

基于 ResNet 的大坝变形预测研究

黄先亮¹, 李 冰², 徐笑笑³

(1.江西理工大学土木与测绘工程学院,江西 赣州 341411;

2.江西应用技术职业学院,江西 赣州 341004;

3.自然资源部南海调查中心,广东 广州 510300)

摘要:为提高大坝变形预测模型的性能,提出将基于残差神经网络模型(ResNet)引入大坝变形预测领域,建立基于 ResNet 的大坝变形预测模型。以丰满大坝坝 30#坝段 1985-01-04~1988-07-13 共 200 期监测数据为例,将全连接神经网络、传统卷积神经网络与本文 ResNet 进行实验对比。研究表明,文章基于 ResNet 的大坝变形预测模型收敛速度快、预测精度高,可为大坝监测数据分析提供参考。

关键词:大坝;变形;预测;ResNet

中图分类号:P258

文献标识码:A

文章编号:2096-9759(2023)06-0120-04

Research on dam deformation prediction based on ResNet

HUANG Xianliang¹, LI Bing², XU Xiaoxiao³

(1.School of Civil and Surveying and Mapping Engineering, Jiangxi University of Science and Technology, 1958 Hakka Avenue, Ganzhou 341000, China;

2.College of Surveying and Geographic Information, Jiangxi College of Applied Technology, 9 Wenfeng Road, Rongjiang New District, Ganzhou 341004, China;

3.South China Sea Marine Survey Center, Ministry of Natural Resources, Guangzhou 510300, China)

Abstract: In order to improve the performance of dam deformation prediction model, the residual neural network model (ResNet) is introduced into the field of dam deformation prediction, and a dam deformation prediction model based on ResNet is established. Taking 200 monitoring data of 30 # dam section of Fengman Dam from January 4, 1985 to July 13, 1988 as an example, the fully connected neural network and traditional convolution neural network are compared with ResNet in this paper. The research shows that the dam deformation prediction model based on ResNet in this paper has fast convergence speed and high prediction accuracy, which can provide reference for dam monitoring data analysis.

Key Words: dam; deformations; predict; ResNet

大坝的形变量能够直接反映大坝的安全运行状态^[1],通过分析大坝形变监测数据,建立大坝变形预测模型,将模型预测值与实际观测值进行比较,是评估大坝安全运行状况最普遍的方法^[2]。大坝变形主要受水位、温度和时效三类因素的影响^[3],基于影响因素对大坝变形进行预测,是建立大坝变形预测模型的有效方法。但是,水位、温度和时效之间存在错综复杂的联系,对大坝变形的影响主次不定,使得建立大坝变形预测模型仍然存在诸多困难。

随着深度学习理论的不发展与完善,不少学者提出将神经网络模型引入大坝变形预测领域^[4],相继提出采用浅层的 BP 神经网络^[5]、深度的全连接神经网络^[6]、卷积神经网络^[7]来对大坝变形进行预测。全连接神经网络对数据特征的提取能力较弱,传统的卷积神经网络存在训练困难,容易过拟合等问题。而拥有残差网络模块(Residual Blocks)设计的残差神经网络 ResNet,拥有强大的数据特征提取能力,同时模型方便训练,收敛速度快,已应用在城市人流预测^[8]、气象预测^[9]、蛋白质预测^[10]等领域,而在大坝变形预测领域应用较少。

本文利用丰满大坝坝 30#坝段 1985-01-04~1988-07-13 共 200 期监测数据^[11],建立基于 ResNet 的大坝变形预测模型,并将全连接神经网络、传统卷积神经网络与本文模型进行实验对比,已验证本文基于 ResNet 的大坝变形预测模型的优越性和可行性。

1 卷积神经网络理论

卷积神经网络模型(Convolutional Neural Networks, CNN)通过卷积与池化操作,极大地降低了神经网络模型的复杂度的同时,能够高效提取数据特征。CNN 最早应用于图像识别领域,随着深度学习理论的发展以及计算机性能的提升,CNN 被广泛应用于计算机视觉、自然语言处理等领域。传统的神经网络模型是由多层的全连接层和激活函数组成,CNN 则在此基础上增加了卷积层与池化层,借助由卷积层和池化层交替组成的隐藏层,实现对输入信息的深度特征挖掘。

1.1 卷积层(Convolutional Layer)

卷积层(Convolutional Layer)是 CNN 的核心部分之一,该层利用卷积核对输入张量进行卷积运算,并通过反向传播算法对卷积核参数进行优化,实现对输入张量的高维特征提取。相较于传统的全连接层,卷积层能够更有效提取输入信息特征,同时可以显著降低模型训练参数的数量。

假设,卷积层中卷积核 $[V]$ 形状为 $c_o \times c_i \times k_h \times k_w$,即卷积层为输入通道为 c_i ,输出通道为 c_o ,则卷积层对于输入张量 $[X]$ 的运算过程如公式(1)所示。

$$[H]_{i,j,k} = \sum_{c_o} \sum_{k_w} \sum_{k_h} ([V]_{k_h, k_w, c_i, c_o} [X]_{i+k_h, j+k_w, c_i} + [u]_{c_o}) \quad (1)$$

式中, $[H]$ 为池化层的输出张量, u 表示卷积层的偏置,为

收稿日期:2023-03-20

作者简介:黄先亮(1996-),男,江西赣州人,硕士,主要研究方向:变形监测理论与数据处理。

大小为 $c_i \times 1$, $[X]_{i,j,k}$ 和 $[H]_{i,j,k}$ 分别表示 $[X]$ 和 $[H]$ 中位置 (i,j,k) 处的值。

1.2 池化层(Pooling)

池化层(Pooling Layer)目的是将输入数据在特定窗口中的数据特征提取出来,分为最大池化层(maximum pooling)和平均池化层(average pooling)两种。假设,池运算的窗口形状为 $k_h \times k_w$,最大池化层和平均池化层对于输入张量 $[X]$ 的计算过程分别如公式(2)(3)所示。

$$[H]_{i,j,k} = \max_{k_h, k_w, c_i} ([X]_{i+k_h, j+k_w, k}) \quad (2)$$

$$[H]_{i,j,k} = \max_{k_h, k_w, c_i} ([X]_{i+k_h, j+k_w, k}) \quad (3)$$

式中, $[H]$ 为池化层的输出张量, $[X]_{i,j,k}$ 和 $[H]_{i,j,k}$ 分别表示 $[X]$ 和 $[H]$ 中位置 (i,j,k) 处的值。

2 残差神经网络理论

在神经网络的结构设计中,常常将多个计算层视作一个计算块,通过多个结构相同或相似的计算块来简洁实现对深度神经网络的设计。传统的 CNN 是将卷积层和池化层一并视作一个卷积块,通过多个卷积块实现深度 CNN 的设计。但是,如果单纯增加卷积块的数量,则会使模型的训练难度加大。而增加了批量规范化层(Batch Normalization)和残差网络模块(Residual Blocks)的残差神经网络模型(ResNet)^[12],能够在模型深度增加的同时,保证模型训练难度不增加,并且可取得更好的结果。

2.1 批量规范化层(Batch Normalization)

批量规范化层(Batch Normalization)的具体操作是将小批量的输入数据进行批量标准化,目的是避免模型训练时出现梯度爆炸或梯度消失的情况。假设,批量归一化 BN 的输入是包含多个样本 x 的小批量 B ,则 BN 的具体运算过程如(4)所示。

$$BN(x) = \gamma \odot \frac{x - \hat{\mu}_B}{\hat{\sigma}_B} + \beta \quad (4)$$

式中, \odot 表示 Hadamard 积,即两个张量按元素相乘; γ 表示拉伸参数(scale), β 表示偏移参数(shift), $\hat{\mu}_B$ 表示小批量 B 的样本均值, $\hat{\sigma}_B$ 表示小批量 B 的样本标准差。 γ 和 β 形状与 x 相同,是 BN 的参数,需要和模型的其他参数一同训练更新。

2.1 残差网络模块(Residual Blocks)

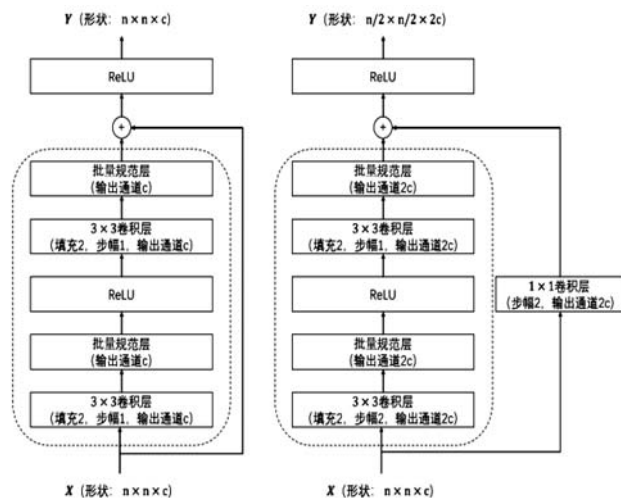


图1 两种残差块的设计结构

残差网络模块(Residual Blocks)是 ResNet 的核心组成部分,从传统卷积块改进而来,其主要思路是将模块的输入和模块原本的输出相加,以保证模型在增加残差网络模块后,输出结果不会比增加前更差。残差块的实现分为一下两种情况,若原本卷积块的输入与输出形状一致,则直接采用 Hadamard 积运算将卷积块的输出与输入相加,构建成残差块。若原本卷积块的输入与输出形状不一致,则引入一个卷积核大小为 1×1 的卷积层对输入张量的形状进行调整后相加。通常是将输入数据的行、列数减少一半,将通道数增加了一倍。具体两种残差块的结构通常如图1左、右子图所示。

3 基于 ResNet 的大坝变形预测模型

一般而言,大坝变形预测模型都是将大坝变形影响因子作为输入,大坝形变量作为输出,并通过历史监测数据构造数据集,对模型进行训练,最终实现对大坝变形的预测。本文大坝监测数据的特点,结合 ResNet 的相关理论,建立了基于 ResNet 的大坝变形预测模型,建立步骤如下:

(1)数据处理。本文从环境监测数据中提取水位影响因子 H^1, H^2, H^3, H^4 , 温度影响因子 $T^1, T^2, T^3, T^4, \sin(2\pi t/365), \cos(2\pi t/365), \sin(2 \times 2\pi t/365), \cos(2 \times 2\pi t/365), \sin(3 \times 2\pi t/365), \cos(3 \times 2\pi t/365)$ (其中 t 表示为起始观测年1月1日至本次观测日的累计天数),选择效影响因子 $\theta, \ln(\theta)$ (其中 $\theta = t/100$)。为影响因子不同量纲对预测模型的影响,并提高模型的训练效率与预测精度,上述16个影响因子进行归一化处理,最后将归一化后的影响因子编码成 4×4 的张量作为 CNN 的输入,大坝形变量作为输出,构建数据集。其中,对影响因子进行归一化处理的计算方法如(5)所示。

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

式中, x 表示标准化前的数值, y 表示标准化后的数值, x_{\min}, x_{\max} 分别表示 x 的最小值和最大值。

(2)网络设计。本文采用先一个输入块将形状为 $4 \times 4 \times 1$ 的输入转换成 $8 \times 8 \times 8$ 的输出;然后采用8个残差块进行特征提取,将数据转换成 $32 \times 1 \times 1$;最后采用一个输入为32,输出为1的全连接层将数据转换成输出。基于 ResNet 的大坝变形预测模型结构如图2所示。



图2 基于 ResNet 的大坝变形预测模型结构

图中残差块1表示图1左边子图的残差块结构,残差块2表示图1右边子图的残差块结构。

(3)模型训练。本文采用均方差损失(Mean Squared Error

Loss) 计算模型损失函数值, 采用自适应矩估计优化算法(Adam)对模型进行训练。

(3) 性能评价。本文采用平均绝对误差(Mean Absolute Error, MAE)对模型在训练集和测试集上的性能表现进行评价。

4 工程实例应用

4.1 丰满大坝监测数据概况

为验证本文基于 ResNet 的大坝变形预测模型的有效性, 本文采用丰满大坝 30#坝段 1985-01-04 至 1988-07-13 共 200 期监测数据构造数据集, 对模型进行训练与评价。该数据具有较强的代表性, 被多篇大坝变形预测相关论文采用。30#坝段位坝顶监测点的水平位移监测数据以及同期的温度和在水位数据如图 3 所示。




图 3 大坝安全监测数据

4.2 模型训练

本文采用数据集的前 160 期作为训练集, 后 40 作为测试集, 对模型的性能进行验证与分析。为充分验证本文基于 ResNet 的大坝变形预测模型的有效性, 本文采用多层感知机模型(Multilayer Perceptron, MLP)和传统的 CNN 模型进行实验对比, MLP 和 CNN 的模型结构如图 4 左右子图所示。

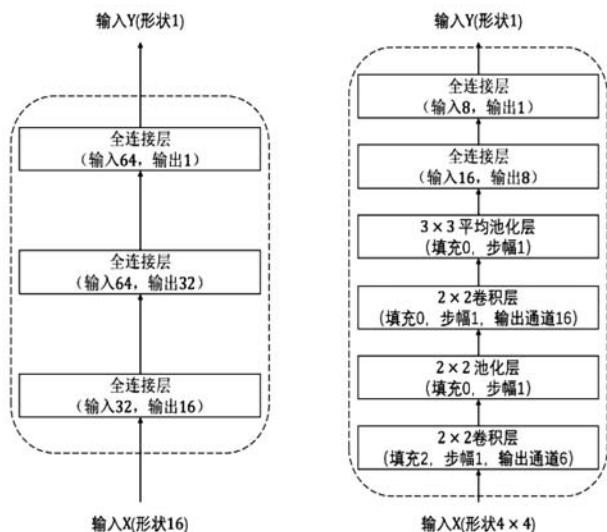


图 4 MLP 和 CNN 的模型结构

本文程序的实现基于 python 3.8.10 环境、Pytorch 1.9.0 深度学习框架和 Numpy 1.21.1 和 Sklearn 1.1.2 计算工具库, 本文训练模型前对模型参数进行随机初始化, 采用 Adam 对模型参数进行优化, 算法参数设置如下: 学习率 η 为 0.03, 数值稳定量 δ 为 10^{-8} , 一阶矩估计的指数衰减率 p_1 为 0.9, 一阶矩估计的指数衰减率 p_2 为 0.99。MLP、CNN 和 ResNet 训练过程的损失函数值变化曲线如图 5 所示。




图 5 MLP、CNN 和 ResNet 训练过程的损失函数值变化曲线

4.3 模型评价

由 5 可知, MLP、CNN 和 ResNet 都可以将损失函数值收敛到 $2mm^2$ 以内, CNN 的收敛速度比较慢, 200 个训练周期后才将损失收敛到 $2mm^2$ 以内, ResNet 收敛速度最快, 5 个训练周期后就稳定收敛了, 充分验证了本文模型训练难度低的特点。

MLP、CNN 和 ResNet 的预测结果以及预测结果的残差如图 6、图 7 所示, 图中虚线左边表示训练集, 右边表示测试集。由图 6、图 7 可知, CNN 和 ResNet 均能大致拟合出大坝变形的大致规律, 表明卷积和池化操作能够有效提取有利于大坝预测的数据特征。细节上看, ResNet 的预测结果更加贴合真实数据, 表明 ResNet 对大坝变形预测的有效性。




图 6 各模型混凝土坝变形预测值和实测值




图 7 模型水平位移残差结果

MLP、CNN 和 ResNet 在训练集和测试集的预测误差如表 1 所示。由表 1 可知, ResNet 在测试集误差小于 $0.12mm$, 在测试集误差小于 $0.56mm$, 均是最低。表明 ResNet 相较于 MLP 和 CNN, 更能从安全监测数据中提取有数据特征, 对大坝变形实现更精准的预测。

表 1 模型误差

模型	训练集误差(mm)	测试集误差(mm)
MLP	0.840	0.931
CNN	0.688	1.087
ResNet	0.115	0.558

5 结语

本文提出将 ResNet 引入大坝变形预测领域, 设计了针对 CNN 的大坝变形预测数据集的构造方式, 并设计了基于 Res

一种基于 ARM 的餐厅服务机器人设计

邱展旺,农荣超,李树宏,陈婉菁,李柱林

(桂林电子科技大学 机电工程学院,广西 桂林 541004)

摘要:在餐饮行业发展趋于稳定的背景下,为提高餐饮服务质量、降低服务成本,可以将基于 ARM 技术开发的机器人引入餐饮服务行业中,提升餐厅竞争力^[1]。为此,提出了一种新型的餐厅服务机器人的设计,通过 K210 视觉检测物体的形状特征和其所所在的空间位置,利用 D-H 法进行机械臂坐标系的变换并解算出运动轨迹,实现对物体的抓取和放置。

关键词:ARM;餐厅服务机器人;K210 视觉识别

中图分类号:TP311

文献标识码:B

文章编号:2096-9759(2023)06-0123-03

0 引言

近几十年来,随着科技水平的进步,机器人领域得到了很大的发展,传统的机器人不再只是应用在工业制造中,开始进入到餐饮服务行业。在国内一些餐饮企业中,陆续出现了诸如以和人外形相似的机器人及智能送餐小车等服务型机器人^[2],这是机器人进入餐饮服务行业的显著标志;此外,中国制造 2025 规划纲要中也指出机器人发展要涉及智能服务方面,餐饮行业作为典型的服务型行业,可以为机器人未来的发展提供很大的市场。本文针对餐饮服务行业的服务需求,设计了一款外型独特且智能的餐厅服务机器人。

1 整体结构设计

餐厅服务机器人整体由一体式机械臂、餐柜、底盘 AGV 小车三大部分组成。其整体结构由图 1 所示。

1.1 一体式机械臂

一体式机械臂采用的是深圳市幻尔科技有限公司的一款教育型机械臂,机体在材料上选用的是全铝合金,使整个机体具有独特的外型、更优化简捷的结构;同时,各个关节处选用了高精度的 PWM 数字舵机,使整个机械臂本体具有六个自由

度。该机械臂的组成部分有机械臂本体和兼容开发控制板。




图 1

1.1.1 机械臂本体

机械臂的本体由全铝合金折弯 U 型件、全金属旋转底座、合金机械爪和 PWM 数字舵机组成,U 型件和 U 型件之间、U 型件和舵机之间皆采用螺钉连接,这不仅使整个装配变得更加简易,而且更便于后期的调试工作;合金开合式机械爪是由末端舵机直接驱动开合,从而实现夹取动作;PWM 数字舵机

收稿日期:2023-03-04

项目基金:省部级大学生创新训练项目:S202210595124。

作者简介:邱展旺(1999-),男,广西贺州人,在读本科生,主要研究方向:机器人的应用场景设计。

Net 的大坝变形预测模型的网络结构,后采用 Adam 模型参数进行优化,最终建立了基于 ResNet 的大坝变形预测模型。通过实例验证表明,本文模型拥有收敛速度快、拟合精度高、泛化能力强等特点,可以更加精准地预测大坝的形变量,为判断大坝安全运行状态提供参考依据。

参考文献:

- [1] 张正禄,张松林,黄全义,等.大坝安全监测、分析与预报的发展综述[J].大坝与安全,2002(05):13-16.
- [2] 黄耀英,何一洋,沈振中,等.大坝监测量最佳统计模型优选方法[J].水利学报,2022,53(02):154-164.
- [3] 吴中如.水工建筑物安全监控论及其应用[M].北京:高等教育出版社,2003.
- [4] 吴中如,陈波.大坝变形监控模型发展回眸[J].现代测绘,2016,39(5):3-8.
- [5] 胡纪元,文鸿雁,周吕,等.基于 IPSO-BP 模型的大坝多源监测数据预报与反演[J].大地测量与地球动力学,2014,34(04):67-70.

- [6] 杨恒,岳建平,邢尹,周钦坤.基于深度全连接神经网络的大坝变形预测研究[J].大地测量与地球动力学,2021,41(02):162-166.
- [7] 魏道红,王博,张明.基于 CNN 的混凝土坝变形预测深度学习模型研究[J].水利水电技术(中英文),2021,52(06):52-57.
- [8] Zhang J, Yu Z, Qi D. Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction[J].2016.
- [9] Rasp S, Thuerey N.Data-driven medium-range weather prediction with a Resnet pretrained on climate simulations: A new model for WeatherBench [J]. Journal of Advances in Modeling Earth Systems.
- [10] Lu S, Hong Q, Wang B,et al. Efficient ResNet Model to Predict Protein-Protein Interactions With GPU Computing[J]. IEEE Access, 2020,8:1-1.
- [11] 姜成科.基于遗传算法的神经网络在大坝变形预报中的应用[D].大连理工大学,2009.
- [12] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[J]. IEEE, 2016.