

基于深度学习的青梅品级半监督智能认知方法

李帷韬^{1,2} 陶海¹ 吴四茜¹ 王建平¹ 徐晓冰^{1*}

¹(合肥工业大学电气及自动化工程学院 安徽 合肥 230009)

²(东北大学 辽宁 沈阳 110004)

摘要 针对水果品级监督学习认知方法中样本获取困难、特征空间充分性表征和分类器能力不足的缺陷,模仿人反复推敲比对的信息交互模式,提出一种基于深度学习的青梅品级半监督智能认知方法。基于半监督学习扩充训练样本库,从信息论角度建立多层面特征充分表征的青梅品级认知智能决策信息系统;基于具有充分表征性的自适应架构卷积神经网络和随机配置网络,建立青梅图像由全局到局部多层面充分表征特征空间和具有万局逼近能力的分类准则;基于广义熵理论,建立青梅图像认知结果的语义熵测度评价指标;构建基于不确定认知结果熵测度指标约束的特征空间和样本信度自寻优反馈调节机制。仿真实验表明,该方法青梅品级平均识别率为 98.2%。

关键词 青梅品级 半监督学习 自适应架构卷积神经网络 万局逼近能力 潜在语义熵测度

中图分类号 TP391.4 **文献标识码** A **DOI**:10.3969/j.issn.1000-386x.2018.11.042

SEMI-SUPERVISED INTELLIGENT COGNITION METHOD OF GREENGAGE GRADE BASED ON DEEP LEARNING

Li Weitao^{1,2} Tao Hai¹ Wu Sixi¹ Wang Jianping¹ Xu Xiaobing^{1*}

¹(School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, Anhui, China)

²(Northeastern University, Shenyang 110004, Liaoning, China)

Abstract Aiming at the shortcomings of sample acquisition, feature space adequacy and classifier capability in fruit grade supervised learning cognition methods, a semi-supervised intelligent cognition method for greengage grade based on deep learning was proposed, which imitated the information interaction mode of human repeated deliberation and comparison. Based on semi-supervised learning, a multi-level intelligence system was developed to fully characterize the intelligent decision information system of greengage grade from the perspective of information theory. Based on the self-adaptive architecture convolution neural network and random configuration network with abundant representation, the classification criterion of greengage images from global to local multi-layered was established, which fully characterized the feature space and had universal approximation. Based on generalized entropy theory, semantic entropy measurement evaluation index of greengage images recognition results was established. A self-optimizing feedback regulation mechanism of feature space and sample reliability was constructed based on entropy measurement index constraints of uncertain cognitive results. The simulation results show that the average recognition rate of greengage grade is 98.2%.

Keywords Greengage grade Semi-supervised learning Adaptive structure convolutional neural network Universal approximation Latent semantic entropy measurement

0 引言

随着人们生活水平的提高,消费者对水果的品级极为重视。然而水果的商品化处理水平低成为制约国内水果附加值以及国际市场竞争力的主要因素。实现水果品级的准确自动分级已成为国内水果行业现代化的前提条件。青梅作为一种具有多重保健功能的药食资源,深受广大群众的喜欢。目前基于可见光技术的水果分级方法中,人工筛选模式受经验、劳动强度等主观因素制约,认知效果难以令人满意。与之相对应的基于机器视觉的筛选模式^[1-2]受限于认知方法等客观因素,无法满足准确化、快速化的现实需求。因此,基于可见光的青梅品级智能认知方法研究成为提升青梅产业的迫切要求。

人工品级筛选模式是针对多态对象的不同认知需求,由全局到局部多次比对对检验多层次特征的过程。基于机器视觉的筛选模式可归结为一个具有不确定水果图像输入和不确保水果品级输出的开环监督认知系统。其监督学习下的特征空间和分类准则一旦建立不再更新,且特征空间的充分性不确定,这与人类反复推敲比对的思维信息交互机制存在明显差异。

近年来,由于神经网络训练算法的本质改进,以及学习模型在特征提取或学习表达能力方面的提升^[3-4],以深度学习为代表的人工智能理论与应用研究受到了前所未有的关注^[5-6]。卷积神经网络 CNN 作为一类深层神经网络,随着网络结构的逐渐加深,层层卷积池化提取出从浅到深的语义特征,这与人从全局到局部的认知模式一致。然而,卷积池化全连接导致的特征空间冗余,网络拓扑结构的试凑设定,以及全连接层逼近能力的不足,直接影响学习模型的可达性和可靠性。文献[7]给出了一种认知结果熵测度指标约束的青梅品级智能反馈认知方法,在监督学习的框架下,消除冗余特征图。通过评测不确定认知结果性能,动态调节自适应架构卷积神经网络 ASCNN(adaptive structure convolutional neural networks)和集成随机权向量函数连接网络分类器 RVFL(random vector functional-link net)所构建的特征空间和分类准则,克服网络构架过程中的缺陷。但是,特征空间的充分性表征和 RVFL 分类器万局逼近能力的不足依然未能解决。

在许多实际问题中,往往存在海量的无标签数据和少量的有标签样本。针对有标签样本的监督学习方法会使得无标签数据无用武之地。因此,如何利用海量无标签数据成为一个广泛关注的问题。半监督学习方法能够同时利用两种样本,以增强认知模型的精度和可靠性,广泛应用于医学影像、Web 网页、信用评估以及生物

信息等领域^[8-10]。通常半监督学习可分为生成式方法、协同训练法、基于图的方法和基于差异的方法。其中,协同训练法受模型假设、数据规模和损失函数非凸性的影响较小。然而,半监督学习依然被归结为一个具有不确定输入和不确保输出的开环认知系统。

在已有的研究基础之上,为了克服特征空间充分性表征和集成 RVFL 分类器万局逼近能力的缺乏,以及半监督学习的开环认知模式缺陷,本文基于具有充分表征性的自适应架构卷积神经网络 ARASCNN(adaptive structure convolutional neural networks with abundant representation)、随机配置网络分类器 SCN(stochastic configuration networks)和半监督学习,探索了一种基于深度学习的青梅品级半监督智能认知模型。

1 青梅品级半监督智能认知模型

本文提出了一种基于深度学习的青梅品级半监督智能认知模型,结构如图 1 所示,采用训练层、认知层、反馈层和半监督层四层耦合结构实现信息实时交互。

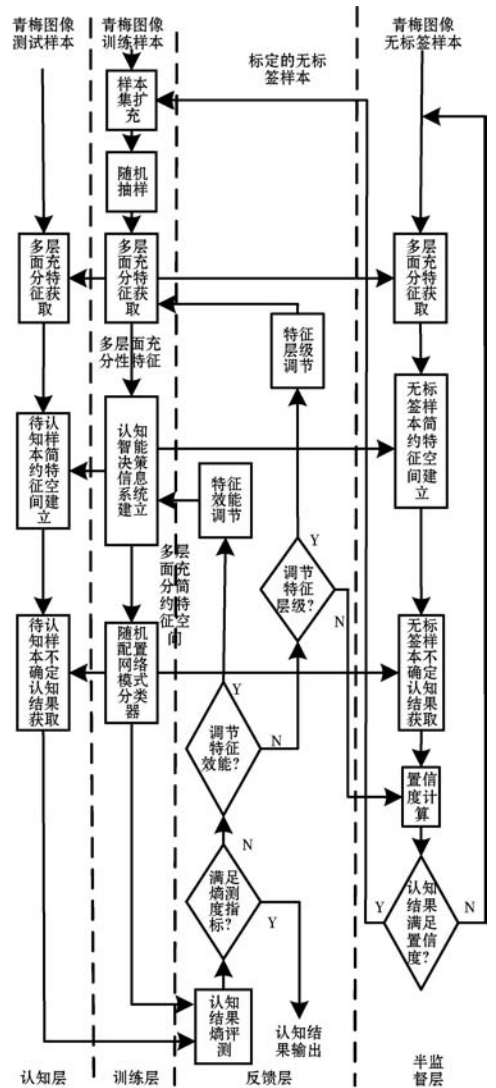


图 1 青梅品级半监督智能认知模型

1) 训练层 初始运行时, bootstrapping 随机抽样有标签训练青梅图像后^[11], 基于极大信息熵性能指标和反馈层下达的特征层级。采用自适应架构卷积神经网络实现抽样训练集的多层面充分特征空间获取。继而基于粗糙集理论和特征效能模块下达的认知精度, 建立抽样训练集具有充分表征性的认知智能决策信息系统。将多层面充分简约特征空间送入随机配置网络分类器获取认知结果, 为认知层和半监督层提供多层面充分简约特征空间和分类认知的构建准则。测试青梅图像实现当前准则下的认知后, 将半监督层在当前准则下标定的无标签样本送入训练层, 扩充训练样本集, 更新构建准则。

2) 认知层 认知层基于训练层提供的多层面充分简约特征空间和分类认知准则, 获取特定特征层级和特征效能条件下测试青梅图像的不确定品级认知结果。为反馈层认知结果的潜在语义熵测度评测提供启发式反馈信息。

3) 反馈层 反馈层基于测试样本认知结果的认知误差潜在语义熵测度指标, 评测测试青梅图像不确定品级认知结果的可信度。自寻优调节外层表征样本信度的置信度、中间层表征特征层级的网络层数和内层表征特征效能的认知精度。

4) 半监督层 半监督层包括多层面充分特征空间获取模块、具有充分表征性的认知智能决策信息系统模块、无标签样本认知结果获取模块、置信度计算模块和无标签样本认知结果判别模块。训练层下达多层面简约特征空间和分类认知构建准则后, 在特定特征等级和特征效能条件下, 面向无标签样本的集成认知结果。基于反馈层设定的置信度, 将满足条件的无标签样本送至训练层, 扩充训练样本集, 不满足置信度的样本则等待更新的多层面充分特征空间和分类认知准则, 进行下一次反馈认知。

2 青梅品级半监督智能认知算法

2.1 充分表征性的自适应架构卷积神经网络

2.1.1 卷积神经网络

如图 2 所示, CNN 采用卷积和池化交叉的多层网络架构, 获取输入的特征表征。相邻卷积层和池化层特征图个数相同, 这里将其视为一个层级组合。设训

练青梅图像扩充样本集 $U = \Theta \cup L$, Θ 和 L 分别是有标签训练样本集和半监督层输出的标定无标签样本集, n 和 ω 分别为 Θ 和 L 的样本个数。 U 随机抽样后的训练样本集为 $\tilde{U} = \tilde{\Theta} \cup \tilde{L}$, $\tilde{\Theta}$ 和 \tilde{L} 分别是 Θ 和 L 的抽样集合, \tilde{n} 和 $\tilde{\omega}$ 分别为 $\tilde{\Theta}$ 和 \tilde{L} 的样本个数。 $U_i \in \tilde{U}$, $i \in [1, \tilde{n} + \tilde{\omega}]$ 经过 l 个交替的卷积池化操作后, 获得 g_l 个尺寸为 $\Delta_{p_l} \times \nabla_{p_l}$ 的特征图。全连接层采用 1×1 的卷积核对 g_l 个特征图进行卷积运算, 提取 U_i 的 γ 维特征向量 $C_i^l = \{C_{i,1}^l, C_{i,2}^l, \dots, C_{i,\gamma}^l\}$, 其中, $\gamma = \Delta_{p_l} \times \nabla_{p_l} \times g_l$ 。




图 2 卷积神经网络认知模型

2.1.2 基于极大信息熵的青梅图像充分性表征

在特定的特征层级内进行卷积运算时, 一个卷积核可以实现输入到一个输出特征图的映射。通常, 增加卷积核可以从不同的视角表征图像。然而, 在有限论域条件下, 特征维度的增加使得系统信息量趋于饱和且增大计算复杂度, 因而, 需要平衡特征空间规模与计算量。

设网络层级为 $l-1$ 时的特征图为 $X^{l-1} = [X_1^{l-1}, X_2^{l-1}, \dots, X_{g_{l-1}}^{l-1}]$, 其中 $X_i^{l-1} = [X_{i,1}^{l-1}, X_{i,2}^{l-1}, \dots, X_{i,\tilde{n}+\tilde{\omega}}^{l-1}]^T$ 。 $i \in [1, g_{l-1}]$ 表示第 i 个卷积核的 \tilde{U} 样本的特征图, 则有限论域条件下, 网络层级为 l 时具有充分信息量的最小特征图空间 $X^l = [X_1^l, X_2^l, \dots, X_{g_l}^l]^T$ 可定义为:

$$\max_{g_l} H(B(X^l)) = \max_{g_l} \left(- \sum_{q=1}^{\delta_l} \frac{|\phi_q|}{|X^{l-1}|} \log_2 \frac{|\phi_q|}{|X^{l-1}|} \right) \quad (1)$$

s. t. $0 < \delta_l \leq g_l$

式中, $H(B(X^l))$ 为 X^l 的信息熵, $B(X^l) = \{\phi_1, \phi_2, \dots, \phi_{\delta_l}\}$ 为 X^l 基于等价关系划分而成的商集^[12]。由式(1)可获取极大信息熵条件下 \tilde{U} 的多层面充分特征空间。

2.1.3 基于马氏可分性度量和前向选取技术的特征图空间选取

卷积神经网络构建的特征空间性能与特征图的表征能力密切相关。特征图个数越大, 相邻特征图的信息越相似。传统卷积池化全连接的架构必然会导致特征空间冗余。因此, 特征图的选取应是深度学习中心必

不可少的一部分。马氏可分性度量函数可以评估每个特征图对多类青梅图像的可区分能力。设网络层级为 l 时 \tilde{U} 的多层面充分特征空间为 X^l , 则特征图 $X_i^l = [X_{i,1}^l, X_{i,2}^l, \dots, X_{i, \tilde{n} + \tilde{m}}^l]^T, i \in [1, g_l]$ 的马氏可分性度量函数 D_i^l 定义为:

$$D_i^l = 2 \times \frac{\sum_{a=1}^{n_c-1} \sum_{b=a+1}^{n_c-1} (m_{a,i} - m_{b,i}) C_{a,b,i}^{-1} (m_{a,i} - m_{b,i})^T}{n_c \times (n_c - 1)} \quad (2)$$

式中: $m_{a,i}$ 、 $m_{b,i}$ 和 $C_{a,b,i}$ 分别表示特征图 X_i^l 中第 a 和 b 类青梅图像特征图的均值和协方差矩阵; n_c 代表青梅图像类别。将该度量函数与前向选取技术相结合以自动评估排序全体特征图^[13]。具体步骤如下:

1) 对于每个 X_i^l , 基于式(2)计算 D_i^l 。假设 $D_{h_1}^l \geq D_{h_2}^l \geq \dots \geq D_{h_g}^l, h_1, h_2, \dots, h_g \in [1, g_l]$, 与 $D_{h_1}^l$ 所对应的特征图 $X_{e_1}^l$ 作为第一个候选特征图子集, 表示为 $f_1 = \{X_{e_1}^l\}$ 。

2) 剩余的每个特征图均与 f_1 组合得到 $g_l - 1$ 个候选子集 $f_2 = \{X_{e_1}^l, X_j^l\} (j \in [1, g_l], j \neq e_1)$ 。基于式(2)计算得到的最大的马氏可分性度量值所对应的子集 $\{X_{e_1}^l, X_{e_2}^l\} (e_2 \in [1, g_l], e_2 \neq e_1)$ 作为第二个候选特征图子集, 表示为 $f_2 = \{X_{e_1}^l, X_{e_2}^l\}$ 。

3) 重复上述过程直至获取网络层级为 l 下的 g_l 个候选特征图子集:

$$\{X_{e_1}^l\}, \{X_{e_1}^l, X_{e_2}^l\}, \dots, \{X_{e_1}^l, X_{e_2}^l, \dots, X_{e_g}^l\} \quad (3)$$

2.2 青梅品级认知决策信息系统

特征图空间选取后, 特征图内部仍可能存在冗余信息, 因而需要对其约简以避免“维数灾”现象。信息论中的粗糙集理论可以仿人自由调节认知精度约简信息的过程^[14]。引入构建特定特征层级、特征效能和置信度条件下的随机抽样扩充训练青梅图像认知智能决策信息系统 $S_{\beta,r}^l = (\tilde{U}, \mathbf{Z}, \mathbf{V}, \mathbf{f})$, 获取随机抽样扩充训练青梅图像的多层面充分简约特征空间, 其中 l 、 β 和 r 分别表示网络层级、认知精度和无标签样本认知结果的置信度; $\mathbf{Z} = \tilde{X}_r^l \cup \mathbf{F}$ 是特征集, 其中 $\tilde{X}_r^l = \{X_{e_1,r}^l, X_{e_2,r}^l, \dots, X_{e_x,r}^l\}, e_x \leq e_g$ 表示基于式(3)的置信度为 r 下的 \tilde{U} 某个候选特征图子集, \mathbf{F} 表示决策属性向量; \mathbf{V} 是 \tilde{X}_r^l 的值域; \mathbf{f} 是 \tilde{U} 与 \mathbf{Z} 之间的映射集。给定 β 后, \tilde{X}_r^l 可由 $S_{\beta,r}^l$ 约简为 $\tilde{X}_{\beta,r}^l = \{X_{e_1,\beta,r}^l, X_{e_2,\beta,r}^l, \dots, X_{e_x,\beta,r}^l\}$ 。

由于冗余信息的存在, $\tilde{X}_{\beta,r}^l$ 中特征图的尺寸小于等于 \tilde{X}_r^l 中特征图的尺寸。模式分类器输出的残差需

反向传播至 ARASCNN, 以更新卷积层和池化层的权值和偏置。因此, 需解决约简前后特征图尺寸不匹配的问题。对每个约简特征图 $\{X_{e_1,\beta,r}^l, X_{e_2,\beta,r}^l, \dots, X_{e_x,\beta,r}^l\}$ 中的信息约简处补零, 重构至与 \tilde{X}_r^l 中特征图一致的尺寸, 送至模式分类器以计算输出类别的残差。

2.3 随机配置网络分类器的设计

机器学习模型的基本要求是它的学习能力, 即通过样本学习实现表达复杂信号的能力。Pao 等提出了用随机算法训练多层感知机模型以来, 随机参数的设置方法都是首先选定一个固定闭区间, 等概率分配输入层到隐层之间的权矩阵, 然后用最小二乘法或正则模型算出输出权向量。然而, 由于随机参数没有任何约束条件, RVFL 模型并不能保证有万局逼近性。SCN 通过自适应设置参数范围, 约束输入权值和偏移, 确保学习模型的万局逼近能力。SCN 可以等效为一个单隐层前馈神经网络:

$$\varphi(\tilde{X}_{\beta,r}^l, \boldsymbol{\vartheta}) = \sum_{j=1}^{n_b} \vartheta_j h_j(w_j \cdot \tilde{X}_{\beta,r}^l + b_j) \quad (4)$$

式中: $\boldsymbol{\vartheta} = [\vartheta_1, \vartheta_2, \dots, \vartheta_{n_b}]$ 是输出层权值向量; $\tilde{X}_{\beta,r}^l$ 是输入特征向量; w_j 和 b_j 是输入层权值和隐含层偏移, 其中 $w_j, b_j \in [-\lambda, \lambda]$; $h_j(\cdot)$ 是基函数; n_b 是基函数的个数。

为了确保 SCN 的万局逼近能力, 基于下面的约束条件对第 j 个基函数 w_j 和 b_j 进行取值:

$$\zeta_j = \frac{(e_{j-1}^T(\mathbf{U}_i) \cdot A_j(\mathbf{U}_i))^2}{A_j^T(\mathbf{U}_i) \cdot A_j(\mathbf{U}_i)} - (1 - v - \mu_j) e_{j-1}^T(\mathbf{U}_i) e_{j-1}(\mathbf{U}_i) > 0 \quad (5)$$

式中: $A_j = h_j(w_j \cdot \tilde{X}_{\beta,r}^l + b_j)$ 表示隐含层输出矩阵; $e_{j-1}(\mathbf{U}_i)$ 为 $j-1$ 个基函数的输出误差。由式(5)可以获得 $\boldsymbol{\vartheta}$ 的一个分析解:

$$\hat{\boldsymbol{\vartheta}} = \mathbf{A}^\dagger \mathbf{O} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{O} \quad (6)$$

式中: $\mathbf{A} = [A_1, \dots, A_j]$; \mathbf{A}^\dagger 表示 \mathbf{A} 的 Moore-Penrose 广义逆; \mathbf{O} 为训练样本的输出矩阵。具体内容请参见文献[15]。

SCN 的输出误差需要反向传播, 以优化 ARASCNN 和 SCN 的参数。由于协同训练集成分类器的需求, 这里采用投票机制获取 G 个 SCN 子网络的最终输出结果。设 \mathbf{Q} 表示输入样本集的真实类别, 则认知结果的输出误差 $e = \sqrt{(\mathbf{P} - \mathbf{Q})^T (\mathbf{P} - \mathbf{Q})}$, \mathbf{P} 表示集成分类器对于输入样本集的输出类别。对于每个子 SCN 来说, 其输出误差 $e_k (k=1, 2, \dots, G)$ 反向传播至输入端的误差 ex_k 为:

$$ex_k = w((\hat{\vartheta}_{e_k}^\dagger)^\dagger((\hat{\vartheta}_{e_k}^\dagger)^\dagger(1 - (\hat{\vartheta}_{e_k}^\dagger)^\dagger))) \quad (7)$$

令式(7)中 $(\hat{\partial}e_k^\dagger)^\dagger = \kappa$,将 e_k 反向传播至隐含层的输出端, $\kappa(1-\kappa)$ 基于 sigmoid 函数的逆将 κ 反向传播至隐含层的输入端,继而实现隐含层输入端反向传播至 SCN 的输入端 ex_k 。将 G 个子 SCN 输入端的误差 $\tilde{e} = \sum_{k=1}^G ex_k/G$ 转换为充分约简特征图的残差,反向传播以更新 ARASCNN 中各层级的参数。

2.4 青梅品级认知误差熵测度表征

青梅品级的认知结果具有不确定性,需要对其进行度量,为反馈层和半监督层的特征层级、特征效能和样本标定比自适应优化调节提供启发式信息。熵是量测系统不确定性的工具,因而被引入构建青梅品级认知误差语义信息系统,以建立认知结果评价的概率知识模型。

设第 w 次反馈认知过程中,基于特征层级 l_w 、特征效能 β_w 和样本标定比 r_w , $\mathbf{Y} = \{Y_1, Y_2, \dots, Y_d\}$ 中第 t 个测试青梅图像 Y_t , $t \in [1, d]$ 的青梅品级认知结果为 $P_t^{l_w, \beta_w, r_w}$,则基于文献[16]可定义 Y_t 的青梅品级认知误差语义信息系统为:

$$\Pi_t(w, l_w, \beta_w, r_w) = (\Gamma_{t,u}, \mathbf{M}_t^u(w, l_w, \beta_w, r_w)) \quad u \in [1, n_c] \quad (8)$$

式中: $\Gamma_{t,u}$ 是 Y_t 和相同认知类别随机抽样扩充训练样本的 n_u 维认知误差语义论域; \mathbf{M}_t^u 是 Y_t 的 z_u 维认知误差语义矩阵。基于等价关系可将 $\Gamma_{t,u}$ 划分,得到商集 $\Gamma_{t,u}/\mathbf{M}_t^u = \{E_1, E_2, \dots, E_s\}$,商集中元素越多,则 Y_t 在当前认知过程中的误差越大,反之亦然。 Y_t 在第 w 次反馈认知过程中的青梅品级认知误差潜在语义熵可定义为:

$$H_t(w, l_w, \beta_w, r_w) = - \frac{\sum_{\sigma=1}^s \frac{|E_\sigma|}{|\Gamma_{t,u}|} \log_2 \frac{|E_\sigma|}{|\Gamma_{t,u}|}}{\log_2 n_u} \quad (9)$$

由式(9)可知, H_t 越小, Π_t 的不确定性越小, Y_t 的认知误差亦较小,反之亦然。最优认知的目标就是在可行域内任意调节 l_w 、 β_w 和 r_w 使得 H_t 极小。这样,多层面充分简约特征空间建模的信息论与不确定青梅品级认知结果评测的认知论之间构建了等价的潜在语义熵形式测度关系。

2.5 基于协同训练的半监督学习

半监督学习可以利用海量无标签数据,辅助有标签数据的学习。文献[9]给出了一种基于协同训练的半监督学习框架,通过置信度标定无标签样本扩充训练样本集,提升认知模型的精度和泛化能力。其步骤如下:

1) 设训练青梅图像扩充样本集 $\mathbf{U} = \Theta \cup \mathbf{L}$,初始时 $\mathbf{L} = \emptyset$;

2) 采用 bootstrapping 对 \mathbf{U} 随机抽样 G 次,获得 G

个青梅图像扩充训练样本集 $\tilde{\Xi} = \{\tilde{U}_1, \tilde{U}_2, \dots, \tilde{U}_G\}$ 。

3) 基于 ARASCNN 建立 $\tilde{U}_i \in \tilde{\Xi} (1 \leq i \leq G)$ 的多层面充分特征空间数据结构,继而基于粗糙集理论获取 \tilde{U}_i 的具有充分表征性的认知智能决策信息系统。

4) 对 G 个多层面充分简约特征空间分别训练 SCN 分类器模型。

5) 将全体无标签样本 $\mathbf{R} = \{R_1, R_2, \dots, R_v\}$ 中 G 个子 SCN 分类器预测类别一致的样本送入候选集 Λ 中,基于式(10)计算 Λ 中的每一个样本的置信度;

$$C_{om} = I/J \quad (10)$$

式中: J 表示 Λ 中某个样本在 Θ 空间中的近邻个数; I 表示 J 个近邻中其类别与该投射样本类别一致的样本个数。

6) 将 Λ 中满足置信度的标定无标签样本送入 \mathbf{L} 中,更新 \mathbf{U} ,不满足的样本送回无标签样本库等待下一次反馈认知。

2.6 基于认知误差的认知特征调节准则

青梅品级认知误差潜在语义熵量化了特定 l_w 、 β_w 和 r_w 条件下的认知结果性能。因此,基于 H_t 构造特征层级、认知精度和样本容量的增量计算模型,在熵测度指标约束下自适应调节 l_w 、 β_w 和 r_w ,以反复推敲比对智能认知青梅品级。

对于内层的特征效能调节, β_w 的非均匀变换更为符合人类认知时从全局到局部的感官特性,即随着 w 的增加, $\Delta\beta_w$ 递减,特征空间的粒度由粗糙到精细。设第 w 次反馈认知过程中, Y_t 的认知误差潜在语义熵为 H_t ,则第 $w+1$ 次反馈认知过程的认知精度 β_{w+1} 可定义为:

$$\begin{cases} \beta_{w+1} \leftarrow \beta_w + \Delta\beta_{w+1} = \beta_w + \frac{\alpha l_w}{w(2^\alpha - 1)} \times \min_{t \in [1, d]} [H_t] \\ \beta_1 \leftarrow 0.5 \quad \beta_w \in (0.5, 1] \end{cases} \quad (11)$$

式中, α 为实数且 $\alpha \neq 1$ 。

对于中间层的特征层级调节, l_w 越大可以抽取更多层面的图像特征,但计算量也将大大增加,因此,需要平衡特征空间的规模与计算量。设第 w 次反馈认知过程中,若基于式(11)反复调节的 β_w 始终无法满足认知误差潜在语义熵性能指标要求,则令第 $w+1$ 次反馈认知过程的认知精度 $\beta_{w+1} = 0.5$,特征层级 l_{w+1} 定义如下,挖掘更深层次的认知特征以重新表征青梅图像:

$$l_{w+1} \leftarrow l_w + 1 \quad l_1 \leftarrow 1 \quad l_{\max} = 5 \quad (12)$$

对于外层的无标签样本置信度调节, r_w 越小可以为随机抽样扩充训练样本库提供更多的无标签标定样本,但 r_w 太小会造成置信度不高的样本进入训练样本库。设第 w 次反馈认知过程中,若基于式(11) - 式(12)反复调节的 β_w 和 l_w 始终无法满足认知误差潜在语义熵性

能指标要求,则令第 $w+1$ 次反馈认知过程的特征层级 $l_{w+1}=1$, 认知精度 $\beta_{w+1}=0.5$, 无标签样本置信度定义为:

$$\begin{cases} r_{w+1} \leftarrow r_w - \frac{r_w - (2)^{-w}}{w(2^\alpha - 1)} \times \min_{t \in [1, d]} [H_t] \\ r_1 \leftarrow 0.98 \quad r_w \in [0.8, 0.98] \end{cases} \quad (13)$$

2.7 具有认知结果潜在语义熵测度指标约束的青梅品级半监督智能认知算法

青梅品级半监督智能认知算法流程如图 3 所示。

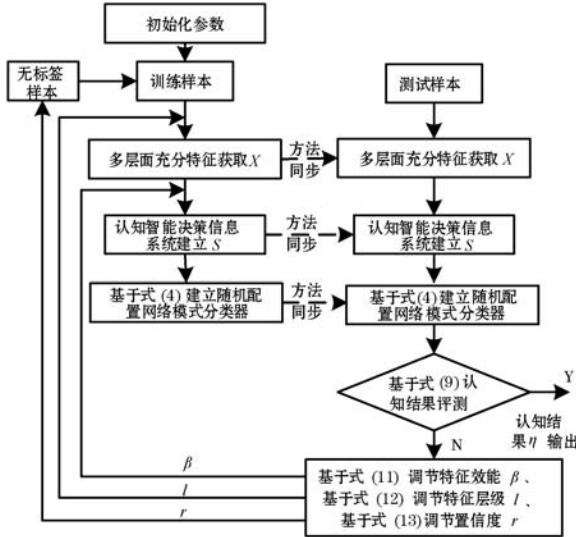


图 3 算法流程图

基于图 3 算法流程图的软件实现如下:

Input: Θ, Y, R , 期望误差 ε , 基函数最大值 n_b^{\max} , w 和 b 的范围 λ

1. Begin;
2. 初始化参数 $l \leftarrow 1, \beta \leftarrow 0.5, r \leftarrow 0.98, w = 1$;
3. 提取 \tilde{U} 的多层面充分特征 X ;
4. 建立 $S = (\tilde{U}, X \cup F)$;
5. 构建 SCN 分类器;
6. While $r_w \geq 0.8$
7. While $l_w \leq 5$
8. While $\beta_w \leq 1$
9. While $n_b \leq n_b^{\max}$
10. If $\min(\zeta_j) > 0$
11. Save w, b and λ ;
12. End If
13. End While;
14. 基于式(4)和式(9)获取 Y_t 的 $P_t^{l_w, \beta_w, r_w}$ 和 H_t ;
15. If $H_t \leq \varepsilon$, Then
16. $\eta_{opt} \leftarrow P_t^{l_w, \beta_w, r_w}$;
17. Else $w \leftarrow w + 1$, 基于式(11)调节 β_{w+1} ;
18. End If;
19. End While;
20. $w \leftarrow w + 1, \beta_{w+1} \leftarrow 0.5$, 基于式(12)调节 l_{w+1} ;

20. End While

21. $w \leftarrow w + 1, l_{w+1} \leftarrow 1, \beta_{w+1} \leftarrow 0.5$, 基于式(13)调节 r_{w+1} ;

22. End While

23. 根据以上步骤获得的参数从而获取测试样本的最优认知结果 η_{opt} ;

24. End

Output: 认知结果 η_{opt} ;

其中, SCN 的核心代码为:

1. While $n < n_b^{\max}$ and $\|e\| > \varepsilon$
2. For $k = 1, 2, \dots, 50, Do$
3. Randomly assign w , band λ from $[-\lambda, \lambda]$;
4. Calculate h_j and ζ_j ;
5. If $\min(\zeta_j) > 0$
6. Save w , band λ ;
7. Else go back to step 2;
8. End If
9. End For
10. Calculate φ base on (4);
11. End While

3 仿真实验

3.1 数据采集

本文选取 1 800 个青梅样本, 使用一台彩色 CMOS 照相机(Canon EOS 700D)设备在前后左右上下 6 个方向拍摄多幅图像, 以模拟青梅在传送带上的运动姿态(共计 $1\ 800 \times 6 = 10\ 800$ 幅图像)。将青梅图像的大小分别变换为 28×28 、 64×64 、 100×100 , 分辨率为 300 dpi。将 10 800 幅青梅图像分为 6 800 幅无标签图像和 4 000 幅有标签图像, 所有样本的标定由多位分拣专家投票给出, 其中 4 000 幅有标签图像包括优品青梅 1 260 幅, 次品 1 580 幅, 腐烂品 1 160 幅。采取随机抽样的方法选取 4 000 幅有标签图像中的 2 400 幅作为训练样本集, 剩余 1 600 幅图像作为测试样本集, 部分大小为 28×28 , 分辨率为 300 dpi 样本如图 4 所示。所有实验均在 Intel Core i5 CPU 2.50 GHz, 8 GB 内存, MATLAB R2017a 环境下运行。




图 4 部分青梅样本(28×28 , 300 dpi)

3.2 结果与分析

实验中 l 、 β 和 r 的范围分别定义为 $[1, 5]$ 、 $(0.5, 1]$ 和 $[0.8, 0.98]$ 。集成 SCN 中基网络个数 G 、基函数最大值 n_b^{\max} 以及 w 和 b 的范围 λ 分别定义为 $[2, 10]$ 、 $[5, 95]$ (步长为 5)、 $[1, 15, 30, 45, 60]$ 。此外,基于文献[9]的建议 $J = 50$ 。下面以 28×28 的图像大小,分辨率为 300 dpi 为例,给出本文算法的参数选取过程。

不同模式分类器的参数对青梅品级认知结果有较大影响。图 5 给出了某次实验中,当 $l = 3$ 、 $\beta = 0.83$ 、 $r = 0.85$ 时,测试样本集的认识率 RA 关于不同基网络个数 G 、基函数个数 n_b 以及权值和偏移范围 λ 的变化曲线。可以看出过多的基网络不能有效提高识别率反而增加计算量,3 个基网络足以构建可靠的集成模型。每个基网络建模局部特征空间,过多的基函数会过拟合输入特征空间和输出类别之间的非线性映射,并且在相同基网络和基函数个数条件下,SCN 的分类性能优于 RVFL。当 λ 较小时, w 和 b 参数可选择的范围比较小,而 λ 太大,提供的搜索范围过大,会产生过拟合的现象。




图 5 测试样本的识别精度 vs 不同的基网络个数 G 、不同的基函数个数 n_b 和不同的 w 和 b 的范围 λ

图 6 给出了在某次试验中,基于图 5 选取最优 $\{G = 3, \lambda = 35, n_b = 65\}$ 组合后,测试样本集的认识率 RA 关于认知精度 β 、网络层级 l 和置信度 r 的变化曲线。可以看出,通过调节 β ,可以控制有限论域条件下不同精度特征对样本的适用程度。当内层 β 最优时,认知性能随着 l 的增大呈现先递增后略微下降的趋势。这是由于特征空间加入大量冗余信息而导致错误分类和计算复杂度的剧增。当中间层 l 和内层 β 最优时,随着置信度 r 的下降,认知性能呈现先增后下降的趋势。这是由于较大的外层 r 值标定的无标签样本置信度较高,而较小 r 值可能会引入错误标定的无标签样本,从而影响认知性能。




图 6 测试样本的识别精度 vs 不同的认知精度 β 、网络层数 l 和置信度 r

为了验证所提出算法的有效性,基于图像大小为 28×28 ,分辨率为 300 dpi,无噪声的条件下,比较了本文算法与其他监督学习算法的识别结果,包括 Gabor 小波结合色彩矩的特征提取 + 支持向量机分类器 SVM^[17]、完全色彩局部二值模式 CCLBP (color completed local binary pattern) 的特征提取 + 最近邻分类器 KNN (k nearest neighbor)、CNN 的特征提取 + 全连接层分类器等开环认知模型,以及 ASCNN 的特征提取 + 集成 RVFL 分类器和 ARASCNN 的特征提取 + 集成 RVFL 分类器^[7] 的闭环监督学习模型。上述方法的在平均识别率和平均测试时间如表 1 所示。此外,不同图像大小和分辨率,以及图像中加入不同噪声的本文算法识别结果如表 2 所示。所有数据均采用均值 \pm 标准差的形式。

表 1 青梅品级不同识别方法性能的比较 (28 × 28, 300 dpi)

方法	平均识别率/%	平均测试时间/s
本文方法	98.32 ± 0.6	2.3 ± 0.7
Gabor 小波 + 色彩矩 + SVM	89.75 ± 0.9	1.8 ± 0.7
CCLBP + HSV + KNN	91.67 ± 1.2	2.4 ± 1.1
CNN + 全连接层	93.45 ± 0.6	1.8 ± 0.5
ASCNN + 集成 RVFL	96.15 ± 0.6	2.1 ± 0.6
ARASCNN + 集成 RVFL	97.25 ± 0.7	2.2 ± 0.9

表 2 不同图像大小、分辨率、噪声平均识别率

条件	平均识别率/%	平均测试时间/s
28 × 28 (300 dpi)	98.32 ± 0.6	2.3 ± 0.7
64 × 64 (300 dpi)	98.03 ± 0.9	4.5 ± 0.8
100 × 100 (300 dpi)	97.52 ± 1.2	8.6 ± 1.2
96 dpi (28 × 28)	93.45 ± 0.6	2.2 ± 0.7
120 dpi (28 × 28)	96.15 ± 0.6	2.3 ± 0.6
300 dpi (28 × 28)	98.32 ± 0.6	2.3 ± 0.7
高斯噪声 (300 dpi, 28 × 28)	96.33 ± 0.8	2.5 ± 0.7
泊松噪声 (300 dpi, 28 × 28)	95.88 ± 0.9	2.4 ± 0.9

由表1和表2可以看出,在图像大小为 28×28 ,分辨率为300 dpi,无噪声的条件下,本文的青梅品级半监督智能认知算法较其他监督学习算法性能更优,平均识别率达到 $98.32\% \pm 0.6\%$ 。半监督学习机制的引入,充分利用大量的无标签样本扩充训练样本库,较监督学习中的固定训练样本集增强了认知模型的鲁棒性。ARASCNN和认知智能决策信息系统模拟人脑认知过程,在信息量充分的条件下,从不同认知视角构建青梅图像由全局到局部多层面充分特征空间,选取区分能力强的特征图消除其内部冗余信息,建立多层面充分简约特征空间。较开环认知模型和已有闭环监督学习模型中的特征空间表征能力更强。具有万局逼近能力的SCN较其他模式分类器的泛化能力更优。此外,图像大小在 28×28 时取得最优,图像太大,会大大增加训练和测试的时间,分辨率高的图像识别精度更高,且加入噪声会影响识别的精度。

4 结 语

为了克服特征空间充分性表征和集成RVFL分类器万局逼近能力的缺乏,以及半监督学习开环认知模式的缺陷,本文基于ARASCNN、SCN和半监督学习探索了一种具有认知结果熵测度指标约束的青梅品级半监督智能认知算法。

1) 本文提出的基于深度学习青梅品级的半监督智能认知方法解决了监督学习过程中难以获得大量有标签样本的问题,并保证了特征空间的充分性,增强了学习模型的万局逼近能力。

2) 基于潜在语义熵测度指标约束的特征效能、特征层级与样本信度自寻优调节机制有效模拟了人类反复推敲比对的认知机理。

3) 本文提出的基于深度学习的半监督智能认知方法能够有效地对青梅品级进行划分,具有较高的实用价值。该方法在其他农业产品中的应用将是下一步的工作重点。

4) 水果品级技术能够保证水果的质量,提高消费者的满意度,增强水果产业的竞争力和利润水平。水果品级技术的成功将有利于改变国产水果和农产品的外观质量较差、同一批产品中良莠不齐、混等混级等现状。若以我国苹果产量的50%(约3 000万吨)通过自动分级处理为例,每公斤大概增值0.2元,那么总量能够增值6亿元。这对提高我国水果的品质,增强参与国际竞争的能力,并大大降低工人的劳动强度,具有重要的理论意义和实际意义。

参 考 文 献

- [1] 公丽艳,孟宪军,刘乃侨,等. 基于主成分与聚类分析的苹果加工品级评价[J]. 农业工程学报, 2014, 30(13): 276-285.
- [2] 钱建平,杨信廷,吴晓明,等. 自然场景下基于混合颜色空间的成熟期苹果识别方法[J]. 农业工程学报, 2012, 28(17):137-142.
- [3] Hinton G, Osindero S, The Y. A fast learning algorithm for deep belief nets [J]. *NeuralComputation*, 2006, 18(7): 1527-1554.
- [4] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016:770-778.
- [5] Goodfellow I, Bengio Y, Courville A. Deep learning [M]. Cambridge: MIT Press, 2016.
- [6] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. *Nature*, 2015, 521(7553):436-444.
- [7] 李帷韬,曹仲达,朱程辉,等. 基于深度集成学习的青梅品级智能反馈认知方法[J]. 农业工程学报, 2017, 33(23):276-283.
- [8] 周志华. 基于分歧的半监督学习[J]. 自动化学报, 2013, 39(11):1871-1878.
- [9] 肖进,薛书田,黄静,等. 客户信用评估半监督协同训练模型研究[J]. 中国管理科学, 2016, 24(6):124-131.
- [10] Hang W, Choi K S, Wang S, et al. Semi-supervised learning using hidden feature augmentation [J]. *Applied Soft Computing*, 2017, 59:448-461.
- [11] Chemick M. Bootstrap methods: A practitioner's guide [M]. New York: Wiley, 1999.
- [12] 陈克琼,王建平,李帷韬,等. 基于变粒度仿反馈机制的回转窑烧成状态智能认知方法[J]. 模式识别与人工智能, 2015, 28(11):1013-1022.
- [13] Li W T, Wang D H, Chai T Y. Flame image-based burning state recognition for sintering process of rotary kiln using heterogeneous features and fuzzy integral [J]. *IEEE Transactions on Industrial Informatics*, 2012, 8(4):780-790.
- [14] Pattaraintakorn P, Cercone N. Integrating rough set theory and medical applications [J]. *Applied Mathematics Letters*, 2008, 21(4):400-403.
- [15] Wang D, Li M. Stochastic configuration networks: fundamentals and algorithms [J]. *IEEE Transactions on Cybernetics*, 2017, 47(10):3466-3479.
- [16] Chen K, Wang J, Li W, et al. Simulated feedback mechanism-based rotary kiln burning state cognition intelligence method [J]. *IEEE Access*, 2017, 5:4458-4469.
- [17] 张建华,祁力钧,冀荣华,等. 基于Gabor小波和颜色矩的棉花盲椿象分类方法[J]. 农业工程学报, 2012, 28(1): 133-138.