



计算机科学

COMPUTER SCIENCE

基于蜂群优化的Spiking神经网络模型研究与评估

马韦伟, 郑勤红, 刘珊珊

引用本文

马韦伟, 郑勤红, 刘珊珊. 基于蜂群优化的Spiking神经网络模型研究与评估[J]. 计算机科学, 2023, 50(8): 221-225.

MA Weiwei, ZHENG Qinong, LIU Shanshan. [Study and Evaluation of Spiking Neural Network Model Based on Bee Colony Optimization](#) [J]. Computer Science, 2023, 50(8): 221-225.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[多策略离散人工蜂群算法设计FIR低通数字滤波器](#)

FIR Low Pass Digital Filter Based on Multi-strategy Discrete Artificial Bee Colony Algorithm

计算机科学, 2023, 50(6A): 220700026-5. <https://doi.org/10.11896/jsjcx.220700026>

[基于人工蜂群的三支k-means聚类算法](#)

Three-way k-means Clustering Based on Artificial Bee Colony

计算机科学, 2023, 50(6): 116-121. <https://doi.org/10.11896/jsjcx.220800150>

[基于标签共现和特征局部相关的心电异常检测方法](#)

ECG Abnormality Detection Based on Label Co-occurrence and Feature Local Pertinence

计算机科学, 2023, 50(3): 139-146. <https://doi.org/10.11896/jsjcx.220200004>

[基于人工蜂群算法的多维函数优化加速方法](#)

Acceleration Method for Multidimensional Function Optimization Based on Artificial Bee Colony Algorithm

计算机科学, 2022, 49(11A): 211200075-6. <https://doi.org/10.11896/jsjcx.211200075>

[一种基于超网络的多目标回归方法](#)

Multi-target Regression Method Based on Hypernetwork

计算机科学, 2022, 49(11A): 211000205-9. <https://doi.org/10.11896/jsjcx.211000205>

基于蜂群优化的 Spiking 神经网络模型研究与评估

马伟伟¹ 郑勤红² 刘珊珊³

1 云南师范大学教育学部 昆明 650500

2 云南师范大学物理与电子信息学院 昆明 650500

3 亚太科技大学科技学院 吉隆坡 56000

(marqul2003@163.com)

摘要 为提高 Spiking 神经网络的训练能力,以多标签分类问题作为研究切入点,采用蜂群算法进行模型优化。基于 Spiking 理念的神经网络模型有多种,文中选择概率 Spiking 神经网络(Probabilistic Spiking Neural Network, PSNN)进行多标签分类。首先,建立概率 Spiking 神经网络分类模型,通过点火时间序列进行编码,触发脉冲响应实现数据传递;然后,利用 Spiking 神经网络的权重、动态阈值、遗忘参数等构建蜂群,并以多标签分类准确率作为人工蜂群(Artificial Bee Colony, ABC)算法的适应度函数,从而通过不断更新蜂群个体适应度值来获得最优个体;最后,以最优参数完成概率 Spiking 神经网络的多标签分类。实验结果表明,通过合理设置蜂群个体规模及蜜源搜索范围,ABC-PSNN 算法能够获得较高的多标签分类准确率。相比其他 Spiking 神经网络模型和常用多标签分类算法,ABC-PSNN 算法具备更高的分类准确率和稳定性。

关键词: Spiking 神经网络; 概率 Spiking 神经网络; 蜂群算法; 多标签分类; 脉冲响应

中图分类号 TP3-05

Study and Evaluation of Spiking Neural Network Model Based on Bee Colony Optimization

MA Weiwei¹, ZHENG Qinrong² and LIU Shanshan³

1 Faculty of Education, Yunnan Normal University, Kunming 650500, China

2 College of Physics and Electronic Information, Yunnan Normal University, Kunming 650500, China

3 School of Technology, Asia-pacific University of Science and Technology, Kuala Lumpur 56000, Malaysia

Abstract In order to improve the training ability of Spiking neural network, this paper takes multi-label classification problem as the research breakthrough point and adopts bee colony algorithm to optimize the model. There are many neural network models based on the concept of Spiking. Probabilistic Spiking neural network(PSNN) is selected for multi-label classification. Firstly, a probabilistic Spiking neural network classification model is established. The ignition time sequence is coded, and the pulse response is triggered to realize data transmission. Then, the weight, dynamic threshold and forgetting parameters of Spiking neural network are used to construct bee colony, and the accuracy of multi-label classification is used as the fitness function of artificial bee colony(ABC) algorithm, so that the optimal individual can be obtained by constantly updating the fitness value of individual bee colony. Finally, the multi-label classification of probabilistic Spiking neural network is completed with the optimal parameters. Experimental results show that ABC-PSNN algorithm can achieve high multi-label classification accuracy by reasonably setting the individual size of bee colony and honey source search range. Compared with other Spiking neural network models and commonly used multi-label classification algorithms, ABC-PSNN algorithm has higher classification accuracy and stability.

Keywords Spiking neural network, Probabilistic Spiking neural network, Bee colony algorithm, Multi label classification; Impulse response

Spiking 神经网络由于具有良好的计算能力常被用于复杂问题的训练求解^[1]。该神经网络通过脉冲信号实现数据的传递,根据脉冲点火时间来进行编码,由于其输出电压求解

引入了指数函数,增强了运算能力,因此在多个领域得到了深化应用。相比传统神经网络结构,Spiking 神经网络训练不仅要确定神经元连接权重,还需要确定阈值及遗忘变量等多个

到稿日期:2022-07-19 返修日期:2022-08-28

基金项目:国家自然科学基金(61961044);教育部人文社会科学研究基金项目(20XJJA880008);云南省教育厅科学研究基金项目(2021Y512)

This work was supported by the National Natural Science Foundation of China(61961044), Research Fund for Humanities and Social Sciences of the Ministry of Education(20XJJA880008) and Science and Research Foundation of the Education Department of Yunnan Province, China(2021Y512).

通信作者:郑勤红(zheng_qh62@aliyun.com)

参数,因此 Spiking 神经网络的训练求解更加复杂。当前常见的 Spiking 神经网络模型的训练求解并不是采用反向传播来确定参数,而是转化为期望和实际点火时间差值的最小化优化问题进行替代求解^[2],从而确定稳定的 Spiking 神经网络模型。

当前,关于 Spiking 神经网络模型的研究较多,Zhuang 等^[3]对基于脉冲时间依赖可塑性(Spike Timing Dependent Plasticity,STDP)的脉冲神经网络模型 STDP-SNN 的结构及应用场景进行了细致分析。Wang 等^[4]采用长短期记忆(Long Short Term Memory,LSTM)结构对传统的脉冲神经网络进行有效改进,提出了 LSTM-SNN 模型。前者是对传统脉冲神经网络结构的分析,后者则进行了改进。

为了适应复杂问题训练分析的需求,常需要对传统的 Spiking 神经网络进行有效改进。本文以复杂的多标签分类问题为切入点,对 Spiking 神经网络模型进行研究与评估,并验证了概率 Spiking 神经网络在多标签分类应用中的可行性。为了提升其多标签分类性能,采用 ABC 算法对概率 Spiking 神经网络的主要参数进行优化求解。实验结果表明,通过 ABC 算法优化的概率 Spiking 神经网络具备良好的多标签高精度分类性能。

1 Spiking 神经网络模型

1.1 基于 Spiking 的脉冲响应模型

Spiking 神经网络包含 3 种模型,其中最典型的是脉冲响应模型,下面对该模型进行数学描述。设后突神经元 j 的电压为 $u(t)$,当 $u(t)$ 下穿阈值 τ ,则触发一个输出 $t_j^{(f)}$,其输出序列为^[5]:

$$F_j = \{t_j^{(f)}; 1 \leq f \leq n = t | u_j(t) = \tau\} \quad (1)$$

设全部前突神经元 i 均存在于集合 Γ_j 中,点火脉冲对 $u(t)$ 的影响变化为^[6]:

$$P_j(t) = \sum_{i \in \Gamma_j} \sum_{t_j^{(f)} \in F_j} \omega_{ij} \epsilon_{ij}(t - \hat{t}_j, t - t_j^{(f)} - \Delta_{ij}^{ax}) + U_j^{\text{ext}} \quad (2)$$

其中, ω_{ij} 表示权值, U_j^{ext} 表示电压变化, ϵ_{ij} 表示突触电势, \hat{t}_j 是脉冲输出时间, Δ_{ij}^{ax} 是延迟项。

令 $s = t - t_j^{(f)} - \Delta_{ij}^{ax}$,用 u_{rest} 表示静止电位,此过程的变化量为 $\eta_j(t - \hat{t}_j)$,结合式(2),获得常见的脉冲响应模型:

$$u_j(t) = \eta_j(t - \hat{t}_j) + P_j(t) \quad (3)$$

在式(2)的基础上,常用简化脉冲响应模型(SRM₀)进行替代^[7]:

$$u_j(t) = \eta_j(t - \hat{t}_j) + \sum_{i \in \Gamma_j} \sum_{t_j^{(f)} \in F_j} \omega_{ij} \epsilon_{ij}(t - t_j^{(f)}) + U_j^{\text{ext}} \quad (4)$$

常见的 $\epsilon_{ij}(t)$ 表示形式为:

$$\epsilon_{ij}(t) = \frac{t - t_j^{(f)} - \Delta_{ij}^{ax}}{\tau} \cdot \exp\left(1 - \frac{t - t_j^{(f)} - \Delta_{ij}^{ax}}{\sigma}\right) \cdot H(t - t_j^{(f)} - \Delta_{ij}^{ax}) \quad (5)$$

其中, σ 为常量, $H(\cdot)$ 为阶跃函数。

1.2 概率 Spiking 神经网络

监督模型中,基于概率的 Spiking 神经网络(PSNN)的电压为^[8]:

$$u(t) = \sum_{i \in N} \omega_i \sum_{t'=0}^t \zeta(t-t') p^{t'} - \theta \sum_{k=0}^{t-1} \exp\left(-\frac{t-k}{\sigma}\right) p^k \quad (6)$$

其中, p_i^t 和 p^t 分别为 t 时刻第 i 个节点和所有节点触发脉冲的概率, ζ 为 $(0,1)$ 之间的随机数,一般 $\sigma=1$ 。 ω_i 表示当前神经元与第 i 个前突神经元权重^[9]。

$$\omega_i(t+1) = \eta x_i(t) \phi(y(t), \theta(t)) + (1-\zeta) \omega_i(t) \quad (7)$$

其中, η 为常量, x_i 表示脉冲时间。

$$\phi(y(t), \theta(t)) = y(t)(y(t) - \theta(t)) \quad (8)$$

其中, y 为 Spiking 脉冲点火输出序列, θ 表示动态阈值^[10]。

$$\theta(t) = \frac{\sum_{t'=t-h}^t y^2(t') \lambda^{t-t'}}{\sum_{t'=t-h}^t \lambda^{t-t'}} \quad (9)$$

其中, λ 为遗忘参数。

在采用 Spiking 神经网络进行训练时,合理设置 θ , ω_i , η 和 λ 非常关键,这会直接影响 SNN 的训练效果。在实际训练过程中,根据不同的样本,找到一组合适的 $(\theta, \omega_i, \eta, \lambda)$ 值并不容易,因此本文考虑采用智能算法对 SNN 的关键参数 $(\theta, \omega_i, \eta, \lambda)$ 进行优化训练,以获得较好的 SNN 训练性能。

2 改进的 SNN 模型

2.1 人工蜂群算法(ABC)

ABC 算法通过模拟蜜源搜索来进行运算求解,设蜜源为 i ,探测蜂在第 d 维的初始随机位置为 \mathbf{X}_{id} ^[11]:

$$\mathbf{X}_{id} = \mathbf{L}_d + \text{rand}(0,1)(\mathbf{U}_d - \mathbf{L}_d) \quad (10)$$

其中, \mathbf{U}_d 与 \mathbf{L}_d 分别为蜜源在第 d 维搜索的边界上下限范围, $d \in \{1, 2, \dots, D\}$, D 表示总维度。

探测蜂在 \mathbf{X}_{id} 处进行蜜源搜索,新蜜源为 \mathbf{V}_{id} ,表示为^[12]:

$$\mathbf{V}_{id} = \mathbf{X}_{id} + \varphi(\mathbf{X}_{id} - \mathbf{X}_{jd}) \quad (11)$$

其中, $j \neq i$, φ 值的范围是 $[-1, 1]$, \mathbf{X}_{jd} 是 $[\mathbf{L}_d, \mathbf{U}_d]$ 内第 d 维除 \mathbf{X}_{id} 外的任意位置。

当探测蜂侦探到新蜜源 $\mathbf{V}_i (\mathbf{V}_i = [\mathbf{V}_{i1}, \mathbf{V}_{i2}, \dots, \mathbf{V}_{id}])$ 时,其适应度 fit_i 的为:

$$fit_i = \begin{cases} 1/(1+f_i), & f_i \geq 0 \\ 1+abs(f_i), & \text{otherwise} \end{cases} \quad (12)$$

对比新旧蜜源两者的适应度值,选择 \mathbf{V}_i 和 \mathbf{X}_i 两者中较大的为新蜜源。

探测蜂将多个蜜源传递至跟随蜂,而跟随蜂选择其偏好蜜源的概率 p_i 为^[13]:

$$p_i = fit_i / \sum_{i=1}^{SP} fit_i \quad (13)$$

其中, SP 为所有蜜源数量。

探测蜂搜索蜜源的策略为:当迭代次 $trial$ 达到最大次数 $Itr \max$ 时,则重新跳转至式(11),否则继续找最优蜜源。

$$\mathbf{X}_i^{t+1} = \begin{cases} \mathbf{L}_d + \text{rand}(0,1)(\mathbf{U}_d - \mathbf{L}_d), & trial \geq Itr \max \\ \mathbf{X}_i^t, & trial < Itr \max \end{cases} \quad (14)$$

2.2 基于 ABC-PSNN 的分类流程

首先分别采用 Word2Vec 方法对文本样本进行初始化处理,采用 RGB 对图像数据进行矩阵化,然后建立 PSNN 分类模型,提取 PSNN 权重及动态阈值等参数构建蜂群,接着通过选择蜂群的探测蜂个体和跟随蜂个体进行位置更新优化,以分类准确率为适应度函数求解蜂群最优个体,从而获得适合 PSNN 分类的最优参数,最后采用经过 ABC 优化后的 PSNN 进行分类,具体分类流程如图 1 所示。

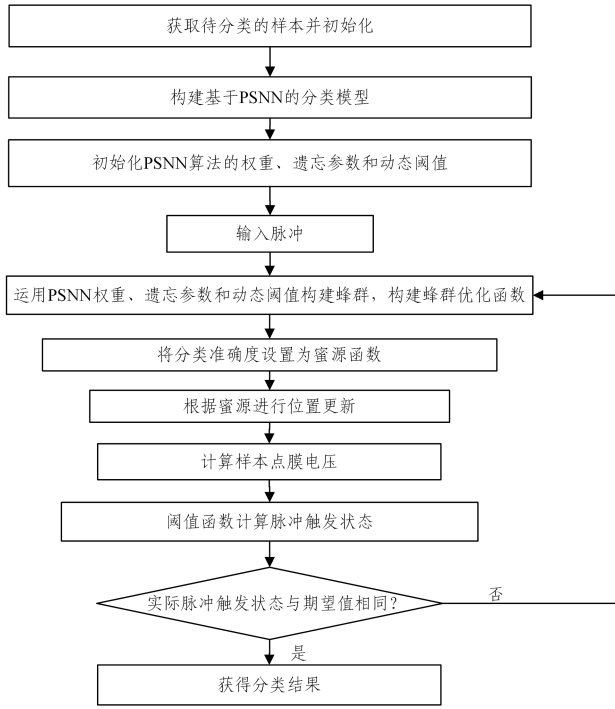


图1 基于 ABC-PSNN 算法的分类流程

Fig. 1 Classification process based on ABC-PSNN algorithm

3 实例仿真结果与分析

为了验证 ABC-Spiking 神经网络(PSNN)算法的性能,本文进行了实例仿真。仿真对象为 4 类不同领域的样本集,具体样本数据如表 1 所列。首先,采用 PSNN 算法和 ABC-PSNN 算法进行实例仿真,验证 ABC 算法的 PSNN 参数优化求解对 PSNN 的多标签分类性能的影响。其次将 ABC-PSNN 与常见的脉冲神经网络类型进行分类性能对比仿真。最后,将本文算法和常用多标签分类算法进行性能对比仿真。

表 1 分类样本集

Table 1 Classification sample sets

样本集	领域	样本数	属性	类别
Langlog	语言文本	1460	1004	75
Enron	邮件文本	1702	1001	53
Scene	图像	2407	294	6
Emotion	音乐文件	1593	72	6

在 PSNN 的分类训练中,采用的模型均为 4 层结构。

3.1 ABC 的优化性能

分别采用 PSNN 和 ABC-PSNN 算法进行分类训练,验证 PSNN 和 ABC-PSNN 算法针对表 1 中的 4 类样本集的分类性能,结果如表 2 和表 3 所列。由表 2 可知,4 类多标签样本集经过 ABC 算法的 PSNN 核心参数优化之后,其分类准确率提升明显。Langlog 集、Enron 集、Scene 集、Emotion 集的分类准确率均值分别提升了 8.89%,6.67%,8.34%,6.69%,其中 Langlog 集的分类准确率提升程度最明显。这表明 PSNN 的不同参数对 Langlog 集的多标签分类任务具有较大的影响。

从表 3 可知,4 类多标签样本集经过 ABC 算法的 PSNN

核心参数优化之后,其分类 RMSE 值有一定下降。Langlog 集的 RMSE 均值降低了 2.52%,而 Enron 集的 RMSE 均值降低了 0.36%,Scene 集的分类 RMSE 均值降低了 2.68%,Emotion 集的分类 RMSE 均值降低了 0.59%。其中 Scene 集和 Langlog 集的分类 RMSE 下降程度较明显,其他两类集的分类 RMSE 变化较小。这说明 PSNN 和 ABC-PSNN 算法的分类 RMSE 均没有明显的波动。虽然 ABC 算法可以提高 PSNN 的分类稳定性,但是效果并不十分显著,这可能是由于 PSNN 对 4 类多标签样本集已具有较好的适应性。

表 2 PSNN 和 ABC-PSNN 的分类准确率

Table 2 Classification accuracy of PSNN and ABC-PSNN

样本	算法	准确率		
		最小值	平均值	最大值
Langlog	PSNN	0.8475	0.8542	0.8611
	ABC-PSNN	0.9287	0.9301	0.9365
Enron	PSNN	0.8535	0.8637	0.8665
	ABC-PSNN	0.9189	0.9213	0.9231
Scene	PSNN	0.8560	0.8605	0.8692
	ABC-PSNN	0.9306	0.9323	0.9381
Emotion	PSNN	0.8572	0.8628	0.8667
	ABC-PSNN	0.9187	0.9205	0.9223

表 3 PSNN 和 ABC-PSNN 的分类 RMSE

Table 3 Classification RMSE of PSNN and ABC-PSNN

样本	算法	RMSE		
		最小值	平均值	最大值
Langlog	PSNN	0.8311	0.8342	0.8381
	ABC-PSNN	0.8111	0.8132	0.8144
Enron	PSNN	1.0283	1.0305	1.0332
	ABC-PSNN	1.0252	1.0268	1.0283
Scene	PSNN	1.1215	1.1366	1.1293
	ABC-PSNN	1.1052	1.1061	1.1071
Emotion	PSNN	1.1604	1.1621	1.1653
	ABC-PSNN	1.1531	1.1552	1.1568

3.2 ABC-PSNN 和其他 SNN 的分类性能对比

分别采用 ABC-PSNN,STDP-SNN 和 LSTM-SNN 对表 1 中的样本集进行性能仿真,验证不同脉冲神经网络算法的性能,结果如表 4—表 7 所列。

表 4 3 种脉冲神经网络模型分类准确率

Table 4 Classification accuracy of three spiking neural network models

数据集	算法		
	STDP-SNN	LSTM-SNN	ABC-PSNN
Langlog	0.8226	0.8415	0.9301
Enron	0.8317	0.8562	0.9213
Scene	0.8144	0.8479	0.9323
Emotion	0.8103	0.8632	0.9205

表 5 3 种脉冲神经网络模型分类召回率

Table 5 Classification recall rate of three spiking neural network models

数据集	算法		
	STDP-SNN	LSTM-SNN	ABC-PSNN
Langlog	0.8151	0.8327	0.9215
Enron	0.8237	0.8347	0.9049
Scene	0.8025	0.8219	0.8927
Emotion	0.7962	0.8525	0.8883

表 6 3种脉冲神经网络模型的分F1值

Table 6 Classification F1 values of three spiking neural network models

数据集	算法		
	STDP-SNN	LSTM-SNN	ABC-PSNN
Langlog	0.8023	0.8110	0.9125
Enron	0.8016	0.8212	0.9105
Scene	0.7925	0.8124	0.8901
Emotion	0.7703	0.8138	0.8824

表 7 3种脉冲神经网络模型的分RMSE

Table 7 Classification RMSE of three spiking neural network models

数据集	算法		
	STDP-SNN	LSTM-SNN	ABC-PSNN
Langlog	0.8491	0.8380	0.8132
Enron	1.0916	1.1083	1.0268
Scene	1.3892	1.3765	1.1061
Emotion	1.4324	1.4221	1.1552

从表4—表7可知,经过ABC优化之后,在主要4类分类指标上,ABC-PSNN算法性能明显优于其他两种脉冲神经网络算法。在多标签的分类准确率方面,ABC-PSNN算法在Scene数据集上获得了最高准确率,为0.9323,STDP-SNN在Emotion数据集上获得了最低准确率,仅为0.8103。这也从侧面验证了传统的脉冲神经网络算法在用于多标签分类时仍存在较大的不足。在具体应用环境中,需要根据需要选择合适的脉冲神经网络模型,而且根据模型训练性能需要,还要对传统算法进行适当改进。

3.3 不同算法的分类性能

为了进一步验证ABC-PSNN对表1中数据集的分类性能,采用常用的多标签分类算法SVM^[14],CNN^[15],GCN^[16]和ABC-PSNN算法分别对表1中的数据样本进行分类仿真,结果如图2—图5所示。

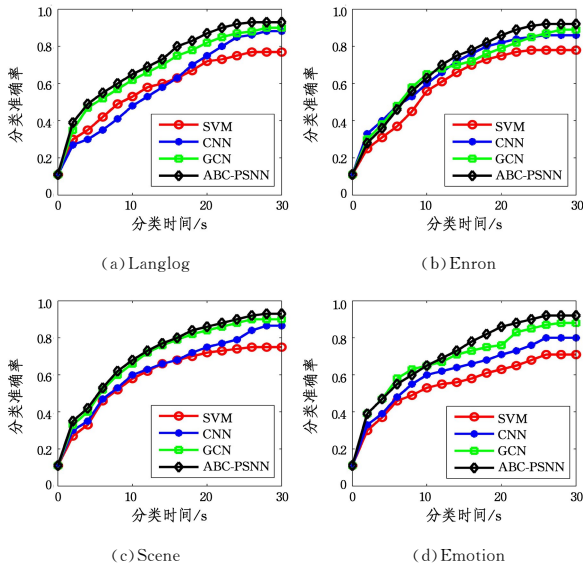


图 2 4种算法的分类准确率

Fig. 2 Classification accuracy of four algorithms

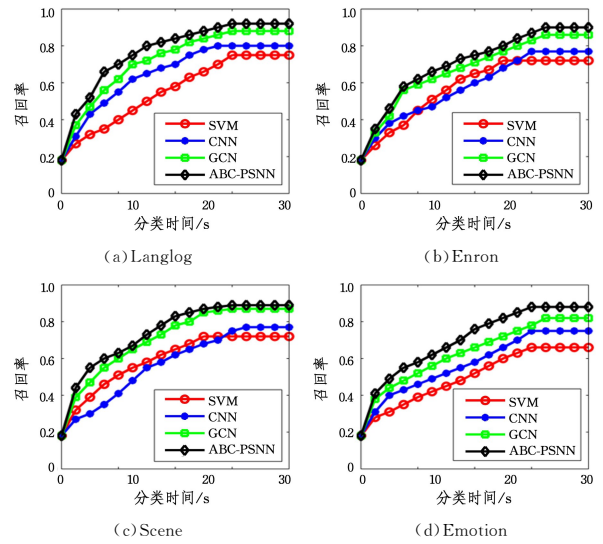


图 3 4种算法的分类召回率

Fig. 3 Classification recall rate of four algorithms

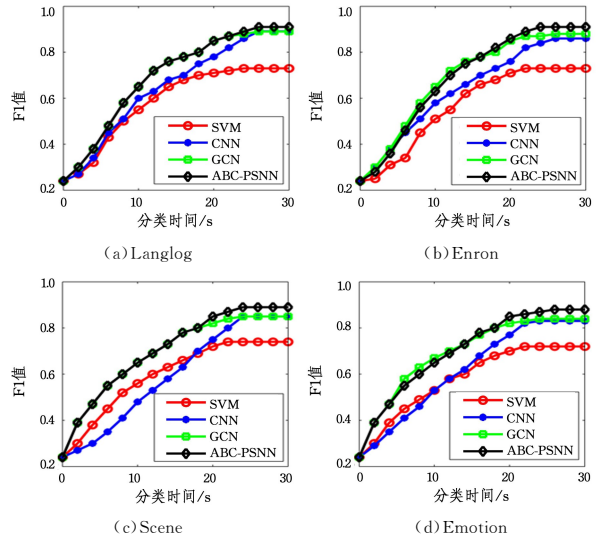


图 4 4种算法的分类F1值

Fig. 4 Classification F1 values of four algorithms

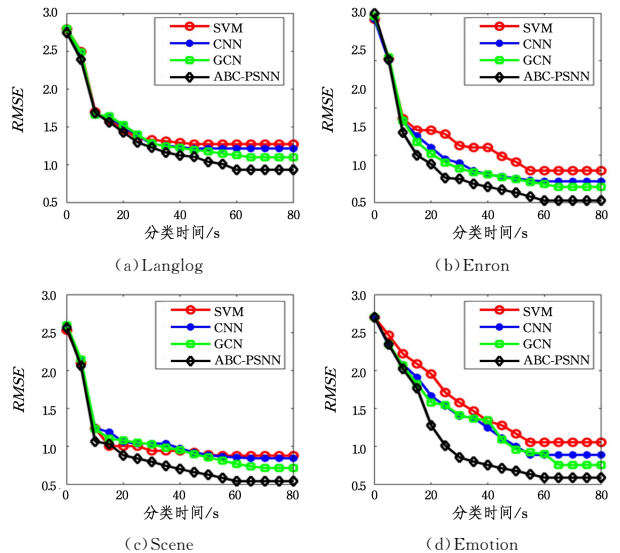


图 5 4种算法的分类RMSE

Fig. 5 Classification RMSE of four algorithms

从图 2 可以看出,对于 4 类样本集,在多标签分类准确率方面,ABC-PSNN 算法最高,分类准确率值均超过了 0.9, CNN 和 GCN 算法非常接近,均保持在 0.8 以上。SVM 算法最差,4 类样本的分类准确率仅维持在 0.7 左右。从分类算法执行时间来看,4 类样本集略有差异。整体来看,SVM 分类时间最短,其他 3 种算法执行时间接近。

在 4 类样本集的多标签分类召回率方面,当分类算法稳定时,ABC-PSNN 算法的召回率值最高,表明 ABC-PSNN 算法能够从复杂属性中获得多标签样本的实际类别。这主要是因为深度脉冲神经网络具有强大的处理多维特征数据的能力,且通过 ABC 优化后,能够获得更优的 PSNN 核心参数,从而提升 ABC-PSNN 的分类性能。

在 4 类样本集的分类 F1 值性能上,SVM 算法最差,其他 3 种算法非常接近,但 ABC-PSNN 算法仍具备一定的优势。ABC-PSNN, CNN 和 GCN 算法都经过了多层网络的非线性训练,展现了较高的分类 F1 性能,这 3 种算法均具备强大的多属性多标签分类能力。

在 4 类样本集的分类 RMSE 方面,ABC-PSNN 算法均有一定的提升。在 Langlog 和 Scene 集中,其他 3 种算法达到稳定时 RMSE 非常接近,而 ABC-PSNN 与其他算法的 RMSE 值差异明显。综合而言,ABC-PSNN 算法在 4 类样本集中的多标签分类稳定性最高。

结束语 本文采用 ABC-PSNN 算法进行多标签分类,通过 PSNN 算法的脉冲触发响应有效解决了高难度分类问题,而采用 ABC 算法能够对 PSNN 的关键参数进行有效优化,从而提升了 PSNN 算法的分类性能。和常用分类算法的对比实验表明,在解决多标签分类学习方面,ABC-PSNN 算法具备明显的分类优势,展现了更高的分类准确度和稳定性。后续研究将进一步差异化设置 ABC 算法的主要参数,以提高 ABC-PSNN 算法的分类效率,从而增强大规模多标签分类的适应度。

参 考 文 献

- [1] SONG D, LU K, DAI X F. Research on Mail Classification Algorithm Based on Improved Convolutional Neural Network[J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 2022, 39(3): 20-25.
- [2] ZHANG X F, WANG Z Q, TANG Y L. Helmet Detection Based on YOLO-CDF Neural Network[J]. Journal of Chongqing Technology and Business University(Natural Science Edition), 2022, 39(4): 32-41.
- [3] ZHUANG Z J, FANG Y, LEI J C, et al. Research on impulse neural network based on STDP rules[J]. Computer Engineering, 2020, 46(9): 83-88, 94.
- [4] WANG Q H, WANG L N, XU S. Research and application of pulse neural network model fused with LSTM structure[J]. Computer Application Research, 2021, 38(5): 1381-1386.
- [5] AUGÉ D, HILLE J, MUELLER E, et al. A survey of encoding techniques for signal processing in spiking neural networks[J]. Neural Processing Letters, 2021, 53(6): 4693-4710.
- [6] WEI Q M, LI Y B, YING Y L. Network security situation prediction based on Dempster-Shafer evidence theory and recurrent neural network [J]. Journal of University of Jinan(Science and Technology), 2020, 34(3): 238-246.
- [7] XIAO M, MENG Q, ZHANG Z, et al. Training feedback spiking neural networks by implicit differentiation on the equilibrium state[J]. Advances in Neural Information Processing Systems, 2021, 34: 14516-14528.
- [8] FANG W, YU Z, CHEN Y, et al. Deep residual learning in spiking neural networks[J]. Advances in Neural Information Processing Systems, 2021, 34: 21056-21069.
- [9] LOBO J L, DEL SER J, BIFET A, et al. Spiking neural networks and online learning: An overview and perspectives[J]. Neural Networks, 2020, 121: 88-100.
- [10] TAVANA EI A, GHODRATI M, KHERADPISHEH S R, et al. Deep learning in spiking neural networks[J]. Neural Networks, 2019, 111: 47-63.
- [11] AWADALLAH M A, AL-BETAR M A, BOLAJI A L, et al. Natural selection methods for artificial bee colony with new versions of onlooker bee[J]. Soft Computing, 2019, 23(15): 6455-6494.
- [12] LI J Q, SONG M X, WANG L, et al. Hybrid Artificial Bee Colony Algorithm for a Parallel Batching Distributed Flow-Shop Problem With Deteriorating Jobs[J]. IEEE Transactions on Cybernetics, 2020, 50(6): 2425-2439.
- [13] FOROUZANDEH S, BERAHMAND K, NASIRI E, et al. A Hotel Recommender System for Tourists Using the Artificial Bee Colony Algorithm and Fuzzy TOPSIS Model: A Case Study of TripAdvisor[J]. International Journal of Information Technology and Decision Making, 2021, 20(1): 399-429.
- [14] LIU J, GUO Z W, SUN Z W, et al. Research on fast multi label support vector machine classification algorithm using divide and conquer strategy[J]. Journal of Ocean University of China(Natural Science Edition), 2020, 50(12): 160-166.
- [15] LIU J Z, DUAN L. Network security text multi label classification method based on Albert textcnn[J]. Naval Electronic Engineering, 2022, 42(3): 114-118, 170.
- [16] YANG M H, CHEN L, LIU H, et al. Multi label remote sensing image classification based on graph convolution network[J]. Computer Application Research, 2021, 38(11): 3439-3445.



MA Weiwei, born in 1980, Ph.D, associate professor. His main research interests include artificial intelligence and big data, statistical analysis of education.



ZHENG Qinzhong, born in 1962, Ph.D, professor. His main research interests include artificial intelligence and big data, statistical analysis of education.