

基于 BP 神经网络的钻井轨迹滚动预测

顾乐成^{1,4} 曹万鹏² 王灶红¹ 魏秦文³ 梅丹阳³

1 四川工业科技学院, 四川省德阳, 618000;

2 新天绿色能源股份有限公司, 河北省石家庄, 050051;

3 北华航天工业学院, 河北廊坊, 065000;

4 廊坊川越科技有限公司, 河北廊坊 065000;

摘要: 准确预测钻进轨迹对提高钻进效率较为重要, 但影响钻进轨迹的因素较多, 且井内工况复杂, 难以通过力学模型进行预测。目前常用的几何预测法精度不足, 传统神经网络预测方法需要的训练样本量大, 对不同设计类型的轨迹适应性不高, 为此, 提出了一种基于时间序列的 BP 神经网络滚动预测模型, 采用移动窗口的方式控制训练样本量, 对轨迹延伸方向的参数进行预测, 使用某定向井部分实钻数据进行模型验证, 并与几何预测模型、支持向量机模型进行对比, 结果显示, 滚动预测的井斜角平均绝对误差分别较圆柱螺旋线法、自然参数法、支持向量机分别降低 33.2% 与 15.2%, 方位角平均绝对误差较圆柱螺旋线法、自然参数法、支持向量机分别降低 91.7%、74.8%、17.5%。表明该模型精度较高, 具备实时预测能力, 可为轨迹预测控制提供一定的参考。

关键词: 井眼轨迹; 实时预测; 滚动预测; 神经网络

Horizontal directional drilling trajectory prediction and control technology

GU Yuecheng^{1,4} CAO Wanpeng² WANG Zaohong¹ Wei Qinwen³ MEI Danyang³

1 Sichuan Institute of Industrial university, Deyang 618000, China;

2 China Suntien Green Energy Co.,Ltd, Shijiazhuang 050051, China;

3 North China Institute of Aerospace Technology, Langfang 065000, China;

4 Langfang Chuanyue Technology Co.,Ltd, Langfang065000, Hebei, China;

Abstract: Accurate prediction of drilling trajectory is important to improve drilling efficiency, but there are many factors affecting drilling trajectory, and the working conditions in the well are complex, so it is difficult to predict by mechanical model. At present, the commonly used geometric prediction method is not accurate enough. The traditional neural network prediction method requires a large amount of training samples and has low adaptability to different design types of trajectories. Therefore, a BP neural network rolling prediction model based on time series is proposed. The amount of training samples is controlled by moving window, and the parameters of the trajectory extension direction are predicted. The model is verified by some real drilling data of a directional well, and compared with the geometric prediction model and the support vector machine model. The results show that the BP neural network rolling prediction model based on time series is more accurate than the geometric prediction model and the support vector machine model. The average absolute error of inclination angle of rolling prediction is 33.2 % and 15.2 % lower than that of cylindrical spiral method, natural parameter method and support vector machine respectively. The average absolute error of azimuth angle is 91.7 %, 74.8 % and 17.5 % lower than that of cylindrical spiral method, natural parameter method and support vector machine respectively. It shows that the model has high accuracy and real-time prediction ability, which can provide some reference for trajectory prediction control.

Key words: wellbore trajectory; real-time prediction; rolling forecast; neural network

DOI:10. 69979/3029-2727. 24. 08. 016

引言

在定向钻进施工中, 实钻轨迹受到较多因素的干扰, 相较于设计轨迹会产生一定程度的偏移。轨迹发生偏移

的原因主要包括: 地质特性、钻具组合、已钻轨迹的几何形状、钻井的工程参数等的影响。同时实钻轨迹偏差不能直观展现、人工进行轨迹控制没有参考值等造成了穿越轨迹预测误差大、效率低, 控制轨迹难。

马玉凤^[1]等人利用支持向量机建立井眼轨迹预测模型,实现轨迹的三维可视化。在建立模型方面,苗在强^[2]通过纵横弯曲梁法建立钻井力学模型,优化造斜率预测方法,提高井眼轨迹预测精度。王舸^[3]考虑各种相互作用因素,建立推靠式旋转导向钻具组合的轨迹预测模型。谢鑫^[4]等人建立水平段实钻轨迹模型,分析井斜角对轨迹的影响,提高储层钻遇率,Tae Joon Jung^[5]开发动态钻井模拟模型,预测由粘滑和钻头轨迹引起的故障。。尽管井眼轨迹预测领域的研究取得了显著进展,但仍存在一些缺陷。在实际钻井过程中,数据的质量和数量可能受到限制,这可能导致模型在未见过的数据上表现不佳。井眼轨迹预测需要实时更新和调整,但一些模型可能需要较长的训练时间,难以满足钻井过程中对实时性的要求。尽管模型可能在训练数据上表现良好,但在新的或未见过的钻井条件下,模型的泛化能力可能不足,导致预测不准确。随着机器学习和深度学习方法的发展,其自动特征提取能力强,擅长处理复杂模式,泛化能力好,且对大量数据具有出色的学习能力的优点正被挖掘出来,国内外学者开始把这些用于钻井轨迹预测。李臻^[6]等人提出双输入序列到序列模型(Di-S2S),结合时序和非时序特征,实现轨迹的实时预测。Andrzej T. Tunkiel^[7]等人利用递归神经网络进行随钻训练,解决模型过时和不准确问题。Lu Wang^[8]等人使用简化惯性传感器系统(RISS)进行三维导航,提高钻井轨迹测量精度。Yi Gao^[9]等人提出 L2-SSA-LSTM 模型,加入 L2 正则化防止过拟合。Qingjian Ni^[10]等人提出 TFBNet,利用轨迹特征增强提高预测精度。Meng Huang^[11]等人利用 LSTM 网络预测井倾角和方位角。Jiho Jeong^[12]还提出一种优化定向井轨迹的方法,考虑长度、阻力和扭矩的目标函数,降低屈曲风险,节省钻孔时间和成本。国内外的研究均显示了井眼轨迹预测技术的进步,特别是在算法创新、模型优化和数据处理方面。通过结合机器学习、深度学习、自然语言处理和三维可视化技术,研究人员能够更准确地预测井眼轨迹,为钻井施工提供了有力的技术支持。未来的研究可能会集中在提高模型的泛化能力、实时预测性能以及进一步降低施工风险和成本上。

由于井眼轨迹影响因素复杂,力模型计算复杂度高且部分所需参数难以采集;几何预测轨迹法计算虽简便,但过于假设,预测精度不理想;普通的人工智能预测方

式虽精度高,操作方便,但所需样本数量较多,模型泛用性不高。因此,准确的轨迹预测技术与科学的轨迹控制方法是保证定向穿越工程顺利进行、降低成本的关键技术。

1 定向钻进轨迹延伸方向预测

在施工中需要及时了解当前钻头的方向参数及待钻轨迹延伸趋势,对待钻轨迹的准确预测是后续轨迹精准控向的前提。

为对比不同轨迹预测方法精确度,以某定向井造斜段及水平段测井数据为原始样本集。部分测井数据如表 1 所示。

表 1 某定向井部分实钻数据 10m 点

Table1 10m points of actual drilling data for a certain directional well

测深	井斜	方位	垂深	南北	东西
2982.45	1.70	241.04	2981.73	9.02	-26.12
2991.70	2.90	199.44	2990.97	8.73	-26.32
3001.39	4.70	185.54	3000.64	8.11	-26.44
...	...	...	...	...	...
3384.74	81.30	352.44	3278.57	203.71	-62.96
3405.00	84.00	352.00	3281.16	223.61	-65.68

1.1 BP 神经网络滚动预测

BP 神经网络由输入层、隐含层和输出层组成,适用于分类、回归和预测等多种任务。通过学习算法对数据进行训练,能够自适应地调整权重和偏差,从而实现对非线性问题的高效建模和预测^[13],如图 1 所示。




图 1 BP 神经网络结构

Fig.1 BP neural network structure

(1) 输入层

输入层接受原始数据。如果我们考虑归一化,那么输入层的数据是经过归一化处理的。

(2) 隐含层

通常,一个 BP 神经网络至少包含一个隐含层。在

上述模型中, 隐含层的节点数是通过经验公式确定的:

$$\text{hiddennum} = \sqrt{\text{inputnum} \cdot \text{outputnum}} \cdot a \quad (1)$$

式中, inputnum 为输入层节点数量; outputnum 为输出层节点数量; a 为整数, $1 \sim 10$ 。

隐含层第 j 个节点的输出 H_j 可用下式表示:

$$H_j = f\left(\sum_{i=1}^n W_{ij} \cdot I_i + B_j\right) \quad (2)$$

式中, I_i 为输入节点 i 的值; W_{ij} 为从输入层节点 i 到隐含层节点 j 的权重, B_j 是隐含层节点 j 的偏置, f 是激活函数。

(3) 输出层

输出层的每个节点接收来自隐含层的加权信号, 并将其转换为最终输出。对于使用线性转换函数的输出节点, 其计算公式为:

$$O_k = \sum_{j=1}^m W_{jk} \cdot H_j + B_k \quad (3)$$

式中, O_k 为输出层节点 k 的值; W_{jk} 为从隐含层节点 j 到输出层节点 k 的权重; B_k 为输出层节点 k 的偏置; m 为隐含层的节点数量。

1.1.1 激活函数及训练算法

在神经网络中, 激活函数用于模拟神经元的激活和抑制状态, 对信号进行转换, 使其能够传递到下一层神经元。激活函数通过引入非线性特性可以使神经网络更好地拟合复杂数据, 提高预测精度和模型的泛化能力。在实际应用中, 常见的激活函数包括以下几种。

(1) Sigmoid 函数

Sigmoid 将任意实数值作为输入, 输出的范围在介于 0 和 1 之间。当输入值越大时候, 输出值越接近 1; 输入值越小, 输出值越接近 0, 适用于二分类问题。Sigmoid 函数与导函数如式所示:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

$$f'(x) = \frac{e^{-x}}{(1 + e^{-x})^2}$$

Sigmoid 函数及其导函数图像见图 2 所示, 它的优点是: 将输入值映射到 0 到 1 的范围内, 适用于二分类问题, 可以将输出值解释为概率值; 在梯度下降优化过程中, 梯度的变化平滑, 不易出现梯度爆炸的问题。缺点是: 存在梯度消失的问题, 当网络层数较深时, 梯度可能会逐渐变小, 导致网络训练速度较慢; 在输入较大

或较小的情况下, 梯度接近于 0 时, 可能会导致梯度消失的问题。




图 2 Sigmoid 函数与导函数图像

Fig.2 Sigmoid function and derivative function image

(2) tanh 函数

tanh 函数与 Sigmoid 函数形状类似, 将任意实数值映射到区间 $(-1, 1)$ 之间。当输入值增大时, 函数值输出值逼近于 1, 输入值减小时, 输出值逼近于 -1, tanh 函数与其导函数如式所示:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

$$f'(x) = \frac{4}{(e^x + e^{-x})^2} \quad (5)$$

tanh 函数及其导函数图像如下图所示, 它是 Sigmoid 函数的变体, 类似于 Sigmoid 函数, tanh 函数也可以将输出值解释为概率值。双曲正切函数具有较好的非线性性质, 可以对更广泛的非线性关系进行建模。相较于 Sigmoid 函数, tanh 函数在输出范围上的对称性更好, 有助于模型更好地处理正负输入值。在梯度下降优化过程中, tanh 函数的梯度变化较大, 相较于 Sigmoid 函数, tanh 函数的梯度更加陡峭, 这意味着在使用 tanh 函数时, 可能具有更好的收敛速度和训练效果。但是, 仍然存在可能遇到类似 Sigmoid 函数的梯度消失问题; 同时, tanh 函数输出的值域在 $[-1, 1]$ 之间, 这使得它不适用于某些情况下的正数输入或负数输入。例如, 如果输入数据的取值范围是正数, tanh 函数可能无法捕捉到数据的全部特征。




图 3 tanh 函数与导函数图像

Fig.3 Images of tanh function and derivative function

(3) ReLU 函数

ReLU 函数是一种非线性函数,相较于线性激活函数,ReLU 函数在神经网络中能够更好地解决非线性问题。ReLU 计算非常简单,只需判断输入是否大于零,如果大于零则输出输入值,否则输出零,这大大减少了计算的复杂性,提高了训练和推理的效率。ReLU 函数与其导函数如式所示:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x \leq 0 \end{cases} \quad (6)$$

$$f'(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x \leq 0 \end{cases}$$

ReLU 函数及其导函数图像如下图所示,相较于 Sigmoid 函数于 tanh 函数,在正数区间上 ReLU 函数的导数为 1,这意味着在反向传播过程中梯度不会消失。由于 ReLU 函数在输入大于零时输出非零值,因此可以激活较少的神经元。然而,当其输入小于或等于零时,ReLU 函数的输出为零,在训练过程中可能会导致神经元无法更新权重。同时,其输出不以零为中心,导致某写优化算法的不稳定性。




图 4 ReLU 函数与导函数图像

Fig.4 ReLU function and derivative function image.

因此输入隐藏层激活函数选择 Sigmoid 函数,输出

隐藏层激活函数选择 tanh 函数。

(4) Levenberg-Marquardt 算法

Levenberg-Marquardt 算法,中文为列文伯格-马夸尔特算法,简称——LM 算法,是一种非线性回归参数最小二乘估计的一种估计。LM 算法和梯度下降算法在 BP 神经网络中都用于参数优化。梯度下降算法是基于二阶导数的优化算法,通过计算目标函数的梯度来更新参数。而 LM 算法是一种基于二阶导数 (Hessian 矩阵) 的优化算法,综合考虑了一阶导数和二阶导数的信息,相较于梯度下降算法可以更加精确地估计参数。梯度下降算法通过将参数沿着负梯度的方向进行更新,以最小化损失函数。而 LM 算法结合了梯度下降和高斯-牛顿法,根据损失函数的一阶导数和二阶导数,通过求解一个类似于线性方程组的问题更新参数。LM 算法通常具有更快的收敛速度和更好的全局收敛性,尤其在曲线拟合和非线性问题上的表现较好,因此,本文对于优化算法选择上使用 LM 算法。

LM 算法作为 BP 神经网络的学习算法,是梯度下降算法和高斯牛顿法的结合,引入阻尼因子 μ 来调节算法特性,结合两种算法的优点,一定程度上减少了 BP 神经网络陷入局部极小点、收敛速度慢等缺点。将高斯牛顿法的 Δ 替换为 $-\left[J_f^T J_f + \mu I\right]^{-1} J_f^T f(x_n)$ 即是 LM 算法,其迭代公式为。

$$x_{n+1} = x_n - \left[J_f^T J_f + \mu I\right]^{-1} J_f^T f(x_n) \quad (7)$$

式中, $\mu > 0$; I 为单位矩阵, $\mu > 0$ 时,能保证系数矩阵正定,从而确保迭代下降的方向,当 μ 很大时, μI 占主导地位,此时 LM 算法退化为梯度下降算法,说明此时距离终点还很远,用梯度下降算法更合适,即:

$$x_{n+1} = x_n - \frac{1}{\mu} J_f^T f(x_n) \quad (8)$$

当 μ 很小时, $J_f^T J_f$ 占主要地位,说明此时离终解距离较近,用二阶近似模型比较合适,可以避免梯度下降的“震荡”,此时 LM 算法退化为高斯牛顿法,从而使得接近解时快速收敛。LM 算法相较于梯度下降算法有诸多优点,因此本文的训练算法选用 LM 算法进行。

1.1.2 滚动预测模型

(1) 滚动预测

滚动预测是时间序列分析中的一种预测技术,是一种动态的预测方法。在每次新的数据点或时间步骤到达时,进行实时预测。在钻井轨迹预测中,滚动预测可以

根据已知的历史数据来预测下一个时间步骤的轨迹，这种方法会不断更新输入数据，以包含最新的信息，并基于最新的数据生成预测。

滚动预测的基本思想是使用一个“窗口”来捕获时间序列的最新部分，窗口包含固定数量的最近观测值。预测模型在这个窗口上训练，然后用于生成下一个时间步长的预测。一旦新的实际观测值可用，它就被加入数据集，同时窗口移动，即最旧的观测值被移除。这个过程不断重复，使得模型能够适应和反映时间序列的最新趋势和模式。滚动预测的步骤如下：

(1) 选定窗口大小

确定窗口内包含的时间序列点的数量，例如钻进轨迹预测的输入参数数量。

(2) 训练模型

在初始窗口的数据上训练时间序列预测模型，例如本文使用的 BP 神经网络。

(3) 进行预测

使用训练好的模型预测预测未来的轨迹走向。

(4) 更新窗口

获取新的时间序列数据，将其添加到窗口中，并移除最旧的数据。

(5) 重复步骤 2-4

使用更新后的窗口数据重新训练模型，并进行下一轮预测。

滚动预测没有一个通用的公式，因为它是一个“过程”，接下来用伪代码描述这个过程：

“设定滚动窗口大小 W

对于每个预测时间点 t:

选择时间序列中 t-W 到 t-1 之间的数据作为训练集
在训练集上训练模型

使用训练好的模型预测时间点 t 的值

当时间点 t 的实际观测值可用时，更新窗口数据”

如果在训练过程中需要预测更多的点，重复上述步骤即可。在 BP 神经网络的情况下，滚动预测训练过程也会涉及标准的神经网络训练步骤，包括前向传播、误差更新、反向传播和权重更新，每次窗口更新后，这些步骤都会重新进行，确保模型捕捉到最新的数据模式。

(2) 特征选择与参数预处理

特征选择是指从原始数据中选择对预测任务最有用的特征，滚动预测实际上就是利用 BP 神经网络对历史数据进行学习，然后用学到的模式对未来数据进行预测。通过对表 1 定向井钻井实测数据进行分析，结合滚动预测的特点，选取测深、井斜角以及方位角作为特征。

使用 mapminmax 函数对输入和输出数据进行归一化处理，使数据落在统一的数值范围内 (0, 1)，有助于提高神经网络的收敛速度和准确性。

$$Y = \frac{(Y_{\max} - Y_{\min}) * (x - x_{\min})}{(x_{\max} - x_{\min}) + Y_{\min}} \quad (9)$$

式中，X_{max} 为原始数据最大值；X_{min} 为原始数据最小值；Y_{max} 为目标范围最大值；Y_{min} 为目标范围最小值；Y 为归一化后的数据；X 为原始数据。

(3) 预测模型结构

本文建立了一个三层网络结构的 BP 神经网络模型，将井斜角、方位角、南北坐标、东西坐标以及测深作为输入参数，即输入神经元个数为 5。同时，将井斜角和方位角作为输出参数，即输出的神经元个数为 2。模型的数据集按照训练集 80%，测试集 20% 的方式带入模型训练。BP 神经网络模型中涉及到的网络参数如表所示。

表 2 BP 神经网络参数

参数	数值
训练次数	1000
学习速率	0.01
训练目标最小误差	1e-6
输入层节点数	5
输出层节点数	2
隐含层节点数	3~12
窗口大小	10

在 BP 神经网络中加入滚动预测的过程实际上就是利用网络对历史数据进行学习，然后使用学习到的模式对未来数据进行预测。在每一步预测之后，模型会更新其数据集，通常将最新的观测值加入到数据集中，并可能移除最早的数据点，然后再次进行预测。BP 神经网络滚动预测结构如图 5 所示。





图 5 BP 神经网络滚动预测结构图


Fig.5 BP neural network rolling prediction structure diagram

(4) 预测结果

将建立的模型用于表 1 的数据，对某水平井的造斜段及水平段的轨迹进行预测，结果如图 6 所示。



(a) BP 神经网络滚动预测井斜角



(b) BP 神经网络滚动预测方位角

图 6 BP 神经网络滚动预测结果

Fig.6 BP neural network rolling prediction results

1.2 模型对比

(1) 几何预测

几何预测包括圆柱螺旋线法与自然参数法，圆柱螺旋线法把已钻轨迹等同于等边螺旋角的圆柱螺旋线^[14]，依据当前最后两个点的井底曲率值，将井眼轨迹方向延伸到 i 点，比较适用于实钻监测时的井眼轨迹预测方法，预测公式为：

$$L_i = L_2 + \Delta L_i$$

$$\alpha_i = \alpha_2 + \frac{\alpha_2 - \alpha_1}{L_2 - L_1} \Delta L_i \quad (10)$$

$$\varphi_i = \varphi_2 + \frac{(\varphi_2 - \varphi_1)(\cos \alpha_2 - \cos \alpha_i)}{\cos \alpha_1 - \cos \alpha_2}$$

式中， α_1 、 φ_1 分别为 1 点井斜角、方位角； α_2 、 φ_2 分别为 2 点井斜角、方位角；


ΔL_i 表示当前点到预测点的井深； α_i 表示预测点井斜角； φ_i 表示预测点方位角。

自然参数法认为已钻井眼轨迹的井斜角变化率和方位角变化率均保持为常数^[15]，一般适用于存在方位漂移井段的井眼轨迹预测。


$$L_i = L_2 + \Delta L_i$$

$$\alpha_i = \alpha_2 + \frac{\alpha_2 - \alpha_1}{L_2 - L_1} \Delta L_i \quad (11)$$

$$\varphi_i = \varphi_2 + \frac{\varphi_2 - \varphi_1}{L_2 - L_1} \Delta L_i$$




(a) 圆柱螺线法预测井斜角




(b) 几何预测法预测井斜角

图 7 几何预测法预测井斜角

Fig.7 Geometric prediction method to predict well deviation angle



(a) 圆柱螺线法预测方位角



(b) 自然参数法预测方位角

图 8 几何预测法预测方位角

Fig.8 Geometric prediction method to predict Azimuth prediction

(2) 支持向量机预测

支持向量机算法对井眼轨迹预测等小样本问题具有较好的适用性^[16]。

1) 特征选取

选取如下的参数作为输入特征：

上一测点的井斜角， x_1 ；

上一测点的方位角， x_2 ；

上一测段的井斜变化率， x_3 ；

上一测段的方位变化率， x_4 。

此外，将当前测点处井斜角和方位角作为目标输出

y ：

$$\begin{aligned} X &= [x_1, x_2, x_3, x_4]^T \\ Y &= [y_1, y_2] \end{aligned} \quad (12)$$

由 $[X, Y]$ 构成一组训练样本。


(2) 参数选择

采用 SVR 算法进行训练，通过改变不同的惩罚系数 C 和控制误差 ϵ ，使模型预测井斜和方位的误差最小。

根据特征选取确定模型输入输出。最终模型的训练参数选择如下：核函数选择高斯基核函数(RBF)、 γ 取 0.002、


惩罚系数 C 为 3000、控制误差 ϵ 为 0.002。

通过 SVR 模型训练，利用造斜段刚开始的部分进行



(a) 支持向量机预测井斜角

模型训练，确定了模型参数，然后某定向井下部井段的井斜角和方位角进行了预测。结果如图 9 所示。



(b) 支持向量机预测方位角

图 9 支持向量机预测结果

Fig.9 Support vector machine prediction results

不同模型对比结果如表 3 所示。

表 3 不同方法对井斜角、方位角的预测误差对比

Table 3 Comparison of prediction errors of different methods

对比模型	井斜角误差/(°)		方位角误差/(°)	
	MAE	ME	MAE	ME
BP 滚动预测	0.34	0.006	1.213	0.292
圆柱螺线法	0.509	0.229	14.667	0.759
自然参数法	0.509	0.229	4.805	0.482
支持向量机	0.401	0.077	1.47	13.48

根据表 3 可知, BP 神经网络滚动预测模型的井斜角和方位角平均绝对误差分别为 0.34° 与 1.213° , 最大误差分别为 0.006° 与 0.292° , 其中井斜角平均绝对误差较圆柱螺线法、自然参数法、支持向量机分别降低 33.2% 与 15.2%, 方位角平均绝对误差较圆柱螺线法、自然参数法、支持向量机分别降低 91.7%、74.8%、17.5%。

1.3 轨迹可视化


在 Python 中编写三维轨迹跟踪程序, 轨迹计算方法为最小曲率法, 将实钻轨迹、预测轨迹进行可视化展现及对比。如图 10, 为轨迹数据加载界面。




图 10 轨迹数据加载界面

Fig.10 Trajectory data loading interface


分别对比几何预测、支持向量机预测、BP 神经网络滚动预测的轨迹图, 如图 11 所示。




(a) 圆柱螺线法预测结果



(b) 自然参数法预测结果



(c) 支持向量机预测结果



(d) BP 神经网络滚动预测结果

图 11 轨迹图

Fig. 11 locus plot

由轨迹图可知,采用 BP 神经网络滚动预测的轨迹与实钻轨迹重合度最高,预测靶点与实钻轨迹的靶点间差距 1.03m。相比于圆柱螺旋线法预测靶点间差距 4.28m,精确度提高 75.9%;自然参数法预测靶点间差距 2.17m,精确度提高 52.4%;支持向量机预测靶点间差距 1.81m,精确度提高 42.9%。

2 结论

(1)建立了基于时间序列的 BP 神经网络滚动预测模型,解决了传统 BP 神经网络预测钻进轨迹需要大量样本且模型适应性差的问题,与几何预测、支持向量机预测相比,有效提高了钻进轨迹的预测精度。

(2)模型采用滑动窗口的方式进行滚动预测,因此初始预测模型需要根据实钻数据来进行样本训练,在此之前的预测需要用几何预测方法。结合探边电阻率、近钻头伽马等超前探测仪器,考虑地层因素对轨迹预测的影响还有待进一步研究。

参考文献

- [1] 马玉凤,袁野.井眼轨迹预测及井眼轨迹三维可视化系统开发[J].微型电脑应用,2017,33(08):65-67+71.
Ma Yufeng,Yuan Ye.Development of wellbore trajectory prediction and 3D visualization system [J].Microcomputer Application,2017,33(08):65-67+71
- [2] 苗在强.旋转导向钻井工具稳斜钻进模式自动调控方法研究[D].中国石油大学(华东),2018.DOI:10.27644/d.cnki.gsydu.2018.000637.
Miao Zaiqiang.Research on Automatic Control Me-

thod for Stable Angle Drilling Mode of Rotating Directional Drilling Tools[D].China University of Petroleum(East China),2018.DOI10.27644/d.cnki.gsydu.2018.000637

[3] 王舸.推靠式旋转导向工具造斜率分析软件平台开发[D].中国石油大学(北京),2021.DOI:10.27643/d.cnki.gsybu.2021.001580.

Wang Ge.Development of software platform for slope analysis of push-pull rotary guidance tools[D].China University of Petroleum(Beijing),2021.DOI:10.27643/d.cnki.gsybu.2021-001580

[4] 谢鑫,唐玉华,徐浩,等.水平段钻进井眼轨迹的预测方法[J].中国石油大学胜利学院学报,2022,36(04):62-66.

Xie Xin,Tang Yuhua,Xu Hao,et al.Prediction method for horizontal drilling wellbore trajectory[J].Journal of Shengli College,China University of Petroleum,2022,36(04):62-66

[5] Jung,Tae Joon,Yeon Hwi Jeong,and Younggy Shin."Simulation of directional drilling by dynamic finite element method."Journal of Mechanical Science and Technology 36.7(2022):3239-3250.

[6] 李臻,宋先知,李根生,等.基于双输入序列到序列模型的井眼轨迹实时智能预测方法[J].石油钻采工艺,2023,45(04):393-403.DOI:10.13639/j.odpt.202212019.

Li Zhen,Song Xianhe,Li Gensheng,et al.Real time intelligent prediction method for wellbore trajectory based on dual input sequence to sequ-

- ence model[J]. Petroleum Drilling and Production Technology, 2023, 45(04): 393-403. DOI: 10.13639/j.odpt.202212019
- [7] Tunkiel, Andrzej T., Dan Sui, and Tomasz Wiktor. "Training-while-drilling approach to inclination prediction in directional drilling utilizing recurrent neural networks." Journal of Petroleum Science and Engineering 196(2021): 108-128.
- [8] Wang, Lu, et al. "Drilling trajectory survey technology based on 3D RISS with a single fiber optic gyroscope." Optik 203(2020): 163971.
- [9] Gao, Yi, Na Wang, and Yihao Ma. "L2-SSA-LSTM prediction model of steering drilling wellbore trajectory." IEEE Access(2023).
- [10] Ni, Qingjian, et al. "A Novel Trajectory Feature-Boosting Network for Trajectory Prediction." Entropy 25.7(2023): 1100.
- [11] Huang, Meng, et al. "Application of long short-term memory network for wellbore trajectory prediction." Petroleum Science and Technology(2023): 1-20.
- [12] Jeong, Jiho, et al. "Multi-objective optimization of drilling trajectory considering buckling risk." Applied Sciences 12.4(2022): 1829.
- [13] 王申. 非直井井眼轨道修正设计方法研究[D]. 东北石油大学, 2023. DOI: 10.26995/d.cnki.gdqsc.2023.000466.
- Wang Shen. Research on Design Method for Non Vertical Well Trajectory Correction[D]. Northeast University of Petroleum, 2023. DOI: 10.26995/d.cnki.gdqsc.2023.000466
- [14] 刘颖. 煤层气井眼轨迹三维可视化建模研究[D]. 中国石油大学(华东), 2017. DOI: 10.27644/d.cnki.gsydu.2017.000341.
- Liu Ying. Research on three-dimensional visualization modeling of coalbed methane wellbore trajectory[D]. China University of Petroleum(East China), 2017. DOI: 10.27644/d.cnki.gsydu.2017.000341
- [15] 王潘涛. 井眼轨迹预测与待钻轨道优化设计方法研究[D]. 中国石油大学(北京), 2022. DOI: 10.27643/d.cnki.gsybu.2022.000421.
- Wang Pantao. Research on wellbore trajectory prediction and optimization design method for drilling trajectory[D]. China University of Petroleum (Beijing), 2022. DOI: 10.27643/d.cnki.gsybu.2022.000421
- [16] 王延江, 杨培杰, 史清江, 等. 一种基于支撑向量机学习预测井眼轨迹的新方法[J]. 石油学报, 2005(05): 102-105.
- Wang Yanjiang, Yang Peijie, Shi Qingjiang, et al. A new method for predicting wellbore trajectory based on support vector machine learning[J]. Journal of Petroleum, 2005(05): 102-105
- 基金项目: 河北省教育厅科研项目“基于深度学习的钻井极限延伸及动力钻具智能控制控制方法研究”(编号: ZD2021304); 北华航天工业学院博士基金项目“无线反循环超短动力钻具关键技术研究”(编号: BKY-2022-04)。
- 作者简介: 顾乐成(1997-), 2024年毕业于北华航天工业学院机械专业, 硕士研究生, 现从事石油钻井自动控制技术及理论研究工作