

基于多智能算法融合的盾构机掘进参数优化控制

王子文

(山西工程技术学院 电气与控制工程系, 山西 阳泉 045000)

摘要: 盾构机掘进过程中土压力的平衡控制是盾构施工安全的关键因素;为实现盾构机安全高效智能的土压力平衡控制,文章对基于盾构掘进参数的智能优化控制策略进行了研究;该策略基于先进的预测模型框架,采用离散小波变换对原始施工数据进行去噪预处理;利用一维卷积神经网络和长短时记忆神经网络对土压力进行特征提取和土压力多步预测;通过改进的粒子群优化算法对掘进速度和螺旋机转速等掘进参数进行在线优化求解,进而实现土压力的平衡控制;实验结果表明:该策略能够精确地追踪设定的土压力,实现密封舱内外土压力的控制,从而显著提升盾构掘进作业的安全性和效率。

关键词: 盾构机;土压力;控制参数优化;多智能算法;掘进速度;螺旋机转速

Optimized Control of Shield Machine Tunneling Parameters Based on Multi-Intelligent Algorithm Fusion

WANG Ziwen

(Department of Electrical and Control Engineering, Shanxi Institute of Technology, Yangquan 045000, China)

Abstract: The balance control of soil pressure during the shield machine tunneling process is a key factor for the safety of shield construction. To achieve the safe, efficient, and intelligent control of soil pressure balance in shield machines, this paper researches an intelligent optimization control strategy based on shield machine tunneling parameters. Based on an advanced predictive model framework, a discrete wavelet transform is used to denoise original construction data; A one-dimensional convolutional neural network and long short-term memory neural network are used to extract features and predict multi-step soil pressure; Tunneling parameters such as tunneling speed and screw conveyor speed are optimized online by using an evolutionary particle swarm optimization algorithm, thereby achieving the balanced control of soil pressure. Experimental results indicate that this strategy can accurately track the preset soil pressure and achieve the soil pressure inside and outside the sealed chamber, thus significantly enhancing the safety and efficiency of shield tunneling operations.

Keywords: shield machine; soil pressure; control parameter optimization; multi-intelligent algorithm; propulsion speed; screw conveyor speed

0 引言

随着城市化进程的加速,地下空间开发与利用的重要性日益凸显。在此背景下,盾构施工技术因其高效性和安全性而被广泛应用。盾构掘进过程中,密封舱内外土压力的平衡对于维持开挖面及地表稳定性起着至关重要的作用。

盾构机前端的结构设计包括隔板、刀盘和螺旋机,这3个组件相互隔离形成了密封舱结构,如图1所示,

该结构与土压平衡原理密切相关,概括如下:刀盘切削前方土体,经剪切后的土壤通过刀盘开口进入密封舱,随后落入舱底;螺旋机将舱底土体输送至皮带运输机,最终由轨道上的渣土车运出盾外。在推进过程中,液压缸对充满渣土的密封舱施加压力,使密封舱内的土压力作用于开挖面,从而确保其稳定性。因此,土压力的精确控制是维护掘进稳定性、防止地面沉降和确保施工安全的关键因素。然而,传统的掘进参数设置方法多依赖于经验判断,难以适应复杂地质条件下的土压力动态变

收稿日期:2024-08-07; 修回日期:2024-09-22。

作者简介:王子文(1988-),男,硕士,助教。

引用格式:王子文. 基于多智能算法融合的盾构机掘进参数优化控制[J]. 计算机测量与控制, 2025, 33(9): 144-151.

化^[1-4]。综上，提出一种能实时精确调整控制参数以实现土压力优化控制的智能策略，对于提升盾构施工的安全性和效率具有重要意义。




图 1 密封舱土压力平衡原理图

在盾构隧道施工中，有效地控制和维持土压平衡是保障掘进过程稳定及防止地面沉降的核心。文献 [5] 通过相关性分析说明了掘进速度和螺旋机转速是影响土压力平衡最为直接且关键的两个掘进参数。掘进速度影响掘进面土压力，其精确控制可防止掘进面坍塌或地面沉降。螺旋机转速则决定排土效率和密封舱土压力，其适宜设置有助于保持土压力平衡。这两掘进参数的协调控制对确保施工过程的稳定性和连续性至关重要。文献 [6] 构建了基于掘进速度和螺旋机转速的土压力控制机理模型，以此达到土压力优化控制的目的。文献 [7] 通过最小二乘支持向量机 (LS-SVM, least squares support vector machine) 预测模型结合 (AS, ant system) 的优化控制模型，实现了土压力的综合优化控制。文献 [8] 利用 BP 神经网络与 PID 控制相结合的方式，实现了螺旋机转速和盾构机掘进速度参数的优化调整，进而完成了盾构机密封舱土压力的精确控制。文献 [9] 提出了一种基于 LS-SVM 和粒子群算法 (PSO, particle swarm optimization) 的控制策略，用于实现盾构隧道施工中地层压力的预测和平衡控制，其中控制变量包括掘进速度和螺旋输送机速度。文献 [10] 提出了一种基于动态模糊神经网络直接逆控制方法的盾构机协调优化控制策略，通过调整盾构机的螺旋输送机速度和掘进速度，实现了对密封舱内土压力的平衡控制。文献 [11] 通过模型预测控制器的方式，实现推进系统、螺旋输送系统和刀盘控制系统的协调控制。综上所述：在研究土压力平衡控制问题中均选取掘进速度和螺旋机转速作为土压力优化控制的参数，基于此，掘进速度和螺旋机转速这两个关键操作参数的精确调节，是实现土压力精确控制和土压平衡的关键因素。但上述控制参数优化模型主要存在两个问题：1) 预测模型的性能存在局

限，特别是在预测精度方面有待进一步提高；2) 所采用的优化算法在控制过程中显示出一定的缺陷。

因此，文章采用离散小波变换 (DWT, discrete wavelet transform)、一维卷积神经网络 (1DCNN, one dimensional convolutional neural network)、长短时记忆神经网络 (LSTM, long short-term memory) 和改进的粒子群 (EPSO, evolutionary particle swarm optimization) 的核心算法对盾构机掘进参数进行优化控制，从而解决土压力控制模型中存在的问题。

1 多智能算法融合的优化控制模型构建

多智能算法融合的土压力优化控制模型的具体流程如图 2 所示，模型由 3 部分构成。

第一部分：DWT 数据去噪。DWT 作为一种强大的信号处理工具，能够有效地分离信号中的噪声成分，从而提高数据质量。具体步骤如下：

1) 数据分解：将预处理后的数据通过 DWT 进行多尺度分解。本研究选择四级分解，得到 4 个高频子带 (D_1 、 D_2 、 D_3 、 D_4) 和一个低频子带 (A_1)。高频子带主要包含噪声和细节信息，而低频子带则代表了信号的近似成分。

2) 阈值处理与重构：对分解后的高频子带进行软阈值或硬阈值处理，以消除或减弱噪声成分。随后，利用处理后的小波系数进行信号重构，得到去噪后的数据序列。

3) 数据标准化：为了消除量纲影响并使数据分布更加均匀，对去噪后的数据进行归一化和标准化处理。这一步骤有助于提高后续分析和建模的准确性和可靠性。

4) 实验数据集构建：基于上述处理后的数据，构建本研究所需的实验数据集。

第二部分：土压力预测模型的构建。这部分由 1DCNN 和 LSTM 两个模块构成，1DCNN 模块负责从输入数据中提取关键特征，LSTM 模块则基于提取的特征进行土压力的时序预测，由此形成基于 1DCNN 和 LSTM 的土压力时序预测模型。

第三部分：掘进参数的优化控制。将当前 k 时刻的土压力 P_m 、螺旋机转速 n 、掘进速度 v 和 $k-1$ 时刻的土压力 P_m 、螺旋机转速 n 、掘进速度 v 输入到基于 1DCNN 和 LSTM 的土压力时序预测模型中得出 $k+i$ 时刻内的土压力 P_m ，其中 i 为预测时域。基于预测结果，采用 EPSO 对 $k+j$ 时刻内的掘进参数进行实时优化，从而实现密封舱土压力的精确平衡控制，其中 j 为控制时域。

1.1 DWT 数据去噪

在基于多智能算法融合的黑箱模型中，数据的优劣




图 2 多智能算法融合的土压力优化控制模型构建

将决定模型的准确性。由于地层复杂性及恶劣的工作环境，盾构施工中采集的监测数据常常夹杂大量噪声，表现为尖峰、突变等非平稳特征，偏离盾构机正常运行状态，给基于数据建模分析带来挑战^[12]。

为应对这一挑战，本文选用 DWT 用于监测数据去噪，原因在于 DWT 能够利用多尺度分析能力，将盾构机在掘进过程中产生的复杂监测数据分解成不同频率成分，这不仅有助于识别和分析信号中的有效数据和噪声，而且能够更深入地理解盾构机的运行状态。DWT 的时间-频率局部化特性进一步增强了这种分析能力，使其能够精确地定位信号中的突变，能够及时捕捉到盾构监测数据变化并采取相应措施，以确保这些关键特征不被误删，保证了监测数据的准确性和可靠性^[5,13]。

计算效率是 DWT 的另一大优势，它能够快速响应并及时提供处理结果，这对于需要实时或近实时监控的盾构机监测系统来说至关重要。DWT 对不同类型噪声的鲁棒性，使其能够有效地从盾构监测数据中去除噪声，提高数据质量。通过迭代处理，DWT 能够不断优化去噪效果，适应盾构机运行状态的动态变化。基于此，DWT 因其出色的去噪性能，成为盾构施工监测数据去噪的理想选择。

本研究对所有盾构监测数据均采用 DWT 进行去噪处理。以盾构机上端土压力监测数据为例，通过对比去噪前后的结果，直观展示了 DWT 去噪方法的效果。图

3 和图 4 分别呈现了盾构机上端土压力监测数据去噪前后的对比图。从这两图的对比中可以明显观察到，经过去噪处理后的土压力数据呈现出更为平滑和清晰的特征。这一处理过程有效降低了尖峰和突变等噪声，从而显著提高了土压力数据的质量和可用性，为后续预测模型的构建和掘进参数的优化控制提供了更加可靠的数据基础。




图 3 盾构机上端土压力原始数据

盾构监测数据经过 DWT 去噪后，需要对其进行标准化和归一化，而后对标准化和归一化的盾构监测数据进行时间序列数据集的构建，最后将构建好的数据集输入到 1DCNN 中。其中，标准化和正则化的公式如式 (1) 和 (2) 所示，数据集的构建方法与文献 [5] 相同。




图 4 盾构机上端土压力去噪数据

$$b_i = \frac{a_i - \text{mean}\{a_i\}}{\text{std}\{a_i\}} \quad (1)$$

$$c_i = \frac{b_i - \min\{b_i\}}{\max\{b_i\} - \min\{b_i\}} \quad (2)$$

其中： a_i 为原始数据； b_i 为标准化后的数据； c_i 为归一化后的数据； $\text{mean}\{ \}$ 为取均值； $\text{std}\{ \}$ 数据取标准差； $\min\{ \}$ 为取最小值； $\max\{ \}$ 为取最大值。

1.2 1DCNN 数据特征提取

在本研究中，1DCNN 的作用为：1) 盾构监测数据经过 DWT 去噪和时序数据集构建后，1DCNN 为其提供输入路径；2) 连接 LSTM 神经网络，对盾构监测数据进行有效地特征提取，并降低训练代价。1DCNN 结构如图 5 所示，其具体工作方式以下三步^[14-16]。




图 5 一维卷积神经网络结构

第一步：将构建好的数据集输入到 1DCNN 的输入层，在输入信号和相应的卷积核之间进行一维卷积运算，以生成输入特征映射，然后通过激活函数生成卷积层的输出特征映射。卷积层输出的表达式可表示为式 (3)：

$$x_j^l = f\left(\sum_{i=1}^M x_i^{l-1} * k_{ij}^l + b_j^l\right) \quad (3)$$

其中： k 表示卷积核数， j 表示神经元数， M 表示输入 x^{l-1} 的通道数， b 是对应于内核的偏置， $f()$ 是

激活函数， $*$ 是卷积算子。
第二步：经过卷积运算的数据进入池化层，池化层可通过降低从上部卷积层提取的特征维数来降低计算成本，还能为被选取的特征提供基本的平移不变性。其公式如式 (4) 所示：

$$z_j^{l+1} = f(\beta_j^l \text{down}(y_j^l) + b_j^{l+1}) \quad (4)$$

其中， $\text{down}()$ 为下采样函数； β_j^l 为加权系数， b_j^{l+1} 为偏差系数。

第三步：池化层每个神经元的输出成为全连接层每个神经元的输入，全连接层则对应于文中的 LSTM 神经网络。

1DCNN 设置了 1 个卷积层，2 个池化层和 1 个全连接层，其中卷积核数设置为 32，卷积层的神经元数为 9，池化层的神经元数为 5。通过上述结构参数的设置，在确保特征信息完整的同时，有效地降低了 LSTM 模型的训练代价，展现了 1DCNN 在处理时序数据集中的优势。

1.3 LSTM 的土压力预测

LSTM 作为门控循环神经网络 (RNN, recurrent neural network) 的典型代表，在时间序列预测任务中展现出了显著的优势^[17-18]。传统 RNN 仅依赖单一的短期隐藏状态作为输入，这使得它难以学习和保留时间跨度较大的历史信息，导致对短期输入过于敏感。相比之下，LSTM 引入了一个专门用于存储长期信息的状态更新单元，并通过 3 个精心设计的门来控制信息的流动，这 3 个门及其功能如表 1 所示。

表 1 LSTM 门控单元的作用

门控单元名称	控制作用
遗忘门	决定是否保存前序状态
输入门	决定是否加入新状态
输出门	决定是否把前序状态和输入一起输出

LSTM 的内部架构则可参见图 6，由于 LSTM 的独特结构能够有效捕捉长期依赖关系，其记忆单元可以长期保存盾构监测数据中隐含的地质条件、施工参数等关键信息，使模型能够考虑远期因素对当前土压力的影响。同时，LSTM 的门控机制允许模型灵活地更新和遗忘信息，适应盾构施工过程中的动态变化，如地层变化和施工参数调整。此外，LSTM 能够同时处理多尺度的时间特征，考虑瞬时因素和长期因素的共同影响，提供更全面、准确的预测^[19]。LSTM 强大的非线性建模能力使其能够捕捉土压力变化中的复杂模式和隐含关系，这对于处理盾构施工中的非线性、非平稳过程至关重要。

综上所述，LSTM 的这些特性使其在构建盾构机土压力预测模型方面具有显著的合理性，能够提供更准




图 6 LSTM 内部结构图

确、可靠的预测结果，为盾构施工的安全性和效率提供有力支持。

1.4 基于 EPSO 的掘进参数优化控制

掘进参数智能优化控制部分，采用以 EPSO，为核心的优化控制算法，其优化过程主要分为以下 3 个步骤。

1) 土压力预测模型的建立：

土压力预测模型是以 DWT-1DCNN-LSTM 模型为基础，选择密封舱土压力 P 、螺旋机转速 n 、掘进速度 v 等参盾构监测数据作为输入变量，通过数据模型的反复训练，构建出符合掘进参数优化控制的土压力预测模型，为实现螺旋机转速 n 和掘进速度 v 优化及土压力控制奠定基础。该模型的具体结构如图 7 所示。




图 7 1DCNN-LSTM 神经网络结构参数设置

本研究考虑到预测数据的时序特性及盾构执行机构的滞后特性，将预测时域设置为 3，其中土压力预测值 P_m 的表达式如式 (5) ~ (7) 所示：

$$P_m(k+1) = f[P_m(k), n(k), v(k), n(k-1), v(k-1), P_m(k-1)] \quad (5)$$

$$P_m(k+2) = f[P_m(k+1), n(k), v(k), n(k+1), v(k+1), P_m(k)] \quad (6)$$

$$P_m(k+3) = f[P_m(k+2), n(k+2), v(k+2), n(k+1), v(k+1), P_m(k+1)] \quad (7)$$

其中： $P_m(k+i)$ 为时刻 k 后 i 时刻的土压力预测值， i 为预测时域，本研究中取 1, 2, 3； $n(k)$ ， v

(k) 分别为 k 时刻优化后的螺旋机转速 n ，掘进速度 v ； $n(k+j)$ 和 $v(k+j)$ 为控制变量， j 为控制时域，本研究中 j 取 1, 2，其含义为 k 时刻后 j 个时域内，经过优化的螺旋机转速 n 和掘进速度 v 。

2) 优化控制模型：

优化控制模型的控制目标是：实现土压力预测值 P_m 与其预设值 P_d 之间的差值最小化，其最优化目标函数及如约束条件如式 (8) ~ (9) 所示：

$$\min J(k) = \sum_{i=1}^3 \alpha_i \cdot |P_m(k+i) - P_d(k+i)| + \sum_{i=1}^{k=2} \beta_i \cdot [|v(k+j) - v(k+j-1)| + |n(k+j) - n(k+j-1)|] \quad (8)$$

$$s. t. n_{\min} \leq n(k) \leq n_{\max} \quad v_{\min} \leq v(k) \leq v_{\max} \quad (9)$$

其中： α_i 与 β_i 分别为土压力和掘进控制参数的惩罚系数，其范围为： $\alpha_i, \beta_i \in [0, 1]$ ，用于惩罚各层级下掘进控制参数变化过大的情况。 $n_{\min}$ ， $n_{\max}$ ， $v_{\min}$ 和 $v_{\max}$ 分别为螺旋机转速和掘进速度的上下限。

3) 基于 EPSO 的优化求解：

PSO 以其简单易实现、计算效率高、参数少、并行性好、适用性广、鲁棒性强和全局搜索能力突出等优点而著称，这些特性使其成为一种在多领域广泛应用的有效优化方法，能够快速且高效地解决各种复杂的优化问题，其算法核心为粒子速度的更新，其公式为式 (10) [20]：

$$v_{id}^k = \omega v_{id}^{k-1} + c_1 r_1 (p_{ibest} - x_{id}^{k-1}) + c_2 r_2 (p_{gbest} - x_{id}^{k-1}) \quad (10)$$

其中： v_{id}^k 是第 k 次迭代中粒子 i 速度矢量的第 d 维分量； x_{id}^k 是第 k 次迭代中粒子 i 位置矢量的第 d 维分量； c_1, c_2 为加速度常数； r_1, r_2 为随机数，范围为： $r_1, r_2 \in [0, 1]$ ； ω 为惯性权重。

PSO 尽管在解决多种优化问题时表现优异，但仍存在一些值得注意的局限性。它容易陷入局部最优解，对参数选择较为敏感，且在高维问题中性能可能下降。算法在接近最优解时收敛速度可能减慢，理论基础相对薄弱，结果具有一定随机性 [21]。基于式 (10) 的分析可知，当算法中的速度权重 ω 保持恒定时，其搜索最优解的灵活性显著受限。这种固定权重的方法难以满足密封舱土压力优化控制策略中对最优控制参数搜索的精细要求。有鉴于此，本研究引入了混沌因子和收缩因子，分别用于速度权重的动态调整和搜索速度的整体缩放。混沌因子和收缩因子的计算方法分别由式 (11) 和式 (12) 给出，而改进后的速度更新公式则呈现在式 (13) 中：

$$\omega = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \cdot \frac{1}{1 + e^{-\tau/t}} \quad (11)$$

$$u = \frac{2}{\left| 2 - \varphi - \sqrt{\varphi^2 - 4\varphi} \right|}, \varphi = c'_1 + c'_2, \varphi > 4 \tag{12}$$
$$v_{id} = u[\omega v_{id}^k + c'_1 r_1 (p_{ibest} - x_{id}^{k-1}) + c'_2 r_2 (p_{gbest} - x_{id}^{k-1})] \tag{13}$$

其中： $\omega_{\max}$ ， $\omega_{\min}$ 分别为最大、最小惯性权重， u 为收缩因子， τ 为当前迭代数， t 为算法迭代总数。

2 工程项目背景及研究数据的整理

2.1 工程项目背景

本项研究的试验数据采集自北京地铁 10 号线的特定区段，该区段的隧道深度达到 12.6 米，地下水位为 7.1 米。地质构成以粉质黏土、粉砂、卵石和细砂为主，形成了典型的砂卵石地层。这种地层的孔隙度较大，黏聚力相对较弱。在盾构机进行土体剪切时，开挖面容易发生坍塌，这给施工安全带来了挑战。

此次施工采用土压平衡盾构机进行隧道的掘进，精确预测密封舱内的土压力变化趋势，以及有效控制开挖面的土压力，对于减少围岩扰动风险、确保掘进面稳定性至关重要。

2.2 研究数据的准备

本研究所采用的数据集源自上述工程施工过程，通过盾构机的可编程控制器进行实时记录，并由工控机读取后存储于专用数据库中。原始数据集结构丰富，包含了操作参数和状态参数两大类，共计 227 个变量（列）和 23 316 个时间点（行）。每一行数据代表特定时刻的全面状态快照，涵盖所有相关物理量；而每一列则详细记录了某一特定物理量在整个施工过程中的变化轨迹。

为确保数据的科学性和可比性，我们对原始数据进行了严格的预处理。这包括数据归一化和标准化步骤，旨在消除不同物理量之间的量纲差异，并使数据分布更加规范。经过这些处理步骤，我们得到了一个高质量、统一标准的数据集，为后续的实验分析奠定了坚实的基础。

3 仿真结果与分析

3.1 试验仿真环境

本试验采用 Matlab2023b 作为编程工具，使用 Matlab2023b 中深度学习模块对密封舱土压力上端监测点进行回归分析并建立土压力预测模型，而后与优化控制模型相结合实现掘进参数的优化控制。硬件条件为：8 GB 的运行内存，2.80 GHz 的主频，4 核 8 线程英特尔酷睿 i7-7700 的 CPU 和 NVIDIA GeForce GTX1060Ti 的 GPU。

3.2 土压力预测结果

在本研究中，选取了密封舱上端监测的土压力作为主要研究对象，这一选择基于该位置土压力数据具有高

精度和代表性。处理好的数据采用了 90%/10% 的训练集/测试集划分比例，以评估模型性能，在构建预测模型中 LSTM 模型参数设置如表 2 所示。

表 2 LSTM 模型参数设置

参数类型	对应英文	设定值
学习率	Learning rate	0.001
最大训练周期	Maximum epoch	100
最小样本数	Batch size	128
损失函数	Loss function	MAE
测量值	Metrics	MAE, MSE
优化器	Optimizers	RAAdam

图 8 和图 9 分别呈现了模型预测结果与实测值的对比，以及相应的误差分析。图 7 和图 8 定量分析显示，模型在测试数据上的土压力预测值与实际观测值之间呈现高度一致性，反映了模型对潜在数据模式的精准捕捉。




图 8 测试结果与真实值对比图




图 9 测试误差结果图

值得注意的是，尽管在数据预处理阶段进行了去噪处理，但数据集中仍然存在一些非最优的掘进参数配

置，这在一定程度上影响了预测的精确度。然而，从整体性能来看，本模型的预测结果和预测精度均显著满足工程实践要求。这一结果不仅验证了所提出方法的有效性，也为后续掘进参数优化奠定了基础。

3.3 掘进参数优化求解

为了优化 EPSO 算法在掘进参数求解中的性能，选取了一系列关键参数并进行了相应设置，具体如表 3 所示。在此次试验中，目标数据为此次施工中 400 环后的 200 组密封舱土压力设定值。基于上述参数设置得到的最优螺旋机转速 n 和掘进速度 v 如图 10 和图 11 所示，密封舱土压力控制试验结果如图 12 所示。

表 3 EPSO 相关参数设置

参数名称	对应符号	设定值
最大螺旋机转速	$n_{\max}$	12 r/m
最小螺旋机转速	$n_{\min}$	3 r/m
最大掘进速度	$v_{\max}$	60 mm/min
最小掘进速度	$v_{\min}$	10 mm/min
种群个数	N	50
惩罚因子 α	α_{k+i}	$\alpha_{k+1}=1, \alpha_{k+2,3}=0.01$
惩罚因子 β	β_{k+j}	$\beta_{k+1,2}=0.01$
最大惯性权重	$w_{\max}$	1.2
最小惯性权重	$w_{\min}$	0.2
迭代次数	t	100
粒子加速度	c_1, c_2	1.8




图 10 螺旋机转速优化结果




图 11 掘进速度优化结果




图 12 土压力优化控制结果

为验证本文提出的智能优化策略的有效性，选择基于 LS-SVM 和 PSO 的掘进控制参数智能优化策略作为对照模型。具体参数设置如下：LS-SVM 预测模型中参数设定为： $\sigma^2=0.9$ ， $C=2$ 。在 PSO 优化算法中相关参数设置如下： $w=1.2$ ， $N=50$ ， $t=100$ ， $c_1=c_2=1.8$ ，在其优化过程中，螺旋机转速 $n(k)$ 和掘进速度 $v(k)$ 的上下限约束及其跟踪目标值，与本文提出的基于 DWT-1DCNN-LSTM 和 EPSO 的优化控制策略中的设定保持一致，以确保比较的公平性。

基于上述参数和设定值得出的试验结果与本文所用方法对比如图 13 所示，其误差对比如图 14 所示。从图 13 和图 14 中能够明显看出本研究所用优化策略能够更好地跟踪设定的密封舱土压力值，在土压力控制效果方




图 13 土压力优化控制结果对比




图 14 优化控制误差对比

面的表现明显优于基于 LS-SVM 和 PSO 的智能优化策略。因此, 本研究所构建的智能优化策略相较于 LS-SVM 和 PSO 构建的优化策略具有更高的精度和准确性。

4 结束语

本研究针对盾构机掘进过程中的土压力平衡控制问题, 提出了一种基于多智能算法融合的盾构掘进参数智能优化控制策略。通过 DWT 进行数据去噪, 1DCNN 提取特征, LSTM 对土压力变化进行精确预测, EPSO 算法对掘进速度和螺旋机转速等关键参数进行在线多目标优化求解, 构建出了高效的预测和优化模型, 有效实现了土压力的平衡控制, 显著提升了盾构掘进过程中的系统鲁棒性, 为盾构隧道施工中的土压力平衡控制提供了一种新的解决方案。

参考文献:

- [1] NUH B, ALI Y. The effect of EPB face pressure on TBM performance parameters in different geological formations of Istanbul [J]. Tunnelling and Underground Space Technology, 2023, 138 (10): 1-16.
- [2] SAMADI H, HASSANPOUR J, ROSTAMI J. Prediction of earth pressure balance for EPB-TBM using machine learning algorithms [J]. International Journal of Geo-Engineering, 2023, 14 (21): 1-31.
- [3] TYRER J, PARASKEVOPOULOU C, SHAH R, et al. Tunnelling with full-face shielded machines: A 3D numerical analysis of an earth pressure balance (EPB) excavation sequence using the finite element method (FEM) [J]. Geosciences, 2023, 13 (8): 1-27.
- [4] CEHNG P P, LIU F, XU Y J, et al. Regulating bulkhead pressure of EPB shield machines through DEM modeling and data mining [J]. Underground Space, 2023, 8 (2): 15-29.
- [5] LIU X Y, WANG Z W, SHAO C, et al. Predicting variation of multipoint earth pressure in sealed chambers of shield tunneling machines based on hybrid deep learning [J]. Automation in Construction, 2022, 143 (12): 1-24.
- [6] 刘 博, 李守巨. 土压平衡盾构机密封舱土压力控制研究 [J]. 哈尔滨工业大学学报, 2011, 43 (S1): 262-266.
- [7] 刘宣宇, 邵 诚, 栗 觅. 盾构机密封舱土压平衡综合优化控制 [J]. 大连理工大学学报, 2013, 53 (3): 233-239.
- [8] 曹丽娟, 上官子昌, 李守巨, 等. 基于神经网络的盾构机密封舱压力控制研究 [J]. 广西师范大学学报 (自然科学版), 2010, 28 (3): 175-181.
- [9] LIU X Y, SHAO C, MA H F, et al. Optimal earth pressure balance control for shield tunneling based on LS-SVM and PSO [J]. Automation in Construction, 2011, 20 (4): 321-327.
- [10] LIU X Y, WANG W T, WANG Y D, et al. Coordinated optimization control of shield machine based on dynamic fuzzy neural network direct inverse control [J]. Transactions of the Institute of Measurement and Control, 2021, 43 (6): 1445-1451.
- [11] 邵诚俊, 李修亮, 苏宏业. 基于多系统协调的密封舱压力智能化控制 [J]. 机械工程学报, 2014, 50 (21): 105-110.
- [12] LIU X Y, ZHANG W S, SHAO C, et al. Autonomous intelligent control of earth pressure balance shield machine based on deep reinforcement learning [J]. Engineering Applications of Artificial Intelligence, 2023, 125 (10): 1-20.
- [13] ZHOU C, XU H C, DING L Y, et al. Dynamic prediction for attitude and position in shield tunneling: A deep learning method [J]. Automation in Construction, 2019, 105: 1-16.
- [14] YU J B, ZHANG C Y, WANG S J. Multichannel one-dimensional convolutional neural network-based feature learning for fault diagnosis of industrial processes [J]. Neural Computing and Applications, 2021, 33: 3085-3104.
- [15] HuANG S Z, TANG J, DAI J Y, et al. Signal status recognition based on 1DCNN and its feature extraction mechanism analysis [J]. Sensors, 2019, 19 (9): 1-19.
- [16] WANG H, LIU Z, PENG D, et al. Understanding and learning discriminant features based on multi-attention 1DCNN for wheelset bearing fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16 (9): 5735-5745.
- [17] ZHAO Z, CHEN W H, WU X M, et al. LSTM network: a deep learning approach for short-term traffic forecast [J]. IET Intelligent Transport Systems, 2017, 11 (2): 68-75.
- [18] YU Y, SI X S, HU C H, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. Neural Computation, 2019, 31 (7): 1235-1270.
- [19] SEPP H, JURGEN S. Long Short-Term Memory [J]. Neural Computation, 1997, 9 (8): 1735-1780.
- [20] EEDERICO M, BEATA W. Particle swarm optimization (PSO). a tutorial [J]. Chemometrics and Intelligent Laboratory Systems, 2015, 149 (15): 153-165.
- [21] NURUL A M, NOFRI Y D, WAN N A, et al. Optimum energy management strategy with NEM-ETOU for campus buildings installed with solar PV using EPSO [J]. Energy Reports, 2023, 9 (12): 54-59.