

DOI:10.13203/j.whugis20190471



文章编号:1671-8860(2022)05-0762-07

领域知识优化深度置信网络的遥感变化检测

张海明¹ 王明常^{1,2} 陈学业² 王凤艳¹ 杨国东¹ 高 苏³

1 吉林大学地球探测科学与技术学院,吉林 长春,130026

2 自然资源部城市国土资源监测与仿真重点实验室,广东 深圳,518000

3 云南省地图院,云南 昆明,650034

摘要:为提高高分辨率遥感影像变化检测精度,提出一种以领域知识为优化策略的深度学习变化检测方法。利用改进的变化矢量分析和灰度共生矩阵算法获取影像的光谱和纹理变化,设定合理阈值获得变化区域待选样本;引入领域知识中图斑形状特征指数与光谱知识,筛选得到高质量的训练样本;构建并训练了深度置信网络模型,使用优化策略对深度学习变化检测结果进行优化,以减少“椒盐”噪声和伪变化区对检测精度的影响。通过高分二号与IKONOS影像的变化检测实验表明,该方法较优化前准确率与召回率最大增幅分别为7.58%和14.69%(高分二号)、17.08%和23.87%(IKONOS),虚警率和漏检率最大降幅为30.22%和23.30%(高分二号)、17.08%和23.87%(IKONOS),能够有效提高变化检测精度。

关键词:遥感;变化检测;深度置信网络;领域知识;高分二号

中图分类号:P237

文献标志码:A

遥感变化检测是利用不同时相的遥感影像和相关地理数据,结合遥感成像机理和地物特性,采用图像、图形处理理论和数学模型方法,确定和分析研究区的地表覆盖变化范围和变化类型。其研究目的是提取研究区变化信息,并生成变化图^[1-2]。

高分辨率遥感影像比中低分辨率遥感影像具备更加丰富的光谱、纹理和形状等地物特征,但影像中同类地物的差异性增强,不同地物的光谱特征相互混淆,影像光谱域的统计可分性降低,信息提取难度增大,影像中“同物异谱,异物同谱”的现象大量发生,加重了地物光谱和纹理特征的离散程度,使得基于像元的变化检测精度难以提高^[3]。

深度学习^[4-5]作为机器学习的一个重要分支,可以自动地将简单特征组合成复杂特征,并利用复杂特征进行分类,分类精度大大提高,其在变化检测领域的应用比其他方法更为宽泛,适用性也更强。随着AlexNet^[6]、VGG^[7]、GoogLeNet^[8]和ResNet^[9-10]等深度学习网络的出现,神经网络

在变化检测领域得到了成功应用。张鑫龙等^[2]提出了基于深度玻尔兹曼机的深度学习变化检测方法;Peng等^[10]提出了一种改进的用于语义分割编码器-解码器结构,端到端变化检测方法;Mou等^[11]将光谱空间模块和时态模块进行组合,设计了一种循环3D全卷积网络用于建筑物变化检测。虽然国内外学者针对变化检测中存在的问题进行了大量研究,但深度学习变化检测方法优质训练样本的选取和自动化程度、基于像元检测的“椒盐”现象和伪变化区的出现等仍是目前亟待解决的问题^[12-14]。

领域知识在遥感影像变化检测中的应用,对于解决图像处理算法的局限性、提高变化检测的精度和图像处理的自动化程度具有较为理想的效果^[3]。深度置信网络(deep belief networks, DBN)是深度学习领域较为经典的模型,它通过联合概率分布来推断样本数据分布,非常适用于基于像元的变化检测研究。改进的变化矢量分析算法^[2](robust change vector analysis, RCVA)和灰度共生矩阵算法^[15-16](grey level co-occur-

收稿日期:2019-12-25

项目资助:国家自然科学基金(41472243);自然资源部城市国土资源监测与仿真重点实验室开放基金(KF-2018-03-020, KF-2019-04-080);自然资源部地面沉降监测与防治重点实验室开放基金(KLLSMP201901);吉林省教育厅“十三五”科学研究规划项目(JJKH20200999KJ)。

第一作者:张海明,硕士,主要从事深度学习变化检测研究。zhanghm18@mails.jlu.edu.cn

通讯作者:王明常,博士,教授。wangmc@jlu.edu.cn

rence matrix, GLCM)能够提取影像光谱和纹理差异特征,减小由于预处理阶段的配准所造成的误差,减弱高分辨率遥感影像中地物间光谱特征相互混淆等不利因素对检测结果的影响。

本文以DBN为深度学习模型,利用RCVA和GLCM算法提取影像光谱和纹理差异特征。将原理性和经验性的领域知识整合成为知识规则,用于选取优质训练样本并作为优化深度学习变化检测结果的依据。通过高分二号与IKONOS影像的变化检测实验,验证了本文方法的有效性。

1 本文方法

1.1 光谱变化特征提取

由于不同时相影像成像条件不同,在对影像进行精配准后,影像间的配准误差仍难以消除。其结果则是两幅影像间的像元对应关系不正确,进而导致了检测时伪变化区的大量出现。RCVA算法通过考虑像元的邻域信息,选择光谱差异最小的像元对进行检测,消除了配准误差带来的影响。

RCVA算法原理如下:基于影像1中的某个像元 $x_1(j, k)$,在影像2($j \pm \omega, k \pm \omega$)范围内求与 x_1 亮度值差异最小的像元 x_2 ,此时认为 x_2 为 x_1 的同名像点,并求取差值 $x_{\text{different}, a}$,表示通过亮度值求得的影像1中 (j, k) 点的变化强度值。同样,基于影像2求对应影像1中的同名像点,并求取差值 $x_{\text{different}, b}$,表示通过亮度值求得的影像2中 (j, k) 点的变化强度值,以 $x_{\text{different}, a}$ 和 $x_{\text{different}, b}$ 较小者作为该点变化强度。

遍历影像,可得到所有像元的光谱变化强度值,进而得到考虑邻域信息的光谱变化强度图。

1.2 纹理变化特征提取

纹理特征是反映图像中同质的一种视觉特征,它体现了物体表面的结构组织排列属性,对于反映物体的表层特征变化具有重要利用价值。GLCM是提取纹理的一种经典方法,也是目前普遍使用且提取效果较好的纹理特征分析法^[16]。已有的研究定义了14种标量来进行纹理分析,其中最常用的有均值、方差、协同性、对比度、熵等8种。以方差为标量研究纹理特征时,最能反应不同地物间的差异^[17-18]。

得到两幅影像的方差特征值后,即可通过差值计算得到纹理变化强度图。

1.3 结合领域知识的训练样本优化

根据光谱变化和纹理变化强度图,通过设置不同阈值提取样本,可对样本进行不同程度的划分。为保证样本的充分性,最大限度地选择到具有代表性的变化地物和未变化地物样本,通过自定义阈值取并集的方式,分析得出合理的阈值组合,并选择该阈值组合下的标记样本作为待优化样本。

阈值组合的选取如下:以光谱变化和纹理变化强度图为基准,在最小强度值和最大强度值闭区间内,从小到大逐个设置阈值对样本进行标记;以参考变化结果为依据,对所有阈值下的样本标记结果进行统计,计算其准确率;计算相邻阈值间的准确率增幅,由于准确率反映了正负样本标记的正确程度,因此在准确率增幅趋于稳定的节点处即可选定较为合理的阈值;以相同的方法分别获得RCVA和GLCM下的合理阈值,即组成阈值组合。通过变化强度区间逐个分析得到合理阈值的方式,对阈值的分析较细致,同样能够运用于其他情景下的阈值分析。

高分辨率遥感影像中异常光谱值多,同时,由于影像获取时间和获取条件的不同,植被季节性返青和建筑物阴影区等因素影响,造成了伪变化样本的大量出现。

1)形状特征知识。本文结合领域知识,引入面积(S)和形状复杂度(C)两种形状特征指数作为过滤离散伪变化样本的优化策略。优化策略定义为:(1) $S \geq S_{\min}$,即所有变化样本组成的图斑,其面积均应大于等于最小定义图斑面积,若不满足,则将其归并为未变化样本;(2) $(C = P/s) \leq C_{\min}$, P 为待检测图斑周长, s 为其面积,当满足条件 $S_{\max} \geq s \geq S_{\min}$ 时, C 值越大说明图斑越复杂,是离散碎图斑的概率就越大,可将其归并为未变化样本。根据形状特征知识,本文设计的各类小图斑检测图谱如图1所示。

图1中共有134种图斑类型,是像素个数不大于4的所有图斑形式,其中,(a)~(l)为根据图斑形状和遍历窗口大小进行的排序。将待检测图斑与图1比对,若形状相同,则可对该图斑进行删除或归并(归为未变化图斑)。

2)光谱特征知识。针对植被(农作物、绿化带等)季节性返青和建筑物阴影等因素所引起的带状、块状伪变化样本集中区,通过对两幅影像固定窗口内同名像元亮度值采样的方式,自定义光谱映射区间。依据光谱映射区间建立光谱知

识规则，并对两幅影像进行遍历，剔除伪变化样本。

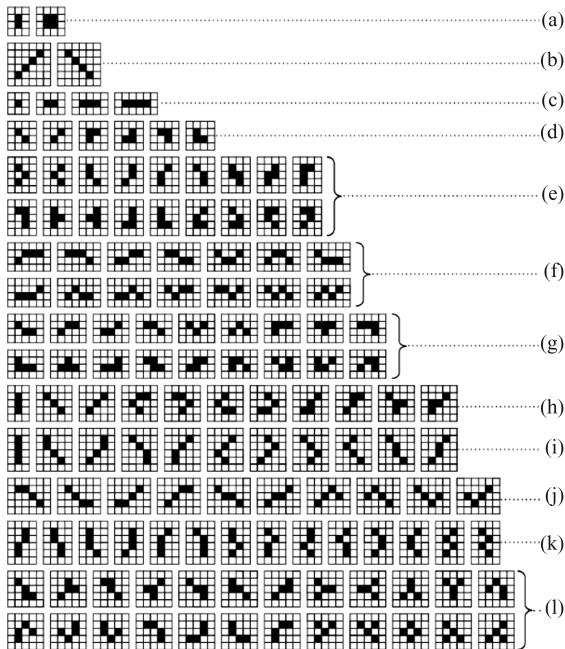


图1 小图斑检测图谱

Fig.1 Graph for Detecting Small Patches

映射关系建立方式为：

$$(\varphi_{\min}^1 \leqslant \varphi^1 \leqslant \varphi_{\max}^1) \xleftrightarrow{f_w} (\varphi_{\min}^2 \leqslant \varphi^2 \leqslant \varphi_{\max}^2) \quad (1)$$

式中， φ^1 和 φ^2 分别为两幅影像中同名像元红、绿、蓝 3 个波段的亮度值 ($\varphi_R^1, \varphi_G^1, \varphi_B^1$ 与 $\varphi_R^2, \varphi_G^2, \varphi_B^2$)； φ_{\min}^1 与 φ_{\max}^1 为映射区间下限； φ_{\min}^2 与 φ_{\max}^2 为映射区间上限； w 为滑动窗口大小。

1.4 DBN 模型训练与变化检测

DBN 是一种概率生成模型^[19]，通过联合概率分布来推断样本数据分布。通过逐层非监督的训练方式对大量无标签样本数据进行特征提取，并通过少量有标签的样本数据进行模型优化，最后获得网络最优权重，使得网络能依据最大概率生成训练数据。DBN 主要由两部分构成，第一是多层限制玻尔兹曼机 (restricted Boltzmann machine, RBM)，用于预训练网络；第二是前馈反向传播网络，此部分可以使 RBM 堆叠的网络更加精细化。

RBM 含有两层(显层 v 、隐层 h)，为无向图模型，每层可定义为一个向量，向量的维度即为该层神经元的个数，不同层之间的神经元由权值矩阵 W 连接。对于每一个 RBM，都有其作为一个系统所具备的能量，而根据能量函数则可以得到关于 v 与 h 的联合概率分布 $P(v, h|\theta)$ ($\theta =$

$\{W_{ij}, a_i, b_j\}$ 为模型参数， W_{ij} 为神经元 i, j 之间的权重， a_i 和 b_j 分别表示显层和隐层神经元间的偏置)，DBN 则是通过基于 $P(v, h|\theta)$ 的相关计算来重构样本数据。经过迭代可不断优化网络参数，达到初始化每个 RBM 参数的目的。当 RBM 网络中的特征向量在映射到不同特征空间时能够保存最多的特征信息，完成 DBN 的预训练。基于误差反向传播算法，利用有标签的样本数据，通过计算各 RBM 层的学习误差，对网络权值 W 进行更新，微调整整个模型，完成 DBN 的训练。

RBM 的显层用来接收变量，且传统的输入多为二值变量，而连续输入的实值变量则更适用于图像分类和语音识别等^[2]。本文 DBN 的输入为 2×2 像素范围内像元红、绿、蓝 3 波段的归一化亮度值依次排列的向量。

利用预选好的样本对模型进行训练，当训练精度达到精度要求后，对模型进行保存，并利用模型对整幅影像进行检测，得到变化检测结果。由于 DBN 模型是基于像元的变化检测，模型训练完毕后权值已固化，因此当进行变化检测时会出现少量的“椒盐”噪声。为进一步提高检测精度，利用图 1 中的(a)检测图斑对未变化区域中的孤立点进行剔除，对变化区域中的孤立点进行填充，得到最终的变化检测结果。

2 实验与分析

2.1 实验 1

实验 1 所用数据为 2016-05-19 和 2017-04-29 获取的长春市某地区高分二号遥感影像，影像分辨率为 1 m，包含红、绿、蓝 3 个波段，影像大小为 1389×2200 像素，如图 2(a)所示；利用 RCVA 和 GLCM 得到变化强度图如图 2(b)所示。通过分析准确率增幅，选定 RCVA 和 GLCM 的阈值分别为 75 和 16，作为划分变化样本的尺度。准确率增幅随阈值变化趋势图如图 3 所示。在该阈值组合下得到的变化样本，覆盖范围较广，各类变化地物样本标记较全面、充分，变化样本标记情况如图 4(a)所示。

利用领域知识优化策略，对所标记的变化样本进行过滤，得到能够准确反映变化与未变化区域的高质量样本。对植被季节性返青区和建筑物阴影区的典型区域进行采样，建立映射区间，剔除伪变化区。执行优化策略后的变化样本标记图如图 4(b)所示，其中，红色实线框内为建筑

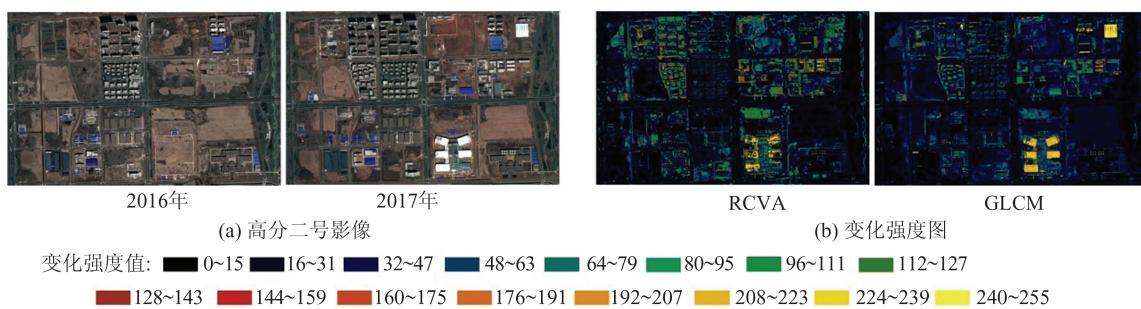


图2 高分二号遥感影像与变化强度图
Fig.2 GF-2 Images and Intensity Change Images

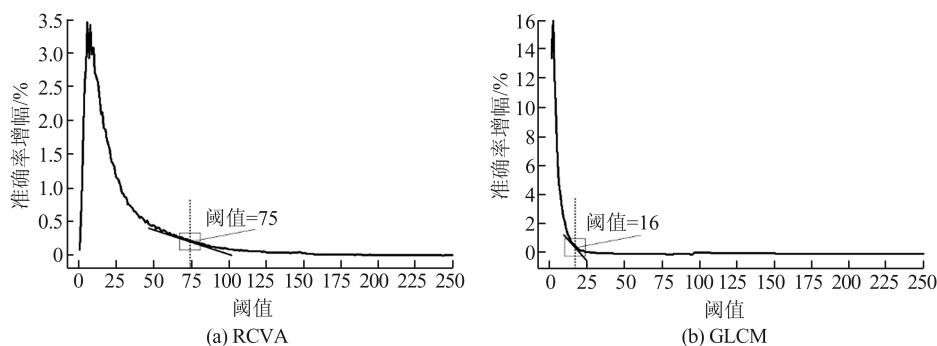


图3 准确率增幅变化趋势图
Fig.3 Trend of Accuracy Increase



图4 执行优化策略前后变化样本标记图(实验1)
Fig.4 Change Sample Marker Image Before and After Executing the Optimization Strategy (Experiment 1)

物阴影被大量剔除的典型区域,红色虚线框内为植被季节性返青大量剔除的典型区域。与图4(a)对比可知,执行优化策略后有大量伪变化样本被剔除。

根据图4(b)的样本标记图,共选取变化样本 211 637 个,未变化样本 2 844 163 个。为了验证

本文方法的有效性,分别在已有的变化与未变化样本中随机选取了不同数量的样本对 DBN 进行训练,并统计了 DBN 变化检测结果的准确率、召回率、虚警率和漏检率,如表 1 所示,其中,A、B、C 分别代表训练样本优化前、训练样本优化后和变化检测结果优化后。

表1 训练样本优化前后精度分析表(实验1)

Tab.1 Precision Analysis Before and After Optimizing Training Samples (Experiment 1)

数量/个	正样本	负样本	准确率/%			召回率/%			虚警率/%			漏检率/%		
			A	B	C	A	B	C	A	B	C	A	B	C
5 000	5 000	5 000	88.70	93.28	93.77	65.30	76.30	80.10	60.42	42.42	39.76	34.70	23.70	19.90
10 000	10 000	10 000	88.63	94.09	94.59	66.59	73.75	78.68	60.45	37.37	34.30	33.41	26.25	21.32
30 000	30 000	30 000	88.26	92.45	93.07	66.60	78.95	83.68	61.46	46.57	43.70	33.40	21.05	16.32
50 000	50 000	50 000	87.72	91.74	92.80	68.21	79.16	83.45	62.62	49.44	44.96	31.79	20.84	16.55
80 000	80 000	80 000	86.90	94.42	94.48	69.14	73.14	75.21	64.37	35.09	34.15	30.86	26.86	24.79

由表1可知,训练样本优化后,准确率和召回率有较大幅度提高,其中,准确率最大增幅7.52%,召回率最大增幅12.35%;虚警率和漏检率有较大幅度下降,其中,虚警率最大降幅29.28%,漏检率最大降幅12.35%。对变化检测结果优化后,准确率最大增幅1.06%,召回率最大增幅4.93%,虚警率最大降幅4.48%,漏检率最大降幅4.93%。

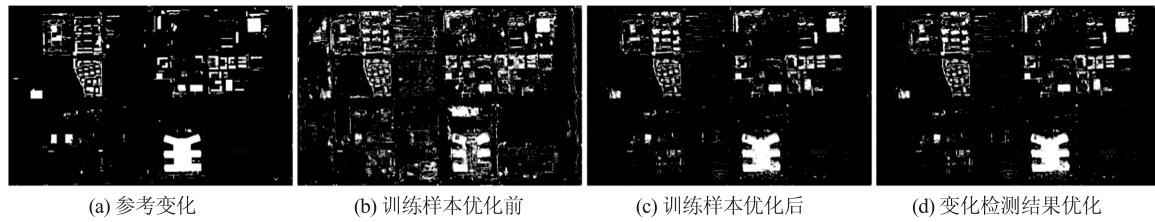


图5 变化检测结果对比图(实验1)

Fig.5 Comparison of Change Detection Results (Experiment 1)

2.2 实验2

实验2数据选自在武汉多时相场景变化检测数据集(multi-temporal scene Wuhan, MtS-WH),影像由IKONOS传感器分别获取于2002-02-11和2009-06-24,分辨率为1 m,包含红、绿、蓝和近红外4个波段,实验区影像大小为1 778×1 784像

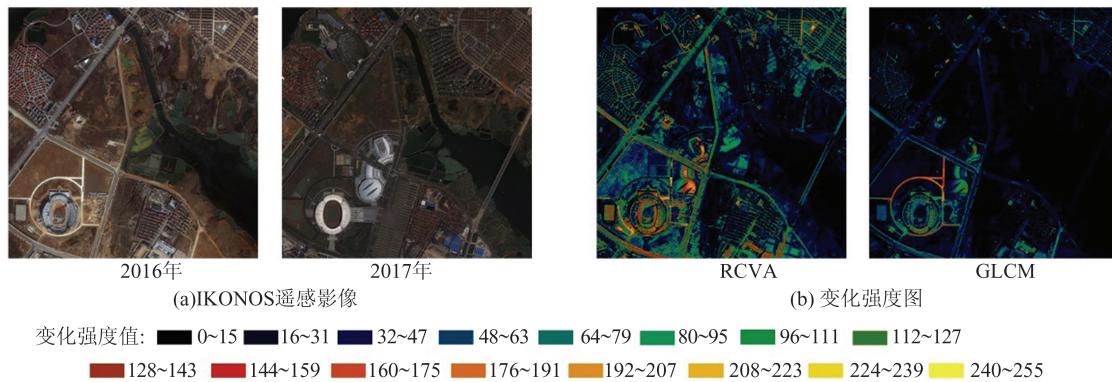


图6 IKONOS遥感影像与变化强度图

Fig.6 IKONOS Images and Intensity Change Images

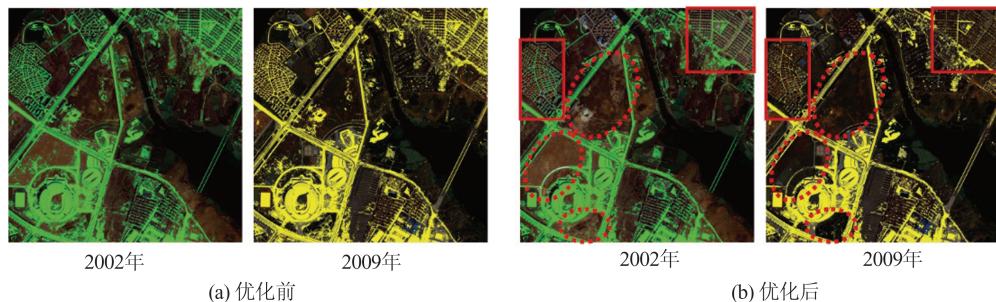


图7 优化前后变化样本标记图(实验2)

Fig.7 Change Sample Marker Images Before and After Executing the Optimization Strategy (Experiment 2)

参考变化检测结果是通过MtS-WH中给出的类别标签作差,附加人工目视解译得到,类别标签作差过程完全按照MtS-WH的类别参考结

果进行,可认为无相对误差,参考变化及变化检测结果如图8所示。不同数量训练样本得到的DBN变化检测的精度如表2所示。

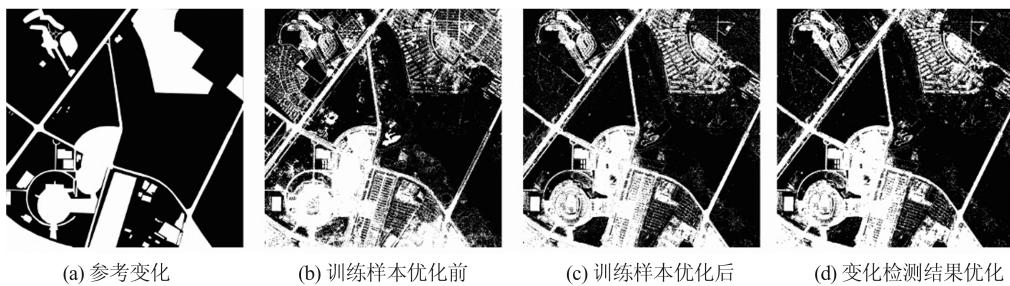


图 8 变化检测结果对比图(实验 2)

Fig.8 Comparison of Change Detection Results (Experiment 2)

表 2 训练样本优化前后精度分析表(实验 2)

Tab.2 Precision Analysis Before and After Optimizing Training Samples (Experiment 2)

数量/个	正样本	准确率/%			召回率/%			虚警率/%			漏检率/%		
		A	B	C	A	B	C	A	B	C	A	B	C
5 000	5 000	73.27	83.57	86.29	64.58	73.37	77.79	45.42	27.75	23.23	35.42	26.63	22.21
10 000	10 000	72.20	83.83	85.70	66.89	77.86	79.02	47.13	28.99	25.26	33.11	22.14	20.98
30 000	30 000	72.28	84.37	86.97	57.26	79.39	81.13	46.57	28.42	23.27	42.74	20.61	18.87
50 000	50 000	73.83	83.93	86.52	65.20	80.86	82.28	44.60	29.88	24.87	34.80	19.14	17.72
80 000	80 000	72.95	84.51	87.46	63.06	81.81	84.87	45.80	29.04	23.83	36.94	18.19	15.13

由表 2 可知, 实验 2 准确率和召回率都有较大幅度的提高, 其中, 准确率最大增幅为 12.14%, 召回率最大增幅为 22.13%; 同时, 虚警率和漏检率都有较大幅度的下降, 虚警率最大降幅为 18.15%, 漏检率最大降幅为 22.13%。变化检测结果优化后, 准确率最大增幅为 2.95%, 召回率最大增幅为 4.42%, 虚警率最大降幅为 5.12%, 漏检率最大降幅为 4.42%。

3 结语

本文提出一种利用领域知识优化策略进行高分辨率遥感影像深度学习变化检测的方法。根据 RCVA 和 GLCM 提取的光谱和纹理特征标注初选样本; 利用领域知识优化策略对样本进行筛选, 获得优质样本; 训练 DBN 模型, 得到变化检测结果, 并利用优化策略对检测结果进行优化。实验表明, 本文方法能够有效提高变化检测结果的准确率和召回率, 大幅度降低虚警率和漏检率。通过提高训练样本质量, 进而提高深度学习模型检测性能, 为高分辨率遥感影像深度学习变化检测提供了一条新途径。同时, 在变化检测结果的基础上执行优化策略, 则进一步提高了检测结果的精度。

参考文献

[1] Tong Guofeng, Li Yong, Ding Weili, et al. Review

of Remote Sensing Image Change Detection [J]. *Journal of Image and Graphics*, 2015, 20(12): 1561-1571 (佟国峰, 李勇, 丁伟利, 等. 遥感影像变化检测算法综述[J]. 中国图象图形学报, 2015, 20(12): 1561-1571)

- [2] Zhang Xinlong, Chen Xiuwan, Li Fei, et al. Change Detection Method for High Resolution Remote Sensing Images Using Deep Learning [J]. *Acta Geodaetica et Cartographica Sinica*, 2017, 46(8): 999-1008 (张鑫龙, 陈秀万, 李飞, 等. 高分辨率遥感影像的深度学习变化检测方法[J]. 测绘学报, 2017, 46(8): 999-1008)
- [3] Li Sheng. Detection Method of Urban Land Cover Change Based on Combining Domain Knowledge and Deep Learning [D]. Wuhan: Wuhan University, 2018 (李胜. 联合领域知识和深度学习的城市地表覆盖变化检测方法[D]. 武汉: 武汉大学, 2018)
- [4] Zhao Z Q, Guo L, Jia M, et al. The Generalized Gamma-DBN for High-Resolution SAR Image Classification [J]. *Remote Sensing*, 2018, 10(6): 878
- [5] Traore B B, Kamsu-Foguem B, Tangara F. Deep Convolution Neural Network for Image Recognition [J]. *Ecological Informatics*, 2018, 48: 257-268
- [6] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition [EB/OL]. [2018-09-15]. <https://arxiv.org/abs/1409.1556>
- [7] Hou B, Wang Y H, Liu Q J. Change Detection Based on Deep Features and Low Rank [J]. *IEEE*

- Geoscience and Remote Sensing Letters*, 2017, 14(12): 2418-2422
- [8] He K M, Zhang X Y, Ren S Q, et al. Deep Residual Learning for Image Recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 2016
- [9] Ji Shunping, Tian Siqi, Zhang Chi. Urban Land Cover Classification and Change Detection Using Fully Atrous Convolutional Neural Network [J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(2): 233-241 (季顺平, 田思琦, 张驰. 利用全空洞卷积神经元网络进行城市土地覆盖分类与变化检测[J]. 武汉大学学报·信息科学版, 2020, 45(2): 233-241)
- [10] Peng D F, Zhang Y J, Guan H Y. End-to-End Change Detection for High Resolution Satellite Images Using Improved UNet++ [J]. *Remote Sensing*, 2019, 11(11), DOI:10.3390/rs11111382
- [11] Mou L C, Bruzzone L, Zhu X X. Learning Spectral-Spatial-Temporal Features via a Recurrent Convolutional Neural Network for Change Detection in Multispectral Imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(2): 924-935
- [12] Sui Haigang, Feng Wenqing, Li Wenzhuo, et al. Review of Change Detection Methods for Multi-Temporal Remote Sensing Imagery [J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(12): 1885-1898 (眭海刚, 冯文卿, 李文卓, 等. 多时相遥感影像变化检测方法综述[J]. 武汉大学学报·信息科学版, 2018, 43(12): 1885-1898)
- [13] Zhao Shengyin, An Ru, Zhu Meiru. Urban Change Detection by Aerial Remote Sensing Using Combining Features of Pixel-Depth-Object[J]. *Acta Geodaetica et Cartographica Sinica*, 2019, 48(11): 1452-1463 (赵生银, 安如, 朱美如. 联合像元-深度-对象特征的遥感图像城市变化检测[J]. 测绘学报, 2019, 48(11): 1452-1463)
- [14] Huang X, Liu X B, Zhang L P. A Multichannel Gray Level Co-occurrence Matrix for Multi/Hyperspectral Image Texture Representation [J]. *Remote Sensing*, 2014, 6(9), DOI:10.3390/rs6098424
- [15] Kupidura P. The Comparison of Different Methods of Texture Analysis for Their Efficacy for Land Use Classification in Satellite Imagery [J]. *Remote Sensing*, 2019, 11(10), DOI:10.3390/rs11101233
- [16] Park K, Kim D H. Accelerating Image Classification Using Feature Map Similarity in Convolutional Neural Networks [J]. *Applied Sciences*, 2018, 9(1), DOI:10.3390/app9010108
- [17] Xiao P F, Zhang X L, Wang D G, et al. Change Detection of Built-Up Land: A Framework of Combining Pixel-Based Detection and Object-Based Recognition[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 119: 402-414
- [18] Li J J, Xi B B, Li Y S, et al. Hyperspectral Classification Based on Texture Feature Enhancement and Deep Belief Networks[J]. *Remote Sensing*, 2018, 10(3), DOI:10.3390/rs10030396
- [19] Gao X G, Li F, Wan K F. Accelerated Learning for Restricted Boltzmann Machine with a Novel Momentum Algorithm [J]. *Chinese Journal of Electronics*, 2018, 27(3): 483-487

Remote Sensing Change Detection Based on Deep Belief Networks Optimized by Domain Knowledge

ZHANG Haiming¹ WANG Mingchang^{1,2} CHEN Xueye² WANG Fengyan¹
YANG Guodong¹ GAO Su³

1 College of Geo-Exploration Science and Technology, Jilin University, Changchun 130026, China

2 Key Laboratory of Urban Land Resources Monitoring and Simulation, MNR, Shenzhen 518000, China

3 Yunnan Provincial Mapping Institute, Kunming 650034, China

Abstract: **Objectives:** A method of deep learning change detection with domain knowledge as an optimization strategy was proposed to improve the change detection precision of high-resolution remote sensing images. **Methods:** The improved change vector analysis algorithm and grey-level co-occurrence matrix algorithm were used to obtain the spectral and texture changes of images, and reasonable thresholds were set to divide the changed samples from the unchanged samples based on the spectral and texture change intensity

(下转第 788 页)

waveform noise, respectively, while the recognition accuracy of NTFT+CNN model was 99.80%, 97.21% and 98.50%, respectively, which further verified the recognition effect of NTFT on noise and seismic signal, the correctness of model results. The NTFT+CNN model was applied to identify the seismic-impulse noise data shared by the Southern California Earthquake Data Center. Comparing to CNN, NTFT+CNN model has more advantages on convergence speed, recognition accuracy and the number of training samples required. **Conclusions:** NTFT provides a new and efficient way for the recognition of seismic signal in neural network structure.

Key words: time frequency analysis; convolutional neural networks(CNN); earthquake signal auto-recognizing

First author: YAO Yanji, PhD candidate, specializes in the theory, algorithm and application of normal time-frequency transform. E-mail: yaoyanji@asch.whigg.ac.cn

Corresponding author: LIU Lintao, PhD, professor. E-mail: llt@asch.whigg.ac.cn

Foundation support: The National Natural Science Foundation of China (41074050); the Natural Science Foundation of Hubei Provincial (2019CFB795); the Open Foundation of Key Laboratory of Geo-Informatics of State Bureau of Surveying and Mapping (201814).

引文格式: YAO Yanji, LIU Lintao, WANG Guocheng, et al. A Normal Time-Frequency Transform Method for Automatic Recognition of Earthquake Event[J]. Geomatics and Information Science of Wuhan University, 2022, 47(5):780–788. DOI:10.13203/j.whugis20190432(姚彦吉,柳林涛,王国成,等.地震事件自动识别的标准时频变换方法[J].武汉大学学报·信息科学版,2022,47(5):780–788. DOI:10.13203/j.whugis20190432)

(上接第 768 页)

maps. The pattern shape index and spectral knowledge in domain knowledge were introduced as an optimization strategy to filter the changed samples for obtaining high-quality training samples. The deep belief network model was constructed and trained, and the results of deep learning change detection were optimized by the optimization strategy to reduce the influence of “salt and pepper noise” and false change zones on the detection accuracy. **Results:** The Results of change detection experiments show that the accuracies of Gaofen-2 and IKONOS images were increased by 7.58% and 14.69% and the recall by 17.08% and 23.87%, respectively, while the false alarms and were decreased by 30.22% and 23.30% and the missing alarms by 17.08% and 23.87%, respectively. **Conclusions:** Compared with the method before the optimization strategy was adopted, the proposed method in this paper can effectively improve the precision of change detection, and it provides a new way of using remote sensing images to improve the precision of deep learning change detection.

Key words: remote sensing; change detection; deep belief networks; domain knowledge; Gaofen-2 (GF-2)

First author: ZHANG Haiming, master, specializes in deep learning change detection. E-mail: zhanghm18@mails.jlu.edu.cn

Corresponding author: WANG Mingchang, PhD, professor. E-mail: wangmc@jlu.edu.cn

Foundation support: The National Natural Science Foundation of China (41472243); the Open Fund of Key Laboratory of Urban Land Resources Monitoring and Simulation, Ministry of Natural Resources(KF-2018-03-020, KF-2019-04-080); the Open Fund of Key Laboratory of Land Subsidence Monitoring and Prevention, Ministry of Natural Resources (KLLSMP201901); the Scientific Research Project of the 13th Five-Year Plan of Jilin Province Education Department (JJKH20200999KJ).

引文格式: ZHANG Haiming, WANG Mingchang, CHEN Xueye, et al. Remote Sensing Change Detection Based on Deep Belief Networks Optimized by Domain Knowledge[J]. Geomatics and Information Science of Wuhan University, 2022, 47(5):765–772. DOI:10.13203/j.whugis20190471(张海明,王明常,陈学业,等.领域知识优化深度置信网络的遥感变化检测[J].武汉大学学报·信息科学版,2022,47(5):765–772. DOI:10.13203/j.whugis20190471)