

胡常俊, 夏红红, 曹玉林, 等. 基于果蝇视觉神经网络的农作物害虫检测预警[J]. 智能计算机与应用, 2025, 15(4): 69-76.
DOI: 10.20169/j.issn.2095-2163.24093003

基于果蝇视觉神经网络的农作物害虫检测预警

胡常俊, 夏红红, 曹玉林, 陈秋菊

(茅台学院, 贵州 仁怀 564500)

摘要: 为提高自然环境下农作物害虫检测预警, 实现综合治理的意义, 现有的机器视觉技术较难对其进行有效的监测。基于果蝇视觉神经系统的生物特性与 LPTC 神经元响应特性提出一种农作物害虫预警检测的神经网络模型。借助果蝇视觉神经系统的前馈神经元细胞和 LPTC 神经元响应特性机理构建合成尖峰神经元细胞, 借助合成尖峰神经元细胞建立预警检测系统, 以检测农作物中出现的害虫。该文涉及生物视觉神经机理启发的害虫动态视觉信息处理, 可为智能视频监控中的害虫检测分析提供新方法。

关键词: 害虫; 果蝇视觉神经系统; LPTC 神经元; 前馈神经元细胞; 合成尖峰神经元细胞

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 2095-2163(2025)04-0069-08

Crop pest warning and detection based on fruit fly visual neural network

HU Changjun, XIA Honghong, CAO Yulin, CHEN Qiuju

(Moutai Institute, Renhuai 564500, Guizhou, China)

Abstract: In order to improve the detection and early warning of crop pests in the natural environment and realize the significance of comprehensive management, it is difficult for existing machine vision technologies to realize effective monitoring. Based on the biological characteristics of the fruit fly's visual nervous system and the response characteristics of LPTC neurons, a neural network model for early warning and detection of crop pests is proposed. Synthetic spiking neuron cells are constructed by means of the feedforward neuron cells of the fruit fly's visual nervous system and the response characteristic mechanism of LPTC neurons. An early warning detection system is established by means of synthetic spiking neuron cells to detect pests appearing in crops. This paper involves the processing of pest dynamic visual information inspired by the biological optic nerve mechanism, which can provide a new method for pest detection and analysis in intelligent video surveillance.

Key words: pests; fruit fly visual nervous system; LPTC neurons; feedforward neuron cells; synthetic spiking neuron cells

0 引言

在农作物生长期, 虫害存在突发性、危害面积大等特点, 及时发现和控制害虫, 积极采取有效防治措施, 可以确保农作物的产量和质量。目前, 害虫检测主要靠人工识别, 智能化检测程度低, 因此, 需要一种有效的害虫检测预警检测系统, 及时地发现农作物中的害虫。

近年来, 国内外研究学者都已经将机器视觉算法应用在农业害虫识别检测领域。李亚硕等学者^[1]采用固定位置放置粘虫板捕捉害虫并自动识别, 同时利用自动阈值分割, 标粘连处理、目标识别

和利用生物特征干扰去除等机器视觉方法, 为病虫害防治提供依据。Faithpraise 等学者^[2]利用聚类 and 滤波的方法识别病虫害。Mireia 等学者^[3]采用多重 PCR 方法检测, 鉴定关于谷蠹、谷象、米象、玉米象、麦蛾的虫态。姚青等学者^[4]提出一种改进 RetinaNet 的水稻冠层害虫为害状自动检测模型, 模型中采用 ResNeXt101 作为特征提取网络。该模型对 2 种害虫为害状区域检测的平均精度均值达到 93.76%。Mohanty 等学者^[5]和 Ferentinos^[6]利用卷积神经网络 (Convolutional Neural Networks, CNN) 模型识别农作物中存在的几十种病虫害, 取得较好的检测效果。据新刚等学者^[7]利用太赫兹光谱仪加

基金项目: 遵义市科技计划项目 (遵市科合 HZ 字 (2022)168 号, (2023)122 号)。

作者简介: 胡常俊 (1991—), 男, 硕士, 主要研究方向: 智能信息处理。Email: 1262555320@qq.com; 夏红红 (1995—), 女, 硕士, 中级职称, 主要研究方向: 密码学, 信息安全; 陈秋菊 (1989—), 女, 副教授, 主要研究方向: 机器学习, 故障诊断, 音频识别, 多媒体数据检索。

收稿日期: 2024-09-30

装反射成像模块,对麦粒内部结构进行太赫兹层成像,该方法能有效地识别出麦粒内部的虫蛀区域,但未能实现堆积麦粒虫蛀损害的在线监测。张诗雨等学者^[8]建立真实背景下粮仓害虫图像数据集 SGI-6,使用聚类算法改进 Faster R-CNN 模型的区域提案网络,识别 6 种常见的储粮害虫,且其平均准确率 (*mAP*) 达到 96.63%。以上识别检测害虫方法是基于数字图像处理技术和基于深度学习的方法,存在依赖先验规则、计算资源大的缺点。对此类问题的研究需要寻求新技术的突破。研究可知,动物的视觉神经系统在长时间的进化演变中,适应实际场景中对目标有特殊偏好的响应检测神经元,例如,果蝇的视觉系统感知外部环境中视觉信息,且能获取视场中明暗光线强度的行为变化量,利用神经层中小叶板切向细胞 (Lobula Plate Tangential Cells, LPTC) 检测目标的运动方向,实现目标的检测、跟踪等功能^[9-10]。然而,目前尚未有借助生物启发构建农作物害虫目标检测技术模型的相关研究报道。因此,本文拟借助果蝇视觉神经系统来探索和设计在视觉场景中农作物中出现害虫的预警检测模型。

基于果蝇视觉神经系统的生物特性与 LPTC 神经元响应特性,研究在视觉场景下农作物害虫预警检测的问题,主要研究包括:

(1) 适应不同场景下的视觉神经网络,用于检测农作物中存在的害虫。

(2) 利用合成尖峰神经元细胞建立一种仿生的农业害虫检测神经网络模型 (Agricultural Pest Detection Neural Network Model, APDNNM)。

(3) 基于不同环境下的农作物害虫视频,开展了系统的实验并验证 APDNNM 的性能。

1 相关工作

1.1 果蝇视觉神经系统通路

果蝇视觉神经系统的功能结构、器官组织等神经生理学理论中提及,果蝇视觉神经系统由 2 只复眼组成,每只复眼超过 3 500 个小眼^[11]。果蝇利用视觉神经系统的感知层 (Photoreceptor, P) 感知外界目标信息光亮强度的变化;将信息差传递到视网膜层 (Retina, R),消除信息冗余噪声,将信号去极化处理后传递给薄膜层 (Lamina, L);利用分流抑制或侧抑制获得输出行为量;髓质层 (Medulla, M) 中 m_1 节点采用对称侧抑制机制和运动方向检测器获得目标局部运动输出量, m_2 节点通过累加的方式获得目标运动输出行为量;小叶板切向细胞 (Lobula Plate

Tangential Cells, LPTC) 具有目标方向检测功能,同时还有尖峰传递神经元 H2^[12]、小目标运动检测神经元 LC11^[13] 和 LC16^[14] 等,每个 LPTC 神经元对特定运动模式和方向具有响应特性,并将其输出行为量传递给脑神经系统,为果蝇检测目标提供重要参考^[15]。

1.2 人工视觉系统设计

农业害虫主要出现在植物根茎和叶子等部位,以缓慢的运动啃咬农作物的根茎和叶子,就会在一定的时间内导致植物死亡,需要及时发现,及早处理。因此,本文基于果蝇视觉神经系统能实时检测运动目标变化行为的生物机理,设计与实现一种仿生的农业害虫检测神经网络模型 (Agricultural Pest Detection Neural Network Model, APDNNM)。

APDNNM 将单目摄像机拍摄的视频图像序列进行加工处理获得目标信息后,送入系统网络模型中获得时空位置信息膜电位兴奋量的变化。本文提出的视觉神经网络模型内部结构如图 1 所示。图 1 中,APDNNM 分别由突触前和突触后神经网络组成。模型的设计细节如下所述。

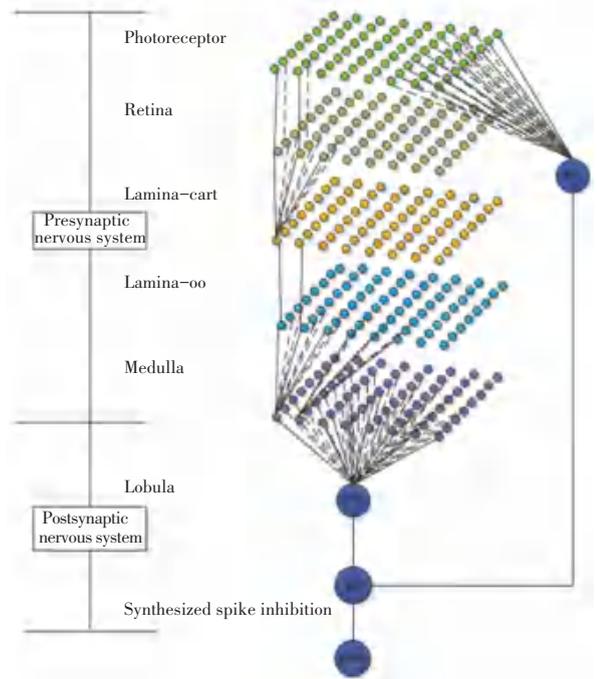


图 1 APDNNM 内部结构图

Fig. 1 Internal structure diagram of APDNNM

1.3 突触前神经网络

APDNNM 的突触前神经网络网络包括 Photoreceptor、Retina、Lamina 和 Medulla 四个神经层,模拟果蝇视觉神经系统的结构特性。将视频图像序列输入到网络中,再逐层对目标信息产生的膜

电位兴奋量进行处理。各神经层的功能设计如下。

1.3.1 P和R神经层

P和R神经层是由 $M \times N$ 个感光细胞构成,每个感光细胞对应输入图像的像素点。P层利用目标检测识别算法获得目标信息 $P(i, j)$,将R层中 $M \times N$ 个感光细胞划分为 $M = 8m$ 和 $N = 8n$ 。对目标信息做平滑滤波处理,消除噪声影响,由此获得对应子块的输出,即可推得:

$$Z_t(i, j) = \frac{1}{3}(P_t(i, j) + P_{t-1}(i, j) + P_{t-2}(i, j)) \quad (1)$$

其中, Z_t 表示R层细胞 (i, j) 在第 t 帧时刻的输出膜电位; P_t 、 P_{t-1} 和 P_{t-2} 分别表示存储 t 时刻帧、 $t-1$ 时刻帧和 $t-2$ 时刻帧的像素值。

1.3.2 L神经层

L神经层是由墨盒节点(Cartridge, Cart)和开关节点(On-Off, OO)层构成,Cart节点层中 (p, q) 细胞的输入的公式可表示为:

$$X_t(6i + p, 6j + q) = \sum_{u, v=0}^2 w_{uv} P_t(8i + k + u, 8j + l + v) \quad (2)$$

其中, w_{uv} 表示 3×3 的高斯卷积核,即:

$$w_{uv} = \frac{1}{16} \begin{bmatrix} \hat{e}_1 & 2 & \hat{u} \\ \hat{e}_2 & 4 & 2\hat{u} \\ \hat{e}_1 & 2 & \hat{u} \end{bmatrix} \quad (3)$$

其中, $p \geq 1, q \geq 1, 1 \leq i \leq m, 1 \leq j \leq n$,经由下式输出位置 (r, s) 处Cart节点细胞的输出量:

$$E_t(r, s) = X_t(r, s) - X_{t-1}(r, s) \quad (4)$$

其中, $1 \leq r \leq 6m, 1 \leq s \leq 6n$ 。OO节点细胞是由 $6m \times 6n$ 个节点细胞构成,并且对应接受Cart节点细胞的输入,然后经由分流抑制获得当前时刻OO节点细胞输出量 $\chi_t(r, s)$:

$$\dot{\chi}_t(r, s) = -A_t \chi_t(r, s) + (B_t - \chi_t(r, s)) \gamma_t(r, s) \quad (5)$$

其中, A_t 表示正的衰减系数; B_t 表示正的兴奋活跃度; $\gamma_t(r, s)$ 表示Cart节点细胞 (r, s) 的侧抑制量。研究推得的公式为:

$$\gamma_t(r, s) = E_t(r, s) - \frac{1}{8} \sum_{-1 \leq k, l \leq 1} E_{t-1}(r+k, s+l), \quad k+l \neq 0 \quad (6)$$

1.3.3 M神经层

M神经层是由 $2m \times 2n$ 个子块节点细胞按顺序排列构成,OO节点细胞 (r, s) 借助关联运动检测

器EMD^[16]获得 $2m \times 2n$ 个子块的节点细胞 (r, s) 输出量:

$$m_t(u, v) = \chi_t(3r+1, 3s+1) \times \chi_{t-1}(3r+u, 3s+v) - \chi_{t-1}(3r+1, 3s+1) \times \chi_t(3r+u, 3s+v) \quad (7)$$

其中, $0 \leq (u, v) \leq 2$,且 $(u, v) \neq (1, 1)$,经由关联运动检测器获得 (r, s) 节点细胞8个方向行为量,得到表达式为:

$$m_t(r, s) = \sum_{u=0, v=0}^2 m_t^2(u, v), (u, v) \neq (1, 1) \quad (8)$$

利用Sigmoid函数进行归一化处理^[16],获得节点细胞 (r, s) 的输出行为量:

$$M_t(r, s) = \frac{1}{1 - \exp(-m_t(r, s))} - 0.5, \quad 0 \leq r \leq 2m, 0 \leq s \leq 2n \quad (9)$$

1.4 突触后神经网络

APDNM的突触后神经网络是由小叶板切向细胞(Lobula Plate Tangential Cells, LPTC)、前馈细胞(FeedForward Cell, FFC)和合成尖峰细胞(Synthesized Spike Cell, SSC)构成检测神经网络模型。功能设计如下。

1.4.1 LPTC神经层

图1中,小叶板切向细胞LPTC接受突触前神经系统中细胞的输出量,进而依据自身的输出量借助检测阈值方案^[17]来确定是否发送尖峰信号。经由下式产生LPTC的输出量:

$$\dot{Y}_t(lob) = -A_p Y_t(lob) + (B_p - Y_t(lob)) \left(\sum_{r=1}^{2m} \sum_{s=1}^{2n} M_t(r, s) - \sum_{r=1}^{2m} \sum_{s=1}^{2n} M_{t-1}(r, s) \right) \quad (10)$$

其中, A_p 和 B_p 分别表示 $Y(lob)$ 衰退系数和神经元细胞输出的最大值。

门限阈值设置偏高,不能及时检查害虫;设置偏低,会出现误报现象。因此,根据LPTC输出量设计的门限阈值^[17]需要自适应的变化,计算公式具体如下:

$$\sigma_t(th) = \begin{cases} 0, & \text{if } Y_t(lob) \leq 0 \\ Y_t(lob) + \tau, & \text{else if } Y_t(lob) > 0, \bar{Y}_t \leq 0 \\ |Y_t| + \tau, & \text{else if } Y_t(lob) > 0, \bar{Y}_t > 0, |Y_t| > \tau \\ \tau, & \text{else } Y_t(lob) > 0, \bar{Y}_t > 0, |Y_t| \leq \tau \end{cases} \quad (11)$$

其中, $\sigma_t(th)$ 表示门限阈值; t 表示当前帧图像; Y_t 与 \bar{Y}_t 分别由下式进行计算:

$$\bar{Y}_t = \sum_{i=1}^l w_i Y_{t-l-i}(lob), w_i = \frac{1 - \lambda(t-i)}{\sum_{j=1}^l (1 - \lambda(t-l+j))}, 1 \leq i \leq l \quad (12)$$

$$Y_t = \frac{Y_t(lob) - \bar{Y}_t}{Y_t(lob) + \bar{Y}_t} \quad (13)$$

其中, l 表示图像帧的时间步长。当农作物中出现害虫时, 会触发小叶板切向细胞的输出量, 若到达一定程度会出现尖峰信号, 即:

$$\beta_t = \begin{cases} 1, & \text{if } Y_t(lob) \geq \sigma_t(th) \\ 0, & \text{else} \end{cases} \quad (14)$$

其中, 1 表示出现尖峰信号。

1.4.2 前馈细胞

FFC 接受 P 神经层中目标信息光亮强度的变化, 抑制目标信息受环境引起的噪声干扰, FFC 经平滑滤波处理后的信息 $F_t(i, j)$ 为:

$$F_t(i, j) = \sum_{x=0}^2 \sum_{y=0}^2 P_t(i, j) w_{xy} \quad (15)$$

其中, w_{ij} 的平滑滤波核^[18] 可以表示为:

$$w_{ij} = \begin{bmatrix} 0.25 & 0.50 & 0.25 \\ 0.50 & 1.00 & 0.50 \\ 0.25 & 0.50 & 0.25 \end{bmatrix} \quad (16)$$

经由下式可得 t 帧的平均灰度值^[19]:

$$V_t(FFC) = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N F_t(i, j) \quad (17)$$

随后, 经由下式对上式获得的平均灰度值做平滑处理:

$$F_t(FFC) = V_t(FFC) + \sum_{l=1}^{n_c} k_l V_{t-l}(FFC) \quad (18)$$

其中, n_c 表示图像帧的时间步长; $k_l = \text{Sigmoid}(n_c \times l)$ 表示时间步长的持久性系数。最后, 对 FFC 的输出做归一化处理:

$$S_t(FFC) = 2(\text{Sigmoid}(F_t(FFC)) - 0.5) \quad (19)$$

经由下式可得 t 帧时刻前馈细胞发送尖峰信号:

$$S_t(FFCspike) = \begin{cases} 1, & \text{if } T_{FFC} \leq S_t(FFC) \\ 0, & \text{else} \end{cases} \quad (20)$$

其中, T_{FFC} 表示一个动态阈值^[20], 公式定义为:

$$T_{FFC} = T_{FO} + \alpha_{FFC} \times S_t(FFC) \quad (21)$$

其中, T_{FO} 和 α_{FFC} 为给定的常数因子。

1.4.3 合成尖峰细胞

SSC 借助 FFC 神经元细胞的输出量和尖峰信号产生自身的输出量和尖峰信号, 进而决定 APDNNM 何时发出预警信号。由下式产生合成尖峰细胞的尖峰信号:

$$S_t(SSCspike) = \begin{cases} 1, & \text{if } SSC_t \geq T_{SSC} \\ 0, & \text{else} \end{cases} \quad (22)$$

其中, T_{SSC} 借用上述检测阈值方案获得动态检测阈值, SSC_t 借助 FFC 神经元细胞获得其输出行为量:

$$SSC_t = \begin{cases} S_t(FFC), & \text{if } \sum_{i=1}^{n_c} S_{t-1}(FFCspike) \geq n_s \\ S_t(m), & \text{else} \end{cases} \quad (23)$$

其中, n_s 表示在一段时间内连续出现尖峰信号的个数。 $S_t(m)$ 由 M 神经节点细胞输出量获得, 对其输出进行归一化处理:

$$S_t(m) = \frac{1}{1 - \exp(-sum_t(m))} - 0.5 \quad (24)$$

其中, $sum_t(m)$ 由下式计算:

$$sum_t(m) = \frac{1}{2m \times 2n} \sum_{r=0}^m \sum_{s=0}^n m_t(r, s) \quad (25)$$

随后, 借用 SSC 神经元细胞的尖峰信号确定 APDNNM 是否发出预警检测信号:

$$Alarm_t = \begin{cases} 1, & \text{if } \sum_{l=0}^{n_c} S_{t-l}(SSCspike) \geq n_s \\ 0, & \text{else} \end{cases} \quad (26)$$

其中, 1 表示 APDNNM 发出预警检测信号。

1.5 APDNNM 算法描述

基于图 1 的神经网络结构和视觉系统设计相关论述, 下面给出了本文提出的 APDNNM 算法描述。

输入 视频图像序列帧 P_t

输出 小叶板切向细胞尖峰信号 β_t , 合成尖峰细胞的尖峰信号 $S_t(SSCspike)$, 预警检测信号 $Alarm_t$

步骤 1 参数设置 $\varphi_1, \varphi_2, \tau, \varepsilon, n_s, n_c, T_{FO}$ 和 α_{FFC} ;

步骤 2 依据式(1) 计算前帧 t 在 R 神经层中细胞 (i, j) 的亮度变化;

步骤 3 依据式(2) ~ (6) 计算在 L 神经层中 OO 节点细胞 $\chi_t(r, s)$ 的兴奋量;

步骤 4 依据式(7) ~ (9) 计算在 L 神经层 m_t

节点细胞 $M_i(r,s)$ 的行为量, 进而获得突出前神经系统网络的输出量;

步骤 5 依据式 (10) ~ (14) 计算在小叶板切向细胞是否存在尖峰信号 β_i ;

步骤 6 依据式 (15) ~ (21) 计算在前馈细胞是否存在尖峰信号 $S_i(FFC_{spike})$;

步骤 7 依据式 (22) ~ (23) 计算在合成尖峰细胞是否存在尖峰信号 $S_i(SSC_{spike})$;

步骤 8 依据式 (24) ~ (26) 计算 APDNNM 的输出量是否发出预警信号;

步骤 9 返回步骤 2, 遍历所有视频图像序列, 算法终止。

2 数值实验

仿真实验在 CPU/3.60 GHz、RAM/8.00 GB、Win10 的计算机上实现。使用 C++ 并在 Visual Studio 2019 平台编写程序代码。测试视频图像序列

均为 35 frame/s, 输入神经网络的图像序列大小为 128×128 像素的 8 位灰度图。APDNNM 的参数设置见表 1。

表 1 APDNNM 参数设置

| Table 1 Parameter settings of APDNNM | | | |
|--------------------------------------|------|----------------|------|
| 参数名称 | 值 | 参数名称 | 值 |
| τ | 0.15 | T_{FO} | 0.30 |
| ns | 6 | α_{FFC} | 0.03 |
| nc | 5 | φ_1 | 0.50 |
| φ_2 | 0.30 | | |

2.1 实验分析

为验证 APDNNM 的有效性, 实验涉及的农作物有高粱、玉米、山茶花等农作物, 拍摄的视频图像序列记录了害虫的行为活动; I-IV 视频包含 4 种害虫场景, 如图 2 所示。对此开展对比实验分析, 验证本文提出的 APDNNM 算法在不同场景下的预警检测任务中具有优越性。



图 2 实际场景图像采样帧

Fig. 2 Sampled frames of actual scene images

2.2 APDNNM 的性能分析

2.2.1 突触后神经网络

由图 2 可知, 视频中出现目标, 利用上述 APDNNM 神经网络, 获得的实验结果如图 3 所示。图 3(a) 和图 3(b) 展现了在阴天环境下害虫在视野中出现时, SSC 神经元细胞将变得兴奋, 并且害虫一直在视野中, 兴奋量会持续产生; 图 3(c) 和图 3(d) 展现了在晴天环境下害虫在在视野中出现时, SSC 神经元细胞将变得兴奋, 当害虫离开视野, 兴奋量逐渐减低, 直到没有任何兴奋量响应。由此说明, 该神经网络的设计是合理的。

2.2.2 APDNNM 的性能比较分析

选取文献 [19] AFVNN 神经网络模型和不区分天气场景下的神经网络模型 FIMDL 参与比较。

AFVNN、FIMDL、APDNNM 三种模型通过接受视野中的目标信息, 借助视觉神经系统对目标信息进行加工处理, 实现预警检测。不同在于 AFVNN 模型利用突触前神经网络对目标信息进行简单的汇总处理; FIMDL 模型在 AFVNN 模型的基础上, 增加突触后神经网络, 但在实际环境中容易受到天气场景的影响; APDNNM 模型将突触前和突触后神经网络进行结合, 借助前馈神经元细胞和 LPTC 神经元响应特性机理, 设计模型, 满足不同天气场景下的预警检测。实际拍摄视频用于 3 种模型的性能测试结果如图 4 所示。

由图 4 可知, 以上 3 种模型获得的预警检测性能见表 2。

结合图 4 及表 2 获知 AFVNN 和 FTMDL 两种模型在对 4 种害虫场景的预警检测准确率是有很大差

别的,这是由于晴天和阴天拍摄4种害虫的时间和角度不同,导致图像亮度和背景信息存在较大差异。2种模型在处理目标信息的过程中,AFVNN模型只是借助突触前神经网络对目标信息加以简单汇总处理后进行预警检测,阴天场景下出现图像亮度信息

平滑和晴天场景下出现图像亮度信息尖锐等问题,将导致神经网络处理目标信息的能力变弱;FTMDL模型接受不同天气场景下复杂的背景信息,会导致神经网络将背景信息进行加工处理。因此,2种模型在处理实际场景中预警检测存在非常明显差异。

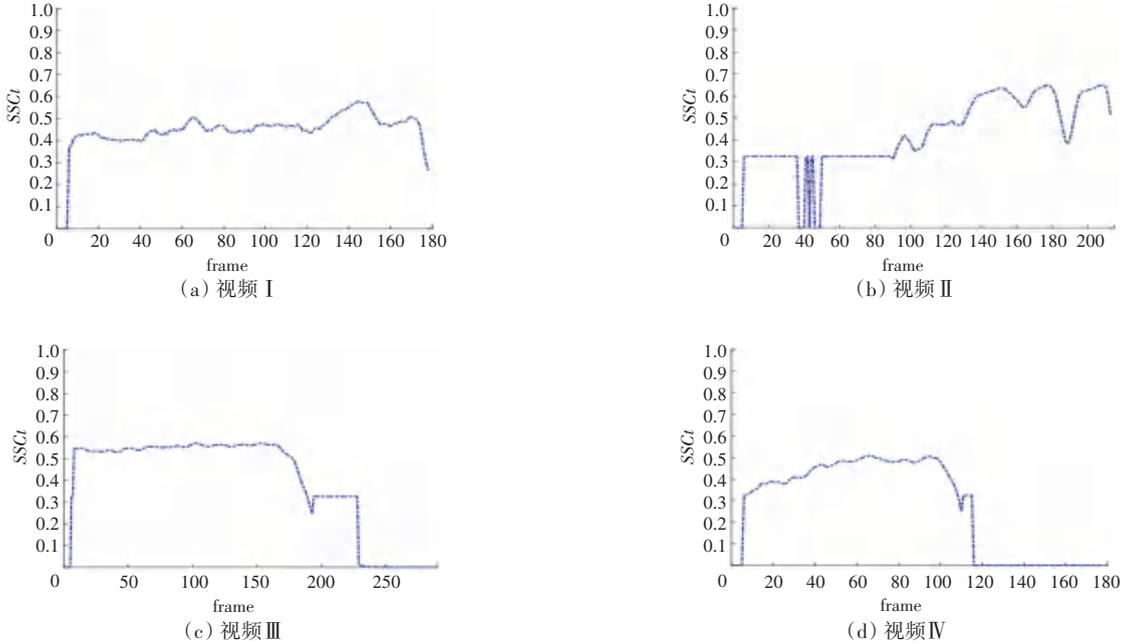


图3 APDNNM的突出后神经网络作用于视频I、II、III、IV的合成尖峰细胞输出量

Fig. 3 Output of synthetic spiking cells of the post-eminent neural network of APDNNM acting on videos I, II, III, and IV

表2 实验结果对比分析

Table 2 Comparative analysis of experimental results

| 检测场景 | 样本集 | 检测模型 | 漏报/frame | 误报/frame | 准确率/% |
|--------|-----|--------|----------|----------|-------|
| 视频 I | 180 | AFVNN | 40 | 5 | 75.00 |
| | | FTMDL | 22 | 4 | 85.56 |
| | | APDNNM | 1 | 0 | 99.44 |
| 视频 II | 213 | AFVNN | 65 | 0 | 30.51 |
| | | FTMDL | 32 | 11 | 79.81 |
| | | APDNNM | 14 | 0 | 93.42 |
| 视频 III | 293 | AFVNN | 18 | 27 | 84.64 |
| | | FTMDL | 13 | 0 | 95.56 |
| | | APDNNM | 8 | 0 | 97.27 |
| 视频 IV | 177 | AFVNN | 24 | 36 | 66.10 |
| | | FTMDL | 95 | 0 | 46.32 |
| | | APDNNM | 4 | 4 | 95.48 |

由于生物特性具有延迟特性导致 APDNNM 神经网络的输出延后出现误判现象,但 APDNNM 将突触前和突触后神经网络结合,利用前馈细胞消除图像亮度和背景信息的干扰,借助 LPTC 神经元响应特性机理构建预警检测模型,在阴天和晴天场景下的准确率

大于以上 2 种模型准确率;从表 2 可知,APDNNM、FTMDL、AFVNN 平均准确率为:96.40%、76.81%、64.06%,APDNNM 的性能优于 FTMDL,AFVNN 的性能最差。因此,APDNNM 预警检测模型在实际场景下的检测效果要更具稳定性和优越性。

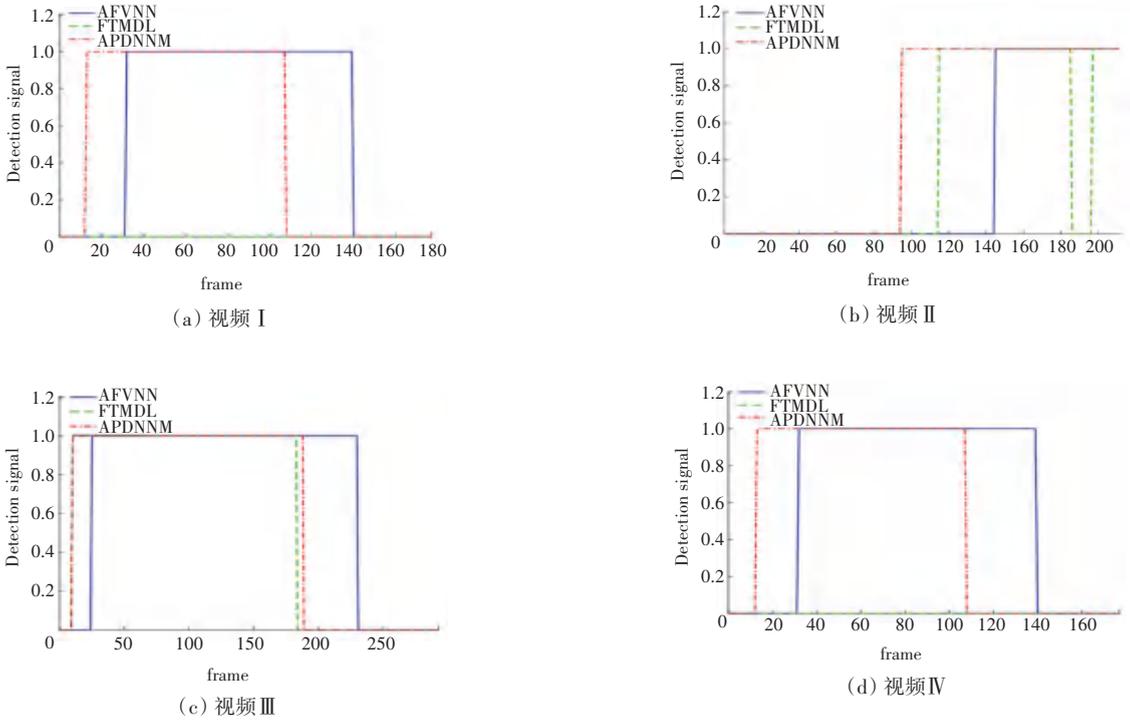


图 4 预警检测信号输出图

Fig. 4 Output diagram of early warning detection signal

3 结束语

基于果蝇视觉系统网络的生物启发,对视野信息进行加工处理。本文对农作物中存在的害虫预警检测问题进行了研究,提出一种 APDNNM 视觉神经网络模型,用于解决智能视频监控中的害虫检测的技术问题。该模型基于果蝇视觉神经网络的前馈神经元细胞和 LPTC 神经元响应特性机理构建合成尖峰神经元细胞检测害虫信息,实现预警检测。基于阴天和晴天不同环境下的视频图像序列,实验结果表明所提出 APDNNM 能有效满足预警检测。但该模型仍然存在以下一些不足:

(1) APDNNM 是单目视觉系统,在复杂环境中需要在视野中提取更完整信息进行加工处理,但存在严重遮挡现象,可能会直接影响检测性能。

(2) 实验数据需要低空采集,若图像中存在过多噪声将会干扰神经网络网络的检测性能。本文研究受到生物神经网络机理启发对农作物害虫信息进行加工处理和预警检测,可为人工智能预警检测害虫提供有效帮助。

为了在实际环境中应用,未来将进一步展开研究工作。将 APDNNM 嵌入 ARMv8 开发板中,使用无人机搭载开发板对害虫进行预警检测。

参考文献

- [1] 李亚硕,伊飞,王崇,等. 基于机器视觉的田间飞行害虫自动检测方法[J]. 农业工程,2018,8(3):26-29.
- [2] FAITHPRAISE F, BIRCHP, YOUNG R, et al. Automatic plant pest detection and recognition using k - means clustering algorithm and correspondence filters [J]. International Journal of Advanced Biotechnology and Research,2013,4(2):189-199.
- [3] MIREIA S, JORDI R, NURIA A. Detectin and Identification of five common internal grain insect pests by multiplex PCR [J]. Food Control,2018,84:246-254.
- [4] 姚青,谷嘉乐,吕军,等. 改进 RetinaNet 的水稻冠层害虫为害状自动检测模型[J]. 农业工程学报,2020,36(15):182-188.
- [5] MOHANTY S P, HUGHES D P, SALATHE M. Using deep learning for image - based plant disease detection [J]. arXiv preprint arXiv,1604. 03169,2016.
- [6] FERENTINOS K P. Deep learning models for plant disease detection and diagnosis [J]. Computers and Electronics in Agriculture,2018,145:311-318.
- [7] 琚新刚,廉飞宇,张元,等. 虫蛙麦粒的大赫兹成像检测方法研究 [J]. 中国粮油学报,2018,33(8):106-111.
- [8] 张诗雨,夏凯,杜晓晨,等. 一种基于聚类特征的 Faster R-CNN 粮仓害虫检测方法[J]. 中国粮油学报,2020,35(4):165-172.
- [9] HAAG J, VERMEULEN A, BORST A. The intrinsic electrophysiological characteristics of fly lobula plate tangential cells;III. Visual response properties[J]. Journal of Computational Neuroscience,1999,7:213-234.
- [10] CHIAPPE M E, SEELIG J D, REISER M B, et al. Walking modulates speed sensitivity in drosophila motion vision [J].

- Current Biology,2010,20(16): 1470-1475.
- [11]TUTHILL J C,NERN A,HOLTZ S L, et al. Contributions of the 12 neuron classes in the fly lamina to motion vision[J]. Neuron, 2013,79(1): 128-140.
- [12]HAUSEN K. Functional characterization and anatomical identification of motion sensitive neurons in the lobula plate of the blowfly calliphora erythrocephala[J]. Zeitschrift Für Naturforschung C,1976, 31(9-10): 629-634.
- [13]ECKERT H. Functional properties of theH1-neurone in the third optic ganglionof the blowfly, phaenicia [J]. Journal of Comparative Physiology,1980,135: 29-39.
- [14]WU Ming,NERN A,WILLIAMSON W R,et al. Visual projection neurons in thedrosophila lobula link feature detection to distinct behavioral programs[J]. Elife,2016,5:e21022.
- [15]SEN R, WU M, BRANSON K, et al. Moonwalker descending neurons mediate visually evoked retreat in drosophila[J]. Current Biology,2017,27(5): 766-771.
- [16]REICHARDT W, EGELHAAF M. Properties of individual movement detectors as derived from behavioral experiments onthe visual system of the fly[J]. Biological Cybernetics,1988,58(5): 287-294.
- [17]ZHANG Zhuhong, YUS S,ZHANG Guopeng. Fly visual system inspired artificial neural network for collision detection [J]. Neurocomputing,2015,153(4):221-234.
- [18]HU B, ZHANG Z. Bio-inspired visual neural network on spatio-temporal depth rotation perception [J]. Neural Computing and Applications,2021,33(16):10351-10370.
- [19]李论. 基于果蝇视脑响应机制的神经网络构建及运动避碰系统应用[D]. 贵阳:贵州大学,2023.
- [20]YUS S,RIND F C. Collision detection in complex dynamic scenes using an LGMD - based visual neural networkwith feature enhancement[J]. IEEE Transactions on Neural Networks,2006, 17(3):705-716.