

## 基于CGA模型的盾构扭矩预测研究

刘映晶<sup>1</sup>, 卢敬科<sup>1</sup>, 陈城<sup>2</sup>, 刘维<sup>2</sup>

(1. 中天建设集团有限公司, 浙江杭州 322199; 2. 苏州大学轨道交通学院, 江苏苏州 215000)

**摘要:** 以盾构近距离下穿既有车站结构为背景, 提出了一种结合卷积神经网络(Convolutional Neural Networks, CNN)、门控制循环单元神经网络(Gated Recurrent Unit, GRU)和注意力机制(Attention)的新型盾构荷载预测模型。首先用CNN-Attention模型提取数据的高维空间特征并区分不同特征的重要性, 然后通过GRU模型提取数据的时序特性, 紧接着通过注意力机制提取出重要时间节点信息, 最后得出预测的结果。为验证所提模型的预测效果, 选取了4种现有的算法进行比较。结果表明所提出的模型在三种评价指标上均优于其他算法模型, 同时该模型还可为盾构刀具磨损、地表及结构变形等方面的预测研究提供思路。

**关键词:** 盾构隧道; 扭矩预测; 深度学习; 注意力机制; 时空特征

中图分类号: TU472

文献标识码: A

### Study on Shield Torque Prediction Based on CGA Model

LIU Yingjing<sup>1</sup>, LU Jingke<sup>1</sup>, CHEN Cheng<sup>2</sup>, LIU Wei<sup>2</sup>

(1. Zhongtian Construction Group Co., Ltd., Hangzhou, Zhejiang 322199, China;

2. School of Rail Transportation, Soochow University, Suzhou, Jiangsu 215000, China)

**Abstract:** Shield load is an important parameter of shield machine, and accurate prediction of shield load is very important to ensure the safe construction of shield tunnel. In this paper, a new load prediction model (CGA), combining convolutional neural network (CNN), gate recurrent unit neural network (GRU) and attention mechanism (Attention), is proposed based on the shield machine cross existing station at close range. The CNN-Attention model is first used to extract the high-dimensional spatial features of the data and distinguish the importance of different features. Then the GRU model is used to extract the temporal characteristics of the data, followed by the attention mechanism to extract the important time node information. Finally, the prediction results are obtained. To verify the prediction performance of the proposed model, four existing algorithms are selected for comparison. The results show that the proposed model in this paper outperforms other models in three evaluation metrics, and the proposed model can also provide reference for predicting researches on shield tunneling tool wear, surface and structural deformation, etc.

**Key words:** shield tunnel; torque prediction; deep learning; attention mechanism; spatial-temporal characteristic

随着“交通强国”战略的实施, 中国的城市轨道交通发展迅速, 2022年新增城市轨道交通运营线路21条, 先有53个城市开通运营城市轨道交通线路290条, 运营里程达到9584 km的地铁。其中盾构机凭借其机械化的优势, 可以有效地缩短

工期, 降低造价等优点被广泛地应用到城市地铁隧道建设中<sup>[1-2]</sup>。盾构掘进过程中不可避免地会对周边环境产生影响, 其影响程度受到多种因素的影响, 如地质参数、隧道几何参数、盾构施工参数等<sup>[3]</sup>。其中盾构施工参数(如盾构荷载, 注浆量

收稿日期: 2023-07-09

基金项目: 国家自然科学基金资助项目(51978430); 中天控股集团技术研发项目(ZTCG-GDJTYJS-JSKF-2021001)

作者简介: 刘映晶(1985-), 男, 广东汕头人, 博士, 高级工程师, 从事地下工程、机器学习方面的研究。

等)可以通过人为调整来降低施工过程对周边环境的影响。盾构荷载则是盾构切削掘进的主要动力,荷载过大会造成周边环境的失稳和刀具的磨损加快,荷载过小会导致盾构机切削效率较低,影响过程进度<sup>[4]</sup>,因此对于盾构荷载的精准预测可有助于技术人员及时调整工程措施以保证工程的顺利完工。

传统的盾构荷载预测方法主要有理论分析<sup>[5-6]</sup>、数值模拟<sup>[7]</sup>和模型试验<sup>[8-9]</sup>。传统的预测方法可以预测出荷载的变化趋势,但由于其受到多种因素的制约影响导致预测数值的准确性较低。随着人工智能技术的迅速发展,其为荷载预测提供了新的思路。通过机器学习模型对采集到的数据进行训练学习,挖掘数据的变化规律,然后对其未来变化规律进行预测。Gao等<sup>[10]</sup>利用 Support Vector Machine (SVM)建立了基于原位地质数据和运行数据的盾构机荷载预测模型,并取得了良好的效果。Salimi等<sup>[11]</sup>通过使用岩体分类系统的输入参数,重点提出了一种基于回归树和遗传编程的新模型,用于估计盾构机的性能。然而,由于支持向量机回归或随机森林的输出只由当前的输入决定,而没有以前的学习信息的帮助,它们不适合实时预测 TBM 的运行参数。

深度学习是机器学习领域的一个新兴领域,在计算机视觉<sup>[12]</sup>、自然语言处理<sup>[13]</sup>和语音识别<sup>[14]</sup>等方面已经取得了丰硕的成果。近年来随着大量的监测数据被收集整理,深度学习技术逐渐被用来预测盾构的荷载。Chen等<sup>[15]</sup>建立了一个基于 LSTM 的神经网络模型,用于根据上升阶段的现场数据预测稳定阶段的扭矩和推力,使得实时调整 TBM 隧道参数成为可能。考虑到网络结构的优化,Qin等<sup>[16]</sup>基于 GRU 网络设计了多步预测模型,并通过实验验证了模型性能的准确

性。Lin等<sup>[17]</sup>采用粒子群优化算法对 GRU 模型进行优化,提出了一种新的模型框架用于盾构荷载预测。

由此可见机器学习技术在工程领域已经取得了一些成果,但尚有一些可以提高的方面:(1)现有的机器学习模型主要考虑了盾构荷载数据的时序特性,对数据的空间特征挖掘不充分;(2)忽略了重要时间节点对预测结果的影响,因此模型的预测精度还有进一步提升的空间。本文根据盾构荷载数据的特征提出融合卷积神经网络(Convolutional Neural Networks, CNN)、门控循环神经网络(Gated Recurrent Unit, GRU)和注意力机制(Attention)的新算法(CNN-GRU-Attention, CGA),首先通过融合注意力机制的卷积神经网络(CNN-Attention)挖掘数据的空间特征并突出不同特征的影响程度,再通过融合 Attention 机制的多层门控循环单元(GRU)提取数据的时序特征,并对不同时刻的输出进行权重赋值,得到最终的扭矩预测结果。本文提出的算法不但可以充分的挖掘数据的时空特征,还可以突出重要特征和时间节点对预测结果的影响,从而提高预测精度。

## 1 CGA 算法原理

本文结合卷积神经网络、循环神经网络和注意力机制提出 CGA 算法,具体算法结构如图 1 所示。

### 1.1 CNN-Attention

盾构荷载受到许多因素特征的影响,比如盾构操作参数、地层参数、隧道几何参数等,充分挖掘各因素特征对荷载变化的影响有助于提高预测精度。卷积神经网络最初被广泛地运用于图像的

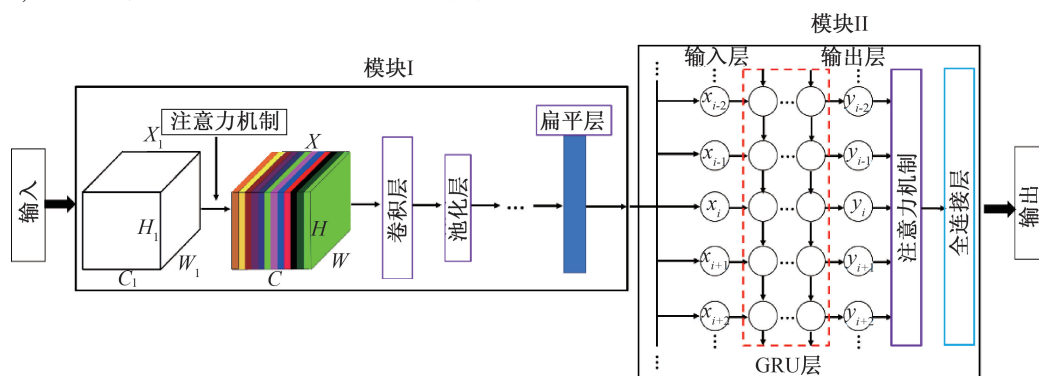


图 1 CGA 模型

Fig. 1 CGA model

识别,因其可以通过卷积和池化等运算保持图像的空间连续性,提取图像的局部特征。但面对高维度特征的数据,卷积运算不能区分不同特征的重要性。Attention 机制最初是对人类视觉的研究,由于信息的复杂性使得人类往往会优先关注重要的信息,从而忽略一些次要的信息。类似地,Attention 机制可以帮助模型在训练预测过程中挖掘数据内部的重要特征,忽略次要特征,使得预测的结果更加准确<sup>[18]</sup>。因此本文引入通道域注意力机制,对通道域上不同特征的重要性进行学习,使得预测结果更符合实际。具体步骤如图 2 所示,首先将不同的数据特征构建在张量  $X_1$  的通道域上 ( $C_1$ ),然后原始矩阵  $X_1$  卷积 ( $F_{tr}$ ) 运算得到矩阵  $X$ ,将矩阵  $X$  通过最大池化操作 ( $F_{sq}(\cdot)$ ) 得到沿通道方向的单位长度矩阵  $1 \times 1 \times C$ 。紧接着经过两个全连接层,得到权重赋值过后的单位矩阵,将更新后的单位矩阵对原矩阵进行更新,得到新的矩阵  $X$ ,再经过全连接层等结构,将图形式的数据转换成向量形式,作为模块 II 的输入。

### 1.2 GRU-Attention

盾构荷载变化与掘进时间密切相关,具有明显的时序性。因此还需要考虑数据的时序特征。循环神经网络(Rerrent Neural Network, RNN) 适合处理时序性数据,但其因网络结构的原因,存在梯度消失和梯度爆炸的缺点。LSTM 和 GRU 模型是 RNN 模型的改进结构,有效地避免了上述存在的问题。GRU 模型是 LSTM 神经网络的一种变体,其结构更加简单,对于时序性数据的预测效果也较好。GRU 模型中只有更新门和重置门。更新门用于控制前一时刻的状态信息被带入到当前状态中的程度。重置门控制前一状态有多少信息被写入到当前的候选集上。GRU 的计算公式为

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (1)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (2)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t \times h_{t-1}, x_t]) \quad (3)$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \quad (4)$$

式中:  $x_t$  为当前时刻的输入值;  $h_{t-1}$  为前一个神经元的输出;  $z_t$  和  $r_t$  分别表示更新门和重置门;  $W_z$  和  $W_r$  分别为更新门和重置门的神经单元的权重参数。

有研究表明<sup>[19]</sup> 多层网络结构预测效果优于单层结构,故本算法中采用多层 GRU 结构挖掘数据的时序特性,在得到 GRU 网络结构的输出后,考虑到不同时刻输出值  $y_i$  对最后输出值的影响,引入注意力机制,自动学习不同时刻  $y_i$  的权重,最后得出模型的输出,网络结构如图 1 中的模块 II 部分所示。

基于以上分析,本研究以杭州某地铁盾构工程为背景,采用 CGA 算法对盾构的扭矩进行预测,具体的细节如下图 3 所示。

## 2 工程背景与数据预处理

### 2.1 工程背景

本文以杭州地铁 7 号线某在建区间隧道下穿既有车站结构为研究背景。如图 4 所示,盾构掘进过程中需近距离下穿既有车站,新建隧道顶部距离既有车站的底板仅 1.52 m,既有车站易受到盾构掘进施工的影响,因此工程施工过程中,盾构掘进参数的设定十分重要,参数过大则会对既有结构产生不利的影响。

### 2.2 工程地质

根据工程勘察报告,区间盾构主要穿越地下地层由杂填土地层(地层①)、砂质粉土层(地层②)、粉土夹砂质粉土(地层③<sub>s</sub>)、砂质粉土(③<sub>7</sub>)、淤泥质粉质黏土(⑥<sub>2</sub>)、粉质黏土(⑨<sub>2</sub>)、细砂(地层⑫<sub>1</sub>)组成,如图 4 所示。天然土为中硬、中密土。盾构机掘进区间主要穿越淤泥质粉质黏土(⑥<sub>2</sub>)




图 2 CNN-Attention 模型  
Fig.2 CNN-Attention model

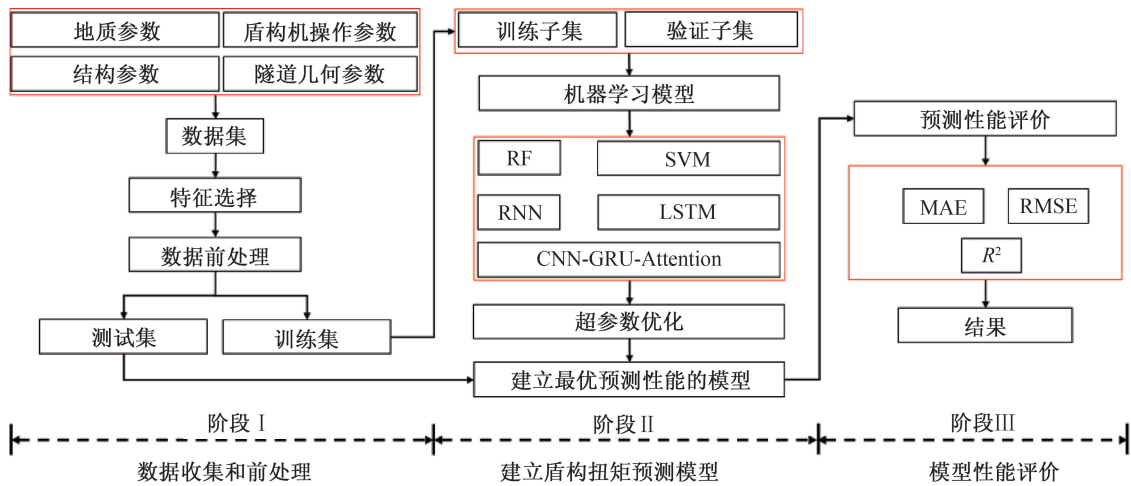


图 3 盾构扭矩预测流程图

Fig. 3 Flow chart of the shield torque prediction

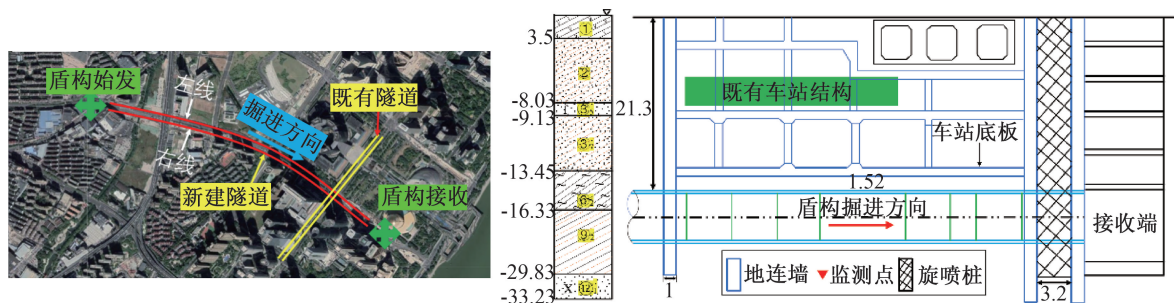


图 4 工程概况 (单位:m)

Fig. 4 Project overview (unit: m)

表 1 土的物理力学参数

Tab. 1 Physical and mechanical parameters of the soils

土层	容重 $\gamma / (\text{kN} \cdot \text{m}^{-3})$	含水量 $w / \%$	黏聚力 $C / \text{kPa}$	内摩擦角 $\varphi / (^\circ)$	压缩模量 $E_s / \text{MPa}$	泊松比 $\nu$
<①> 填土	17.5	—	8.0	15.0	3.0	0.33
<②> 砂质粉土	19.4	26.7	6.0	29.0	8.5	0.32
<③ <sub>3</sub> > 粉土夹砂质粉土	19.6	24.8	5.0	33.0	14.0	0.28
<③ <sub>7</sub> > 砂质粉土	19.7	23.6	5.0	32.0	15.0	0.27
<⑥ <sub>2</sub> > 淤泥质粉质黏土	19.2	29.5	7.0	24.0	7.0	0.34
<⑨ <sub>2</sub> > 砂质粉土	18.2	36.8	12.0	16.0	4.0	0.37

和粉质黏土(⑨<sub>2</sub>)层。土体物理力学参数见表 1。

### 2.3 盾构机刀盘

根据地质勘探资料和工程经验,本工程采用土压平衡盾构机。工程建设中采用中铁装备 280 #。盾构机主要参数如表 2 所示。刀具配置如图 5 所示,刀盘配置包括 4 把双楔形滚刀、32 把单楔形滚刀、8 把刮刀和 36 把切刀。滚刀与面板相对高度为 175 mm,切刀高度为 155 mm,刮刀高度为 130 mm,刀间距为 25 mm。

表 2 盾构机参数

Tab. 2 Shield machine parameters

参数	数值
盾构机型号	中铁装备 280#
直径/mm	6 470
刀盘转速/( $\text{r} \cdot \text{min}^{-1}$ )	0~3.7
最大推力/t	4 255
额定扭矩/( $\text{kN} \cdot \text{m}$ )	6 000
脱困扭矩/( $\text{kN} \cdot \text{m}$ )	7 200

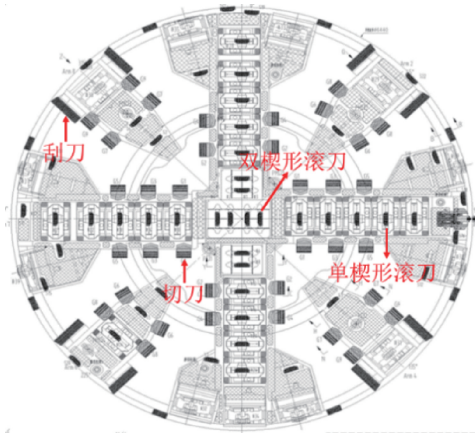


图 5 盾构机刀盘布置

Fig. 5 Cutter head layout of the shield machine

## 2.4 数据的选取

本文选取的数据来自于工程施工过程中的监测系统,盾构掘进过程中涉及到的参数较多,大致可分为四类:盾构机参数、隧道几何参数和地层参数。盾构机参数主要包括盾构直径、推力、扭矩、转速、推速、土仓压力、刀盘温度等。隧道几何参数主要包括隧道的埋深、直径。地层参数主要包括黏聚力、内摩擦角等。盾构机参数相关的数据来源于盾构机监测系统,隧道几何参数和地层参数来源于工程勘察报告。选取的输入参数由盾构机参数、隧道几何参数和地层参数组成,由于参数的种类繁多,选取所有的参数作为输入参数是不现实的,因此本文在借鉴已有研究的基础上<sup>[20-21]</sup>,结合本工程的特点,共选取出 8 种输入参数,如表 3 所示。数据的获取为方便神经网络的训练,需将输入数据进行归一化处理,本文拟采用 max-min 归一化方法,计算公式如下所示。

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

式中:  $x$  为实际值;  $x_{\max}, x_{\min}$  为实际值中的最大值和最小值;  $x'$  为归一化后的值。

表 3 输入特征的描述

Tab. 3 Description of the input variables

参数	最大值	最小值	平均值
掘进速度/(mm · min <sup>-1</sup> )	3.40	0.24	1.82
转速/(r · min <sup>-1</sup> )	1.80	0.60	1.20
土仓压力/MPa	0.27	0.12	0.19
盾构姿态/mm	41.00	0.00	20.50
粘聚力/kPa	12.00	7.00	9.50
注浆量/L	0.10	0.00	0.05
刀盘温度/℃	54.20	40.50	47.35
注浆压力/MPa	0.63	0.45	0.54

## 3 模型的建立与训练

### 3.1 数据的划分

本节先采用试错法<sup>[22]</sup>(trial-and-error method)对数据集进行划分,经过试错分析,最终确定训练集为 80%(4 000),验证集为 10%(500),测试集为 10%(500)。训练集、验证集与测试集之间应该互斥。

### 3.2 模型的构建

盾构的扭矩具有明显的时空特征<sup>[23]</sup>,因此本文通过盾构掘进的时间和距离来构建 CNN 结构的时空域,即为图 1 中的  $H_1$  和  $W_2$ ,盾构切削的数据特征维度构成通道域,即为  $C_1$ 。如此可以得到 CNN 模型的初始输入,然后经过通道域注意力机制对初始输入进行更新,得到新的输入,然后采用卷积、池化、展平等一系列过程,提取数据的高维空间特征,得到一维阵列,作为 GRU-Attention 模型的输入,最后通过全连接层和输出层得到预测结果。

本次模型构建经反复尝试对比来搜索最优超参数。具体参数如表 4 所示。

表 4 模型超参数

Tab. 4 Model hyperparameters

模型	超参数
CGA	卷积层:2;池化层:2;卷积核:32;批量大小:40;损失函数:MSE;批量大小:20;迭代次数:200;网络层数:3;激活函数:Sigmoid 函数

### 3.3 模型评价指标

预测的精度主要是指预测值  $y'_i$  与真实值  $y_i$  之间的误差,常用评价指标有 RMSE(均方根误差)、MAE(平均绝对误差)及  $R^2$ (确定系数)来评估回归分析的拟合度。各评价指标如下:

$$\alpha_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (6)$$

$$\alpha_{RMSE} = \left[ \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \right]^{1/2} \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

## 4 结果与讨论

为验证本文所提出的模型的有效性,将本文

所提模型与随机森林(Random Forest, RF),支持向量(Support Vector Machine, SVM),循环神经网络(Rerrent Neural Network, RNN),长短期记忆神经网络(Long Short-Term Memory, LSTM)模型进行对比。每次实验均在训练集上训练,在验证集上对性能进行分析,调整超参数,最终在测试集上验证结果。

#### 4.1 模型性能

为验证模型的泛化能力,本节以误差值为衡量指标。训练集和验证集上的损失值如图6所示,从图中可以看出随着迭代次数的增加,训练集和验证集上的损失值迅速降低到最小值,并开始趋于稳定,表明模型可以学习到数据的内部特征,掌握数据的变化规律。并且在训练子集和验证子集上最终的损失值相差较小,表明本文提出的模型在训练集和验证集上有较好的泛化能力。




图6 训练集和验证集的损失值

Fig. 6 Loss values of testing and validation data

#### 4.2 模型对比

各模型在测试集上的预测结果如表5和图7所示,从表5中可以看出本文提出CGA模型得到的MAE、RMSE值最小, $R^2$ 值最大,表明该模型比其他4种现有模型的预测效果更优。且深度学习模型的预测效果要优于其他两种模型(RF和SVM),这主要可以归因于深度学习方法强大的数据挖掘能力。此外,CGA模型的预测效果也优于RNN和LSTM模型,这主要是因为本文提出的模型还考虑扭矩数据的空间特征,并引入了注意力机制,使得预测精度得到了较大的提升。根据表5中的数据进一步绘制出图7的对比结果图可以发现:对比4种基准模型,本文提出的CGA模型的预测结果得到了大幅度的提高;图8展示了预测曲线图,可以发现CGA模型得到的预测曲线与监测曲线吻合度更高。

表5 模型评价

Tab. 5 Model evaluation

模型	平均绝对误差 MAE	均方根误差 RMSE	确定系数 $R^2$
RF	28.06	38.74	0.453
SVM	33.65	49.22	0.386
RNN	18.31	27.74	0.712
LSTM	11.62	15.61	0.795
CNN-GRU-Attention	3.36	4.93	0.871

#### 4.3 消融实验

本文提出的CGA模型是一个组合模型,为了验证各个子模型(CNN、GRU、CNN-Attention和GRU-Attention)的作用,本节以各个子模型为对照组进行消融实验。

从表6中各指标的对比可以看出,基于CNN模型得到的预测效果最差,主要是因为盾构掘进的各项参数具有明显的时序性,而传统的CNN模型不能有效地挖掘数据的时序特征,所以预测的效果最差,但融合了注意力机制的CNN-Attention模型的预测效果得到了提升,表明注意力机制有助于提高模型的预测精度;GRU-Attention模型的预测效果比GRU模型得到了一些提升,主要是因为注意力机制可以突出重要的时间节点信息,使得预测的结果更加精准;本文所提出的CGA模型的预测精度最高,表明其可以整合各个子模型的优势,即通过CNN结构提取数据的空间特征,还采用GRU结构挖掘数据的时序规律,并通过注意力机制突出重要的特征和时间节点信息。

表6 模型评价

Tab. 6 Model evaluation

模型	平均绝对误差 MAE	均方根误差 RMSE	确定系数 $R^2$
CNN	21.57	29.51	0.692
GRU	9.67	12.47	0.802
CNN-Attention	12.61	17.38	0.787
GRU-Attention	5.62	9.61	0.843
CNN-GRU-Attention	3.36	4.93	0.871

## 5 结论

本文通过构建CGA模型,将机器学习运用到盾构荷载预测领域,实现了对盾构扭矩高精度的




图 7 模型评价指标

Fig. 7 Model evaluation indexes




图 8 不同模型的扭矩预测曲线图

Fig. 8 Torque prediction results for different models

预测,具体结论如下:

1) 本文基于 CNN 神经网络、GRU 神经网络、Attention 机制提出的扭矩预测模型不但可以挖掘监测数据的高维特征和时序特性,还可以突出重要特征和时间节点信息。

2) 通过实验发现本文提出的预测模型,在 MAE、RMSE 和 R<sup>2</sup> 三种指标上均优于四种现有的模型,且通过曲线图发现本文提出的模型对扭矩的预测具有更高的精度。

3) 本文提出的预测模型不仅适用于扭矩预测,而且可为盾构刀具磨损、地层及结构变形等时

序预测开拓思路,并能为城市盾构隧道的预警提供参考。

参考文献:

[1] WANG L, YANG X, GONG G, et al. Pose and trajectory control of shield tunneling machine in complicated stratum[J]. Automation in Construction, 2018, 93: 192-199.

[2] HUO J, XU Z, MENG Z, et al. Coupled modeling and dynamic characteristic of TBM cutterhead system under uncertain factors [J]. Mechanical Systems and Signal Processing, 2020, 140: 106664.

- [3] YANG B, CHEN S, SUN S, et al. Vibration suppression of tunnel boring machines using non-resonance approach [J]. *Mechanical Systems and Signal Processing*, 2020, 145: 106969.
- [4] DENG K, TANG X, WANG L, et al. On the analysis of force transmission performance for the thrust systems of shield tunneling machines [C]//*Intelligent Robotics and Applications: Second International Conference, ICIRA 2009*, Singapore, December 16-18, 2009. Proceedings 2. Springer Berlin Heidelberg, 2009: 268-278.
- [5] 徐冲. 砂卵石地层泥水平衡盾构隧道掘进参数控制 [J]. *铁道建筑*, 2019, 59(02): 94-97.
- [6] 李杰, 张斌, 付柯, 等. 基于现场掘进数据的复合地层盾构掘进性能预测方法研究 [J]. *现代隧道技术*, 2019, 56(04): 97-104.
- [7] FARROKHH E. A study of various models used in the estimation of advance rates for hard rock TBMs [J]. *Tunnelling and Underground Space Technology*, 2020, 97, 103219.
- [8] ZHAO P X, ZHUO R S, LI S G, et al. Analysis of advancing speed effect in gas safety extraction channels and pressure-relief gas extraction [J]. *Fuel*, 2020, 265, 116825.
- [9] HU X, ZHANG Z. Physical model test on the behavior of large slurry shield-driving tunnel in soft clay [J]. *Journal of Shanghai Jiaotong University (Science)*, 2013, 18: 693-698.
- [10] GAO L, LI X. Utilizing partial least square and support vector machine for TBM penetration rate prediction in hard rock conditions [J]. *Journal of Central South University*, 2015, 22(01): 290-295.
- [11] SALIMI A, ROSTAMI J, MOORMANN C, et al. Application of non-linear regression analysis and artificial intelligence algorithms for performance prediction of hard rock TBMs [J]. *Tunnelling and Underground Space Technology*, 2016, 58: 236-246.
- [12] 张慧, 王坤峰, 王飞跃. 深度学习在目标视觉检测中的应用进展与展望 [J]. *自动化学报*, 2017, 43(08): 1289-1305.
- [13] 黎新川, 方艺, 方涛, 等. 深度学习在自然语言处理中的运用 [J]. *电子技术*, 2022, 51(12): 206-207.
- [14] 朱小燕, 利节, 王东. 深度学习和图像识别 [J]. *电子技术应用*, 2022, 48(11): 1.
- [15] CHEN H, XIAO C, YAO Z, et al. Prediction of TBM tunneling parameters through an LSTM neural network [C]//*2019 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. IEEE, 2019: 702-707.
- [16] QIN C J, SHI G, TAO J F, et al. An adaptive hierarchical decomposition-based method for multi-step cutterhead torque forecast of shield machine [J]. *Mechanical Systems and Signal Processing*, 2022, 175: 109148.
- [17] LIN S S, SHEN S L, ZHOU A. Real-time analysis and prediction of shield cutterhead torque using optimized gated recurrent unit neural network [J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2022, 14(4): 1232-1240.
- [18] BAHDANAU D, CHO K H, BENGIO Y. Neural machine translation by jointly learning to align and translate [C]//*3rd International Conference on Learning Representations*, 2015.
- [19] IGNACIO E, DAVID L, FERNANDO M, et al. From single layer to multilayer networks in mild cognitive impairment and Alzheimer's disease [J]. *Journal of Physics: Complexity*, 2021, 2:4.
- [20] CHEN C, WU B, JIA P, et al. A novel hybrid deep neural network prediction model for shield tunneling machine thrust [J]. *IEEE Access*, 2022, 10: 123858-123873.
- [21] LIU B, LI L, FANG X L, et al. Hard-rock tunnel lithology prediction with TBM construction big data using a global-attention-mechanism-based LSTM network [J]. *Automation in Construction*, 2021, 125: 103647.
- [22] ZHANG D M, ZHANG J Z, HUANG H W, et al. Machine learning-based prediction of soil compression modulus with application of 1D settlement [J]. *Journal of Zhejiang University-SCIENCE A*, 2020, 21(6): 430-444.
- [23] 于广明, 雷军, 张鹏辉, 等. 盾构隧道施工引起地表沉降的“五维”空间效应探索及其展望 [J]. *青岛理工大学学报*, 2022, 43(02): 1-10.

(责任编辑 周雪梅)