

# 一种神经网络弹道诸元快速解算方法

连欢<sup>1</sup>, 邓泽晓<sup>1</sup>, 李志国<sup>2</sup>, 黄祺威<sup>1</sup>, 刘鲁华<sup>1</sup>

1. 深圳市智能微小卫星星座技术与应用重点实验室, 深圳 518107

2. 北京宇航系统研究所, 北京 100076

**摘要** 针对导弹快速发射的任务需求, 提出一种神经网络诸元快速解算方法。首先, 根据任务需求建立了终端速度、高度、速度倾角和弹道诸元的映射关系, 推导了基于 LM 优化算法的神经网络参数更新方法; 然后, 基于贝叶斯正则化理论设计了 BP 神经网络结构, 得到满足精度要求的优化网络结构; 最后, 利用牛顿迭代法生成诸元数据库, 将其作为训练集对神经网络进行训练, 获得了具有优化参数的网络模型, 并展开了仿真验证。理论与仿真结果表明, 该方法可以实现射前诸元的快速精确计算, 有效缩短射前准备时间。

**关键词** 弹道诸元; LM 优化算法; BP 神经网络; 贝叶斯正则化

中图分类号: TJ760

文献标识码: A

文章编号: 1006-3242(2024)05-0038-07

## A Fast Calculation Method for Solving Firing Data by Neural Network

LIAN Huan<sup>1</sup>, DENG Zexiao<sup>1</sup>, LI Zhiguo<sup>2</sup>, HUANG Qiwei<sup>1</sup>, LIU Luhua<sup>1</sup>

1. Shenzhen Key Laboratory of Intelligent Microsatellite Constellation, Shenzhen 518107, China

2. Beijing Institute of Astronautical Systems Engineering, Beijing 100076, China

**Abstract** Regarding meeting the task requirement of rapid missile launch, a fast firing data solving method based on neural network is proposed. Firstly, the mapping relationship among terminal velocity, altitude, velocity inclination and firing data is established, and the LM optimization neural network model is derived. Then, based on Bayesian regularization theory, the BP neural network structure is designed, and the optimized network structure which can meet the accuracy requirements is obtained. Finally, Newton iteration method is used to generate the database as training set which is used to train the neural network, so that the network model with optimized parameters is obtained, and the simulation is implemented. The theoretical and simulation results show that the rapid calculation of the firing data before shooting can be achieved by applying this method.

**Key words** Firing data; LM optimization algorithm; BP neural network; Bayesian regularization

资助项目: 国家自然科学基金资助(61973326); 深圳市科技计划资助(ZDSYS20210623091808026)

收稿日期: 2024-02-19

作者简介: 连欢(1999-), 女, 硕士研究生, 主要研究方向为飞行动力学、制导与控制; 刘鲁华(1977-), 男, 教授, 博导, 主要研究方向为飞行动力学、制导与控制, 飞行器系统建模与仿真, 本文通信作者。

引用格式: 连欢, 邓泽晓, 李志国, 等. 一种神经网络弹道诸元快速解算方法[J]. 航天控制, 2024, 42(5): 38-44.

LIAN Huan, DENG Zexiao, LI Zhiguo, et al. A Fast Calculation Method for Solving Firing Data by Neural Network[J]. Aerospace Control, 2024, 42(5): 38-44.

## 0 引言

以射前计算的标准弹道为基准,装订于导弹上,用于飞行控制的基准参数即为诸元<sup>[1]</sup>。在现代战争中,作战反应能力直接影响导弹武器系统效能的发挥,缩短发射准备时间能有效提高导弹生存能力和打击效能,因此诸元计算的快速性尤为关键。如何在保证诸元计算的精确性的前提下提高诸元计算的速度是亟待解决的重要问题。

针对诸元计算主要有解析法和迭代法两种经典方法。解析法计算实时性好,但求解困难且精度受限;迭代法则可以对任意发射条件下的发射诸元进行精确计算<sup>[2]</sup>,但计算量大。针对解析法,诸元解析解通常作为初值,需要结合其他方法对精度进行补偿,文献[3]推导了滑翔段弹道解析解,考虑常数及一阶解,为诸元解析解的计算提供思路;文献[4]针对弹道导弹采用解析与迭代相结合的方法计算诸元,一定程度上结合了解析方法的快速性和迭代方法的精确性;文献[5]针对弹道导弹,利用线性回归方法建立拟合的解析式,并将其作为初值,再通过LM方法搜索诸元精确解。基于迭代法,文献[6]针对助推段提出了标准弹道诸元的迭代求解模式,提供了全程弹道诸元的选取策略;文献[7]预先准备简易射表为牛顿迭代准备初值,有效减少诸元解算的迭代次数;文献[8]利用牛顿迭代法离线生成数据库,在射前利用插值即时计算诸元,但其插值方法需遍历数据库。近年来,智能优化方法在提升诸元计算精确性和快速性上提供了新思路,文献[9]提出了基于长短时记忆神经网络的导弹机动轨迹预测方法,利用离线数据库进行训练,在线预测导弹的位置和速度;文献[10]提出了基于广义回归神经网络的弹丸落点预报方法,并利用粒子群算法优化网络参数,实现了快速精确的落点预报;文献[11]提出了助推段飞行程序参数化方法,并利用神经网络实现高精度的终端状态预报。综上,智能优化方法具有较强的时效性,且能保证解算结果的精确性,在诸元解算问题上具有良好的适配性。

本文针对导弹快速发射的任务需求,研究助推段的诸元计算问题,提出了一种神经网络诸元快速解算方法。根据任务需求确定诸元,基于LM(Levenberg-marquardt)优化算法推导神经网络的参数更新方法,并基于贝叶斯正则化理论优化神经网络结

构,然后利用诸元数据库训练网络,最后通过训练好的神经网络快速解算诸元。

## 1 助推段诸元选取策略

弹道诸元是为确保导弹按照一定轨迹命中目标的一组装订参数,包括瞄准方位角、飞程序角等。通常情况下,在发射点和落点确定后应首先确定飞行方位角,而本文针对助推段进行诸元选取,其飞行任务是将飞行器按要求推送至弹箭分离点。为了使任务更具泛用性,不考虑具体的发射点和落点,将弹道诸元选取为能够确定弹道的若干飞程序角。

在半速度坐标系下建立导弹助推段动力学模型<sup>[12]</sup>。采用三级火箭串联助推模式满足飞行器关机点要求,利用工程设计法<sup>[13]</sup>,将一、二及三级攻角设计为如下形式:

$$\alpha(t) = \begin{cases} 0^\circ, & 0 \leq t \leq t_{11} \\ -\alpha_{m1} \sin^2[f_1(t)], & t_{11} < t \leq t_2 \\ \alpha_{m2} \sin^2[f_2(t)], & t_2 < t \leq t_3 \\ \alpha_{m3} \sin^2[f_3(t)], & t_3 < t \leq t_{\text{end}} \end{cases} \quad (1)$$

式中: $t_{11}$ ,  $t_2$ ,  $t_3$  和  $t_{\text{end}}$  分别为垂直起飞段结束时间、二级点火时间、三级点火时间和三级点火结束时间,  $\alpha_{m1}$ ,  $\alpha_{m2}$  和  $\alpha_{m3}$  分别为第一、二和三级最大攻角。其中  $f(t)$  的表达式为

$$f(t) = \frac{\pi(t - t_{11})}{k_i(t_{12} - t) + (t - t_{11})} \quad (2)$$

式中: $k_i$  为攻角转弯参数,为攻角到达极值时间的相关常数。

助推段的主要约束条件为关机点的高度  $h^*$ 、速度  $V^*$  和当地速度倾角  $\theta^*$ ,将这3个终端参数作为网络输入。根据前文分析,将弹道诸元选取为助推段弹道的设计量  $\alpha_{m1}$ ,  $\alpha_{m2}$  和  $\alpha_{m3}$ ,即3个火箭段的最大攻角。由此可以得到神经网络的输入和输出参数,如图1所示。




图1 助推段诸元解算神经网络模型映射关系

## 2 LM-BP 神经网络模型构建

### 2.1 LM-BP 神经网络参数确定方法

BP 神经网络训练由输入的正向传播与误差的反向传播两个过程组成。输入样本从输入层传入,经过前馈网络传向输出层后,将输出结果与期望输出间的误差反向传播,网络各层参数据其不断调整,这就是神经网络学习和训练的过程。传统的训练算法为最速下降法,其训练精度和效率较低,故本文采用 LM 算法作为 BP 神经网络的训练算法。

LM 算法是高斯-牛顿法的改进形式,非常适合用以优化神经网络的训练过程<sup>[14]</sup>。神经网络的性能指标为误差平方和,即

$$E_D = \sum_{q=1}^Q (t_q - a_q)^T (t_q - a_q) = \mathbf{e}^T(\mathbf{x})\mathbf{e}(\mathbf{x}) \quad (3)$$

式中: $t_q$  为理想输出向量, $a_q$  为实际输出向量, $Q$  为训练样本数, $\mathbf{x}$  为全体权值和偏置所组成的向量, $\mathbf{e}(\mathbf{x})$  为所有样本的误差。

LM-BP 算法每一次迭代过程按照以下方式对权值和偏置进行更新:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} - [\mathbf{J}^T(\mathbf{x})\mathbf{J}(\mathbf{x}) + \mu\mathbf{I}]^{-1}\mathbf{J}^T(\mathbf{x})\mathbf{e}(\mathbf{x}) \quad (4)$$

式中:上标  $k$  表示迭代次数, $\mathbf{J}(\mathbf{x})$  为  $\mathbf{e}(\mathbf{x})$  关于  $\mathbf{x}$  的雅可比矩阵, $\mu$  为设计常数。

合理选取  $\mu$  值是减少训练收敛时间、提升训练精度的关键。 $\mu$  取值越大,LM 方法越接近梯度下降法,收敛速度慢但保证收敛性; $\mu$  取值越小,越接近高斯-牛顿法,精确度越高。本文采用的  $\mu$  的取值方法为:

$$\mu = c \cdot E_D \quad (5)$$

式中: $E_D$  为输出误差平方和, $c$  为设计常数,用以调控  $\mu$  的量级,通过试验法得出。

将  $\mu$  设计为输出误差平方和的倍数是符合相应趋势的,当误差结果较大时,需要保证收敛性;当误差结果较小时,则需要更精确的解。

### 2.2 LM-BP 神经网络的结构优化方法

神经网络结构是指网络的层数及各层节点数,网络结构过大可能造成网络过拟合导致其泛化能力不足。本文利用贝叶斯正则化法来实现网络的简化<sup>[15]</sup>,正则化是指在性能指标上添加用于惩罚网

络复杂度的正则化项  $E_w$ ,其形式为网络参数值平方和,故正则化后的目标函数为

$$F(\mathbf{x}) = \beta E_D + \alpha E_w = \beta \sum_{q=1}^Q (t_q - a_q)^T (t_q - a_q) + \alpha \sum_{i=1}^n x_i^2 \quad (6)$$

贝叶斯公式的基本形式表示为

$$\text{后验密度} = \frac{\text{似然函数} \times \text{先验密度}}{\text{归一化因子}} \quad (7)$$

贝叶斯估计的目的是最大化后验密度。将网络训练过程置于两层贝叶斯框架中,最终得到所需的网络有效参数数量  $\gamma$  的值。

在第一层贝叶斯框架中假设网络参数值  $\mathbf{x}$  为随机变量,其后验密度满足

$$P(\mathbf{x} | D, \alpha, \beta, M) = \frac{P(D | \mathbf{x}, \beta, M) P(\mathbf{x} | \alpha, M)}{P(D | \alpha, \beta, M)} \quad (8)$$

式中: $D$  表示训练数据集, $M$  表示网络结构, $\alpha$  和  $\beta$  为正则化参数,分子分别为似然函数和先验密度,分母为归一化项。

假设数据集中存在随机独立分布的零均值噪声源,网络参数服从零均值高斯分布,则分子为两个指数函数乘积表达式,整理式(8)为

$$P(\mathbf{x} | D, \alpha, \beta, M) = \frac{\frac{1}{Z_w(\alpha)} \exp(-\alpha E_w) \frac{1}{Z_D(\beta)} \exp(-\beta E_D)}{\text{归一化因子}} = \frac{1}{Z_F(\alpha, \beta)} \exp(-F(\mathbf{x})) \quad (9)$$

式中: $Z_w(\alpha)$ ,  $Z_D(\beta)$  和  $Z_F(\alpha, \beta)$  均为高斯分布的常数项。

由式(9)可知,训练网络的过程为最小化正则化性能指标  $F(\mathbf{x})$  的过程,即为最大化后验密度的过程。

第二层贝叶斯框架是为了估计参数  $\alpha$  和  $\beta$ ,与式(7)的结构相同, $\alpha$  和  $\beta$  的后验密度为

$$P(\alpha, \beta | D, M) = \frac{P(D | \alpha, \beta, M) P(\alpha, \beta | M)}{P(D | M)} \quad (10)$$

假设  $P(\alpha, \beta | M)$  为均匀分布函数,则可以通过最大化似然函数  $P(D | \alpha, \beta, M)$  最大化后验密度。

整理式(8)可得到似然函数的表达式:

$$P(D | \alpha, \beta, M) = \frac{Z_F(\alpha, \beta)}{Z_D(\beta) Z_w(\alpha)} \quad (11)$$

将  $F(\mathbf{x})$  在其极小点  $\mathbf{x}^{MP}$  附近进行二阶泰勒展开并代入式(9),将其与高斯分布的标准形式对应相等后求得  $Z_F(\alpha, \beta)$ ,即可对式(11)进行最大似然

估计,求得在极小点处  $\alpha$  和  $\beta$  的最优值:

$$\alpha^{MP} = \frac{\gamma}{2E_w(\mathbf{x}^{MP})}, \quad \beta^{MP} = \frac{N - \gamma}{2E_D(\mathbf{x}^{MP})} \quad (12)$$

式中: $\gamma$  定义为有效参数数量,其表达式为

$$\begin{aligned} \gamma &= n - 2\alpha^{MP} \text{tr}\{(\mathbf{H}^{MP})^{-1}\} = \\ &= n - 2\alpha^{MP} \sum_{i=1}^n \frac{1}{\beta^{MP} \lambda_i + 2\alpha^{MP}} = \\ &= \sum_{i=1}^n \frac{\beta^{MP} \lambda_i}{\beta^{MP} \lambda_i + 2\alpha^{MP}} \end{aligned} \quad (13)$$

式中: $\mathbf{H} = \beta \nabla^2 E_D + \alpha \nabla^2 E_w$  是  $F(\mathbf{x})$  的海森矩阵, $n$  为网络的所有权值和偏置的数量, $\lambda_i$  为  $\nabla^2 E_D$  的特征值。

根据式 (13) 可得,当某个特征值  $\lambda_i$  很大时,可忽略分母中的  $\alpha^{MP}$ ,认为有效参数数量增加 1 个。特征值大意味着性能指标沿着其特征向量的方向变化快,每一个大的特征值代表一个性能优化的有效方向。故有效参数数量的物理意义为  $\nabla^2 E_D(\mathbf{x})$  具有的较大特征值的数量,即有效优化的参数个数。

### 2.3 神经网络的结构确定方法

针对强非线性的导弹运动方程组,将神经网络的隐藏层设为两层,并设定每层的节点个数相同。初始网络的节点个数选为 30,此时网络结构较大。

通过贝叶斯正则化 LM-BP 算法对神经网络进行训练,收敛后得到有效参数数量  $\gamma$ ,令网络参数总个数与其相等,即可根据式 (14) 计算新的隐藏

层的节点个数,将其作为最终网络结构的每层节点个数:

$$n = \gamma \quad (14)$$

## 3 基于神经网络的诸元解算方法

### 3.1 标准弹道训练集构建方法

为了给神经网络提供训练集,利用牛顿迭代法构建高精度的标准弹道诸元数据库。首先确定助推段终端约束条件的极大值 ( $h_{\max}, V_{\max}, \theta_{\max}$ ) 和极小值 ( $h_{\min}, V_{\min}, \theta_{\min}$ ),将其作为数据库的边界,然后通过等间距剖分确定多组终端状态,最后通过牛顿迭代法计算每组状态对应的诸元,即可得到多条标准弹道的终端状态-诸元映射关系,将其作为神经网络训练时所需的数据支撑。

在训练集使用时,由于各参数量级差别较大,因此需要对其进行归一化,按下式将每个元素按照对应类别归一化至  $[-1, 1]$ :

$$\hat{x}_i = 2 \frac{x_i - \min_{i=1,2,\dots,Q} x_i}{(\max_{i=1,2,\dots,Q} x_i - \min_{i=1,2,\dots,Q} x_i)} - 1 \quad (15)$$

将训练集的最大值和最小值记录下来,在使用训练好的神经网络时据其进行数据的归一化和逆归一化。

### 3.2 弹道诸元求解方法

基于神经网络的诸元解算方法的整体框架图如图 2 所示。

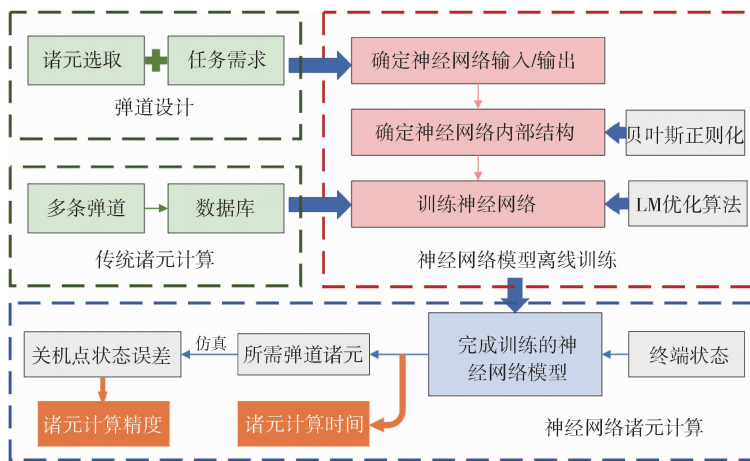


图 2 神经网络诸元解算方法的整体框架图

根据任务需求和诸元选取方案确定神经网络的输入和输出,通过传统诸元计算方法得到标准弹

道数据库,将其作为训练集。基于贝叶斯正则化理论确定较优的神经网络结构,并利用 LM 优化算法

进行网络参数更新。

基于完成训练的神经网络模型可进行诸元的在线计算,输入终端状态则可计算相应诸元,此时得到诸元计算时间的指标。利用神经网络计算的诸元进行弹道仿真,通过对比终端状态误差,可以验证诸元的计算精度。

## 4 基于神经网络的诸元解算仿真校验

### 4.1 神经网络训练效果的仿真

对助推段弹道数据库进行构建,关机点高度范围为 76 ~ 83 km,剖分间隔为 100 m;关机点速度范围为 6240 ~ 6290 m/s,剖分间隔为 2 m/s;关机点速度倾角范围为  $0^\circ \sim 2^\circ$ ,剖分间隔为  $0.5^\circ$ ,共 9230 组样本,将 80% 作为训练集,20% 作为测试集,用于训练神经网络。

将神经网络的隐藏层设为两层,首先设定每层节点为 30,此时网络的实际参数个数为 1141。利用贝叶斯正则化训练方法进行训练,收敛后得到有效参数  $\gamma = 397$ ,根据式(14)计算的节点个数  $n = 16$ ,将其作为网络的每层节点个数。神经网络的训练相关参数取值如表 1 所示。

表 1 神经网络训练相关参数的取值

参数名称	参数值
输入层节点数	3
输出层节点数	3
隐藏层数	2
隐藏层节点数	[12, 16, 20, 30]
设计常数 $\mu$	$1 \times 10^3$
激活函数	双曲正切
训练次数	80

为验证贝叶斯正则化 LM-BP 神经网络的训练效果,选取不同隐藏层节点数进行训练,获得的训练效果如表 2 所示。

表 2 不同隐藏层节点数的训练效果

节点数	参数个数	均方差	训练时间/s
12	243	$7.2557 \times 10^{-11}$	68.6542
16	387	$1.6169 \times 10^{-11}$	77.8740
20	563	$3.9371 \times 10^{-11}$	94.5934
30	1143	$5.7393 \times 10^{-11}$	150.3568

由表 2 可知,随着节点数增加,训练时间递增,当节点个数小于 16 时,网络未拟合完全;当节点个数大于 16 时,网络呈现过拟合的趋势。由此可知,利用贝叶斯正则化得到的网络节点数能够达到很好的训练效果,能有效地避免过拟合现象的发生。

神经网络的最终结构为 3-16-16-3,训练过程的均方误差变化曲线如图 3 所示。由图可知,神经网络的训练在第 48 次时收敛,在第 80 次完成训练,此时测试集的均方差值为  $1.6169 \times 10^{-11}$ ,训练集的均方差值为  $7.9594 \times 10^{-12}$ ,神经网络具有较好的训练效果。




图 3 神经网络训练过程均方误差变化曲线图

### 4.2 神经网络诸元解算的仿真

针对发射任务给定所需的主动段终端高度  $h_f$ ,终端速度  $V_f$  和当地速度倾角  $\theta_f$ ,将其归一化后输入至完成训练的神经网络,得到逆归一化后的助推段弹道诸元,将其直接装订并进行弹道仿真,得到助推段弹道数据。

为了检验神经网络诸元解算方法的准确性和快速性,在诸元数据库的边界内随机生成 500 组终端高度、速度和速度倾角的测试数据,将其输入神经网络后解算每组相应的诸元,并进行弹道积分,对比仿真结果与测试数据即可得到终端状态误差。仿真计算结果如图 4 所示。

据图可知,主动段的终端速度误差绝对值在  $6 \times 10^{-4}$  m/s 内,终端高度误差绝对值在 0.3 m 内,终端速度倾角误差绝对值在  $(4 \times 10^{-5})^\circ$  内。利用神经网络计算诸元具有很高的精度。

仿真的试验环境为 Windows 11 操作系统,内存空间为 8 GB,处理器为 Intel (R) Core (TM) i5-8265U CPU @ 1.60 GHz 1.80 GHz。采用 tic 函数和 toc 函数,获取 500 组样本诸元解算的运行总时

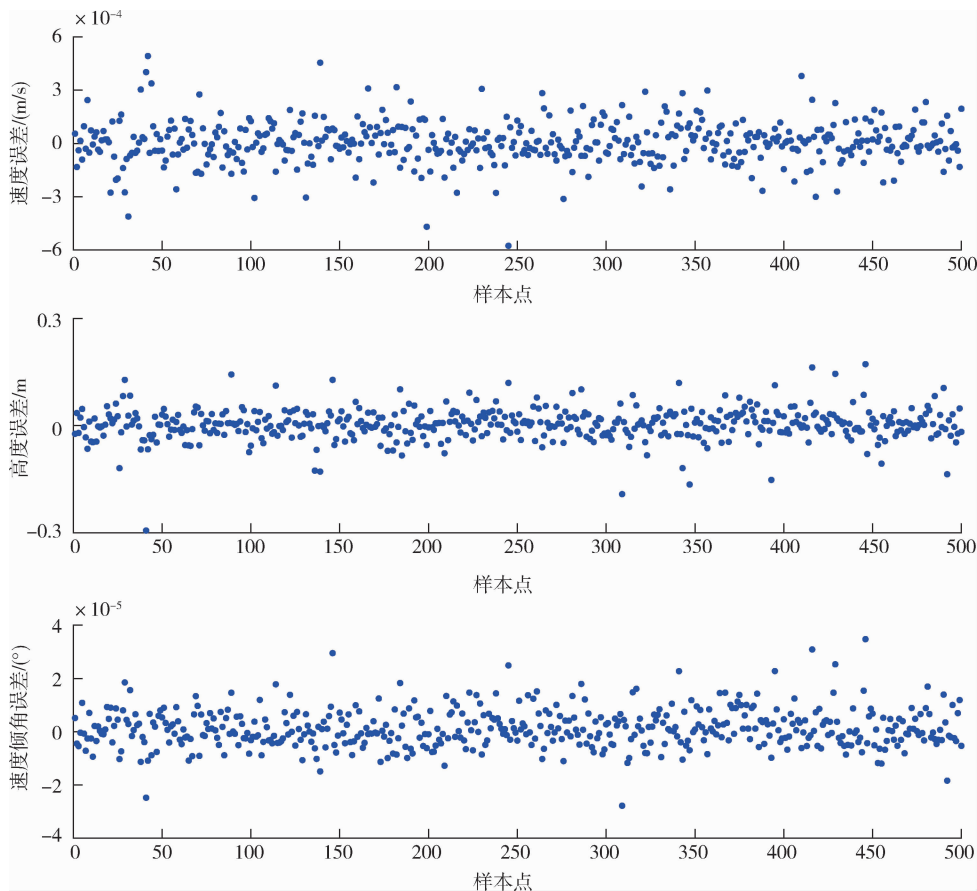


图 4 神经网络解算诸元的仿真结果

间,求平均后得到平均求解时间。利用牛顿迭代法、解析拟合法和神经网络方法求解诸元的结果对比如表 3 所示,其中解析法采用二次多项式进行最小二乘拟合。

表 3 三种弹道诸元解算方法的对比

解算参数	牛顿迭代法	解析拟合法	神经网络
平均求解时间/s	5.3504	$1.316 \times 10^{-5}$	$7.842 \times 10^{-4}$
速度误差/( $m \cdot s^{-1}$ )	$3.559 \times 10^{-5}$	4.2250	$6.247 \times 10^{-4}$
高度误差/m	0.01303	2534.91	0.2935
速度倾角误差/( $^{\circ}$ )	$1.792 \times 10^{-6}$	0.3045	$3.476 \times 10^{-5}$

由表 3 可知,与解析法相比,神经网络方法的计算时间稍长,但解算精度提升很大;与牛顿迭代法相比,基于神经网络的诸元解算方法虽然精度略低,但相对于目标状态量级方法的误差很小。两种方法均可以达到理想的精度。神经网络方法的诸元求解速度很快,能在保证精度的前提下大大缩短发射前诸元准备时间,在快速发射的需求下具有充分的工程应用价值。

## 5 结 论

针对助推段的弹道快速规划问题,提出了基于神经网络的弹道诸元解算方法,通过研究得到以下结论:

1) 针对不同发射任务的需求,利用神经网络诸元解算方法,可以快速求解高精度弹道诸元,相较于传统方法可大大缩短计算时间,对提高导弹的生存能力具有重要意义;

2) 基于贝叶斯正则化理论确定神经网络结构,所得的网络结构能达到较好的训练效果,利用此种方法可避免进行长时间的大量试验;

3) 本文采用的诸元均为飞行程序角,在未来的工作中,可以确定发射任务的发射点和落点位置,将发射方位角作为诸元参数之一,利用本文的方法进行进一步研究。

## 参 考 文 献

[ 1 ] 安占新,任慧敏,许传明,等. 一种用于飞行诸元定

- 义、表示的领域专用语言[J]. 航天控制, 2020, 38(5):50-53. (AN Zhanxin, REN Huimin, XU Chuanning, et al. A domain-specific language for flight parameters definition and representation [J]. Aerospace Control, 2020, 38(5): 50-53.)
- [ 2 ] 赵强, 汤祁忠, 韩珺礼, 等. 基于代理模型的制导火箭炮发射诸元计算方法[J]. 北京航空航天大学学报. 2019, 45(3):508-519. (ZHAO Qiang, TANG Qizhong, HAN Junli, et al. Method for calculating firing data of guided rocket launcher based on surrogate model [J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(3): 508-519.)
- [ 3 ] YU W, YANG J, CHEN W. Entry guidance based on analytical trajectory solutions [J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 58(3): 2438-2466.
- [ 4 ] 钱山. 弹道导弹变点机动射击诸元快速计算方法研究[D]. 长沙: 国防科学技术大学, 2006. (QIAN Shan. The research of efficient method for firing data calculation of ballistic missiles in mobile condition [D]. Changsha: School of National University of Defense Technology, 2006.)
- [ 5 ] 韦文书, 荆武兴, 高长生. 机动发射的弹道导弹飞行诸元的快速计算[J]. 哈尔滨工业大学学报, 2012, 44(11):7-12. (WEI Wenshu, JING Wuxing, GAO Changsheng. A rapid method for flight program design of the ballistic missile launched on mobile platform [J]. Journal of Harbin Institute of Technology, 2012, 44(11): 7-12.)
- [ 6 ] 何睿智, 刘鲁华, 汤国建, 等. 机动发射条件下助推滑翔导弹射击诸元快速解算[J]. 国防科技大学学报, 2017, 39(4):56-61. (HE Ruizhi, LIU Luhua, TANG Guojian, et al. Efficient method for firing data calculation of boost-glide missile in mobile condition [J]. Journal of National University of Defense Technology, 2017, 39(4): 56-61.)
- [ 7 ] 王海丽, 陈磊, 胡小平. 弹道导弹基本诸元的快速装订算法研究[J]. 国防科技大学学报, 1999, 21(2): 8-11. (WANG Haili, CHEN Lei, HU Xiaoping. The research on efficient method for computing basic firing data of ballistic missiles [J]. Journal of National University of Defense Technology, 1999, 21(2): 8-11.)
- [ 8 ] 黄祺威, 邓泽晓, 刘鲁华. 基于数据库的助推滑翔导弹助推段弹道诸元快速解算方法[J]. 飞行力学, 2023, 41(1):71-76. (HUANG Qiwei, DENG Zexiao, LIU Luhua. Efficient calculation method for firing data in boost phase of boost-glide missile based on database [J]. Flight Dynamics, 2023, 41(1): 71-76.)
- [ 9 ] LUI D G, TARTAGLIONE G, CONTI F, et al. Long short-term memory-based neural networks for missile maneuvers trajectories prediction [J]. IEEE Access, 2023(11): 30819-30831.
- [ 10 ] HUANG X, ZHAO H D. Projectile impact point prediction method based on GRNN [J]. Journal of Measurement Science and Instrumentation, 2016, 7(1): 7-12.
- [ 11 ] 刘哲. 助推滑翔飞行器集群协同规划与制导技术研究[D]. 长沙: 国防科技大学, 2020. (LIU Zhe. Research on cooperative planning and guidance technique for boost-glide vehicle cluster [D]. Changsha: School of National University of Defense Technology, 2020.)
- [ 12 ] 高兴. 再入滑翔飞行器快速轨迹优化及制导方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2018. (GAO Xing. Research on rapid trajectory optimization and guidance for entry gliding vehicle [D]. Harbin: Harbin Institute of Technology, 2018.)
- [ 13 ] 陈克俊, 刘鲁华, 孟云鹤. 远程火箭飞行动力学与制导[M]. 北京: 国防工业出版社, 2014:226-243.
- [ 14 ] 史步海, 朱学峰. LMBP神经网络改进算法的研究[J]. 控制工程. 2008, 86(2):164-167. (SHI Buhai, ZHU Xuefeng. On improved algorithm of LMBP neural networks [J]. Control Engineering of China, 2008, 86(2): 164-167.)
- [ 15 ] FORESEE F D, HAGAN M T. Gauss-Newton approximation to Bayesian learning [C]// Proceedings of international conference on neural networks (ICNN'97). IEEE, 1997, 3: 1930-1935.