

文章编号 1004-924X(2019)02-0410-11

滑翔导弹末段多约束智能弹道规划

邵会兵, 崔乃刚, 韦常柱*

(哈尔滨工业大学 航天学院, 黑龙江 哈尔滨 150006)

摘要:滑翔导弹末段飞行时空复杂度高、不确定性强、约束多,给弹道规划与制导算法带来了较大的建模和求解难度。针对这一问题,同时增大末段机动范围并提高弹道规划效率,本文提出一种利用连续型深度置信神经网络(Convolutional Deep Belief Networks, CDBN)预测机动能力、设计经由点状态实现末段多约束智能弹道规划的方法。过程中采用 CDBN 对机动能力进行在线预测,快速判定经由点状态的可行性,并且通过经由点状态智能设计,实现前后段能量的优化分配,扩大弹道机动包络;通过设计三角函数型弹目视线角实现末段弹道摆动机动,推导机动弹道最优末制导律对视线角进行跟踪,并调节机动频率以满足速度约束。仿真结果表明,CDBN 相对 BP 网络具有更高的机动能力预测精度;本文所提智能弹道规划方法在满足末端速度约束的前提下,可以实现弹道摆动机动并大幅增加飞行包络。弹道规划能够在 0.5 s 内完成,满足工程应用的快速性要求。

关键词:滑翔导弹;机动能力预测;连续型深度置信网络;机动弹道规划

中图分类号:V448.2 **文献标识码:**A **doi:**10.3788/OPE.20192702.410

Multi-constrained intelligent trajectory planning for gliding missiles

SHAO Hui-bing, CUI Nai-gang, WEI Chang-zhu*

(School of Astronautics, Harbin Institute of Technology, Harbin 150006, China)

* Corresponding author, E-mail:weichangzhu@hit.edu.cn

Abstract: The terminal flight of the gliding missile involves high complexity, strong uncertainty, and many constraints. It is difficult to model and solve the corresponding trajectory planning and guidance problems. To increase the maneuvering range of the gliding missile and reduce the difficulty of trajectory planning, a multi-constrained trajectory intelligent planning method was proposed. This method included waypoint design and maneuverability prediction using the Continuous Deep Belief Network (CDBN). The CDBN was used to predict the maneuvering ability online, and the feasibility of the waypoint's state was determined rapidly. With the intelligent design of the waypoints, optimized allocation of energy was realized, which increases the flight envelope. To realize oscillatory maneuvering, the Line of Sight (LOS) relative to the target was designed as a trigonometric function, which was tracked by designing the optimal maneuvering guidance law. Finally, the desired velocity constraint was satisfied by adjusting the frequency of the LOS angle. The simulation results show that the CDBN has higher maneuverability prediction accuracy than the BP network. The proposed method

收稿日期:2018-08-09;**修订日期:**2018-09-13.

基金项目:国家自然科学基金资助项目(No. 61403100);中央高校基本科研业务费专项资金资助(No. HIT. NSRIF. 2015. 037);微小航天器技术国防重点实验室开放基金资助项目(No. HIT. KLOF. MST. 201704);哈尔滨市科技创新人才专项基金资助项目(No. 2015RQQXJ089)

can realize oscillatory maneuvering and achieve a large increase in the flight envelope while satisfying the terminal velocity constraint. Online trajectory planning based on the CDBN can be completed in half a second, which satisfies the rapidity requirements for engineering applications.

Key words: gliding missile; maneuverability prediction; continuous deep belief network; maneuvering trajectory planning

1 引言

滑翔导弹是一种区别于传统弹道导弹、可在临近空间长时间高速滑翔、机动飞行的新型武器装备^[1],具有飞行速度快、飞行高度高、飞行环境复杂的特点。为了满足现代化战争中实际作战需要,滑翔导弹需要具有对威胁区和拦截网进行规避、对拦截弹和探测网有效突防、为满足制导或侦察需求经由特定区域以及对目标进行高精度打击等能力。复杂的飞行环境、多变的战场态势、多类型的任务要求使滑翔导弹任务规划及弹道规划的时空复杂度急剧增加,亟需在相关技术中获得突破。

滑翔导弹末段打击任务对弹道末端倾角、速度等多种约束具有严苛的要求。同时,飞行过程中的绕飞探测任务需要导弹在满足速度、过载、姿态、终点状态等多约束前提下增加飞行通道、扩大机动区域、增加机动形式^[2]。因此,需要开展末段多约束弹道规划和制导方法研究。

然而,滑翔导弹末段飞行的高时空复杂度、强不确定性和多约束的特点使相应的弹道规划与制导问题也具有了类似的特征,既难以精确建模,又难以快速精确求解,需要研究行之有效的解决方案。近年来,人工智能基础理论获得了突破发展,人工智能以其强大的学习能力与适应性在自动控制、航空航天等领域表现出突出的优势与应用前景。其中,基于深度学习神经网络的智能方法在解决各领域中具有复杂、不确定、多约束等特点的问题上获得了巨大成功。深度学习神经网络可通过大量样本的训练来逼近实际问题的真实模型,然后根据新的输入迅速给出对应的结果。因此,本文将结合深度学习神经网络,一方面解决滑翔导弹末段规划与制导中部分环节的复杂系统建模问题,一方面满足在线弹道规划与制导的快速性要求。

深度学习和传统的人工神经网络不同,在采用监督学习进行网络训练前,引入了梯度向上的非监督学习,利用无标记的训练样本逐层训练参

数,通过对输入数据信息的充分利用有效地解决了上述问题,深度学习的深层非线性网络结构通过训练大量的样本数据学习有用的特征,逼近复杂的非线性函数。目前较为公认的深度学习基本模型包括卷积神经网络^[3]、基于自动编码器的堆叠自动编码器^[4]和基于限制玻尔兹曼机(Restricted Boltzmann Machine, RBM)的深度置信网络(Deep Belief Network, DBN)^[5]。DBN不仅在图像、语音、金融预测、模式识别等领域表现出较好的特征提取及学习能力,而且在多因素影响的特征提取及回归预测问题中也得到越来越多的应用研究,如储层预测^[6]、用户投诉预测^[7]、油井热采收率预测^[8]、工业软测量建模^[9]、疾病风险预警^[10]等问题。

在智能弹道规划方面,魏黎明等人^[11]利用BP神经网络设计了吸气式高超声速导弹突防弹道,在导弹工作动压窗口、攻角窗口的条件下,通过大量离线仿真数据训练BP神经网络以拟合得出导弹初始机动高度、马赫数、质量与机动时间之间的非线性映射关系,从而实现了通过机动初始条件预测机动时间。方科等人^[12]基于BP神经网络设计了高超声速再入飞行器时间可控再入制导律,通过离线仿真获得时间预估BP网络训练集,并采用贝叶斯正则化算法进行离线训练,从而实现了对剩余再入飞行时间的预估。相关研究主要集中于采用智能优化算法进行轨迹优化设计,以及采用大量离线数据训练神经网络以实现弹道规划过程中相关参数的在线快速预测两个方面。

为了增大滑翔导弹的末段机动范围并降低弹道规划难度,本文提出一种利用经由点设计实现末段多约束智能弹道规划的方法。通过智能规划经由点状态,扩大导弹机动包络,同时保证有足够的能量实现对目标的多约束精确打击。经由点的智能设计中,将采用深度置信神经网络建立机动能力预测模型,快速判定经由点状态的可行性,实现经由点前、后段能量的合理分配,提高经由点在线设计的效率。

为满足弹道摆动机动需求,本文将导弹相对目标点的视线角设计为三角函数形式,并通过设计机动弹道最优末制导律,实现对期望视线角的跟踪,最后通过调节视线角的机动频率满足期望的速度约束。

2 基于 CDBN 的末段机动能力预测

2.1 机动能力预测流程

结合任务需求,弹头在滑翔末段需要判断从当前状态是否能够到达给定终端状态,为经由点或机动指令的设计提供基础。滑翔末段机动能力可通过比较导弹当前位置能量状态与限定终端状态后反向推算出的当前位置所需最小能量状态进行衡量。其中当前位置所需最小能量状态是指,弹头从当前位置按当前速度方向,以最省能量弹道到达给定终端位置时,恰好满足终端速度大小及方向约束,所对应的初始能量状态。由于无动力导弹质量恒定,故能量状态可用速度来表示。

因此,对导弹机动能力的预测可以通过建立相应的神经网络模型来进行。即选取关键的状态变量作为神经网络的输入,预测的能量状态作为输出。通过优化设计获得样本库,利用样本库对神经网络进行离线训练,通过神经网络模型实现对机动能力的在线预测。机动能力预测流程图如图 1 所示。

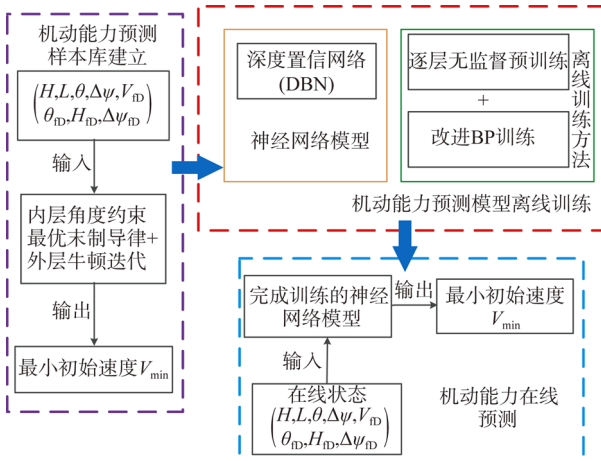


图 1 机动能力预测流程图

Fig. 1 Flowchart of maneuverability prediction

假定地球模型为均质非旋圆球,则滑翔末段机动能力主要受当前点的状态、终点状态以及当前点与终点的相对状态的影响。输入变量包括当

前点状态中的速度倾角 θ 、高度 H 、终点状态中的末端速度 V_{fD} 、末端落角 θ_{fD} 、末端高度 H_{fD} 、当前点与终点相对状态中的航向角偏差 $\Delta\psi$ 、水平距离 L 、末端航向角偏差 $\Delta\psi_{fD}$ 。

输出变量为当前位置、当前速度方向下,保证飞行终点满足给定终端状态的当前最小速度 V_{\min} 。

样本生成中,内层采用角度约束最优末制导律获得满足末端约束的能量最优弹道,外层采用牛顿迭代法获得满足末端约束的最小初始速度。

预测模型采用连续型深度置信神经网络。

2.2 机动能力预测样本库构建

对每一个包含当前状态、终端状态和相对状态的输入 $X = (H, L, \theta, \Delta\psi, V_{fD}, \theta_{fD}, \Delta\psi_{fD}, H_{fD})$,采取牛顿迭代的方法,可得到满足末端约束的最小初始速度 V_{\min} ,步骤如下:

(1)取当前时刻速度大小初值为 V_0 ,基于角度约束最优末制导律^[13]:

$$\dot{\gamma}_D = 4\dot{\lambda}_D + \frac{2}{T_g}(\lambda_D - \theta_{fD}), \quad (1)$$

其中: γ_D 为弹道倾角, $T_g = -r/\dot{r}$ 为剩余飞行时间, λ_D 为高低视线角。

从当前位置积分到终端状态,得到末速 $V_{f\max}$,得到 $f(V_0) = (V_{f\max} - V_{fD})^2$ 。

(2)通过牛顿迭代法搜索速度 V_{0f}

$$x_{k+1} = x_k - \left. \left\{ \frac{\partial f(x)}{\partial x} \right|_{x=x_k} \right\}^{-1} f(x_k), \quad (2)$$

直至式(3)成立:

$$|V_{f\max} - V_{fD}| < \epsilon, \quad (3)$$

最终得到的 V_{0f} 即为满足末端约束的最小初始速度 V_{\min} 。

给定多组输入,通过上述计算可获得相应的 V_{\min} 作为机动能力预测输出变量,构成机动能力预测样本库。

2.3 深度置信网络及其训练

深度置信网络(DBN)是典型的深度学习算法,于2006年由Hinton研究组在《Science》上提出,其通过无监督贪婪学习算法逐层优化深度置信网络的连接权重和阈值。深度置信网络实际上借鉴了人脑的多层抽象的机能,通过大量的限制玻尔兹曼机单元(可看作神经元)构成深度置信网,利用输入和输出的非线性关系,近似复杂的多输入函数,它在提取输入样本的特征时具有较好的性能。

通常DBN网络中RBM单元可视层的输入必须为二值状态,由于机动能力预测问题中输入

数据为连续型数值,因此直接利用传统二值 DBN 网络来进行预测会存在问题。为解决这一问题,本文通过在网络的 RBM 单元可视层中加入高斯噪声附加项使其转变成连续型 RBM(Continuous RBM, CRBM),使得网络具有对连续型特征值的处理能力。

深度置信网络是一个概率生成模型,拥有深层的网络结构,可以看作由多个 CRBM 堆叠而成,最底层接收输入数据向量,并通过 CRBM 转换输入数据到隐含层,通过对多个 CRBM 进行堆叠可从机动能力预测问题的复杂原始输入数据中获得一些高层非线性特征,在最顶层添加一层 BP 网络,即可对输出量即最小初始速度,进行回归预测。深度置信网络的训练由无监督的逐层预训练和有监督的微调两个过程组成。下面给出用于机动能力预测的深度置信网络结构和训练过程。

对应于机动能力预测的完整深度置信网络结构如图 2 所示,深度置信网络模型由最底层接收机动能力预测问题的输入数据 $(H, L, \theta, \Delta\psi, V_{JD}, \theta_{JD}, \Delta\psi_{JD}, H_{JD})$,第一层和第二层形成一个 CRBM,第二层和第三层形成第二个 CRBM,依次类推。将最上层 CRBM 的输出层得到的结果,即提取得到的高层非线性特征,输入到 BP 网络中进行回归预测。输入层的节点数由输入数据的维数决定,输出层为归一化后的最小初始速度,节点数为 1。

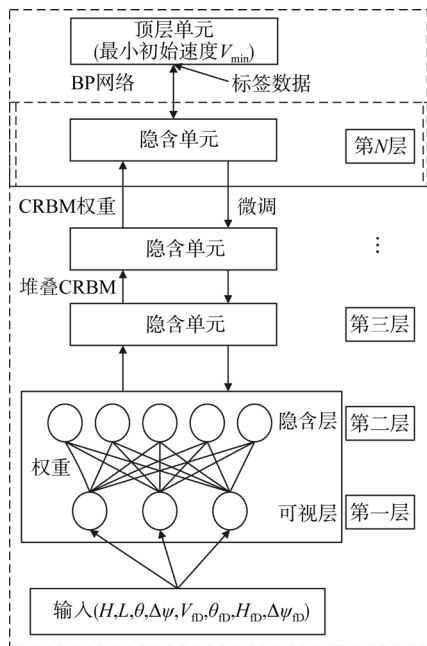


图 2 深度置信网络的结构图

Fig. 2 Diagram of deep belief network structure

限制玻尔兹曼机 CRBM 模型基于能量生成,能够学习数据的固有内在表示。每个 CRBM 包含一个可视层和一个隐含层,只有可视层和隐含层单元之间有双向连接权值,而可视层内部各单元及隐含层内部各单元之间没有连接。

传统 RBM 的结构单元为二值状态,为了处理连续数据,CRBM 在可视层 sigmoid 激活函数 $\text{sig}(x) = 1/(1 + e^{-x})$ 中加入一个均值为 0、方差为 σ^2 的高斯单元,常数 σ 和 $N_j(0, 1)$ 共同产生了高斯输入分量 $n_j = \sigma N_j(0, 1)$ 。

隐含层的激活概率为:

$$p(h_j = 1/v) = \varphi_j \left(\sum_{i=1}^I v_i w_{ji} + \sigma N_j(0, 1) \right), \quad (4)$$

其中,函数 φ_j 的表达式为:

$$\varphi_j(x_j) = \theta_L + (\theta_H - \theta_L) \frac{1}{1 + \exp(-b_j x_j)}. \quad (5)$$

同理,可视层的激活概率为:

$$p(v_i = 1/h) = \varphi_i \left(\sum_{j=1}^J h_j w_{ji} + \sigma N_i(0, 1) \right), \quad (6)$$

$$\varphi_i(x_i) = \theta_L + (\theta_H - \theta_L) \frac{1}{1 + \exp(-a_i x_i)}, \quad (7)$$

其中: I 为可视单元的数量, J 为隐含单元的数量。 θ_L, θ_H 分别为 sigmoid 函数的下渐近线和上渐近线,一般取 $\theta_H = 1, \theta_L = -1$,参数 b_j 是控制 sigmoid 函数斜率的变量,当 b_j 由小变大时,单元就可以从无噪声的确定性状态向二进制随机状态平滑过渡。

在给定可视层单元 $\mathbf{v} = \{v_1, v_2, v_3, \dots, v_I\} \in [0, 1]$ 、隐含层单元 $\mathbf{h} = \{h_1, h_2, h_3, \dots, h_J\} \in [0, 1]$ 、权重矩阵 \mathbf{w} 、可视层单元的斜率 a 和隐含层单元斜率 b 的条件下,所有可视单元和隐含层单元联合状态 (\mathbf{v}, \mathbf{h}) 的能量函数为^[14]:

$$E(\mathbf{v}, \mathbf{h}) = - \sum_{j=1}^J \sum_{i=1}^I w_{ji} v_i h_j + \sum_{j=1}^J \frac{1}{b_j} \int_0^{h_j} \varphi^{-1}(s) ds. \quad (8)$$

可视层向量 \mathbf{v} 的独立分布为:

$$p(\mathbf{v}) = \sum_{\mathbf{h}} p(\mathbf{v}, \mathbf{h}) = \frac{\sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})}}{\sum_{\mathbf{v}} \sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})}}. \quad (9)$$

因为 CRBM 的同一层任何两个单元之间没有连接,因此给定一个随机输入的可视层向量 \mathbf{v} ,各隐含层单元相互独立,隐含层向量 \mathbf{h} 的概率如式(10)所示。类似的,给定一个随机输入隐含层

向量 \mathbf{h} , 得到对应可视层向量 \mathbf{v} 的概率如式(11)所示:

$$p(\mathbf{h}/\mathbf{v}) = \prod_j p(\mathbf{h}_j = 1/\mathbf{v}), \quad (10)$$

$$p(\mathbf{v}/\mathbf{h}) = \prod_i p(\mathbf{v}_i = 1/\mathbf{h}). \quad (11)$$

CRBM 的本质就是使学习到的模型符合输入样本分布的概率最大, 即在给定训练数据的情况下, 通过调节相应的参数, 使式(9)的概率 $p(\mathbf{v})$ 的值达到最大。由式(9)可知, 可以通过调节权重矩阵 \mathbf{w} 、可视层单元斜率 a 和隐含层单元斜率 b 去降低能量函数值, 间接提高 $p(\mathbf{v})$ 的值。基于极大似然估计理论, 对式(9)两边取对数, 然后执行随机梯度下降, 可以从训练样本中学习 CRBM 模型的参数 $\theta = \{a_i, b_j, w_{ji}\}$, 使概率 $p(\mathbf{v})$ 的值最大。

以对比散度(Contrastive Divergence, CD-k)算法应用最为广泛^[14]。通过使用对比散度算法, k 次更新即可完成训练, 一般取为 1, 参数更新公式如式(12):

$$\begin{aligned} \Delta w_{ji} &= \gamma(\langle \mathbf{v}_i \mathbf{h}_j \rangle_0 - \langle \mathbf{v}_i \mathbf{h}_j \rangle_k), \\ \Delta b_j &= \frac{\gamma}{b_j^2}(\langle \mathbf{h}_j^2 \rangle_0 - \langle \mathbf{h}_j^2 \rangle_k), \\ \Delta a_i &= \frac{\gamma}{a_i^2}(\langle \mathbf{v}_i^2 \rangle_0 - \langle \mathbf{v}_i^2 \rangle_k), \end{aligned} \quad (12)$$

其中 γ 表示学习率, 取值在 $[0, 1]$ 之间, 一般根据经验确定。

在逐层无监督训练完成后, 通过在最顶层添加标签数据, 对深度置信网络进行有监督训练, 即采用反向传播算法对深度置信网络的相关参数进行微调。与无监督训练中每次训练一层相比, 反向传播有监督微调同时对所有层的参数进行更新, 以进一步减少训练误差和提高深度置信网络的预测精度。

全局有监督微调利用网络输出误差对各权值的梯度来调整所有权值, 直至误差收敛。在模型的微调过程中, 有两类参数需要调整: 层之间的连接权值、斜率控制项。先求出连接权值、斜率控制项的梯度值^[15], 再利用拟牛顿法优化算法对各参数进行优化。

样本的目标函数值为:

$$J(\mathbf{W}, \mathbf{a}; \mathbf{x}) = \frac{1}{2} \|\mathbf{x} - \mathbf{F}_{\mathbf{W}, \mathbf{a}}(\mathbf{x})\|^2, \quad (13)$$

其中: \mathbf{x} 是 CRBM 的样本输出数据, $\mathbf{F}_{\mathbf{W}, \mathbf{a}}(\mathbf{x})$ 是网络的输出数据。

3 飞行末段多约束智能弹道规划

为了增大滑翔导弹的末段机动范围并降低弹道规划难度, 本文通过智能规划经由点, 实现末段多约束智能弹道规划。

导弹通过智能规划末段经由点状态, 可以扩大机动包络, 同时保证有足够的能量实现对目标的多约束精确打击。在经由点的智能规划过程中, 采用上节中训练好的深度置信网络进行机动能力预测, 快速判定经由点状态的可行性, 实现经由点前、后段能量的合理分配, 提高经由点在线设计的效率。经由点位置的设计, 需要为后段增强突防能力的弹道摆动机动预留一定的速度增量, 因此在迭代搜索经由点位置时, 在期望终端速度的基础上增大一定速度增量作为经由点位置迭代的速度约束。

为满足弹道摆动机动需求, 本文将导弹相对目标点的视线角设计为三角函数形式, 并通过设计机动弹道最优末制导律, 实现对期望视线角的跟踪, 最后通过机动频率迭代满足期望的速度约束。

3.1 经由点规划

经由点规划采用内外两层规划的方法: 内层固定经由点的位置, 通过搜索最优的经由点速度方向约束, 使到达目标点的终端速度最大; 外层基于经由点 Z 向位置与终端速度的单调关系, 以期望终端速度为约束, 通过牛顿法迭代得到经由点 Z 向位置。经由点规划流程见图 3 所示。

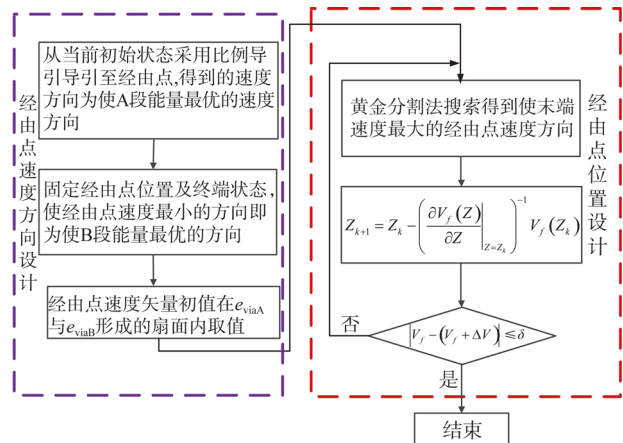


图 3 经由点规划流程图

Fig. 3 Flow diagram of waypoint planning

(1) 经由点的位置设计。将以下压段起始点作为始点、目标点作为终点、采用角度约束最优制导律获得的弹道,作为基准弹道。

为降低规划难度,取基准弹道上射程中点对应的点作为经由点包络的中心。导弹从经由点到达目标点时末端速度恰好满足给定约束时对应的经由点位置,即为最大机动能力对应的经由点位置。

经由点在该点弹道法平面上的不同坐标,对应着不同的机动范围,因此将经由点位置对应的设计量取为 Z 向坐标。

(2) 对于经由点处的速度方向,可根据起始点及终端状态给出其可行的范围,并以此为基础进行经由点速度方向设计。

如图 4 所示,设从当前点到经由点为 A 段,从经由点到终端状态为 B 段。导弹按比例导引律从当前点导引至经由点,到达经由点时的速度矢量方向可视为使 A 段能量最优的经由点速度方向 e_{viaA} ;固定经由点位置及终端状态,使经由点速度最小的速度方向即为使 B 段能量最优的经由点速度方向 e_{viaB} 。经由点速度矢量 e 在 e_{viaA} 与 e_{viaB} 形成的扇面内取值,可留出更多能量用于机动。

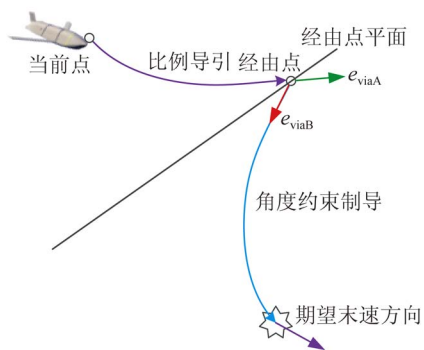


图 4 经由点速度方向设计示意图

Fig. 4 Diagram of waypoint velocity direction designing

(3) 在固定经由点位置时,随着经由点速度方向约束的变化,末端速度呈现先增大后减小的单峰曲线形式,采用黄金分割法即可一维搜索求得在当前经由点位置下使末端速度最大的最优速度方向约束:

$$J = -V_{fmax}. \quad (14)$$

过程中基于当前位置和速度方向状态和经由点的位置及速度方向约束计算 $X = (H, L, \theta, \Delta\psi, V_{fD}, \theta_{fD}, \Delta\psi_{fD}, H_{fD})$,将其输入训练好的深度置信网络,得到在当前位置、当前速度方向下,保证飞行终点满足给定终端状态的当前最小速度

V_{min} 。进而判定经由点状态的可行性。

通过牛顿迭代法更新经由点位置,并搜索相应的最优航向角。由于经由点位置与末端速度存在单调关系,可搜索得到满足期望速度约束的经由点位置。

$$Z_{k+1} = Z_k - \left\{ \frac{\partial V_f(Z)}{\partial Z} \Big|_{Z=Z_k} \right\}^{-1} V_f(Z_k). \quad (15)$$

由于经由点位置的设计,需要为后段的弹道摆动机动预留一定的速度增量,因此在迭代搜索经由点位置时,在期望终端速度的基础上增加一定速度增量作为经由点位置迭代的速度约束。

$$V_{Df} = V_f + \Delta V, \quad (16)$$

其中 ΔV 为弹道摆动机动所需的速度增量。

3.2 三角函数型机动弹道规划

对于从经由点到目标点的飞行段,本文引入三角函数型机动,即在期望角度上叠加三角函数型视线角函数。机动弹道规划流程如图 5 所示。

(1) 视线角函数幅值根据局部机动范围需求而确定,一般取 1° 左右即可满足。在局部机动范围较小时,将机动形式由单边改为双边并进行相位调整,以满足机动范围及机动形式要求。

(2) 通过机动弹道最优制导律得到制导指令,积分得到到达目标点时的终端速度。

(3) 针对末端速度约束,根据机动频率与末端速度的正比关系,通过在线大步长弹道快速积分,对视线角函数的机动频率进行迭代修正,得到满足末端速度约束的机动频率,完成弹道规划。

(4) 在实际飞行中,由于大气密度偏差等因素,实际弹道状态量(主要是速度)相对规划弹道会存在一定偏差,因此每隔一定周期需要进行一次弹道重规划。

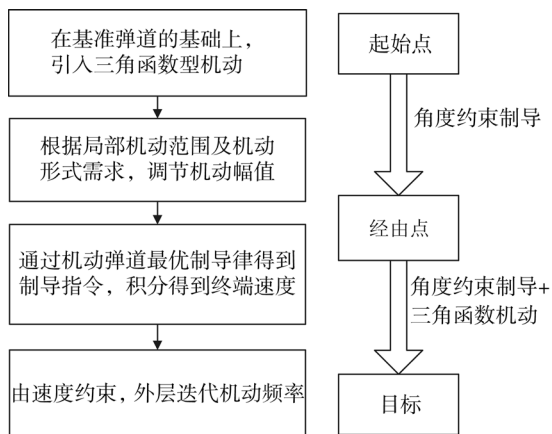


图 5 机动弹道规划流程图

Fig. 5 Flow diagram of maneuvering trajectory planning

3.3 机动弹道最优制导律设计

对于局部机动范围需求,将导弹相对目标点的视线角设计为三角函数形式,通过调节三角函数型视线角的幅值、频率和相位,满足期望的机动形式和局部机动范围,并通过最优控制实现对期望视线角的跟踪,最终实现末制导与机动的一体化设计。

以第二段角度约束末制导与三角函数型机动的一体化设计为例,分别在俯冲平面和侧向平面内进行设计。

为实现在精确攻击前提下的机动飞行,设计以射程为自变量的俯冲平面附加视线角为:

$$\lambda_{DN} = \begin{cases} \varphi_{DN} \sin \left[k_D \frac{L}{L_f} \pi \right], & h \geq h_{me} \\ 0, & h < h_{me} \end{cases}, \quad (17)$$

其中: k_D 为频率系数, φ_{DN} 为幅值系数, L_f 为末段总射程, L 为当前射程。考虑防空系统的最低拦截高度,同时减小机动对制导精度的影响,设置机动结束高度 h_{me} 。

在俯冲平面内,为了在满足落角约束的同时使视线角按照期望的运动规律变化,可取状态变量分别为视线角偏差以及视线角速率偏差:

$$\begin{cases} x_1 = \lambda_D + \gamma_{DF} - \lambda_{DN} \\ x_2 = \dot{\lambda}_D - \dot{\lambda}_{DN} \end{cases}, \quad (18)$$

其中: γ_{DF} 为终端期望落角, λ_{DN} 为期望视线角, λ_D 为高低视线角。

为了简化制导问题,将俯冲段运动分解到俯冲平面及侧向平面内,分别建立相对运动方程:

$$\begin{cases} \ddot{\lambda}_D = \left[\frac{\dot{v}}{v} - \frac{2\dot{r}}{r} \right] \dot{\lambda}_D - \frac{\dot{r}}{r} \dot{\gamma}_D \\ \ddot{\lambda}_{DT} = \left[\frac{\dot{v}}{v} - \frac{2\dot{r}}{r} \right] \dot{\lambda}_{DT} + \frac{\dot{r}}{r} \dot{\gamma}_T \end{cases}, \quad (19)$$

其中: γ_D 为弹道倾角, γ_T 为弹道偏角。

转化为状态空间方程的形式:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & \frac{2}{T_g} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{1}{T_g} \end{bmatrix} (\dot{\gamma}_D + 2\dot{\lambda}_{DN} - T_g \ddot{\lambda}_{DN}), \quad (20)$$

其中 $T_g = -r/\dot{r}$ 为剩余飞行时间。

为简化制导问题的建模及求解,可引入伪控制量:

$$u_s = \dot{\gamma}_D + 2\dot{\lambda}_{DN} - T_g \ddot{\lambda}_{DN}. \quad (21)$$

状态空间方程可进一步改写为:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & \frac{2}{T_g} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{1}{T_g} \end{bmatrix} u_s. \quad (22)$$

根据最优控制理论极大值原理,线性系统二次型性能指标对应的最优控制律形式为:

$$u_s = -\mathbf{R}^{-1} \mathbf{B}^T \mathbf{P} \mathbf{x}. \quad (23)$$

基于最优控制理论及 Riccati 方程,得俯冲平面机动突防最优制导律:

$$\begin{aligned} \dot{\gamma}_D &= -4(\dot{\lambda}_D - \dot{\lambda}_{DN}) - 2\dot{\lambda}_{DN} + T_g \ddot{\lambda}_{DN} - \\ &\frac{2}{T_g} (\lambda_D + \gamma_{DF} - \lambda_{DN}). \end{aligned} \quad (24)$$

在侧向平面内,同样以射程为自变量设计附加视线角为:

$$\lambda_{DT} = \varphi_{DT} \sin \left[k_T \frac{L}{L_f} \pi \right], \quad (25)$$

其中: k_T 为频率系数, φ_{DT} 为幅值系数。

假设对飞行器进入方向没有约束,则在侧向平面取状态变量为:

$$x_3 = \dot{\lambda}_{TT} - \dot{\lambda}_{DT}. \quad (26)$$

同理,以能量最省为性能指标,可获得侧向平面机动最优制导律为:

$$\dot{\gamma}_D = 3(\dot{\lambda}_D - \dot{\lambda}_{DN}) \cos \lambda_D + 2\dot{\lambda}_{DT} - T_g \ddot{\lambda}_{DT}. \quad (27)$$

4 仿真分析

采用美军 CAV 滑翔弹头的总体及气动参数,取俯冲段高度 $h_0 = 30$ km,距目标点射程 $L_0 = 100$ km,速度 $V_0 = 2\ 500$ m/s,速度倾角 $\theta_0 = -10^\circ$,航迹偏航角 $\sigma_0 = 0^\circ$,攻角 $\alpha \in [-20^\circ, 20^\circ]$,落角约束 $\lambda_{DF} = -60^\circ$,末端速度约束 $V_f \geq 800$ m/s。落点位置精度要求 $\Delta x \leq 1$ m,落角精度要求 $\Delta \lambda \leq 1^\circ$,速度精度要求 $\Delta V \leq 2$ m/s。 $\varphi_{DN} = \varphi_{DT} = 1^\circ$, $k_D = k_T$,机动结束高度 $h_{me} = 2$ km。

机动能力预测的样本容量取为 30 000,其中 27 000 个作为训练样本,3 000 个作为测试样本。依据随机运行的平均结果选择最优的参数配置,本文使用平均相对误差 (Mean Relative Error, MRE) 作为评价指标,通过下式计算得到:

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%, \quad (28)$$

其中: y_i 为真实值, \hat{y}_i 为预测值, n 为样本数据量。

深度置信网络模型的结构参数,影响训练过程和预测结果误差。根据已有研究以及数据特

点,CDBN 的学习率取为 $\gamma=0.02$,CRBM 最大迭代次数取为 200。为了使训练效果达到最优化,减小误差,对预测模型训练的隐层层数和隐层节点数进行对比优选。本文取隐层数目为 2~6 层,设定隐层节点数为 24,对隐层数目进行优选,结果如表 1 所示。

表 1 隐层数目的影响

Tab.1 Effect of number of hidden layers

隐层数目	MRE/%
2	5.8
3	4.6
4	5.7
5	7.0
6	7.9

表中比较了隐层数目对预测误差的影响,当隐层数目为 3 时,MRE 值为 4.6%,预测模型准确度最高。隐层数目小于 3 时,模型误差随隐层数目增加而减小;隐层数目大于 3 时,模型误差随隐层数目增大而增大,模型凸显“过拟合”效应。

对于隐含层神经元个数的选取尚无理论上的指导,没有统一的经验公式。假定隐层数目为 3,讨论和确定适宜的节点数目。本文讨论最后一层隐含层节点数目为 4~20 时的预测效果。

表 2 最后一层隐含层节点数目的影响

Tab.2 Effect of nodes number in the last hidden layer

节点数目	MRE/%
4	4.7
8	3.5
12	2.6
16	3.8
20	4.6

由表 2 可知,节点数为 12 时,模型预测效果最佳。综上,本文设定预测模型的隐层数目为 3,各隐层的节点数为 24-24-12。最终确定 CDBN 的网络结构为 8-24-24-12-1。

将设计好的 CDBN 与 BP 网络进行对比,考虑多层 BP 网络存在梯度消失问题,取 BP 网络结构为 8-80-80-1,对 3 000 个测试样本进行预测,对比散点图与拟合误差散点图分别如图 6 与图 7 所示。从图 7 可以看出,相对于 BP 网络,CDBN 明显具有更小的训练误差。

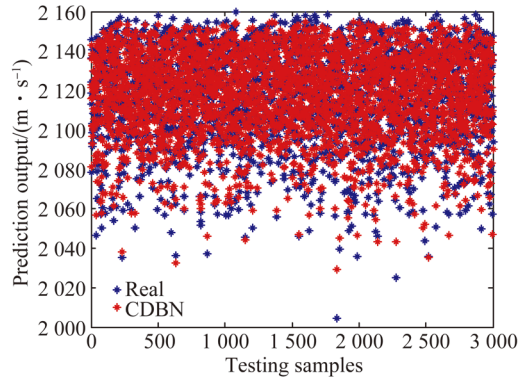


图 6 CDBN 的预测结果散点图

Fig.6 Scatter diagram of CDBN prediction results




图 7 CDBN 与 BP 的测试误差散点图

Fig.7 Scatter diagram of test results for CDBN and BP

由图 8 可以看出,CDBN 网络的初始误差得到减小,误差的下降速度也快于 BP 网络。这是由于 CDBN 通过对三层 CRBM 的贪婪无监督预训练,获得了更好的神经网络权值。

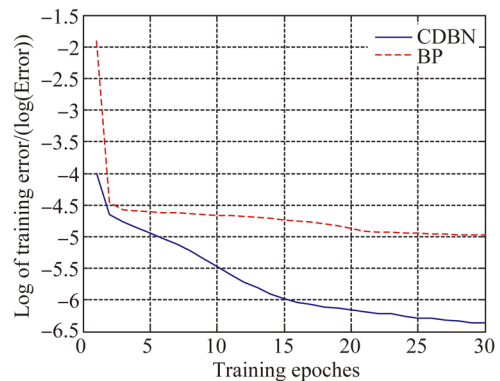


图 8 CDBN 与 BP 的训练残差对数曲线

Fig.8 Logarithm of training error results for CDBN and BP

接下来进行经由点规划,并进一步规划末段机动弹道。首先将经由点位置的 Z 向坐标初值取为 $Z=5$ km,不同的经由点速度方向对应着不同的末端速度,一般随着航向角的增大,末端速度呈现先增大后减小的趋势,由此可以得到在该经由点位置下的最优速度方向。

表 3 航向角对末端速度的影响

Tab.3 Effect of heading angle on terminal velocity

航向角/(°)	速度/($m \cdot s^{-1}$)
-8	1 198
-10	1 215
-11	1 206
-12.5	1 156
-15	860

经过黄金分割法搜索,当前经由点位置 $Z=5$ km 下的最优航向角为 -10° 。进一步,根据牛顿迭代法更新经由点位置,并搜索相应的最优航向角。为了给弹道机动预留速度增量,在期望终端速度的基础上增大 100 m/s 作为经由点位置设计的速度约束,通过牛顿迭代搜索得到满足该速度约束的经由点位置。

终端速度随经由点 Z 向位置的变化曲线如图 9 所示。经过迭代搜索,经由点的最大侧向位置为 $Z=5.36$ km,对应的最优航向角约束为 -12° 。




图 9 终端速度随经由点 Z 向位置的变化

Fig.9 Terminal velocity versus Z position of waypoint

对于期望的末端速度约束,根据机动频率与末端速度的单调性,迭代搜索得到三角函数型视线角的机动频率系数 $k_D=4.02$ 。终端速度随机动频率的变化曲线如图 10 所示。




图 10 终端速度随机动频率系数的变化

Fig.10 Terminal velocity versus maneuvering frequency coefficient

末段规划弹道如图 11~图 15 所示。




图 11 攻角随时间的变化曲线

Fig.11 Time histories of attack angle




图 12 倾侧角随时间的变化曲线

Fig.12 Time histories of bank angle

由俯冲段弹道参数曲线,落点位置误差为 0.2 m,落角误差为 0.4° ,速度误差为 0.5 m/s,机动弹道规划耗时 0.5 s。表明本文所提的弹道规划方法在实现摆动机动飞行的同时,能够高精度地满足终端落点、落角及速度约束条件。




图 13 三维弹道曲线

Fig. 13 Three-dimensional trajectory curve




图 14 速度曲线

Fig. 14 Time histories of velocity




图 15 弹道倾角曲线

Fig. 15 Time histories of flight path angle

5 结 论

本文针对滑翔导弹末段多约束智能弹道规划问题展开研究,取得了如下研究成果:

针对连续数值型机动能力预测问题,提出了一种离线训练 CDBN 用于在线预测的方法。仿真表明基于 CDBN 的机动能力预测相对于 BP 网络具有更高精度,且具有较高的效率。通过智能规划经由点的 Z 向位置与航向角,优化了末段能量分配,在保证对目标多约束精确打击的同时增大了末段机动范围。针对增强突防能力的弹道摆动机动,引入了三角函数形式的弹目视线角,设计了机动弹道最优末制导律,实现了对期望视线角的跟踪,最后通过调节机动频率实现了速度控制。落点位置、落角、速度误差分别为 0.2 m, 0.4° , 0.5 m/s。弹道规划最大耗时为 0.5 s,能够满足工程应用的快速性要求。

参考文献:

- [1] 李瑜,崔乃刚,郭继锋.助推-滑翔导弹发展概况及关键技术分析 [J]. 战术导弹技术, 2008, 1(5): 13-19.
LI Y, CUI N G, GUO J F. Development and key technology analysis of boost-glide missile [J]. *Tactical Missile Technology*, 2008, 1(5): 13-19. (in Chinese)
- [2] CHUANG C H, MORIMOTO H. Optimal periodic cruise for a hypersonic vehicle with constraints[R]. AIAA-96-3876, 1996: 1-11.
- [3] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]. *International Conference on Neural Information Processing Systems*. Curran Associates Inc. 2012: 1097-1105.
- [4] BENGIO Y. Learning deep architectures for AI [J]. *Foundations and Trends in Machine Learning*, 2009, 2(1): 1-127.
- [5] GEOFFREY E H, SIMON O, THE Y W. A fast learning algorithm for Deep Belief Nets [J]. *Neural computation*, 2006, 18(7): 1527-1554.
- [6] 徐旺林, 庞雄奇, 高仁安. 储层测井特征属性反演方法 [J]. 天然气工业, 2005, 25(3): 52-54.
XU W L, PANG X Q, GAO R A. Inversion methods of log character attribute of reservoir [J]. *Nature. GAS IND*, 2005, 25(3): 52-54. (in Chinese)

- [7] 周文杰, 严建峰, 杨璐. 基于深度学习的用户投诉预测模型研究 [J]. 计算机应用研究, 2017, 34(5):1428-1432.
ZHOU W J, YAN J F, YANG L. Research on prediction model of complaint based on deep learning [J]. *Application Research of Computers*, 2017, 34(5):1428-1432. (in Chinese)
- [8] 董华松. 油井地热开发的数值模拟与回归预测研究 [D]. 北京: 中国地质大学, 2014.
DONG H S. *Numerical Simulation and Regression Prediction for Geothermal Wells Development* [D]. Beijing: China University of Geosciences, 2014. (in Chinese)
- [9] 刘瑞兰, 毛佳敏. 基于深度置信网络的 4-CBA 软测量建模 [J]. 计算机工程与应用, 2017, 53(6):227-230.
LIU R L, MAO J M. Soft sensor modeling of 4-CBA based on deep belief networks [J]. *Computer Engineering and Applications*, 2017, 53(6):227-230. (in Chinese)
- [10] 杨星. 基于深度置信网络的脑血管病风险预警研究 [D]. 北京: 北京交通大学, 2016.
YANG X. *Study of Early Warning for Cerebrovascular Risk Based on Deep Beliefs Networks* [D]. Beijing: Beijing Jiaotong University, 2016. (in Chinese)
- [11] 魏黎明, 李晓龙, 赵征, 等. 神经网络在吸气式高超声速导弹突防弹道设计上的应用 [J]. 空天防御, 2018, 1(2):14-17.
WEI L M, LI X L, ZHAO ZH, et al.. Application of neural network in penetration of air-breathing hypersonic missile [J]. *Air& Space Defense*, 2018, 1(2):14-17. (in Chinese)
- [12] 方科, 张庆振, 倪昆, 等. 高超声速飞行器时间协同再入制导 [J]. 航空学报, 2018, 39(5):202-217.
FANG K, ZHANG Q ZH, NI K, et al.. Time-coordination reentry guidance law for hypersonic vehicle [J]. *Acta Aeronautica et Astronautica Sinica*, 2018, 39(5):202-217. (in Chinese)
- [13] 陈克俊, 赵汉元. 一种适用于攻击地面固定目标的最优再入机动制导律 [J]. 宇航学报, 1994, 15(1):1-7.
CHEN K J, ZHAO H Y. An optimal reentry maneuver guidance law applying to attack the ground fixed target [J]. *Journal of Astronautics*, 1994, 15(1):1-7. (in Chinese)
- [14] CHENH, MURRAY A F. A continuous Restricted Boltzmann Machine with a hardware-amenable learning algorithm [C]. *International Conference on Artificial Neural Networks*. Springer-Verlag, 2002:358-363.
- [15] THEODORIDISS, KOUTROUMBAS K. 模式识别 (第四版) [M]. 李晶皎, 王爱侠, 王骄, 译. 北京: 电子工业出版社, 2010.
THEODORIDISS, KOUTROUMBAS K. *Pattern Recognition (4th edition)* [M]. LI J J, WANG A X, WANG J, translation. Beijing: electronics industry press, 2010. (in Chinese)

作者简介:



邵会兵(1977—),男,江西南城人,研究员,博士生,1998年于哈尔滨工程大学获得学士学位,2005年于航天科工二院研究生院导航制导与控制专业获得硕士学位,主要从事智能弹道规划与制导方面的研究。E-mail: shaohuibingshb@163.com

通讯作者:



韦常柱(1982—),男,黑龙江佳木斯人,博士,副教授,2004年、2010年于哈尔滨工业大学分别获得学士、博士学位,主要从事飞行器制导与控制研究。E-mail: weichangzhu@hit.edu.cn

导师简介:



崔乃刚(1965—),男,辽宁沈阳人,教授,博士生导师,1986年于国防科技大学获得学士学位,1989年、1996年于哈尔滨工业大学分别获得硕士、博士学位,主要从事导弹飞行力学与控制、组合导航及自主导航技术、惯导系统对准技术、导弹攻防对抗仿真、滤波理论及应用等。E-mail: naigang_cui@126.com

(本栏目编辑:秦 思)