

基于组合优化神经网络的航空发动机叶片损伤图像分割

石宏¹, 张维亮^{1,2}, 田中笑², 李楠^{1,2}, 李波²

(1. 沈阳航空航天大学 航空航天工程学部, 沈阳 110136; 2. 93057 部队, 吉林 132000)

摘要: 采用 PNN 网络和 RBF 网络相融合的方法对航空发动机叶片损伤图像进行分割, 选取损伤图像 80 个像素点的 RGB 值和 HSV 值分别作为 PNN 网络和 RBF 网络的输入样本; 针对 PNN 网络和 RBF 网络的不足, 采用 GA 算法优化 PNN 网络和 RBF 网络的输入参数; 考虑到叶片损伤图像采集过程中不确定因素对分割结果的影响, 采用 D-S 证据理论将两种网络分割结果进行融合, 进而得到最终的叶片损伤图像分割结果; 在 30 组测试样本中正确识别组数为 29, 识别率高达 96.67%, 实践表明, 该方法有效地克服了凭借单一识别网络和单一信息源进行叶片损伤图像分割的不足, 实现了对叶片损伤图像的高效分割。

关键词: PNN 神经网络; RBF 神经网络; GA 算法; D-S 证据理论; 图像分割

Segmentation of Blade Damage Image of Aero-Engine Based on Combined-Optimization Neural Networks

Shi Hong¹, Zhang Weiliang^{1,2}, Tian Zhongxiao², Li Nan^{1,2}, Li Bo²

(1. Faculty of Aerospace Engineering, Shenyang Aerospace University, Shenyang 110136, China;
2. 93057 Troop of PLA, Jilin 132000, China)

Abstract: Fusion method which is based on PNN neural networks and RBF neural networks is used for segmentation the blade damage image of aero-engine. Select 80 pixel RGB and HSV values of the image as train samples of PNN neural networks and RBF neural networks. According to the shortage of PNN neural networks and RBF neural networks, the genetic algorithm is used to optimize the input parameters of PNN neural networks and RBF neural networks. Take into account the uncertainty of aero-engine blades damage image in acquisition process, the D-S evidence theory was applied to fuse two kinds of neural networks and get the finally segmentation results. This method correctly recognize 29 groups of sample when all the samples is 30. So, the recognition rate is as high as 96.67%. The results show that this method effectively overcome the shortage of the single recognition network and single source of information for image segmentation of blade damage and this segmentation the blade damage image method is high-efficiency.

Key words: PNN neural networks; RBF neural networks; genetic algorithm; D-S evidence theory; image segmentation

0 引言

航空发动机叶片损伤图像分割是实现叶片损伤图像有效分析、叶片损伤类型准确判定和叶片损伤情况自动化评估的关键环节^[1]。由于发动机内部光照不均匀且存在大量灰尘颗粒, 导致叶片损伤图像对比度低、随机噪声多、不确定因素增加, 这些因素大大增加了分割难度, 传统的图像分割方法很难将损伤区域准确的分离出来^[2]。

随着神经网络的不断发展, 其研究成果已被应用到图像分割领域, 文献 [3] 采用 BP 网络对管道裂纹进行图像分割, 实现了管道裂纹和背景区域的有效分割; 文献 [4] 将 BP 网络成功运用于印鉴图像分割和车牌号码图像分割。但是, 由于叶片损伤图像自身的特点, 采用上述 BP 网络分割方法很难将损伤区域准确的分离出来, 鉴于上述原因, 本文采用组合优化神经网络的方法对叶片损伤图像进行分割。首先, 建立 PNN

网络和 RBF 网络并行的图像分割模型, 实现初步分割; 然后, 针对 PNN 网络和 RBF 网络的不足, 采用 GA 算法优化网络参数; 最后, 采用 D-S 证据理论进行信息融合, 得到最终的分割结果, 并且采用该方法对某飞机维修地基地采集的航空发动机叶片损伤图像进行仿真试验, 结果表明, 该方法高效的实现了对损伤区域的准确分割。

1 PNN 网络和 RBF 网络及其优化

1.1 PNN 网络

PNN 网络是一种前馈型神经网络, 采用以高斯函数为基数来形成联合概率密度分布的估计方法和贝叶斯优化规则构造神经网络, 具有很好的泛化能力和快速学习能力^[5]。PNN 网络具有两层网络, 隐含层为径向基层, 输出层为竞争型网络层。径向基函数为高斯函数, 假设网络的输入为 P , 隐节点数为 Q , Q 个隐含层神经元对应的径向基中心为 C 、阈值为 b_1 ; 输出层的连接权值为 W_2 、阈值为 b_2 , 由此可得径向基层的神经元的输出为: $a_1 = \exp(-\|C - P\|^2 \cdot * b_1)$; 输出层的神经元的输出为: $a_2 = \text{compet}(W_2 a_1)$; 本文采用 MATLAB 神经网络工具箱编写 PNN 网络图像分割仿真程序, 部分主要程序代码如下。

网络创建及训练代码: `net=newpnn(P,T,spread);`

收稿日期: 2014-01-28; 修回日期: 2014-03-08。

基金项目: 航空科学基金(2008ZG54024)。

作者简介: 石宏(1961-), 女, 辽宁沈阳人, 教授, 博士, 主要从事航空发动机制造与维修方向的研究。

网络仿真代码: $Y = \text{sim}(\text{net}, P_test)$;

其中: P 为输入样本矩阵; T 为目标样本矩阵; P_test 测试样本矩阵, $spread$ 为网络平滑因子。

1.2 RBF 网络

RBF 网络能够以任意精度逼近任意连续函数, 是一种局部逼近网络, 训练速度较快。其为两层网络结构, 隐含层为径向基层、输出层为线性层^[6], 设网络输入矩阵为 P , 径向基修正权值为 IW , 阈值为 b_1 , 输出为 a_1 , 线性层修正权值为 LW , 阈值为 b_2 , 输出为 a_2 , 则网络输出 $a_2 = \text{purelin}(LW a_1 + b_2)$, 其中 $a_1 = \|IW - P\| \cdot b_1$ 。本文采用 MATLAB 神经网络工具箱编写 RBF 网络图像分割仿真程序, 部分主要程序代码如下。

网络创建及训练代码: $\text{net} = \text{newrb}(P, T, \text{goal}, \text{spread})$;

网络仿真代码: $Y = \text{sim}(\text{net}, P_test)$;

其中: P 为输入样本矩阵; T 为目标样本矩阵; P_test 测试样本矩阵; $goal$ 为训练目标这里选取 0.001; $spread$ 为网络平滑因子。

1.3 GA 算法优化 PNN 网络和 RBF 网络参数

PNN 和 RBF 网络参数 $spread$ 对网络性能影响较大, 较大的 $spread$ 能够使径向基神经元覆盖输入向量的所有区间产生响应, 但是 $spread$ 过大会导致网络计算困难, 甚至分割结果不准确。为了提高 PNN 网络和 RBF 网络的稳定性和分割能力, 本文采用 GA 算法^[7]优化 PNN 和 RBF 网络参数 $spread$, 采用 MATLAB 编程仿真, 具体实现过程如下:

(1) 确定遗传算法初始参数, 种群规模为 50, 最大遗传代数数为 20, 采用二进制编码, 编码位数为 10, 遗传代沟 0.95, 初始交叉概率 $P_c = 0.7$, 初始变异概率 $P_m = 0.01$ 。

(2) 确定优化参数区间, 由于 PNN 网络和 RBF 网络的 $spread$ 值不宜过大和过小, 设置优化区间为 $[1, 10]$ 。

(3) 构造适应度函数, 将 PNN 网络和 RBF 网络的预测值和实际值的误差矩阵范数作为遗传算法的适应度函数。

(4) 计算个体适应度值的大小, 采用随机遍历抽样 (sus) 选择分配适应度值, 采用单点交叉方式进行交叉操作, 采用基本位变异操作进行变异操作。

(5) 重新计算目标函数值, 如果算法得到全局最优解, 则执行 (6), 否则返回执行 (4) 直到达到最大遗传代数。

(6) 将全局最优解作为网络的最优参数值, 训练 PNN 和 RBF 网络, 进而得到更加稳定、高效的分割模型。

2 D-S 证据理论的基本概率分配函数和合成规则

Dempster-Shafer 理论是经典概率理论的扩展, 具有很强的处理不确定信息能力。在 Dempster-Shafer 理论中, 一个样本空间称为一个辨识框架, 表示为 $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$, 该框架中的子集就是研究对象, 2^Θ 是 Θ 的所有子集组成的幂集, 且满足 $\phi \in 2^\Theta, \Theta \in 2^\Theta$, 这时一个命题就可以表达为 Θ 的一个子集 A , 即 $A \subseteq \Theta$ 或 $A \in 2^\Theta$ 。设 Θ 为辨别框, 函数 $m: 2^\Theta \rightarrow [0, 1]$ 称为概率分配函数, 假设对于空集 ϕ , $m(\phi) = 0$; 对于 $\forall A \in 2^\Theta, \sum m(A) = 1, m(A)$ 称为 A 的基本概率分配, 表示对命题 A 的精确信任程度, 若 $m(A) > 0$, 则称 A 为该函数的焦点^[8]。D-S 证据理论中并没有给出基本概率分配函数的一般形式, 因此在实际应用中要根据具体问题构造具体的形式。本文采用 PNN 网络和 RBF 网络的输出构造 D-S 理论的基本

概率分配函数, 具体构造过程如下:

根据推导公式 (1) 将 PNN 和 RBF 图像分割网络的输出值进行归一化处理作为每个焦点的基本概率分配。

$$m(A_i) = \frac{y(A_i)}{S} \quad (1)$$

式中, $A_i (i = 1, 2)$ 表示本文叶片损伤图像像素点的类型, 即为损伤区域像素点还是背景像素点, $y(A_i)$ 表示 PNN 网络和 RBF 网络的输出结果。

$$S = \sum_{i=1}^n y(A_i) + E_n \quad (2)$$

式中, E_n 为网络误差, 具体表示为 $E_n = \frac{1}{2} \sum (t_{nj} - y_{nj})^2$, t_{nj}, y_{nj} 对应第 j 个神经元的目标值和实际值。

D-S 证据理论的核心是 Dempster 合成规则, 设 m_1 和 m_2 是 Θ 上的两个基本概率分配函数, 则两个基本概率分配函数的合成规则为:

$$m_1 \oplus m_2 = \frac{\sum_{A_i \cap B_j = A} m_1(A_i) m_2(B_j)}{1 - \sum_{A_i \cap B_j = \emptyset} m_1(A_i) m_2(B_j)} \quad (3)$$

3 叶片损伤图像分割实例仿真

本文采用在某飞机维修基地采集的叶片损伤图像进行仿真试验, 提取 80 个像素点的 RGB 值作为 PNN 网络的训练样本, 提取 80 个像素点的 HSV 值作为 RBF 网络的训练样本, 其中 40 个为损伤区域像素点, 40 个为背景像素点, 另外采集 30 个像素点的 RGB 值和 HSV 值作为网络的测试样本, 损伤区域标签为 $\{1, 0\}$, 背景区域标签为 $\{0, 1\}$ 。采用上述方法分别建立优化后的 PNN 和 RBF 网络分割模型, GA 算法进化过程如图 1、图 2 所示, 叶片损伤原图、GA 算法优化 PNN 网络和 RBF 网络分割结果见图 3。




图1 PNN网络优化进程图




图2 RBF网络优化进程图




图 3 GA 优化 PNN 和 RBF 网络分割结果

由图 1, 图 2 可知, GA 算法迭代到第 12 代时 PNN 网络优化模型误差矩阵范数达到最小值, 得到的最优 *spread* 值为 4.44, 而遗传算法迭代到第 6 代时 RBF 网络得到的最优 *spread* 值为 4.57。由图 3 的分割结果可以看出, 优化后的 PNN 和 RBF 网络可以将图像的叶片损伤区域分离出来, 但是分割效果没有达到最佳, 主要体现在: (1) 优化后的 PNN 分割结果背景和叶片损伤区域边界分离不明显; (2) 优化后的 RBF 网络分割结果没有很好的抑制背景区域像素点, 部分背景区域像素点被识别为叶片损伤区域像素点。这些因素都对图像的下一步处理提出了更高的要求, 很可能导致处理结果不准确。

鉴于上述原因, 本文进一步建立基于 D-S 证据理论的 PNN 和 RBF 网络相融合的叶片损伤图像分割模型, 将 30 组测试样本的 RGB 值和 HSV 值分别输入到优化后的 PNN 和 RBF 网络进行初步分割, 然后将两个网络的分割结果进行融合, 得到最终分割结果。采用 MATLAB 编程仿真, 由于篇幅原因这里只列四组样本识别结果, 优化后的 PNN 和 RBF 网络分割结果见表 1, 表 2。

表 1 PNN 网络优化模型识别结果

损伤区域	背景区域	损伤区域	背景区域
0.537 5	0.034 1	0.939 6	0
0.316 9	0.155 2	0.291 5	0.300 8

表 2 RBF 网络优化模型识别结果

损伤区域	背景区域	损伤区域	背景区域
0.521 9	0.506 2	0.513 6	0.477 6
0.487 0	0.493 7	0.493 7	0.516 0

对优化后的 PNN 和 RBF 网络分割结果进行归一化处理, 根据上述推导公式 (1), (2) 构造样本的基本概率分配值, 见表 3, 运用上述推导公式 (3) 合成分割结果, 见表 4。

表 3 基本概率分配值

损伤区域	背景区域	损伤区域	背景区域
0.531 3	0.062 4	0.736 6	0
0.313 3	0.283 9	0.228 5	0.551 8
0.424 8	0.402 9	0.415 4	0.388 9
0.389 1	0.392 9	0.393 3	0.425 3

表 4 融合识别结果

损伤区域	背景区域	损伤区域	背景区域
0.649 3	0.167 5	0.772 9	0
0.350 6	0.832 4	0.227 0	1

从上表中可以看出: (1) 单一优化网络不能正确识别的像素点, 经过融合后可以正确识别, 如表 2 的第一个背景像素点, 经过融合后被准确的识别为背景像素点, 在 30 组测试样本中这样的点有 3 个; (2) 经过融合的结果更加接近标签类别, 这说明网络性能有很大的提高, 从表 4 第二个背景区域可以看出, 识别结果直接为标签 {0, 1}, 省去了判别门限的判别过程, 提高了识别率。融合后的分割结果及其形态学运算后的最终图像见图 4, 可见, 经过优化和融合后的分割模型, 分割叶片损伤图像的能力有较大的增强, 分割结果更加清晰准确, 能够达到航空发动机叶片损伤检测、叶片性能评估的要求。




图 4 融合分割结果及形态学运算后分割结果

4 结论

本文提出了一种将 PNN 网络和 RBF 网络相融合的航空发动机叶片损伤图像分割方法。实践证明, 该方法既能克服航空发动机叶片损伤图像复杂的采集环境对分割结果的影响, 又能充分发挥 PNN 网络和 RBF 网络高效的模式识别能力。通过对两种图像分割网络的融合, 克服了凭借单一网络和单一信息进行叶片损伤图像分割的不足, 提高了叶片损伤图像分割模型的识别率、稳定性和鲁棒性, 实现了叶片损伤图像的高效分割, 对后期的航空发动机叶片损伤类型判定和损伤情况评估具有重要价值。

参考文献:

- [1] 杨康叶, 邹春学. 基于 RGB 模型颜色相似性的彩色图像分割 [J]. 计算机系统应用, 2013, 22 (3): 128-131.
- [2] 许新征, 丁世飞, 史忠植, 等. 图像分割的新理论新方法 [J]. 电子学报, 2010, 38 (2s): 76-81.
- [3] 孙文雅, 黄 民, 李天剑, 等. 基于 BP 神经网络的管道裂纹图像分割 [J]. 计算机测量与控制, 2012, 20 (5): 1363-1364.
- [4] 杨治明, 王晓蓉, 彭 军, 等. BP 神经网络在图像分割中的应用 [J]. 计算机科学, 2007, 34 (3): 234-236.
- [5] 张维亮, 李 楠, 李 昂, 等. 基于概率神经网络的航空发动机叶片损伤图像分割 [J]. 沈阳航空航天大学学报, 2013, 30 (2): 22-26.
- [6] 石 宏, 张 帅, 李 昂. 基于结构最优化 RBF 神经网络的滑油金属含量预测 [J]. 润滑与密封, 2012, 37 (11): 35-38.
- [7] Srinivas M, Patnaik L M. Adaptive probabilities of crossover and mutation in genetic algorithms [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1994, 24 (4): 656-667.
- [8] 杜海莲, 吕 峰, 辛 涛, 等. 基于证据理论的优化集成分类器融合算法及应用 [J]. 化工学报, 2012, 63 (9): 2877-2881.