

DOI: 10.7652/xjtuxb201910016

一种用于视觉颜色特征分类的脉冲神经网络

苏亚丽¹, 吴健行², 惠维³, 张国和²

(1. 西安石油大学机械工程学院, 710065, 西安; 2. 西安交通大学微电子学院, 710049, 西安;
3. 西安交通大学计算机科学与技术学院, 710049, 西安)

摘要: 针对脉冲神经网络(SNNs)在视觉颜色特征分类领域精度不高的问题,提出了一种基于新型 RGB-HSV 预处理模型的高精度脉冲神经网络。该脉冲神经网络融合了 RGB 颜色通道简单和 HSV 色彩空间直观的特点来提取聚类色彩特征,增强了网络的识别能力。此外,在 Tempotron 有监督学习基础上提出了一种结合权值动量的训练方式,该方式在计算当前权值更新量的同时保留一定程度的上次权值更新量,加快了网络权值的收敛速度,节省了仿真时间。仿真实验结果表明,所设计的脉冲神经网络的分类精度高达 96.21%,且在 6 次训练迭代后精度仍可达 84% 左右。

关键词: 脉冲神经网络;特征分类;颜色特征;网络权值

中图分类号: TN402 **文献标志码:** A **文章编号:** 0253-987X(2019)10-0115-07

A Spiking Neural Network for Classification of Visual Color Features

SU Yali¹, WU Jianxing², HUI Wei³, ZHANG Guohe²

(1. School of Mechanical Engineering, Xi'an Shiyou University, Xi'an 710065, China;
2. School of Microelectronics, Xi'an Jiaotong University, Xi'an 710049, China;
3. School of Computer Science and Technology, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A spiking neural network with high precision based on a new RGB-HSV preprocessing model is proposed to solve the problem of low accuracy of spiking neural networks in the field of the classification of visual color features. The proposed network extracts cluster color features by combining the features of the simplicity of RGB color channels and intuitive of HSV color space and enhances the recognition ability. A training method with weight momentum is also proposed based on Tempotron supervised learning rules. The method updates weights with new calculations while some of last weights is retained, so that the convergence of network weights is speeded up and the simulation time is saved. Experimental results show that the classification accuracy of the proposed network is up to 96.21%, and the accuracy reaches about 84% after 6 training iterations.

Keywords: spiking neural networks; characteristic classification; color feature; network weight

脉冲神经网络(SNNs)被誉为第三代人工智能神经网络,可模拟生物神经元存储和并行处理信息的工作方式,能克服传统神经网络基于冯诺依曼架构系统的缺陷^[1],在复杂运算或处理庞大信息任务方面具有较高的效率。脉冲神经元作为 SNNs 网络

处理信息的基本单元具有高度仿生性^[2]。不同于传统神经网络中的神经元接受模拟信号并在每一次迭代传播中都被激活,脉冲神经元以基于事件的异步方式处理信息^[3],接受刺激信号并积累膜电位,只有当它的突触前膜电位达到某个特定值后,突触后膜

电位才被激活并产生动作电位,大大降低了网络的整体功耗。另外,脉冲神经元将输入信号的时间信息也考虑在内,二进制编码过程中丢失的部分信息,可以通过时间维度的信息得到一定程度的补偿,因此 SNNs 网络在理论上具有更好的识别能力和鲁棒性。

尽管 SNNs 网络被证实是与生物神经系统最接近的网络,但是生物脑神经网络的学习机制尚不明确,故对学习方法的研究也不成熟。脉冲神经元以离散脉冲的形式来传递信号,其响应函数的不可微特性导致 SNNs 网络难以直接应用基于梯度下降的反向传播算法来进行有效地训练^[4],而现存的学习算法普遍效率不高,与 SNNs 网络的仿生特性不完全兼容。因此,网络精度的提高更加依赖于输入信息的预处理。文献[5]受视觉处理路径模型的启发,提出一种彩色图像特征提取方法,通过添加多重复杂处理,建立红绿、黄蓝对抗通道,将图像像素值转换为多种相互关联的输入信息,以此来提高色彩识别率。若仅利用图像的 RGB 值作为特征值,其色彩特征相关性不高,难以有效地提升网络的性能。

本文受文献[5]处理色彩信息的启发,从增强色彩信息关联性的角度出发,提出了一种新的 RGB-HSV 预处理模型,将单一像素值转换为具有高度色彩相关度的四通道信息,能更为有效地提取色彩聚类特征,增强特征信息之间的相关性,从而提高网络的识别能力。此外,本文提出了一种 Tempotron 有监督学习规则结合权值动量的训练方式,在计算当前权值更新量的同时保留一定程度的上次权值更新量,加快了网络权值的收敛速度,节省了仿真时间。

1 脉冲神经网络高级建模

本节构建应用于视觉颜色特征分类的脉冲神经网络,主要研究内容包括图像特征提取、特征信息时间编码、脉冲神经元建模及网络拓扑构建等 4 个部分。

1.1 RGB-HSV 模型

一般采用 RGB 三通道值叠加得到归一化的灰度值作为色彩特征^[6],以此作为神经网络的输入,但网络的识别精度只能达到 70% 左右。通过分析发现单一的 RGB 值不具备良好的色彩相关性,不能完善地表征图像色彩信息,限制了网络识别能力的提升。通过研究输入信息的结构特征,本文在 RGB 模型的基础上加入 HSV 参量提取,HSV 空间如图 1 所示。具体的实现方法为:先将单一像素值转换为 RGB 三色参量,然后将 RGB 参量通过式(1)~式(5)

转换成 HSV 参量,同时通过式(6)确定 RGB 灰度值 G_r ,这种提取色彩特征的方法可称之为 RGB-HSV 模型,该模型通过建立 4 个通道的关联信息,能有效地聚类色彩特征,增强网络的识别能力,有利于网络训练出理想的权值,从而达到较高的分类精度。




图1 HSV 空间示意图

HSV 颜色参量与 RGB 颜色参量之间的转换公式如下

$$N = \min(R, G, B) \quad (1)$$

$$V = \max(R, G, B) \quad (2)$$

$$H = \begin{cases} (G - B) / (R - N), & R = \max(R, G, B) \\ 2 + (B - R) / (G - N), & G = \max(R, G, B) \\ 4 + (R - G) / (B - N), & B = \max(R, G, B) \end{cases} \quad (3)$$

$$H = \begin{cases} H \times 60, & H > 0 \\ H + 360, & H < 0 \end{cases} \quad (4)$$

$$S = (V - N) / V \quad (5)$$

$$G_r = (R \times 30 + G \times 59 + B \times 11 + 50) / 100 \quad (6)$$

式中: H 为色调值; S 为饱和度值; V 为明度值; G_r 为灰度值。HSV 空间是 Smith 根据颜色的直观特性创建的一种颜色空间,也称为六角锥形模型(如图 1 所示)。

(1)色调 H 。色调一般用角度来表示,取值的范围是 $0^\circ \sim 360^\circ$,从红色开始以逆时针方向,红色为 0° ,绿色为 120° ,蓝色为 240° 。

(2)饱和度 S 。饱和度是一种用来表示颜色接近光谱色程度的参数。

(3)明度 V 。明度区别于亮度,是用来表达人所感知到的色彩明暗程度的参数。

图 2 为一幅图像经过 RGB-HSV 预处理模型的各通道示意图,可以看出 RGB-HSV 模型提取的图像特征信息具有高度的色彩相关性,弥补了单输入 RGB 参量表征图像特征信息不足的缺点,为网络性能的优化奠定了基础。

1.2 群体编码

时间编码的目的是将输入信息表示成脉冲发放




图 2 RGB-HSV 模型的各通道示意图

时间序列,利用神经元不同的点火时间来编码不同的数据。时间编码方式主要分为线性编码、群体编码、相位编码等。本文采用适于图像像素点处理的群体编码方式对特征信息进行编码^[7]。

群体编码:通过数学概率分布的模型,把输入的数据映射到多个神经元的脉冲时间上。通过群体编码的方法,可以将图像的特征信息转化为精确的脉冲发放时间序列^[8-9]。群体编码利用一个具有不同均值和相同方差的高斯接收域编码输入数据,具体可以由式(7)~式(9)表示

$$f(x_i) = A \exp\left(-\frac{(x_i - c_i)^2}{2\sigma^2}\right)$$

(7)

$$\sigma = \frac{1}{\gamma(m+1)}$$

(8)

$$c_i = \frac{i-1}{m-1}$$

(9)

式中: A 为最大脉冲时间; m 为高斯接收域的个数; γ 为控制参数。

1.3 LIF 神经元的数学建模

本文使用 LIF 神经元模型(阈值点火模型)^[8,10]来构建所设计的脉冲神经网络。阈值点火模型不再考虑神经元之间具体的信息传递方式,而将神经元抽象为一个功能单元,利用数学公式描述脉冲在神经元之间的传递以及具体的膜电位变化方式^[11-12]。在阈值点火模型中,所有输入神经元脉冲信号产生的电压在后突触神经元上累加,如果某一时刻膜电位达到阈值,后突触神经元就会点火,释放一个脉冲信号。

图 3 为 LIF 神经元的等效物理模型,它是由膜电容 C_m 和膜电阻 R_m 组成的电阻电容电路^[13],外部输入电流 I 作为驱动电流,以此模拟 LIF 神经元膜电位动力学变化过程。在无任何输入电流的静息状态下,膜电位 V 与电池电压 V_{rest} 保持相同。当电流进入神经元电路后,通过支路电流 $I_C(t)$ 给电容充电,支路电流 $I_R(t)$ 流过电阻给电容放电。




图 3 LIF 神经元的等效物理模型

当输入电流截止时,电容电荷通过电阻泄漏使得膜电位 V 衰减回 V_{rest} 。在时域 t 内各电流之间的关系描述如下

$$I(t) = I_R(t) + I_C(t) = \frac{V - V_{rest}}{R_m} + C_m \frac{dV}{dt}$$

(10)

LIF 神经元的膜电位随输入电流变化而变化的过程用微分方程的形式描述如下

$$\tau_m \frac{dV}{dt} = -(V - V_{rest}) + R_m I(t)$$

(11)

式中: $\tau_m = C_m R_m$ 称为膜电位时间常数。

当膜电位达到阈值时,它将被重置为低于 V_{rest} 的一个复位电压。描述 LIF 神经元动力学的关键在于:①线性微分方程描述膜电位的变化;②设定产生脉冲的阈值^[14]。

1.4 网络拓扑构建

图 4 为本文构建的用于视觉颜色特征分类的脉冲神经网络拓扑示意图,由图像特征提取层、时间编码层、隐藏层和输出层构成。




图 4 本文用于视觉颜色特征分类的 SNN 拓扑图

本文构建神经网络步骤如下:首先,图像特征提取层利用 RGB-HSV 模型提取颜色特征,生成具有色彩高度相关性的四通道信息;然后,时间编码层接受特征信息作为输入,利用群体编码方式将特征信息编码为一系列脉冲序列,并传入隐藏层;接着,LIF 神经元的动力学模型接受脉冲序列的输入,经过处理转换为神经元膜电位,权重矩阵与膜电位相

乘叠加得到输出神经元膜电位,并与输出神经元设定的阈值做比较以决定输出神经元是否点火。在训练阶段,利用 Tempotron 学习规则训练网络,更新权重矩阵,迭代完毕后得到训练好的网络;在测试阶段,突触权值不再变化,网络接受输入脉冲序列,经过计算直接输出分类结果。

2 脉冲神经网络的算法设计与改进

2.1 Tempotron 有监督学习规则

在神经元发放脉冲后,脉冲神经网络需要对神经元的突触权重做动态学习调整,其训练算法一般分为无监督学习规则和有监督学习规则^[15-16]。STDP 学习规则^[17]作为无监督学习的典型代表,没有目标约束,自发地学习输入信息的内在特征,需要的样本信息较少,但其迭代精度提升较慢,网络训练速度和精度都不高。Tempotron 有监督学习规则源自于 STDP,可以通过有监督过程有方向地调节神经网络的权重,使得网络可以达到高效提升迭代精度的效果^[18-19]。

LIF 神经元膜电位是来自所有传入神经元的突触后电压(PSP)的加权总和

$$V(t) = \sum_i \omega_i \sum_i K(t - t_i) + V_{\text{rest}} \quad (12)$$

式中: ω_i 和 t_i 分别是第 i 个传入的突触权重和脉冲发放时间; V_{rest} 是神经元的静息电位,对应图 3 中的电源电压 V_{rest} ; K 表示归一化的 PSP 内核函数,表达式为

$$K(t - t_i) = \frac{V_o}{\tau_m} \left(\exp\left(-\frac{(t - t_i)}{\tau_m}\right) - \exp\left(-\frac{(t - t_i)}{\tau_s}\right) \right) \quad (13)$$

其中 τ_m 和 τ_s 分别表示膜电位和突触电流随时间衰减的时间常数。 $K(t)$ 随时间变化曲线如图 5 所示。Tempotron 学习规则权值更新的计算公式为

$$\Delta\omega_i = \lambda \sum_{t_i < t_{\text{max}}} K(t_{\text{max}} - t_i) \quad (14)$$

式中: t_{max} 表示时域中神经元膜电位 V 达到峰值的时间; λ 表示学习率,本文设置 $\lambda_+ = 0.005$, $\lambda_- = -0.005$ 。

有监督学习的关键在于如何更新突触权重,以获得期望的输出脉冲。在具体的实现过程中,一个神经元可以通过发射或不发射脉冲来区分不同的状态,简称为状态 1 或状态 0。如果目标是状态 1,则神经元应该发射一个脉冲;如果目标是状态 0,则神经元应该不作响应。

在神经网络学习过程中,如果神经元的响应状




图 5 归一化核函数 $K(t)$ 曲线

态与期望的状态不同,则网络会根据 Tempotron 学习规则更新权重,而神经元的实际输出状态与期望状态不相符一般分为以下两种情况:

(1) 某神经元的实际输出状态为 1,而期望输出状态为 0,此时应减小上层神经元与该神经元的连接权值,以减小输入刺激抑制该神经元点火;

(2) 某神经元的实际输出状态为 0,而期望输出状态为 1,此时应增大上层神经元与该神经元的连接权值,以增大输入刺激促进该神经元点火。

从生物学的角度来说,训练算法应该根据突触前和突触后神经元释放脉冲的时间差对突触权重做出相应的调整。较大的时间差导致权重的变化较小;相反地,较短的时间差将会导致权重发生巨大变化。图 6 为权重更新示意图,其中 LTP 窗口用于增加突触权重,LTD 窗口用于减小突触权重^[20]。在 t_{max} 之前释放的每个脉冲都会引起 t_i 相应的突触变化,其变化量取决于 t 与 t_i 的时间差。如果仅仅考虑单个脉冲编码和最新的脉冲更新情况,Tempotron 学习规则将被简化为下式

$$\Delta\omega_i = \begin{cases} \lambda_+ K(t - t_i) \Theta(t - t_i), & \text{状态 0 错误} \\ \lambda_- K(t - t_i) \Theta(t - t_i), & \text{状态 1 错误} \\ 0, & \text{其他} \end{cases} \quad (15)$$

式中: $\Theta(x)$ 为 heavyside 函数。




图 6 权重更新示意图

2.2 结合动量的训练算法及理论分析

结合动量的训练算法受自然界物理运动规律的启发,模拟的是物体运动时的惯性,在计算当前权值

更新量时,同时保留一定程度的上次权值更新量来做出微调,以决定最终的更新方向。它不完全依赖于当前的计算梯度,可以在一定程度上增加算法的稳定性,加快收敛速度。另外,由于权值动量的存在,该训练算法在一定程度上还有跳出局部最优陷阱的能力,从而使网络达到最优的性能。本文提出了一种结合动量的权值更新规则

$$\Delta\omega_i = \lambda \sum_{t_i < t_{\max}} K(t_{\max} - t_i) + \Delta\omega_i^d \tag{16}$$

式中: $\Delta\omega_i$ 为当前的权值更新量; $\Delta\omega_i^d$ 为当前的权值动量。

权值动量 $\Delta\omega_i^d$ 等于动量学习率 λ_m 乘以上次的权值改变量 $\Delta\omega_i$,其中动量学习率 λ_m 与权值学习率 λ 的定义类似,表征上次权值改变量在多大程度上对当前梯度做出贡献,其值在 0~1 之间。权值动量的计算公式为

$$\Delta\omega_i^d = \lambda_m \Delta\omega_i^l \tag{17}$$

式中: $\Delta\omega_i^l$ 为上次的权值改变量。

随着网络的收敛,权值参数的更新进入微调阶段。如果仍然使用和初始状态相同的动量学习率,网络精度在训练的最后阶段会产生微小的振荡。针对此问题,可以通过引入一个线性衰减的动量来解决,具体的实现方法如下:在原有动量学习率的基础之上乘以一个动量学习衰减因子,随着训练的进行,权值动量会逐渐衰减消失,网络在训练的最后阶段主要由当前的梯度来决定权值的更新量,有利于网络达到稳定的收敛状态。

3 实验方案及仿真结果分析

本文先利用 RGB-HSV 模型对测试集和训练集进行预处理,得到图像特征信息,并在通用数据集上对像素点颜色进行分类测试。在训练之前,对权值矩阵进行随机初始化,利用 Tempotron 学习规则更新权值参数;经过 50 次迭代,得到训练好的权值矩阵;最后网络在通用数据集上对像素点颜色进行分类。

图 7 为输出神经元突触后膜电位在某次时间窗口的变化过程,可以看到 1 号神经元和 2 号神经元的突触后膜电位 V_1 和 V_2 均在阈值电位之下波动,说明它们处于静息状态,而 3 号神经元的突触后膜电位 V_3 最先在 26 ms 的时刻达到了阈值电位,并发放了脉冲信号,然后其膜电位迅速下降到复位电位以下,说明此时的输入目标属于第 3 类。

为了验证本文设计的 SNNs 网络对视觉颜色特




图 7 输出神经元膜电位在一次时间窗口内的变化过程

征分类的有效性,将本文基于 RGB 和 RGB-HSV 预处理模型与文献[5]中基于 RGB、VPmod 和 SNN-Wu 构建的 SNNs 在相同任务上的分类精度进行对比,结果如表 1 所示。

表 1 不同预处理模型下的 SNNs 网络色彩分类精度对比

模型名称	分类精度/%	
	数据集 1	数据集 2
RGB ^[5]	78.54	82.63
VPmod ^[5]	62.19	90.38
SNN-Wu ^[5]	89.24	90.16
本文 RGB	71.42	69.54
本文 RGB-HSV	96.21	94.14

由表 1 可见:采用不同特征提取模型的网络分类精度在 62.19%~96.21%之间,分布范围较大,说明图像的预处理对于网络分类精度至关重要,图像特征信息聚类越高,越有利于网络性能的优化。经比较可知,本文基于 RGB-HSV 模型的脉冲神经网络,其色彩分类精度高达 96.21%,超出了其他预处理模型下的网络分类精度,证明了 RGB-HSV 预处理模型能够有效地聚类色彩特征,增强网络的识别能力。

采用 VPmod 模型的网络在数据集 1 和数据集 2 上的分类精度差别较大,分别为 62.19%和 90.38%,说明在某一数据集上表现良好的模型不一定适用于其他的数据集。因为不同数据集样本的特征信息结构一般不同,而一种模型只能代表一种固定的特征提取模式,故其在不同数据集上的表现效果会有一定的差距。因此,分析数据结构,设计适合特定数据集的特征提取方式对网络性能的提升至关重要。

图 8 为所设计的网络在数据集 1 上的分类精度

随迭代次数的增加而变化的曲线。由图8可见,网络的分类精度在迭代30次后达到稳定,高达96.21%,证明本文的实验方案达到了预期的效果。网络的分类精度在6次迭代后即可达到84%,收敛速度很快,证明本文提出的结合权值动量的训练方式能够加快网络的收敛。




图8 网络分类精度随迭代次数增加而变化的曲线

4 结 论

本文以传统神经网络及人类视觉系统为研究背景,设计了一种用于视觉颜色特征分类的脉冲神经网络。为解决由于单一的RGB值不具备良好的色彩相关性所导致的脉冲神经网络不能完善地提取图像色彩信息的问题,提出了一种基于新型RGB-HSV预处理模型的高精度脉冲神经网络,有效地增强了色彩特征之间的相关性,提高了网络的识别能力。通过研究脉冲神经网络的学习算法,本文提出了一种结合权值动量的训练方式,改进了Tempotron有监督学习规则以加快权值的更新速率,同时避免陷入局部最优陷阱,提高了网络的计算效率。实验结果表明,本文所构建的脉冲神经网络在视觉颜色特征分类任务上具备训练速度快、分类精度高的优异性能。

参考文献:

- [1] FANG Haowen, SHRESTHA A, DE Ma, et al. Scalable NoC-based neuromorphic hardware learning and inference [C]//2018 International Joint Conference on Neural Networks. Piscataway, NJ, USA: IEEE, 2018: 1-8.
- [2] WANG W, PEDRETTI G, MILO V, et al. Computing of temporal information in spiking neural networks with ReRAM synapses [J]. Faraday Discussions, 2018, 213: 453-469.
- [3] KIM J, KIM H, HUH S, et al. Deep neural networks

- with weighted spikes [J]. Neurocomputing, 2018, 311(1): 373-386.
- [4] LI Xiumin, WANG Wei, XUE Fangzheng, et al. Computational modeling of spiking neural network with learning rules from STDP and intrinsic plasticity [J]. Physica: A Statistical Mechanics and Its Applications, 2018, 491: 716-728.
- [5] SUN Qiyang, WU Qingxiang, WANG Xuan, et al. A spiking neural network for extraction of features in colour opponent visual pathways and FPGA implementation [J]. Neurocomputing, 2017, 228: 119-132.
- [6] 张悦, 霍宏, 方涛. 基于生物视觉的颜色直方图特征提取 [J]. 高技术通讯, 2014, 24(4): 407-413.
- ZHANG Yue, HUO Hong, FANG Tao. Color histogram feature extraction based on biological vision [J]. Chinese High Technology Letters, 2014, 24(4): 407-413.
- [7] LEE J H, DELBRUCK T, PFEIFFER M. Training deep spiking neural networks using backpropagation [J]. Frontiers in Neuroscience, 2016, 10: 1-10.
- [8] BALADRON J, HAMKER F H. A spiking neural network based on the basal ganglia functional anatomy [J]. Neural Networks, 2015, 67: 1-13.
- [9] 贾迪, 孟祥福, 孟隼, 等. RGB空间下结合高斯曼哈顿距离图的彩色图像边缘检测 [J]. 电子学报, 2014, 42(2): 257-263.
- JIA Di, MENG Xiangfu, MENG Lu, et al. Color image edge detection combining with Gauss Manhattan distance map in RGB space [J]. Acta Electronica Sinica, 2014, 42(2): 257-263.
- [10] DETHIER J, NUYUJUKIAN P, RYU S I, et al. Design and validation of a real-time spiking-neural-network decoder for brain-machine interfaces [J]. Journal of Neural Engineering, 2013, 10(3): 036008.
- [11] YU Q, TANG H, TAN K C, et al. A brain-inspired spiking neural network model with temporal encoding and learning [J]. Neurocomputing, 2014, 22: 3-13.
- [12] BAWANE P, GADARIYE S, CHATURVEDI S, et al. Object and character recognition using spiking neural network [J]. Materials Today: Proceedings, 2018, 5(1): 360-366.
- [13] AMIR S A, STRADMAN Y, MÜLLER P, et al. An accelerated LIF neuronal network array for a large-scale mixed-signal neuromorphic architecture [J]. IEEE Transactions on Circuits & Systems, 2018, 65(12): 4299-4312.
- [14] 杨静, 徐彦, 赵欣. Spiking神经元输入脉冲扰动敏感性研究 [J]. 计算机工程与应用, 2017(2): 6-11.

- YANG Jing, XU Yan, ZHAO Xin. Research on spiking neuron sensitivity to input perturbation [J]. Computer Engineering and Applications, 2017, 53(2): 6-11.
- [15] JARVIS S J, CAZE R, CLOPATH C. Extending the Tempotron with hierarchical dendrites allows faster learning [J]. BMC Neuroscience, 2015, 16: 37.
- [16] XIE X, QU H, LIU G, et al. Efficient training of supervised spiking neural networks via the normalized perceptron based learning rule [J]. Neurocomputing, 2017, 241(7): 152-163.
- [17] TAHERKHANI A, BELATRECHE A, LI Y, et al. A supervised learning algorithm for learning precise timing of multiple spikes in multilayer spiking neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(11): 5394-5407.
- [18] 程龙, 刘洋. 脉冲神经网络: 模型、学习算法与应用 [J]. 控制与决策, 2018, 33(5): 158-172.
- CHENG Long, LIU Yang. Spiking neural networks: model, learning algorithms and applications [J]. Control and Decision, 2018, 33(5): 923-937.
- [19] XIAO R, TANG Huajin, GU Pengjie, et al. Spike-based encoding and learning of spectrum features for robust sound recognition [J]. Neurocomputing, 2018, 313(11): 65-73.
- [20] ROGGENHOFER E, FIDZINSKI P, SHOR O, et al. A forecast-based biologically-plausible STDP learning rule [C]//Proceedings of the International Joint Conference on Neural Networks. Piscataway, NJ, USA: IEEE, 2011: 1810-1817.

(编辑 刘杨)

(上接第 108 页)

- [9] YANG X, RUAN H, FENG H. A recognition algorithm of deception jamming based on image of time-frequency distribution [C]//2017 7th IEEE International Conference on Electronics Information and Emergency Communication. Piscataway, NJ, USA: IEEE, 2017: 275-278.
- [10] 李紫航, 宋万杰. 有源干扰感知的熵理论方法 [J]. 信号处理, 2017(12): 1652-1656.
- LI Zihang, SONG Wanjie. Entropy theory method for active jamming perception [J]. Journal of Signal Processing, 2017(12): 1652-1656.
- [11] 郝万兵, 马若飞, 洪伟. 基于时频特征提取的雷达有源干扰识别 [J]. 火控雷达技术, 2017, 46(4): 12-15.
- HAO Wanbing, MA Ruofei, HONG Wei. Radar active jamming identification based on time-frequency characteristic extraction [J]. Fire Control Radar Technology, 2017, 46(4): 12-15.
- [12] WEN C, PENG J, ZHOU Y, et al. Enhanced three-dimensional joint domain localized STAP for airborne FDA-MIMO radar under dense false-target jamming scenario [J]. IEEE Sensors Journal, 2018, 18(10): 4154-4166.
- [13] HUANG D, CUI G, YU X, et al. Joint range-velocity deception jamming suppression for SIMO radar [J]. IET Radar, Sonar & Navigation, 2019, 13(1): 113-122.
- [14] 孙殿星, 陈翔, 万建伟, 等. 基于多特征的密集假目标干扰融合识别与抑制 [J]. 系统工程与电子技术, 2018, 40(10): 2207-2215.
- SUN Dianxing, CHEN Xiang, WAN Jianwei, et al. Fusion identification and suppression technique against concentrated false targets jamming based on multiple features [J]. Systems Engineering and Electronics, 2018, 40(10): 2207-2215.
- [15] 杨兴宇, 阮怀林. 基于双谱分析的雷达有源欺骗干扰识别 [J]. 探测与控制学报, 2018, 40(2): 122-127.
- YANG Xingyu, RUAN Huailin. Active deception jamming identification method based on bispectrum analysis [J]. Journal of Detection & Control, 2018, 40(2): 122-127.
- [16] KONSTANTIN D, DOMINIQUE Z. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [17] XUE Y J, CAO J X, WANG D X, et al. Applications of variational mode decomposition in seismic time-frequency analysis [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(8): 3821-3831.
- [18] KANG N X, HE M H, HAN J, et al. Radar emitter fingerprint recognition based on bispectrum and SURF feature [C]//2016 CIE International Conference on Radar. Piscataway, NJ, USA: IEEE, 2017: 1-5.
- [19] YU L, TAN V Y F. Rényi Resolvability and Its applications to the wiretap channel [J]. IEEE Transactions on Information Theory, 2019, 65(3): 1862-1897.
- [20] ZHAO X, WU Y, LEE D L, et al. iForest: interpreting random forests via visual analytics [J]. IEEE Transactions on Visualization and Computer Graphics, 2019, 25(1): 407-416.

(编辑 刘杨)