

基于卷积神经网络的无人作战飞机飞行轨迹实时预测

张宏鹏¹, 黄长强¹, 唐上钦¹, 轩永波²

(1. 空军工程大学 航空工程学院, 陕西 西安 710038; 2. 空军研究院, 北京 100085)

摘要: 飞行轨迹预测是空战技术的一部分, 预测方结合轨迹预测结果可以选择出更有预见性的机动。为快速、准确地获得无人作战飞机在未来时刻的位置, 提出了基于卷积神经网络的飞行轨迹预测方法。原始动力学模型不能正确仿真滚转角有偏差的筋斗机动, 采取限制角速度的方式对该模型进行改进; 使用改进后的模型在不同条件下进行飞行仿真, 得到大量轨迹样本; 训练并测试具有不同层数和卷积核数的网络, 从中找出预测误差最小的网络; 对比卷积神经网络与长短时记忆网络、循环神经网络、全连接网络的运算速度和误差, 结果表明: 卷积神经网络预测方法在没有增加运算用时情况下, 0.25 s 后的平均预测误差在 x 轴方向约为 4.2 m, y 轴方向约为 8.0 m, z 轴方向约为 19.5 m, 且误差均小于其他 3 种方法。

关键词: 无人作战飞机; 飞行轨迹预测; 卷积神经网络; 循环神经网络; 动力学模型; 飞行仿真

中图分类号: E844 文献标志码: A 文章编号: 1000-1093(2020)09-1894-10

DOI: 10.3969/j.issn.1000-1093.2020.09.022

CNN-based Real-time Prediction Method of Flight Trajectory of Unmanned Combat Aerial Vehicle

ZHANG Hongpeng¹, HUANG Changqiang¹, TANG Shangqin¹, XUAN Yongbo²

(1. Aeronautics Engineering College, Air Force Engineering University, Xi'an 710038, Shaanxi, China;

2. Air Force Research Institute, Beijing 100085, China)

Abstract: Trajectory prediction is part of air combat technology, and the predictors can select a more predictable maneuvering consideration of trajectory prediction results. A convolution neural network predicting method is proposed to obtain the position of unmanned combat aerial vehicle in a future time quickly and accurately. An improved model for limiting the angular velocity is presented since the original dynamic model can not correctly simulate the somersault maneuvering with roll angle deviation. The improved model is used for flight simulation under different conditions, and a large number of trajectory samples are obtained. The convolution neural networks with different layer number and convolution kernel number is trained and tested, and the network with the smallest prediction error is selected. Operational speed and error of the proposed method are compared with those of long short term memory neural network, recurrent neural network and fully connected neural network. The results show that the average prediction error of the proposed method is about 4.2 m on x axis, 8.0 m on y axis and 19.5 m on z axis after 0.25 s without increasing operational time, and the errors are all smaller than those of the other

收稿日期: 2019-11-20

基金项目: 国家自然科学基金项目(51579209)

作者简介: 张宏鹏(1996—), 男, 硕士研究生。E-mail: 1152951370@qq.com

通信作者: 黄长强(1961—), 男, 教授, 博士生导师。E-mail: hcqxian@163.com

methods.

Keywords: unmanned combat aerial vehicle; flight trajectory prediction; convolutional neural network; recurrent neural network; dynamics model; flight simulation

0 引言

自主空战的关键技术主要有4个方面:目标跟踪技术、威胁评估技术、目标轨迹预测技术和机动决策技术。其中,机动决策技术是指通过机动作改变空战双方相对位置,从而获得有利的攻击位置或逃离敌机攻击范围,是自主空战的核心技术。

目前,大多数机动决策方法^[1-4]主要根据空战双方当前状态选择有利的机动。例如,根据对方当前坐标计算出相对角度、相对距离和高度差(这些计算量统称为状态),根据这些状态构建态势函数,从动作库中找出使态势函数值最大的动作。另一种更先进的机动决策方法建立在准确预测对方轨迹的基础上,首先预测出对方的轨迹,即对方在未来时刻可能的位置,然后根据预测结果选择有利机动,由此保证所选择的机动具有一定的预见性。另一方面,近距空战的双方轨迹变化较为剧烈,具有明显的对抗性,要求准确预测较短时间内的敌机飞行轨迹。

文献[5]提出基于Elman网络的轨迹预测方法,对一段一对一空战轨迹每隔0.25 s采样一次,并从中取前5个连续时刻的位置为网络输入,第6个时刻的位置为输出,训练了轨迹预测网络。文献[6]在文献[5]基础上使用混合变异粒子群优化(HPSO)算法优化预测网络的初始权值,减小了网络训练时间和预测误差。文献[7]先自适应聚类目标飞行轨迹,再使用反向传播(BP)神经网络方法预测目标轨迹,但BP网络结构自身的局限性导致预测结果误差较大。文献[8]从贝叶斯估计角度研究轨迹预测问题,并在动力学模型中考虑气象和随机风场的影响,利用粒子滤波法求出贝叶斯估计问题的数值解。文献[9]使用容积卡尔曼滤波方法进行目标机轨迹预测。文献[10]提出基于隐马尔科夫模型(HMM)的轨迹预测方法,在HMM基础上结合自适应参数选择,使预测算法能自动调整预测轨迹段的长度。文献[11]将递归最小二乘法与最优导引律相结合,用于预测目标在未来的位置并调整导弹状态,提高了导弹命中率。文献[12]提出结合动态测量理论与灰色系统理论的轨迹预测方法,利用参数向量的最小方差估计值代替真实值,并将其代入微分方程中,求出轨迹预测值。文献[13]提出使用长短时记忆(LSTM)神经网络方法预测多个目标的轨迹,采用池化层以达到共享相邻目

标信息的目的,结果表明该方法能减小预测多目标轨迹时的预测误差。文献[14]使用卷积神经网络(CNN)法预测不同数据集上行人的轨迹,结果表明CNN的预测误差始终小于LSTM的预测误差;在预测多个目标的轨迹时,CNN的效果优于生成式对抗网络(GAN),且CNN的预测用时始终最少。文献[15]为解决晶体特性的预测问题提出晶体图神经网络(CGCNN)的预测方法,利用CNN处理空间信息能力,根据晶体结构图进行预测,结果表明预测准确率较高。

当前,深度学习技术飞速发展,其中LSTM和CNN是深度学习的主要工具。上述研究中,基于LSTM和CNN的预测方法大多是对平面上的轨迹进行预测,对三维空间中的轨迹预测研究较少。为了提高近距空战中轨迹预测的准确率、减小预测用时并辅助机动决策,本文提出一种基于CNN的无人作战飞机轨迹预测方法。首先指出基于过载的动力学模型存在的问题,并提出改进方法。然后利用改进后的模型,在不同初始条件下采用不同机动作进行飞行仿真,得到由87 120条不同的机动轨迹坐标组成的集合,其中每条轨迹由空间中3个维度上的坐标组成。最后从轨迹集合中取出训练和测试样本。

本文的具体工作包括:设计并训练不同层数和卷积核个数的CNN,从中选出预测误差最小的CNN;设计并训练不同隐藏层神经元个数的LSTM网络,再比较各个网络的预测误差,从中选出预测误差最小的LSTM网络;在相同的训练集上对与LSTM结构相同的全连接神经网络(FCNN)以及传统循环神经网络(RNN)进行训练;比较以上4种不同网络的收敛情况,在测试集上的相对预测误差以及预测所需时间,通过坐标变换使轨迹预测网络能预测任意初始位置和航向的轨迹;对比4种方法在一段空战仿真轨迹上的预测结果及绝对误差。

1 改进飞行动力学模型

1.1 飞行动力学模型

在研究空战轨迹预测时,采用以法向过载、切向过载和滚转角为飞行操控量的飞机运动动力学模型。为简化问题复杂度,不考虑飞行过程中的迎角和侧滑角,将地面坐标系视为惯性坐标系,同时忽略

地球自转及公转的影响,并且不考虑地球曲率变化。具体公式^[16]如下:


$$\begin{cases} \dot{x} = v \cos \gamma \cos \psi, \\ \dot{y} = v \cos \gamma \sin \psi, \\ \dot{z} = v \sin \gamma, \\ \dot{v} = g(n_x - \sin \gamma), \\ \dot{\gamma} = \frac{g}{v}(n_z \cos \mu - \cos \gamma), \\ \dot{\psi} = \frac{g}{v \cos \gamma} n_z \sin \mu, \end{cases} \quad (1)$$

式中: v 、 γ 和 ψ 分别为飞行速度、航迹俯仰角和航迹偏航角; g 为重力加速度; μ 为滚转角; n_x 和 n_z 分别为飞机切向过载和法向过载; x 、 y 、 z 为飞机在惯性坐标系中的坐标。


1.2 动力学模型的问题及改进

由动力学模型中的偏航角速度计算公式可知,飞机的偏航角速度与其航迹俯仰角的余弦值呈反比。飞机在爬升、向斜上方机动或做筋斗机动时,其航迹俯仰角会逐渐逼近 90° ,在此过程中偏航角速度也会逐渐增大。偏航角速度代表飞机在水平面内改变方向的能力,但仿真中随着航迹倾角的增大,偏航角速度会超过合理的范围,实际中无法实现。分别用 4° 和 0° 的滚转角进行一个筋斗机动的仿真,得到轨迹曲线以及相应的偏航角变化曲线如图1所示。

理想情况下筋斗机动的滚转角为 0° ,该轨迹应该是一个在竖直平面中的二维曲线。由偏航角速度计算公式可知,此时偏航角速度为 $0^\circ/\text{s}$,因此对筋斗机动的仿真未出现异常,从图1(a)中也可看出此时轨迹是一个二维曲线。在实际情况中,筋斗机动开始时滚转角可能会有一个微小的偏差,因此将滚转角设为 4° 。此时偏航角速度不断增大,导致偏航角出现不合理的改变,故无法获得正确的筋斗仿真轨迹。从图1(a)中可以看出,轨迹已经变成1条空间中的三维曲线,且偏航角最大可达 150° ,此时的轨迹明显不符合筋斗机动的特点。原因是仿真过程中航迹俯仰角越接近 90° ,其余弦值越接近0,而余弦值又在分母位置,因此偏航角速度急剧增大,从而导致偏航角增大。上述问题可通过对偏航角速度加以限制来解决,即为其设置一个阈值,超过该值后角速度不再增大。本文选择飞机在初始速度为 250 m/s 、初始滚转角为 0° 时,向左上方以最大过载爬升6 s内的最大偏航角速度 ψ_{\max} 为阈值。偏航角的计算公式如下:



(a) 原始模型仿真轨迹
(a) Simulated trajectory of original model



(b) 偏航角变化
(b) Change of yaw angle

图1 原始模型

Fig. 1 Original model

$$\psi = \begin{cases} \frac{g}{v \cos \gamma} n_z \sin \mu, & |\psi| < \psi_{\max}; \\ \psi_{\max}, & |\psi| \geq \psi_{\max}. \end{cases} \quad (2)$$

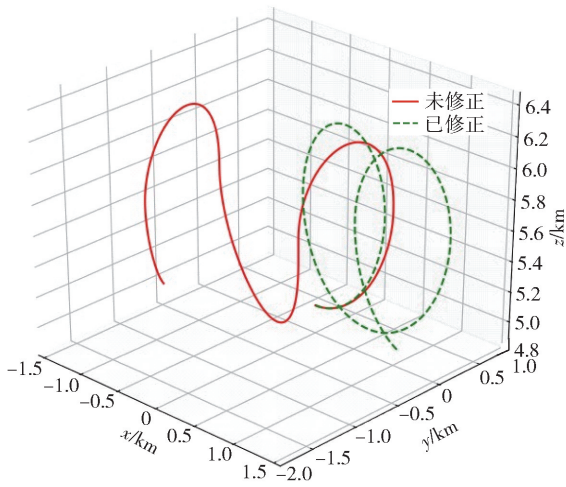
利用改进后的模型对滚转角有 4° 偏差的筋斗机动飞行轨迹进行仿真,原模型与改进模型的对比结果如图2所示。

由图2可知,改进模型能完成滚转角存在微小偏差的筋斗机动,且偏航角始终处于一个合理的范围内,符合筋斗机动的特点。目前大多数空战研究文献都采用该模型,但没有明确指出偏航角速度的阈值。如果不对偏航角速度加以限制,则轨迹就会出现失真,并且俯仰角越大,轨迹失真越严重。


2 CNN 轨迹预测模型

2.1 CNN 简介

CNN 是指那些至少在网络某一层使用卷积运算来代替一般矩阵乘法运算的神经网络^[17]。对CNN的研究起源于神经科学实验,远早于相关计算模型的发展。1962年Hubel等^[18]通过生物学研究



(a) 不同模型仿真轨迹
(a) Simulated trajectories of different models



(b) 偏航角变化
(b) Change of yaw angle

图 2 不同模型对比

Fig. 2 Comparison of different models

表明,从视网膜传递到大脑中的视觉信息是通过多层次的感受野激发完成的,并首先提出感受野的概念,其也被看作是卷积核的雏形。

传统的神经网络主要依靠矩阵乘法运算,对每个输入量、中间量和输出量都赋予单独的权重,因此大大增加了网络的参数量。CNN 采用卷积核作为参数共享的方式,卷积核的每一个元素都作用在输入的每个位置上,在减少网络所需要的存储空间和训练时间的同时,提高了模型的运算能力。卷积核也与大脑视觉皮层不同位置只对局部区域有响应的特点相对应。同时,CNN 适合处理具有网格结构的数据,一维网格数据如时间序列,二维网格数据如图像。

CNN 处理时间序列的优势在于:轨迹数据本质上是连续的,不存在滤波方法中所用到的复杂状态,而 CNN 本身就是一种端到端的方法,没有复杂的状态概念,可以直接根据历史轨迹输出未来轨迹,符合轨迹数据的本质;CNN 的连接权重是稀疏的,因此既能减少存储空间又能减小计算量,从而保证轨迹

预测的实时性;CNN 具有参数共享的特点,由此可以保证 CNN 在处理时间序列时具有一定的记忆性。

2.2 CNN 轨迹预测

2.2.1 轨迹预测模型

由于空战双方都想快速完成攻击占位,近距离空战轨迹在三维空间中的起伏通常较大,且轨迹变化的频率较高,很少出现控制量基本不变的巡航飞行状态。另一方面,历史轨迹所处的时刻距当前时刻越远则其对未来时刻的轨迹影响越小,轨迹预测时输入网络的历史数据越多并不一定能保证更高的预测准确率。因此,参考文献[6]对轨迹采样间隔和网络输入的设置,本文取前 8 个时刻的轨迹坐标作为网络输入,采样间隔为 0.25 s,网络输出为下一时刻的轨迹坐标。具体方法是首先采集大量轨迹样本并设计不同的网络结构,利用轨迹样本训练不同结构的网络,从中选出预测精度最高的网络结构。再分别利用轨迹样本上 3 个坐标轴的分量,训练 3 个结构相同的网络,使其能根据对应坐标轴的历史数据预测轨迹下一时刻的坐标分量,最后将 3 个分量组合为目标下一时刻在空间中的位置。轨迹预测示意图如图 3 所示。




图 3 轨迹预测示意图

Fig. 3 Schematic diagram of trajectory prediction

2.2.2 训练集与测试集采样

近距离空战获胜主要通过各种机动动作占据有利位置并达到导弹发射条件,这些机动动作可以被概括为一大类,即转弯。因此,为提高轨迹预测网络的实用性和近距离空战轨迹预测准确率,本文不采用特定任务或背景下的轨迹数据作为训练样本,而是从空战机动动作出发,通过对各种初始条件下不同的机动动作采样,以构建大量训练样本,使其尽可能覆盖空战中可能出现的各种轨迹,再利用这些样本训练网络。若空战中的历史轨迹与训练样本中的轨迹

相似度较高,则此时轨迹预测的准确率较高。这种方法的优点是训练出的网络具有一定通用性,可以用于不同空战的轨迹预测。为尽可能覆盖空战中可能出现的机动动作,设置轨迹采样范围及间隔如表 1 所示。

表 1 采样范围及间隔

Tab.1 Sampling range and interval

采样量	采样范围	采样间隔
航迹俯仰角/(°)	(-50,50)	10
初始滚转角/(°)	(-100,100)	20
速度/(m·s ⁻¹)	(250,340)	10
目标滚转角/(°)	(-180,180)	5

表 1 显示了不同初始条件下飞机采用不同机动动作的组合。由表 1 可知,轨迹预测样本由 87 120 条轨迹组成,对数据进行归一化后,取其中 82 120 条轨迹作为训练集,剩余 5 000 条轨迹作为测试集,归一化公式如下:

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (3)$$

式中: x_n 为经过归一化的样本; x 为原始样本; x_{\max} 为所有轨迹中 x 轴坐标的最大值; x_{\min} 为最小值。 y 轴与 z 轴的归一化与上述方法相同。

3 设置实验方法

3.1 选择网络结构

神经网络的结构对预测准确率的影响较大,为提高预测准确率,首先要确定合适的网络结构。CNN 轨迹预测网络包括输入层、隐藏层和输出层,其中输入层和输出层已事先确定,确定网络结构就是要确定隐藏层的结构。隐藏层结构有 3 部分:隐藏层层数、每层的卷积核个数和卷积核的大小。由于输入层只有 8 个数据,将所有卷积核的大小都设置为 1×3 ,且每层卷积核个数相同。

一方面,不同的网络对应着轨迹预测问题的一个局部最优解,对于一定规模的神经网络而言,大部分局部最优解都有很小的代价函数,能否找到真正的全局最优解并不重要;另一方面,理论上神经网络结构有无限多种可能,把每种结构都尝试一遍的代价太大。因此设置卷积层数为 1、2、3、4、5、6 和每层卷积核个数为 4、5、6、7、8、9 的组合,训练这 36 种不同结构的网络,从中找出一个预测效果最好的。

3.2 设置对比方法

本文共选择 FCNN、RNN 和 LSTM 3 种不同方法

进行对比实验,其中 FCNN 预测法从拟合多元函数的角度解决轨迹预测问题,而 RNN 预测法与 LSTM 预测法则将轨迹预测视为对时间序列的预测。与 CNN 不同,3 种网络没有卷积核,因此只需确定网络层数和每层神经元个数。根据文献[19]可知:当有两个隐藏层的网络的两个隐藏层节点数相近时,网络训练效果最好。网络层数太多容易出现梯度消失或梯度爆炸,层数太少则会导致欠拟合。因此,本文设置 LSTM 为隐层节点数相同的双隐藏层结构,分别训练节点数为 18、20、22、24、26、28、30 的网络,从中找出轨迹预测准确率最高的节点数,将其作为 LSTM 的最终结构,FCNN 预测法与 RNN 预测法不再另外寻找新的结构,而是直接使用 LSTM 的最终结构。

3.2.1 FCNN 预测法

FCNN 结构示意图如图 4 所示。图 4 中: x 表示输入层,是若干个用向量形式表示的特征; s 表示隐藏层的输出,隐藏层可以有多个神经元,该层神经元的个数即为 s 的维度; o 为神经网络的输出,具体个数依据问题的需要选定; U 为输入特征 x 与隐藏层全连接的权值矩阵; V 为隐藏层与输出层全连接的权值矩阵。




图 4 FCNN 示意图

Fig.4 Schematic diagram of FCNN

FCNN 整个结构分为输入层、隐藏层和输出层。其中,FCNN 中数据在各层之间单向传递,输出量不会直接影响输入量。只要神经元个数充足,FCNN 能够以任意精度拟合任何一个从有限维空间到另一个有限维空间的 Borel 可测函数^[20]。因此,从这个角度看,若将轨迹预测视为一个从以输入量个数为维度的空间到一个一维空间的函数,则这个函数可用 FCNN 拟合。

3.2.2 RNN 预测法

与 FCNN 不同,RNN 中每层神经元的输入不仅有上一层神经元的输出,还有本层的输出,因此 RNN 具有一定的记忆能力。

轨迹预测问题也可以看作是处理有前后依赖性的时间序列问题,利用神经网络解决这类问题时,如果网络的输出能够结合前一时刻或后一时刻的输入,则比起单向传递信号的网络,其处理时序信息的能力更强。因此本文采用 RNN 及其变体 LSTM 作

为轨迹预测的对比方法。RNN 的基本结构如图 5 所示。




图 5 RNN 示意图

Fig. 5 Schematic diagram of RNN

图 5 中, W 为前一隐藏层的输出到本隐藏层输入的权值矩阵。RNN 与前馈网络最大的区别在于, 多了一个从上一次隐藏层的输出到这一次隐藏层输出的权值矩阵 W 。

3.2.3 LSTM 预测法

与其他神经网络同样,RNN 在训练过程中也会出现梯度消失和梯度爆炸问题,从而导致梯度在 BP 过程中不能在较长序列中传递下去,使得训练过程无法完成。梯度爆炸的解决办法与本文处理偏航角速度的办法相同,即设置一个梯度阈值,梯度超过该阈值后不再增加;梯度消失主要通过设计特殊的网络结构解决,如 LSTM。

传统 RNN 对短期输入很敏感,LSTM 在其中加入一个单元状态来记忆较长时间内的信息。这种基于单元状态的信息传递方式可有效克服传统 RNN 的缺点。LSTM 的详细结构如图 6 所示。图 6 中, σ 为 Sigmoid 函数, \tanh 为双曲正切函数, s_t 为当前时刻网络的输出, c_t 为当前时刻网络的单元状态, x_{t-1} 为上一时刻网络的输入, f_t 为当前时刻遗忘门, i_t 为当前时刻输入门, e_t 为当前时刻备选更新信息, o_t 为当前时刻输出门, W_f 为遗忘门的权值矩阵, W_i 为输入门的权值矩阵, W_e 为备选更新信息的权值矩阵, W_o 为输出门的权值矩阵。

由图 6 可知,LSTM 的输入由 3 部分组成:当前网络的输入 x_t 、上一时刻网络的输出 s_{t-1} 和上一时刻网络的单元状态 c_{t-1} , LSTM 的输出为当前网络的输出 s_t 和当前网络的状态 c_t 。LSTM 引入了 3 种门结构保护并记忆信息:遗忘门 f_t 、输入门 i_t 和输出门 o_t 。

遗忘门主要决定上一时刻的 s_{t-1} 和 c_{t-1} 是否继续存在于当前时刻的 c_t 中。遗忘门计算公式如下:

$$f_t = \sigma(W_f[s_{t-1}, x_t] + b_f), \quad (4)$$

式中: b_f 为遗忘门偏置量; $[s_{t-1}, x_t]$ 表示 2 个向量纵向连接; $\sigma(W_f[s_{t-1}, x_t] + b_f)$ 表示两个矩阵 W_f




图 6 LSTM 结构图

Fig. 6 Structure chart of LSTM

和 $[s_{t-1}, x_t]$ 相乘后加上偏置量,再用 Sigmoid 函数进行计算。

输入门主要决定当前时刻的输入 x_t 有多少要传到当前单元状态 c_t 中。输入门计算公式如下:

$$i_t = \sigma(W_i[s_{t-1}, x_t] + b_i), \quad (5)$$

式中: b_i 为输入门偏置量。输入门与输出门相结合,可以对单元状态 c_t 进行更新,公式如下:

$$e_t = \tanh(W_e[s_{t-1}, x_t] + b_e), \quad (6)$$

$$c_t = f_t * c_{t-1} + i_t * e_t, \quad (7)$$

式中: b_e 为备选更新信息偏置量; * 表示矩阵的哈达马积。

输出门主要决定单元状态 c_t 中有多少可以传到当前输出 s_t 中。输出门计算公式如下:

$$o_t = \sigma(W_o[s_{t-1}, x_t] + b_o), \quad (8)$$

$$s_t = o_t * \tanh(c_t), \quad (9)$$

式中: b_o 为输出门偏置量。

4 网络训练

4.1 确定网络结构

为了降低过拟合风险,加入 L2 正则化。选择 Adagrad^[21] 作为网络训练算法。损失函数设为样本的均方误差,激活函数设为 ReLU,学习率取 0.001,并用测试集上的预测相对误差作为评价网络的准确性的指标。单个预测结果相对误差计算公式如下:

$$e_r = \frac{|x_p - x_0|}{x_0}, \quad (10)$$

式中: x_0 为期望输出量; x_p 为网络的预测结果。相对误差越小,则网络预测准确率越高。不同结构网络在测试集上的平均相对误差如图 7 所示。

从图 7 中可以看出,随着层数增加,网络预测误差并没有一直减小,因为网络层数越多过拟合的风险越大,所以层数最多的网络预测误差,反而是最大

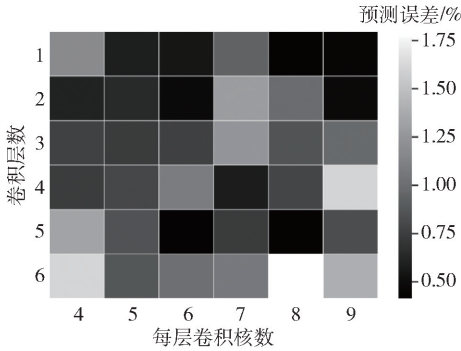


图 7 平均相对误差

Fig. 7 Average relative error

的。纵向来看,当每层卷积核数为 5 时,网络的预测误差变化较平稳,表明网络性能更稳定;当每层卷积核数为 6 时,网络的平均预测误差最小,因此每层卷积核数选为 6。横向来看,隐藏数为 1 和 2 的网络的平均预测误差更小,因此选择与对比方法相同的隐藏层数。

对双隐藏层的 LSTM,按照上述方法分别取节点数为 18、20、22、24、26、28、30 进行训练,并计算其在测试集上的平均预测误差,结果如图 8 所示。




图 8 预测准确率


Fig. 8 Prediction accuracy

从图 8 可知,LSTM 的预测准确率随着隐藏层神经元个数的增加先减小再增大,且在隐藏层有 28 个神经元时预测误差最小,因此选择隐藏层神经元个数为 28,且 FCNN、RNN 与 LSTM 的结构相同。


4.2 评估训练结果

分别用训练集中 3 个坐标轴的轨迹数据,其中验证集占训练集的 20%,训练 3 个具有从 4.1 节中所选结构的 CNN。训练过程中的损失变化如图 9 所示。


由图 9 中的损失变化可知,预测 x 轴的网络在训练到第 3 个回合时验证集和训练集损失几乎一样小,虽然之后验证集损失有所起伏但最终与训练集



(a) Change of loss of CNN on x axis



(b) Change of loss of CNN on y axis



(c) Change of loss of CNN on z axis

图 9 CNN 损失变化

Fig. 9 Change of loss of CNN

相差不大,因此网络已经收敛。预测 y 轴和 z 轴坐标的网络在训练到第 3 个回合时验证集上和训练集上的损失相差不大,且此后损失不再继续减小,说明网络已经收敛。用训练好的网络预测测试集中的轨迹,并计算相对预测误差,结果如图 10 所示。

从图 10 中可以看出,测试集中 x 轴的相对预测误差大部分小于 3%, y 轴和 z 轴的相对预测误差几乎全部小于 2%,表明 CNN 的轨迹预测能力较强。用上述方法训练 FCNN、RNN 和 LSTM,并求出所有测试样本的平均预测误差,再与 CNN 进行比较,结果如图 11 所示。

从图 11 可知,对 x 轴坐标的预测,LSTM 误差最小,RNN 和 CNN 误差比 LSTM 略大,FCNN 误差最大;对 y 轴坐标的预测,CNN 误差最小,LSTM 误差

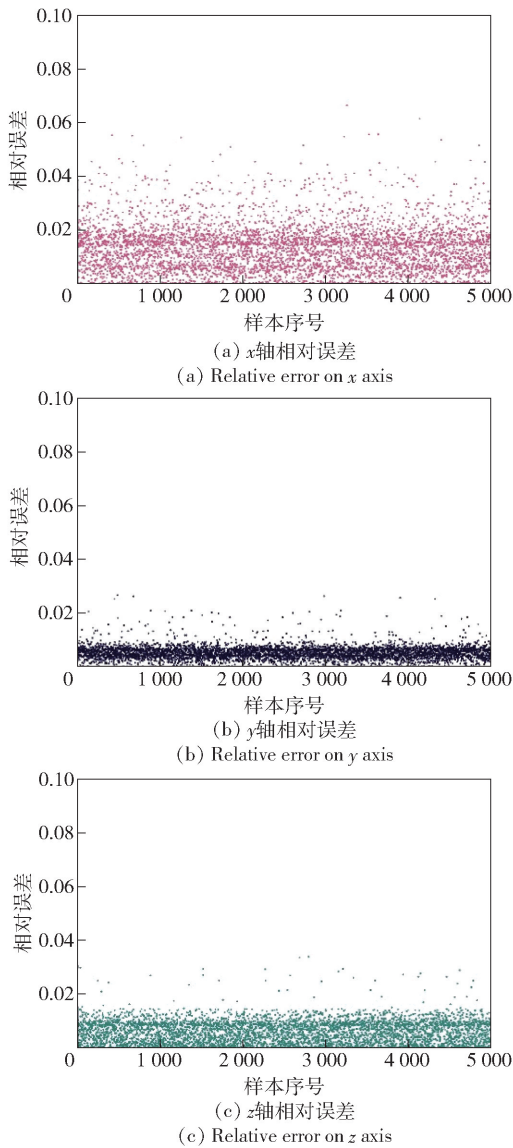


图10 CNN 预测相对误差

Fig. 10 Relative error of CNN prediction




图11 预测准确率

Fig. 11 Prediction accuracy

比 CNN 大,FCNN 误差比 LSTM 大,RNN 误差最大;对 z 轴坐标的预测,仍是 CNN 误差最小,LSTM 次之,RNN 和 FCNN 差距不大。以上 4 种方法预测

一次的平均用时如图 12 所示。从图 12 中可以看出,4 种方法的用时差别不大,约为 2.4 ms。对于 340 m/s 的飞机,2.4 ms 大约前进了 0.8 m,相对于预测出的轨迹可以忽略不计,因此本文所提方法满足实时性要求。

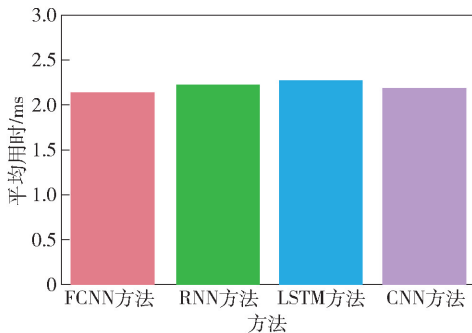


图12 预测用时

Fig. 12 Time cost of prediction


5 实时轨迹预测

4.2 节中的样本预测误差只是对网络的输出进行比较,但网络输出还要经过进一步处理才能转换为真实的轨迹坐标,因此本节比较不同方法的真实的输出轨迹及其误差。由于训练网络的样本初始时刻均位于原点,且偏航角为 0°,在预测空战仿真轨迹时需要先利用坐标变换,将飞机在地面坐标系下的坐标变换到采集样本时的坐标系中,然后进行预测,再将预测结果变换到地面坐标系。坐标变换公式如下:



$$\begin{bmatrix} x' \\ y' \\ z' \end{bmatrix} = \begin{bmatrix} \cos \psi & \sin \psi & 0 \\ -\sin \psi & \cos \psi & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix}, \quad (11)$$

式中: ψ 为网络第 1 个输入量对应的地面坐标系中的偏航角; (x',y',z') 为 (x,y,z) 的变换结果。变换后再将其平移至坐标原点并进行归一化后即可进行预测。图 13(a) 所示为一组空战追逃仿真轨迹,追击方初始位置为(6 000 m,3 000 m,8 000 m),航迹倾角为 0°,航迹偏角为 180°;逃跑方初始位置为(0 m,3 000 m,8 000 m),航迹倾角和偏角与追击方相同。逃跑方采用右上方最大过载转弯机动,追击方采用智能机动^[22]。图 13(a) 中逃方仅采用右转的机动,而追方采用文献[22]中的机动方法,机动轨迹的变化比较频繁,预测追方的轨迹更能体现不同方法之间的差距。用上述方法预测追击方在每个整数秒时的三维坐标,其轨迹在水平面和竖直面的投影以及用 4 种方法的预测结果如图 13(b)、图 13(c) 所示。

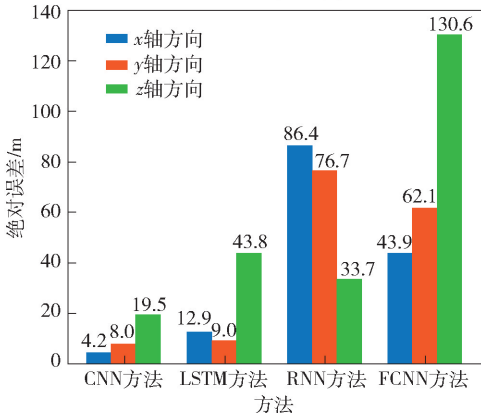
共预测该轨迹上的 8 个位置,每个位置的预测



(a) 空战仿真轨迹
(a) Trajectory of air combat simulation



(b) 轨迹预测结果
(b) Results of trajectory prediction



(c) 平均绝对误差
(c) Mean absolute error

图 13 轨迹预测

Fig. 13 Trajectory prediction

间隔为 1 s。从图 13(b)中可以看出,CNN 与 LSTM 的预测结果与原轨迹贴合得最紧密。RNN 的预测点距原轨迹较远,FCNN 的预测点距原轨迹最远。由图 13 可以看出,RNN 在 x 轴方向的预测值最大,而 FCNN 在 x 轴方向的预测值最小。求出 4 种方法在 3 个方向上的预测结果与真实点的平均距离差,结果如图 13(c)所示。

从图 13(c)中可以看出,CNN 在 3 个方向上的平均预测误差都是最小的;LSTM 在 x 轴和 y 轴方向上的预测误差较小,在 z 轴方向上的误差达到了 43.8 m;RNN 和 FCNN 在 3 个方向上的误差明显更大,说明这两种方法的轨迹预测能力有限。

6 结论

本文针对无人作战飞机空战轨迹预测问题,提出使用 CNN 的方法进行预测。得出主要结论如下:

1) 用飞行动力学模型对有微小滚转角偏差的筋斗机动进行仿真,结果表明原始模型不能正常完成筋头机动仿真;改进后模型的仿真结果表明所提的改进方法是有效的。

2) CNN 训练的损失变化曲线表明网络已收敛,CNN 在测试集上的相对预测误差表明所选取的 CNN 层数和卷积核个数是合理的,可以进行轨迹预测。

3) CNN 在 x 轴方向上平均预测误差约为 4.2 m,在 y 轴方向上平均预测误差约为 8.0 m,在 z 轴方向上平均预测误差约为 19.5 m,表明 CNN 的轨迹预测能力在 4 种方法中最好。

4) 目标机的机动控制量通常难以通过外部设备测量,本文所提轨迹预测法不需要知道目标机的机动控制量,可以直接根据目标机的历史位置预测未来位置。

5) 本方法的预测误差较小且用时较少,可以在空战中结合对目标机的轨迹预测进行机动决策,以提高机动决策的预见性。

为进一步减小 CNN 在 z 轴方向上的轨迹预测误差,可以为 z 轴预测设计不同的网络。

参考文献 (References)

- [1] HUANG C Q, DONG K S, HUANG H Q, et al. Autonomous air combat maneuver decision using Bayesian inference and moving horizon optimization[J]. Journal of Systems Engineering and Electronics, 2018, 29(1): 86-97.
- [2] 孙楚,赵辉,王渊,等.基于强化学习的无人机自主机动决策方

- 法[J]. 火力与指挥控制,2019,44(4):142-149.
- SUN C,ZHAO H,WANG Y,et al. UCAV autonomic maneuver decision-making method based on reinforcement learning[J]. Fire Control and Command Control,2019,44(4):142-149. (in Chinese)
- [3] 杜海文,崔明朗,韩统,等. 基于多目标优化与强化学习的空战机动决策[J]. 北京航空航天大学学报,2018,44(11):2247-2256.
- DU H W,CUI M L,HAN T,et al. Maneuvering decision in air combat based on multi-objective optimization and reinforcement learning[J]. Journal of Beijing University of Aeronautics and Astronautics,2018,44(11):2247-2256. (in Chinese)
- [4] 李世豪,丁勇,高振龙. 基于直觉模糊博弈的无人机空战机动决策[J]. 系统工程与电子技术,2019,41(5):1063-1070.
- LI S H,DING Y,GAO Z L. UAV air combat maneuvering decision based on intuitionistic fuzzy game theory[J]. Systems Engineering and Electronics,2019,41(5):1063-1070. (in Chinese)
- [5] 张涛,郭基联,徐西蒙,等. 基于 Elman 神经网络的战斗机空战轨迹预测[J]. 飞行力学,2018,36(5):86-91.
- ZHANG T,GUO J L,XU X M,et al. Air combat trajectory prediction of a fighter based on Elman neural network [J]. Flight Dynamics,2018,36(5):86-91. (in Chinese)
- [6] 王新,杨任农,左家亮,等. 基于 HPSO-TPFENN 的目标机轨迹预测[J]. 西北工业大学学报,2019,37(3):613-620.
- WANG X,YANG R N,ZUO J L,et al. Trajectory prediction of target aircraft based on HPSO-TPFENN neural network[J]. Journal of Northwestern Polytechnical University,2019,37(3):613-620. (in Chinese)
- [7] 钱夔,周颖,杨柳静,等. 基于 BP 神经网络的空中目标航迹预测模型[J]. 指挥信息系统与技术,2017,8(3):54-58.
- QIAN K,ZHOU Y,YANG L J,et al. Aircraft target track prediction model based on BP neural network[J]. Command Information System and Technology,2017,8(3):54-58. (in Chinese)
- [8] LYMPEROPOULOS I,LYGEROS J. Adaptive aircraft trajectory prediction using particle filters [C] // Proceedings of Guidance, Navigation and Control Conference and Exhibit. Honolulu, HI, US:AIAA,2008:1-16.
- [9] LEFFERTS E J,MARKLEY F L,MALCOLM D S. Kalman filtering for spacecraft attitude estimation [J]. Journal of Guidance Control and Dynamics,1982,5(5):417-429.
- [10] QIAO S J,SHEN D Y,WANG X T,et al. A self-adaptive parameter selection trajectory prediction approach via hidden Markov models[J]. IEEE Transactions on Intelligent Transportation Systems,2015,16(1):284-296.
- [11] AKCAL M U,URE N K,YANG C G,et al. Predictive missile guidance with online trajectory learning [J]. Defence Science Journal,2017,67(3):332-338.
- [12] WANG Q Y,ZHANG Z L,WANG Z Y,et al. The trajectory prediction of spacecraft by grey method [J]. Measurement Science and Technology,2016,27(8):085011.
- [13] ALAHI A,GOEL K,RAMANATHAN V,et al. Social LSTM: human trajectory prediction in crowded spaces [C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, US:IEEE,2016:961-971.
- [14] NIKHIL N,MORRIS B T. Convolutional neural network for trajectory prediction [C] // Proceedings of ECCV 2018 Workshops. Switzerland: Springer,2019:186-196.
- [15] TIAN X,JEFFREY C. Crystal graph convolutional neural networks for an accurate and interpretable prediction of material properties [J]. Physical Review Letters,2018,120(14):1-6.
- [16] WILLIAMS P. Three-dimensional aircraft terrain-following via real-time optimal control [J]. Journal of Guidance, Control, and Dynamics, 2007,30(4):1201-1205.
- [17] 古德费洛. 深度学习 [M]. 北京:人民邮电出版社,2017:201-226.
- GOODFELLOW. Deep learning [M]. Beijing: People's Post and Telecommunications Press,2017:201-226. (in Chinese)
- [18] HUBEL D H,WIESEL T N. Receptive fields, binocular interaction, and functional architecture in the cat's visual cortex [J]. Journal of Physiology,1962,160:106-154.
- [19] 毛景慧. 基于 LSTM 深度神经网络的股市时间序列预测精度的影响因素研究 [D]. 广州:暨南大学,2017:25-26.
- MAO J H. Research on influencing factors of stock market time series prediction accuracy based on LSTM deep neural network [D]. Guangzhou:Jinan University,2017:25-26. (in Chinese)
- [20] HORNIK K,STINCHCOMBE M,WHITE H. Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks [J]. Neural Networks,1990,3:551-560.
- [21] DUCHI J,HAZAN E,SINGER Y. Adaptive subgradient methods for online learning and stochastic optimization [J]. Journal of Machine Learning Research,2011,12(7):2121-2159.
- [22] 国海峰,侯满义,张庆杰,等. 基于统计学原理的无人作战飞机鲁棒机动决策 [J]. 兵工学报,2017,38(1):160-167.
- GUO H F,HOU M Y,ZHANG Q J,et al. UCAV robust maneuver decision based on statistics principle [J]. Acta Armamentarii,2017,38(1):160-167. (in Chinese)