

基于深度学习的锂电池褶皱检测方法的研究

王 刚 官元九*

(辽宁大学信息学院 辽宁 沈阳 110036)

摘 要 为了解决锂电池褶皱检测问题,提出基于深度学习的褶皱检测方法。CNN 是在实际应用中最成功的深度神经网络,能够很好地实现分类。提出 CNN 来解决锂电池褶皱检测的方法:收集锂电池 X 光照片;人工把锂电池 X 光照片分为无褶皱和有褶皱两种,并标注;将数据集放入构建的 CNN 模型中训练学习。在数据集充足的情况下,通过大量实验表明:该方法的准确率能够达到 99%,相对于原始的凭借经验、人工观察检测的方法有很大提升。

关键词 深度学习 CNN 锂电池褶皱检测

中图分类号 TP3 文献标识码 A DOI:10.3969/j.issn.1000-386x.2019.01.039

LITHIUM BATTERY WRINKLE DETECTION METHOD BASED ON DEEP LEARNING

Wang Gang Gong Yuanjiu*

(College of Information, Liaoning University, Shenyang 110036, Liaoning, China)

Abstract In order to solve the problem of lithium battery wrinkle detection, we proposed a wrinkle detection method based on deep learning. CNN is the most successful deep neural network in practical applications. It can achieve good classification. CNN was put forward to solve the problem of lithium battery wrinkle detection. We collected the X-ray photo of the lithium battery. The X-ray photo of the lithium battery was manually divided into two types: no wrinkles and wrinkles, and we marked them. The data set was put into the constructed CNN model for training and learning. With sufficient data sets, a large number of experiments have shown that the accuracy of the CNN-based lithium battery wrinkle detection method can reach 99%. Compared with the original experience, and manual observation and detection methods, it has been a big improvement.

Keywords Deep learning CNN Lithium battery wrinkle detection

0 引 言

锂电池作为手机、PAD、笔记本电脑、数码相机等电子设备的主要能源。随着电子设备的普及,对锂电池产量的需求也越来越大^[1]。在锂电池的生产过程中,由于隔膜在缠绕的过程中与锂电池板结合的不紧密(出现气泡)或者工作人员在生产过程中对锂电池板有挤压。这些原因都会导致锂电池褶皱,使电池性能严重下滑。这部分电池必须在出厂前挑出来重新处理。目前,锂电池生产厂家对锂电池褶皱的检测方法是采用人工判断的方法。主要依赖于人工的感觉和经

验,效率低而且容易受到外界环境和心态的影响。

提出基于深度学习的锂电池褶皱检测的方法,深度学习模型是卷积神经网络模型。模型是由 6 层组成:一个输入层、三个卷积-池化层、一个全连接层、一个 softmax 层和一个输出层。为了能得到更适合锂电池褶皱检测的模型,选取了 10 403 个无褶皱和 10 081 个有褶皱 X 光图像作为数据集。使用 BP 算法求出最合适的权重和偏执,更好地提高模型的性能。还添加了 softmax 层,softmax 评分函数可以更精准地分类。经过大量实验,结果表明:基于深度学习的锂电池检测成功率能达到 99%,而且检测速度低于 100 ms,符合锂电池生产流水线的基本要求。

1 模型与方法

1.1 模型

近年来,卷积神经网络在图像分类方面取得了很大的突破,达到令人满意的效果,并且能够自动实现分类,不需要人工干预。这些是选择 CNN 的主要原因。

目前, CNN 模型主要有 LeNet-5^[2]、AlexNet^[3]、Overfeat^[4]、VGG^[5]、GoogLeNet^[6]、ResNet^[7] 等。本文选用 Yann LeCun 教授提出的 LeNet-5^[2] 模型,并对模型加以改进,实现锂电池褶皱的检测效果。

本文锂电池褶皱的检测流程图如图 1 所示。




图 1 锂电池褶皱检测流程图

1.2 图像归一化处理

图像归一化处理是对图像进行一系列标准的处理变换,使之变换为一固定标准形式的过程。转换后的标准图像对平移、旋转、缩放等仿射变换具有不变性^[8],为之后的数据集生成做准备。本文采用线性归一化方式,把输入的数据转换到 $[0, 1]$ 的范围,公式如下:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

该方法实现对原始数据的等比例缩放,其中 X_{norm} 为归一化后的数据, X 为原始数据, X_{max} 、 X_{min} 分别为原始数据集的最大值和最小值。将归一化的数据 X_{norm}

乘以 255 得到新的 X_{norm} , 公式如下:

$$X_{norm} = 255 \times X_{norm} \quad (2)$$

新的 X_{norm} 数据是分布在 $[0, 255]$ 的范围,经过一系列转换后,图像的对比度增强,特征更明显。图像处理前后的对比图如图 2 所示。




图 2 图像处理前后对比图

1.3 数据集的制作

深度学习的过程中需要大量的有标注的数据进行训练学习。在锂电池生产领域里,保密性很强,很难获得足够的数据集。本文数据集是通过将 X 光照片人工分为有褶皱和无褶皱两类,并且对它们进行分别标注,达到制作数据集的目标。

为了满足工业生产要求制作数据集的效率要足够高,数据集要尽量数字化。数据集在制作前需要图片预处理。首先将图片要转换成矩阵数据,将图像标准化。标准化公式如下:

$$X^* = \frac{X - V}{255} \quad (3)$$

该方法实现对矩阵数据的等比例缩小且去除差异较明显的干扰,其中 X^* 为标准后的数据, X 为原始数据, V 为 X 的均值。

将数据集进行标注,无褶皱的标注为 1,有褶皱的标注为 0。

将数据值和标注打包并压缩成可以使用的数据集文件。

1.4 改进的 LeNet-5 模型

传统的卷积神经网络是由输入层、卷积层、池化层、输出层组成。本文模型是基于 LeNet-5 模型上进行改进的,称为 ILeNet-5,模型的结构图如图 3 所示。




图 3 ILeNet-5 模型结构图

1.4.1 输入层

输入层的作用加载数据集。本文的输入是由 66×66 个神经元构成。

1.4.2 卷积层

卷积层根据多个一定的权重(即卷积核),对一个块的像素进行内积运算,其输出就是提取的特征。3个超参数控制着输出数据体的尺寸:深度(depth),步长(stride)和零填充(zero-padding)。公式如下:

$$\frac{(W - F + 2P)}{S} + 1 \quad (4)$$

该方法实现对卷积核 F 大小的确定,其中 W 为输入数据的尺寸, P 为是否使用零填充, S 为步长,所得的结果需为整数,且 F 的值一般为奇数。有了这些条件,能够很容易地推断出卷积核的大小。

卷积层使用的代价函数是极大似然代价函数,公式如下:

$$C = -\ln a_y^L \quad (5)$$

式中: C 为代价函数的代价,可以看出当输出比较接近目标值时,概率 a 接近1,对数 C 接近0。反之概率较小时,对数 C 比较大。

卷积层使用的激活函数是ReLU激活函数。ReLU不会像Sigmoid函数、Tanh函数容易饱和。ReLU函数公式如下:

$$f(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad (6)$$

$x \geq 0$ 时,梯度恒为1,无梯度耗散问题,收敛快;增大了网络的稀疏性。当 $x < 0$ 时,该层的输出为0,训练完成后为0的神经元越多,稀疏性越大,提取出来的特征就约具有代表性,泛化能力越强。即得到同样的效果,真正起作用的神经元越少,网络的泛化性能越好。运算量很小,训练时间少。

ILeNet-5模型具有3个卷积层。第一个卷积层选用20个大小为 11×11 ,步长为1的卷积核。第二个卷积层选用40个大小为 5×5 ,步长为1的卷积核。第三个卷积层选用80个大小为 5×5 ,步长为1的卷积核。

1.4.3 池化层

池化的作用是负责将下层提取到的特征进行采样,缩小网络规模。池化的方法有很多。如Max Pooling、Average Pooling、Overlapping Pooling等^[9]。本文均采用的池化尺寸为 2×2 ,步长为1的下采样方式。

1.4.4 全连接层

全连接层的每一个结点都与上一层的所有结点相连,用来把前边提取到的特征综合起来。经过最后一个池化层生成了80个 4×4 的特征图构成1280个神经元,输出是1000个神经元构成。全连接用的激活

函数是ReLU激活函数。为了防止过拟合现象出现,在全连接层使用了Dropout的方法。使用Dropout可以让原始复杂的网络,变得简单起来,又能很好地解决过拟合问题。

1.5 评分算法与整合

这里用的是softmax评分函数。其公式如下:

$$a_j^L = \frac{e^{z_j^L}}{\sum_k e^{z_k^L}} \quad (7)$$

a 为评分值,这些值被映射到 $(0,1)$ 之间,且这些值的累加和为1。符合概率分布。可以将softmax评分函数评分之后输出两个神经元,通过调节阈值为0和1两类。

2 实验

2.1 实验数据

本文的实验数据是一个横向项目单位提供的,在网络上很难找到这些X光照片。其中包含了10403个无褶皱和10081个有褶皱X光照片,如图4所示。




图4 实验数据图

无褶皱的X光图像纹理是平行的,有褶皱的X光图像纹理是杂乱无章的。本文所有的X光照片尺寸大小都是 66×66 ,皆为灰度图像。

2.2 训练策略

本文的数据集是将两种类型的图像处理之后混合打散,选择前16000个数据作为训练集,选择16001~18000的数据作为验证集。选择18001~20484的数据作为测试集。训练集是为了训练模型利用BP算法找到最优的weight和bias;验证集的作用是为了能够帮助选择超参数,例如学习率、惩罚因子等;测试集的作用是检验模型的泛化能力,衡量模型的分類能力,对模型性能的评价。

2.3 实验环境

实验使用theano^[10]框架,是在Win7操作系统下,CPU为CORE i5。开发工具是Pycharm + Anaconda,用的是Python 2.7版。运行过程中,迭代10次。训练结束大约需要时间2h。识别一条数据的时间大约为20ms左右。

2.4 实验结果与分析

10 次迭代的运行结果如表 1 所示。

表 1 十次迭代的运行结果 %

迭代次数	验证集准确率	测试集准确率
0	48.19	48.22
1	95.82	96.30
2	97.79	97.94
3	98.63	98.85
4	98.86	98.91
5	99.00	98.97
6	98.86	98.80
7	99.50	99.46
8	99.46	99.30
9	99.26	99.31

表中第一列描述的是迭代次数,是从 0 开始的。第二列是识别的准确率。本文设置的 batch_size 尺寸大小为 10,学习率为 0.03。验证集的准确率最终集中在 99% 左右。测试集的准确率最终在 99% 处收敛。相对于验证集的准确率,大多数测试集的准确率普遍高一点。原因是根据验证集微调了超参数,让模型有了很好的泛化能力,所以才会出现测试集准确率稍微高于验证集准确率的情况。测试集和验证集的准确率会在 99% 处出现细微的波动,这主要是因为学习效率速度放慢导致的,不影响检测的效果。

2.5 与其他方法比较

因为在锂电池褶皱检测领域里,目前很少有人研究,所以很难找到其他的方法。本实验之前设计的模型是具有两个全连接层,称它为 DLeNet-5,本文的实验模型为 ILeNet-5。用 matplotlib^[11] 两种结构的卷积网络对比图,如图 5 所示。




图 5 卷积网络对比图

对比表明,ILeNet-5 的识别率明显比 DLeNet-5 模型高,而且两个全连接层也会让迭代的时间变长。

3 结 语

本文通过使用改进的 LeNet-5 模型,对锂电池是否有褶皱进行了判断,将锂电池分为无褶皱和有褶皱两类。实验结果表明基于深度学习的锂电池检测方法的准确率是相对满意的。本文的不足之处在于没有在 GPU 上测试运行,今后有机会尝试 GPU 上运行,提高模型的可靠性。

参 考 文 献

- [1] 詹茵茵,邓积微,王太宏. 属性约简的气胀锂电池在线检测方法[J]. 电源技术,2015,39(4):736-748.
- [2] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [3] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012:1097-1105.
- [4] Sermanet P, Eigen D, Zhang X, et al. OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks [C]//ImageNet Large Scale Visual Recognition Challenge 2013 (ILSVRC2013), 2013.
- [5] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[EB]. arXiv:1409.1556,2014.
- [6] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2015.
- [7] 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.
- [8] 杨云,杜飞. 深度学习实战[M]. 北京:清华大学出版社,2018.
- [9] 郑群花,段慧芳,沈尧,等. 基于卷积神经网络和迁移学习的乳腺癌病理图像分类[J]. 计算机应用与软件,2018, 35(7): 237-242.
- [10] Bergstra J, Breuleux O, Bastien F, et al. Theano: a CPU and GPU math expression compiler[C]//Proceedings of the Python for Scientific Computing Conference (SciPy), 2010.
- [11] 张良均,杨海宏,何子健,等. Python 与数据挖掘[M]. 北京:机械工业出版社,2016.
- [12] 孙正军. 基于图像边缘提取的电池极片瑕疵检测研究[D]. 湖南:中南大学,2009.

3.73,说明本文方法具有很好的鲁棒性。从图5中可以看出,本文所提方法在大多数光照条件下的识别效果比其他几种方法更好。尤其是在 No. 1、No. 9、No. 14、No. 15、No. 16 的光照条件下,识别率明显提高了,远高于其他方法。同时可以很明显地看出,本文方法波动较小,对光照变化更加鲁棒。因此,本文所提方法的效果优于其他几种方法。

4 结 语

针对人脸识别中复杂的光照问题,本文基于 Fechner 定律和梯度特征,提出了一种新的人脸识别方法。根据 Fechner 定律,该方法直接在对数域内去除了光照,并增强了人脸图像,得到真实的反射人脸,并结合梯度特征进行识别。在 CMU-PIE 公共数据库上进行的实验数据表明,本文所提方法的识别率为 97.86%,明显高于 LBP、SQI + LBP、WF + LBP、GF、SQI + GF 等其他几种方法,并且在光照变化条件下识别效果更加鲁棒。

参 考 文 献

- [1] 郑方,艾斯卡尔·肉孜,王仁宇,等. 生物特征识别技术综述[J]. 信息安全研究,2016,2(1):12-26.
- [2] Zou X, Kittler J, Messer K. Illumination invariant face recognition: a survey [C]//IEEE International Conference on Biometrics: Theory, Applications, and Systems, 2007: 1-8.
- [3] Ahonen T, Hadid T, Pietikäinen M. Face description with local binary patterns: application to face recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(12):2037-2041.
- [4] Tan X, Triggs B. Enhanced local texture feature sets for face recognition under difficult lighting conditions [J]. IEEE Transactions on Image Processing, 2010,19(6):1635-1650.
- [5] Liao H. Region description using extended local ternary patterns [C]//IEEE International Conference on Pattern Recognition, 2010: 1003-1006.
- [6] Zhang T, Tang YY, Fang B, et al. Face recognition under varying illumination using gradient-faces [J]. IEEE Transactions on Image Processing, 2009, 18(11):2599-2606.
- [7] Gonzalez R C, Woods R E. Digital image processing [M]. Prentice Hall, 2008.
- [8] Shan S, Gao W, Cao B, et al. Illumination normalization for robust face recognition against varying lighting conditions [C]//IEEE Workshop on Analysis and Modeling of Faces and Gestures. 2003:157-164.
- [9] Jobson D J, Rahman Z, Woodell G A. Properties and performance of a center/surround retinex [J]. IEEE Transactions on Image Processing, 1997,6(3):451-462.
- [10] Wang H, Li S Z, Wang Y, et al. Self-quotient image for face recognition [C]//IEEE International Conference on Image Processing, 2004: 1397-1400.
- [11] Wang B, Li W, Yang W, et al. Illumination normalization based on Weber's Law with application to face recognition [J]. IEEE Signal Processing Letters, 2011,18(8):462-465.
- [12] Chen J, Shan S G, He C, et al. WLD: a robust local image descriptor [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(9):1705-1720.
- [13] Biglari M, Mirzaei F, Ebrahimpour-Komeh H. illumination invariant face recognition using SQI and weighted LBP histogram [C]//IEEE Pattern Recognition and Image Analysis. 2013:1-7.
- [14] 王刘涛,李肖立. 自商图像优化加权 LBP 直方图的光照变化人脸识别 [J]. 科学技术与工程, 2014, 14(28):98-103.
- [15] Fechner G T, Adler H E, Howes D H, et al. Elements of psychophysics [M]. Psychological Bulletin, 1966.
- [16] Sim T, Baker S, Bsat M. The CMU Pose, illumination, and expression (PIE) database [C]//IEEE International Conference on Automatic Face and Gesture Recognition, IEEE, 2002:46-51.
- [17] Basri R, Jacobs D W. Lambertian reflectance and linear subspaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(2):218-233.
- [18] Grigoryan A M, Agaian S S. Tensor form of image representation: enhancement by image-signals [J]. Proceedings of SPIE—The International Society for Optical Engineering, 2003(5014):221-231.

(上接第 219 页)

- [13] 肖安邦. 基于机器视觉的锂电池检测系统开发 [D]. 哈尔滨:哈尔滨工业大学,2007.
- [14] Sato M, Horie K, Hara A, et al. Application of deep learning to the classification of images from colposcopy: [J]. Oncology Letters, 2018, 15(3):3518-3523.
- [15] Li B, Hu X. Effective vehicle logo recognition in real-world application using mapreduce based convolutional neural networks with a pre-training strategy [J]. Journal of Intelligent & Fuzzy Systems, 2018, 34(3):1985-1994.
- [16] 邓红莉,杨韬. 一种基于深度学习的异常检测方法 [J]. 信息通信,2015(3):3-4.
- [17] 韩洪伟,赵晓云. 基于机器视觉的高速切片机锂电池极片在线检测系统设计 [J]. 电源世界,2017(5):34-36.
- [18] 杨保亮,杨守良. 基于 STM32 和 PWM 的锂离子电池检测系统设计和研究 [J]. 现代电子技术,2018,41(12):120-123.