

基于 K-means 聚类与 RBFNN 的点云 DEM 构建方法

赵庆展^{1,2} 李沛婷^{1,2} 马永建³ 田文忠⁴

(1. 石河子大学信息科学与技术学院, 石河子 832003; 2. 国家遥感中心新疆兵团分部, 石河子 832003; 3. 兵团空间信息工程技术研究中心, 石河子 832003; 4. 石河子大学机械电气工程学院, 石河子 832003)

摘要: 因无人机机载激光雷达(Light detection and ranging, LiDAR)数据具有离散性,在生成数字高程模型(Digital elevation model, DEM)时需选择有效插值方法。以荒漠植被区为研究背景,使用零-均值标准化方法归一化点云回波强度,利用肘方法确定最佳聚类数目,采用 K-means 方法对点云强度值聚类得到地面点云。在此基础上,采用克里金(Kriging)方法插值抽稀率为 20% 和 80% 的地面点云数据,且将点云高程作为变量,建立 RBF 神经网络预测模型,并通过线性回归检验方法对模型进行精度分析,采用 Delaunay 三角网内插生成高精度 DEM。结果表明:采用 K-means 方法实现最佳聚类数目为 4 的聚类,得到地面点云 48 722 个,在点云较优抽稀率 20% 的情况下,径向基函数神经网络(Radical basis function neural network, RBFNN)训练时间为 56 s,点云高程预测的决定系数 R^2 为 0.887,均方根误差 RMSE 为 0.168 m。说明使用 RBFNN 对 K-means 聚类滤波得到的地面点云进行高程预测效果较好,可为基于点云构建高精度 DEM 提供参考。

关键词: 无人机机载激光雷达; 数字高程模型; 肘方法; K-means 聚类; 径向基函数神经网络; 线性回归

中图分类号: TN958.98; P231.5 **文献标识码:** A **文章编号:** 1000-1298(2019)09-0208-07

Construction Method of Point Clouds' DEM Based on K-means Clustering and RBF Neural Network

ZHAO Qingzhan^{1,2} LI Peiting^{1,2} MA Yongjian³ TIAN Wenzhong⁴

(1. College of Information Science and Technology, Shihezi University, Shihezi 832003, China

2. Division of National Remote Sensing Center, Xinjiang Production and Construction Corps, Shihezi 832003, China

3. Geospatial Information Engineering Research Center, Xinjiang Production and Construction Corps, Shihezi 832003, China

4. College of Mechanical and Electrical Engineering, Shihezi University, Shihezi 832003, China)

Abstract: Digital elevation model (DEM) is a basic surface information product for constructing hydrological models, drawing slope maps, and extracting topographic features and so on. Because unmanned aerial vehicle (UAV) light detection and ranging (LiDAR) point cloud data has discrete characteristics, a reasonable interpolation method needs to be selected when generating DEM based on point clouds. The desert vegetation area in Xinjiang was taken as the research background, the zero-mean normalization method was used to normalize the point clouds' echo intensity, the elbow method was used to determine the optimal number of clustering by K-means approach, and the K-means clustering method was used to cluster the point clouds' intensity values to obtain the test area's ground point clouds. After that, the Kriging interpolation method was used to interpolate the ground point clouds with the thinning rate of 20% and 80%, respectively. Furthermore, the point clouds' elevation value was used as a variable to establish the radical basis function neural network (RBFNN) prediction model, the accuracy of RBFNN prediction model was analyzed by linear regression method, and then the high-precision DEM was generated by Delaunay triangulation interpolation. The results showed that K-means clustering method was adopted to realize the clustering with the optimal number of clustering as 4, and 48 722 ground point clouds were obtained. The root mean squared error (RMSE) corresponding to the point cloud thinning rate of 20% was smaller, and RBFNN training time was 56 s when the point cloud thinning rate was 20%. The determination coefficient R^2 of fit for predicting the point clouds' elevation value was

收稿日期: 2019-03-09 修回日期: 2019-04-02

基金项目: 国家重点研发计划项目(2017YFB0504203)和中央引导地方科技发展专项资金项目(201610011)

作者简介: 赵庆展(1972—),男,教授,主要从事农业信息化、空间信息系统集成与服务研究, E-mail: zqz_inf@shzu.edu.cn

0.887, and RMSE was 0.168 m when elevations of ground point clouds was predicted based on RBFNN. This method not only showed that the point cloud filtering can be realized by K-means clustering filtering, but also showed that the RBF neural network was a better way for predicting point cloud elevation. This can provide reference for constructing high-precision DEM based on point cloud.

Key words: unmanned aerial vehicle light detection and ranging; digital elevation model; elbow method; K-means clustering method; radical basis function neural network; linear regression

0 引言

数字高程模型(Digital elevation model, DEM)是地形高程信息的数字化表示,是重要的基本地形产品之一^[1],不仅可以非常直观地显示地形和地貌,而且为各种地形特征的定量分析和不同类型专题图的绘制提供了基本数据^[2]。无人机机载激光雷达(Light detection and ranging, LiDAR)是集激光测距技术、计算机技术、高精度动态惯性导航系统(Inertial navigation system, INS)和高精度动态差分全球定位系统(Differential global positioning system, DGPS)等于一体的摄影测量新技术^[3],可提供地物三维空间坐标、地物激光回波强度、获取时间等信息^[4]。因无人机机载 LiDAR 具有起降灵活、机动性好等优点而被广泛应用,可直接获取高精度、高密度点云数据以生成 DEM。

同时,点云滤波是生成 DEM 的基础,即把点云分成地面点与非地面点。林祥国等^[5]采用多基元三角网渐进加密方法实现点云滤波,使滤波误差降低。李鹏程等^[6]基于表面实现点云滤波,即采用点云的波形信息进行加权曲面拟合以获取点云表面。张继贤等^[7]利用 K-means 聚类方法快速分割点云中的电线。周晓明^[8]结合点云全波形属性信息和聚类方法实现滤波。综上,具有代表性的点云滤波方法可以分为基于逐渐加密、基于表面和基于聚类等方法^[9]。本文选择原理简单、且便于处理海量数据的 K-means 聚类方法实现点云滤波。

神经网络不需建立精确的数学模型即可实现非线性映射,以预测相关数据。KUÇAK 等^[10]利用自组织映射神经网络和 K-means 聚类两种方法,结合点云法向量、强度和曲率 3 种属性信息,实现点云分割,以生成 DEM。ZUO 等^[11]采用神经网络实现城市点云分类,以验证神经网络可以成功分离地面点、建筑物、树木和裸露土等地物。径向基函数神经网络(Radical basis function neural network, RBFNN)以其学习速度快、不易陷入局部极小值等优点,常被应用在数据插值预测中。陈昌华等^[12]利用主成分分析方法消除径向基函数神经网络(RBFNN)输入层数据的相关性,即以主成分分析模型的结果作为

RBFNN 的输入,建立土壤水分的预测模型,结果表明,RBFNN 预测精度比误差反向传播神经网络预测精度高。周仲礼等^[13]采用模拟退火蚁群算法改进径向基函数神经网络模型,分别对地层高程进行面插值和对矿体品位进行空间体插值,且与普通克里金(Kriging)插值方法进行交叉验证,结果表明,改进径向基函数神经网络插值效果明显优于克里金插值方法。目前使用径向基函数神经网络实现点云预测的研究较少^[14],本文使用径向基函数神经网络预测地面点云高程值,且采用 Delaunay 三角网生成 DEM。

1 数据获取

以 AeroScout B1-100 型单旋翼油动无人机作为飞行平台,搭载 Riegl VUX-1 型激光扫描仪、OxTS Survey+2 型惯性导航系统和 Sony 可见光相机获取研究区 LiDAR 数据和可见光数据。无人机的长、宽、高为 3.3 m × 1.0 m × 1.3 m,尾旋翼直径 0.65 m,空机质量 50 kg,有效载荷 18 kg,发动机功率 13.23 kW,标准油箱容积 10 L。Riegl VUX-1 型激光扫描仪是专业测绘级激光扫描仪,扫描方式为线性扫描,近红外波长,最大转速 200 r/s,激光脉冲频率高达 550 kHz,记录 16 bit 的回波强度。Riegl VUX-1 型激光扫描仪详细参数见表 1。

表 1 Riegl VUX-1 型激光扫描仪产品参数

Tab. 1 Product parameters of Riegl VUX-1 laser scanner

转速/ (r·s ⁻¹)	发射频率/ kHz	测距 误差/mm	最大飞行 高度/m	最大视场 角/(°)	回波强 度/bit
10~200	550	±10	5 500	330	16

研究区域位于新疆兵团第八师一五零团五连周边荒漠植被区,地理位置为 44°57'29"~44°58'0"N, 85°58'35"~85°59'4"E,激光雷达数据基本包含了荒漠植被区的部分植物类型,主要以梭梭、骆驼蓬、麻黄、碱蓬草、驼绒藜为主。获取数据的飞行任务参数设置如下:航高 60 m,巡航速度 6 m/s,航线 3 条。在采用 Riegl LMS 配套软件和 OxTS NAVgraph 配套软件对激光雷达数据进行配准、校正、平差和删除噪声点等预处理后,截取部分区域数据作为试验区,且

以 WGS-1984-UTM-Zone-44 N 为投影坐标系导出 .las 格式的点云数据。为方便后期描述,令 \mathbf{X} 、 \mathbf{Y} 、 \mathbf{Z} 、 \mathbf{P} 分别表示由点云三维坐标和回波强度组成的 $N \times 1$ 维矩阵,其中 \mathbf{X} 和 \mathbf{Y} 分别表示东向和北向的位置,单位为($^\circ$), \mathbf{Z} 表示点云高程,单位为 m。试验区点云总数 N 为 69 544,点云 \mathbf{X} 中元素的范围在 $-46.065^\circ \sim -15.000^\circ$ 之间, \mathbf{Y} 中元素的范围在 $83.958^\circ \sim 112.145^\circ$ 之间, \mathbf{Z} 中元素的范围在 275.863 ~ 280.535 m 之间, \mathbf{P} 中元素的范围在 12 036 ~ 49 850 之间。

2 研究方法

2.1 零-均值标准化

因为 K-means 聚类方法需使用不同距离来度量数据相似性,所以为了消除数据量纲和取值范围差异的影响,需要将数据缩放到相同区间,即标准化^[15]。同时,标准化后的数据也利于加快 RBFNN 的训练速度,提高预测的准确性^[16]。常用的标准化方法有 3 种:最大-最小标准化、零-均值标准化和小数定位标准化。其中,最大-最小标准化容易受到数据最大值和最小值的影响,小数定位标准化中移动的小数位数取决于绝对值最大的样本点,故本文选择零-均值标准化,与其它两种标准化方法对比,零-均值标准化保持了异常值所包含的有用信息,标准化公式为

$$S_{\text{normal}} = \frac{S_{\text{origin}} - \mu_t}{\sigma_t} \quad (1)$$

其中
$$\mu_t = \frac{1}{N} \sum_{i=1}^N t_i \quad (2)$$

$$\sigma_t = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |t_i - \mu_t|^2} \quad (3)$$

式中 S_{normal} ——点云属性 t 标准值
 S_{origin} ——点云属性 t 原始值
 μ_t ——点云属性 t 的均值
 σ_t ——点云属性 t 的标准差
 t_i ——点云属性 t 的第 i 个点

2.2 K-means 聚类方法

2.2.1 K-means 聚类原理

K-means 聚类方法是把数据分成 k 簇,使簇内数据具有较高的相似度,而不同簇之间数据相似度较低^[17],采用 K-means 聚类方法实现点云聚类获得地面点云的基本步骤如下:

(1) 根据采集得到的研究区数据,确定需要的聚类数目 k 。

(2) 确定 k 个聚类对象的初始聚类中心 $\{U_i | i = 1, 2, \dots, k\}$ 。

(3) 分别计算每个样本数据到 k 个聚类中心的距离。

(4) 筛选样本数据到聚类中心的最小距离,且将此样本划分到聚类最小的类别中。

(5) 当所有样本点都划分完毕,重新计算 k 个对象的聚类中心。

(6) 与前一次获取的 k 个聚类中心比较,判断聚类中心是否发生变化或达到预定的最大迭代次数。如果聚类中心发生变化,转到步骤(3);如果聚类中心发生变化但已经达到最大迭代次数或者聚类中心没有发生变化,则算法终止^[18]。

通常,采用不同的距离标准可以得到不同的聚类结果。本文选择适用范围较广的平方欧几里距离作为距离标准,其计算公式为

$$d^2(x, y) = \sum_{i=1}^4 (x_i - y_i)^2 = \|x - y\|_2^2 \quad (4)$$

式中 $d(x, y)$ ——属性 t 中样本点云 x 与样本点云 y 的欧几里距离

x_i ——属性 t 的样本点云 x

y_i ——属性 t 的样本点云 y

2.2.2 肘方法确定最佳聚类数目

K-means 聚类方法的难点之一是必须事先指定聚类数目 k , k 值的选择会严重影响聚类结果,故本文使用肘方法确定最佳聚类数目。基本思想是选择簇内误差平方和 (Within-cluster sum of squared errors, SSE) (即聚类偏差) 骤变时的 k 值^[19],此时对应的 k 值为最佳聚类数目。即先对不同聚类数目进行 K-means 聚类,然后根据聚类偏差得到不同 k 值的曲线,且绘制不同 k 值对应的聚类偏差图,最后找到聚类偏差最显著拐点处对应的 k 值,其中聚类偏差的计算公式为

$$D_{\text{SSE}} = \sum_{i=1}^N \sum_{j=1}^l h_{(i,j)} = \|B_i - U'_j\|_2^2 \quad (5)$$

其中
$$h_{(i,j)} = \begin{cases} 0 & (\text{点 } B_i \text{ 不属于簇 } j) \\ 1 & (\text{点 } B_i \text{ 属于簇 } j) \end{cases}$$

式中 D_{SSE} ——簇 j 的聚类偏差

B_i ——第 i 个点

U'_j ——簇 j 中心点

l ——指定的最大聚类数目

K-means 聚类方法的另一个难点是初始聚类中心的选择。为了得到最优的聚类结果,本文在随机选择初始聚类中心和采用肘方法最佳聚类数目的基础上,针对不同的随机初始中心独立运行 K-means 聚类方法多次,然后从中选择 D_{SSE} 最小的模型作为最终模型。

2.3 点云抽稀

海量地面点云给后期处理带来较大影响,尤其是在数据处理速度方面^[20],故在保证研究对象的必要信息下,对高密度的点云进行抽稀有一定的实际意义。为了简化抽稀过程,本文按照比例对点云进行抽稀,且仅对比抽稀率为 20% 和 80% 的抽稀结果。

Kriging 插值是一种统计插值方法,可以准确对表面预测,不仅考虑了待估点与已知点位置的相互关系,而且考虑了变量的空间相关性^[21],所以采用 Kriging 方法插值抽稀结果,获取较好的抽稀率。随机抽取 100 个地面点云作为检验数据集,然后对剩余地面点云进行抽稀率为 20% 和 80% 的抽稀,对抽稀后的点云进行点云高程插值。最后从插值结果中提取检验数据集的高程预测值,且通过点云的预测值与实测值进行对比分析。

均方根误差 (RMSE) 能够评判插值结果,均方根误差越小,表明插值精度越高,误差越小^[22],其计算公式为

$$R_{RMSE} = \sqrt{\frac{1}{N'} \sum_{i=1}^{N'} (\bar{Z}_i - Z_i)^2} \quad (6)$$

式中 R_{RMSE} ——点云高程的均方根误差
 \bar{Z}_i ——检验数据集中点云高程预测值
 Z_i ——检验数据集中点云高程实测值
 N' ——检验数据集中点云数量

2.4 径向基函数神经网络模型

2.4.1 RBFNN 模型建立

RBFNN 是应用多变量的径向基函数设计而成,由输入层、隐含层和输出层组成。RBFNN 的输入层为 n 维向量 $\mathbf{I} = (I_1, I_2, \dots, I_n)$; 隐含层为 m 维向量 $\mathbf{D} = (D_1, D_2, \dots, D_m)$; 输出层为 $f(\mathbf{I})$, 即输出层是 RBFNN 的输入层对应的实测值, 以此实现 RBFNN 模型的建立^[23], 其输出公式为

$$f(\mathbf{I}) = \sum_{i=1}^m W_i D_i(\mathbf{I}) \quad (7)$$

其中

$$D_i(\mathbf{I}) = \exp\left(-\frac{\|\mathbf{I} - \mathbf{C}_i\|^2}{2r_i^2}\right) \quad (8)$$

式中 $f(\mathbf{I})$ ——径向基函数神经网络的输出层函数
 W_i ——第 i 个隐含层神经元到输出层神经元的权值

$D_i(\mathbf{I})$ ——隐含层径向基函数,采用高斯函数
 \mathbf{C}_i ——第 i 个隐含层神经元中基函数的中心
 r_i ——第 i 个隐含层神经单元的宽度,调节网络的灵敏度

RBF 神经网络模型设计结构如图 1 所示。

采用软件 Matlab 神经网络工具箱的 newrb 函数

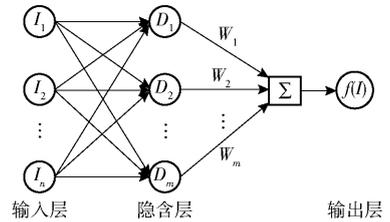


图 1 RBF 神经网络模型结构图

Fig. 1 RBFNN model structure

设计 RBFNN, 在进行径向基函数逼近时, newrb 函数可以自动添加隐含层的神经元数量直到满足训练误差要求, 其实现公式为

$$N_{net} = \text{newrb}(\mathbf{I}, \mathbf{T}, G_{go}, S_{sp}, M_{mn}, D_{df}) \quad (9)$$

式中 N_{net} ——训练得到的 RBFNN

\mathbf{T} ——预测的目标数据

G_{go} ——RBFNN 的目标误差

S_{sp} ——径向基函数散布常数, 默认值 1

M_{mn} ——最大神经元数量

D_{df} ——在网络训练过程中显示的频率, newrb 中默认值为 25

2.4.2 RBFNN 模型验证

为了验证模型的准确性, 用测试点云对训练完成后的 RBFNN 模型进行测试, 且与实测高程值进行对比分析, 来检验 RBFNN 对点云高程预测的准确性。采用软件 Matlab 中 sim 函数, 来实现测试点云高程的预测, 计算公式为

$$\mathbf{A} = \text{sim}(N_{net}, \mathbf{Q}) \quad (10)$$

式中 \mathbf{A} ——点云高程预测值矩阵

\mathbf{Q} ——由测试数据集中点云坐标 \mathbf{X} 、 \mathbf{Y} 和回波强度 \mathbf{P} 组成的矩阵

通过线性回归法对预测值和实测值进行分析, 线性回归分析法是将实测值作为自变量, 预测值作为因变量, 建立一元线性回归方程, 检验回归方程的决定系数 R^2 。决定系数 R^2 越接近 1, 则说明实测值和预测值吻合度越高, 即预测效果越好。

3 结果分析

3.1 K-means 聚类结果

采用软件 Matlab 提取研究区点云三维坐标和回波强度值, 且对点云进行零-均值标准化处理。采用 Python 语言编程确定最佳聚类数目和实现 K-means 点云聚类方法, 图 2 为聚类偏差结果, 横坐标表示聚类数目, 纵坐标表示聚类偏差。分析图 2 可知, 当 k 为 4 时, 聚类偏差呈现肘型, 即对于研究区点云, 最佳聚类数目为 4, 此时的聚类偏差 D_{sse} 为 4 304. 32。

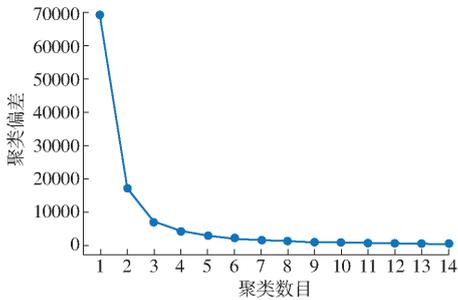


图2 聚类偏差可视化

Fig. 2 Within-cluster sum of squared errors visualization

采用 K-means 聚类方法对回波强度进行 k 为 4 的聚类, 设置聚类最大迭代次数为 3 000、聚类误差为 0.000 1。图 3a 为采用 K-means 聚类得到不同类别可视化结果, 数据 1、数据 2、数据 3 和数据 4 分别对应簇 1、簇 2、簇 3 和簇 4。图 3b 是簇 1 灰度图, 通过目视检查分析可得, 簇 1 包含研究区地面点云和离群点云, 其点云总数为 50 728, 点云高度范围在 275.863 ~ 279.636 m 之间。K-means 聚类得到的地面点云完整地保留了试验区真实地表起伏情况, 但仍然存在少量离群点云, 因此利用反复建立三角网滤出簇 1 中的少量离群点云, 从而获取地面点云数为 48 722, 此时点云高度范围为 275.870 ~ 277.600 m。

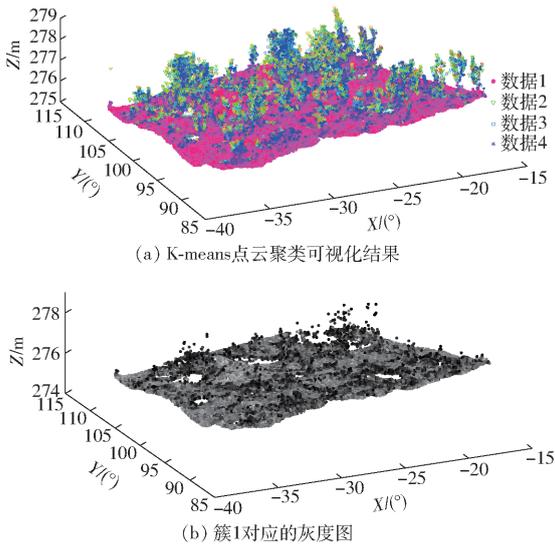


图3 K-means 聚类三维可视化点云图

Fig. 3 Visualization point clouds by using K-means clustering method

3.2 克里金插值结果

通过计算均方根误差评价抽稀精度, 可知采用 20% 和 80% 的抽稀率对应的均方根误差分别为 0.021 m 和 0.023 m, 即采用 20% 抽稀率抽稀可大大减少点云数据量。本文对地面点云进行抽稀处理后得到点云数为 9 724。图 4 为 20% 抽稀率抽稀处理后的克里金插值可视化结果, 其中绿色点表示经过抽稀后的点云, 红色点表示 100 个检验点云。

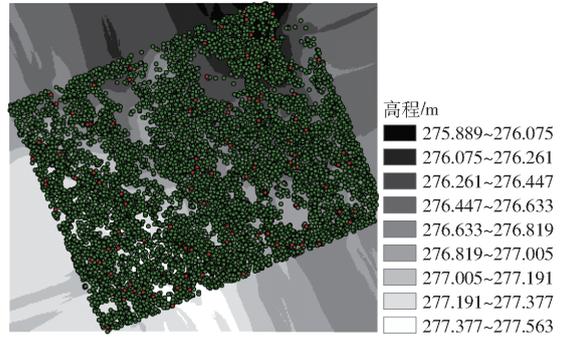


图4 20%抽稀率抽稀后的克里金插值的可视化结果

Fig. 4 Visual Kriging interpolation result at 20% point cloud thinning rate

3.3 径向基函数神经网络训练结果

随机采取抽稀后点云的 70% 作为 RBFNN 的训练数据集, 30% 作为评估网络的测试数据集。选择训练数据集中点云的 X 、 Y 坐标矩阵和回波强度矩阵 P 作为训练 RBFNN 的输入, 即 $n = 3$, 输入向量 $I = (I_1, I_2, I_3)$ 。把训练数据集中点云的高程 Z 作为网络的输出向量, 即 $Z = f(I)$ 。根据给定的目标误差, 多次训练网络确定隐含层数量。建立输入层神经元数量为 3, 输出层神经元数量为 1, 训练误差为 0.02, 散布常数为 1 的 RBFNN。图 5a 为 RBFNN 的训练结果, 可以看出, 训练次数达到 100 即隐含层神经元数量为 100 时, 训练误差 0.020 2 很逼近目标误差 0.02, 对应的 RBF 训练时间为 56 s。

利用训练完成的 RBFNN 对测试数据集进行插值预测高程, 记录预测结果。同时采用线性回归法进行分析, 图 5b 为 RBFNN 模型预测高程与实测高程的线性回归分析, 对应的决定系数 R^2 为 0.887, 说明预测值与实测值的拟合度较高。均方根误差

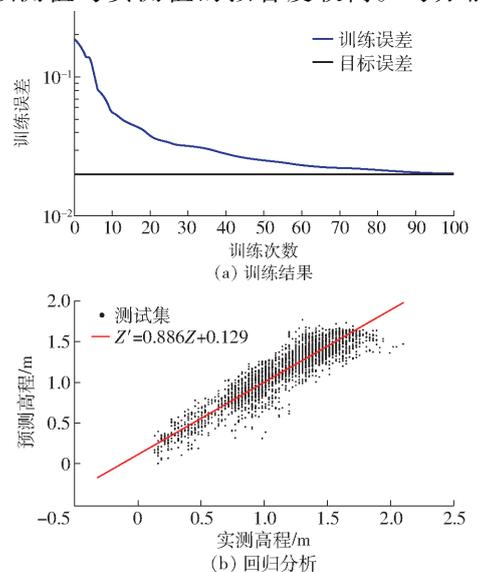


图5 RBFNN 训练结果和线性回归分析

Fig. 5 Training results of RBFNN and regression results of RBFNN

RMSE 为 0.168 m,说明插值预测精度较高。

3.4 内插结果

根据训练完成的径向基函数神经网络,对抽稀后的地面点云高程值进行内插,且根据高程值构建 Delaunay 三角网以生成试验区 DEM。图 6 为采用 Delaunay 三角网生成的 DEM,共构建 97 393 个三角网。

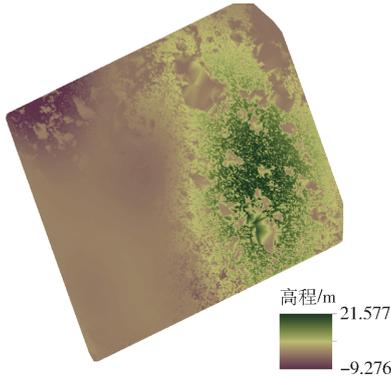


图 6 基于 Delaunay 三角网生成的 DEM 图

Fig. 6 Generated DEM diagram based on Delaunay triangulation network

4 讨论

本文目的是验证利用 RBF 神经网络内插值实现点云高程的预测,所以对 K-means 聚类结果仅采用了目视检查来定性评价聚类结果。在后续研究中,可以计算漏分误差、错分误差和总体误差来定量评价聚类结果。另外,如果需要提高 K-means 聚类速度,可以先采用 K-means 聚类对标准化处理的点云三维坐标进行聚类分簇,然后针对不同的簇,再次

使用 K-means 聚类对回波强度标准值进行聚类,且合并每类地面点云。

本文随机选取 100 个点云测试 Kriging 插值结果,可知测试点分布较好,但是存在部分区域测试点分布较少,故后期可先计算点云曲率再抽稀。在建立 RBF 神经网络模型时,选择输入变量为点云坐标矩阵 X 、 Y 和点云回波强度矩阵 P ,并没有充分考虑到点云之间的相关性,因此 RBF 神经网络输入层数据的相关性还需进一步研究。

5 结论

(1)采用 K-means 聚类方法实现点云滤波获得试验区 48 722 个地面点云,采用肘方法确定最佳聚类数目为 4,采用 Python 语言编程设置聚类数目、最大迭代次数 3 000 和聚类误差 0.000 1 等参数,不仅可以快速得到聚类结果,而且可以将 K-means 聚类独立运行多次,选择最小聚类偏差 D_{SSE} 为 4 304.32 作为最终结果。

(2)在保证用最少的数据量表示地面真实状况下,选择简单、运算速度快的抽稀方法。在 ArcGIS 软件中按比例对点云进行抽稀,且采用 Kriging 插值方法对不同抽稀后的点云进行插值。通过比较插值结果,得到较优抽稀率为 20%。将 RBF 神经网络引入到点云处理过程中,尝试建立一种快速高效的空空间预测方法,从误差分析可以看出,RBF 神经网络对空间数据具有较好的预测能力,预测时间为 56 s,其预测的决定系数 R^2 为 0.887。

参 考 文 献

- [1] POLAT N, UYSAL M, TOPRAK A S. An investigation of DEM generation process based on LiDAR data filtering, decimation, and interpolation methods for an urban area[J]. Measurement, 2015, 75:50 - 56.
- [2] 马鼎, 李斌兵. 黄土沟壑区切沟植被的激光点云滤波及地形构建[J]. 农业工程学报, 2013, 29(15):162 - 171. MA Ding, LI Binbing. Vegetation filtering in gully region of loess plateau based on laser scanning point cloud's intensity attenuation model and its terrain construct[J]. Transactions of the CSAE, 2013, 29(15):162 - 171. (in Chinese)
- [3] 毛学刚, 侯吉宇, 白雪峰, 等. 基于 DOM 及 LiDAR 的多尺度分割与面向对象林隙分类[J/OL]. 农业机械学报, 2017, 48(9):152 - 159. MAO Xuegang, HOU Jiyu, BAI Xuefeng, et al. Multiscale forest gap segmentation and object-oriented classification based on DOM and LiDAR[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(9):152 - 159. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20170919&flag=1&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.09.019. (in Chinese)
- [4] EITEL J U H, BERNHARD H, VIERLING L A, et al. Beyond 3-D; the new spectrum of LiDAR applications for earth and ecological sciences[J]. Remote Sensing of Environment, 2016, 186:372 - 392.
- [5] 林祥国, 张继贤, 宁晓刚, 等. 融合点、对象、关键点等 3 种基元的点云滤波方法[J]. 测绘学报, 2016, 45(11):1308 - 1317. LIN Xiangguo, ZHANG Jixian, NING Xiaogang, et al. Filtering of point clouds using fusion of three types of primitives including points, objects and key points[J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(11):1308 - 1317. (in Chinese)
- [6] 李鹏程, 徐青, 邢帅, 等. 利用波形信息的加权曲面拟合 LiDAR 点云滤波[J]. 武汉大学学报(信息科学版), 2018, 43(3):420 - 427. LI Pengcheng, XU Qing, XING Shuai, et al. Weighted curve fitting filtering method based on full-waveform LiDAR data [J].

- Geomatics and Information Science of Wuhan University, 2018, 43(3):420-427. (in Chinese)
- [7] 张继贤, 林祥国. 架空输电线路机载激光雷达点云电力线三维重建[J]. 测绘学报, 2016, 45(3):347-353.
ZHANG Jixian, LIN Xiangguo. 3D power line reconstruction from airborne LiDAR point cloud of overhead electric power transmission corridors[J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(3):347-353. (in Chinese)
- [8] 周晓明. 机载激光雷达点云数据滤波算法的研究与应用[D]. 郑州:解放军信息工程大学, 2011.
ZHOU Xiaoming. Research and application of airborne LiDAR point cloud data filters[D]. Zhengzhou: PLA Information Engineering University, 2011. (in Chinese)
- [9] 王琦. LiDAR点云生成格网DEM模型的内插算法研究[D]. 武汉:中国地质大学, 2010.
WANG Qi. Research on the grid DEM interpolation algorithm of LiDAR points cloud[D]. Wuhan: China University of Geosciences, 2010. (in Chinese)
- [10] KUÇAK R A, ÖZDEMİR E, EROL S. The segmentation of point clouds with K-means and ANN (artificial neural network) [J]. The International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences, 2017, XLII-1/W1:595-598.
- [11] ZUO W H, SHU H, LUO Q. The urban objects classification based on LiDAR 3D applied mechanics and materials[J]. Applied Mechanics and Materials, 2012, 226:1840-1843.
- [12] 陈昌华, 谭俊, 尹健康, 等. 基于PCA-RBF神经网络的烟田土壤水分预测[J]. 农业工程学报, 2010, 26(8):85-90.
CHEN Changhua, TAN Jun, YIN Jiankang, et al. Prediction for soil moisture in tobacco fields based on PCA and RBF neural network[J]. Transactions of the CSAE, 2010, 26(8):85-90. (in Chinese)
- [13] 周仲礼, 马腾, 陈秀荣, 等. 基于改进RBF的空间插值算法及其在矿体三维可视化中的应用[J]. 成都理工大学学报(自然科学版), 2014, 41(5):645-650.
ZHOU Zhongli, MA Teng, CHEN Xiurong, et al. Spatial interpolation algorithm based on improved RBF and its application to orebody 3D visualization[J]. Journal of Chengdu University of Technology (Science & Technology Edition), 2014, 41(5):645-650. (in Chinese)
- [14] 周方艳, 张启灿, 熊润华. 径向基函数在三维点云数据插补中的应用[J]. 光电工程, 2015, 42(8):20-25.
ZHOU Fangyan, ZHANG Qican, XIONG Runhua. Application of radial basis function in 3D point-cloud data interpolation [J]. Opto-Electronic Engineering August, 2015, 42(8):20-25. (in Chinese)
- [15] VISALAKSHI N K, THANGAVEL K. Impact of normalization in distributed K-means clustering[J]. International Journal of Soft Computing, 2009, 4(4):168-172.
- [16] 张红, 卢茸, 石伟, 等. 基于RBF神经网络的土壤重金属空间变异研究[J]. 中国生态农业学报, 2012, 20(4):474-479.
ZHANG Hong, LU Rong, SHI Wei, et al. Application of RBF neural network in determining soil heavy metal spatial variability[J]. Chinese Journal of Eco-Agriculture, 2012, 20(4):474-479. (in Chinese)
- [17] HOU T C, LIU J W. Algorithmic clustering of LiDAR point cloud data for textural damage identifications of structural elements [J]. Measurement, 2017, 108:77-90.
- [18] 贾伟宽, 赵德安, 刘晓洋, 等. 机器人采摘苹果果实的K-means和神经网络识别[J]. 农业工程学报, 2015, 31(18):175-181.
JIA Weikuan, ZHAO Dean, LIU Xiaoyang, et al. Apple recognition based on K-means and GA-RBF-LMS neural network applied in harvesting robot[J]. Transactions of the CSAE, 2015, 31(18):175-181. (in Chinese)
- [19] SEBASTIAN R. Python machine learning[M]. Birmingham: Packet Publishing, 2015.
- [20] HAN X F, JIN J S, WANG M J, et al. A review of algorithms for filtering the 3D point cloud[J]. Signal Processing: Image Communication, 2017, 57:103-112.
- [21] MARCIN L, MAREK K. Simple spatial prediction-least squares prediction, simple Kriging, and conditional expectation of normal vector[J]. Geodesy and Cartography, 2010, 59(2):69-81.
- [22] 陈飞香, 程家昌, 胡月明, 等. 基于RBF神经网络的土壤铬含量空间预测[J]. 地理科学, 2013, 33(1):69-73.
CHEN Feixiang, CHENG Jiachang, HU Yueming, et al. Spatial prediction of soil properties by RBF neural network[J]. Scientia Geographica Sinica, 2013, 33(1):69-73. (in Chinese)
- [23] 刘同海, 李卓, 滕光辉, 等. 基于RBF神经网络的种猪体重预测[J/OL]. 农业机械学报, 2013, 44(8):245-249.
LIU Tonghai, LI Zhuo, TENG Guanghui, et al. Prediction of pig weight based on radical basis function neural network [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(8):245-249. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?file_no=20130842&flag=1&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2013.08.042. (in Chinese)