

第一届 **太普华南杯** 数据挖掘建模竞赛

题 目 道路缺陷自动识别

队 长 李银城

成 员 李燕珊

学校(院系) 华南师范大学

指导教师

完成时间 2013-04-20

综合评定成绩：_____

评委评语：

评委签名：

道路缺陷自动识别

摘 要:

本文对原始图像采用灰度化、线性和分段增强对比度去噪、二值化、最后去除小区域的图像处理技术进行预处理，对预处理后的不同缺陷类型图像我们建立了两个识别模型：

①通过提取条纹特征、形状特征，运用 Apriori 算法获取频繁集，建立了关联分析模型；

②进行 LBP 纹理特征提取，并采用支持向量机的方法建立识别模型，以准确率的比较作为反馈，选取最优的 SVM 参数，调节基于支持向量机的识别模型；

以上两种模型的建立都很好的解决了道路路面识别的问题，并在此基础上提出一种模型新构想，即用深度学习的机器算法 DBN 建立识别模型；

关键词：灰度化、去噪、二值化、LBP、SVM、DBN、关联分析、Apriori、频繁集、模式识别

Automated recognition of road defects

Abstract:

In this paper, firstly, we use the technology of gray linear ,denoising enhance contrast and segmentation, binarization, removal of a small area to process the original image . Then we establish two recognition model:

① we establish an association analysis model, in which we extract 6 features including stripe and shape and get the frequent itemset by Apriori to build the association.

② we use the LBP pattern to extract texture features,then establish the recognition model based on support vector machine,use the accurately rate as feedback to select the optimal SVM parameters to adjust recognition model;

The establishment of the above two models are great to solve the problems ,and finally we think a new model that deep learning machine algorithm DBN to build recognition model;

Key words: image of gray, denoising, binaryzation, LBP, SVM, DBN, association analysis, frequent itemset, pattern recognition

目 录


1. 研究目标.....	6
2. 分析方法与过程.....	6
2.1. 总体流程	6
2.2. 图像预处理	7
2.3. 建立模型	13
2.3.1 基于关联规则的图像挖掘模型	13
2.3.2 基于支持向量机的图像挖掘模型	17
2.3.3 基于机器学习的深度学习网络算法的模型新构想	21
3. 结论	24
4. 附录	24
5. 参考文献.....	25

1. 挖掘目标

本次建模目标是利用不同道路缺陷类型图像，采用图像处理技术，对不同缺陷类型进行纹理特征提取，并采用数据挖掘技术进行模式识别，实现不同道路缺陷类型的自动识别。

2. 分析方法与过程

2.1. 总体流程



本用例主要包括如下步骤：

步骤一：数据准备

题目提供的数据资源比较少，共有 5 类 25 张图片，因此，本文仍需搜集图像资源，即实地拍摄图像，并根据图像请地理科学专业学生辨别分类。

步骤二：数据抽取

由数据准备阶段得出的原始数据比较杂乱，经过筛选，得出 50 张图像，各类 10 张，建立样本库。

步骤三：数据预处理

图像数据由于颜色以及环境等因素造成噪声比较大，而本文主要是根据提取出图像的纹理几何特征进行建模，因此在这一阶段本文对图像进行灰度化，以及

去噪，最后二值化处理，得到只留下目标物体的二值化图像。

步骤四：建立模型

本文建立了两种模型，一种是基于关联规则的方法，另外一种是基于支持向量机的数据挖掘模型，并提出以机器学习的深度学习网络算法建立模型的新构想。

步骤五：结果分析

模型的评判标准，以分类的准确率作为评价标准，根据准确率对整个模型进行反馈调节，最终得出一个分类模型，识别新图像。

2.2. 图像预处理

由于原始图像不仅数据量丰富，而且含有很多不相干的信息。因此在进行数据分析之前需要对图像进行预处理。对于一张大小为 500×500 的 24 位 BMP 图像，其数据量达到 $500 \times 500 \times 3 = 750000$ ，即一张普通的位图，在计算机进行运算时一次就得处理 75 万个整型数。并且大多的数据是不必要的，是噪声数据，因为对本题来说只需抽象出地面的缺陷形状即可。因此先进行预处理是很有必要的，不仅可以减少计算量，而且可以提高准确度，直接影响到之后数据分析结果的好坏。本文采用的预处理的流程见图 1：




图 1 图片预处理流程

步骤 1：灰度化

采用灰度化算法将 R、G、B 三通道变为单通道。本文采用加权平均算法，根据人眼对蓝绿红的敏感程序的不同（绿 > 红 > 蓝），依次加权^[1]：

$$f(i,j) = 0.59 \times G(i,j) + 0.30 \times R(i,j) + 0.11 \times B(i,j)$$

加权平均算法能够得到较为合理的灰度图。效果见图 2：




图 2

灰度化处理将数据量减少到了原始图像的 1/3，为进一步的处理提供便利。对其它一些图像挖掘模型来说，灰度化减少了计算量的同时，也减少了数据量，因此对之后的分析造成精度降低的影响。但对本题来说，图像彩色或灰白，无关紧要，因为我们只需要进行二值化抽象出地面（缺陷）的轮廓。

步骤 2：线性增强对比度

由于一些图片在拍摄环境较暗或较亮时，或者由于设备原因，导致曝光不足或过度，使得图片整体偏暗或偏亮，地面缺陷不明显，或者图片的灰度值集中在某个区域，导致区分度不高，进一步影响二值化的处理效果。如果先进行线性增强对比度，对这种图片的二值化处理效果会有明显的提高。

线性增强对比度的方法很简单，就是将图片的灰度值范围从原来的例如[20, 160]，按照比率关系拉伸到[0, 255]。计算公式：

$$f(i,j) = f(i,j) \times \frac{255}{\max(f) - \min(f)}$$

如图 3 所示，




图 3 线性增强对比度效果

原始图像的灰度值集中分布在[100, 150]之间，进行灰度化处理后，主体部分拉伸到[75, 150]，并且[0, 255]之间都有像素分布，即分布更加均匀，图片效果如图 4：




图 4

从图 4 可以看出，如果直接将灰度化后的图像二值化，由于像素分布的不平均，导致图像绝大部分的灰度值被致为 255，即为白色，而经过线性增加对比度处理的有明显的效果（在二值化部分会具体展开讨论）。

步骤 3：分段增强对比度

通过观察地面缺陷的图片可以看出，存在严重缺陷的地面，缺陷部分相对于其它部分，都有明显偏白或偏黑，例如，对于严重裂缝、网裂、龟裂，缝痕部分都会偏暗，因为缝的深度影响，使得缝的反射光线不强，因此比较暗，而对于坑槽会偏亮。

根据这个特点，可采用分段线性增强对比度的方法，使得亮暗区分更加显著。

分段增强对比度的方法可将灰度值位于两端的像素——本文采取的范围是 $[0, 97]$ 以及 $[197, 255]$ ，分别压缩至 $[0, 7]$ 和 $[245, 255]$ ，如图 5 所示：





图 5 分段增强对比度效果



可以看出，增添了分段增强对比度的处理后抽取缺陷形状的效果更加明显。

步骤 4：二值化

二值化的目的是抽取目标物体。简单的做法是设定一个阈值，将灰度值小于这个值


的置为 0，大于等于这个值的置为 255，将整个图像置只有黑和白的效果。见图 5。

还有一种做法是采用“迭代阈值法”，^[2]其计算较为复杂，并且对于本模型效果不好。而采用直接设定阈值的方法，简单且效果理想。阈值的选取很关键，直接影响抽取目标物体的效果。本文采取 $[0, 255]$ 下四分之一位的阈值，即为 $\theta = 255 \times 0.75$ ，结果表明，该方法对本模型具有普遍性和适用性。

步骤 5：去除小区域

从图片 5 可以看出，二值化后的图片往往具有很多面积很小的零碎区域，这些区域是路面产生的一些噪点，需要将其去除。

首先采用区域标记算法^[3]，统计连通区域的个数 N ，以及每个连通区域的像素个数 $n_i (i = 0, 1, 2 \dots N)$ ，将 n_i 进行排序，取其上四分之一位的值 n_j ，将 n_j 作为阈值。对每个连通区域，如果其像素个数小于 n_j ，则将该区域去除，即将灰度值置为 255，相反则保留。如图 6 所示：






图6 区域标记算法去除小区域

可以看出去除了很多噪点。

至此，整个图像预处理过程结束，为下面的图像数据分析垫定了一个很好的基础。

2.3 建立模型

2.3.1 基于关联规则的图像挖掘模型

2.3.1.1 特征值提取

(1) 形状特征

形状特征在路面类型识别中占有比较重要的地位，本文采用紧凑度的方法来定量描述表状特征。紧凑度是根据周长 C 和面积 S 计算出来的参数：

$$\rho = \frac{C^2}{4\pi S}$$

当目标区域形状为圆形时，其紧凑度为 1，其它形状均大于 1。

其中面积 S 定义为经过二值化操作后图像上所有目标区域（非白色像素）的个数，简单起见，周长 C 定义为目标区域轮廓的像素个数。目标区域的轮廓可由 Sobel 算子^[4]得到，如图 7：




图 7 Sobel 算子效果

通过训练样本的计算结果可见，各种类型的路面紧凑度有着明显的区别：

表 1

路面类型	好	坑槽	龟裂	裂缝	网裂
紧凑度（平均）	1685.522	182.2011	760.7549	1.954099	288.6835

（2）纹理特征

同种的地面类型在局部上可能呈现某种不规则性，而在整体上却呈现某种规则性，纹理特征能够描述这种规律性。本文采用基于灰度共生矩阵的方法提取纹理特征，这种方法不仅简单，而且能够反映不同灰度像素的空间信息。本文使用此方法一大特点是：在根据二值化的图像目标区域的位置，将目标区域还原为原 256 阶的灰度图。这样子大大减少了无关信息的干扰。然后再计算灰度共生矩阵^[5]。

共生矩阵中的元素 $c_{i,j}$ ：

$$c_{i,j} = p(f_i, f_j, d, \theta)$$

$p(f_i, f_j, d)$ 表示图像是在 θ 方向上距离为 d 的两个灰度值为 f_i, f_j 出现的联合概率，这个概率值可以通过计算图像上距离为 d ，并且灰度值分别为 f_i, f_j 的点对的出现数目 $n_{i,j}$ 来确定。设 n 为图像上距离为 d 的点对的总数，则共生矩阵的元素可以表示为：

$$c_{i,j} = \frac{n_{i,j}}{n}$$

由灰度共生矩阵可计算出各种统计量，本文采用以下五个统计量：能量、熵、惯性矩、局部平稳性、相关性。

（1）能量，它反映的是图像灰度分布均匀性的度量，其计算公式：

$$\text{Energy} = \sum_i \sum_j (c_{i,j})^2$$

(2) 熵，当灰度矩阵各元素相差不大且分布较散时，其值较大，反之较小：

$$\text{Entropy} = \sum_i \sum_j c_{i,j} \log c_{i,j}$$

(3) 惯性矩，对于粗纹理，其值较大，反之较小：

$$\text{InertiaQuadrature} = \sum_i \sum_j (i - j)^2 c_{i,j}$$

(4) 相关性用来描述行或列之间元素的相似性。

本文对所有样本计算 0、45、90、135 度方向上的以上五个特征值，取其平均值，作为另外五个特征值。另外可取这五个特征值的标准差得到另外五个特征值，但考虑到样本数量较小，不再细取。

考虑到颜色对本模型影响不大，因此不取颜色特征。

(3) 选取特征

综上，本模型总共选取了 6 个特征值，并且 SQL Sever 制作了一个数据库，使用 VC++ 的 ODBC 连接，方便数据的存放与分析，有较好的扩展性，并且当训练样本较大时，这种优点更加明显。

2.3.1.2 关联规则分析

(1) Apriori 算法

本文采用主流的 Apriori 算法^[6]进行关联分析。

Apriori 算法是一种宽度优先算法，通过对数据库的多趟扫描发现所有的频繁项目集。算法的基本思想是：在第 K 趟扫描过程中，只生成长度为 K 的频繁项目集。以前一趟生成的所有频繁项目集为基础，生成新的候选项目集，然后扫描数据库，计算这些项目集的支持度，按照给定的支持度确定频繁项目集。

重复上述过程直至不再生成新的项目集为止。其基本流程如下：

- (1) 首先计算所有的候选 1-项集的集合 C_1
- (2) 扫描数据库，删除其中的非频繁项子集，生成频繁 1-项集的集合 L_1
- (3) 将 L_1 与自己连接生成候选 2-项集 C_2
- (4) 扫描数据库，删除 C_2 中的非频繁子集，生成频繁 2-项集 L_2
- (5) 以此类推，通过 k-1-项频繁项集 L_{k-1} 与自己连接生成候选 k-项集 C_k ，然后

生成频繁 k -项集 k_l ，直到不再有频繁项集产生为止。

其中，项的集合称为项集。包含 k 个项的项集称为 k -项集。

(2) 构造频繁项集

从 Apriori 算法的描述中可知，首先要构造 1-频繁项集。上文提到的提取的 6 个特征值并不能直接作为 1-频繁项集，因为它们可以取任意值，而频繁项集中的项要么出现要么不出现，是布尔型的。因此需要对提取到的六个特征值进行转换，本文采取的方法为——对每个特征值划分区间，本文按将每个特征的范围划分为三个等间区间，将特征值的不同取值映射到得分高、中、低的三个区间，用 1、2、3 标记。不同的特征值也用数字标记，并跟得分组合。例如，若频繁项集中出现 61，则表示该图像凑度得分低。

与此同时，将不同的地面类型也用数字标记，从 1 到 5 分别表示不同的类型。由此一个频繁项集中出现个位数字的表示地面类型，出现两位数字的表示相应特征值相应得分。至此频繁项集便构造完毕。25 个样本的初始化频繁项集可以附录 1。

(3) 生成关联规则

初始化频繁项集后，设定最小支持度，由 Apriori 算法得出最终的频繁项集，便可由这些频繁项集生成关联规则^[5]：

首先设定最小置信度阈值 γ

然后对每个项集 I 产生所有非空子集 S ，对任一个 S_i ，如果

$$\frac{R[S_i \cup (I - S_i)]}{R(S_i)} \geq \gamma$$

则输出规则：

$$S_i \rightarrow I - S_i$$

其中 $R(S_i)$ 表示 S_i 的支持频数。

对于本文来说，只生成含有地面类型的关联规则。最终生成以下部分关联规则：

表格 2

关联规则	置信度	支持度($\times 5$)
相关性低，能量高，熵低，惯性矩高，局部平稳性低 $\Rightarrow$ 好	1.0	0.8

紧凑度低，相关性中，能量低，惯性矩低 $\Rightarrow$ 坑槽	1.0	0.6
紧凑度低，能量低，熵高，局部稳定性低 $\Rightarrow$ 龟裂	1.0	0.6
相关性低，能量低，熵高，局部稳定性低 $\Rightarrow$ 裂缝	1.0	0.6
紧凑度低，相关性低，能量低，惯性矩高 $\Rightarrow$ 网裂	1.0	0.8

2.3.1.3 结果分析

在上述生成的众多关联规则中，可以找出与关联规则一样或者最为接近，并且置信度、支持度最高的一个关联规则，从而确定地面类型。

另外由初始化的频繁项集表来看，有较多的特征落于较高或较低区间，因此可改用由上 1/3 和下 1/3 位点来划分区间。

经过拥有的少量的测试样本检验，本模型有较高的适应性和准确性。

本模型虽然没有根本性的创新，但却很好地利用了现有的技术和方法，进行灵活的选用、组合、变通，建立了适合本课题的模型，为了更好的提高模型的精确度，我们尝试了另外一种方法建立模型，即基于支持向量机的学习方法。

2.3.2 基于支持向量机的图像挖掘模型

Vapnik 等人提出的 SVM 技术^{[7][8]}具有极强的模型泛化能力，与以往的建立在经验风险最小化基础上的模式识别不同，SVM 是基于统计学习理论提出的建立在结构风险最小化基础上的一种新的机器学习方法，有很强的非线性处理能力，能根据当前有限的样本信息在机器的学习能力和模型的复杂性之间寻求最小问题并提高泛化能力，最终提高分类效果，适用于本文研究的道路缺陷图像小样本的特征。

支持向量机应用的典型流程是首先提取出图像的局部特征并形成特征码，然后将每幅图像的局部特性形成的特征单词直方图作为图像特征，通过 SVM 进行训练得到分类模型^[9]。




图 8 支持向量机应用的典型流程

因此支持向量机的图像分类关键在于如何提取样本的特征向量和如何选择合适的核函数及参数，最终确定图像分类的效果

（1）图像特征的提取—LBP 特征提取

用于描述图像的特征有颜色特征、纹理特征和几何形状特征等，由于本文预处理过程将图像二值化表示，因此不考虑颜色特征，而对纹理特征进行探究，近年来广泛应用于瑕疵检测等领域^{[10][11][12]}的局部二进制模式（Local Binary Patterns, LBP）能通过对图像中的一点与其周围点的灰度值大小关系的准确描述来表征图像的局部纹理结构，最原始的 LBP 算子是由 Ojala 提出的^[13]，算法思路是：假定某一像素为中心，以该中心点的灰度值为阈值与相邻一定半径上等间隔的像素灰度值进行比较，得到一组二进制数作为中心点的二值模式，并计算得到一个 LBP 值。

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot 2^p$$

上式中， g_c 为中心点 (x_c, y_c) 的灰度值， P 为半径 R 上选定的像素个数， g_p 是邻居点的灰度值，当 $g_p > g_c$ 时， $s=1$ ，反之 $s=0$ 。LBP 编码方法例子如下

8	5	9
4	7	10
6	12	13

1	0	1
0		1
0	1	1

1	0	4
0		16
0	64	128

Pattern=10101011

LBP=1+4+16+64+128

(2) 核函数的选取

支持向量机最大的优点就是通过核函数的引入将输入空间中的线性不可分问题转化为高维空间中的线性可分问题^{[14][15]}，极大的提高了学习机器的非线性处理能力。采用不同的内积函数将导致不同的支持向量算法，目前，常用的核函数主要有以下 4 种^[9]。

表格 3

核函数类型	表达式	说明
多项式函数	$K(x, x_i) = [(x \cdot x_i) + 1]^q$	$q = 1, 2, 3 \dots$ 由用户定义
RBF 函数	$K(x, x_i) = \exp \left\{ -\frac{ x - x_i ^2}{\sigma^2} \right\}$	σ 为参数，由用户定义
Sigmoid 核函数	$K(x, x_i) = \tanh(b(x, x_i) + c)$	b, c 为常，由用户定义
B-样条核函数	$K(x, x_i) = B_{2p+1}(x - x_i)$	其中 B_{2p+1} 是 $2p + 1$ 阶 B-样条函数

(3) SVM 参数优化方法

① 模型参数分析

下面是选取 RBF 核的 SVM 随参数 σ 变化时的两个主要性质^[9]：

性质 1 若 RBF-SVM 的参数 $\sigma \rightarrow \infty$ ，则其学习推广能力，也就是对新样本的正确判别能力为 0，它把所有的样本都判为一类。

性质 2 若 RBF-SVM 的参数 $\sigma \rightarrow 0$ ，则所有的训练样本 x_i ($i=1, 2, \dots, n$) 都是支持向量，且它们全部都能被正确分类。

惩罚因子 C 的作用是在确定的样本数据子空间中调节支持向量机经验风险和置信

范围之间的比例，直到学习机器达到较好的泛化能力。在样本数据子空间确定的情况下，C 的取值越小，说明对经验误差的惩罚越小，SVM 的复杂度较小但经验风险值较大；反之，则 SVM 复杂度增加，经验风险较小。

惩罚因子 C 和 RBF 核自身的参数 σ 共同影响着 SVM 的学习能力和推广能力，以这两种参数为标准选择最优 SVM 参数优化方法。

②网格搜索

网格搜索是一种试凑的方法，适合从不同的增长方向并行搜索最优解。

③GA

遗传算法具有强大的搜索能力，可以在较短时间内搜索到全局最优解。

（4）进行分类实验

步骤 1：数据说明

本文选用题目附件所给图像库中的 25 幅图像，以及从实际地面采样样本，共 5 个类别，每类 10 幅来进行图像分类实验，它们分别是好、坑槽、龟裂、网裂、缝裂，将所有类别图像的前 5 幅用作训练，后 5 幅用做测试。

步骤 2：算法软件包的使用

目前已经出现许多针对 SVM 算法的软件包。台湾大学 Chih-Jen Lin 教授用 c++ 编写的 LIBSVM^[16] 是目前使用较为广泛的 SVM 软件，它最大的优点是使用方便，供用户选择的参数比较少，因此本文选择 LIBSVM 来进行图像分类，核参数优化方法也是通过在 LIBSVM 上进行修改的。

步骤 3：图像特征提取

本文对预处理后的图像用 LBP 算法对纹理进行提取

步骤 4：核函数选择

在常用的几种核函数中，RBF 核在大多数情况下都能达到较好的分类效果，因此，本文选取基于 RBF 核函数的 SVM 进行图像分类。

步骤 5：确定评价标准

图像分类实验的评价标准为图像分类准确率，即

$$\text{准确率}(\%) = \frac{\text{正确分类的样本数}}{\text{测试样本总数}} \times 100\%$$

图像分类流程图如下：




图 7 图像分类流程图

(5) 结果分析

用上述算法进行分类，得到如下 LBP 纹理特征分类准确率表格

表格 4

采用 SVM 默认参数	网格搜索			GA		
正确率 (%)	σ	C	正确率 (%)	σ	C	正确率 (%)
63.33	0.03115	2004	66.66	0.0448	18.56	73.33

由表格可见，这种方式的正确率不是很高，即使使用核函数的参数以 GA 确定，正确率也只能在 73.33% 左右，重要原因之一是由于样本量太少，但是由于样本量小的问题引起的误差认为这种模型是可以接受的，只要样本量足够多，准确率也会越高。

2.3.3 基于 DBN 深度学习教育网络的图像挖掘模型新构想

从预处理后得到的是图像的二值化表示，但是我们在上述模型的应用中仍然是以图像为单位进行处理，因此本文尝试以 30*30 像素大小的样本图像直接以 900 特征项输入，利用深度学习的机器学习算法进行训练。

神经网络也是一种图像分类的算法，但是 2 层神经网络的建模能力虽然非常强大，但是要求隐节点个数足够多，然而当输入层的特征足够多的时候，对整个模型的建立不仅会加深一种计算训练难度，也会降低准确度^[17]所以 Hinton 等人提出的贪婪的逐层无监督训练的深度学习算法是非常适合用于多特征项的输入的，基本思想就是^[18]：

把一个 DBN 网络分层，对每一层进行无监督学习，最后对整个网络用监督学习进行微调。把一个 DBN 网络分层，每层都由若干计算单元（常常是几百个或几千个）组成，各层独立计算该层接受到的数据，每个层的节点之间没有连接。与外界环境连接的节点层为输入层，输入层接受来自于外界输入，例如图像数据，第 1 层（即输入层）与第 2 层构成一个典型的 RBM，根据无监督学习调节网络参数，使得 RBM 达到能量平衡。然后，第 2 层的输出作为第 2 层与第 3 层构成一个新的 RBM。第 1 层的输出作为外界输入，继续调节参数，使当前 RBM 结构达到能量平衡。如此进行下去，直到最后一层。当完成无监督逐层训练学习后，再以原始外界输入和目标输出对整个网络进行有监督学习，调整网络各层的参数。

(1) DBN

DBN 是由若干层 RBM 和一层 BP 组成的一种深层神经网络^[19]，其结构如下所示：




图 8 DBN 结构图

DBN 在训练模型的过程中主要分为两步：


- 1、分别单独无监督地训练每一层 RBM 网络，确保特征向量映射到不同的特征空间时，都尽可能多地保留特征信息；
- 2、在 DBN 的最后一层设置 BP 网络，接收 RBM 的输出特征向量作为它的输入特征向量，有监督地训练实体关系分类器。

每一层 RBM 网络只能确保自身层内的权值对该层特征向量映射达到最优，并不是对整个 DBN 的特征向量映射达到最优，所以反向传播网络还将错误信息自定而下传播至每一层 RBM，微调整个 DBN 网络。

(2) RBM

RBM 是 DBN 的核心组件之一，但是 RBM 是种能量模型，他的权值是用来计算连接节点的能量值的^[20]。

这是一种无向图模型，如下：有 N 个节点，节点是互相连接的（不一定要全连接），第 i 个节点和第 j 个节点间权值为 w_{ij} ，为简单起见，这里认为节点的取值是 2 值的，即只能取 0 或 1。有些节点值是已知的，有些是未知的，我们把已知的和未知的分开，分成两层，已知的节点集记为 V ，未知的节点集合记为 H 。若是 V 内节点之间都不相连， H 内节点之间也都不相连，这种模型叫 Restricted Boltzmann Machines。



定义一个能量函数 $E(V, H)$

$$E(v, h|\theta) = - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{i,j} h_j$$

则 (v, h) 的联合概率分布为

$$P(v, h|\theta) = \frac{e^{-E(v, h|\theta)}}{Z(\theta)}, \quad Z(\theta) = \sum_{v, h} e^{-E(v, h|\theta)}$$

最大化 $P(V)$ 的值，用梯度法，经过一系列推导可得权值的更新规则为

$$\Delta w_{ij} = \langle v_{ih} \rangle_{\text{data}} - \langle v_{ih} \rangle_{\text{model}}$$

这里的 $\langle \rangle$ 意思是求期望，**data** 是指已知样本集时， v_{ih} 的期望值，这时 v_i 是由样本确定的， h_j 是未知的。而第二项，是模型中 v_{ih} 的期望值。这时 v_i ， h_j 都是未知的。直接求这两个期望不好求，可以用抽样的方法来估计。

(3) 模型建立

模型输入层为 900 个特征值的输入向量，输出为 6 个类别的输出向量，1 表示为该类别。

算法的实现过程可以采用^[21]提供的 DBN 算法

(4) 模型应用

由于样本量太小使用 DBN 算法带来的误差很大，但是从理论上研究，这种方式的使用是能带来较高准确率的，因此本文只是提出一种新的构想

3. 结论

本文研究目标是利用不同道路缺陷类型图像，进行数据挖掘，实现不同道路缺陷类型的自动识别，而本文最终实现了这一目标。

对图像预处理部分，本文作者在实验过程中用 VC++ 的 MFC 开发了图像预处理功能的图像处理软件（见附件），能把原始图像转成统一的二值化图像，接着把二值化图像通过关联规则建立了识别软件（见附件），并利用 MATLAB 的 LIBSVM 算法建立了基于 SVM 的图像分类模型，最后提出一种模型新构想，即利用机器学习的深度学习网络 DBN 算法建立模型。

4. 附录

(1) 25 个样本的初始化频繁项集

1, 11, 22, 31, 43, 51, 63	2, 11, 21, 31, 43, 53, 61	4, 11, 21, 31, 43, 53, 61
1, 11, 21, 31, 43, 52, 61	2, 11, 23, 32, 42, 51, 63	4, 11, 21, 31, 43, 51, 63
2, 11, 21, 33, 41, 53, 61	3, 11, 21, 31, 43, 53, 61	4, 11, 21, 31, 43, 53, 61
2, 13, 22, 31, 43, 51, 63	3, 11, 22, 31, 43, 51, 63	0, 11, 21, 33, 41, 53, 61
2, 11, 23, 32, 42, 51, 63	4, 11, 21, 31, 43, 51, 63	0, 11, 21, 33, 41, 53, 61
3, 11, 21, 31, 43, 52, 61	4, 11, 22, 31, 42, 51, 63	0, 11, 22, 31, 42, 51, 63
3, 11, 22, 31, 43, 51, 63	0, 11, 21, 33, 41, 53, 61	1, 11, 21, 31, 43, 52, 61
3, 11, 21, 31, 43, 53, 61	0, 13, 21, 33, 41, 53, 61	1, 11, 22, 31, 43, 51, 63
4, 11, 22, 31, 42, 51, 63	0, 11, 22, 31, 42, 51, 63	2, 13, 22, 31, 43, 51, 63
4, 11, 21, 31, 43, 53, 61	1, 11, 21, 31, 43, 52, 61	2, 11, 21, 31, 43, 53, 61
0, 13, 21, 33, 41, 53, 61	1, 11, 22, 31, 43, 51, 63	3, 11, 21, 31, 43, 52, 61
0, 13, 21, 33, 41, 53, 61	1, 11, 22, 31, 42, 51, 63	3, 11, 21, 31, 43, 52, 63
1, 11, 21, 31, 43, 52, 61	2, 11, 21, 31, 43, 53, 61	3, 11, 21, 31, 43, 53, 61
1, 11, 22, 31, 43, 51, 63	2, 11, 21, 31, 43, 53, 61	4, 11, 21, 31, 43, 53, 61
1, 11, 22, 31, 42, 51, 63	3, 11, 21, 31, 43, 52, 63	4, 11, 21, 31, 43, 53, 61
2, 11, 21, 33, 41, 53, 61	3, 11, 21, 31, 43, 53, 61	

(2) 各部分程序见附件

5. 参考文献

- [1] 灰度化, 百度百科 <http://baike.baidu.com/view/3701940.htm>
- [2] 周颖, 赵海凤, 郝红敏, 基于图像处理的焊点缺陷识别方法的研究[M], 计算机科学与应用, 2013, 49(1)
- [3] 王安静, 陈玲, 宋建永, 金赞, 用 VC++实现连通区域标记[M], 电脑编程技巧与维护, 2003. 1
- [4] 冯伟兴, 唐墨, 贺波, Visual C++数字图像模式识别技术详解[M], 机械工业出版社, 2010. 7
- [5] 张启孟, 基于图像挖掘的冰雹云研究, 硕士论文, 2007. 1
- [6] 田广昊, 基于关联规则的图像数据挖掘研究, 硕士论文, 2008. 3

- [7] Cortes C., Vapnik V. Support Vector Networks[J]. Machine Learning, 1995, 20:273-297
- [8] Vapnik V. Statistical Learning Theory[M]. New York:Wiley, 1998
- [9] 高锦. 基于 SVM 的图像分类[D]. 西北大学:中国学位论文全文数据库, 2010.
- [10] Rodriguez Y., Marcel S. Face authentication using adapted local binary pattern histograms[J]. ECCV, 2006, (4):321-332
- [11] Marcel S., Rodriguez Y., Heusch G. On the Recent Use of Local Binary Patterns for Face Authentication[J]. International Journal of Image and Video Processing, Special Issue on Facial Image Processing, 2007, (1):1-9
- [12] 王宇, 林成德. 非局部二值模式人脸表示与识别方法[J]. 厦门大学学报(自然科学版), 2009, 48 (2): 208-210
- [13] Ojala T., Pietikainen M., Harwood D. A comparative study of texture measures with classification based on feature distributions[J]. Pattern Recognition, 1996, 29(1):51-59
- [14] Bernhard Scholkopf, Alexander J. Smola, Learning with Kernels[M]. Cambridge:MIT Press, 2001
- [15] Bernhard Scholkopf, Alexander J. Smola, Support Vector Machines and Kernel Algorithms[M]. Encyclopedia of Biostatistics:John Wiley and Sons, 2003
- [16] Chih-Jen Lin. LIBSVM -- A Library for Support Vector Machines[EB/OL]. [2013-4-10]. <http://www.csie.ntu.edu.tw/~cjlin/>.
- [17] 黄言之. Deep Learning 基础知识 [EB/OL]. [2013-3-27]. http://blog.sina.com.cn/s/blog_72995dcc0101a12r.html.
- [18] Hinton GE, Osindero S. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18:1527-1554.
- [19] 殷力昂. 一种在深度结构中学习原型的分类方法[D]. 上海交通大学, 2012.
- [20] 杨莹, 吴城炜, 胡苏. 基于受限波尔茨曼机的中文文档分类[J]. 科技创新导报, 2012(16):35-36.
- [21] Rasmus Berg Palm. A Matlab toolbox for Deep Learning[EB/OL]. [2013-3-28]. <http://www.mathworks.cn/matlabcentral/fileexchange/38310>.