

DOI:10.19322/j.cnki.issn.1006-4710.2021.01.014

GANs 与 GRBFNN 在空间插值中的对比分析

刘 鑫¹, 韩宇平¹, 黄会平²

(1. 华北水利水电大学 水利学院, 河南 郑州 450046; 2. 华北水利水电大学 测绘与地理信息学院, 河南 郑州 450046)

摘要: 为了进一步提高空间插值的精度, 搭建生成对抗网络(GANs)、最小二乘生成对抗网络(LSGANs)及 Gauss 径向基神经网络(GRBFNN)。使用国家气象科学数据网 1960—2013 年 619 个气象站点数据的平均值, 将上述 3 种深度学习模型对降水量和平均气温的插值结果与普通 Kriging (OK) 及反向距离加权(IDW)的插值结果进行对比分析, 并进行交叉验证。结果表明: 全国气象站点降水量和平均气温数据的空间插值中, IDW 法优于 OK 法。当训练样本较多时, LSGANs 模型空间插值表现最好; 当训练样本数量较少时, GRBFNN 的插值精度最高。高程对平均气温的插值精度影响较大, 对降水量的插值精度影响较小。LSGANs 和 GRBFNN 深度学习模型有助于拓展空间插值的思路和应用范围, 具有很好的前景。

关键词: 生成对抗网络; 最小二乘生成对抗网络; Gauss 径向基神经网络; 深度学习模型; 交叉验证; 空间插值

中图分类号: TV11

文献标志码: A

文章编号: 1006-4710(2021)01-0096-09

Comparative analysis of GANs and GRBFNN in spatial interpolation

LIU Xin¹, HAN Yuping¹, HUANG Huiping²

(1. College of Water Conservancy, North China University of Water Resources and Electric Power, Zhengzhou 450046, China; 2. College of Surveying and Geo-informatics, North China University of Water Resources and Electric Power, Zhengzhou 450046, China)

Abstract: In order to further improve the accuracy of spatial interpolation, generative adversarial networks (GANs), least squares generative adversarial networks (LSGANs) and gaussian radial basis neural network (GRBFNN) are built. The average data of 619 meteorological stations from 1960 to 2013 of the National Meteorological Science Data website are used, the interpolation results of precipitation and average temperature of the above three deep learning models are compared with those of ordinary Kriging (OK) and inverse distance weighted (IDW), and the cross-validation is also performed. The results show that the IDW method is better than the OK method in the spatial interpolation of precipitation and average temperature data of national meteorological stations. When there are plenty of training samples, the LSGANs model performs best in spatial interpolation. When the number of training samples is small, the interpolation accuracy of GRBFNN is the greatest. Elevation has a greater influence on the interpolation accuracy of average temperature, and a smaller influence on the interpolation accuracy of precipitation. Using LSGANs and GRBFNN deep learning models help to expand the spatial interpolation ideas and application range, and have a good prospect.

Key words: generative adversarial networks; least squares generative adversarial networks; gaussian radial basis neural network; deep learning models; cross-validation; spatial interpolation

收稿日期: 2020-06-01; 网络出版日期: 2020-08-31

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1294.N.20200831.1538.002.html>

基金项目: 水利部“948”计划资助项目(201328); 国家自然科学基金资助项目(51709107)

第一作者: 刘鑫, 男, 博士生, 研究方向为水资源信息化。E-mail: 153508240@qq.com

通信作者: 韩宇平, 男, 博士, 教授, 研究方向为水资源系统工程。E-mail: hanyup@ncwu.edu.cn

目前气象数据主要来自气象站的直接观测,具有局部性与离散性等特点,利用空间插值的方法可以根据已知气象站的数据估计那些没有气象站但知道经度、纬度及高程的位置的特征。空间插值的方法很多,不同的插值方法结果差别可能较大,在实际应用中并不存在一种普适性的插值方法。常用的空间插值方法主要有普通 Kriging 法(Ordinary Kriging, OK)^[1-2] 和反向距离加权法(Inverse Distance Weighted, IDW)^[3-4] 等。OK 法在 Kriging 插值方法中应用最广泛,通过对已知样本加权平均估计平面上的未知点,而加权平均势必要对数据做平滑处理,会削弱变量的自然属性,从而不能较好地表现非线性特征数据的空间分布。IDW 法以插值点与样本点间的距离为权重进行加权平均,该方法要求离散点均匀分布。

人工神经网络(Artificial Neural Network, ANN)处理非线性数据的能力较强^[5],且不依赖数据分布和假设,因此 ANN 模型被广泛应用于空间插值^[6]。徐英等^[7]利用 Bayes 最大熵融合 Bayes 人工神经网络,在农田土壤水分和养分的空间插值中取得了较好结果。但是 ANN 学习能力不足,在纯数据驱动模式下建立数据之间的映射关系,ANN 容易过度拟合^[8-9]。此外 ANN 只是在输入与输出之间建立映射关系,没有对该映射关系进行优劣评价。虽然 ANN 也得到一定的改进和完善,但是性能的提升却比较有限。近些年深度学习模型的出现为数据插值处理提供了新的思路,如径向基网络^[10-11]、长短时记忆循环神经网络^[12-13]及生成对抗网络^[14-15]等展示了出色的性能,在预报预测及空间插值等领域取得了较好的结果。

本研究搭建深度学习模型生成对抗网络(Generative Adversarial Networks, GANs),最小二乘生成对抗网络(Least Squares Generative Adversarial Networks, LSGANs)及 Gauss 径向基神经网络(Gaussian Radial Basis Function Neural Network, GRBFNN),期望通过博弈及局部逼近提高降水量和平均气温的插值精度。为了验证 GANs、LSGANs 及 GRBFNN 模型在空间插值中的优劣,我们选择 OK 和 IDW 法作为基准方法,将 GANs、LSGANs 及 GRBFNN 的插值结果与基准方法的插值结果进行对比分析,并进行交叉验证。结果表明:

$$\begin{cases} BCELoss = \text{mean}(L), L = \{l_1, l_2, \dots, l_N\}^T, \\ l_i = -\frac{1}{n} \sum [y_i \times \ln x_i + (1 - y_i) \times \ln(1 - x_i)], i = 1, 2, \dots, N \end{cases} \quad (1)$$

式中:样本标签 y 的范围是 $0 \sim 1$, y_i 是目标样本第 i 个

IDW 法比 OK 法更适合对空间数据进行插值;LSGANs 和 GRBFNN 的插值精度优于 IDW 法,有利于拓展空间插值的应用范围,具有很好的应用前景。

1 研究区与数据

本研究以国家气象科学数据网 1960—2013 年 619 个气象站点数据的平均值为例进行实验。

数据包括经度、纬度、高程、相对湿度、降水量、平均风速、气压、平均气温及日照时数。数据样本覆盖中国的海河流域、黄河流域、淮河流域及长江流域等多个流域;涵盖 31 个省级行政区,包括西藏和青海等高海拔地区、新疆和甘肃等干旱半干旱地区,也包括南方的湿润半湿润地区。研究区涵盖不同地形、不同海拔及不同气候等各种复杂条件。

在实际应用中,我们得到的样本数据是多个维度的,且这些数据可能存在有不符合要求,以及不能直接进行分析的数据,需要经过数据清洗才可以满足模型构建的要求。因此,首先根据箱图筛选出异常值(离群点),将异常值删除后,对全部缺失值进行插补,插补方法使用 Lagrange 法。其次,样本数据的量纲和数值存在很大差别。为了消除每个维度之间的量纲与数值的影响,模型训练前要进行数据的标准化处理,使得不同的维度具有相同的尺度,从而解决维度之间的可比性。测试时再全部映射回原始值。

2 研究方法

2.1 生成对抗网络(GANs)

自动编码解码器最开始是一种数据的压缩方法,使用神经网络模型作为编码器和解码器,得到了较广泛的应用^[16-17]。编码器慢慢演变成了生成对抗网络的生成网络。生成对抗网络与自动编码解码器最大的区别就是多一个判别网络,自动编码解码器是通过对比输入输出矩阵之间的差异计算损失函数,而生成对抗网络则通过判别网络与生成网络的博弈来更新模型参数,这也是生成对抗网络效果要更好的根本原因。判别网络就是一个判别真假的判别器,相当于完成的是一个二分类的任务。因此,判别网络的损失函数是二分类的交叉熵(Binary Cross Entropy, BCE):

标签; x_i 是输入矩阵的第 i 个值;输入输出矩阵都是

(N, n) , N 是批的大小, n 表示特征的维度; 函数 mean 表示求平均值。生成对抗网络的结构见图 1。

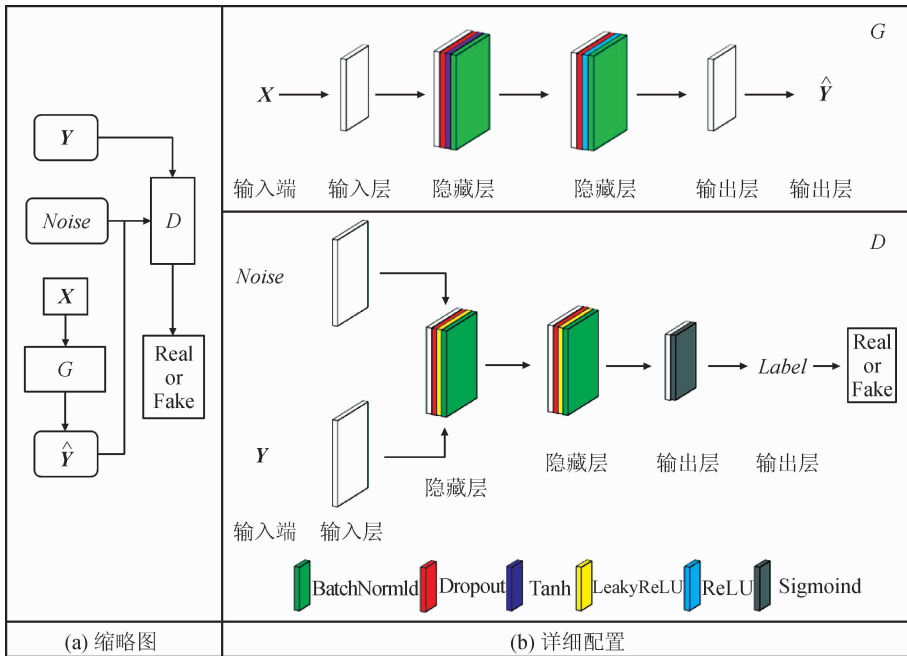


图 1 GANs 的缩略图与详细配置

Fig. 1 Thumbnail and detailed configuration of GANs

生成对抗网络由两部分组成:生成网络 G 与判别网络 D 。输入观测数据时希望 D 的输出结果是 Real(值为 1),输入噪声时希望 D 的输出结果是 Fake(值为 0)。这跟原始数据的标签没有关系,不管原始数据包含几个类别,只要是观测数据,输出标签是 1,非观测数据的标签是 0。生成对抗网络的对抗过程就是生成网络与判别网络的“博弈”过程,掌握观测数据的 D 不断地对观测数据与生成数据进行判别来更新自身,而 G 也通过不断寻优,希望产生的生成数据通过 D 的输出为 1,能够“欺骗” D ,即 G 生成的数据能够被判别为真。

由图 1 可知,将噪声 $Noise$ 和观测数据 Y 同时导入 D , Y 的 $Label$ 是 Real,噪声的 $Label$ 是 Fake,然后将输入矩阵 X 导入 G ,输出生成数据 \hat{Y} ,然后将 \hat{Y} 也导入 D 进行判别,期望得到的 $Label$ 是 Real。

BatchNorm1d 是批标准化操作,作用于隐藏层,目的是上一层的输出进行标准化以后再传入下一层。这是因为数据经过这一层网络计算后,数据的分布会发生变化,如果不进行标准化,会增加下一层网络学习的困难,还可能导致梯度消失的问题。Dropout 是引入集成学习的思想,将网络中的隐藏层设置为非全连接的,即随机切断某两个神经元之间的连接,旨在训练模型的时候,每层以一定概率 P 丢弃每个神经元,也就是每次训练的时候有些神经元是没有建立连接的。这样每一次训练之后,训练

好的模型都可以看成是一个新的模型,然后训练结束以后,最终模型就可以看成是这些新模型的集成。这样可以增加模型的随机性,本研究取 $P=0.3$ 。模型中的算法、激活函数及优化器等需要人工设置值的参数,都是根据以往大量的计算、训练及验证经验得出的。

G 的隐藏层中先使用 Tanh 激活函数(式(2)),将数据映射到 $(-1, 1)$,输出变成了 0 均值,后使用 ReLU 激活函数(见式(3)),简单地将大于 0 的部分保留,将小于 0 的部分变成 0,因为它是线性的且参数更新过程中不存在梯度消失的问题。

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \in (-1, 1) \quad (2)$$

$$\text{ReLU}(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \in [0, +\infty) \quad (3)$$

D 中使用 LeakyReLU 激活函数(见式(4)),这个函数解决了神经饱和问题,它不再是简单的舍弃小于 0 的部分,而是以一定的斜率留下小于 0 的部分,可以保证神经元不死。最后输出结果时使用 Sigmoid 激活函数(见式(5)),将结果映射到 $(0, 1)$ 。

$$\text{LeakyReLU}(x) = \max(0, x) + slope \times \min(0, x) \quad (4)$$

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \in (0, 1) \quad (5)$$

式中: $slope$ 在本研究设置为 0.2。

本研究从 619 个气象站点中按照 7 : 3 的比例

进行随机抽样组成训练集和测试集。生成对抗网络训练时较难把握 D 和 G 的训练程度,因此将每轮训练按批进行,以增加生成数据的多样性,本文设置批的大小为 35。对于每一批数据的迭代,采用训练 4 次 D 再训练 8 次 G 的方式,来解决 D 和 G 之间的同步问题。先训练 D 优化更新 D 的参数,使它能够正确地判别出 Y 和 $Noise$ 。再训练 G ,此时将 D 的参数固定,通过反向传播优化 G 的参数。更新 G 的参数时不能同时更新 D ,否则 G 永远无法骗过 D 。最终希望 G 生成的数据在经过 D 的输出是 1。更新 D 是为了将 \hat{Y} 判别为 0,而更新 G 是为了能让 \hat{Y} 被判别为 1。

优化函数使用自适应矩估计优化器 Adam(Adaptive Moment Estimation)。本研究取 Adam 的 β_1, β_2 为 0.9 和 0.999。为了避免模型收敛到一定程

$$V(G, D) = E_{x \sim P_{\text{real}(x)}} [\ln D(x)] + E_{x \sim P_{G(x)}} [\ln(1 - D(G(x)))] \quad (6)$$

$$\begin{cases} \text{For } D \text{ and } f(x), \begin{cases} D(x) \rightarrow 1 \\ D(G(x)) \rightarrow 0 \end{cases} \Rightarrow \begin{cases} \ln(D(x)) \rightarrow 0 \\ \ln(1 - D(G(x))) \rightarrow 0 \end{cases} \\ \text{For } G, \ln(1 - D(G(x))) \rightarrow \infty \end{cases} \quad (7)$$

$$V(x) = \int_x [P_{\text{real}}(x) \ln D(x) + P_G(x) \ln(1 - D(x))] dx \quad (8)$$

将数学期望 $E(x)$ 表示成微积分的形式,可以将 V 变为式(7)。对于这个积分,要取它的最大值,就是希望对于给定的 x ,积分里面的项是最大的,即计算出一个最优的 D 使得积分里面的项最大化。通

$$\max V(G, D^*) = \int_x P_{\text{real}}(x) \ln \frac{P_{\text{real}}(x)}{P_{\text{real}}(x) + P_G(x)} dx + \int_x P_G(x) \ln \frac{P_G(x)}{P_{\text{real}}(x) + P_G(x)} dx \quad (10)$$

式中: G 是生成网络; $P_{\text{real}}(x)$ 是观测数据的概率分布; $P_G(x)$ 是生成数据的概率分布; E 是期望值。

$$\max V(G, D^*) = -2 \log 2 + \int_x P_{\text{real}}(x) \ln \frac{P_{\text{real}}(x)}{(P_{\text{real}}(x) + P_G(x))/2} dx + \int_x P_G(x) \ln \frac{P_G(x)}{(P_{\text{real}}(x) + P_G(x))/2} dx \quad (11)$$

式(11)中,如果两种分布没有重叠部分,或者重叠部分可以忽略,对于不重叠的部分 x 的取值, $P_{\text{real}}(x) = 0$ 或者 $P_G(x) = 0$,则代价函数恒等于常数,即使两种分布很接近,但是只要它们没有重叠,代价函数就是常数,这会导致梯度为 0 无法更新。而通过大量实验发现,梯度为 0 的概率较大,即真实分布与生成分布没有重叠部分的概率较大。除此之外,如果 D 训练太好, G 梯度消失非常严重。如果 D 训练地不好, G 很容易欺骗 D ,则 G 可能产生错误的优化方向。如果希望 GANs 较好收敛,需要 D 训练地不好也不坏,而这个程度很难把握。因此,GANs 的训练非常困难。

度时会出现震荡现象,使得模型不能较好地持续收敛,本研究采用动态学习率,初始学习率设置为 0.000 2,且在训练的过程中设定监视器,实时检测误差的变化。当模型误差持续减小时不对学习率进行更新。当误差反弹时不立即更新学习率,而是等待 200 次训练后将学习率乘 0.9,再等待 200 次训练之后重新启动监视器,一直到两次更新后的学习率的差小于 10^{-8} 时关闭监视器。

对于与观测数据非常相似的数据,我们希望 D 的输出能够趋近于 1,对于不相似的数据,我们希望 D 的输出趋近于 0。对于 \ln 函数,在 $(0, 1]$ 上获得的最大值就是 0。通过将 $Noise$ 不断输入 D ,目的就是将与观测数据不相似的数据全部判别为 0 或者趋近于 0,而希望 $D(G(x))$ 被判别为 1 或者趋近于 1,使得代价函数 V 趋近于最小值,使用期望求最值。

过对 D 求导可以得到 D^* ,将 D^* 代回 V 中。

$$D^*(x) = \frac{P_{\text{real}}(x)}{P_{\text{real}}(x) + P_G(x)} \quad (9)$$

概率密度在整个域的积分等于 1,即 $\int P(x) dx = 1$,可变形为下面的公式:

2.2 最小二乘生成对抗网络(LSGANs)

最小二乘生成对抗网络(LSGANs)^[18-19],是把交叉熵损失函数换成最小二乘损失函数,期望构建一个更加稳定收敛更快且生成质量更高的模型。GANs 的判别网络在输出结果前使用了 Sigmoid 激活函数。很显然 Sigmoid 有一个很显著的特点就是将输出结果划分到 0 或者 1,这在分类任务中是很有效的,因为分类任务的目的是将目标的种类进行划分,而目标的种类不是 0 就是 1(二分类)。但是生成对抗网络的目的是生成对抗样本,让 D 和 G 进行博弈,二分类没办法衡量这个 G 到底好不好。而 LSGANs 把二分类问题变成了求损失的问题,这就

更好地为生成模型找准了寻优方向,解决了 GANs 训练困难及生成样本质量不高的问题,且 LSGANs

训练过程十分稳定。LSGANs 的最小代价如下:

$$\min V_{\text{LSGANs}}(D) = \frac{1}{2} E_{x \sim P_{\text{real}}(x)} [(D(x) - a)^2] + \frac{1}{2} E_{x \sim P_G(x)} [(D(G(x)) - b)^2] \quad (12)$$

$$\min V_{\text{LSGANs}}(G) = \frac{1}{2} E_{x \sim P_G(x)} [(D(G(x)) - c)^2] \quad (13)$$

式中: $a=c=1, b=0$ 。模型仍采用 Real(1)和 Fake(0)标签,但不做分类而是求损失。

2.3 Gauss 径向基神经网络(GRBFNN)

Gauss 径向基神经网络(GRBFNN)^[20-21]是比较理想的非线性神经网络(见图2)。由于 GRBFNN 是局部逼近网络,对于输入空间的某个局部区域只有少数几个连接权值影响输出,不仅继承了 ANN 的优点,还在一定程度上克服了 ANN 需要调整每一个权值从而导致学习速度慢的缺点。GRBFNN 的分类能力和学习速度都优于 ANN。此外 GRBFNN 结构简单、训练简洁、收敛速度快,能在一定程度上克服过拟合和局部极小值问题。

隐藏层对输入矢量进行变换,将输入数据变换到高维空间内,使得在低维空间内线性不可分问题在高维空间内线性可分,这样就可以将输入矢量不通过权连接,直接映射到隐藏层空间。当 RBF 的中心点确定以后,这种映射关系也就确定了。而隐藏层到输出层的映射是线性的,即网络输出是线性加权和,此处的权即为网络的可调参数。

见图2, $(x_1, x_i, \dots, x_n)^T$ 是输入端, $(X_1, X_i, \dots, X_n)^T$ 是输入层, $(h_1(x), h_i(x), \dots, h_n(x))^T$ 是隐藏层, $(W_1, W_i, \dots, W_n)^T$ 是隐藏层到输出层的连接权重, $f(x)$ 是输出层,最后 Y 是输出端。输入层到隐藏层的数据变换是非线性的。通过径向基变换之后,将这些结果进行线性加权求和就可以得到 GRBFNN 的输出,其中激活函数选择为 Tanh 和 ReLU,优化器是 Adam,参数设置同上。

OK 和 IDW 法有非常多的公开资料可查,本研究不再叙述,直接利用 ARCGIS10.2 实现 OK 和 IDW 的插值。GANs、LSGANs 和 GRBFNN 深度学习模型使用 PyTorch 实现。PyTorch 是 Python 的深度学习框架,该框架具有非常强的灵活性及易用性。

2.4 评价标准

本研究评价标准采用均方根误差 RMSE(Root Mean Square Error)和 Nash 效率系数 NSE(Nash-Sutcliffe Efficiency Coefficient)。其计算公式为:

$$RMSE = \sqrt{\frac{\sum (\mathbf{Y} - \hat{\mathbf{Y}})^2}{n}} \quad (19)$$

$$NSE = \left\{ 1 - \left[\frac{\sum (\mathbf{Y} - \hat{\mathbf{Y}})^2}{\sum (\mathbf{Y} - \bar{y})^2} \right] \right\} \times 100\%, \quad \bar{y} = \frac{\sum \mathbf{Y}}{n} \quad (20)$$

式中: \mathbf{Y} 是观测值矩阵; $\hat{\mathbf{Y}}$ 是估计值矩阵; \bar{y} 是观测值的平均值; n 是样本总量。其中,矩阵与矩阵的计算采用深度学习中矩阵的运算法则,矩阵与标量的计算是矩阵全部元素都与标量做一次运算。

RMSE 体现的是估计值与观测值的绝对偏离程度,反应了估计值与观测值的误差。RMSE 越小,估计值和观测值之间的误差就越小。NSE 系数常用于评估模型的预测能力,代表了插值的吻合度。

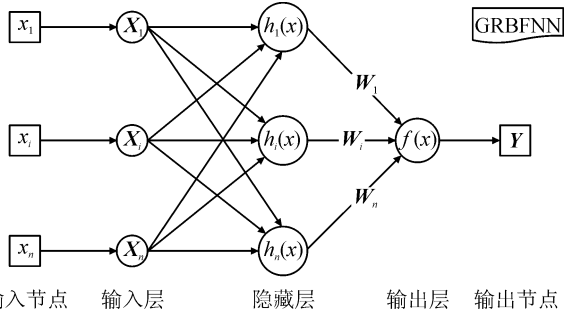


图2 GRBFNN 的缩略图

Fig.2 Thumbnail of GRBFNN

径向基(RBF)是延径向对称取值仅依赖于到中心点距离的实值函数,通常定义为空间任意点 x 到中心 c 之间的欧式距离,可以记作 $dist$ 。然后对 $dist$ 做一个函数变换,本研究采用 Gauss 函数,将这个距离函数套入 Gauss 函数中,得到 Gauss 径向基函数 $h(x)$,详见下列公式:

$$dist = \|x - c\| \quad (14)$$

$$\phi(dist) = \phi(\|x - c\|) \quad (15)$$

$$h_i(x) = h(x, c_i) = e^{-\frac{\|x - c_i\|^2}{2\sigma^2}}, i = 1, 2, 3, \dots, n \quad (16)$$

$$f(x) = \sum_{j=1}^n W_j h_j(x), j = 1, 2, 3, \dots, n \quad (17)$$

$$output = w_0 + f(x) \quad (18)$$

式中: $\|x - c_i\|^2$ 是空间任意一点到中心点的欧式距离; σ 是方差; $h(x, c_i)$ 是 Gauss 核函数, c_i 是核函数中心; $h_i(x) = h(x, c_i)$; w_0 是线性变换的截距。

GRBFNN 用 RBF 作为“基”构成隐藏层空间,

NSE 等于 100% 表示估计值与观测值完全吻合。估计值越接近真实值, NSE 就接近 100%。

3 结果与分析

3.1 5 种方法插值精度的对比分析

分别应用上述方法建立 GANs、LSGANs 和 GRBFNN 深度学习模型, 将 3 个模型的插值结果与基准方法进行对比。表 1 给出了 5 种方法对降水量插值的结果。

表 1 降水量的插值结果对比

Tab. 1 Comparison of interpolation results of precipitation

方法	RMSE	NSE/%
OK	136.62	91.73
IDW	128.07	92.74
GANs	二维输入	133.97
	三维输入	191.78
LSGANs	二维输入	116.34
	三维输入	161.84
GRBFNN	二维输入	120.59
	三维输入	118.62

因为 619 个气象站点的高程值存在一定差别, 为了探讨高程对于降水量和平均气温插值的影响, 应用 3 个深度学习模型时分别采用两种方式建模, 二维输入代表使用经度和纬度建模, 三维输入代表使用经度、纬度和高程进行建模。

由表 1 可知, IDW 法的 RMSE 和 NSE 都优于 OK 法。与三维输入相比, 使用二维输入, GANs 的 RMSE 减小 30.14%, NSE 提高 8.34%; LSGANs 的 RMSE 减小 28.11%, NSE 提高 5.61%。GANs 和 LSGANs 的二维输入的估值精度明显高于三维输入, 可见在降水量的插值中, GANs 和 LSGANs 对于高程比较敏感。与 IDW 法相比, 使用二维输入, LSGANs 的 RMSE 减小 9.16%, NSE 提高 1.27%; GANs 的 RMSE 和 NSE 虽然优于 OK 法, 但却不如 IDW 法。对于 GRBFNN, 二维输入与三维输入的估值精度相差不大, 可见在降水量插值中 GRBFNN 对高程不敏感。使用三维输入的 GRBFNN 比 IDW 的 RMSE 减小 7.38%, NSE 提高 1.03%。5 种方法精度最高的是 LSGANs。

表 2 给出了 5 种方法对平均气温进行插值的结果。结果表明, IDW 法的 RMSE 和 NSE 都优于 OK 法。与二维输入相比, 使用三维输入, GANs 的 RMSE 减小 28.10%, NSE 提高 5.06%; LSGANs 的 RMSE 减小 49.78%, NSE 提高 8.83%;

GRBFNN 的 RMSE 减小 47.86%, NSE 提高 11.5%。GANs、LSGANs 及 GRBFNN 模型使用三维输入的估值精度高于二维输入, 可知在平均气温的插值中, 3 个深度学习模型对高程都比较敏感。与 IDW 相比, 使用三维输入, GANs 的 RMSE 减小 18.38%, NSE 提高 2.71%; LSGANs 的 RMSE 减小 39.46%, NSE 提高 5.16%; GRBFNN 的 RMSE 减小 27.57%, NSE 提高 3.89%。

表 2 平均气温的插值结果对比

Tab. 2 Comparison of interpolation results of average temperature

方法	RMSE	NSE/%
OK	1.92	91.25
IDW	1.85	91.86
GANs	二维输入	2.10
	三维输入	1.51
LSGANs	二维输入	2.23
	三维输入	1.12
GRBFNN	二维输入	2.57
	三维输入	1.34

下面对模型的最好结果进行对比。由表 1~2 可知, 在降水量和平均气温的插值中, IDW 法的估值精度优于 OK 法, 因此 IDW 法更适用于空间数据的插值。LSGANs 的 RMSE 和 NSE 都优于 GANs, 表明 LSGANs 在根本上解决 GANs 模型训练困难及生成样本质量不高的问题。在降水量的插值中, LSGANs 的 RMSE 比 GANs 的 RMSE 减小 13.16%, 而 NSE 提高 1.96%; 比 GRBFNN 的 RMSE 减小 1.92%, 而 NSE 提高 0.24%。在平均气温的插值中, LSGANs 的 RMSE 比 GANs 的 RMSE 减小 25.83%, 而 NSE 提高 2.45%; 比 GRBFNN 的 RMSE 减小 16.42%, 而 NSE 提高 1.27%。在降水量和平均气温的插值中, 3 个深度学习模型的泛化能力排序: LSGANs > GRBFNN > GANs, 泛化能力最强的是 LSGANs。GRBFNN 的效果不如 LSGANs, 是因为 GRBFNN 是一个网络训练与测试, 只能通过算法减小误差, 没有两个网络的博弈, 很难捕获数据深层的数量与特征关系。LSGANs 通过两个网络的博弈, 使得模型能够深度挖掘数据之间的潜在联系, 使生成网络学习目标更明确, 优化方向更清晰, 因此 LSGANs 的插值精度最高。

3.2 LSGANs 的生成对抗过程

本研究从对抗训练过程中, 截取 600 轮的训练

数据进行展示,详情见图3。

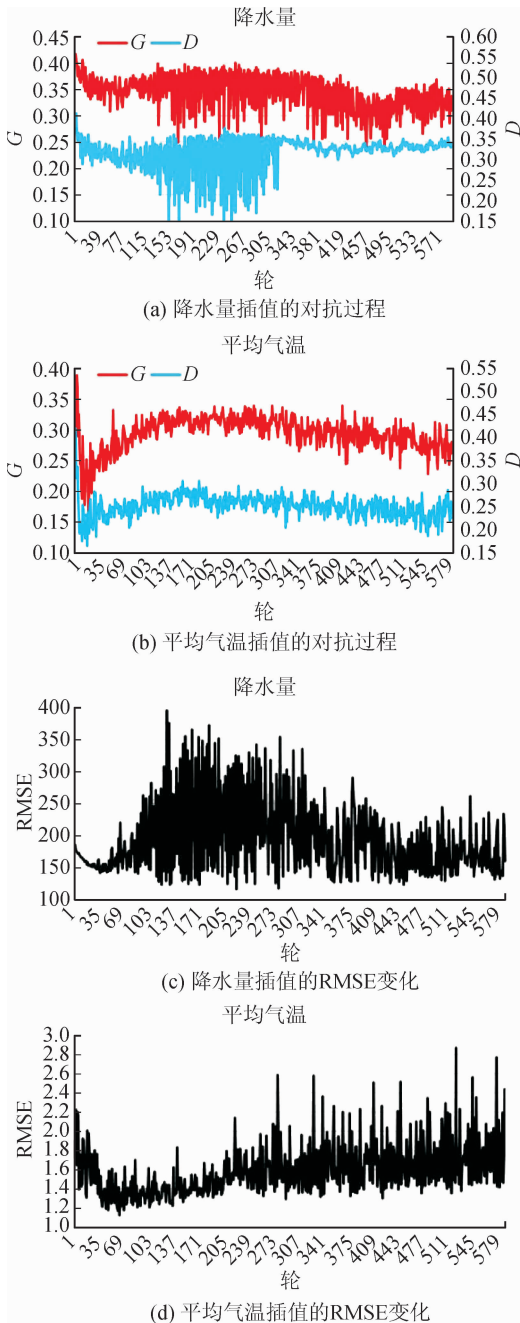


图3 LSGANs的生成对抗过程

Fig. 3 Generative adversarial process of LSGANs

图3的(a)和(b)分别是模型在降水量和平均气温的插值训练时,生成网络 G 与判别网络 D 的对抗过程,(c)和(d)分别是模型在降水量和平均气温的插值训练时,估计值与观测值的RMSE变化。从(a)和(b)中可以轻松地看到模型的对抗过程。(a)中黑色曲线 G 在下降到一定程度时会突然上升,这反映了生成网络 G 的对抗性质。当 G 达到一个局部最优值时, G 无法进一步欺骗判别网络 D ,这时 G 将跳出局部参数空间并调整更新方向,尝试找到更理想的解决方案。而在尝试新方向的优化时,通常

会返回较差的生成数据从而导致曲线上升。较差的生成数据在通过 D 后的输出与Real的误差会变大,导致 D 的最小二乘损失MSELoss (Mean Square Error Loss)会升高,即 D 的曲线也会反弹。通过 G 不断更新自身,产生的生成数据能够骗过 D ,即生成数据更逼真,此时 G 的MSELoss将会下降(曲线下降),产生的生成数据质量较高,再通过 D 后的输出与Real的误差变小, D 的曲线也会下降。随着模型的持续优化,估计值与观测值的RMSE也逐步下降。

由图3(c)也可以获得验证,每次 G 重新选择优化方向时误差变大,估计值与观测值的RMSE都会反弹一个较大值,之后随着 G 的更新再持续下降。从RMSE曲线还可以发现,在这600轮训练的最初一段, RMSE曲线处于稳定下降的状态。这是因为图3(a)中, G 持续更新自身调整模型参数, G 的MSELoss在波动下降,产生的生成数据更逼真。而生成数据质量较高,骗过 D 的可能性很大,导致 D 的MSELoss也在波动下降。因此估计值与观测值的RMSE稳定下降。在600轮训练的中间一段, D 和 G 的曲线波动比较剧烈。 G 调整优化方向之后,多次出现趋于0.25的极小MSELoss,对应 D 出现趋于0.15的极小MSELoss,估计值与观测值的RMSE也多次出现趋于100的极小RMSE。而在343~600轮训练期间, G 的MSELoss仍然在剧烈波动,虽然 G 的曲线也出现了趋于0.25的极小MSELoss,但是 D 的MSELoss却稳定在0.3~0.35之间,这是因为经过一定程度的训练, D 的判别能力提升, G 很难欺骗 D ,所以对估计值与观测值的RMSE也没有再出现更小的值。

图3(b)的变化与图3(a)的变化情况类似。唯一的区别就是在第35~205轮训练期间, D 和 G 的MSELoss有一小段波动上升,对应图3(d)中估计值与观测值的RMSE也有一定程度的波动上升。这是因为 D 的MSELoss波动上升导致 G 认为目前的优化方向是错误的,因此加快调整自己的优化方向导致 G 的MSELoss也在波动上升,一直到 G 找到一个可以让 D 的MSELoss不再波动上升的方向,而不断的调整优化方向导致估计值与观测值的RMSE也出现增大的现象。

3.3 交叉验证

将训练集与测试集交换作为交叉验证的测试集与训练集。分别应用IDW、LSGANs和GRBFNN对降水量和平均气温进行插值,结果见表3和表4。因为IDW法优于OK法,GANs的效果较差,因此

不再进行交叉验证。

表 3 降水量的插值结果对比

Tab. 3 Comparison of interpolation results of precipitation

方法	RMSE	NSE/%
IDW	199.83	86.44
LSGANs	二维输入	189.31
	三维输入	199.60
GRBFNN	二维输入	178.38
	三维输入	184.82

表 4 平均气温的插值结果对比

Tab. 4 Comparison of interpolation results of average temperature

方法	RMSE	NSE/%
IDW	2.85	81.19
LSGANs	二维输入	3.67
	三维输入	1.87
GRBFNN	二维输入	3.02
	三维输入	1.26

由表 3 可知,与三维输入相比,使用二维输入,LSGANs 的 RMSE 减小 5.16%,NSE 提高 1.35%;GRBFNN 的 RMSE 减小 3.48%,NSE 提高 0.8%。LSGANs 和 GRBFNN 的二维输入虽然优于三维输入,但是差别不大。这可能是训练样本总量减少导致。与 IDW 法相比,使用二维输入,LSGANs 的 RMSE 减小 5.26%,NSE 提高 1.39%,GRBFNN 的 RMSE 减小 10.73%,NSE 提高 2.76%。GRBFNN 比 LSGANs 的 RMSE 减小 5.77%,而 NSE 提高 1.37%,GRBFNN 的精度要优于 LSGANs。

由表 4 可知,与二维输入相比,使用三维输入,LSGANs 的 RMSE 减小 49.05%,NSE 提高 23.12%;GRBFNN 的 RMSE 减小 58.28%,NSE 提高 17.51%。LSGANs 的三维输入的估值精度明显高于二维输入,表明在训练样本总量较少的情况下,模型对于平均气温的插值精度依然对高程很敏感。与 IDW 法相比,使用三维输入,LSGANs 的 RMSE 减小 34.39%,NSE 提高 10.74%;GRBFNN 的 RMSE 减小 55.79%,NSE 提高 15.13%。GRBFNN 比 LSGANs 的 RMSE 减小 32.62%,而 NSE 提高 4.39%,GRBFNN 的精度要优于 LSGANs。

综上,对于降水量的插值,建模时更适合使用二维输入;对于平均气温的插值,建模时更适合使用三维输入。当训练样本充足时,LSGANs 优于

GRBFNN,但是 LSGANs 的插值精度受到训练样本总量的影响,当训练样本总量较少时,模型的插值精度会降低,插值精度不如 GRBFNN。

4 结 论

深度学习侧重从数据驱动的角度来理解过程,在给定复杂空间一部分特征情况下,预测未知特征的能力很强,因此可以提供非线性近似描述数据潜在关系的方法。基于 GANs 的深度学习模型由生成网络 G 和判别网络 D 组成。 G 尝试从空间数据中挖掘出数据之间潜在的数量与特征关系,并使用学习到的空间知识尽可能准确地生成空间数据,目的是骗过 D ,而 D 也不断的优化自身,希望可以判别出观测数据和生成数据。本研究建立了 GANs、LSGANs 及 GRBFNN 三个深度学习模型进行空间插值,与基准方法的插值结果进行对比分析,同时进行交叉验证,得出如下结论。

IDW 法比 OK 法更适合对空间数据进行插值。LSGANs 进行了改进之后,从根本上解决 GANs 训练困难及生成数据质量不高的问题。当训练样本较多时,LSGANs 在空间插值中表现最好,降水量的插值结果比 IDW 法的 RMSE 减小 9.16%,NSE 提高 1.27%;平均气温的插值结果比 IDW 法的 RMSE 减小 39.46%,NSE 提高 5.16%。当训练样本数量较少时,GRBFNN 的插值精度更高,降水量的插值结果比 IDW 法的 RMSE 减小 10.73%,NSE 提高 2.76%;平均气温的插值结果比 IDW 法的 RMSE 减小 55.79%,NSE 提高 15.13%。高程对于平均气温的插值精度影响较大,对于降水量的插值精度影响较小。

本研究利用 LSGANs 和 GRBFNN 的深度学习模型进行空间插值的想法,期望能给未来有关空间插值的工作带来启发。随着大数据技术和人工智能的快速发展,深度学习模型未来可能与空间预测有关的各个领域被采用,具有很好的应用前景。

参考文献:

- [1] 何鹏,张媛,高文波,等. 四川省多年平均气温数据空间插值方法与影响因素研究[J]. 中国农业资源与区划, 2019,40(9):114-124.
- HE Peng, ZHANG Yuan, GAO Wenbo, et al. Study on spatial interpolation method and influencing factors of annual mean air temperature data in Sichuan Province [J]. China Journal of Agricultural Resources and Regional Planning, 2019,40(9): 114-124.
- [2] GAO Bingbo, HU Maogui, WANG Jinfeng, et al. Spatial interpolation of marine environment data using P-

- MSN[J]. *International Journal of Geographical Information Science*, 2020, 34(3): 577-603.
- [3] 蒲阳,王汝兰,罗明良,等. 不同雨量次降雨空间插值对比—以四川省南充市降雨为例[J]. *水文*, 2018, 38(4): 73-77.
Comparison of spatial interpolation between different rainfall levels: a case study of rainfall in Nanchong City, Sichuan Province[J]. *Journal of China Hydrology*, 2018, 38(4): 73-77.
- [4] QU Rui, XIAO Keke, HU Jingping, et al. Predicting the hormesis and toxicological interaction of mixtures by an improved inverse distance weighted interpolation[J]. *Environment International*, 2019, 130: 104892.
- [5] CHIAPPINI F A, TEGLIA C M, FORNO Á G, et al. Modelling of bioprocess non-linear fluorescence data for at-line prediction of etanercept based on artificial neural networks optimized by response surface methodology [J]. *Talanta*, 2020, 210: 120664.
- [6] 刘永锋,李润祥,李纯斌,等. BP神经网络和支持向量机在积温插值中的应用[J]. *干旱区资源与环境*, 2014, 28(5):158-165.
LIU Yongfeng, LI Runxiang, LI Chunbin, et al. Application of BP neural network and support vector machine to the accumulated temperature interpolation[J]. *Journal of Arid Land Resources and Environment*, 2014, 28(5): 158-165.
- [7] 徐英,夏冰. 综合 BME 和 BNN 法的农田土壤水分与养分分布空间插值[J]. *农业工程学报*, 2015, 31(16): 119-127.
XU Ying, XIA Bing. Spatial interpolation of soil moisture and nutrients using BME combined with BNN[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2015, 31(16): 119-127.
- [8] MERKULOV D, OSELEDETS I. Empirical study of extreme overfitting points of neural networks[J/OL]. (2019-07-13) [2020-04-22]. <https://arxiv.org/abs/1906.06295>.
- [9] POON H K, YAP W S, TEE Y K, et al. Hierarchical gated recurrent neural network with adversarial and virtual adversarial training on text classification[J]. *Neural Networks*, 2019, 119: 299-312.
- [10] 陈雅婷,刘奥博. 中国流域降水数据的空间插值方法评估[J]. *人民长江*, 2019, 50(4):100-105.
CHEN Yating, LIU Aobo. Optimal spatial interpolation method for precipitation data in China's river basins[J]. *Yangtze River*, 2019, 50(4): 100-105.
- [11] 段平. 三维空间场各向异性径向基函数空间插值模型研究[J]. *测绘学报*, 2018, 47(12):1696.
DUAN Ping. Anisotropy radial basis function spatial interpolation model research for 3D spatial field[J]. *Acta Geodaetica et Cartographia Sinica*, 2018, 47(12): 1696.
- [12] 汪云,杨海博,徐建,等. 基于长短期记忆神经网络模型的地下水水位预测研究[J]. *节水灌溉*, 2019, 10: 73-77.
WANG Yun, YANG Haibo, XU Jian, et al. Groundwater level prediction based on long-short-term memory neural network model[J]. *Water Saving Irrigation*, 2019, 10: 73-77.
- [13] 陈国涛,滕欢. 基于混合神经网络深度学习的短期负荷预测[J]. *水电能源科学*, 2020, 38(4):193-196.
CHEN Guotao, TENG Huan. Short-term load forecasting based on deep learning of hybrid neural networks [J]. *Water Resources and Power*, 2020, 38(4): 193-196.
- [14] 郑哲,胡庆浩,刘青山,等. 量化权值激活的生成对抗网络[J]. *计算机科学*, 2020, 47(5):144-148.
ZHENG Zhe, HU Qinghao, LIU Qingshan, et al. Quantizing weights and activations in generative adversarial networks[J]. *Computer Science*, 2020, 47(5): 144-148.
- [15] 吴少乾,李西明. 生成对抗网络的研究进展综述[J]. *计算机科学与探索*, 2020, 14(3):377-388.
WU Shaoqian, LI Ximing. Survey on research progress of generating adversarial networks[J]. *Journal of Frontiers of Computer Science & Technology*, 2020, 14(3): 377-388.
- [16] SANTOS E C. Clustering-Based Resource Allocation mechanism in Long Term Evolution Advanced networks with auto-encoder for feature learning [J]. *Transactions on Emerging Telecommunications Technologies*, 2019, 30(7): e3591.
- [17] HOU Biao, WANG Jianlong, JIAO Licheng, et al. Auto encoder feature learning with utilization of local spatial information and data distribution for classification of polsar image[J]. *Remote Sensing*, 2019, 11(11): 1313.
- [18] 王孝顺,陈丹,丘海斌. 最小二乘迁移生成对抗网络[J]. *计算机工程与应用*, 2019, 55(14):24-31.
WANG Xiaoshun, CHEN Dan, QIU Haibin. Least squares transfer generative adversarial networks [J]. *Computer Engineering and Applications*, 2019, 55(14): 24-31.
- [19] MAO Xudong, LI Qing, XIE Haoran, et al. On the effectiveness of least squares generative adversarial networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(12): 2947-2960.
- [20] GOMES C R, MEDEIROS J A C C. Neural network of Gaussian radial basis functions applied to the problem of identification of nuclear accidents in a PWR nuclear power plant [J]. *Annals of Nuclear Energy*, 2015, 77: 285-293.
- [21] ZHAO Zhongqiu, WU Xindong, LU Canyi, et al. Optimizing widths with PSO for center selection of Gaussian radial basis function networks [J]. *Science China Information Sciences*, 2014, 57(5): 82-98.