

基于 EBPNN 模型的遥感图像变化检测研究

李正伟

(成都理工大学 工程技术学院, 四川 乐山 614007)

摘要: 对不同时段获取的特定图像进行自动变化检测是遥感图像研究的主要问题; 通过自适应中值滤波 (AMF) 去除遥感图像中的噪声, 结合 Tamura 和 Law 掩模方法提取图像中的次级特征, 并将研究区域划分为植被、水域和城区三类, 利用增强型反向传播神经网络 (EBPNN) 对特征提取结果进行分类并实现不同时期遥感图像的变化检测; 与现有的 FFNN 和 CNN 分类技术相比, 利用 EBPNN 进行分类可以有效地检测出图像中的变化且具有更好的检测性能。

关键词: 遥感图像; 特征提取; 变化检测; 分类; 预处理

Remote Sensing Image Change Detection Based on EBPNN Model

Li Zhengwei

(Engineering & Technical College, Chengdu University of Technology, Leshan 614007, China)

Abstract: Automatic change detection of specific images acquired in different periods is the main problem of remote sensing image research. Adaptive median filter (AMF) is used to remove the noise in remote sensing image, and Tamura and law mask methods are used to extract the secondary features of the image. The study area is divided into vegetation, water area and urban area. The enhanced back propagation neural network (EBPNN) is used to classify the feature extraction results and realize the change detection of remote sensing images in different periods. Compared with the existing FFNN and CNN classification techniques, EBPNN can effectively detect the changes in the image and has better detection performance.

Keywords: remote sensing images; feature extraction; change detection; classification; preprocessing

0 引言

遥感图像的变化检测可用于监测区域内不同时期的变化, 由于遥感图像具有非线性、区分性和不变性等特点, 因此, 必须提取这些特征后再进行图像的分类和目标检测^[1]。在复杂的数据集中, 可以通过数据挖掘技术提高分类精度来实现变化检测。散斑噪声是遥感图像中普遍存在的噪声, 遥感图像还包括高斯噪声和脉冲噪声^[2]。遥感图像变化检测技术主要有: 光谱混合分析法^[3]、支持向量机 (SVM)^[4]、分类与回归树模型^[5] 和人工神经网络 (ANN)^[6]。文献 [7] 提出了基于随机森林的变化检测方法, 有效降低了漏检率和虚检率。而遥感图像分类的最常用空间特征包括小波纹理、灰度共生矩阵 (GLCM)、像素形状记录和形态轮廓^[8]。文献 [9] 提出了基于特征融合的遥感图像分类, 有效提高了不同场景分类精度。

为了有效实现遥感图像的分类和变化检测, 本文利用自适应中值滤波 (AMF) 对遥感图像中进行降噪预处理并提取次级特征, 从而加快了分类过程。将提取的特征结合增强型反向传播神经网络 (EBPNN) 进行分类, 并识别分类后遥感图像的变化。

1 研究概况

1.1 研究区域

本文采用国家遥感中心的资源 1 号线性成像扫描仪—4 (LISS—4) 图像, 该图像取自 2011 年 8 月 12 日和 2017 年 4 月 28 日期间河北省沧州市任丘市的遥感图像, 任丘市位于北纬 38.42、东经 116.07, 海拔为 40 m。重采样技术采用三次卷积并对地形进行了校正, 传感器的输出分辨率为 24 m。

1.2 研究方法

图 1 给出了所提出方法的流程。首先, 在 AMF 的帮助下, 对 2011 年 12 月和 2017 年 4 月的输入图像进行降噪预处理。然后对预处理后的图像进行特征提取, 最后实现分类及变化检测。

2 遥感图像预处理

为了降低遥感图像的噪声影响, 本文使用自适应中值滤波 (AMF)^[10] 来平滑图像。AMF 能够有效处理高密度的脉冲噪声, 并且在处理非脉冲噪声的同时, 还能保存更多的图像细节。将 $S_{x,y}$ 作为中心像素 (x,y) 的模板窗口, Z_{\min} 、 Z_{\max} 和 Z_{med} 分别为窗口 $S_{x,y}$ 中的最小灰度、最大灰度和中度

收稿日期: 2020-08-16; 修回日期: 2020-10-09。

作者简介: 李正伟 (1980-), 男, 河南安阳人, 博士, 讲师, 主要从事信息图像处理理论、遥感图像处理、通信系统理论与技术、信息安全与智能控制等方向的研究。

引用格式: 李正伟. 基于 EBPNN 模型的遥感图像变化检测研究[J]. 计算机测量与控制, 2021, 29(3): 124-128, 144.

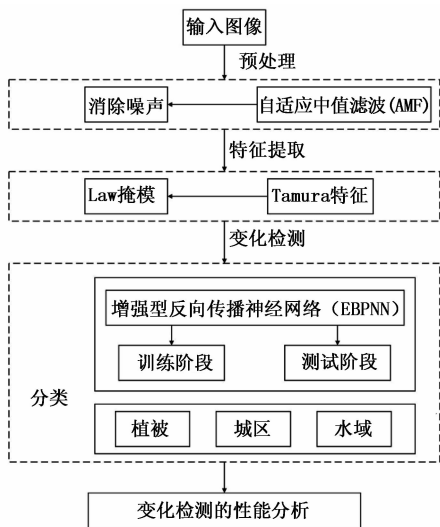


图 1 所提方法的流程

灰度, $Z_{x,y}$ 为像素 (x,y) 中的灰度值, S_{max} 为 $S_{x,y}$ 的最大容许范围。AMF 分两个阶段处理:

阶段 1: $A_1 = Z_{med} - Z_{min}, A_2 = Z_{max} - Z_{med}$, 若 $A_1 > 0$ 且 $A_2 > 0$, 则继续阶段 2; 若 $S_{x,y} \leq S_{max}$, 则重复阶段 1; 直至输出 $Z_{x,y}$ 。

阶段 2: $B_1 = Z_{x,y} - Z_{min}, B_2 = Z_{max} - Z_{x,y}$, 若 $B_1 > 0$ 且 $B_2 > 0$, 则输出 $Z_{x,y}$; 否则, 输出 Z_{med} 。

因此, 如果 Z_{med} 是否为脉冲噪声, 则分析阶段 1。如果 $Z_{x,y}$ 是否为脉冲噪声, 则不采用阶段 2。如果 Z_{med} 和 $Z_{x,y}$ 都不是脉冲噪声, 则输出为常量 $Z_{x,y}$ 。利用该输出代替中间值以此避免丢失遥感图像中的其他信息。通过扩展 AMF 的窗口技术, 可以降低脉冲噪声的谱密度。为了提高该技术的应用, 还需对窗口的形状和方向进行改进, 从而降低脉冲噪声的空间密度。在完成图像平滑处理后, 对图像进行特征提取。

3 特征提取

将特征提取与预处理图像结合使用, 对 2011 年至 2017 年期间的空间时空变化和几何变化建模。在机器学习中, 特征提取从最初的一组测量数据开始, 刻意地构建特征值以使其有用且无冗余。特征提取的关键是从新的数据中获取最重要的信息, 并在较小的维数间隙内表示这些信息。对图像中的每个像素进行特征提取, 提取出与其邻域相关的 Tamura 和 Law 掩模等特征。

3.1 Tamura 特征

Tamura 特征的提出是人在纹理中感知到特征成分的心理物理研究, 包括对比度、方向性和粗糙度^[11]。Tamura 特征取决于人类的图像感知。传统的 Tamura 特征可用于纹理均匀的图像, 并能处理较差的普通图像。

1) 对比度: 对比度特征有助于测量图像中像素灰度强度的变化, 以及其分布偏向黑色或白色的程度:

$$C = \frac{\sigma}{(\beta_1)^v} \quad (1)$$

其中: σ 为标准差, $v = 0.25, \beta$ 为峰度。

2) 方向性: 方向性特征考虑了边缘强度和方向角。根据 Prewitt 边缘检测算子^[12]使用逐像素导数计算:

$$Da = \arctan \frac{\Delta x}{\Delta y} + \frac{\pi}{2} \quad (2)$$

其中: Δx 和 Δy 分别为 x 和 y 方向上的像素差。

3) 粗糙度: 利用粗糙度特征可测量图像粒度, 识别出显著的灰度空间变化距离。对于固定窗口估计, 具有较少纹理成分的纹理比具有较大纹理成分的纹理更粗糙, 该方法用于评估纹理的粗糙度。在每个像素 (x,y) 处, $p(x,y)$ 用于计算窗口大小分别为 0, 1, 2, 3, 4, 6 周围像素的平均值。在每个像素 (x,y) 处, 计算不同方向相反侧的不重叠平均集, 在每个尺度 $Y_i(x,y)$ 上的绝对差值为:

$$\begin{cases} Y_{i,c}(p) = |B_i^1 - B_i^2| \\ Y_{i,d}(p) = |B_i^3 - B_i^4| \end{cases} \quad (3)$$

$$p(x,y) = \{Y_{1,c}, Y_{1,d}, Y_{2,c}, Y_{2,d}, \dots\} \quad (4)$$

选择变化最大的尺度 $\max(Y_i)$, 则最佳像素窗口大小 S_{best} 为 2^i 。通过对整个图像的 S_{best} 进行平均来计算图像的粗度。

3.2 Law 掩模特征

Law 掩模特征提取利用图像的自然微观结构属性 (水平、边缘、斑点和纹波) 提取出次级特征并用于分类^[13]。序列窗口 (SW) 和随机窗口 (RW) 产生 Law 掩模为 3×3 的统计参数。根据条件 $2 \leq C \leq M$ 和 $2 \leq D \leq N$, 选择 SW/RW 的大小 $C \times D$, 其中, C 和 D 为窗口大小, P 和 O 为图像大小。确定图像上随机窗口的起始位置:

$$X(n+1) = ((q \cdot x(v)) + s) \% \cdot P \quad (5)$$

其中: q 和 s 为窗口数量的决定因素。Law 掩模建立了测量固定估计窗口内变化量的纹理能量方法。利用 9 个 5×5 卷积掩模的排列计算纹理能量, 该纹理能量由 9 个矢量表示图像的每个像素。

中心加权局部平均值由 L_5 矢量给出。利用 E_5, S_5 和 R_5 矢量分别用于检测边缘、斑点和波纹。矢量对的外积得到二维卷积掩模。

Law 掩模程序的初始阶段是通过在图像周围移动一个小窗口并从每个像素中减去局部平均值来消除影响。为了得到特征提取的图像, 将每个邻域的平均强度降至接近于零的值。窗口的大小取决于图像类别; 特征场景使用 15×15 的窗口。将二维掩模相乘得到 16 个纹理能量图。将每个纹理能量图替换为其平均图, 并生成 9 个过滤图像。

4 基于变化检测的分类

对于特征提取的结果, 在分类阶段之后进行变化检测, 并借助增强型反向传播神经网络 (EBPNN)^[14] 进行检测。分类阶段又分为两个阶段: 训练阶段和测试阶段。在训练阶段, 根据每个节点的权重创建一个 EBPNN, 然后根据提取的特征对图像进行分类。根据图像的特征, 将遥感图像分为植被、城区和水域三类。测试阶段在 EBPNN 中执行,

以实现最优的权重选择。将提取的特征与测试阶段数据库中积累的特征进行比较得到分类输出。分类后，将识别出 2011 年 12 月和 2017 年 4 月的遥感图像的变化。

反向传播神经网络 (BPNN) 是用于训练多层神经网络的直接学习策略。术语“反向传播”表示在输出处处理的错误反向复制，并从输出层开始到隐藏层，最后到输入层。EBPNN 算法取决于输出神经元的线性和非线性误差之和，以最少的迭代次数来提高收敛速度。EBPNN 算法分为前馈、误差计算和更新权重。结合测试程序用于评估算法的实现情况。EBPNN 算法步骤如下。

步骤 1: 初始化训练集参数 s, w, v, Max_v 和 Min_v (大小、权重、变量、最大变量、最小变量)

步骤 2: 计算每个节点的隐藏层:

$$v_b^r = \sum_{a=1}^{r-1} w_{ba}^r p_a^{r-1} \quad (6)$$

$$z(v_b^r) = \frac{1}{1 + e^{-v_b^r}} = t_b^r \quad (7)$$

步骤 3: 计算隐藏层之间的距离:

$$L_i = (Max_v, Min_v)^2 \quad (8)$$

步骤 4: 计算最大权重:

$$w_{\max} = \frac{8.72}{e} \cdot \sqrt{\frac{3}{s_k}} \quad (9)$$

$$e = \sqrt{\sum_i L_i} \quad (10)$$

其中: s_k 为隐藏层神经元的数量。

步骤 5: 计算中心值:

$$C(s, 1) = (Max_v, Min_v) / 2 \quad (11)$$

步骤 6: 更新输出层权重:

$$w_{ba}(i-1) = w_{ba}(i-1) + \nabla w_{ba} \quad (12)$$

步骤 7: 随机选择权重

步骤 8: 计算隐藏层阈值

步骤 9: 寻找输出层阈值:

$$T_{b0} = -0.5 \sum_{a=1}^R T_{ba} \quad (13)$$

步骤 10: 训练过程: 创建前馈神经网络, 误差计算, 更新新的权重;

步骤 11: 测试阶段;

步骤 12: 确定网络模型;

步骤 13: 对图像 (植被、水域和城区) 进行分类;

步骤 14: 对分类结果进行分析。

5 实验分析

本文在 Matlab 软件中开发基于变换检测的特征提取。该数据集取自资源 1 号图像。数据集收集了 2011 年和 2017 年的 Geotiff 图像格式并执行变化检测技术。本文开发了适用于变化检测的 EBPNN 分类器以提高分类精度。此外, 还集成了 AMF 来消除遥感图像中的噪声。从图像中提取次级特征并进行分类, 最后与现有的前向神经网络 (FFNN) 和卷积神经网络 (CNN) 进行了比较。

5.1 变换检测

从数据库获取的图像作为自动变化检测技术的输入, 如图 2 和图 3 所示。




图 2 任丘市 2011 年 12 月的图像




图 3 任丘市 2017 年 4 月的图像

通过 AMF 进行预处理来降低噪声, 得到的输出如图 4 和图 5 所示。同时保留了两个部分得到的窗口形状和方向变化细节, 避免了由于窗口尺寸增大而导致的影响。




图 4 任丘市 2011 年 12 月的预处理图像




图 5 任丘市 2017 年 4 月的预处理图像

经过预处理后进行灰度变化等特征提取, 包括边缘强

度和方向角、次级特征提取、局部物体形状和外观表征、物体不确定度的测量、表面引入变化的测量，最终得到最可靠的特征。利用 EBPNN 方法进行分类。表 1 给出了 Law 掩模特征提取的 9 个纹理数值，表 2 给出了 Tamura 特征的粗糙度、对比度和方向等特征。

表 1 Law 掩模的 9 种滤波图像特征

区域	$E_5 E_5$	$S_5 S_5$	$R_5 R_5$
城区	84.69	42.79	20.45
植被	74.72	24.47	8.88
水域	49.93	11.81	6.12
区域	$E_5 L_5$	$S_5 L_5$	$R_5 L_5$
城区	8.09	10.89	63.22
植被	3.44	8.82	44.81
水域	2.45	8.18	28.66
区域	$S_5 E_5$	$R_5 E_5$	$R_5 S_5$
城区	50.86	11.80	5.84
植被	24.79	6.28	3.56
水域	17.05	4.96	3.04

表 2 Tamura 特征图像

区域	粗糙度	对比度	方向性
城区	33.37	22.82	0.26
植被	34.96	16.54	0.32
水域	36.44	26.92	0.01

图 6 和图 7 给出了任丘市 2011 年 12 月和 2017 年 4 月图像中的植被区域变化。




图 6 2011 年 12 月图像种植被区域变化检测




图 7 2017 年 4 月图像种植被区域变化检测

图像中的城区区域变化。从 2017 年 4 月的图像中可以清楚地看到，与 2011 年 12 月相比，任丘市城区化影响比 2017 年 4 月有所增加。




图 8 2011 年 12 月图像中城区区域变化检测




图 9 2017 年 4 月图像中城区区域变化检测

任丘市 2011 年和 2017 年的水域变化比较如图 10 和图 11 所示。与 2011 年相比，2017 年水域面积明显减少。炎热的夏季使各种水域恶化，给城区带来了负面影响。2011 年 12 月，水域清晰可见，在 2017 年 4 月的图像中，水域恶化，基本无法观测。夏季的影响和降雨量的减少对任丘市的水源产生了负面影响。




图 10 2011 年 12 月图像中水域区域变化检测

图 12 和图 13 给出了 2011 年 12 月和 2017 年 4 月任丘市的变化检测图。从图 12 和图 13 可以分析 2011 年和 2017 年植被的变化。由此产生的图像显示了 2011 年和 2017 年城市化的变化。从图 13 可以清楚地看出，与 2011 年相比，2017 年城区面积有所增加。

表 3 给出了植被、水域和城区区域等各种变化。在 2011 年，城区面积为 148 877 像素，2017 年增加到 216 253 像素。因此，城市化对城区环境的变化产生了巨大的影响。在 2011 年，水域面积为 57 965 像素，2017 年大幅减少到

图 8 和图 9 给出了任丘市 2011 年 12 月和 2017 年 4 月




图 11 2017 年 4 月图像中水域区域变化检测




图 12 2011 年 12 月图像城市变化检测




图 13 2017 年 4 月图像城市变化检测

21 834 像素。城市炎热的气候对水域产生了负面影响。在 2011 年，植被面积为 743 894 像素，2017 年减少到 712 649 像素。

表 3 在不同区域检测到的变化

区域	2011 年像素	2017 年像素	变化区域 像素	变化区域面积 (km ²)
城区	148 877	216 253	67 376	2.26
植被	743 894	712 649	-31 245	-1.05
水域	57 965	21 834	-36 131	-1.22

5.2 性能分析

本文选取 TP、TN、FP、FN、FPR、FDR、PPV、NPV、灵敏度、特异性、Kappa、虚检率、漏检率和准确度作为评价指标。假阴性 (FN) 可以表征为变化的像素，即未被检测到，而假阳性 (FP) 则由于未正确检测到未更改的像素而被计算。真阴性 (TN) 表示真负数，即像素数准确表示为未改变，而真阳性 (TP) 表示真正值，即有效地分组为失真的像素数。通过以下公式评估指标：

1) 正预测值

$$PPV = \frac{TP}{TN + FN} \quad (14)$$

2) 负预测值

$$NPV = \frac{TN}{TN + FN} \quad (15)$$

3) 灵敏度

$$SE = \frac{TP}{TP + FN} \quad (16)$$

4) 特异性

$$SP = \frac{TN}{TP + FN} \quad (17)$$

5) 准确度

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (18)$$

6) 假阳性率

$$FPR = \frac{FP}{FP + TN} \quad (19)$$

实际的像素数量归为未更改和更改过的类，其特征为 Mu 和 Mc 。则 $Kappa$ 为：

$$Kappa = \frac{PCC - PRE}{1 - PRE} \quad (20)$$

其中：PCC 为正确分类的百分比。且：

$$PRE = \frac{(TP + FP)Mc + (FN + TN)Mu}{(TP + FP + FN + TN)^2} \quad (21)$$

虚检率为：

$$CE = \frac{FP}{FP + TP} \quad (22)$$

漏检率为：

$$OE = \frac{FN}{FN + TP} \quad (23)$$

将文献 [15] 提出的 FFNN 和文献 [16] 提出的 CNN 与本文所提出的 EBPNN 进行比较，如表 4 所示。

表 4 不同方法的性能比较

指标	FFNN 模型[15]	CNN 模型[16]	EBPNN 模型
TP	791 813	809 526	829 894
FP	35 128	22 568	19 854
TN	93 485	89 125	89 651
FN	30 310	29 517	11 337
FPR	0.273 1	0.202 1	0.181 3
PPV	0.963 1	0.972 9	0.976 6
NPV	0.755 2	0.751 2	0.887 7
SE	0.963 1	0.964 8	0.986 5
SP	0.816 9	0.797 9	0.818 7
AC	0.931 2	0.945 2	0.967 2
Kappa	0.701 3	0.742 7	0.840 3
CE	0.042 5	0.027 1	0.023 4
OE	0.036 9	0.035 2	0.013 5

图 14 给出了不同变化检测方法之间的准确度、KAPPA 和灵敏度的定量比较。

(下转第 144 页)