

基于边缘检测及 RBF 神经网络的遥感图像帧特征动态识别技术

薛薇¹, 张锋², 凡静¹, 王博¹, 李娜¹

(1. 西安交通大学城市学院 计算机系, 西安 710018; 2. 西安交通大学 电气学院, 西安 710049)

摘要: 为解决分辨率超限问题, 实现对遥感图像帧特征对象的精准识别, 提出基于边缘检测及 RBF 神经网络的遥感图像帧特征动态识别技术; 求解微分算子与 OTSU 阈值, 并以此为基础, 确定边缘节点追踪参数的取值范围, 实现对遥感图像边缘检测; 根据 RBF 神经网络机制的构建标准, 推导神经性激活函数, 完成 RBF 神经网络识别模型的设计; 在所选遥感图像中, 实施帧特征分割处理, 再联合动态合并条件, 计算超像素指标与并行识别参量, 完成基于边缘检测及 RBF 神经网络的遥感图像帧特征动态识别方法的设计; 实验结果表明, 在边缘检测与 RBF 神经网络模型的作用下, 主机元件在长、宽、高 3 个方向上对于遥感图像帧特征对象的识别精度都达到了 100%, 分辨率超限问题得到较好解决, 符合精准识别遥感图像特征的实际应用需求。

关键词: 边缘检测; RBF 神经网络; 遥感图像; 帧特征; 动态识别; OTSU 阈值; 神经性激活函数; 超像素

Dynamic Recognition Technology of Remote Sensing Image Frame Features Based on Edge Detection and RBF Neural Network

XUE Wei¹, ZHANG Feng², FAN Jing¹, WANG Bo¹, LI Na¹

(1. Computer Department, Xi'an Jiaotong University City College, Xi'an 710018, China;

2. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: In order to solve the problem of resolution overrun and realize the accurate recognition of remote sensing image frame feature objects, a dynamic recognition technology of remote sensing image frame feature based on edge detection and radical basis function (RBF) neural network is proposed. The differential operator and OTSU threshold are solved to determine the value range of the tracking parameters of the edge node, and realize the edge detection of the remote sensing image. According to the construction standard of the RBF neural network mechanism, the neural activation function is deduced, and the RBF neural network recognition model is designed. In the selected remote sensing image, the frame feature segmentation processing is implemented, and then combined with the dynamic merging conditions, the super-pixel index and parallel recognition parameters are calculated, and the dynamic recognition method of remote sensing image frame feature based on the edge detection and RBF neural network is completed. The experimental results show that under the action of the edge detection and RBF neural network model, the recognition accuracy of the host component for the remote sensing image frame feature object in three directions of length, width and height reaches 100%, and the problem of resolution overrun is well solved, which meets the practical application requirements of the accurate recognition of remote sensing image features.

Keywords: edge detection; RBF neural network; remote sensing image; frame characteristics; dynamic identification; OTSU threshold; neurogenic activation function; super-pixel

0 引言

边缘检测是计算机视觉与图像处理的交叉研究问题, 其目的在于对数字图像中亮度发生明显变化的节点对象进行标注。一般来说, 数字节点表现出的显著变化行为能够反映出图像属性的变化规律, 且对于变化规律的定义并不局限于连续性、非连续性、场景变化等某一特定方向^[1]。RBF 神经网络中文全称为径向基函数神经网络模型, 常保

持三层前馈型连接模式, 既可以用于对数据样本进行分类, 也可以对函数表达式的取值结果进行逼近处理。相较于其他类型的人工神经网络体系, RBF 神经网络的连接结构更加简单, 能够在快速学习数据信息的同时, 提升网络体系的泛化运行能力^[2]。从某种程度来说, 边缘检测思想与 RBF 神经网络的设计原则具有相似性, 将二者结合能够精准提取目标对象中的隐藏信息, 且在选择目标对象时, 并不设置明确的取样条件。

收稿日期: 2023-01-18; 修回日期: 2023-03-07。

基金项目: 西安交通大学城市学院 2020 年度校级科研项目(202002X03)。

作者简介: 薛薇(1987-), 女, 陕西汉中, 硕士, 助教, 主要从事图像识别、人工智能、大数据分析方向的研究。

引用格式: 薛薇, 张锋, 凡静, 等. 基于边缘检测及 RBF 神经网络的遥感图像帧特征动态识别技术[J]. 计算机测量与控制, 2023, 31(7): 163-168.

遥感影像由卫星相片、航空像片两部分组成,特指能够记录地物电磁波水平的照片与胶片。能供计算机元件直接处理的遥感图像一定是数字图像,而通过摄影方式所获取的图像大多为模拟状态,因此在录入图像信息时,需借助扫描仪等设备对其进行模/数转换处理。为了提升遥感影像的分辨率,相关学者纷纷对遥感图像处理方法做出了研究。文献 [3] 提出少样本条件下基于生成对抗网络的遥感图像数据增强处理方法,通过全局决策的方式,对帧节点对象特征进行识别,再借助训练集单位,实施对目标信息的融合与检测处理。文献 [4] 提出基于偏好型支持向量机的遥感图像云检测技术,从灰度特征与纹理特征的角度着手,对遥感图像的帧特征信息进行识别,可以通过偏好训练的方式,确定节点对象所处位置,并实施针对性识别与处理。然而上述两种方法的应用并不足以解决分辨率超限的问题,因此达不到 100% 精准识别的目标。针对上述问题,设计基于边缘检测及 RBF 神经网络的遥感图像帧特征动态识别方法。

1 遥感图像边缘检测

遥感图像边缘检测的实现,需要根据微分算子取值,求解 OTSU 阈值,从而对边缘节点追踪参数进行精准计算,本章节将针对上述内容展开深入研究。

1.1 微分算子

微分算子从微分思想的角度,对遥感图像中帧特征参量的梯度水平进行描述,如果所采集到遥感图像具有数字图像的表现特征,那么只要保障微分算子求解结果按照灰度变化梯度规则进行排序,就可以实现对遥感图像帧特征对象的精准识别^[5-6]。对于微分算子的求解需要以导向量系数为基础,具体计算式如下:

$$\alpha = \frac{\beta \cdot \dot{P}}{\chi} \quad (1)$$

式中, \dot{P} 表示遥感图像中帧特征参量的梯度分布向量, β 表示梯度标准定义参数, χ 表示数字化统计参数。

所谓微分就是指无限缩小,在识别遥感图像帧特征时,只有确保对象样本的取样空间足够小,才能够避免既定特征参量在单一识别区间内频繁出现,因此对于微分算子的计算,还要保障帧特征参量的取值空间小于数字化图像的最小分辨率条件^[7]。设 i_1, i_2 表示两个随机选取的微分取样参数,且 $i_1 \neq i_2$ 的不等式条件恒成立, δ 表示帧特征对象在单一样本空间内的取样标准值, I 表示遥感图像的帧特征定义结果, e, u 表示两个不相等的帧特征对象梯度参数,联立式 (1), 可将遥感图像微分算子表达式定义为:

$$O = \frac{\alpha}{2eu^2} |I|^{-(i_1^2 + i_2^2 / 2\delta^2)} \quad (2)$$

如果帧特征对象不存在于遥感图像边缘区域之内,那么微分算子的取值将与数字图像的灰度水平无关,故而为使微分算子表达式影响遥感图像的边缘检测结果,只能在同一边缘区域内对帧特征对象进行取样。

1.2 OTSU 阈值

OTSU 阈值就是在数据样本保持最大类间距情况下求

解所得的方差结果,在识别遥感图像帧特征参数时,对于该项物理指标的求解,不要求数据样本的取值来源于同一个数值区间,所以即便是在边缘检测区域内,运算主机也可以根据 OTSU 阈值的取值结果,判断帧特征对象的数值变化情况^[8-9]。由于微分算子只能反映出遥感图像的灰度变化规则,没有在非边界与非统一背景的情况下对帧特征参数的方差结果进行要求,所以在求解 OTSU 阈值时,还要将帧特征参数在非边界与非统一背景情况下的取值结果考虑在内。

非边界情况下的帧特征参数取值条件:

$$U_1 = \sum_{\epsilon=1}^{+\infty} O_{\epsilon} \dot{R} \quad (3)$$

非统一背景情况下的帧特征参数取值条件:

$$U_2 = \dot{q} \sum_{\epsilon=1}^{+\infty} \left(1 - \frac{\dot{R}}{|R|}\right)^2 \quad (4)$$

其中: ϵ 表示同一遥感图像内的帧特征对象协调参数, \dot{q} 表示基于灰度变化规则的帧特征对象排列系数, \dot{R} 表示遥感图像边缘检测区域内的数据样本取值特征, \bar{R} 表示帧特征数据在遥感图像边缘检测区域内的单位累积量。

联立式 (2) ~ (4), 推导 OTSU 阈值定义式如下:

$$E = \frac{1}{U_1 \times U_2} \sum_{\epsilon=1}^{+\infty} \frac{\sqrt{1 - O^{\epsilon}}}{\varphi \times |\Delta Q|} \quad (5)$$

式中, ΔQ 表示边缘检测区域内遥感图像帧特征数据的取值总量, φ 表示方差统计参数。OTSU 阈值等于零表示实施遥感图像边缘检测的过程中,主机元件可以对帧特征参数进行无差别识别。

1.3 边缘节点追踪参数

节点追踪是一种动态搜索思想,对于遥感图像边缘区域的检测,采用节点追踪的方式对帧特征参量进行动态识别,既可以避免数据样本出现相互覆盖的情况,也能够实现对某一个或某一类样本对象的精准识别^[10-11]。对于边缘节点追踪参数的计算涉及对帧特征参量覆盖率、数据样本利用价值的求解,具体计算式如下:

$$\begin{cases} \gamma = \left[\tilde{A} \left(\frac{1 - \dot{y}}{|\Delta T|} \right) \right]^{-\varphi} \\ W = E \frac{\sqrt{2 \ln(a_1 \cdot a_2 \cdot \dots \cdot a_n)}}{\bar{a}^2} \end{cases} \quad (6)$$

γ 表示帧特征参量覆盖率, W 表示数据样本利用价值, \tilde{A} 表示遥感图像边缘检测中的节点定义参数, \dot{y} 表示遥感图像帧特征对象的类样本归结向量, ΔT 表示帧特征对象的单位追踪时长, φ 表示类样本识别权限, a_1, a_2, \dots, a_n 表示边缘检测区域内 n 个不重合的数据样本对象, \bar{a} 表示数据样本对象的平均取值。

遥感图像边缘检测还要求数据样本取值的唯一性,因此在求解边缘节点追踪参数时,还要求帧特征参量覆盖率、数据样本利用价值的取值必须属于同一个样本区间^[12]。设 λ 表示遥感图像帧特征参量在单位检测区域内的动态匹配系数, s 表示实时追踪向量, D 表示单位时间内的帧特征对象检测总量,联立式 (6), 可将边缘节点追踪参数计算结果表

示为:

$$S = \frac{n - 2\gamma + (\lambda^2 - 1)W}{\sum_{s=1}^{+\infty} n \times |D|^2} \Bigg|_{\substack{\gamma \neq 0 \\ W \neq 0}} \quad (7)$$

为在同一边缘区域内完成对遥感图像帧特征参量的取值, 要求 $\gamma \neq 0, W \neq 0$ 的不等式取值条件同时成立。

2 RBF 神经网络识别模型

2.1 RBF 神经网络机制

RBF 神经网络机制是一个集成的数据处理结构, 能够借助神经网络终端将已输入的遥感图像帧特征样本改写成指令执行文件, 从而得到多样化的动态识别结果, 以便于网络主机在实施边缘检测的过程中, 能够较好解决分辨率超限的问题^[13]。遥感图像分辨率超限是一个普遍存在的问题, 对于网络主机而言, 其在完成边缘检测时, 如果能够利用 RBF 神经网络机制提取大量的帧特征参量, 就可以在长、宽、高 3 个方向上对图像帧特征对象模型进行模拟, 从而在精准识别特征参量的同时, 控制分辨率指标的波动变化行为^[14]。RBF 神经网络机制的具体作用原理如图 1 所示。




图 1 RBF 神经网络机制的作用原理

规定 d_{\min} 表示遥感图像帧特征对象建模参数的最小取值, d_{\max} 表示建模参数的最大取值, 且二者属于遥感图像的另一边缘检测区域, ι 表示图像帧特征参量的神经性表达参数。在上述物理量的支持下, 联立式 (7), 推导 RBF 神经网络机制作用表达式如式 (8) 所示。

$$h = \sqrt{\frac{1}{S} \sum_{\iota=1}^{+\infty} (d_{\max} - d_{\min})^2} \quad (8)$$

神经网络终端不具备过滤数据样本信息的能力, 所以网络主机在录入遥感图像帧特征样本时, 必须过滤数据参量中的不合理信息。

2.2 神经性激活函数

激活函数在改变 RBF 神经网络中遥感图像帧特征参量的数学关系方面起到了关键影响作用。加入激活函数之前, 前一神经网络阶层中遥感图像帧特征参量的取值直接影响后一网络阶层中特征参量的数值表达结果, 所以图像帧特征参量在 RBF 神经网络机制中总是呈现相对混乱的表现状

态^[15-16]。加入激活函数之后, 前一神经网络阶层中遥感图像帧特征参量被激活函数进行了映射定义, 因此后一网络阶层中特征参量指标的取值总是呈现非线性状态, 从某种程度上来说, 神经性激活函数具有非线性表达能力。设 g 表示前一神经网络阶层中遥感图像帧特征参量的函数赋值结果, f 表示后一网络阶层中遥感图像帧特征参量的函数赋值结果, η 表示图像帧特征参量在 RBF 神经网络中的传输效率, κ 表示基于 RBF 神经网络机制的函数激活参数, 联立式 (8), 推导神经性激活函数表达式如下:

$$F = g^2 \cdot \frac{|\eta \cdot f|}{(1 + h^{\kappa})^2} \quad (9)$$

RBF 神经网络识别模型的构建除了影响网络主机对于遥感图像帧特征参量的边缘检测结果, 还决定了样本参数的实际取值结果能否适应帧特征参量的动态识别条件。

3 遥感图像帧特征的动态识别

在边缘检测与 RBF 神经网络模型的作用下, 为实现对遥感图像帧特征的动态识别, 还应根据帧特征分割条件, 确定超像素指标的取值范围, 并联合动态合并条件, 计算并行识别参量的具体数值结果。

3.1 帧特征分割

神经网络主机对于遥感图像帧特征的分割遵循如下处理流程: 帧特征参量在网络体系中保持动态分布的排列形式, 对于 RBF 神经网络模型而言, 这种数据样本分布方式便于边缘检测算法的实施, 能够在保持帧特征参量样本特性的同时, 使网络主机能够对其进行精准识别^[17-18]。为避免分辨率超限问题的发生, 神经网络主机在分割帧特征参量时还要遵循按需提取原则, 且单一识别指令的执行只能得到帧特征参量的预分割处理结果。具体的分割处理执行步骤如图 2 所示。

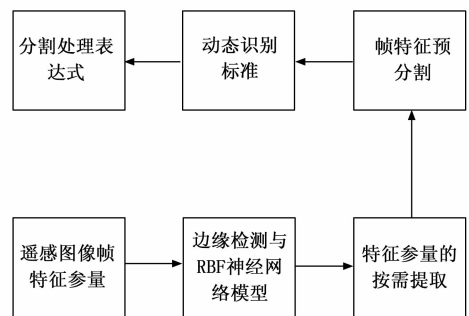


图 2 遥感图像的帧特征分割步骤

联立式 (9) 所示的神经性激活函数, 可将遥感图像的帧特征分割表达式定义为:

$$L = \frac{F^{1/\nu}}{\sum_{j=1}^{+\infty} \vec{j}_1 \cdot \vec{j}_2 \cdot \vec{j}_3} \quad (10)$$

其中: μ 表示遥感图像帧特征参量在 RBF 神经网络中的传输参数, ν 表示帧特征参量的按需调度参数, \vec{j}_1 表示遥感图像帧特征在长方向上的建模向量, \vec{j}_2 表示宽方向上的建模

向量, \vec{j}_3 表示高方向上的建模向量。对遥感图像帧特征进行边缘检测的过程中, RBF 神经网络对于建模向量的提取不设置明确要求, 所以 \vec{j}_1 向量、 \vec{j}_2 向量、 \vec{j}_3 向量的取值存在完全相等的可能。

3.2 超像素指标

超像素指标的求解与聚类思想类似, 都是通过多次堆叠处理的方式, 确定与样本参量最为接近数据指标的取值结果^[19]。对于遥感图像帧特征而言, 在对其进行动态识别的过程中, 只会在长、宽、高 3 个方向上造成分辨率超限的问题, 所以在求解超像素指标时, 也只需要在长、宽、高 3 个方向上对数据样本进行堆叠处理。所谓超像素是指分辨率水平超过遥感图像平均承载能力的像素单位, 对于帧特征参量的识别只有在保证超像素指标处于合理取值范围的情况下, 才有可能获得理想化的识别结果^[20]。设 z 表示像素堆叠参数, k_1 、 k_2 、 k_3 分别表示长、宽、高 3 个方向上的帧特征参量像素取值结果, $\dot{X}_{1 \rightarrow 2}$ 表示长向、宽向之间的像素转换参数, $\dot{X}_{2 \rightarrow 3}$ 表示宽向、高向之间的像素转换参数, $\dot{X}_{3 \rightarrow 1}$ 表示高向、长向之间的像素转换参数, 联立上述物理量, 计算超像素指标表达式如式 (11) 所示。

$$H = \frac{\sum_{z=1}^{+\infty} L \cdot \|k_1^2 + k_2^2 + k_3^2\|}{\sum_{z=1}^{+\infty} |\dot{X}_{1 \rightarrow 2}| \cdot |\dot{X}_{2 \rightarrow 3}| \cdot |\dot{X}_{3 \rightarrow 1}|} \quad (11)$$

由于 RBF 神经网络在识别遥感图像帧特征时, 只在边缘区域内对数据样本进行检测, 所以为避免全局提取事件的发生, 应在求解超像素指标之前, 计算边缘区域内帧特征参量平均值的取值范围。

3.3 动态合并条件

动态合并注重对相似的遥感图像帧特征参量进行处理, 可以根据超像素指标的取值范围, 判断网络主机对遥感图像的边缘检测能力, 从而在保障 RBF 神经网络运行能力的同时, 将多个相似的帧特征区域合并起来, 以确保动态识别指令的运行结果能够符合实际应用需求^[21-22]。所谓动态合并就是指在合并遥感图像帧特征参量的过程中, 网络主机对于数据样本的提取始终处于动态表现状态, 且由于 RBF 神经网络对帧特征参量的存储能力有限, 遥感图像边缘检测区域的取值不宜过大, 但又必须包含多个完整的帧特征参量样本。设 μ 表示动态化识别参数, 且 $\mu > 1$ 的不等式取值条件恒成立, \tilde{C} 表示 RBF 神经网络单位检测区域内帧特征参数的取值向量, ω 表示数据样本的实时合并参数, \tilde{B} 表示基于边缘检测算法的数据样本识别特征, V' 表示基于超像素指标的帧特征参量融合系数。在上述物理量的支持下, 联立式 (11), 推导动态合并条件表达式为:

$$v = \frac{H}{(\mu-1)\sqrt{\omega}|\tilde{C}|^2 - V'\tilde{B}} \quad (12)$$

为避免遥感图像帧特征出现重叠合并的情况, 推导推导动态合并条件表达式时, 要求 $\omega \neq V'$ 、 $\tilde{C} \neq \tilde{B}$ 的不等式取值条件必须同时成立。

3.4 并行识别参量

并行识别参量是具有双向作用能力的参数指标, 既可以促进网络主机对遥感图像帧特征参量的快速识别, 也可以在数据样本频繁重复的情况下, 降低网络主机对遥感图像帧特征参量的识别速率, 从而使得 RBF 神经网络体系在对遥感图像进行边缘检测的过程中, 不会出现数据样本错误匹配或是差异化识别的情况^[23-24]。选取 G_1 (长向数据样本)、 G_2 (宽向数据样本)、 G_3 (高向数据样本) 3 个互不相等也不为零的帧特征参量复原指标, \bar{l} 表示 RBF 神经网络面向遥感图像帧特征参量的统一识别参数, θ 表示无差向量, 联立式 (12), 可将并行识别参量求解结果表示为:

$$m = \theta \left| \frac{v}{\bar{l} \times (G_1 + G_2 + G_3)} \right|_{G_1 \neq G_2 \neq G_3 \neq 0} \quad (13)$$

RBF 神经网络对于遥感图像帧特征参量的边缘检测, 不会对数据样本进行重复取样, 因此网络主机运行所得到的帧特征参量动态识别结果具有唯一性。

4 实例分析

4.1 实验流程

为验证上文所设计识别方法的应用能力, 设计如下对比实验。

1) 在图 1 所示遥感图像中, 提取一个面积为 $3\,000\ \mu\text{m} \times 3\,000\ \mu\text{m}$ 的像素区域作为实验用帧特征样本参量;

2) 利用基于边缘检测及 RBF 神经网络的遥感图像帧特征动态识别技术, 对所选实验区域内的帧特征样本进行识别, 所得实验结果记为实验组变量;

3) 利用少样本条件下基于生成对抗网络的遥感图像数据增强处理方法, 对所选实验区域内的帧特征样本进行识别, 所得实验结果记为 A 对照组变量;

4) 利用基于偏好型支持向量机的遥感图像云检测技术对所选实验区域内的帧特征样本进行识别, 所得实验结果记为 B 对照组变量;

5) 统计所得变量数据, 总结实验规律;

完成像素区域提取后, 应对其进行无误差复制, 以确保实验组、对照组所需识别的帧特征样本参量保持一致。

4.2 参数描述

分辨率超限是影响网络主机对于遥感图像识别能力的主要因素。在既定像素区域内, 主机元件分别从长、宽、高 3 个方向对遥感图像进行识别, 且 3 个方向上对于帧特征对象的识别精度都会影响分辨率超限问题的表现程度。由于分辨率超限是一种普遍存在的图像识别问题, 所以只有在识别精度保持为 100% 的情况下 (完全精准识别), 才能够避免该问题的出现。

图 4 反映了本次实验过程中所定义的坐标轴方向及长、宽、高 3 个方向上对于帧特征对象的选取。

由于所选像素区域为正方形, 且帧特征对象保持均匀分布状态, 所以在识别过程中, 每一方向上帧特征对象的取样长度都完全相等。



图 3 遥感图像的帧特征样本提取

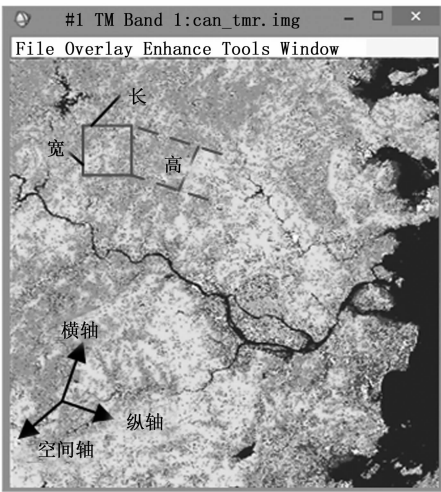


图 4 识别方向定义

4.3 数据解析

每隔 500 μm 设置一个取样点, 在包含两端零点的情况下, 每一方向上设置 7 个取样点。由于实验过程中不会出现帧特征参量相互覆盖的情况, 所以只需确定每一取样点处主机元件对于帧特征参量的识别位置是否与其真实位置保持一致, 就可以判断出所选用方法对遥感图像帧特征参量的识别能力。

表 1 记录了主机元件对帧特征参量的具体识别结果。

分析表 1 可知, 在整个实验过程中, 实验组方法作用下, 长、宽、高 3 个方向上遥感图像帧特征参量识别结果均与真实情况保持一致; A 对照组方法作用下, 第 1、第 2 号取样点在长、宽、高 3 个方向上的遥感图像帧特征参量识别结果与真实情况保持一致, 从第 3 个取样点开始, 识别结果与真实情况出现了偏差; B 对照组方法作用下, 第 1、第 2、第 3 号取样点在长、宽、高 3 个方向上的遥感图像帧特征参量识别结果与真实情况保持一致, 从第 4 个取样点开始, 识别结果与真实情况出现了偏差。

表 1 遥感图像帧特征参量识别结果(单位: μm)

取样点		1	2	3	4	5	6	7
真实情况	长	0	50	100	150	200	250	300
	宽	0	50	100	150	200	250	300
	高	0	50	100	150	200	250	300
实验组	长	0	50	100	150	200	250	300
	宽	0	50	100	150	200	250	300
	高	0	50	100	150	200	250	300
A 对照组	长	0	50	100	147	202	251	299
	宽	0	50	98	145	200	246	290
	高	0	50	99	145	196	244	300
B 对照组	长	0	50	100	148	203	252	300
	宽	0	50	100	148	201	255	300
	高	0	50	100	149	205	253	298

由于本次实验所选像素区域面积有限, 所以在第 7 个取样点处, 实验识别结果刚好等于或大于真实情况, 识别结果都会与真实情况相等, 因此第 7 个取样点处识别结果的参考价值相对较小。

综上所述: 少样本条件下基于生成对抗网络的遥感图像数据增强处理方法、基于偏好型支持向量机的遥感图像云检测技术的应用, 并不能保证长、宽、高 3 个方向的遥感图像识别结果均与真实情况保持一致, 故而对于分辨率超限问题的解决能力也就相对有限; 基于边缘检测及 RBF 神经网络的遥感图像帧特征动态识别技术的应用, 在长、宽、高 3 个方向上都可以实现对遥感图像的精准识别, 这就表示该方法能够有效解决分辨率超限问题, 符合精准识别遥感图像特征的实际应用需求。

5 结束语

遥感图像帧特征动态识别技术对于数据样本参量的识别借助 RBF 神经网络, 并可以根据边缘检测结果, 对微分算子与 OTSU 阈值进行计算, 由于神经性激活函数可以同时约束帧特征分割表达式与超像素指标求解结果, 所以边缘节点追踪参数始终与并行识别参量保持数值匹配关系。相较于其他类型的识别应用技术, 这种新型算法的应用, 在长、宽、高 3 个方向上都实现了对遥感图像帧特征对象的 100% 精准识别, 分辨率超限问题能够得到较好解决, 在实用性方面具有突出作用价值。

参考文献:

[1] 李锦鹏, 熊显名, 曾启林, 等. 基于三次 B 样条小波变换和 Franklin 矩亚像素级图像边缘检测算法 [J]. 红外技术, 2022, 44 (3): 255-261.

[2] 张 爽, 陈西宏, 刘 强, 等. 耦合 PSO 与扩展 RBF 神经网络估计 NWM 模型 ZTD 计算精度 [J]. 测绘学报, 2022, 51 (9): 1911-1919.

[3] 姜雨辰, 朱 斌. 少样本条件下基于生成对抗网络的遥感图像数据增强 [J]. 激光与光电子学进展, 2021, 58 (8): 238-244.

- [4] 杜家昊, 周 晴, 赵文杰. 基于偏好型支持向量机的遥感图像云检测技术 [J]. 计算机工程与设计, 2022, 43 (5): 1404-1411.
- [5] 左延红, 左承基, 袁 彬, 等. 基于分数阶微分算子的集成制造系统移动设备检测数据融合技术 [J]. 传感技术学报, 2022, 35 (5): 587-594.
- [6] 江卫华, 董 倩. Conformable 分数阶微分方程三点共振边值问题解的存在性 [J]. 吉林大学学报 (理学版), 2021, 59 (4): 821-827.
- [7] 黄翠玲, 孔韦韦, 李 萌, 等. 一种基于 Levy-人工蜂群的三维 Otsu 阈值分割算法 [J]. 电讯技术, 2021, 61 (3): 263-268.
- [8] 姜联堂, 何慧玲. 基于图像灰度变换的 OTSU 阈值优化算法 [J]. 中南民族大学学报 (自然科学版), 2021, 40 (3): 325-330.
- [9] 胡 畔, 聂祺昕, 刘晓强, 等. 基于离散域采样数据模型的电力移动终端边缘节点数据采集系统设计 [J]. 中国测试, 2022, 48 (8): 144-149.
- [10] 李 宁, 霍 兵, 宋瑞良, 等. 多 PAN 太赫兹无线个域网边缘节点信息高效报告方法 [J]. 系统工程与电子技术, 2022, 44 (5): 1709-1716.
- [11] 张慧颖, 于海越, 王 凯, 等. 基于 KPCA-K-means++ 和 GA-LMS 模型的改进 RBF 神经网络室内可见光定位 [J]. 光学学报, 2021, 41 (19): 72-81.
- [12] 刘 凌, 李志成, 张 莹. 面向双关节机械臂的参数可调 RBF 神经网络控制 [J]. 西安交通大学学报, 2021, 55 (4): 1-7.
- [13] 安凤平. 优化非线性激活函数—全局卷积神经网络的物体识别算法 [J]. 小型微型计算机系统, 2021, 42 (2): 393-398.
- [14] 李 军, 李 明, 曾 蒸, 等. 基于改进激活函数和学习率的双向 LSTM 研究 [J]. 重庆师范大学学报 (自然科学版), 2021, 38 (2): 70-76.
- [15] 王雪松, 荣小龙, 程玉虎, 等. 基于自适应多尺度图卷积网络的多标签图像识别 [J]. 控制与决策, 2022, 37 (7): 1737-1744.
- [16] 陈飞玥, 朱玉莲, 田甲略, 等. 融合图嵌入的光滑主成分分析网络图像识别算法 [J]. 国防科技大学学报, 2022, 44 (3): 16-22.
- [17] 朱方瑞, 张 力, 付彦伟, 等. 基于自监督学习方法的半监督视频目标分割研究 [J]. 复旦学报 (自然科学版), 2022, 61 (2): 188-195, 204.
- [18] 高 翔, 李春庚, 安居白. 基于注意力和多标签分类的图像实时语义分割 [J]. 计算机辅助设计与图形学学报, 2021, 33 (1): 59-67.
- [19] 任伟建, 刘泽宇, 霍凤财, 等. 一种改进的多光谱遥感图像超像素分割算法 [J]. 吉林大学学报 (理学版), 2022, 60 (2): 351-360.
- [20] 陈孝如. 基于改进 AlexNet 和线性迭代聚类的超像素分割方法 [J]. 大连工业大学学报, 2022, 41 (4): 298-305.
- [21] 李克文, 马祥博, 候文艳. 带有自适应合并策略和导向算子的增强型烟花算法 [J]. 计算机应用, 2021, 41 (1): 81-86.
- [22] 卢瑞涛, 申 通, 杨小冈, 等. 高动态条件下增量惯导信息辅助的空地红外弱小移动目标检测算法 (特邀) [J]. 红外与激光工程, 2022, 51 (4): 50-60.
- [23] 田乔鑫, 孔韦韦, 滕金保, 等. 基于并行混合网络与注意力机制的文本情感分析模型 [J]. 计算机工程, 2022, 48 (8): 266-273.
- [24] 马 洋, 张继福, 蔡江辉, 等. 基于稀疏子空间的类星体光谱异常特征并行提取与分析 [J]. 光谱学与光谱分析, 2021, 41 (4): 1086-1091.
- [10] CHARTUNI A, MARQUEZ J. Multi-Classifer of DDos Attacks in Computer Networks Built on Neural Networks [J]. Applied Sciences, 2021, 11 (22): 10609.
- [11] SHARAFALDIN I, LASHKARI A H, GHORBANI A A. Toward generating a new intrusion detection dataset and intrusion traffic characterization [J]. ICISSp, 2018, 1: 108-116.
- [12] TAVALLAEE M, BAGHERI E, LU W, et al. A detailed analysis of the KDD CUP 99 data set [C] // 2009 IEEE symposium on computational intelligence for security and defense applications. Ieee, 2009: 1-6.
- [13] 周慧怡, 何丽华, 劳传媛, 等. 基于一维卷积神经网络的加密单数据包分类 [J]. 桂林航天工业学院学报, 2022, 27 (1): 1-8.
- [14] LASHKARI A H, DRAPER-GIL G, MAMUN M S I, et al. Characterization of tor traffic using time based features [C] // ICISSp, 2017: 253-262.
- [15] DRAPER-GIL G, LASHKARI A H, MAMUN M S I, et al. Characterization of encrypted and vpn traffic using time-related [C] // Proceedings of the 2nd international conference on information systems security and privacy (ICISSP), 2016: 407-414.
- [16] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C] // International conference on machine learning. PMLR, 2015: 448-456.
- [17] 谢玉惠, 肖桂荣. 融合注意力机制的多通道 CNNs-BiLSTM 情感极性分析方法 [J/OL]. 小型微型计算机系统: 1-7 [2022-10-24]. DOI: 10. 20009/j. cnki. 21-1106/TP. 2021-0796.
- [18] SU T, SUN H, ZHU J, et al. BAT: Deep learning methods on network intrusion detection using NSL-KDD dataset [J]. IEEE Access, 2020, 8: 29575-29585.
- [19] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique [J]. Journal of artificial intelligence research, 2002, 16: 321-357.
- [20] YANG Z M, QIAO L Y, PENG X Y. Research on data mining method for imbalanced dataset based on improved SMOTE [J]. Acta Electronica Sinica, 2007, 35 (B12): 22-26.
- [21] 韩 煜, 张义民, 张 凯, 等. Adam 优化 CNN 的滚动轴承多故障耦合诊断方法研究 [J]. 机械设计与制造, 2022 (8): 169-172.