



(12)发明专利

(10)授权公告号 CN 105608698 B

(45)授权公告日 2018.12.25

(21)申请号 201510990465.0

CN 101694719 A, 2010.04.14, 全文.

(22)申请日 2015.12.25

CN 102169545 A, 2011.08.31, 全文.

(65)同一申请的已公布的文献号

CN 105046241 A, 2015.11.11, 权利要求1.

申请公布号 CN 105608698 A

CN 102819838 A, 2012.12.12, 全文.

(43)申请公布日 2016.05.25

CN 104392442 A, 2015.03.04, 全文.

(73)专利权人 西北工业大学

Lorenzo Bruzzone 等.Automatic

地址 710072 陕西省西安市友谊西路127号

Analysis of the Difference Image for

(72)发明人 李映 徐隆浩 刘韬

Unsupervised Change Detection.《IEEE

(74)专利代理机构 西北工业大学专利中心

TRANSACTIONS ON GEOSCIENCE AND REMOTE

61204

SENSING》.2000, 第38卷(第3期), 1171-1182.

代理人 王鲜凯

Yushi Chen 等.Deep Learning-Based

(51)Int.Cl.

Classification of Hyperspectral Data.

G06T 7/00(2017.01)

《IEEE JOURNAL OF SELECTED TOPICS IN

G06T 7/11(2017.01)

APPLIED EARTH OBSERVATIONS AND REMOTE

SENSING》.2014, 第7卷(第6期), 摘要, 正文第II

节C部分第1、3段, 第III节第2段, 第IV节第1-3

段.

(56)对比文件

审查员 崔蓝芳

CN 103345742 A, 2013.10.09, 权利要求1.

权利要求书1页 说明书4页 附图1页

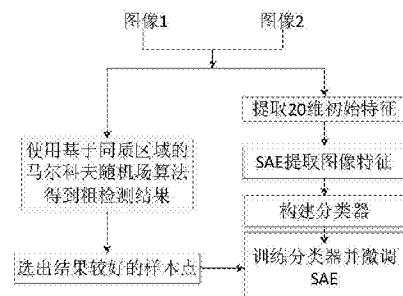
(54)发明名称

一种基于SAE的遥感图像变化检测方法

(57)摘要

本发明涉及一种基于SAE的遥感图像变化检测方法，使用堆叠自编码器(Stacked AutoEncoder, SAE)的训练方式，先训练好一个SAE，然后利用它对原始数据进行自主式特征提取；再用无监督的变化检测方法对两幅原始图像做变化检测，得到的粗变化检测结果；在去除掉一些疑似噪音的样本点后，将其作为教师数据对分类器进行训练；在训练分类器的同时也需要对SAE的参数进行微调。训练结束后，就可得到一种基于SAE的检测网络，从而利用该检测网络实现遥感图像变化检测。本发明将深度神经网络这种有监督的学习模型，与遥感图像变化检测这种无监督的图像分类问题巧妙地结合起来，并改进了特征和训练样本，提高了检测精度和检测的鲁棒性。

CN 105608698



1. 一种基于SAE的遥感图像变化检测方法,其特征在于步骤如下:

步骤1:对不同时刻同一地点获取的两幅待检测遥感图像进行配准、辐射校正及几何校正;对校正后的图像数据进行原始特征提取,提取方法是:提取以每个坐标点为中心 $3*3$ 的图像块,组成一个18维的向量,并进行归一化;再加入2维的图像点归一化的坐标信息,拓展成为一个20维向量,作为一个检测样本点的原始特征;

步骤2:以提取到的原始特征作为输入对堆叠自编码器SAE进行无监督的训练;

步骤3:计算两幅待检测图像的差分图像,对差分图像使用基于同质区域的马尔科夫随机场算法得到粗变化检测结果图;

如果待检测图像是光谱图像,则对两幅待检测图像进行绝对值差分,得到差分图像;

如果是合成孔径雷达SAR图像,则使用取对数差分,得到差分图像;

步骤4:通过坐标将步骤1获得的原始特征与步骤3中获得的粗变化检测结果图进行配对,对于在粗变化检测结果图中与自身8邻域结果均不相同的输出点,去掉与它们配对对应的样本点;

步骤5:在堆叠自编码器SAE后构造逻辑回归分类器形成基于SAE的检测网络,然后将筛选后的样本点数据,作为基于SAE的检测网络的输入样本,对基于SAE的检测网络进行训练;

训练方法为:将步骤4精炼后的变化检测结果作为输入样本的教师信号,采用误差的反向传播BP算法微调SAE的参数;迭代次数为200到300次;

步骤6:训练终止后,利用训练好的基于SAE的检测网络对待测样本进行检测,得到最终变化检测结果图;

所述步骤2的堆叠自编码器SAE的隐层数为2到9,每层中节点个数取5到35;所述步骤2的训练方法为堆叠自编码器SAE进行无监督训练的常规训练方法。

一种基于SAE的遥感图像变化检测方法

技术领域

[0001] 本发明属于遥感图像变化检测方法,具体涉及一种基于SAE的遥感图像变化检测方法。

背景技术

[0002] 遥感图像变化检测的通常技术是先将两图像进行差分,再将差分图以像素点为单位进行二分类;或者先对图像进行分割,再以分割后的对象作为基本单位对分割后的图像进行二分类。在现有技术中,提取哪些特征来进行分类,通常由人为设定,往往会忽略图像本身含有的许多信息,导致检测结果不够精确。

[0003] 深度神经网络通过逐层训练的方式自主提取图像特征,有效地解决了人为提取特征过程中信息遗漏的问题。但深度神经网络是一种有监督的学习模型,而遥感图像变化检测问题是一个无监督的图像分类问题,没有训练数据,也没有类别标签,因此这两种技术通常被认为很难结合使用。

发明内容

[0004] 要解决的技术问题

[0005] 为了避免现有技术的不足之处,本发明提出一种基于SAE的遥感图像变化检测方法,把深度神经网络技术运用到遥感图像变化检测方面以解决检测精确度不高的问题。

[0006] 技术方案

[0007] 一种基于SAE的遥感图像变化检测方法,其特征在于步骤如下:

[0008] 步骤1:对不同时刻同一地点获取的两幅待检测遥感图像进行配准、辐射校正及几何校正;对校正后的图像数据进行原始特征提取,提取方法是:提取以每个坐标点为中心 3×3 的图像块,组成一个18维的向量,并进行归一化;再加入2维的图像点归一化的坐标信息,拓展成为一个20维向量,作为一个检测样本点的原始特征;

[0009] 步骤2:以提取到的原始特征作为输入对堆叠自编码器SAE进行无监督的训练;

[0010] 步骤3:计算两幅待检测图像的差分图像,对差分图像使用基于同质区域的马尔科夫随机场算法得到粗变化检测结果图;

[0011] 如果待检测图像是光谱图像,则对两幅待检测图像进行绝对值差分,得到差分图像;

[0012] 如果是合成孔径雷达SAR图像,则使用取对数差分,得到差分图像;

[0013] 步骤4:将步骤1获得的原始特征与步骤3中获得的粗变化监测结果图以坐标进行配对,对于在粗变化检测结果图中与自身8邻域结果均不相同的输出点,去掉与它们配对对应的样本点;

[0014] 步骤5:在堆叠自编码器SAE后构造逻辑回归分类器形成基于SAE的检测网络,然后将筛选后的样本点数据,作为基于SAE的检测网络的输入样本,对基于SAE的检测网络进行训练;

[0015] 训练方法为：将步骤4精炼后的变化检测结果作为输入样本的教师信号，采用误差的反向传播BP算法微调SAE的参数。迭代次数通常为200到300次；

[0016] 步骤6：训练终止后，利用训练好的基于SAE的检测网络对待测样本进行检测，得到最终变化检测结果图。

[0017] 所述步骤2的堆叠自编码器SAE的隐层层数为2到9，每层中节点个数取5到35。

[0018] 所述步骤2的训练方法为堆叠自编码器SAE进行无监督训练的常规训练方法。

[0019] 有益效果

[0020] 本发明提出的一种基于SAE的遥感图像变化检测方法，使用堆叠自编码器(Stacked AutoEncoder, SAE)的训练方式，先训练好一个SAE，然后利用它对原始数据进行自主式特征提取；再用无监督的变化检测方法对两幅原始图像做变化检测，得到的粗变化检测结果；在去除掉一些疑似噪音的样本点后，将其作为教师数据对分类器进行训练；在训练分类器的同时也需要对SAE的参数进行微调。训练结束后，就可得到一种基于SAE的检测网络，从而利用该检测网络实现遥感图像变化检测。

[0021] 而且，本发明对输入数据的原始特征进行了改进。在现有技术中，通常采用的为差分图中每个坐标点为中心的3*3区域拉伸成9维向量作为原始特征。本发明中不采用差分图，更改为：采用两幅图像相同坐标点的3*3区域，拉伸成18维向量，再加入归一化的坐标点位置信息，拓展成20维向量。

[0022] 本发明将深度神经网络这种有监督的学习模型，与遥感图像变化检测这种无监督的图像分类问题巧妙地结合起来，并改进了特征和训练样本，提高了检测精度和检测的鲁棒性。

附图说明

[0023] 图1：基于SAE的检测网络的训练流程图；

[0024] 图2：利用训练好的基于SAE的检测网络获得变化检测结果图流程图

具体实施方式

[0025] 现结合实施例、附图对本发明作进一步描述：

[0026] 深度神经网络通常包括三个模型，分别为：堆叠自编码器、深度置信网络、卷积神经网络。本发明使用堆叠自编码器(Stacked AutoEncoder, SAE)的训练方式。

[0027] 实施方式的具体步骤如下：

[0028] (1) 设时刻 t_1, t_2 为两个不同时刻，设 X_1, X_2 为在 t_1, t_2 时刻，同一遥感传感器及同一波段上对同一地点获取的两幅遥感图像，且 X_1, X_2 已经经过配准和辐射校正及几何校正。对每个坐标点 (i, j) ，提取两幅图像中以此坐标点为中心的3*3的像素，并将其拉成一列，作为一个18维的向量，并对其进行归一化，再加入归一化后的坐标信息 (i', j') ，获得一个20维训练样本 $Tr(i, j)$ 。

[0029] (2) SAE是由多个自动编码器(AutoEncoder, AE)组成。AE由三层节点组成，分别为输入层、隐藏层和重建层。AE具体训练方式如下：

[0030] 设置输入层到隐藏层的权重为 W_y ，偏置为 b_y ；隐藏层到输出层权重和偏置分别为 W_z, b_z ，我们对 W_y 和 W_z 定义如下的约束：

[0031] $W_y = W_z^T = W$;

[0032] 定义代价函数:

$$[0033] c = -\frac{1}{m} \sum_{i=1}^m \sum_{k=1}^d (x_{ik} - z_{ik})^2$$

[0034] 其中d代表输出单元的个数,m表示训练数据的个数, x_{ik} 表示第i个输入的第k个单元, z_{ik} 表示第i个输出的第k个单元,分别计算代价函数c对权重W及偏置 b_y, b_z 的偏导数,然后利用BP算法:

$$[0035] W = W - \eta \frac{\partial c}{\partial W}; \quad b_y = b_y - \eta \frac{\partial c}{\partial b_y}; \quad b_z = b_z - \eta \frac{\partial c}{\partial b_z}$$

[0036] 来更新网络参数,最小化AE的代价函数。其中 η 代表学习速率,通常取0.01左右,训练迭代次数为20-50次,这样重建层能较好地还原输入层。

[0037] 在构造SAE时,使用的是AE的输入层和隐藏层进行堆叠,后续一层的AE将上一层AE的隐藏层作为输入层,3层的SAE即3个累加构建的SAE。在变化检测中,网络深度通常采用2到9层的SAE,每个隐层节点个数通常为5到35个节点。本实施例中测试数据采用的是3层的SAE,每个隐层节点个数为15。构造好的SAE使用步骤1中提取的特征进行分层无监督的训练。

[0038] (3)对于光谱图像,可对 X_1, X_2 差分,得到差分图D, $D(i, j) = |X_1(i, j) - X_2(i, j)|$;对于SAR图像,先取两图像的比值,然后取这个比值的对数的绝对值构成差分图,

$$D(i, j) = |\log_2 \frac{X_1(i, j)}{X_2(i, j)}|, \text{最后进行归一化,即 } D = 255 * \frac{D - \min(D)}{\max(D) - \min(D)}, \min(\cdot), \max(\cdot) \text{ 分别为}$$

取最小值与最大值函数。

[0039] 对差分图像D利用Mean Shift算法进行图像分割。得到分割成许多同质区域的分割图像 $SC = \{SC_k, 1 \leq k \leq L\}$,L为分割图像的不同同质区域的数目, SC_k 为分割图像中的第k个同质区域。

[0040] 对差分图像D利用EM算法估计图像整个域上高斯分布模型的参数。建立如下的MRF变化检测模型:

$$[0041] U(D, C) = \sum_{(i, j)} U_{data}(D(i, j) / C(i, j)) + U_{context}[C(i, j) / \{C(g, h), (g, h) \in SC_k \cap (i, j) \in SC_k\}]$$

[0042] 其中 $D = \{D(i, j), 1 \leq i \leq M, 1 \leq j \leq N\}$ $D(i, j)$ 为D中第i行、第j列的像素值; $C = \{C(i, j), 1 \leq i \leq M, 1 \leq j \leq N\}$ 为标号图,即所要求的变化检测图,其中 $C(i, j)$ 取值为{0, 1},0代表不变,1代表变化。

[0043] 通过条件迭代模型算法最小化MRF变化检测模型 $U(D, C)$,获得粗变化检测图C,详见参考文献:[1]Fangshun Liao, Sufen Yu, Ying Li, Yanning Zhang. An Improved Method in Change Detection of Multitemporal Remote Sensing Image. Lecture Notes in Computer Science, 2013, 8261:587-594.。

[0044] (4)将步骤1获得的原始特征与步骤3中获得的粗变化监测结果图以坐标进行配对,对于那些在粗变化检测结果图中与自身8邻域结果均不相同的输出点,去掉与它们配对对应的样本点。例如在粗变化检测结果中,点(i, j)与以其为中心3*3邻域的结果均不相同,

则抛弃此样本点。

[0045] (5) 构造逻辑回归分类器，并连接到SAE尾部。使得输入数据先经无监督的SAE提取特征，再将SAE网络自动提取的特征使用逻辑回归分类器进行分类。将上一步骤筛选后的样本点数据，作为基于SAE的检测网络的输入样本，对SAE和逻辑回归分类器进行训练。训练分类器时利用步骤3中得到的粗变化检测结果作为教师信号，使用BP算法微调整整个网络的参数。迭代通常进行200到300次，本实施例中取的是300次，学习率取0.01。

[0046] (6) 训练好基于SAE的检测网络后，就可以利用步骤1获得的原始特征 $Tr(i, j)$ 作为输入数据，使用训练好的基于SAE的检测网络对其进行特征提取并分类，得到最终变化检测结果图。

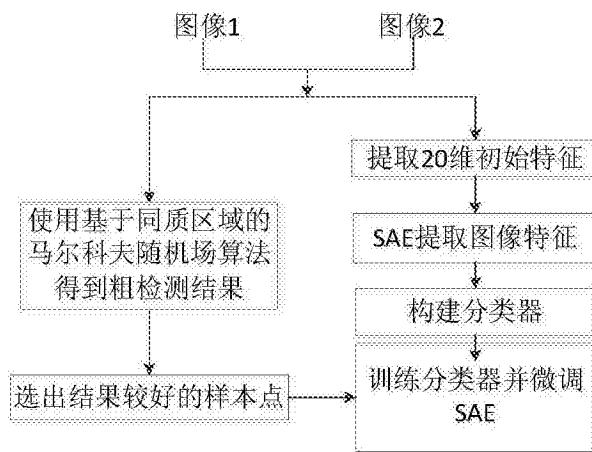


图1



图2