

DOI:10.19651/j.cnki.emt.2107958

基于类别空间约束的弱监督卷积神经网络特征学习算法^{*}

高 博

(天津职业大学电子信息工程学院 天津 300410)

摘要: 传统卷积神经网络虽然具有较好的应用准确度,但是其的主要缺陷是效率低,为解决这一问题,弱监督算法被提出,现有的弱监督学习算法标记训练样本较少,效率较理想,但是仍然存在误分类率较高等不足。为了同时满足高效率和高精度的要求,本研究结合了弱监督算法和卷积神经网络,提出一种基于类别空间约束的弱监督卷积神经网络特征学习算法。首先,建立弱监督卷积神经网络特征学习算法的网络模型;其次,通过对空间加以约束,使标记样本和未标记样本建立一定的联系,从而实现特征空间聚类;最后,利用模型训练样本数据,实现基于类别空间约束的弱监督卷积神经网络特征学习算法的设计。实验结果表明,所提方法误分类率达到5%,分类耗时不超过0.4 ms,能够更好地开展特征学习。

关键词: 类别空间约束;弱监督;卷积神经网络;特征学习算法

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.20

Weak supervised convolutional neural network feature learning algorithm based on class space constraint

Gao Bo

(School of Electronic Information Engineering, Tianjin Vocational University, Tianjin 300410, China)

Abstract: Although the traditional convolutional neural network has good application accuracy, its main defect is low efficiency. In order to solve this problem, the weak supervised learning algorithm is proposed. The existing weak supervised learning algorithm has less labeled training samples and ideal efficiency, but there is still a lack of high misclassification rate. In order to meet the requirements of high efficiency and high precision at the same time, this study combines weak supervision algorithm and convolutional neural network, a weak supervised convolutional neural network feature learning algorithm based on class space constraints is proposed. Firstly, the network model of the feature learning algorithm of weakly supervised convolutional neural network was established. Secondly, by constraining the space, the labeled samples and unlabeled samples were connected to realize the feature space clustering. Finally, the training sample data was used to realize the design of weak supervised convolutional neural network feature learning algorithm based on class space constraint. The results show that the proposed method has a misclassification rate of 5% and a classification time is no more than 0.4 ms, which can better carry out feature learning.

Keywords: class space constraint; weak supervision; convolution neural network; feature learning algorithm

0 引 言

随着信息化的快速发展,机器学习的数据规模越来越大,学习维度也越来越高,这些都给机器学习带来一定的挑战。特征学习算法的目的是利用一定的策略从在机器学习

的数据中选择出原始特征集的最优子集^[1]。现有的特征学习算法分为两种,分别为基于神经网络的算法和传统学习算法^[2]。卷积神经网络因具有诸多优点且结构更为紧凑,被广泛应用于各个领域^[3]。在卷积神经网络特征学习算法中,当标记样本数据量少甚至没有的情形下,准确快速地

收稿日期:2021-09-26

^{*} 基金项目:全国高等院校计算机基础教育研究会计算机基础教育教学研究项目(2019-AFCEC-073)资助

对数据作处理具有一定的难度^[4]。因此,为解决这一问题,弱监督算法被提出,常见的弱监督算法分为不确切监督、不准确监督和不完全监督^[5]。然而,现有的弱监督学习算法研究中,由于标记训练样本较少,仍然存在误分类率较高等不足,需要对其作进一步研究。

文献[6]提出结合迁移学习模型的卷积神经网络算法研究,根据卷积神经网络特性,对源域与目标数据集进行降维,实现相似数据特征分布获取,获取部分标注目标数据集,利用初始化的隐藏层补全 trCNN 模型对其训练,实现卷积神经网络算法的设计,但该方法计算过程较为复杂。文献[7]提出高斯核函数卷积神经网络跟踪算法,通过聚类并提取初始帧目标滤波,获取目标背景信息与前景信息数据特征,并将其叠加后的卷积结果进行进行深层次表达,利用高斯核函数提升算法卷积计算效率,对目标数据信息进行更新,实现卷积神经网络跟踪算法的设计,但该方法存在计算误差较大问题。文献[8]提出面向图像超分辨率的紧凑型多径卷积神经网络算法研究,获取低分辨率图像信息,利用残差学习方法对不同分辨率残差信息进行重构,重构后图像统一为高分辨率,当卷积核数量无法达到网络重构数量要求时,利用最大特征图激活函数可有效提升网络泛化能力,使网络结构更紧凑,实现多径卷积神经网络算法的设计,但该方法存在计算效率较低问题。

为解决上述问题,提出基于类别空间约束的弱监督卷积神经网络特征学习算法。构建弱监督卷积神经网络特征学习算法模型,为解决该算法中样本数据不足问题,利用类别空间约束通过对空间加以约束,使标记样本和未标记样本建立一定的联系,以提高分类正确率,从而实现弱监督卷积神经网络特征学习算法的设计,实验证明该方法可有效降低卷积神经网络特征学习算法的误分类率,鲁棒性较强,具有较好的实际应用价值。

1 基于类别空间约束的弱监督卷积神经网络特征学习算法

针对基于类别空间约束的弱监督卷积神经网络特征学习算法,通过建立网络模型、基于类别空间实现空间约束、特征空间聚类和利用模型对样本数据作训练^[9-10],完成对该算法的设计,具体设计步骤如下所述。

1.1 网络模型的建立

为有效实现基于类别空间约束的弱监督卷积神经网络特征学习算法,需要先构建网络模型。网络模型结构主要包括输入层、卷积层、池化层、全连接层和输出层,各层的主要功能如下所述^[11-12]。在输入层中,输入的是候选区域集合 B 。在卷积层中,获取卷积神经网络特征图^[13-14]。假设特征统计时间窗口共有 A 个,每个窗口有 P 个特征,每个输入样本 z 可以用一个 $Q \times P$ 矩阵表示($z \in R^{Q \times P}$)。卷积层中的卷积核 w 用 $l \times P$ 向量表示($w \in R^{l \times P}$), l 代表

卷积核的窗口长度,用 $z_{i,i+l}$ 表示窗口 i 到窗口 $i+l$ 通过拼接得到的特征向量,特征图为 $f = [f_1, f_2, \dots, f_{A-l+1}]$,其中, $A-l+1$ 代表可得到的特征个数^[15],第 i 个特征 f_i 通过式(1)得到:

$$f_i = g(w \cdot z_{i,i+l} + b) \quad (1)$$

式中: $g(x)$ 代表非线性激活函数,常用激活函数分别如式(2)~(4)所示; b 代表偏置项。

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$\text{ReLU}(x) = \max(0, x) \quad (3)$$

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

在池化层中,主要对卷积层中每个候选区域的特征图开展池化操作。池化操作如式(5)所示。

$$\text{pool_feature}(i) = \text{down}(f_j) \quad (5)$$

式中: $\text{down}(x)$ 代表对卷积层中特征图的池化操作。

之后,候选区域的特征向量输入两个不同的分支。首先,将候选区域特征向量输入分类分的全连接层^[16-17]。

全连接层 U_c 的输出 X^c 归一化得到目标检测结果 S^c :

$$S_{ij}^c = \frac{c^{X_{ij}^c}}{\sum_{k=1}^K c^{X_{ik}^c}} \quad (6)$$

式中: K 代表类别数日。

其次,根据每个候选区域通过全连接层 U_d 得到分矩阵 X_d , 归一化得到目标检测结果 S^d :

$$S_{ij}^d = \frac{e^{X_{ij}^d}}{\sum_{r=1}^R e^{X_{ij}^d}} \quad (7)$$

式中: R 代表候选区域数目。最后,通过输出层实现输出。

1.2 基于类别空间约束对候选区域实施空间约束

过滤第 k 个类别特征图的空间密度 ρ_k :

$$\rho_k = \frac{1}{\sqrt{|I|}} \sum_{i,j \in I} 1[M_{ij}^k \geq 0.1 \cdot \max M^k] \quad (8)$$

式中: M_{ij}^k 代表第 k 个类别特征图里第 i 行第 j 列元素; $1[\cdot]$ 代表指示函数,当参数为真,则返回 1,反之,则返回 0。候选区域 B_r 在特征图的空间密度为:

$$\rho_{rk} = \frac{1}{\sqrt{|B_r|}} \sum_{i,j \in B_r} 1[M_{ij}^k \geq 0.1 \cdot \max M^k] \quad (9)$$

通过积分图更加快速有效地开展计算。首先,构建特征图的积分图 $ii(i, j)$:

$$ii(i, j) = \sum_{i' \leq i, j' \leq j} 1[M_{i'j'}^k \geq 0.1 \cdot \max M^k] \quad (10)$$

之后,通过式(11),循环计算快速得到积分图:

$$\begin{cases} ci(i, j) = ci(i, j-1) + 1[M_{ij}^k \geq 0.1 \cdot \max M^k] \\ ii(i, j) = ii(i-1, j) + ci(i, j) \end{cases} \quad (11)$$

式中: $ci(x, -1) = 0, ii(-1, y) = 0$ 。

由于中心空间密度通常比边缘空间密度高,因此,加入上下文密度 ρ_{rk}^c , 以避免此种情况的出现。通过下述公式计算候选区域 $B_r = \{i_1, j_1, i_2, j_2\}$ 的上下文区域 $B_r^c = \{i_1^c, j_1^c, i_2^c, j_2^c\}$:

$$h_c = \frac{i_1 + i_2}{2} \quad (12)$$

$$w_c = \frac{j_1 + j_2}{2} \quad (13)$$

$$h_r = (i_2 - i_1) \cdot \epsilon \quad (14)$$

$$w_r = (j_2 - j_1) \cdot \epsilon \quad (15)$$

式中: h_c 代表纵向坐标; w_c 代表横向坐标; h_r 代表区域高度; w_r 代表区域宽度; 为获取候选区域 B_r^c 坐标, 结合上述公式结果进行计算:

$$i_1^c = \max\left(h_c - \frac{h_r}{2}, 0\right) \quad (16)$$

$$j_1^c = \max\left(w_c - \frac{w_r}{2}, 0\right) \quad (17)$$

$$i_2^c = \min\left(h_c + \frac{h_r}{2}, H\right) \quad (18)$$

$$j_2^c = \min\left(w_c + \frac{w_r}{2}, H\right) \quad (19)$$

其中, ϵ 代表缩放因子 ($\epsilon = 1.5$); H 代表卷积核的窗口高度。在得到上下文候选区域的坐标后, 计算出其空间密度。候选区域的置信度矩阵 \mathbf{W} 的计算, 如式(20)所示。

$$\mathbf{W}_{rk} = \rho_{rk} - \rho_k \quad (20)$$

式中: $\mathbf{W} \in \mathbf{R}^{R \times K}$, 对每个类别的置信度分别作归一化处理, 使得置信度矩阵中的每列中元素的最大值为 1。通过对置信度的处理, 基于类别空间约束, 实现对候选区域的空间约束。

1.3 特征空间聚类

通过类别空间约束对候选区域实现空间约束后, 开展特征空间聚类^[18]。

令第 $t+1$ 轮迭代的特征的每个类别的聚类中心远离第 t 轮其他类别的聚类中心, 则目标函数如式(21)所示。

$$R = - \sum_{i=1}^D \left\| q_i^{t+1} - \sum_{j \neq i} q_j^t / (d-1) \right\|^2 \quad (21)$$

式中: 为和最小化目标函数保持一致, 而类间距离需增大, 在函数前加负号。其中, D 代表给定的聚类的类别数目, q_i^{t+1} 代表第 $t+1$ 轮迭代的第 i 个聚类中心, $\sum_{j \neq i} q_j^t / (d-1)$ 代表第 t 轮迭代除第 i 个聚类中心外的其他类别样本中心。通过数据重构约束, 得到类间约束的目标函数式(22)所示。

$$R_{data} = \sigma \cdot R \quad (22)$$

式中: σ 代表两个约束之前的权重系数。通过聚类迭代, 目标样本在特征空间可以远离其他类别样本的聚类中心。通过上述内容, 完成特征空间聚类。

1.4 模型训练

在实现特征空间聚类后, 利用模型对样本数据开展训

练^[19-20]。将池化层得到的每个候选区域的特征图通过全连接的网络结构实现传递, 将其传递到输出层, 通过函数得到特征图每个类别的概率值。假设模型中卷积核的个数为 V , 输出层的类别个数为 Y , 则输出层的权值参数 φ 为一个 $Y \times V$ 的矩阵, 即 $\varphi \in \mathbf{R}^{Y \times V}$, 样本数据 a 经过池化操作后, 得到一个 V 维向量的特征 \bar{f} , 即 $\bar{f} \in \mathbf{R}^V$, 样本数据 a 成为第 i 个类别的概率用式(23)表示:

$$P(i | a, \varphi) = \frac{c^{(\varphi_i, \bar{f} + b_i)}}{\sum_{k=1}^Y c^{(\varphi_k, \bar{f} + b_k)}} \quad (23)$$

式中: b_i 代表全连接层的第 i 个偏置项, b_k 代表全连接层的第 k 个偏置项。通过将模型的概率值最大化, 得到模型的熵损失函数:

$$J(\varphi) = - \sum_{i=1}^T \log(p(y_i | a_i, \varphi)) \quad (24)$$

式中: T 代表训练样本数据集, y_i 代表第 i 个样本数据的实际类别, a_i 代表第 i 个样本数据的特征, φ 代表模型参数。将该熵损失函数极小化, 学习模型参数。通过上述内容, 利用模型实现样本数据的训练。

至此, 完成基于类别空间的弱监督卷积神经网络特征学习算法的设计。

1.5 本文算法

利用类别空间约束方法对特征空间进行聚类, 并训练输出层各类别特征图样本, 获取模型熵损失函数, 实现类别空间的弱监督卷积神经网络特征学习算法的设计, 该算法流程如算法 1 所示。

算法 1 弱监督卷积神经网络特征学习算法

输入: 分类样本数据 p 与训练样本集 M , 迭代次数 T 。

输出: 各类别特征图, 得到输出层的权值参数集 α 。

- 1) 令迭代次数 $m=0$;
- 2) 构建网络, 并设置其输入层、卷积层、池化层、全连接层和输出层, 计算代表候选区域数目;
- 3) **for** $m < T$ **do**;
- 4) 计算特征图的积分图;
- 5) 获取获选区域置信度的处理;
- 6) 利用聚类迭代方法, 实现特征空间聚类;
- 7) 利用模型对样本数据开展训练, 获取特征图各类别的概率;
- 8) 得到输出层的权值参数集 α ;
- 9) **end for**;
- 10) $m = m + 1$;
- 11) **end**

2 实验验证

2.1 实验环境和数据集

为了验证所提方法性能, 本文的训练环境选择硬件环

境为4 GB内存, Intel Core™ i7-6700 CPU, 主频3.4 GHz的计算机进行检测。实验采用间接类别数据预测值与实际值获取模型的熵损失函数, 利用数据类别的概率值与输出层的权值对空间进行约束, 实现优化目标函数目的。

在训练实验数据时, 输入类别个候选区域的特征图通过全连接的网络结构数据, 通过函数获取特征图各类别的概率值来判断空间特征类型, 实验选用数据库来源于MovieLens, 选择其数据集中70%作为训练模型, 剩余30%测试该模型性能, 如表1所示。

表1 实验数据集描述

数据集名称	对象数	属性数	总数据大小/G
富元数据集	120	10	1.2
开源数据集	90	9	0.7
混合数据集	110	10	1.1

在实验中, 算法的部分网络参数设置如表2和3所示。

表2 部分网络参数设置1

序号	参数名称	参数值
1	卷积核激活函数	Tanh
2	卷积核数量	600
3	卷积核窗口大小	[3,4]
4	迭代次数	10
5	每次更新样本数量	50
6	Dropout 比例	0.6

表3 部分网络参数设置2

参数	卷积		池化		卷积		池化	
	层1	层1	层2	层2	层3	层3	层3	层3
卷积核数	32	32	64	64	128	128		
特征维度	212	184	30	312	15	156	1	684
边缘间隔	32	0	16	0	4	4		

在设置网络参数后, 随机选定相同的数据样本集开展训练。采用不同算法开展实验。通过观察各个算法的网络模型在实验过程中的网络收敛性能的变化, 分析不同算法的性能。

2.2 实验指标

1) 误分率: 在网络学习特征数据计算中, 通过空间约束优化函数目标, 为验证所提方法精度, 选择误分率作为指标进行对比分析, 识别误差率计算, 如式(25)所示。

$$U = \frac{G}{E} \times 100\% \quad (25)$$

式中: G 表示分类误差, E 表示分类实际值。

2) 分类耗时: 为验证所提方法分类效率, 选择不同迭代次数中分类耗时作为指标:

$$T = \frac{X}{N} \quad (26)$$

式中: N 表示为分类效率。

3) 拟合度: 为验证方法精度, 输入一段数据并选择不同方法拟合度进行对比, 拟合度直接决定方法分类性能。

$$R^2 = 1 - \frac{Q}{L} \quad (27)$$

式中: Q 表示为差异平方和, L 表示为回归误差。

2.3 实验结果

为验证所提方法精度, 选择误分率作为指标, 利用所提方法与文献[6-8]方法的实验结果进行对比并记录, 误分率越低说明该方法精度越好, 实验结果如图1所示。




图1 误分率对比结果

从图1中可以看出, 所提方法在训练开展到第8次迭代后, 其误分类率达到5%。说明所提算法在第8次迭代后开始收敛, 且能够取得最佳训练效果。文献[6]在训练开展到第8代趋于收敛, 在第12代又开始趋于上升, 其误分类率最小值出现在第12代, 最小值为14.2%; 文献[7]方法在训练开展到第8代趋于收敛, 之后又有所上升, 其误分类率的波动较大, 其误分类率最小值出现在第12代, 最小值为13.8%; 文献[8]方法在训练过程中的曲线变化较大, 十分不稳定, 其误分类率最小值出现在第8代和第12代, 最小值为17.2%。将上述实验结果汇总表4所示。

表4 不同方法的实验对比结果

算法名称	收敛	误分类率/ %	最小误分类率 出现迭代次数
	周期		
所提方法	8	5	8
文献[6]方法	8	14.2	12
文献[7]方法	不稳定	13.8	12
文献[8]方法	不稳定	17.2	12

通过对比4种不同的弱监督卷积神经网络特征学习算法, 在训练样本数据量非常少的情况下, 提出的基于类别空间约束的弱监督卷积神经网络特征学习算法的误分类率明显少于其他3种传统的弱监督卷积神经网络特征学习算法。通过分析发现, 提出的基于类别空间约束的弱监督卷积神经网络特征学习算法基于类别空间约束, 即使样本数据量不够充分, 也可以实现对样本数据的良好训练, 最终可使误分类率达到较小的水平, 达到最佳的学习状态。

为验证所提方法运行效率,在不同迭代次数中,选择分类耗时作为指标,利用所提方法与 3 种现有方法进行对比,耗时越少说明该方法分类效率越高,实验结果如图 2 所示。




图 2 不同算法分类耗时对比

由图 2 可知,在不同迭代次数中,所提方法分类耗时较少,始终不超过 0.4 ms,且耗时波动幅度较为稳定,而现有方法耗时最高达到 1.6 ms,远远高于所提方法,且随迭代次数增加,耗时上升幅度逐渐升高,该方法稳定性较差,说明所提方法分类效率较高,并具有较好的稳定性。

为保证所提方法精度,在不同迭代次数中,选择拟合优度作为指标进行分析,拟合度与输入数据差距过大会导致算法泛化性能下降,利用 4 种方法进行对比,对比实验结果如图 3 所示。




图 3 不同算法拟合度对比

由图 3 可知,在不同迭代次数中,所提方法与输入数据拟合度较高,且波动区间在 $[0.2, 1.3]$,波动幅度较小,而现有方法波动区间在 $[0.4, 1.4]$,与输入数据差距较大,说明所提方法精度与稳定性较好。

3 结 论

针对传统的弱监督卷积神经网络特征学习算法存在的误分类率较高的缺点,设计一种基于类别空间约束的弱监

督卷积神经网络特征学习算法。解决该算法中样本数据不足问题,利用类别空间约束通过对空间加以约束,使标记样本和未标记样本建立一定的联系,从而实现基于类别空间约束的弱监督卷积神经网络特征学习算法设计。实验结果表明所提方法误分类率较低,且具有较好的分类效率及分类精度,能够更好地完成特征学习。由于本次研究主要针对该算法功能性进行优化,没有考虑到成本因素,下一步研究将对该算法成本进行优化。

参 考 文 献

- [1] 张朝林,范玉刚. CEEMD 与卷积神经网络特征提取的故障诊断方法研究[J]. 机械科学与技术,2019,38(2): 178-183.
- [2] 毛向向,王红军,韩凤霞,等. 基于深度卷积神经网络的机电系统故障分类识别方法[J]. 电子测量与仪器学报,2021,35(2):87-93.
- [3] 姚品,万旺根. 基于深度学习和属性特征的行人再识别算法[J]. 电子测量技术,2020,43(12):70-74.
- [4] 孙平安,祁俊,谭秋月. 利用卷积神经网络改进迭代深度学习算法的图像识别方法研究[J]. 计算机应用研究,2019,36(7):2223-2227.
- [5] 蓝金辉,王迪,申小盼. 卷积神经网络在视觉图像检测的研究进展[J]. 仪器仪表学报,2020,41(4):167-182.
- [6] 邱宁佳,王晓霞,王鹏,等. 结合迁移学习模型的卷积神经网络算法研究[J]. 计算机工程与应用,2020,56(5): 43-48.
- [7] 汪鸿翔,柳培忠,骆炎民,等. 高斯核函数卷积神经网络跟踪算法[J]. 智能系统学报,2018,13(3):388-394.
- [8] 应自炉,商丽娟,徐颖,等. 面向图像超分辨率的紧凑型多径卷积神经网络算法研究[J]. 信号处理,2018, 34(6):668-679.
- [9] 康家银,张文娟. 用于图像分割的非局部空间约束的核 FCM 算法[J]. 南京师大学报(自然科学版),2019, 42(3):122-128.
- [10] 蒲磊,冯新喜,侯志强,等. 基于空间可靠性约束的鲁棒视觉跟踪算法[J]. 电子与信息学报,2019,41(7): 1650-1657.
- [11] SAVKOVIC B, KOVAC P, DUDIC B, et al. Comparative characteristics of ductile iron and austempered ductile iron modeled by neural network[J]. Materials, 2019, 12(18):2864.
- [12] DU L H, ZHANG Q, GAO C, et al. Response characteristics prediction of surge protective device based on NARX neural network [J]. IEEE Transactions on Electromagnetic Compatibility, 2018; 1-9.
- [13] YIXUE M, HELED J, YUAN A. Analysis of surface temperature characteristics of multiscale fusion based on convolution neural network [J]. Matec Web of

- Conferences, 2018, 173:03011.
- [14] LI Y, LUO B, LIU D, et al. Robust synchronization of memristive neural networks with strong mismatch characteristics via pinning control[J]. Neurocomputing, 2018, 289:144-154.
- [15] XIANG Y, LIN Z, MENG J. Automatic QRS complex detection using two-level convolutional neural network[J]. BioMedical Engineering OnLine, 2018, 17(1):1-17.
- [16] ZENG H, LIU Y, LI S, et al. Convolutional neural network based multi-feature fusion for non-rigid 3D model retrieval[J]. Journal of Information Processing Systems, 2018, 14(1):176-190.
- [17] DONG K, MUHAMMAD A, KANG P. Convolutional neural network-based shadow detection in images using visible light camera sensor [J]. Sensors, 2018, 18(4):960.
- [18] JUNG H Y, HEO Y S. Fingerprint liveness map construction using convolutional neural network[J]. Electronics Letters, 2018, 54(9):564-566.
- [19] DU C B, GAO S S. Multi-focus image fusion with the all convolutional neural network[J]. Optoelectronics Letters, 2018, 14(1):71-75.
- [20] 朱斌,陈磊,邬金萍. 基于改进卷积神经网络结构的机器视觉室内定位算法[J]. 国外电子测量技术, 2021, 40(1):58-64.

作者简介

高博,工学硕士,助理实验师,主要研究方向为计算机教育与管理。

E-mail:303347264@qq.com