

# 基于稀疏深度置信网络的图像分类识别研究

刘梦溪<sup>1,2</sup>, 王 征<sup>2</sup>, 宋久旭<sup>2</sup>, 巨永锋<sup>1</sup>, 武晓朦<sup>2</sup>

(1 长安大学 电子与控制工程学院, 陕西 西安 710064;

2 西安石油大学 光电油气测井与检测教育部重点实验室, 陕西 西安 710065)

**摘 要:** 针对工业生产中 X 射线获取的焊缝图片缺陷难以被识别的问题, 构建了一个深度置信网络模型, 该模型由三层受限玻尔兹曼机组成, 由于将稀疏约束引入深度学习模型的算法中, 使得焊缝缺陷信息能够获得到有效的目标稀疏表示, 以更为简洁有效的训练实现对焊缝缺陷信息的识别. 通过分层网络模型对比实验表明, 稀疏深度置信网络能够提高焊缝缺陷图像识别的正确率, 实现更为精准的图像信息分类, 在有效避免过拟合现象的发生的同时, 提升了模型对于焊缝缺陷识别的性能.

**关键词:** 焊缝缺陷; 深度学习; 稀疏约束; 深度置信网络

**中图分类号:** TP391.41; TG441.7

**文献标识码:** A

**文章编号:** 1000-7180(2018)09-0059-05

## Weld Defects Images Classification and Recognition Based on Sparse Deep Belief Network

LIU Meng-xi<sup>1, 2</sup>, WANG Zheng<sup>2</sup>, SONG Jiu-xu<sup>2</sup>, JU Yong-feng<sup>1</sup>, WU Xiao-meng<sup>2</sup>

(1 School of Electronic and Control Engineering, Chang'an University, Xi'an, 710064, China;

2 Shaanxi Key Laboratory of Measurement and Control Technology for Oil and Gas  
Wells, Xi'an Shiyou university, Xi'an, 710065, China)

**Abstract:** Because weld defects images obtained by X-ray are difficult to be identified in industrial production, a Deep Belief Network (DBN) model composed of three-layer Restricted Boltzmann Machine(RBM) is proposed. Due to the sparse constraint introduced into the depth learning model algorithm, the weld defects information can obtain the target sparse representation in more effective way and the weld defects information can be identified through more concise and effective training. The comparison experiment of layered network model shows that the Sparse Deep Belief Network can ensure the accuracy of weld defects images recognition and classification while improving the performances of Deep Belief Network by avoiding the overfitting.

**Key words:** weld defects; deep learning; sparsity constraints; deep belief network

### 1 引言

随着技术的进步, 图像识别与分类的自动检测技术取得了较大的发展, 深度学习已在计算机视觉领域中的图像分类、目标检测、图像检索、图像分割<sup>[1]</sup>等任务中取得了成功的应用, 为焊缝图像的识别与分类提供了一种思路. 虽然深度学习网络结构

决定了其对于特征目标的训练与测试能达到较高的精度, 但由于深层网络的网络层级和可学习参数较多, 增加了算法的复杂程度, 一定程度上损失了鲁棒性和时效性<sup>[2]</sup>. 稀疏编码(Sparse Code, SC)是一种采用低维数据对高维数据进行描述的方法<sup>[3]</sup>, 输入信号经稀疏化后, 特征的稀疏表示可以在很大程度上控制网络中神经元的总体激活率, 从而使得使用

者可以根据应用和数据的需要来灵活控制特征的维度,对于输入样本的变化具有较高的鲁棒性,可极大的提高深度学习的性能和效率.考虑到焊缝缺陷图像的复杂背景和现有分类识别效率较低的问题,本文采用深度学习中最简单有效的深度置信网络模型并结合稀疏编码技术,以期达到对焊缝缺陷精准识别与分类的目的.

## 2 稀疏深度置信网络研究焊缝缺陷的方法

### 2.1 焊缝图像特征信息的提取

本文在图像预处理阶段先将提取的原始图像处理成不大于  $128 \times 128$  的图像,为防止图片畸变,对长、宽较长的一边变换成 128,较短的一边进行等比变换<sup>[4]</sup>.之后,将图像分割为四幅图片,分别是图像的四个顶点所截取的  $64 \times 64$  图像块,这样一方面可以实现对图片的特征信息的充分提取,另外一方面可以对图片数据进行降维,避免因输入维数过大而导致的深度学习训练性能下降、出现过拟合问题.

按照上述方法进行的图像分割的算法如下所示:

焊缝缺陷图像特征提取算法

Input InImage

Output OutImage

Step1: 计算图像长和宽中较大的一边,记为 ma,较小的一边记为 mi;

Step2: 如果  $mi > 128$ ,以  $128/mi$  进行等比变换,变换后的图像记为 Tr;

Step3: 对图像 Tr 分别从四个顶点和中心进行截取  $64 \times 64$  的图像块,产生 4 张训练图像,记为 OutImage[0]; OutImage[1]; OutImage[2]; OutImage[3];

Step4: 输出 OutImage

### 2.2 稀疏深度置信网络模型的构建

#### 2.2.1 受限玻尔兹曼机的稀疏约束

由于增加稀疏约束的特征表示能够有效提升 DBN 的目标识别性能,而深度置信网络的构建基础为受限玻尔兹曼机 (Restricted Boltzmann Machine, RBM)<sup>[5]</sup>,所以对于深度置信网络的稀疏约束问题就转化为在 RBM 中引入稀疏机制,使得 RBM 可以学习到非分布式的稀疏表达.

RBM 的结构如图 1 所示,由两层神经元构成,分别为隐含层 (Hidden layer) 和可视层 (Visible layer),作为特征检测器和输入数据训练使用. 每一个 RBM 都可以作为一个单独的聚类器来使用,其能量函数的大小可表示为:




图 1 RBM 结构示意图

$$E(v, h; \theta) = -v^T W h - b^T v - c^T h =$$

$$- \sum_{ij} W_{ij} v_i h_j - \sum_{i=1}^m b_i v_i - \sum_{j=1}^n c_j h_j \quad (1)$$

式中,  $W_{ij}$  表示可视层  $i$  与隐含层  $j$  之间的连接权重;  $b_i$  表示可视层  $i$  的偏置;  $c_j$  表示可视层  $j$  的偏置;  $\theta = \{w, b, c\}$  为 RBM 参数,其更新计算为:

$$\theta^{(\tau+1)} = \theta^{(\tau)} + \eta \left. \frac{\partial \log P(v)}{\partial \theta} \right|_{\theta} = \theta^{(\tau)} + \eta \times \Delta \theta^t \quad (2)$$

式中,  $\tau$  为迭代次数;  $\eta$  为学习速度.

可视层内的特征向量  $v$  和隐含层内的特征向量的联合概率分布为:

$$P(v, h; \theta) = \frac{\exp(-E(v, h))}{Z(\theta)} = e^{h^T W v + b^T v + c^T h} \quad (3)$$

式中,  $Z(\theta) = \sum_v \sum_h \exp(-E(v, h))$  为配分函数,

用来确保概率的归一化. 实际过程中  $Z(\theta)$  的计算比较复杂,同时 RBM 模型工作性能良好的前提是隐层单元的数目较少,但利用深层网络解决复杂识别问题时,会为了提升网络的学习性能而增加网络中的隐层单元数,使模型更加复杂的同时会增加数据分析的困难,淹没一些具有表性本征. 对此,引入高斯限制玻尔兹曼机模型 (Gaussian RBM, GRBM),其能量函数为:

$$E(v, h; \theta) = \frac{1}{2\sigma^2} \sum_i v_i^2 - \frac{1}{\sigma^2} \left( \sum_i c_i v_i + \sum_j b_j h_j + \sum_{ij} v_i W_{ij} h_j \right) \quad (4)$$

式中,  $\theta = \{w, b, c, \sigma\}$ , 条件分布函数为:

$$p(v_i | h) = N(c_i + \sum_j W_{ij} h_j, \sigma^2) \quad (5)$$

$$p(h_j | v) = \text{logistic} \left( \frac{1}{\sigma^2} (b_j + \sum_i W_{ij} v_i) \right) \quad (6)$$

式中,  $N(\cdot)$  是高斯密度; logistic 函数为  $\text{sigm}(x) = 1/(1 + \exp(-x))$ , 加入稀疏惩罚因子,最终对于 RBN 的稀疏优化问题可表达如下:

$$\text{minimize}_{\{w_{ij}, c_i, b_j\}} - \sum_{l=1}^m \log \sum_h P(v^{(l)}, h^{(l)}) + \lambda \sum_{j=1}^n \left| p - \frac{1}{m} \sum_{l=1}^m E[h_j^{(l)} | v^{(l)}] \right|^2 \quad (7)$$

式中,  $E[\cdot]$  是给定数据的条件期望;  $\lambda$  是权衡参数, 用于调整 SRBM(Sparse-RBM) 模型中生成部分和判决部分的比重;  $p$  为稀疏常数, 用来控制隐含层的稀疏程度. 稀疏的具体训练算法如下所示:

Sparse-RBM 训练算法:

Input: training sample:  $V = \{v_1, v_2, \dots, v_i, \dots, v_D\}$

hidden layer:  $H = \{h_1, h_2, \dots, h_i, \dots, h_F\}$

learning rate:  $\epsilon$

number of hidden layer:  $n$

the max training period:  $T$

Output: weight:  $w$ , bias vector  $c$  and  $b$ .

Initialization:  $w_{ij} = c_j = b_i = 0 \quad V^{(0)} = V$

For  $t = 1, 2, \dots, T$

For  $i = 1, 2, \dots, F$  % 对所有隐含层

采样  $h_j^{(0)} \sim P(h_j | V^{(0)})$

End for

For  $j = 1, 2, \dots, D$  % 对所有可视层

采样  $v_i^{(1)} \sim P(v_i | H^{(0)})$

End for

For  $i = 1, 2, \dots, F$  % 对所有隐含层

采样  $h_j^{(1)} \sim P(h_j | V^{(1)})$

End for

Update parameters:

$w_{ij} = w_{ij} + \epsilon(P(h_j = 1 | V^{(0)})v_i^{(0)} - P(h_j = 1 | V^{(1)})v_i^{(1)})$

$c_j \leftarrow c_j + \epsilon(P(h_j = 1 | V^{(0)}) - P(h_j = 1 | V^{(1)}))$

$b_i \leftarrow b_i + \epsilon(v_i^{(0)} - v_i^{(1)})$

End for

在实际学习过程中, 采用对比散度(Contrastive Divergence)算法对输入数据进行拟合. 该算法使用训练数据初始化(一般  $k=1$ )步 Gibbs 采样<sup>[6]</sup>就可以得到足够好的近似, 实现对模型的估计, 之后用对应的条件分布进行相应隐层的计算, 根据分布计算结果, 就得到对输入数据的一个重构.

### 2.2.2 Sparse-DBN 的构建

在 SRBM 基础上, 进行稀疏深度置信网络(Sparse-DBN, SDBN)的构建, 如图 2 所示, 该结构由三个 SRBM 组成, 此结构既可以视为一个生成模型, 也可以作为一个判别模型.

其训练过程为上层的输出数据作为下层的输入数据来使用, 每一个隐含层经过训练得到输入层的传递信息, 即第  $n$  个( $n < 3$ )RBM 模型在第  $n-1$  个 SRBM 模型训练后开始,  $P(h_n; h_{n-1}, W)$  的输入为第  $n-1$  个 SRBM 的输出  $P(h_{n-1}, h_n; W_{n-1})$ , 而它的输出  $P(h_{n+1}, h_n; W_{n+1})$ , 就构成了第  $n+1$  个 SRBM 的输入. 最终的输出采用 sigmoid 作为输出层函数, 其公式为:




图2 DBN网络结构图

$$f(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

SDBN 结构的最后一层为微调(Fine Tune), 使用 BP 算法对判别性能做一个标签集并被附加到顶层, 给从下而上的学习设置 BP 网络用以调优, 因为 BP 算法对权值参数空间仅是一个局部的搜索, 相较于前向神经网络来说, 训练是较快的, 而且收敛的时间也少.

## 3 实验检测

实验所用到的焊缝缺陷图片来自于工业生产所拍摄的钢管焊缝缺陷 X 射线图像, 图像规格大小随机选取, 按照图像特征提取方式进行处理为  $64 \times 64$  图像块列, 并对其列向量化及能量归一化后的数据作为输入矩阵  $V$ .




图3 权衡参数与正确率的关系

由式(7)可知在 SRBM 的稀疏约束中主要的两个参数为权衡参数  $\lambda$  和稀疏常数  $p$ , 在一层 SRBM 下对两个参数进行选取试验,  $\lambda$  的测试区间为  $[0.1, 1.5]$ ,  $p$  的测试区间为  $[0, 1]$ , 试验结果如图 3, 图 4 所示, 实验结果表明:  $\lambda$  在  $[0.3, 0.5]$  区间范围内识别正确率较高,  $p$  在整个区间范围内的识别正确率




图 4 稀疏常数和正确率的关系

较为均衡,波动较小,[0.2,0.3]区间范围时识别正确率相对较高.与此同时,考虑到 SDBN 中神经元数量过多所导致的网络训练复杂程度加大,故对三层网络分别采用 128—200—200 的神经元个数结构,具体 SDBN 网络参数设置如表 1 所示:

表 1 SDBN 网络参数设置

| 网络层数 | 神经元数 | 权衡参数 | 稀疏常数 | SRBM 学习率 | SDBN 学习率 | 迭代次数 |
|------|------|------|------|----------|----------|------|
| 1    | 128  |      |      |          |          |      |
| 2    | 200  | 0.3  | 0.2  | 0.005    | 1        | 500  |
| 3    | 200  |      |      |          |          |      |

在如表 1 的参数设置下,分别对 DBN 和 SDBN 采用由浅及深的网络实验,实验目的在于论证特征稀疏性对于深度置信网络的优化与改进程度,实验结果表明:随着网络层次的深入,DBN 和 SDBN 对于焊缝缺陷识别率均有所上升;对于同样层次的网络结构:在一层网络结构时,DBN 和 SDBN 的正确识别率趋于近似,在二层网络和三层网络结构下,SDBN 的识别精度明显高于 DBN,并且随着迭代次数的增加,这种趋势愈发明显.这是由于一方面深层网络结构通过训练算法可以对错误的信息进行层层筛查并剔除,逐渐提高识别精度;另一方面,随着网络的深入和迭代次数的增加,数据的处理和训练趋于复杂化,而 SDBN 结构中的稀疏约束排除冗余信息,使数据信息更加简洁,处理更为有效,故能更好的提升目标识别的性能.

针对气孔、裂纹、夹渣、未融合、未焊透几种缺陷类型选取训练样本和测试样本各 500 个进行分类实验,同时为了验证深层网络的性能,选取经典的支持向量机(SVM)和人工神经网络(ANN)进行类比,两种方法的焊缝图像采用潜在缺陷跟踪的处理方式<sup>[7]</sup>,其中 ANN 同样采用 BP 算法,且单层的神经元数和 SDBN 设置一致,实验结果如表 2 所示,结果表明深层网络对于焊缝缺陷的分类识别精确度高

于 SVM 和 ANN,且训练数据和测试数据差异较小,避免了过拟合,提高了模型的泛化能力.

表 2 焊缝缺陷分类识别正确率

| 焊缝缺陷类型     | 实验方法 | 训练正确率(%) | 测试正确率(%) |
|------------|------|----------|----------|
| 气孔         | SVM  | 90.73    | 87.82    |
|            | ANN  | 85.95    | 84.75    |
|            | DBN  | 90.36    | 89.69    |
|            | SDBN | 91.26    | 91.40    |
| 裂纹         | SVM  | 89.67    | 86.24    |
|            | ANN  | 88.36    | 85.65    |
|            | DBN  | 91.63    | 89.72    |
|            | SDBN | 91.98    | 92.01    |
| 夹渣         | SVM  | 89.12    | 87.96    |
|            | ANN  | 87.98    | 83.24    |
|            | DBN  | 89.25    | 90.13    |
|            | SDBN | 90.69    | 92.36    |
| 未焊透<br>未融合 | SVM  | 88.69    | 85.39    |
|            | ANN  | 88.95    | 86.63    |
|            | DBN  | 90.76    | 89.39    |
|            | SDBN | 91.68    | 91.97    |

试验中 SDBN 相较于其它方法对于焊缝缺陷的图像较好的识别分类精度,是因为:一是在图像的预处理时对图像特征信息的采集进行了降维处理,在对焊缝原始图像的有效描述下,提高了深层网络数据处理,学习和训练的性能;二是 SDBN 的深层网络结构决定了数据信息的传递是自底向上,逐层抽取、抽象的,能够尽可能保留重要信息并对其进行多层表示,所以具有相较于浅层网络更为理想的识别精度;三是深度置信网络中稀疏约束的引入能够获取目标的稀疏表示,减小信息处理量,将学习和训练过程化繁为简,使得缺陷特征分类的准确性和自适应性得到了极大的提高.

4 结束语

本文针对工业生产中 X 射线焊缝图像的识别与分类,构建了一种基于稀疏性的深度置信网络,相较于其它方式(SVM, ANN, DBN),SDBN 在保留深层结构逐层鉴别特征信息可用度的同时,增加了稀疏性特征研断与筛选的能力,通过对于稀疏常数的选取,赋予 SDBN 用稀疏性鉴别图像特征的能力,更为有效的提高了焊缝缺陷识别的精度和效率.SDBN 的相较于浅层网络有更为复杂的网络结构和处理方式,一定程度上降低了数据信息处理的实效

性,对于在保持深度网络识别性能的同时进行网络结构和参数的优化是今后需要进一步研究的内容。

## 参考文献:

- [1] Zeiler M D, Fergus R. Visualizing and Understanding Convolutional Networks[C]// European Conference on Computer Vision. Springer, Cham, 2014:818-833.
- [2] 张立民,刘凯. 基于深度玻尔兹曼机的文本特征提取研究[J]. 微电子学与计算机, 2015, 32(02):142-147.
- [3] 欧阳宁,李子,袁华,陈利霞. 基于自适应稀疏表示的多聚焦图像融合[J]. 微电子学与计算机, 2015, 32(06): 22-26.
- [4] Jia, Yangqing, Shelhamer, et al. Caffe: Convolutional Architecture for Fast Feature Embedding[C]// Proceedings of the 22nd ACM international conference on Multimedia. ACM New York, NY, USA 2014: 675-678.
- [5] Hinton G E. Training Products of Experts by Minimizing Contrastive Divergence [J]. Neural Computer, 2002, 14(8):1771 - 1800.
- [6] Bishop C M. Pattern Recognition and Machine Learn-

ing (Information Science and Statistics)[M]. Secaucus, NJ, USA: Springer-Verlag New York, Inc. , 2006: 542 - 546.

- [7] Shao J, Du D, Chang B, et al. Automatic weld defect detection based on potential defect tracking in real-time radiographic image sequence[J]. Ndt & E International, 2012, 46(1):14-21.

## 作者简介:

**刘梦溪** 女, (1983-), 博士研究生, 讲师. 研究方向为智能控制, 图像与信号处理. E-mail: 26702163@qq. com.

**王 征** 男, (1982-), 博士, 讲师. 研究方向为故障诊断, 智能检测.

**宋久旭** 男, (1979-), 博士, 硕士生导师, 副教授. 研究方向为智能测控技术及电力电子技术与新型半导体器件.

**巨永锋** 男, (1962-), 男, 博士, 博士生导师, 教授. 研究方向为交通控制与管理、智能测控技术及应用和智能化工程机械.

**武晓朦** 女, (1974-), 博士, 硕士生导师, 教授. 研究方向为自动控制及智能控制.

(上接第 58 页)

- [6] 王少熙, 王康, 樊晓桢, 等. 基于商用工艺的抗辐射触发射器单元设计 [J]. 核电子学与探测技术, 2013, 33 (1): 79-84.
- [7] Balasubramanian A, Bhuva B L, Black J D, et al. RHBD techniques for mitigating effects of single-event hits using guard-gates [J]. IEEE Transactions on Nuclear Science, 2006, 52(6): 2531-2535.
- [8] 黄正峰, 彭小飞, 鲁迎春. 基于 C 单元反馈回路的容 SEU 锁存器设计 [J]. 微电子学, 2015, 45 (2): 178-183.
- [9] Neto E H, Ribeiro I, Vieira M, et al. Using bulk built-in current sensors to detect soft errors [J]. IEEE Micro, 2006, 26(5): 10-18.
- [10] Bajura M A, Boulghassoul Y, Naseer R, et al. Models and algorithmic limits for an ECC-based approach to hardening Sub-100-nm SRAMs [J]. IEEE Transactions On Nuclear Science, 2007, 54(4): 935-945.

- [11] 苏霖, 王佳, 高武, 等. 一种新颖的抗辐射加固 SR 锁存器设计 [J]. 微电子学与计算机, 2017, 34(9): 136-140.

## 作者简介:

**王 佳** 男, (1983-), 博士, 副教授. 研究方向为电源管理电路设计、传感器前端读出电路设计、辐射加固设计.

E-mail: jwang@nwpu. eed. cn.

**李 萍** 女, (1993-), 硕士研究生. 研究方向为抗辐射 DC-DC 电压变换器设计.

**郑 然** 男, (1981-), 博士, 副教授. 研究方向为 CMOS 图像传感器辐射加固设计.

**魏晓敏** 女, (1984-), 博士, 助理研究员. 研究方向为单片有源像素传感器设计及辐射加固设计.

**胡永才** 男, (1956-), 博士, 教授. 研究方向为传感器前端微电子设计.