引文格式:孙彦杰,赖志诚,周传龙,等.从绘画到地图的笔触风格迁移方法[J].武汉大学学报(信息科学版),2026,51(3):463-474.DOI:10.13203/j.whugis20250209

Citation: SUN Yanjie, LAI Zhicheng, ZHOU Chuanlong, et al. A Brushstroke Style Transfer Method from Painting to Map[J]. Geomatics and Information Science of Wuhan University, 2026, 51(3):463-474.DOI:10.13203/j.whugis20250209

从绘画到地图的笔触风格迁移方法

孙彦杰[1,2] 赖志诚[1,3] 周传龙[2] 吴明光[1,3,4]

1 南京师范大学地理科学学院,江苏 南京,210023

2 中国电子科技集团公司第二十八研究所,江苏 南京,210023

3 南京师范大学虚拟地理环境教育部重点实验室,江苏 南京,210023

4 江苏省地理信息资源开发与利用协同创新中心,江苏 南京,210023

摘 要:地图风格迁移是指将颜色、纹理、笔触等视觉元素从绘画等作品转移到地图上的过程,好的风格迁移能够提升个性、创意地图制作的效率和质量。在绘画中,笔触包含了线条的粗细、纹理及笔画的方向等丰富的线状图形信息,是绘画风格的关键特征,也是艺术家表达情感的重要视觉元素。从绘画到地图的笔触风格迁移,有利于提升地图的视觉表现力,加强地图的形式美与情感表达效果,在城市印象地图、旅游地图等类型的泛地图制作方面有着迫切的技术需求。当前的地图风格迁移主要集中在颜色、纹理等方面,缺少针对笔触的地图风格迁移研究,通用的绘画笔触风格迁移方法通常忽略了地图空间关系保持与笔触风格表达之间的平衡,容易导致损失地图的信息负载及传输功能。为解决这一问题,基于扩散模型提出一种模拟绘画过程的从绘画到地图的笔触风格迁移方法。该方法借鉴人类绘画从结构框架到笔触填充的过程,并结合地图符号的绘制策略,区分符号几何维度和图形-背景关系。通过将笔触风格迁移视为扩散模型下的渐进式笔触匹配过程,能够在保留地图空间关系准确性的基础上实现笔触风格的自适应迁移。实验在多个指标上进行了评估,包括结构相似性、内容保真度、风格相似性与符号清晰性,结果显示,所提方法在多个方面均表现出较优的迁移效果($p < 0.05$),有望丰富地图风格迁移的方法体系,为个性创意制图提供新的技术途径。

关键词:地图风格;地图风格迁移;人工智能;笔触;地图设计;泛地图

中图分类号:P208 **文献标识码**:A **收稿日期**:2025-07-15

DOI:10.13203/j.whugis20250209 **文章编号**:1671-8860(2026)03-0463-12

A Brushstroke Style Transfer Method from Painting to Map

SUN Yanjie[1,2] *LAI Zhicheng*[1,3] *ZHOU Chuanlong*[2] *WU Mingguang*[1,3,4]

1 College of Geographic Sciences, Nanjing Normal University, Nanjing 210023, China

2 The 28th Research Institute of China Electronics Technology Group Corporation, Nanjing 210023, China

3 Key Laboratory of Virtual Geographic Environment of Ministry of Education, Nanjing Normal University, Nanjing 210023, China

4 Jiangsu Center for Collaborative Innovation in Geographical Information Resource Development and Application, Nanjing 210023, China

Abstract: **Objectives**: Map style transfer involves the integration of visual elements such as color, texture, and brushstrokes from artistic works into cartographic design. Among these, brushstrokes convey essential stylistic features and emotional tones through attributes like line thickness, directionality, and texture. Incorporating brushstroke styles into maps enhances their expressive capacity and aesthetic appeal, especially in personalized and thematic cartography such as urban impression maps and cultural or tourist maps. Existing research has largely focused on color and texture transfer, with limited attention to brushstroke-specific migration in a cartographic context. **Methods**: To address the lack of brushstroke-focused transfer methods to maps, a diffusion model-based approach is proposed that simulates the human painting process. First, control points are identified for various map elements: for point features, the coordinates are directly used; for line features, all vertices forming the line are selected; for polygonal and background features, contour char-

基金项目:国家自然科学基金面上项目(42371443)。

第一作者:孙彦杰,博士,工程师,研究方向为地图风格迁移、地图设计等。yanjiesun@njnu.edu.cn

通信作者:吴明光,博士,教授。wmg@njnu.edu.cn

acteristics are extracted using a self-attention mechanism and transformed into contour control points. These control points from point, line, area, and background elements are then unified to form a complete map framework control point set. Next, Bézier curves are generated from these control points and used as initial strokes for iterative optimization of the map framework. During optimization, a differentiable rasterizer converts Bézier curves into differentiable raster images, enabling the generation process to be integrated into deep learning models for further refinement. The optimization model takes the Bézier control points and opacity as inputs, using alpha blending to simulate stroke intensity and overlap effects, and applies an extended score distillation sampling to minimize differences between the rasterized image and the input map. Parameters are iteratively updated until convergence to produce an accurate brushstroke-based map framework. Building on this, inspired by the What-Where dual-channel mechanism of human vision, specific loss functions are designed for different stroke types to jointly constrain the diffusion model's optimization in terms of spatial relationship and stylistic features. The Where channel ensures spatial consistency between the generated and input maps, while the What channel evaluates stylistic similarity between the generated map and the reference painting. Finally, the diffusion model progressively matches and stylizes the map brushstrokes, achieving adaptive brushstroke transfer while preserving figure-ground relationships and symbol geometric precision. **Results:** The proposed method was evaluated against representative brushstroke transfer techniques through both quantitative and qualitative analyses across four key metrics: structural similarity, content fidelity, style consistency, and symbol clarity. For structural similarity, the structural similarity index measure (SSIM) was employed to quantitatively assess the generated maps, where the proposed method achieved an average SSIM score of 0.876 across two test maps, substantially higher than the comparison method's 0.333, indicating superior preservation of the spatial structure of map content. Regarding content fidelity, the content fidelity (CF) metric was used to evaluate the consistency of cartographic information before and after style transfer, with the proposed method achieving an average CF score of 0.911 compared to 0.551 for the comparison method, demonstrating higher precision in content restoration and information retention. To further examine perceptual differences in style transfer performance, a user study was conducted employing a 7-point Likert scale to evaluate style consistency and symbol clarity. In terms of style consistency, maps generated by the proposed method consistently received higher ratings than those of the comparison method, with mean improvements exceeding 1 point and all differences reaching statistical significance ($p < 0.05$). In terms of symbol clarity, the proposed method outperformed the comparison method across all test cases, achieving average improvements of over 3 points, with all results statistically significant. Overall, experimental results indicate that the proposed method outperforms the representative brushstroke transfer method across all four evaluation metrics, with statistically significant improvements ($p < 0.05$), particularly in maintaining the legibility and semantic accuracy of map elements under stylization. **Conclusions:** The proposed method employs diffusion-based modeling to guide the progressive transfer of brushstroke styles from paintings to maps, balancing the preservation of spatial relationship and symbol semantics. This approach also provides a feasible solution for integrating brushstroke styles into maps, facilitating further exploration of the coordination of style and structure in cartographic design. Nevertheless, the method still has room for improvement regarding map information load, transmission efficiency, and brushstroke adaptability. Future research should further examine the impact of artistic style on map readability and information communication, and investigate the adaptability and transferability of reference artworks, to achieve an optimal balance between artistic expression and cartographic functionality.

Key words: map style; map style transfer; artificial intelligence; brushstroke; map design; pan-maps

风格迁移起源于图像处理领域,是指将一幅图像的视觉感受迁移到另一幅图像上[1]。风格迁移已经在艺术创作、电影特效、数字媒体等领域取得了广泛应用。在地图学领域,将绘画的风格迁移到地图上,可以提高地图风格设计的效率和质量,有助于实现地图制图由专家主导的“授人

以鱼”发展到面向大众的“授人以渔”[2-5],在城市印象地图、旅游地图、文化地图等类型的泛地图制作方面有着迫切的技术需求[6-9]。

当前的地图风格迁移主要集中在颜色、纹理等方面,针对笔触的地图风格迁移研究相对匮乏。在色彩迁移方面,已有研究从艺术绘画中分离出配色方案,并将其应用到矢量地图上,以实现更具表现力的地图效果[10]。纹理迁移则通过神经网络等算法,实现从风格图像到内容图像的纹理迁移,增强地图的视觉细节和真实感[11-12]。除了颜色和纹理,笔触包含了线条的粗细、纹理及笔画的方向等丰富的线状图形信息,是绘画风格的关键特征,也是艺术家表达情感的重要视觉元素。虽然有些学者开始尝试用通用的笔触风格迁移方法实施地图风格迁移,但是尚缺少地图相关的笔触风格迁移研究。HERTZMANN[13]于 1998 年提出了一种基于非真实感渲染的算法,通过迭代绘制不同大小的曲线画笔描边从而达到模拟油画效果。该研究首次引入了笔触形状、大小和方向的动态调整机制,允许通过改变画笔属性(如圆形笔触或曲线笔触)生成不同艺术风格(如点描派、印象派),为之后的笔触风格迁移奠定了基础。随着深度学习技术的发展,后续笔触风格迁移研究大多数都是基于深度学习技术来展开。YAO等[14]提出了一种基于注意力感知的多笔触风格迁移方法,通过多笔触融合策略,在保留内容结构的同时,将不同尺度的风格笔触自适应地融合到图像的不同区域,生成视觉协调且细节丰富的风格化结果,解决了传统风格迁移中视觉焦点冲突与笔触单一的问题。LIU 等[15]将笔触风格迁移过程建模为笔触生成和放置问题,其中如何学习笔触风格分布和按照语义感知将笔触放置在正确位置上是该问题的关键之处。这一思路突破了当下大部分神经网络基于纹理块进行风格迁移的限制,转而采用笔触精准放置的迁移策略,使整个风格迁移过程更贴近真实绘画的创作方式。当前笔触风格迁移的一个主要问题是空间关系保持准确度不高,难以精确地维持原有的结构信息。

地图笔触风格迁移不仅要在地图上精细地再现绘画上的触视觉特征,还需要考虑地图的空间关系和语义一致性。当尝试将绘画的笔触风格应用到地图时,可能会出现变形、夸张和偏移等问题,这些风格特征和地图内容的空间关系保持之间可能存在一定的冲突[16-17]。例如,尽管水彩画的笔触相对细腻,但仍然可能会削弱地图信息负载和传输功能,遗漏部分地理实体,破坏了地图内容的完整性,如图 1 所示。对于地图而言,地图上的地理要素需要准确描绘,如道路、河流和地标的位置和形状,所以空间关系保持尤为重要。因此,需要在风格的相似程度和空间关系的保持度之间找到平衡,以确保风格迁移的结果既具备艺术性,又不丢失地图的信息负载和传输功能。然而现有的绘画笔触风格迁移方法[15,18]未区分地图符号在几何维度和图形-背景的差异,也忽略了地图符号的绘制策略,缺少地图内容的空间关系保持和风格的相似程度平衡的迁移方法,使得迁移结果更像绘画而不是地图[19]。



(a) 罗马谷歌地图(来源于 https://www.google.com/maps/)　(b) 罗马水彩地图(来源于 https://maps.stamen.com/)

图 1　笔触对地图空间关系的影响

Fig. 1　Impact of Brushstrokes on Map Spatial Relationship

为解决地图笔触风格迁移中地图空间关系保持与笔触风格表达之间的平衡问题,本文提出一种基于扩散模型从绘画到地图的笔触风格迁移方法,试图丰富地图风格迁移的方法体系,为个性、创意制图提供新的技术途径。

1　地图笔触风格迁移模型

地图笔触风格迁移模型框架如图 2 所示,该方法通过模仿人类绘画从结构框架到笔触填充的过程,结合地图符号的绘制策略,区分符号几何维度和图形-背景,将笔触风格迁移视作扩散模型框架下整体布局到细节描绘的渐进式过程。该方法在逐步引入绘画风格特征的同时,保持地图的空间关系和地理信息的准确性,从而实现艺术风格表达和空间关系保持之间的平衡性。

受颜料、媒介等因素的影响,绘画存在着很多不同的技巧,但许多艺术家往往在绘画过程中采用分层的策略,通常会先勾勒出框架构图,然后添加笔触来渲染细节[15,20]。本文结合绘画的分层策略进行地图笔触风格迁移的建模,将风格地图绘制过程归纳为两个主要步骤:地图结构框架的生成和风格笔触的匹配。

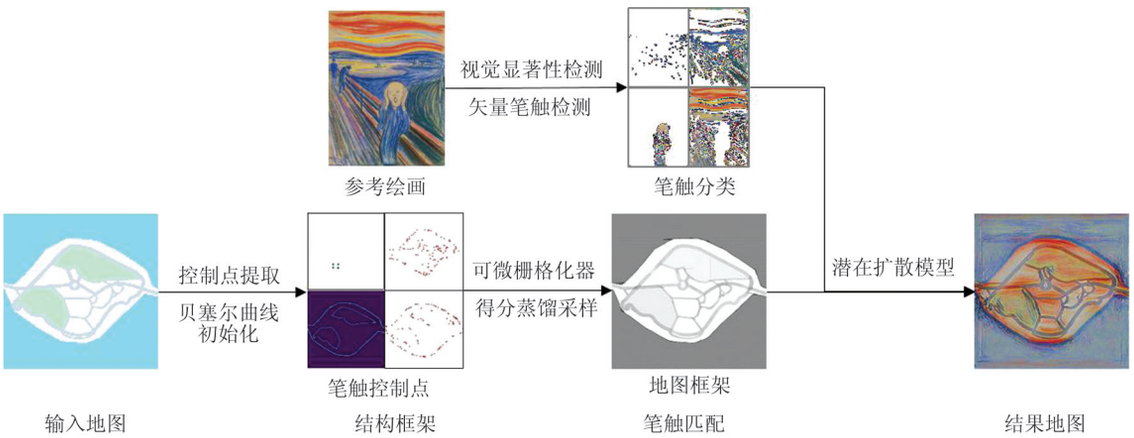


图2 地图笔触风格迁移模型框架

Fig. 2 Framework of Map Brushstroke Style Transfer Model

1.1 地图结构框架生成

结构框架的核心是确定作品的基本内容结构和对应比例。为此,本文先按几何类型与图形-背景关系对地图要素进行分类,进而展开初始笔触的构建。首先为每一类要素提取关键控制点,然后在各控制点处生成贝塞尔曲线作为初始笔触线条,最后通过迭代优化,将这些曲线转化为精准、清晰的地图线条框架。

1.1.1 框架笔触初始化

本文在依据参考绘画的内容简化的地图上进行地图框架笔触的初始化。初始化过程遵循先定位控制点,再生成框架线条的两步策略。

对于点要素,取其坐标作为控制点。对于线要素,以构成该线的全部节点为控制点。对于面要素和背景要素,本文利用自注意力机制捕获其轮廓,并转为轮廓控制点。文献[21]证明自注意力机制可以提取图像的空间布局和几何结构的关系。本文从U-NetModel的自注意力层提取注意力图,分别在前景面域与背景区域内部采样关键控制点,为满足图形-背景分离需求,前景与背景区域在注意力权重上被赋予不同数值,将上述点、线、面、背景4类控制点统一整合,得到完整的地图框架控制点集合P。总的地图框架控制点P表达如下:

$$P=\left\{p_{\text{point}},p_{\text{line}},p_{\text{polygon}},p_{\text{background}}\right\} \tag{1}$$

式中,p_{point}、p_{line}、p_{polygon}和$p_{\text{background}}$分别为点、线、面和背景要素的控制点。

然后,将每个控制点初始化为一条贝塞尔曲线,作为初始笔触。绘画笔触往往具有不规则且复杂的形状,而贝塞尔曲线是一种常用的向量表示方法,仅需极少的参数就能刻画出灵动而复杂的线形。这种特性与绘画笔触的不规则性高度契合,能够以较高的精度和效率描述其特征。同时,贝塞尔曲线的解析形式支持高效的数值优化与梯度回传,能够通过不断地优化控制点,有效地调整地图结构框架,使其能够随不同绘画风格自适应调整。

具体而言,本文采用四节点贝塞尔曲线来模拟初始笔触。每条贝塞尔曲线可表示为$s_i=\{p_i^j\}$,$j=1,2,3,4$,并附带一个透明度属性o_i。为满足贝塞尔曲线的条件参数,本文在控制点的邻域内进行节点采样。对于点要素,则其控制点和点符号尺寸得到一组节点,作为初始笔触,如图3(a)所示。具体采样规则如下:

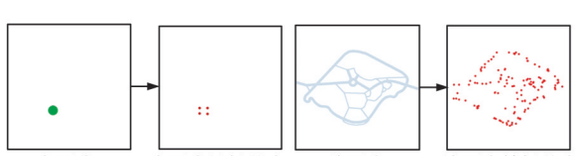
$$p_i^j=\left\{p_i\pm\frac{d}{2}\right\},j=1,2,3,4 \tag{2}$$

式中,p_i为点要素坐标;d为点要素的尺寸。

对于线要素,本文沿其走向自动补采其余3处节点,如图3(b)所示。采样规则如下:

$$p_i^j=\left\{p_i^1+\frac{j}{4}\cdot\boldsymbol{v}\right\},j=2,3,4 \tag{3}$$

式中,p_i^1为线要素上的控制点坐标;$\boldsymbol{v}$为线要素或者面轮廓的线条方向的单位向量。



(a) 点要素笔触节点采样 (b) 线要素笔触节点采样

图3 点、线要素笔触节点采样示意图

Fig. 3 Diagram of Point and Line Features Stroke Node Sampling

对于面和背景的内容控制点,为保证笔触平滑,剩余节点在控制点的二维高斯邻域内随机采样,由此构成完整的四节点贝塞尔曲线,如图4所示。采样规则如下:

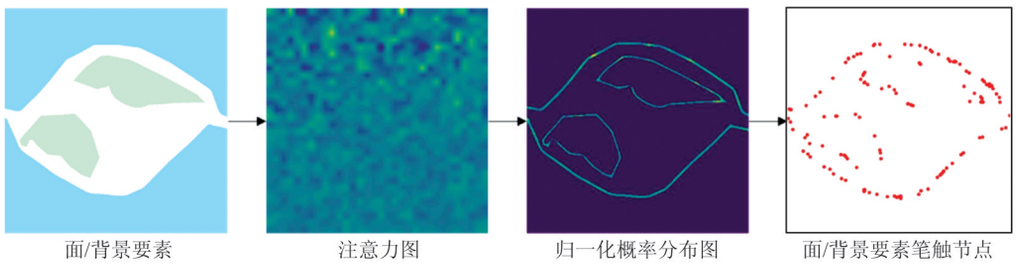


图 4　面/背景要素笔触节点采样示意图

Fig. 4　Diagram of Polygon/Background Features Stroke Node Sampling

$$p_i^j \sim N(p_i^{j-1}, \sigma^2), j = 2,3,4 \tag{4}$$

式中，N 为采样中心为 p_i^j、方差为 σ^2 的二维高斯分布；p_i^j 表示由控制点 p_i 在其邻域采样得到的第 j 个节点坐标。

获得初始的地图框架笔触后，本文进一步对其布局和精简度进行优化调整，使地图在契合参考绘画风格的同时，仍能保留核心的地图内容结构。

1.1.2　框架笔触优化

首先优化初始笔触的布局，使其符合输入地图的内容结构。随后，通过迭代方式不断调整各笔触的位置、形状与透明度，直至损失函数收敛。

为实现该优化过程，本文使用可微栅格化器进行布局笔触的优化。可微栅格化器能够将矢量图形（如贝塞尔曲线、矢量路径等）转换为栅格图像（即像素图像），同时在转换中保持矢量图形参数的可微[22]。这意味着在进行这种转换的过程中，可以计算图像相对于输入矢量参数的梯度，因此能够将图像生成过程嵌入到深度学习模型中，并通过反向传播算法进行优化。

具体而言，本文将每条贝塞尔曲线的控制点坐标与不透明度作为可学习参数。可微栅格化器首先将这些曲线投影到像素网格，并依据不透明度进行 alpha 混合，以模拟手绘笔触的浓淡变化，同时正确处理笔触间的重叠关系。

为进一步提升生成质量，本文引入扩展的得分蒸馏采样（score distillation sampling，SDS）进行笔触布局的优化。SDS 是一种生成模型训练的方法，它将扩散模型的生成过程表示为优化问题，通过最小化某种损失来调整生成样本的参数，引导生成模型向某个特定的目标分布收敛[23]。其对应的SDS损失公式如下：

$$L_{\mathrm{SDS}} = E_{t,\epsilon}\left[\left\| \hat{\epsilon}_\phi(x_t; y, t) - \epsilon \right\|^2\right] \tag{5}$$

式中，x_t 表示加噪后的可微栅格化图像；y 表示输入地图图像；t 表示随机采样的时间步；$\hat{\epsilon}_\phi(\cdot)$ 表示模型依据输入条件预测的噪声；ϵ 表示真实的噪声。

随后，计算生成图像与输入地图之间的感知损失，并将梯度反向传播至贝塞尔曲线的控制点与不透明度参数。其对应的感知损失公式如下：

$$L_{\mathrm{map}} = \sum_i \left\| \phi_i(I_{\mathrm{gen}}) - \phi_i(I_{\mathrm{map}}) \right\|^2 \tag{6}$$

式中，$\phi_i(\cdot)$ 是神经网络中的某一特征提取层；I_{gen} 和 I_{map} 分别表示生成的可微栅格化图像和输入地图。

综合以上 SDS 损失和感知损失可得到框架总损失，其对应的公式如下：

$$L_{\mathrm{frame}} = \lambda_{\mathrm{SDS}} \cdot L_{\mathrm{SDS}} + \lambda_{\mathrm{map}} \cdot L_{\mathrm{map}} \tag{7}$$

式中，λ_{SDS} 和 λ_{map} 分别是控制两种损失权重的超参数。

经过多轮迭代优化，在每一步中直接更新控制点位置及笔画的不透明度，直到框架总损失函数收敛，生成精确的地图布局框架笔触图，整体流程如图 5 所示。

1.2　风格笔触匹配

风格笔触匹配旨在对地图结构框架进行着色与笔触填充。首先区分绘画笔触类型与地图符号的几何类别及图形-背景关系，识别不同类型的绘画笔触，并建立地图要素与绘画笔触之间的语义对应。随后，利用扩散模型实现地图笔触的风格化匹配。

1.2.1　笔触类型识别

本文对绘画笔触类型以及地图符号的几何类别和图形-背景关系进行区分，并据此建立两者的语义对应。地图符号可依据几何类型与图形-背景关系划分为点、线、面及背景四类。在笔触提取方面，首先采用文献[10]的颜色分类方法，根据视觉显著性将绘画笔触分解为填充与背景。随后，为了完整获取绘画中的笔触信息，引用文献[24]提出的通用矢量笔触检测方法。该方法使用循环神经网络来模拟绘制过程，从而逐步生成笔触。在获得绘画中的显著笔触后，进一步进

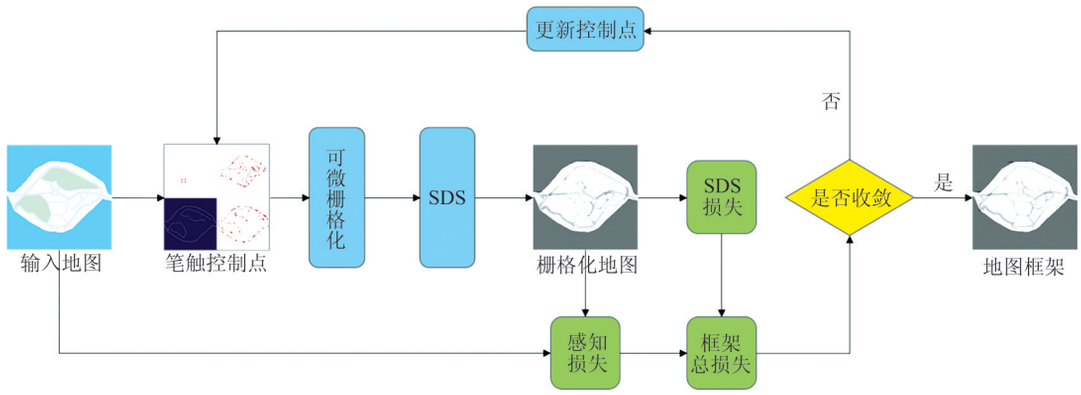


图5 框架笔触优化流程

Fig. 5 Framework Stroke Optimization Process

行形态分析,将尺寸较小且形状近似圆形的区域判定为斑点,将细长区域判定为线条。最终依据本文的分类方法,将笔触划分为斑点、线条、填充和背景4类,如图6所示。

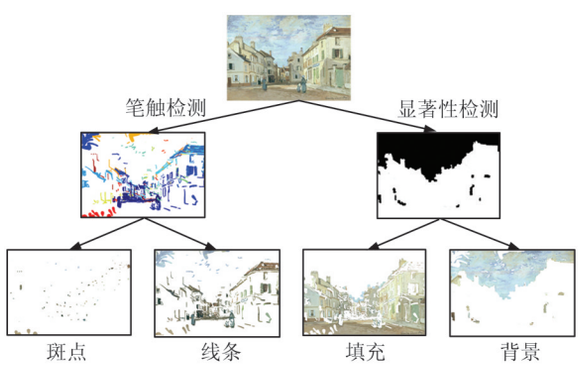


图6 绘画的四类笔触提取

Fig. 6 Four Types of Brushstroke Extraction for Paintings

1.2.2 噪声初始化

本文使用扩散模型进行地图风格笔触的匹配。扩散模型是一类基于概率生成的深度学习模型,近年来在图像合成、风格迁移等任务中表现突出。其核心思想是通过逐步向数据中添加噪声,将复杂的真实数据分布转化为易于建模的高斯分布(前向扩散过程),再通过学习逆过程逐步去除噪声,从而重建原始数据(反向生成过程)[25]。

本文对地图结构框架进行噪声初始化,首先将优化的地图结构框架表示为高维特征向量。假设输入的地图结构框架为F_{map},通过对比语言-图像预训练(contrastive language-image pretraining,CLIP)模型,将其编码为高维特征向量FV_{map}:

$$FV_{\text{map}}=\text{CLIP}(F_{\text{map}}) \tag{8}$$

式中,$FV_{\text{map}}\in\boldsymbol{R}^d$表示输入图像在高维空间中的特征表示;$d$是特征向量的维度。

然后,在高维特征FV_{map}上添加初始噪声,生成一个具有随机性的初始状态FV_{map}^0:

$$FV_{\text{map}}^0=FV_{\text{map}}+\epsilon_0 \tag{9}$$

式中,$\epsilon_0\sim N(0,\sigma^2)$表示高维空间中的高斯噪声,其中$\sigma$是噪声的标准差。

1.2.3 迭代去噪

利用扩散模型的迭代去噪过程实现风格化笔触的匹配。该去噪过程可以视为对特征表示FV_{map}^t的逐步更新直到收敛。设总的迭代次数为T,则在第t步,去噪后的特征表示FV_{map}^t可通过以下公式继续更新:

$$FV_{\text{map}}^{t+1}=FV_{\text{map}}^t-\eta\cdot\frac{\partial L_{\text{total}}}{\partial FV_{\text{map}}^t} \tag{10}$$

式中,η是模型迭代的学习率;L_{total}是综合损失函数。本文考虑两类损失:空间关系损失和风格相似损失。

在每一轮去噪过程中,更新后的特征FV_{map}^{t+1}应同时满足空间关系约束和风格相似约束。这意味着在迭代的每一步,模型会基于上述定义的损失函数对图像进行微调,使其逐步逼近既在空间布局上与输入地图保持一致,又在风格上与参考绘画相似的目标效果。采用该方法生成的最终图像不仅保持了输入地图的结构框架,而且在笔触类型对齐约束下,实现了参考绘画风格的有效迁移。

1.3 损失函数

在地图要素与绘画笔触匹配的基础上,本文进一步区分笔触类型,并针对不同类别设计相应的损失函数进行度量。文献[26]证明注意力机制符合视觉过程的What-Where分离机制。受此启发,本文借鉴人类视觉的What-Where通道分离原理,从两个独立的通道构建风格笔触匹配的损失函数,如图7所示。具体而言,从Where通道出发,设计用于保持生成结果地图与输入地图框

架空间关系一致的损失函数;从What通道出发,设计用于衡量生成结果地图与参考绘画在风格上的相似性的损失函数。

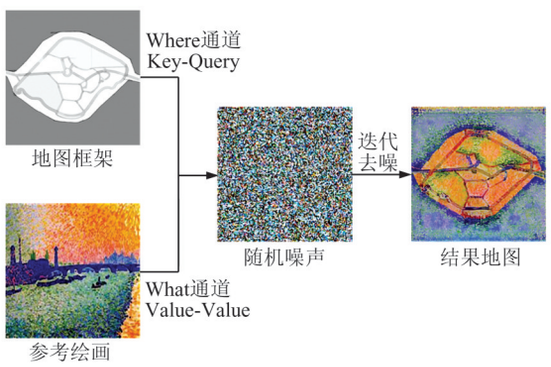


图7　地图笔触风格匹配

Fig. 7　Map Stroke Style Matching

1.3.1　空间关系损失

空间关系损失函数L_{Where}用于衡量去噪后的地图与输入地图在空间关系上的一致性。通过计算键-查询相似度构建空间关系矩阵$\boldsymbol{S}_{\text{Where}}$:

$$\boldsymbol{S}_{\text{Where}}=\boldsymbol{K}(FV_{\text{map}}^{t})\cdot\boldsymbol{Q}(FV_{\text{map}}^{t})^{\text{T}} \tag{11}$$

式中,$\boldsymbol{K}(FV_{\text{map}}^{t})$和$\boldsymbol{Q}(FV_{\text{map}}^{t})$分别是基于特征表示$FV_{\text{map}}^{t}$计算的键和查询矩阵。

空间关系损失定义为去噪后地图的空间关系矩阵与输入地图的空间关系矩阵之间的差异:

$$L_{\text{Where}}=\left\| \boldsymbol{S}_{\text{Where}}-\boldsymbol{S}_{\text{Where}}^{0}\right\|^{2} \tag{12}$$

1.3.2　风格相似损失

风格相似损失函数L_{What}用于衡量去噪后地图与参考绘画在风格上的一致性。通过计算数值-数值相似度构建风格相似矩阵$\boldsymbol{S}_{\text{What}}$:

$$\boldsymbol{S}_{\text{What}}=\boldsymbol{V}(FV_{\text{map}}^{t})\cdot\boldsymbol{V}(FV_{\text{image}})^{\text{T}} \tag{13}$$

式中,$\boldsymbol{V}(FV_{\text{map}}^{t})$和$\boldsymbol{V}(FV_{\text{image}})$分别是去噪后地图和参考绘画的高维特征向量。

风格相似损失定义为去噪后地图的风格相似矩阵与参考绘画的风格相似矩阵之间的差异:

$$L_{\text{What}}=\left\| \boldsymbol{S}_{\text{What}}^{0}-\boldsymbol{S}_{\text{image}}\right\|^{2} \tag{14}$$

1.3.3　空间关系和风格相似的平衡

扩散模型的生成过程可以划分为不同的阶段,每个阶段对应不同的细节层次,从整体的布局到精细的纹理[27],这种分层生成方式与视觉系统中的What-Where分离机制高度契合。本文在此基础上结合空间关系和风格相似两个指标,自适应地调整扩散过程中空间关系损失与风格相似损失的权重。结合L_{Where}和L_{What}得到综合损失函数L_{total}:

$$L_{\text{total}}=\lambda_{\text{Where}}\cdot L_{\text{Where}}+\lambda_{\text{What}}\cdot L_{\text{What}} \tag{15}$$

式中,λ_{Where}和λ_{What}分别是控制两种损失权重的超参数。

扩散过程的早期阶段(低频阶段)侧重于整体的空间信息,提高λ_{Where}强化Where通道的空间关系损失。扩散过程的后期阶段(高频阶段),通过增大λ_{What},完善细节和纹理特征来细化结果地图的笔触,如图8所示。

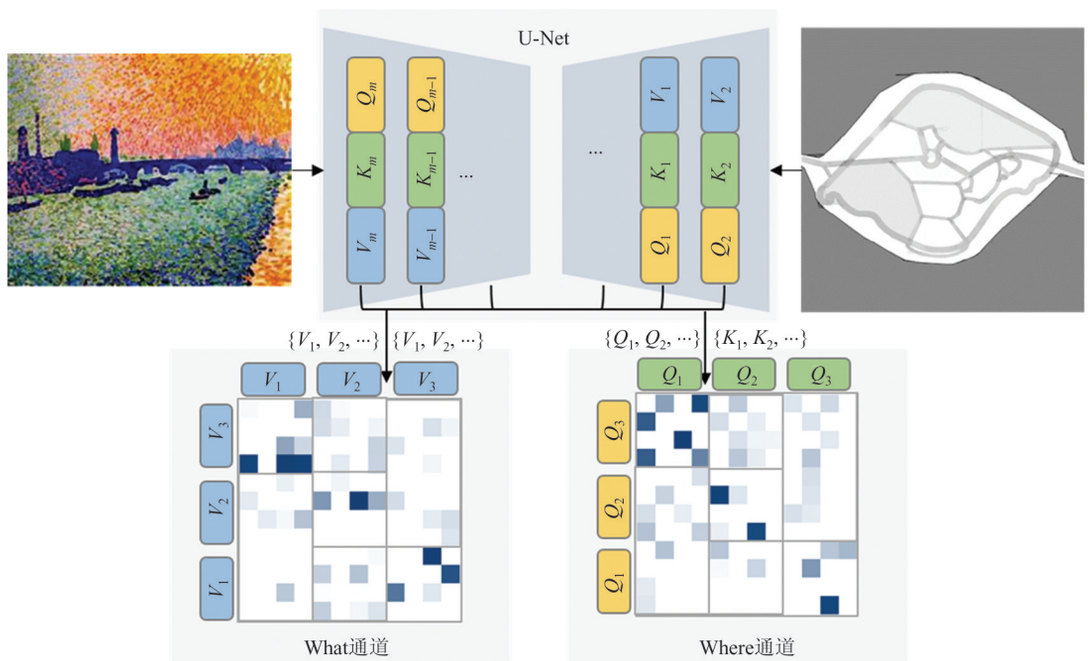


图8　What-Where分离的空间关系和风格相似性损失

Fig. 8　Loss of Spatial Relationship and Style Similarity for What-Where Separation

通过自适应调节L_{Where}与L_{What}的权重,模型在去噪过程中能够动态平衡对空间关系一致性与风格相似性的关注。随着图像特征的演变,损失权重随之调整,从而生成的图像既保留输入地图的空间布局,又充分体现参考绘画的风格特征。

1.4 模型训练和推理

本文的地图笔触风格迁移框架以原始潜在扩散模型为基础,采用Python实现。训练阶段以不同风格的参考绘画为输入,既支持单一图像的训练,也支持多图像混合训练;每幅参考画作的预训练迭代数固定为2 000次。为避免分辨率差异干扰迁移效果,所有地图与参考图像均统一至1 024×1 024像素。全部实验均在NVIDIA A100(80 GB)GPU上完成,单幅参考画的训练耗时约40 min。

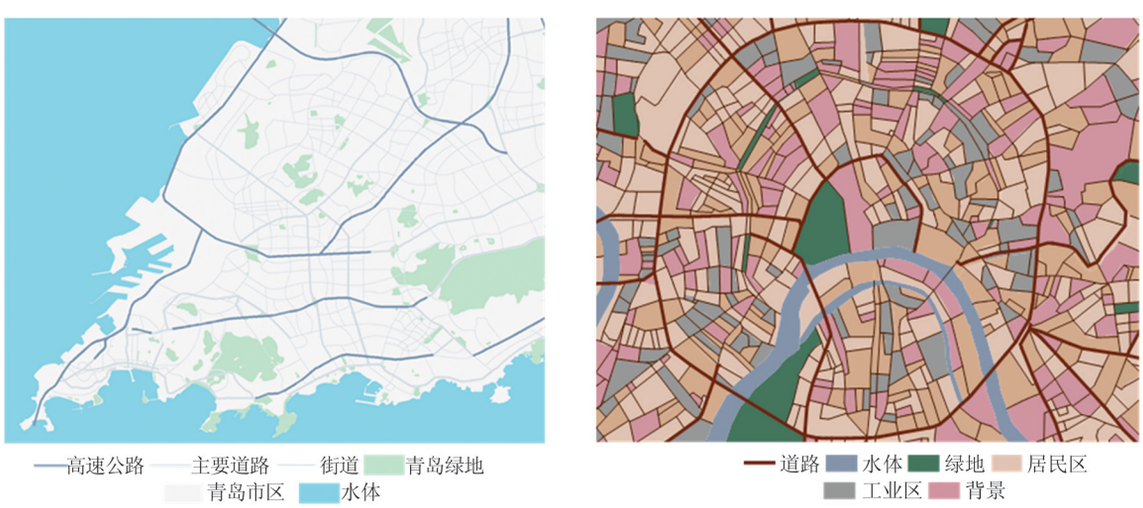
模型推理接收输入地图及其要素几何掩膜、参考绘画的预训练权重及对应几何掩膜。首先对输入地图进行随机噪声添加,然后从纯噪声出发,按阶段条件逐步去噪。模型早期重点关注Where通道,确保地图内容空间结构的一致性,后期则重点关注What通道,逐步改进笔触纹理细节。最终输出在空间布局和风格表达方面具有较高一致性的笔触风格迁移地图。

2 实验验证

围绕风格化地图设计中风格表达和空间关系维持平衡的要求,本节通过读图任务与问卷调查,系统评估本文提出的从绘画到地图笔触风格迁移方法。

2.1 实验数据

本文挑选了两幅具有代表性的城市地图作为实验数据,其中青岛道路网地图包含6种符号:3种不同等级的道路线符号、水体和绿地多边形符号以及背景,如图9(a)所示。莫斯科城市地图包含道路线、水体、绿地等多边形符号以及背景,如图9(b)所示。两幅测试地图均使用标准颜色方案,并辅以ColorBrewer推荐的色彩方案进行着色,以确保实验结果的可比性与视觉一致性。



(a) 青岛道路网地图 (b) 莫斯科城市地图

图9 示例地图

Fig. 9 Example Maps

本文同时也挑选了4位著名画家的经典作品作为笔触风格迁移的参考图像,其艺术风格与笔触方式各具鲜明特征,如图10所示。图10(a)是挪威表现主义画家爱德华·蒙克创作的绘画作品《呐喊》,画面以奔涌而交错的粗线与细线铺陈,厚度不同的线条描绘出火红的天空、深蓝的峡湾以及棕色的路;图10(b)是荷兰后印象派画家文森特·梵高创作的油画作品《星夜》,画家以弧形与螺旋形叠加的笔触勾勒出旋转涌动的星云与夜空,赋予画面强烈动感与蓬勃生命力;图10(c)是法国印象派画家克劳德·莫奈创作的《日出·印象》,其描绘法国勒阿弗尔港口晨雾笼罩的日出景象,以轻快跳跃的笔触捕捉光在海面反射、颤动的瞬间;图10(d)是比利时点彩派画家西奥·曼迪辛希尔的画作《港口风景》,全幅以细小而规整的色点铺陈,细密色点的叠加技法巧妙地捕捉了光影在水面与景物间的细腻变化。

2.2 实验设计

目前尚无专用于将任意绘画的笔触迁移到地图的方法,因此本文选择当前最具代表性的通用笔触风格迁移方法进行对比实验。文献[15]



(a) 表现主义　(b) 后印象派　(c) 印象派　(d) 点彩派

图 10　4幅不同风格的参考绘画

Fig. 10　Four Reference Paintings in Different Styles

中基于笔触学习的绘画风格迁移方法(对比方法)将最基本的绘制单元从像素转变为笔触,更贴近真实绘画的创作方式,故本文以其提出的风格迁移方法作为基线方法。实验中,将待迁移的测试地图与参考绘画统一缩放至1 024×1 024像素的高分辨率,输入上述两种方法,分别得到如图11和图12所示的两张地图4种不同风格的迁移结果。

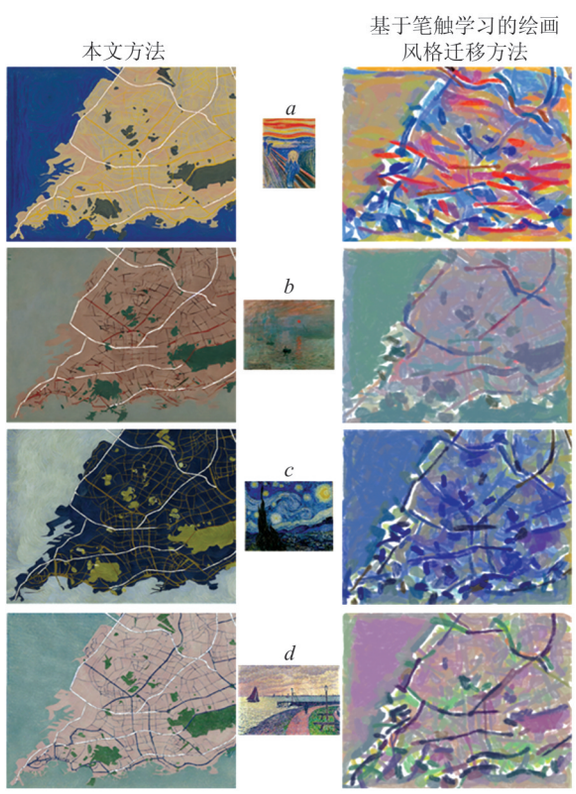


图 11　青岛地图笔触风格迁移结果对比

Fig. 11　Comparison of Brushstroke Style Transfer Results in Qingdao Map

首先评估本文方法和对比方法在地图空间关系保持的有效性。为此,引入两种广为采用的结构感知指标——结构相似性指数(structural similarity index measure,SSIM)与内容保真度(content fidelity,CF),对结果地图的空间关系保持程度进行量化比较。

SSIM是最常用的图像结构评价指标之一[28]。SSIM从亮度、对比度和结构3个不同因素

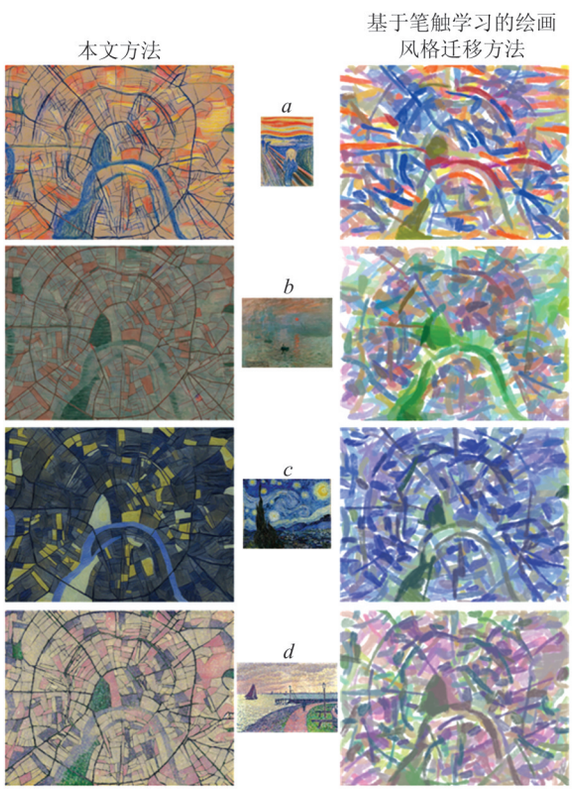


图 12　莫斯科地图笔触风格迁移结果对比

Fig. 12　Comparison of Brushstroke Style Transfer Results of Moscow Map

衡量两幅图像的结构差异,基于图像窗口的像素值进行计算[29],其计算公式如下:

$$\mathrm{SSIM}(x,y)=\frac{(2\mu_x\mu_y+C_1)(2\sigma_{xy}+C_2)(\sigma_{xy}+C_3)}{(\mu_x^2+\mu_y^2+C_1)(\sigma_x^2+\sigma_y^2+C_2)(\sigma_x+\sigma_y+C_3)} \tag{16}$$

式中,x和y是待比较的两幅图像;μ_x和μ_y分别是x和y的亮度均值;σ_{xy}是x和y的协方差(结构相关性);σ_x和σ_y分别是x和y的方差(对比度);C_1、C_2和C_3是常数。

CF则使用神经网络的隐含特征,它利用余弦相似度来衡量深度特征激活的差异,可以在多个尺度上衡量风格化结果对原始图像的保真

度[30],其计算公式如下:

$$\mathrm{CF}(x,y)=\frac{\phi(x)\cdot\phi(y)}{\|\phi(x)\|\cdot\|\phi(y)\|} \tag{17}$$

式中,x和y是待比较的两幅图像;$\phi(\cdot)$是神经网络中某一层的特征提取器。

为进一步比较两种方法在风格迁移中的主观接受度,本文还设计并实施了一份问卷来评估上述两种方法的风格迁移程度。考虑到参考绘画本身未必能代表大众审美,实验未让受试者直接评价结果地图的"美观"程度,而是聚焦于以下两项核心问题:(1)结果地图与对应参考绘画的风格相似程度是多少?(2)该笔触风格是否会影响地图符号的识别?采用7级Likert量表记录受试者的反馈(1表示完全不同意,7表示非常同意)。

本次实验共招募了40名色觉正常的学生,在安静、光线恒定、无干扰的实验室内完成评估。所有材料统一在1 920×1 080像素分辨率显示器上呈现,以避免设备差异带来的颜色失真。受试者依次观看同一参考绘画对应的两种方法结果(分别见图11和图12),全程不设时限,仅鼓励其尽量高效地完成打分。实验中不透露迁移方法信息,确保评估结果客观。

2.3 结果分析

2.3.1 空间关系保持

表1展示了本文方法与对比方法在输入地图和结果地图在SSIM和CF两个指标的对比结果。在SSIM指标方面,本文方法在两幅地图中的平均得分为0.876,而对比方法的平均得分则为0.333。在CF指标方面,本文方法的平均得分为0.911,而对比方法的平均得分则为0.551。结果显示,在8幅结果地图中,无论是SSIM指标还是CF指标,本文方法的内容保持程度都优于对比方法。这表明通过区分地图几何维度、图形-背景,本文方法更能维持迁移前后的内容信息和空间关系。

2.3.2 风格偏好

表2展示了本文方法和对比方法在风格相似性的对比结果。结果表明,本文方法在8幅结果地图的相似性都优于对比方法,其中6幅结果地图的相似性显著优于对比方法。在参考图像为*b*、*c*的图9(a)所示的青岛道路网地图中,其风格相似性均值分别提升了1.32和1.12,且在统计上存在显著差异。在图9(b)所示的莫斯科城市地图中,风格相似性均值提升范围在1.96~3.64之间,也存在显著差异。上述结果表明,借助迭代去噪策略,本文方法将参考绘画的风格更有效地迁移到了结果地图。

表1 空间关系保持对比

Table 1 Comparison of Spatial Relationship Preservation

地图	参考图像	SSIM		CF	
		本文方法	对比方法	本文方法	对比方法
图9(a)地图	*a*	0.902	0.305	0.941	0.637
	b	0.983	0.398	0.992	0.637
	c	0.921	0.163	0.948	0.649
	d	0.931	0.297	0.972	0.633
图9(b)地图	*a*	0.745	0.325	0.814	0.567
	b	0.947	0.495	0.926	0.641
	c	0.805	0.300	0.855	0.603
	d	0.776	0.379	0.838	0.593

表2 风格相似性的成对样本检验

Table 2 A Paired Sample Test of Style Similarity

地图	参考图像	成对差异(本文方法−对比方法)		*t*	df	*p*值
		均值	标准差			
图9(a)地图	*a*	0.28(4.80−4.52)	1.208	1.15	24	0.25
	b	1.32(4.92−3.60)	1.887	3.49	24	0.00*
	c	1.12(4.72−3.60)	2.108	2.65	24	0.01*
	d	0.08(4.68−4.60)	1.579	0.25	24	0.80
图9(b)地图	*a*	1.96(5.60−3.64)	1.989	4.92	24	0.00*
	b	2.92(5.72−2.80)	1.077	13.55	24	0.00*
	c	3.64(6.24−2.60)	0.700	26.00	24	0.00*
	d	2.64(5.92−3.28)	1.977	6.67	24	0.00*

注:*t*是*t*统计量;df(degree of freedom)为自由度;*表示差异显著性($p<0.05$)。

表3展示了本文方法和对比方法在符号清晰度上的对比结果。结果表明,本文方法在全部8幅测试地图中均显著优于对比方法,平均影响程度相差3分以上,且差异均达到统计显著性水平。该结果验证了通过模仿What-Where通道分离所提出的框架,能够在风格化表达与空间关系保持之间实现更优的平衡性。

3 结 语

鉴于不同绘画风格对空间关系的保留程度存在显著差异,本文提出了一种从绘画到地图的笔触风格迁移方法。该方法量化了不同绘画作品中风格表达对空间关系的影响程度,然后模拟绘画过程,通过渐进式的笔触渲染,逐步实现绘画风格与地图空间关系的协调,确保迁移结果兼具风格表现力与地图的可读性和实用性。与文

表 3　风格表达对符号清晰程度影响的成对样本检验

Table 3　A Pair Sample Test of the Effect of Style Expression on the Degree of Symbolic Clarity

地图	参考图像	成对差异（本文方法－对比方法）		t	df	p值
		均值	标准差			
图9(a)地图	*a*	−3.68(2.68−6.36)	1.145	−16.07	24	0.00*
	b	−4.00(1.84−5.84)	1.225	−16.33	24	0.00*
	c	−4.28(1.88−6.16)	1.339	−15.98	24	0.00*
	d	−3.48(2.20−5.68)	0.714	−24.36	24	0.00*
图9(b)地图	*a*	−3.32(3.60−6.92)	1.464	−11.33	24	0.00*
	b	−3.56(2.96−6.52)	1.758	−10.12	24	0.00*
	c	−4.08(2.64−6.72)	1.498	−13.62	24	0.00*
	d	−3.32(3.36−6.68)	1.520	−10.92	24	0.00*

注：t是t统计量；df为自由度；*表示差异显著性（$p < 0.05$）。

献[15]中基于笔触学习的绘画风格迁移方法相比，本文方法在地图空间关系保持、笔触风格相似性以及地图符号清晰度等方面均有显著提升，从而进一步提升了迁移结果的艺术性与科学性，能够为个性创意制图提供新的技术途径。

本文方法在地图信息负载及传输、笔触风格适宜性等方面仍然还有一些不足，需要在未来的研究中进行完善。首先，绘画风格通过视觉形式影响地图的空间关系和内容表达，从而深度影响地图信息负载及传输功能。在地图风格迁移中，也必须仔细考虑绘画风格的视觉影响，使其更精准地契合制图目标，实现地图信息与艺术性的融合。其次，需考虑参考绘画的适配性与可迁移性。并非所有画作都适合充当地图风格迁移的蓝本，即便艺术性再高的作品，也未必能产出高质量的地图。在地图风格迁移中，绘画的形式（例如色彩、线条、构图）必须首先满足地图的功能诉求，方能使美学表达与信息传达达成平衡。这需要考虑可读性、主题契合度、风格一致性等因素。

参　考　文　献

[1] GATYS L A, ECKER A S, BETHGE M. Image Style Transfer Using Convolutional Neural Networks [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016.

[2] 吴明光，孙彦杰，阎国年. 地图风格迁移：概念、综述与展望[J]. 武汉大学学报(信息科学版)，2022，47(12)：2069-2084.
WU Mingguang, SUN Yanjie, LÜ Guonian. Cartographic Style Transfer: Idea, Review and Envision [J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(12): 2069-2084.

[3] 任福，翁杰，王昭，等. 关于智能地图制图的几点思考[J]. 武汉大学学报(信息科学版)，2022，47(12)：2064-2068.
REN Fu, WENG Jie, WANG Zhao, et al. Some Thoughts on Smart Cartography[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(12): 2064-2068.

[4] 艾廷华. 深度学习赋能地图制图的若干思考[J]. 测绘学报，2021，50(9)：1170-1182.
AI Tinghua. Some Thoughts on Deep Learning Enabling Cartography[J]. *Acta Geodaetica et Cartographica Sinica*, 2021, 50(9): 1170-1182.

[5] 孙群，任福，龙毅，等. 中国地图制图学与地理信息工程进展报告(2019—2023)[J]. 测绘学报，2024，53(3)：399-412.
SUN Qun, REN Fu, LONG Yi, et al. The Progress and Trend of Cartography and Geographic Information Engineering in China (2019—2023)[J]. *Acta Geodaetica et Cartographica Sinica*, 2024, 53(3): 399-412.

[6] 郭仁忠，陈业滨，赵志刚，等. 泛地图学理论研究框架[J]. 测绘地理信息，2021，46(01)：9-15.
GUO Renzhong, CHEN Yebin, ZHAO Zhigang, et al. A Theoretical Framework for the Study of Pan-Maps[J]. *Journal of Geomatics*, 2021, 46(11): 9-15.

[7] 郭仁忠，陈业滨，赵志刚，等. ICT时代地图的科学概念及表达框架[J]. 武汉大学学报(信息科学版)，2022，47(12)：1978-1987.
GUO Renzhong, CHEN Yebin, ZHAO Zhigang, et al. Scientific Concept and Representation Framework of Maps in the ICT Era[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(12): 1978-1987.

[8] 郭仁忠，陈业滨，应申，等. 三元空间下的泛地图可视化维度[J]. 武汉大学学报(信息科学版)，2018，43(11)：1603-1610.
GUO Renzhong, CHEN Yebin, YING Shen, et al. Geographic Visualization of Pan-Map with the Context of Ternary Spaces[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(11): 1603-1610.

[9] 闫浩文，张黎明，杜萍，等. 自媒体时代的地图：微地图[J]. 测绘科学技术学报，2016，33(5)：520-523.
YAN Haowen, ZHANG Liming, DU Ping, et al. We-Map: A New Type of Map in the Era of We Media[J]. *Journal of Geomatics Science and Technology*, 2016, 33(5): 520-523.

[10] WU M G, SUN Y J, LI Y Q. Adaptive Transfer of Color from Images to Maps and Visualizations[J]. *Cartography and Geographic Information Science*, 2022, 49(4): 289-312.

[11] JENNY B, HEITZLER M, SINGH D, et al. Cartographic Relief Shading with Neural Networks[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2021, 27(2): 1225-1235.

[12] SUN Y J, WU M G. Flexible Style Transfer from Remote Sensing Images to Maps[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2025, 139: 104566.

[13] HERTZMANN A. Painterly Rendering with Curved Brush Strokes of Multiple Sizes[C]//The 25th Annual Conference on Computer Graphics and Interactive Techniques, New York, NY, USA, 1998.

[14] YAO Y, REN J Q, XIE X S, et al. Attention-Aware Multi-stroke Style Transfer[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 2020.

[15] LIU X C, WU Y C, HALL P. Painterly Style Transfer with Learned Brush Strokes[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2024, 30(9): 6309-6320.

[16] MACKANESS W A. An Algorithm for Conflict Identification and Feature Displacement in Automated Map Generalization[J]. *Cartography and Geographic Information Systems*, 1994, 21(4): 219-232.

[17] BOUTS Q W, DWYER T, DYKES J, et al. Visual Encoding of Dissimilarity Data via Topology-Preserving Map Deformation[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2016, 22(9): 2200-2213.

[18] JING Y C, LIU Y, YANG Y Z, et al. Stroke Controllable Fast Style Transfer with Adaptive Receptive Fields[M]//Computer Vision — ECCV 2018. Cham: Springer International Publishing, 2018: 244-260.

[19] KANG Y H, GAO S, ROTH R E. Transferring Multiscale Map Styles Using Generative Adversarial Networks[J]. *International Journal of Cartography*, 2019, 5(2/3): 115-141.

[20] HERTZMANN A. A Survey of Stroke-Based Rendering[J]. *IEEE Computer Graphics and Applications*, 2003, 23(4): 70-81.

[21] XING X M, WANG C, ZHOU H T, et al. DiffSketcher: Text Guided Vector Sketch Synthesis Through Latent Diffusion Models[C]// The 37th International Conference on Neural Information Processing Systems, New Orleans, Louisiana, USA, 2023.

[22] LI T M, LUKÁČ M, GHARBI M, et al. Differentiable Vector Graphics Rasterization for Editing and Learning[J]. *ACM Transactions on Graphics*, 2020, 39(6): 1-15.

[23] SAHARIA C, CHAN W, SAXENA S, et al. Photorealistic Text-to-Image Diffusion Models with Deep Language Understanding[C]// The 36th International Conference on Neural Information Processing Systems, New Orleans, Louisiana, USA, 2022.

[24] MO H R, SIMO-SERRA E, GAO C Y, et al. General Virtual Sketching Framework for Vector Line Art[J]. *ACM Transactions on Graphics*, 2021, 40(4): 1-14.

[25] DHARIWAL P, NICHOL A. Diffusion Models Beat GANs on Image Synthesis[C]//The 35th International Conference on Neural Information Processing Systems, New York, NY, United States, 2021.

[26] ZHANG X, YUNIS D, MAIRE M. Deciphering 'What' and 'Where' Visual Pathways from Spectral Clustering of Layer-Distributed Neural Representations[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Seattle, WA, USA, 2024.

[27] 阮国庆, 杨守威, 徐琳, 等. 基于提示的视觉语言基础模型综述[J]. 指挥信息系统与技术, 2024, 15(6): 12-20.
RUAN Guoqing, YANG Shouwei, XU Lin, et al. Review of Prompt-Based Vision Language Foundation Models[J]. *Command Information System and Technology*, 2024, 15(6): 12-20.

[28] IOANNOU E, MADDOCK S. Evaluation in Neural Style Transfer: A Review[J]. *Computer Graphics Forum*, 2024, 43(6): e15165.

[29] 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.

[30] WANG Z Z, ZHAO L, CHEN H B, et al. Evaluate and Improve the Quality of Neural Style Transfer[J]. *Computer Vision and Image Understanding*, 2021, 207: 103203.