

DOI: 10.13652/j.issn.1003-5788.2020.08.008

基于电子舌及一维深度 CNN-ELM 模型的普洱茶贮藏年限快速检测

A fast detection Pu-erh tea storage based on the voltammetric electronic tongue and one-dimension CNN-ELM

杨正伟¹ 张鑫¹ 李庆盛¹ 缪楠¹ 王志强¹

YANG Zheng-wei¹ ZHANG Xin¹ LI Qing-sheng¹ MIAO Nan¹ WANG Zhi-qiang¹

李彩虹¹ 袁文浩¹ 马云霞² 周智²

LI Cai-hong¹ YUAN Wen-hao¹ MA Yun-xia² ZHOU Zhi²

(1. 山东理工大学计算机科学与技术学院, 山东 淄博 255049; 2. 淄博市中西医结合医院, 山东 淄博 255026)

(1. School of Computer Science and Technology, Shandong University of Technology, Zibo,

Shandong 255049, China; 2. Zibo Integrative Medicine Hospital, Zibo, Shandong 255026, China)

摘要:采用伏安电子舌对不同贮藏年限的普洱茶进行快速检测。将深度学习技术引入到电子舌的模式识别中,提出一种基于一维卷积神经网络(1-D CNN)与极限学习机(ELM)组合的模式识别模型(1-D CNN-ELM)。采用该模型结合伏安电子舌对 5 种不同贮藏年限的普洱茶进行分类鉴别,结果表明,与传统基于离散小波变换(DWT)结合支持向量机(SVM)或极限学习机(ELM)的模型相比,1-D CNN-ELM 对普洱茶贮藏年限的分类效果更优,其测试集准确率、精确率、召回率和 F1-Score 分别达到 98.32%, 98.0%, 98.0%, 0.98。试验表明深度学习方法适用于对电子舌信号进行模式识别处理,且具有较高的分类准确性和泛化能力。

关键词:普洱茶;贮藏年限;一维卷积神经网络;极限学习机;伏安电子舌

Abstract: Pu-erh tea storage year detection has the problems of cumbersome operation and complicated evaluation process. On this basis, a voltammetric electronic tongue (VE-Tongue) came out for fast detection of different storage years of Pu-erh tea. Conventional pattern recognition method of VE-Tongue was mainly based on manual feature design combined with shallow

machine learning algorithms. In this study, a deep learning algorithm was introduced into pattern recognition method of VE-Tongue. A hybrid pattern recognition method based on combination of one-dimension convolutional neural network (1-D CNN) and extreme machine learning (ELM) was proposed. The 1-D CNN-ELM model combined with VE-Tongue was utilized to distinguish Pu-erh tea with five different storage years. The result showed that compared with traditional models based on discrete wavelet transform (DWT) combining with support vector machine (SVM) or extreme machine learning, 1-D CNN-ELM model gained better classification performance, in which the accuracy, precision, recall and F1-Score were 98.32%, 98.0%, 98.0% and 0.98 respectively. This experiment illustrated that deep learning algorithm was suitable for pattern recognition dispose of VE-Tongue signal and could obtained superior classification accuracy and generalization ability.

Keywords: Pu-erh tea; storage year; One-dimension convolutional neural network; extreme learning machine; voltammetric electronic tongue

基金项目:山东省自然科学基金(编号:ZR2019MF024);国家自然科学基金(编号:61701286);教育部科技发展中心产学研创新基金(编号:2018A02010);赛尔网络下一代互联网技术创新项目(编号:NGII20170314)

作者简介:杨正伟,男,山东理工大学在读硕士研究生。

通信作者:王志强(1977—),男,山东理工大学教授,博士。

E-mail: wzq@sdut.edu.cn

收稿日期:2020-04-10

普洱茶是以云南特有的大叶种晒青毛茶为原料,经过渥堆发酵工艺生产的后发酵类茶^[1],具有降血糖、降血脂、抗病毒等功效,深受国内外消费者的喜爱^[2]。随着贮藏时间的增加,普洱茶的内部会发生复杂的化学变化,使得其风味和口感得以提升^[3]。近年来,受经济利益驱动,市场上常会出现普洱茶产品以新替旧、以次充好等现象,严重损害了消费者的权益和普洱茶市场的声誉。传统普洱茶贮藏年限鉴别方法主要有感官分析法和理化分析

法。湛滢等^[4]采用感官分析法对不同年限的普洱茶外形、茶汤色泽和口感进行评价并做出区分,但该方法受人为因素影响较大,结果的客观性容易受到干扰;谢直虎等^[5]采用傅里叶红外光谱对不同年限普洱茶中的酚类、醇类等物质进行分析,进而对不同普洱茶进行分辨;郑玲等^[6]采用表面增强拉曼光谱对不同年限普洱茶中的茶素、茶氨酸等物质进行检测,从而区分不同年限的普洱熟茶。但以上理化分析方法检测仪器成本高、分析过程繁琐、耗时耗力且需要检测人员具备专业技能,不适用于对普洱茶贮藏年限进行快速鉴别。

电子舌是一种利用多传感阵列结合模式识别技术对液态样本的“指纹图谱”进行分析的仿生学仪器,具有操作简单、检测迅速、仪器体积小、成本低、检测结果客观性强等特点。近年来电子舌已被广泛应用于环境监测^[7]、食品检测与鉴别^[8]和药物分析^[9]等多个领域。模式识别技术在电子舌系统中起着至关重要的作用,其适用性直接影响到检测结果的准确性。Bhondekar 等^[10]使用电子舌结合主成分分析和判别因子分析等模式识别方法对不同生产工艺的印度红茶进行了辨别;Bhattacharyya 等^[11]采用电子舌结合线性判别分析和反向传播神经网络等模式识别方法对不同种类的红茶进行了区分。一般来说,电子舌系统的模式识别过程主要包括特征提取和分类识别两个阶段。特征提取的主要作用是从原始电子舌信号中提取出最重要的信息,从而减少后续数据分析的复杂性。常见的特征提取方法有特征点法^[12]、主成分分析法(PCA)^[13]、快速傅里叶变换法(FFT)^[14]、离散小波变换法(DWT)等,其中离散小波变换已被证明是一种较为有效的电子舌特征提取方法^[15]。然而,以上特征提取方法主要基于人工特征设计,效率较低,并且其效果受设计人员的经验和技能影响较大。分类识别是基于所提取的特征信息对样本进行分类或识别的方法。目前常用的电子舌分类识别算法主要有线性判别分析(LDA)^[16]、反向传播神经网络(BPNN)^[17]、支持向量机(SVM)^[18]等。然而,这些方法主要基于浅层的机器学习算法构造,存在模型精度有限、泛化能力不足等问题。

深度学习是近年来发展起来的一种新型数据分析和信号分析技术。深度学习对传统的人工神经网络进行扩充,增加了模型的深度(复杂性),并通过使用允许分层级别的数据表示,提高了数据分析和处理的能力。在深度学习算法中,卷积神经网络(Convolutional Neural Network, CNN)是最著名的模型之一。CNN 通过引入多个卷积层和池化层(下采样层),实现了一种自动的特征提取机制^[19]。目前, CNN 已被广泛应用于计算机视觉、语音识别、自然语言处理等多个与人工智能相关的研究领域^[20]。然而,当前尚未见文献将 CNN 应用于电子舌的模式识别处理。由于 CNN 的全连接层采用反向传播

(BP)算法进行训练,容易陷入局部最小或出现过度训练,导致模型训练时间长、泛化性能下降。极限学习机(ELM)是一种基于单隐层前馈神经网络(SLFN)的监督型算法,具有训练参数计算量小、训练时间短、分类效率高特点,作为分类器可以很好地弥补 BP 算法的缺点^[21]。

研究拟提出一种基于伏安电子舌和一维深度 CNN 结合 ELM 模型(1-D CNN-ELM)的普洱茶贮藏年限鉴别方法。利用卷积神经网络自动提取特征的特点对电子舌信号进行特征提取,并通过 ELM 建立分类模型对提取后的特征向量进行分类,为不同年限普洱茶的快速、准确地鉴别提供新的方法和思路。


1 材料与方法

1.1 试验材料及样本处理

试验材料均采用勐海茶厂出产的普洱熟茶,出厂时间分别为 2011 年、2013 年、2015 年、2017 年和 2019 年 5 个不同年份。准确称取 5 g 茶叶,放入 200 mL 沸腾蒸馏水冲泡 5 min,茶溶液经滤纸过滤,冷却至室温 $[(25 \pm 2) ^\circ\text{C}]$ 后采用伏安电子舌进行数据采集。每个样本采集完成后,用 Al_2O_3 粉末对传感器阵列进行打磨,然后放入超声波清洗仪中清洗。采用上述方法共采集到 1 595 个电子舌信号,其中 2011 年、2013 年、2015 年、2017 年和 2019 年的样品数量分别为 333, 310, 314, 317, 321。

1.2 电子舌系统

伏安电子舌系统由实验室自行开发,结构如图 1 所示。该系统由 4 部分组成:① 传感器阵列,包括 8 个不同的工作电极(铂、金、钛、钯、银、钨、镍和玻碳)、一个铂辅助电极和一个 Ag/AgCl 参比电极。Winqvist 等^[22]发现不同种类贵金属电极对不同化学成分的敏感性不同,导致其表面的电化学反应产生差异,多个工作电极采集的电流信号经汇总后可形成被测溶液的“指纹图谱”。② 信号调理电路,用于控制三电极系统的恒压电势并完成采集信号的放大与滤波功能。③ 数据采集卡,通过其 D/A 模块产生电极激励信号并利用 A/D 模块采集传感器响应信号。④ LabVIEW 上位机软件,用于对检测过程进行



1. 参比电极 2. 工作电极与辅助电极 3. 信号调理电路
4. LabVIEW 上位机软件 5. 数据采集卡

图 1 伏安电子舌系统

Figure 1 VE-tongue system

操控,并对采集到的电极响应信号进行分析。电子舌检测过程中,采用如图 2 所示的大幅方波脉冲(LAPV)对工作电极进行伏安扫描,其工作电势范围为-1~1 V,扫描频率为 10 Hz,阶跃电位为 5 mV。在 LAPV 的激励下,多个工作电极表面发生氧化还原反应,产生不同幅度的微弱电流响应信号。该信号经调理电路放大后,通过数据采集卡采集至 LabVIEW 软件进行分析。

1.3 一维卷积神经网络

传统的 CNN 为二维卷积神经网络,通常用于图像识别领域^[23]。由于电子舌信号为一维信号,因此选用一维




图 2 大幅方波脉冲伏安信号

Figure 2 Large amplitude pulse voltammetry signal

卷积神经网络(1-D CNN)模型。其结构如图 3 所示,主要由多个卷积层、池化层(下采样层)和全连接层组成。




图 3 一维卷积神经网络模型结构

Figure 3 One-dimension CNN model structure

卷积层的主要作用是从上一层中提取特征,并为下一层创建新的输出(特征图)。通过对多个卷积核进行卷积运算,增强了原始信号的特征信息,同时降低了噪声水平。对于第 k 层卷积层,其输出为 x^k ,则对应第 j 个一维卷积核的输出为 x_j^k 。

$$x_j^k = f\left(\sum_{x_i^{k-1} \in D_i} x_i^{k-1} \times W_{ij}^k + b_j^k\right), \quad (1)$$

式中:

D —— 输入数据;

W_{ij}^k —— 卷积核;

$*$ —— 一维卷积操作;

b —— 偏置项;

$f(\cdot)$ —— 激活函数。

卷积层后为池化层(下采样层),其目的是进一步缩小特征图的尺寸,减轻 1-D CNN 的计算负担。池化层一般只进行降维操作,没有参数,不进行权重更新。文中,选择最大池化操作:

$$x_j^k(n) = \max\{x_j^k(2n-1), x_j^k(2n)\}, \quad (2)$$

式中:

$x_j^k(n)$ —— 第 k 层第 j 个卷积核;

n —— 卷积核的尺寸边长;

$\max(\cdot)$ —— 最大值函数。

全连接层由多个隐含层组成,作用是将所得到的多通道特征图转化为一维向量,其形式为 $X = [x_1, x_2, \dots, x_n]$,其中 n 为最后一个卷积层的节点个数。模型最后一

层输出层采用 Softmax 激活函数,其公式:

$$\text{Softmax}(X) = \frac{e^{x_i}}{\sum_{i=1}^n e^{x_i}}. \quad (3)$$

1.4 极限学习机

极限学习机(ELM)是由 Huang 等^[21]提出的一种改进的单隐层前馈神经网络(SLFN)。ELM 可以随机选择输入层和隐含层之间的隐藏节点和连接权值,从而确定网络的输出权值。对 N 个任意不同的样本 (x_i, y_i) , $(x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n, y_i = [y_{i1}, y_{i2}, \dots, y_{in}]^T \in R^n)$,其具有 L 个隐含层节点的 SLFN 为

$$t_j = \sum_{i=1}^L \beta_i f(\alpha_i x_j + b_i), j = 1, 2, \dots, N; b_i, \beta_i \in R; \alpha_i \in R^n, \quad (4)$$

式中:

$f(\cdot)$ —— 激活函数;

β_i —— 隐含层和输出层第 i 个节点之间的输出权重;

α_i —— 输入层和隐含层第 i 个节点之间的输入权重;

b_i —— 第 i 个节点之间的偏置。

用矩阵的形式对式(6)进行重构:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T}, \quad (5)$$

其中, \mathbf{H} 表示隐含层输出矩阵:

$$\mathbf{H} = \begin{bmatrix} w(x_1) \\ w(x_2) \\ \vdots \\ w(x_N) \end{bmatrix} = \begin{bmatrix} f(\alpha_1 x_1 + b_1) & \cdots & f(\alpha_L x_1 + b_L) \\ f(\alpha_1 x_2 + b_1) & \cdots & f(\alpha_L x_2 + b_L) \\ \vdots & \ddots & \vdots \\ f(\alpha_1 x_N + b_1) & \cdots & f(\alpha_L x_N + b_L) \end{bmatrix}_{N \times L} \quad (6)$$

式中:

β ——输出权重矩阵, $\beta = [\beta_1^T \cdots \beta_L^T]_{L \times m}$;

T ——期望输出矩阵, $T = [t_1^T \cdots t_L^T]_{L \times m}$ 。

在 SLFN 中,当激活函数 f 无限可微,对于随机选择的输入权值和隐含层偏置,只要训练集样本数 N 大于隐含层神经元个数 L ,SLFN 即可零误差去逼近训练样本。因此,训练 ELM 的过程相当于求解方程组 $\mathbf{H}\beta = \mathbf{T}$ 的最小二乘解:

$$\text{Min}_{\beta} \|\mathbf{H}\beta - \mathbf{T}\| \quad (7)$$

可证明该最小二乘解的最小值为:

$$\hat{\beta} = \mathbf{H}^+ \mathbf{T} \quad (8)$$

式中:

\mathbf{H}^+ ——隐含层输出矩阵 \mathbf{H} 的广义雅克比矩阵的逆,可通过正交法计算求得。

1.5 1-D CNN-ELM 模型

经典 1-D CNN 采用 BPNN 作为分类器,会导致训练时间长、泛化能力差的问题。ELM 具有训练速度快、泛化性好、分类精度高等优点。鉴于 1-D CNN 以及 ELM 各自的特点,将 1-D CNN 和 ELM 组合构建 CNN-ELM 模型。图 4 为 1-D CNN-ELM 模型结构图,其中,1-D CNN 模型由 5 个卷积层和 4 个池化层组成。第 1 个卷积层使用了 16 个尺寸为 7 的卷积核。第 2 个卷积层使用 32 个尺寸为 5 的卷积核。第 3~5 个卷积层均采用尺寸为 3 的卷积核,其个数分别为 64,128,64。模型的激活函数采用指数线性单元(ELU)。在第 1 个卷积层到第 5 层卷积层之间均放置一个 Max-Pooling 层,池化窗口尺寸和步幅为 2。最后一层卷积后采用 ELM 进行分类识别。

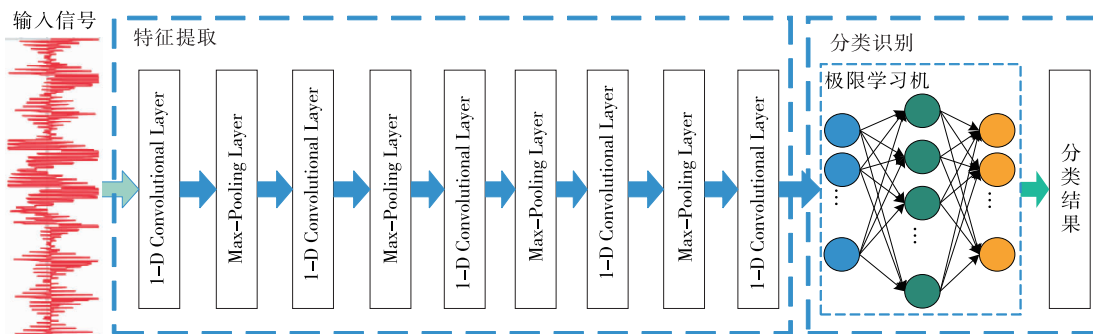


图 4 1-D CNN-ELM 模型

Figure 4 Structure of 1-D CNN-ELM model

1-D CNN-ELM 模型的训练流程如图 5 所示,先将伏安电子舌采集的普洱茶信号进行数据预处理操作(数据增强、数据归一化),再将处理好后的数据集中的 70% 作为训练集样本,其余作为测试集样本。使用训练集样本训练 1-D CNN 至收敛,然后提取最后一个卷积层的特征训练 ELM,可得到 1-D CNN-ELM 模型,采用测试集样本对模型进行分类效果检验。

2 结果与分析

模型训练均是在 Keras 框架下完成的。硬件环境: Intel i7-8700K @ 3.70 GHz; 24 G 内存; Nvidia GeForce GTX 1080Ti, 11 G 显存。软件环境: CUDA Toolkit 10.0, CUDNN V7.6.1; Python 3.6; Keras 2.2.4; Windows 10 64 bit 操作系统。

2.1 电子舌响应信号

伏安电子舌系统的 8 个工作电极得到的响应信号如

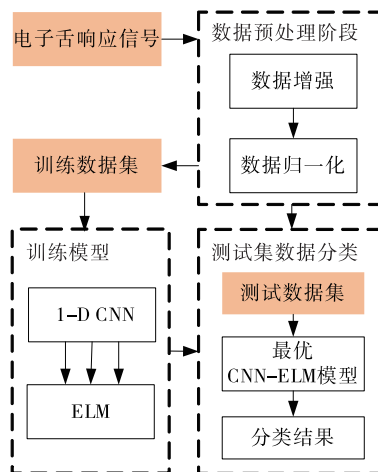


图 5 1-D CNN-ELM 模型训练流程

Figure 5 Training flow of 1-D CNN-ELM model

图 6 所示。由图 6 可以看出,每个电极区域都表现出一种独特的普洱茶样品“指纹图谱”。普洱茶经检测后,每个样品可采集得到 8 000 个数据点(1 000×8 个电极)。

2.2 数据预处理与数据增强

由于电子舌信号噪声大且数值变化幅度较大,因此需要采用式(9)对电子舌信号进行归一化处理:

$$x_{scale}^i = \frac{x_i - x_{max}}{x_{max} - x_{min}}, \quad (9)$$

式中:

x_i ——信号中第 i 个采样值;

x_{max} ——信号中最大值;

x_{min} ——信号中最小值。

为了进一步提高 1-D CNN 模型的鲁棒性,采用数据增强技术增加电子舌信号的训练样本数量。文中采用信号加噪扩容的信号增强方法,步骤是:首先将均值为 0,标准差为 0.05 的随机高斯噪声信号嵌入到原始的电子舌信号中,形成加噪数据集。然后将加噪数据集与原数据集组合,共可得到 3 190 个电子舌信号训练样本。

2.3 CNN-ELM 模型

2.3.1 CNN 结构优化 不同的卷积层和池化层组合会影响 1-D CNN 对电子舌信号特征的提取效果。较多的卷积层(Conv- i)和池化层(Pooling- i)会导致模型提取过多不必要的特征,易产生过拟合问题;而较少的卷积层和池化层则会使得样本特征得不到充分提取,易产生欠拟合问题。为了达到最佳的特征提取效果,采用(Conv-6, Pooling-5)、(Conv-5, Pooling-4)、(Conv-4, Pooling-3)和(Conv-3, Pooling-2) 4 种不同数目的卷积层和池化层组合对 CNN 模型进行优化。从图 7 可以看出,随着卷积层从 3 增加到 6、池化层从 2 增加到 5,1-D CNN 模型在训练集上的收敛速度和分类准确率增加。从图 8 可以看出,测试集上,最佳组合为(Conv-5, Pooling-4),而组合(Conv-6, Pooling-5)出现性能下降的原因可能是卷积层和池化层数量过多,导致电子舌特征被过度提取从而产生过拟合问题。

1-D CNN 的超参数如学习率、训练周期 epoch 和 mini-batch size 也会对模型的训练速度和泛化性能产生




图 6 电子舌响应信号

Figure 6 Electronic tongue response signal




图 7 不同模型组合在训练集和测试集的分类精度

Figure 7 Accuracy of 1-D CNN models with different combination on training set and testing set




图 8 不同卷积层和池化层组合的模型在训练集和测试集上的平均分类精度

Figure 8 Average accuracy 1-D CNN models with different combination on training set and testing set

较大影响。因此,采用单一因素法对 1-D CNN 的超参数进行选择优化,具体步骤见文献[24],其结果如图 9 所示。通过比较不同超参数在测试集上的分类性能,得到最佳分类效果的模型的学习率为 0.000 5、训练周期 epoch 为 30、mini-batch size 的参数为 42。

2.3.2 ELM 分类器优化 1-D CNN-ELM 模型的 ELM 分类器在训练中能够随机产生输入层和隐含层间的连接权值和阈值,因此,仅需要对 ELM 隐含层节点数进行优化即可。分别将隐含层的节点数为 2~200 的不同 ELM 与 1-D CNN 结合,其不同结构的模型分类准确性结果如图 10 所示。由图 10 可以看出,当隐含层节点数为 146 时,1-D CNN-ELM 的性能最佳,其准确率为 98.32%。

2.4 传统机器学习模型

为了验证文中方法的有效性,采用离散小波变换(DWT)作为特征提取方法,分别使用 SVM 和 ELM 作为分类器,组成 DWT-SVM 和 DWT-ELM 两种对比模型,对普洱茶电子舌信号进行模式识别操作。

在 DWT 特征提取过程中,为了达到最佳效果,对小波基函数和分解阶数进行优化。电子舌信号分别选择 4 种不同的小波基函数(Coiflets、Daubechies、Haar、Symlets)进行 4~7 阶的分解。为了评价分解效果,选择




图 9 不同超参数在 CNN 测试集上的准确率

Figure 9 Accuracy of CNN model with different hyperparameters on testing set

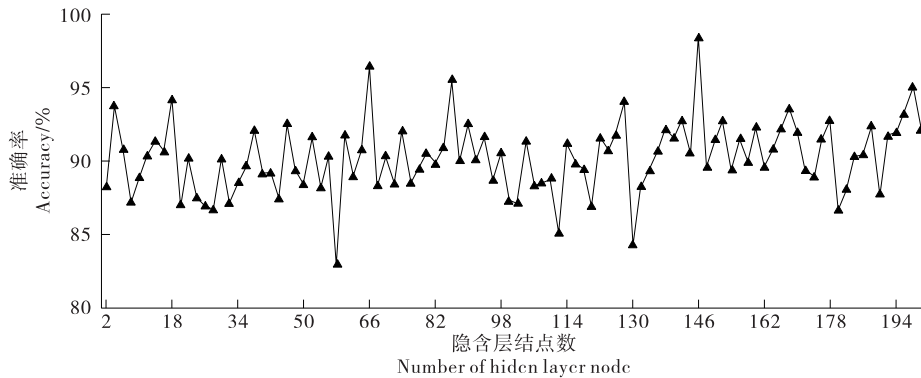


图 10 不同隐含层节点数的 ELM 在测试集上的准确率

Figure 10 Accuracy of ELM model with different number of hidden layer nodes on testing set

相关系数 R^2 作为评价指标。其试验结果如图 11 所示。结果表明,当采用 Sym6 母小波进行 7 层分解时,相似系数达到最大值 0.974 9,此时压缩效果最好。电子舌信号经 DWT 特征提取后,8 000 个数据点被压缩至 73 个。

采用 SVM 作为模型分类器,其分类性能主要受到惩罚系数 C 和核函数参数 λ 影响。采用网格寻优算法对

SVM 进行优化,其中的 C 和 γ 的取值范围均为 $[2^{-5}, 2^{-4}, \dots, 2^4, 2^5]$,其结果如图 12 所示,试验表明,当 $C=2^{-5}, \gamma=2^5$ 时,DWT-SVM 模型的分类效果达到最优,其准确率为 91.36%。采用与 3.3.2 节相同的方法对 DWT-ELM 模型中的 ELM 隐含层节点进行优化,结果表明,当节点数为 96 时,DWT-ELM 模型的性能最佳,其准确率为 93.63%。

2.5 模型性能对比分析

分别建立 1-D CNN-ELM、传统 CNN、DWT-SVM 和

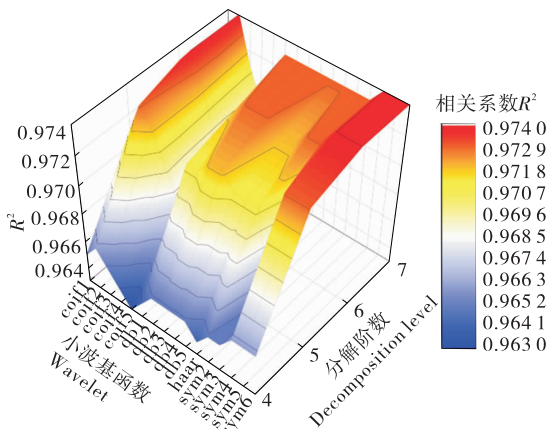


图 11 DWT 特征提取中不同母小波和分解层数对 R^2 的影响

Figure 11 Influence of different mother wavelet and decomposition level on similarity coefficient R^2




图 12 SVM 中不同的 C 和 γ 对测试集准确率的影响
Figure 12 Effect of SVM with different C and γ on accuracy on testing set

DWT-ELM 模型的分类混淆矩阵。如图 13 所示,可发现传统 CNN 对普洱茶年限鉴别的正确分类的样本个数要

大于 DWT-ELM 和 DWT-SVM,而 1-D CNN-ELM 的正确分类的样本数多于传统 CNN。

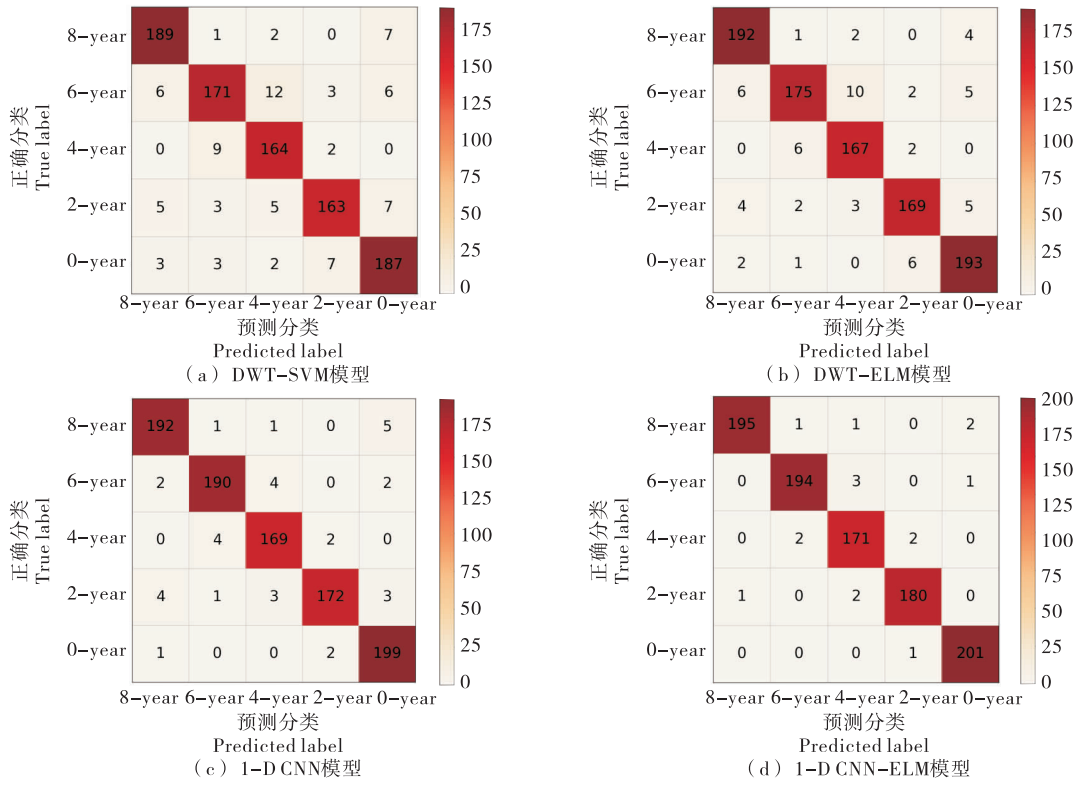


图 13 4 种模型分类混淆矩阵

Figure 13 Confusion matrix of four different model

进一步对 4 种模型的精确率、召回率和 F1-Score 参数进行对比分析,其公式:

$$Precision = \frac{T_p}{T_p + F_p} \times 100\%, \quad (10)$$

$$Recall = \frac{T_p}{T_p + F_N} \times 100\%, \quad (11)$$

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall}, \quad (12)$$

式中:

Precision —— 精确率, %;

Recall —— 召回率, %;

F1-Score —— F1-Score 参数;

T_p —— 真实的正样本数量;

F_p —— 真实的负样本数量;

F_N —— 虚假的负样本数量。

从表 1 可以看出,DWT-ELM 模型的精确率、召回率和 F1-Score 分别为 94.0%,94.0%,0.94,较 DWT-SVM 模型的性能提高了约 3%。这可能是由 ELM 模型比 SVM 模型具有更好的泛化能力和鲁棒性造成的。传统 1-D CNN 模型性能又较 DWT-ELM 模型提高了约 2%,表明 1-D CNN 在其分类器(BPNN)性能劣于 ELM 的情

况下,仍能取得较好的分类效果,证明了深度学习方法比传统机器学习方法具有更好的特征提取性能。而 1-D CNN-ELM 模型与 1-D CNN 模型相比性能更好,说明 ELM 分类器的引入有效地提高了传统 CNN 模型的分类准确率和模型泛化性能。

3 结论

研究提出了一种基于 1-D CNN-ELM 模式识别模型结合伏安电子舌对普洱茶年限进行鉴别的方法。采用一维卷积神经网络对电子舌信号进行自动特征提取,然后利用 ELM 算法进行分类识别。该方法克服了传统 CNN 泛化能力差、训练耗时长的缺点,同时避免了传统机器学习

表 1 不同模式识别模型的性能对比

Table 1 Comparison of performance evaluation of different models

模型	精确率/%	召回率/%	F1-Score 参数
DWT-SVM	91.0	91.0	0.91
DWT-ELM	94.0	94.0	0.94
CNN	96.0	96.0	0.96
1-D CNN-ELM	98.0	98.0	0.98

习模型需要人工特征设计,导致特征提取不完善、费时费力等问题。试验结果表明,与传统电子舌信号模式识别模型相比,1-D CNN-ELM 模型对不同贮藏年限的普洱茶电子舌信号的分类准确率有较大提升。研究仅对 5 种不同年限的普洱茶进行鉴别且采用单一因素法优化 1-D CNN 模型超参数,后续将采用更加高效的模型优化方法,并将其应用于电子舌的其他检测领域,以进一步验证其适用性。

参考文献

- [1] 宁井铭, 张正竹, 宛晓春. 基于气相色谱技术的普洱熟茶 7572 挥发性物质指纹图谱建立及应用[J]. 食品与发酵工业, 2016, 42(10): 176-183.
- [2] 周丽静, 侯彩云, 乔艳慧, 等. 不同贮藏年份普洱茶功能特性研究[J]. 食品科学, 2010, 31(13): 19-22.
- [3] XIE Guo-xiang, YE Mao, WANG Yun-gang, et al. Characterization of pu-erh tea using chemical and metabolic profiling approaches[J]. Journal of Agricultural and Food Chemistry, 2009, 57(8): 3 046-3 054.
- [4] 湛滢, 欧行畅, 张杨波, 等. 不同储藏年份普洱生茶感官品质的分析[J]. 食品科技, 2018, 43(4): 48-52.
- [5] 谢直虎, 杨群. FTIR 法对贮藏年限不同的两种普洱绿茶的研究[J]. 光谱实验室, 2008(5): 909-913.
- [6] 郑玲, 赵燕平, 冯亚东. 不同产地和陈化年限普洱茶的表面增强拉曼光谱鉴别分析研究[J]. 光谱学与光谱分析, 2013, 33(6): 1 575-1 580.
- [7] KRANTZ-RULCKER C, STENBERG M, WINQUIST F, et al. Electronic tongues for environmental monitoring based on sensor arrays and pattern recognition: A review[J]. Analytica Chimica Acta, 2001, 426(2): 217-226.
- [8] 潘俊娴, 段玉伟, 蒋玉兰, 等. 福鼎白茶风味的电子鼻和电子舌评价[J]. 食品工业科技, 2017, 38(12): 25-30, 43.
- [9] YAROSHENKO I, KIRSANOV D, KARTSOVA L, et al. Exploring bitterness of traditional Chinese medicine samples by potentiometric electronic tongue and by capillary electrophoresis and liquid chromatography coupled to UV detection[J]. Talanta, 2016, 152: 105-111.
- [10] BHONDERKAR A P, DHIMAN M, SHARMA A, et al. A novel iTongue for Indian black tea discrimination[J]. Sensors and Actuators B: Chemical, 2010, 148 (2): 601-609.
- [11] BHATTACHARYYA R, TUDU B, DAS S C, et al. Classification of black tea liquor using cyclic voltammetry[J]. Journal of Food Engineering, 2012, 109(1): 120-126.
- [12] 钟海军, 田师一, 邓少平. 智能型电子舌的虚拟仪器构建技术[J]. 仪表技术与传感器, 2009(10): 31-34, 38.
- [13] 刘双印, 徐龙琴, 李振波, 等. 基于 PCA-MCAFA-LSSVM 的养殖水质 pH 值预测模型[J]. 农业机械学报, 2014, 45 (5): 239-246.
- [14] LU Liu, HU Xian-qiao, TIAN Shi-yi, et al. Visualized attribute analysis approach for characterization and quantification of rice taste flavor using electronic tongue [J]. Analytica Chimica Acta, 2016, 919: 11-19.
- [15] SHI Qing-rui, GUO Ting-ting, YIN Ting-jia, et al. Classification of pericarpium citri reticulatae of different ages by using a voltammetric electronic tongue system[J]. International Journal of Electrochemical Science, 2018, 13(12): 11 359-11 374.
- [16] YIN Ting-jia, GUO Ting-ting, MA Ze-liang, et al. Classification of wolfberry with different geographical origins by using voltammetric electronic tongue[J]. IFAC-Papers On Line, 2018, 51(17): 654-659.
- [17] CETÓ X, GUTIÉRREZ-CAPITÁN M, CALVO D, et al. Beer classification by means of a potentiometric electronic tongue[J]. Food Chemistry, 2013, 141(3): 2 533-2 540.
- [18] CHANG Kuang-hua, CHEN Richie L C, HSIEH Bo-chuan, et al. A hand-held electronic tongue based on fluorometry for taste assessment of tea[J]. Biosensors and Bioelectronics, 2010, 26(4): 1 507-1 513.
- [19] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2 278-2 324.
- [20] 章琳, 袁非牛, 张文睿, 等. 全卷积神经网络研究综述[J]. 计算机工程与应用, 2020, 56(1): 25-37.
- [21] HUANG Guang-bin, ZHU Qin-yu, SIEW Chee-K. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70(1): 489-501.
- [22] WINQUIST F, WIDE P, LUNDSTRÖM I. An electronic tongue based on voltammetry[J]. Analytica Chimica Acta, 1997, 357(1): 21-31.
- [23] SENGUPTA S, BASAK S, SAIKIA P, et al. A review of deep learning with special emphasis on architectures, applications and recent trends[J]. Knowledge-Based Systems, 2020, DOI: 10.1016/j.knosys.2020.105596.
- [24] THENMOZHI K, SRINIVASULU REDDY U. Crop pest classification based on deep convolutional neural network and transfer learning[J]. Computers and Electronics in Agriculture, 2019, 164: 104906.