

基于空洞卷积神经网络的随机动载荷识别

王伟,许步锋,何文博,邸泽坤,孙含宇

(中国民航大学安全科学与工程学院,天津 300300)

摘要:为解决随机动载荷识别精度低的问题,本文将空洞卷积神经网络(ACNN, atrous convolutional neural network)引入随机动载荷识别研究中,提出一种扩张率为2的基于一维ACNN的随机动载荷识别方法,该方法通过提高扩张率来增大信号感受野,进而提高载荷识别精度。以GARTEUR飞机模型为研究对象进行载荷识别验证实验,结果表明:无噪声干扰时,用本文方法识别的翼尖激励点上随机动载荷与真实载荷之间的均方根误差为0.990 1 N,相关系数为0.987 4,功率谱密度曲线(PSD, power spectral density)能够较好地吻合;在不同噪声水平干扰下,本文方法也能有效识别出随机动载荷时间序列。本文方法具有识别精度高、抗干扰能力强的优点。

关键词: 载荷识别;空洞卷积神经网络;扩张率;随机动载荷

中图分类号: V215;TB391;O324

文献标志码: A

文章编号: 1674-5590(2025)05-0058-06

Random dynamic load identification based on atrous convolutional neural network

WANG Wei, XU Bufeng, HE Wenbo, DI Zekun, SUN Hanyu

(College of Safety Science and Engineering, CAUC, Tianjin 300300, China)

Abstract: To address the issue of low accuracy in random dynamic load identification, the atrous convolutional neural network (ACNN) is introduced into the research of random dynamic load identification. A random dynamic load identification method based on one-dimensional ACNN with a dilation rate of 2 is proposed, which increases the signal receptive field by increasing the dilation rate, thereby improving the accuracy of load identification. The load identification verification experiment is conducted using the GARTEUR aircraft model as the research object, and the results show that the root mean square error between the random dynamic load on the wingtip excitation point identified by the method in this article and the real load is 0.990 1 N, with a correlation coefficient of 0.987 4, and the power spectral density (PSD) curve can match well. Under different levels of noise interference, the proposed method can effectively identify the time series of random dynamic load. The proposed method has the advantages of high recognition accuracy and strong anti-interference ability.

Key words: load identification; atrous convolutional neural network; dilation rate; random dynamic load

在飞行中,飞机机体结构会受到各种振动载荷的作用,引起相应的振动,对飞机的乘坐舒适性和机载设备的正常工作产生不利影响。尤其是受到随机动载荷作用时,飞机机体结构更容易发生振动破坏和疲劳失效,原因是随机动载荷的频带范围广,覆盖机体结构的固有频率,会引起结构共振。因此,在飞机的结构强度设计中,飞机机体结构承受的振动载荷是设计者所要考虑的重要问题之一,正确地辨识出飞机承受的振动载荷,对飞机的飞行安全和结构优化至关重要。

动载荷识别是结构动力学的第二类反问题,解决思路是根据结构动态特性和实测动态响应来估计结构所受到的动载荷^[1]。传统的动载荷识别方法如直接求逆法^[2]、截断奇异值分解(TSVD, truncated singular value decomposition)方法^[3]和 Tikhonov 方法^[4],都是基于“模型”的方法,根据已知的系统模型参数或者传递函数进行求解,但这些方法需要精确的结构动力学模型。对于大型或复杂的工程结构而言,其精确的结构动力学模型往往不易获得,且容易受到正则化参数

和噪声的影响,所以传统动载荷识别方法在实际应用中具有局限性。随着计算机技术的迅速发展,神经网络作为一种“数据驱动”的智能算法,通过大量数据集进行学习训练,根据外部信息调整内部网络结构,进而建立复杂的输入和输出关系,已被广泛地应用于动载荷识别领域^[9]。

张方等^[9]利用反向传播(BP, back propagation)神经网络模型对正弦、扫频及冲击载荷进行了仿真与实验研究,验证了神经网络方法在载荷识别上具有可行性。深度学习采用多层非线性信息处理方法,能够避免 BP 神经网络因数据量庞大而导致的训练速度过慢、费时过长、难以收敛等问题。卷积神经网络(CNN, convolutional neural network)是深度学习方法中应用最广泛的算法模型之一,是一种特殊的多层神经网络,通过分层网络获取分层次的不同抽象程度的特征表示,通过减少网络参数来达到降低网络复杂度的目的。宋雪刚^[7]使用 CNN 对分布式载荷识别进行仿真研究,结果表明,CNN 在不同频率和不同噪声干扰下,都可以较好地建立系统载荷和响应之间的动力学关系。曾俊玮等^[8]提出一种融合一维 CNN 和双向门控循环单元的胶轮车辆轮胎径向载荷识别方法,能够有效提取信号的空间特征和时序特征,提升载荷识别精度。在工程实际中,振动响应信号的测量会受到各种噪声的干扰,普通 CNN 因感受野的限制,以及振动数据的复杂扰动,容易导致信息丢失,影响载荷识别精度,因此,从响应信号中提取准确的时频信息对于载荷识别至关重要。Yang 等^[9]提出了一种基于深度扩张卷积神经网络(DCNN, deep convolutional neural network)的动载荷识别方法,在 CNN 的基础上引入空洞卷积来扩展响应信号的感受野,避免了普通卷积层会导致信息丢失的问题,有效提高了识别精度。

随机动载荷频带覆盖范围广、特征复杂,所以使用传统方法进行识别时,在结构固有频率附近因传递函数矩阵病态性,随机动载荷识别结果会出现较大误差,而使用神经网络方法对载荷特征进行学习,能够有效提高载荷识别精度。夏鹏等^[10]结合有限长脉冲响应的原理和时延神经网络的特点,提出了针对平稳随机动载荷的基于时延神经网络的倒序识别方法,在铝制悬臂板上准确识别出两点平稳随机动载荷。但是随着时延步数的增加,时延神经网络的内部参数会呈指数级增加,网络模型的训练难度增加,容易导致局部收敛。杨特等^[11]提出了一种针对平稳随机动载荷的特征信号识别方法,首先通过小波变换提取信号的时频

特征,然后结合长短期记忆(LSTM, long short-term memory)神经网络对随机动载荷进行识别,最后通过仿真与实验证明了该方法的可行性,但其识别过程复杂,因此需要引入简单高效的神经网络方法进行随机动载荷识别。

飞机在飞行过程中工作环境异常复杂,常受到气动力等多种外界激励作用,影响载荷识别精度。为进一步提高神经网络方法在随机动载荷识别方面的高效性与准确性,本文引入空洞卷积,将一维空洞卷积神经网络(ACNN, atrous convolutional neural network)应用于随机动载荷识别,同时考虑外加噪声激励干扰下的识别精度问题。本文首先介绍 ACNN 在载荷识别问题上的应用原理;然后在 GARTEUR 飞机模型上进行随机振动实验,获取振动响应与随机动载荷数据;最后将数据划分为训练集与测试集,对基于 ACNN 的随机动载荷识别方法进行训练与预测,识别出随机动载荷的时间历程。

1 载荷识别原理

1.1 离散系统控制方程

对于一个单输入单输出(SISO, single-input single-output)的多自由度线弹性振动系统,当初始位移与速度均为 0 时,系统受到的外部载荷与系统加速度响应在时间上的卷积关系为

$$y(t) = \int_0^t h(t-\tau)f(\tau)d\tau \quad (1)$$

式中: $y(t)$ 表示 t 时刻系统响应; $h(t)$ 表示脉冲响应函数; $f(\tau)$ 表示系统受到的外部载荷; τ 为时延变量,满足 $0 \leq \tau \leq t$ 。为方便计算,将式(1)离散化,得到

$$\begin{bmatrix} y(\Delta t) \\ y(2\Delta t) \\ \vdots \\ y(n\Delta t) \end{bmatrix} = \Delta t \begin{bmatrix} h(\Delta t) & \cdots & 0 \\ \vdots & & \vdots \\ h(n\Delta t) & \cdots & h(\Delta t) \end{bmatrix} \begin{bmatrix} f(\Delta t) \\ f(2\Delta t) \\ \vdots \\ f(n\Delta t) \end{bmatrix} \quad (2)$$

式中: Δt 为时间间隔; n 为采样长度。将式(2)简化为矩阵-向量形式,即

$$\mathbf{y} = \mathbf{H}\mathbf{f} \quad (3)$$

式中: \mathbf{y} 为系统响应向量; \mathbf{H} 为传递函数矩阵; \mathbf{f} 为待识别的载荷向量^[12]。实际测量过程中噪声无法避免,因此,含有测量噪声的控制方程为

$$\bar{y} = Hf + w \quad (4)$$

式中: w 表示测量噪声; \bar{y} 表示带有噪声的系统响应向量。

传统的动载荷识别方法通过求逆来解决以上问题, TSVD 方法和 Tikhonov 方法可以在一定程度上解决因传递函数矩阵病态性导致的不适定问题, 但由于系统响应测量过程中噪声干扰不可避免, 传统方法的识别精度较差, 尤其是对随机动载荷的识别。为了解决这一问题, 本文选择基于神经网络来构建响应和激励的对应模型: 将测量点的加速度值作为神经网络的输入, 将对应时刻的载荷值作为神经网络的输出, 通过神经网络建立加速度响应和随机动载荷之间的对应关系, 从而实现基于神经网络的载荷识别。

1.2 基于 ACNN 的载荷识别原理

ACNN 是对标准 CNN 的改进, 主要结构有输入层、空洞卷积层、池化层、全连接层和输出层^[13], 本文构建的一维 ACNN 结构如图 1 所示。与标准 CNN 相比, ACNN 的特点是用空洞卷积层代替标准卷积层, 通过在卷积核内部元素之间加入空洞来扩展卷积核的尺寸, 在计算过程中给神经网络提供更大的感受野^[14], 且不带来额外的计算负担, 所以 ACNN 能够在保证效率的前提下提高网络识别精度。




图 1 一维空洞卷积神经网络结构

Fig.1 Structure of one-dimensional ACNN

针对振动响应数据的特点, 一维 ACNN 载荷识别方法包含 1 个输入层, 输入信号为振动加速度响应数据, 空洞卷积层通过卷积核来提取有效特征, 一维卷积运算的表达式为

$$x'_i = G(y'_i \times \omega'_i + b'_i) \quad (5)$$

式中: y'_i 为第 l 个卷积层第 i 个卷积核的输入; x'_i 为第 l 个卷积层第 i 个卷积核的输出; ω'_i 和 b'_i 分别为第 l 个卷积层第 i 个卷积核的权值参数和偏置参数; $G(\cdot)$ 为激活函数 GELU (Gaussian error linear units), 该激活函数是一种改进的 ReLU (rectified linear unit) 激活函数, 在语音和图像识别中具有良好的性能。假设 k 为原始卷积核尺寸, 加入扩张率 r 后, 实际卷积核尺寸 K 与原始卷积核尺寸 k 之间的关系为 $K = k + (k -$

$1)(r - 1)$, 一维空洞卷积运算感受野的变化情况如图 2 所示, 标准卷积的卷积核尺寸为 3×1 , $r = 1$; 当 r 增大为 2 时, 空洞卷积的卷积核尺寸变成 5×1 , 卷积核尺寸增大, 在计算过程中给神经网络提供的感受野增大, 这样不仅不会带来额外的计算负担, 而且能够提高网络识别精度。本文 ACNN 包含 2 个空洞卷积层, 卷积核尺寸均为 2×1 , 卷积核数量分别为 32 和 64, 步长为 1, 扩张率为 2。




图 2 一维空洞卷积示意图

Fig.2 Schematic diagram of one-dimensional atrous convolution

响应数据经空洞卷积层进行特征提取后, 输入到池化层对特征进行降维压缩, 进一步提取主要特征, 同时降低模型的参数量, 简化模型的计算复杂度。2 个池化层紧接在 2 个空洞卷积层之后, 池化类型为平均池化。池化后的输出为

$$x'_i = G(\beta'_i \times d(y'_i) + b'_i) \quad (6)$$

式中: β'_i 为第 l 个卷积层第 i 个卷积核的采样比例; $d(\cdot)$ 为下采样。然后, 将池化数据 x 输入到 1 个全连接层中进行线性组合, 对特征进行投影和分类, 最后输出层输出信号为预测的载荷数据 \hat{f} 。

2 实验研究

2.1 实验方案设计

为了验证基于 ACNN 的随机动载荷识别方法的工程实用性, 采用 GARTEUR 飞机模型来进行随机动载荷识别实验。GARTEUR 飞机模型是一种具有高柔度、低频、密频特性的标准飞机模型, 由法国航天局研制, 用以评价模态实验技术和实验方法的标准性^[15]。GARTEUR 飞机模型包括机身、机翼、垂尾、平尾和左右翼端配重板 6 个矩形截面梁, 不同部位之间采用螺栓连接, 机身长 1.5 m, 翼展 2 m, 模型材料为 2024-T3 铝合金, 材料参数分别为: 弹性模量 73 GPa、密度 2 780 kg/m³、泊松比 0.33。模型以软绳悬挂在实验台架上, 模拟自由边界条件。

如图 3 所示, 进行 GARTEUR 飞机模型的随机激励振动实验。实验用到的随机激励信号是平稳遍布历程的纯随机信号, 其特点是具有随机变化的幅值和相

位,是一种很好的通用激励方法。实验过程为:1# 激振器垂直作用于左机翼翼尖小翼前部,加速度传感器位于机头位置,使用 LMS Test.Lab 信号采集处理软件生成随机动载荷形式,经功率放大器与 1# 激振器作用在 GARTEUR 飞机模型上;加速度传感器测量响应数据,1# 激振器的力传感器测量载荷数据,由 LMS SCADAS III 数据采集系统同步采样,采样频率为 200 Hz,采样时长为 10 s,数据长度为 2 000,按照 3:1 的比例分成训练集与测试集,即 1 500 个数据用于神经网络的学习与训练,500 个数据用于对训练完成的神经网络进行载荷预测。




图 3 GARTEUR 飞机模型与实验设备

Fig.3 GARTEUR aircraft model and experimental equipment

考虑到工程实际中不可避免地会遇到其他振动源的噪声干扰问题,为进一步研究基于 ACNN 的随机动载荷识别方法的抗噪能力,在 GARTEUR 飞机模型右机翼中部布置 2# 激振器,施加随机动载荷作为噪声激励,模拟其他噪声源对振动响应的影响。定义噪声激励水平为 2# 激振器与 1# 激振器最大激励电压的比值,保持 1# 激振器的激励电压不变,通过 2# 激振器施加 5%~60%水平的噪声激励,分别测量噪声干扰下的系统响应,对左机翼翼尖处的随机动载荷进行识别。

2.2 识别精度评判标准

首先使用 GARTEUR 飞机模型进行随机动载荷瞬态响应分析实验,获得随机动载荷数据和振动响应数据;然后对数据进行划分,按照 3:1 的比例分为训练集与测试集,用于 ACNN 的训练和预测;最后将预测得到的随机动载荷时间历程与测量得到的真实载荷进行对比分析,定义均方根误差(RMSE, root mean square error)和相关系数 R 为载荷识别精度的评判标准。

RMSE 用来比较预测值和真实值之间的偏差,其值越小,数据的离散性越小,识别精度越高。相关系数 R 用来衡量 2 组数据之间的关联度, R 值区间为 0~1,

R 越接近 1,2 组数据之间的关联度越高,表示识别精度越高。二者公式可表示为

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{j=1}^n (\tilde{f}_j - f_j)^2} \quad (7)$$

$$R = \frac{\text{Cov}(\tilde{F}, F)}{\sqrt{\text{Var}(\tilde{F})\text{Var}(F)}} \quad (8)$$

式中: \tilde{f}_j 为 j 时刻载荷信号的预测值; f_j 为 j 时刻载荷信号的真实值; \tilde{F} 为预测载荷样本的时间序列; F 为真实载荷样本的时间序列; $\text{Cov}(\cdot)$ 为协方差; $\text{Var}(\cdot)$ 为方差。

2.3 载荷识别结果

当噪声激励为 0 时,使用测量得到的实验数据进行基于 ACNN 的随机动载荷时间历程识别。为了对比本文方法的识别效果,分别建立 2 种对比方法:一种是基于标准 CNN 的随机动载荷识别方法,另一种是基于 Tikhonov 方法的随机动载荷识别方法。Tikhonov 方法是载荷识别逆问题获得稳定解的最常用正则化方法,通过最小化残差范数与解范数的加权和得到正则化解。

3 种方法的识别载荷与真实载荷对比,如图 4 所示,其中 EXACT 为真实载荷曲线。由图 4 可以看出,ACNN 识别载荷的时间历程曲线与真实载荷曲线的吻合度是最高的。经计算,噪声激励为 0 时,基于 ACNN 的随机动载荷识别结果与真实载荷的 $E_{\text{RMSE}} = 0.990 1 \text{ N}$, $R = 0.987 4$;基于 CNN 的随机动载荷识别结果与真实载荷的 $E_{\text{RMSE}} = 3.941 6 \text{ N}$, $R = 0.802 6$;而基于 Tikhonov 方法的随机动载荷识别结果与真实载荷的 $E_{\text{RMSE}} = 5.121 0 \text{ N}$, $R = 0.531 2$ 。证明本文方法用于随机动载荷识别是有效的。

图 5 中比较了 3 种方法识别载荷时间历程局部细节。由图 5 可以看出,2 种神经网络方法的随机动载荷识别效果优于 Tikhonov 方法,这是因为 CNN 有特征提取的功能,可以先对随机响应信号进行特征提取,然后建立响应与载荷的关系;随着扩张率的提高,在不改变卷积核个数的情况下,ACNN 的卷积核可以覆盖时间间隔更大的振动响应信息,扩大振动响应数据的特征提取范围,有效提高了神经网络对随机动载荷的识别精度。相比而言,基于 Tikhonov 方法的识别载荷与真实载荷曲线的吻合度最差,这是由于传统的载荷识别方法在随机动载荷识别过程中受测量噪声或传递函数矩阵病态性的影响大,使得识别误差大。

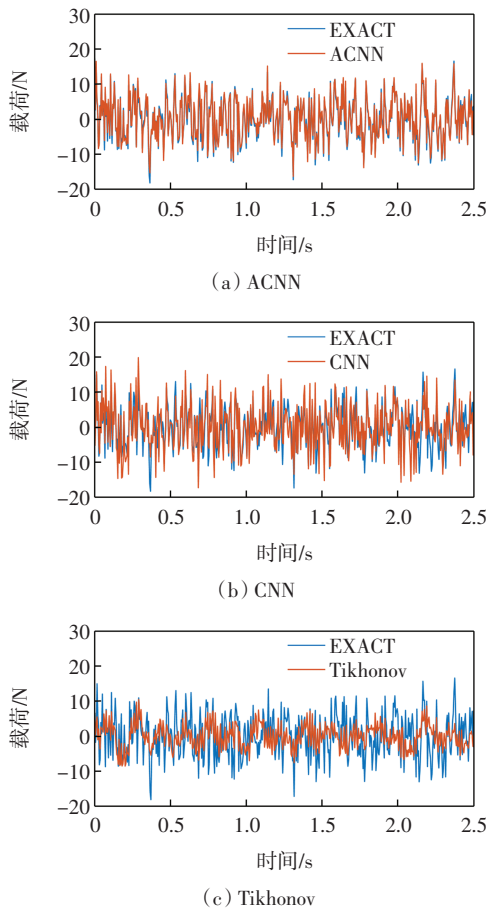


图 4 3 种方法的识别载荷与真实载荷对比

Fig.4 Comparison of identified load of 3 methods and real load




图 5 随机动载荷识别结果局部对比

Fig.5 Local comparison of random load identification results

为了在频域上更加简单明确地表示载荷信号的特性和物理意义,根据识别出的随机动载荷时间历程样本,得到其对应的功率谱密度(PSD, power spectral density)函数,并与真实载荷的功率谱密度函数进行对比,如图 6 所示。由图 6 可以直观地看到,基于 ACNN 的随机动载荷识别结果功率谱密度函数曲线与真实载荷功率谱密度函数曲线吻合度更好,说明本文提出的基于 ACNN 的随机动载荷识别方法具有很好的识别效果。

为进一步研究基于 ACNN 的随机动载荷识别方法的抗噪能力,通过 2# 激振器施加 5%、10%、20%、

40%、60%水平的噪声激励,测量噪声干扰下的实验数据,进行基于 ACNN 的随机动载荷时间历程识别,部分识别结果如图 7 所示。





图 6 识别载荷的功率谱密度

Fig.6 PSD of identified load






图 7 不同噪声水平下随机动载荷识别结果

Fig.7 Random dynamic load identification results under different levels of noise

计算得到不同噪声水平下随机动载荷识别结果的 E_{RMSE} 和 R 如表 1 所示。结果表明,空洞卷积在提高感受野的同时不损失数据信息,提高了计算效率与精度,对比传统 CNN,利用 ACNN 对 GARTEUR 飞机模型进行噪声激励干扰下的随机动载荷时间历程的识别,识别载荷结果的精度更高,抗干扰能力更强。

表 1 基于 ACNN 的随机动载荷识别精度

Tab.1 Random dynamic load identification accuracy based on ACNN

噪声激励水平/%	E_{RMSE}/N	R
0	0.990 1	0.987 4
5	1.310 5	0.974 6
10	1.195 6	0.977 5
20	1.303 5	0.971 3
40	1.231 0	0.979 6
60	1.771 3	0.953 1

3 结语

本文针对随机动载荷识别问题,将一维 ACNN 应用于随机动载荷识别领域,利用空洞卷积可以增大感受野,扩大振动响应数据的特征提取范围的特点,提出一种基于 ACNN 的随机动载荷识别方法。通过分析 GARTEUR 飞机模型的随机动载荷识别实验结果,得出如下结论。

(1)基于 ACNN 的随机动载荷识别方法能够比较

准确、有效地识别出作用在结构上的随机动载荷时间历程。相较于标准 CNN,ACNN 通过提高扩张率,增大神经网络的感受野,进而增大计算过程中提供给神经网络的数据维度,表现出更好的识别能力与抗干扰能力。

(2)相较于传统动载荷识别方法,本文方法可以利用先进的人工智能技术构建基于“数据驱动”的神经网络,避免传统方法难以获取精确模型、受测量噪声影响大而导致识别误差较大等问题,是一种新型的动载荷识别方法,为今后复杂结构的动载荷识别问题提供了新的解决思路。

参考文献:

- [1] 杨智春,贾 有. 动载荷的识别方法[J]. 力学进展, 2015, 45: 29-54.
- [2] LIU R X, DOBRIBAN E, HOU Z C, et al. Dynamic load identification for mechanical systems: a review[J]. Archives of Computational Methods in Engineering, 2022, 29(2): 831-863.
- [3] MIAO B R, ZHOU F, JIANG C Y, et al. A comparative study of regularization method in structure load identification[J]. Shock and Vibration, 2018(1): 9204865.
- [4] WANG L J, LIU J W, XIE Y X, et al. A new regularization method for the dynamic load identification of stochastic structures[J]. Computers & Mathematics with Applications, 2018, 76(4): 741-759.
- [5] 贾 俊. 基于神经网络的图像轮廓提取算法研究[D]. 重庆: 重庆师范大学, 2009.
- [6] 张 方,朱德懋. 基于神经网络模型的动载荷识别[J]. 振动工程学报, 1997, 10(2): 156-162.
- [7] 宋雪刚. 基于光纤光栅传感器的动载荷识别算法研究[D]. 南京: 南京航空航天大学, 2018.
- [8] 曾俊玮,季元进,任利惠,等. 融合一维卷积神经网络和双向门控循环单元的 APM 车辆轮胎径向载荷识别方法[J]. 中国机械工程, 2023, 34(3): 359-368.
- [9] YANG H J, JIANG J H, CHEN G P, et al. Dynamic load identification based on deep convolution neural network[J]. Mechanical Systems and Signal Processing, 2023, 185: 109757.
- [10] 夏 鹏,杨 特,徐 江,等. 利用时延神经网络的动载荷倒序识别[J]. 航空学报, 2021, 42(7): 224452.
- [11] 杨 特,杨智春,梁舒雅,等. 平稳随机动载荷的信号特征提取与深度神经网络识别[J]. 航空学报, 2022, 43(9): 410-420.
- [12] 常晓通,闫云聚,刘 鑾,等. 基于 Green 函数和正则化的动态载荷识别方法[J]. 振动·测试与诊断, 2014, 34(1): 124-129.
- [13] 张燕红. 基于卷积神经网络的人脸识别研究[D]. 天津: 天津大学, 2018.
- [14] 谭 龙,高 昂. 感受野特征增强的 SSD 目标检测算法[J]. 计算机系统应用, 2020, 29(9): 149-155.
- [15] 冯振宇,郝晓帆,杨青青,等. GARTEUR 飞机模型的模态实验与模型修正技术[J]. 科学技术与工程, 2019, 19(25): 105-111.

(责任编辑:明 月)