	20.9	6.5	40	40	12	0	S
6	27	32	33	42	289	0.25	F
7	17.2	10	24.3	17	38	0.4	S
8	23	20	20.3	46.2	40.3	0.25	S
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
279	28.01	9.5	27.36	41.86	538.1	0.23	S
280	31.25	25.73	27.97	48.23	91.55	0.21	F

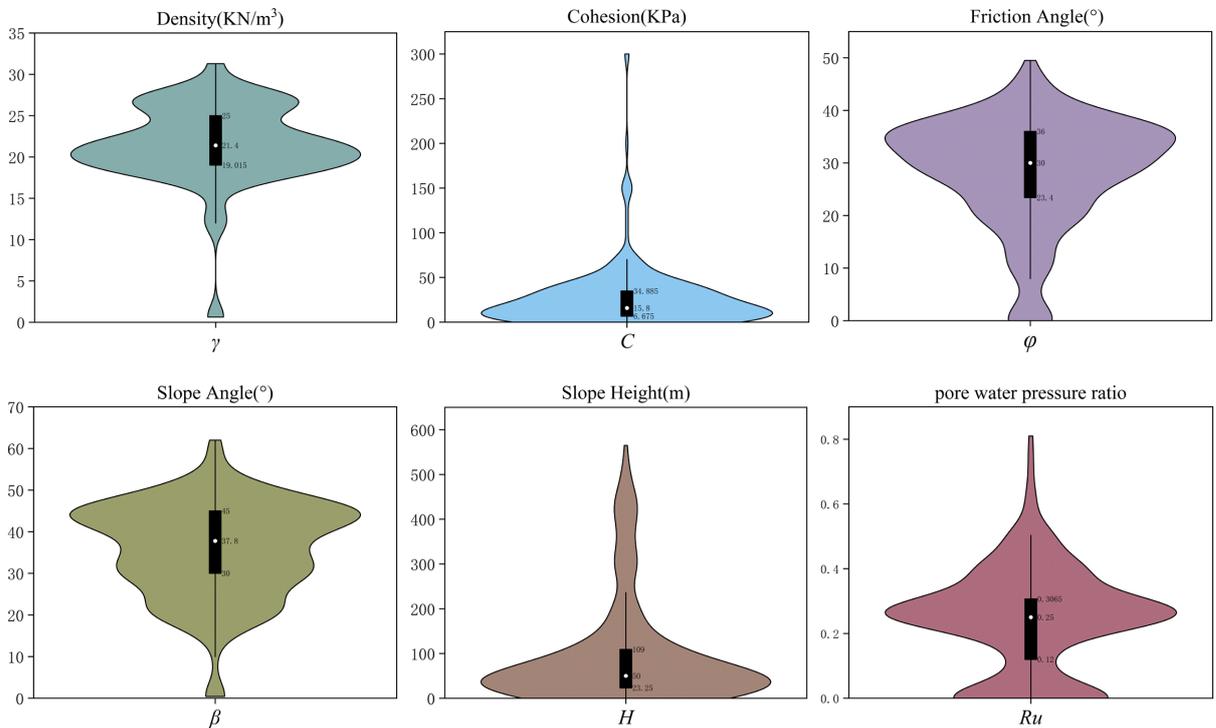


Figure 4. Violin plot of slope parameters
图 4. 边坡各指标小提琴分布图

3.2. 相关性分析

为定量评估各指标间的相关性，本研究绘制了皮尔逊相关矩阵图[12]，见图 5。皮尔逊从矩阵的三角部分可以看出，六组特征变量之间的相关系数(R)均低于 0.6，表明它们之间不存在强相关性($0.6 \leq R < 0.8$)，只有部分指标与 γ 之间存在中等的相关性($0.2 \leq R < 0.4$)。由此可认为选取的 6 个指标彼此独立，没有强线性关系，存在复杂的非线性关系。

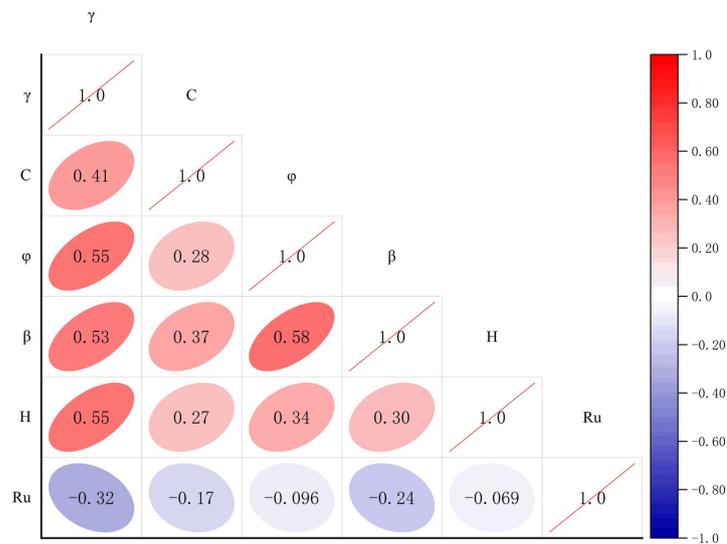


Figure 5. Feature parameter correlation analysis matrix diagram
图 5. 特征参数相关性分析矩阵图

4. 结果预测与分析

4.1. 评价指标选取

在本研究中, 为全面且准确地评估 ASSA-Transformer 模型性能, 使用 5 个关键指标: 准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F1 分数 (F1-Score) 以及受试者工作特征曲线下面积 (AUC), 这些指标可以用数值来量化模型的性能, 指标的数值越高, 表示模型的性能越好。此外还引入了 ROC 曲线和混淆矩阵, 可以进一步直观地反映模型的性能。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (12)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (13)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (14)$$

$$F_{1\text{-Score}} = \frac{2 \times (\text{Precision} \cdot \text{Recall})}{\text{Precision} + \text{Recall}} \quad (15)$$

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (16)$$

$$\text{FPR} = \frac{\text{FP}}{\text{TN} + \text{FP}} \quad (17)$$

式中, TP 表示真正类的样本数, TN 表示真负的样本数, FN 表示假负类的样本数, FP 表示假正类的样本数。ROC 曲线以假阳率 (FPR) 为横坐标、真阳性率 (TPR) 为纵坐标构建 (二者取值范围均为 [0, 1]), AUC (曲线下面积) 越接近 1, 模型的预测性能越好。

4.2. 模型训练结果分析

本研究将边坡数据库中边坡案例以 8:2 的比例随机分配为训练集与测试集, 训练集用于构建模型, 测试集则用于评价模型的性能。处理后的数据导入 ASSA-Transformer 模型并训练, 得到混淆矩阵结果如图 6 所示。

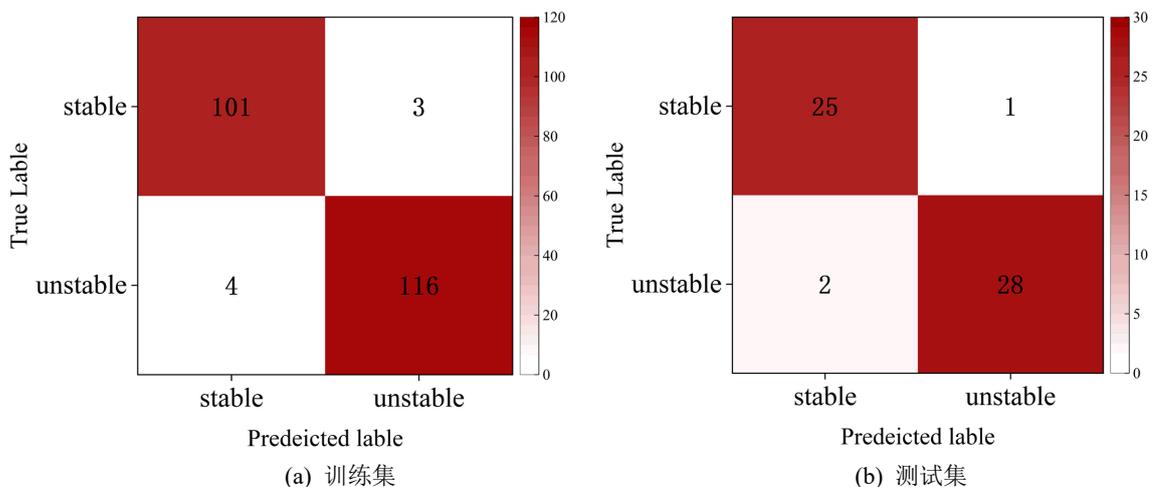


Figure 6. ASSA-transformer model confusion matrix
图 6. ASSA-transformer 模型混淆矩阵

模型在训练集上的表现为：2 个稳定数据被误判为失稳，3 个失稳样本被预测为稳定；在测试集中，仅 1 个稳定数据被误判为失稳，1 个失稳数据被预测为稳定。结果表明，所构建的 ASSA-Transformer 模型在边坡稳定性预测方面具有较好的鲁棒性与准确性。受试者工作特征(ROC)曲线如图 7 所示：

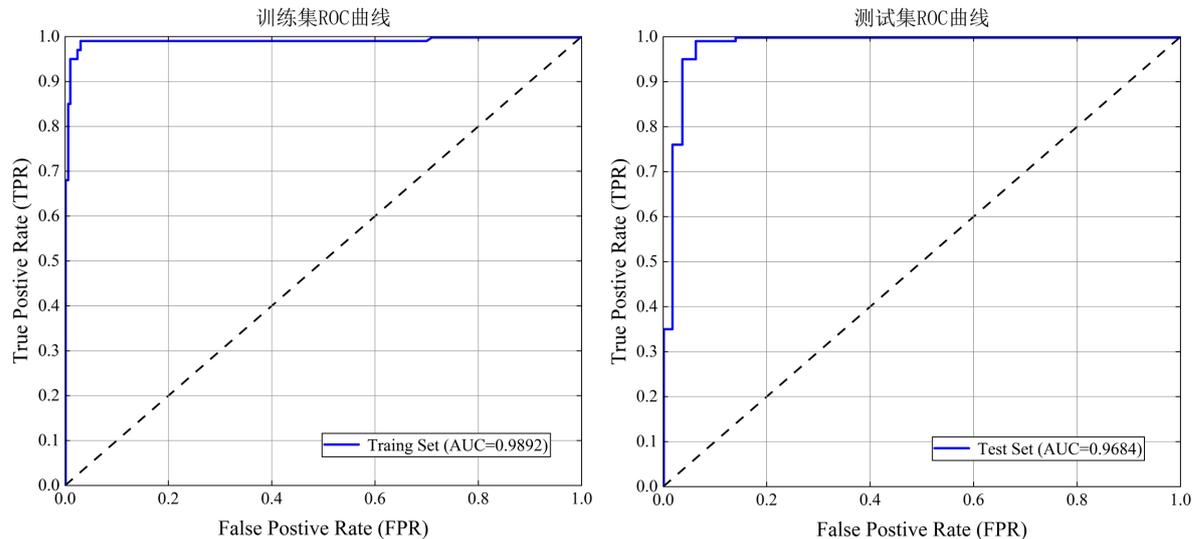


Figure 7. ASSA-transformer model ROC curve
图 7. ASSA-transformer 模型 ROC 曲线

4.3. 不同分类模型性能对比分析

为检验 ASSA-Transformer 模型的预测性能与泛化能力，本文选取支持向量机(SVM)、轻量级梯度提升机(LightGBM)、轻量级梯度提升机(LightGBM)、Transformer、网格搜索优化 Transformer (GS-Transformer) 以及粒子群优化 Transformer (PSO-Transformer) 作为对比模型，采用准确率、精确率、召回率与 F1 分数评价指标对各模型的分类结果进行评估，见表 2。研究得出，ASSA-Transformer 模型的准确率、精确率、召回率和 F1 分数分别为 0.9464、0.9459、0.9611 和 0.9684，在各项性能指标上都超过了其他模型，预测性能与泛化能力表现最佳。与未优化的 Transformer 模型相比，ASSA-Transformer 模型的各项评价指标均得到显著提高，准确率、精确率、召回率与 F1 分数分别从 0.9464、0.9459、0.839 和 0.867 提升到 0.943、0.875、1.000、0.933，这表明通过 ASSA 机制对 Transformer 模型架构进行优化，显著提升了模型的分类预测性能与泛化能力。

Table 2. Performance comparison of different classification models
表 2. 不同分类模型的性能对比

模型	准确率	精确率	召回率	F1 分数	AUC 值
SVM	0.8471	0.8653	0.8871	0.8761	0.8726
LightGBM	0.8827	0.8819	0.8963	0.8927	0.9182
Transformer	0.8634	0.8758	0.8849	0.8736	0.8927
GS-Transformer	0.8952	0.8924	0.9013	0.9047	0.9359
PSO-Transformer	0.9065	0.9082	0.9147	0.9104	0.9275
ASSA-Transformer	0.9464	0.9459	0.9611	0.9621	0.9684

4.4. 特征重要性分析

本研究通过置换特征重要性(Permutation Feature Importance, PFI)方法解释机器学习模型, 图 8 展示了各特征的平均特征重要性值, 根据特征重要性排序结果, 内摩擦角是影响边坡稳定性最主要的因素, 平均特征重要性值为 0.4154, 其次是坡角(0.204)、土体重度(0.3708)、边坡高度(0.3275)、粘聚力(0.3042)与孔隙水压力比(0.2663)。值得注意的是, 内摩擦角、边坡坡角与土体重度的重要性较高, 这与孙华芬[7]等的研究结果相似, 表明在边坡稳定性的研究中, 内摩擦角、边坡坡角与土体重度这三要素的重要性。

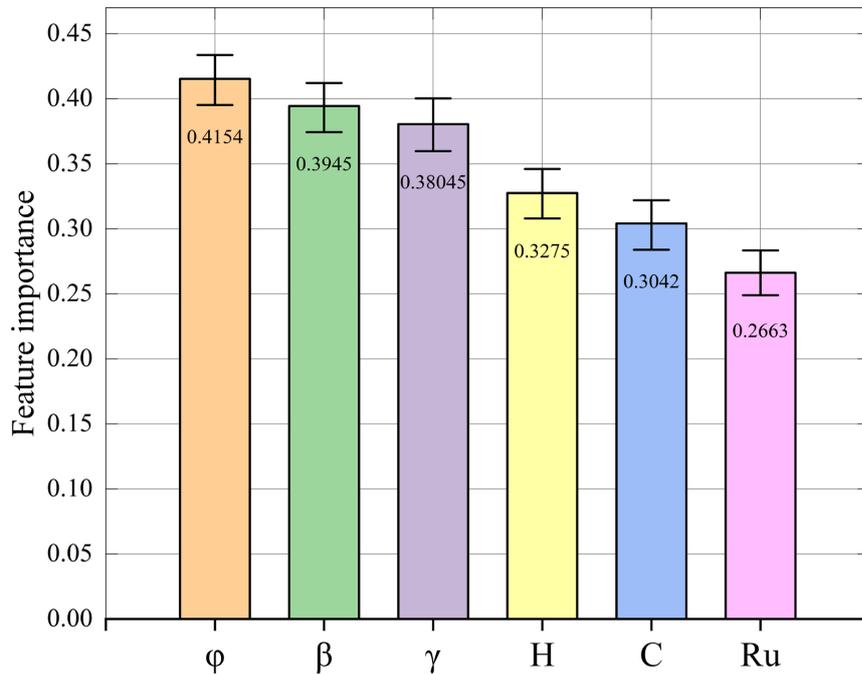


Figure 8. Feature importance analysis chart
图 8. 特征重要性分析图

5. 结论

1) 本研究构建了一种融合自适应稀疏自注意力机制(ASSA)和 Transformer 架构的边坡稳定性预测模型。在边坡预测模型的对比研究中, ASSA-Transformer 模型的准确率、精确率、召回率和 F1 分数分别为 0.9464、0.9459、0.9611 和 0.9684, 均为各模型中的最高值, 避免了 ANN 神经网络容易出现过拟合的问题, 证明了 ASSA-Transformer 模型较高的分类性能与泛化能力。

2) 与 Transformer 模型相比, 优化后的 ASSA-Transformer 模型的各项指标均得到提升, 准确率、精确率、召回率与 F1 分数分别提升了 9.6%、8.1%、8.6%和 10.2%。另外, 相较于网格搜索(GS)和粒子群(PSO)算法优化的 Transformer 模型, ASSA-Transformer 的各项指标均更高, 这充分验证了 ASSA 机制在优化 Transformer 模型的有效性, 增强了模型在边坡稳定性任务中的预测性能和泛化能力。

3) 通过对构建的边坡案例数据库进行相关性分析, 发现特征参数之间存在较复杂的非线性关系。基于特征重要性分析得出, 内摩擦角是影响边坡稳定性最主要的因素, 其次是边坡角与土体重度。表明在边坡稳定性的研究中, 重点关注内摩擦角、边坡坡角与土体重度, 有助于提升边坡稳定性评价的可靠度。

综上, ASSA-Transformer 模型为边坡稳定性的预测提供了一种新方法, 对边坡工程安全评估与防灾决策具有实际意义。

参考文献

- [1] 刘贤, 刘亚栋, 黎学优, 等. 基于随机种子约束法的非均质边坡参数表征及失稳风险评估[J/OL]. 岩土工程学报, 1-10. <https://link.cnki.net/urlid/32.1124.TU.20260120.1104.006>, 2026-02-03.
- [2] 彭文喜. 变质岩高边坡稳定性分析及加固技术研究[J/OL]. 铁道建筑技术, 1-5. <https://link.cnki.net/urlid/11.3368.TU.20260121.1913.044>, 2026-02-03.
- [3] 张仕杰, 张煜, 张宁. 基于 PSO-LightGBM 模型的边坡稳定性预测研究[J]. 防灾减灾工程学报, 2025, 45(5): 1233-1240.
- [4] Zhou, S., Chen, D., Pan, J., *et al.* (2024) Adapt or Perish: Adaptive Sparse Transformer with Attentive Feature Refinement for Image Restoration. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seattle, 16-22 June 2024, 2952-2963. <https://doi.org/10.1109/CVPR52733.2024.00285>
- [5] Vaswani, A., Shazeer, N., Parmar, N., *et al.* (2017) Attention Is All You Need. *Advances in Neural Information Processing Systems*, **30**, 5998-6008.
- [6] 伊廷婧汶, 黄才生, 覃勇, 等. 基于北斗监测数据的高陡边坡变形 Transformer-CNN 预测模型[J]. 重庆大学学报, 2025, 48(10): 81-94.
- [7] Wang, M., Zhao, G. and Wang, S. (2024) Hybrid Random Forest Models Optimized by Sparrow Search Algorithm (SSA) and Harris Hawk Optimization Algorithm (HHO) for Slope Stability Prediction. *Transportation Geotechnics*, **48**, Article 101305. <https://doi.org/10.1016/j.trgeo.2024.101305>
- [8] 孙吉书, 夏健超, 王建平, 等. 相关向量机模型在边坡稳定性预测中的应用[J]. 科学技术与工程, 2021, 21(28): 12234-12242.
- [9] 臧焜岩, 李梅红. 基于 GA-BP 模型的露天矿边坡稳定性预测[J]. 中国矿业, 2019, 28(6): 144-148.
- [10] 张豪, 罗亦泳. 基于人工免疫算法的边坡稳定性预测模型[J]. 煤炭学报, 2012, 37(6): 911-917.
- [11] 孙华芬, 饶辉, 候克鹏, 等. 基于 WMA-SVM 的边坡稳定性预测模型[J/OL]. 高压物理学报, 1-16. <https://link.cnki.net/urlid/51.1147.o4.20260129.1408.002>, 2026-02-01.
- [12] 张流业. 基于皮尔逊相关系数的 AW189 直升机扭矩监测与故障诊断研究[J]. 装备维修技术, 2025(6): 38-41.