

文章编号:0253-9993(2007)11-1206-05

概率神经网络在矿井红外监控图像识别中的应用

孙继平, 陈伟, 王福增, 唐亮, 李彬

(中国矿业大学(北京)煤炭资源与安全开采国家重点实验室, 北京 100083)

摘要: 对粉煤图像和块煤图像灰度相关矩阵各统计量的数值进行了极差正规化处理, 并分析了其统计量的分布特征. 使用概率神经网络对粉煤图像和块煤图像进行了识别仿真. 实验结果表明, 用灰度相关矩阵各统计量作为粉煤图像和块煤图像的识别特征, 成功地识别出了粉煤和块煤的图像.

关键词: 概率神经网络; 粉煤图像; 块煤图像; 灰度相关矩阵

中图分类号: TD676 **文献标识码:** A

Application of probabilistic neural network in recognizing coalmine infrared monitoring images

SUN Ji-ping, CHEN Wei, WANG Fu-zeng, TANG Liang, LI Chen

(The State Key Laboratory of Coal Resources and Safe Mining, China University of Mining and Technology (Beijing), Beijing 100083, China)

Abstract: The normalization values of texture statistics of gray level correlative matrix were given, which were taken from the smashed-coal-images and block-coal-images. The distribution feather of statistical variables was analyzed. Recognizing the smashed-coal-images and block-coal-images was simulated with a probabilistic neural network. The experiment results show that the statistical variables of the gray level correlative matrix act as the recognizable feather, and the algorithm can recognize the smashed-coal-image and block-coal-image successfully.

Key words: probabilistic neural network; smashed-coal-image; block-coal-image; gray level correlative matrix

矿井火灾是直接威胁矿井安全生产的主要灾害之一, 我国有 56% 的煤矿存在自然发火问题, 在统配和重点煤矿中具有自然发火危险的矿井约占 47%, 矿井自然发火又占总发火次数的 94%, 其中采空区自燃则占内因火灾的 60%^[1]. 在矿井通风良好的状态下, 破碎状态或粉状的煤比块状的煤有更高的自燃可能性^[2].

矿井图像监控是增强煤矿安全生产、提高生产率和矿井自动化生产水平的重要措施, 基于计算机系统的矿井红外监控系统对井下粉煤和块煤的图像进行正确的识别, 不仅可以实现对矿井自燃图像监控区域中粉煤易自燃区域的自动识别和重点监控、定位及预测, 还可以进一步实现对粉煤和块煤的自动分类和分选, 提高煤矿的安全生产水平和经济效益.

J. Dehmeshki 等人利用多值分割技术对煤块的图像进行分类, 得到了良好的应用效果^[3]; 细胞神经网络技术在选煤图像的处理中得到了成功的应用^[4]; 国内的研究人员通过细致、深入地研究, 研制了基

收稿日期: 2007-09-24 责任编辑: 许书阁

基金项目: 教育部博士点基金资助项目(20050290010); 北京市教育委员会共建经费研究生教育资助项目

作者简介: 孙继平(1958-), 男, 山西翼城人, 教授, 博士生导师. 联系人: 陈伟(1978-), 男, 江苏邳州人, 博士研究生.

Tel: 010-62331011; 010-51733083, E-mail: chenwei13046@163.com

于红外探测技术的矿井远程视频监控系统, 实现了对井下图像的监控^[5,6], 发展了基于一维小波分析和 BP 网络的图像识别的方法, 并成功地应用于煤矿井下带式输送机煤流图像的快速识别^[7]等. 国内外的研究成果为矿井红外监控图像中破碎状态或粉状的煤和块煤识别的研究打下了良好的基础. 煤矿井下的环境特殊、多变, 对井下监控图像中不同对象有效识别的问题仍需要进行深入的探讨.

1 基于概率神经网络的识别原理

在模式识别研究中, 人工神经网络是重要的分类器, 其类型和应用比较多, 常用的有感知器、BP 网络及径向基神经网络. 径向基神经网络比感知器、BP 网络需要更多的神经元, 但是它设计和训练的时间比较短, 应用效果好. 在径向基神经网络中, 概率神经网络 (Probabilistic Neural Networks, PNN) 常用于模式分类的问题, 它包含一个径向基网络层和一个竞争网络层. 网络在工作时, 径向基网络层首先计算输入向量与训练向量间的距离; 竞争网络层根据输入向量到每一模式类之间的距离的大小来输出概率向量, 并由竞争激活函数选择最大的概率向量, 输出相应的类别. PNN 的结构如图 1 所示*. 其中, \mathbf{P} 为输入向量; R 为输入向量中元素的数目; Q 为径向基网络层神经元数目, 即输入/目标对的数目; K 为竞争网络层神经元数目, 即输入向量类别的数目; $\mathbf{I}_{w_{1,i}}$ 为径向基网络层的权值矩阵; $\mathbf{I}_{w_{1,i}}$ 为 $\mathbf{I}_{w_{1,i}}$ 的第 i 列向量; $\mathbf{L}_{w_{2,i}}$ 为竞争网络层的权值矩阵.

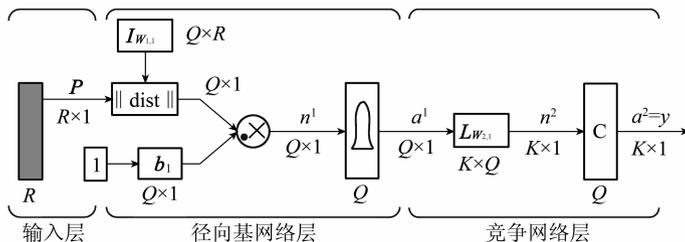


图 1 概率神经网络结构

Fig. 1 Illustration of PNN

$$\mathbf{b}_1 = 0.5 \times (-\lg 0.5) / \text{spread}, \quad a_i^1 = \text{radbas}(\|\mathbf{I}_{w_{1,i}} - \mathbf{P}\| \cdot \mathbf{b}_i^1), \quad (1)$$

$$\text{radbas}(n) = e^{-n^2}, \quad a^2 = \text{compet}(\mathbf{L}_{w_{2,i}} a^1),$$

式中, \mathbf{b}_1 为径向基网络层的偏值向量; spread 为径向基函数的扩展系数, 常取 1.0; b_i^1 为 \mathbf{b}_1 的第 i 个值; radbas() 为径向基函数; compet() 为竞争函数; a^1 为径向基网络层的输出; a^2 为竞争网络层的输出.

在研究中, 待识别的是粉煤和块煤两类稳定的对象, 但是其图像的可识别特征比较分散, PNN 适合作为这类问题的分类器. 基于此网络的粉煤和块煤图像识别系统的设计如下:

(1) 提取粉煤和块煤图像的识别特征, 并对特征数据进行相应的预处理.

(2) 设计 PNN. 给定一组训练集输入向量和一组目标向量, 调整网络的权值和阈值, 使网络有稳定的输出.

(3) 测试 PNN. 输入测试集向量, 如果待测试的向量与网络设计时某个输入向量接近, 网络最有可能输出该输入向量所属的模式类, 说明网络设计成功; 否则认为设计不成功, 返回 (2).

(4) 存储设计成功的 PNN 的权值和阈值.

(5) 输入新的向量, 利用设计成功的 PNN 进行模式识别, 网络将输出该向量所属模式的类别.

2 粉煤和块煤图像的识别特征

基于红外图像技术的视频采集系统比较适用于井下视频监控^[5], 在研究中, 使用自带 6 个红外发光管

的强红外线夜视 CCD 摄像机, 型号为 D&F - DF - 117, 使用 $f - 3.6 \text{ mm}$ 的原配镜头, 在平顶山矿务局六矿丁四采区大巷中, 从侧面俯视方向拍摄的井下巷道中的监控对象的典型图像如图 2 所示, 前 4 幅为粉煤的图像, 后 2 幅图像中存在块煤。

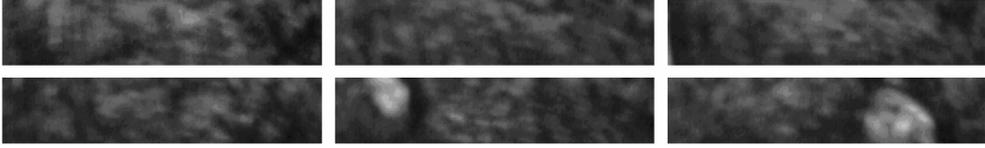


图 2 粉煤和块煤的红外视频监控图像

Fig. 2 Infrared video surveillance images of coal dust and block coal

块煤和粉煤在几何形状和空间位置的分布上是不规则的, 井下监控图像的灰度对比度也不是很大, 这为基于矿井图像监控的块煤和粉煤的自动识别带来了很大的困难, 为此在研究中采用了灰度相关矩阵各统计量作为其识别特征。

灰度相关矩阵用图像灰度的数量、灰度值以及像素间邻域灰度的关系来描述图像特征。对图像 $F(i, j)$ 的邻域距离为 d , 灰度值差为 a 时, 相关矩阵 $Q(k, s)$ 的各元素值定义为

$$Q(k, s) = \#\{(i, j) \mid F(i, j) = k, \#\{(q, r) \mid \rho((i, j), (q, r)) \leq d, \mid F(k, s) - F(q, r) \mid \leq a\} = s\},$$

式中, $(i, j), (q, r) \in F$, $\#$ 为集合中元素的数值; $\rho((i, j), (q, r))$ 为像素 (i, j) 与 (q, r) 之间的距离; d 和 a 为根据图像粗度而选取的正整数值。

对灰度集表示的图像, $Q(k, s)$ 表示的是图像中每个像素与周围 8 个像素灰度值相关的信息, 与统计的角度无关; $Q(k, s)$ 中元素的分布反映图像的粗度和细度。其相关的统计量有二阶矩、灰度不均匀度、邻域不均匀度和熵, 其计算公式分别为

$$M_2 = \sum_{k=1}^K \sum_{s=1}^S [Q(k, s)]^2 / \Delta, \quad G_{\text{NU}} = \sum_{s=1}^S \left[\sum_{k=1}^K Q(k, s) \right]^2 / \Delta,$$

$$B_{\text{NU}} = \sum_{k=1}^K \left[\sum_{s=1}^S Q(k, s) \right]^2 / \Delta, \quad H_n = - \sum_{k=1}^K \sum_{s=1}^S Q(k, s) \log_2 [Q(k, s)] / \Delta,$$

其中, $\Delta = \sum_{k=1}^K \sum_{s=1}^S Q(k, s)$ 。对红外图像视频采集系统采集到的 30 幅典型图像进行计算, 其数据结果见表 1^[6]。

表 1 各统计量计算结果 (30 幅图像)

Table 1 Results of each statistical variable (30 images)

序号	二阶矩	灰度不均匀度	邻域不均匀度	熵	类别	序号	二阶矩	灰度不均匀度	邻域不均匀度	熵	类别
1	108.133	228.473	6 278.0	-6.376 2	1	16	26.978	76.006	1 911.7	-3.515 1	2
2	206.924	373.412	5 757.4	-5.687 0	1	17	20.068	67.140	2 565.8	-3.753 7	2
3	185.620	481.308	4 586.7	-8.957 3	1	18	11.924	50.989	1 813.8	-3.997 3	2
4	90.451	550.600	6 434.2	-5.647 4	1	19	139.894	480.072	6 084.4	-5.734 9	1
5	145.770	337.925	5 151.3	-5.581 3	1	20	91.443	494.750	4 014.5	-6.525 7	1
6	96.513	398.297	5 112.5	-6.154 7	1	21	75.589	272.057	3 917.6	-8.775 9	1
7	64.877	427.164	5 194.6	-6.297 4	1	22	108.859	269.654	5 413.8	-8.160 2	1
8	77.679	331.421	5 014.5	-5.959 9	1	23	83.139	322.456	4 064.2	-5.927 7	1
9	101.866	433.367	4 995.8	-6.320 4	1	24	161.756	275.110	4 642.3	-7.532 2	1
10	8.578	24.512	1 835.3	-4.135 1	2	25	10.879	31.731	2 608.1	-2.639 6	2
11	17.526	73.242	2 581.5	-3.312 5	2	26	24.957	56.399	1 915.6	-4.592 3	2
12	14.543	60.007	1 209.3	-3.745 9	2	27	8.502	86.098	1 776.4	-2.879 0	2
13	24.408	59.746	1 297.9	-4.117 8	2	28	28.237	81.177	2 415.9	-4.872 9	2
14	9.030	28.403	1 616.5	-2.715 1	2	29	18.498	25.666	2 527.4	-3.108 2	2
15	31.655	24.019	2 310.8	-4.311 0	2	30	14.313	41.591	1 118.4	-3.903 6	2

在表 1 中，共有两类待识别的模式：粉煤图像和块煤图像，分别用 1 和 2 作为类型标识。30 组数据中，序号 1~9 和 19~24 为粉煤图像的灰度相关矩阵各统计量数据，分别作为粉煤图像的训练集和测试集；序号 10~18 和 25~30 为块煤图像的灰度相关矩阵各统计量数据，分别作为块煤图像的训练集和测试集。

表 1 中不同的纹理统计量之间的数值相差很大，为了更有效地分析其统计特征，提高神经网络的识别效率，对各个纹理统计量的数值进行极差正规化处理，即

$$A[i] = \frac{a[i] - \min(a)}{\max(a) - \min(a)} \quad (i = 0, 1, 2, 3, \dots, n), \quad (2)$$

式中， A 为极差正规化后的纹理统计量数组数据； a 为纹理统计量数组数据； $\min()$ 和 $\max()$ 分别为计算最小值和最大值的函数。

邻域灰度相关矩阵各统计量的数据经过极差正规化后，数值分布在 $(0, 1)$ 范围内，不同统计量之间数值的差别变小，其分布如图 3 所示。

在图 3 中，横坐标为纹理统计量：二阶距、灰度不均匀度、长度不均匀度和熵；纵坐标为极差正规化后纹理统计量的值。

从图 3 可以看出，两类待识别模式的数据各自聚集在一起，说明这两类数据的均值是不相等的；块煤图像的数据曲线比粉煤图像的数据曲线更集中，说明其方差比较小；这两类模式是可分的，对这两类数据的分类和识别是有意义的；

二阶距、灰度不均匀度和长度不均匀度的统计可分离性要比熵的好。

由径向基网络层输出的计算公式 (1) 表明，当输入的特征数据很大时，如二阶距、灰度不均匀度和长度不均匀度的原始数值作为网络的输入数据，在网络设计的初始阶段， $\|I_{w_{1,1}} - P\| \cdot \times b_i^1$ 的值会很大，其输出 a^1 的值也很容易为 0，增加权值和阈值调整的次数；网络稳定后，其权值和阈值在数值上的差别也比较大。

特征数据经过极差正规化处理之后，训练样本向量中的元素在数值上都分布在 $(0, 1)$ 范围内，便于网络的权值和阈值的调整。

在网络的仿真或实际应用中， $\min()$ 和 $\max()$ 分别保留为训练样本的最小值和最大值，使用式 (2) 计算输入数据，基本上可以将输入向量中的元素映射到 $(0, 1)$ 范围内；对于输入向量中的元素特别大或特别小的数据或待识别向量中的元素的数据经过映射后不会偏离 $(0, 1)$ 范围太大，从而可以使网络的训练和仿真比较稳定。

3 实验结果

在实验中，将表 1 中的数据进行极差正规化处理，其前 18 组统计量的数据作为 PNN 设计的训练集数据，后 12 组数据作为 PNN 的测试集数据。在设计 PNN 中，径向基网络层和竞争网络层各有 18 个神经元，网络训练成功后的权重和阈值见表 2。

将表 1 中序号为 19~24 的粉煤测试集特征值输入 PNN，网络的输出值均为 1，说明 PNN 能根据这些特征值正确识别出粉煤图像，这些图像即是矿井红外图像监控系统中易燃区域的图像；将序号为 25~30 的块煤测试集的特征值输入 PNN，网络的输出值均为 2，说明这个 PNN 也能正确识别出块煤图像，此图像是矿井红外图像监控系统中非易燃区域的图像。

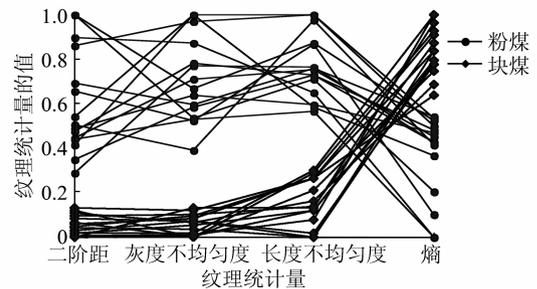


图 3 各统计量分布 (30 幅图像)

Fig. 3 Distribution of each statistical variable (30 images)

表2 PNN的权值和阈值
Table 2 Weights and bias of PNN

序号	$I_{w_{1,1}}$				b_1	$L_{w_{2,1}}$	序号	$I_{w_{1,1}}$				b_1	$L_{w_{2,1}}$
1	0.501 9	0.388 3	0.970 1	0.413 5	8.325 5	1	10	0	0.000 9	0.119 8	0.772 5	8.325 5	2
2	1.000 0	0.663 5	0.870 5	0.523 9	8.325 5	1	11	0.045 1	0.093 5	0.262 6	0.904 3	8.325 5	2
3	0.892 6	0.868 4	0.646 4	0	8.325 5	1	12	0.030 1	0.068 3	0	0.834 9	8.325 5	2
4	0.412 8	1.000 0	1.000 0	0.530 2	8.325 5	1	13	0.079 8	0.067 8	0.017 0	0.775 3	8.325 5	2
5	0.691 7	0.596 1	0.754 5	0.540 8	8.325 5	1	14	0.002 3	0.008 3	0.077 9	1.000 0	8.325 5	2
6	0.443 3	0.710 8	0.747 0	0.449 0	8.325 5	1	15	0.116 3	0	0.210 8	0.744 3	8.325 5	2
7	0.283 8	0.765 6	0.762 8	0.426 1	8.325 5	1	16	0.092 8	0.098 7	0.134 4	0.871 8	8.325 5	2
8	0.348 4	0.583 8	0.728 3	0.480 2	8.325 5	1	17	0.057 9	0.081 9	0.259 6	0.833 6	8.325 5	2
9	0.470 3	0.777 4	0.724 7	0.422 4	8.325 5	1	18	0.016 9	0.051 2	0.115 7	0.794 6	8.325 5	2

4 结 论

(1) 在对粉煤和块煤矿井红外监控图像的识别中,采用邻域灰度相关矩阵各统计量作为其可识别特征量,可以使这两类图像在统计上得到较好的分类.对监控图像的邻域灰度相关矩阵各统计量的数值进行正规化处理,便于直观地分析其分布特性;通过对网络输出的分析表明,数据的正规化处理方法可以提高网络的可训练性和识别仿真能力.

(2) 本文设计的算法对粉煤和块煤红外视频监控图像进行识别仿真的结果很稳定;算法能成功地实现矿井红外图像监控系统中粉煤区域图像的识别,为进一步开发煤矿井下煤自燃的智能监控系统提供了理论基础.

参考文献:

- [1] 鲜学福,王宏图,姜德义,等.我国煤矿矿井防灭火技术研究综述[J].中国工程科学,2001,3(12):28~32.
- [2] Rosema A, Guan H, Veld H. Simulation of spontaneous combustion, to study the causes of coal fires in the Rujigou Basin [J]. Fuel, 2001, 80: 7~16.
- [3] Dehmeshki J, Daemi M F, Miles N J, et al. Classification of coal images by a multi-scale segmentation techniques [A]. 1995 Proceedings of International Symposium on Computer Vision [C]. Coral Gables: IEEE, Inc., 1995. 271~276.
- [4] Jeanmeure L F C, Zimmerman W B J. A CNN video based control system for a coal froth flotation [A]. Vedat Tavsanoglu. 1998 Fifth IEEE International Workshop on Cellular Neural Networks and Their Applications Proceedings [C]. London: Institute of Electrical and Electronics Engineers, Inc., 1998. 192~197.
- [5] 孙继平,关永,张杰. DSP 极低码率的矿井远程视频监控系统 [J]. 西安科技学院学报, 2003, 23 (3): 283 ~ 286.
- [6] 关永. 基于红外探测技术的矿井远程视频监控系统 [D]. 北京: 中国矿业大学 (北京), 2004.
- [7] 孟凡芹,王耀才. 煤矿井下带式输送机煤流图像识别方法的研究 [J]. 煤炭学报, 2003, 28 (1): 91~95.