

基于频域通道交互增强的多维时间序列异常检测方法

杜睿山^{1,2}, 单亚洲¹, 孟令东³, 付晓飞³

(1. 东北石油大学计算机与信息技术学院, 黑龙江 大庆 163318; 2. 黑龙江省石油大数据与智能分析重点实验室, 黑龙江 大庆 163318; 3. 黑龙江省油气藏及地下储库完整性评价重点实验室, 黑龙江 大庆 163318)

摘要: 针对现有多维时间序列异常检测方法在局部频率变化和通道表征刻画存在的不足, 提出了一种基于频域通道交互增强的多维时间序列异常检测方法 TFDG-AD。该方法首先通过快速傅里叶变换并进行分块构建频谱实虚部子频段表示, 以表征不同频率范围内的局部异常特征。其次, 根据当前子频段表示自适应学习通道间关系, 构建稀疏归一化通道图, 并在该图上进行残差式图传播以聚合相关通道信息, 获得增强后的子频段表示。最后, 利用增强后的表示重构回时域序列, 并结合时域重构误差与频域误差完成异常评分。多个公开数据集上的实验结果表明, 所提方法能够有效提升多维时间序列异常检测效果, 与多种基线方法相比取得了明显提升。

关键词: 多维时间序列; 异常检测; 频域重构; 时频联合评分

中图分类号: TP309

文献标志码: A

Multivariate Time Series Anomaly Detection Based on Frequency-Domain Channel Interaction Enhancement

Du Ruishan^{1,2}, Shan Yazhou¹, Meng Lingdong³, Fu Xiaofei³

1. School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, Heilongjiang, China

2. Heilongjiang Provincial Key Laboratory of Petroleum Big Data and Intelligent Analysis, Daqing 163318, Heilongjiang, China

3. Heilongjiang Provincial Key Laboratory of Oil and Gas Reservoir and Underground Storage Integrity Evaluation, Daqing 163318, Heilongjiang, China

Abstract: To address the insufficient characterization of local frequency variations and channel representations in existing multivariate time series anomaly detection methods, this paper proposes TFDG-AD, a frequency-domain channel interaction enhancement method for multivariate time series anomaly detection. The proposed method first applies the fast Fourier transform to the input sequence and partitions the spectrum into sub-bands, where the real and imaginary components are combined to construct sub-band representations for describing local anomaly features in different frequency ranges. Then, channel relationships are adaptively learned from the current sub-band representations to build sparse normalized channel graphs, on which residual graph propagation is performed to aggregate information from related channels and obtain enhanced sub-band representations. Finally, the enhanced representations are reconstructed back to the time domain, and anomaly scores are calculated by combining time-domain reconstruction errors with frequency-domain errors. Experiments on multiple public datasets show that TFDG-AD effectively improves detection performance and outperforms several baselines.

Key words: multivariate time series, anomaly detection, frequency-domain reconstruction, time-frequency joint scoring

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 杜睿山, durs918@163.com

基金项目: 国家重点研发计划项目(2022YFE206800); 东北石油大学人才引进科研启动经费资助项目(13051202402)

Foundation Items: The National Key Research and Development Program of China (No. 2022YFE206800), the Scientific Research Startup Foundation for Introduced Talents of Northeast Petroleum University (No. 13051202402)

0 引言

多维时间序列异常检测旨在从多个变量构成的时序数据中识别偏离正常分布的点或区域,在工业状态监测、设备故障预警、网络安全与金融风控等领域具有重要应用价值^[1]。及时发现异常能够有效保障系统的安全运行,并降低经济损失。例如,在工业场景中,对设备运行数据进行异常检测有助于减少停机和维护成本^[2]。在金融交易中识别异常交易信息有助于减少资金流失^[3]。

近年来,基于重构的方法因其强大的非线性表征能力得到了广泛应用^[4]。该类方法通常通过学习正常序列的重构模式,并利用重构偏差识别异常。然而,异常既可能表现为单个时刻的突发偏离,也可能表现为更为复杂的序列模式的异常^[5]。此类异常伴随波动结构的改变,而频率特征能够从结构组成层面反映这种变化。在重构过程中充分利用频率特征,有助于增强重构误差对不同异常模式的区分能力^[6]。Su 等^[7]提出 OmniAnomaly 模型,通过随机变量连接和归一化流学习多变量时间序列的鲁棒隐表示,并利用重构概率判断异常,但其主要从序列隐空间建模正常模式,对异常引起的频率成分变化缺少显式刻画。Audibert 等^[8]提出 USAD 方法,利用对抗训练的自编码器学习正常序列的重构模式,并通过重构误差隔离异常,但该方法主要依赖窗口级重构偏差,对频率结构信息的利用仍不充分。Tuli 等^[9]提出 TranAD 模型,通过 Transformer 编码器—解码器、自条件机制和对抗训练放大异常重构误差,以提高多变量时间序列异常检测效果,但其重点在于增强时序窗口重构能力,对频率特征差异的建模仍较有限。

此外,多维时间序列中的异常往往包含通道间协同关系的异常变化。模型难以有效刻画复杂的通道交互模式,导致其对正常联合模式的学习能力减弱,进而影响异常检测效果。围绕这一问题,现有研究主要从 MLP、Transformer 和 GNN 等机制展开^[10-11]。Zhong^[12]将时间序列异常检测问题转化为多尺度 patch 表示下的轻量级 MLP-Mixer 表征学习问题,旨在通过混合操作提高异常模式表征能力,但其跨通道关系主要隐含于共享混合权重之中,难以显式区分正常状态下稳定的协同模式及其异常破坏形态。Wang 等^[13]将多维时序异常检测问题视为多尺度 patch 下的时空混合问题,通过 Temporal-

Mixer 与 Spatial-Mixer 联合刻画组内和组间依赖,但其跨通道交互仍主要依赖密集混合,缺少对有效交互与冗余交互的显式筛选。Liu 等^[14]将重构类异常检测中过拟合异常模式的问题转化为重构趋势引导下的 Transformer 建模问题,通过全局注意力与自条件机制增强异常可分性,但其建模更偏向趋势级全局依赖,对通道间具体交互形态变化的表达仍较为间接。Xie 等^[15]将异常检测中的依赖学习问题视为粗粒度变量内时间依赖和变量间关系捕获问题,通过多尺度 attention map 与原型交互学习时序和变量依赖,但其主要关注粗粒度依赖显著性,对正常联合模式中更细致的协同变化的刻画缺乏直接的结构表达。Liu 等^[16]将多维时序异常检测中的跨变量关系建模问题转化为图注意力与拓扑特征联合增强问题,以提升图结构对变量依赖的表达能力,但其图关系仍主要服务于传播与聚合,对哪些通道交互最能表征异常缺少更直接的差异化刻画。Wang 等^[17]将传感器关系建模为带时延的动态图学习过程,通过动态图结构学习、图卷积传播和多尺度时间特征提取完成异常检测,但其建模重心仍在关系演化与传播过程本身,对交互模式如何直接增强异常表征、如何抑制无效交互的考虑相对不足。

以上方法取得了良好的效果,但仍然存在以下问题:一是现有频域建模方法多从整体频谱对序列进行建模,难以表示不同频率范围的结构特征信息,导致模型对复杂模式异常的识别能力受限。二是现有方法对通道交互模式的表达不足,导致模型难以充分学习正常联合模式。同时,无效的通道交互还会削弱异常的特征表征能力。针对上述挑战,本文提出一种异常检测方法 TFDG-AD(Time-series Frequency-domain Dynamic Graph-based Anomaly Detection)。主要贡献如下:

(1) 提出一种面向多维时间序列的频域重构异常检测框架。该框架将序列映射到频域并进行子频段级细粒度建模,以增强局部频段异常特征的可分性,并为后续通道交互表示增强提供统一的子频段表示。

(2) 设计子频段动态通道交互表示增强模块。该模块以子频段表示为输入,自适应学习通道间非对称依赖关系,并通过稀疏化与归一化构建通道图,并结合残差式图传播机制进行交互增强,从而提升模型对多通道关联变化的刻画能力,为后续重

构模块提供更具判别性的输入表示。

(3) 在多个公开数据集上开展了对比实验、消融实验与参数敏感性分析, 验证了所提方法的有效性。

1 方法

为了充分刻画不同频率范围内的局部异常结构以及通道交互模式表达, 本文将完整频谱划分为多个局部频率片段。为每个子频段自适应学习通道关系图, 并通过残差式图传播增强频段相关的通道交互特征。最后利用频域表示进行序列重构, 并依据重构偏差计算异常分数。

设输入多维时间序列为 $\mathbf{X} \in \mathbb{R}^{N \times T}$, 其中 N 为通道数, T 为长度。记 $X_{n,t}$ 为第 n 个通道在时刻 t 的观测。 $\mathbf{x}_t = [x_{1,t}, \dots, x_{n,t}]^T \in \mathbb{R}^N$ 表示在时刻 t 的多通道观测。模型的完整架构如图 1 所示。

1.1 子频段表征构建

多维时间序列中的异常并不总是以统一的频率模式出现, 不同异常往往对应不同频率范围内的局部扰动或结构偏移。如果仅基于整体建模, 容易削弱局部异常模式的可行性。为此, 本文在频域上引入子频段级建模机制, 构造更细粒度的频段表示。

子频段划分能够将不同频率范围内的响应分离表示, 使局部频率扰动在对应频段内更加集中地显

现, 从而增强局部频率异常特征的可行性。首先对输入进行实例归一化, 以缓解训练和测试阶段统计差异带来的分布偏移。随后使用快速傅里叶变换将时域序列映射到频域, 同时保留实部与虚部以避免信息损失。为了在频域实现细粒度建模, 本文将频谱沿频率轴划分为 L 个互不重叠的子频段:

$$\mathbf{X}_R, \mathbf{X}_I = \text{FFT}(\mathbf{X}) \quad (1)$$

$$\mathbf{P}_1^R, \dots, \mathbf{P}_L^R = \text{Patching}(\mathbf{X}_R) \quad (2)$$

$$\mathbf{P}_1^I, \dots, \mathbf{P}_L^I = \text{Patching}(\mathbf{X}_I)$$

其中 $\mathbf{X}_R, \mathbf{X}_I$ 分别表示输入序列的频谱实部和虚部。 $\mathbf{P}_i^R, \mathbf{P}_i^I$ 表示 $\mathbf{X}_R, \mathbf{X}_I$ 在第 i 个子频段的切片。为使模型充分获取子频段的完整信息, 将实部与虚部沿特征维度拼接得到:

$$\mathbf{P}_i = \text{Concat}(\mathbf{P}_i^R, \mathbf{P}_i^I) \quad (3)$$

然而, 不同子频段之间可能存在尺度差异和分布差异, 若直接用于建模, 容易影响后续通道图构建的稳定性。本文引入投影层对 $\mathbf{P}_i \in \mathbb{R}^{N \times 2p}$ 进行特征映射, 将子频段映射到高维嵌入空间 $\mathbf{P}_i' \in \mathbb{R}^{N \times d}$, 并对所有子频段复用一组投影层的参数。

$$\mathbf{P}_i' = \text{Projection}(\mathbf{P}_i) = \text{GELU}(\mathbf{P}_i \mathbf{W}_p + b_p) \quad (4)$$

$\mathbf{W}_p$ 和 b_p 分别为共享特征映射层的权重矩阵和偏置项。通过映射模型得到子频段通道表示 $\mathbf{P}_i'$, 为后续构建动态通道关系图提供输入。




图 1 TFDG-AD 网络架构

1.2 通道交互增强

不同通道之间往往存在不同的交互模式，而这些交互关系在不同频段下可能表现出明显差异。低频成分通常反映整体趋势或周期结构，高频成分更容易包含局部扰动或瞬时变化，因此不同子频段中的通道交互模式可能存在差异。若所有子频段共享同一通道关系图，则难以刻画频段相关的交互变化。基于此，本文设计子频段通道交互增强模块，在每个子频段内自适应学习通道交互结构，并通过图传播来增强通道表征。

为了给后续图传播提供通道关系结构，在每个子频段内构建通道依赖图，并且考虑到通道间可能存在的非对称依赖关系，本文将子频段表示 $\mathbf{P}'_i$ 映射到两个潜在嵌入空间：

$$\begin{aligned} \mathbf{E}_i^{(1)} &= \mathbf{P}'_i \mathbf{W}_1 \\ \mathbf{E}_i^{(2)} &= \mathbf{P}'_i \mathbf{W}_2 \end{aligned} \quad (5)$$

$\mathbf{W}_1, \mathbf{W}_2 \in \mathbb{R}^{d \times d_s}$ 为可学习参数矩阵，基于两组嵌入表示。上述构造方式能够显式保留通道关系的方向性，从而避免将通道交互关系简化为对称相似性。定义第 i 个子频段的原始通道关联矩阵为 $\mathbf{S}_i$ ，对 $\mathbf{S}_i$ 施加非线性变换，得到初始关联矩阵 $\mathbf{A}_i^{\text{raw}}$ ：

$$\mathbf{S}_i = \mathbf{E}_i^{(1)} \mathbf{E}_i^{(2)\top} - \mathbf{E}_i^{(2)} \mathbf{E}_i^{(1)\top} \quad (6)$$

$$\mathbf{A}_i^{\text{raw}} = \text{ReLU}(\tanh(\alpha \mathbf{S}_i)) \quad (7)$$

其中， α 为缩放系数。通过上述操作，模型能够根据当前子频段内不同通道的频域表示，自适应学习更具判别性的通道交互结构。

考虑到同一子频段内有效的通道依赖通常具有稀疏性，若保留全部通道连接，容易引入无关通道信息并削弱表示的判别能力。因此，本文对原始通道关系矩阵 $\mathbf{A}_i^{\text{raw}}$ 进行按行 TopK 稀疏化：

$$\mathbf{A}_i = \text{TopK}(\mathbf{A}_i^{\text{raw}}, k) \quad (8)$$

对每个通道节点仅保留关系强度最大的 k 个邻居，其余位置置为 0。经过稀疏化后得到通道关系矩阵 $\mathbf{A}_i \in \mathbb{R}^{N \times N}$ 。为保证后续图传播过程的稳定性，在 $\mathbf{A}_i$ 上加入自环以保留节点自身信息，并利用度矩阵 $\mathbf{D}_i$ 对通道关系进行归一化处理，从而平衡不同节点连接度差异对邻域聚合的影响，得到归一化后的稀疏通道关系图：

$$\widehat{\mathbf{A}}_i = \mathbf{D}_i^{-\frac{1}{2}} (\mathbf{A}_i + \mathbf{I}) \mathbf{D}_i^{-\frac{1}{2}} \quad (9)$$

$$(\mathbf{D}_i)_{r,r} = \sum_{c=1}^N (\mathbf{A}_i + \mathbf{I})_{r,c} \quad (10)$$

得到归一化后的稀疏通道关系图 $\widehat{\mathbf{A}}_i$ 后，为使通道关系进一步作用于特征表达，在该图上进行图传播，聚合相关通道信息，使每个通道节点能够结合邻居特征进而感知同一子频段内的协同变化。

在图传播过程中需要同时依赖通道关系结构 $\widehat{\mathbf{A}}_i$ 和初始节点特征，初始节点特征需要同时保留当前子频段内实部与虚部共同决定的幅值变化和相位变化的完整信息。因此，本文将具有完整信息的 $\mathbf{P}'_i$ 线性映射至图传播空间，以构建初始节点特征。

$$\mathbf{H}_i^{(0)} = \phi(\mathbf{P}'_i) \quad (11)$$

其中 $\mathbf{H}_i^{(0)} \in \mathbb{R}^{N \times d}$ ， ϕ 为可学习映射，用于将子频段表示投影到图传播空间，从而在保留频域特征的同时，增强节点表示对跨通道交互结构的适配性。随后，采用残差式图传播机制实现跨通道信息聚合。设第 m 层传播后的节点表示为 $\mathbf{H}_i^{(m)}$ ，则第 $m+1$ 层传播定义为 $\mathbf{H}_i^{(m+1)}$ 。

$$\mathbf{H}_i^{(m+1)} = \beta \mathbf{H}_i^{(0)} + (1 - \beta) \widehat{\mathbf{A}}_i \mathbf{H}_i^{(m)} \quad (12)$$

其中， m 表示图传播层数， $\beta \in [0, 1]$ 为原始节点特征保留系数。该传播方式通过 $\widehat{\mathbf{A}}_i$ 聚合相关通道信息，显式建模子频段内通道交互。同时通过残差项保留初始子频段特征，以缓解图传播过程中可能出现的过平滑问题。经过 m 层传播后，得到融合通道关系信息的子频段表示 $\mathbf{H}_i$ ，通过输出映射函数 ψ 得到通道交互增量表示 $\mathbf{U}_i$ ，最后，通过残差连接得到增强后的第 i 个子频段的通道交互表示 $\widetilde{\mathbf{P}}_i$ 。

$$\mathbf{H}_i = \mathbf{H}_i^{(M)}, \mathbf{U}_i = \psi(\mathbf{H}_i) \quad (13)$$

$$\widetilde{\mathbf{P}}_i = \mathbf{P}'_i + \mathbf{U}_i \quad (14)$$

由此得到的 $\widetilde{\mathbf{P}}_i$ 既保留了原始子频段中的局部频域结构，又融合了同一频段内相关通道的协同变化信息，并将其作为后续重构模块的输入。

1.3 重构模块

经过上述模块后，模型得到各子频段上的通道交互表示 $\widetilde{\mathbf{P}}_i$ ，为了将学习到的子频段级表示恢复到原始信号空间，本文构建重构模块。通过分别重构频谱实部与虚部，模型能够保留频域表示中的幅值和相位相关信息。再经逆快速傅里叶变换 iFFT 恢复时域序列 $\mathbf{X}'$ ，使频域结构偏差最终能够反映到时

域重构误差中。该过程为后续时频联合评分提供了统一的重构基础。具体表示为:

$$\mathbf{P}'_R, \mathbf{P}'_I = \text{Proj}(\text{Flatten}(\{\tilde{\mathbf{P}}_i\}_{i=1}^L)) \quad (15)$$

$$\mathbf{X}' = \text{iFFT}(\mathbf{P}'_R, \mathbf{P}'_I) \quad (16)$$

其中 $\mathbf{P}'_R, \mathbf{P}'_I \in \mathbb{R}^{N \times T}$ 分别表示重构频谱的实部与虚部, Flatten 表示将每个通道在所有子频段上的特征按子频段顺序串接并展平, Proj 为投影映射。频域重构能够保留不同子频段上的谱结构信息, 从而增强模型对频率模式偏离程度的刻画能力, 而时域重构能够恢复原始序列的整体变化趋势, 为异常评分提供依据。

1.4 损失函数

为了约束模型学习正常数据在时域与频域上的稳定结构, 本文采用时域重构损失与频域重构损失共同训练模型。时域重构损失用于衡量模型对原始序列整体时序形态的恢复能力, 频域重构损失用于衡量模型对频谱结构及频率成分的恢复能力。通过优化这两个目标, 模型能够同时学习正常样本在时域和频域上的一致性表示。具体定义如下:

$$L_{\text{rec}} = \|\mathbf{X} - \mathbf{X}'\|_F^2 \quad (17)$$

$$L_{\text{freq}} = \|\mathbf{X}_R - \mathbf{P}'_R\|_1 + \|\mathbf{X}_I - \mathbf{P}'_I\|_1 \quad (18)$$

$$L = L_{\text{rec}} + \lambda_f \cdot L_{\text{freq}} \quad (19)$$

其中 λ_f 为平衡系数, 用于调节时域重构项与频域重构项之间的权重。模型能够同时降低时域和频域偏差, 为后续异常评分提供稳定基础。

1.5 异常评分

在模型中, 异常评分用来衡量输入序列偏离正常模式的程度。由于模型主要通过正常样本学习时域形态与频域结构之间的重构关系, 当测试样本符合正常模式时, 其时域局部重构误差和频域谱结构重构误差均应保持较低; 当样本出现突发偏离、周期变化或局部模式异常时, 正常重构关系被破坏, 相应时域重构误差或频域重构误差升高。因此, 时域异常分数和频域异常分数均需作为异常判别依据。时域异常分数 S_{temp} 用于刻画当前时刻的局部重构偏差, 频域异常分数 S_{freq} 用于刻画当前分析窗口的整体谱结构的偏离程度。并将其加权融合为最终异常分数:

$$\text{Score} = S_{\text{temp}}(t) + \lambda_{\text{score}} S_{\text{freq}} \quad (20)$$

其中, λ_{score} 为平衡系数, 该参数并非模型训练过程

中自动学习的参数。考虑到不同数据集在频率结构和异常模式方面存在差异, 本文在预设候选集合内采用网格搜索, 并根据验证集性能确定各数据集对应的参数取值, 在测试阶段保持固定。

对于时域异常分数, 本文采用当前判别时刻的点点级重构误差进行度量。

$$S_{\text{temp}}(t) = \frac{1}{N} \sum_{n=1}^N (X_n(t) - X'_n(t))^2 \quad (21)$$

其中, $X_n(t)$ 和 $X'_n(t)$ 分别表示第 n 个通道在时刻 t 的真实观测值与重构值。时域分数 S_{temp} 能够直接反映当前时刻在时域上的局部偏差, 因此对突发性的点点级异常较为敏感。

对于频域异常分数, 本文采用当前分析窗口整体频谱的平均偏差进行度量。随后以幅度谱之间的平均绝对误差 (MAE) 刻画频域偏差:

$$S_{\text{freq}} = \frac{1}{N} \sum_{n=1}^N \frac{1}{F} \sum_{f=1}^F |M_n(f) - M'_n(f)| \quad (22)$$

$$M_n(f) = \sqrt{X_{R,n}(f)^2 + X_{I,n}(f)^2} \quad (23)$$

$$M'_n(f) = \sqrt{X'_{R,n}(f)^2 + X'_{I,n}(f)^2} \quad (24)$$

其中 $M_n(f)$ 与 $M'_n(f)$ 分别表示对应的原始幅值谱与重构幅值谱。 $X_{R,n}(f)$ 、 $X_{I,n}(f)$ 与 $X'_{R,n}(f)$ 、 $X'_{I,n}(f)$ 分别表示原始和重构频谱在频点 f 处的实部和虚部。

本文通过综合异常分数将重构偏差作为异常判别依据, 分数越高表示当前样本偏离正常模式的程度越大。

1.6 基于TFDG-AD的异常检测

为了更加清晰地说明模型的执行过程, 并提高所提方法的可复现性, 本文将TFDG-AD的完整流程划分为模型训练和异常检测两个阶段, 如算法1和算法2所示。训练阶段主要利用正常训练序列学习子频段表示、动态通道关系和双域重构映射, 并通过联合重构损失更新模型参数。检测阶段将待测序列输入训练好的模型, 依次获得时域重构结果、频域重构结果和综合异常分数。

算法1 TFDG-AD模型训练

输入: 正常训练序列集合 $\mathbf{X}_{\text{train}}$, 子频段长度 p , 子频段数量 L , 训练轮数 E , 批量大小 B , 频域损失权重 λ_f

输出: 训练好的 TFDG-AD 模型 Θ

算法2 TFDG-AD模型检测

```

1.      初始化模型参数  $\Theta$ 
2.      for epoch = 1,2,...,E do
3.      for each training iteration do
4.      从  $\mathbf{X}_{\text{train}}$  中选取一批训练序列  $\mathbf{X}$ 
5.      对  $\mathbf{X}$  进行实例归一化, 得到  $\mathbf{X}^{\text{norm}}$ 
6.      根据式 (1) 至式 (4) 得到频谱实部  $\mathbf{X}_R$ 、虚部  $\mathbf{X}_I$  和子频段表示  $\{\mathbf{P}'_i\}_{i=1}^L$ 
7.      for  $i = 1,2,\dots,L$  do
8.      根据式 (5) 至式 (10) 构建第  $i$  个子频段的归一化通道关系图  $\hat{A}_i$ 
9.      根据式 (11) 至式 (14) 得到第  $i$  个子频段的通道交互增强表示  $\tilde{P}_i$ 
10.     end for
11.     根据式 (15) 和式 (16) 得到重构序列  $\mathbf{X}'$ 
12.     根据式 (17) 至式 (19) 计算训练损失
13.     最小化训练损失, 更新模型参数  $\Theta$ 
14.     end for
15.     根据验证集损失保存最优模型参数
16.     end for
17.     返回训练好的 TFDG-AD 模型  $\Theta$ 

```

输入待检测序列 $\mathbf{X}$, 训练好的 TFDG-AD 模型 Θ , 评分权重 λ_{score}
 输出: 综合异常分数 Score

```

1.      将待检测序列  $\mathbf{X}$  输入训练好的 TFDG-AD 模型  $\Theta$ 
2.      根据式 (1) 至式 (16) 得到重构序列  $\mathbf{X}'$ 
3.      根据式 (21) 计算时域异常分数  $S_{\text{temp}}(t)$ 
4.      根据式 (22) 至式 (24) 计算频域异常分数  $S_{\text{freq}}$ 
5.      根据式 (20) 计算综合异常分数  $\text{Score}(t)$ 
6.      返回综合异常分数 Score

```

2 实验

2.1 数据集

本文实验使用的数据集包括: 由美国国家 NASA 采集的 MSL^[18] 和 SMAP^[18] 数据集, 分别记录火星探测器的传感器运行状态与土壤遥测信息。PSM^[19] 数据集来自 eBay 服务器, 包含 25 维公共检测指标。以及 SMD^[7] 数据集, 收集自一家互联网公司计算集群, 包含了 28 台机器的资源利用率访问记录。WADI^[20] 是工业控制系统领域常用的水分配系统异常检测数据集, 包含 123 个传感器与执行器变量。

表 1 数据集介绍

数据集	维度	训练集	测试集	异常比例/%
MSL	55	58317	73729	10.5
SMAP	25	135183	427617	12.8
SMD	38	566724	708420	4.2
PSM	25	132481	87841	27.8
WADI	123	1209601	172801	5.71

2.2 评估指标

本文采用基于关联度的片段级指标 Affiliated-F1-score (Aff-F1)^[21] 和 阈值无关的 AUC-ROC (A-R)^[22] 作为主要评价指标。Aff-F1 更关注连续片段的连续性和完整性。其定义为:

$$\text{Aff-F1} = 2 \cdot \frac{P \cdot R}{P + R} \quad (25)$$

$$P = \frac{1}{m} \sum_{i=1}^m p_i \quad (26)$$

$$R = \frac{1}{m} \sum_{i=1}^m r_i \quad (27)$$

其中, m 表示真实异常事件区间的数量, p_i 和 r_i 分别表示第 i 个真实异常事件对应的准确率和召回率。

AUC-ROC 通过考察全部可能的决策阈值, 减

小了由单一阈值选取所引入的评估偏差。AUC-ROC 值越高,说明异常分数对正常点和异常点的整体区分能力越强。

2.3 实验设置

所有实验在处理器 Intel CoreTM i9-14900KF、显卡 NVIDIA Ge-Force RTX 4090 24 GB、Python 3.9、CUDA11.8 环境下进行。训练过程中输入窗口长度 window size 默认设为 192,初始学习率为 0.0001,优化器选择为 Adam。

2.4 对比实验

本文将所提方法 TFDG-AD 与 11 种基线方法进行综合对比评估。将基线方法主要划分为两类:第一类为时域方法,包括基于扩散重构的方法 PhysDiff^[23],基于纯卷积时序建模的方法 ModernTCN^[24],基于对比学习的方法 DCdetector^[25],基于通用时序分析骨干网络的方法 TimesNet^[26],基于线性建模的方法 DLinear^[27] 和 NLinear^[27],基于重构的方法 AutoEncoder^[28],以及基于传统机器学习方法的 iForest^[29]。引入频域信息的方法 DualTF^[30]、TFAD^[31]和 FEDformer^[32],其中,TFAD 和 DualTF 通过时频建模增强异常检测能力,FEDformer 采用频率增强分解来提升长序列预测性能。近年来多项异常检测研究将其作为基线使用。

比较表 3 可以发现与 ModernTCN、DLinear、NLinear、TimesNet 等时域建模方法相比,TFDG-AD 在五个数据集上均保持领先,尤其在 SMD 和 PSM 上优势更为明显。这表明,仅依赖时域模式建模虽然能够捕获局部时序变化,但对多维场景下的复杂模式异常的刻画仍显不足。相较于仅在时域进行模式建模的方法,

引入频域信息后更有利于刻画序列中的复杂模式,从而提升异常检测性能。

此外,比较 FEDformer、TFAD 和 DualTF 等引入频域或时频信息的方法可以发现,FEDformer 取得了较好的性能,说明频域增强机制有助于提升模型对整体周期结构和频率变化的感知能力。TFAD 和 DualTF 联合频域增强异常表征能力,但整体性能仍存在一定波动。说明本文采用的细粒度子频段建模与子频段通道交互增强策略,较其他频域方法更有利于保留局部频率结构并刻画跨通道关联,提升异常检测效果。

部分基线方法在 Aff-F1 和 A-R 指标上存在明

显分化。例如,TimesNet 和 AutoEncoder 在 SMD 数据集上具有较高的 Aff-F1,但 A-R 较低。相比之下,TFDG-AD 在 5 个数据集的两项指标上均保持较高水平,说明所提方法既能较好地识别连续异常片段,又具有较为均衡的整体异常判别能力。

为进一步验证模型训练结果的稳定性,本文在 MSL 和 SMD 数据集上采用不同随机种子重复运行 5 次,并统计 Aff-F1 和 A-R 的均值与标准差,结果如表 2 所示。实验过程中除随机种子外,其余设置均与主实验保持一致,以减少额外因素对结果波动的影响。可以看出,TFDG-AD 在两项指标上的标准差均较小,说明模型在不同随机初始化下性能波动较小,在重复实验中具有较好的稳定性。

综上,本文所提模型能够更有效学习时间序列中的异常模式,引入的细粒度子频段建模和通道交互增强策略进一步提升了模型的异常表征能力和检测效果。

表 2 模型稳定性实验结果

数据集	指标	均值/标准差
MSL	Aff-F1	0.744±0.012
MSL	A-R	0.635±0.006
SMD	Aff-F1	0.850±0.011
SMD	A-R	0.814±0.006

2.5 消融实验

为验证 TFDG-AD 模型中各核心模块的有效性,本文在五个数据集上进行了消融实验,性能指标 Aff-F1 的结果如表 4 所示,具体如下:

(1) TFDG w/o B: 在 TFDG-AD 原始模型中去除了子频段表征构建模块,不再对频谱进行局部子频段划分,而是直接基于整体频域表示完成后续通道关系编码与重构。

(2) TFDG w/o G: 在 TFDG-AD 原始模型中去除了子频段动态通道关系编码模块,使用简单特征变换替代通道关系编码。

(3) TFDG-UR: 在 TFDG-AD 原始模型中将子频段动态通道关系建模替换为统一建模方式,不再针对不同子频段分别自适应学习通道关系,而是在所有子频段上共享同一关系结构。

(4) TFDG w/o F: 在 TFDG-AD 原始模型中去除了频域评分分支,仅保留时域重构误差进行异常

表 3

不同模型的实验结果

模型	MSL		SMAP		SMD		PSM		WADI	
	Aff-F1	A-R	Aff-F1	A-R	Aff-F1	A-R	Aff-F1	A-R	Aff-F1	A-R
PhysDiff ^[23] (2025)	0.627	0.538	0.643	0.579	0.713	0.578	0.660	0.472	0.694	0.545
ModernTCN ^[24] (2024)	0.726	0.633	0.635	0.455	0.835	0.714	0.825	0.593	0.610	0.587
DCdetector ^[25] (2023)	0.694	0.507	0.683	0.522	0.668	0.501	0.682	0.501	0.731	0.528
TimesNet ^[26] (2023)	0.734	0.613	0.638	0.453	0.793	0.288	0.842	0.592	0.724	0.557
DLinear ^[27] (2023)	0.725	0.624	0.616	0.397	0.836	0.721	0.831	0.580	0.708	0.548
NLinear ^[27] (2023)	0.723	0.592	0.601	0.434	0.845	0.742	0.843	0.585	0.714	0.552
AutoEncoder ^[28] (2014)	0.625	0.562	0.463	0.522	0.451	0.763	0.707	0.650	0.612	0.638
iForest ^[29] (2008)	0.584	0.524	0.512	0.487	0.634	0.673	0.620	0.542	0.642	0.603
DualTF ^[30] (2024)	0.588	0.576	0.674	0.478	0.695	0.567	0.725	0.600	0.693	0.612
TFAD ^[31] (2022)	0.665	0.500	0.675	0.500	0.686	0.500	0.628	0.500	0.628	0.535
FEDformer ^[32] (2022)	0.696	0.608	0.691	0.593	0.840	0.799	0.851	0.647	0.734	0.639
TFDG-AD	0.745	0.634	0.696	0.598	0.849	0.815	0.853	0.663	0.762	0.669

判别。

以上 4 种方法在各数据集上的性能结果如表 4 所示。整体来看, 去除子频段分块机制后, 模型平均性能下降明显, 说明子频段级细粒度建模能够更充分地刻画不同频率范围内的异常结构信息。去除频域评分分支后, 模型在 5 个数据集上的 Aff-F1 均有不同程度下降, 表明仅依赖时域重构误差难以全面反映异常样本中的频谱偏移和结构变化, 频域评分能够为异常判别提供有效补充, 从而增强模型的综合检测能力。

进一步地, 采用统一关系编码策略的 TFDG-UR 和 TFDG w/o G 在 5 个数据集上的性能均低于完整模型。这说明动态的通道表示增强模块对模型性能提升具有更为关键的作用。一方面, 动态通道关系编码能够在子频段表示基础上更充分地组织有效通道关联信息。另一方面更有利于刻画复杂通道关系变化, 从而进一步提升异常检测精度。

综合来看, 完整的 TFDG-AD 模型通过子频段细粒度建模、动态通道关系编码以及时频域评分的协同作用, 在不同数据集上均取得了最优结果, 在 WADI 高维数据集上, 各消融变体均出现不同程度下降, 进一步验证了各模块在复杂通道交互场景下的有效性。

2.6 参数敏感性实验

为探究关键超参数对 TFDG-AD 模型的鲁棒性和稳定性的影响, 本文在 MSL、SMAP、SMD 和

表 4 不同数据集的消融实验

模型	MSL	SMAP	SMD	PSM	WADI
	Aff-F1				
TFDG-AD	0.745	0.696	0.849	0.853	0.762
w/o B	0.728	0.684	0.830	0.818	0.733
TFDG-UR	0.723	0.681	0.823	0.806	0.720
w/o G	0.692	0.658	0.792	0.801	0.704
w/o F	0.732	0.688	0.835	0.825	0.740

PSM 数据集分析了训练批大小 Batch Size、双域评分权重 λ_{score} 以及频域分块长度 Patch Size 对 A-R 指标的影响。三者分别对应子频段表征建模粒度、模型训练稳定性以及时域与频域异常分数的融合比例。具体分析结果如图 2 所示。

(1) 训练批大小. 在不同 Batch Size 下, 各数据集的检测性能整体变化较为平缓。当 Batch Size=32 时, MSL 和 PSM 数据集的 A-R 取最优值, 当 Batch Size=16 时, SMAP 数据集效果最佳。而 SMD 在 Batch Size=64 时达到最优。总体而言, Batch Size 的变化未造成明显的性能波动, 说明模型在候选训练批大小范围内具有一定适应性。

(2) 评分权重. 评分权重 λ_{score} 用于平衡时域异常分数与频域异常分数。模型在不同权重下整体保持较为稳定的检测效果。从实验结果看, MSL 在 $\lambda_{score}=0.05$ 时取得最优值, SMAP 和 SMD 在 $\lambda_{score}=0.1$ 时表现最好, PSM 则在 $\lambda_{score}=0.02$ 时达到最优。

(3) 频域分块长度. 从整体趋势来看, 模型在不同 Patch Size 下均保持了较为稳定的检测性能。当 Patch Size=32 时, MSL 数据集的 A-R 取最优值。当 Patch Size=16 时, SMAP 和 PSM 数据集的 A-R 最高, 而 SMD 数据集在较大分块长度下表现最好。不同数据集的最优取值存在一定差异, 这可能与各数据集局部频率结构的差异有关。

综上, TFDG-AD 在不同参数设置下整体保持了较为稳定的检测性能。不同数据集存在相对合适的参数取值, 这与数据集自身的频率结构、异常类型和通道变化模式差异有关。实验结果表明, 本文方法不依赖单一严格参数取值, 在合理参数范围内具有较好的参数鲁棒性。

2.7 复杂度分析

为评估模型的计算开销, 本文分析了不同方法在同一配置下的时间复杂度和参数量, 并以测试阶段推理时间和训练阶段峰值 GPU 显存占用分别衡量推理效率与训练资源开销。本文推理时间统计模型训练完成后在测试集上前向推理并计算异常分数的耗时, 不包含训练、反向传播和参数更新等开销。表 5 中的推理时间为测试阶段批量推理后折算得到的平均单窗口耗时。

设输入序列长度为 T , 通道数为 N , 子频段数量为 L , 图传播层数为 M , 特征维度为 d 。TFDG-AD 进行频域映射以及变换的复杂度为 $NT \log T$ 。在完整通道关系下, 动态图构建与残差图传播的主要复杂度为 MLN^2d , 实际实现中, 稀疏化操作能够降低计算开销, 但由于通道关系建模涉及通道关联, 本文仍采用完整通道关系下的上界估计。双域特征重构复杂度近似为 $N(Ld)^2$ 。因此, 模型的主要时间复杂度为 $O(NT \log T + MLN^2d + N(Ld)^2)$ 。

如表 5 所示。TFDG-AD 能够保持较低的平均

单窗口推理时间, 与参数量相差较大的 AutoEncoder 接近。这是因为推理时间还受到多因素影响^[33], 比如计算算子类型、并行度、窗口展开与聚合方式等。而模型参数量主要反映模型可训练权重规模, 并不能完全反映实际推理耗时。如 TFAD 虽然参数量较小, 但其推理过程涉及序列分解、时频域双分支编码以及滑动窗口聚合等额外的计算和数据处理开销。TFDG-AD 的主要计算由频域映射、矩阵运算以及稀疏化后的图传播组成, 具有较好的并行性。同时, 稀疏化通道交互减少了冗余通道关系带来的额外计算。

2.8 异常检测可视化

为更直观展示本文方法的异常检测效果, 本文从 NeurIPS-TS^[34] 数据集中分别选取一段点异常和模式异常样例进行可视化分析。该数据集对点异常和模式异常样例进行了明确标注, 便于分析模型对不同异常形态的响应。

图 3 展示了点异常和模式异常样例下原始序列、重构序列及异常分数的变化。可以看出, 在正常区间内, 重构序列与原始序列整体趋势较为一致; 在异常位置附近, 二者之间的偏差明显增大, 并在异常分数中形成峰值响应。对于点异常, 异常分数主要在局部突发位置升高; 对于模式异常, 异常分数在异常片段内持续升高, 说明所提方法能够对不同异常形态产生有效响应。

整体来看, 对于突发点异常和模式异常, 本文模型都能够在正常区间保持较好的模式学习与重构能力, 验证了本文方法在不同异常模式下的异常检测能力。

3 结束语

本文提出了一种基于频域通道交互增强的多维




图 2 参数敏感性分析结果

表 5

复杂度分析

模型	时间复杂度	参数量/M	推理时间/ms	GPU 显存/GB
AutoEncoder	$O\left(Dh_1 + \sum_j h_j h_{j+1}\right)$	0.10	0.68	0.4
ModernTCN	$O\left(N \sum_j T_j (k_j d_j + d_j^2)\right)$	0.11	0.89	1.9
DCdetector	$O(P_s T^2 d)$	0.87	1.12	3.7
DualTF	$O(T^2 d + F^2 d)$	9.72	2.98	5.8
TFAD	$O\left(T^3 + NT \log T + T \sum_j k_j c_{j-1} c_j\right)$	0.30	8.91	2.2
TFDG-AD	$O(NT \log T + MLN^2 d + N(Ld)^2)$	4.36	0.70	3.1




图 3 异常检测可视化分析

时间序列异常检测方法 TFDG-AD。该方法通过构建细粒度子频段表示,学习不同频率范围内的特征,并利用动态通道图学习与残差式图传播增强多通道交互表示,最后结合时域与频域重构误差进行异常评分。多个公开数据集上的实验结果表明,TFDG-AD 在检测性能上优于多种基线方法。消融实验和参数敏感性分析进一步验证了细粒度子频段划分、通道交互增强以及时频联合评分策略的有效性。

不过本文仍存在一定的改进空间,对于运行状态快速切换或频率成分局部突变的非平稳序列,固

定窗口内的频域表示可能难以充分描述其瞬时变化。未来可引入小波变换等多分辨率时频分析方法,以增强模型对局部非平稳频率变化的刻画能力。

参考文献:

- [1] Wang F, Jiang Y, Zhang R, et al. A survey of deep anomaly detection in multivariate time series: taxonomy, applications, and directions[J]. Sensors, 2025, 25(1): 190.
- [2] Garcia J, Rios-Colque L, Peña A, et al. Condition monitoring and predictive maintenance in industrial equipment: an NLP-assisted review of signal processing, hybrid models, and implementation challenges[J]. Ap-

- plied Sciences, 2025, 15(10): 5465.
- [3] Wu Y, Wang L, Li H, et al. A deep learning method of credit card fraud detection based on continuous-coupled neural networks[J]. Mathematics, 2025, 13(5): 819.
 - [4] Pang G, Shen C, Cao L, et al. Deep learning for anomaly detection: a review[J]. ACM Computing Surveys, 2021, 54(2): 1-38.
 - [5] Sui J, Yu J, Song Y, et al. Anomaly detection for telemetry time series using a denoising diffusion probabilistic model[J]. IEEE Sensors Journal, 2024, 24(10): 16429-16439.
 - [6] 段雪源, 付钰, 王坤, 等. 基于多尺度特征的网络流量异常检测方法[J]. 通信学报, 2022, 43(10): 65-76.
Duan X Y, Fu Y, Wang K, et al. Network traffic anomaly detection method based on multi-scale characteristic[J]. Journal on Communications, 2022, 43(10): 65-76.
 - [7] Su Y, Zhao Y, Niu C, et al. Robust anomaly detection for multivariate time series through stochastic recurrent neural network[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2019: 2828-2837.
 - [8] Audibert J, Michiardi P, Guyard F, et al. USAD: unsupervised anomaly detection on multivariate time series[C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2020: 3395-3404.
 - [9] Tuli S, Casale G, Jennings N R. TranAD: deep transformer networks for anomaly detection in multivariate time series data[J]. Proceedings of the VLDB Endowment, 2022, 15(6): 1201-1214.
 - [10] 霍伟纲, 梁锐, 李永华. 基于随机 Transformer 的多维时间序列异常检测模型[J]. 通信学报, 2023, 44(2): 94-103.
Huo W G, Liang R, Li Y H. Anomaly detection model for multivariate time series based on stochastic Transformer[J]. Journal on Communications, 2023, 44(2): 94-103.
 - [11] Zamanzadeh Darban Z, Webb G I, Pan S, et al. Deep learning for time series anomaly detection: a survey[J]. ACM Computing Surveys, 2024, 57(1): Article 15, 1-42.
 - [12] Zhong Z, Yu Z, Yang Y, et al. PatchAD: a lightweight patch-based MLP-Mixer for time series anomaly detection[J]. IEEE Transactions on Big Data, 2025, 11(6): 3460-3473.
 - [13] Wang Q, Zhu Y, Sun Z, et al. A multi-scale patch mixer network for time series anomaly detection[J]. Engineering Applications of Artificial Intelligence, 2025, 140: 109687.
 - [14] Liu X, Li X, Li Y, et al. RTdetector: deep transformer networks for time series anomaly detection based on reconstruction trend[C]//Proceedings of the Thirty-Fourth International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2025: 5788-5796.
 - [15] Xie Y, Zhang H, Babar M A. Multivariate time series anomaly detection by capturing coarse-grained intra- and inter-variate dependencies [C]//Proceedings of the ACM Web Conference 2025. New York: ACM Press, 2025: 697-705.
 - [16] Liu Z, Huang X, Zhang J, et al. Multivariate time-series anomaly detection based on enhancing graph attention networks with topological analysis[C]//Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2024: 1555-1564.
 - [17] Wang K, Kong J, Zhang M, et al. MAD-DGTD: multivariate time series anomaly detection based on dynamic graph structure learning with time delay[J]. Neurocomputing, 2025, 635: 129887.
 - [18] Hundman K, Constantinou V, Laporte C, et al. Detecting spacecraft anomalies using LSTMs and nonparametric dynamic thresholding[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2018: 387-395.
 - [19] Abdulaal A, Liu Z, Lancewicki T. Practical approach to asynchronous multivariate time series anomaly detection and localization[C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2021: 2485-2494.
 - [20] Ahmed C M, Palleti V R, Mathur A P. WADI: a water distribution test-bed for research in the design of secure cyber physical systems[C]//Proceedings of the 3rd International Workshop on Cyber-Physical Systems for Smart Water Networks. New York: ACM Press, 2017: 25-28.
 - [21] Huet A, Navarro J M, Rossi D. Local evaluation of time series anomaly detection algorithms[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2022: 635-645.
 - [22] Fawcett T. An introduction to ROC analysis[J]. Pattern Recognition Letters, 2006, 27(8): 861-874.
 - [23] Li L, Zhang W, Yuan S, et al. PhysDiff: a physically-guided diffusion model for multivariate time series anomaly detection[C]//Advances in Neural Information Processing Systems 38. 2025.
 - [24] Luo D, Wang X. ModernTCN: a modern pure convolution structure for general time series analysis[C]//Proceedings of the Twelfth International Conference on Learning Representations. OpenReview. net, 2024.
 - [25] Yang Y, Zhang C, Zhou T, et al. DCdetector: dual attention contrastive representation learning for time series anomaly detection[C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2023: 3033-3045.
 - [26] Wu H, Hu T, Liu Y, et al. TimesNet: temporal 2D-variation modeling for general time series analysis[C]//Proceedings of the Eleventh International Conference on Learning Representations. OpenReview. net, 2023.
 - [27] Zeng A, Chen M, Zhang L, et al. Are transformers effective for time series forecasting? [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2023, 37(9): 11121-11128.
 - [28] Sakurada M, Yairi T. Anomaly detection using autoencoders with non-linear dimensionality reduction[C]//Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis. New York: ACM Press, 2014: 4-11.
 - [29] Liu F T, Ting K M, Zhou Z H. Isolation forest[C]//Proceedings of the 2008 Eighth IEEE International Conference on Data Mining. Piscataway: IEEE Press, 2008: 413-422.
 - [30] Nam Y, Yoon S, Shin Y, et al. Breaking the time-frequency granularity discrepancy in time-series anomaly detection[C]//Proceedings of the ACM Web Conference 2024. New York: ACM Press, 2024: 4204-4215.
 - [31] Zhang C, Zhou T, Wen Q, et al. TFAD: a decomposition time series anomaly detection architecture with time-frequency analysis[C]//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. New York: ACM Press, 2022: 2497-2507.
 - [32] Zhou T, Ma Z Q, Wen Q S, et al. FEDformer: frequency enhanced decomposed transformer for long-term series forecasting[C]//Proceedings of the 39th International Conference on Machine Learning.

PMLR, 2022, 162: 27268-27286.

- [33] Xu Z J, Zeng A L, Xu Q. FITS: modeling time series with 10k parameters[C]//Proceedings of the Twelfth International Conference on Learning Representations. OpenReview.net, 2024.
- [34] Lai K H, Zha D C, Xu J J, et al. Revisiting time series outlier detection: definitions and benchmarks[C]//Proceedings of the Neural Information Processing Systems Track on Datasets and Benchmarks. OpenReview.net, 2021.

[作者简介]



杜睿山 (1977–), 男, 博士, 东北石油大学副教授, 主要研究方向为机器学习。



单亚洲 (2001–), 男, 东北石油大学硕士生, 主要研究方向为智能计算与应用技术。



孟令东 (1986–), 男, 博士, 东北石油大学副教授, 主要研究方向为断层带结构、渗透性与稳定性。



付晓飞 (1973–), 男, 博士, 东北石油大学教授, 主要研究方向为断层带结构、渗透性与稳定性。