

一种面向多无人机协同编队控制的改进深度神经网络方法

谢文光^{1,2}, 吴康^{1,3}, 阎芳^{1,2}, 史豪斌⁴, 张啸晨^{1,2}

(1.民航航空器适航审定技术重点实验室, 天津 300300; 2.中国民航大学 适航学院, 天津 300300;
3.中国民航大学 电子信息与自动化学院, 天津 300300; 4.西北工业大学 计算机学院, 陕西 西安 710072)

摘要:研究了多维度飞行数据下的协同编队控制问题,提出了一种基于改进深度神经网络的协同飞行控制方法。首先,使用深度神经网络在线整定PID控制器,设计了一种基于深度神经网络的PID控制器;其次,针对传统深度神经网络收敛速度慢、学习效率低的问题,同时为了满足多无人机编队飞行的实时性,在深度神经网络控制器中引入动量因子以提高网络的学习性能;最后,将所设计的改进深度神经网络控制器扩展到多无人机协同飞行任务场景实现协同编队飞行。对多无人机协同编队飞行进行仿真验证,仿真结果表明,所设计的改进深度神经网络编队控制器可以有效实现多无人机的编队生成与协同飞行。

关键词:协同编队;改进深度神经网络;PID控制器;动量因子

中图分类号:TP13 **文献标志码:**A **文章编号:**1000-2758(2020)02-0295-08

高效的多无人机协同编队飞行在电子对抗以及救援侦测等任务中发挥着十分重要的作用,因此成为了国内外学者的关注热点^[1-2]。协同编队控制器实现了多无人机在一定时间内按照一定的编队规则保持稳定飞行以完成预定的任务^[3]。但是,目前的多无人机协同控制方法仍然受限于诸多因素,例如编队飞行队形结构、编队飞行器数量、多无人机编队内部气动耦合等。PID控制器(proportion integration differentiation, PID)具有易于实现以及控制效果好等特性,被广泛应用于工业过程控制^[4]。PID控制器的性能受限于比例、积分、微分3种参数。因此,合理地设置PID控制器参数至关重要。研究人员使用PID控制器设计多无人机编队飞行控制器,然而经典PID控制器参数的设定受限于特定任务场景与专家经验^[5]。另外,经典的PID控制器无法适用于一类动态非线性控制系统。对于复杂的多无人机协同编队过程,经典控制器往往无法得到理想的控制效果。在线自整定PID控制器参数是一种提高控制器性能的可行方式。

多无人机编队飞行过程中的协同策略与管控方法一直是国内外学者的研究热点^[6-7]。文献[8]研究了多飞行器编队飞行控制中的协同策略问题,作者给出了多飞行器编队的六自由度动力学模型,并基于一致性理论设计了非线性编队飞行控制律。文献[9]研究了多飞行器编队控制中的协同问题。首先,基于协同姿态调节,给出了一种多飞行器协同姿态调控模型;其次,结合滑膜控制器设计了姿态协同控制律;最后,通过李亚普诺夫理论证明了所设计控制律的稳定性。文献[10]提出了一种基于信息一致性的协同控制策略,实现了从多飞行器的编队建立、编队保持到最后编队整体机动。文献[11]基于循环追踪策略,给出了一种六自由度多无人机协同控制方案,并且通过实验验证了所设计协同编队方法的有效性。除此之外,有的学者提出使用李亚普诺夫闭环三角设计多无人机编队飞行控制器^[12]。针对多无人机编队飞行中的近距离编队飞行控制,文献[13]应用了滑膜控制的方法。动力学建模是目前多数多无人机协同编队控制方法的首要选择。

传统的非线性控制方法需要对被控制对象建立复杂的数学模型;其次,在不确定环境下,传统方法很难实现对非线性对象的有效控制。再者,先前工作没有考虑控制器参数的不确定性。设定合理的控制器参数往往需要依赖人工经验,并且效率低下。

神经网络已经被广泛应用于许多领域,成为了研究热点^[14-15]。为了实现 PID 控制器参数实时整定,研究人员通过 BP 神经网络自适应调节 PID 控制器参数。然而,受限于经典神经网络的学习性能,基于 BP 神经网络的 PID 控制器仍然具有收敛速度慢、控制效果差等问题。深度学习通过扩展多层隐含层,可以学习到深层的特征表示与样本数据的内在规律,为设计高效的控制器学习模型提供了一种新的契机。

本文在多无人机编队控制问题中使用了深度神经网络模型,设计了一种多无人机协同编队方法。首先,为了满足多无人机协同编队的实时性要求,本文将动量因子^[16]引入深度神经网络,设计了一种改进深度神经网络学习模型。其次,基于改进深度神经网络,设计了一种编队控制器,该控制器使用深度神经网络在线自适应整定 PID 控制器参数。最后,基于主从结构,将所设计的深度神经网络控制器扩展到多无人机协同编队飞行场景。

该文组织结构如下:第一节给出相关背景知识;第二节给出了改进深度神经网络模型;第三节给出了基于改进深度神经网络的飞行控制器;第四节给出了基于改进深度神经网络的多无人机协同编队控制器,并进行了稳定性分析;第五节,仿真实验验证了所提出方法的有效性。第六节总结全文并给出未来工作展望。

1 改进深度神经网络模型

神经网络的学习性能受限于训练样本数量与网络隐含层的层数。实时的多无人机协同编队控制要求神经网络学习模型具有较高的学习性能。因此,本文在反向传播过程^[17]中引入了动量常数以加快学习速度以及保证训练过程的相对稳定。

类似于经典的神经网络,深度神经网络的输入层不包含激活函数。除了输入层外,设定某一层中神经元 n 的输入为 I_n ,输出信号为 y_n 。设定相邻低一层中神经元 m 的输出信号为 y_m ,则该神经元的输出值如(1)式所示。

$$\begin{cases} y_n = f(\theta_n + I_n) \\ I_n = \sum_m \omega_{nm} f(\theta_n + I_n) \\ f(x) = \frac{2E - F(1 + e^{-Fx})}{1 + e^{-Fx}} \end{cases} \quad (1)$$

式中: $E = 1.634$; $F = 0.652$; 神经元 n 的阈值表示为 θ_n ; 神经网络输出层的上一隐含层中的某个神经元 n 的输出为 y_n 。设定输出层中神经元 k 的输出信号为 y_k ,其对应的输入信号为 I_k ,则 y_k 和 I_k 如(2)式所示

$$\begin{cases} y_k = f(\theta_k + \sum_n \omega_{kn} y_n) \\ I_k = \sum_n \omega_{kn} y_n \end{cases} \quad (2)$$

对于第 $t + 1$ 次网络权重的更新,神经元 u 的输入信号为 x_p^{t+1} ,输出信号为 y_{pu}^{t+1} ,期望输出信号为 O_{pu}^{t+1} ,则误差信号的方差如(3)式所示

$$E_p^{t+1} = \frac{1}{2} \sum_u (y_{pu}^{t+1} - O_{pu}^{t+1})^2 \quad (3)$$

对于 N 个输入样本,(4)式表示深度神经网络的方差

$$E_p^{t+1} = \frac{\sum_p \sum_u (y_{pu}^{t+1} - O_{pu}^{t+1})^2}{2N} \quad (4)$$

方差 E_p^{t+1} 在反向传播过程中不断减少,并且连接权值 ω_{ij}^{t+1} 沿着方差 E_p^{t+1} 的梯度不断变化。设定神经单元的输入信号为 x_p^{t+1} ,对于连接权值 ω_{ij}^{t+1} 的修正量 $\Delta_p \omega_{ij}^{t+1}$,此修正量正比于 $-\frac{\partial E_p^{t+1}}{\partial \omega_{ij}^{t+1}}$,权值的修正量 $\Delta_p \omega_{ij}^{t+1}$ 如(5)式所示

$$\begin{cases} \frac{\partial E_p^{t+1}}{\partial \omega_{ij}^{t+1}} = \left(\frac{\partial E_p^{t+1}}{\partial I_u^{t+1}} \right) \cdot \left(\frac{\partial I_u^{t+1}}{\partial \omega_{ij}^{t+1}} \right) \\ \frac{\partial I_u^{t+1}}{\partial \omega_{ij}^{t+1}} = y_{pj}^{t+1} = \frac{\partial \left(\sum_j \omega_{uj}^{t+1} y_{pj}^{t+1} \right)}{\partial \omega_{ij}^{t+1}} \\ \Delta_p \omega_{ij}^{t+1} = \frac{\beta}{\lambda} \left(\lambda \Delta_p \omega_{ij}^t - \frac{\partial E_p^{t+1}}{\partial \omega_{ij}^{t+1}} \right) \end{cases} \quad (5)$$

式中, λ 为学习率, $0 \leq \beta < 1$ 为动量常数,动量因子取值为 0.95。

设定 $\delta_{pu}^{t+1} = -\frac{\partial E_p^{t+1}}{\partial I_u^{t+1}}$,根据(5)式可得

$$\begin{cases} f(\theta_u^{t+1} + I_u^{t+1}) = (1 - \gamma_{pu}^t) \gamma_{pu}^t = \\ \frac{\partial}{\partial I_u^t} \left(\frac{2E}{\exp(-F(\theta_u^{t+1} + I_u^{t+1})) + 1} \right) \\ \delta_{pu}^{t+1} = - \left(\frac{\partial E_p^{t+1}}{\partial I_u^{t+1}} \right) \cdot \left(\frac{\partial y_{pu}^{t+1}}{\partial I_u^{t+1}} \right) = \\ f(\theta_u^{t+1} + I_u^{t+1}) \cdot (O_{pu}^{t+1} - \gamma_{pu}^{t+1}) \end{cases} \quad (6)$$

根据(6)式可得

$$\begin{cases} \Delta_p \omega_{uj}^{t+1} = \beta \left(\Delta_p \omega_{uj}^t - \frac{1}{\beta} \delta_{pu}^{t+1} \gamma_{pj}^{t+1} \right) \\ \delta_{pu}^{t+1} = (1 - \gamma_{pu}^{t+1}) (O_{pu}^{t+1} - \gamma_{pu}^{t+1}) \gamma_{pu}^{t+1} \end{cases} \quad (7)$$

输出层相邻隐含层中的神经元 j 与神经元 i 连接权值 ω_{ji} 的修正值如(8)式所示。其中,神经元 i 处于相邻的更低一层的隐含层。

$$\begin{cases} \delta_{pj} = \left(\frac{\partial E_p}{\partial y_{pj}} \right) \cdot \left(\frac{\partial y_{pj}}{\partial I_j} \right) = f(I_j) \cdot \left(\frac{\partial E_p}{\partial y_{pj}} \right) \\ = - \left(\frac{\partial E_p}{\partial y_{pj}} \right) (1 - y_{pj}) y_{pj} \\ \Delta_p \omega_{ji} = - \lambda \left(\frac{\partial E_p}{\partial I_j} \right) \cdot \left(\frac{\partial I_j}{\partial \omega_{ji}} \right) = - \lambda y_{pi} \left(\frac{\partial E_p}{\partial I_j} \right) = \lambda y_{pj} \delta_{pj} \end{cases} \quad (8)$$

式中

$$\begin{aligned} - \frac{\partial E_p}{\partial y_{pj}} &= - \sum_u \left(\frac{\partial E_p}{\partial I_u} \right) \cdot \left(\frac{\partial I_u}{\partial y_{pj}} \right) = \\ &- \sum_u \left(\frac{\partial E_p}{\partial I_u} \right) \cdot \left(\frac{\partial \sum_m \omega_{um} y_{pm}}{\partial y_{pj}} \right) = \sum_u \delta_{pu} \omega_{uj} \end{aligned} \quad (9)$$

根据以上表达式,得到(10)式

$$\delta_{pj} = (\gamma_{pj} - \gamma_{pj}^2) \cdot \left(\sum_u \omega_{uj} \delta_{pu} \right) \quad (10)$$

最后,隐含层权值的更新量为: $\Delta_p \omega_{ji} = \lambda y_{pj} \delta_{pj}$ 。

2 基于改进深度神经网络的 PID 飞行控制器

网络输入层与输出层的神经单元个数相同,均为 3。设定深度神经网络含有 n 层隐含层,隐含层 k 的神经元个数为 a_k^m 。输入层的神经节点、隐含层的神经节点与输出层的神经节点分别使用 i, j 与 p 表示。深度神经网络输入层的 3 个输入信号分别为控制系统在某一时刻的输入信号,输出信号以及输入与输出的差值。该深度神经网络的输出信号是 PID 控制器的控制参数 K^p, K^i, K^d 。

其中, $O_i^{(1)} = x(i), i = 1, 2, 3$ 为深度神经网络的输出。在第 u 次神经网络学习过程中,第一层隐含层中神经元 j 的输入如(11)式所示。

$$I_j^{(2)}(u) = \sum_{i=0}^3 \omega_{ij}^{(2)} O_i^{(1)}, j = 1, 2, \dots, a_1^m \quad (11)$$

该神经元的输出如(12)式所示

$$\begin{aligned} O_j^{(2)}(u) &= f(I_j^{(2)}(u)) = \\ &f\left(\sum_{i=0}^3 \omega_{ij}^{(2)} O_i^{(1)}\right), j = 1, 2, 3, \dots, a_1^m \end{aligned} \quad (12)$$

式中,输入层神经元节点 i 到隐含层神经元节点 j 的连接权值为 $\omega_{ij}^{(2)}$ 。激活函数 $f(x)$ 为双曲线正切函数。神经网络的输入层、第一层隐含层、第二层隐含层,第 k 层隐含层分别使用(1),(2),(3)与(2+k-1)表示,输出层使用(2+n)表示。隐含层中第 k 层中某个神经元节点 j 的输出如(13)式所示。

$$\begin{aligned} O_j^{(2+k-1)}(u) &= f(I_j^{(2+k-2)}(u)) = \\ &f\left(\sum_{i=0}^{a_{k-1}^m} \omega_{ij}^{(2+k-1)} O_i^{(2+k-2)}\right), j = 1, 2, 3, \dots, a_k^m \end{aligned} \quad (13)$$

激活函数 $f(x)$ 如(14)式所示

$$f(x) = E \left(\frac{1 - \exp(-Fx)}{\exp(-Fx) + 1} \right) \quad (14)$$

式中, $E = 1.634, F = 0.652$ 。(15)式表示最后一层隐含层的输出

$$\begin{aligned} I_p^{(2+n)}(u) &= \sum_{j=0}^3 O_p^{(2+n-1)}(u) \omega_{jp}^{(2+n)} \\ p &= 1, 2, 3; j = 1, 2, 3, \dots, a_n^m \end{aligned} \quad (15)$$

输出层的输出如(16)式所示

$$\begin{aligned} O_p^{(2+n)}(u) &= f(I_p^{(2+n)}(u)) = \\ &f\left(\sum_{j=0}^3 \omega_{jp}^{(2+n)} O_p^{(2+n-1)}(u)\right) \\ p &= 1, 2, 3; j = 1, 2, 3, \dots, a_n^m \end{aligned} \quad (16)$$

(17)式表示深度神经网络的最终输出

$$\begin{cases} k^p = O_1^{(2+n)} \\ k^i = O_2^{(2+n)} \\ k^d = O_3^{(2+n)} \end{cases} \quad (17)$$

为了加快训练速度并且保持相对稳定的训练过程,在反向传播过程中引入动量因子。反向传播过程使用了梯度下降法,输出层的权重更新如(18)式所示。

$$\begin{aligned} \Delta \omega_{jp}^{(2+n)}(u) &= \alpha \delta(u) y(u) + \beta \omega_{jp}^{(2+n)}(u-1) = \\ &\alpha \left(\frac{\partial y(u)}{\partial \omega_{jp}^{(2+n)}} \right) y(u) e(u) + \beta \omega_{jp}^{(2+n)}(u-1) = \end{aligned}$$

$$\beta\omega_{jp}^{(2+n)}(u-1) + \alpha y(u)e(u) \left(\frac{\partial y(u)}{\partial u(u)} \right) \cdot \left(\frac{\partial O_p^{(2+n)}(u)}{\partial I_p^{(2+n)}(u)} \right) \left(\frac{\partial I_p^{(2+n)}(u)}{\partial \omega_{jp}^{(2+n)}} \right) \quad (18)$$

式中, $e(u) = r(u) - y(u)$ 。使用 $\mu(u), y(u)$ 的相对变化量表示 $\partial y/\partial \mu$ 的估计值, 如 (19) 式所示

$$\frac{\partial y}{\partial \mu} = y(u) \left(\frac{1 - \frac{y(u-1)}{y(u)}}{\mu(u) - \mu(u-1)} \right) \quad (19)$$

PID 控制器的输出如 (20) 式所示。

$$\mu(u) = \mu(u-1) + O_1^{(2+n)}(e(u) - e(u-1)) + O_2^{(2+n)}e(u) + O_3^{(2+n)}(e(u) - e(u-1) + e(u-2)) \quad (20)$$

(21) 式表示权重更新过程

$$\Delta\omega_{jp}^{(2+n)}(u) = \beta\omega_{jp}^{(2+n)}(u-1) + \alpha\delta(u)y(u) = \beta\omega_{jp}^{(2+n)}(u-1) + \alpha y(u)e(u) \left(\frac{\partial y(u)}{\partial u(u)} \right) \cdot \left(\frac{\partial O_p^{(2+n)}(u)}{\partial I_p^{(2+n)}(u)} \right) \cdot \left(\frac{\partial I_p^{(2+n)}(u)}{\partial \omega_{jp}^{(2+n)}} \right) = \beta\omega_{jp}^{(2+n)}(u-1) + \alpha \left(\frac{\partial u(u)}{\partial O_p^{(2+n)}(u)} \right) \cdot$$

$$\left(\frac{\partial O_p^{(2+n)}(u)}{\partial I_p^{(2+n)}(u)} \right) \cdot \left(\frac{\partial I_p^{(2+n)}(u)}{\partial \omega_{jp}^{(2+n)}} \right) \cdot \left(\frac{y(u) - y(u-1)}{\mu(u) - \mu(u-1)} \right) \cdot y(u)(r(u) - y(u)) \quad (21)$$

3 基于改进深度神经网络的多无人飞机协同编队控制

3.1 多无人飞机协同编队控制器

设定编队无人机的数量为 5, 其中 1 架无人飞机为领航机, 其余 4 架无人飞机为跟随机。多无人飞机协同编队飞行可以使得多架无人飞机快速保持一致性的状态, 即 5 架无人飞机保持相对稳定的飞行距离。其中, 4 架跟随无人飞机保持统一的高度, 并且分别处于正方形的 4 个顶点。领航无人飞机使用 PID 控制器。如图 1 所示, 设定 $j=1, 2, 3, 4$ 分别表示 4 架跟随无人飞机的编号。其中, 对于 4 架跟随无人飞机, 每架无人

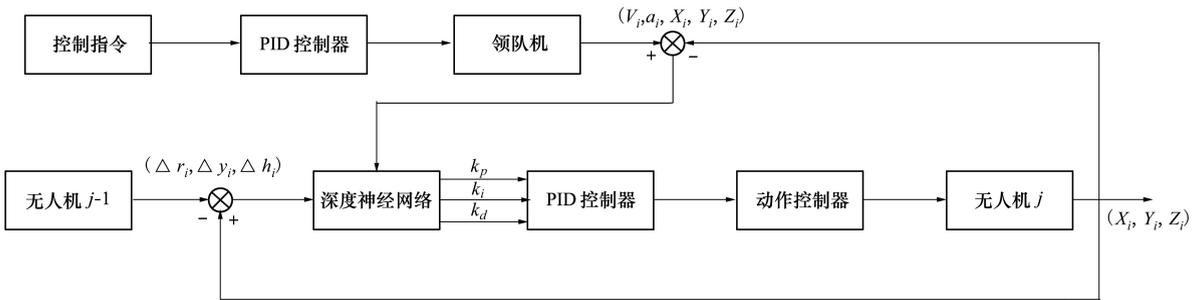


图 1 基于改进深度神经网络的多无人飞机编队控制器

飞机只需考虑前一架无人飞机的飞行状态并作出调节。对于跟随无人飞机, 不仅需要考虑领航机的飞行状态, 同时需要与相邻无人飞机保持一定飞行距离, 并且飞行高度保持一致。本文使用改进深度神经网络控制器实现对跟随无人飞机的飞行控制。

改进深度神经网络的输入为: 领航机的速度 V_i , 偏航角 α_i , 位置坐标 X_i, Y_i, H_i , 以及跟随无人飞机的水平距离与高度的变化 $\Delta X_i, \Delta Y_i, \Delta H_i$ 。对于多无人飞机协同编队飞行, 短时间内各个跟随无人飞机的状态量可能变化较大, 这对编队飞行控制的性能要求较高。因此, 改进深度神经网络控制器可以更有效地实现非线性协同编队控制。由于深度神经网络的

离线训练方式鲁棒性较差, 并且对于噪声不能很好地抑制, 故本文采取了深度神经网络的在线训练方法。

对于所使用的神经网络, 网络的输入层, 隐含层第一层, 隐含层第二层, ..., 隐含层第 $m-1$ 层分别使用 $K=0, 1, 2, \dots, m$ 表示。设定网络的第 K 层有 a_i^K 个神经元, 设定第 L 层的第 j 个神经元到第 $L+1$ 层的第 i 个神经元的连接权重为 ω_{ij} 。

对于反向传播过程中的第 $u+1$ 次权值更新, (22) 式与 (23) 式分别给出了第 $L+1$ 层到第 L 层的连接权值 $\omega_{ij}^{(L+1)}$ 以及第 $L+1$ 层中第 i 个神经元的阈值 $\theta_i^{(L+1)}$ 的更新方式。

$$\omega_{ij}^{(L+1)}(u+1) = \lambda \sum_{k=1}^{n_{L+2}} O_k^{L+1}(u) \delta_k^{L+1}(u) + \omega_{ij}^{(L+1)}(u) \quad (22)$$

$$\theta_i^{(L+1)}(u+1) = \gamma \sum_{k=1}^{n_{L+2}} O_k^L(u) \delta_k^{L+1}(u) + \theta_i^{(L+1)}(u) \quad (23)$$

式中, λ, γ 分别是常数、步长因子。

引入动量常量之后的权值更新如(24)式所示。

$$\begin{cases} E = \frac{1}{2} \sum_{i=1}^{a_n} (y'_i - y_i)^2 \\ \Delta \omega_{ij}^{(L+1)}(u+1) = \\ \beta \Delta \omega_{ij}^{(L+1)}(u) - \alpha \left(\frac{\partial E}{\partial \omega_{ij}^{(L+1)}(u+1)} \right) \end{cases} \quad (24)$$

式中, E 表示期望, y', y 分别表示期望输出与实际的输出。 α, β 分别表示学习率与动量常数, 范围均在 $(0, 1)$ 内。 $\delta_k^{L+1}(u)$ 的迭代方式如(25)式所示。

$$\delta_k^{(L+1)}(u+1) =$$

$$\begin{cases} y_k - O_k^{(L+1)}, & L+1 = m \\ f^{(L+1)} O_i^{(L+1)} \left(\sum_{\rho=1}^{N_{L+2}} \omega_{i\rho}^{(L+2)}(u) \delta_k^{(L+2)}(u) \right), & 1 < L+1 < m \end{cases} \quad (25)$$

$f(x)$ 为激活函数, 如(26)式所示。

$$f(x) = \frac{2C}{1 + \exp(-Fx)} - C \quad (26)$$

式中, C, F 为 2 个常量参数, 数值分别为 1.716, 0.667。

跟随无人机的飞行控制器包括 2 个子控制器: 高度维持控制器与水平维持控制器。其中, 高度维持控制器考虑多无人机飞行时的高度, 水平维持控制器考虑多无人机飞行水平面的 x 方向与 y 方向的相对距离。高度维持控制器与水平维持控制器如下所示。

1) 高度维持控制器

多架跟随无人机相对稳定的飞行高度通过高度维持控制器来保持。在线训练完成的改进深度神经网络输出得到稳定的 PID 控制参数。所设计的高度控制律如(27)式所示。

$$\begin{cases} \delta_z = k_p^\alpha (\alpha_c - \alpha) + k_i^\alpha \int (\alpha_c - \alpha) dt - k_{\omega_z} (\omega_z) \\ \alpha_c = k_p^h \Delta h(t) + k_i^h \int \Delta h(t) dt \\ \Delta h(t) = h_c - h(t) - k_{v_z} \left(\frac{dh(t)}{dt} \right) \end{cases} \quad (27)$$

式中, 领航无人机的飞行高度为 h_c , 即跟随无人机需要保持的高度, ω_z 表示俯仰角速度。 v_z 表示无人机在高度方向的线速度。 $k_p^\alpha, k_i^\alpha, k_{\omega_z}, k_p^h, k_i^h, k_{v_z}$ 均为常量。 δ_z 为高度方向上的控制命令。

2) 水平维持控制器

水平保持控制器包含 2 个部分。首先是在水平面上与领航机保持相对稳定的距离。 x 方向上的距离维持控制器如(28)式所示。

$$\begin{cases} \delta_x = k_p^{v_x} (v_x - v_x^c) + k_i^{v_x} \int (v_x - v_x^c) dt + k_d^{v_x} \left(\frac{v_x}{dt} \right) + u_x \\ u_x = k_p^x \Delta x_i(t) + k_i^x \int \Delta x_i(t) dt + k_d^x \left(\frac{\Delta x_i(t)}{dt} \right) \end{cases} \quad (28)$$

式中: v_x 为跟随无人机当前速度; v_x^c 为期望飞行速度; $\Delta x_i(t)$ 为在水平面内 x 方向的位置变化; $k_p^{v_x}, k_i^{v_x}, k_d^{v_x}, k_p^x, k_i^x, k_d^x$ 分别为常量; δ_x 为水平面内 x 方向的控制命令。

与 x 方向控制器类似, (29) 式展示了无人机在 y 方向上的距离维持控制器。

$$\begin{cases} \delta_y = k_p^{v_y} (v_y - v_y^c) + k_i^{v_y} \int (v_y - v_y^c) dt + k_d^{v_y} \left(\frac{v_y}{dt} \right) + u_y \\ u_y = k_p^y \Delta y_i(t) + k_i^y \int \Delta y_i(t) dt + k_d^y \left(\frac{\Delta y_i(t)}{dt} \right) \end{cases} \quad (29)$$

式中: 跟随无人机的实时速度为 v_y ; 跟随无人机的期望飞行速度为 v_y^c ; 无人机在水平面内 y 方向的位置变化为 $\Delta y_i(t)$; $k_p^{v_y}, k_i^{v_y}, k_d^{v_y}, k_p^y, k_i^y, k_d^y$ 分别为常量; δ_y 为水平面内 y 方向的控制命令。

3.2 稳定性分析

根据经典 PID 控制器的特性可知, 领航无人机的稳定飞行可以通过经典 PID 控制器来保持。训练完成的深度神经网络可以得到 PID 控制器的 3 个控制参数, k^p, k^i, k^d 。同时, 跟随无人机的飞行高度与水平飞行距离通过改进深度神经网络在线调节。当深度神经网络输出稳定的控制器参数时, PID 控制器可以保持控制系统的相对稳定, 并且受控变量的变化维持在有界范围内。对于跟随无人机, 在水平 x 方向, 水平 y 方向上, 高度 h 3 个方向上的控制命令, 分别满足 $\lim_{t \rightarrow \infty} (\delta_x^t - \delta_1) = 0$, $\lim_{t \rightarrow \infty} (\delta_x^t - \delta_2) = 0$, $\lim_{t \rightarrow \infty} (\delta_z^t - \delta_3) = 0$ 。当基于深度神经网络的 PID 控制器稳定时, 对于每台无人机 i , 均存水平方向的相对距离 $\Delta X, \Delta Y$ 与高度 ΔH 保持稳定, 即 $\lim_{t \rightarrow \infty} \Delta X = 0$,

$\lim_{t \rightarrow \infty} \Delta Y = 0$ 与 $\lim_{t \rightarrow \infty} \Delta H = 0$ 。由此可见所提出的多无人机编队深度神经网络控制器能够保持稳定。

4 仿真验证

4.1 深度神经网络协同编队控制器仿真验证

为了论证深度神经网络协同编队控制器的有效性,本文设计了仿真验证试验。仿真对象为 4 架编队飞行的无人机。领航机高度为 7 km,3 架跟随无人机高度为 7 km,跟随无人机间的期望间距为 5 km。其中,3 架跟随无人机分别位于三角形的顶点,而领航机在跟随无人机平面内的投影为三角形的中心,跟随无人机与领航机水平期望距离为 2.887 km。

设定领航无人机初始位置为 (0,0,7) km,3 架跟随无人机初始位置分别为 (-2.5,0,7) km,(2.5,0,0) km,(0,2.5,7) km。3 架跟随无人机具有相同的初始速度,均为 40 m/s,而跟随无人机的协同飞行速度为 (15,0,0) m/s。仿真时间为 30 s,采样周期为 0.01 s。本文在多无人机编队飞行环境中引入了均值为 0,方差为 0.01 的外部扰动噪声。跟随无人机的相对距离作为协同编队控制性能的评价指标。

图 2 展示了深度神经网络控制器的仿真结果。在 25 s 之后,多无人机之间的相对距离保持稳定,即实现了协同飞行。仿真验证结果表明深度神经网络协同编队控制器的有效性。所设计的深度神经网络

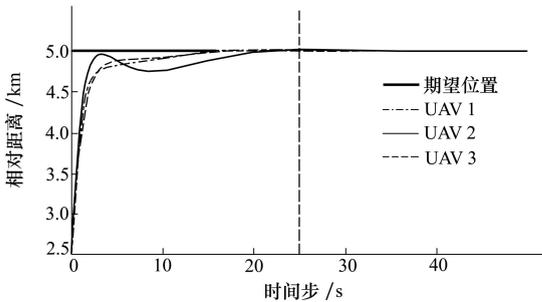


图 2 4 架无人机的距离变化曲线

络编队飞行控制方法具有可收敛性,并且可以有效保持无人机之间的协同飞行。

4.2 基于自适应动量的深度神经网络控制器仿真验证

本文设计了改进深度神经网络控制器的仿真验证试验,并将经典深度神经网络控制器作为对比。图 3 展示了改进深度神经网络控制器仿真结果。从仿真试验结果可以看出 2 种控制器最终都会得到收敛,但是收敛时间不同。对于改进深度神经网络控制器,3 架无人机的相对距离在 20 s 之后就会保持不变,即保持相对稳定的状态编队飞行。仿真验证说明了改进深度神经网络控制器具有更高效的多无人机协同编队控制性能。

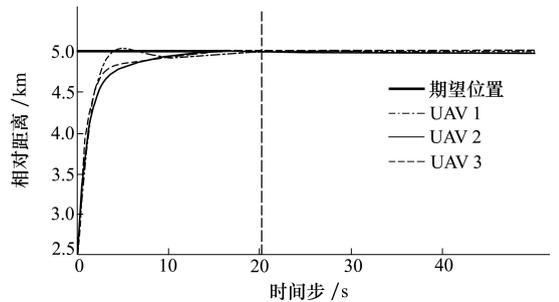


图 3 4 架无人机的距离变化曲线

5 结论

针对高维飞行数据下的多无人机协同编队控制问题,结合当下流行的深度神经网络技术提出了一种面向多无人机编队飞行的改进深度神经网络控制方法,在反向传播过程中引入动量因子以加速网络的收敛速度以及保持相对稳定的训练过程。最后仿真结果验证了本文提出协同编队方法的有效性。然而,本文所设计的仿真验证场景规模仍然较小,未来会尝试将该方法应用在更大规模场景中,并且在多无人机编队飞行中设置更多的噪声等干扰条件以设计更高泛化性与鲁棒性的协同编队飞行控制方法。

参考文献:

[1] GU J, SU T, WANG Q, et al. Multiple Moving Targets Surveillance Based on a Cooperative Network for Multi-UAV[J]. IEEE Communications Magazine, 2018, 56(4): 82-89

[2] ERHART S, HIRCHE S. Internal Force Analysis and Load Distribution for Cooperative Multi-Robot Manipulation[J]. IEEE

- Trans on Robotics, 2015, 31(5): 1238-1243
- [3] CHENG H, PAGE J, OLSEN J. Cooperative Control of UAV Swarm via Information Measures[J]. International Journal of Intelligent Unmanned Systems, 2013, 1(3): 256-275
- [4] TONG Q, YUAN Z, LIAO X, et al. Magnetic Levitation Haptic Augmentation for Virtual Tissue Stiffness Perception[J]. IEEE Trans on Visualization and Computer Graphics, 2017, 24(12): 3123-3136
- [5] OU L, SHAO Q, CHEN J, et al. Decentralized PID Controller Design for the Cooperative Control of Networked Multi-Agent Systems[C]//2012 12th International Conference on Control Automation Robotics & Vision, 2012: 554-559
- [6] ZHOU Y, CHENG N, LU N, et al. Multi-UAV-Aided Networks: Aerial-Ground Cooperative Vehicular Networking Architecture [J]. IEEE Vehicular Technology Magazine, 2015, 10(4): 36-44
- [7] HEREDIA G, CABALLERO F, MAZA I, et al. Multi-UAV Cooperative Fault Detection Employing Vision-Based Relative Position Estimation[J]. IFAC Proceedings Volumes, 2008, 41(2): 12093-12098
- [8] BI Peng, LUO Jianjun, ZHANG Bo. Cooperate Control Algorithm for Spacecraft Formation Flying Based on Consensus Theory [J]. Journal of Astronautics, 2010, 31(1): 70-74
- [9] ZHOU Jian, GONG Chunlin, SU Hua, et al. Finite Time Distributed Synchronization of Spacecraft Formation Attitude with Complex Constraints[J]. Journal of Astronautics, 2018, 39(12): 1340-1347
- [10] ZHANG Bo, LUO Jianjun, YUAN Jianping. On-Orbit Autonomous Operation Cooperative Control of Multi-Spacecraft Formation [J]. Journal of Astronautics, 2010, 31(1): 130-136
- [11] LUO Jianjun, ZHOU Liang, JIANG Qiqi, et al. 6 DOF Coordinated Control Using Cyclic Pursuit for Spacecraft Formation[J]. Journal of Astronautics, 2017, 38(2): 166-175
- [12] LAWRENCE D A, FREW E W, PISANO W J. Lyapunov Vector Fields for Autonomous Unmanned Aircraft Flight Control[J]. Journal of Guidance Control & Dynamics, 2012, 31(31): 1220-1229
- [13] WANG Y, WANG X, ZHAO S, et al. Vector Field Based Sliding Mode Control of Curved Path Following for Miniature Unmanned Aerial Vehicles in Winds[J]. Journal of Systems Science & Complexity, 2018, 31(1): 302-324
- [14] PARK D C, ELSHARKAWI M A, MARKS R J I, et al. Electric Load Forecasting Using an Artificial Neural Network[J]. IEEE Trans on Power Systems, 1991, 6(2): 442-449
- [15] DAS D, MATOLAK D W, DAS S. Spectrum Occupancy Prediction Based on Functional Link Artificial Neural Network (FLANN) in ISM Band[J]. Neural Computing & Applications, 2018, 29(12): 1363-1376
- [16] LUO Y, FU Q, LIU J, et al. An Extended Algorithm Using Adaptation of Momentum and Learning Rate for Spiking Neurons Emitting Multiple Spikes[C]//International Work-Conference on Artificial Neural Networks, 2017: 569-579
- [17] BENGIO Y, MESNARD T, FISCHER A, et al. STDP-Compatible Approximation of Backpropagation in an Energy-Based Model [J]. Neural Computation, 2017, 29(3): 555-577

A Formation Flight Method with an Improved Deep Neural Network for Multi-UAV System

XIE Wenguang^{1,2}, WU Kang^{1,3}, YAN Fang^{1,2},
SHI Haobin⁴, ZHANG Xiaocheng^{1,2}

(1.Key Laboratory of Airworthiness Certification Technology for Civil Aviation Aircraft, Tianjin 300300, China;
2.College of Airworthiness, Civil Aviation University of China, Tianjin 300300, China;
3.College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China;
4.School of Computer Science, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: It is crucial to develop an effective controller for the multi-UAV system to contribute to the frontier fields, such as the electronic warfare. To address the dilemma of the cooperative formation with the high dimensional data, a deep neural network(NN) controller is developed in this paper. Firstly, a deep NN model is used to tune parameters of PID controller online. Secondly, this paper introduces an improved deep NN model integrating the momentum to improve the performance of the classical NN model and satisfy the condition for the real time cooperative formation. Lastly, the cooperative formation task is achieved by extending the proposed cooperative controller with an improved NN to the complex multi-UAV system. The simulation result of multi-UAV formation demonstrates the effectiveness of the proposed method, which achieves a faster formation than competitors.

Keywords: multi-UAV formation; improved deep neural network; PID controller; momentum; simulation