



## PSdropout卷积神经网络在危化品巡检车中的应用

沙芸, 李齐飞, 甘建旺, 刘学君, 隗立昂

引用本文:

沙芸, 李齐飞, 甘建旺, 等. PSdropout卷积神经网络在危化品巡检车中的应用[J]. 智能系统学报, 2020, 15(6): 1131–1139.

SHA Yun, LI Qifei, GAN Jianwang, et al. Application of PSdropout convolutional neural network in inspection car for hazardous chemicals[J]. *CAAI Transactions on Intelligent Systems*, 2020, 15(6): 1131–1139.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202007022>

## 您可能感兴趣的其他文章

### 一种改进的深度学习的路标识别算法

An improved deep learning algorithm for road traffic identification

智能系统学报. 2020, 15(6): 1121–1130 <https://dx.doi.org/10.11992/tis.201811009>

### 区域损失函数的孪生网络目标跟踪

Regional loss function based siamese network for object tracking

智能系统学报. 2020, 15(4): 722–731 <https://dx.doi.org/10.11992/tis.201910005>

### 深度学习的交互行为识别与预测算法研究

Human interaction recognition and prediction algorithm based on deep learning

智能系统学报. 2020, 15(3): 484–490 <https://dx.doi.org/10.11992/tis.201812029>

### 一种高效的稀疏卷积神经网络加速器的设计与实现

Design and implementation of an efficient accelerator for sparse convolutional neural network

智能系统学报. 2020, 15(2): 323–333 <https://dx.doi.org/10.11992/tis.201902007>

### 基于改进卷积神经网络的多标记分类算法

A multi-label classification algorithm based on an improved convolutional neural network

智能系统学报. 2019, 14(3): 566–574 <https://dx.doi.org/10.11992/tis.201804056>

### 基于快速密度聚类的RBF神经网络设计

Construction of RBF neural networks via fast density clustering

智能系统学报. 2018, 13(3): 331–338 <https://dx.doi.org/10.11992/tis.201702014>



关注微信公众号，获取更多资讯信息

DOI: 10.11992/tis.202007022

# PSdropout 卷积神经网络在危化品巡检车中的应用

沙芸, 李齐飞, 甘建旺, 刘学君, 隗立昂

(北京石油化工学院 信息工程学院, 北京 102617)

**摘要:** 危化品仓储环境复杂多变, 基于卷积神经网络的视觉巡检车需要快速的训练方法以便适用不同的环境, 提高卷积神经网络的训练速度是当前亟待解决的问题。迅速在网络中提取有效的神经元, 是提高算法训练速度的关键。传统的算法中, 全链接层神经元的去留问题通常采用基于伯努力分布假设的 Dropout 方法, 本文提出一种基于泊松分布的 Dropout 方法。理论上, 在充分利用神经元历史行为的基础上, 基于泊松分布与基于伯努力分布的最大似然函数类似。实验结果表明, 在保持正确率的情况下, 训练提前收敛, 节约了训练时间。

**关键词:** 危化品仓储; 巡检车; 卷积神经网络; 神经元筛选; 泊松分布; 子网络; 全链接层; 网络架构  
**中图分类号:** TP391.4; TQ086.5   **文献标志码:** A   **文章编号:** 1673-4785(2020)06-1131-09

**中文引用格式:** 沙芸, 李齐飞, 甘建旺, 等. PSdropout 卷积神经网络在危化品巡检车中的应用 [J]. 智能系统学报, 2020, 15(6): 1131-1139.

**英文引用格式:** SHA Yun, LI Qifei, GAN Jianwang, et al. Application of PSdropout convolutional neural network in inspection car for hazardous chemicals[J]. CAAI transactions on intelligent systems, 2020, 15(6): 1131-1139.

## Application of PSdropout convolutional neural network in inspection car for hazardous chemicals

SHA Yun, LI Qifei, GAN Jianwang, LIU Xuejun, WEI Li'ang

(School of Information Engineering, Beijing Institute of Petrochemical Technology, Beijing 102617, China)

**Abstract:** The storage environment of hazardous chemicals is complex and changeable. To adapt to different environments, visual-inspection vehicles based on convolutional neural networks require fast training methods, but the problem of improving the training speed of convolutional neural networks remains to be solved. To improve the training speed of the algorithm, effective neural cell in network must be extracted from the network more quickly. In the traditional algorithm, the removal of neurons from the fully connected layer is typically performed using the dropout method, which is based on the Bernoulli distribution hypothesis. In this paper, we propose a dropout method based on the Poisson distribution. Theoretically, by making full use of the historical behavior of neurons, the maximum likelihood function based on the Poisson distribution is similar to that based on the Bernoulli distribution. The experimental results show that while maintaining the correct rate, the training can be converged in advance, thereby saving the training time.

**Keywords:** storage of hazardous chemicals; inspection vehicle; convolutional neural network; dropout; Poisson distribution; subnetwork; full link layer; network architecture

危化品仓库中存储物通常是易燃、易爆、腐蚀性强的危险化学品。危化品存储时, 有些种类严禁混存, 可以混存的有严格距离要求, 违反这些规定会引发重大的安全事故, 危化品的存储安全是当前亟待解决的问题。针对复杂的危化品仓

储环境, 前人主要从危险化学品堆垛安全距离<sup>[1-4]</sup>、堆垛位置布局<sup>[5]</sup>优化方面来解决问题, 这些方法大部分是布置静态摄像头计算距离, 但是存在镜头遮挡和计算偏差等问题。将卷积神经网络应用于危化品仓储巡检车视觉中, 利用自动巡检车对仓库进行自动巡检, 并实时给出反馈是当前研究的热点。实际危化品仓库中光线不清、危化品货物压线、危化品场景多变、仓库巡检路线

收稿日期: 2020-07-12.

基金项目: 国家重点研发计划项目子项目 (2016YFC0801500).

通信作者: 沙芸. E-mail: shayun@bipt.edu.cn.

遮挡等都会造成巡检困难。当场景变化比较多的时候,需要模型具有较强的适应能力。

目前卷积神经网络研究中,网络层数和神经元数目越来越多,模型对特征的刻画和表达能力越来越强,测试准确率不断提高。但是随着参数不断增多,模型复杂度迅速提升,计算复杂度越来越高,计算时间越来越长。然而实际工业应用中,模型需要具备快速的训练方法,较强的适用能力。卷积神经网络必须降低网络的训练时长和计算复杂度才能得到实际的工业应用。因此,基于卷积神经网络的危化品仓储巡检车的视觉模型应当在保持准确率的同时,具有规模小、训练速度快的特点。

在设计卷积神经网络时,需要保持特征提取能力的同时减少参数数量,压缩、修剪网络框架是目前较常用降低计算复杂度的方法。Srinivas等<sup>[6]</sup>提出了修剪神经元的方法,在神经元显著性最低时删除两个相似神经元中的一个神经元,提高了计算效率,简化了网络架构,但是神经元显著性的量化难于界定。Han等<sup>[7]</sup>在训练网络架构时探索连接的重要性,修剪不重要的连接以减少连接的数量。在一定程度上,修剪连接可以简化网络架构,但是性能与修剪神经元相比还是差强人意的。Chen等<sup>[8]</sup>提出了HashedNets,使用一个哈希函数将权重随机分组到HashedNets中,一个HashedNets中的连接将共享相同的参数,参数共享极大地简化了计算过程,加速网络训练速度,但是参数在共享计算时并非对网络架构中的所有神经元都是友好的。在文献<sup>[9]</sup>中,权值小于阈值的连接将被视为不必要的连接并被删除,对权值进行量化,并对量化后的权值进行霍夫曼编码,进一步压缩网络,精简网络框架,但是阈值的设定需要一定的工作量。网络压缩<sup>[10-13]</sup>、网络剪枝<sup>[14]</sup>、Dropout<sup>[15-16]</sup>的相关改进本质上都是精简网络架构,修剪神经元、修剪神经元之间的连接、Dropout神经元,使网络变得稀疏,简化计算过程。同时,由于在一定程度上抑制提取的特征同化现象,可以有效缓解过拟合的发生。

本文将卷积神经网络应用于危化品仓储巡检车中,主要任务为实现巡检车自主巡检,为加快loss收敛速度对传统卷积神经网络算法进行改进,提出了一种基于泊松分布的Dropout方法。

## 1 相关工作

### 1.1 卷积神经网络

卷积神经网络<sup>[17-19]</sup>能够很好地利用图像的结构信息,可以较完整地提取图像中的特征信息。文献<sup>[20]</sup>研究表明,全链接层可以保证模型表示

能力的迁移。

### 1.2 具体实现

搭建网络架构<sup>[21]</sup>,如图1所示,本文的参数设置经过多次在本样本上实验测试,综合考量loss与准确率情况选定而来。




图1 网络架构

Fig. 1 Network architecture

网络框架参数设置:

首先,将原始图片归一化为 $120 \times 120 \times 3$ 大小的样本作为输入,采用步长为1具有32个 $5 \times 5$ 大小的卷积核的卷积层作为第1层。采用步长为2的池化层作为第2层。采用步长为1具有64个 $5 \times 5$ 大小的卷积核的卷积层作为第3层,采用步长为2的池化层作为第4层。后接入512个神经元的全链接层。每层卷积层和全链接层之后紧接ReLU非线性激活函数<sup>[22]</sup>以提高网络性能,保证提取到更有用的信息。利用Dropout方法抑制过拟合现象。实验中,将训练好的模型进行测试,将当前画面中人为控制的巡检车的行驶角度和行驶速度是否相等作为测试评判标准,损失函数<sup>[23]</sup>为

$$L(\theta, \theta^*, X) = \text{MSE} = \frac{1}{n} \sum_{i=1}^n \|\hat{y}_i(X, \theta_i^*) - y_i(X, \theta_i)\|^2$$

以上的卷积神经网络模型在实验样本中取得了较好的测试结果,但是仍存在训练过程中损失下降及收敛缓慢、对其他危化品仓库场景样本适应性较低的问题。因此,本文对Dropout进行改进,提出基于泊松分布的Dropout方法。

## 2 PSdropout 抽样算法

根据观察,不频繁更新的神经元在后期的训练中,最终会以较大的概率被关闭。如果尽早根据网络中神经元节点的历史激活状态进行神经元取舍,理论上可以快速找到作用大的子网络,从而提高网络的训练速度。

### 2.1 理论分析及算法步骤

无Dropout的传统卷积网络计算公式为



$$\begin{aligned} z_i^{(l+1)} &= w_i^{l+1} y^l + b_i^{l+1} \\ y_i^{(l+1)} &= f(z_i^{(l+1)}) \end{aligned}$$

2012 年, Hinton<sup>[15]</sup> 在论文中提出 Dropout, 当一个复杂的神经网络用于训练特征较为简单的数据集时, 会很容易出现过拟合现象, 主要表现为训练时测试准确率很高、测试时测试准确率很低。为了防止过拟合, 可以通过阻止特征检测器的共同作用来提高神经网络的性能。

采用 Dropout 的网络计算公式为

$$r_j^{(l)} \sim B(p_m) \quad (1)$$

$$\tilde{y}^l = r^{(l)} * y^{(l)} \quad (2)$$

$$z_i^{(l+1)} = w_i^{(l+1)} \tilde{y}^l + b_i^{(l+1)} \quad (3)$$

$$y_i^{(l+1)} = f(z_i^{(l+1)}) \quad (4)$$

Dropout 方法神经元去留概率服从伯努利分布, 根据式 (1)~(4) 对网络框架进行更新。Drop-Connect<sup>[24]</sup> 不再是随机将隐含层节点的输出清 0, 而是将节点中的每个与其相连的输入权值以一定的概率清 0, 在输入处修剪掉多余的连接, 在 Dropout 概率设置为 0.5 时在本层网络中可以节省一半的计算量。以此算法作为实验中的对比算法。

泊松概率分布<sup>[25]</sup>(poisson distribution) 描述的是在某段时间或某个空间内发生随机事件次数的概率, 也就是根据过去某个随机事件在某段时间或某个空间内发生的平均次数。在 PSdropout 抽样算法中, 统计前一阶段训练中一定步数内的网络框架中全链接层的神经元的修改次数情况, 作为下一阶段网络训练更新的指导, 基于 PSdropout 的抽样算法神经元权重的筛选是服从泊松分布的。

采用 PSdropout 抽样算法的网络计算公式包括:

$$p_m = \frac{C_w}{R_{\text{times}}} \quad (5)$$

$$p'_m = \begin{cases} 1, & p_m \geq p_0 \\ 0, & p_m < p_0 \end{cases} \quad (6)$$

$$r_j^{(l)} \sim P(p'_m) \quad (7)$$

$$\tilde{y}^l = r_j^{(l)} * y^{(l)} \quad (8)$$

$$z_i^{(l+1)} = w_i^{(l+1)} \tilde{y}^l + b_i^{(l+1)} \quad (9)$$

$$y_i^{(l+1)} = f(z_i^{(l+1)}) \quad (10)$$

首先, 根据式 (5) 记录当前神经元的修改次数  $C_w$  和训练次数  $R_{\text{times}}$ , 计算每个神经元权重的激活(抑制) 概率  $p_m$ ,  $p'_m$  为激活张量,  $p'_m$  来源符合泊松分布。

取出张量  $p'_m$  中的每一个元素与设定值  $p_0$  作对比, 若某个神经元的某个权重激活(抑制) 概率  $p_m > p_0$ , 将当前  $p'_m$  中对应位置设置为激活状态 1, 否则, 设置为抑制状态 0, 记录激活张量  $p'_m$ ; 在大

量实验结果中进行对比, 综合 loss 和测试的结果, 选择实验结果最好的值作为  $p_0$ 。

按 PSdropout 更新当前层, 公式如式 (5)~(10)。

## 2.2 理论推导

Dropout 与 PSdropout 抽样算法不同之处在于神经元的去留服从分布不同, 极大似然估计的依据是概率最大的事件最可能发生, 在神经元去留问题上, 神经元激活不同数目可作为不同事件, 改进的 PSdropout 使具有积极意义的神经元最大化的激活这一事件发生概率可由极大似然估计进行推导。另外, 在理论中找相等是很难的, 泊松分布和伯努利分布的极大似然相似, 即可证明其有一定的相似性。对比伯努利分布与泊松分布, 观测二者的极大似然估计值如下:

Dropout: 在实验中, 神经元去留概率服从伯努利分布:

$$D = \{y_1, y_2, \dots, y_n\}, y \sim B(\mu)$$

似然函数为

$$L = p(D|\mu) = \prod_{n=1}^N p(y_n|\mu) = \prod_{n=1}^N \mu^{y_n} (1-\mu)^{(1-y_n)}$$

取对数, 整理化简:

$$\begin{aligned} l = \ln p(D|\mu) &= \sum_{n=1}^N \ln \{ \mu^{y_n} (1-\mu)^{(1-y_n)} \} = \\ &= \sum_{n=1}^N \{ y_n \ln \mu + (1-y_n) \ln (1-\mu) \} \end{aligned}$$

最大化似然函数, 取导数为 0 的极值:

$$\begin{aligned} \frac{\partial l}{\partial \mu} &= \sum_{n=1}^N \left\{ y_n \frac{1}{\mu} (1-y_n) \frac{1}{1-\mu} \right\} = \frac{1}{\mu(1-\mu)} \{ y_n - \mu \} = 0 \\ \mu_{\text{MLE}} &= \frac{1}{N} \sum_{n=1}^N y_n \end{aligned}$$

PSdropout 抽样算法: 在实验中, 神经元的去留服从泊松分布:

$$D = \{y_1, y_2, \dots, y_n\}, y \sim P(\lambda)$$

似然函数:

$$L = \prod_{n=1}^N \frac{\lambda^{y_n}}{y_n!} e^{-\lambda} = e^{-n\lambda} \prod_{n=1}^N \frac{\lambda^{y_n}}{y_n!}$$

取对数, 整理化简:

$$l = \ln L = -n\lambda + \sum_{n=1}^N (y_n \ln \lambda - \ln y_n)$$

最大化似然函数, 取导数为 0 的极值:

$$\begin{aligned} \frac{\partial l}{\partial \lambda} &= -N + \sum_{n=1}^N \frac{y_n}{\lambda} = 0 \\ \lambda_{\text{MLE}} &= \frac{1}{N} \sum_{n=1}^N y_n \end{aligned}$$

两种分布最终的极大似然函数取值相同, 因此 PSdropout 抽样算法的神经元抽样方法的选取是合理的。

### 3 实验

在主频为 2.20 GHz, CPU 为 GTX1080 Ti GPU 的服务器上, 将典型卷积神经网络模型和改进后的网络模型进行实验并对比结果。

#### 3.1 数据集

实验中, 选用不同的数据集对原始算法和 PSdropout 抽样算法的实验结果进行整理, 以证明 PSdropout 抽样算法的有效性。采用智能小车采集彩色 160×120 大小的实验现场照片, 将该数据命名为 Car 数据集, 含有 4 个训练子集, 样本数量为 5 000、10 000、15 000、20 000; 同时含有 1 个 2 000 张照片的测试集。在实验中, 使用了深度学习网络架构对 Car 数据集进行训练。

部分 Car 原始场景训练数据集如图 2 所示, 该数据集主要是危化品仓库中良好状态下采集的样本, 采集样本过程中无障碍物遮挡路线、光线条件良好, 拍摄清晰, 以最优条件下采集的素材作为实验中的训练集。



图 2 原始场景样本图

Fig. 2 Sample pictures of original scene

在实际的危化品仓库中, 危化品智能巡检车的道路情况并非如实验样本中的理想化状态, 实际采集的样本在道路线上存在着光线条件不好、障碍物遮挡道路线、不明物体遮挡道路线等一系列情况, 将复杂场景情况下采集的道路样本作为数据集, 为以后在实际的危化品仓库中的应用以及重新训练奠定基础。图 3 为部分复杂样本图。



图 3 复杂场景样本图

Fig. 3 Sample photos of complex scene

#### 3.2 单场景数据量测试实验

在深度学习训练中, 训练数据是很重要的, 在样本量方面, 一是要有尽量多的训练样本, 二是要保证样本的分布够均匀。但实际采集数据的过程中, 不同样本量的设置训练出来的网络架构以

及测试结果也差异较大, 为探究 PSdropout 算法的稳定性, 选取数量不同的原始场景样本制作 Car 数据集进行训练并在 Car 测试集上进行测试, 对 loss 损失函数结果及测试结果进行分析: 采集数据量为 5 000、10 000、15 000、20 000 的样本进行实验, 学习率设为固定值, loss 测试结果如表 1, 测试准确率结果如表 2。

表 1 loss 统计结果  
Table 1 Statistical loss results

实验名称	Loss	Dropout	DropConnect	PSdropout
5000原始样本实验	0.14	2 200	3 500	2 000
	0.13	4 500	4 500	2 800
	0.12	未达到	7 200	5 400
10000原始样本实验	0.14	4 200	4 200	3 000
	0.13	7 100	7 300	5 800
	0.12	未达到	未达到	7 900
15000原始样本实验	0.14	2 500	3 300	2 000
	0.13	4 200	4 100	2 700
	0.12	未达到	6 300	5 000
20000原始样本实验	0.14	2 500	4 200	1 800
	0.13	4 000	7 000	3 800
	0.13	未达到	未达到	6 800

表 2 测试结果  
Table 2 Statistical test results

实验名称	Dropout	Dropconnect	PSdropout
5000原始样本实验	0.96	0.96	0.97
10000原始样本实验	0.95	0.95	0.96
15000原始样本实验	0.96	0.95	0.96
20000原始样本实验	0.95	0.92	0.95

将学习率设置为固定值, 进行训练, 训练中 loss 的变化无其他变化因素干扰, 可以更好地观测 PSdropout 引起的变化。横向观测实验结果, 就表 1 的 loss 统计结果来说, 样本量分别定为 5 000、10 000、15 000、20 000, DropConnect 与 Dropout 相比, 达到相同损失率时所用步骤相差不大, DropConnect 最终取得的 loss 值较小, 而 PSdropout 抽样算法相比于 Dropout 和 DropConnect 能够以更少的训练轮数步骤取得更小的 loss 值; 就测试结果而言, 在 4 组实验中, PSdropout 测试率皆高于前两者。

纵向观测表 2 的测试结果, 随着实验中训练样本的样本量不断增加, 在 3 类实验中可以看到测试准确率处于不断下降状态, 因为随着样本量

的增加,网络的训练轮数不断增加,网络中的神经元会记忆训练样本,导致过学习现象。而较小的实验样本量训练中,PSdropout 抽样算法以较少的训练步数取得了较好的 loss 值,并且训练出的网络架构测试准确率更高。PSdropout 抽样算法为现今面临的样本缺失问题提供了一个新的解决问题思路。综合上述实验中 loss 的收敛以及测试结果,PSdropout 抽样算法对不同数量样本的训练集都有较好的适应能力,该算法是稳定健壮的。

### 3.3 多场景测试

不同危化品仓库的地面与标志线差异较大,图4是一些危化品仓库的实景图,而实际仓库场景多,对于新场景的适应成为识别的一大难点。



图4 复杂危化品仓库实景图

Fig. 4 Photos of complex chemical warehouses

因此,对多场景的适应能力好坏是评判改进算法的一个重要依据。在不同场景的样本上进行实验,分别用基于 Dropout 的原始算法、基于 DropConnect 的对比算法、基于 PSdropout 抽样算法进行实验,因为 DropConnect 是对神经元之间的连接的去留进行选择,来抑制过拟合现象,加速训练,与 PSdropout 算法中舍弃不活跃神经元的方法是一致的,因此选择基于 DropConnect 的卷积神经网络作为对比算法进行实验,loss 结果如表3,测试结果如表4。

表3 Loss 统计结果  
Table 3 Statistical loss results

实验名称	损失值	Dropout	DropConnect	PSdropout
原始场景 样本实验	0.14	2 500	3 300	2 000
	0.13	4 200	4 100	2 700
	0.12	未达到	6 300	5 000
复杂场景 样本实验	0.14	3 500	6 200	3 700
	0.14	6 300	10 000	3 700
	0.13	未达到	未达到	8 600

表4 测试结果  
Table 4 Statistical test results

实验名称	Dropout	DropConnect	PSdropout
原始场景样本实验	0.96	0.95	0.96
复杂场景样本实验	0.93	0.91	0.91

根据表3的 loss 统计结果,原始样本数据集训练完成时,调用原始算法时 loss 值未达到 0.12,调用 DropConnect 时 loss 值达到 0.12,调用 PSdropout 抽样算法时 loss 最低值为 0.12;复杂场景样本数据集训练完成时,调用原始算法时 loss 最低值未达到 0.13,调用 DropConnect 时 loss 值未达到 0.13,调用抽样时 loss 最低值为 0.13。根据表4测试结果,改进算法在原始样本数据集上训练的模型测试结果皆高于原始算法,原始算法在复杂场景样本数据集上训练的模型测试结果高于 DropConnect 和抽样。在保证正确率相差不大的前提下,PSdropout 抽样算法的训练步数明显减少,训练速度提高。

### 3.4 网络架构适应性测试

在实际的应用中,由于危化品仓库的跑道具有多样性、多变性,不同的危化品仓库,地面与标志线差异较大,场景多,对于新场景的适应成为识别的一大难点,因此需要把训练的样本在多种场景内进行应用,所以训练出的网络架构必须有较好的适应性,减少对样本的依赖。采取实验 A 和 B 对算法进行适应能力测试。实验 A:在原始样本数据集上进行训练,用复杂样本作为测试集进行测试。实验 B:在复杂样本数据集上进行训练,用简单样本作为测试集进行测试。表5中记录测试准确率:

表5 适应性测试  
Table 5 Adaptive test results

实验名称	Dropout	PSdropout
实验A	0.79	0.79
实验B	0.95	0.96

进行上述实验旨在检验两个算法训练的网络架构的适应性。由表5适应性测试的结果可以看出 PSdropout 抽样算法对不同场景的适应能力更强,因为 PSdropout 算法能尽早抽取出活跃的神经元,网络架构的学习能力更强,删除掉冗余的神经元,对于抑制过拟合现象有较好的贡献。这点对于实际的危化品仓库现今存在的样本采集困难、网络架构适应差等问题,PSdropout 抽样算法提供了新的解决思路。

### 3.5 细节性实验

在原始场景数据集上训练,实验参数设置如下。原始算法:batchsize 为 50,优化函数算法为随机梯度下降算法,实现参数更新,其中,学习率为固定值 0.01。PSdropout 抽样算法:在原始算法基础上,对训练结果进行统计,每 500 步统计 1 次,之后的 500 步训练根据前 500 步统计结果计算出式(5)中的  $P$  更新,修改次数少的继续抑制,



修改次数多的进行激活。在原始场景数据集上实验结果 loss 函数值统计图如图 5 所示, 横坐标为训练步数, 纵坐标为 loss 值。




图 5 原始场景数据集上 loss 统计

Fig. 5 Loss statistics for the original scene data set

在复杂场景数据集上实验结果 loss 函数值统计如图 6 所示。




图 6 复杂场景数据集上 loss 统计

Fig. 6 Loss statistics for the complex scene data set

原始、复杂场景数据集上的 loss 统计结果、测试结果如表 6 所示。

表 6 loss 及准确率统计结果  
Table 6 Loss and accuracy statistics

实验名称	Loss	Dropout	PSdropout	Dropout	PSdropout
原始场景 训练	0.15	1 100	1 000		
	0.14	2 500	1 800		
	0.13	4 000	3 800	0.95	0.95
	0.13	未达到	6 800		
复杂场景 训练	0.15	2 000	1 500		
	0.14	3 500	3 700		
	0.14	6 300	4 500	0.93	0.91
	0.13	未达到	8 600		

在原始样本数据集上, 由原始 Dropout 和 PSdropout 抽样的损失函数图 (图 5、图 6) 可以看出 loss 的细节变化情况, 训练过程中, 调用 PSdropout 抽样的每 500 步训练过程中, loss 会明显下降到  $[0.005, 0.01]$  区间, 之后的训练在调用 Dropout 时, loss 会在短时间内出现上升趋势。以训练 3 500~4 500 步的损失值变化为例分析, 3 500~4 000 调用 PSdropout 抽样算法时, loss 的变化整体呈现迅速下降趋势, 并且很快取得了 loss 的一个极小值 0.13, 低于调用原始 dropout 时的 0.14; 训练 4 000~5 000 步时, 原始 dropout 的 loss 值急剧上升, 出现这个变化的原因是对于网络架构有消极作用的神经元再次被激活。对以上实验数据整体进行观察, 调用 dropout 算法的 loss 实验结果波动较大, 训练中 loss 最小值大概为 0.129, 出现在训练步数为 6 700 时, loss 值收敛最终在 0.14 左右浮动; 调用 PSdropout 抽样算法的 loss 实验结果, 在实验训练过程中波动较小, 数据较为稳定, 训练中 loss 最小值大概为 0.122, 出现在训练步数为 4 900 时, 最终 loss 的收敛值在 0.135 左右浮动。复杂场景数据集由于道路环境复杂所以训练更为困难, 因此, loss 值大于原始场景数据集训练的 loss; 由表 6 观测测试准确率, PSdropout 抽样算法测试结果和原始算法相差不大。综合 loss 下降速度和测试准确率来看, PSdropout 抽样算法效果优于原始算法。

### 3.6 算法有效性验证实验

Mnist 数据集为分类实验公共数据集, 在训练网络架构中主要提取的特征为手写体数字的边缘轮廓信息, 而本实验提取的信息主要为危化品仓库道路样本的特征信息, 侧重点同样在于道路边缘, 因此, 为了测试 PSdropout 抽样的稳定性与有效性, 采用深度学习经典公共数据集 Mnist 进行

实验,训练集 6 000 张图片,测试集为 1 000 张照片,大小为 28×28 的灰度照片。

对于数据集 Mnist 使用的损失函数是交叉熵损失函数,因为使用交叉熵能够提高精度和训练速度,函数使用的是交叉熵损失函数。

Mnist1: Mnist 数据集,学习率调整形式为自动指数衰减,改进函数统计前 1 000 步的训练结果,后续 5 000 步按统计结果更新。

Mnist2: Mnist 数据集,学习率为固定值,改进函数统计前 1 000 步的训练结果,后续 9 000 步按统计结果更新。

表 7 中记录了 loss 函数值与测试准确率结果。

表 7 Mnist 数据集上训练结果  
Table 7 Training results for Mnist data set

实验名称	Loss	Dropout	PSdropout	Dropout 测试正确率	PSdropout 测试正确率
	0.80	2 300	1 800		
Mnist1	0.75	4 500	3 500	0.98	0.98
	0.70	未达到	5 000		
	1.00	2 500	1 500		
Mnist2	0.75	9 000	5 000	0.97	0.98
	0.60	未达到	10 000		

综合表 7 显示的 Mnist 数据集上的训练结果,进行分析。在实验 Mnist1 上,按自动指数衰减的形式进行学习训练,PSdropout 抽样算法训练的网络架构获得的 loss 值下降迅速,最终的收敛值达到 0.7,而 Dropout 算法未达到 0.7,而且 PSdropout 抽样算法与 Dropout 算法的测试准确率相差不大;在 Mnist2 实验中,采用固定值学习率进行学习训练,PSdropout 抽样算法在训练到 10 000 步时,最终的收敛值达到 0.6,而 Dropout 算法未达到 0.6,PSdropout 抽样算法测试准确率达到 97.84%,而 Dropout 算法测试准确率为 97.06%,而且在训练过程中 PSdropout 抽样波动更小,表现更为稳定。在 Mnist 数据集上,相较于调整学习率的学习方式,PSdropout 抽样算法更适合固定学习率算法的学习方式。综合实验 Mnist1、Mnist2,PSdropout 抽样算法是优于 Dropout 算法的。

## 4 结束语

本文提出将卷积神经网络应用于危化品仓库智能巡检车,为提高 loss 收敛速度和对新样本的适应性,提出一种基于泊松分布的 Dropout 方法,即 PSdropout 抽样算法,将此方法用于卷积神经网络中全链接层,根据前期的权重修改情况对

神经元的去留作出取舍,神经元的去留情况服从泊松分布,充分利用神经元选择的历史情况,快速抽取出适合本样本的网络架构。理论上,在充分利用神经元历史行为的基础上,本文的神经元去留概率与原始的 Dropout 算法去留概率的最大似然函数类似;实验结果表明,在保持正确率的情况下,训练提前收敛,节约了训练时间,并且提高了巡检车对不同复杂度道路的识别能力。后续可以将该方法与卷积神经网络的模型剪裁方法结合起来,进一步提高卷积神经网络训练速度。

## 参考文献:

- [1] 刘学君,江帆,戴波,等.基于 ARM 的危化品仓库堆垛安全距离监测装置的研究与开发[J].制造业自动化,2016,38(4): 11-14, 25.  
LIU Xuejun, JIANG Fan, DAI Bo, et al. The research and development of stack safe distance monitoring device for the chemicals warehouse based on ARM[J]. Manufacturing automation, 2016, 38(4): 11-14, 25.
- [2] 李琳.基于 UWB 定位的危化品仓库管理的设计和研究[D].北京:北京邮电大学,2018.  
LI Lin. Design and research of hazardous chemicals warehouse management based on UWB positioning[D]. Beijing: Beijing University of Posts and Telecommunications, 2018.
- [3] 戴波,周泽戎,张岩,等.危化品仓储堆垛安全距离监测系统[J].化工学报,2019,70(002): 707-715.  
DAI Bo, ZHOU Zeyu, ZHANG Yan, et al. Design of safe distance monitoring system for hazardous chemicals storage stack[J]. CIESC Journal, 2019, 70(002): 707-715.
- [4] 戴波,吕昕,刘学君,等.基于 UWB 四参考点矢量补偿的危化品仓储堆垛货物定位方法[J].化工学报,2016,67(3): 871-877.  
DAI Bo, LÜ Xin, LIU Xuejun, et al. A UWB-based four reference vectors compensation method applied on hazardous chemicals warehouse stacking positioning[J]. CIESC journal, 2016, 67(3): 871-877.
- [5] DAI Bo, LI Yanfei, REN Haisheng, et al. Research on optimization for safe layout of hazardous chemicals warehouse based on genetic algorithm[J]. IFAC-PapersOnline, 2008, 51(18): 245-250.
- [6] SRINIVAS S, BABU R V. Data-free parameter pruning for deep neural networks[C]//Proceedings of British Machine Vision Conference 2015. Swansea, UK, 2015: 1-12.
- [7] HAN Song, POOL J, TRAN J, et al. Learning both weights and connections for efficient neural networks[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, Quebec, Canada, 2015: 1135-1143.



- [8] CHEN Wenlin, WILSON J, TYREE S, et al. Compressing neural networks with the hashing trick[C]//Proceedings of the 32nd International Conference on Machine Learning. Lille, France, 2015: 2285–2294.
- [9] HAN Song, MAO Huizi, DALLY W J. Deep compression: compressing deep neural networks with pruning, trained quantization and Huffman coding[C]//Proceedings of 2016 International Conference on Learning Representations. San Juan, Pucrto Rico, 2015: 3–7.
- [10] MA Rongrong, NIU Lingfeng. A survey of sparse-learning methods for deep neural networks[C]//Proceedings of 2018 IEEE/WIC/ACM International Conference on Web Intelligence. Santiago, Chile, 2018: 647–650.
- [11] 李江昀, 赵义凯, 薛卓尔, 等. 深度神经网络模型压缩综述[J]. 工程科学学报, 2019, 41(10): 1229–1239.  
LI Jiangyun, ZHAO Yikai, XUE Zhuoer, et al. A survey of model compression for deep neural networks[J]. Chinese journal of engineering, 2019, 41(10): 1229–1239.
- [12] 纪荣嵘, 林绍辉, 晁飞, 等. 深度神经网络压缩与加速综述[J]. 计算机研究与发展, 2018, 55(9): 1871–1888.  
JI Rongrong, LIN Shaohui, CHAO Fei, et al. Deep neural network compression and acceleration: a review[J]. Journal of computer research and development, 2018, 55(9): 1871–1888.
- [13] 王晓华, 杨新艳, 焦李成. 基于多尺度几何分析的复杂网络压缩策略[J]. 电子与信息学报, 2009, 31(4): 968–972.  
WANG Xiaohua, YANG Xinyan, JIAO Licheng. Compression of complex networks based on multiscale geometric analysis[J]. Journal of electronics & information technology, 2009, 31(4): 968–972.
- [14] YU Jie, TIAN Shen. A review of network compression based on deep network pruning[C]//Proceedings of the 3rd International Conference on Mechatronics Engineering and Information Technology. Dalian, China, 2019: 324–335.
- [15] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors[J]. Computer Science, 2012, 3(4): 212–223.
- [16] BALDI P, SADOWSKI P. The dropout learning algorithm[J]. Artificial intelligence, 2014, 210: 78–122.
- [17] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229–1251.  
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. Chinese journal of computers, 2017, 40(6): 1229–1251.
- [18] 李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508–2515, 2565.  
LI Yandong, HAO Zongbo, LEI Hang. Survey of convolutional neural network[J]. Journal of computer applications, 2016, 36(9): 2508–2515, 2565.
- [19] 陈先昌. 基于卷积神经网络的深度学习算法与应用研究[D]. 杭州: 浙江工商大学, 2014.  
CHEN Xianchang. Research on algorithm and application of deep learning based on convolutional neural network[D]. Hangzhou: Zhejiang Gongshang University, 2014.
- [20] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, USA, 2014: 580–587.
- [21] 刘亦芃. 一种关于深度学习网络结构的改进策略[D]. 长春: 吉林大学, 2019.  
LIU Yipeng. A strategy for improving the structure of deep learning network[D]. Changchun: Jilin University, 2019.
- [22] 杨国亮, 许楠, 李放, 等. 关于非线性激活函数的深度学习分类方法研究[J]. 江西理工大学学报, 2018, 39(3): 76–83.  
YANG Guoliang, XU Nan, LI Fang, et al. Research on deep learning classification for nonlinear activation function[J]. Journal of Jiangxi University of Science and Technology, 2018, 39(3): 76–83.
- [23] 张永雄, 王亮明, 李东. 基于多示例深度学习与损失函数优化的交通标志识别算法[J]. 现代电子技术, 2018, 41(15): 133–136, 140.  
ZHANG Yongxiong, WANG Liangming, LI Dong. Traffic sign recognition algorithm based on multi-instance deep learning and loss function optimization[J]. Modern electronics technique, 2018, 41(15): 133–136, 140.
- [24] WAN Li, ZEILER M, ZHANG Sixin, et al. Regularization of neural networks using dropconnect[C]//Proceedings of the 30th International Conference on Machine Learning. Atlanta, GA, USA, 2013: 1058–1066.
- [25] 徐玉华, 曾明. 泊松分布性质及应用研究[J]. 长江大学学报(自科版), 2006, 04: 132–133.  
XU Yuhua, ZENG Ming. Poisson distribution properties and application research[J]. Journal of Yangtze University (Natural Science Edition), 2006, 04: 132–133.


#### 作者简介:



沙芸, 副教授, 主要研究方向医疗数据挖掘、模式识别。



李齐飞, 硕士研究生, 主要研究方向为深度学习。



甘建旺, 硕士研究生, 主要研究方向为图像处理与机器学习。

## 全球人工智能 AI 2021 技术创新大赛 GLOBAL AI INNOVATION CONTEST

首届全球人工智能技术创新大赛(Global AI Innovation Contest)是由中国人工智能学会和杭州市余杭区人民政府共同创办,由杭州市未来科技城管委会、阿里云计算有限公司、清华-OPPO 未来终端技术研究中心联合承办,职场社交平台脉脉为大赛提供宣传支持。大赛将立足国际视野,聚焦前沿科技与应用创新,推进人工智能领域的学术交流、人才培养、技术发展以及跨界应用与融合,打造人工智能的人才交流平台与产业生态圈。本次大赛面向全球开放,设置医学影像报告异常检测、PANDA 大场景多对象检测跟踪、小布助手对话短文本语义匹配三个智能算法赛道,欢迎相关领域的开发者、学生和研究人员积极参与,突破其中的关键性瓶颈,推进下一代人工智能前瞻性研究发展。

### 参赛对象:

本次大赛面向全球开放,不限年龄国籍,高等院校在校学生(包括高职高专、本科、研究生)以及科研机构和企业从业人员均可参赛,具体要求如下:

可以自由组队参赛,具体组队要求见赛道相关说明;

参赛选手应保证报名信息准确有效,如队伍中的选手信息不符合要求,组委会有权取消整个队伍的参赛资格及奖励。

为了保证大赛的公平性,将禁止以下类型人员报名参赛:

大赛主办和技术支持单位如有机会接触赛题和相关数据的人员不允许参赛;

赞助企业的在职人员(不含实习生)不允许参赛。

### 赛程安排:

报名和组队: 2021 年 1 月 15 日—2021 年 4 月 7 日

初赛 A 榜: 2021 年 3 月 2 日—2021 年 4 月 7 日

初赛 B 榜: 2021 年 4 月 8 日

复赛: 2021 年 4 月 15 日—2021 年 5 月 10 日

总决赛: 2021 年 5 月下旬

### 组织机构:

主办单位: 中国人工智能学会、杭州市余杭区人民政府

承办单位: 杭州未来科技城管委会、阿里云计算有限公司、清华 OPPO 未来终端技术研究中心