

基于残差网络曲线去噪方法的研究综述

马影

合肥工业大学 数学学院, 安徽 合肥 230009

DOI: 10.61369/TACS.2026060004

摘 要： 曲线数据广泛存在于应用统计各实际场景，噪声干扰严重影响后续统计分析效果，去噪是数据预处理的核心。传统去噪方法依赖手工特征与统计假设，难以适配复杂曲线。残差网络通过残差连接解决深层网络中存在的梯度消失问题，具有较强的特征学习能力，成为深度学习与应用统计的研究热点。本文介绍曲线去噪方法的研究背景与传统方法的局限性，综述基于残差网络去噪的核心技术、改进方向及应用场景，分析现存的问题并展望未来的发展趋势，为相关研究提供参考。

关 键 词： 应用统计；残差网络；曲线去噪；特征学习

A Review of Curve Denoising Methods Based on Residual Networks

Ma Ying

School of Mathematics, Hefei University of Technology, Hefei, Anhui 230009

Abstract： Curve data widely exist in various practical scenarios of applied statistics. Noise interference severely affects the subsequent statistical analysis, making denoising a core step in data preprocessing. Traditional denoising methods rely on handcrafted features and statistical assumptions, which are often inadequate for complex curves. Residual networks address the vanishing gradient problem in deep networks through skip connections and possess strong feature learning capabilities, making them a research hotspot in deep learning and applied statistics. This paper introduces the research background of curve denoising and the limitations of traditional methods, reviews the core techniques, improvement directions, and application scenarios of residual network-based denoising, analyzes existing challenges, and discusses future development trends, aiming to provide a reference for related research.

Keywords： applied statistics; residual network; curve denoising; feature learning

引言

曲线数据的精准分析是应用统计数据驱动决策的前提，噪声会导致统计估计偏差、特征提取失真，影响后续的建模预测效果。曲线去噪的核心是在保留真实特征的同时抑制噪声，传统方法难以适配复杂场景。残差网络（ResNet）通过残差连接突破深层网络的局限性，可以深度挖掘曲线的非线性特征，显著提升模型的去噪性能，适配各类复杂曲线数据预处理的需求^[1-3]。

近年来，基于残差网络的曲线去噪已经取得了显著进展并受到广泛关注。本文从应用统计专业出发，梳理基于残差网络的曲线去噪方法研究，并展望未来的发展趋势，为后续相关研究提供思路。

一、传统的曲线去噪方法

（一）曲线去噪的定义

曲线去噪本质上是一个逆问题，即给定含噪曲线 $y(t)=x(t)+\varepsilon(t)$ ，其中 $x(t)$ 为真实曲线信号， $\varepsilon(t)$ 为噪声信号，通过设计合理的去噪算法，从含噪曲线 $y(t)$ 中还原出真实曲线 $x(t)$ 。

根据噪声的来源与特性，曲线上的噪声可以大致分为高斯噪

声、脉冲噪声、泊松噪声和周期性噪声这四类。选择曲线去噪算法的评价标准应根据具体的应用需求而定，在一般情况下常用的几个方面有：信噪比（SNR）、均方根误差（RMSE）、平均绝对误差（MAE）、结构相似性指数（SSIM）。信噪比是衡量去噪的效果好坏的一个重要参数，它描述的是去噪后信号强度的变化情况；均方根误差和平均绝对误差都是从统计的角度出发来度量去噪带来的误差大小；结构相似性指数主要是用来衡量去噪之后

的数据空间上的一些特性是否被保持。这几个方面结合起来就形成了一个比较完整全面的曲线去噪效果的评判标准。

（二）传统的曲线去噪方法

传统的曲线去噪的方法大致可以分为三类：基于统计学原理的平滑方法、利用信号变换理论的解析方法以及基于稀疏表示的方法。而这些方法一般需要人为定义特征提取规则或者对信号进行统计假设，对于复杂的结构和非线性关系存在一定局限性。

基于统计平滑的方法，如移动平均、LOESS 通过局部平滑抑制噪声，LOESS 方法适配非线性场景，但在高噪声、非平稳曲线处理中难以兼顾平滑与特征保留，参数依赖性强。

基于信号变换方法，如傅里叶变换、小波变换或者 Curvelet 变换等。其中小波变换因其多分辨率特性被广泛使用^[4-7]，许多研究通过改进小波阈值函数或结合自适应算法提升去噪效果^[8-10]。然而，这类方法普遍存在局部特征处理不足，依赖人工调参，计算复杂度高等问题，难以适配大规模实时场景。

基于稀疏表示的方法对于单一类型的曲线具有良好的性能，但是对于复杂的曲线却存在较大问题：字典的学习更加困难并且需要更高的计算成本。同时传统的算法一般不能很好地拟合非线性的特性，难以满足各种不同类型的曲线的要求。

二、基于残差网络的曲线去噪方法

残差网络的核心是引入残差连接（Residual Connection），将输入信号直接传递至后续层，形成“残差块”结构，有效解决了深层网络训练中的梯度消失与退化问题，使网络能够达到更深的层数，具备更强的特征学习能力。与传统深度神经网络相比，残差网络能够自适应学习曲线信号与噪声的差异，无需手工设计特征，在处理非线性、非平稳曲线时具有显著优势，成为曲线去噪研究的核心方法。

（一）基础残差网络在曲线去噪中的应用

基础残差网络的核心结构为残差块，每个残差块由卷积层、批量归一化层、激活函数组成，通过残差连接将输入 x 与残差块的输出 $F(x)$ 相加，得到最终输出 $H(x)=F(x)+x$ 。在曲线去噪中，基础残差网络的输入为含噪曲线数据，输出为去噪后的曲线数据，网络通过逐层学习，逐步提取曲线的真实特征，抑制噪声。

在应用统计领域，基础残差网络首先被应用于气象数据和股价数据等简单时序曲线去噪。但基础残差网络在曲线去噪中仍存在不足：网络结构较为单一，难以适配不同类型的曲线数据与噪声场景；对曲线的局部特征，对峰值、拐点捕捉能力不足，容易导致去噪后曲线的细节丢失；在样本较少的情况下容易产生过拟合的现象，导致模型不具备良好的泛化能力和鲁棒性。

（二）基于残差网络去噪方法的改进

基础残差网络在曲线去噪的应用中存在一定的局限性。近年来，围绕残差网络的结构改进、损失函数优化、统计特征融合等方面进行了大量研究，形成了一系列适配曲线去噪的改进模型。其中最具代表性的包括深度残差收缩网络、注意力机制融合残差网络、轻量化残差网络等。

深度残差收缩网络（DRSN）将软阈值化嵌入残差块，设计自适应阈值学习子网络，实现逐通道噪声抑制，阈值可随信号动态调整，适用于强噪声曲线去噪，性能显著优于普通残差网络。同时频域自适应阈值方法也被证明能够有效提升去噪性能并防止过拟合^[11]。

注意力机制融合残差网络，如 TAR-Net 通过分配注意力权重，聚焦曲线关键特征区域，能够更好的保留保留数据特征。部分模型结合多尺度卷积与残差结构，在故障诊断等任务中表现出优越的特征提取能力^[12-13]。此外，将残差网络与小波变换相结合的方法，能够充分发挥频域分析与深度学习的互补优势，提升对非平稳曲线的去噪效果^[14]。

轻量化残差网络，如 LRD-Net 通过简化结构、采用轻量化卷积核，能够有效降低计算复杂度，在保证去噪性能的同时，能够快速响应，满足实时去噪的需求。在损失函数优化方面，混合损失、统计损失等替代传统 MSE，兼顾误差量化与结构保留，使去噪曲线更贴合真实的统计分布，满足统计学规律。

（三）基于残差网络曲线去噪的应用

残差网络去噪方法已广泛应用于应用统计各领域，为后续分析提供高质量数据支撑。在金融领域，基于残差网络对数据进行预处理能够有效分离时序曲线噪声，提升股价预测准确率与风险评估可靠性；在医疗领域，能抑制信号干扰，保留微弱特征，帮助疾病的诊断；在工业领域，能够准确识别设备故障特征，提升监测与诊断的准确性^[12-13]。此外在机械臂轨迹规划、超表面逆向设计^[15-16]等工程场景中，残差网络也展现出强大的信号处理与特征学习能力，为后续研究提供了可靠的数据基础。

三、前景与展望

由于应用场景不同及需求差异，目前的研究还面临一些问题^[17-20]。在小样本情形下，容易产生过拟合。而数据增强方法对于复杂噪声的效果不佳，不能较好地解决多种噪声叠加的问题。大多数网络都是针对某一种特定类型的噪声进行优化设计，缺少对不同类型噪声的通用处理方法。传统的模型一般使用“黑箱”，内部机理难以理解，统计特征与深度学习的有效结合还有待进一步探索。

未来的研究工作可以朝以下几个方面发展：首先可以结合小样本学习、半监督学习的方法，引入迁移学习、自监督学习以及新的数据增强方式等来提高模型鲁棒性；其次在多种噪声条件下算法鲁棒性的问题上，开发有效的噪声识别方法并优化相应的去噪过程，利用可视化以及统计学原理揭示不同变量之间关系，建立既高效又具有良好可解释性的统计与深度学习相结合的模式。

四、结论

本文对基于残差网络曲线去噪的研究进展进行了综述。在此基础上，重点阐述以残差网络为核心的曲线去噪方法的发展过程以及主要特点。作为深度学习与应用统计相结合的研究热点问

题, 基于残差网络进行曲线去噪, 其目的在于去除数据中的噪声, 提高数据质量, 从而更好地服务于后续研究。随着深度学习领域的发展, 引入统计特性能够进一步增强模型的可解释性, 基

于残差网络的曲线去噪方法在金融风险管理、生物医学分析以及工业质量控制等问题的应用上发挥重要作用, 为后续研究奠定数据基础, 对于解决现实问题具有重要意义。

参考文献

[1] 刘帅, 寇金泉, 刘少康, 等. 基于混合残差网络和宽度学习的小样本轴承故障诊断 [J]. 电力科学与工程, 2026, 42(03): 50-57.

[2] 左国王, 陈国栋, 刘月雷, 等. 基于均匀概率的目标启发式 RRT 机械臂路径规划方法 [J]. 北京工业大学学报, 2022, 48(8): 812-821.

[3] 袁胜智, 王少蕾, 李静, 等. 基于小波变换和改进残差神经网络的故障诊断方法 [J/OL]. 系统工程与电子技术, 1-11[2026-05-14].

[4] 陈圣禹, 郭小萍, 臧春华, 等. 基于频域自适应阈值 U-Net 卷积神经网络信号去噪方法 [J]. 自动化与仪表, 2026, 41(02): 49-55+137.

[5] 刘静. 基于深度学习的人工智能图像处理技术分析 [J]. 电脑知识与技术, 2026, 22(06): 13-15.

[6] 张伟胜, 朱瑞超, 闫明宝, 等. 基于残差增强神经网络的宽带极化转换超表面逆向设计 [J]. 电波科学学报, 2026, 41(01): 98-106.

[7] 向玲, 王宁, 邵汉昆, 等. 基于多尺度残差动态域适应网络的不同工况下转子故障诊断方法 [J]. 振动工程学报, 2026, 39(02): 595-604.

[8] 钱方, 许永博, 赵伟. 基于多尺度小波变换的光谱数据预处理算法 [J]. 中国光学 (中英文), 2025, 18(04): 794-802.

[9] 徐敏, 张宗楼, 毕爽爽, 等. 基于小波变换的微动勘探频散去噪分析研究 [J]. 工程地球物理学报, 2025, 22(02): 277-284.

[10] 王水清, 张明栋, 张明智. 基于小波去噪的变形监测预测模型优化研究 [J]. 测绘与空间地理信息, 2025, 48(02): 198-201+204.

[11] 刘云飞, 周光远, 尹凤梅, 等. 基于改进小波阈值的无人机巡检图像去噪方法 [J]. 湖南电力, 2024, 44(06): 113-119.

[12] 颜嘉晴. 统计分析法在基层经济统计中的应用 [J]. 财富时代, 2024, (05): 57-59.

[13] 张鑫, 杨倩倩, 李世娜. 基于小波去噪和反卷积的光声成像优化算法 [J]. 科技通报, 2024, 40(05): 46-50+54.

[14] 逯兆虎, 贾少雷, 李广豪, 等. 自适应新小波阈值函数中子图像去噪方法 [J]. 同位素, 2024, 37(02): 153-163.

[15] 臧益鹏, 李现勤, 吴松桂, 等. 基于改进小波变换的 OTDR 事件检测方法 [J]. 光通信技术, 2024, 48(01): 23-28.

[16] 王嘉蔚. 数字化转型与经济社会统计工作面临的挑战和创新研究 [J]. 活力, 2023, 41(12): 115-117.

[17] 丁岳. 基于大数据时代应用统计对企业管理的影响 [J]. 营销界, 2022, (09): 155-157.

[18] 宫迪蝶. 应用统计学在大数据背景下的应用与创新 [J]. 财富时代, 2020, (02): 146.

[19] 陈星. 大数据背景下统计信息化的应用研究 [J]. 中国管理信息化, 2019, 22(15): 152-154.

[20] 黄红贵, 黄加生. 数据科学的统计学内涵分析 [J]. 科技风, 2018, (04): 202.