基于变分自编码器三维纹理特征的路面抗滑性能预测

金传雨[1]，贺轩浩[2]，许伟强[2]，林修全[3]，战友[1*]
（1.西南交通大学 土木工程学院，四川 成都 610031；2.四川华腾公路试验检测有限责任公司，四川 成都 611730；3.北部湾港北海码头有限公司，广西 北海 536000）

摘要：路面三维纹理能够反映表面起伏、粗糙程度及局部结构特征，为抗滑性能的非接触式评价提供了数据基础。本文采用变分自编码器（VAE）提取三维路面纹理特征，并建立相应的摆值（BPN）预测方法。共采集 1300 组三维纹理数据，其中 871 组具有 BPN 标签。数据经离群值处理和宏微观纹理分解去噪后，利用引入感知损失的 VAE 将高维纹理映射至潜在空间，并以编码器输出的后验分布均值作为确定性潜在纹理特征；随后固定编码器参数，利用所提取特征训练 BPN 回归模型。重建结果表明，加入感知损失后，模型峰值信噪比（PSNR）和结构相似性（SSIM）分别为 40.01 dB 和 0.947，感知损失由 0.386 降至 0.154；BPN 测试集上的平均绝对误差（MAE）、均方根误差（RMSE）和决定系数 R^2分别为 2.962、3.901 和 0.872，优于采用深度残差网络（ResNet34）和视觉 Transformer（ViT）进行特征提取的对比模型。结果表明，VAE 提取的三维纹理特征可用于 BPN 预测，为基于三维纹理的路面抗滑性能评价提供了一种特征提取与预测方法。

关键词：路面三维纹理；抗滑性能；变分自编码器；特征提取；深度学习
中图分类号：U416.2 **文献标志码：**A

Pavement skid resistance prediction based on three-dimensional texture features extracted by a variational autoencoder

Jin Chuanyu[1], He Xuanhao[2], Xu Weiqiang[2], Lin Xiuquan[3], Zhan You[1*]

(1. School of Civil Engineering, Southwest Jiaotong University, Sichuan, Chengdu 610031, China;2. Sichuan Huateng Highway Testing Checking and Measuring Co.,Ltd., Sichuan, Chengdu 611730, China;3. Beibu Gulf Port Beihai Terminal Co., Ltd., Guangxi, Beihai 536000, China)

Abstract: Three-dimensional pavement texture reflects surface elevation variation, roughness, and local structural characteristics, providing an important basis for non-contact evaluation of skid resistance. This study uses a variational autoencoder (VAE) to extract three-dimensional pavement texture features and develops a corresponding British Pendulum Number (BPN) prediction method. A total of 1,300 three-dimensional texture samples were collected, of which 871 were labeled with BPN values. After outlier removal, macrotexture–microtexture decomposition and denoising, a VAE with perceptual loss was used to map the high-dimensional texture data into a latent space. The posterior mean output by the encoder was then taken as a deterministic latent texture feature. The encoder parameters were subsequently fixed, and the extracted features were used to train the BPN regression model. Reconstruction results showed that, after introducing perceptual loss, the peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM) were 40.01 dB and 0.947, respectively, while the perceptual loss decreased from 0.386 to 0.154. On the BPN test set, the model achieved a mean absolute error (MAE) of 2.962, a root mean square error (RMSE) of 3.901, and a coefficient of determination (R^2) of 0.872, outperforming the comparison models based on ResNet34 and the Vision Transformer (ViT) for feature extraction. The results show that the three-dimensional texture features extracted by the VAE can be effectively used for BPN prediction, providing a feature extraction and prediction approach for pavement skid-resistance evaluation based on three-dimensional texture data.

Key words: three-dimensional pavement texture; skid resistance; variational autoencoder; feature extraction; deep learning

收稿日期：2026-07-11 **修回日期：**2026-09-10
基金项目：国家自然科学基金资助项目（编号：52478471）；内蒙古自治区 2025 年重点研发和成果转化计划项目（编号：2025YFHH0009）；重庆市技术创新与应用发展川渝科技创新合作计划（编号：CSTVB2024TIAD-CYKJCXX0004）；蜀道投资集团科技项目（编号：SDIG2024YY0003）
作者简介：金传雨，男，硕士研究生，道路与铁道工程. E-mail：jcy0120@my.swjtu.edu.cn
***通信作者：**战友，男，博士，副教授，道路与铁道工程. E-mail：zhanyou@swjtu.edu.cn

0 引言

路面抗滑性能是影响车辆行驶安全的重要因素之一[1]。尤其在雨天、制动和转弯等行驶工况下，轮胎与路面之间的附着状态直接关系到车辆的操纵稳定性和制动距离[2]。路面表面纹理是抗滑性能形成的重要基础，三维纹理能够较为完整地反映路表峰谷起伏、粗糙程度和局部结构特征[3]。随着三维激光检测、结构光测量等技术的发展，路面纹理数据的获取精度不断提高，也为抗滑性能的分析与预测提供了更加丰富的数据支撑[4]。

基于三维纹理的非接触式路面抗滑性能分析通常通过计算平均断面深度（Mean Profile Depth，MPD）、均方根粗糙度（Root Mean Square Roughness，RMS）、偏度（Surface Skewness，Ssk）和峰度（Surface Kurtosis，Sku）等纹理参数，反映路表高程起伏、粗糙程度以及峰谷分布特征。已有研究在上述纹理参数的基础上，进一步结合机器学习和神经网络等方法拟合其与抗滑指标之间的关系[5-7]。此类方法能够综合利用多个纹理参数，但模型输入仍以预定义纹理参数为主，对三维纹理中的局部形态和空间分布信息利用不足。因此，部分研究开始引入深度学习方法，直接从三维纹理数据中提取空间特征，用以弥补预定义纹理参数对局部纹理形态表达不足的问题。裴等[8]从路面三维纹理数据中获取二维纹理信息，构建路面摩擦性能分级模型，实现了摩擦等级的准确预测。Zhan 等[9]进一步利用傅里叶变换对路面三维纹理数据进行多尺度分解，在此基础上构建了基于 Transformer 的路面摩擦性能回归网络，实现了沥青混凝土路面摩擦性能的有效预测。此类方法减少了对预定义纹理参数的依赖，并增强了对纹理空间信息的利用。然而，三维纹理数据空间分辨率较高，在包含丰富局部结构信息的同时，也可能存在噪声和冗余信息，直接进行特征学习仍具有一定难度。因此，在保留主要纹理结构的同时获得更加紧凑的特征表征，是进一步开展抗滑性能预测需要考虑的问题。

自编码器（Autoencoder，AE）和变分自编码器（Variational Autoencoder，VAE）等模型通过编码和解码将高维数据压缩至潜在空间，并通过重建过程学习原始数据的主要特征[10-11]。相较于 AE 的确定性编码，VAE 对潜在变量进行概率建模，并通过 Kullback–Leibler（KL）散度约束潜在分布，使潜在空间具有更加明确的分布结构；已有研究表明，VAE 学习得到的潜在特征可用于预测、生成等下游任务，并在部分任务中较普通 AE 表现出更好的特征表达能力[12-15]。本文采用 VAE 对路面三维纹理进行压缩表征，并在重建过程中引入感知损失，以进一步约束局部纹理结构。VAE 训练完成后固定编码器，提取潜在特征用于摆值（British Pendulum Number，BPN）回归预测。为比较不同特征提取方式对抗滑性能预测的影响，进一步选取深度残差网络（ResNet34）和视觉 Transformer（Vision Transformer，ViT）作为对比模型。

1　数据采集与预处理

1.1 数据采集

本文采用 LS-40 三维纹理测量设备采集不同类型路面的表面高程数据。该设备的水平采样分辨率为 0.05 mm，垂直分辨率为 0.01 mm，单次采集可生成尺寸为 2 048×2 048 的三维高程矩阵。矩阵中每个数据点对应路面表面相应位置的高程值。纹理数据采集对象包括普通沥青混凝土路面（Asphalt Concrete，AC）、沥青玛蹄脂碎石混合料路面（Stone Mastic Asphalt，SMA）、高摩擦表面处治路面（High Friction Surface Treatment，HFST）、超薄罩面、有刻槽水泥混凝土路面和未刻槽水泥混凝土路面 6 类典型路面表面。样本来源包括室内车辙板、校园道路以及川内在役高速公路和收费站路面，具体见表 1。共获得三维纹理数据 1300 组。其中，部分沥青类路面在纹理采集的同时进行了摆式摩擦系数仪测试，共获得 871 组具有 BPN 标签的纹理数据。水泥混凝土样本仅用于无监督纹理表征阶段，以增加训练数据中的纹理形态差异，不参与后续 BPN 回归模

型的训练、验证和测试。不同路面在材料组成、表面构造和峰谷分布方面存在明显差异，使采集的数据具有较为丰富的纹理形态。图 1 展示了部分三维纹理数据。

表 1 不同路面结构三维纹理数据来源

Table 1 Sources of 3D Texture Data for Different Pavement Types

路面结构类型	数据来源	三维纹理样本数	BPN 标签样本数
AC	室内车辙板试验、学校路面、川内在役高速公路路面	650	614
HFST	川内在役高速公路收费站路面	212	92
SMA	室内车辙板试验、川内在役高速公路	152	65
超薄罩面	川内在役高速公路路面	101	100
水泥混凝土路面	川内在役高速公路收费站路面	185	0

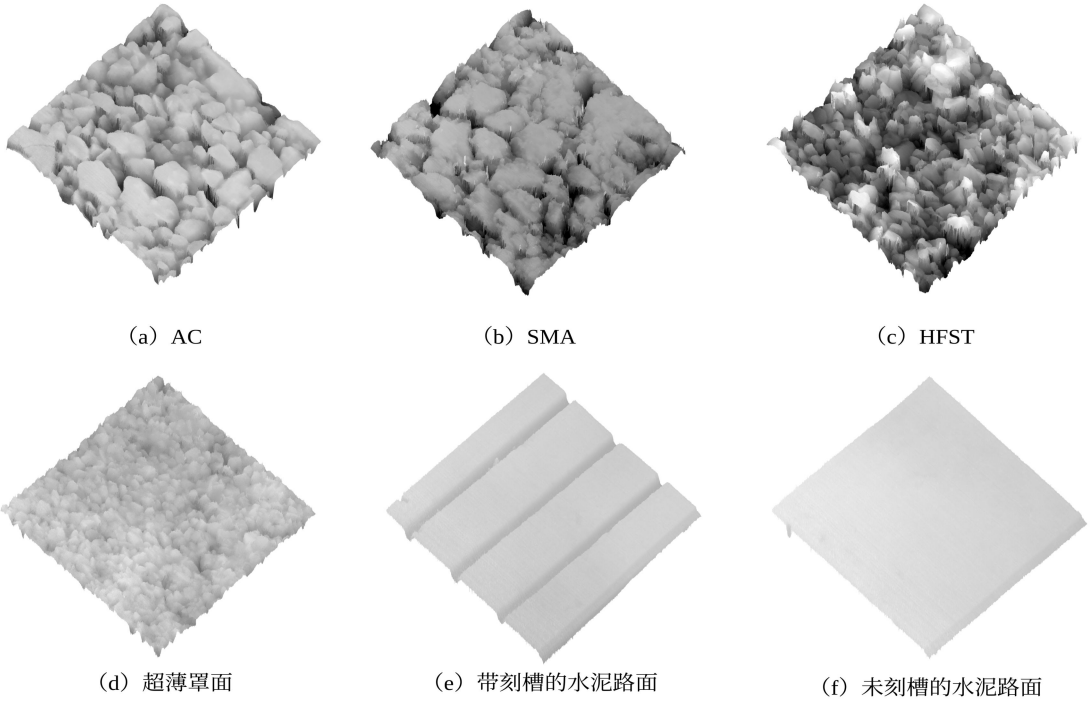

（a）AC （b）SMA （c）HFST

（d）超薄罩面 （e）带刻槽的水泥路面 （f）未刻槽的水泥路面

图 1 不同路面结构的三维纹理样本

Figure 1 3D Texture Samples of Different Pavement Types

1.2 数据预处理

由于设备测量精度、环境扰动、路表局部污染以及纹理表面突变反射等因素的影响，LS-40 采集得到的原始三维高程数据中存在较多噪声和异常高程点。为保证纹理数据的连续性和可靠性，本文沿用前期研究中的去噪方法[9]。首先对原始高程矩阵中的离群值进行识别和剔除，设定阈值为 2000，超过阈值的点视为离群值，将其替换为相邻 3 格内非离群值的均值。

离群值处理完成后，对三维纹理数据进行傅里叶变换，将原始三维纹理分解为宏观纹理和微观纹理两部分。由于两类纹理的尺度和噪声表现不同，本文分别对其进行处理。根据 ISO 13473-1 对路面纹理尺度的划分，以 0.5 mm 为宏观纹理与微观纹理的临界波长，将波长大于 0.5 mm 的纹理成分划分为宏观纹理，波长小于 0.5 mm 的纹理成分划分为微观纹理。

对于宏观纹理部分，采用均值滤波去除其中的局部异常起伏。均值滤波能够削弱局部突变，使宏观纹理变化更加平缓，同时保留主要的高程起伏特征。其公式为：

$$g(x,y)=\frac{1}{mn}\sum_{i=-a}^{a}\sum_{j=-b}^{b}f(x+i,y+j) \qquad (1)$$

$$m=2a+1, n=2b+1 \tag{2}$$

式中：x、y 为计算坐标点；g 为坐标点滤波后值；f 为坐标点原始值；m、n 分别为卷积核的高和宽，本文均取 11；a，b 分别为两个方向上的半窗口尺寸，本文取 5。

对于微观纹理部分，采用中位数绝对偏差（Median Absolute Deviation，MAD）方法进行噪声处理。微观纹理中包含较多细小峰谷结构，这些细节与路表粗糙程度和抗滑性能密切相关，不宜采用过强的平滑方法。MAD 方法对异常值具有较好的鲁棒性，能够识别局部尖峰噪声，同时尽量保留真实的细小纹理变化。其公式如下：

$$D_{\mathrm{MAD}}=median\left(\left|x_i-median\left(x\right)\right|\right) \tag{3}$$

$$\left|x_i-median\left(x\right)\right|>n\cdot D_{\mathrm{MAD}} \tag{4}$$

式中：x_i 为局部窗口内第i个高程值；x 为窗口内所有高程值组成的数据向量；D_{MAD} 为中位数绝对偏差；n 为异常值判别系数，本文取 3；当某一高程值 x_i 与局部中位数之间的绝对偏差大于 nD_{MAD} 时，将该点判定为异常点，取窗口内非异常值集合的中位数代替。

完成宏观纹理和微观纹理的分别去噪后，将两部分重新组合，得到修正后的三维高程数据。重组后，对高程数据进行简单的高斯平滑，以减小可能存在的局部不连续。图 2 展示了某个样本的去噪过程。

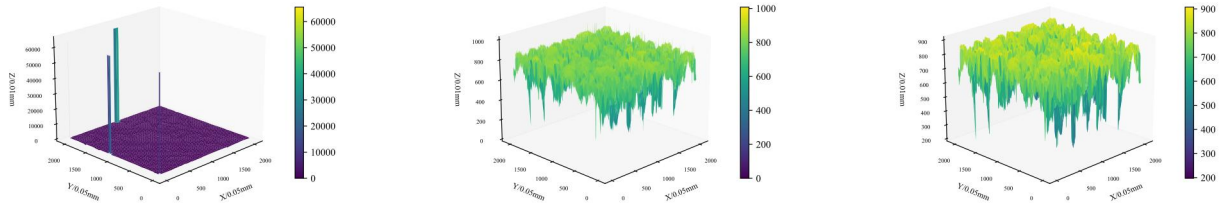

图 2 去噪流程

Figure 2　Denoising Workflow

1.3 数据集构建

本文以单次采集得到的 2 048×2 048 三维高程数据作为一个原始纹理样本。首先对 871 组具有 BPN 标签的样本进行划分。为避免不同路面类型及 BPN 取值范围分布差异过大，按照路面结构进行分类，并以 5 BPN 为一个区间，在各类样本中随机抽取训练集、验证集和测试集。最终得到训练样本 612 组、验证样本 87 组和测试样本 172 组，比例约为 7:1:2。

其余 429 组无 BPN 标签样本按照路面结构补充至相应数据集中，使全部 1300 组纹理数据的训练集、验证集和测试集分别为 910、130 和 260 组。其中，1300 组纹理数据构成后续纹理表征任务的数据集，871 组具有 BPN 标签的样本构成抗滑性能预测数据集。

数据集划分以原始 2048×2048 纹理样本为单位进行。不同采集样本的测量区域之间不存在重叠，同一原始样本后续裁剪得到的纹理块均保留在原数据集中。

2　基于变分自编码器的三维纹理潜在表征与抗滑预测方法

2.1 三维路面变分自编码器

路面三维纹理高程图具有较高的空间分辨率，能够记录路表细小峰谷和粗糙结构，但同时包含大量局部纹理信息和冗余数据，直接用于抗滑性能预测会增加模型的特征学习难度。变分自编码器（Variational Autoencoder，VAE）[11]能够将高维数据压缩到连续潜在空间，并利用解码器的重建约束，使潜在变量在压缩数据维度的同时保留较丰富的纹理形态和空间结构信息。因此，本文首先利用 VAE 学习三维路面纹理的潜在表征，再将其作为后续抗滑性能预测的特征输入。其网络结构如图 3 所示。其中，编码器和解码器均包含 4 个阶段，每个阶段均由两个残差块[16]组成。编码器通过逐级下采样提

取纹理特征，特征通道数随网络加深逐步增加，并输出潜在分布的均值和对数方差；解码器采用与编码器相对应的结构逐级恢复空间分辨率，实现三维纹理的重建。各阶段特征图尺寸和通道数见图 3。

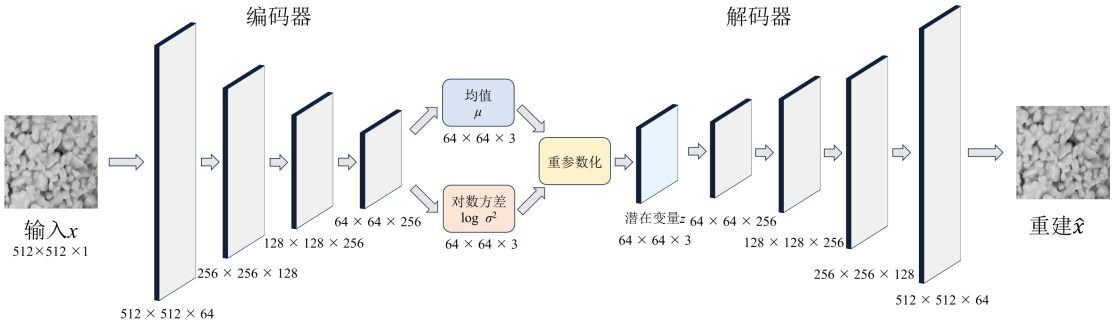

图 3 VAE 结构图

Figure 3 VAE Architecture

设输入的三维纹理高程图为 x，编码器输出潜在变量分布的均值μ和对数方差 $\log\ \sigma^2$，并由对数方差计算得到标准差σ。潜在变量的近似后验分布可表示为：

$$q_\phi(z\mid x)=\mathrm{N}\left(z;\mu_\phi(x),\sigma_\phi^2(x)I\right) \tag{5}$$

式中：z 为潜在变量，ϕ表示编码器参数；$\mu_\phi(x)$和$\sigma_\phi(x)$分别为编码器输出的均值和由对数方差计算得到的标准差；I 为单位矩阵。为保证采样过程能够参与反向传播，模型采用重参数化方法得到潜在变量 z：

$$z=\mu_\phi(x)+\sigma_\phi(x)\odot\varepsilon,\varepsilon\sim\mathrm{N}\left(0,I\right) \tag{6}$$

式中：ε为从标准正态分布中采样得到的随机噪声；$\odot$表示逐元素相乘。通过该方式，随机采样过程被转化为关于$\mu_\phi(x)$和$\sigma_\phi(x)$的可导计算，从而实现端到端训练。

解码器以潜在变量 z 为输入，重建路面三维纹理高程图。模型训练过程中，编码器需要将原始三维纹理中的主要峰谷起伏和局部粗糙结构及其空间分布等信息映射到潜在空间，解码器则根据潜在变量恢复纹理形态。为完成纹理重建，潜在变量需要保留原始纹理中的主要结构信息。VAE 训练完成后，采用编码器输出的后验分布均值$\mu_\phi(x)$作为确定性的潜在纹理特征，并将其用于后续抗滑性能预测。对于 512×512 的纹理块，编码器最终输出的潜在纹理特征大小为 64×64×3。后续分别通过纹理重建性能和 BPN 预测性能评价 VAE 学习得到的纹理特征。

2.2 潜在特征抗滑回归模型

为利用变分自编码器得到的潜在特征预测路面抗滑性能，本文在编码器后连接抗滑回归模型。去噪后的三维纹理图像首先输入编码器，提取后验分布均值μ作为潜在纹理特征；随后将该特征送入回归模型，输出样本对应的 BPN 预测值。通过这种方式，抗滑预测不再直接依赖原始高程矩阵，而是基于压缩后的纹理表征完成。模型结构如图 4 所示。

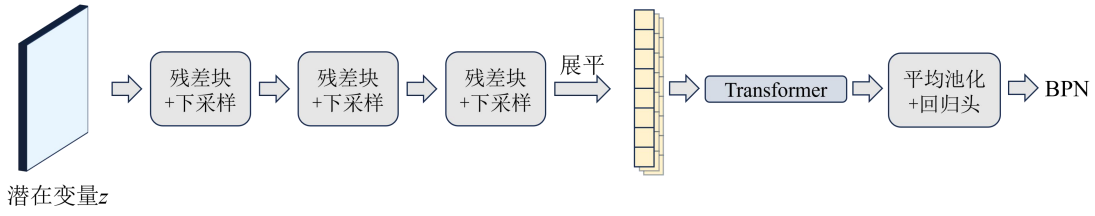

图 4 抗滑预测模块

Figure 4 Skid Resistance Prediction Module

2.3 损失函数

本文采用两阶段方式完成模型训练。第一阶段仅训练三维纹理 VAE，使模型能够将原始高程图压缩到潜在空间，并通过解码器恢复路面纹理形态。该阶段不使用 BPN 标签，所有完成预处理的三维纹理样本均可参与训练。VAE 的训练损失由重建损失、感知损失和 KL 散度损失组成，其总损失可表示为：

$$\mathrm{L}_{\mathrm{VAE}}=\mathrm{L}_{\mathrm{rec}}+\lambda_{\mathrm{per}}\mathrm{L}_{\mathrm{per}}+\lambda_{\mathrm{kl}}\mathrm{L}_{\mathrm{kl}} \tag{7}$$

式中：$\mathrm{L}_{\mathrm{rec}}$ 为重建损失；$\mathrm{L}_{\mathrm{per}}$ 为感知损失；L_{kl} 为 KL 散度损失；λ_{per} 和λ_{kl} 分别为对应损失项的权重系

数，结合各损失项的量级与训练情况，本文分别取 0.1 和 10^{-7}。

重建损失用于约束解码器输出结果与原始三维高程图之间的数值差异。考虑到路面纹理中仍可能存在少量局部异常波动，本文采用 Charbonnier 损失作为重建损失[17]。该损失可看作 L1 损失的平滑形式，对局部异常值相对不敏感，同时在零点附近具有更好的可导性。设一个批次中包含 m 张纹理图像，原始高程图为 x，重建结果为$\hat{x}$，图像尺寸为$H \times W$，则重建损失为：

$$\mathrm{L}_{\mathrm{rec}}=\frac{1}{mHW}\sum_{k=1}^{m}\sum_{i=1}^{H}\sum_{j=1}^{W}\rho\left(\hat{x}_{k,i,j}-x_{k,i,j}\right) \tag{8}$$

$$\rho\left(r\right)=\sqrt{r^2+\varepsilon^2} \tag{9}$$

式中：$\hat{x}_{k,i,j}$ 和 $x_{k,i,j}$ 分别表示第 k 张纹理图像在位置(i,j)处的重建高程值和原始高程值；ε为稳定项，本文取 10^{-3}。

为提高重建纹理的结构一致性，本文在 VAE 训练过程中引入感知损失。感知特征提取网络采用 VGG（Visual Geometry Group）网络，其参数首先由 ImageNet 预训练权重初始化，随后在本文路面纹理数据集上进行路面类型分类微调[18-20]。分类微调采用前文 1.3 所述的纹理表征数据集，在测试集上取得了 97.7%的准确率。微调完成后，固定 VGG 网络参数，并提取其部分中间层输出作为纹理特征，通过约束重建纹理与原始纹理在特征空间中的差异，保证重建结果在局部结构、边缘信息和纹理形态等方面保持较高的一致性。

KL 散度损失用于约束潜在变量的分布。VAE 编码器输出潜在变量的均值μ和对数方差 $\log\sigma^2$，并由此得到标准差σ，将近似后验分布 $q_\phi(z|x)$向标准正态先验 $p(z)=\mathcal{N}(0,I)$靠近。其损失可表示为：

$$\mathrm{L}_{\mathrm{kl}}=D_{\mathrm{KL}}\left(q_\phi(z|x)\middle|p\left(z\right)\right) \tag{10}$$

对于高斯分布形式的潜在变量，上式可展开为：

$$\mathrm{L}_{kl}=\frac{1}{2m}\sum_{k=1}^{m}\sum_{d=1}^{D}\left(\mu_{k,d}^2+\sigma_{k,d}^2-\log\left(\sigma_{k,d}^2\right)-1\right) \tag{11}$$

式中：D 为潜在变量维度。KL 散度项用于约束潜在变量分布，但在三维纹理重建任务中，过强的 KL 约束可能削弱编码器的表达能力，甚至导致后验崩塌[15]。为避免编码器作用被弱化，本文设置较小的 KL 损失权重。第一阶段训练完成后，VAE 编码器用于提取三维纹理潜在特征，并作为第二阶段抗滑性能回归模型的输入。

第二阶段训练抗滑性能回归模型。该阶段固定第一阶段训练得到的 VAE 编码器参数，仅利用编码器提取三维纹理潜在特征，并将其输入抗滑回归模型中预测 BPN。设第 k 个样本的实测摆值为 y_k，模型预测值为$\hat{y}_k$，一个批次中具有 BPN 标签的样本数量为 m_b，采用均方误差作为抗滑预测损失，可表示为：

$$\mathrm{L}_{\mathrm{bpn}}=\frac{1}{m_b}\sum_{k=1}^{m_b}\left(\hat{y}_k-y_k\right)^2 \tag{12}$$

式中：$\mathrm{L}_{\mathrm{bpn}}$ 为抗滑预测损失。通过最小化该损失，模型学习潜在纹理特征与 BPN 之间的对应关系。第二阶段仅采用具有 BPN 标签的样本进行训练。

3　试验与分析

3.1 模型训练与评价设置

模型训练分为两个阶段完成。第一阶段训练三维纹理 VAE，第二阶段在固定 VAE 编码器参数的基础上训练抗滑性能回归模型。训练过程中采用 Adam 优化器[21]，学习率设为 10^{-4}，批量大小 16。由于训练过程中采用随机纹理裁剪，输入的纹理块随着迭代动态生成，因此本文采用迭代次数来控制训练过程。VAE 阶段训练 30 万次迭代，抗滑回归阶段训练 5 万次迭代。所有试验均在单张 NVIDIA RTX 5090 GPU 上完成。

VAE 训练阶段以三维纹理高程图为输入。训练时，从训练集中随机裁剪尺寸为 512×512 的纹理块作为 VAE 的输入，在控制计算量的同时保留必要的纹理信息。验证和测试阶段则将 2 048×2 048 原始纹理无重叠划分为 16 个 512×512 纹理块，分别进行重建，并按照原始空间位置拼接恢复为 2 048×2 048 高程图，在完整重建图上计算相应的重建评价指标。

抗滑性能预测阶段仅使用具有BPN标签的样本

进行训练。为保留较完整的纹理空间分布，训练时先从原始 2 048×2 048 的三维纹理数据中随机裁剪 1024×1 024 区域，再将其划分为 4 个互不重叠的 512×512 纹理块。各纹理块分别经过第一阶段训练完成的 VAE 编码器提取潜在特征，随后按照其在原始 1 024×1 024 区域中的空间位置在潜在空间中重新拼接，形成完整的潜在特征图，并输入抗滑回归模型预测 BPN。验证和测试阶段，将尺寸为 2048×2048 的原始三维纹理数据划分为四个互不重叠的 1 024×1 024 区域，并按照与训练阶段相同的方法处理，4 个 1 024×1 024 区域分别得到一个 BPN 预测值，取平均值作为该 2 048×2 048 原始三维纹理样本的最终预测结果。

3.2 模型性能评价指标

为评价 VAE 对路面三维纹理的重建效果，本文采用峰值信噪比（Peak Signal-to-Noise Ratio，PSNR）[22]、结构相似性（Structural Similarity Index Measure，SSIM）[23]和路面感知损失作为评价指标，其中 PSNR 和 SSIM 的公式如下：

$$\mathrm{PSNR}=10\log_{10}\left(\frac{MAX^2}{\mathrm{MSE}}\right) \tag{13}$$

$$\mathrm{MSE}=\frac{1}{MN}\sum_{i=1}^{M}\sum_{j=1}^{N}\left[x(i,j)-\hat{x}(i,j)\right]^2 \tag{14}$$

$$\mathrm{SSIM}=\frac{(2\bar{x}\bar{\hat{x}}+C_1)(2\mathrm{Cov}(x,\hat{x})+C_2)}{(\bar{x}^2+\bar{\hat{x}}^2+C_1)(\mathrm{Var}(x)+\mathrm{Var}(\hat{x})+C_2)} \tag{15}$$

式中：MAX 表示原始纹理数据的最大可能取值，MSE 表示原始纹理与重建纹理之间的均方误差，M 和 N 分别表示纹理矩阵的行数和列数，$x(i,j)$和 $\hat{x}(i,j)$ 分别表示原始纹理与重建纹理在(i,j)位置处的数值。$\bar{x}$和$\bar{\hat{x}}$分别表示原始纹理和重建纹理的均值；Var(x)和 Var($\hat{x}$)分别表示两者的方差；Cov(x, x̂)表示两者之间的协方差；C1 和 C2 为防止分母接近于零而设置的稳定常数，本文取 10^{-6}。

为评价抗滑性能预测模型的预测精度，本文采用平均绝对误差（Mean Absolute Error，MAE）、均方根误差（Root Mean Square Error，RMSE）和决定系数（Coefficient of Determination，R^2）作为评价指标，公式如下：

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|y_i-\hat{y}_i\right| \tag{16}$$

$$\mathrm{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2} \tag{17}$$

$$R^2=1-\frac{\sum_{i=1}^{n}\left(y_i-\hat{y}_i\right)^2}{\sum_{i=1}^{n}\left(y_i-\bar{y}\right)^2} \tag{18}$$

式中：n 表示测试集样本数量。

3.3 纹理重建性能及抗滑性能评价

为评价 VAE 的三维重建性能，并分析感知损失的影响，本文设置了 VAE 重建消融试验。对照模型 VAE-Base 仅采用 Charbonnier 重建损失和 KL 散度损失进行训练；改进模型 VAE-Per 在此基础上加入感知损失。两组模型采用相同的数据划分、网络结构和训练参数，以保证公平。结果见表 2。

表 2 不同 VAE 模型的纹理重建评价结果

Table 2 Texture Reconstruction Performance of Different VAE Models

方法	PSNR/dB ↑	SSIM ↑	路面感知损失 ↓
VAE-Base	40.93	0.955	0.386
VAE-Per	40.01	0.947	0.154

由表 2 可知，VAE-Base 的 PSNR 和 SSIM 分别为 40.93 dB 和 0.955，均高于 VAE-Per 的 40.01 dB 和 0.947。加入感知损失后，模型的像素级重建指标略有下降；但从路面感知损失来看，VAE-Per 由 0.386 降低至 0.154，重建纹理在 VGG 特征空间中与原始纹理更为接近。由此可见，引入感知损失改变了模型对像素一致性与纹理特征一致性的权衡。

在完成 VAE 重建性能评价后，进一步对潜在特征用于 BPN 预测的效果进行验证。抗滑回归阶段固定已训练好的 VAE 编码器，仅训练后续回归网络。模型在测试集上的预测结果见表 3，预测值与实测 BPN 的散点图见图 5。

表 3 不同 VAE 模型的抗滑性能预测结果

Table 3 Skid Resistance Prediction Performance of

Different VAE Models

方法	MAE ↓	RMSE ↓	R^2 ↑
VAE-Base	3.230	4.483	0.830
VAE-Per	2.962	3.901	0.872

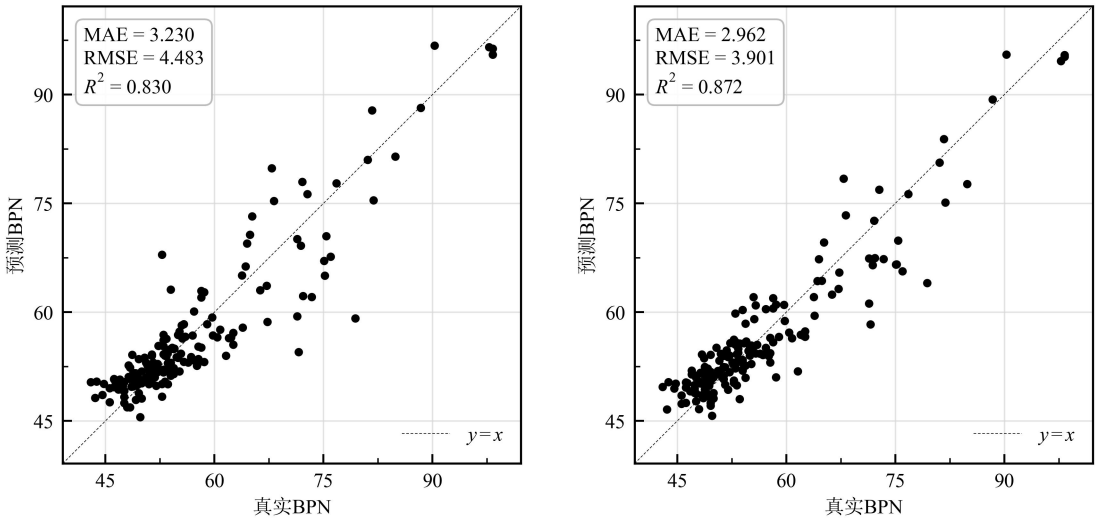

（a） VAE-Base　　（b） VAE-Per

图 5 模型预测散点图

Figure 5　Scatter Plot of Ground Truth and Predicted BPN Values

由图 5 可见，两组模型的预测结果整体均分布在理想线附近，表明基于 VAE 潜在特征建立的回归模型能够较好地拟合 BPN 实测值。左图所示模型的 MAE、RMSE 和 R^2 分别为 3.230、4.483 和 0.830，右图所示模型则分别为 2.962、3.901 和 0.872。与左图相比，右图模型的 MAE 和 RMSE 均有所降低，R^2 进一步提高，说明其预测误差更小、拟合效果更好。综合来看，尽管感知损失的引入会使部分像素级重建指标略有下降，加入感知损失后，基于 VAE 潜在特征的模型取得了更好的 BPN 预测结果。

3.4 与不同特征提取网络的比较

为比较不同纹理特征提取方式对BPN预测的影响，本文选取 ResNet34 和 ViT[24]作为对比模型。对比试验采用相同的数据集划分、数据预处理方式以及训练和测试流程，仅替换用于 BPN 预测的特征提取网络。不同模型在测试集上的预测结果见表 4。

表 4 不同特征提取网络的抗滑性能预测结果

Table 4　Skid Resistance Prediction Performance of Different Feature Extraction Networks

方法	MAE ↓	RMSE ↓	R^2 ↑
ResNet34	3.230	4.444	0.833
ViT	4.369	6.313	0.663
VAE-Per	2.962	3.901	0.872

由表 4 可知，与 ResNet34 和 ViT 相比，所提出模型取得了更低的 MAE 和 RMSE，以及更高的 R^2，基于 VAE 潜在特征构建的回归模型表现出更高的预测精度和更好的拟合能力。其中，ViT 的整体预测效果相对较差，这可能与本文数据集规模有限有关。ViT 通常对训练样本规模和训练设置较为敏感，在样本数量不足的情况下，难以充分学习路面纹理特征与 BPN 之间的复杂映射关系，从而限制了其预测性能[25]。

此外，ResNet34 和 ViT 均直接从原始三维高程图中提取特征，而本文方法首先通过纹理重建学习潜在表征，再利用编码器提取潜在特征进行 BPN 预测。不同的特征学习方式导致了预测性能上的差异。由表 4 可见，在本文数据集和试验设置下，基于 VAE 潜在特征的模型取得了更低的 MAE 和 RMSE 以及

更高的 R^2，表明该特征提取方式更适用于本文数据的 BPN 预测任务。

4 结论

本文利用 VAE 学习路面三维纹理的潜在表征，并在此基础上开展 BPN 预测，主要结论如下：

（1）采用经路面类型分类任务微调的 VGG 网络构建感知损失，可改善 VAE 对路面局部纹理结构的表征。加入感知损失后，模型的 PSNR 和 SSIM 由 40.93 dB、0.955 降至 40.01 dB、0.947，但感知损失由 0.386 降至 0.154，表明像素级误差虽略有增加，重建纹理在特征空间中与原始纹理更为接近。

（2）VAE 潜在特征可用于路面抗滑性能预测。测试集上，所构建模型的 MAE、RMSE 和 R^2分别为 2.962、3.901 和 0.872，预测精度优于 ResNet34 和 ViT。结果表明，VAE 提取的潜在纹理特征可用于 BPN 预测，并取得较好的预测效果。

（3）受 BPN 标注样本数量和路面类型分布的限制，模型在不同路面结构上的泛化能力仍需进一步验证。后续可扩大不同路面类型及抗滑水平的数据规模，并对潜在通道数、网络深度和 KL 散度权重等参数开展系统分析，以进一步明确潜在空间结构对纹理表征和 BPN 预测性能的影响。

参考文献

[1]Hall J W,Smith K L,Titus-Glover L,et al.Guide for pavement friction[R].NCHRP Web-Only Document 108. Washington,DC:Transportation Research Board,2009.

[2]Chen S,Liu X,Luo H,et al.A state-of-the-art review of asphalt pavement surface texture and its measurement techniques[J].Journal of Road Engineering,2022, 2(2):156-180.

[3]Jin C,Wu J,Ge D,et al.Three-dimensional modeling and morphological characterization of pavement texture using a self-developed laser scanning device[J].Measurement, 2025:119767.

[4]陈占权.沥青路面表面纹理的检测方法及其精准度分析[J].中外公路,2023,43(6):74-78.DOI:10.14048/j.issn.1671-2579.2023.06.012.
CHEN Zhanquan.Detection method and accuracy analysis of asphalt pavement surface texture[J].Journal of China & Foreign Highway, 2023,43(6):74-78.DOI:10.14048/j.issn.1671-2579.2023.06.012.

[5]战友,邓强胜,罗志伟,等.基于 GBDT 的沥青路面抗滑性能感知模型研究[J].土木工程学报,2023,56(2):121-132.DOI:10.15951/j.tmgcxb.21111144.
ZHAN You,DENG Qiangsheng,LUO Zhiwei,et al.Research on GBDT-based skid resistance perception model for asphalt pavement[J].China Civil Engineering Journal,2023,56(2):121-132. DOI:10.15951/j.tmgcxb.21111144.

[6]Zhan Y,Liu C,Deng Q,et al.Integrated FFT and XGBoost framework to predict pavement skid resistance using automatic 3D texture measurement[J]. Measurement,2022,188:110638.

[7]彭毅,李强,战友,等.基于区域三维纹理特征的路面抗滑性能评估[J].东南大学学报（自然科学版）,2020,50(4):667-676.
PENG Yi,LI Qiang,ZHAN You,et al. Pavement skid resistance evaluation based on 3D areal texture characterization[J]. Journal of Southeast University (Natural Science Edition),2020,50(4):667-676.

[8]裴非飞,聂梓龙,许国敏,等.Friction-1D Transformer：用于沥青路面抗滑预测的一维 VIT 混合模型[J].中外公路,2024,44(6):51-58.DOI:10.14048/j.issn.1671-2579.2024.06.005.
PEI Feifei,NIE Zilong,XU Guomin,et al.Friction-1D Transformer: A 1D Vision Transformer Hybrid Model for Skid Resistance Prediction on Asphalt Pavements[J].Journal of China & Foreign Highway,2024,44(6):51-58. DOI: 10.14048/j.issn.1671-2579.2024.06.005.

[9]Zhan Y,Nie Z,Lin X,et al.Hybrid prediction model for the friction performance of asphalt pavements by combining multi-scale decomposition and transformer network[J].Engineering Applications of Artificial Intelligence,2025,155:110896.

[10]Hinton G E,Salakhutdinov R R.Reducing the dimensionality of data with neural networks[J].Science,2006,313(5786):504-507.DOI:10.1126/science.1127647.

[11]Kingma D P,Welling M.Auto-Encoding Variational Bayes[C]//International Conference on Learning Representations.2014.

[12]Berthelot D,Raffel C,Roy A,Goodfellow I.Understanding and Improving Interpolation in Autoencoders via an Adversarial Regularizer[C]//International Conference on Learning Representations.2019.

[13]Solera-Rico A,Sanmiguel Vila C,Gómez-López M,et al.β-Variational autoencoders and transformers for reduced-order modelling of fluid flows[J].Nature Communications,2024,15:1361.DOI:10.1038/s41467-024-45578-4.

[14]Hou B,Wu J,Qiu D Y.Unsupervised representation learning of Kohn–Sham states and consequences for downstream predictions of many-body effects[J].Nature Communications,2024,15:9481.DOI:10.1038/s41467-024-53748-7.

[15]Rombach R,Blattmann A,Lorenz D,Esser P,et

al.High-resolution image synthesis with latent diffusion models[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.New Orleans:IEEE,2022:10674-10685.

[16]He K,Zhang X,Ren S,et al.Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition.2016:770-778.

[17]Wang G,Wang K C P,Yang G.Reconstruction of sub-mm 3D pavement images using recursive generative adversarial network for faster texture measurement[J].Computer-Aided Civil and Infrastructure Engineering,2023,38(16):2206-2224.

[18]Simonyan K,Zisserman A.Very deep convolutional networks for large-scale image recognition[C]//Proceedings of the 3rd International Conference on Learning Representations.San Diego:ICLR,2015.

[19]Deng J,DongW,Socher R,et al.ImageNet: a large-scale hierarchical image database[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.Miami: IEEE,2009:248-255.

[20]Johnson J,Alahi A,Fei-Fei L.Perceptual losses for real-time style transfer and super-resolution[C]//Proceedings of the European Conference on Computer Vision.Cham: Springer, 2016:694-711.

[21]Kingma D P,Ba J.Adam: A method for stochastic optimization[C]//International Conference on Learning Representations.2015.

[22]Huynh-Thu Q,Ghanbari M.Scope of validity of PSNR in image/video quality assessment[J].Electronics Letters,2008,44(13):800-801.

[23]Wang Z,Bovik A C,Sheikh H R,et al. Image quality assessment: from error visibility to structural similarity[J].IEEE Transactions on Image Processing,2004,13(4):600-612.

[24]Dosovitskiy A,Beyer L,Kolesnikov A,et al.An image is worth 16×16 words: Transformers for image recognition at scale[C]//International Conference on Learning Representations.2021.

[25]Touvron H,Cord M,Douze M,et al. Training data-efficient image transformers & distillation through attention[C]//International Conference on Machine Learning.PMLR,2021:10347-10357.