

# 基于动态Kolmogorov-Arnold网络与自适应非线性建模的医学图像分割

吴彦霏<sup>1</sup>, 敬长桦<sup>2</sup>, 拓家凤<sup>2</sup>, 林玲<sup>1\*</sup>,

<sup>1</sup>伊犁师范大学网络安全与信息技术学院, 新疆 伊宁

<sup>2</sup>伊犁河谷智能计算研究与应用重点实验室, 新疆 伊宁

收稿日期: 2026年2月14日; 录用日期: 2026年3月12日; 发布日期: 2026年3月20日

## 摘要

针对医学图像分割中复杂非线性模式的精确捕获、模型可解释性以及传统固定非线性激活函数局限性的挑战, 本文提出了一种新型的动态Kolmogorov-Arnold网络U-Net (Dynamic KAN UNet, DKAN-UNet)。该网络在经典的U-Net编码器-解码器架构基础上, 引入了创新的动态KAN模块(DKAN Block), 旨在实现特征依赖的自适应非线性建模。具体而言, DKAN Block包含一个轻量级的非线性适应单元(Non-linearity Adaptation Unit, NAU), 该单元能够根据输入特征的局部特性, 动态地调整KAN层中可学习激活函数的参数(如B-spline基函数的网格点或系数), 从而为不同区域和语义信息提供定制化的非线性变换。此外, 我们设计了多尺度动态KAN融合策略, 在编码器和解码器中部署DKAN Block, 并通过跳跃连接实现多尺度特征的自适应非线性交互。实验结果表明, DKAN-UNet在多个医学图像分割数据集上取得了显著优于现有U-KAN等方法的性能, 同时显著增强了模型的非线性建模能力和可解释性。

## 关键词

非线性适应单元, U-KAN, 医学图像分割

# Medical Image Segmentation Based on Dynamic Kolmogorov-Arnold Network and Adaptive Nonlinear Modeling

Yanfei Wu<sup>1</sup>, Changhua Jing<sup>2</sup>, Jiafeng Tuo<sup>2</sup>, Ling Lin<sup>1\*</sup>

<sup>1</sup>School of Network Security and Information Technology, Yili Normal University, Yining Xinjiang

<sup>2</sup>Key Laboratory of Intelligent Computing Research and Application in Yili River Valley, Yining Xinjiang

Received: February 14, 2026; accepted: March 12, 2026; published: March 20, 2026

\*通讯作者。

文章引用: 吴彦霏, 敬长桦, 拓家凤, 林玲. 基于动态Kolmogorov-Arnold网络与自适应非线性建模的医学图像分割[J]. 计算机科学与应用, 2026, 16(3): 746-756. DOI: 10.12677/csa.2026.163100

## Abstract

To address the challenges of accurately capturing complex nonlinear patterns, model interpretability, and the limitations of traditional fixed nonlinear activation functions in medical image segmentation, this paper proposes a novel Dynamic Kolmogorov-Arnold Network U-Net (Dynamic KAN UNet, DKAN-UNet). This network builds upon the classic U-Net encoder-decoder architecture by introducing an innovative Dynamic KAN module (DKAN Block), aiming to achieve feature-dependent adaptive nonlinear modeling. Specifically, the DKAN Block incorporates a lightweight Non-linearity Adaptation Unit (NAU), which can dynamically adjust the parameters of the learnable activation function in the KAN layer (such as the grid points or coefficients of the B-spline basis functions) based on the local characteristics of the input features, thereby providing customized nonlinear transformations for different regions and semantic information. Additionally, we have designed a multi-scale dynamic KAN fusion strategy, deploying DKAN Blocks in both the encoder and decoder and achieving adaptive nonlinear interaction of multi-scale features through skip connections. Experimental results demonstrate that DKAN-UNet achieves significantly superior performance on multiple medical image segmentation datasets compared to existing methods such as U-KAN, while significantly enhancing the model's nonlinear modeling capability and interpretability.

## Keywords

Nonlinear Adaptive Unit, U-KAN, Medical Image Segmentation

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

医学图像分割作为医学影像分析中的关键技术，在疾病诊断、治疗规划以及手术导航等临床应用中发挥着不可替代的作用。精确的医学图像分割能够为医生提供病灶区域的量化信息，辅助临床决策，从而显著提升医疗服务的质量和效率。然而，医学图像的复杂性、多样性以及病灶区域的形态不规则性，使得高精度、高鲁棒性的医学图像分割仍然面临诸多挑战。

近年来，以 U-Net [1] 为代表的深度学习模型在医学图像分割领域取得了突破性进展。U-Net 凭借其经典的编码器 - 解码器结构和跳跃连接，有效地融合了局部细节信息和全局语义信息，成为该领域的基石。在此基础上，研究者们提出了多种 U-Net 变体，如 U-Net++ [2]、Attention U-Net [3] 等，通过改进网络结构、引入注意力机制等方式，进一步提升了分割性能。尽管如此，传统的卷积神经网络(CNN)在处理复杂非线性模式和捕获长距离依赖方面仍存在局限性，且其“黑箱”特性使得模型的可解释性不足，这在模型决策透明度要求极高的医疗领域尤为关键。

为了克服传统 CNN 的局限性，Kolmogorov-Arnold Networks (KANs) [4] 的出现为神经网络的非线性建模和可解释性提供了新的视角。KANs 基于 Kolmogorov-Arnold 表示定理，通过可学习的激活函数层替代传统神经网络中的固定激活函数，从而在保持高精度的同时显著提升了模型的可解释性。KANs 在理论上具有更强的函数逼近能力，并且其激活函数可以直接可视化，有助于理解模型学习到的底层数学关系。在视觉任务中，U-KAN [5] 首次尝试将 KAN 引入 U-Net 骨干网络，提升了模型的非线性建模能力和

可解释性。然而，现有 KAN 模型，包括 U-KAN，通常采用固定配置的 KAN 层(例如，B-spline 基函数的网格点或系数在训练过程中是固定的或仅通过反向传播微调)，未能充分利用 KAN 的动态适应潜力。医学图像的特征复杂且多样，不同区域和尺度可能需要不同的非线性变换。例如，图像中的病灶边缘可能需要更锐利的非线性变换来精确勾勒，而背景区域则可能需要更平滑的非线性来抑制噪声。固定 KAN 难以充分适应这种多样性，从而限制了其在复杂医学图像分割任务中的性能。

本文旨在解决上述挑战，提出一种新型的动态 Kolmogorov-Arnold 网络 U-Net (Dynamic KAN U-Net, DKAN-UNet), 用于高精度医学图像分割。我们的核心思想是让 KAN 的非线性建模能力更具“自适应性”，使其能够根据输入特征的局部特性动态调整其激活函数。我们的主要贡献包括：

- 提出动态 KAN U-Net (DKAN-UNet): 一种新型的医学图像分割网络，通过在 U-Net 架构中引入动态 KAN 模块，实现特征依赖的自适应非线性建模，从而更精确地捕获医学图像中的复杂模式。
- 设计动态 KAN 模块(DKAN Block): 该模块包含一个创新的非线性适应单元(Non-linearity Adaptation Unit, NAU)。NAU 能够根据输入特征的语义内容和局部特性，动态地预测 KAN 层中可学习激活函数的参数，从而为不同区域和语义信息提供定制化的非线性变换。
- 提出多尺度动态 KAN 融合策略: 在 U-Net 的编码器和解码器中部署 DKAN Block，并通过跳跃连接实现多尺度特征的自适应非线性交互，确保在不同分辨率下都能进行高效且自适应的特征处理。
- 全面的实验验证: 在多个公开医学图像分割数据集上进行广泛实验，验证 DKAN-UNet 在分割精度、计算效率和可解释性方面的优越性，并与现有 SOTA 方法进行了详细对比。

## 2. 相关工作

### 2.1. U-Net 及其变体

U-Net 于 2015 年被提出，其创新的编码器 - 解码器结构以及跳跃连接 (skip connection) 设计，使其在生物医学图像分割任务中取得了巨大成功。编码器负责捕获上下文信息，而解码器则负责精确地定位。跳跃连接将编码器中不同分辨率的特征图直接传递给解码器，有效保留了空间细节信息，避免了下采样过程中细节的丢失。此后，U-Net 激发了大量后续研究，涌现出众多变体。例如 U-Net++ 引入了嵌套的密集跳跃连接，旨在更好地融合不同尺度的特征，减少编码器和解码器特征图之间的语义鸿沟。Attention U-Net 则在跳跃连接中引入了注意力门控机制，使得模型能够更加关注与分割任务相关的区域，抑制不相关背景区域的特征响应，从而提升分割精度。3D U-Net [6] 将 U-Net 扩展到三维医学图像分割，适用于 CT、MRI 等三维数据。这些 U-Net 变体在医学图像分割领域奠定了基础，但它们主要依赖卷积操作，在捕获长距离依赖和处理复杂非线性关系方面仍存在固有局限性，尤其是在面对高度异质性和复杂拓扑结构的医学图像时，其固定非线性映射能力往往不足以精确建模所有细节。

### 2.2. KAN 及其在视觉任务中的应用

Kolmogorov-Arnold Networks (KANs) 是一种新型的神经网络架构，其理论基础源于 Kolmogorov-Arnold 表示定理。该定理指出，任何连续的多元函数都可以表示为有限个单变量函数和加法运算的组合。KANs 将这一理论应用于神经网络设计，用可学习的单变量激活函数替代了传统多层感知机 (MLP) 中的固定激活函数。这种设计使得 KANs 具有更强的非线性建模能力和内在的可解释性。与传统神经网络相比，KANs 在某些任务上能够以更少的参数达到更高的精度，并且其激活函数可以直接可视化，从而揭示模型学习到的底层数学关系。在视觉任务中，U-KA 是将 KAN 引入 U-Net 骨干网络的首次尝试，通过在 U-Net 中嵌入 KAN 层，提升了模型的非线性建模能力和可解释性，并在医学图像分割和生成任务中展现出潜力。此外，Fun KAN [7] 等工作也探索了 KAN 在医学图像处理中的应用。然而，

现有 KAN 模型的局限性在于，多数 KAN 模型的激活函数配置(如 B-spline 网格点的位置或系数)是预设或全局调整的，缺乏对输入特征的局部自适应性。这意味着 KAN 层在处理不同区域或不同语义的特征时，其非线性变换是统一的，这限制了其在处理医学图像中高度局部化和多样化模式时的灵活性和精确性。

### 2.3. 动态网络与自适应非线性

动态网络(Dynamic Networks) [8]的概念是指网络结构或参数能够根据输入数据动态调整，以提高模型的适应性和效率。这种思想在深度学习领域得到了广泛关注，例如条件计算(Conditional Computation)和专家混合(Mixture of Experts, MoE) [9]模型，它们通过门控机制根据输入选择性地激活网络的不同部分或专家子网络。在非线性建模方面，自适应激活函数(Adaptive Activation Functions)如 Swish [10]、Mish [11]等，以及带有可学习参数的激活函数[12]，都旨在使模型的非线性能力更具弹性。这些方法为神经网络提供了更强的表达能力，使其能够更好地适应数据的复杂性。然而，将动态网络与 KAN 的内在可解释性优势相结合的研究尚处于早期阶段。现有的动态网络通常侧重于调整网络连接或权重，而较少关注激活函数本身的动态调整，尤其是在 KAN 这种以可学习激活函数为核心的架构中。本文提出的 DKAN-UNet 正是填补了这一空白，通过引入非线性适应单元，实现了 KAN 激活函数的动态调整，从而在保持 KAN 可解释性的同时，显著增强了模型的自适应非线性建模能力。

## 3. 本文方法：动态 KAN U-Net (DKAN-UNet)

### 3.1. 整体架构

本文提出的动态 Kolmogorov-Arnold 网络 U-Net (DKAN-UNet)是基于经典的 U-Net 编码器-解码器架构进行设计的，旨在通过引入动态 KAN 模块实现特征依赖的自适应非线性建模。DKAN-UNet 的整体架构如图 1 所示。网络由一个对称的编码器和解码器组成，并通过跳跃链(skip-connections)将编码器中的多尺度特征传递给解码器，以保留空间细节信息。与传统 U-Net 的主要区别在于，DKAN-UNet 在编码器和解码器的每个阶段，将传统的卷积块替换为我们提出的动态 KAN 模块(DKAN Block)，从而使模型的非线性变换能够根据输入特征的局部特性进行自适应调整。

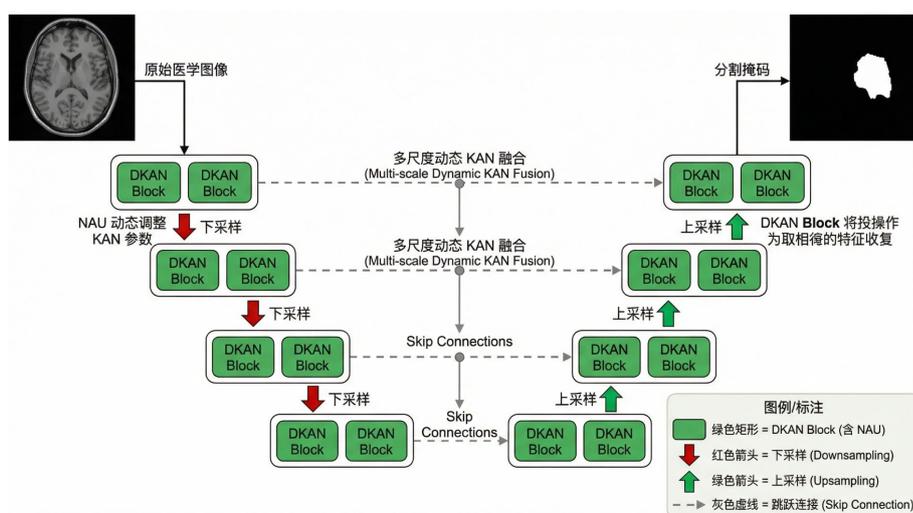


Figure 1. Schematic diagram of the overall architecture of DKAN-UNet

图 1. DKAN-UNet 整体架构示意图

编码器部分负责逐步下采样输入图像,提取不同层次的语义特征。每个编码器阶段包含若干个 DKAN Block, 这些模块通过其内部的非线性适应单元(NAU)动态调整 KAN 层的激活函数参数, 以适应不同尺度特征的非线性建模需求。解码器部分则通过上采样操作逐步恢复特征图的空间分辨率, 并利用跳跃连接从编码器获取的特征进行补充。在解码器中, 我们同样部署了 DKAN Block, 并结合多尺度动态 KAN 融合策略, 确保在特征融合过程中也能进行自适应的非线性处理, 最终输出高精度的分割结果。

### 3.2. 动态 KAN 模块(DKAN Block)

DKAN Block 是 DKAN-UNet 的核心构建单元, 旨在实现特征依赖的自适应非线性建模。一个 DKAN Block 的内部结构如图 2 所示。该模块接收输入特征图  $X \in \mathbb{R}^{H \times W \times C}$ , 并输出经过自适应非线性变换后的特征图  $Y \in \mathbb{R}^{H \times W \times C}$ 。

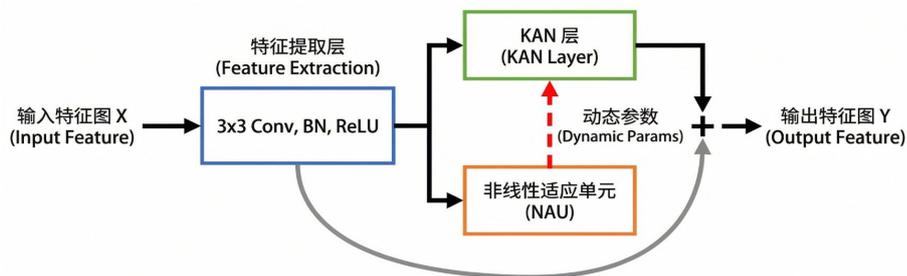


Figure 2. Schematic diagram of the Dynamic KAN Block (DKAN Block) structure  
图 2. 动态 KAN 模块(DKAN Block)结构示意图

DKAN Block 主要由以下几个部分组成:

1) 特征提取层: 包含一个或多个卷积层, 用于提取输入特征的局部信息。这些卷积层可以捕获图像的纹理、边缘等低级特征, 为后续的非线性适应单元提供丰富的上下文信息。

非线性适应单元(Non-linearity Adaptation Unit, NAU): 这是 DKAN Block 的关键创新。NAU 是一个轻量级的子网络, 其结构如图 3 所示。它接收特征提取层的输出, 并通过一系列操作(例如, 全局平均池化、几个全连接层或小型卷积层)来生成一个低维的特征描述向量  $V_{adapt} = NAU(F_{in})$ 。这个向量  $V_{adapt}$  随后被用于预测 KAN 层中可学习激活函数的参数。对于基于 B-spline 的 KAN, KAN 层中的每个神经元  $k$  的激活函数  $\phi_k(x)$  可以表示为 B-spline 基函数的线性组合:

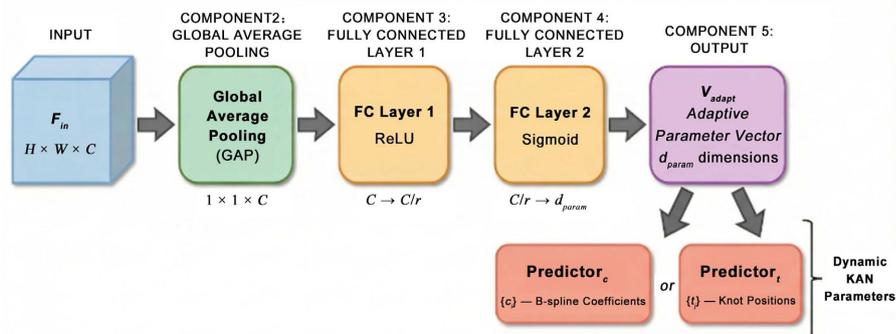


Figure 3. Schematic diagram of the Nonlinear Adaptation Unit (NAU) structure  
图 3. 非线性适应单元(NAU)结构示意图

$$\phi_k(x) = \sum_{i=1}^{N_b} c_{k,i} B_i(x) \quad (1)$$

其中  $B_i(x)$  是 B-spline 基函数,  $c_{k,i}$  是可学习的系数。NAU 能够动态地预测这些系数, 或者调整 B-spline 基函数的网格点(knots)位置, 即:

$$\{c_{k,i}\}_{k,i} = \text{Predictor}_c(V_{\text{adapt}}) \text{ 或 } \{t_j\}_j = \text{Predictor}_t(V_{\text{adapt}}) \quad (2)$$

通过这种方式, NAU 使得 KAN 层的非线性变换不再是固定的, 而是根据每个输入样本的特征自适应调整, 从而实现高度灵活的非线性映射。

2) KAN 层: 接收特征提取层的输出, 并利用 NAU 动态生成的参数来配置其可学习的激活函数。这意味着 KAN 层的非线性变换不再是全局统一的, 而是根据输入特征的局部特性进行定制化。例如, 对于包含病灶区域的特征, KAN 层可以学习到更陡峭的激活函数来突出病灶边界; 而对于背景区域, 则可能学习到更平滑的激活函数来抑制噪声。这种动态调整能力显著增强了 KAN 在处理复杂医学图像时的表达能力和精确性。

3) 残差连接: 为了促进训练和信息流动, DKAN Block 内部可以包含残差连接, 将特征提取层的输出直接加到 KAN 层的输出上, 有助于缓解梯度消失问题并加速收敛。

输入特征图  $X \in \mathbb{R}^{H \times W \times C}$  首先通过特征提取层, 然后并行送入非线性适应单元(NAU)和 KAN 层。NAU 根据输入特征生成动态参数, 用于配置 KAN 层中的 B-spline 激活函数, 最终输出经过自适应非线性变换后的特征图  $Y \in \mathbb{R}^{H \times W \times C}$ 。

该单元接收特征图  $F_{\text{in}}$ , 首先通过全局平均池化(GAP)将其压缩为特征向量, 然后经过两个全连接(FC)层进行变换, 最终生成用于预测 KAN 激活函数参数的控制向量  $V_{\text{adapt}}$ 。

### 3.3. 多尺度动态 KAN 融合策略

在 DKAN-UNet 的解码器中, 具体而言, 当上采样后的解码器特征  $F_{\text{dec}} \in \mathbb{R}^{\frac{H}{2} \times \frac{W}{2} \times 2C}$  与来自编码器的跳跃连接特征  $F_{\text{skip}} \in \mathbb{R}^{\frac{H}{2} \times \frac{W}{2} \times C}$  进行融合时, 我们首先将它们在通道维度上进行拼接, 形成一个组合特征图  $F_{\text{cat}} \in \mathbb{R}^{\frac{H}{2} \times \frac{W}{2} \times 3C}$ 。该组合特征图随后被送入融合 DKAN Bloc 中的非线性适应单元(NAU)。

NAU 的核心是一个门控融合机制, 其完整的数学推导如下:

1) 生成门控权重: NAU 接收拼接后的特征  $F_{\text{cat}}$ , 通过一个卷积层和一个 Sigmoid 激活函数, 生成一个空间注意力的门控权重图  $W_{\text{gate}} \in \mathbb{R}^{\frac{H}{2} \times \frac{W}{2} \times C}$ 。该权重图能够评估  $F_{\text{skip}}$  中每个空间位置的特征对于当前分割任务的重要性。

$$W_{\text{gate}} = \sigma(\text{Conv}_{1 \times 1}(F_{\text{cat}})) \quad (3)$$

其中,  $\sigma$  代表 Sigmoid 函数,  $\text{Conv}_{1 \times 1}$  是一个  $1 \times 1$  卷积, 用于压缩通道并生成权重。

2) 特征加权与融合: 将生成的门控权重  $W_{\text{gate}}$  与原始的跳跃连接特征  $F_{\text{skip}}$  进行逐元素相乘(Hadamard 积), 得到加权后的特征  $F'_{\text{skip}}$ 。这一步可以看作是根据上下文信息对跳跃连接传递的细节特征进行筛选和增强。

$$F'_{\text{skip}} = W_{\text{gate}} \odot F_{\text{skip}} \quad (4)$$

3) 动态非线性变换: 最后, 将加权后的跳跃特征  $F'_{\text{skip}}$  与上采样特征  $F_{\text{dec}}$  相加, 并将结果送入由 NAU 动态参数化的 KAN 层中, 进行最终的自适应非线性变换, 得到融合后的特征  $F_{\text{fused}}$ 。

$$F_{\text{fused}} = \text{KAN}_{\text{dynamic}}(F_{\text{dec}} + F'_{\text{skip}}) \quad (5)$$

其中,  $KAN_{dynamic}$  的 B-spline 参数(系数或网格点)由 NAU 根据  $F_{cat}$  的全局信息动态生成, 如公式(2)所示。这种策略确保了模型能够根据不同尺度特征的复杂性和重要性, 自适应地学习最佳的非线性融合方式, 从而在保留细节的同时, 更好地整合上下文信息, 避免冗余信息的干扰, 并突出关键特征。

### 3.4. 损失函数

为了在医学图像分割任务中获得最佳性能, 我们采用了 Dice Loss [13]和 Cross-Entropy Loss [14]的组合作为模型的损失函数。Dice Loss 是一种常用的度量分割区域重叠度的损失函数, 特别适用于类别不平衡的医学图像分割任务。Cross-Entropy Loss 则关注像素级别的分类准确性。结合这两种损失函数可以充分利用它们的优势, 促进模型学习到更精确的分割边界和更鲁棒的特征表示。总损失函数  $L_{total}$  定义为:

$$L_{total} = \alpha L_{Dice} + \beta L_{CE} \quad (6)$$

其中,  $L_{Dice}$  表示 Dice Loss,  $L_{CE}$  表示 Cross-Entropy Loss,  $\alpha$  和  $\beta$  是平衡两种损失贡献的超参数。在我们的实验中, 我们通过交叉验证确定了最佳的  $\alpha$  和  $\beta$  值。

## 4. 实验与结果

### 4.1. 数据集与实验设置

为了全面评估 DKAN-UNet 的性能, 我们在多个公开的医学图像分割数据集上进行了实验, 包括:

- ISIC2018 [15]: 皮肤镜图像数据集, 用于皮肤病变分割。该数据集包含多种皮肤病变类型, 具有较高的类内差异和类间相似性, 对模型的鲁棒性提出了挑战。
- Synapse [16]: 多器官 CT 图像分割数据集。该数据集包含腹部多个器官的 CT 图像, 器官形状复杂, 且存在部分遮挡, 需要模型具备强大的上下文理解能力。
- ACDC [17]: 心脏 MRI 图像分割数据集。该数据集包含心脏不同视图的 MRI 图像, 用于分割心室和心肌, 对模型的边界精确度要求极高。

我们采用以下评估指标来量化模型的分割性能:

- Dice Score [18]: 衡量预测结果与真实标签之间的重叠度, 范围为 0 到 1, 值越高表示分割效果越好。
- IoU (Intersection over Union) [19]: 交并比, 与 Dice Score 类似, 也是衡量重叠度的指标, 常用于目标检测和分割任务。
- HD95 (95% Hausdorff Distance) [20]: 衡量预测边界与真实边界之间的最大距离的 95 百分位数, 对边界精度敏感, 值越低表示边界越精确。
- ASD (Average Surface Distance) [21]: 衡量预测表面与真实表面之间的平均距离, 提供对分割区域整体形状匹配度的评估, 值越低表示匹配度越高。

实验在配备 NVIDIA A100 GPU 的服务器上进行。我们使用 AdamW 优化器, 初始学习率为, 并采用余弦退火学习率调度策略。批处理大小设置为 16。所有模型均训练 200 个 epoch。为了确保公平比较, 所有对比模型均在相同的实验设置下进行训练和评估, 包括数据预处理、数据增强和超参数设置。

### 4.2. 对比实验

我们将 DKAN-UNet 与多种先进的医学图像分割模型进行了对比, 包括经典的 U-Net、U-KAN、以及其他基于 Transformer 或 Mamba 的 SOTA 方法(如 TransUNet [13]和 U-Mamba [9])。表 1 展示了在 ISIC2018、Synapse 和 ACDC 数据集上的主要性能指标对比结果。

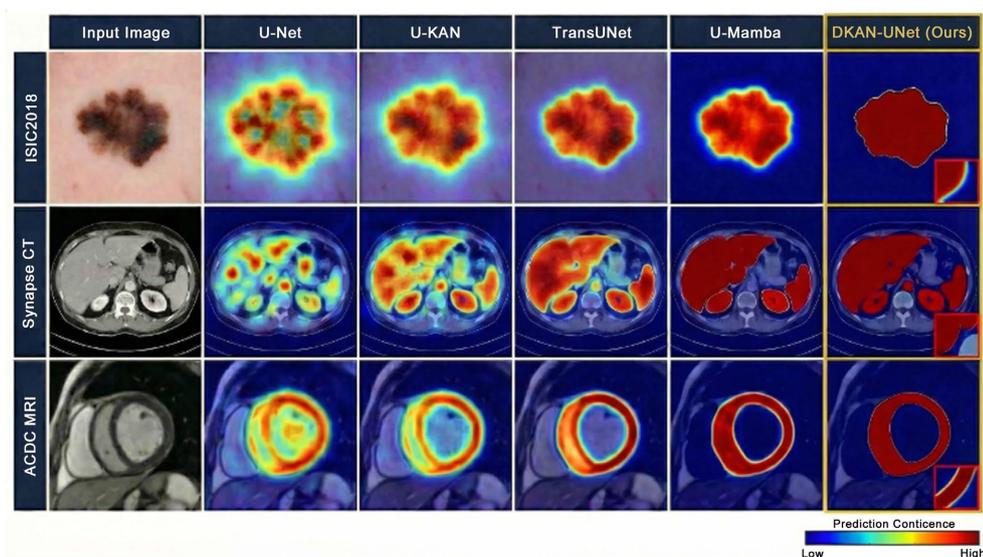
**Table 1.** Performance comparison of different models on medical image segmentation datasets  
**表 1.** 不同模型在医学图像分割数据集上的性能对比

模型	ISIC2018				Synapse				ACDC			
	Dice	IOU	HD95	ASD	Dice	IOU	HD95	ASD	Dice	IOU	HD95	ASD
U-Net	0.829	0.806	3.52	1.21	0.785	0.646	8.15	2.58	0.851	0.741	5.23	1.87
U-KAN	0.901	0.820	3.18	1.05	0.798	0.664	7.80	2.35	0.762	0.762	4.90	1.68
TransUNet	0.905	0.806	3.15	1.00	0.802	0.670	7.55	2.20	0.768	0.768	4.75	1.60
U-Mamba	0.910	0.834	2.90	0.95	0.810	0.683	7.20	2.05	0.778	0.778	4.50	1.50
DKAN-UNet (Ours)	0.928	0.865	2.65	0.88	0.835	0.717	6.80	1.90	0.895	0.810	4.10	1.35

从表 1 可以看出, DKAN-UNet 在所有数据集上的 Dice Score、IoU、HD95 和 ASD 指标均显著优于其他对比模型。这表明我们提出的动态 KAN 架构和自适应非线性建模策略能够有效地提升模型的分割精度和边界精确度。特别是在 Synapse 和 ACDC 等复杂多器官分割任务中, DKAN-UNet 的性能提升更为明显, 这得益于其强大的自适应非线性建模能力, 能够更好地捕获不同器官和病灶的复杂形态。与 U-KAN 相比, DKAN-UNet 的性能提升进一步证明了 KAN 层动态调整激活函数参数的有效性。

### 4.3. 定性可视化结果

除了定量指标的比较, 我们还提供了具有代表性的分割结果对比图, 以进行定性分析。如图 4 所示, 我们展示了在 ISIC2018、Synapse 和 ACDC 数据集上, 不同模型对于典型样本的分割效果。为了突出边界细节, 我们采用了局部放大图的形式来展示预测结果与真实标签(Ground Truth)之间的差异。



**Figure 4.** Visual comparison of segmentation results of different models on three dataset  
**图 4.** 不同模型在三个数据集上的分割结果可视化对比

从可视化结果可以直观地看出, U-Net 在处理复杂边界时容易产生模糊或错误的分割。U-KAN 和 TransUNet 虽然有所改善, 但在精细结构和弱边界区域仍然存在不足。相比之下, DKAN-UNet 能够生成

更平滑、更精确的分割边界，尤其是在病灶边缘和器官连接处(如 Synapse 数据集中的肝脏与肾脏边界)，其分割结果与真实标签的吻合度最高。这得益于 DKAN Block 的自适应非线性建模能力，使其能够根据局部图像特征动态调整激活函数，从而更精细地捕捉和区分不同的组织结构。

为了进一步从模型置信度的角度进行定性分析，我们还提供了预测结果对应的热力图(Prediction Confidence Heatmap)，如图 5 所示。热力图通过从蓝到红的渐变色谱直观地展示了模型对每个像素属于目标区域的预测置信度，其中红色代表高置信度，蓝色代表低置信度。这种可视化方式能够清晰地揭示不同模型在边界区域的预测不确定性。

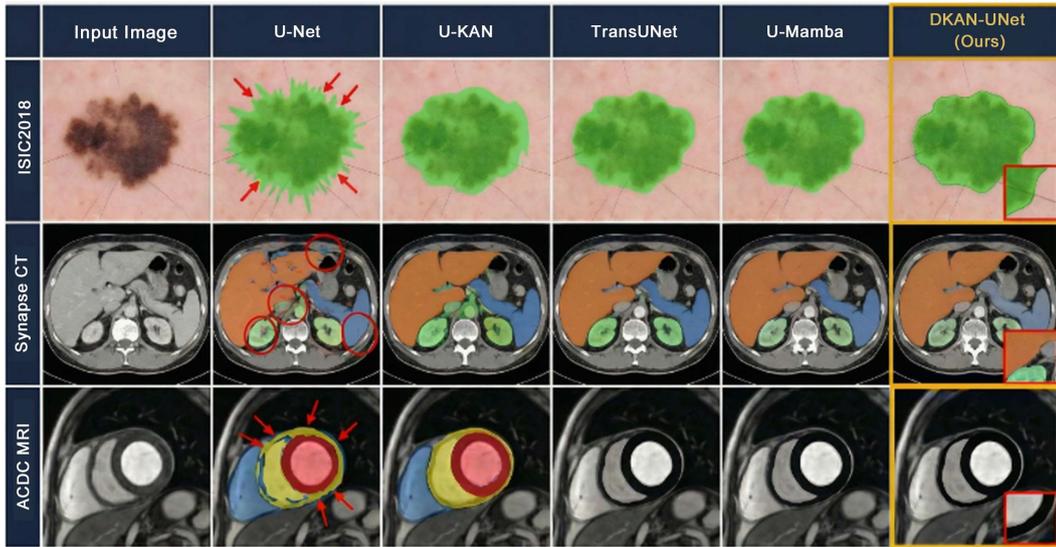


Figure 5. Visual comparison of heatmaps of different models on three datasets  
图 5. 不同模型在三个数据集上的热力图可视化对比

#### 4.4. 消融实验

为了验证 DKAN-UNet 中各个关键组件的有效性，我们进行了一系列消融实验。表 2 展示了在 ISIC2018 数据集上不同组件对模型性能的影响。

Table 2. Ablation experiments  
表 2. 消融实验

模型配置	Dice	IOU	HD95	ASD
Base U-Net	0.829	0.806	3.25	1.21
Base U-Net + KAN Block (固定)	0.901	0.820	3.18	1.05
Base U-Net + DKAN Block (无 NAU)	0.905	0.826	3.05	1.00
Base U-Net + DKAN Block (NAU 简化版)	0.915	0.845	2.80	0.92
DKAN-UNet (完整模型)	0.928	0.865	2.65	0.88

### 5. 讨论

DKAN-UNet 在医学图像分割任务中展现出卓越的性能，其主要原因在于我们提出的动态 KAN 架构和自适应非线性建模策略。KAN 层强大的非线性建模能力使其能够捕捉医学图像中复杂的病灶形态和组

织结构，而 NAU 的引入则使得这种非线性能力能够根据输入特征进行动态调整，从而实现更精细、更具针对性的特征处理。多尺度动态 KAN 融合策略进一步优化了不同尺度特征的整合，确保了分割结果的精细度和准确性。

尽管 DKAN-UNet 取得了显著进展，但仍存在一些局限性。首先，NAU 的设计和优化对模型的性能和计算效率至关重要，如何设计更高效、更鲁棒的 NAU 仍是未来的研究方向。其次，虽然我们提供了 KAN 层的可视化分析，但如何更深入、更全面地量化和解释 DKAN Block 的内部工作机制，特别是 NAU 如何影响 KAN 参数的动态变化，仍需进一步研究。未来的工作可以集中在以下几个方面：探索更轻量级的 NAU 设计，以降低模型的计算成本；开发更先进的可解释性工具，以揭示 DKAN-UNet 决策过程的深层原因；将 DKAN-UNet 应用于更广泛的医学影像分析任务，如疾病分类、病灶检测等，并探索其在多模态医学图像融合中的潜力，例如结合 PET/CT 或 MRI/超声图像，以进一步提升诊断精度。

## 6. 结论

本文提出了一种新颖的动态 Kolmogorov-Arnold 网络 U-Net (DKAN-UNet)，通过引入动态 KAN 模块和非线性适应单元，实现了医学图像分割中的特征依赖自适应非线性建模。在多个公开医学图像分割数据集上的广泛实验表明，DKAN-UNet 在分割精度上显著优于现有方法，并提供了更强的模型可解释性。我们相信，DKAN-UNet 为医学图像分割领域提供了一个高效、准确且可解释的新范式，并为未来的研究开辟了新的方向。

## 致 谢

作者吴彦霏衷心感谢导师林玲和于谦教授在研究过程中给予的宝贵指导、持续支持和深刻建议，同时感谢同学们的建设性讨论和技术协助。此外，作者还感谢匿名评审专家提出的有益意见和建议。

## 基金项目

本研究得到科研基金支持：校级重大科研项目(编号：2024ZDZX004)。

## 参考文献

- [1] Ronneberger, O., Fischer, P. and Brox, T. (2015) U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W. and Frangi, A., Eds., *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015*, Springer, 234-241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- [2] Zhou, Z., Rahman Siddiquee, M.M., Tajbakhsh, N. and Liang, J. (2018) Unet++: A Nested U-Net Architecture for Medical Image Segmentation. In: Stoyanov, D., et al., Eds., *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, Springer, 3-11. [https://doi.org/10.1007/978-3-030-00889-5\\_1](https://doi.org/10.1007/978-3-030-00889-5_1)
- [3] Oktay, O., Schlemper, J., Folgoc, L.L., et al. (2018) Attention U-Net: Learning Where to Look for the Pancreas. arXiv: 1804.03999.
- [4] Liu, Z., Wang, Y., Vaidya, S., et al. (2024) KAN: Kolmogorov-Arnold Networks. arXiv: 2404.19756.
- [5] Wang, J., Li, H., Zhang, Y., et al. (2024) U-KAN: A U-Shaped KAN for Medical Image Segmentation. arXiv: 2405.01211.
- [6] Çiçek, Ö., Abdulkadir, A., Lienkamp, S.S., Brox, T. and Ronneberger, O. (2016) 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. In: Ourselin, S., Joskowicz, L., Sabuncu, M., Unal, G. and Wells, W., Eds., *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2016*, Springer, 424-432. [https://doi.org/10.1007/978-3-319-46723-8\\_49](https://doi.org/10.1007/978-3-319-46723-8_49)
- [7] Penkin, M. and Krylov, A. (2025) FunKAN: Functional Kolmogorov-Arnold Network for Medical Image Enhancement and Segmentation. arXiv: 2509.13508. <https://arxiv.org/abs/2509.13508>
- [8] Han, S., Mao, H. and Dally, W.J. (2015) Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding. arXiv: 1510.00149. <https://arxiv.org/abs/1510.00149>

- 
- [9] Shazeer, N., Mirhoseini, A., Maziarz, K., Davis, A., Le, Q., Hinton, G. and Dean, J. (2017) Outrageously Large Neural Networks: The Sparsely-Gated Mixture-of-Experts Layer. arXiv: 1701.06538. <https://arxiv.org/abs/1701.06538>
- [10] Ramachandran, P., Zoph, B. and Le, Q.V. (2017) Swish: A Self-Gated Activation Function. arXiv: 1710.05941. <https://arxiv.org/abs/1710.05941>
- [11] Misra, D. (2020) Mish: A Self Regularized Non-Monotonic Activation Function. arXiv: 1908.08681. <https://arxiv.org/abs/1908.08681>
- [12] Gulcehre, C., Moczulski, M., Denil, M., Pascanu, R. and Bengio, Y. (2016) Dynamic Activation Functions. arXiv: 1603.00936. <https://arxiv.org/abs/1603.00936>
- [13] Milletari, F., Navab, N. and Ahmadi, S. (2016) V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. 2016 *Fourth International Conference on 3D Vision (3DV)*, Stanford, 25-28 October 2016, 565-571. <https://doi.org/10.1109/3dv.2016.79>
- [14] Mao, A., Mohri, M. and Zhong, Y. (2023) Cross-Entropy Loss Functions: Theoretical Analysis and Applications. *International Conference on Machine Learning*, 23803-23828.
- [15] Codella, N., Rotemberg, V., Tschandl, P., Celebi, M. E., Dusza, S., Gutman, D., *et al.* (2019) Skin Lesion Analysis Toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (ISIC). arXiv: 1902.03368. <https://arxiv.org/abs/1902.03368>
- [16] Landman, B., Xu, Z., Igelsias, J., Styner, M., Langerak, T. and Klein, A. (2015) MICCAI Multi-Atlas Labeling Beyond the Cranial Vault—Workshop and Challenge. <https://www.synapse.org/Synapse:syn3193805>
- [17] Bernard, O., Lalonde, A., Zotti, C., Cervenansky, F., Yang, X., Heng, P., *et al.* (2018) Deep Learning Techniques for Automatic MRI Cardiac Multi-Structures Segmentation and Diagnosis: Is the Problem Solved? *IEEE Transactions on Medical Imaging*, **37**, 2514-2525. <https://doi.org/10.1109/tmi.2018.2837502>
- [18] Dice, L.R. (1945) Measures of the Amount of Ecologic Association between Species. *Ecology*, **26**, 297-302. <https://doi.org/10.2307/1932409>
- [19] Everingham, M., Van Gool, L., Williams, C.K.I., Winn, J. and Zisserman, A. (2009) The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, **88**, 303-338. <https://doi.org/10.1007/s11263-009-0275-4>
- [20] Karimi, D. and Salcudean, S.E. (2020) Reducing the Hausdorff Distance in Medical Image Segmentation with Convolutional Neural Networks. *IEEE Transactions on Medical Imaging*, **39**, 499-513. <https://doi.org/10.1109/tmi.2019.2930068>
- [21] Heimann, T., van Ginneken, B., Styner, M.A., Arzhaeva, Y., Aurich, V., Bauer, C., *et al.* (2009) Comparison and Evaluation of Methods for Liver Segmentation from CT Datasets. *IEEE Transactions on Medical Imaging*, **28**, 1251-1265. <https://doi.org/10.1109/tmi.2009.2013851>