第 52 卷 第 6 期：2816-2827 高电压技术 Vol.52, No.6: 2816-2827
2026 年 6 月 30 日 High Voltage Engineering June 30, 2026
DOI: 10.13336/j.1003-6520.hve.20251025

基于液体铺展模拟的变压器地面漏油图像数据集生成方法

王瀚彬[1]，刘亚东[2]，严英杰[2]，刘庆臻[2]，李嘉兵[3]，杨兴武[1]
（1. 上海电力大学电气工程学院，上海 200090；2. 上海交通大学电气工程学院，上海 200240；
3. 华北电力大学电子与通信工程系，保定 071003）

摘　要：变压器作为电力系统中的关键设备，其漏油问题逐渐成为设备运行中的重要隐患。针对目前变压器漏油检测训练数据量少、图像质量较低的问题，该文提出一种基于液体铺展模型和物理建模方法的地面变压器漏油图像数据集生成方法。该方法通过模拟变压器油在地面上的扩散、蒸发与吸收过程，结合网格划分与有限差分法对其进行数值求解，从而获得油渍在地面上的密度分布。在模拟油渍在地面的铺展过程中，引入各向异性的扩散系数并对地面材质空间特性的调制，提升了油渍形态模拟的可解释性与多样性，并结合 3 维虚拟环境中多场景、多视角的模拟，扩展数据覆盖范围，为检测模型提供了足量的数据。同时对合成数据集的图像相似性与变压器漏油目标检测进行实验。结果表明，采用该方法生成的数据在视觉和结构上与真实图像具有较高的相似性，并能够有效支持变压器漏油检测任务。

关键词：变压器漏油检测；智能巡检；液体铺展模拟；合成数据；3 维建模

Generation of Transformer Ground Oil Leakage Image Dataset Based on Liquid Spreading Simulation

WANG Hanbin[1], LIU Yadong[2], YAN Yingjie[2], LIU Qingzhen[2], LI Jiabing[3], YANG Xingwu[1]
(1. School of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;
2. School of Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;
3. Department of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: Transformer oil leakage has become an increasingly prominent fault in power systems, posing a significant risk to equipment reliability and operational safety. To address the current challenges of limited training data and low image quality in transformer oil leakage detection, this paper proposes a method for generating transformer oil leakage image datasets based on a liquid spreading model and physical modeling. The method simulates the diffusion, evaporation, and absorption of transformer oil on ground surfaces and numerically solves the process using grid partitioning and the finite difference method, thereby obtaining the density distribution of oil stains on the ground. In the process of simulating the spreading of oil stains on the ground, anisotropic diffusion coefficients and spatial modulation of surface material properties are introduced to enhance the interpretability and diversity of oil stain morphology. By integrating simulations of multi-scene and multi-view within 3D virtual environments, the method expands data coverage and provides sufficient training samples for detection models. Experiments are carried out on image similarity and transformer oil leakage detection based on synthetic datasets. The generated data have high visual and structural similarity with real images, and can effectively serve transformer oil leakage detection tasks.

Key words: transformer oil leak detection; intelligent inspection; liquid spreading simulation; synthetic data; 3D modeling

基金资助项目：上海交通大学-联想集团产学研合作研发项目(202211SJTU03-LR011)。
Project supported by Shanghai Jiao Tong University-Lenovo Group University-Enterprise Cooperation R&D Project(202211SJTU03-LR011).

0 引言

电力变压器是电力系统中的关键枢纽设备，其运维工作尤为重要。电力变压器漏油是变压器中最普遍的故障之一，地面油渍是变压器漏油故障最直接、最易观测的外在表现形式。及时发现并处理变压器漏油故障，能够降低其维修成本，延长使用寿命[1]。因此，为保证电力系统可靠稳定运行，变压器漏油检测具有重要的意义。

传统变压器巡检主要依靠人工目测来判断是否渗漏油，这种检查方式成本高、效率低，且依赖于人的经验和判断，准确性不稳定。使用机器代替人工巡检，已在电力巡检中得到越来越多的应用。目前有很多基于深度学习的方法对变压器漏油进行目标检测，但这种方法依然存在着检测精度不高的问题[2]。造成现有深度学习方法检测精度受限的一个关键因素在于模型训练依赖于大量高质量且多样化的标注数据。然而，由于保密性等原因，目前的变压器漏油等缺陷类图像数据集极为有限，且图像质量差，数据集分布分散。因此，针对变压器漏油图像数据稀缺的问题，需要构建高质量、多样化的数据集。

目前常用的数据生成方法有数据增强和数据合成。图像数据增强是在有限的数据中提炼出更多有用的信息，使用旋转、缩放、颜色扰动等方式进行扩充数据，不改变图像的基本内容。文献[3]指出，可以通过对单张图像自身进行变换生成新图像，或者从多幅图像中组合出新样本，但这种方式无法改变图像的内容，图像混合不自然。相较于图像增强，图像合成是将背景、物体、纹理等视觉要素重新组合与渲染，生成具有新的结构或者语义的图像。文献[4]提出一种基于 Perlin 噪声和形态建模的 2 维花卉图像合成方法，生成具有自然纹理变化和形态多样性的花卉图像。在 2 维空间内，利用生成对抗网络(generative adversarial network, GAN)等网络模型也可以在有限的数据范围内提升数据的多样性。文献[5]提出基于 GAN 网络的缺陷生成方法，在已有正常绝缘子图像基础上自动生成具有缺陷的图像样本，但生成的缺陷形态单一，可控性差。文献[6]提出了一种基于双维度注意力机制的集成生成对抗网络，在 2 维图像空间内生成太阳能电池缺陷图像，提升了模型在小样本条件下的识别能，但生成的图像局限于特定的视角，且算法较复杂，训练速度慢。

相较于在 2 维空间内的图像生成，在虚拟 3 维空间内合成数据可以灵活地调整视角、场景信息以及光照条件。在 3 维空间内合成数据已经是几年来计算机视觉、深度学习、机器人感知等领域的快速发展趋势，其生成数据已经在自动驾驶、医学影像等多个领域广泛应用[7-9]。文献[10]基于物理渲染在 3 维场景中生成了高动态范围驾驶场景的图像，为高动态范围(high dynamic range imaging，HDR)成像与感知算法的研究提供了真实可控的训练样本，但所构建场景仍以理想化模型为主，动态复杂性有限。文献[11]提出了一种基于 3 维建模和域随机化的绝缘子缺损数据集生成方法，通过程序化建模构建一个参数可调整的绝缘子伞盘模型和材质纹理模型，提升了数据的泛化能力，但绝缘子的缺陷模拟主要依赖于经验建模，缺乏物理机理支撑。

针对上述问题，本文提出了一种基于油渍铺展模拟的变压器漏油图像数据集生成方法。与现有的基于数据驱动或基于经验建模的图像合成方法不同，本文从液体物理扩散机理出发，构建了一个多物理过程的渍演化模型，系统考虑了扩散、蒸发与吸收等作用过程。同时在离散的网格上模拟油渍的铺展扩散行为，生成具有物理一致性的 2 维浓度矩阵以及油渍掩膜，随后将油渍掩膜融合进 3 维变压器场景中，通过程序化控制相机参数，实现图像渲染与采集，完成图像自动标注，最终程序化生成漏油数据集，并验证了生成数据集的有效性。

1 油渍铺展形态建模与模拟

在实际无人机或机器人巡检中，由于拍摄角度、距离和背景复杂多变，油渍的具体边缘形态、分布位置和纹理特征对目标识别模型具有重要的辅助判别价值。仅依赖油渍有无的粗略判断，容易受到水渍、阴影等干扰影响。若直接使用规则图形生成训练样本，可能导致模型忽视油渍的真实结构特征，降低其在复杂场景下的识别效果。因此，模拟真实油渍形态不仅有助于提升识别精度，也增强了模型对复杂场景下的鲁棒性。为了构建具有真实感和可辨识度的油渍铺展模型，有必要首先分析变压器漏油在实际场景中的视觉表现与特征，以此为物理建模与图像生成提供依据。

1.1 变压器漏油油渍的视觉特征

变压器在发生漏油后，油膜覆盖在物体表面，会使得原本干燥的表面呈现更暗的色调、更饱和的

颜色以及明显的光泽度，这主要是因为油膜引发了复杂的光线交互作用，如反射、折射和吸收，从而改变了其表面双向反射分布函数(bidirectional reflectance distribution function，BRDF)的表现[12]。通常，油渍呈现不规则扩散的形状，边缘模糊，且会随着时间逐渐向外扩散[13]。基于这些物理和几何属性，油渍在图像中表现出一些独特的、可被识别和学习的视觉模式，其颜色与周围干燥表面存在明显的对比差异，且其边缘往往不规则但具有连续性，呈扩散状分布。此外，在多数场景中，油渍通常集中出现在变压器下方地面区域。

目前，对于液体在粗糙表面的铺展已有很多研究，利用仿真计算能够精确地模拟油液的真实流动、扩散等过程[14-16]。文献[17]指出，从微观层面精确地描述流体的行为尽管精确，但代价非常高，为了在计算效率和物理真实性之间取得平衡，在图形学领域通常将液体看作连续分布的物理量场，在宏观尺度上进行描述。因此，本文对油渍扩散的物理机理进行简化建模，聚焦于油污表面视觉效果的仿真，以便能够在较短时间内生成高质量的图像效果，从而通过参数化控制实现对不同形态油渍的快速生成，提升数据集的多样性和丰富度。

1.2 模拟油渍扩散的关键物理机制

扩散、吸收和蒸发这 3 个过程广泛存在于液体与吸收性介质接触的场景中，决定了油渍的分布形态等关键的视觉特征[18]。下文将分别对这 3 个物理过程进行建模与简化处理。

1.2.1 变压器油在地面的扩散

变压器漏油后，油液从泄漏点向周围地面扩散，在地面的铺展过程本质上是由于局部高浓度区域的油向低浓度区域迁移的行为，这种迁移过程符合典型的扩散特征。

液体的铺展过程受到毛细作用、重力、地形等因素的影响形成一种沿表面扩散的行为，这个过程可通过 Fick 第二定律来描述：

$$\frac{\partial C}{\partial t}=\nabla(D\nabla C) \tag{1}$$

式中：∇C 为浓度梯度；D 为扩散系数，是描述物质扩散速率的重要物理参数。扩散系数受到多种因素影响，包括油液的物理性质、地面材质与粗糙度、温度、孔隙结构等。本文认为扩散过程各向异性，扩散系数会随地形或材料属性变化。

1.2.2 地面油渍的蒸发

根据 Hall 和 Hoff 的研究[18]，蒸发速率 e 可用式(2)描述：

$$e=-\frac{p_{\mathrm{w}0}D_{\mathrm{w}}\rho_{\mathrm{w}}M}{R\tau}\frac{\mathrm{d}H}{\mathrm{d}x} \tag{2}$$

式中：$p_{\mathrm{w}0}$ 为等温条件下自由水面的饱和水蒸气分压；H 表示相对湿度的分数值；ρ_{w} 为液体密度；M 为摩尔质量；D_{w} 代表液体在空气中的分子扩散系数；R 为气体常数；τ 表示温度。

尽管 Hall 和 Hoff 提出的式(2)可用于描述蒸发速率的理论计算，但变压器油属于低挥发性液体，在常温环境下其蒸发速率远低于水等液体。为简化蒸发过程，并反映油渍在表面逐渐减少的趋势，本文采用基于指数衰减的模型对油渍蒸发过程进行描述，如式(3)所示：

$$C_{\mathrm{eva}}=C_0\mathrm{e}^{-\lambda t} \tag{3}$$

式中：C_{eva} 为油渍随时间蒸发的浓度；C_0 表示扩散后油渍的初始浓度分布；λ 为蒸发速率系数。

1.2.3 地面对变压器油的吸收

鹅卵石、沙砾等地表材料具有显著的渗透性，其吸收行为在模拟液体扩散时不可忽略，在微观尺度上渗透呈空间异质性，难以直接建模，但在宏观尺度上可通过引入有效渗透率或基于表面粗糙度与缝隙分布的调制系数加以表征。为描述油液在此类多孔介质中的吸收过程，本文采用 Muskat 对 Darcy 定律进行改进表达，据此构建了近似模型[19]：

$$\Phi_{\mathrm{A}}=-\frac{C_{\mathrm{M}}A\Delta p}{\mu L} \tag{4}$$

式中：Φ_{A} 为吸收流量通量；C_{M} 为 Muskat 提出的渗透性修正系数；A 为渗流的横截面积；μ 为液体黏度；Δp 为介质两端的流体压力差；L 为流动路径长度。

由于本文所关心的是油渍外观铺展形态，而不是精确计算地表吸收流量，因此本文将基准的渗透率视为常数，定义一个局部调制系数来调整吸收流量的空间变化，局部坡度调制系数 $M(x,y)$可由式(5)表示：

$$M(x,y)=\alpha\left|\nabla h(x,y)\right| \tag{5}$$

式中：α 为调制强度，可以控制坡度对吸收影响的灵敏度。$h(x,y)$表示在地面(x,y)处的高度。局部坡度调制系数本质上相当于一个位置相关的吸收增益系数，反映了油液在地表地形作用下局部渗透特性的变化。又根据式(4)，可将油渍在单位面积上的吸收量简化写为：

$$C_{\text{abs}} = -\frac{1}{\mu} C \cdot \alpha \left| \nabla h(x,y) \right| \tag{6}$$

式中：C_{abs} 为单位时间内在单位面积上被吸收掉的油渍浓度；C 为此刻该位置处的油渍浓度。

1.3 油渍形态的数值模拟

本文使用掩膜遮罩图像来描述变压器油在地面形成油渍的形态。由于在实际场景中，地面上的油渍主要受重力作用形成沉积，在垂直方向的厚度远小于水平方向的扩展范围，因此可忽略高度变化，将油渍视为一种近似 2 维的分布结构。

根据式(1)，油膜的扩散通量与浓度梯度成正比，扩散方向指向油渍较稀薄的区域。为了得到油渍在地面上的铺展形态，本文先建立一个在 2 维表面上的油渍浓度场 $C(x,y,t)$，于是式(1)可以写为：

$$\frac{\partial C}{\partial t} = \frac{\partial}{\partial x}\left(D(x,y)\frac{\partial C}{\partial x} \right) + \frac{\partial}{\partial y}\left(D(x,y)\frac{\partial C}{\partial y} \right) \tag{7}$$

为简化求解偏微分方程，使用有限差分法将式(7)离散化为：

$$\frac{\partial C}{\partial t} \approx \frac{C^{t+\Delta t} - C^{t}}{\Delta t} \tag{8}$$

即：

$$\frac{C^{t+\Delta t} - C^{t}}{\Delta t} = \frac{D_{x+1}(C_{x+1,y} - C_{x,y}) - D_{x-1}(C_{x,y} - C_{x-1,y})}{(\Delta x)^2} + \frac{D_{y+1}(C_{x,y+1} - C_{x,y}) - D_{y-1}(C_{x,y} - C_{x,y-1})}{(\Delta y)^2} \tag{9}$$

式中：C^t 表示在第 t 时间上的浓度；Δt 为时间步长；$C_{x,y}$ 表示在点(x,y)处的浓度；D_{x+1} 表示点(x,y)与点$(x+1,y)$平均扩散系数；Δx、Δy 分别为在 x 方向和在 y 方向上的离散间距。

扩散系数描述的是物质从高浓度区域向低浓度区域扩散的速率，不仅取决于油液本身的物理性质，还受到地表粗糙度、坡度及温度等环境因素的影响。通常来说，高表面张力、低黏度、小接触角液体会更易铺展，而越粗糙的地面会使铺展速率变慢[20]。本文在传统的单一常数值基础上，引入一个考虑多种物理因素的扩散系数，其表达式为：

$$D(x,y) = D_0 \frac{\gamma \cos\theta}{\mu(1 + k \cdot r(x,y))} \tag{10}$$

式中：D_0 为本文设置的一个基础扩散系数；γ 为变压器油的表面张力；θ 为变压器油与地面之间的接触角；$r(x,y)$表示地面为粗糙度；k 为本文定义的一个粗糙度调整系数，可以用来控制地面粗糙度对于扩散的影响程度。

为模拟真实材料地面，本文提出将基于物理的渲染器(physically based rendering，PBR)材质纹理中的粗糙度贴图(roughness map)作为替代 2 维噪声图的输入信息，通过对提取的灰度图进行归一化处理，并映射至模型网格表面，再将其数值范围重新线性映射至[0.5,1.5]，以反映表面粗糙度的空间分布特性。同时使用法线图(normal map)得到地面的高度分布信息 $h(x,y)$。实际场景中，若地面存在坡度差异，油液将受到沿坡度方向的重力分量驱动而产生偏移扩展，其运动方向与地表高度梯度是一致的。

本文在引入各向异性扩散的基础上引入蒸发项、吸收项以及地形坡度引发的重力影响项，共同构建油渍浓度随时间演化的控制方程。油渍浓度场的演化可由式(11)表示：

$$\frac{\partial C}{\partial t} = \nabla(D\nabla C) - C_{\text{eva}} - C_{\text{abs}} - (g_x \frac{\partial C}{\partial x} + g_y \frac{\partial C}{\partial y}) \tag{11}$$

式中：第 1 项为扩散项，扩散系数 D 受到地面粗糙度的影响；C_{eva} 为蒸发项；C_{abs} 为吸收项；最后 1 项为因重力影响下的沿坡度方向的偏移扩散，g_x、g_y 表示重力投影系数。

本文提出了一种基于油渍铺展模拟的变压器漏油图像数据集生成方法，如图 1 所示。采用 2 维等间距的网格进行流体形态模拟[21]。定义每个网格大小与 1 个像素大小相同，代表实际地面横向区域，如图 2 所示。在网格上一定区域内随机投放多个油滴作为初始浓度源，每个油滴的大小和位置均由随机函数控制。

本文以 2 维扩散方程为基础，模拟油渍随时间在非理想表面上的扩散过程，相关过程参数设置如表 1 所示，对每组参数进行计算时进行一定扰动来高泛化性，模拟过程包括以下步骤。

1）粗糙度读取与网格映射：将地面材质图像处理为灰度图并归一化，作为地面粗糙度条件。

2）初始油滴注入：在中心区域随机注入多个油滴，构成初始浓度分布。

3）有限差分模拟扩散过程：对时间进行离散迭代，引入蒸发吸收项和倾角项，更新每个网格点的浓度，如图 3(a)。

4）过程可视化与结果输出：记录最终得到的浓度矩阵，得到所有单元格的浓度值。

由上述方法生成的灰度掩膜图如图 3(b)所示。

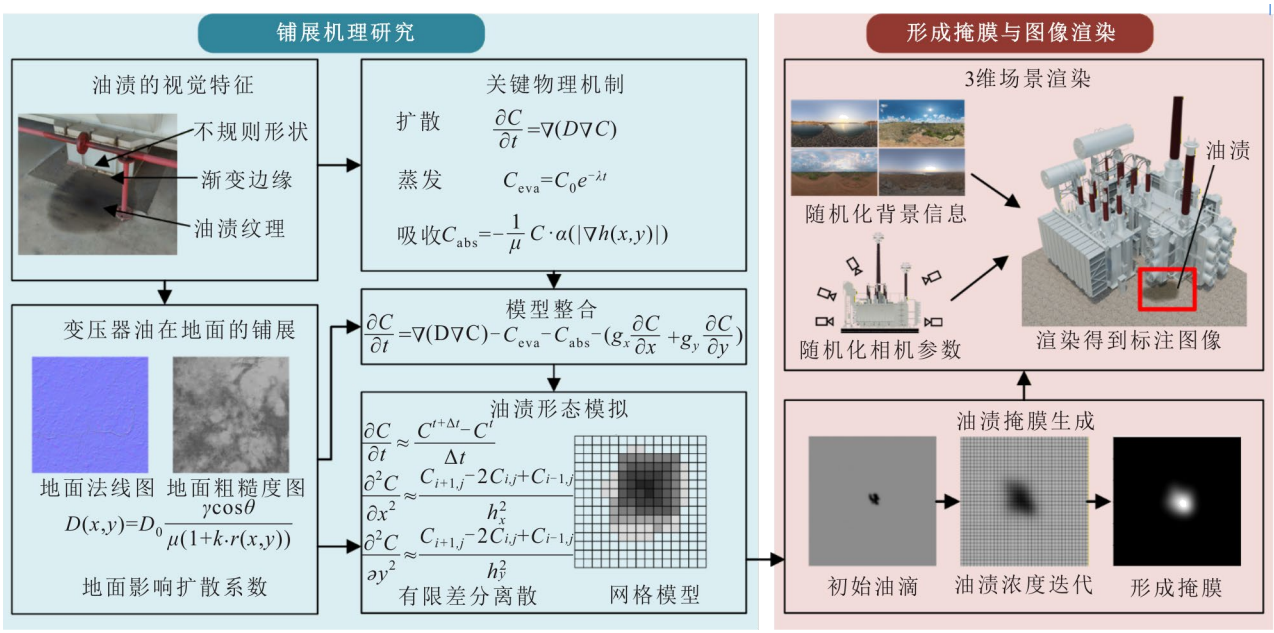


图 1 基于 2 维铺展模型的变压器漏油数据集生成框架

Fig.1 Framework for generating transformer oil leakage dataset based on two-dimensional spreading model

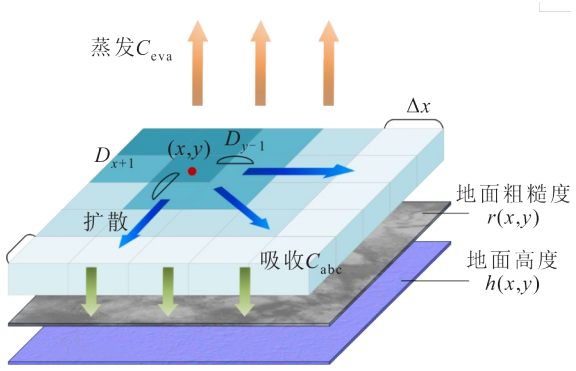
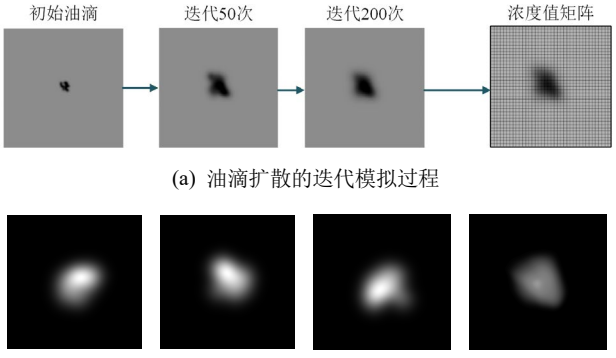


图 2 二维油渍扩散-蒸发-吸收过程网格化模型示意图

Fig.2 Diagram of grid model for two-dimensional oil stain diffusion evaporation absorption process



(a) 油滴扩散的迭代模拟过程

(b) 生成的掩膜示例

图 3 变压器油滴扩散模拟的迭代过程与生成的掩膜示例

Fig.3 Iteration process of transformer oil droplet diffusion simulation with generated mask examples

表 1 油渍掩膜生成模型的参数设置

Table 1 Parameters for oil stain mask generation model

参数名称	含义	单位	数值范围
T	环境温度	K	295~303
μ	液体黏度	mm²/s	5~15
r_0	初始油滴半径	m	10^{-3}~10^{-2}
λ	蒸发速率系数		10^{-4}
D_0	基础扩散系数	m²/s	0.2~0.3

2 变压器地面漏油数据集生成

本文提出的漏油数据集在 3 维虚拟场景的生成框架包括场景与背景的随机化生成、油渍纹理融合、图像的渲染与自动标注。

2.1 场景与模型的搭建

仿照真实某变电站的场景，在真实世界中扫描表面纹理，并在虚拟世界中搭建变电站的环境，同时改变变压器模型的型号并改变对于路面厂房等实现多样性的场景搭建。

本文使用的是环境光的高动态范围成像(high dynamic range imaging，HDRI)渲染，由 PolyHaven 下载得到高质量的 HDRI 数据，对于背景环境进行贴图映射与光照调整，以模拟真实世界中的光照环境[22-23]。采用基于 PBR 纹理的渲染方式，程序能够

根据物体材质属性自动计算光照、反射、折射等参数，使生成的图像数据符合真实场景中的光照传播模型，无需额外进行图像和谐处理。此外，HDRI光照贴图能够真实反映自然环境中的光照强弱、阴影方向与反射干扰等因素，通过参数调整可以模拟不同光照条件以及阴影情况下的世界环境，PBR渲染方式可以对不同材质(如油渍、水渍)反射特性进行模拟。最终生成不同背景以及光照阴影条件下的图象，如图4所示。



图4　随机化背景环境与光照阴影条件

Fig.4　Randomized background environments and lighting-shadow conditions

为了将前文所生成的掩膜图像准确叠加至3维场景中，本文对前文中生成的掩膜通过式(12)融合进表面纹理。

$$R(x,y)=(1-M(x,y))\cdot T(x,y)+M(x,y)\cdot O(x,y) \quad (12)$$

式中：$R(x,y)$表示融合后最终纹理图像；$M(x,y)$为带有权重的掩膜图像；$T(x,y)$、$O(x,y)$分别为地面的纹理和油渍的纹理。掩膜融合过程如图5所示。

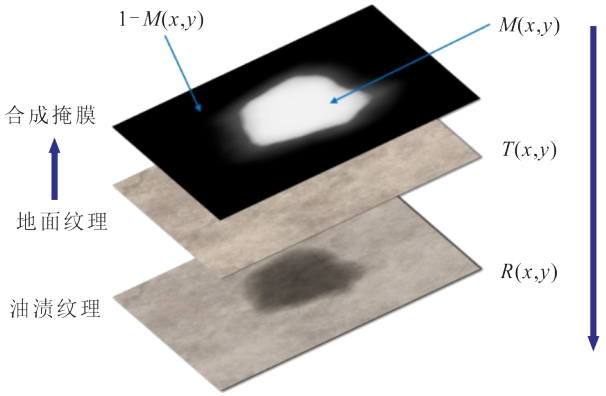


图5　油渍的掩膜融合

Fig.5　Mask fusion of oil stains

2.2　图像渲染与自动标注

考虑到不同巡检方式在实际电力巡检作业中的应用需求，本文以油渍为中心构建柱面随机拍摄模型，通过射线对准完成初步定位[11]，结合针孔成像关系，设定 0.3~0.6 的油渍占比来计算相机有效位置参数(相机角度 φ、距离油渍中心轴的距离 R、离地高度 H 等)并完成自动对准如图6所示。

为构建精确的标注数据，建立了一套的图像渲染与标注自动化流程。在该流程中，提取目标对象(即变压器及其漏油区域)，并对场景进行2次独立渲染。

第1次渲染输出正常的可见光图像，保留场景中所有元素的真实外观，包括变压器、地面、阴影和漏油区域等，生成的虚拟图像如图7所示。

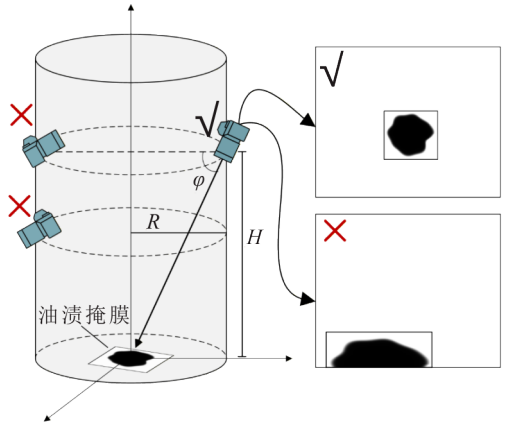


图6　相机的参数设置

Fig.6　Camera parameter setting

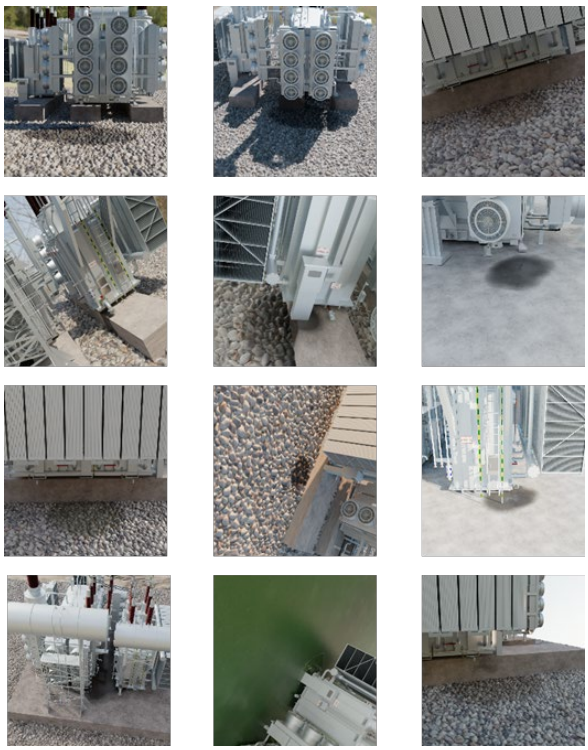


图7　虚拟样本样例

Fig.7　Virtual data samples

然后，保持相机的参数不变、拍摄的视角不变，进行第 2 次渲染，在这次的渲染中，仅保留漏油的油渍区域可见，将场景中其他物体包括背景在内的渲染属性设为不可见，从而仅保留油渍区域的信息。某些油渍部分可能在第 1 次渲染中由于物体遮挡的原因未被显示，因此在得到 2 次渲染图像后，本文对两次图像取并集运算，提取到油渍区域，并对每个区域计算其最小外接矩形，最终得到标注边界框。

3 验证

3.1 数据生成环境与参数设置

本文的图像生成基于 Blender 4.2 图形建模与渲染平台，使用的 Cycles 渲染器，图像渲染选用 RTX 4070 SUPER 显卡。图像自动生成与渲染程序基于 Blender Python API 编写，包括 3 种变压器模型，20 种不同的地面纹理材质模型。油渍掩膜浓度数据计算由 Python 程序计算得到，并由 Open CV 得到掩膜图像[24]。

为验证虚拟数据生成方法的可靠性和实用性，本文会对生成的图像在物理理想条件、3 维场景以及实际目标检测应用 3 个层面上是否能够有效地模拟真实场景进行验证，如图 8 所示。

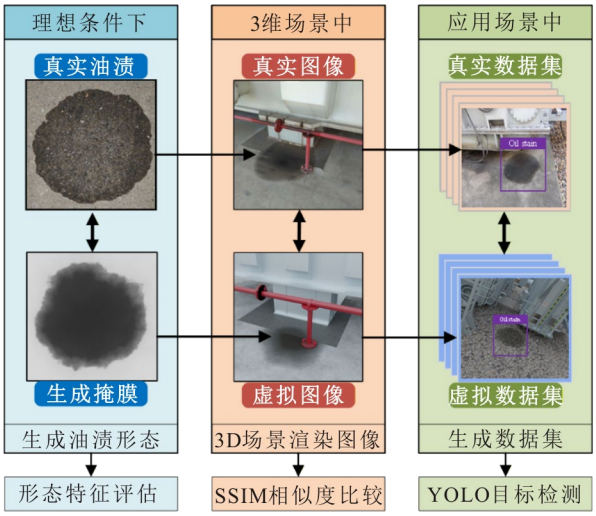


图 8 生成图像的验证流程框架

Fig.8 Validation process framework for generating images

3.2 物理模型验证

为验证本文所构建的 2 维物理扩散模型在模拟油渍形态上的有效性，本文分别从真实实验与程序仿真 2 个路径获取油渍掩膜图像，评估其形状特征的相似性。

本文使用 25 号变压器油，由滴管滴落于水泥或鹅卵石地面，通过拍照方式获取真实油渍图像共 100 张，其中在水泥地面与鹅卵石地面各 50 张，正俯视角度拍摄图像；虚拟油渍图像由本文 2.3 节中模型得到，共 150 张，其中在水泥地面的合成掩膜有 100 张，在鹅卵石地面合成数据有 50 张。

对于得到的 2 组图像，为了在比较时排除光照地面纹理的影响，本文对 2 组图像均进行了统一的掩膜提取与标准化处理。所有图像均居中裁剪为正方形区域，并统一缩放至 527×527 像素。随后对图像进行二值化。对于因拍摄误差等导致的图形内部的小裂缝与孤立孔洞噪声，本文使用 5×5 的卷积核进行闭运算去除，最后得到的图像如图 9 所示。

图 9 中的 4 组图像依次展示了真实油渍图像、真实油渍掩膜、模拟油渍浓度渲染图以及模拟掩膜图，每组图像包含粗糙硬质地面和鹅卵石地面情况。可以看出，二值化的真实与生成的油渍掩膜图像非常相似。

由于油渍掩膜图像为一个封闭结构且大致呈圆形或是椭圆形，因此本文选用 Hu 形状不变矩(Hu Moment)作为两类掩膜图像的结构特征表示，Hu 矩在连续状态下具有平移、旋转、缩放不变性[25]。对每个生成的掩膜图像提取的 Hu 矩与所有真实掩膜图像的 Hu 矩进行两两配对比较，并计算其与真实图之间的最小距离指标。

图 10 展示了合成掩膜与真实掩膜之间最小 Hu 距离分布情况。由图 10 可以看出，两种地面在 Hu 最小距离分布整体偏左，大部分模拟掩膜的最小 Hu 距离集中在 0~0.3 范围，而鹅卵石地面由于表面结构复杂，导致部分样本 Hu 距离略大，但总体仍保持较高的结构相似性，由此可见所生成的掩膜与真实的掩膜在形状轮廓上与真实的具有一致性。

Hu 矩主要关注于图像轮廓的几何形状，尚不能反映图像中的纹理、边缘密度等高级语义特征。因此，本文基于 YOLOv8[25]骨干网络的深层特征提取方法，通过将真实图像与模拟图像同时输入预训练的 YOLOv8 模型，并提取其主干网络中第 8、12、15 层的特征输出特征表示，再使用 t-SNE[26-27]降维方法将其映射至 2 维空间中，对于粗糙水泥和鹅卵石两类不同的地面结果如图 11 所示。

图 11 是使用 YOLOv8 特征提取后得到的两组图像的特征 t-SNE 图，其中黑色点代表真实的油渍掩膜样本，灰色点代表生成的掩膜样本。从图 11 可以看出，真实样本与生成样本在特征空间中形成

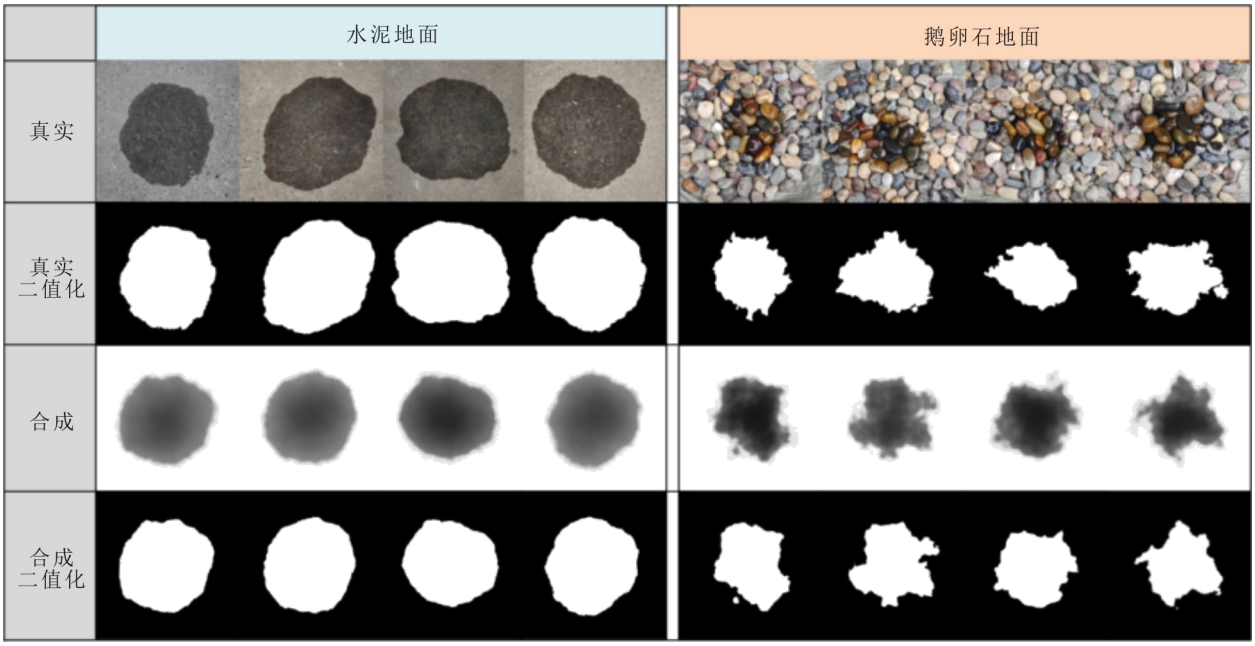


图 9　油渍图像及掩膜处理结果对比：真实和仿真

Fig.9　Oil stain images and mask processing: real and simulated ones

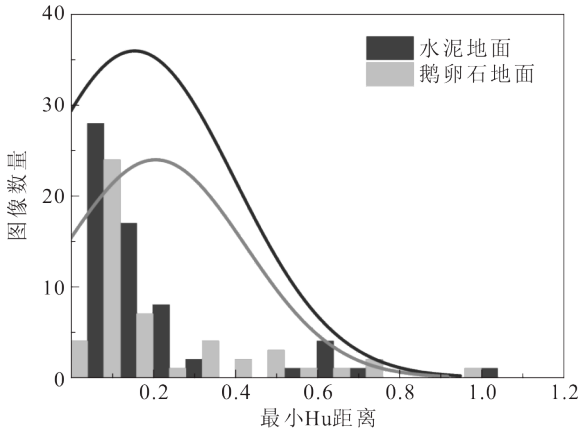
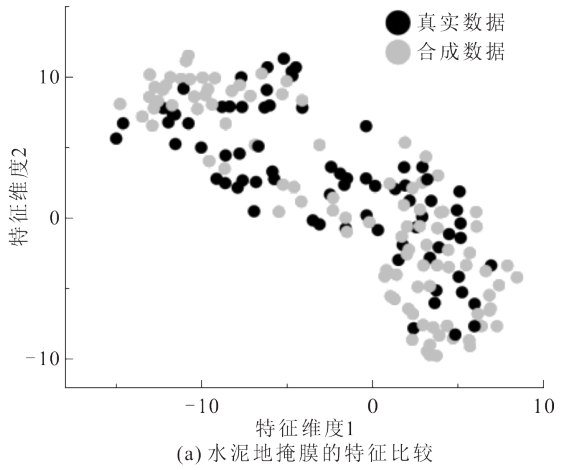
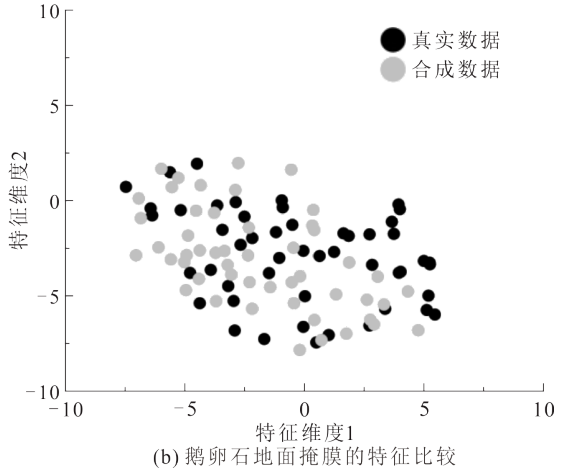


图 10　不同地面模拟图的最小 Hu 距离分布对比

Fig.10　Comparison of minimum Hu distance distributions across different surfaces



(a) 水泥地掩膜的特征比较



(b) 鹅卵石地面掩膜的特征比较

图 11　生成图像和真实掩膜图像的特征可视化对比

Fig.11　Visual comparison of features between generated and real images

了较集中的聚结构，虽然部分区域存在一定分离，但大多数生成样本与真实样本之间的分布具有明显重叠，说明所生成油渍掩膜在几何形状结构层面与真实油渍具有较高的一致性，两张图像均未出现明显分离的情况，进一步表明生成图像在视觉层面与真实图像的差异性较小。

3.3　图像相似度评估

本文选取 1 组典型的变压器漏油真实图像作为参考，在虚拟 3 维空间中依照该场景进行搭建场景，包括变压器本体、支架、地面材质以及油渍形态等内容，保证每组两张图像的内容信息一样，相机的

拍摄视角一样。对每组图像对计算其结构相似性指数(structural similarity index measure，SSIM)[28]，结果可视化如图 12。

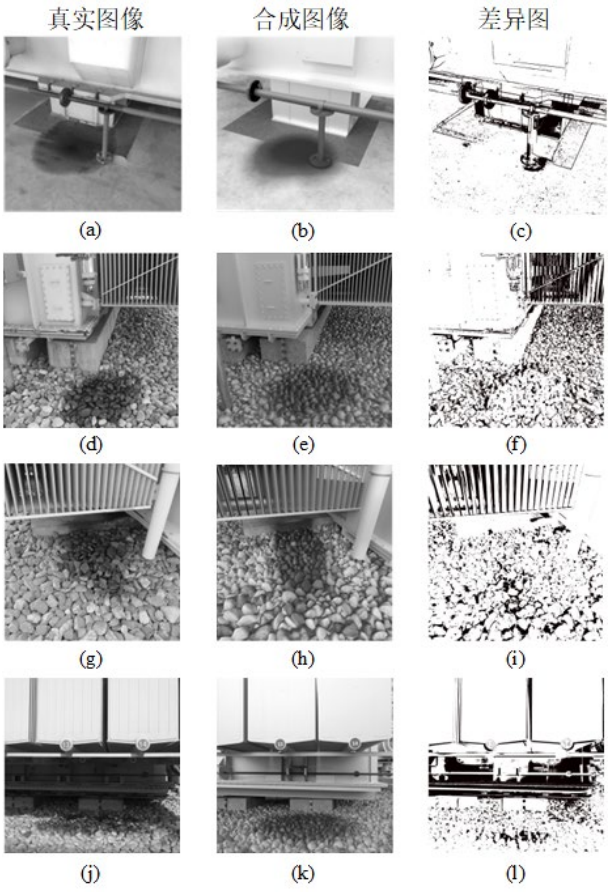


图 12 合成图像与真实图像的相似度比较

Fig.12 Comparison of similarity between generated images and real images

图 12 中，(a)、(d)、(g)、(j)为真实采集的变压器漏油灰度图像，在次基础上本文在虚拟 3 维世界中搭建了相同的场景，采集得到了(b)、(e)、(h)、(k)共 4 张合成灰度图像。

SSIM 评价函数从亮度、对比度与结构 3 个维度对 4 组图像进行评估，评估结果可视化展示为(c)、(f)、(i)、(l)，其中黑色区域表示差异较大(相似度低)的位置，白色区域表示差异较小(相似度高)的位置。SSIM 评估分数取值范围为[0, 1]，值越接近 1，表示两张图像在结构信息上越接近。实验结果如图 12 所示，4 组图像分别获得了 0.8589、0.809 1、0.838 1 和 0.854 4 的 SSIM 分数。

因此，本文认为当保持场景、物体布置、相机位置和光照一致时，虚拟 3 维世界中的图像采样器能够真实复现真实世界采样器(即相机拍摄)的输出结果，二者在结构层面是一致且可信的。

3.4 合成数据的目标检测

在完成对于掩膜的验证和图像相似度评价后，本节对所生成的漏油数据集进行目标检测实验。为系统验证本文合成数据的可迁移性与泛化能力，本文在不同模型架构与不同训练数据策略下进行统一评测。实验测试数据集在变电站采集图像，共 400 张。本文的数据集划分与用途如下：数据集 A 为 200 张真实地面漏油图像，仅用作单独训练或与合成数据混合训练；数据集 B 为 200 张真实图像，仅用于测试；数据集 C/D/E 分别为 200/500/1 000 张由本文物理建模方法生成的合成图像，用作训练或与数据集 A 混合训练。为保证可比性，训练与推理参数在不同模型间保持一致：基于 PyTorch 2.5.1 和 CUDA 12.1，使用默认的优化器与学习率的调度，设置训练轮数 epochs=100、批次大小 batch size=16、输入图像尺寸 imgsz=640，统一开启常规数据增强；推理阶段置信度阈值设置为 0.25、NMS IoU=0.5。模型性能评估采用多项常用目标检测指标，包括检测准确率(P)、召回率(R)、F1 分数(F_1)以及平均精度均值(mAP@0.5)。本文使用了 3 种不同的检测模型进行对比，分别为 YOLOv5s、YOLOv5m 和 YOLOv8m。本文的样本数据 A，C，D，E 以及 A+E 均在这 3 个网络模型上进行了训练，在真实样本上的推理结果如表 2 所示，部分推理结果如图 13 所示。

表 2 使用 YOLOv5 目标检测实验结果比较

Table 2 Comparison of experimental results using YOLOv5 for object detection

模型	数据集	数据集构成	P/%	R/%	F_1	mAP50/%
YOLOv5s	A	200 张真实图像	76.9	56.4	65.074	67.1
YOLOv5m			79.2	53.3	63.719	65.6
YOLOv8m			76.9	58.8	66.643	69.8
YOLOv5s	C	200 张生成图像	66.8	52.9	59.043	60.4
YOLOv5m			68.0	54.1	60.259	55.5
YOLOv8m			62.4	54.9	58.410	59.2
YOLOv5s	D	500 张生成图像	72.0	54.9	62.298	65.2
YOLOv5m			77.0	53.3	62.995	67.8
YOLOv8m			77.0	53.7	63.273	64.7
YOLOv5s	E	1 000 张生成图像	71.9	60.8	65.886	67.4
YOLOv5m			75.3	62.4	68.264	72.5
YOLOv8m			81.7	69.0	74.814	81.5
YOLOv5s	A+E	1 000 张生成图像+200 张真实图像	83.7	68.3	75.220	72.0
YOLOv5m			89.3	65.1	75.303	72.5
YOLOv8m			83.2	67.8	74.714	79.6



图 13 在真实样本下的推理结果样例

Fig.13 Example of real oil stains on the ground

从表 2 可以看出，随着合成数据规模由 C(200 张)逐步扩展至 D(500 张)和 E(1 000 张)，3 种检测模型的 F_1 值和 mAP50 总体呈现提升，模型检测性能持续提升。同时，少量真实数据与大规模合成数据的混合训练性能优于单一数据源训练性能，能够更全面地覆盖目标特征分布并增强模型的泛化能力。

为了进一步测试本文生成数据在不同检测范式下的有效性，除 YOLO 系列单阶段检测模型外，本文还在双阶段目标检测模型 Faster R-CNN 上进行了实验评估。实验采用前述生成的虚拟漏油数据作为训练集，并在相同的真实测试集上进行推理。结果如表 3 所示。表 3 测试结果表明，本文方法生成的数据在主流目标检测模型中同样具有良好的适用性与泛化能力。

表 3 使用 Faster R-CNN 目标检测实验结果比较

Table 3 Comparison of experimental results using Faster R-CNN for object detection

模型	训练数据	P/%	R/%	F_1	mAP50/%
Faster R-CNN	200 张真实数据	60.03	52.8	56.18	65.62
Faster R-CNN	1 000 张生成数据	71.59	54.70	62.01	68.98
Faster R-CNN	1 000 张生成图像+200 张真实图像	76.90	56.40	65.07	67.10

为验证油渍形态模拟的必要性，设计了油渍生成方式的消融实验。目前可以通过直接贴附几何图案(如图 14(a)、(b))、噪声扰动(如图 14(c))以及本文所提出的基于液体铺展模拟的方式来生成油渍(如图 14(d))，对 3 种方式各合成 200 张图像用于训练，固定相机视角，其余的渲染流程保持一致，并以 YOLOv5m 进行评估，结果如表 4 所示。



(a) (b) (c) (d)

图 14 不同油渍形态模拟方法在 3 维场景中的可视化对比

Fig.14 Comparison of different oil stain morphology simulation methods in a 3D scene

表 4 不同油渍生成方式对目标检测效果的对比

Table 4 Comparison of oil stain generation methods for object detection

油渍生成策略	P/%	R/%	F_1	mAP50/%
几何图案	57.6	47.1	51.9	52.0
随机噪声	58.3	47.8	52.8	51.4
本文方法	62.8	57.9	60.7	59.6

结果表明，本文所生产的油渍的图像在结构特征上能够被检测器有效学习，降低对简单“深色斑块或阴影”的误检倾向。相较之下，随机几何与噪声掩膜缺乏上述物理一致性，导致模型更容易过拟合颜色或局部纹理，从而在真实场景中表现较差。

4 结论

本文提出了一种基于 2 维扩散模型和物理建模

方法的变压器地面漏油图像数据集生成方法。对油渍在地面多孔介质中的扩散、蒸发与吸收过程进行了建模与简化模拟，能够在保留真实物理特性的同时，实现高效的数据合成。同时结合 3 维场景搭建、程序化纹理合成、动态投影纹理映射等手段，大幅提升了数据集的多样性与真实性，结论如下：

1）本文构建了一个综合考虑了扩散，蒸发与吸收过程的油渍铺展的物理模型。通过构建一个各向异性的扩散方程来数值求解，并结合地面材质等对扩散系数进行空间调制，形成了可控性强、物理性良好的油渍形态模拟方法，能够在不同环境条件下灵活生成多样化的油渍形态。

2）本文提出了一套自动化的变压器地面漏油数据生成框架，涵盖了 3 维场景随机化构建，纹理融合，相机参数生成，以及图像渲染与自动标注多个模块。该框架基于 Blender 平台，结合 Python 程序进行统一控制，从物理模拟到图像生成都可实现程序化。

3）本文生成图像数据在视觉质量层面对真实拍摄的图像具有较好的还原能力。通过对比相同场景布局和视角条件下采集真的实图像与合成图像的结构相似性，结果显示合成图像在局部结构与纹理特征上与真实图像具有较高的一致性。

4）本文生成了多场景、多视角、多样化油渍形态的变压器地面油渍的数据集，所有的图像均配套有掩膜图与检测标注信息。生成的数据集可以较好地完成变压器漏油的检测任务。未来工作将进一步扩展至箱体侧壁渗漏等仍有部分出现的复杂场景的数据集生成。

本文聚焦于地面漏油场景的数据生成与铺展模拟，在实际应用中，箱体侧壁、管道接口渗漏仍时有发生，其泄漏路径及油液流动形态与地面漏油存在差异且相关数据匮乏，未来将补充生成此类场景以进一步提升模型的泛化能力。

本文的验证主要基于 YOLO 系列与 Faster R-CNN 两类模型，训练参数设置相对固定。未来将引入更多检测框架及不同特征提取网络，并针对学习率、批量大小等关键超参数开展系统性对比，以评估不同数据源组合在多模型、多参数条件下的性能变化，进一步提升方法的泛化性与鲁棒性。

参考文献 References

[1] 刘垚. 基于图像处理的变电站漏油设备检测方法研究[D]. 北京：华北电力大学，2021.
LIU Yao. Research on detection method of substation oil leakageequipment based on image processing[D]. Beijing, China: North China Electric Power University, 2021.

[2] 赵文清，刘亮，胡嘉伟，等. 基于深度可分离空洞卷积金字塔的变压器渗漏油检测[J]. 智能系统学报，2023，18(5)：966-974.
ZHAO Wenqing, LIU Liang, HU Jiawei, et al. Detection of transformer oil leakage based on deep separable atrous convolution pyramid[J]. CAAI Transactions on Intelligent Systems, 2023, 18(5): 966-974.

[3] 马崇昪，唐娉，赵理君，等. 深度学习图像数据增广方法研究综述[J]. 中国图象图形学报，2021，26(3)：487-502.
MA Dong'ao, TANG Ping, ZHAO Lijun, et al. Review of data augmentation for image in deep learning[J]. Journal of Image and Graphics, 2021, 26(3): 487-502.

[4] 王志强，张志伟，杨海泉. 基于 Perlin 噪声的花卉仿真方法[J]. 深圳大学学报(理工版)，2019，36(4)：460-466.
WANG Zhiqiang, ZHANG Zhiwei, YANG Haiquan. Perlin noise-based flowers simulation method[J]. Journal of Shenzhen University (Science and Engineering), 2019, 36(4): 460-466.

[5] 闫志杰，张凌浩，贾振堂，等. 基于 Tw_Cycle Gan 的绝缘子缺陷样本自动生成技术[J]. 电子测量技术，2021，44(17)：138-145.
YAN Zhijie, ZHANG Linghao, JIA Zhentang, et al. Automatic generation technology of insulator defect samples based on Tw_Cycle Gan[J]. Electronic Measurement Technology, 2021, 44(17): 138-145.

[6] 周颖，裴盛虎，陈海永，等. 基于双维度注意力集成对抗网络的太阳能电池缺陷图像生成[J]. 计算机辅助设计与图形学学报，2024，36(5)：750-759.
ZHOU Ying, PEI Shenghu, CHEN Haiyong, et al. Solar cell defect image generation based on dual-dimensional attention integrated adversarial network[J]. Journal of Computer-Aided Design & Computer Graphics, 2024, 36(5): 750-759.

[7] SEGAL B, RUBIN D M, RUBIN G, et al. Evaluating the clinical realism of synthetic chest X-rays generated using progressively growing GANs[J]. SN Computer Science, 2021, 2(4): 321.

[8] TANG H, JIA K. A new benchmark: on the utility of synthetic data with blender for bare supervised learning and downstream domain adaptation[C]//Proceedings of the 2013 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE, 2023: 15954-15964.

[9] HOSKERE V, NARAZAKI Y, SPENCER JR B F. Physics-based graphics models in 3D synthetic environments as autonomous vision-based inspection testbeds[J]. Sensors, 2022, 22(2): 532.

[10] LIU Z Y, SHAH D, WANDELL B A. ISETHDR: a physics-based synthetic radiance dataset for high dynamic range driving scenes[J]. IEEE Sensors Journal, 2025, 25(9): 15261-15269.

[11] 刘庆臻，刘亚东，严英杰，等. 基于域随机化的绝缘子缺损数据自动生成与评价方法[J]. 高电压技术，2024，50(5)：1900-1912.
LIU Qingzhen, LIU Yadong, YAN Yingjie, et al. Automatic generation and evaluation method of insulator broken defect data based on domain randomization[J]. High Voltage Engineering, 2024, 50(5): 1900-1912.

[12] GUO J, QIAN J H, GUO Y W, et al. Rendering thin transparent layers with extended normal distribution functions[J]. IEEE Transactions on Visualization and Computer Graphics, 2017, 23(9): 2108-2119.

[13] 鲍伟超，顾理，何劲松，等. 基于循环训练法的变压器漏油检测[J]. 计算机辅助设计与图形学学报，2021，33(3)：431-438.
BAO Weichao, GU Li, HE Jinsong, et al. Transformer oil leakage de-

tection based on loop training method[J]. Journal of Computer-Aided Design & Computer Graphics, 2021, 33(3): 431-438.

[14] FU F D, LI P C, WANG K Y, et al. Numerical simulation of sessile droplet spreading and penetration on porous substrates[J]. Langmuir, 2019, 35(8): 2917-2924.

[15] GORIN B, DI MAURO G, BONN D, et al. Universal aspects of droplet spreading dynamics in Newtonian and non-Newtonian fluids[J]. Langmuir, 2022, 38(8): 2608-2613.

[16] LIANG H, YANG P Y, WANG W Z, et al. Spreading behavior of single oil droplet impacting surface with/without a thin liquid film[J]. Lubricants, 2023, 11(1): 31.

[17] WANG X K, XU Y R, LIU S N, et al. Physics-based fluid simulation in computer graphics: survey, research trends, and challenges[J]. Computational Visual Media, 2024, 10(5): 803-858.

[18] BAJO J M, DELRIEUX C, PATOW G. Physically inspired technique for modeling wet absorbent materials[J]. The Visual Computer, 2021, 37(8): 2053-2068.

[19] CANCÈS C, GALLOUËT T O, MONSAINGEON L. The gradient flow structure for incompressible immiscible two-phase flows in porous media[J]. Comptes Rendus. Mathématique, 2015, 353(11): 985-989.

[20] YANCHESHME A A, PALMESE G R, ALVAREZ N J. A generalized scaling theory for spontaneous spreading of Newtonian fluids on solid substrates[J]. Journal of Colloid and Interface Science, 2023, 636: 677-688.

[21] CHU N S H, TAI C L. MoXi: real-time ink dispersion in absorbent paper[J]. ACM Transactions on Graphics, 2005, 24(3): 504-511.

[22] CONG W Y, ZHANG J F, NIU L, et al. DoveNet: deep image harmonization via domain verification[C]//Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE, 2020: 8391-8400.

[23] MA X, DESCHAINTRE V, HAŠAN M, et al. Materialpicker: Multi-modal dit-based material generation[J]. ACM Transactions on Graphics, 2025, 44(4): 1-12.

[24] BRADSKI G, KAEHLER A. Learning OpenCV 4: Computer Vision with Python[M]. Sebastopol, Russia: O'Reilly Media, 2019.

[25] 张子健，马吉恩，李旭峰，等. 基于深度学习与 Hu 不变矩的绝缘子故障检测[J]. 铁道学报，2021，43(2)：71-77.
ZHANG Zijian, MA Jien, LI Xufeng, et al. Insulator fault detection based on deep learning and Hu invariant moment[J]. Journal of the China Railway Society, 2021, 43(2): 71-77.

[26] Ultralytics. Yolov8[EB/OL]. (2024-09-30)[2025-04-23]. https: //github.com/ultralytics/ultralytics.

[27] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn: machine learning in Python[J]. Journal of Machine Learning Research, 2011, 12(85): 2825-2830.

[28] 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.



王瀚彬
2000—，男，硕士生
主要从事电力设备状态监测与故障诊断方面的研究工作
E-mail: itswhb@mail.shiep.edu.cn

WANG Hanbin



严英杰(通信作者)
1988—，男，博士，副教授
主要从事变压器、开关数字化技术等方面的研究工作
E-mail: yanyingjie@sjtu.edu.cn

YAN Yingjie
Ph.D.
Associate professor
Corresponding author

收稿日期 2025-07-07 在线出版日期 2025-10-10 编辑 卫李静