

基于集成深度学习的玻璃缺陷识别方法

张丹丹, 金永, 胡缤予, 赵宇帆

(中北大学 信息与通信工程学院, 太原 030051)

摘要: 针对玻璃缺陷形态复杂多变, 难以准确识别其所属类型的特点, 文章提出了一种集成深度学习模型对玻璃缺陷进行识别, 该模型本质上是一种稀疏编码分类器与深度卷积神经网络的结合; 该模型在自编码器的基础上引进了 KL 距离和 L1 范数作为稀疏项, 构成新的稀疏自编码器; 并在次通过稀疏自编码器学习输入样本特征, 将训练好的权值作为卷积神经网络的卷积核从而提高了识别速度; 在稀疏编码阶段用 L_1-L_2 范数代替 L_0 范数, 并在 KSVD 上添加了判别分类能力使其更好地进行分类运算, 以此提高识别准确率; 实验结果表明, 该方法识别准确率达到 95%, 满足了工程上的应用, 并有很好的鲁棒性。

关键词: 卷积神经网络; 玻璃缺陷识别; KSVD 算法; 稀疏自编码

Glass Defect Recognition Method Based on Integrated Learning

Zhang Dandan, Jin Yong, Hu Binyu, Zhao Yufan

(College of Information and Communication Engineering, North University of China, Taiyuan 030051, China)

Abstract: In view of the complex shape of glass defect, it is difficult to accurately identify the characteristics of its type. This paper proposes an integrated deep learning model to identify glass defects, which is essentially a combination of sparse coding classifier and deep convolutional neural network. Based on the auto-encoder, the model introduces the KL distance and the L1 norm as sparse terms to form a new sparse auto-encoder. The model learns the features of input sample by sparse auto-encoder and uses the trained weights as the convolution kernel of the convolutional neural network to improve the recognition speed. In the sparse coding stage, L_1-L_2 norm is used to replace the L_0 norm, and the discriminant classification ability is added to the KSVD to make it better to classify operations, thereby improving the recognition accuracy. The experimental results show that the recognition accuracy of this method is up to 95%, which satisfy the need in on-field application and it is robust.

Keywords: convolutional neural network; glass defect recognition; KSVD algorithm; sparse auto-encoder

0 引言

随着国家的发展, 工业及民众对玻璃的需求日趋增加, 对高质量玻璃的需求也越来越大, 而玻璃的外观质量是影响其产品性能的一个重要因素。衡量玻璃外观质量的好坏主要通过检测表面是否存在缺陷。由于玻璃生产过程中工艺制度的破坏或操作过程的差错, 使玻璃往往带有不同类型和大小的缺陷。例如夹杂、气泡、锡皮、麻点、线条和划痕等, 不仅影响制品的外观质量, 还影响玻璃制品的透明性和光学均一性, 降低了制品的机械强度和热稳定性^[1]。因此, 在生产过程中对玻璃缺陷进行识别, 对于提高产品质量等级, 指导工艺改进具有重要意义。

传统上玻璃缺陷的识别主要靠人工肉眼观察和业内专家的经验来识别缺陷, 导致了人工的工作强度大、工作周期长, 工作效率低, 而且长时间疲劳工作会造成错误率提高。目前玻璃缺陷识别方法主要通过 BP 算法、小波变换、灰度共生矩阵、SVM 等。文献 [2] 中利用 BFGS 算法的三

层前馈神经网络 (BP) 作为分类器, 采用不变矩和灰度共生矩阵描述图像的纹理, 并综合提取出可分类的特征向量, 有效的实现了玻璃缺陷分类。文献 [3] 中利用多分辨率和信息融合分析的方法对玻璃缺陷进行识别, 并采用二维离散小波变换, 将具有有效区域的相减缺陷图像分解为近似子图像和详细子图像。利用灰度共生矩阵对玻璃缺陷进行纹理特征提取, 将气泡、污点等缺陷进行分类^[4]。利用统计方法的局部方差旋转不变测量算子 (RIMLV) 检测出缺陷边缘, 并采用统计模式识别理论中的多策略支持向量机 (SVM) 作为分类器对缺陷类型进行识别^[5]。

然而上述特征提取方法均根据简单的几何特征提取, 脱离了玻璃缺陷本身的特点: 玻璃缺陷没有固定的形状特征, 没有固定的大小, 没有明显的灰度差别, 也没有大量的细节特征^[6]。因此特征提取同种缺陷时的特征差异较大, 无法实现对玻璃表面质量的客观、高精度、高效率的识别。近年来计算机技术、电子技术的快速发展, 基于机器学习自动化识别技术也得到了飞速的发展, 为玻璃表面质量检测提供了切实可行的方案。

目前, 通过结构重组和减少权值将特征提取功能融合进多层感知器中的卷积神经网络在人脸识别^[7]、车牌识别^[8-9]等方面取得了极大地成功。卷积神经网络模拟具有层次结构的生物视觉感知系统, 图像无须复杂预处理即可直接输入网络学习到描述缺陷目标的特征, 直接输入网络学

收稿日期: 2018-08-25; 修回日期: 2018-10-19。

基金项目: 山西省回国留学人员科研资助项目 (2016-084)。

作者简介: 张丹丹 (1993-), 女, 天津人, 硕士研究生, 主要从事无损检测和机器视觉等方向的研究。

金永 (1977-), 男, 山西人, 硕士生导师, 教授, 主要从事图像处理、无损检测及机器视觉等方向的研究。

习到描述缺陷目标的特征, 即使对光照、几何畸变等因素干扰仍具有很好识别效果^[9], 这避免了传统玻璃缺陷识别方法中需要复杂图像预处理和繁琐的人工提取过程。

因此本文提出了一种集成学习方法。将卷积神经网络(Convolutional Neural Network, CNN) 和 KSVD 字典相结合的方式来进行识别操作。首先采用图像处理方法中的分段线性变换方法来降低图像原有的噪声, 实现图像预处理工作。然后引入 KL 距离和 L_1 范数稀疏化自编码器(Sparse Autoencoder, SAE), 再利用 SAE 预训练权值并给予卷积神经网络充当卷积核进行训练, 最后通过改进 KSVD 字典进行分类。

1 引入稀疏性的自编码器

稀疏自编码是指隐层特征具有稀疏响应特性。其预训练: 首先提取输入图片的小块信息经过输入层到达隐藏层则是对输入数据进行编码, 然后经过隐藏层到达输出层则是对输入数据进行解码重构出小块图片的过程。通常, 在隐藏层神经元中引入稀疏性, 这样可以带来很多优势: 一是编码方案存储能力大, 具有联想记忆能力, 并且计算简便; 二是使自然信号的结构更加清晰; 三是编码方案既符合生物进化普遍的能量最小经济策略, 又满足电生理实验的结论。

本文根据不同的情况引入两种稀疏性, 分别应用在 SAE 的不同过程中, 一种是不考虑隐层特征的维数与输入维数之间的关系, 利用 KL 距离引入稀疏性约束, 二是在隐层特征的维数大于输入的维数时, 利用范数 L_1 正则项引入稀疏性。

第一, 利用 KL 距离引入稀疏性约束^[10]: 对于数据集有隐层特征的输出:

$$\{x^n \in \mathbf{R}^u\}_{n=1}^N \rightarrow \{X^n \in \mathbf{R}^v\}_{n=1}^N \quad (1)$$

利用如下公式计算隐层输出每个节点的平均值:

$$\bar{X} = \frac{1}{N} \sum_{n=1}^N X^{(n)} \in \mathbf{R}^v \quad (2)$$

让隐层每个节点的平均输出值尽量为 0, 大部分的隐层节点处于静默状态, 为了量化隐层这种特性, 通常假设隐层每个节点以一定的概率进行响应, 且节点之间相互独立。设每个隐层节点响应或发生的期望概率为 $\rho = 0.05$ 。利用 KL 距离构造的稀疏正则项^[11]为:

$$KL(\rho \| \bar{X}(j)) = \rho \cdot \log\left(\frac{\rho}{\bar{X}(j)}\right) + (1 - \rho) \cdot \log\left(\frac{1 - \rho}{1 - \bar{X}(j)}\right) \quad (3)$$

公式 (3) 中 $\bar{X}(j)$ 为 \bar{X} 的第 j 个元素, 即隐层第 j 个节点响应的平均值, 其中 $j = 1, 2, \dots, v$ 。得到的稀疏自编码网络的优化目标函数为:

$$\min_{\theta} J(\theta) = \frac{1}{N} \sum_{n=1}^N \|\hat{x}^{(n)} - x^{(n)}\|_2^2 + \lambda \cdot R(\theta) + \beta \cdot \sum_{j=1}^v KL(\rho \| \bar{X}(j)) \quad (4)$$

第二, 利用范数 L_1 正则项引入稀疏性, 对于隐层节点的

输出构造的范数约束项为:

$$\frac{1}{N} \sum_{n=1}^N X_1^{(n)} = \frac{1}{N} \sum_{n=1}^N \sum_{j=1}^v |X^{(n)}(j)| \quad (5)$$

得到的稀疏自编码网络的优化目标函数为:

$$\min_{\theta} J(\theta) = \frac{1}{N} \sum_{n=1}^N \|\hat{x}^{(n)} - x^{(n)}\|_2^2 + \lambda \cdot R(\theta) + \beta \cdot \frac{1}{N} \sum_{n=1}^N X_1^{(n)} \quad (6)$$

2 改进 KSVD 算法

传统的字典学习方法是应用一种无监督的学习方法, 如 K-均值^[11]对从图像中采样得到的训练样本进行聚类。然而 K-均值算法训练得到的词典不具有确定性和合理性。为改进 K-均值算法而提出了 KSVD 算法。KSVD 算法^[12]是一个学习字典的优化算法, 当算法中仅由一个聚类中心表示样本点时即为 K-均值算法。它主要通过 SVD 奇异值分解方法优化每个字典原子从而减少误差获得最优值并通过基于当前字典的稀疏编码输入数据之间迭代交替, 更新字典中的原子以更好的拟合数据来工作。

其优化学习的目标函数为:

$$\min_{D, X} \|Y - DX\|_{2, s, t} \|X\|_0 \leq T_0 \quad (7)$$

其中: Y 是为算法输入的无标记样本, D 为待训练的过完备稀疏冗余字典, X 为应用字典 D 对样本 Y 进行表示的稀疏系数。稀疏约束为 L_0 范数。公式 (7) 的求解是个 NP 难问题, 可以使用 Stephane 提出的贪婪算法如正交匹配追踪(orthogonal matching pursuit, OMP), 匹配追踪(matching pursuit, MP), 弱匹配追踪(weakly matching pursuit, WMP) 和阈值算法(threshold algorithm, TA)。还有 S. S Chen 提出的松弛因子算法如基匹配算法(basis pursuit, BP) 等求解。

在字典更新时, 第一步得到的系数矩阵表示的数据往往和原数据有误差, 为了使整体误差越来越小, 采取逐列更新的方式并且更新后的字典满足稀疏约束条件。更新规则为优化目标函数:

$$\min_{D, X} \|Y - DX\|_F^2 = \min_{D, X} \|Y - \sum_{j=1}^K D_j x_j^T\|_F^2 = \min_{D, X} \|E_k - D_k x_k^T\|_F^2 \quad (8)$$

每次迭代对进行奇异值(SVD)分解并更新 D_k , 使得目标函数值最小, 其中 E_k 去掉字典 D_k 的重构误差, T 为进行稀疏表示得到稀疏 X 中非零元素的个数的最大值。通过阈值 T 的设置来达到稀疏表示目的。

虽然 KSVD 方法在真实图像中很有效, 而且也考虑了重建误差和系数的稀疏性, 但是学习的字典没有针对分类任务进行优化。所以本文提出以下内容进行优化。

2.1 更改稀疏约束

凸松弛算法是常用的一种稀疏约束方法, 利用 L_1 范数代替 L_0 , 但 L_1 范数是基数层面上的稀疏, 编码具有较少的信息。基于此缺点, 本文引入比较流行的 $L_1 - L_2$ 范数, 定义为:

$$\|X\|_{L_1-L_2} = \sum_{G \in \xi} \left(\sum_{j \in \xi} X_j^2 \right)^{\frac{1}{2}} \quad (9)$$

L_1-L_2 范数是群集水平上的稀疏。其目标函数改成：

$$\min_{D, X} \|Y - DX\|_2^2 + \gamma \|X\|_{L_1-L_2} \quad (10)$$

其中： γ 是平衡误差和稀疏度的参数。

2.2 增加判别能力

KSVD 方法在真实图像中很有效，而且也考虑了重建误差和系数的稀疏性，但是学习的字典没有针对分类任务进行优化。所以在此基础上增加判别准则。此处的判别准则包括 Softmax 判别代价函数、费舍尔判别准则、线性预测分类误差、Logistic 代价函数等。其核心模型为：

$$[D, W, X] = \arg \min_{D, W, X} \|Y - DX\|_2 + \gamma \|H - WX\|_2 \quad (11)$$

其中： D 为稀疏表示字典， W 为判别能力字典，第二项为分类误差。通过交替迭代求解优化问题，得到的解为 $[D, W]$ 。然后在测试阶段，对于测试信号 X^{Test} ，利用判别能力字典，得到 $l = W \times X^{Test}$ ，通过判断进而分类。

3 实验研究

3.1 数据集

玻璃缺陷是影响玻璃质量的首要因素。常见的玻璃缺陷主要有气泡、光畸变、划伤、夹杂、疙瘩等。本文数据是通过在实际生产线中使用 CCD 相机采集得到的图片。其中我们选取夹杂、气泡、划痕、污点、疙瘩、断板作为我们研究缺陷类型的初始样本。由于采集的数据量不大，数据集的正负样本分布极不均匀等特点往往会出现过拟合现象，为了防止过拟合，可以利用正则化方法^[13]或者数据集扩增的方法^[14]。因为我们的数据样本比较小所以在此采用数据集扩增的方法，既可以消除过拟合现象也可以提高识别准确率。

首先对原始图像进行平移：以图片上的缺陷为中心在水平方向上左右各移 20 个单位，上下各移 10 个单位。然后以平移后的图像为样本进行角度 θ 旋转，旋转步长为 10° 从

$0^\circ \sim 90^\circ$ 。最后部分进行镜像变换采用 $\begin{bmatrix} -1 & 0 & f_w \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$ 水平

镜像公式和 $\begin{bmatrix} 1 & 0 & 0 \\ 0 & -1 & f_H \\ 0 & 0 & 1 \end{bmatrix}$ 垂直镜像公式对部分扩展，最终

得到 1800 张缺陷样本。

由于划痕缺陷、夹杂缺陷、疙瘩缺陷、气泡缺陷和污点缺陷这些缺陷特征图受到系统噪声的影响较大，为了降低系统噪声，增大缺陷与背景灰度的差异，可以使用中值滤波和灰度变换方法。但某些小型缺陷和边沿缺陷在滤除噪声时会对其造成一定地损伤，因此我们采用分段线性变换方法。处理前后图片分别为图 1 和图 2。

3.2 实验过程

实验数据是在实际生产线中使用 CCD 像机采集的数据图片。经过后期操作总共可以使用的图片为 1800 张，包含 6 种缺陷，每种缺陷各 300 张。其中每类抽取 200 张共计




图 1 部分未处理玻璃缺陷样本




图 2 部分处理后玻璃缺陷样本

1200 张作为训练图片，600 张作为测试图片。图片统一预处理为 28×28 的灰度图片。针对小数据集的研究首先采用深度卷积神经网络进行训练，提取特征，其中 relu 作为激活函数。参数设置如图 3 所示。




图 3 深度卷积神经网络 (CNN)

训练集作为输入图片经过图 4 后分别提取 S2 层特征图 h_1 和 S4 层特征图 h_2 。然后分别作为 SAE 的输入图片。下面是对图 4 SK_CNN 处理过程：

- 1) 从训练样本中随机选取局部图像块进行 Zero-phase Component Analysis (ZCA) 白化处理^[15]。
- 2) 将处理后的图片经过稀疏自编码（此过程用 KL 引入稀疏项）预训练得到权值 W_1 。
- 3) 特征图 h_1 进行 ZCA 白化处理。
- 4) 将处理后的图片经过稀疏自编码（此过程用 L_1 范数引入稀疏项）预训练得到权值 W_2 。
- 5) 特征图 h_2 进行 ZCA 白化处理。
- 6) 将处理后的图片经过稀疏自编码（此过程用 L_1 范数引入稀疏项）预训练得到权值 W_3 。
- 7) W_1, W_2, W_3 在经过 CNN 的监督性训练就得到最优的权值。
- 8) 把测试集输入 CNN 后经过 KSVD 分类器，进行识别。

如图 5 所示分别对应步骤 2)、4)、6) 所得到的权值图像。此权值图像是使用 SAE 无监督训练 CNNs 滤波器权值 W 而得到的。设定 CNNs 第一层权值为 $12 \times 7 \times 7$ ，即 12 个 7×7 大小的滤波器，则先在白化后的图片切 30000 个 7×7 patches，将这些 patches 作为 SAE 的输入，通过训练得到权值 W 为 49×12 ，如图 5 (a) 所示，输入层个数为 49，隐藏层个数为 12，输入层维数大于隐藏层维数则引入 KL 稀疏约束，进行稀疏化；第二层权值为 $24 \times 4 \times 4$ ，即 24 个 4×4 大小的滤波器。将上述提取的特征图 h_1 作为 SAE 的输

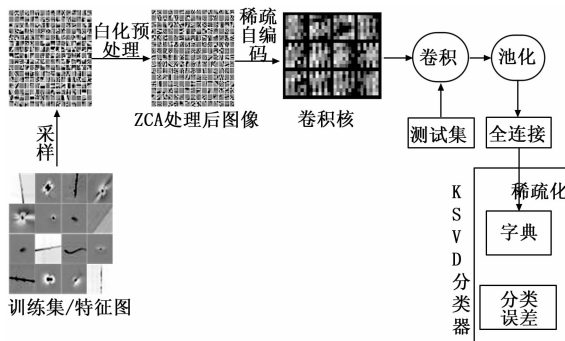



图 4 SK_CNN 模型

入, 隐藏层个数为 24, 通过训练得到的权值 W 为 24×16 , 如图 5 (b) 所示, 输入层维数小于隐藏层维数则引入 L_1 范数进行稀疏化; 第三层权值为 $48 \times 3 \times 3$, 即 48 个 3×3 大小的滤波器, 将上述提取的特征图 h_2 作为 SAE 的输入, 隐藏层个数设为 48, 通过训练得到权值 W 为 48×9 , 如图 5 (c) 所示, 输入层维数小于隐藏层维数则引入 L_1 范数进行稀疏化。



(a) C1层权值 $w_1:12 \times 49$ (b) C3层权值 $w_2:24 \times 16$ (c) C5层权值 $w_3:48 \times 9$

图 5 步骤 2)、4)、6) 所得到的权值图像

3.3 实验结果

3.3.1 玻璃数据库

我们在自己创建的数据库上评估提出的玻璃缺陷识别方法, 并将其性能与最近提出的几种算法进行比较, 包括 softmax, SVM, kmeans 和 KSVD。在实验中所有算法使用的参数全部相同, 学习词典大小是全连接层输出的大小, 稀疏度先设为 $T=6$ 。识别结果表明本文算法在缺陷的识别中除了疥瘤缺陷外的每一类识别率均在 90% 以上, 这可能是因为疥瘤样本数据量较少, 没有大范围的涵盖所有缺陷类型所致。但相比其他方法也具有明显的提高。识别结果如表 1 所示。

表 1 识别缺陷的个数

深度学习模型	softmax	SVM	kmeans	KSVD	本文算法
夹杂/个	89	90	92	91	93
疥瘤/个	85	87	89	89	90
气泡/个	94	93	94	93	95
划痕/个	94	95	95	95	98
污点/个	93	95	96	96	98
断板/个	97	96	97	96	99

表 2 的实验结果是在表 1 的基础上完成的并增加了 Kappa 系数来说明。实验参数不变。从表中可以观察到, 本文算法是在改进的 KSVD 上增加了稀疏自编码器相比于

单纯的 KSVD 提高了识别时间和准确率。所有准确率和识别时间均是在训练了 10 次后取的平均值。

表 2 分类算法对比结果

分类算法	平均准确率/%	Kappa 系数	平均时间/s
softmax	92.04	0.8729	432.1
SVM	92.62	0.8872	397.8
Kmeans	93.85	0.9038	341.0
KSVD	94.02	0.9256	322.7
本文算法	95.43	0.9302	225.9

本文使用 CNN 网络特征提取优先于 Gabor^[16] 特征提取 (五尺度和八方向的 40 个过滤器)。由 θ 控制采样方向分别设置为 $0, \frac{\pi}{8}, \frac{\pi}{4}, \frac{3\pi}{8}, \frac{\pi}{2}, \frac{5\pi}{8}, \frac{3\pi}{4}, \frac{7\pi}{8}$ 。测试集和训练集跟上述训练参数一样, 稀疏因子为 30。实验结果如表 3。这两种方法在识别玻璃缺陷方面都很有效, 但本文方法表现的更好一点。

表 3 不同方法对比

算法	平均时间/s	平均识别率/%
CNN+改进 KSVD	312.9	95.43
Gabor+改进 KSVD	350.2	93.18

3.3.2 AR 数据库

AR 数据库对应 126 个人 (70 名男性, 56 名女性) 的 4, 000 多张彩色图片整合成的数据集。图像具有不同的面部表情, 每个人有 26 个人脸图像。我们使用 50 名男性和 50 名女性的 2, 600 张图片作为新的数据集。本文随机选取每个人的 20 张图像作为训练, 剩余的 6 张作为测试。实验过程中算法参数保持不变。本文投影脸部图像 $\in R^{192 \times 168}$ 到一个矢量 $\in R^{540}$ 使用 Randomface^[17]。稀疏度设定为 $T=10$, 识别结果总结在表 4 中。本文的方法优于所有竞争方法。

表 4 AR 数据库识别准确率

分类算法	平均准确率/%	平均时间/s
softmax	88.04	456.6
SVM	88.62	403.1
Kmeans	89.85	363.0
KSVD	90.43	341.4
本文算法	92.92	257.7

4 结语

传统玻璃缺陷识别方法中缺陷特征类型的选取以及提取存在人为主观因素影响、效率低、计算量大等不足。而玻璃缺陷目标存在形态复杂多变、目标过小等问题, 采取人为设计的特征提取方法难以有效表述缺陷目标。因此基于稀疏自编码与卷积神经网络相结合的缺陷识别模型已经建成。结合卷积神经网络参数的多层次和精细转换的优点, 本文采用 SAE 预训练卷积核, 取代传统 CNN 中权值的随

机初始化,在优化前参数可以得到更合适的值,以提高识别时间。并用 KSVD 进行识别操作提高识别准确率。实验结果表明,该方法可以对常见的玻璃缺陷进行精确的分类。但是应用于人脸领域表现效果不是很好,接下来研究的重点是如何提高多方面领域的识别。

参考文献:

- [1] Jin Y, Wang Z, Zhu L, et al. Study on glass defect inspection based on projecting grating method [J]. J TEST EVAL, 2013, 41: 332 - 339.
- [2] Wang S Z, Wang Z B, Jin Y, et al. Research of recognition technology for glass defect based on BP neural network [J]. Modern Electronics Technique, 2010.
- [3] Liu H G, Chen Y P, Peng X Q, et al. A classification method of glass defect based on multiresolution and information fusion [J]. International Journal of Advanced Manufacturing Technology, 2011, 56 (9-12): 1079 - 1090.
- [4] Sachdeva K, Girdhar A. A technique for glass defect detection [J]. International Journal of Innovative Research and Development, 2013, 2: 25 - 31.
- [5] Hanzaei S H, Afshar A. Automatic detection and classification of the ceramic tiles' surface defects [J]. Pattern Recognition, 2016, 66.
- [6] 刘怀广, 陈幼平, 谢经明, 等. 浮法玻璃缺陷在线识别技术的研究 [J]. 小型微型计算机系统, 2011, 32 (4): 738 - 742.
- [7] 杨海燕, 蒋新华, 聂作先. 基于并行卷积神经网络的人脸关键点定位方法研究 [J]. 计算机应用研究, 2015, 32 (8): 2517 - 2519.
- [8] 朱旭辰, 游双燕. 基于深度学习的车牌识别 [J/OL]. 图像与多

(上接第 215 页)

对文件属性翻译,直观地表征出不同时间段的数据,并可任意选择不同的文件进行导出、删除等操作,其数据使用效率明显优于直接存储的方式,并能够实现存储空间的均衡使用,所存储的数据在完整性、实时性、正确性等方面完全满足实际使用要求,更值得一提的是软件设计容易实现,占用系统资源少。实验结果表明,该分区设计思想实现简单,用户使用方便,满足实际工程使用的需要。

4 结束语

本文提出的大容量 NAND Flash 存储器分区设计思想,其关键技术特点在于通过文件属性数据结构的设计和动态维护的算法,模拟了文件管理系统,实现了对大容量 NAND Flash 存储器的数据存储管理和均衡使用。该设计思想对嵌入式系统性能资源要求低、软件编程简单、实现效率高,提供一条解决大容量存储器在嵌入式系统中应用的简捷途径,在实际的应用中取得了良好的效果,具有广泛的推广应用价值。

参考文献:

- [1] 陈育智, 嵌入式系统中的 Flash 文件系统 [J]. 单片机与嵌入

媒体技术. (2017) [2018-7-18]. <http://kns.cnki.net/kcms/detail/10.1108.TP.20171222.1519.100.html>.

- [9] 李珊珊, 李一民, 郭真真. 基于神经网络的分阶车牌字符识别算法研究 [J]. 工业仪表与自动化装置, 2016, 2: 7 - 10.
- [10] 王冠皓, 徐军. 基于多级金字塔卷积神经网络的快速特征表示方法 [J]. 计算机应用研究, 2015, 32 (8): 2492 - 2495.
- [11] 华辉有, 陈启买, 刘 海, 等. 一种融合 Kmeans 和 KNN 的网络入侵检测算法 [J]. 计算机科学, 2016, 43 (3): 158 - 162.
- [12] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Transactions on signal processing, 2006, 54 (11): 4311.
- [13] Jiang Z, Wang Y, Davis L, et al. Learning Discriminative Features via Label Consistent Neural Network [J]. arXiv preprint arXiv: 1602. 01168, 2016; 561 - 563.
- [14] 丁伟雄. MATLAB R2015a 数字图像处理 [M]. 北京: 清华大学出版社, 2016.
- [15] Coates A, Ng A Y. Selecting receptive fields in deep networks [A]. Advances in Neural Information Processing Systems [C]. 2011: 2528 - 2536.
- [16] Haghgha Mohammad; Zonouz Saman; Abdel-Mottaleb Mohamed. CloudID: Trustworthy cloud-based and cross-enterprise biometric identification [J]. Expert Systems with Applications, 2015, 42 (21): 7905 - 7916.
- [17] Wright J, Yang M, Ganesh A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009: 210 - 227.
- [1] 邓 剑, 杨晓非, 廖俊卿, FAT 文件系统原理及实现 [J]. 计算机与数字工程, 2005, 33 (9): 105 - 108.
- [2] 王 威, 等, HCS12 微控制器原理及应用 [J]. 北京: 北京航空航天大学出版社, 2007.
- [3] Micron Technology, Inc. m60_4gb_8gb_16gb_ecc_nand.pdf-Rev. N 10/12 EN.
- [4] Freescale. MC9S12XF512 Reference Manual [Z].
- [5] 邵贝贝. 单片机嵌入式应用的在线开发方法 [M]. 北京: 清华大学出版社, 2004.
- [6] Raj Kamal. 嵌入式系统: 体系结构、编程与设计 [M]. 陈曙晖, 译. 北京: 清华大学出版社, 2005.
- [7] 王宜怀, 曹金华. 嵌入式系统设计实战——基于粉丝卡尔 S12X 微控制器 [M]. 北京: 北京航空航天大学出版社, 2011.
- [8] Cormen T H, Leiserson C E, Rivest R L, 等. 算法导论 [M]. 潘金贵, 顾铁成, 等, 译. 北京: 机械工业出版社, 2006.
- [9] Weiss M, ACormen T H. 数据结构与算法分析——C 语言描述 [M]. 冯舜玺, 译. 北京: 机械工业出版社, 2005.
- [10] 肖楚梅, 梁杰申. SD 卡在记录汽车 CAN 总线数据中的应用 [J]. 信息纵横, 2009 (18): 14 - 16.