

文章编号:1007-5321(2020)03-0038-07

DOI:10.13190/j.jbupt.2019-127

基于改进 CNN 的阀门泄漏超声信号识别方法

宁方立^{1,2}, 韩鹏程^{1,2}, 段爽^{1,2}, 李航^{1,2}, 韦娟³

(1. 西北工业大学 机电学院, 西安 710072; 2. 东莞市三航军民融合创新研究院, 东莞 523808;

3. 西安电子科技大学 通信工程学院, 西安 710071)

摘要: 为了检测输气管道阀门泄漏,对改进 AlexNet 网络结构进行了研究,提出了基于改进卷积神经网络(CNN)的阀门泄漏超声信号识别方法. 针对泄漏信号短时稳定的窄带线谱特征,从图像邻域信息密度角度出发,将卷积核形状由图像识别领域通常使用的“正方形”改进为“扁横状”. 同时,对 AlexNet 层数进行优化,重新确定卷积核和全连接层神经元数目,并选择小尺寸卷积核,在减少参数量的同时增加网络容量和模型复杂度,防止模型出现过拟合. 分别建立二分类和不同泄漏量下的多分类模型,通过输气管道实验平台采集阀门泄漏数据集,生成对应时频图样本,包括不同阀门开度、不同管道压力下的泄漏及背景声信号. 结果表明,对比传统的 CNN 分类模型,改进 CNN 分类模型在测试集上取得了更高的识别性能.

关键词: 卷积核; 短时傅里叶变换; 卷积神经网络; 阀门; 泄漏检测

中图分类号: TP391

文献标志码: A

Identification Method of Valve Leakage Ultrasonic Signal Based on Improved CNN

NING Fang-li^{1,2}, HAN Peng-cheng^{1,2}, DUAN Shuang^{1,2}, LI Hang^{1,2}, WEI Juan³

(1. School of Mechanical Engineering, Northwestern Polytechnical University, Xi'an 710072, China;

2. Dongguan Sanhang Civil-military Integration Innovation Institute, Dongguan 523808, China;

3. School of Telecommunications Engineering, Xidian University, Xi'an 710071, China)

Abstract: In order to detect valve leakage in gas pipelines, an improved AlexNet network architecture is studied, an ultrasonic signal recognition method for valve leakage based on an improved convolutional neural network (CNN) is proposed. Due to short-term and narrow-band line spectrum features of the leakage signals, the “square” convolution kernel, commonly used in image recognition, is changed to “flat” based on the perspective of image neighborhood information density. At the same time, the AlexNet layers are optimized, the number of convolution kernel and neurons in the fully connected layers are re-determined, and the small-scale convolution kernel is selected to increase the network capacity and model complexity while reducing the number of parameters to prevent model overfitting. The two-class and multi-class models with different leakages are established respectively, and the data set is collected through experiments to generate corresponding time-frequency diagram samples as well, including leakage signals at different valve openings and pipeline pressures and background acoustic signals. It is shown that the improved CNN classifier achieves higher recognition performance on the test set than the tradi-

收稿日期: 2019-07-01

基金项目: 国家自然科学基金项目(51675425); 陕西省重点研发计划项目(2020ZDLGY06-09); 2018 年东莞市社会科技发展(重点)项目(20185071021600)

作者简介: 宁方立(1974—), 男, 教授, 博士生导师, E-mail: ningfl@nwpu.edu.cn.

tional CNN classifier.

Key words: convolution kernel; short-time Fourier transform; convolutional neural network; valve; leakage detection

高压输气管道阀门在使用过程中会受到气体压力、温度和振动腐蚀影响,不可避免地产生泄漏,造成重大经济损失和人员伤亡。目前,输气管道气体泄漏检测技术的研究对于防止阀门泄漏事故发生具有重大工程意义^[1-3]。其中,音波法^[4]具有不受限于气体类型、灵敏度高等优点,可在线连续地检测管道运行状态。但是音波法采集的信号频率在可听声范围内,容易受到其他环境声信号干扰而发生虚警。超声检测法^[5]使用 38 ~ 42 kHz 频带范围内的声压幅值阈值作为泄漏发生的判别准则,该方法使用的超声检测设备已商业化,但其效率低、实时性差。阀门气体泄漏还会在空气中产生不同于环境背景声的宽频超声信号,可用于对阀门泄漏进行识别。

卷积神经网络(CNN, convolutional neural network)是一种有监督的深度学习算法,广泛应用于语音识别、文本分类、图像处理等领域^[6]。随着深度学习不断发展,基于 CNN 的智能故障诊断^[7]逐渐成为设备状态监测研究主流,因此可以应用 CNN 对阀门气体泄漏产生的超声信号进行特征提取,识别出泄漏源。CNN 中卷积核通过模拟人类视野感受野,依次与输入不同位置的图像块做卷积提取特征,基于邻域信息密度假设,卷积核形状一般设计为“正方形”,如 AlexNet^[8]和 VGGNet^[9]等经典网络均采用 $n \times n$ 的卷积核提取特征, n 为卷积核尺寸。目前,一些学者对卷积核尺寸大小和模型性能之间的关系做了研究。Simonyan 等^[9]通过反复堆叠 3×3 小尺寸卷积核,减少参数的同时增加了网络深度,提高了模型性能;Szegedy 等^[10]提出将大尺寸卷积核分解为小尺寸卷积核,减小运算量,加速模型训练。

笔者在对 AlexNet 网络结构优化的基础上,提出对卷积核形状进行改进,更好地提取阀门气体泄漏超声信号时频域特征,建立基于改进 CNN 的阀门气体泄漏超声信号分类模型。通过和传统基于“正方形”卷积核的 CNN 分类模型进行比较,验证基于“扁横状”卷积核的 CNN 分类模型在阀门气体泄漏超声信号识别方面的优势。

1 阀门泄漏超声信号表征

短时傅里叶变换(STFT, short-time Fourier

transform)通过时频联合分析,将阀门气体泄漏信号转化为保留了原始时频域信息的二维时频图。

STFT 将原始时域信号和窗函数相乘,进行一维傅里叶变换,通过窗函数的滑动得到一系列傅里叶变换结果,具体运算为

$$\text{STFT}_z(t, f) = \int_{-\infty}^{\infty} [z(t)g(t-\tau)e^{-j2\pi f\tau}d\tau] \quad (1)$$

其中: $z(t)$ 为原始信号, $g(t-\tau)$ 为中心位于 τ 时刻的窗函数。

在 STFT 过程中,窗函数长度和窗口重叠宽度决定了时间分辨率和频率分辨率,具体运算为

$$T = \left\lfloor \frac{N_x - N_0}{N_w - N_0} \right\rfloor \quad (2)$$

$$F = \begin{cases} \frac{N_w}{2} + 1, & N_w \text{ 是偶数} \\ \frac{N_w + 1}{2}, & N_w \text{ 是奇数} \end{cases} \quad (3)$$

其中: T 为时间分辨率, F 为频率分辨率, $\lfloor \cdot \rfloor$ 表示向下取整运算, N_x 为参与 STFT 的样本长度, N_w 为窗函数长度, N_0 为窗口重叠宽度。

将时频图分辨率 P 定义为

$$P = T \times F \quad (4)$$

P 值大小即是 CNN 分类模型输入特征图的大小。通过阀门气体泄漏超声信号样本长度选择合适的窗长和窗口重叠长度,可以更清晰地表征出其时频域信息。图 1 所示为阀门气体泄漏超声信号时频图。分析可知,在 20 ~ 40 kHz 超声频率段内,原始信号被表征为具有窄带线谱特征的时频图。在不同管道压力和阀门开度泄漏条件下,同样频率位置也存




图1 阀门气体泄漏超声信号时频图

在类似的呈横向纹理的窄带线谱特征.

2 改进 CNN 的信号分类模型

2.1 改进卷积核的 CNN

CNN 在图像处理方面有很大优势,卷积层可以对阀门气体泄漏超声信号特征进行自适应提取. 假设第 l 层为卷积层,第 $l-1$ 层为池化层或输入层,则

$$x_n^l = f \left(\sum_m x_m^{l-1} \otimes k_{m,n}^l + b_n^l \right) \quad (5)$$

其中: x_n^l 为第 l 层输出的 n 个特征图, x_m^{l-1} 为第 l 层输入的 m 个特征图, k 为卷积核, b 为偏置项, \otimes 表示卷积操作, $f(\cdot)$ 为激活函数.

卷积核尺寸大于 1×1 时,提取特征需要邻域信息. 在图像识别任务中,通常提取的纹理种类比较丰富,横向邻域信息密度和纵向邻域信息密度相当,因此卷积核形状设计为“正方形”. 而阀门气体泄漏超声信号时频图呈横向纹理的窄带线谱特征,横向邻域信息密度比纵向邻域信息密度高,因此,笔者提出采用“扁横状”卷积核进行阀门气体泄漏超声信号特征提取. 即每一个卷积层中,卷积核在特征图频域上的尺寸要小于在时域上的尺寸.

CNN 以损失函数作为误差,采用误差反向传播和优化算法最小化损失函数更新卷积层和全连接层的权重和偏置值,建立分类模型.

选择交叉熵函数作为损失函数,定义为

$$L = - \sum_{i=1}^N y_i \lg \hat{y}_i + (1 - y_i) \lg (1 - \hat{y}_i) \quad (6)$$

其中: N 为某批次样本数, y_i 为真实的类别标签, \hat{y}_i 为预测的类别概率值.

2.2 分类模型建立

在参考 AlexNet 等经典网络设计思路基础上,对模型超参数调整,通过多次预训练确定卷积层和池化层中的核尺寸和数目、全连接层的神经元数目和层数,建立基于 CNN 的阀门气体泄漏超声信号分类模型. 具体结构如表 1 所示.

3 个卷积层中,“扁横状”卷积核在时域和频域使用不同尺寸,分别为 5×3 、 3×1 和 3×1 . 这样一种小尺寸卷积核处理参考了 VGGNet 设计思路:减小卷积核尺寸,增加网络容量和模型复杂度. Conv-1 层卷积核滑动步长和卷积核尺寸保持一致,有效地减小输出特征图尺寸,并选择 Relu 函数^[11]作为激活函数.

为了更多地保留输入层纹理信息,采用最大池

表 1 “扁横状”卷积核的 CNN 分类模型结构

层名称	核尺寸和数目	滑动步长	Padding	特征图尺寸
Input				$513 \times 513 \times 3$
Conv-1	$5 \times 3 \times 16$	5×3	SAME	$103 \times 171 \times 16$
Pool-1	3×3	3×3	SAME	$35 \times 57 \times 16$
Conv-2	$3 \times 1 \times 32$	1×1	SAME	$35 \times 57 \times 32$
Pool-2	3×3	3×3	SAME	$12 \times 19 \times 32$
Conv-3	$3 \times 1 \times 64$	1×1	SAME	$12 \times 19 \times 64$
Pool-3	3×3	3×3	SAME	$4 \times 7 \times 64$
Fc-1				128
Fc-2				2

化^[12]进行池化操作. 3 个池化层中,池化核尺寸均为 3×3 . 同样地,池化核滑动步长和尺寸保持一致,因此输出特征图尺寸为原来的 $1/3$.

卷积层和池化层进行特征提取和降维,观察输出特征图的尺寸,当 Pool-3 层输出特征图的尺寸为 $4 \times 7 \times 64$ 时,不再加深卷积层和池化层,而是把 $4 \times 7 \times 64$ 的二维特征图拉伸为一维向量和全连接层连接.

设计 2 个全连接层,第 1 个全连接层把提取的局部特征通过权值矩阵重新组合,第 2 个全连接层输出预测的类别.

2.3 信号识别流程

基于 CNN 的阀门气体泄漏超声信号识别方法将原始信号表征、特征提取和识别统一到 1 个框架下,如图 2 所示. 首先将样本划分为“泄漏”类和“正常”类,“泄漏”类包括输气管道各泄漏条件下的实验样本,“正常”类包括实验室环境背景样本,对“泄漏”类样本和“正常”类样本进行 STFT 得到时频图,建立输气管道阀门气体泄漏数据集. 数据集划分为训练集、验证集和测试集,将训练集输入基于“扁横状”卷积核的 CNN 中,不断地更新权重和偏置值学习阀门气体泄漏超声信号特征,根据验证集结果对模型超参数进行调整,多次预训练后建立最优分类模型,通过计算测试集在最优分类模型上的指标,评估模型性能.

3 实验及结果分析

3.1 阀门泄漏频谱分析

在实验室搭建阀门气体泄漏实验平台,如图 3 所示. 实验平台主要针对次高压燃气管道,设计管道最大压力为 1.2 MPa.

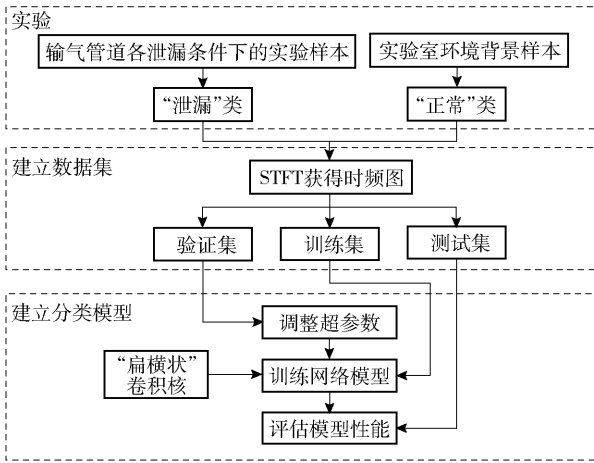


图 2 阀门气体泄漏超声信号识别方法流程



图 3 阀门气体泄漏实验平台


主管道和支管道末端装有 6 个法兰球阀,实验时手动打开法兰球阀至某一开度,模拟不同位置、不同流量的泄漏,流量计记录阀门气体泄漏过程中流量大小. 通过实验室已有的 16 通道超声传声器阵列采集信号,采样频率为 96 kHz.

图 4(a) 为流量在 0.4 m³/h 时,不同管道压力下阀门气体泄漏超声信号频谱图. 图 4(b) 为管道压力在 0.7 MPa 时,不同阀门开度下阀门气体泄漏超声信号频谱图,以流量计显示流量表示阀门开度大小. 为了消除可听声范围内环境噪声的影响,只对 20 ~ 40 kHz 超声频率段进行分析.


由图 4 可知,管道压力和阀门开度越大,泄漏流量越大,泄漏产生的超声信号声压级幅值越大. 在不同管道压力、阀门开度下,虽然声压级幅值大小不同,但频谱基本走势相同,表现出超声锁频特性.

3.2 数据集建立

利用 STFT 对样本长度为 1 s 的阀门气体泄漏超声信号进行表征,选择窗长为 1 024 个采样点,窗口重叠宽度为 838 个采样点,根据式(4)得到分辨率为 513 × 513 的时频图. 图 5 为流量在 0.4 m³/h、管道压力在 0.7 MPa 条件下阀门气体泄漏和某时刻实验室环境超声信号时频图.



(a) 不同管道压力下的信号频谱



(b) 不同阀门开度下的信号频谱

图 4 阀门气体泄漏实验频谱分析

由 3.1 小节频谱分析和图 5(a) 可知,阀门气体泄漏超声信号在频域上主要包括宽带连续谱和窄带线谱,宽带连续谱声压级幅值会随着不同泄漏条件发生变化,但是幅值较高的窄带线谱出现位置是一样的,而在时域上窄带线谱具有连续性,贯穿了整个短时域. “扁横状”卷积核 CNN 分类模型可以提取这种稳定的窄带线谱进行识别.

由图 5(b) 可知,虽然可听声范围内实验室环境声已经被截掉,但是在 20 ~ 40 kHz 超声频率段内,由于电路噪声和其他环境中超声信号的影响,在时频图上会存在窄带线谱噪声,这些噪声具有时变性和不稳定性,对模型的抗干扰能力有了更高要求.

分别采集 6 个法兰球阀在阀门开度为 0.4 m³/h、0.2 m³/h、0.15 m³/h,管道压力为 0.9 MPa、0.7 MPa、0.5 MPa 下的泄漏信号,进行时频图表征作为“泄漏”类样本,采集不同时刻实验室环境声作为“正常”类样本,构建输气管道阀门气体泄漏数据集. 数据集包括 7 970 (4 208 个“泄漏”类和 3 762 个“正常”类) 个训练集样本,以及同分布的 500 个验证集样本和 1 500 个测试集样本. 其中,训练集和验证集包含 5 个阀门的泄漏数据,测试集包含另外 1 个阀门的泄漏数据,可以有效地评估模型泛化能力.




图5 阀门气体泄漏和实验室环境超声信号时频图

保证训练集、验证集和测试集无交叉,处理的为非同批次数据集样本。

3.3 性能对比分析

为了验证“扁横状”卷积核 CNN 分类模型在阀门气体泄漏超声信号识别方面的优势,建立传统“正方形”卷积核的 CNN 分类模型进行比较.除了每一个卷积层中均采用 3×3 的“正方形”卷积核,其他结构参数和基于“扁横状”卷积核的 CNN 分类模型设计思路一致。

图 6(a)和(b)分别为训练集在 2 个 CNN 分类模型上损失函数和准确率随训练步数变化的情况。

由图 6 可知,在“扁横状”卷积核作用下,训练步数增加到 5 456 步时,模型收敛;在“正方形”卷积核作用下,训练步数增加到 3 534 步时,模型收敛.此时,2 个模型的损失函数稳定在 0.05 左右,准确率稳定在 97% 左右。

分别计算测试集在 2 个分类模型上的指标,如表 2 所示。

相比于传统“正方形”卷积核的 CNN 分类模型,在“扁横状”卷积核作用下,召回率由 0.947 提高到 1.000,而精度由 1.000 下降到 0.988,但是精度和召回率的调和平均数 F1-score 由 0.973 提高到




图6 训练集在 2 个 CNN 分类模型上的训练过程

0.994,模型性能有了很大提高。

虽然在“扁横状”卷积核作用下,CNN 分类模型虚警率由 0 上升到 0.018,但是漏警率由 0.053 下降到 0,这也更加满足实际工程需要,因为发生漏警的代价更大.除此之外,测试集识别准确率由 96.90% 提高到 99.25%. 因此,通过设计“扁横状”卷积核,能更好地学习到阀门气体泄漏超声信号窄带线谱特征。

表 2 CNN 分类模型性能比较

模型	召回率	精度	F1-score	漏警率	虚警率	识别准确率/%
“扁横状”卷积核	1.000	0.988	0.994	0	0.018	99.25
“正方形”卷积核	0.947	1.000	0.973	0.053	0	96.90

表 3 为 2 个 CNN 分类模型训练过程、测试过程和识别过程的计算时间对比. 其中,测试过程即计算测试集准确率和 F1-score,识别过程是对单个样本识别,判断其是“泄漏”类还是“正常”类。

在训练过程中,“扁横状”卷积核的 CNN 分类模型用时 2 897 s,“正方形”卷积核的 CNN 分类模型用时 1 967 s. 前者在提高模型性能的同时,牺牲了计算效率。

表 3 CNN 分类模型的计算效率对比

模型	训练过程/s	测试过程/s	识别过程/s
“扁横状”卷积核	2 897	8. 693	2. 753
“正方形”卷积核	1 967	8. 660	2. 738

在测试过程中,“扁横状”卷积核和“正方形”卷积核的 CNN 分类模型用时都在 8.6 s 左右,同样地,在识别过程中 2 个模型用时都在 2.7 s 左右. 因为测试过程和识别过程都是加载训练好的模型,通过一次前向传播输出测试结果和识别结果,其计算效率主要和计算机性能有关.


在实际的阀门气体泄漏检测中,训练过程和测试过程都是离线完成的,应该以识别过程时间作为评价 CNN 分类模型计算效率的标准. 即 2 个模型对单个样本识别时间基本一样,均在 2.7 s 左右.

3.4 多分类模型建立


对所建立的数据集重新划分为 6 个类别,包括 0.5、0.4、0.3、0.2、0.15 m³/h 不同流量下泄漏和背景声信号. 分别将“扁横状”卷积核和“正方形”卷积核作用在重新划分的数据集上,对模型超参数调整,建立基于 CNN 的阀门气体泄漏超声信号多分类模型.

图 7(a) 和 7(b) 分别为训练集在 2 个 CNN 多分类模型上损失函数和准确率随训练步数变化的情况.

由图 7 可知,在“扁横状”卷积核作用下,训练步数增加到 16 306 步时,模型收敛;在“正方形”卷



(a) 损失函数随训练步数变化的情况



(b) 准确率随训练步数变化的情况

图 7 训练集在 2 个 CNN 多分类模型上的训练过程

积核作用下,训练步数增加到 14 880 步时,模型收敛. 此时,2 个模型的损失函数稳定在 0.15 左右,准确率稳定在 95% 左右.

分别计算测试集在 2 个多分类模型上的总体识别准确率和每一类的识别准确率,如表 4 所示.

表 4 CNN 多分类模型的识别准确率比较

模型	总体识别 准确率	流量/(m ³ ·h ⁻¹)					背景
		0.5	0.4	0.3	0.2	0.15	
“扁横状”卷积核	94.56	100.00	90.60	94.92	94.92	86.44	98.64
“正方形”卷积核	92.49	92.00	88.00	89.29	96.61	92.85	100.00

相比于二分类模型,多分类模型识别准确率有所降低. 因为不同管道压力和阀门开度下,阀门气体泄漏超声信号的多分类是一种细粒度分类,类别数更多,分类情况更复杂.

在“扁横状”卷积核作用下,虽然无法提高每一类的识别准确率,但是总体识别准确率由 92.49% 提高到 94.56%,因此在二分类模型和多分类模型中,“扁横状”卷积核都能更好地学习到阀门气体泄漏超声信号窄带线谱特征.

4 结束语

通过分析不同管道压力和阀门开度下阀门气体泄漏超声信号的频谱特点,利用 STFT 对其进行表征. 针对阀门气体泄漏超声信号时频域特征,提出对 AlexNet 网络结构进行优化,对卷积核形状进行改进,建立改进 CNN 的分类模型对阀门气体泄漏超声信号进行识别,得出以下结论.

1) 阀门气体泄漏超声信号具有短时稳定的窄带线谱特征,基于 STFT 的方法能够很好地对其进

行时频图表征。

2) 相比于传统“正方形”卷积核,“扁横状”卷积核的 CNN 分类模型可以有效地提取阀门气体泄漏超声信号窄带线谱特征。测试集在“扁横状”卷积核的 CNN 二分类和多分类模型上,取得了更高的识别性能,为输气管道阀门气体泄漏检测领域提供了一种高识别率的新方法。

参考文献:

- [1] Murvay P S, Silea I. A survey on gas leak detection and localization techniques[J]. Journal of Loss Prevention in the Process Industries, 2012, 25(6): 966-973.
- [2] Sheltami T R, Bala A, Shakshuki E M. Wireless sensor networks for leak detection in pipelines: a survey[J]. Journal of Ambient Intelligence and Humanized Computing, 2016, 7(3): 347-356.
- [3] Liu Cuiwei, Li Yuxing, Yan Yukun, et al. A new leak location method based on leakage acoustic waves for oil and gas pipelines[J]. Journal of Loss Prevention in the Process Industries, 2015, 35: 236-246.
- [4] 刘翠伟, 李雪洁, 李玉星, 等. 基于音波法的输气管道泄漏检测与定位[J]. 化工学报, 2014, 65(11): 4633-4642.
Liu Cuiwei, Li Xuejie, Li Yuxing, et al. Leak detection and location for natural gas pipelines based on acoustic waves[J]. Journal of Chemical Industry and Engineering, 2014, 65(11): 4633-4642.
- [5] Liao Pingping, Cai Maolin. Study on compressed air leak detection using ultrasonic detection technology and instrument[C] // Conference on Industrial Electronics and Applications. Beijing: IEEE, 2011: 1690-1693.
- [6] Zhou F, Jin L, Dong J. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [7] Lu Chen, Zhou Bo, Wang Zhenya. Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification[J]. Advanced Engineering Informatics, 2017, 32(2): 139-151.
- [8] Krizhevsky A, Sutskever I, Hinton G E, et al. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [9] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[C] // Computer Vision and Pattern Recognition. Columbus: [s. n.], 2014: 1-14.
- [10] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C] // Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 2818-2826.
- [11] Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines[C] // International Conference on Machine Learning. Haifa: [s. n.], 2010: 807-814.
- [12] Boureau Y, Ponce J, Lecun Y, et al. A theoretical analysis of feature pooling in visual recognition[C] // International Conference on Machine learning. Haifa: [s. n.], 2010: 111-118.