

# 基于自动深度学习盾构掘进姿态预测与控制

秦灏

(上海建工集团股份有限公司,上海市200080)

**摘要:**提出了基于自动深度学习(AutoDL)算法和多目标优化算法的结合可实现数据驱动的姿态偏差控制指导,用于盾构掘进姿态的预测与控制,以解决现有盾构掘进姿态预测中所面临的执行难度高、成本高、效率低等问题,可用于自动精准地预测盾构掘进姿态随着工程进展的动态变化趋势,并针对盾构机施工状态执行多目标优化算法,快速自动搜寻最优策略,实时调整合适的盾构操作参数,减少对于现场操作人员经验和主观判断的依赖。以上海市天然气主干管网崇明岛—长兴岛—浦东新区五号沟LNG站管道工程隧道A线工程为例,展示该算法框架的优越性。研究结果有助于降低深度学习进入盾构智能控制领域的门槛,推动智能盾构发展。

**关键词:**自动深度学习;时间窗;盾构姿态;粒子群优化算法;多目标优化算法

中图分类号:U455.43

文献标志码:A

文章编号:1009-7716(2024)02-0200-06

## 0 引言

大量研究已经表明,深度学习算法在盾构机姿态预测的准确率上非常有优势,相较于集成树、支持向量机等传统机器学习模型,深度学习更能适应盾构机运行过程中采集到的各种参数的拟合,从而达到更精准的预测结果。但是,深度学习对开发人员的要求也提出了更苛刻的要求,除了常规机器学习需要的数据预处理、特征工程外,深度学习模型的超参数优化变成了影响深度学习模型性能最重要的因素。然而,深度学习的超参数比传统机器学习算法多得多,这就让本就困难重重的算法调参变得更具有挑战性。这些困难都使得深度学习对算法工程师的专业能力要求极高,这也限制了深度学习算法在盾构掘进姿态预测方面的使用。因此,本文旨在提供一种能够将数据预处理、特征工程自动化,并能自动选择最适合的深度学习算法及其最优超参数的自动深度学习框架来完成盾构姿态的预测和评估,来降低深度学习对开发人员专业技能苛刻的要求,使得深度学习能够低成本高效地用于盾构姿态预测与控制。

综上,之前的研究主要是对比不同机器学习算法在盾构掘进性能预测中的表现,却很少有学者研究如何将整个流程自动化。例如,吴惠明等人<sup>[1]</sup>基于

盾构施工中的大量数据和机器学习中的支持向量机算法,提出一种预测盾构姿态与优化施工参数的方法;Xianlei Fu等人<sup>[2]</sup>提出了深度学习的方法来预测盾构姿态;Cheng Zhou等人<sup>[3]</sup>使用混合深度学习方法实现了6个盾构姿态参数的预测,并与另外3种算法进行了对比。

基于之前研究存在的局限性,本文提出了基于自动深度学习(AutoDL)的盾构姿态预测和控制解决方案。基于粒子群优化算法的自动机器学习框架,该框架包含标准化、归一化和最大绝对值标准化共3种数据预处理方法,ANN、RNN、Bi-RNN、LSTM和GRU共5种深度学习算法,通过加时间窗的方式对数据集进行监督学习,能够输出反映盾构姿态的前后端及铰接处的水平和垂直偏差的6个预测值。自动深度学习中的参数都是由粒子群优化算法在超参数空间自动搜索的,不需要人工调参。将数据集读入之后,该AutoDL框架能够自动完成数据预处理、特征工程,并自动选择最合适的深度学习算法及其最优超参数进行预测,并返回效果最优的模型及该模型在测试集上的表现。

遵循“数据收集和预处理—基于自动深度学习盾构姿态偏差预测—基于多目标优化的盾构姿态偏差控制”3个步骤,检测该自动深度学习方法在上海市天然气主干管网崇明岛—长兴岛—浦东新区五号沟LNG站管道工程隧道A线工程中的实战效果。在这个案例中,将介绍如何逐步搭建深度学习框架以用于实际工程,展示自动深度学习框架在盾构姿态偏差的

收稿日期:2023-06-02

作者简介:秦灏(1970—),男,本科,高级工程师,从事工程管理工作。

预测效果,并对其预测结果进行分析讨论评估,最后得出结论并总结本研究存在的局限,推动智能盾构发展。

## 1 工程概况

上海市天然气主干管网崇明岛—长兴岛—浦东新区五号沟 LNG 站管道工程,自崇明岛南岸崇明清管站开始,沿 G40 沪陕高速敷设,经长兴岛至浦东新区 G40、G1501 立交,向南沿浦东新区 G1501 至规划巨峰路,向东至五号沟 LNG 站,管道总长约 24.5 km。

管道工程过江段长约 15.2 km,工程位置如图 1 所示,采用泥水平衡盾构法施工,包括 A、B 两线。A 线从长兴岛至崇明岛,长约 8 237 m,穿越长江北港;B 线从五号沟至长兴岛,长约 6 931 m,穿越长江南港。隧道施工结束后敷设一根 6 MPa、DN800 超高压天然气管道。管道采用单侧布置(见图 2),管道下部为滑动支座及导向支座,支座在隧道内的 700 mm 高混凝土平台上。为克服隧道内充水后的浮力,管道上方设置防浮块以确保管道稳定。防浮块采用混凝土预制鞍型块。



图 1 工程位置图

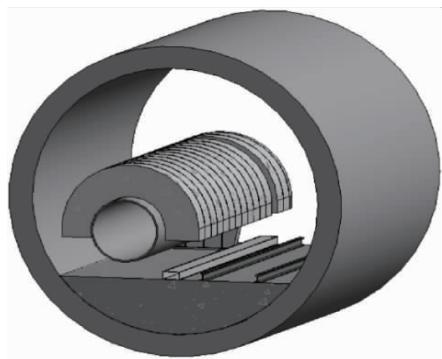


图 2 天然气管道布置示意图

该工程为上海市天然气主干管网崇明岛—长兴岛—浦东新区五号沟 LNG 站管道工程隧道 A 线(以

下简称隧道 A 线),全长 8 236.862 m,采用泥水平衡盾构法施工,由一台盾构机一次性掘进完成,从长兴岛北工作井至崇明岛工作井,线路起始于长兴岛北工作井,走行在长江大桥东侧,与长江大桥基本平行,出长兴岛北工作井后,线路穿越长兴岛北子江堤、长江北港水域(其中南侧 4 km 主要为深水水域,北侧约 3 km 为滩涂区域)、崇明岛主江堤,然后上行接入崇明岛工作井。

## 2 研究内容及方法

### 2.1 5 种深度学习模型

选取粒子群算法(PSO)作为深度学习框架的超参数优化算法。该框架嵌入 5 种常用的时序预测深度学习模型,包括多层感知机(MLP)、循环神经网络(RNN)、双向循环神经网络(Bi-RNN)、长短期记忆网络(LSTM)以及循环神经网络(GRU),深入探究盾构数据间的复杂映射关系、因果关系及动态特征。自动深度学习框架可依据数据特点自动选取预测效果最好的深度学习模型。

### 2.2 自动深度学习

#### 2.2.1 数据采集和预处理

由于传感器不稳定、地下环境复杂等不利因素,所获取的监测数据会包含一定程度的噪声,因此需要设计一个大数据预处理流程,包含自动处理缺失数据、过滤异常值、删除冗余信息、归一化标准化原始数据、编码分类变量、贝叶斯小波去噪等关键步骤,形成高质量可用数据,确保探索性数据挖掘过程的高效性及结果的可靠性。

数据采集系统获取盾构原始数据之后,首先需要剔除 0 值和缺失值。

设输入的运行参数特征为  $x_n = \{x_1, x_2, x_3, \dots, x_n\}^T$ ,则采用下式进行数据清洗:

$$F = f(x_1)f(x_2)f(x_3)\cdots f(x_n)$$

$$f(x_i) = \begin{cases} 1, & x_i \neq 0 \\ 0, & x_i = 0 \end{cases}$$

其中  $f(x_i)$  用于检查特征  $x_i$  是否是 0 值或缺失值,一条数据中若存在任意特征的  $f(x_i)$  为 0,则该条数据的  $F=0$  即被判定为无效。

为了保证预测的可靠性,还需要对异常值和噪声数据进行处理。本研究通过计算每条数据的标准分与上限值  $m$  进行比较,标准分超过  $m$  的数据会被判定为无效,具体流程如下:

$$x_{ki} = \frac{x_i - \bar{x}_i}{S}$$

$$f(x_{ki}) = \begin{cases} 1, & x_{ki} \leq m \\ 0, & x_{ki} > m \end{cases}$$

$$F_k = f(x_{k1})f(x_{k2})f(x_{k3}) \cdots f(x_{kn})$$

其中  $x_i$  和  $S$  分别是整个分布的平均值和标准差, 算出每个数据点的标准分  $x_{ki}$  之后, 决定函数  $f(x_{ki})$  根据设定的上限值  $m$  判定该数据点的有效性, 再由  $F_k$  判定该条数据的有效性。

上述步骤完成后, 就需要完成特征工程。由于盾构的数据采集系统已经非常健全, 因此原始数据中包含大量对于预测盾构姿态帮助不大甚至无用的特征信息, 因此首先需要进行特征提取, 优选出对于预测贡献最大的特征, 多余的特征不仅会降低模型的效率, 还会影响预测的精度。特征选取完成后, 需要对数据集进行规范化, 使得数据的变化范围和分布形式更适合深度学习模型训练。

本研究将数据规范化作为自动深度学习的参数之一, 可选择的数据规范化方法有: 归一化、标准化和最大绝对值标准化。

归一化的公式如下:

$$z = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

式中:  $x_{\min}$  和  $x_{\max}$  分别为输入特征的最小值和最大值。

标准化的公式如下:

$$z = \frac{x - \mu}{\sigma}$$

式中:  $\mu$  和  $\sigma$  分别为输入特征的均值和标准差。

最大绝对值标准化的公式如下:

$$z = \frac{x}{|x|_{\max}}$$

式中: 为特征  $x$  中的最大绝对值。

## 2.2.2 超参数优化与结果评估

完成数据采集和预处理之后, 算法工程师将面临两个新的挑战: 选择合适的深度学习算法和超参数优化。手动调参需要大量专业知识和经验积累, 且存在成本高、效率低等缺点。因此, 本研究提出的自动深度学习正好能解决这些问题。

对于确定的数据集, 影响因素主要在于其超参数的选择。我们需要确定网络隐藏层数、各层神经元的数量、激活函数、优化器、训练批次、批次大小、迭代次数。

我们引入 MAE 和 RMSE 对预测结果进行评估。MAE 反映的是预测值和真实值之间的平均绝对离

差, RMSE 反映预测值和真实值之间的均方根误差。两个评价指标的定义如下:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N [f_i(x) - y_i]$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N [f_i(x) - y_i]^2}$$

式中:  $N$  为数据集参与预测的样本数量;  $f_i(x)$  为预测值;  $y_i$  为真实值。

## 2.3 多目标优化算法

同时将 4 个目标(HDH, VDH, HDT, VDT)控制在合理的数值范围内可以被描述为一个多目标优化即 Multi-Objective Optimization(MOO)问题, 基于自动深度学习框架建立的深度学习模型, 以盾构机移动轨迹偏差最小为目标, 进行 MOO 过程, 寻求自适应于当前工程状态的盾构操作参数调整最优决策方案。

为了达到成本函数的最小值, 可以获得一组帕累托最优解, 而不是单个解, 旨在揭示目标的不同权衡。为了促进最优决策, 帕累托前沿的非支配解比其他解更可取。

$$\min f(x) = \{f_1(x), f_2(x), f_3(x), f_4(x)\} \\ s, t, x \in \Omega \in R^n$$

式中:  $\Omega$  为变量可行空间;  $n$  为决策变量的维数。

NSGA-II (non-dominance Sorting Genetic Algorithm II, 非支配排序遗传算法 II) 作为 MOO 问题的可行解决方案, 具有收敛速度快、种群多样性大的优点。

## 3 盾构姿态自动预测与控制的工程应用

隧道 A 线在盾构掘进过程中, 数据采集系统会实时监测运行参数和地质参数, 并以 20 mm 的净行程间隔显示数据。在每个环上获得约 1 000 组原始数据, 总共约 300 万组数据被用于本研究。虽然数据采集系统采集了超过 1 000 个参数, 但只选取对偏差预测最关键的参数作为特征, 过多相关性较低的参数只会导致更大的预测误差和更低的模型效率。本研究所选取的特征及其详细描述见表 1、表 2。

这些获取到的特征首先按上文介绍的预处理方法, 先删除 0 值和缺失值, 然后再用决定函数  $f(x_i)=0$  和  $F=0$  将标准分大于 3 的异常值剔除; 随后, 按照上文对数据进行规范化处理, 处理结果作为自动深度学习的参数。

## 3.1 预试验段

完成预处理的数据集被划分成 3 组: 前 70% 作

表1 输入变量

参数	符号	单位	描述
总推进力	$x_1$	kN	使盾构掘进的力
掘进速率	$x_2$	mm/min	每分钟开挖的距离
刀盘压力	$x_3$	MPa	刀盘上承受的土压力
排泥水压	$x_4$	kPa	排出泥浆的水压力
刀盘回转速度	$x_5$	rpm	刀盘旋转的速度
千斤顶推力	$x_6, x_7, x_8, x_9$	kN	分别在盾构上下左右的千斤顶提供的推力
推进油缸行程	$x_{10}, x_{11}, x_{12}, x_{13}$	mm	用于调整盾构头部和中部之间角度的油缸行程

表2 输出变量

参数	符号	单位	描述
HDA	$y_1$	mm	水平偏差 前端
HDJ	$y_2$	mm	水平偏差 铰接
HDT	$y_3$	mm	水平偏差 后端
VDA	$y_4$	mm	竖直偏差 前端
VDJ	$y_5$	mm	竖直偏差 铰接
VDT	$y_6$	mm	竖直偏差 后端

为训练集,中间10%作为验证集,最后的20%作为测试集。已有的研究证实,得益于日益高效的数据采集系统,我们能实时地获得最新的数据,这就方便了我们进行在线实时预测。

首先,开展的试验是探究时间窗n对于预测结果的影响。已有的研究证实,引入时间窗进行时空结合的预测能很大程度地提升预测效果,尤其是上一时刻 $t-1$ 的特征对于当前时刻t的偏差预测贡献极高。因此,本研究统一将 $x_1-x_7$ 的上一时刻 $t-1$ 和当前时刻t的值同时作为当前时刻偏差的特征。选取时间窗变量 $n=0,1,2\cdots,7$ 用于训练和预测。例如:当时间窗 $n=2$ 时,将 $t-1$ 和t时刻的 $x_1-x_7$ 以及 $t-2$ 到 $t-1$ 的y作为输入特征来预测t时刻的y;当时间窗 $n=7$ 时,仍然将 $t-1$ 和t时刻的 $x_1-x_7$ 作为输入特征,并将 $t-7$ 到 $t-1$ 时刻的y作为输入特征来预测t时刻的y。试验中变化的参数以及结果对比见表3。

6个输出的偏差和4组时间窗的预测结果见图3。随着作为输入特征的历史数据的增多,6个偏差的预测准确率都有所提高。但是,随着训练集时间窗的增大,效果提升的幅度却在逐渐降低。从图3中可以看到,当时间窗从0变成1时,单点预测准确率有显著提升。但是,随着时间窗的增大,历史数据的输入对于预测准确率的提升效果在逐渐衰减,当时窗n增大到2之后,6个目标输出的测试集单点预

表3 不同时间窗的预测结果

单位:mm

	MAE	无时间窗	时间窗=1	时间窗=2	时间窗=3
HDH	10.911 53	5.910 968	5.232 082	5.376 284	
HDJ	11.330 09	5.825 563	4.807 014	5.676 399	
HDT	14.884 74	4.421 959	4.452 301	4.979 366	
VDH	6.783 467	3.898 506	3.866 647	3.913 937	
VDJ	3.991 401	2.878 736	2.274 555	3.014 360	
VDT	4.818 021	2.117 052	2.519 580	2.112 969	

测误差基本稳定。



图3 不同时间窗对比图

这表明历史数据的引入对于单点预测准确率的提高有重要作用,但随着加窗数量的增多,加窗对于预测效果提升的影响变得微乎其微。尤其是当时间窗 $n>2$ 时,预测结果的各项指标基本上趋于不变。由于时间窗的增多会增加模型训练的时间,降低预测效率,因此,我们均采用时间窗 $n=2$ 进行后续试验。

### 3.2 5种深度学习算法对比

试验发现,对于本数据集,在选择数据规范化方法时,无论是什么深度学习算法,均是采用标准化的效果最佳。故在各种学习算法的对比试验中,我们均采用标准化的数据规范化方法。由于本研究采用的5种算法均是keras框架下的深度学习算法,因此每种算法的超参数空间均相同,且5种算法的超参数均采用粒子群优化算法对其超参数空间进行最优超参数搜索,以保证每种算法的预测结果都基于同一调参水平。上述两个条件使得本研究的5种算法对比具有极强的说服力。

进行对比的5种算法中见表4和图4。HDH, HDJ, HDT, VDJ的预测误差最小的是LSTM,而对VDH和VDT的预测表现最优的则分别是RNN和Bi-RNN。值得注意的是,尽管LSTM对VDH和VDT的预测效果不如另外两种算法,但是LSTM的预测误差与另外两种算法非常接近。而且,RNN和Bi-RNN在另外4项偏差的预测表现一般,MLP和GRU在6项偏差的预测上表现均不如LSTM。因此,LSTM是6项偏差预测中综合表现最优的算法。

表4 5种算法的预测结果对比 单位:mm

MAE	MLP	RNN	Bi-RNN	LSTM	GRU
HDH	5.361	5.277	5.367	5.232	5.286
HDJ	5.355	5.545	5.692	4.807	4.923
HDT	4.570	5.278	5.793	4.452	4.606
VDH	3.837	3.569	3.583	3.867	3.840
VDJ	2.729	2.349	3.395	2.275	2.407
VDT	2.507	2.502	2.200	2.520	2.788

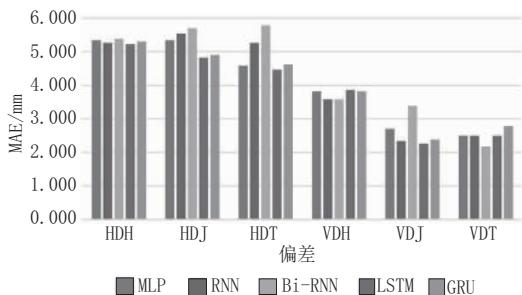


图4 五种算法的预测结果对比

### 3.3 自动深度学习预测结果

采用 AutoDL 同时进行单点预测,与 5 种算法单独预测的结果进行对比,结果如图 5 所示。

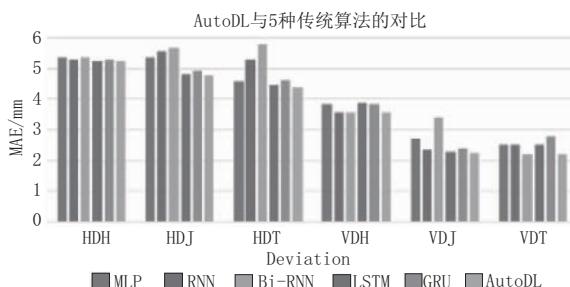


图5 自动深度学习与5种算法的预测结果对比图

在 AutoDL 和其他 5 种算法的对比中可以看出,AutoDL 对 6 个偏差的预测误差均是最小,这是因为 AutoDL 在训练时会使用 PSO 挑选最适合该数据集的模型并选择最优超参数。因此,我们可以得出结论,AutoDL 是一种非常有效的方法,可以显著提升深度学习算法的性能,同时也能提供一种便捷的深度学习方法,让开发人员不需要精通深度学习也能使用 AutoDL 框架轻易地实现精确的单点预测和区间预测。

在隧道盾构机掘进过程中,数据采集系统实现实时监控,记录反映隧道盾构机当前工作状态的时序数据。特别是,系统中保存了每个环的 200 多个操作变量,以动态捕获盾构机的行为。但是,这些多变量可能会带来冗余信息,降低深度学习模型的计算效率。为简单起见,提取 27 个关键变量,它们与盾构机位置偏差的 4 个目标密切相关。其中,HDH( $y_1$ )、

HDT ( $y_2$ )、VDH ( $y_3$ )、VDT ( $y_4$ ) 这 4 个目标分别是盾构机横轴在水平向机头位置和机尾位置的偏差,以及盾构机横轴在竖直机头位置和机尾位置的偏差,单位为 mm。

如图 6 所示,图中曲线分别为真实值、单点预测值、预测上界值和预测下界值的曲线。可以看出,预测值与真实值非常接近,它们的趋势基本相同。这表明所提出的 AutoDL 框架可以准确地捕捉到 4 种盾构机位置偏差的演变,4 个目标的预测区间很窄,覆盖率较高,验证了所构建区间的可靠性和意义。

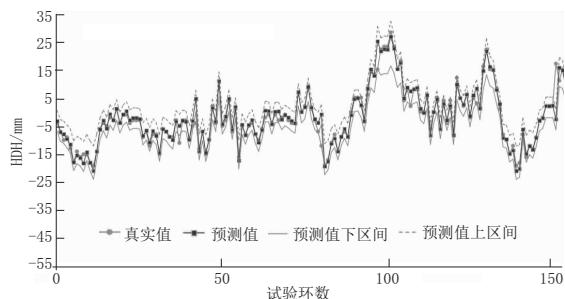


图6 基于 AutoDL 的 HDH 预测结果

### 3.4 多目标优化算法决策控制

基于 AutoDL 框架建立的智能模型,进行 NSGA-II 算法智能优化,寻求将 HDH、HDT、VDH 和 VDT4 个目标控制在可接受范围内的最优解。MOO 任务的目标是迭代搜索决策空间,使同时反映盾构机移动轨迹偏差的 4 个目标最小化。然而,为了实现这一目标,在实际工程中需要不断调整全部 27 个输入变量是不方便的。为了提高灵活性,试验中只选取推进行程( $x_1$ )、刀盘扭矩( $x_2$ )、推进速度( $x_3$ )、刀盘转速( $x_4$ )、注浆压力( $x_5$ )5 个变量作为关键可调变量。

以 1517 号环为例,验证了优化的良好性能。依托 NSGA-II 的实施,将得到 40 组最优解,所有优化后的值都低于 MOO 前的原始值。平均控制 HDT 和 VDH 分别提高 48.68% 和 5.01%

为了进一步测试 NSGA-II 算法的性能,将其应用于盾构机的所有环,实现掘进过程中的控制。图 7 显示了 HDH、HDT、VDH、VDT 4 个目标的优化结果。对于不同的环,NSGA-II 可以返回适合其实际情况的具体控制方案。最大偏差总和不超过 130 mm,其中 36 号环改善率最大,达到 52.61%。平均改进率在 17.55% 左右,验证了所提优化方法在不同工程条件特征下自适应生成适合盾构机运行调整策略的有效性。

优化结果表明,基于 NSGA-II 的 MOO 任务在控制 66 个环上的盾构机位置偏差方面表现出良好

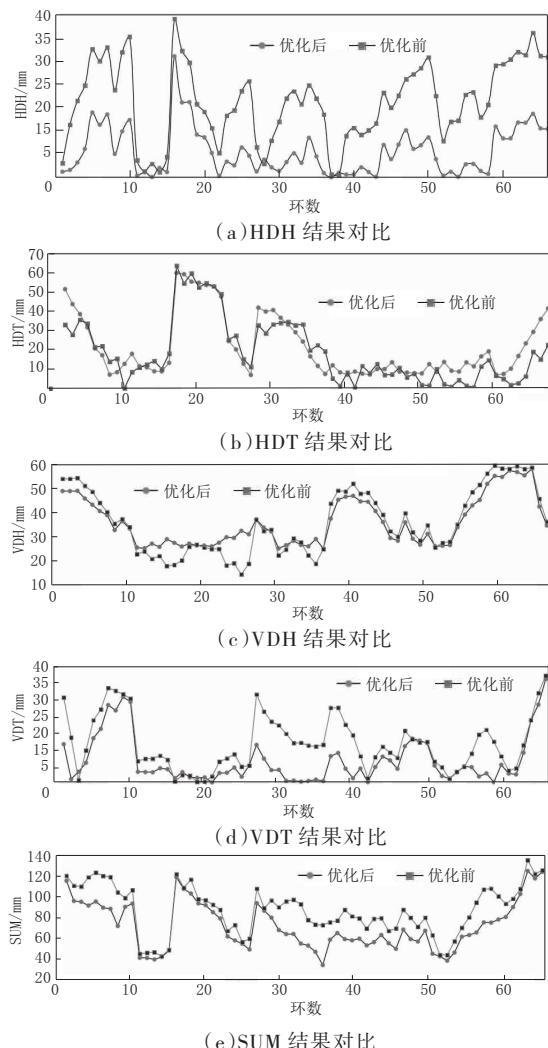


图7 盾构姿态参数优化前后对比

的优化能力,遵照多目标优化算法产生的盾构操作方案调整,盾构机姿态偏差值平均可降低 16.05%。

#### 4 结语

本研究综合使用基于粒子群优化算法自动深度学习,实现了对盾构掘进姿态的预测。

本研究以上海市天然气主干管网崇明岛—长兴岛—浦东新区五号沟 LNG 站管道工程隧道 A 线为例,首先探究了时间窗对预测效果的影响,分析结果后采用时间窗  $n=2$  进行后续试验;接下来又对不同的深度学习算法进行了统一调参水平的预测效果对比,发现 LSTM 在 6 个指标的预测综合表现最优;最后,在自动深度学习的试验中,AutoDL 在盾构姿态的 6 个指标预测方面均优于 5 种深度学习算法,不论是水平偏差还是垂直偏差,AutoDL 均得到了最优的结果,这也体现了本研究所提出的 AutoDL 的优越性,证明了粒子群算法是寻找深度学习超参数的有力工具,为盾构机安全高效掘进提供了非常可靠的预测结果。

自动深度学习算法和多目标优化算法的结合可提供数据驱动的姿态偏差控制指导,在不同工程条件特征下可自适应地制定适合盾构运行状态的姿态偏差控制策略,降低了模型训练评估对开发人员专业知识的要求,从而解放人力,促进盾构安全高效掘进。

#### 参考文献:

- [1] 吴惠明,常佳奇,李刚,等.基于支持向量机的盾构掘进姿态预测与施工参数优化方法[J].隧道建设(中英文),2021(S01): 041.
- [2] FU X, WU M, PONNARASU S, et al. A hybrid deep learning approach for dynamic attitude and position prediction in tunnel construction considering spatio-temporal patterns [J]. Expert Systems with Applications, 2023(212): 118721.
- [3] ZHOU C, XU H, DING L, et al. Dynamic prediction for attitude and position in shield tunneling: A deep learning method[J]. Automation in construction, 2019, 105(SEP.): 102840.
- [4] YANG L, SHAMI A. On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice[J]. Neurocomputing, 2020 (415): 295–316.

## 《城市道桥与防洪》杂志

是您合作的伙伴,为您提供平台,携手共同发展!

欢迎新老读者订阅期刊 欢迎新老客户刊登广告

投稿网站:<http://www.csdqyfh.com> 电话:021-55008850 联系邮箱:cdq@smedi.com