

基于广义回归神经网络插值的 雷达引信回波模拟

王洋洋, 曹 菲

(火箭军工程大学, 陕西 西安 710025)

摘 要: 为了更加精确地对雷达引信回波信号进行模拟, 以北京市密云区数字高程模型 (Digital Elevation Model, DEM) 作为地形研究数据进行插值分析和回波模拟, 提出了使用广义回归神经网络 (Generalized Regression Neural Network, GRNN) 进行插值的方法。在插值后的DEM仿真地形上, 考虑地形起伏对雷达引信回波遮挡的影响, 仿真得到传统插值算法和GRNN插值算法下的雷达引信回波图, 通过内插精度和回波分析了算法性能。结果表明: 在地貌类型以平原、丘陵为主的地区, 相较于传统算法, 本文算法能够描绘地形细节, 更加精确地模拟回波分布规律。

关键词: 广义回归神经网络; 高程插值算法; 精度评价; 回波模拟; 深度神经网络; 数字高程模型

中图分类号: TN973.3; TJ43+4 **文献标志码:** A **文章编号:** 2097-2741(2024)05-069-12

Radar Fuse Echo Simulation Based on Generalized Regression Neural Network Interpolation

WANG Yangyang, CAO Fei

(Rocket Force University of Engineering, Xi'an 710025, Shaanxi)

ABSTRACT: In order to simulate the radar fuze echo signal more accurately, the interpolation and echo simulation were explored by taking the digital elevation model (DEM) of Miyun District in Beijing as the terrain research data. Accordingly, an interpolation method using generalized regression neural network (GRNN) was proposed. Furthermore, with the consideration of the effect of terrain undulation on radar fuze echo obstruction, radar fuze echo maps of the interpolated DEM simulated terrain were obtained respectively by the traditional interpolation algorithm and the GRNN interpolation algorithm. Through the analysis of the interpolation accuracy and echo, the performance of the proposed method was explored. Results showed that in the area where the terrain type is mainly plains and hills, the bilinear interpolation algorithm and the GRNN algorithm can depict the details of the terrain and simulate the distribution of the echo more accurately.

KEYWORDS: GRNN; elevation interpolation algorithms; accuracy evaluation; echo simulation; deep neural network; DEM

收稿日期: 2024-05-22

第一作者: 王洋洋 (1999—), 女, 硕士研究生, 主要从事雷达引信回波模拟研究。E-mail: qq2yang2023@qq.com

引用格式: 王洋洋, 曹菲. 基于广义回归神经网络插值的雷达引信回波模拟[J]. 火箭军工程大学学报, 2024, 38 (5): 69-80.

雷达引信是通过发射电磁波探测目标,并提取出目标回波信号中所携带的距离、速度、角度等信息,从而控制导弹在最佳时机起爆的系统^[1]。在雷达引信系统研究及研制的过程中,目标回波信号模拟是其重要调试工具。对面目标进行模拟时,通常是将总回波近似为各点目标回波的矢量叠加,在近似的过程中,地面高程模型的精度对总回波模拟的准确性具有重要影响。格网数字高程模型(Grids Digital Elevation Model, GR-ID DEM)因其结构简单、易于进行空间分析等特点,目前已经在土壤^[2]、地质^[3-4]、水文^[6]、城乡规划 and 战场模拟等众多领域得到广泛应用。

然而,DEM是对地球表面地形地貌的一种离散的数字表达^[6],由于各种条件限制,所建立的数学模型与实际地形存在偏差,使得DEM可信度低^[7]。文献[8-10]采用传统插值方法生成规则格网DEM,并对内插结果进行了精度分析,为后续地形建模提供理论基础;文献[11]针对传统格网DEM插值数学模型在解算权重系数时存在负权的问题,通过最大熵原理分析模型对权值的依赖程度,增设非负约束条件,提高了估值精度。文献[12]改进了最大熵模型,解决了传统空间数据内插方法过度依赖原始数据数目、最大熵模型结果不唯一和效率低等弊端。Binh等^[13]通过DEM精度评定,分析不同插值算法对DEM精度的影响,得出样条函数插值方法更适合用于建立山地地形的DEM,普通克里金法和反距离权重法更适合对平原和丘陵地形数据进行DEM插值的结论。但是将插值结果应用在回波模拟领域的研究并不多见。

为了探究不同插值方法对回波模拟的影响,本文分别采用双线性插值法、反距离加权法(Inverse Distance Weighting, IDW)、遗传算法(Genetic Algorithm, GA)结合岭回归算法、深度神经网络(Deep Neural Network, DNN)算法和基于广义回归神经网络(Generalized Regression Neural Network, GRNN)的插值方法对地面进行网格划分,对这几种方法进行精度验证和评价分析。通过对比采用各种DEM内插算法的回波,得到地形网格划分精度对引信测高的影响。

1 传统插值算法

1.1 双线性插值法

双线性插值法使用最靠近内插点的4个数据

点,确定一个双线性平面^[5]。设 P 点附近有随机的4个点 $P_1(e_1, q_1, z_1)$ 、 $P_2(e_2, q_2, z_2)$ 、 $P_3(e_3, q_3, z_3)$ 、 $P_4(e_4, q_4, z_4)$,那么内插点高程为

$$Z = a_0 + a_1e + a_2q + a_3eq$$

式中:参数 a_0 、 a_1 、 a_2 、 a_3 的值可通过4个已知数据点求解。

若4点构成方格网, a 为单元格网的间距,双线性插值算法如图1所示。




图1 双线性插值法

Fig. 1 Bilinear interpolation

那么,插值后 P 点的高程值 z 为

$$z_p = (1 - \frac{e_p}{a})(1 - \frac{q_p}{a})z_1 + \frac{e_p}{a}(1 - \frac{q_p}{a})z_2 + \frac{q_p}{a}(1 - \frac{e_p}{a})z_3 + \frac{e_p}{a} \cdot \frac{q_p}{a} \cdot z_4$$

1.2 反距离加权法

反距离加权插值方法^[14]是一种局部插值方法,它假设未知点的值受较近控制点的影响比较远控制点的影响更大,影响的程度(权重)用点之间距离乘方的倒数表示。乘方为1意味着点之间数值变化率为恒定。该方法称为线性插值法。本文考虑乘方为1的线性情况,方法如下:设 (e_i, q_i, z_i) , $i = 1, 2, \dots, n$ 为被插值点 $P(e, q, z)$ 附近的一组参考点坐标, P 的高程插值计算公式为

$$z_p = \frac{\sum_{i=1}^n (c_i z_i)}{\sum_{i=1}^n c_i}$$

式中: c_i 为距离加权函数,本文取 $c_i = 1/d_i$; d_i 为控制点与原点之间的距离。

1.3 遗传算法结合岭回归法

岭回归是一种专用于共线性数据分析的有偏估计回归方法,实质上是一种改良的最小二乘估计法,通过放弃最小二乘法的无偏性,以损失部分信息、降低精度为代价获得回归系数更符合实际、更可靠的回归方法。

岭回归的代价函数加入了二范数惩罚项,岭回归模型的损失函数为

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(s^{(i)}) - r^{(i)})^2 + \lambda \|\theta\|_2^2 = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(s^{(i)}) - r^{(i)})^2 + \lambda \sum_{j=1}^l \theta_j^2 \quad (1)$$

式中: $s^{(i)} \in \mathbb{R}^p$ 是自变量向量; $r^{(i)} \in \mathbb{R}$ 是因变量向量; $h_{\theta}(x) = \sum_{j=0}^n \theta_j s_j$; $\|\theta\|_2$ 为 L2 范数; θ_j 为模型参数; λ 为岭系数; m 为样本数; l 为特征数。

对式 (1) 的 θ 进行求导, 得

$$\frac{\partial J(\theta)}{\partial \theta} = S^T S \theta - S^T R + \lambda \theta$$

令求导后的式子等于 0, 可以求得最优解为

$$w = (S^T S + \lambda I)^{-1} S^T r$$

在采用岭回归法对数据进行拟合时, 采用遗传算法对岭回归的模型参数 θ_j 进行优化。遗传算法基本思想^[11]是通过基因的组合交叉和变异逐步进行问题的优化, 从而寻找到最优解。遗传算法基本流程如图 2 所示。




图 2 遗传算法流程

Fig. 2 Flowchart of genetic algorithm

1.4 DNN

按照不同层的位置, DNN 可分为输入层、隐藏层和输出层, 各层之间是全连接的, 即第 i 层的任意一个神经元一定与第 $i+1$ 层的任意一个神经元相连^[15]。

本实验采用 3 层全连接 DNN, 每层的隐藏节点数都是 64, 输入节点数为 2, 输出节点数为 1。采用均方根误差 (MSE) 作为损失函数, Epoch 设置为 100, 初始学习率为 0.001, 每隔 10 个 Epoch 学习率减半。具体网络结构如图 3 所示。

2 GRNN 插值算法

2.1 GRNN 基础理论

广义回归神经网络使用样本集充当验证数据, 运用 Parzen 非参数估计, 以最大概率原则输出广义回归神经网络的运算结果。




图 3 DNN 网络结构

Fig. 3 Structure of DNN network

设 x 、 y 为随机变量, 其联合概率密度为 $f(x, y)$, 假设 x 的观测值为 x_0 , 对 y 进行求导, 那么 y 对 x 的回归 $E(y|x_0)$ 为

$$E(y|x_0) = \frac{\int_{-\infty}^{\infty} y f(x_0, y) dy}{\int_{-\infty}^{\infty} f(x_0, y) dy}$$

在输入为 x_0 的情况下, y 的输出预测即为 $y(x_0)$ 。执行 Parzen 非参数估计, 得到样本数据集 $\{x_i, y_i\}_{i=1}^n$, 根据式 (2) 估计密度函数 $f(x_0, y)$ 。

$$f(x_0, y) = \frac{1}{n(2\pi)^{\frac{p+1}{2}} \sigma^{\frac{p+1}{2}}} \sum_{i=1}^n \exp(-d(x_0, x_i)) \cdot \exp(-d(y_0, y_i)) \quad (2)$$

式中: n 为样本容量; p 为随机变量 x 的维数; σ 为光滑因子, 即高斯函数的标准差; $d(x_0, x_i)$ 和 $d(y_0, y_i)$ 分别为 x 数据集 x_i 的均方根误差和 y 数据集 y_i 的方差, 即

$$\begin{cases} d(x_0, x_i) = \sum_{j=1}^p [(x_{0j} - x_{ij}) / \sigma]^2 \\ d(y, y_i) = [y - y_i]^2 \end{cases} \quad (3)$$

将式 (3) 的 $d(x_0, x_i)$ 代入密度函数, 并交换

求和与积分顺序, 得

$$y(x_0) =$$

$$\frac{\sum_{i=1}^n (\exp(-d(x_0, y_i)) \int_{-\infty}^{+\infty} y \exp(-d(y_0, y_i)) dy)}{\sum_{i=1}^n (\exp(-d(x_0, y_i)) \int_{-\infty}^{+\infty} \exp(-d(y_0, y_i)) dy)} \quad (4)$$

因为 $\int_{-\infty}^{+\infty} x \exp(-x^2) dx = 0$, 所以化简式 (4)

可得

$$y(x_0) = \frac{\sum_{i=1}^n y \exp(-d(y_0, y_i))}{\sum_{i=1}^n \exp(-d(x_0, y_i))}$$

式中: 分子为所有训练样本算得的 y_i 值的加权和; $\exp(-d(x_0, y_i))$ 为权值。

2.2 GRNN 结构

广义回归神经网络由 4 层构成, 即输入层、模式层、求和层和输出层。设输入层为 $X = [x_1, x_2, \dots, x_n]^T$, 其输出层为 $Y = [y_1, y_2, \dots, y_n]^T$ 。GRNN 结构如图 4 所示。




图 4 GRNN 网络结构

Fig. 4 Structure of GRNN network

2.2.1 输入层

在广义回归神经网络中, 输入层的神经元数量通常等于学习样本中输入向量的维数。每个神经元都是一个简单的分布单元, 其主要作用是将输入变量直接传递到模式层。这意味着输入层的每个神经元对应于输入向量中的一个维度, 其输出直接影响了模式层中的神经元。因此, 输入层在网络中起着将原始输入数据传递到后续层的作用, 为后续层提供必要的输入信息。

2.2.2 模式层

模式层神经元的数目等于学习样本的数目 n , 每个神经元对应不同的样本, 而模式层神经元传递函数为

$$M_i = \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma_1^2} \right] \quad (i = 1, 2, \dots, n)$$

式中: σ_1 为样本标准差; X 为网络输入变量; X_i 为第 i 个神经元对应的学习样本^[4]。

神经元 i 的输出为输入变量与其对应的样本 X 之间欧氏距离平方的指数形式。

2.2.3 求和层

在求和层中, 使用 2 种神经元进行求和。

第 1 种求和公式为

$$\sum_{i=1}^n X_i = \sum_{i=1}^n \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma_1^2} \right]$$

它对所有模式层神经元的输出进行算术求和, 其模式层与各神经元的连接权值为 1, 传递函数为

$$S_D = \sum_{i=1}^n M_i$$

第 2 种求和公式为

$$\sum_{i=1}^n X_i = \sum_{i=1}^n Y_i \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma_1^2} \right]$$

它对所有模式层的神经元进行加权求和, 模式层中第 i 个神经元与求和层中第 j 个分子求和, 神经元之间的连接权值为第 i 个输出样本 Y_i 中的第 j 个元素, 传递函数为

$$S_{Nj} = \sum_{i=1}^n y_{ij} M_i \quad (j = 1, 2, \dots, m)$$

式中: m 为无限值 (因为上式中存在 n , 所以用 m 代指)。

2.2.4 输出层

输出层中的神经元数目等于学习样本中输出向量的维数 m , 各神经元与求和层的输出相除, 神经元 j 的输出对应估计结果 $\hat{Y}(X)$ 中的第 j 个元素, 即

$$y_i = \frac{S_{Nj}}{S_D} \quad (j = 1, 2, \dots, m)$$

3 插值实验

3.1 数据集

以北京市密云区实测高程数据 DEM 为基础^[16], 该数据集包含平原、丘陵、山地等地形, 分辨率为 10 m。由于整个数据集数据量较大, 因此, 本文通过索引切片取出部分区域构造形成新的数据集。原始数据集尺寸为 (6 393, 7 221), 索引区域大小为 200×200 , 数据量为 40 000, 索

引区域为 (2101 : 2301, 5881 : 6081)，包括丘陵、高原和山地等多种地形。训练集、测试集划分为 9 : 1，采用广义回归神经网络算法进行插值精度的分析与评价。

对原始数据集的高程图与索引地形区域的高程图进行可视化绘制，结果如图 5 与图 6 所示。




图 5 密云区高程图像
Fig. 5 Elevation map of Miyun District




图 6 数据集三维高程图像
Fig. 6 3D elevation maps of the dataset

3.2 数据预处理

使用 Python 编程实现广义回归神经网络对高程进行预测的功能，采用 neupy 库中的 Algorithms.GRNN () 函数实现网络的构建，该函数详细参数设置如表 1 所示。

本文采用的数据集是对密云区.tif索引后的地形区域数据集，大小为 200×200，按照 9 : 1 的数量比划分训练集与测试集，即训练样本有 36 000 条数据，测试样本有 4 000 条数据。输入网络的数据格式是 [1, 2] 的坐标，对应的标签数据是该坐

标点对应的高程值。

为了加快模型收敛速度，同时避免模型对输入数据敏感的问题，需要对输入数据进行归一化处理。采用 sklearn 库中的 preprocessing.min-max_scale () 函数对输入数据进行归一化处理，同时为了统一，对应的高程标签值也进行归一化处理。minmax_scale () 变换函数为 min-max 标准化，也称为离差标准化，是对原始数据的线性变换。该函数归一化原理为

$$U_{\text{scaled}} = \frac{U - U_{\min}}{U_{\max} - U_{\min}}$$

表 1 GRNN 参数设置
Tab. 1 GRNN parameters

网络参数	变量设置
std	0.01
verbose	True
Epochs	100
step	0.1
show-epoch	1
Initial learning rate	0.01
train-end-signal	None
epoch-end-signal	None
shuffle-data	True

输入归一化后的输入数据 U_{scaled} 和对应的标签 V ，通过中间节点（隐层点）作用于输出节点，经过非线性变换产生输出信号 V_0 。广义回归神经网络的所有训练样本为输入值 U_{scaled} 、标签 V 、输出值 V_0 以及 V_0 与标签 V 的偏差。通过不断调节隐层与输入节点的连接强度、隐层与输出节点的连接强度以及阈值，可以利用梯度下降的方法来不断调整偏差，以使神经网络在训练过程中逐渐学习并确定最优的权值和阈值，从而使得神经网络的输出结果与实际值之间的误差最小化。

以上就是神经网络的学习过程。通过学习，神经网络能够自动对相似的样本信息进行计算，并输出与输入数据最拟合的结果。这种自动学习的特性使得神经网络在处理各种复杂的问题时具有很强的适应能力和泛化能力，能够处理大量的数据并输出高质量的结果，从而在人工智能领域发挥着重要作用。

3.3 预测精度评价

运行广义回归神经网络法程序时，设置学习

率为 0.01，最大训练数为 100 次。本文采用 GRNN，深度神经网络、双线性插值法、反距离权重法以及 GA+岭回归作为对比插值方法，对地表高程插值得到预测结果，并进行精度验证和评价分析。

本次实验在一台 NVIDIA RTX A6000 服务站上进行，CPU 为 Intel (R) Xeon (R) Gold 6248R CPU @ 3.00 GHz，内存为 384 GB，操作系统为 Windows 10 64 位操作系统，深度学习框架为 Torch 1.10.1，编程语言为 Python 3.8，GPU 框架为 CUDA11.2、Cudnn8.1.1。

采用均方误差 (MSE)、均值绝对误差 (MAE)、总平方和 (SSE)、均方根误差 (RMSE) 以及确定系数 (R-square) 来评价不同算法的预测精度，结果见表 2。其中，MSE、MAE、SSE 和 RMSE 越小越好，R-square 越接近 1 越好。

对比发现，在 5 种方法中，广义回归神经网络算法的均方误差、均值绝对误差、总平方和最小，确定系数最接近 1。说明在样本数据的数目和分布

状况均相同的条件下，广义回归神经网络算法的插值精度最高。通过表 2 中的结果可以看出，DNN 网络的预测效果比较差，确定系数甚至出现了负数的情况，这说明传统的深度学习网络无法完成对高程数据的插值拟合任务，验证了广义回归神经网络比传统的深度神经网络在插值问题上更占据优势。

针对 5 种不同插值方法，选取部分测试数据的真实值和预测值进行对比。图 7~11 分别表示表 2 中 GRNN、双线性插值、GA+岭回归以及 DNN 插值方法的预测误差曲线和散点图。

由图 7~11 可知，数据点的离散程度逐渐变大，广义回归网络方法在整个高程范围内的数据点距拟合线平均距离最近，近似呈线性分布，拟合程度最高。其他方法拟合程度逐渐降低。

综上所述，GRNN 方法拟合程度最高，其插值数据更加接近验证数据，是 5 种方法中最适合该地区进行地形拟合的插值算法。同时，得出传统的深度神经网络不能完成高程数据插值任务的结论。

表 2 不同插值方法精度对比

Tab. 2 Accuracies of different interpolation methods

方法	MSE	MAE	SSE	RMSE	R-square
GRNN	0.000 528	0.017 917	2.136 042	0.022 991	0.989 944
双线性插值	0.002 118	0.036 147	8.470 848	0.046 018	0.959 766
IDW	0.004 959	0.041 993	10.068 085	0.050 966	0.935 918
GA+岭回归	0.019 722	0.117 594	78.890 022	0.140 436	0.659 279
DNN	0.048 667	0.180 035	194.668 498	0.220 606	-1.453 681





图 7 GRNN 插值法预测值与真实值对比

Fig. 7 GRNN interpolation method predicted values versus true values




图 8 双线性插值法预测值与真实值对比

Fig. 8 Bilinear interpolation method predicted values versus true values




图 9 IDW 插值法预测值与真实值对比

Fig. 9 IDW interpolation method predicted values versus true values




图 10 GA+岭回归插值法预测值与真实值对比

Fig. 10 GA+ridge regression interpolation method predicted values versus true values




图 11 DNN 插值法预测值与真实值对比

Fig. 11 DNN interpolation method predicted values versus true values

4 回波模拟实验

4.1 回波模型

4.1.1 回波功率模型

雷达引信回波信号是整个天线波束角照射范围内的大地回波，为一面目标回波。对该面目标作离散化处理，划分为多个散射单元，每个散射单元可以看作一个点目标，将各散射单元的回波矢量叠加则得到面目标回波。设脉冲多普勒引信的脉冲峰值功率为 P_t ，天线对地的增益为 $G_\perp$ ，波长为 λ ，收发共用天线，天线对地高度为 h ，光滑地面的反射系数的幅值为 K 。

1) 回波脉冲的反射功率为

$$P_\perp = \frac{P_t G_\perp^2 \lambda^2}{(4\pi)^2 (2h)^2} T^2 K^2$$

式中： T^2 表示实际地面的反射功率与光滑地面反射功率之比； K 称为菲涅耳反射系数。

2) 回波脉冲的散射功率为

$$P_r = \frac{P_t G^2 \lambda^2 \varepsilon}{(4\pi)^3 R^4}$$

式中： R 表示天线与目标之间的距离； ε 是与目标相关的散射面积； G 视为一个常数。

电磁波以光速传播，接收到的回波行进距离是天线与目标距离的 2 倍，所以回波的时延为

$$\tau = \frac{2R}{c}$$

式中： τ 为回波时延； c 为光速。

由于导弹沿直线高速飞行，回波与目标在径向上会产生频率差，通常称之为多普勒频率^[17-19]，

表达式为

$$f_d = \frac{2v \cos \xi}{\lambda}$$

式中： f_d 为多普勒频率； v 为导弹飞行速度； ξ 为引信飞行方向与目标之间的夹角。

4.1.2 回波散射系数

文献[20]在已有实测数据的基础上，解出了回波散射系数的解析表达式为

$$\sigma_0(\delta) = \frac{\alpha^2 \delta}{4\pi \mu^2 \sin \delta} \exp\left(-\frac{\alpha^2}{4\mu^2} \tan^2 \delta\right) \quad (5)$$

式中： α 表示散射单元的水平相关距离； μ^2 表示相对平均地面高度起伏方差； δ 表示波束相对照射点的入射角。

文献[21]考虑地面极化和吸收的影响，引入实际散射分量相对完全散射比例因子 $(1-K^2)$ 和影响因子 β ，将式 (5) 修正为

$$\sigma_0(\delta) = \beta (1-K^2) \frac{\alpha^2 \delta}{4\pi \mu^2 \sin \delta} \exp\left(-\frac{\alpha^2}{4\mu^2} \tan^2 \delta\right)$$

4.1.3 散射单元模型

对于每一个散射单元，入射角并不相同，图 12 展示了不同散射单元时入射角的求法。其中：照射点 A 的坐标为 (e, q, z) ， R 、 h 分别表示天线与目标之间的距离和天线距离地面的高度。入射角 δ 和距离 R 分别为

$$\delta = \frac{\pi}{2} - \arctan\left(\frac{h-z}{\sqrt{e^2+q^2}}\right)$$

$$R = \sqrt{e^2+q^2+(h-z)^2}$$

4.1.4 地形遮挡模型

对照射区域逐点进行可视性判断，图 13 为视

线与地形所成的剖面图, 该剖面表示 eOq 切面, 横轴表示地面平面距离, 纵轴 z 表示地面起伏高度。




图 12 散射单元模型

Fig. 12 Scattering unit model





图 13 照射区域剖面

Fig. 13 Section of the exposure area


在 x 轴上等距离取点, 各点在地形剖面图上对应的高程值已知, 设 A_0 为视点, 且 A_0 点的坐标为 $(0, z_0)$, A_{i-1} 的坐标为 (e_{i-1}, z_{i-1}) , A_i 的坐标为 (e_i, z_i) , 其中 $1 < i < k$ 。

由图 13 可知, 可以根据 A_0A_{i-1} 和 A_0A_i 所在直线的斜率来判断目标点的可视性。


$$k_{A_0A_{i-1}} = \frac{z_{i-1} - z_0}{e_{i-1}}$$



(a) 未插值



(b) DNN插值法



(c) 反距离加权法

$$k_{A_0A_i} = \frac{z_i - z_0}{e_i}$$

在 A_{i-1} 可视的情况下, 若 A_0A_i 所在直线的斜率大于 A_0A_{i-1} 所在直线的斜率, 则 A_i 可视; 反之, A_i 不可视。在 A_i 可视的情况下, 将 A_i 作为新的 A_{i-1} 点, 继续判断下一点的可视性。在 A_i 不可视的情况下, 仍以 A_{i-1} 为基准点直至找出后面的第一个可视点作为新的 A_{i-1} 。通过此方法将划分的剖面区域目标点的可视性判断完毕后, 扫描整个地形区域完成可视搜索, 最后把所有可视点的回波相加得到该区域的总回波。

4.2 仿真实验

本文实验仿真参数设置如下: 雷达引信高度为 3 000 m, 波束宽度为 $\pi/3$, DEM 初始分辨率为 10 m, 天线波束照射角度为 0° , 此时地面网格数目为 174×174 。经过一次插值后的 DEM 数据分辨率为 5 m, 此时地面网格数目为 348×348 。在波束垂直照射、不考虑地形遮挡的情况下, 未插值和采用 DNN 插值法、反距离插值法、遗传算法结合岭回归插值法、双线性加权法、GRNN 插值法 5 种插值算法的回波如图 14 所示。在波束垂直照射、考虑地形遮挡的情况下, 未插值和采用 DNN 插值法、反距离插值法、遗传算法结合岭回归插值法、双线性插值法、GRNN 插值法 5 种插值算法的回波如图 15 所示。

观察图 15 可知: 有遮挡时峰值功率的大小与未遮挡时基本存在相同的变化规律; 在有遮挡条件下, 尽管存在个别峰值功率大于无遮挡条件下的峰值功率, 但是整体小于无遮挡回波的值且差异较小。这是因为在垂直照射地面时, 地形的起伏会对波束照射产生遮蔽作用, 又因为波束照射角度为 0° , 所以地形遮蔽对回波的影响差异不大。通过对比可以看出, 采用双线性插值算法和广义回归神经网络插值算法能够更加细致地反映出回波的起伏状况。




图 14 无遮挡回波模拟

Fig. 14 Unobstructed echo simulation




图 15 有遮挡回波模拟

Fig. 15 Obstructed echo simulation

5 结论

本文将DEM插值算法应用到地形建模中,提出一种基于广义回归神经网络插值的回波模拟算法,与其他插值算法的精度进行对比,之后进行了插值实验和回波模拟实验。可以得出以下结论:

1) 广义回归神经网络算法的插值精度最高,传统的深度神经网络不能有效地完成高程数据插值任务;

2) 双线性插值算法和广义回归神经网络的预测精度高,基于这两种算法的回波模拟分布规律相近,能够清晰描述回波起伏细节;

3) 有遮挡时的回波功率整体小于无遮挡时的

回波功率;

4) GRNN方法具有收敛快与非线性逼近的优势,但是存在计算复杂度高(每个测试样本要与全部的训练样本进行计算)以及空间复杂度高(因为没有模型参数,对于测试样本全部的训练样本都要参与计算,因此需要存储全部的训练样本)的问题,下一步在保证高插值精度的前提下针对如何降低时间复杂度和空间复杂度展开研究。

参考文献:

- [1] 王旭. 脉冲多普勒引信体目标回波模拟及信号处理[D]. 南京: 南京理工大学, 2017: 54-59.
WANG X. Pulse Doppler fuze target echo simulation and signal processing[D]. Nanjing: Nanjing University of Science & Technology, 2017: 54-59.

- [2] LI L, NEARING M A, NICHOLS M H, et al. The effects of DEM interpolation on quantifying soil surface roughness using terrestrial LiDAR[J]. *Soil and Tillage Research*, 2020, 198: 104520.
- [3] GU T F, LI J, WANG M G, et al. Landslide susceptibility assessment in Zhenxiong County of China based on geographically weighted logistic regression model[J]. *Geocarto International*, 2022, 37(17): 4592-4973.
- [4] HABIB M. Evaluation of DEM interpolation techniques for characterizing terrain roughness[J]. *Catena*, 2021, 198: 105072.
- [5] 高超, 金高洁. SWIM水文模型的DEM尺度效应[J]. *地理研究*, 2012, 31(3): 399-408.
GAO C, JIN G J. Effects of DEM resolution on results of the SWIM hydrological model in the Changtaiguan basin[J]. *Geographical Research*, 2012, 31(3): 399-408.
- [6] 齐晓飞. DEM误差可视化方法的研究与实践[D]. 郑州: 解放军信息工程大学, 2011: 14-23.
QI X F. Research and practice of the visualization method of DEM error[D]. Zhengzhou: PLA Information Engineering University, 2011: 14-23.
- [7] 齐晓飞, 王光霞, 崔秀飞, 等. DEM误差可视化方法分析与研究[J]. *测绘科学*, 2011, 36(3): 169-171.
QI X F, WANG G X, CUI X F, et al. Analyse and study of visualization method on DEM errors[J]. *Science of Surveying and Mapping*, 2011, 36(3): 169-171.
- [8] 黄长军, 夏红梅, 杜梓维. 南方典型丘陵区域DEM高程插值方法研究[J]. *湖南城市学院学报(自然科学版)*, 2018, 27(3): 1-6.
HUANG C J, XIA H M, DU Z W. Discussion on different DEM interpolation methods in typical hilly area in southern China[J]. *Journal of Hunan City University (Natural Science)*, 2018, 27(3): 1-6.
- [9] 马翔, 黄要武. 几种常用高程插值方法的比较[J]. *江西测绘*, 2012(1): 51-53.
- [10] 朱添翼, 王昶. DEM内插方法的研究与分析[J]. *北京测绘*, 2014(6): 16-19.
ZHU T Y, WANG C. Research and analysis of DEM interpolation method[J]. *Beijing Surveying and Mapping*, 2014(6): 16-19.
- [11] 陈天伟. 最大熵模型结合遗传算法解算DEM插值权重系数[J]. *测绘科学*, 2017, 42(1): 25-28.
CHEN T W. Calculation of DEM's interpolation weight modulus with model of maximum entropy and genetic algorithm[J]. *Science of Surveying and Mapping*, 2017, 42(1): 25-28.
- [12] 贾相苹. 基于线性最大熵原理的空间数据内插建模研究[D]. 桂林: 桂林理工大学, 2023: 15-21.
JIA X P. Research on spatial data interpolation modeling based on linear maximum entropy principle[D]. Guilin: Guilin University of Technology, 2023: 15-21.
- [13] BINH T Q, THUY N T. Assessment of the influence of interpolation techniques on the accuracy of digital elevation model[J]. *VNU Journal of Science, Earth Sciences*, 2008, 24(4): 176-183.
- [14] 张洁, 段平. 地形因子对反距离加权插值方法(IDW)最优距离指数的影响分析[J]. *地理科学*, 2023, 43(7): 1281-1290.
ZHANG J, DUAN P. Influence of terrain factors on optimal order distance of inverse distance weighted (IDW)[J]. *Scientia Geographica Sinica*, 2023, 43(7): 1281-1290.
- [15] 侯顺虎, 方胜良, 曾庆尧, 等. 基于RIS的元素分组面状全连接网络[J]. *系统仿真学报*, 2024, 36(4): 1017-1027.
HOU S H, FANG S L, ZENG Q Y, et al. Element grouping faceted fully connected network based on RIS[J]. *Journal of System Simulation*, 2024, 36(4): 1017-1027.
- [16] 王磊, 孙文俊. 基于DEM数据的HEC-HMS和Vflo降雨特征模拟对比研究: 以北京密云区为例[J]. *环境科学学报*, 2019, 39(10): 3559-3564.
WANG L, SUN W J. Research on HEC-HMS and Vflo rainfall characteristics simulation and comparative based on DEM data: A case of Miyun district, Beijing[J]. *Acta Scientiae Circumstantiae*, 2019, 39(10): 3559-3564.
- [17] ROLDAN I, DEL-BLANCO C R, DUQUE DE QUEVEDO Á, et al. DopplerNet: A convolutional neural network for recognizing targets in real scenarios using a persistent range-Doppler radar[J]. *IET Radar, Sonar & Navigation*, 2020, 14(4): 593-600.
- [18] ZHANG X W, ZUO L, YANG D D, et al. Coherent-like integration for PD radar target detection based on short-time Fourier transform[J]. *IET Radar, Sonar & Navigation*, 2020, 14(1): 156-166.
- [19] ABOUZAIID S H, AHMAD W A, EIBERT T F, et al. Vital signs monitoring using pseudo-random noise coded Doppler radar with Delta-Sigma modulation[J]. *IET Radar, Sonar & Navigation*,

- 2020, 14(11): 1778-1787.
- [20] EDISON A R, MOORE R K, WARNER B D. Radar terrain return measured at near-vertical incidence[J]. IRE Transactions on Antennas and Propagation, 1960, 8(3): 246-254.
- [21] 朱晓菲, 李东, 沈晓卫, 等. 天线主瓣照射区多普勒谱分布规律研究[J]. 电光与控制, 2021, 28(1): 52-55, 85.
- ZHU X F, LI D, SHEN X W, et al. Doppler spectrum distribution law in the area radiated by antenna mainlobe[J]. Electronics Optics & Control, 2021, 28(1): 52-55, 85.