

基于复杂网络特性的带钢 表面缺陷识别

任海鹏¹ 马展峰¹

摘要 针对带钢表面缺陷识别问题,提出一种基于动态演化复杂网络特性的特征描述方法,这些特征同时具有位移、旋转不变性、大小不变性、较强的抗干扰能力和鲁棒性,为缺陷识别提供良好的分类特征;为了提高分类器的效率,应用主成分分析法(Principal component analysis, PCA)对复杂网络特征向量进行特征降维处理;采用最优有向无环图支持向量机(Directed acyclic graph support vector machine, DAG-SVM)算法进行缺陷分类。结果表明该方法识别率高而且识别速度快。

关键词 缺陷识别, 复杂网络特征, 主成分分析法, 有向无环图支持向量机

DOI 10.3724/SP.J.1004.2011.01407

Strip Steel Surface Defect Recognition Based on Complex Network Characteristics

REN Hai-Peng¹ MA Zhan-Feng¹

Abstract A feature extraction method based on the characteristics of dynamic evolution complex networks is proposed for the strip steel surface defect recognition. The extracted features possess displacement, rotation and size invariability, strong anti-interference ability and robustness, therefore they are good classification features for steel surface defect recognition. In order to improve the efficiency of classification, the principal component analysis (PCA) is adopted to reduce the dimension of the feature vector. The directed acyclic graph support vector machine (DAG-SVM) algorithm is used for the defect classification. The experimental results show that this method is of high recognition rate and fast recognition speed.

Key words Defect recognition, complex network characteristics, principal component analysis (PCA), directed acyclic graph support vector machine (DAG-SVM)

带钢是汽车、家电、造船、机械制造、航空航天等行业的重要原材料。在生产过程中,由于原料、轧制设备、加工工艺等方面因素,导致带钢表面出现多种不同类型的缺陷。这些缺陷不仅严重影响产品的外观,而且对带钢的抗疲劳性、抗腐蚀性、耐磨性、电磁特性都有不同程度的影响,从而降低了最终产品的性能和质量。进行带钢表面缺陷的实时检测与分类,并根据不同的缺陷成因采取相应的控制手段减小缺陷发生几率,成为提高带钢产品质量的关键问题之一。目前针对带钢缺陷的图像检测和分类已经有了一些方法^[1-4],由于带钢表面缺陷形成机理复杂,使得缺陷图像类内特征离散性强,类间特征区分性差,同时现场工况复杂,采集图像中存在严重干扰,这些因素导致带钢缺陷识别率低、识别速度慢等问题。

复杂网络作为一个新兴的研究领域,其基本理论正渗透到从数理科学到生命科学、工程科学甚至社会科学等众多不同的领域中去,已成为近年来不同领域的科学家们研究的热点^[5-7]。文献[8]利用了复杂网络理论进行形状识别,受到该研究的启发,本文针对带钢表面缺陷识别问题,提出了基于复杂网络特性的带钢表面缺陷识别方法,该方法在提取缺陷图像边缘的基础上,建立图像边缘的复杂网络模型,进而用图像复杂网络的度变化特征来描述带钢缺陷。该特征具有对图像大小、位移及旋转的不变性,且具有较强的抗干扰能力和鲁棒性。为了提高识别效率,采用主成分分析方法进一步降低了特征维数,采用支持向量机实现两类区分,并进一步用最优有向无环图方法实现多类缺陷的高效识别。实验结果表明,基于复杂网络特性的带钢表面缺陷识别方法获得了很好的识别效果,识别率高,而且识别速度快。

1 基于复杂网络特性的缺陷图像特征描述

本文不涉及图像获取方法,只对基本的图像处理部分进行简单介绍,主要针对带钢表面缺陷图像的识别问题进行研究。通过大量工程实践总结,德国钢铁学会给出的钢板表面缺陷图谱^[9]如图1所示,其中有36幅标准缺陷图像,按照从左到右、从上到下的顺序,分别是不同类型的缺陷:气体夹杂(1~3)、夹层类缺陷(4~9)、裂纹类缺陷(10~15)、穿裂(16)、氧化铁皮压入(17~20)、压入类缺陷(21~23)、机械损伤(24~28)、边部缺陷(29~34)、热轧重叠(35)、横折印(36),共10个大的类别。这些图谱中每一幅都是对大量工程图像的总结和归纳得到的。




图1 带钢表面缺陷图谱

Fig. 1 Strip steel surface defect feature picture

缺陷图像特征的选取和描述,是缺陷图像识别的关键问题。文献[1]直接提取图像的几何和灰度特征来描述缺陷特征,由于缺陷尺寸、角度及灰度会发生较大变化,使得提取的特征对环境比较敏感;文献[2]用整幅二值图像作为缺陷分类特征,要适应尺寸、角度及灰度的变化必须对更多的样本进行训练,效率较低;文献[3]抽取纹理特征参数中的灰度共生矩阵作为缺陷分类特征,当缺陷类别较多时,其灰度和纹理特征区分度不明显,可分性差;传统的基于图像矩^[4]、傅里叶描述子^[10]及小波描述子^[11]等形状特征描述方法,虽然具有旋转、大小不变等特性,但这些方法对形状完整性要求较高,抗噪能力和鲁棒性较差。

收稿日期 2010-12-01 录用日期 2011-05-28
Manuscript received December 1, 2010; accepted May 28, 2011
国家自然科学基金(60804040),霍英东教育基金会(111065)资助
Supported by National Natural Science Foundation of China (60804040) and Fok Ying Tong Education Foundation (111065)
1. 西安理工大学信息与控制工程系 西安 710048
1. Department of Information and Control Engineering, Xi'an University of Technology, Xi'an 710048

1.1 缺陷图像特征的选择与提取

分析图 1 可知,带钢表面缺陷图像具有如下特点:1) 各类带钢表面缺陷图像的灰度和纹理特征基本相似,不宜作为分类特征;2) 同类缺陷的图像形状有很大差别,如夹层类缺陷(4~9)、机械损伤(24~28)、边部缺陷(29~34),使得找到相同的类内特征区分整个类与他类变得异常困难;3) 典型图谱的图像边缘是完全不同的.针对图 1 带钢缺陷图像特征,本文将类内差别较大的图像类别进一步细分为图像子类,采用缺陷形状作为区分特征,并基于复杂网络特性对缺陷形状特征进行描述,以获得更好的分类性能.

为了获得良好的形状特征,先需要对图像进行一些预处理.从现场获取的带钢图像难免会存在噪声,因此在对图像进行处理前需要对图像进行滤波处理,以减小或消除噪声对后续处理的影响.采用经典的中值滤波算法进行滤波,不但算法简单而且滤波效果较好.采用自适应迭代阈值二值化方法,根据图像灰度自适应计算分割阈值,将图像分割成缺陷和背景两部分,以突出缺陷形状特征.图像经过二值化处理后可能会存在一些小的颗粒或者毛刺等,利用数字形态学滤波算法对二值化后的图像进行滤波处理,这里使用开运算方法,即对图像先腐蚀再膨胀,这样不但有效去除颗粒、毛刺等噪声,而且能够保持目标尺寸基本不变.再采用 Sobel 边缘检测算法提取缺陷目标的边缘,进而得到缺陷的形状特征,这些特征可以进一步用下面的复杂网络进行描述.

1.2 缺陷特征的复杂网络建模与特性分析

复杂网络是由节点和连边构成的网络,是一种很宽泛、很灵活的网络,其节点是对个体的抽象,其连边是个体间关系的抽象,连边的构造对复杂网络特性起着决定性的作用.现实世界中很多事物都可以用复杂网络来描述^[5].建立缺陷特征的复杂网络模型,利用复杂网络刻画缺陷图像特征,可以将局部特性和全局特性结合,从而在图像分析过程中提供更全面、有效的特征信息.

缺陷图像的边缘像素点构成点集 $S = [s_1, s_2, \dots, s_N]$, N 为边缘像素点总数, $s_i = (x_i, y_i)$ 表示第 i 个点的坐标.本文以点集 S 中每个像素点作为复杂网络的节点,采用可以体现像素点间的相对位置关系的距离作为节点之间的连边,即每对节点 s_i 和 s_j 间的连边用它们的欧氏距离来表示:

$$d(s_i, s_j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (1)$$

于是网络可以用一个 $N \times N$ 的权值矩阵 W' 来表示: $w'_{ij} = d(s_i, s_j)$, 并将其归一化到 $[0, 1]$ 区间有:

$$W = \frac{W'}{\max(w'_{ij} \in W')} \quad (2)$$

由此构建了一个全连接权值网络,为了更好地研究节点间联系,给定一个阈值 $t \in [0, 1]$, 用算子 $\delta_t(W)$ 对权值网络进行划分,当两个节点间的连接权值大于等于 t 时,表明两个节点间关系不紧密,认为没有连边,反之则有连边.算子 $\delta_t(W)$ 如式(3)所示.

$$A_t = \delta_t(W) = \begin{cases} a_{ij} = 0, & \text{若 } w_{ij} \geq t \\ a_{ij} = 1, & \text{其他} \end{cases} \quad (3)$$

式中, A_t 是阈值为 t 时得到的复杂网络的邻接矩阵, A_t 中的元素 $a_{ij} = 1$ 表示节点 s_i 和 s_j 间有连边,相反, $a_{ij} = 0$ 表

示这两个节点间没有连边.由此便生成了一个由缺陷图像边缘像素点和这些点间位置关系构成的复杂网络.

给定一个初始阈值 T_0 , 并按一定的间隔 ΔT 递增,便形成一个阈值集合 $T = [T_0, T_1, \dots, T_n]$, 其中 $T_n = T_{n-1} + \Delta T$. 利用阈值集合 T 和式(3)可得到一组随阈值动态演化的复杂网络.在复杂网络随阈值动态演化过程中,随着阈值从小到大变化,形成不同的复杂网络,充分体现出缺陷特征从细节到整体的不同特征.而不同类型的缺陷在动态演化过程中,会有不同复杂网络特性,可以采用动态演化复杂网络度特性来描述缺陷.

复杂网络中节点 s_i 的度 k_i 是指与该节点连接的其他节点的数目.对度进行归一化处理,以使得度特性不受网络规模 N (即节点总数)的影响,关于度的几个定义式如下:归一化度: $k_i = \frac{1}{N} \sum_{j=1}^N a_{ij}$, 平均度: $k_\mu = \frac{1}{N} \sum_{i=1}^N k_i$, 最大度: $k_{\max} = \max_i k_i$. 提取每种缺陷对应的动态演化复杂网络平均度和最大度特征值组成的特征向量如式(4)所示.为了更好地描述不同缺陷特征的差异及其对应复杂网络演化过程中的动态变化,与文献[8]不同,本文采用复杂网络度特征值的变化量作为缺陷图像的特征向量,由式(5)给出.

为了说明采用式(5)方法的效果,图 2(a) 给出四类相似缺陷的图像,由图 2(b) 可见,不同类缺陷对应的度特性曲线总体都是递增的,特性差异不明显;而图 2(c) 中度特征变化量差异更明显,类间区分性明显增强.由此可见,相对于文献[8]中提取复杂网络度特征,本文所提取的度特征变化量更能体现缺陷的本质特征,更好地描述缺陷图像形状特征.

动态演化阈值的选取对缺陷特征的刻画和后续识别有重要影响.为选择合适的动态阈值演化范围,对不同阈值的复杂网络度特性进行对比,得到图 3 结果.可见,阈值过小或者过大时,复杂网络的度特性区分性变差,这些阈值下所对应的特征有较大冗余,因此阈值演化范围选取区分较明显的中间部分.阈值间隔也很重要,间隔选取小则运算量增大,而且会增加特征冗余度,间隔较大又可能错过区分度大的特征.经过大量实验和对比,本文最终选取阈值演化范围为: $T_0 = 0.05$; $T_n = 0.6$, 阈值间隔 $\Delta T = 0.05$, 得到总的特征维数为 24 维.

所提取出的 24 维特征,特征间可能具有一定的相关性,为进一步提高识别的效率,减小特征冗余,在提取出各类缺陷的复杂网络特征向量后,采用了主成分分析法(Principal component analysis, PCA)^[12] 对特征进行降维处理,取主分量累计方差贡献率为 98%, 得降维后维数为 15.

$$\mathbf{F} = [k_\mu(T_0), k_\mu(T_1), \dots, k_\mu(T_n), k_{\max}(T_0), k_{\max}(T_1), \dots, k_{\max}(T_n)] \quad (4)$$

其中, $k_\mu(T_i)$ 表示阈值为 T_i 时复杂网络平均度, $k_{\max}(T_i)$ 表示阈值为 T_i 时复杂网络最大度.


$$\Delta \mathbf{F} = [\Delta k_\mu(T_0), \Delta k_\mu(T_1), \dots, \Delta k_\mu(T_n), \Delta k_{\max}(T_0), \Delta k_{\max}(T_1), \dots, \Delta k_{\max}(T_n)] \quad (5)$$

其中, $\Delta k_\mu(T_i) = k_\mu(T_i) - k_\mu(T_{i-1})$, $\Delta k_\mu(T_0) = k_\mu(T_0)$, $\Delta k_{\max}(T_i) = k_{\max}(T_i) - k_{\max}(T_{i-1})$, $\Delta k_{\max}(T_0) = k_{\max}(T_0)$.



上述方法得到的特征具有如下特点:

1) 位移、旋转及大小不变性.在构建缺陷特征的复杂网络连接关系时,采用的是相对的欧氏距离,刻画的是像素点间的相对位置关系,以此来刻画缺陷边缘特征,没有包含绝对的空间信息,不受缺陷图像所处位置、角度的影响;采用归



一化度特征, 使得特征不受网络规模即缺陷图像大小的影响, 因此具有大小不变性. 图 4(a) 中样本 2 和样本 4 分别是对样本 1 和样本 3 旋转、放大和平移后得到的样本. 各样本对应的度特征变化如图 4(b) 给出, 可见这些特征对于位移、旋转和大小具有不变性.



(a) 四种相似缺陷样本
(a) Four similar defect samples



(b) 四种相似缺陷样本的度特征
(b) Degree characteristics of the four defect samples



(c) 四种相似缺陷样本的度变化量
(c) Degree characteristics difference of the four similar samples

图 2 相似样本度特征与度特征变化比较

Fig. 2 Comparison between degree and degree variation for similar samples

2) 抗噪能力. 在建立复杂网络模型时, 采用整个网络的最大度和平均度特征来刻画缺陷形状, 使得噪声点对整体度特性影响很小, 因此算法具有较强的抗干扰能力. 图 5(a) 中样本 2 和样本 3 是对样本 1 增加了不同能量的噪声得到的

样本, 样本 5 和样本 6 是对样本 4 增加了不同能量的噪声得到的样本. 图 5(b) 给出度特征变化量, 可见该特征对噪声不敏感, 噪声样本与原样本具有十分相似的特征.







图 3 所有缺陷度特性曲线

Fig. 3 Degree characteristics for all defect patterns



(a) 样本的位移、旋转和放缩
(a) Displacement, rotation and zoom of the samples



(b) 位移、旋转和放缩后的特征
(b) Features for displacement, rotation and zoom

图 4 特征位移、旋转及大小不变性

Fig. 4 Feature invariance for displacement, rotation and zoom

3) 鲁棒性. 所构建的复杂网络没有包含绝对的空间和节点次序信息, 只需要能代表缺陷边缘特征的一些离散点就能够较好地刻画出缺陷特征, 这便使得算法对缺陷位移、小畸变和缺失等干扰具有较强的鲁棒性.

在本文特征定义下, 不同位置、角度和尺寸以及受不同程度噪声干扰的同类缺陷具有相同或非常相似的复杂网络特性, 而不同类缺陷的复杂网络特性差异较大, 具有很好的区

分异类且聚集同类的特性, 这些特性更适合带钢表面缺陷的识别.

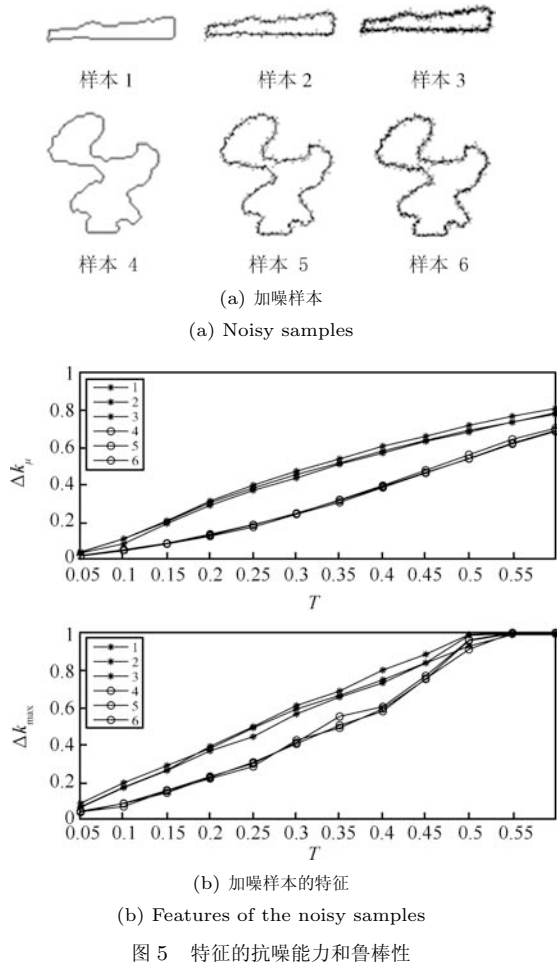


图 5 特征的抗噪能力和鲁棒性

2 带钢表面缺陷识别

支持向量机 (Support vector machine, SVM) 采用结构风险最小化准则进行训练, 在训练样本有限的情况下具有良好的推广能力, 在解决非线性、高维度以及局部极小点等问题中表现出优良的特性, 近来 SVM 也被应用于多类分类问题^[13]. 本文采用最优有向无环图支持向量机 (Directed acyclic graph-SVM, DAG-SVM) 算法^[14] 对缺陷进行识别. DAG-SVM 能够高效地将 SVM 用于多分类问题, 继承了 SVM 算法良好的分类能力, 相对于传统 1v1-SVM 多类识别算法大大提高了识别效率. DAG-SVM 算法训练时仍然采用 1v1-SVM 算法的训练方式训练出 $N(N-1)/2$ 个两类模式分类器. 而在识别时采用图 6 所示方式组织分类器, 即在测试时先进行顶端两类比较, 若类别为非 1 则继续比较 2 和 3, 若类别为非 3 则比较 1 和 2, 这样一直向下进行, 直到最低端得到判别结果. DAG-SVM 针对每个待识别样本仅需要 $N-1$ 个分类器便可以完成分类, 相对于 1v1-SVM 算法所需分类器数目 $N(N-1)/2$ 个, 效率极大提高.

DAG-SVM 算法存在误差累积效应, 即若在某个节点处发生分类错误, 则会把分类错误延续到该节点的下层节点, 分类错误在越靠近根节点的地方发生, 误差累积就越严重, 分类性能就越差, 所以分类器在有向无环图中的位置对分

类性能影响较大. 应该将差别大, 容易区分的两类模式的分类器优先放在有向无环图中靠近上层节点位置. 本文采用最优节点拓扑排序策略组织多个两分类支持向量机, 构成最优 DAG-SVM 分类器对缺陷进行分类. 设共有 N 个类别, 每类有 n 个样本, x_{ik} 表示第 i 类中第 k 个样本的特征向量. 具体步骤如下:

步骤 1. 计算各类的重心 $\bar{x}_i = \sum_{k=1}^n x_{ik}/n$;

步骤 2. 计算每个类的重心到其他类重心的距离的平均值 $\bar{D}_i = \sum_{j=1, j \neq i}^N \|\bar{x}_i - \bar{x}_j\| / (N-1)$;

步骤 3. 对数组 \bar{D} 中的元素按从大到小顺序进行排列, 得到所有类别按平均距离大小排序, 排序后类别的顺序标号为 m_1, m_2, \dots, m_N ;

步骤 4. 对新类别序列按照平均距离由大到小, 以数列的两端为起始位置交替地向中间排列, 得到最优排序序列 $m_1, m_3, \dots, m_{N-1}, m_N, \dots, m_4, m_2$ (假设 N 为偶数), 这样最优序列中越靠近数列两端的类别平均距离越大, 越靠近中间位置的类别平均距离越小;

步骤 5. 根据最优排序序列生成最优有向无环图多分类器.




图 6 DAG-SVM 3 分类算法示意图

Fig. 6 Classification procedure of DAG-SVM for 3 classes

3 实验及结果分析

本文对缺陷图谱中的类别进行重新划分, 得到 36 个子类别分别进行识别, 再将识别出的子类别归类到原先具有工程意义的大类别中去. 实验中用缺陷图谱中 36 类缺陷图像作为缺陷标准图像, 再由标准图像经过多个角度旋转、不同尺寸变化, 以及加不同强度噪声处理, 共得到 2088 幅测试图片, 其中所加噪声是给提取边缘后图像分别加入噪声强度为 1~15 dBW 的高斯白噪声. 本文结果的仿真环境均为 Intel (R) Pentium (R) 1.8 GHz PC, 2 G RAM, Matlab R2007a.

首先检验演化阈值间隔选取对识别性能和效率的影响, 表 1 中给出了不同演化阈值间隔对应的识别结果, 当 $\Delta T = 0.05$ 时获得了良好的识别结果, 而 ΔT 较小或较大时识别率均有所下降, 当 ΔT 较小时还会增大运算量.

为了比较算法识别率和效率, 本文分别用多种不同识别算法对测试样本进行识别, 它们分别是: 1) 直接模板匹配; 2) 线性判别分析 (Linear discriminant analysis, LDA); 3) BP 神经网络; 4) 1v1-SVM; 5) 最优 DAG-SVM. 仿真所使用参数及识别结果如表 2. 由表 2 可见, 本文算法在相对较短平均识别时间内能够得到最高的识别率. 各种识别算法在不同强度噪声下的识别率如表 3 和图 7 所示, 可见本文算法的对噪声的鲁棒性最强.

现有的一些图像特征描述方法, 如不变矩、傅里叶描述子及小波描述子都具有位移、旋转和大小不变性等特点, 采用这些描述算法进行特征提取, 并统一采用 DAG-SVM 算法

进行识别, 得到这些特征描述方法与本文方法的对比结果如表 4 所示. 可见, 虽然不变矩、傅里叶描述子及小波描述子都具有位移、旋转及大小不变性, 但这些描述算法不适用于存在较大噪声干扰, 特别是边缘小变形等情况, 抗噪能力和鲁棒性差. 而本文算法在具有位移、大小及旋转不变性的同时, 具有较强的抗干扰能力和鲁棒性, 能够很好地适应缺陷分类问题. 相对其他特征描述方法, 本文算法速度较慢, 但 16.3 毫秒仍可以满足实际应用要求.

表 1 阈值间隔对识别结果的影响 (识别算法: 最优 DAG-SVM)
Table 1 Effect of the threshold interval on the recognition result (optimal DAG-SVM)

阈值间隔 (ΔT)	识别率 (%)	识别速度 (ms/幅)
0.015	94.36	50.01
0.025	95.85	46.33
0.05	97.19	37.12
0.075	96.03	36.79
0.1	95.99	35.64

表 2 各识别算法识别结果比较
Table 2 Comparison of different recognition algorithms

识别算法	算法参数	识别率 %	速度 (ms/幅)
直接模板匹配	模板尺寸: 100 × 100	91.65	19
LDA	模板尺寸: 100 × 100	94.05	30
BPNN	网络结构: 15-39-1	95.55	77
1v1-SVM	RBF, $C = 10, \sigma^2 = 100$	97.14	110
最优 DAG-SVM	RBF, $C = 10, \sigma^2 = 100$	97.19	37

由上述结果可见, 与现有图像特征描述方法相比, 基于复杂网络的特征对于位移、旋转、尺寸具有不变性, 抗噪能力和鲁棒性强. 即使在采用简单的直接模板匹配法的情况下仍取得较好的识别效果. 但由于模板匹配算法固有的缺点, 当噪声级别增大时识别率大幅度下降; LDA 算法相对于模板匹配抗噪性能较好. 但线性识别算法的泛化能力差, 识别率仍不太高; BPNN 算法对于低噪声情况识别率很高, 但随着噪声级别增大识别率急剧下降, 对噪声敏感, 而且训练和识别时间都较长; 1v1-SVM 算法由于 SVM 的强分类能力, 平均识别率较高而且算法稳定, 有较强的抗噪性和鲁棒能力, 但对于多类识别问题其效率很低; 本文给出的复杂网络图像特征和最优 DAG-SVM 算法在识别率、识别速度以及抗噪能

力等多方面都获得了良好的效果.

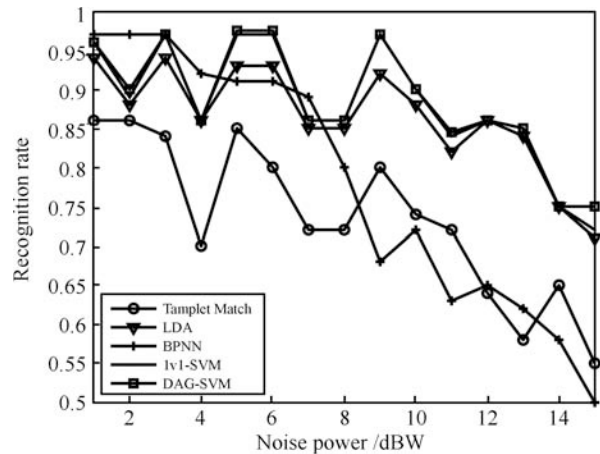


图 7 各识别算法在噪声环境下的识别率变化曲线

Fig. 7 Recognition rate curves of different recognition algorithms under different noises

表 4 不同特征描述方法识别效果比较 (识别算法: DVG-SVM)
Table 4 Recognition rate comparison of different feature description methods (DVG-SVM)

特征描述方法	特征维数	识别率 (%)	速度 (ms/幅)
不变矩	7	85.11	10.1
傅里叶描述子	20	72.57	5.9
小波描述子	40	61.19	9.6
本文方法	15	97.19	16.3

识别率是模式分类问题最直接的性能指标, 上述比较可见本文方法在各种情况下具有更高的识别率, 说明了本文方法的优越性. 为了进一步说明本文方法的识别性能, 给出了本文方法的平均接受者操作特性 (Receiver operating characteristic, ROC) 和正确率-召回率 (Precision-recall) 分别如图 8(a) 和图 8(b) 所示. 接受者操作特性和正确率-召回率都是针对两类问题的, 图 8 对应的结果是将 36 类分别看成一类对于其余类的 (一对多) 两类分类问题, 然后求取了 36 类的平均得到的结果. 可以看到本文方法的平均接受者操作特性非常靠近左上角, 而平均正确率-召回率特性非常接近右上角, 说明了本文方法的良好性能.

表 3 各识别算法在不同噪声下识别率 (%)

Table 3 Recognition rates of different recognition algorithms under different noises (%)

识别方法	噪声功率 (dBW)														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
直接模板匹配	86	86	84	70	85	80	72	72	80	74	72	64	58	65	55
LDA	94	88	94	86	93	93	85	85	92	88	82	86	84	75	71
BPNN	97	97	97	92	91	91	89	80	68	72	63	65	62	58	50
1v1-SVM	96	89	97	86	97	97	86	86	97	90	84	86	85	75	72
最优 DAG-SVM	96	90	97	86	98	86	86	97	90	84	85	86	85	75	75

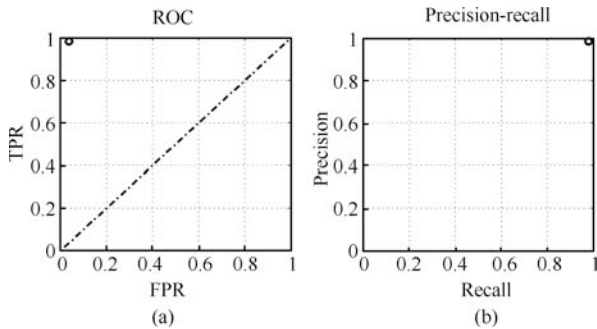


图 8 最优 DAG-SVM 分类结果的平均接受者操作特性和正确率-召回率特性 ((a) ROC 曲线; (b) 正确率-召回率特性)

Fig. 8 ROC and precision-recall feature of optimum DAG-SVM classification results ((a) ROC; (b) Precision-recall)

4 结论

本文将原缺陷分类问题转化为可分性更好的子类分类问题,采用边缘形状作为子类特征,并采用动态演化复杂网络的度变化特性对缺陷边缘特征进行描述,充分利用复杂网络的优良特性,为缺陷识别提供良好的分类特征和描述.使用 PCA 进行特征降维和最优 DAG-SVM 算法进行缺陷识别,在保证识别率的前提下,提高了识别效率.

图像中的像素及像素(灰度、色彩)之间关系可以用复杂网络中的节点和表示节点之间关系的边来描述,从这个意义上讲,图像本身就是一个复杂网络.利用这个图像复杂网络的特征,进行图像识别、修复等研究是复杂网络应用的一个重要方向.本文只是这种应用的一个初步探索,期望能够推动这方面研究的深入开展.

致谢

感谢我系 2010 年毕业生张宏欣在本论文 BP 网络方法实现上的部分仿真工作.

References

- Choi K, Koo K, Lee J S. Development of defect classification algorithm for POSCO rolling strip surface inspection system. In: Proceedings of the International Joint Conference on SICE-ICASE. Busan, Korea: IEEE, 2006. 2499–2502
- Peng K X, Zhang X L. Classification technology for automatic surface defects detection of steel strip based on improved BP algorithm. In: Proceedings of 5th International Conference on Natural Computation. Tianjin, China: IEEE, 2009. 110–114
- Han Ying-Li, Yan Yun-Hui. Discernment and classification of banding strip surface defect based on BP neural network. *Chinese Journal of Scientific Instrument*, 2006, **27**(12): 1692–1694
(韩英莉, 颜云辉. 基于 BP 神经网络的带钢表面缺陷的识别与分类. 仪器仪表学报, 2006, **27**(12): 1692–1694)
- Zhang Yuan, Chen Wan-Sheng, Zhao Jie. Classification of surface defects of strips based on invariable moment functions. *Opto-Electronic Engineering*, 2008, **35**(7): 90–94
(张媛, 程万胜, 赵杰. 不变矩法分类识别带钢表面的缺陷. 光电工程, 2008, **35**(7): 90–94)
- Barabasi A L. Scale-free networks: a decade and beyond. *Science*, 2009, **325**(5939): 412–413

- Huang Wen-Liang, Liu Yong, Zhong Zhi-Qiang, Shen Zhong-Ming. Complex network based SMS filtering algorithm. *Acta Automatica Sinica*, 2009, **35**(7): 990–996
(黄文良, 刘勇, 钟志强, 沈仲明. 基于复杂网络的垃圾短信过滤算法. 自动化学报, 2009, **35**(7): 990–996)
- He Dong-Xiao, Zhou Xu, Wang Zuo, Zhou Chun-Guang, Wang Zhe, Jin Di. Community mining in complex networks-clustering combination based genetic algorithm. *Acta Automatica Sinica*, 2010, **36**(8): 1160–1170
(何东晓, 周栩, 王佐, 周春光, 王喆, 金弟. 复杂网络社区挖掘——基于聚类融合的遗传算法. 自动化学报, 2010, **36**(8): 1160–1170)
- Backes A R, Casanova D, Bruno O M. A complex network-based approach for boundary shape analysis. *Pattern Recognition*, 2009, **42**(1): 54–67
- Verein Deutscher Eisenhüttenleute [Author], Chinese Society for Metals [Translator]. *Hot Rolled, Cold Rolled, Hot Plating and Electroplating Flat Steel Product Surface Defect Picture Spectrum*. Beijing: Iron and Steel Editor Office, 2000. 6–37
(德国钢铁学会 [著], 中国金属学会 [译]. 热轧、冷轧、热镀、电镀金属板带的表面缺陷图谱. 北京: 中国金属学会《钢铁》编辑部, 2000. 6–37)
- Wallace T P, Wintz P A. An efficient three-dimensional aircraft recognition algorithm using normalized Fourier descriptors. *Computer Graphics and Image Processing*, 1980, **13**(2): 99–126
- Chuang G C H, Kuo C C J. Wavelet descriptor of planar curves: theory and applications. *IEEE Transactions on Image Processing*, 1996, **5**(1): 56–70
- Martinez A M, Kak A C. PCA versus LDA. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, **23**(2): 228–233
- Li Jun-Tao, Jia Ying-Min. Huberized multiclass support vector machine for microarray classification. *Acta Automatica Sinica*, 2010, **36**(3): 399–405
- Qian Kun, Ma Xu-Dong, Dai Xian-Zhong, Hu Chun-Hua. Optimal DAGSVM based posture recognition for human-robot interaction. *Journal of Image and Graphics*, 2009, **14**(1): 118–124
(钱堃, 马旭东, 戴先中, 胡春华. 基于最优 DAGSVM 的服务机器人交互手势识别. 中国图象图形学报, 2009, **14**(1): 118–124)

任海鹏 西安理工大学信息与控制工程系教授. 主要研究方向为非线性动力学系统, 复杂网络, 高效电力电子电路. 本文通信作者.

E-mail: renhaipeng@xaut.edu.cn

(REN Hai-Peng Professor in the Department of Information and Control Engineering, Xi'an University of Technology. His research interest covers nonlinear dynamics, complex networks, and high efficiency power electronics circuits. Corresponding author of this paper.)

马展峰 2011 年 4 月获得西安理工大学控制理论与控制工程专业硕士学位. 2011 年 5 月进入深圳腾讯公司工作. 主要研究方向为复杂网络及其在信息处理中的应用. E-mail: mazhanfeng0624@126.com

(MA Zhan-Feng Received his master degree in control theory and control engineering from Xi'an University of Technology in April 2011. He joined Tencent Inc. (Shenzhen) in May 2011. His research interest covers complex networks and its application in information processing.)