



# 基于卷积神经网络的防坡堤施工沉降预测\*

翟征秋<sup>1</sup>, 程林<sup>2</sup>, 宋效第<sup>2</sup>, 袁俊俊<sup>3</sup>

- (1. 天津临港港务集团有限公司, 天津 300452;  
2. 天津市北洋水运水利勘察设计院有限公司, 天津 300460;  
3. 中交上海航道局有限公司, 上海 200001)

**摘要:** 为了保证防坡堤施工安全, 通过预测不同施工阶段防坡堤的沉降变形, 以调整施工进度和工序。传统沉降预测方法主要包括太沙基固结理论、曲线拟合法和 BP 神经网络, 太沙基固结理论和曲线拟合法预测精度较低, BP 神经网络需要大量样本才能逼近最优解。针对这些问题, 提出基于卷积神经网络(convolutional neural networks, CNN)建立防波堤施工阶段的沉降预测方法。应用此方法预测天津港大沽口港区防波堤施工阶段沉降量和沉降速率, 并以预测结果分析沉降速率所映射的安全风险等级, 从而为实际施工提供行动指南。结果表明: 卷积神经网络能较为准确地预测沉降变形速率, 根据预测结果能够对安全风险等级的结果进行分析并予以指导。

**关键词:** 卷积神经网络; 沉降预测; 防坡堤施工; 风险等级

**中图分类号:** U 656

**文献标志码:** A

**文章编号:** 1002-4972(2021)08-0202-05

## Prediction of embankment construction settlement based on convolutional neural network

ZHAI Zheng-qiu<sup>1</sup>, CHENG Lin<sup>2</sup>, SONG Xiao-di<sup>2</sup>, YUAN Jun-jun<sup>3</sup>

(1. Tianjin Lingang Port Group Co., Ltd., Tianjin 300452, China;

2. Tianjin Beiyang Survey and Design Institute of Water Transport & Water Conservancy Co., Ltd., Tianjin 300460, China;

3. CCCC Shanghai Dredging Co., Ltd., Shanghai 200001, China)

**Abstract:** To ensure the safety of embankment construction, it is necessary to predict the settlement of embankment in different construction stages of breakwater to adjust the construction schedule and working procedure. The traditional settlement prediction methods mainly include Terzaghi consolidation theory, curve fitting method, and BP neural network. The prediction accuracy of Terzaghi consolidation theory and curve fitting method is low, and BP neural network needs a large number of samples to approximate the optimal solution. Aiming at these problems, this paper proposes a prediction method of breakwater settlement in different construction stages based on convolutional neural networks(CNN). This method is applied to predict the settlement and rate of the embankment in the Dagukou port area of Tianjin port during the construction stage, and the safety risk level mapped by the settlement rate is analyzed by the prediction results, to provide actionable guidance for the actual construction period. The results show that the convolution neural network can accurately predict the settlement rate, and can analyze and guide the results of safety risk level according to the prediction results.

**Keywords:** convolutional neural network; settlement prediction; embankment construction; risk level

为了保证防坡堤施工安全, 在防波堤的不同  
施工阶段中, 需要对防坡堤的沉降速率进行预测,

以调整施工进度和工序。目前, 沉降的预测方法  
主要分成两大类: 1) 太沙基固结理论影响防坡堤

**收稿日期:** 2020-11-10

**\*基金项目:** 天津市交通运输科技发展计划项目(G2019-10)

**作者简介:** 翟征秋(1974—), 男, 硕士, 高级工程师, 研究方向为港口与航道工程。

沉降因素众多, 用经典的理论预测沉降较为困难; 2) 根据沉降参数建立沉降与时间关系模型的曲线拟合方法受实际的沉降曲线影响较大, 在沉降参数的动态调整上存在很大的局限性。越来越多的学者开始关注人工神经网络 (artificial neural network, ANN) 在沉降变形预测中的应用, Tsinker<sup>[1]</sup>、徐洪钟等<sup>[2]</sup>和苏怀智等<sup>[3]</sup>研究发现传统的曲线拟合方法无法满足大坝安全监测需求, 他们率先通过 ANN、支持向量机 (SVM) 等方法将其成功应用于大坝变形预测; 杨杰等<sup>[4]</sup>、万臣等<sup>[5]</sup>、罗丹等<sup>[6]</sup>和齐银峰等<sup>[7]</sup>采用了 BP 神经网络预测了大坝的变形。可见, 在现阶段 BP 神经网络沉降变形预测方面应用广泛, 但需要大量样本才能较好地逼近非线性函数问题, 此外在求解非线性问题时, 容易在初始化过程中因连接权值和阈值不稳定导致局部收敛, 产生过拟合, 极大地降低了预测精度。

深度学习是机器学习中一个新的方向, 可以从小样本中学习参数的本质特征, 其中卷积神经网络 (convolutional neural network, CNN) 应用最为广泛。近年来, 卷积神经网络在图像处理<sup>[8]</sup>、人脸识别技术<sup>[9]</sup>、参数预测技术<sup>[10]</sup>、语音识别检索<sup>[11-12]</sup>、临床 ECG 分析<sup>[13-14]</sup>、短文本聚类<sup>[15]</sup>、视觉追踪处理<sup>[16]</sup>等领域有重要的应用, 但是在海上防坡堤施工期的沉降预测领域应用研究很少, 本文提出了基于卷积神经网络的防坡堤施工沉降预测方法。

以天津港大沽口港区东、北防波堤潜堤段工程为研究对象, 以防坡堤的施工阶段、孔隙水压力、深层水平位移作为输入参数, 通过 BP 神经网络和卷积神经网络两种模型对样本进行学习训练, 预测防波堤施工沉降量和沉降速率, 说明卷积神经网络的优越性, 并分析沉降速率所映射的安全风险等级, 从而为实际施工期提供行动指南。

1 沉降预测方法

1.1 卷积神经网络原理

人工神经网络模型中 CNN 应用较为广泛,

CNN 相比 BP 神经网络更适合多维表征的同时输入, 并且包含了卷积层、池化层、权重及偏置<sup>[17]</sup>。通过规划求解不断优化和调整原有池化层、权重及偏置参数, 寻求最优解以达到沉降的预测。

假设 CNN 的输入层  $\mathbf{X}$  ( $n$  个神经单元)、卷积层  $\mathbf{F}$  (3 个子层)、池化层  $\mathbf{P}$  (3 个子层) 和输出层  $\mathbf{a}$  (3 个神经单元), 网络拓扑结构见图 1。

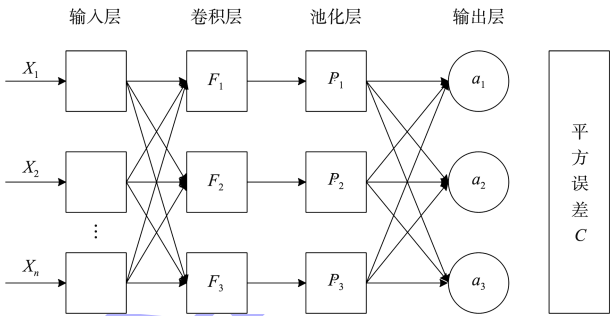


图 1 卷积神经网络拓扑结构

CNN 将已有  $n$  组参数或图像参数经过归一化处理, 将归一化后的参数代入模型, 通过卷积层和池化层的双重滤网过滤系统, 从而实现对  $n$  个参数的训练, 通过判断代价函数 (平方误差)  $C_T$  的值是否无限趋近或等于 0, 得到最优的输出结果。

1.2 卷积及池化操作

假设输入层为  $6 \times 6$  的矩阵, 卷积层为  $4 \times 4$  的矩阵, 准备 3 种  $3 \times 3$  大小的过滤器, 见图 2。

过滤器1			过滤器2			过滤器3		
$w_{11}^{f1}$	$w_{12}^{f1}$	$w_{13}^{f1}$	$w_{11}^{f2}$	$w_{12}^{f2}$	$w_{13}^{f2}$	$w_{11}^{f3}$	$w_{12}^{f3}$	$w_{13}^{f3}$
$w_{21}^{f1}$	$w_{22}^{f1}$	$w_{23}^{f1}$	$w_{21}^{f2}$	$w_{22}^{f2}$	$w_{23}^{f2}$	$w_{21}^{f3}$	$w_{22}^{f3}$	$w_{23}^{f3}$
$w_{31}^{f1}$	$w_{32}^{f1}$	$w_{33}^{f1}$	$w_{31}^{f2}$	$w_{32}^{f2}$	$w_{33}^{f2}$	$w_{31}^{f3}$	$w_{32}^{f3}$	$w_{33}^{f3}$

图 2 卷积神经网络过滤器

这些过滤器中的数值是对学习参数进行学习而确定的模型参数, 表示为  $w_{11}^{fk}, w_{12}^{fk}, \dots, w_{33}^{fk}$  ( $k=1, 2, 3$ ), 利用过滤器进行卷积处理, 将得到卷积值, 见式(1):

$$c_{ij}^{fk} = w_{11}^{fk} x_{ij} + w_{12}^{fk} x_{ij+1} + w_{13}^{fk} x_{ij+2} + \dots + w_{33}^{fk} x_{i+2j+2}$$
 (1)

式中:  $x_{ij}$  为输入层第  $i$  行  $j$  列位置的输入值。

由式(1)得到数值的集合称为特征映射, 这些卷积值还需要加上一个不依赖  $i, j$  变化的数  $b^{fk}$ ,

其中  $b^{Fk}$  为卷积层偏差, 见式(2):

$$Z_{ij}^{Fk} = w_{11}^{Fk}x_{ij} + w_{12}^{Fk}x_{ij+1} + w_{13}^{Fk}x_{ij+2} + \cdots + w_{33}^{Fk}x_{i+2j+2} + b^{Fk} \quad (2)$$

式中:  $Z_{ij}^{Fk}$  为卷积层第  $k$  个子层  $i$  行  $j$  列的神经单元加权输入。

根据式(2)得到加权输入矩阵, 作为卷积层一个子层。本文将 Sigmoid 函数作为激活函数, 卷积层第  $k$  个子层  $i$  行  $j$  列的神经单元输出值见式(3):

$$a_{ij}^{Fk} = \frac{1}{1 + e^{-Z_{ij}^{Fk}}} \quad (3)$$

CNN 中设置有助于压缩卷积层信息的池化层, 通过最大池化法, 将卷积层中  $2 \times 2$  个神经单元压缩为 1 个神经单元, 这些压缩后的神经单元的集合就形成了池化层, 池化层输入和输出分别见式(4)和(5):

$$Z_{ij}^{Pk} = \max(a_{2i-1, 2j-1}^{Fk}, a_{2i-1, 2j}^{Fk}, a_{2i, 2j-1}^{Fk}, a_{2i, 2j}^{Fk}) \quad (4)$$

$$a_{ij}^{Pk} = Z_{ij}^{Pk} \quad (5)$$

由式(6)和(7)可以分别计算输出层第  $n$  个神

经单元的加权输入和第  $n$  个神经单元的输出:

$$Z_n^0 = w_{1-11}^{0n}a_{11}^{P1} + w_{1-12}^{0n}a_{12}^{P1} + \cdots + w_{2-11}^{0n}a_{11}^{P2} + w_{2-12}^{0n}a_{12}^{P2} + \cdots + w_{3-11}^{0n}a_{11}^{P3} + w_{3-12}^{0n}a_{12}^{P3} + \cdots + b_n^0 \quad (6)$$

$$a_n^0 = \frac{1}{1 + e^{-Z_n^0}} \quad (7)$$

式中:  $\omega_{k-ij}^{0n}$  为输出层第  $n$  个神经单元给池化层第  $k$  个子层  $i$  行  $j$  列神经单元的输出  $a_{ij}^{Pk}$  ( $k=1, 2, 3; i=1, 2; j=1, 2$ ) 分配的权重;  $b_n^0$  为输出层第  $n$  个神经单元的偏置。

假设输出层神经单元的 3 个对应的正解分别为  $t_1$ 、 $t_2$ 、 $t_3$ , 平方误差  $C$  由式(8)计算:

$$c = 0.5 [(t_1 - a_1^0)^2 + (t_2 - a_2^0)^2 + (t_3 - a_3^0)^2] \quad (8)$$

将全体学习数据的平方误差  $C$  综合就是代价函数  $C_T$ , 通过求解  $C_T$  最小达到最优模型解的权重及偏差, 将最优模型运用至测试样本, 从而达到沉降的预测效果。上述卷积和池化过程见图 3。

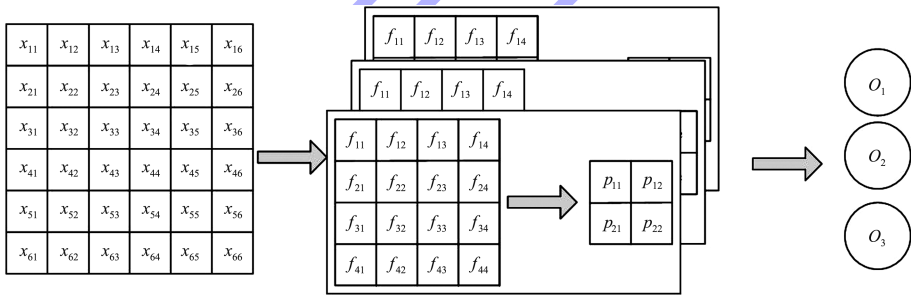


图 3 卷积和池化过程

2 工程应用

2.1 工程背景

天津港大沽口港区东、北防波堤潜堤段工程位于大沽口港区大沽沙航道口门附近, 东、北防波堤为永久性海堤, 设计使用年限 50 a, 结构安全

等级为二级。其中北防波堤从已建堤头端点开始沿与航道平行的方向向海侧延伸, 全长 2 350 m, 前 1 500 m 堤顶高程 5.5 m, 为出水堤, 剩余 850 m 堤顶高程为 2.5 m, 为潜堤, 各堤段的结构参数见表 1。

表 1 北防波堤潜堤段结构设计参数

桩号	堤顶高程/m	堤顶宽度/m	堤身结构	边坡坡度	护面结构	反滤结构	护底结构	地基处理
N0+000~N1+500	5.5	6.32	复合布+编织布大型充填袋装砂棱体	内外坡均 1:1.75	厚度 1.1 m (堤头段 1.6 m) 规格 300~500 kg 抛石垫层+6 t 扭王字块人工护面块体	600 g/m <sup>2</sup> 复合土工布+厚度 0.7 m 规格 10~40 kg 抛石垫层	砂肋软体排+厚度 1.0 m 规格 60~100 kg 抛石	铺设砂被垫层打设塑料排水板, 间距 1.1 m (局部 1.0 m), 底高程-16 m
N1+500~N2+300	2.5	6.32		内外坡均 1:1.75				
N2+300~N2+350	2.5	6.06		内外坡均 1:2.5				

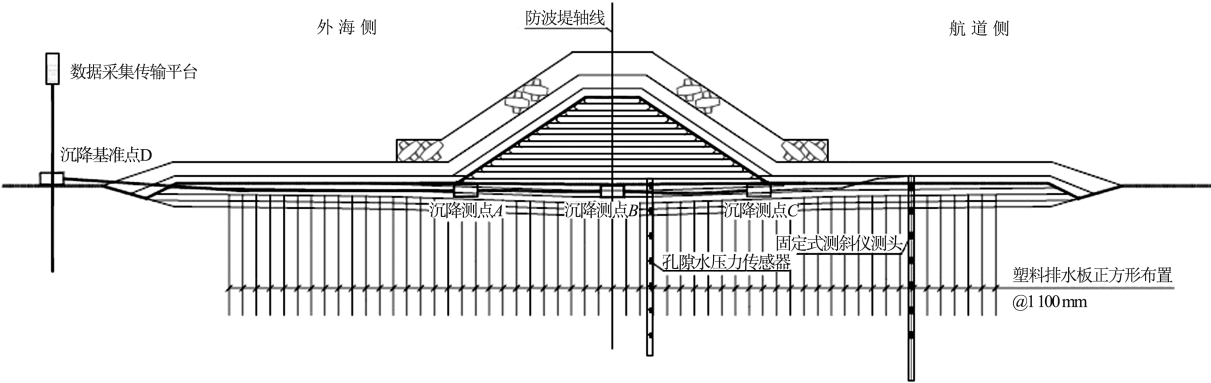


图 4 防波堤监测仪器布置断面

2.2 参数选取及归一化

在施工期间进行了堤身沉降观测、深层土体水平位移观测和孔隙水压力观测, 为了充分利用现有的监测数据预测防波堤施工期间某一阶段沉降速率, 实时掌握防波堤堤身沉降情况动态指导和控制施工。将某一施工过程所处的施工阶段( $r_1$ )、孔隙水压力( $r_2$ )、深层水平位移( $r_3$ )作为 CNN 的输入层, 将施工过程的沉降量( $m_1$ )、沉降速率( $m_2$ )作为 CNN 的输出层。沉降速率低于 1 表示为低风险; 沉降速率在 1~2 表示为较低风险;

沉降速率在 2~3 表示为中风险; 沉降速率在 3 以上之间表示为高风险。

由式(9)对样本中施工阶段( $r_1$ )、孔隙水压力( $r_2$ )、深层水平位移( $r_3$ )参数进行归一化处理。CNN 的学习样本及参数归一化结果见表 2。

$$x'_{ij} = \frac{x_{ij} - x_{\min}}{x_{\max} - x_{\min}} \tag{9}$$

式中:  $x_{ij}$  是第  $i$  个参数的第  $j$  个参数, 分别为原始检测参数的最大值和最小值。

表 2 学习样本和归一化样本

样本	学习样本					样本归一化				
	施工阶段	孔隙水压力/kPa	深层水平位移/mm	沉降量/mm	沉降速率/(mm·d <sup>-1</sup> )	施工阶段	孔隙水压力	深层水平位移	沉降量	沉降速率
1	1	167	9.72	347	2.29	0	0.71	0.05	0.04	0.64
2	1	130	15.75	368	0.71	0	0.25	0.13	0.07	0.14
3	1	170	34.53	418	3.43	0	0.75	0.38	0.15	1.00
4	1	169	40.3	446	3.00	0	0.74	0.45	0.19	0.86
5	1	132	42.56	457	0.71	0	0.28	0.48	0.21	0.14
6	1	133	44.45	463	0.86	0	0.29	0.50	0.22	0.19
7	1	132	52.23	495	0.71	0	0.28	0.60	0.27	0.14
8	1	135	59.76	511	1.00	0	0.31	0.70	0.29	0.23
9	1	170	70.24	626	3.43	0	0.75	0.84	0.47	1.00
10	1	168	73.38	726	2.71	0	0.73	0.88	0.62	0.77
11	1	165	73.5	742	2.29	0	0.69	0.88	0.65	0.64
12	2	190	80.15	933	1.69	0.5	1.00	0.97	0.94	0.45
13	3	130	82.78	972	0.27	1	0.25	1.00	1.00	0.00
14	1	110	5.50	323	0.30	0	0.00	0.00	0.00	0.15
15	1	120	6.10	363	0.42	0	0.13	0.01	0.06	0.31
16	1	125	6.50	388	0.50	0	0.19	0.01	0.10	0.66
17	1	130	79.47	758	0.72	0	0.25	0.96	0.67	0.66

注: 施工阶段中 1 为水下袋装砂棱体阶段; 2 为扭王字块阶段; 3 为施工结束。参数来源于天津市渤海海洋监测监视管理中心。

2.3 CNN 预测结果分析

设置过滤器、权重和偏置的初始值，将样本 1~17 作为学习样本基于式(1)~(8)进行训练学习，求解平方误差  $C_T$ ，并进行优化权重和偏置使  $C_T$  最小，最终得到最小平方误差  $C_T=0.006$ 。将最优过滤器、权重和偏置代入到模型中，作为训练好的 CNN。将 14~17 组样本作为检验样本，代入已经训练好的 CNN 进行检验，输出的沉降量结果分别为

327、360、385、772，沉降速率结果分别为 0.303 3、0.423 5、0.498 7 和 0.718 5，发现与实际结果基本一致，最大误差为 1.85%，说明本文建立的 CNN 方法满足要求。为了表明 CNN 相比其他方法有较高的精度，通过与 BP 神经网络预测结果相比，发现 BP 神经网络预测结果最大误差为 11.8%，最小误差为 0.6%。这可能由于 BP 神经网络受样本数量影响，容易陷入局部最优，导致预测精度不稳定(表 3)。

表 3 沉降速率预测结果及风险等级评估

样本	CNN 模型		BP 模型		实际沉降速率		风险等级
	沉降量/ mm	沉降速率/ (mm·d <sup>-1</sup> )	沉降量/ mm	沉降速率/ (mm·d <sup>-1</sup> )	沉降量/ mm	沉降速率/ (mm·d <sup>-1</sup> )	
14	327	0.303 3	342	0.274 1	323	0.30	低风险
15	360	0.423 5	350	0.304 1	363	0.42	低风险
16	385	0.498 7	361	0.351 1	388	0.50	低风险
17	772	0.718 5	753	0.805 5	758	0.72	低风险

表 3 中沉降速率均小于 1，为低风险，不需要调整施工进度。经实测数据观察，以上施工过程均为停工状态，并且袋装砂棱体打设施工里程可能偏离沉降观测点，对沉降点影响较小，最终导致沉降速率相对较低。样本 17 处于袋装沙棱体施工基本完成阶段，由于上部荷载较大，导致沉降速率逐渐增大。

3 结论

1) 本文将 CNN 应用在防波堤施工沉降速率预测中，与 BP 神经网络相比，CNN 具有降采样特点，预测精度较高，在防坡堤施工沉降速率预测中具有较高的可靠性；

2) 结合观测数据表明，该工程防波堤施工过程基本为低风险状态，施工进度正常，基于 CNN 预测的沉降速率能较准确地分析防波堤施工过程风险状态，动态指导和控制施工进度。

参考文献：

[1] TSINKER G P. Handbook of port and harbor engineering geotechnical and structural aspects[M]. New York: International Thomson Publishing, 1996.

[2] 徐洪钟, 吴中如, 李雪红. 相空间神经网络模型在大坝

安全监控中的应用[J]. 水利学报, 2001(6): 67-71.

[3] 苏怀智, 温志萍, 吴中如. 基于 SVM 理论的大坝安全预警模型研究[J]. 应用基础与工程科学学报, 2009, 17(1): 40-48.

[4] 杨杰, 杨丽, 李建伟, 等. 基于改进遗传算法-偏最小二乘回归的大坝变形监测模型[J]. 西北农林科技大学学报(自然科学版), 2010, 38(2): 206-210+218.

[5] 万臣, 李建峰, 赵勇, 等. 基于新维 BP 神经网络-马尔科夫链模型的大坝沉降预测[J]. 长江科学院院报, 2015, 32(10): 23-27, 32.

[6] 罗丹, 李昌彩, 吴长彬. 基于微粒群-BP 神经网络算法的堆石坝坝体变形监控模型研究[J]. 岩石力学与工程学报, 2012, 31(S1): 2926-2931.

[7] 齐银峰, 谭荣建. 基于改进粒子群优化算法的 BP 神经网络在大坝变形分析中的应用[J]. 水利水电技术, 2017, 48(2): 118-124.

[8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

[9] TAIGMAN Y, YANG MING, RANZATO M A, et al. Deepface: closing the gap to human-level performance in face verification[C]// IEEE Conference on computer vision and patern recognition. New York: IEEE computer society, 2014.