

# 基于自编码神经网络的航空物探遥感数据分类方法研究

于 刘

(上海航空工业(集团)有限公司, 上海 201206)

**摘要:** 航空物探遥感数据的采集过程中受到电磁波辐射等外界因素的影响, 导致航空物探遥感数据分类准确率较低, 为此提出基于自编码神经网络的航空物探遥感数据分类方法; 根据航空物探对象的基本特征, 设置遥感数据的分类标准; 通过辐射校正、几何纠正、噪声消除等步骤, 完成航空物探遥感数据的预处理; 构建自编码神经网络, 利用自编码神经网络算法, 从光谱、形状、纹理等方面提取遥感数据特征, 通过特征匹配确定航空物探遥感数据的所属类型; 通过分类性能测试实验得出结论: 所提方法的全局遥感数据分类成功率和错误率的平均值分别为 99.8% 和 0.6%, 局部遥感数据分类的成功率和错误率的平均值分别为 99.8% 和 0.3%, 即所提方法在分类性能方面具有明显优势。

**关键词:** 自编码神经网络; 航空数据; 物探遥感数据; 数据分类

## Research on Classification Method of Airborne Geophysical Remote Sensing Data Based on Self-Coding Neural Network

YU Liu

(Shanghai Aviation Industrial (Group) Co., Ltd., Shanghai 201206, China)

**Abstract:** The collection process of airborne geophysical remote sensing data is affected by external factors such as electromagnetic wave radiation, resulting in low classification accuracy of airborne geophysical remote sensing data. Therefore, a classification method for airborne geophysical remote sensing data based on self-coding neural network is proposed. The classification standards for remote sensing data are set according to the basic characteristics of aerial geophysical exploration objects, The preprocessing of airborne geophysical remote sensing data is completed through the steps such as the radiation correction, geometric correction, and noise elimination, and the self-coding neural network is built, the self-coding neural network algorithms are used to extract remote sensing data features from spectrum, shape, texture, and other aspects, and the type of aerial geophysical remote sensing data is determined through feature matching. Through classification performance testing experiments, it is concluded that the average success and error rates of the proposed method for global remote sensing data classification are 99.8% and 0.6%, respectively. The average success and error rates for local remote sensing data classification are 99.8% and 0.3%, respectively, indicating that the proposed method has a significant advantage in classification performance.

**Keywords:** self-coding neural network; aviation data; geophysical remote sensing data; data classification

## 0 引言

航空物探即航空地球物理探测, 是利用航空器搭载的物探设备对地下结构进行探测的一种技术。通过测量地下反射波或传播路径的变化, 可以获取地下介质的信息。相比于传统的地面物探方法, 航空物探可以克服地理、地形、气候等方面的不利因素; 快速、高效、省时、能在较短时间内获取大范围的勘探数据; 在航空物探过程中, 通常以遥感作为技术手段<sup>[1]</sup>, 即利用各种飞机、飞艇、气球等作为传感载体, 通过遥感技术对目标的电磁波辐射、反射特性进行遥感探测。航空物探具有覆盖范围广、速度快、数

据精度高等优点, 因此在勘探、地质灾害预警等领域得到了广泛应用。

航空物探遥感数据记录了地球上物体在观测期间的电磁辐射特性, 这是最直接反映地球物象信息的方法, 并且能够根据光度、像元的高度和空间的变化, 反映出各种属性的地物目标和它们的分布情况。在遥感数据中, 同一类型的地物, 其频谱、空间信息特性应当是一致的, 但在同一条件下, 其频谱、空间信息的特点也是不同的<sup>[2]</sup>。遥感数据分类就是根据地物光谱能量与空间结构特性的差别, 通过计算机对各种类型的地物进行分析、处理, 将其分成相应的类型, 并从中抽取相关的主题信息。文献 [3] 提

收稿日期: 2023-04-19; 修回日期: 2023-05-29。

作者简介: 于 刘(1986-), 男, 大学本科, 工程师。

引用格式: 于 刘. 基于自编码神经网络的航空物探遥感数据分类方法研究[J]. 计算机测量与控制, 2024, 32(3): 256-258.

出的基于深度传递迁移学习的遥感影像分类方法以 ImageNet 预训练权重为源域、待分类遥感影像为目标域进行迁移学习,通过对目标域数据集的迁移学习、训练,得出分类结果。文献 [4] 中提出了基于对比学习方法的遥感影像分类方法,该方法解决了遥感数据特征提取与分类时标注数据不足的问题,而文献 [5] 提出的基于改进光谱角法的遥感分类方法以红树林作为分类对象,利用影像端元光谱进行地物分类。上述现有的遥感数据分类方法在处理航空物探遥感数据过程中存在分类精度低的问题,为此引入自编码神经网络算法。

神经网络是模拟动物神经网络的行为特点,对分布的平行信息进行处理的一种算法。该网络依赖于系统自身的复杂性,通过调节大量的节点间的联系来实现对数据的处理,同时还具备自学习和自适应的功能。而自编码神经网络算法是神经网络的一种,使用反向传播算法来训练网络使得输出等于输入。将自编码神经网络算法应用到航空物探遥感数据分类方法的优化设计工作中,以期能够提升遥感数据的分类精度。

### 1 航空物探遥感数据分类方法设计

所设计的航空物探遥感数据分类方法以划分数据中的地物类型为目的,基于自编码神经网络算法提取航空物探遥感数据中的基本特征,并通过提取特征与设置标准特征之间的匹配,最终确定当前航空物探遥感数据的所属类型。由于航空物探遥感数据常以图像的形式进行采集与分析,此次优化设计的分类方法以遥感图像作为分类对象。

#### 1.1 设置航空物探遥感数据分类标准

根据航空地球物理探测的遥感对象,可以将遥感数据内容分为绿地、湿地、岩石、山体等多种类型,不同地物间光谱差异较为明显,以此作为航空物探遥感数据的分类标准。从光谱、边缘形状、纹理等方面设置航空物探遥感数据的分类标准特征,以绿地遥感数据为例,假设其标准特征分量分别表示为  $\tau_{\text{spectrum}}^{\text{greenland}}$ 、 $\tau_{\text{edge}}^{\text{greenland}}$  和  $\tau_{\text{texture}}^{\text{greenland}}$ ,则绿地遥感数据标准特征可以表示为:

$$\tau_{\text{greenland}} = \omega_1 \tau_{\text{spectrum}}^{\text{greenland}} + \omega_2 \tau_{\text{edge}}^{\text{greenland}} + \omega_3 \tau_{\text{texture}}^{\text{greenland}} \quad (1)$$

式中,  $\omega_1$ 、 $\omega_2$  和  $\omega_3$  分别为光谱、边缘形状、纹理特征分量的对应权重<sup>[6]</sup>。同理可以得出其他航空物探遥感数据类型的标准特征设置结果,将第  $i$  类遥感数据类型的划分标准标记为  $\tau_{\text{standard}}(i)$ 。

#### 1.2 航空物探遥感数据预处理

航空物探遥感数据的清晰度质量直接决定了遥感数据的分类性能,为此需要通过预处理提升初始遥感数据的质量。

##### 1.2.1 辐射校正

辐射校正的目的是消除图像中因大气散射引起的辐射照度,并通过绝对辐射修正方法进行修正,在修正时必须获得辐射亮度、反射率等相关参数,并进行相应的调整,以使图像数据处理的标准值得到修正,这样就可以减少某

些干扰因素对图像分类的影响<sup>[7]</sup>。在航空物探遥感数据生成过程中,电磁波要经过大气的传播,由于电磁波与大气层的交互作用,会导致一部分电磁波被大气层所吸收。通过大气层到达地面的辐射照度可以表示为:

$$L = \mu_{\text{reflex}} [Q_w(\lambda) \cos \theta_{\text{zenith}} \exp(-H\theta_{\text{zenith}}) + Q_m] \quad (2)$$

式中,  $\mu_{\text{reflex}}$  为地物表面反射率,  $Q_w(\lambda)$  和  $Q_m$  为波长为  $\lambda$  的太阳光谱的太阳光谱辐照度和大气光漫射到地表的光谱辐照度,  $\theta_{\text{zenith}}$  为太阳天顶角,  $H$  表示的是波长的大气光学厚度<sup>[8]</sup>。同理可以得出遥感数据辐射校正的其他参数,对相关参数进行逆运算,并叠加到初始航空物探遥感数据中,完成初始遥感数据的辐射校正操作。

##### 1.2.2 几何纠正

遥感数据的几何校正是将遥感图像的几何位置与一定的地理坐标相一致,从而达到与地图匹配的目的。在进行遥感影像几何校正时,首先要考虑的是空间位置问题,即利用地面控制点的数据,将原始遥感影像的几何失真过程进行数值模拟,再采用重采样技术,在原有的坐标空间和基准坐标空间中建立一定的对应关系<sup>[9]</sup>。航空物探遥感数据的几何纠正可以分为平移、旋转等步骤,其中平移纠正处理过程可以表示为:

$$\begin{cases} x_{\text{correct}} = x + \Delta x \\ y_{\text{correct}} = y + \Delta y \end{cases} \quad (3)$$

式中,  $\Delta x$  和  $\Delta y$  分别为水平和竖直两个方向上的平移量,  $(x, y)$  和  $(x_{\text{correct}}, y_{\text{correct}})$  对应的是几何纠正前后的航空物探位置遥感数据。同理可以得出遥感数据的旋转纠正处理结果,从而完成几何纠正工作。

##### 1.2.3 噪声消除

采用连续小波变换的方式消除航空物探遥感数据中存在的噪声元素,处理过程如下:

$$G_F(a, b) = \int_R F(x) \cdot |a|^{-\alpha} \varphi\left(\frac{x-b}{a}\right) dx \quad (4)$$

式中,  $a$  和  $b$  均为随机数,  $F(x)$  为初始输入的航空物探遥感数据,  $R$  为遥感数据量,  $\varphi(\cdot)$  为小波函数  $\psi(\cdot)$  的复共轭。将航空物探遥感数据代入到公式 (4) 中,实现遥感数据中噪声元素的消除。

##### 1.2.4 波段选择与组合

为了使图像更好地满足分类要求,同时尽量减少对图像的影响,采用最佳指数因子分析方法,对遥感数据进行多频谱的优化组合,以选出最适合的频谱特征子集。这种方法的基本思路是:随着遥感数据的标准偏差越大,信息越多,信息的相关性越高,信息的冗余性越低。波段最佳指数因子的计算公式如下:

$$\gamma = \frac{\sum_{i=1}^3 \sigma_i}{\sum_{i=1}^3 \sum_{j=i+1}^3 |s_{ij}|} \quad (5)$$

式中,  $\sigma_i$  和  $s_{ij}$  分别表示第  $i$  波段的标准差及其与波段  $j$  之间的相关系数,其中变量  $s_{ij}$  的计算公式为:

$$s_{ij} = \frac{\lambda_i \cdot \lambda_j}{\|\lambda_i\| \cdot \|\lambda_j\|} \quad (6)$$

式中， $\lambda_i$  和  $\lambda_j$  为两波段的波长值。将公式 (6) 的计算结果代入到公式 (5) 中，确定波段的最佳组合指数因子，选择航空物探遥感数据中合适的波段，并按照指数计算结果完成组合工作。

### 1.2.5 航空物探遥感影像分割

针对航空物探遥感影像数据，采用 SLIC 分割的方式进行分割处理，具体的处理过程如图 1 所示。

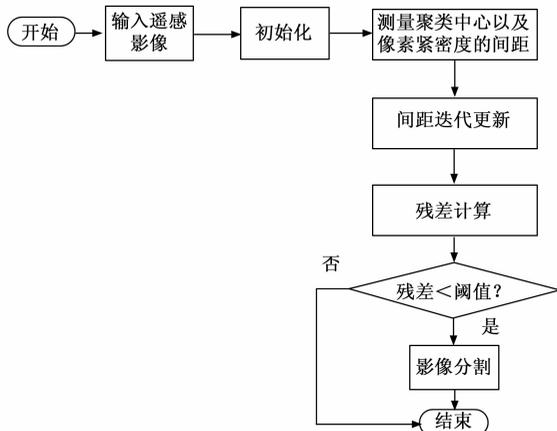


图 1 航空物探遥感影像分割流程图

按照图 1 表示流程，对航空物探遥感影像中所有像素点的聚类中心以及像素紧密度的间距进行测量，测量结果为：

$$D = \sqrt{d_{\text{colour}}^2 + \left(\frac{d_{\text{space}}}{e}\right)^2 \delta^2} \quad (7)$$

式中，变量  $d_{\text{colour}}$  和  $d_{\text{space}}$  分别为颜色距离和空间距离， $\delta$  为空间邻近性和颜色的相对重要性<sup>[10]</sup>。在此基础上，根据不同位置上距离的变化情况，对  $D$  进行迭代和更新，利用公式 (8) 得出残差的计算结果。

$$\epsilon = d_{\text{colour}} - d_{\text{space}} \quad (8)$$

将公式 (8) 的计算结果与设置的残差阈值进行比对，确定该位置是否需要分割，反复执行上述操作，完成对航空物探遥感影像数据的分割结果。

### 1.3 构建自编码神经网络

自编码神经网络中的自编码器由编码器和解码器组成，其基本结构如图 2 所示。

自编码器的工作原理是：把输入信号转换成编码信号  $Y$ ，译码器把编码信号  $Y$  转换成重建信号，同时，自编码器的功能是使输入尽可能恢复输入，编码信号  $y$  就是从自编码器中抽取的特征<sup>[11]</sup>。自编码器中编码和解码过程可以量化表示为：

$$\begin{cases} y_{\text{encoded}} = f_{\text{encoded}}(W_1 x + \beta_1) \\ y_{\text{decipher}} = f_{\text{decipher}}(W_2 x + \beta_1) \end{cases} \quad (9)$$

式中， $f_{\text{encoded}}()$  和  $f_{\text{decipher}}()$  分别为编码器和解码器中的激活函数， $W_1$ 、 $W_2$ 、 $\beta_1$  和  $\beta_1$  对应的是编码器和解码器内部的连

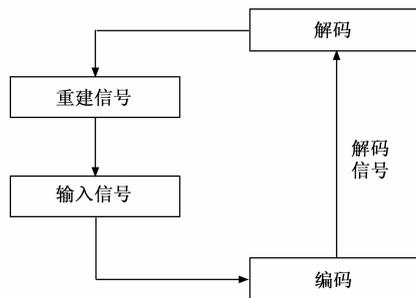


图 2 自编码器结构示意图

接权值矩阵和偏置值<sup>[12]</sup>。构建自编码器的代价函数可以表示为：

$$f_{\text{price}}(W, \beta) = \beta \sum \psi(\delta \|\delta\|) \quad (10)$$

式中， $\psi(\delta \|\delta\|)$  为惩罚项， $\delta$  和  $\delta^-$  对应的是稀疏常数和平均激活量。以构建的自编码器为基础，构建相应的自编码神经网络，具体结构如图 3 所示。

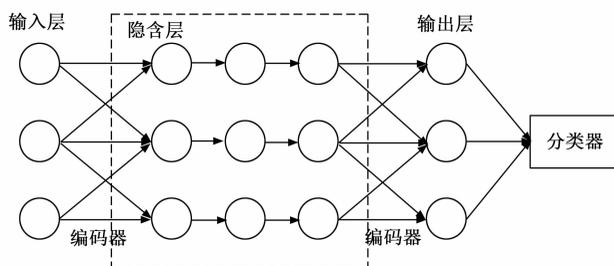


图 3 自编码神经网络结构图

将各隐层依次连接到自编码器中，从图 3 中可以看出构建的自编码神经网络共六层，能够更好地提取特征和节约时间。

### 1.4 利用自编码神经网络算法提取遥感数据特征

利用构建的自编码神经网络将处理完成的航空物探遥感数据输入其中，通过迭代训练得出遥感数据特征的提取结果<sup>[13]</sup>。自编码神经网络的训练包括正向传播和反向传播两个过程，将上述两个过程重复进行，以使误差达到最小或达到规定的容许误差。自编码神经网络的基本训练流程如图 4 所示。

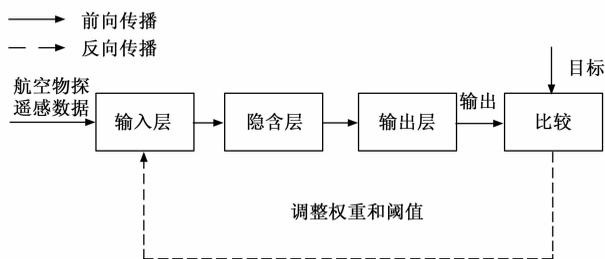


图 4 自编码神经网络训练原理图

定义输入自编码神经网络中的初始航空物探遥感数据为  $X_{\text{remote sense}}$ ，那么隐含层的输入值和输出值可以表示为：

$$\begin{cases} y_{\text{implication-in}} = \sum \bar{\omega}_{\text{implication}} X_{\text{remote sense}} \\ y_{\text{implication-out}} = f_{\text{implication}}(y_{\text{implication-in}} - \zeta_i) \end{cases} \quad (11)$$

式中,  $\bar{\omega}_{\text{implication}}$  和  $f_{\text{implication}}()$  分别为隐含层权值和激活函数,  $\zeta_i$  为隐含层节点阈值, 其中  $f_{\text{implication}}()$  的函数表达式为:

$$f_{\text{implication}}(x) = \frac{1}{1 + e^{-x}} \quad (12)$$

另外自编码神经网络中输出层节点的输入和输出结果可以表示为:

$$\begin{cases} y_{\text{out-in}} = \sum \bar{\omega}_{\text{out}} y_{\text{implication-out}} \\ y_{\text{out-out}} = f_{\text{out}}(y_{\text{out-in}} - \zeta_o) \end{cases} \quad (13)$$

式中, 变量  $\bar{\omega}_{\text{out}}$ 、 $f_{\text{out}}()$  和  $\zeta_o$  分别为输出层节点的权值、激活函数和阈值<sup>[14]</sup>。在这个过程中, 从输入层到输出层的信息通过分层的方式传输。在网络训练结束后, 这个过程也可以正常地进行分类。在反向传播过程中, 自编码神经网络的误差目标函数可以表示为:

$$\epsilon_{\text{err}} = \frac{1}{2} \sum_{i=1}^{n_i} (y_{\text{out-out}} - y_{\text{out-expect}})^2 \quad (14)$$

式中,  $y_{\text{out-expect}}$  为自编码神经网络的预期输出值。若公式(14)的计算结果不为 0, 则需要利用公式(15)对自编码神经网络中的相关参数进行更新。

$$\bar{\omega}_{\text{new}} = \bar{\omega} - \alpha \frac{\partial \text{cost}(x)}{\partial \bar{\omega}} \quad (15)$$

式中  $\alpha$  为学习率。重复上述操作, 当计算得出  $\epsilon_{\text{err}}$  取值为 0 时, 反向传播进程结束, 输出结果即为特征提取结果<sup>[15]</sup>。按照上述流程, 从光谱、形状、纹理、植被指数等方面, 提取航空物探遥感数据特征。航空物探遥感数据的光谱特征信息的提取与对象像元的灰度信息相关联, 反映了实际目标地物的物理光学信息属性, 光谱特征的提取结果如下:

$$\begin{cases} \tau_{g-\chi} = \frac{1}{n_{\text{pixel}} - 1} \sum_{i=1}^{n_{\text{pixel}}} (r_i - \tau_{\sigma})^2 \\ \tau_{g-b} = \frac{1}{n_{\text{pixel}}} \sum_{i=1}^{n_{\text{pixel}}} \tau_{\sigma} \end{cases} \quad (16)$$

式中, 变量  $n_{\text{pixel}}$  为遥感数据中的像素数量,  $r_i$  和  $\tau_{\sigma}$  为像素点  $i$  的像素值和均值, 最终的特征提取结果  $\tau_{g-\chi}$  和  $\tau_{g-b}$  分别表示遥感数据的光谱方差和亮度,  $\tau_{g-\chi}$  用来描述遥感数据的离散情况,  $\tau_{g-b}$  反映的是遥感数据的亮度特征信息<sup>[16]</sup>。此外遥感数据纹理特征反映了图像灰度信息在空间上的相互关系, 是区别不同地物目标的一个重要宏观指标, 能够有效地克服“同物异谱”的问题。航空物探遥感数据纹理特征的提取结果为:

$$\tau_{\text{contrast ratio}} = \sum_i \sum_j (i-j)^2 P(i, j) \quad (17)$$

式中,  $P(i, j)$  为遥感数据中任意两个样本的联合概率<sup>[17]</sup>。同理可以得出形状以及植被指数等其他特征的提取结果, 并对提取的所有特征分量进行融合处理, 并对融合特征进行逐一标记<sup>[18]</sup>。

### 1.5 实现航空物探遥感数据分类

以自编码神经网络提取的遥感数据特征为处理对象, 采用特征匹配的方式确定当前航空物探遥感数据的所属类型<sup>[19-20]</sup>, 具体的匹配过程如下:

$$\varphi = \sqrt{\sum_{i=1}^{n_{\text{type}}} (\tau_{\text{draw}} - \tau_{\text{standard}}(i))^2} \quad (18)$$

式中,  $\tau_{\text{draw}}$  为提取的遥感数据特征,  $n_{\text{type}}$  为设置的航空物探遥感数据类型数量。若公式(18)的计算结果高于阈值  $\varphi_0$ , 说明当前航空物探遥感数据类型与  $\tau_{\text{standard}}(i)$  对应类型一致, 否则需要进行下一类型的匹配, 直至确定数据类型为止。

## 2 分类性能实验分析

为了验证优化设计基于自编码神经网络的航空物探遥感数据分类方法的分类性能, 针对全局遥感和局部遥感两种数据, 设计分类性能实验, 根据遥感数据的准备情况确定其所属类型, 以此作为判断设计方法是否分类正确的评价标准, 通过多数据的统计与对比, 证明所提方法在分类性能方面的优势。

### 2.1 准备航空物探遥感数据样本

此次实验选择的待分类的航空物探遥感数据均为现场采集数据, 可以通过对数据采样对象的选择, 确定生成数据样本的所属类型。

#### 2.1.1 航空物探遥感区域概况

实验以上海航空工业(集团)有限公司作为研究背景, 因此选择上海周边区域作为航空物探对象。上海由 16 个市辖区组成, 总面积约为 6 300 km<sup>2</sup>, 行政区具体包括黄浦区、浦东新区、徐汇区等, 区域内部包括 3 个岛屿、12 座山峰, 山峰的平均海拔高度为 99 米, 满足航空物探遥感数据的采集条件。

#### 2.1.2 航空物探遥感设备飞行准备与实施

航空物探遥感分类数据主要利用型号为 H501A 的飞行器及其内置的相机进行采集, 在实验之前需要对相关的遥感采集设备进行准备与调试, 保证飞行器能够按照既定路线飞行, 并获得预期的物探遥感数据。设定航空物探遥感设备飞行区域为东经 120°52' ~ 122°12', 北纬 30°40' ~ 31°53', 根据遥感数据的分辨率要求, 确定遥感设备的飞行高度, 而在局部遥感数据采集任务中设备的飞行高度为 300 m。在考虑研究区域地理位置、天气条件的情况下, 确定航空物探遥感数据的采集时间, 向预定飞行区域所属军区提出空域请求, 经所属军区批准后, 应提出停放、飞行和试验操作员进出机场的请求, 若试验飞行器未停放在拟停放机场, 则应将飞行器调到拟停放机场。根据研究区域的分布情况生成飞行航线, 在飞行器内部控制器与通信系统的协同作用下, 执行飞行任务。

#### 2.1.3 采集航空物探遥感数据

以航空物探遥感设备为硬件支持, 采用实时采集的方式, 得出航空物探遥感样本数据。全局遥感数据的采集波

段数为 128, 分辨率为 200 ppi, 扫描宽度为 512 像元, 瞬时视场和总视场分别为 5° 和 90°, 而在局部遥感数据的采集过程中波段数参数不变, 分辨率为 160 ppi, 扫描宽度设置为 256 像元, 瞬时视场和总视场调整至 3° 和 60°。航空物探遥感数据的采集频率均为 50 Hz, 数据编码参数为 12 bit, 最终以遥感影像的方式输出。

#### 2.1.4 数据分组与导入

根据航空物探对象, 可以将采集的遥感数据划分为植被、水体、建筑、云顶、道路等类型, 采用一一对应的方式标记所有遥感数据类型。初始采集并标记完成的遥感数据样本如图 5 所示。

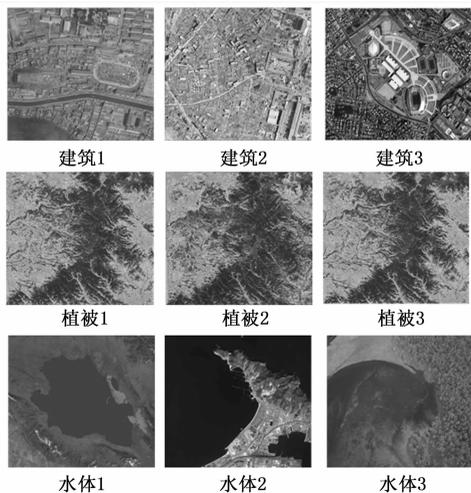


图 5 航空物探遥感数据样本示意图

图 5 中显示的遥感数据均为全局数据, 实验中准备的航空物探遥感数据样本共 1 800 个, 全局和局部遥感数据分别为 900 个, 将遥感数据样本平均分为 12 组, 保证每组中遥感数据类型数量低于 3 种。调整航空物探遥感数据样本格式, 将其统一存储在数据库环境中。

#### 2.2 选择航空物探遥感数据分类方法开发工具

自编码神经网络庞大的网络模型和参数, 使得它在学习时会消耗大量的存储空间和计算资源。由于 GPU 具有并行、浮点操作等特性, 因此采用 CPU 和 GPU 相结合的硬件平台。遥感数据分类方法程序的开发通过 Ubuntu16.04 系统下利用 Python 语言编写脚本, 并保证编写程序能够调用相关数据库。

#### 2.3 输入自编码神经网络算法运行参数

为实现自编码神经网络算法在航空物探遥感数据分类方法中的自适应运行, 需要对相关参数进行设置。由于自编码神经网络具有非线性特性, 其学习时间长短、是否收敛、是否达到局部极小化等问题都与初始化问题有着密切的联系。若各神经元的初始加权输出值均近似于零, 则可确保各神经元的权重均在最大程度上调整。另外设置学习率参数设置为 0.001, 稀疏常数为 0.03。最终将设置的相关参数输入到航空物探遥感数据分类方法对应的运行程序中。

#### 2.4 描述分类方法运行与测试过程

利用选择的开发工具, 完成优化设计基于自编码神经网络的航空物探遥感数据分类方法的开发, 将准备的航空物探遥感数据样本逐一输入到分类方法运行程序中, 得出遥感数据分类结果。图 6 为任意全局遥感数据样本的分类结果。



图 6 航空物探遥感数据分类结果

按照上述方式可以得出所有航空物探遥感数据样本的分类结果。为体现出所提方法在分类性能方面的优势, 设置基于深度传递迁移学习的遥感影像分类方法 (文献 [3] 方法) 和基于对比学习方法的遥感影像分类方法 (文献 [4] 方法) 作为对比方法, 按照上述流程得出对比方法的数据分类结果。

#### 2.5 设置分类性能测试指标

实验使用分类成功率和分类错误率两个指标来度量航空物探遥感数据的分类性能, 分类成功率用来度量分类方法对多种遥感数据的处理能力, 其数值结果如下:

$$\eta_{\text{suc}} = \frac{n_{\text{out}}}{n_{\text{sample}}} \times 100\% \quad (19)$$

式中, 中变量  $n_{\text{out}}$  为方法成功输出分类结果的样本数量,  $n_{\text{sample}}$  为设置的遥感数据样本总数。另外分类错误率的测试结果:

$$\eta_{\text{err}} = \frac{n_{\text{err}}}{n_{\text{sample}}} \times 100\% \quad (20)$$

式中,  $n_{\text{err}}$  为遥感数据分类错误的样本数量。通过相关数据的统计、计算, 得出分类性能量化指标的测试结果。最终测试得出分类成功率指标越接近 1, 分类错误率指标越接近 0, 则表示分类性能越优。

#### 2.6 分类性能测试结果与分析

通过航空物探遥感数据分类方法的反复运行, 得出 3 种方法对全局遥感数据分类性能的测试结果, 如表 1 所示。

根据航空物探遥感数据样本的分组情况, 确定每组遥感数据数量共 150 个, 将表 1 中的数据代入到公式 (19) 和公式 (20) 中, 计算得出两种传统分类方法的平均分类成

功率分别为 96.6% 和 98.3%，平均分类错误率分别为 2.9% 和 1.7%，而所提方法的全局遥感数据分类成功率和错误率的平均值分别为 99.8% 和 0.6%。

表 1 航空物探全局遥感数据分类性能测试数据表

实验组别	基于深度传递迁移学习的遥感影像分类方法		基于对比学习方法的遥感影像分类方法		基于自编码神经网络的航空物探遥感数据分类方法	
	$n_{out}/个$	$n_{err}/个$	$n_{out}/个$	$n_{err}/个$	$n_{out}/个$	$n_{err}/个$
Q1	145	4	147	3	150	2
Q2	146	3	148	2	149	0
Q3	144	5	146	1	150	1
Q4	142	6	147	4	150	1
Q5	147	4	150	3	150	0
Q6	143	4	147	2	149	1

同理可以得出不同方法在航空物探局部遥感数据分类任务中的性能测试结果，如表 2 所示。

表 2 航空物探局部遥感数据分类性能测试数据表

实验组别	基于深度传递迁移学习的遥感影像分类方法		基于对比学习方法的遥感影像分类方法		基于自编码神经网络的航空物探遥感数据分类方法	
	$n_{out}/个$	$n_{err}/个$	$n_{out}/个$	$n_{err}/个$	$n_{out}/个$	$n_{err}/个$
J1	147	3	148	2	150	1
J2	148	3	148	2	149	0
J3	148	4	149	3	150	1
J4	147	3	150	2	150	1
J5	147	4	148	3	149	0
J6	148	2	149	2	150	0

经过公式 (19) 和公式 (20) 的计算，得出 3 种方法在航空物探局部遥感数据分类工作中的成功率分别为 98.3%、99.1% 和 99.8%，而分类错误率分别为 2.1%、1.6% 和 0.3%。由此可得，基于自编码神经网络的航空物探遥感数据分类方法能够实现对航空物探全局遥感数据及局部遥感数据的精准分类。

### 3 结束语

遥感技术是航空物探工作中的重要技术之一，在远距离目标信息的收集与监测等方面具有重要应用价值。本文提出基于自编码神经网络的航空物探遥感数据分类方法，通过自编码神经网络算法的应用，实现对遥感数据特征的精准提取，间接提升数据的分类精度和利用率。实验结果表明，该方法对全局遥感数据及局部遥感数据分类的成功率均较高，体现了该方法在航空物探遥感数据分类方面的优势。

#### 参考文献:

[1] 蒋治浩, 林 辉, 张怀清, 等. 面向对象结合卷积神经网络的 GF-1 影像遥感分类 [J]. 中南林业科技大学学报, 2021, 41 (8): 45-55.  
 [2] 林 童, 米耀辉, 杨漫坪, 等. 基于 VMD-小波阈值的航空

伽玛能谱数据降噪方法的研究 [J]. 地质论评, 2021, 67 (s1): 199-200.  
 [3] 林 禹, 赵泉华, 李 玉. 一种基于深度传递迁移学习的遥感影像分类方法 [J]. 地球信息科学学报, 2022, 24 (3): 495-507.  
 [4] 慕晓冬, 白 坤, 尤轩昂, 等. 基于对比学习方法的遥感影像特征提取与分类 [J]. 光学精密工程, 2021, 29 (9): 2222-2234.  
 [5] 苏 岫, 王 祥, 宋德瑞, 等. 基于改进光谱角法的红树林高分遥感分类方法研究 [J]. 海洋环境科学, 2021, 40 (4): 639-646.  
 [6] 洪 亮, 冯亚飞, 彭双云, 等. 面向对象的多尺度加权联合稀疏表示的高空间分辨率遥感影像分类 [J]. 测绘学报, 2022, 51 (2): 224-237.  
 [7] 任媛媛, 汪建廷. 数据异常情况下遥感影像时间序列分类算法 [J]. 计算机应用, 2021, 41 (3): 662-668.  
 [8] 吕欢欢, 刘 涛, 张 辉, 等. 基于显著性特征和 DCNN 的高分遥感影像场景分类 [J]. 激光与光电子学进展, 2021, 58 (20): 44-56.  
 [9] 苏红军, 姚文静, 吴翌月. 结合弹性网络与低秩表示的高光谱遥感影像分类方法 [J]. 遥感学报, 2022, 26 (11): 2354-2368.  
 [10] 张 健, 保文星. 生成式对抗网络的高光谱遥感图像分类方法研究 [J]. 遥感学报, 2022, 26 (2): 416-430.  
 [11] 李 玉, 陶从辉, 赵泉华. 基于 EVI-Albedo 特征空间的土地荒漠化遥感分类方法 [J]. 遥感信息, 2022, 37 (5): 8-14.  
 [12] 白 慧, 杨风暴. 基于高辨识复合衍生特征的 LiDAR 数据分类方法研究 [J]. 激光与光电子学进展, 2021, 58 (5): 280-288.  
 [13] 赵伍迪, 李山山, 李 安, 等. 结合深度学习的高光谱与多源遥感数据融合分类 [J]. 遥感学报, 2021, 25 (7): 1489-1502.  
 [14] 阮 辉, 刘 雷, 胡晓光. 基于趋势符号聚合近似的卫星时序数据分类方法 [J]. 北京航空航天大学学报, 2021, 47 (2): 333-341.  
 [15] 薛 明, 韦 波, 李景文, 等. 优化 BP 神经网络的多特征融合遥感影像分类方法 [J]. 测绘科学, 2021, 46 (11): 47-55.  
 [16] 孙淑娥, 姚 柳, 赵 怡. 基于卷积神经网络的时间序列数据融合算法 [J]. 西安石油大学学报 (自然科学版), 2021, 36 (5): 136-142.  
 [17] 鞠 星, 徐 蕾, 栾晓东, 等. 解码航空物探遥感技术测珠峰 [J]. 中国矿业, 2021, 30 (s1): 475-478.  
 [18] 马欣悦, 王梨名, 祁昆仑, 等. 基于多尺度循环注意力网络的遥感影像场景分类方法 [J]. 地球科学, 2021, 46 (10): 3740-3752.  
 [19] 周 珂, 杨永清, 张伊娜, 等. 光学遥感影像土地利用分类方法综述 [J]. 科学技术与工程, 2021, 21 (32): 13603-13613.  
 [20] 魏 麟, 刘艳飞, 丁乐乐, 等. 深度度量学习高分遥感影像场景分类方法 [J]. 测绘通报, 2021 (s1): 149-153.