

# 基于虚拟样本生成的脱靶量预测方法研究



赵保琛<sup>1</sup>, 何山<sup>1,2</sup>, 吴盘龙<sup>1</sup>, 王轲<sup>1</sup>, 陈伟<sup>1</sup>

1. 南京理工大学, 江苏 南京 210094

2. 中国空空导弹研究院 空基信息感知与融合全国重点实验室, 河南 洛阳 471099

**摘要:**对脱靶量进行准确预测,能够增强武器系统打击精度,提高系统的可靠性。由于传统的脱靶量预测方法依赖于递推模型的精准度,本文提出了一种基于虚拟样本生成的长短期记忆(LSTM)网络脱靶量预测方法。在分析脱靶量时间序列的特征基础上,利用其误差源特性建立误差源模型,结合其特性叠加形成虚拟样本。随后利用LSTM网络对脱靶量的非线性映射关系进行学习,形成基于虚拟样本的LSTM脱靶量预测模型,最后,利用实测数据验证脱靶量预测模型并与基于新息卡尔曼滤波算法和最小二乘法的预测结果进行对比分析。试验结果表明,基于虚拟样本生成的LSTM脱靶量预测方法能够在数据不足的情况下,通过虚拟样本的补充,提高预测准确性,具有良好的应用前景。

**关键词:**脱靶量预测; 虚拟样本生成; 长短期记忆神经网络; 脱靶量误差模型; 时间序列

中图分类号: TP13

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2025.01.005

高炮作为末端防御的最后一道屏障,在拦截快速近程或复杂环境下的低空目标中具有不可替代的优势,闭环校射是提高射击效能的重要举措。闭环校射由三部分工作组成:测量脱靶量、预测脱靶量和控制武器修正脱靶量。理论已经证明,控制的精度可以达到与预测的精度相等的程度,因此脱靶量的预测是闭环校射的核心<sup>[1-2]</sup>。

脱靶量是始点在目标上、终点在弹头上的一个矢量,是实际值和理想值的偏差矢量。实现对脱靶量的精确预测对闭环校射具有重要的意义,即利用脱靶量一系列的实测值预先估计出脱靶量的未来值,并在火炮射击前,校正射击诸元,以消除尚未发射的弹头可能形成的脱靶量。

脱靶量序列具有实时性高、不确定性强的特点,目前针对脱靶量的预测方法分为两类,第一类基于火炮射击的脱靶量的历史的时历数据,程杰<sup>[3]</sup>应用最优估计理论建立了最佳校正量预测模型;姚志军等<sup>[4]</sup>提出使用时间序列建模的方法,建立了弹丸脱靶量递推预测模型。杨丽君等<sup>[5]</sup>建立了基于自适应新息卡尔曼的脱靶量预测模型,冀云彪等<sup>[6]</sup>建立了基于改进的自适应卡尔曼滤波的脱靶量预测模

型。这些基于时历数据的预测方法计算量比较小,但主要针对低阶模型,对于高阶的系统预报效果不佳,具有很大局限性。第二类方法通过分析运动方程对脱靶量进行建模,曹小兵等<sup>[7]</sup>通过分析脉冲控制力与控制力矩,推导了有控六自由度运动方程组,利用捷联激光导引头测得的弹目偏差角及其方位信息,建立了脱靶量预测模型,实现了对脉冲修正弹的脱靶量预测; Moldavskaya 等<sup>[8]</sup>通过分析测量误差分布、制导律,结合相应滤波器对脱靶量进行预测; Johnson 等<sup>[9]</sup>建立了一个二元异方差线性模型,利用贝叶斯方法估计模型参数从而对脱靶量进行估计,但存在着建模复杂、通用性差的缺点。

近年来,随着人工智能技术的不断发展,以神经网络为代表的机器学习方法日趋成熟,因其可以逼近任意的非线性函数,拟合能力较强,所以逐渐受到研究者的关注,特别是长短期记忆神经网络(LSTM)<sup>[10-11]</sup>,通过引入门控单元实现了长期记忆能力,预测效果较好,被广泛应用在动力参数预测、空气流场预测、电力负荷预测、卫星轨道预测、风力发电预测、弹道轨迹预测等领域<sup>[12-19]</sup>。在脱靶量预测领域,陈

收稿日期: 2024-05-17; 退修日期: 2024-09-13; 录用日期: 2024-11-13

基金项目: 航空科学基金(2022Z037059001, 20220001059001); 江苏省卓越博士后计划(JB23147)

引用格式: Zhao Baochen, He Shan, Wu Panlong, et al. Research on miss distance prediction methods based on virtual sample generation [J]. Aeronautical Science & Technology, 2025, 36(01): 39-45. 赵保琛, 何山, 吴盘龙, 等. 基于虚拟样本生成的脱靶量预测方法研究 [J]. 航空科学技术, 2025, 36(01): 39-45.

劲博等<sup>[20]</sup>提出了一种基于脱靶量预测的飞行器反拦截机动方法,通过对弹目状态实时观测后利用LSTM进行实时脱靶量预测,再根据预测结果来实时决策机动时机。但其未将实际的脱靶量数据加入训练集,缺乏实例验证。

基于此,本文在分析脱靶量产生的原因的基础上,对脱靶量产生的各个部分进行分析建模,同时对脱靶量进行时序分析,利用超拉丁立方抽样形成虚拟样本,将虚拟样本引入LSTM模型进行训练并利用该网络对实际脱靶量数据进行了预测,与最小二乘法和传统卡尔曼滤波模型的预测结果相比,基于虚拟样本和LSTM的脱靶量预测模型的预测精度更高。

## 1 脱靶量虚拟样本生成模型

### 1.1 脱靶量影响因素

在实际应用中脱靶量一般为二维脱靶量。二维脱靶量主要包含高低角误差和方位角误差,各个方向上的分布是相互独立的,所以各个方向的脱靶量的研究方法是相同的。脱靶量是由多个误差源耦合而成的,可以通过多个误差源合成脱靶量序列。依照其统计特性可以分为系统误差、强相关误差、弱相关误差和不相关误差。

系统误差是射击开始前的已知的确定性误差,其方差、相关系数皆为零,其分布如下所示

$$\begin{cases} a_x = \bar{x}(k) \\ \text{cov}[\bar{x}(k), \bar{x}(j)] = 0 \end{cases} \quad (1)$$

式中,  $a_x$  为系统误差,  $\bar{x}(k)$  为射击误差均值。

强相关误差是射击过程中一个未知的常量,其相关系数为1。强相关误差包括各类静态误差,以及弹药、气象条件测量和装定误差,其分布如下所示

$$\begin{cases} \bar{x}_q(k) = 0 \\ x_q(k) = x_q(1) \\ \text{cov}[x_q(k), x_q(j)] = \sigma_q^2 \end{cases} \quad (2)$$

式中,  $x_q(k)$  为强相关误差;  $\sigma_q^2$  为强相关误差的方差。

弱相关误差是由于火炮射击所产生的误差,其特征是相关系数非0非1,由于火炮身管具有惯性,因此射击诸元的弱误差是相关且连续的,其分布如下所示

$$\begin{cases} x_r(k+1) = rx_r(k) + \sqrt{1-r^2} \omega(k) \\ x_r(1) = \omega(0) \\ \text{cov}[\omega(k), \omega(j)] = r^{|k-j|} \sigma_r^2 \\ |r| < 1 \end{cases} \quad (3)$$

式中,  $x_r(k)$  为弱相关误差;  $\sigma_r^2$  为弱相关误差的方差;  $r$  为相关系数。

不相关误差其相关系数为0,在射击误差中只有弹药误差为不相关误差,其分布如下式(4)所示

$$\begin{cases} \bar{x}_b(k) = 0 \\ \text{cov}[x_b(k), x_b(j)] = \begin{cases} 0, & k \neq j \\ \sigma_b^2, & k = j \end{cases} \end{cases} \quad (4)$$

式中,  $x_b(k)$  为不相关误差,  $\sigma_b^2$  为不相关误差的方差。

脱靶量数据由各误差项叠加生成,假设火炮射击的第  $k$  次的脱靶量为  $X(k)$ , 则满足

$$X(k) = x_q(k) + x_r(k) + x_b(k) + a \quad (5)$$

### 1.2 虚拟样本生成

基于神经网络对脱靶量的预测方法是建立在大量的脱靶量数据的基础之上的,因此必须建立一个脱靶量的数据库。而脱靶量的测量受到各种因素的影响导致能采集到的样本有限,因此需要虚拟样本以扩充原有数据,增强预测模型的预测精度和泛化能力。在高炮的射击过程中每一发弹药射击的脱靶量对其后各发都有影响,因而每次发射弹药对脱靶量的影响都是有差别的,需要选择合适的时序模型如自回归(AR)模型、移动平均(MA)模型、自回归移动平均(ARMA)模型等对实测脱靶量数据进行自相关性和偏相关性分析决定脱靶量模型阶数。同时结合脱靶量的误差源模型,以生成虚拟样本。图1所示为脱靶量的虚拟样本生成过程。




图1 虚拟样本生成过程

Fig.1 Virtual sample generation process

由图1可知,采用脱靶量误差源模型生成虚拟样本的基本思路是:在分析脱靶量的误差源模型的基础上,根据时间序列分析虚拟样本的输出长度和数据值,在此基础上,由输入层与隐含层的非线性映射得到虚拟样本的输入输出数据值,最后将得到输入、输出数据值构成虚拟样本集。

## 2 基于LSTM的脱靶量预测

LSTM可以缓解循环神经网络(RNN)中随着时间步长变长而存在的梯度消失的问题。在LSTM中,通过引入三个门处理过程,从而使其具备分析长时序序列数据的能力。LSTM基本的组成如图2所示。

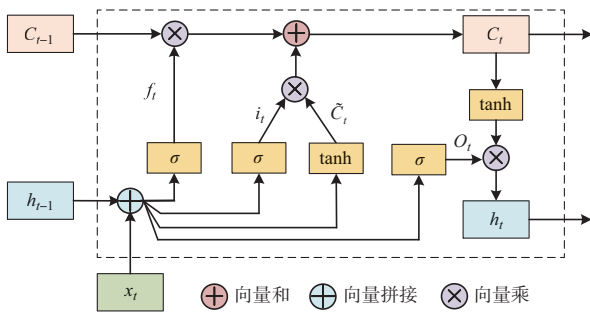


图2 LSTM网络基本组成单元

Fig.2 Basic constituent units of an LSTM network

图2中,  $x_t$  和  $h_t$  分别为  $t$  时刻的输入和输出,  $h_{t-1}$  为上一时刻 LSTM 单元的输出,  $C_{t-1}$  为上一时刻记忆细胞单元的输出,  $C_t$  为  $t$  时刻记忆细胞单元的输出。

遗忘门决定上一时刻有多少信息保留或遗忘在记忆细胞  $C_t$ , 根据上一时刻的输出  $h_{t-1}$  和当前输入  $x_t$  来产生一个 0~1 的  $f_t$  值, 其构成如式(6)所示

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (6)$$

输入门决定当前时刻有哪些值用来更新, 其构成如下

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (7)$$

当前时刻的候选记忆细胞单元  $\tilde{C}_t$  的构成表达式如下

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (8)$$

记忆细胞由  $f_t$  乘上一时刻记忆细胞单元  $C_{t-1}$  的值与  $i_t$  点乘当前时刻临时存储单元  $\tilde{C}_t$  的值结合进行更新。构成如下

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (9)$$

输出门决定当前记忆细胞  $C_t$  有多少输出到当前隐藏层的输出值  $h_t$ , 构成如下

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (10)$$

将记忆细胞  $C_t$  经过  $\tanh$  函数处理后与输出门  $O_t$  相乘, 最终得到输出如下

$$h_t = O_t \cdot \tanh(C_t) \quad (11)$$

式中,  $W_f$ 、 $W_i$ 、 $W_o$  为遗忘门、输入门、输出门的权重矩阵;  $b_f$ 、 $b_i$ 、 $b_c$ 、 $b_o$  分别为遗忘门、输入门、记忆细胞、输出门的偏执项;  $\sigma$  代表 sigmoid 非线性函数;  $\tanh$  为双曲正切函数。

为了更好地应用于长序列数据的分析和对脱靶量的预测等工作, 设计 LSTM 结构如图3所示。

按照信息的流向顺序, LSTM 神经网络由左到右分别为输入层、数个 LSTM 层和输出层, 其中输入层和输出层的激活函数都为  $\tanh$  函数。LSTM 层的个数由外部指定, 经过大量数据训练之后, LSTM 各层各神经元之间的权重发生改变, 误差函数缩小到一个可接受的范围, 从而完成了神经网络对训练数据的学习。

### 3 仿真结果与分析

#### 3.1 虚拟样本的生成

结合时序模型对实测脱靶量数据进行自相关性和偏相关性分析决定脱靶量模型阶数。如图4、图5可知, 自相关系数(ACF)呈现明显“拖尾”现象, 偏相关系数(PACF)呈现“截尾”现象。因此时序模型为自回归模型, 如式(12)所示

$$X_t = \phi_0 + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \varepsilon_t \quad (12)$$

式中,  $\{\varepsilon_t\}$  为独立同分布的白噪声序列, 方差为  $\sigma^2$ , 且  $\varepsilon_t$  与  $X_{t-1}, X_{t-2}, \dots$  独立。

平稳时间序列的偏相关系数(PACF)为5步截尾, 自相关系数(ACF)逐步衰减而不截尾。即当前脱靶量与前5时刻的脱靶量相关性最强。

因此在生成虚拟样本时, 将相关系数、强相关误差、弱相关误差、不相关误差设为随机变量, 将随机变量按照脱靶量模型阶数, 产生多组脱靶量时间序列, 作为训练集的样本。

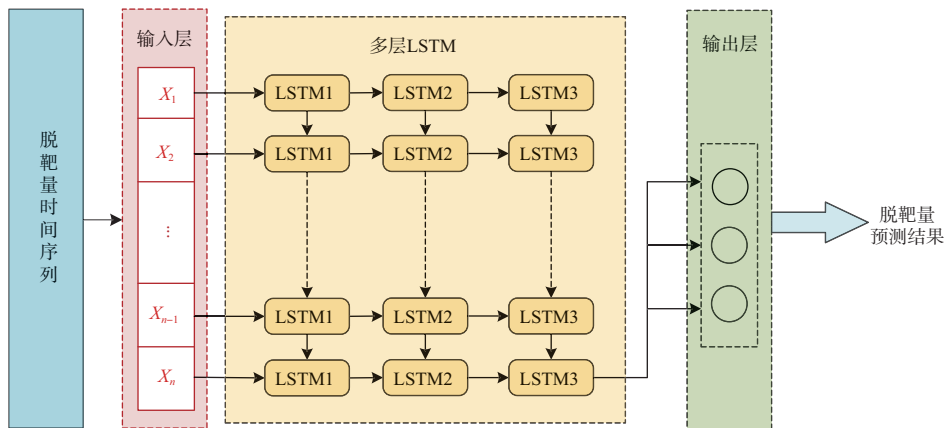


图3 LSTM神经网络结构

Fig.3 LSTM neural network architecture




图4 脱靶量序列自相关图像

Fig.4 Miss distance sequence autocorrelation image




图5 脱靶量序列偏自相关图像

Fig.5 Miss distance sequence partial autocorrelation image

在表1参数范围内使用超拉丁立方抽样法生成多组相关系数、强相关误差、弱相关误差、不相关误差,来构建虚拟样本作为训练集,本文中构建的单个训练集的大小为2650700个样本。

### 3.2 LSTM模型的训练

训练集在输入LSTM训练之前,需要经过归一化处理,

表1 脱靶量数据集生成参数及取值范围

Table 1 Parameters and value ranges for miss distance dataset generation

变量	取值范围
$r$	0.6~0.9
$x_b$	0.1~0.9
$x_r$	0.1~0.9
$x_q$	0.1~0.9

本文中采用的归一化函数定义为

$$X'_i = \frac{X_i - \mu_i}{\sigma_i} \quad (13)$$

式中, $X'_i, X_i$ 分别为归一化前后的状态变量; $\mu_i$ 为状态变量的均值; $\sigma_i$ 为状态变量的标准差。

将归一化后的训练集输入LSTM进行训练,训练过程中的损失函数定义为

$$X_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_{\text{test}}^{(i)} - \hat{y}_{\text{test}}^{(i)}) \quad (14)$$

式中, $n$ 为训练集样本个数; $y_{\text{test}}, \hat{y}_{\text{test}}$ 分别为标签的实际值和预测值。

使用训练集中的轨迹数据训练LSTM网络模型,记录训练过程中训练集的损失变化情况,如图6所示。




图6 训练损失函数

Fig.6 Training loss function

在训练LSTM网络时,采用Adams算法,最大迭代次数设为300,初始学习率设置为0.0001,200轮后学习率降为原来的10%。在训练过程中,LSTM的损失下降非常迅速,几轮后损失已经趋于零。在第100轮左右,进一步放大图6中矩形框中的曲线,可以看出测试集的损失曲线保持平稳。基于这些观察,可以合理地认为网络已经收敛,完成对LSTM进行训练,训练完成后的网络即可用作对当前状态下的脱靶量的实时预测。

为了获取真实的脱靶量数据,本文以某径高炮为测试对象,无人机模拟来袭目标,在标准气象条件下和非标准气象条件下分别进行射击试验,从得到的多组方位角脱靶量数据和高低角脱靶量数据中分别随机抽取一组脱靶量序列,对训练好的LSTM进行测试,在给定前一时间真实的脱靶量数据的情况下,LSTM和对比方法的预测结果分别如



图7和图8所示。

结合图7与图8的两组预测表现来看, 基于虚拟样本和LSTM的脱靶量预测模型能够对脱靶量进行预测, 且与基于新息卡尔曼模型相比精度更高。




图7 方位角脱靶量预测

Fig.7 Azimuth miss distance prediction




图8 高低角脱靶量预测

Fig.8 Elevation miss distance prediction

为了对模型的结果进行定量评价, 同时对比不同模型之间的优劣, 选用的性能评价函数应具有普适性。因此本文选用均方根误差(RMSE)、平均绝对误差(MAE)为评价指标, 其定义为

$$X_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{\text{test}}^{(i)} - \hat{y}_{\text{test}}^{(i)})^2} \quad (15)$$

$$X_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_{\text{test}}^{(i)} - \hat{y}_{\text{test}}^{(i)}| \quad (16)$$

式中,  $y_{\text{test}}$  为测试集上的真实值结果;  $\hat{y}_{\text{test}}$  为测试集上的预测

值结果。MAE是用来衡量预测模型对连续数据的预测精度的指标。它测量预测值与真实值之间的平均绝对差, 表示预测值与真实值之间的平均偏差程度。MAE越小, 模型的预测就越准确。均方根误差是用均方误差的平方根来计算的。因为计算的是误差的平方, 异常值被赋予更多的权重, 为较小的误差创建了平滑的梯度, 有助于优化算法获得参数的最优值。RMSE考虑了实际值的变化并测量了误差的平均幅度, 这有助于确定特征是否增强了模型的预测。RMSE越小, 模型的预测就越准确。

由此可得高低和方位方向上不同方法的脱靶量的预测误差, 见表2和表3。

表2 方位角脱靶量预测误差

Table 2 Azimuthal miss distance prediction error

参数	MAE	RMSE
最小二乘法	0.0643	0.0788
新息卡尔曼	0.0486	0.0618
本文算法	0.0431	0.0513

表3 高低角脱靶量预测误差

Table 3 Elevation miss distance prediction error

参数	MAE	RMSE
最小二乘法	0.0607	0.0747
新息卡尔曼	0.0425	0.0537
本文算法	0.0401	0.0498

由表2和表3可知, 基于虚拟样本和LSTM的脱靶量预测模型优于最小二乘法和基于新息的卡尔曼滤波预测模型, 在方位角方面, 相较于最小二乘法在MAE指标方面提升33%, 在RMSE指标方面提升35%左右; 相较于基于新息的卡尔曼滤波模型在MAE指标方面提升11%, 在RMSE指标方面提升17%左右; 在高低角方面相较于最小二乘法在MAE指标方面提升34%, 在RMSE指标方面提升33%左右; 相较于基于新息的卡尔曼滤波模型MAE性能提升5%, 在RMSE指标方面提升7%左右。

## 4 结论

本文通过对脱靶量误差源统计特性进行分析, 提出基于虚拟样本生成的LSTM脱靶量预测方法。通过研究, 得到以下结论:

- (1) 本文通过分析脱靶量生成的误差源模型, 设计了根据时间序列分析以及误差源模型生成的虚拟样本方法, 并根据此方法生成了虚拟样本集, 为小样本下的神经网络训练提供数据补充。
- (2) 通过仿真试验表明, 对比了本文提出的方法与最小

二乘法、基于新息卡尔曼滤波的脱靶量预测效果,本文提出的方法在RMSE和MAE两方面相较最小二乘法和新息卡尔曼滤波预测方法具有显著优势。本文提出的算法能够在数据不足的情况下,通过虚拟样本的补充,提高预测准确性,具有良好的应用前景。

AST

## 参考文献

- [1] 魏国华, 吴嗣亮, 王菊, 等. 脱靶量测量技术综述[J]. 系统工程与电子技术, 2004, 26(6): 768-772.  
Wei Guohua, Wu Siliang, Wang Ju, et al. Overview of miss distance measurement technology[J]. Systems Engineering and Electronics, 2004, 26(6): 768-772. (in Chinese)
- [2] 戴耀, 汪德虎, 胡江. 舰炮对空闭环校正新方法研究[J]. 电子学报, 2006, 34(12): 2491-2493.  
Dai Yao, Wang Dehu, Hu Jiang. Study of a new method of the shipborne gun's closed loop fire correction against air[J]. Acta Electronica Sinica, 2006, 34(12): 2491-2493. (in Chinese)
- [3] 程杰. 大闭环校正最佳校正量预测模型[J]. 兵工自动化, 2013, 32(2): 17-18+23.  
Cheng Jie. Foresee model of best rectify measure on closed-loop spotting [J]. Ordnance Industry Automation, 2013, 32(2): 17-18+23. (in Chinese)
- [4] 姚志军, 朱凯, 王军, 等. 速射火炮立靶密集度的相关系数分析与检测[J]. 火炮发射与控制学报, 2012, 33(1): 1-4.  
Yao Zhijun, Zhu Kai, Wang Jun, et al. Analysis and detection for correlation coefficient of rapid-fire gun's vertical target density[J]. Journal of Gun Launch & Control, 2012, 33(1): 1-4. (in Chinese)
- [5] 杨丽君, 刘博, 王军, 等. 基于自适应新息卡尔曼滤波的脱靶量预测算法[J]. 指挥控制与仿真, 2021, 43(6): 46-52.  
Yang Lijun, Liu Bo, Wang Jun, et al. Algorithm of miss distance prediction based on innovation adaptive Kalman filter [J]. Command Control and Simulation, 2021, 43(6): 46-52. (in Chinese)
- [6] 冀云彪, 张鹏飞, 赵永娟, 等. 基于改进自适应卡尔曼滤波的闭环脱靶量预测技术研究[J]. 火炮发射与控制学报, 2023, 44(4): 43-50.  
Ji Yunbiao, Zhang Pengfei, Zhao Yongjuan, et al. Research on the prediction technology of closed-loop target-missing quantity based on improved adaptive Kalman filtering[J]. Journal of Gun Launch & Control, 2023, 44(4): 43-50. (in Chinese)
- [7] 曹小兵, 徐伊岑, 常思江, 等. 基于脱靶量预测的脉冲末修迫弹控制方法研究[J]. 火箭与制导学报, 2017, 37(2): 23-26+31.  
Cao Xiaobing, Xu Yicen, Chang Sijiang, et al. Research on control method for terminal correction mortar projectiles subjected to lateral impulses based on miss distance prediction [J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2017, 37(2): 23-26+31. (in Chinese)
- [8] Moldavskaya E, Shinar J. Distribution of the zero-effort miss distance estimation error in interception problems[J]. Applied Mathematics and Computation, 2015, 269: 217-231.
- [9] Johnson T H, Haman J T, Wojton H, et al. Circular prediction regions for miss distance models under heteroskedasticity[J]. Quality and Reliability Engineering International, 2021, 37(7): 2991-3003.
- [10] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [11] Van Houdt G, Mosquera C, Nápoles G. A review on the long short-term memory model[J]. Artificial Intelligence Review, 2020, 53(8): 5929-5955.
- [12] 何昆鹏, 赵瑾玥, 周琪, 等. 基于LSTM神经网络的机载光纤陀螺温度冲击误差补偿技术[J]. 航空科学技术, 2024, 35(2): 31-38.  
He Kunpeng, Zhao Jinyue, Zhou Qi, et al. Temperature shock error compensation technology for airborne fiber optic gyroscopes based on LSTM neural networks[J]. Aeronautical Science & Technology, 2024, 35(2): 31-38. (in Chinese)
- [13] 韩仁坤, 杜焦喜, 刘子扬, 等. 基于深度神经网络的含运动边界非定常流场预测方法研究[J]. 航空科学技术, 2023, 34(12): 37-42.  
Han Renkun, Du Jiaoxi, Liu Ziyang, et al. Research on the prediction method of unsteady flow field with moving boundary based on deep neural network[J]. Aeronautical Science & Technology, 2023, 34(12): 37-42. (in Chinese)
- [14] 王坤, 朱一扬. 基于DAM-QLSTM混合模型的辅助动力装置性能参数预测方法[J]. 航空科学技术, 2024, 35(7): 40-48.  
Wang Kun, Zhu Yiyang. Prediction method of auxiliary power unit performance parameter based on DAM-QLSTM mixed model[J]. Aeronautical Science & Technology, 2024, 35(7): 40-48. (in Chinese)

- [15] Sun Hongbin, Qing Cui, Wen Jingya, et al. Short-term wind power prediction method based on CEEMDAN-GWO-Bi-LSTM[J]. *Energy Reports*, 2024, 11: 1487-1502.
- [16] Guo Xifeng, Zhao Qiannan, Zheng Di, et al. A short-term load forecasting model of multiscale CNN-LSTM hybrid neural network considering the real-time electricity price[J]. *Energy Reports*, 2020, 6: 1046-1053.
- [17] Chen Junfu, Pi Dechang, Wu Zhiyuan, et al. Imbalanced satellite telemetry data anomaly detection model based on Bayesian LSTM[J]. *Acta Astronautica*, 2021, 180: 232-242.
- [18] 任济寰, 吴祥, 薄煜明, 等. 基于增强上下文信息长短期记忆网络的弹道轨迹预测[J]. *兵工学报*, 2023, 44(2): 462-471.
- Ren Jihuan, Wu Xiang, Bo Yuming, et al. Ballistic trajectory prediction based on context-enhanced long short-term memory network[J]. *Acta Armamentarii*, 2023, 44(2): 462-471. (in Chinese)
- [19] Zhu Junpeng, Zhao Hongli, Du Xing. Application of long short-term memory neural network to orbit prediction of satellite[J]. *Journal of Ordnance Equipment Engineering*, 2017, 38(10): 127-132.
- [20] 陈劭博, 严佳民, 卜奎晨. 基于脱靶量预测的飞行器反拦截机动方法[J]. *系统工程与电子技术*, 2023, 45(9): 2922-2930.
- Chen Shaobo, Yan Jiamin, Bu Kuichen. Anti-intercept maneuver method of vehicle based on prediction of miss distance[J]. *Systems Engineering and Electronics*, 2023, 45(9): 2922-2930. (in Chinese)

## Research on Miss Distance Prediction Methods Based on Virtual Sample Generation

Zhao Baochen<sup>1</sup>, He Shan<sup>1,2</sup>, Wu Panlong<sup>1</sup>, Wang Ke<sup>1</sup>, Chen Wei<sup>1</sup>

1. *Nanjing University of Science and Technology, Nanjing 210094, China*

2. *National Key Laboratory of Air-based Information Perception and Fusion, China Institute of Air-to-Air Missile, Luoyang 471099, China*

**Abstract:** Accurately predicting the miss distance can enhance the accuracy of weapon system strikes and improve the reliability of the system. Due to the traditional miss distance prediction methods relying on the accuracy of recursive models, this paper proposes a long short-term memory (LSTM) network off target prediction method based on virtual sample generation. Based on the analysis on the characteristics of off target time series, an error source model is established using its error source characteristics, and combined with its characteristics to form a virtual sample. Subsequently, the LSTM network was used to learn the nonlinear mapping relationship of off target distance, forming an LSTM off target prediction model based on virtual samples. Finally, the off target prediction model was validated using measured data and compared and analyzed with the prediction results based on the novel Kalman filter algorithm and the least squares method. The experimental results show that the LSTM off target prediction method based on virtual sample generation can improve prediction accuracy by supplementing virtual samples in the case of insufficient data, and has good application prospects.

**Key Words:** miss distance prediction; virtual sample generation; LSTM neural network; miss distance error model; time series

**Received:** 2024-05-17; **Revised:** 2024-09-13; **Accepted:** 2024-11-13

**Foundation item:** Aeronautical Science Foundation of China(2022Z037059001, 20220001059001); Jiangsu Funding Program for Excellent Postdoctoral Talent (JB23147)