光电技术及应用

DOI：10.16818/j.issn1001－5868.2022122601

基于滤波网络的多余物状态识别研究

王宇宸[1,2,3]，孙胜利[1,2*]，陈夏宁[3]，陈宝岚[3]，马一骏[1,2,4]

（1. 中国科学院上海技术物理研究所，上海 200083；2. 中国科学院智能红外感知重点实验室，上海 200083；
3. 上海科技大学 信息科学与技术学院，上海 201210；4. 中国科学院大学，北京 100049）

摘　要： 在航天产品的研发制造过程中，多余物控制至关重要，尤其是多余物状态识别的环节，其核心在于如何有效提取高噪声图像中的局部特征。现有方法尚未针对多余物场景进行有效建模，通用的视觉模型往往会对噪声进行过度拟合，而无法有效滤除噪声信号。为此，提出了一种可学习滤波感知机。该感知机通过采用一种可学习滤波器来替代繁琐的自注意力机制，用以学习空间位置的交互作用信息。随后，引入了频谱掩模用于频域分量特征的抽取，以学习不同频段内的重点信息。实验结果表明，该方法在多余物识别中取得了96.7%的准确率，优于基于卷积和自注意力的模型，并且具有更低的计算复杂度。

关键词： 机器视觉；智能制造；多余物控制；航天产品；滤波算法

中图分类号： TP391.4　**文章编号：** 1001－5868(2023)03－0471－07

Research on Remainer State Identification Based on Filtering Network Method

WANG Yuchen[1,2,3], SUN Shengli[1,2], CHEN Xianing[3], CHEN Baolan[3], MA Yijun[1,2,4]

(1. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, CHN;
2. Key Laboratory of Intelligent Infrared Perception, Chinese Academy of Sciences, Shanghai 200083, CHN;
3. School of Information Science and Technology, ShanghaiTech University, Shanghai 201210, CHN;
4. University of Chinese Academy of Sciences, Beijing 100049, CHN)

Abstract: The remainder control is crucial to the development and manufacturing of aerospace products, and the remainders state recognition is an important part of it. The key which is to effectively extract local features in high noise pictures. However, existing methods have not been modeled well specifically for remainder scenes, and generic vision models are prone to overfitting the noise, making it difficult to filter the noisy signals effectively. To solve this problem, this paper proposes a learnable Filter Network, which replaces the heavy self-attention mechanism by a learnable filter which is used to learn spatial location interaction information. And then incorporates a mask for frequency domain component feature extraction to learn the emphasis information of different frequency bands. It is experimentally demonstrated that this method works better in remainder recognition scenarios, outperforms the convolution and self-attention models, and has better time complexity.

Key words: machine vision; intelligent manufacturing; control of remainders; aerospace products; filtering algorithm

收稿日期：2022－12－26.
基金项目：科技部重点领域创新人才推进计划项目(2019RA4018).
* **通信作者：**孙胜利　**E-mail：**palmsun@mail.sitp.cn

0 引言

在航空航天器件的研制过程中，多余物被定义为那些由外部引入或内部生成、与产品规定状态不一致的物质[1]。多余物的存在可能导致航天设备电子元件遭受破坏、电路短路，甚至造成设备损伤等故障，其严重程度甚至可能导致发射任务的失败。多余物的预防和检测技术对于我国的航天事业的发展，具有重大的研究意义和价值。

由于航天器件研制过程的复杂度高、涉及的研究单位众多，以及时间跨度长等因素，导致在操作过程中极易出现如导线段、扳手、螺母等被误封装在产品内部，形成多余物。然而，多余物的机器视觉在线检测仍然面临诸多挑战。最主要的两个挑战分别是：首先，由于监控视频中相机分辨率和拍摄角度的限制，获取的多余物视觉信息质量较低，因此模型如何有效抽取具有区分度的局部特征成为一项重要课题[2]。其次，由于航天产品制造场景环境复杂，多余物图片的背景通常较为嘈杂，小质量高粘度的多余物信号畸变严重，经典机器视觉方法难以有效滤除噪声信号。鉴于以上问题，本文提出了一种能增强网络捕获局部特征的模型——可学习滤波感知机(Learnable Filter Multilayer Perceptron，LFM)。这个模型的设计思想受到数字信号处理的启发，能够在频率域空间下针对性地强化所需频率分量的特征学习能力，有效滤除噪声信号。该模型是基于纯MLP架构而能够学习空间位置交互作用的模型，一方面，它避免了使用具有指数复杂度的多头自注意力机制(Multi-Head Attention)，进一步降低了计算复杂度，适应了监控需求和范围扩大的问题；另一方面，它勿需采用卷积类模型中广泛使用的下采样算子，如池化层，从而提高了捕获局部细节特征的能力，顺应了现有机器视觉模型中消除归纳偏置的趋势。

本文提出的多余物状态识别算法简单而有效，其优越性能已在实际航天场景下的多余物状态识别任务中得到验证。此算法在性能与复杂度之间取得了良好的平衡，更加适应于实际的工业场景。利用纯MLP结构在频率域进行建模为机器视觉领域模型研究开辟了一条新的参考方向。综上，本文的主要贡献如下：(1)提出了一种能够在频率域内进行多余物识别建模的技术，能有效处理高噪声图像，并提取出显著的特征信息；(2)通过应用传统滤波算法优化神经网络，使得本研究所提出的方法在多个数据集中实现领先的性能，同时保持较小的参数规模和计算复杂度。

1 相关工作

多余物状态识别技术的目标是判断不同摄像机视图中可能存在多余物的场景。当前在多余物数据集上表现最佳的解决方案大都得益于深度学习的应用，而先进的识别方法主要基于卷积神经网络(CNN)，也存在少数基于Transformer的方法。这些方法的主要建模思路是利用某种网络结构，例如ResNet[3]、ViT[4]，以提取图片中的特征，损失函数一般采用交叉熵损失函数和三元组损失函数。

深度网络类方法的成功主要源于其有效地检测出多余物对象中丰富的标志性特征。最早的相关研究可追溯到上世纪，美国宇航局(NASA)首次提出了结合BP神经网络和颗粒碰撞噪声检测(PIND)的方法[5]，达到了98%的精确度。然而，由于BP神经网络的一些缺陷以及当时算力的限制，深度学习方法长期处于发展瓶颈。后续的研究将关注点从后期生产检测转向了从生产源头进行多余物识别和控制[2]，这与本文的目标相符。从生产源头进行的多余物识别主要研究方法集中于以下两个关键问题：

(1)局部特征抽取。在多余物数据中，局部结构信息通过特定的模型结构方法抽取，同时通过网络结构设计聚合不同部分的信息。自注意力机制能够有效地构建长距离依赖关系，ViT是早期将这种机制引入视觉任务的模型，表现出色。然而，近期一些研究在探讨自注意力机制在ViT中的有效性，并提出了一些使用纯MLP替代self-attention机制的方法[6-8]，如ResMlp使用仿射变换代替层归一化进行加速。这些方法的缺点在于，与自注意力机制一样，其计算量与patch数目的二次方成正比。本文的目标即是改进这一问题，主要关注减少复杂度以及更好地抽取局部特征。

(2)噪声信号过滤。在传统数字信号处理中，傅里叶变换被广泛应用于时域信息和频域信息之间的转换，利用频率域信息能够提升某些任务的性能，且具有优秀的时间复杂度。因此，一些研究引入了傅里叶变换到深度视觉任务[9-10]，部分利用傅里叶变换更好地利用频率信息，部分利用快速傅里叶变换的特性加速卷积运算。因此，受传统数字信号处理的启发，本文引入了傅里叶变换以减少计算复杂度，

并在频率域过滤噪声信息。

2　滤波网络方法

本章首先将介绍可学习滤波感知机(LFM)的构思来源、整体结构及其工作流程，随后对每一个模块的功能和细节进行深入分析。

2.1　本方法改进思路

虽然深度学习的视觉处理方法在通用任务上已经证明能够有效地抽取图像的关键特征，但在面对特殊的多余物状态检测任务时，相关的深入研究相对匮乏。本文旨在对此进行深入研究，并提出一种基于多余物主要特性的解决策略。通过在航天研究所及实验室中进行深入研究，我们发现多余物图像具有以下特性：细粒度、高噪声、低分辨率、高类内差异及低类间差异。因此，我们需要一个可以高效地识别丰富局部结构信息、有效过滤噪声信号，并能在监控范围持续扩大的情况下处理计算复杂度增长的算法。

当前，应用最为广泛的视觉深度模型主要为 CNN 和 Transformer 两大类别，然而在处理细粒度、高噪声的多余物检测问题上，这两大类别存在一些挑战。首先，以 CNN 为代表的模型受限于有效感受野，真实的感受野尺度较小且遵循高斯分布[11]。尽管 CNN 可以通过卷积操作有效提取感受野内的局部特征，但为了扩大有效感受野，大多数基于 CNN 的模型广泛采用了诸如池化和空洞卷积之类的下采样算子，这在很大程度上削弱了神经网络对细节的捕捉能力。其次，虽然 Transformer 模型在许多视觉任务中展现出优异性能[4,12]，但其主要的挑战在于其高计算复杂度，需要更大的数据集才能使网络收敛，并且随着 token 数目的增加，Transformer 的复杂度呈现出二次方增长。第三，通用任务的算法在学习高频信息和过滤无效噪声信号方面表现不佳：一些相关研究表明，在梯度下降过程中，神经网络更倾向于关注数据的低频成分[13]。然而，部分研究[14-16]也证实了多余物的局部特征和图像的高频分量具有较高的关联性。本文希望能够设计出一种针对高噪声图片能够有所优化的网络结构，基于以上分析，设计一个有效的、高效的全 MLP 模型，并使用适当的过滤算法进行多余物检测是很有必要的，所以接下来分析 LFM 网络结构和机理。

2.2　可学习滤波感知机网络结构

LFM 的一个网络块结构如图 1 所示，它是一种基于滤波增强的纯 MLP 架构的模型，和原始的 ViT 架构类似，同样需要堆叠多个神经网络块，用来学习图片中的丰富信息，但是不同之处是在 Transformer 中移除了繁重的 self-attention 模块。具体工作步骤是在一个网络块中，原始图像首先通过 Patch Embedding 后加入位置编码，随后输入可学习滤波层，这是和 ViT 架构最大的不同，LFM 采用了一种全新的可学习滤波层(Learnable Filter Layer)来代替原有的多头自注意力机制，其效果除了增强对于不同频率域特征的学习，同时还能降低计算复杂度。此模块在功能上等价于循环卷积，但是 LFM 在逻辑上却并不包含卷积。通过可学习滤波层进行学习后，进一步经过一个前馈神经网络处理，最终输入到频谱掩模层(Spectral Mask Layer)，频谱掩模层将会在高频、低频和中通频段抽取特征，进一步细化学习多个频段内的信息，不同频率分量互补性的学习能够有效过滤原始数据中噪声，抽取有区分度的局部特征。

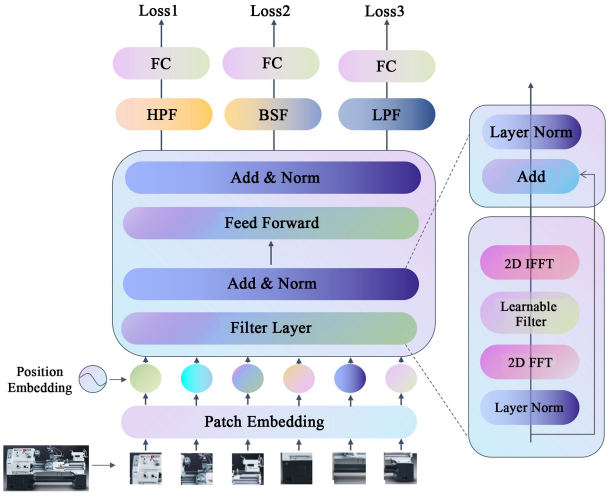


图 1　可学习滤波感知机网络结构图

可学习滤波层通过快速傅里叶变换将输入转换到频率域建模，同时为了减少人类先验情况下从原始数据进行优化，通过带可学习滤波参数的算法对频率特征信息进行编码。然后再由傅里叶逆变换把频率域特征映射回时域。这种方法可以有效地衰减噪声的影响，同时强化捕捉重要频率域的信息。相关的理论研究[17]表明带可学习参数滤波器等价于时域上的循环卷积，同时具备更大感受野。而且因为快速傅里叶变换算法(FFT)具备线性对数的优良复杂度，可学习滤波层具备比带注意力机制的 MLP 更好的效率。

可学习滤波层主要对每一个特征执行滤波操

作，假设输入的原始数据为 $x_p \in \mathbb{R}^{H\times W\times C}$，此操作首先将空间特征通过一个 2D 的傅里叶变换转换为频域的特征：

$$x_1 = f(x_p) \in \mathbb{C}^{H\times W\times C} \tag{1}$$

此时在 x_1 频率维度上是一个复数形式张量，代表输入特征的频谱。$f(\cdot)$代表二维快速傅里叶变换。在此频率空间下，本文使用一个可学习参数 w 来和频谱做点积操作：

$$\tilde{x} = w \odot x_1 \tag{2}$$

式中，w 称之为可学习滤波参数，因为这个参数同样可以在反向传播的过程中被更新。最后通过逆傅里叶变换(IFFT)，将频谱转换为时域：

$$\tilde{x}_1 = f^{-1}(\tilde{x}) \in \mathbb{R}^{H\times W\times C} \tag{3}$$

通过 FFT 变换和 IFFT 变换，可以有效增强模型对细节信息的抽取能力。由于快速傅里叶变换(FFT)具有更低复杂度，该优秀特性使得快速傅里叶变换比自注意力机制和卷积操作效率要高得多，特别是在摄像头范围扩大，图片数目增多的情况下。同样受益于这一点，可学习滤波器可以支持更高像素精度，能够使用更多更长的 patch 数目，因此大部分网络无需修改结构就可以加入可学习滤波层。

频频谱掩模层在频域中执行裁剪操作，而 LFM 则将掩模设计为两个一维函数，一个沿长度方向，另一个沿宽度方向。每个函数都有一个超参数即核大小，以控制滤波器过滤的尺度。这两个一维掩模可以在频率域中引入权重，以学习特征图中每个特征域的信息含量。本文在此模块中引入了三种掩模，包括：(1)高通滤波器(HPF)，它只允许图像的高频分量通过，并将低频信息衰减为零；(2)低通滤波器(LPF)，它只允许图像的低频分量通过，并将高频信息衰减为零；(3)带阻滤波器(BSF)，它允许高频和低频信息通过，并将中间频率的信息衰减为零。如图 2 所示，这些滤波器通过与 LFM 模型中其他部分的集成，实现了去除原始图像中的噪声，并增强多余物特征的目标。此外，此模块极其轻巧，并不引入额外的参数，从而避免了过拟合的风险。

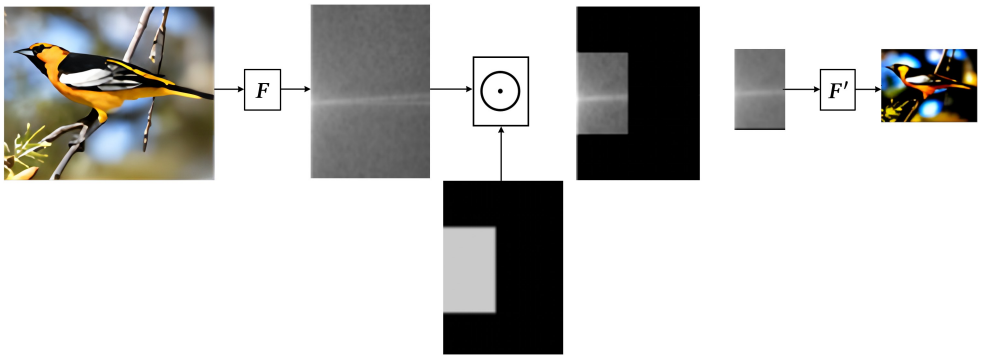


图 2 频谱掩模层工作流程

3 实验结果与分析

3.1 数据与实验参数设置

为了验证本研究方法的有效性，本文选择了对象存在数据集(Object-State)和工人着装状态数据集(Wearing-State)进行实验。这两个针对智能化车间的数据集中，高频分量包含了丰富的信息，它通常代表了图像中的细节和轮廓。由于背景、光照以及对象、型号、人员之间的各种差异，数据集给状态分类带来了较大的类内差距和较小的类间差距的挑战。此外，为了进一步验证本文方法的优越性，本文还在公共数据集 TrashNet 上选取了近几年相关技术的分类性能，与 LFM 的方法进行比较。TrashNet 数据集包含 6 个类别的废弃垃圾图片，共 2 527 张，数据集约 3.5 GB。

在实验方法上，本文首先按照一定比例正交地将数据集划分为训练集、测试集和验证集，然后比较在测试集上的性能。在模型方面，本文采用了迁移学习的方法，将在大规模图像数据集 ImageNet 上预训练得到的参数迁移到多余物识别任务中。实验设置上，本文分别测试了加入和不加入 Learnable Filter 的性能，以及分别测试了加入不同掩模层的性能并进行对比，分析这些模块是否有效。除了测试模型的表现外，本文也测试了模型的计算性能，分析 LFM 这种纯 MLP 架构的计算性能是否有优势。

在实验环境方面，本实验使用的 GPU 显卡为 NVIDIA 的 A100，带有 80 GB 显存，CPU 采用的是 AMD EPYC 7742。实验参数设置中，我们设定 Dropout 和 Droppath 比例为 0.1，输入图片大小为 224×224，优化器使用 Adam，并采用了小批量梯度

下降，每批的大小为 256。同时，本实验也配合使用了早停策略。

3.2 实验结果

对比实验中，主要对比了 LFM 与最近几年相关技术的准确性指标，本文选取的其他对比模型包括：双注意力网络 ABE[18]，ResNet50[3]，M-b Xception[19]，DenseNet[20]，ViT[4]，Swin Transformer[21]，不同方法的实验结果如表 1 所示。可以发现本方法在三个数据集上均取得了领先的性能，其中在 TransNet 数据上，在与其他方法比较中本方法取得了领先第二名 1.2 个百分点的精确度性能。在针对多余物的数据集 Object-State 和 Wearing-State 上，本文的方法同样分别取得了领先第二名约 3.2%和 3%的结果。

表 1　不同方法效果对比

Dataset	ABE	ResNet50	M-b Xception	DenseNet	Vit	Swin Tranformer	Ours
TrashNet	95.53	88.66	94.34	89.00	95.42	95.12	96.70
Object	79.69	75.74	79.31	75.19	79.26	81.01	82.89
Wearing	88.28	77.18	86.12	86.76	89.31	89.75	92.30

3.3 掩模算法效果对比

掩模实验旨在证明不同的掩模层是否有效。因此，实验设计采用了消融实验的方式，保持测试输入神经网络的一致性，分别测试了加入不同掩模结构后的性能表现。为了控制实验变量，本实验严格保持其他条件一致，例如相同的预处理方法以及模型参数的初始化方式。实验步骤按照以下流程执行：首先获得一张图片，将其输入神经网络，然后加入不同的掩模层。本文选择了三种最经典的滤波器：高通滤波器、低通滤波器和带阻滤波器。

最终的实验结果如表 2 所示。结果与本文预期相符，添加一系列滤波器之后，模型的性能有了一定的提升。在 ResNet 中，使用带阻滤波器(BSF)能够获得最佳性能；而在 ViT 中，使用高通滤波器(HPF)能够获得最佳性能。这一发现与参考文献[22]的研究结果一致，且大部分滤波器的添加并未导致性能的下降。因此，可以得出以下结论：(1)不同的滤波器能够助力网络学习；(2)对于不同的模型，最适合的滤波算法可能并不相同，因此 LFM 最终选择了同时使用 HPF，LPF 和 BSF 算法加入 LFM 模型。如结果所示，这三个模块的加入都使 LFM 的表现更佳，这证明了适当的滤波算法能够激发简单的 MLP 网络，使其获得超越卷积和自注意力模型的潜力。

表 2　ResNet 和 ViT 在不同滤波器下效果

Methods	Auxiliary Filter	Cifar	TrashNet	Object
ResNet	—	93.95	88.66	75.74
	＋HPF	−0.42	＋2.70	＋0.23
	＋LPF	＋2.81	＋2.58	＋0.95
	＋BSF	＋3.54	＋2.82	＋0.41
ViT	—	96.06	95.42	79.26
	＋HPF	＋1.48	＋1.18	＋2.49
	＋LPF	＋3.28	＋0.37	＋0.12
	＋BSF	＋3.72	＋1.06	＋1.01

3.4 可视化

图 3 直观地展示可视化原始图片在不同频率分量下的侧重信息，从图中可以看出低通滤波器表现出了过滤图片中的噪声信息的优秀性能，但是容易

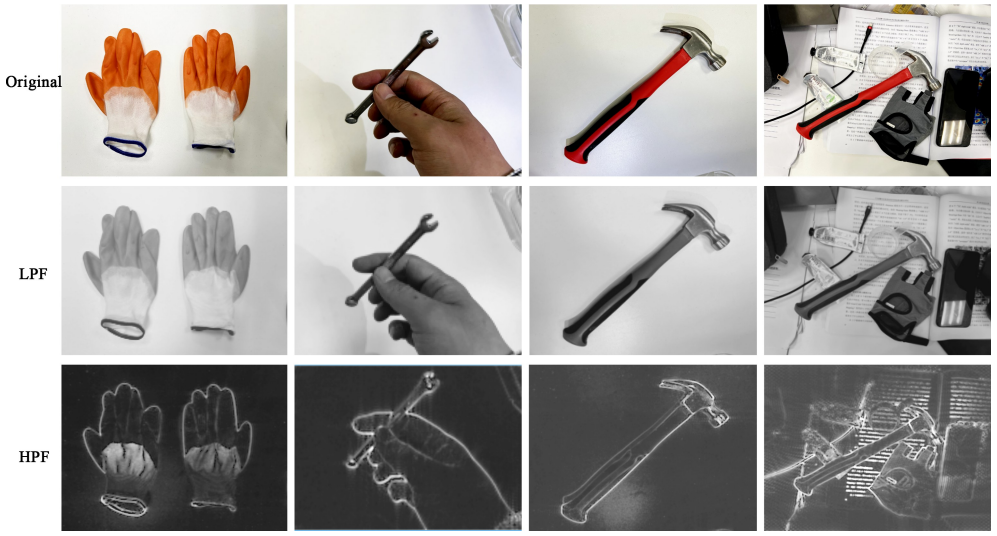
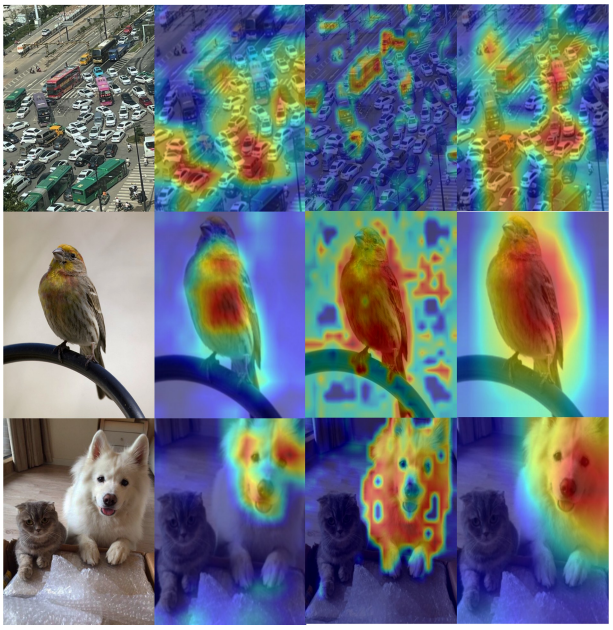


图 3　不同频率分量下的侧重信息

丢失细节和边缘，这是包含多余物信息最多的频段。而高通滤波器可以很好弥补这一缺点，去重点提取图片中的边缘和细节信息。LFM 同时兼具它们的优点，加入了 LPF，HPF 以及 BSF，让模型能够有效去噪的同时保留了图片主体信息。

图 4 展示了 LFM，ViT 以及 ResNet 的可视化注意力图。在这次实验中，作者分别选择了具有多目标复杂背景、单一目标简单背景，以及容易混淆的双目标主体的三种类型图片进行测试。从图中可以看出，相较于其他网络，LFM 能够更好地从高噪声图片中抽取有效的局部特征。它通过搭配不同的频率分量，能够很好地消除环境背景信息和干扰信息，准确地识别目标物体的边缘。其层次结构非常清晰，完全达到了预期的效果。



(a) 原图 (b) ResNet (c) ViT (d) LFM

图 4 不同网络注意力图可视化

4 结论

本文提出了一种针对多余物状态识别的可学习滤波感知机(LFM)算法。该算法从传统数字信号处理领域获取启发，通过一组滤波算法缓解了高噪声环境中多余物对任务的影响。同时，LFM 通过可学习的滤波层代替自注意力机制和卷积算法，有效降低了计算复杂度，同时还具备更大的感受野，从而能够捕捉到图像的局部特征。在实验中，成功做到了在模型的准确性和复杂性之间实现了平衡，使得滤波网络方法优于一系列具有竞争力的基线模型。通过一系列的消融实验和可视化方法，证明了本文提出的模块的有效性。

参考文献：

[1] 中国国家国防科技工业局. 中华人民共和国航天行业标准：QJ 2850A-2011，航天产品多余物预防与控制：[S]. 北京：国家国防科技工业局，2011.

[2] 张 悦，孙胜利，刘会凯，等. 航天器制造过程多余物控制机器视觉方法综述[J]. 计算机测量与控制，2019，27(2)：1-5，51.
Zhang Yue，Sun Shengli，Liu Huikai，et al. A survey of machine vision methods for control of remainders in intelligent manufacturing process of aerospace products[J]. Computer Measurement and Control，2019，27(2)：1-5，51.

[3] He K，Zhang X，Ren S，et al. Deep residual learning for image recognition[C]// 2016 IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). IEEE，2016：770-778.

[4] Dosovitskiy A，Beyer L，Kolesnikov A，et al. An image is worth 16×16 words：Transformers for image recognition at scale[EB/OL]. 2020-10-22. http://ar5iv. labs. arxiv. org/html/200. 11929.

[5] Scaglione L J. Neural network application to particle impact noise detection [C]// Proceedings of 1994 IEEE Inter. Conference on Neural Networks，1994：3415-3419.

[6] Tolstikhin I，Houlsby N，Kolesnikov A，et al. MLP-Mixer：An all-MLP architecture for vision [EB/OL]. 2021-5-4. http://arxiv. org/pdf/2105. 01601. pdf.

[7] Touvron H，Bojanowski P，Caron M，et al. ResMLP：Feedforward networks for image classification with data-efficient training[EB/OL]. 2021-5-7. http://arxiv. org/pdf/2105. 03404v1. pdf.

[8] Liu H X，Dai Z H，So D R，et al. Pay attention to MLPs [EB/OL]. 2021-5-17. http://arxiv. org/pdf/2105. 08050. pdf.

[9] Yang Y C，Soatto S. FDA：Fourier domain adaptation for semantic segmentation[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)，2020：4084-4094.

[10] Rao Y M，Zhao W L，Zhu Z，et al. Global filter networks for image classification[C]// 35th Conference on Neural Information Processing Systems (NeurIPS 2021)，2021：1-19.

[11] Luo W J，Li Y J，Urtasun R，et al. Understanding the effective receptive field in deep convolutional neural networks [C]// NIPS'16：Proceedings of the 30th International Conference on Neural Information Processing Systems，2016：4905-4913.

[12] Touvron H，Cord M，Douze M，et al. Training data-efficient image transformers & distillation through attention [EB/OL]. 2020-12-23. https://arxiv. org/pdf/2012. 12877v1. pdf.

[13] Xu Z Q J，Zhang Y Y，Xiao Y. Training behavior of deep

neural network in frequency domain[C]// International Conference on Neural Information Processing, 2018: 1-12.

[14] Campbell F W, Robson J G. Application of Fourier analysis to the visibility of gratings[J]. The Journal Physiology, 1968, 197(3): 551-556.

[15] De Valois R L, DeValois K K. Spatial vision[J]. Ann. Rev. Psychol., 1980, 31(1): 309-341.

[16] Sweldens W. The lifting scheme: A construction of second generation wavelets[J]. Siam J. Math. Anal., 1997, 29(2): 511-546.

[17] Handkiewicz A. Continuous and Discrete Signals[M]. Wiley-IEEE Press, 2009.

[18] Zhang Y, Sun S L, Liu U H, et al. Target state classification by attention-based branch expansion network [J]. Appl. Sciences, 2021, 11(21): 10208.

[19] Shi C P, Xia R Y, Wang L G. A novel multi-branch channel expansion network for garbage image classification[J]. IEEE Access, 2020, 8: 154436-154452.

[20] Huang G, Liu Z, Laurens V D M, et al. Densely connected convolutional networks[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 2261-2269.

[21] Liu Z, Lin Y, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]// 2021 IEEE/CVF International Conference on Computer Vision (ICCV), 2021: 9992-10002.

[22] Bai J, Yuan L, Xia S T, et al. Improving vision transformers by revisiting high-frequency components[C]// European Conference on Computer Vision, 2022: 1-18.

作者简介：

王宇宸(1997—)，男，硕士研究生，主要从事光电仪器的现代设计方法、航天数字化制造以及多余物检测方面的研究；

孙胜利(1970—)，男，博士，研究员，博士生导师，主要从事光电仪器的现代设计方法、数字化制造和全过程定量化测试方面的研究。