

# 基于3D卷积神经网络的金属滚轮叶片转动计数算法设计与实现

郭立宇, 钟晨杰, 李志鹏

同济大学信息与通信工程系, 上海

收稿日期: 2022年12月6日; 录用日期: 2023年1月2日; 发布日期: 2023年1月12日

## 摘要

近年来, 基于计算机视觉的金属滚轮叶片缺陷检测算法应用越来越广泛, 由于周期性检测的原因, 需要有一种与之配套的滚轮叶片计数算法, 由于检测过程中孔探仪的辅助光源对叶片表面镜面反射的原因, 传统的基于边缘的检测算法难以实现有效的计数, 因此需要设计一种与光照无关的算法。基于此, 本文设计了一种基于3D卷积神经网络的金属滚轮叶片转动计数算法。本算法首先将单个金属叶片转动过程标注上相位标签, 将单个金属叶片的转动过程映射为相位的周期变换过程, 为了满足利普希茨条件, 将相位标签转换为该相位对应的三角函数值标签。其次利用LK光流法将标注好的数据进行预处理, 将叶片的转动方向归一化到水平方向。最后再将预处理好的数据送入3D卷积神经网络中回归出相位信息, 通过相位信息完成对叶片的转动计数。本文算法使用滚轮叶片在实际场景种采集到的数据进行验证, 验证结果表明, 该算法在真实现场数据上的计数准确率满足要求。

## 关键词

金属叶片, 转动计数, 3D卷积, 相位回归

## Design and Implementation of Metal Roller Blade Rotation Counting Algorithm Based on 3D Convolution Neural Network

Liyu Guo, Chenjie Zhong, Zhipeng Li

Department of Information and Communication Engineering, Tongji University, Shanghai

Received: Dec. 6<sup>th</sup>, 2022; accepted: Jan. 2<sup>nd</sup>, 2023; published: Jan. 12<sup>th</sup>, 2023

## Abstract

In recent years, the metal roller blade defect detection algorithm based on computer vision is more and more widely used. Due to periodic detection, a matching roller blade counting algorithm is needed. Due to the mirror reflection of the auxiliary light source of the borescope on the blade surface during the detection process, the traditional edge based detection algorithm is difficult to achieve effective counting, so it is necessary to design an algorithm independent of light. Based on this, this paper designs a metal roller blade rotation counting algorithm based on 3D convolution neural network. In this algorithm, the rotation process of a single metal blade is first marked with a phase tag, and the rotation process of a single metal blade is mapped to a periodic transformation process of phase. In order to meet Lipschitz conditions, the phase tag is converted into a trigonometric function value tag corresponding to the phase. Secondly, the marked data are preprocessed by LK optical flow method, and the rotation direction of the blade is normalized to the horizontal direction. Finally, the preprocessed data are sent into the 3D convolution neural network to regress the phase information, and the rotation of the blade is counted through the phase information. The algorithm in this paper is verified by the data collected by the roller blade in the actual scene. The verification results show that the counting accuracy of the algorithm in the real field data meets the requirements.

## Keywords

Metal Blade, Rotation Count, 3D Convolution, Phase Regression

Copyright © 2023 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

近年来, 计算机视觉得到了快速发展, 基于视觉的金属滚轮叶片缺陷检测算法[1] [2] [3] [4] [5], 由于其高效便捷的特点[6] [7] [8] [9] [10], 在工业界得到了广泛的应用。在具体应用这种检测算法时, 需要检测人员将孔探设备插入到机械设备外壳上预留的孔洞中, 利用孔探设备自带的光源对金属滚轮叶片进行拍摄。由于滚轮叶片是周期性转动的, 使用检测算法对其缺陷进行检测时, 需要确定整个转动周期的开始叶片和结束叶片, 以此来最终确定一个周期的结束。另外, 对于金属滚轮叶片缺陷的检测不仅需要检测出当前叶片上是否有缺陷以及缺陷的种类, 还需要定位当前叶片的编号, 这样才能让工作人员精准地获取缺陷信息, 准确地将缺陷定位到具体叶片上。基于这两点, 设计出一种与缺陷检测算法相匹配的、准确度高、鲁棒性强的叶片转动计数算法显得尤为重要。

传统的周期性部件的计数主要可以使用两种方式来实现。第一种是基于硬件的方式, 通过在设备上安装一些机械装置来解决[11] [12], 在周期性部件的转动过程中通过安装的机械装置产生一些脉冲信号, 利用这些信号来完成对周期性部件的转动计数。但是利用这种方式对金属滚轮叶片进行计数时, 需要滚轮叶片留有足够的空间去安装相应的设备, 而滚轮叶片的空间相对密闭且狭小, 无法安装这类装置, 所以难以应用硬件的方式对金属滚轮叶片进行计数。第二种是基于软件的方式, 这种方式需要获取周期性部件的图像, 再通过边缘检测方法提取出周期性部件的边缘[13] [14], 观察边缘的运动来完成对周期性部件的计数。但是利用这种方式对金属滚轮叶片进行计数时, 由于叶片处于较为封闭的空间中, 需要孔探

仪的辅助光源进行拍摄来获取图像，而辅助光源会对金属叶片产生强烈的镜面反射，导致采集到的图像获取边缘信息较为困难，使得计数的精度大大下降，所以也难以应用这种方式对金属滚轮叶片进行计数。

基于此，本文研究了一种基于 3D 卷积神经网络的金属滚轮叶片转动计数算法，该算法首先通过将单个金属叶片的转动过程映射为相位的周期变换过程，再利用 3D 卷积神经网络回归出输入视频数据各帧的相位信息，最后通过观察相位的周期变换情况完成对叶片的计数。该算法使用深度学习的方式完成对叶片的计数，无需在叶片上安装脉冲装置，解决了基于硬件方式的问题，并且通过训练神经网络适配真实任务，利用神经网络回归出相位值来完成对叶片的计数，无需获取叶片的边缘，避免了光照的影响，解决了基于软件方式的问题。

本文分为四章。第一章是本文的引言部分，主要介绍了目前金属叶片转动计数算法的研究现状，然后阐述本文的研究内容。第二章是本文算法的流程和具体组成部分。第三章是实验部分，使用检测过程中的真实数据进行实验。第四章是总结与展望。

## 2. 基于 3D 卷积的叶片计数算法

针对叶片计数问题，本文采用基于 3D 卷积神经网络的算法来解决，下面将从算法框架与流程以及各个算法模块的具体功能来详细介绍本文所设计的算法。

### 2.1. 算法框架与流程

基于 3D 卷积的金属滚轮叶片转动计数算法分为输入数据标注、数据预处理和 3D 卷积回归计数三个模块，其算法框架流程图如图 1 所示。

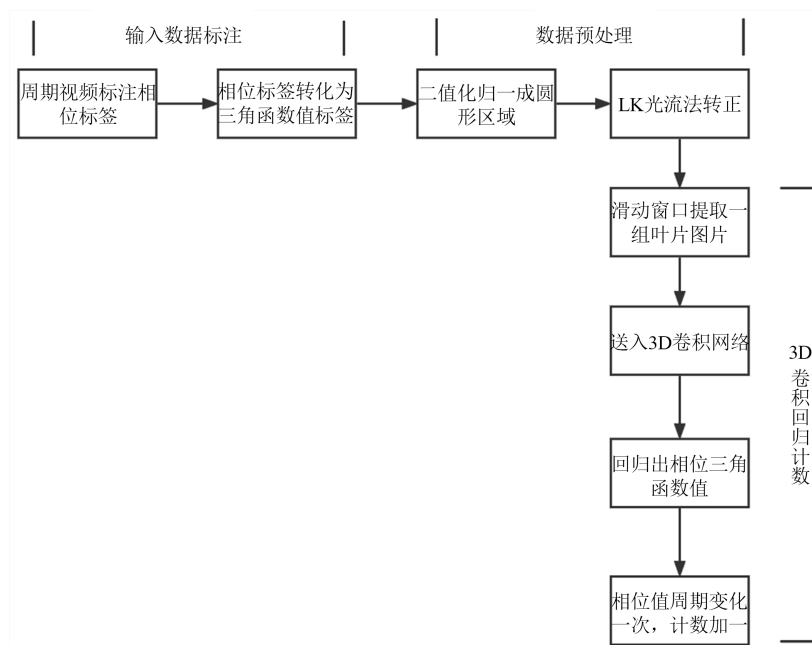


Figure 1. Algorithm flow chart  
图 1. 算法流程图

本文算法第一个模块是输入数据标注模块，该模块的功能是完成对整个输入数据标签的标注，为整个算法的有监督学习提供前置条件。该模块分为两个步骤，第一个步骤是对输入周期视频标注相位标签，定义金属叶片第一次出现在孔探仪摄像范围内，到下一个叶片第一次出现在孔探仪摄像范围内，为一个

叶片的转动周期，一旦一个叶片完成了一次周期转动，便可将计数值加一，该步骤将一个叶片的转动周期上的所有帧均匀地标注上  $0$  到  $2\pi$  相位。第二个步骤是将相位标签转换为三角函数值标签，为了满足利普希茨条件[15]，该步骤将每一帧图像的相位标签转换为该相位对应的三角函数值标签。本文算法第二个模块是数据预处理模块，该模块的功能是将金属叶片的转动方向归一化到水平方向，消除输入数据之间的差异性，充分利用神经网络的表示能力。该模块分为两个步骤，第一个步骤是将矩形金属叶片图像二值化归一成圆形区域。第二个步骤是 LK 光流法转正，该步骤首先提取金属叶片圆形图像的特征点，再利用 LK 光流法寻找转动方向，根据此方向旋转一定角度使运动方向处于水平方向，完成归一化。本文算法第三个模块是 3D 卷积回归计数模块，该模块的功能是将预处理好的数据送入 3D 卷积神经网络完成对叶片的计数。该模块分为四个步骤，第一个步骤是滑动窗口提取一组叶片图片，该步骤将预处理后的视频数据送入滑动窗口，滑动窗口会以一定的窗宽和步长提取出一组图像。第二个步骤将第一个步骤中提取出的一组图像送入 3D 卷积神经网络中。第三个步骤是利用神经网络回归出该组图像中间帧的相位标签所对应的三角函数值。第四个步骤是观察三角函数值标签的周期变换情况，一旦该标签完成一次周期变换，便可将计数值加一。

## 2.2. 输入数据标注

输入数据标注的第一步是对金属滚轮叶片中的每一个叶片标注上开始帧和结束帧。定义一个金属叶片第一次出现在孔探仪摄像范围内的某帧为开始帧，定义该叶片的下一个叶片第一次出现在孔探仪摄像范围内的某帧为结束帧。如图 2 所示。




Figure 2. Start frame and end frame

图 2. 开始帧和结束帧



对金属滚轮叶片的转动视频进行遍历，观察每一个金属叶片的转动周期，从而标注上每一个金属叶片的开始帧和结束帧。

输入数据标注的第二步是为视频中每一帧标注上相位标签。假设视频中的第  $a$  帧和第  $b$  帧是某一金属叶片的开始帧和结束帧，首先将第  $a$  帧和第  $b$  帧标注上  $0$  相位和  $2\pi$  相位。由于金属滚轮叶片的转动是较为均匀的，可以将第  $a$ 、 $b$  两帧之间的所有帧均匀地标注上  $0$  相位至  $2\pi$  相位中的一个相位，假设在第  $a$ 、 $b$  两帧之间有一第  $c$  帧，那么该帧的相位标签计算公式如公式 1 所示。

$$\text{phase} = \frac{c-a}{b-a} * 2\pi \quad (1)$$

根据公式 1 标注出一个周期的相位标签如图 3 所示。




Figure 3. Phase change of one period

图 3. 一个周期的相位变换

输入数据标注的第三步是将视频中的每一帧图像的相位标签转换为三角函数值标签，以此来满足利普希茨条件，计算公式如公式 2 所示。

$$\begin{aligned} \text{label}_{\sin} &= \sin\left(\frac{c-a}{b-a} * 2\pi\right) \\ \text{label}_{\cos} &= \cos\left(\frac{c-a}{b-a} * 2\pi\right) \end{aligned} \quad (2)$$

根据公式 3 标注出一个周期的三角函数值标签如图 4 所示。



Figure 4. Trigonometric function value change of one period

图 4. 一个周期的三角函数值变换

### 2.3. LK 光流法预处理

基于 3D 卷积神经网络的金属滚轮叶片转动计数算法的第二个模块是数据预处理部分，使用 LK 光流法对输入给算法的金属滚轮叶片周期转动视频进行处理，将金属滚轮叶片的转动方向归一化到水平方向，消除输入数据之间的差异性。

由于对金属叶片数据的获取是工作人员在机械设备外部预留的孔洞中插入孔探仪再手动转动金属叶片得到，孔探设备放置的位置存在一定的随机性，因此孔探设备的辅助光源拍摄的角度也存在一定的随

机性，这样的话就会导致在拍摄的时候无法每次都如同图 2 所示一样让金属叶片的转动维持在一个水平方向。例如图 5 所示的转动情况。



Figure 5. Non-horizontal rotation

图 5. 非水平方向转动

但其实这两种运动本质上是一样的，只是在旋转方向上有差异。而对于本文所使用的算法来说，考虑使用卷积神经网络，因为在网络层数固定的情况下，卷积神经网络所能表示的容量是有限的，如果将这些具有不同运动方向的叶片数据都送入到神经网络中进行训练的话，无疑会让神经网络分出更多的容量来记忆和处理这种方向信息，而减少真正用来回归计算预测值部分的容量，导致预测性能的下降。所以可以考虑使用预处理的方式首先将叶片的方向转正，这样使得输入到神经网络中的叶片图片都是在水平方向上的，可以让神经网络有限的容量更多地集中在对叶片转动周期的判断中来。

所以在将金属叶片图片送入神经网络之前，首先将金属叶片进行预处理操作，将不在水平方向上的金属叶片先进行转正操作。由于原始图像的大小是  $768 \times 1024$  像素，是一个矩形，没办法直接进行旋转，

而由于观察到金属叶片转动的区域主要分布在图片的中央区域，中心区域部分的运动便可以代表金属滚轮叶片的运动，因此只保留以图片中心点为圆心，半径为 384 像素的圆形区域作为输入数据。二值化处理操作如图 6 所示。





Figure 6. Binary processing

图 6. 二值化处理

因为对金属叶片的拍摄是通过孔探仪进行拍摄的，而在对金属叶片进行人工转动拍摄的时候，孔探仪已经固定好，所以图片中每个像素的亮度值基本是恒定不变的。其次，金属叶片的转动是检测人员手工进行转动，运动的幅度并不算剧烈。另外，由于金属叶片本身结构并不会变，所以前一帧中相邻像素点在后一帧中也是相邻的。综上所述，金属叶片的运动满足 LK 光流法[16][17]的三个要求，所以对二值化之后的金属叶片数据利用 LK 光流法来分析。

首先选取二值化后图片作为 LK 光流法的分析对象，其像素大小是  $768 \times 768$ 。选取图片中心区域的四个点作为原始特征点来为 LK 光流分析，四个点坐标分别为  $(380.0, 380.0)$ ,  $(380.0, 387.0)$ ,  $(387.0, 380.0)$ ,  $(387.0, 387.0)$ ，利用 LK 光流法分析特征点的运动，如图 7 所示。



**Figure 7.** Movement of feature points  
**图 7.** 特征点运动


通过分析前一帧特征点所在位置坐标以及后一帧特征点所在位置坐标,可以计算出运动方向的斜率,假设前一帧图片中四个特征点分别为 $(x_1, y_1), (x_2, y_2), (x_3, y_3), (x_4, y_4)$ , 后一帧图片中四个特征点分别为 $(x'_1, y'_1), (x'_2, y'_2), (x'_3, y'_3), (x'_4, y'_4)$ , 则可通过这两帧图片算出平均斜率如公式 3 所示。

$$\text{slope} = \frac{\sum_{i=1}^4 \frac{y'_i - y_i}{x'_i - x_i}}{4} \quad (3)$$

设一共用金属叶片转动的前  $n$  帧作为运动方向斜率分析用,使得前  $n$  帧中心特征点的运动基本运动到图像的边缘,一般选择 50 帧,可得到金属叶片转动的平均斜率  $\text{mean\_slope}$ ,从而计算出金属叶片转动的角度  $\text{angle}$ ,如公式 4 所示。

$$\text{mean\_slope} = \frac{\sum_{i=1}^n \text{slope}_i}{n}, \text{angle} = \arctan(\text{mean\_slope}) \quad (4)$$

得到金属叶片转动的角度之后,又由于之前已经将图片二值化处理成了一个圆形,根据公式 2 计算出来的平均角度值,可直接将中间区域的圆形旋转相应的角度,便可得到水平方向上运动的金属叶片图片,如图 8 所示。



**Figure 8.** Turn to horizontal direction  
**图 8.** 转动到水平方向

将金属叶片转正之后再送入到后续的神经网络中训练和预测,可以让神经网络有限的容量更多地集

中在运动周期判断上, 提高预测的准确性。

## 2.4. 3D 卷积回归预测

### 2.4.1. 网络结构

对于图片和视频类型数据, 使用卷积神经网络可以大大减少卷积核参数的数量, 让网络的收敛更快效果更好, 因此本文采用卷积神经网络。由于数据的输入是一个视频而非图片, 帧与帧之间是存在关联的, 如果直接将输入的一帧帧图片输入到卷积神经网络中, 便忽略了这些帧与帧之间的关联性。因此将普通的二维卷积神经网络转换为三维卷积神经网络。

将每 16 帧图像组合成一组, 利用滑动窗口的原理, 设定步长为 4, 取每个窗口的第 8 帧作为整个窗口的代表, 将第 8 帧图像的  $\sin$  值和  $\cos$  值作为神经网络的输出进行回归, 如图 9 所示。在整个视频上利用滑动窗口进行滑动, 直到滑动到视频的末尾。

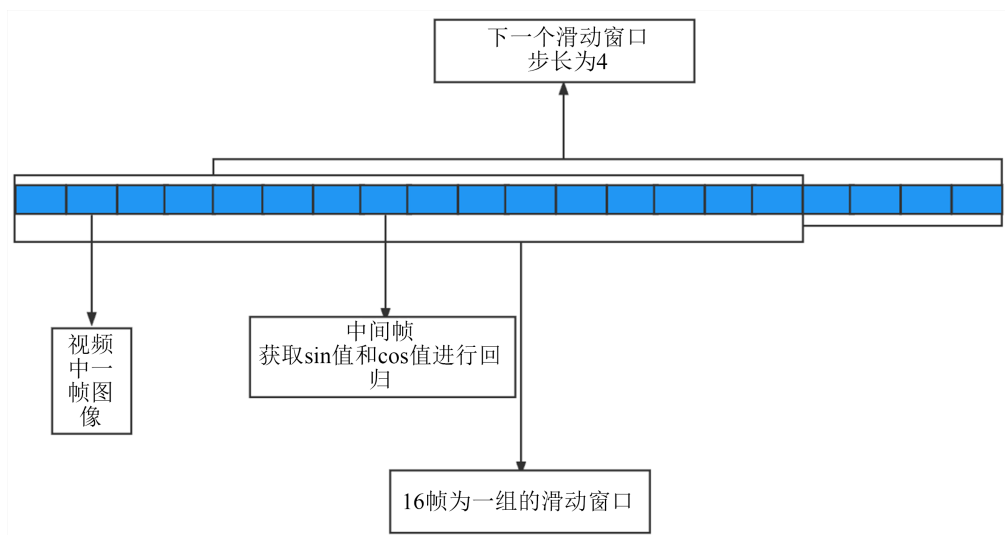


Figure 9. Sliding window  
图 9. 滑动窗口

将每组 16 帧图片组合成一组, 形成一个五维的张量, 送入到 3D 卷积层, 利用  $\text{relu}$  激活函数, 增加整个网络的非线性, 防止梯度消失, 以及将一部分神经元置零, 完成  $\text{dropout}$  的工作, 防止过拟合问题的产生。送入激活函数之后利用批归一化层对数据进行, 让整个网络更容易收敛以及收敛的更快。在经过若干个卷积层之后, 再将 3D 卷积得到的特征图送入到全连接网络中完成最后的回归任务, 最后的输出层设为两个节点, 代表该组图片开始帧的  $\sin$  值和  $\cos$  值。整个网络的结构图如图 10 所示。




Figure 10. Network structure  
图 10. 网络结构



### 2.4.2. 损失函数

整个网络的损失函数分为两个部分，第一部分是整体回归任务所产生的损失，使用 MSE 损失函数，由于最后输出层两个节点的值通过  $\tanh$  激活函数输出，所以值的范围已经在  $[-1, 1]$  之间。设  $x$  代表  $\sin$  节点输出值， $y$  代表  $\cos$  节点输出值，该组滑动窗口的开始帧的真实相位对应的  $\sin$  值为  $s$ ，真实相位对应的  $\cos$  值为  $c$ ，则 MSE 损失函数的表达式如公式 5 所示。

$$\text{MSE} = \frac{(x-s)^2 + (y-c)^2}{2} \quad (5)$$

设整个网络的 `batch_size` 为  $n$ ，则一个 batch 下的 MSE 损失如公式 6 所示。

$$\text{MSE} = \frac{\sum_{i=1}^n \frac{(x_i - s_i)^2 + (y_i - c_i)^2}{2}}{n} \quad (6)$$

由于输出层输出的两个值代表相位的  $\sin$  值和  $\cos$  值，所以两者的平方和应该越接近 1 越好，所以还应加入一项损失，如公式 7 所示。

$$\text{Loss}_2 = 1 - x^2 - y^2 \quad (7)$$

一个 batch 下的损失函数如公式 8 所示。

$$\text{Loss}_2 = \frac{\sum_{i=1}^n (1 - x_i^2 - y_i^2)}{n} \quad (8)$$

将上述两项损失合并起来，并加入一个超参数  $\lambda$  来调节两项损失对总损失的贡献程度，如公式 9 所示。

$$\text{Loss}_{\text{总}} = \text{MSE} + \lambda \text{Loss}_2 \quad (9)$$

将两项损失代入得总损失的表示如公式 10 所示。

$$\text{Loss}_{\text{总}} = \frac{\sum_{i=1}^n \frac{(x_i - s_i)^2 + (y_i - c_i)^2}{2}}{n} + \lambda \frac{\sum_{i=1}^n (1 - x_i^2 - y_i^2)}{n} \quad (10)$$

## 3. 实验结果与讨论

### 3.1. 实验目的

选取真实检测过程中的 5 段金属滚轮叶片周期转动视频作为测试结果，这些金属叶片周期转动视频都是在真实检测过程中工作人员将孔探仪伸入到机械设备内部并手工转动金属叶片拍摄而得。

本次实验使用两块 3060 显卡用作神经网络训练和预测，并使用开始帧这一信息来代表金属叶片转动的周期信息。这 5 段叶片转动的开始帧如表 1 所示。以视频 1 为例，其视频中第 92 帧、第 152 帧和第 257 帧是开始帧，而一个金属叶片的开始帧恰好是上一个叶片的结束帧。所以第 92 帧转动到第 152 帧刚好是一个金属叶片的转动周期，而从第 152 帧到第 257 帧又是下一个金属叶片的转动周期。

将这 5 段金属叶片周期转动视频送入到计数算法系统中，系统会按照 2.1 节所示的流程输出对应的相位信息，根据该相位信息预测出对应的开始帧信息。将预测出来的开始帧信息和真实的开始帧信息进行对比，便可以得到相应的准确率信息，以此来判定算法的性能。

**Table 1.** Period video start frame  
**表 1.** 周期视频开始帧

周期视频	开始帧							
视频 1	叶片 1 开 始帧	叶片 2 开 始帧	叶片 3 开 始帧	叶片 4 开 始帧	叶片 5 开 始帧	叶片 6 开 始帧	叶片 7 开 始帧	
	92	152	257	324	429	553	641	...
视频 2	叶片 1 开 始帧	叶片 2 开 始帧	叶片 3 开 始帧	叶片 4 开 始帧	叶片 5 开 始帧	叶片 6 开 始帧	叶片 7 开 始帧	
	244	309	382	482	548	625	710	...
视频 3	叶片 1 开 始帧	叶片 2 开 始帧	叶片 3 开 始帧	叶片 4 开 始帧	叶片 5 开 始帧	叶片 6 开 始帧	叶片 7 开 始帧	
	199	244	313	415	473	551	633	...
视频 4	叶片 1 开 始帧	叶片 2 开 始帧	叶片 3 开 始帧	叶片 4 开 始帧	叶片 5 开 始帧	叶片 6 开 始帧	叶片 7 开 始帧	
	235	307	359	424	482	545	606	...
视频 5	叶片 1 开 始帧	叶片 2 开 始帧	叶片 3 开 始帧	叶片 4 开 始帧	叶片 5 开 始帧	叶片 6 开 始帧	叶片 7 开 始帧	
	82	137	187	268	348	440	533	...

### 3.2. 实验结果

本次实验使用三个指标来评判算法的准确性，分别是漏报帧数、误报帧数和平均差帧值。假设某段金属滚轮叶片的周期转动视频共有  $m$  个真实开始帧，代表着在这段周期转动视频中一共有  $m$  个金属滚轮叶片相继转动，这些真实开始帧构成集合  $A$ ，将这段视频送入到本文算法网络中，回归出相应的相位信息，观察相位信息的周期变化情况，将相位信息完成一次周期变化的所在帧定义为预测开始帧，假设预测出  $n$  个预测开始帧，代表着本文算法预测在这段周期转动视频中一共有  $n$  个金属滚轮叶片相继转动，这  $n$  个预测开始帧构成集合  $B$ 。

对于任意  $x$  属于集合  $A$ ，初始化一个空集合  $C$ ，对于集合  $B$  中任何元素  $y$ ，如果  $x$  和  $y$  的差值的绝对值小于 10，则将  $y$  元素加入集合  $C$ ，遍历集合  $B$ ，将所有满足条件的元素加入集合  $C$  中。如果  $C$  中一元素  $z$ ，其满足对于任意元素  $u$  属于  $C$ ， $x$  与  $z$  的绝对值均小于等于  $x$  与  $u$  的绝对值，则定义元素  $x$  和元素  $z$  相匹配。如果遍历完  $B$  集合，集合  $C$  依然为空，则定义  $x$  无相匹配元素。

遍历集合  $A$  中所有元素，计算每一个元素在集合  $B$  中相匹配的元素，如果某一元素  $v$  属于  $A$ ，其无法在集合  $B$  中找到相匹配的元素，则漏报帧数加一。遍历集合  $A$  中所有元素，得到最终漏报帧数指标。对于集合  $B$  中一个元素  $w$ ，对于任意元素  $r$  属于集合  $A$ ， $w$  和  $t$  都不匹配，则将误报帧数加一，遍历集合  $B$  中所有元素，统计最终误报帧数指标。

如果元素  $s$  属于  $B$ ，元素  $t$  属于  $A$ ，如果任意元素  $o$  属于  $A$ ， $t$  和  $s$  差值的绝对值均小于等于  $o$  和  $s$  差值的绝对值，则定义  $t$  为  $\text{match}(s)$ 。遍历  $B$  中所有元素，便可求出平均差帧值指标，如公式 11 所示。

$$\text{num}_{\text{平均差帧值}} = \frac{1}{n} \sum_{i=1}^n |B_i - \text{match}(B_i)| \quad (11)$$

将在真实检测过程中收集到的 5 段金属滚轮叶片送入本文算法中，分别计算这 5 段金属滚轮叶片转动视频的平均差帧值、漏报帧数和误报帧数三个指标，得到的结果如表 2 所示。

**Table 2.** Accuracy indicators  
**表 2.** 准确性指标

	平均差帧值	漏报帧数	误报帧数
视频 1	2.786	0	0
视频 2	2.455	0	0
视频 3	1.2	0	0
视频 4	1.429	0	0
视频 5	1.25	0	0

### 3.3. 结果分析与讨论

本节根据 3.2 节的实验结果可知, 使用本算法对 5 类不同的金属叶片进行转动计数都未出现漏报和误报的存在, 对于转动周期个数的判定达到要求。由于金属叶片的周期检测视频的帧速率是 60 帧每秒, 而金属叶片一个转动周期在 3 秒左右, 所以一个完整的金属叶片周期转动过程在视频中大概有 180 帧左右, 根据表 2 可以看出, 平均差帧值相对于一个周期总帧数较小, 所以对转动开始帧的预测也可以达到要求。

为了观察算法中 LK 光流法预处理这一关键步骤对算法总体性能的影响, 本次实验在同样的条件下做了有 LK 光流法预处理和无 LK 光流法预处理的两组对比。对于每一组样本, 分为两路进行实验, 首先两路都将金属叶片周期转动视频标注同样的标签, 之后一路数据样本送入预处理系统进行转正处理, 一路不进行任何预处理操作。最后都送入 3D 卷积网络部分进行周期预测, 两路网络的结构一致, 网络的权重也相同。最后对两路预测结果计算三种预测准确性指标, 如表 3 至表 7 所示。

**Table 3.** Video 1 effect comparison  
**表 3.** 视频 1 效果对比

	平均差帧值	漏报帧数	误报帧数
经过光流法处理	2.786	0	0
未经光流法处理	4.133	0	1

**Table 4.** Video 2 effect comparison  
**表 4.** 视频 2 效果对比

	平均差帧值	漏报帧数	误报帧数
经过光流法处理	2.455	0	0
未经光流法处理	3.364	0	0

**Table 5.** Video 3 effect comparison  
**表 5.** 视频 3 效果对比

	平均差帧值	漏报帧数	误报帧数
经过光流法处理	1.2	0	0
未经光流法处理	1.333	0	0


**Table 6.** Video 4 effect comparison  
**表 6.** 视频 4 效果对比

	平均差帧值	漏报帧数	误报帧数
经过光流法处理	1.429	0	0
未经光流法处理	1.429	0	0


**Table 7.** Video 5 effect comparison  
**表 7.** 视频 5 效果对比

	平均差帧值	漏报帧数	误报帧数
经过光流法处理	1.25	0	0
未经光流法处理	1.5	0	0

以金属叶片转动的圈数作为横坐标，以预测开始帧值和真实开始帧值之间的差值作为纵坐标，绘出两种方法在 5 段金属叶片转动视频的对比图如图 11 所示。




(a) 视频 1 效果对比




(b) 视频 2 效果对比






(c) 视频 3 效果对比



(d) 视频 4 效果对比



(e) 视频 5 效果对比

Figure 11. Effect comparison  
图 11. 效果对比

从以上结果可以看出, 经过预处理的 3D 卷积方法, 也就是保留叶片中心位置的圆形区域, 再将其余位置二值化成背景, 并将不在水平方向运动的叶片通过 LK 光流法转正为水平方向上的运动, 再送入 3D 卷积网络中进行周期的预测。这种方法相对与未预处理的方法来说, 与真实开始帧之间的平均差帧值更小, 并且误报率更低, 效果更好, 因此证明了预处理的有效性。

## 4. 结论

针对金属叶片光照反射较强, 金属叶片表面图像噪声较多, 因此难以准确地对金属叶片转动进行计数的问题, 本文提出了一种基于 3D 卷积神经网络的金属叶片周期转动计数算法。首先通过将单个金属叶片的转动过程映射为一个 0 到  $2\pi$  的相位周期变化, 由于神经网络无法接受输出值的突变, 也即两个周期交替时  $2\pi$  到 0 的激烈变化, 所以再将 0 到  $2\pi$  的相位周期变化转化为  $\sin$  值和  $\cos$  值的连续周期变化, 其次金属叶片转动视频中各个帧之间是有相互联系的, 不应该直接使用简单的卷积神经网络来对视频进行回归操作。所以利用滑动窗口以一定的步长在视频上进行滑动, 将一组窗口中的所有帧图片送入 3D 卷积网络中进行回归操作得出  $\sin$  值和  $\cos$  值, 再通过  $\sin$  值和  $\cos$  值的变化来判断金属叶片的周期计数情况。最后, 由于神经网络的表示能力是有限的, 而金属叶片的转动信息主要集中在图片中心区域, 并且如果金属叶片的转动方向较多, 神经网络还需要分出一部分表示能力来处理叶片转动方向信息。所以在将图片送入神经网络之前, 选取中心圆形区域图片, 其余部分二值化成背景, 再利用 LK 光流法将金属叶片的转动旋转为在水平方向上运动, 之后再送入神经网络中进行周期预测。实验表明, 该算法可以较为准确地预测出金属叶片转动的周期, 从而完成叶片转动计数, 验证了算法的可行性。

## 基金项目

这项工作得到了国家自然科学基金的资助, 资助号威 61773290。

## 利益冲突

作者声明没有利益冲突。

## 参考文献

- [1] 李亦伦, 成和祥, 董礼, 苏宝定, 刘方涛. 基于改进 Yolov4 的风电机组叶片缺陷检测算法[J]. 风机技术, 2022, 64(1): 46-53. <https://doi.org/10.16492/j.fjjs.2022.01.0006>
- [2] 赵春溢, 郭洪涛, 郭涛, 梁国, 荆海城. 一种风机叶片图像采集及缺陷检测系统[J]. 红外技术, 2020, 42(12): 1203-1210.
- [3] 曹庆才, 吴立东, 张路娜, 张舒翔, 徐志轩. 基于机器视觉的风机叶片缺陷检测[J]. 电工技术, 2021(22): 74-76+155. <https://doi.org/10.19768/j.cnki.dgjs.2021.22.024>
- [4] 应俊, 刘迅, 曾学仁, 方亮, 田楠. 基于 SSD 算法优化的风机叶片缺陷检测研究与应用[J]. 浙江电力, 2021, 40(8): 47-52. <https://doi.org/10.19585/j.zjdl.202108007>
- [5] 董礼, 韩则胤, 王宁, 王恩路, 苏宝定. 基于深度学习算法的风电机组叶片开裂缺陷分析[J]. 计算机测量与控制, 2022, 30(8): 142-146+154. <https://doi.org/10.16526/j.cnki.11-4762/tp.2022.08.023>
- [6] Li, X., Wang, W., Sun, L., et al. (2022) Deep Learning-Based Defects Detection of Certain Aero-Engine Blades and Vanes with DDSC-YOLOv5s. *Scientific Reports*, **12**, Article No. 13067. <https://doi.org/10.1038/s41598-022-17340-7>
- [7] Li, D., Li, Y., Xie, Q., Wu, Y., Yu, Z. and Wang, J. (2021) Tiny Defect Detection in High-Resolution Aero-Engine Blade Images via a Coarse-to-Fine Framework. *IEEE Transactions on Instrumentation and Measurement*, **70**, 1-12. <https://doi.org/10.1109/TIM.2021.3062175>
- [8] Qiu, Z., Wang, S., Zeng, Z. and Yu, D. (2019) Automatic Visual Defects Inspection of Wind Turbine Blades via YOLO-Based Small Object Detection Approach. *Journal of Electronic Imaging*, **28**, Article ID: 043023. <https://doi.org/10.1117/1.JEI.28.4.043023>
- [9] Guo, J., Liu, C., Cao, J. and Jiang, D. (2021) Damage Identification of Wind Turbine Blades with Deep Convolutional

- 
- Neural Networks. *Renewable Energy*, **174**, 122-133. <https://doi.org/10.1016/j.renene.2021.04.040>
- [10] Zhu, J., Wen, C. and Liu, J. (2022) Defect Identification of Wind Turbine Blade Based on Multi-Feature Fusion Residual Network and Transfer Learning. *Energy Science & Engineering*, **10**, 219-229. <https://doi.org/10.1002/ese3.1024>
- [11] 曹成. 转动手柄的计数装置[J]. 机械工人·冷加工, 1988(1): 48.
- [12] 潘尚渠. 转动装置周数计数中转向和摆动的软件识别[J]. 纺织学报, 1986(11): 39-41+3. <https://doi.org/10.13475/j.fzxb.1986.11.011>
- [13] 徐天芝, 杨青峰. 针对椒盐噪声图像的 Canny 边缘检测算法[J]. 计算机时代, 2022(9): 63-67. <https://doi.org/10.16644/j.cnki.cn33-1094/tp.2022.09.014>
- [14] Canny, J. (1986) A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **8**, 679-698. <https://doi.org/10.1109/TPAMI.1986.4767851>
- [15] 吴海梅, 李明泉, 祝璇. 利普希茨条件应用的研究[J]. 内江师范学院学报, 2008(S1): 218-219.
- [16] 何燕. 图像序列光流计算方法概述[J]. 电脑知识与技术, 2019, 15(5): 173-175. <https://doi.org/10.14004/j.cnki.ckt.2019.0431>
- [17] Zhao, G., Wang, X. and Wang, L. (2012) Motion Analysis and Research of Local Navigation System for Visual-Impaired Person Based on Improved LK Optical Flow. 2012 *Fifth International Conference on Intelligent Networks and Intelligent Systems*, Tianjin, 1-3 November 2012, 348-351. <https://doi.org/10.1109/ICINIS.2012.80>