

کنترل مدل آزاد یک هواپیمای بال ثابت بر اساس شبکه‌های عصبی کانولوشن

یوسف صیفوری پور^۱، هادی نوبهاری^۲

^۱ دانشجوی دکتری، دانشکده مهندسی هوافضا، دانشگاه صنعتی شریف، تهران، ایران yseifouri@ae.sharif.edu

^۲ استاد، دانشکده مهندسی هوافضا، دانشگاه صنعتی شریف، تهران، ایران nobahari@sharif.edu

پذیرش: ۱۴۰۲/۰۹/۲۷

ویرایش: ۱۴۰۲/۰۸/۲۵

دریافت: ۱۴۰۲/۰۵/۰۸

چکیده: در این پژوهش یک معماری غیرخطی مدل آزاد برای کنترل یک پهپاد با بال ثابت ارائه شده است. این معماری دارای حلقه‌های درونی و بیرونی است. حلقه‌های درونی که بر اساس شبکه‌های عصبی کانولوشن طراحی شده‌اند، دینامیک درونی هواپیما را به صورت مدل آزاد کنترل می‌کند. حلقه‌های بیرونی که از کنترل‌کننده‌های متداول خطی استفاده می‌کند، برای کنترل سینماتیک پرنده طراحی شده‌اند. شبکه‌های عصبی استفاده شده برای کنترل حلقه‌های درونی به صورت خارج از خط و بر اساس دو پایگاه داده آموزش می‌بیند تا از فرآیندهای یادگیری زمانبر به صورت برخط جلوگیری شود. این پایگاه‌های داده با شبیه‌سازی مدل‌های آموزشی ساده ایجاد شده‌اند. سپس، داده‌های ورودی-خروجی این مدل‌های آموزشی پیش‌پردازش شده و به فریم‌های تصویر نگاشت شده‌اند تا بتوان آن‌ها را به عنوان ورودی به شبکه‌های کانولوشن داد. پس از آن، یک ساختار شبکه مناسب انتخاب و شبکه‌ها بر اساس پایگاه داده نگاشت شده آموزش داده شده است. این شبکه‌های آموزش دیده، همراه با کنترل‌کننده‌های خطی به صورت آبشاری، به شبیه‌سازی غیرخطی یک پرنده بال ثابت اعمال و عملکرد آن بررسی می‌شود. حلقه درونی کنترل‌کننده که دینامیک داخلی پرنده را کنترل می‌کند، به دو صورت تک‌مرحله‌ای و دو مرحله‌ای اعمال و عملکرد آن با هم مقایسه شده است.

کلمات کلیدی: شبکه‌های عصبی کانولوشن، هواپیمای بال ثابت، کنترل‌کننده پرواز، کنترل مدل آزاد.

Model-free control of a fixed-wing aircraft based on convolutional neural networks

Yusef Seifouripour and Hadi Nobahari

Abstract: In this paper, a model-free nonlinear architecture is presented to control a fixed-wing UAV. This architecture has inner and outer loops. The inner loops, which are designed based on convolutional neural networks, control the internal dynamics of the aircraft in a model-free procedure. The outer loops, which use conventional linear controllers, are designed to control the kinematics of the UAV. The neural networks used to control the inner loops are trained offline based on databases to avoid time-consuming online learning processes. These databases are created by simulating simple training models. Then, the input-output data of these training models are pre-processed and mapped to image frames so that they can be given as input to convolutional neural networks. After that, a suitable network structure is selected and the networks are trained based on the mapped databases. These trained networks, together with cascaded linear controllers, are applied to the nonlinear simulation of the fixed-wing UAV and its performance is investigated. The inner loop of the controller that controls the internal dynamics of the UAV has been applied in both single-stage and two-stage forms and their performance has been compared.

Keywords: convolutional neural networks, fixed wing aircraft, flight controller, model-free control.

۱- مقدمه

در دهه‌های اخیر و با گسترش روزافزون استفاده از وسایل پرنده (به‌ویژه پرنده‌های بدون سرنشین بال ثابت)، تلاش زیادی در توسعه خلبان‌های خودکار برای این پرنده‌ها انجام شده است. این تلاش‌ها برای افزایش دقت، افزایش ایمنی، افزایش خودگردانی، افزایش قابلیت اطمینان، کاهش هزینه، کاهش خطر و کاهش زمان راه‌اندازی و اجرای ماموریت انجام می‌شود. استفاده از خلبان خودکار (به‌جای خلبان انسانی) برای کنترل وسایل هوایی (به‌ویژه در پرنده‌های بدون سرنشین) باعث کاهش چشمگیر زمان و هزینه و افزایش دقت و کیفیت عملیات مختلف می‌شود. همچنین، بخش قابل ملاحظه‌ای از سوانح هوایی ناشی از خطاهای انسانی است که اهمیت استفاده از سیستم‌های خودکار را دوچندان می‌کند. مهمترین وظایف خلبان خودکار را می‌توان در سه بخش هدایت، ناوبری و کنترل تقسیم‌بندی کرد. هدایت یک وسیله به معنای تولید فرامین لازم برای کنترل مسیر آن است. سیستم ناوبری وظیفه دارد سرعت، موقعیت و وضعیت لحظه‌ای وسیله را نسبت به یک قاب مرجع محاسبه کند و در اختیار سیستم هدایت قرار دهد. سیستم کنترل نیز وظیفه دارد فرامین تولیدشده توسط سیستم هدایت را اجرا کند.

بیشتر کنترل‌کننده‌ها بر مبنای یک مدل طراحی می‌شوند که رفتار سامانه را نشان می‌دهد. در این حالت، مدل‌های خطی یا غیرخطی فرآیندها و عملگرهای موجود در یک سامانه بر اساس قوانین فیزیکی، روش‌های شناسایی یا الگوریتم‌های یادگیری استخراج و کمی‌سازی می‌شود. در برخی از سامانه‌های شناخته‌شده، مانند بسیاری از وسایل نقلیه هوافضایی، مدل سامانه را می‌توان به راحتی استخراج کرد. با این حال، کمی کردن مدل (یعنی مقداردهی پارامترهای آن) مشکل است. روش‌های تعیین پارامترهای مدل ممکن است زمانبر، گران‌قیمت، نادرست، ناقص یا در مواردی گمراه‌کننده باشد. علاوه بر این، ممکن است عدم قطعیت‌ها یا پارامترهای متغیر با زمان در مدل استخراج‌شده وجود داشته باشد که می‌تواند عملکرد کنترل‌کننده مبتنی بر مدل را تضعیف کند. علاوه بر این، ممکن است تغییرات ناخواسته‌ای در دینامیک سامانه رخ دهد یا سامانه با اغتشاشات مواجه شود.

تا به امروز، روش‌های تطبیقی زیادی برای کنترل سامانه‌های دارای دینامیک نامشخص یا غیردقیق توسعه یافته‌اند. در مرجع [۱]، پیشرفت‌های اخیر در طراحی کنترل‌کننده‌های تطبیقی چندمتغیره ارائه و بررسی شده است. مرجع [۲] یک نمای کلی از کنترل‌کننده‌های تطبیقی با مقایسه رویکردهای مبتنی بر مدل و رویکردهای داده‌محور ارائه داده است. مرجع [۳] روشی منظم و دقیق از نظریه کنترل تطبیقی برای سیستم‌های زمان گسسته ارائه می‌دهد. در کاربردهای هوافضایی نیز کنترل تطبیقی به طور

گسترده استفاده شده است. در مرجع [۴]، یک کنترل‌کننده تطبیقی مدل مرجع (MRAC)^۱ برای فرود یک پرنده بدون سرنشین (پهپاد) با بال ثابت روی یک حامل متحرک اعمال شده است. این کنترل‌کننده دارای حلقه‌های درونی (به روش MRAC) و حلقه‌های بیرونی (از نوع PID)^۲ برای کنترل وضعیت و موقعیت پهپاد است. روش MRAC برای انجام پرواز گروهی پهپادهای مشابه نیز استفاده شده است [۵]. در مرجع [۶]، کنترل‌کننده تطبیقی مدل مرجع ضمنی (IRM)^۳ برای استهلاک پدیده ناخواسته بال‌نوسانی^۴ یک هواپیمای بال ثابت استفاده شده است. یک کنترل‌کننده تطبیقی چند مدله نیز در مرجع [۷] برای پرواز یک پهپاد چندپره با بار بیرونی ناشناخته اعمال شده است. در مرجع [۸]، یک کنترل‌کننده ردیابی تطبیقی مقاوم برای یک پهپاد چندپره پیشنهاد شده است. حلقه‌های درونی کنترل‌کننده بر مبنای تنظیم‌کننده خودتنظیم تطبیقی (STR)^۵ برای کنترل نرخ‌های زاویه‌ای پهپاد و حلقه‌های بیرونی از نوع کلاسیک تناسبی-انتگرالی (PI)^۶ برای کنترل وضعیت آن طراحی شده است.

از روش‌های تطبیقی برای افزایش مقاومت کنترل‌کننده به تغییرات ناخواسته در دینامیک سامانه نیز استفاده می‌شود. در مرجع [۹]، یک کنترل‌کننده تحمل‌پذیر خطای تطبیقی (AFTC)^۷ برای یک هواپیمای بال ثابت (که تحت آسیب‌های ناخواسته در دم افقی است) پیشنهاد شده که ترکیبی از روش پس‌گام^۸ و یک جبران‌کننده خطا است. در مرجع [۱۰]، یک کنترل‌کننده AFTC مبتنی بر ترکیب روش MRAC و یک جبران‌کننده خطا برای کنترل یک پهپاد شناورنشین اعمال شده است. در این کار، سازکار تطبیقی MRAC به‌عنوان حلقه‌های درونی (برای کنترل سرعت و موقعیت پهپاد) پیاده‌سازی شده است و حلقه‌های بیرونی از نوع سنتی PID (برای کنترل موقعیت آن) است. در مرجع [۱۱] یک کنترل‌کننده نامی مبتنی بر روش تنظیم‌گر بهینه طراحی شده و برای مدل دینامیکی یک هواپیمای تجاری بزرگ، که حرکت طولی و عرضی آن وابسته‌اند، پیاده‌سازی شده است. این طرح کنترلی در حضور خرابی عملگرهای سکان عمودی، شهر^۹ و موتور بررسی شده است. در مرجع [۱۲] طراحی کنترل‌کننده تطبیقی مدل مرجع مستقیم برای محاسبه برخط پارامترهای کنترل‌کننده ریز پهپادها در حضور نویز و اغتشاش انجام شده است.

در کنترل‌کننده‌های تطبیقی از شبکه‌های عصبی مصنوعی (ANN)^{۱۰} نیز به‌وفور استفاده شده که ابزاری قدرتمند برای مدل‌سازی سیستم‌های غیرخطی پیچیده است [۱۳]. شبکه‌های عصبی به طور معمول به سه روش آموزش داده می‌شوند: روش یادگیری تقویتی، روش یادگیری نظارت‌شده و روش یادگیری بدون نظارت. ایراد اصلی روش‌های یادگیری

^۱ Proportional-Integral^۲ Adaptive Fault-Tolerant Controller^۳ backstepping^۴ Aileron^۵ Artificial Neural Network^۱ Model Reference Adaptive Control^۲ Proportional-Integral-Derivative^۳ Implicit Reference Model^۴ wing rock^۵ Self-Tuning Regulator

شده‌است. در مرجع [۲۸] نیز یک معماری مبتنی بر شبکه‌های عصبی کانولوشن ارائه شده‌است که یک پهپاد را در محیط‌های جدید و ناشناخته با هدف اجتناب از موانع هدایت می‌کند. این معماری هم زاویه مسیر مطلوب و هم احتمال برخورد با موانع را در هر لحظه محاسبه می‌کند.

شبکه‌های عصبی کانولوشن به طور معمول از داده‌های تصویری به‌عنوان ورودی استفاده می‌کند. با این حال، این شبکه‌ها برای ورودی‌های غیرتصویری یا تصویری غیرغنی (که اطلاعات کافی را منتقل نمی‌کند) نیز به کار می‌رود. در این موارد، از روش‌های مناسب برای تبدیل این ورودی‌های نامناسب به تصاویر غنی استفاده می‌شود. به عنوان مثال، در مرجع [۲۹] یک مدل یادگیری بر اساس شبکه‌های CNN و واحدهای LSTM⁴ [۳۰] توسعه یافته‌است تا نوسانات آتی ارزش سهام را پیش‌بینی کند. در این کار، تاریخچه زمانی نوسانات قیمت به تصویری با ابعاد ۴۰×۱۰۰ پیکسل (یعنی ماتریس‌هایی با اندازه ۴۰ × ۱۰۰ درایه) نگاشت می‌شود. در مرجع [۳۱]، یک ساختار مبتنی بر CNN برای شناسایی و طبقه‌بندی پهپادها (یک CNN برای شناسایی و یک CNN برای طبقه‌بندی) توسعه داده شده‌است که در آن، ورودی CNN از ادغام بردارهای سیگنال رادیویی تولید می‌شود. در مرجع [۳۲]، یک CNN برای پیش‌بینی توزیع فشار روی هواپرها^۵ (بر اساس تصویر هندسی آن) به کار رفته‌است. تصویر هندسی هواپرها به اندازه کافی آموزنده نیست. بنابراین، روشی به نام تابع فاصله علامت‌دار برای تبدیل هندسه ساده هواپرها به تصاویر رنگی با ابعاد ۳۲×۳۲ پیکسل به کار رفته‌است که عملکرد CNN را در پیش‌بینی توزیع فشار بهتر می‌کند. کار مشابهی برای پیش‌بینی میدان‌های جریان غیریکنواخت در اطراف اشکال دوبعدی یا سه‌بعدی بر اساس CNN در مرجع [۳۳] انجام شده‌است. در مرجع [۳۴]، یک ساختار مبتنی بر CNN برای شناسایی عدم قطعیت‌ها در دینامیک یک بالگرد بدون سرنشین به کار رفته‌است. در این کار، تاریخچه زمانی ورودی‌های کنترلی و حالت‌های دینامیک بالگرد به بخش‌هایی با طول مشخص تقسیم می‌شود. سپس، این بخش‌ها برای ایجاد ماتریس‌های دوبعدی (به‌عنوان ورودی شبکه‌های CNN) به هم متصل می‌شود. خروجی‌های هدف این شبکه‌ها، خطای بین داده‌های آزمایش پرواز و خروجی یک مدل پایه شناسایی شده است که ناشی از عدم قطعیت در دینامیک بالگرد می‌باشد. مدل پایه نیز با یک الگوریتم بهینه‌سازی، یعنی روش کمینه مربعات (LSM)^۶ شناسایی شده‌است. در این پژوهش، از شش CCN برای تخمین عدم قطعیت در شش درجه آزادی مدل بالگرد استفاده شده‌است. سپس، از مدل‌های شناسایی شده (توسط LSM) و عدم قطعیت‌های شناسایی شده (توسط CNN) برای توسعه یک کنترل‌کننده مبتنی بر روش پسگام استفاده شده‌است.

نظارت‌شده، تهیه پایگاه داده آموزشی است. از طرفی در روش‌های یادگیری تقویتی نیازی به داشتن پایگاه آموزشی نیست. با این حال، فرآیند آموزش در این روش‌ها زمانبر است و همگرایی آن غیرسریع است. علاوه بر این، در برخی از کاربردها به دلیل خطراتی که ممکن است در فرآیند یادگیری رخ دهد (به ویژه در وسایل پرنده گران‌قیمت یا ناپایدار) استفاده از روش‌های یادگیری تقویتی به‌راحتی قابل انجام نیست. با این وجود، از هر دو روش یادگیری تحت نظارت و تقویتی به طور مکرر برای کنترل وسایل هوافضایی استفاده شده‌است. مرجع [۱۴] یک مرور ادبیات جامع در مورد تکنیک‌های ترکیبی MBC^۱-ANN ارائه می‌کند که برای کنترل پرواز پهپاد مناسب هستند. در مرجع [۱۵] یک روش طراحی سیستم کنترل پرواز مبتنی بر یادگیری تقویتی برای بهبود عملکرد پاسخ گذرای یک سیستم کنترل تطبیقی مدل مرجع حلقه‌بسته ارائه شده‌است. مرجع [۱۶] عملکرد کنترل‌کننده تطبیقی مبتنی بر یادگیری تقویتی را با کنترل‌کننده خطی کلاسیک در کنترل وضعیت پرنده‌های بدون سرنشین مقایسه می‌کند. در مرجع [۱۷] نیز با الهام از طبیعت، از یک الگوریتم یادگیری تقویتی با عنوان بهینه‌سازی خط مشی نزدیک مبدا (PPO)^۲ برای کنترل پرواز یک پهپاد چهارپره استفاده شده‌است. این الگوریتم می‌تواند پهپاد را در پرواز شناوری و نیز در دنبال کردن نقاط مسیر مطلوب کنترل کند. مرجع [۱۸] نیز با ترکیب یادگیری تقویتی گرادیان خط‌مشی و روش ازدحام ذرات یک روش ترکیبی برای کنترل جهت‌گیری و موقعیت یک پهپاد چهارپره ارائه می‌کند.

شبکه‌های عصبی کانولوشنال (CNN)^۳ نوعی از شبکه‌های عصبی مصنوعی است که به طور گسترده در بینایی ماشین و پردازش زبان کاربرد دارد [۱۹] و [۲۰]. شبکه‌های عصبی کانولوشن همچنین در کاربردهای هوافضایی، عمدتاً برای هدایت پهپادها یا افزایش قابلیت آن‌ها در انجام وظایف نظارتی و دیده‌بانی استفاده می‌شود [۲۱]. مرجع [۲۲] یک آشکارساز شی تک‌تصویری را بر اساس شبکه‌های عصبی کانولوشنال عمیق ارائه می‌کند که پهپادها را قادر به انجام تشخیص وسایل نقلیه می‌کند. در مرجع [۲۳]، برای کمک به مدیریت چرای گاوها، یک سیستم تشخیص و شمارش گاو بر اساس شبکه‌های عصبی کانولوشن ارائه شده‌است که با استفاده از تصاویر هوایی گرفته‌شده توسط یک پهپاد کار می‌کند. در مرجع [۲۴] یک ساختار هدایتی مبتنی بر CNN توسعه داده شده‌است تا یک پهپاد چندپره را در محیط درونی ساختمان (بدون استفاده از سامانه موقعیت‌یاب جهانی) هدایت کند. کار مشابهی نیز در مرجع [۲۵] انجام شده‌است. در مرجع [۲۶] نیز از شبکه‌های عصبی کانولوشن برای کاهش مات‌بودن تصاویر هوایی یک پهپاد که در ناوبری تصویری آن کاربرد دارد، استفاده شده‌است. در مرجع [۲۷] از شبکه‌های عصبی کانولوشن برای ناوبری تصویری پهپاد با هدف اجتناب از موانع و دنبال کردن یک دوچرخه استفاده

⁵ Airfoils⁶ Target Output⁷ Least Square Method¹ Model-Based Control² Proximal Policy Optimization³ Convolutional Neural Network⁴ Long Short-Term Memory


درونی هواپیما استفاده می‌شود؛ در حالی که حلقه‌های بیرونی به‌روش خطی کنترل می‌شود. لازم به ذکر است که در این پژوهش، حلقه‌های دورنی با استفاده از شبکه‌های کانولوشن در یک و دو مرحله کنترل می‌شود. پایداری این ساختار کنترلی از طریق شبیه‌سازی مونت کارلو ارزیابی می‌شود. نوآوری‌های این پژوهش عبارت است از:

- اعمال روش کنترل مدل آزاد با استفاده از شبکه‌های کانولوشن
- اعمال روش کنترل مدل آزاد به‌صورت دو مرحله‌ای

ادامه این نگارش به شرح زیر است: در بخش بعدی، جزئیات ساختار کنترل‌کننده ارائه شده‌است. در بخش سوم، نحوه تولید پایگاه داده برای آموزش شبکه‌های CNN توضیح داده شده‌است. بخش چهارم ساختار شبکه‌های CNN و جزئیات اعمال آن را بیان می‌کند. نتایج شبیه‌سازی‌ها در بخش پنجم بیان شده‌است. در پایان، نتایج کلی این پژوهش ارائه شده‌است.

۲- جزئیات ساختار کنترلی

در این بخش، ساختار کلی کنترلی و جزئیات مدل آزاد در طراحی کنترل‌کننده پرنده بال ثابت ارائه شده‌است. این ساختار کنترلی مناسب پرنده‌های بال ثابت از نوع غلتش-برای-گردش (BTT)⁶ است. در این ساختار از عملگرهای شهپر و بالابر⁸ (معرفی شده در شکل ۱) برای کنترل کانال غلتش⁹ (زاویه و نرخ غلتش) و کانال فراز¹⁰ (زاویه و نرخ فراز) به‌صورت آشناری استفاده می‌شود. همچنین، فرض می‌شود که زوایا و نرخ‌های غلتش و فراز پرنده در هر لحظه اندازه‌گیری می‌شود. در پرنده‌های BTT، کنترل زاویه سمت پرنده با کنترل زاویه غلتش آن انجام می‌شود؛ یعنی خروجی حلقه کنترل زاویه سمت (به‌عنوان حلقه بیرونی‌تر)، زاویه غلتش مطلوب است که توسط کنترل‌کننده غلتش اجرا می‌شود. در این پژوهش، حلقه‌های بیرونی تر خلبان خودکار مانند کنترل زاویه سمت و نیز کنترل ارتفاع پرنده بررسی نمی‌شود.



شکل ۱: معرفی محورهای قاب بدنی و سطوح کنترلی پرنده

در برخی از روش‌های کنترلی، از یک مدل غیرفیزیکی تحت عنوان مدل آزاد^۱ [۳۵] یا مدل فراموضعی^۲ [۳۶] استفاده می‌شود. برخلاف روش‌هایی که کاملاً مستقل از مدل است (و به آن روش‌های جعبه‌سیاه^۳ گفته می‌شود)، در روش‌های مدل آزاد یک مدل متغیر با زمان و ساده (که لزوماً مبتنی بر فیزیک مسئله نیست) برای سامانه در نظر گرفته می‌شود. سپس، پارامترهای این مدل به‌صورت برخط محاسبه و برای کنترل سامانه استفاده می‌شود. در مرجع [۳۷] از روش مدل آزاد برای کنترل یک پهپاد چندپره استفاده شده‌است. در مرجع [۳۸] از روش مدل آزاد برای طراحی کنترل‌کننده مود لغزشی (SMC)^۴ به‌منظور کنترل وضعیت و موقعیت یک پهپاد چندپره استفاده شده‌است. در مرجع [۳۹] از یک معماری مبتنی بر روش مدل آزاد برای کنترل یک پهپاد چندپره استفاده شده‌است. این معماری از یک کنترل‌کننده پایه به همراه یک کنترل‌کننده مدل آزاد برای جبران نامعینی‌ها و اغتشاشات استفاده می‌کند. در مرجع [۴۰] یک طرح کنترل تطبیقی فازی بدون مدل برای کنترل زاویه سمت هواپیماهای بدون سرنشین بال ثابت توسعه یافته‌است. رویکرد کنترلی در این مرجع مبتنی بر یک سیستم استنتاج عصبی فازی تطبیقی (ANFIS)^۵ برای تخمین مشتق شبه‌جزئی (PPD)^۵ و یک راهبرد کنترل تطبیقی بدون مدل برای کنترل زاویه سمت پهپادهای بال ثابت با اختلالات باد است. از رویکرد کنترل‌کننده مدل آزاد در مرجع [۴۱] برای کنترل مسیر یک پهپاد چندپره، در مرجع [۴۲] برای کنترل یک پهپاد کوچک استفاده شده‌است. در مرجع [۴۳] یک رویکرد چندجسمی تطبیقی و مبتنی بر مدل آزاد برای کنترل یک پرنده بال‌زن (که ماهیت چندجسمی، غیرخطی و متغیر با زمان دارد) ارائه شده‌است که در آن هیچ اطلاعات صریحی از مدل پرنده مورد استفاده قرار نمی‌گیرد. مرجع [۴۴] به طراحی یک کنترل‌کننده ردیابی پرواز برای یک پهپاد چندپره بر اساس رویکرد منطق فازی و بدون مدل بهینه تحت عدم قطعیت‌های مدل می‌پردازد.

در پژوهش حاضر، یک ساختار مدل آزاد مبتنی بر CNN برای کنترل هواپیماهای بال ثابت توسعه داده شده‌است. فرض می‌شود که دینامیک هواپیما ناشناخته است و نیز ممکن است در طول زمان تغییر کند. این معماری شامل دو CNN است که با استفاده از یادگیری نظارت‌شده و به صورت خارج از خط آموزش می‌بیند. بنابراین، نیازی به روش‌های آموزشی وقت‌گیر یا محاسبات برخط سنگین نیست. این دو CNN بر اساس تاریخچه داده‌های ورودی-خروجی مدل‌های ساده آموزش داده می‌شوند و نیازی به جمع‌آوری داده‌های واقعی پرواز نیست. ورودی‌های CNN از نوع داده حسگرهای رایج پرنده‌ها و غیرتصویری هستند. بنابراین، روش مناسبی برای تبدیل این داده‌های حسی خام به فریم تصویر اعمال می‌شود. سپس از شبکه‌های CNN آموزش‌دیده برای کنترل دینامیک

⁶ Pseudo Partial Derivative

⁷ Bank-To-Turn

⁸ Elevator

⁹ Roll

¹⁰ Pitch

¹ Model-Free

² Ultra-Local Model

³ Black-Box

⁴ Sliding Mode Control


⁵ Adaptive Neuro-Fuzzy Inference System

۲-۱ ساختار کلی کنترل کننده

خروجی بسیاری از الگوریتم‌های هدایت در پرند‌های بال ثابت، زوایای غلتش و فراز مطلوب است. بنابراین، ساختار کنترل کننده مشابه شکل ۲ انتخاب می‌شود. در این ساختار، بلوک‌های کنترل q (نرخ فراز) و کنترل p (نرخ غلتش) دینامیک درونی هواپیما را کنترل می‌کند. از طرفی، بلوک‌های کنترل θ (زاویه فراز) و کنترل ϕ (زاویه غلتش) نیز حلقه‌های بیرونی هواپیما را کنترل می‌کند. عملگر مربوط به کنترل کانال فراز، سطح کنترلی بالابر (یعنی δ_{elev}) و عملگر مربوط به کنترل کانال غلتش، سطح کنترلی شپهر (یعنی δ_{ail}) است. فرض می‌شود که مقادیر مطلوب زوایای فراز و غلتش (یعنی θ_{des} و ϕ_{des}) در بخش هدایت خلبان خودکار محاسبه می‌شود. خروجی حلقه‌های کنترل زوایای فراز و غلتش شامل نرخ‌های مطلوب فراز و غلتش (یعنی q_{des} و p_{des}) است که به عنوان ورودی مطلوب به حلقه‌های کنترل درونی داده می‌شود. این حلقه‌های درونی مبتنی بر CNN هستند که بر اساس متغیرهای تخمین شده \hat{a} و \hat{T} کار می‌کند و جزئیات آن در بخش‌های بعد ارائه می‌شود. همچنین، حسگرهای پرند نیز زوایا و نرخ‌های فراز و غلتش را در هر لحظه اندازه‌گیری می‌کند. در این پژوهش، از کنترل کننده‌های مبتنی بر CNN و به روش مدل آزاد برای کنترل دینامیک درونی هواپیما و از کنترل کننده‌های خطی برای کنترل زوایای غلتش و فراز هواپیما استفاده شده است.

$$\frac{Q(s)}{Q_{des}(s)} = \frac{1}{d_q s + 1} \quad (2)$$

که در آن $P(s)/P_{des}(s)$ تابع تبدیل حلقه‌بسته نرخ غلتش، $Q(s)/Q_{des}(s)$ تابع تبدیل حلقه‌بسته نرخ فراز و d_i ($i = p, q$) ثابت مدل‌های مرجع درونی است که مقادیر آن‌ها جز متغیرهای طراحی کنترل کننده است. با انتخاب مدل مرجع حلقه‌های درونی به صورت فوق، کنترل کننده مبتنی بر CNN (که جزئیات آن در ادامه ارائه می‌شود) به صورت PI خواهد بود که خطای حالت ماندگار کم و مقاومت خوبی در برابر نویز اندازه‌گیری دارد.



شکل ۳. ساختار کنترل کننده کانال فراز

پس از آن، پارامترهای کنترلی حلقه‌های بیرونی به شرح زیر طراحی می‌شود:

$$K_{e\phi} = d_p \omega_{\phi_{des}}^2 \quad (3)$$

$$K_{e\theta} = d_q \omega_{\theta_{des}}^2 \quad (4)$$

$$K_{\phi}(s) = k_{\phi} s + 1 = \frac{2\xi_{\phi_{des}} \omega_{\phi_{des}} d_p - 1}{K_{e\phi}} s + 1 \quad (5)$$


$$K_{\theta}(s) = k_{\theta} s + 1 = \frac{2\xi_{\theta_{des}} \omega_{\theta_{des}} d_q - 1}{K_{e\theta}} s + 1 \quad (6)$$

که در آن $\omega_{i_{des}}$ ($i = \phi, \theta$) و $\xi_{i_{des}}$ ثابت‌های مدل مرجع بیرونی و جز متغیرهای طراحی کنترل کننده است؛ ثابت اول بیانگر فرکانس طبیعی و ثابت دوم بیانگر ضریب استهلاک مدل مرجع حلقه‌های بیرونی است. در این حالت، مدل مرجع حلقه‌های بیرونی به صورت زیر خواهد بود:

$$\frac{\Phi(s)}{\Phi_{des}(s)} = \frac{\omega_{\phi_{des}}^2}{s^2 + 2\xi_{\phi_{des}} \omega_{\phi_{des}} s + \omega_{\phi_{des}}^2} \quad (7)$$

$$\frac{\theta(s)}{\theta_{des}(s)} = \frac{\omega_{\theta_{des}}^2}{s^2 + 2\xi_{\theta_{des}} \omega_{\theta_{des}} s + \omega_{\theta_{des}}^2} \quad (8)$$

که در آن $\Phi(s)/\Phi_{des}(s)$ تابع تبدیل حلقه‌بسته زاویه غلتش و $\theta(s)/\theta_{des}(s)$ تابع تبدیل حلقه‌بسته زاویه فراز است. با انتخاب مدل مرجع حلقه‌های بیرونی به صورت فوق، بهره‌های کنترلی حلقه‌های بیرونی به صورت جبری قابل محاسبه است و کنترل کننده نیز به صورت علی خواهد بود. ذکر این نکته ضروری است که ثابت‌های $d_q, d_p, \omega_{\phi_{des}}, \omega_{\theta_{des}}, \xi_{\phi_{des}}, \xi_{\theta_{des}}$ متغیرهای طراحی کنترل کننده هستند که توسط کاربر و متناسب با سرعت و نیز محدودیت‌های دینامیکی پرند تحت کنترل مقداردهی می‌شوند.



شکل ۲. ساختار انتخاب شده برای کنترل کننده هواپیمای بال ثابت

همانطور که در شکل ۲ آمده است، دو کانال غلتش و فراز هواپیما با استفاده از دو کنترل کننده آنباشی کنترل می‌شود که هر کدام شامل دو حلقه است: حلقه درونی که دینامیک درونی را کنترل می‌کند و حلقه بیرونی که سینماتیک خارجی را کنترل می‌کند. به عنوان مثال، حلقه درونی و حلقه بیرونی کانال فراز در شکل ۳ آمده است. این شکل متشکل از دو حلقه کنترل زاویه و نرخ فراز است که ورودی مطلوب فراز در بخش هدایت خلبان خودکار محاسبه می‌شود. خروجی نهایی این دو حلقه متوالی آنباشی نیز دستور بالابر است که به پرند اعمال می‌شود. در این پژوهش، راهبرد کنترل برای حلقه‌های درونی، طراحی کنترل کننده‌های مدل آزاد مبتنی بر CNN است به طوری که حلقه‌های بسته درونی از مدل‌های مرجع خود به شرح زیر پیروی کند:

$$\frac{P(s)}{P_{des}(s)} = \frac{1}{d_p s + 1} \quad (1)$$

¹ Causal

۲-۲ کنترل مدل آزاد حلقه‌های درونی

به‌طور معمول، مدل آزاد حاکم بر سامانه تحت کنترل به‌صورت زیر در نظر گرفته می‌شود [۳۶]:

$$y^v = f + \beta u \quad (9)$$

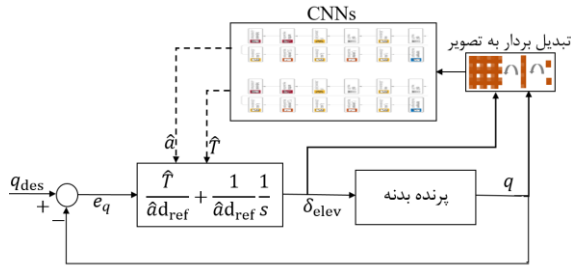
که در آن $u \geq 1$ درجه مشتق مدل، β یک عدد ثابت غیرفیزیکی (که توسط کاربر مقداردهی می‌شود) و f بیانگر دینامیک ناشناخته سامانه و اغتشاشات وارد بر آن است که باید به‌صورت برخط محاسبه شود. مقدار u معمولاً برابر با یک یا دو (در بیشتر موارد برابر با یک) فرض می‌شود. در این پژوهش، مدل آزاد حاکم بر دینامیک درونی پرنده به‌صورت زیر فرض می‌شود ($\beta = \frac{a}{T}$ و $f = -\frac{1}{T}y$, $v = 1$):

$$\dot{y} = -\frac{1}{T}y + \frac{a}{T}u \quad (10)$$

که در آن هر دو متغیر a و T بیانگر دینامیک ناشناخته سامانه و اغتشاشات وارد بر آن است که با استفاده از دو شبکه کانولوشن به‌عنوان \hat{a} و \hat{T} محاسبه می‌شود. لازم به ذکر است که بر خلاف روش مدل آزاد پایه، در این پژوهش مقدار β غیر ثابت فرض شده است. در این حالت، اگر بهره کنترلی حلقه‌های درونی به‌صورت زیر اعمال شود (شکل ۴):

$$K_{ideal}(s) = \frac{\hat{T}s + 1}{\hat{a}d_{ref}s} = \frac{\hat{T}}{\hat{a}d_{ref}} + \frac{1}{\hat{a}d_{ref}s} \quad (11)$$

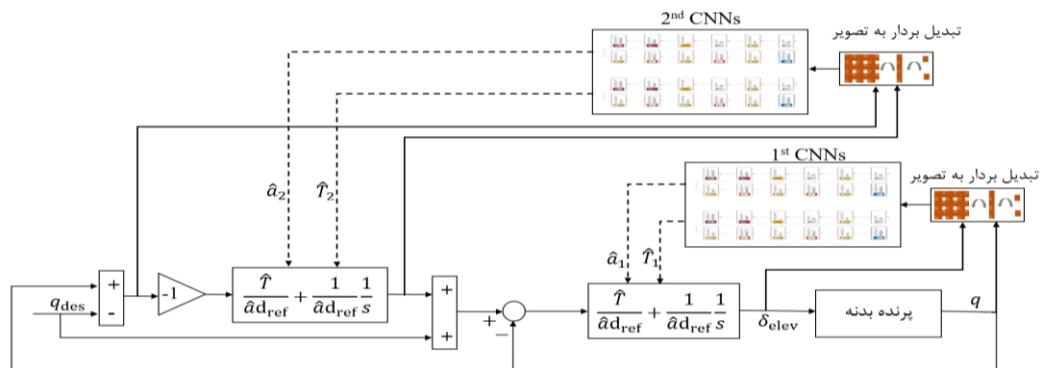
آنگاه تابع تبدیل دینامیک حلقه‌بسته درونی همان توابع ارائه شده در روابط (۱) و (۲) خواهد بود. ثابت d_{ref} در این رابطه متغیر طراحی کنترول کننده است که در دو رابطه فوق معادل d_p و d_q است.



شکل ۴: ساختار حلقه درونی کنترول کننده مبتنی بر CNN برای کنترول نرخ فراز به‌صورت تک مرحله‌ای

۲-۳ کنترول دومرحله‌ای حلقه‌های درونی

در کنترول مدل آزاد فرض می‌شود که دینامیک سامانه مشابه مدل ارائه شده در رابطه (۹) است. در این پژوهش نیز فرض شده است که مدل ارائه شده در رابطه (۱۰) بر دینامیک داخلی پرنده حاکم است و بر این اساس، کنترول کننده K_{ideal} طراحی شد. این فرض را می‌توان بر دینامیک حلقه‌بسته سامانه نیز اعمال کرد؛ یعنی فرض شود که دینامیک حلقه‌بسته داخلی (بعد از یک مرحله اعمال کنترول کننده K_{ideal}) نیز کماکان مشابه مدل ارائه شده در رابطه (۱۰) است و دوباره کنترول کننده K_{ideal} را بر دینامیک حلقه‌بسته داخلی اعمال کرد (شکل ۵). هر دو سری شبکه‌های عصبی (یعنی دو شبکه CNN مرحله اول و دو شبکه CNN مرحله دوم) و اندازه و نوع ورودی‌ها و خروجی‌های آن‌ها کاملاً یکسان است. مرحله اول این کنترول کننده کاملاً مشابه بخش قبل است که ورودی مرجع آن (که از خروجی مرحله دوم محاسبه می‌شود) تغییر کرده است. در مرحله دوم نیز به‌جای خروجی سامانه (یعنی q)، اختلاف خروجی و ورودی مطلوب (یعنی $e_q = -q_{des} + q$) و به‌جای ورودی کنترلی (یعنی δ_{elev})، خروجی کنترول کننده مرحله دوم به شبکه‌های کانولوشن این مرحله داده می‌شود.



شکل ۵: ساختار حلقه درونی کنترول کننده مبتنی بر CNN برای کنترول نرخ فراز به‌صورت دومرحله‌ای


کنترلی می‌شود. لازم به ذکر است که کنترول دومرحله‌ای تنها روی حلقه درونی اعمال می‌شود و حلقه بیرونی (که از نوع خطی است) تغییر نمی‌کند.

این کار (یعنی کنترول مجدد دینامیک حلقه‌بسته) را می‌توان به دفعات انجام داد؛ هرچند بررسی بیشتر این ایده روی مسئله مورد بررسی در این پژوهش نشان داد که یک مرحله کنترول مجدد کفایت می‌کند و مراحل بیشتر کنترول باعث افزایش بار محاسباتی و نیز شدیدتر شدن دستورات

۳- تهیه پایگاه داده برای آموزش شبکه‌های کانولوشن

$$p_h(k) = (p_h(k))(p_h(k))^T \quad (17)$$

که دارای $n_h \times 3$ سطر و $n_h \times 3$ ستون است. این کار برای تمامی مدل‌های آموزشی انجام می‌شود. این فرآیند به‌ازای $n_h = 2$ در شکل ۶ نشان داده شده‌است. برای آموزش شبکه‌های CNN اول و دوم، علاوه بر ورودی‌های مناسب از نوع تصویر، به‌خروجی‌های هدف نیز نیاز است. به‌ازای همه ورودی‌های P_h (که با تاریخچه داده‌های یک مدل آموزشی مانند $G_t(s)$ ایجاد می‌شود)، برای آموزش شبکه اول پارامتر a_t و برای آموزش شبکه دوم پارامتر T_t به‌عنوان خروجی هدف در نظر گرفته و این کار برای همه مدل‌های آموزشی تکرار می‌شود.



شکل ۶: فرآیند تولید تصاویر ورودی شبکه‌های کانولوشن از تاریخچه ورودی-خروجی مدل‌های آموزشی

۴- جزئیات اعمال شبکه‌های کانولوشن

علاوه بر پایگاه داده آموزشی مناسب، باید یک ساختار مناسب با تعداد پارامترهای کافی انتخاب شود تا شبکه دارای عملکرد مناسب باشد. ساختار شبکه‌های CNN در این پژوهش در شکل ۷ آمده‌است. این ساختار به ترتیب شامل یک لایه ورودی تصویر با ابعاد 27×27 پیکسل (یعنی $n_h = 9$)، لایه کانولوشن با 15×15 فیلتر 6×6 ، لایه تابع فعال‌سازی از نوع ReLU، لایه کانولوشن با 30×30 فیلتر 4×4 ، لایه تابع فعال‌سازی از نوع ReLU، لایه کانولوشن با 60×60 فیلتر 2×2 ، لایه تابع فعال‌سازی از نوع علامت^۴، لایه کاملاً متصل با 13^3 گره، لایه بیشینه هموار^۵ و لایه طبقه‌بندی^۶ است.

لازم به ذکر است که تعداد لایه‌ها و تعداد گره‌های هر لایه از این شبکه‌ها به روش عمومی سازی^۶ [۴۵] تعیین شده‌است تا تعمیم‌پذیر باشد؛ به‌این صورت که تعداد لایه‌ها و گره‌ها ابتدا کم در نظر گرفته شده و به مرور آنقدر زیاد می‌شود تا عملکرد شبکه شروع به افت کردن کند. این فرآیند در شکل ۸ نشان داده شده‌است. در این حالت، تعداد لایه‌ها و گره‌های شبکه برابر با حالتی انتخاب می‌شود که بهترین عملکرد را داشته‌است.

هر دو شبکه CNN در این پژوهش به صورت خارج از خط آموزش داده می‌شود. برای آموزش این شبکه‌ها، دو پایگاه داده ایجاد می‌شود. پایگاه داده اول از شبیه‌سازی مدل‌های آموزشی با مقادیر $a_t = e^{[-5:0.5:5]}$ (تعداد ۲۱ مقدار مختلف برای a_t) و $T_t = [0.1, 0.5, 1, 2, 4]$ و پایگاه داده دوم با مقادیر $a_t = [0.1, 1, 10, 100]$ و $T_t = e^{[-2.5:0.5:3.5]}$ (تعداد ۱۳

اولین قدم در آموزش شبکه‌های عصبی به روش یادگیری نظارت‌شده، تولید پایگاه داده است. عملکرد شبکه به ساختار، روش آموزشی و کیفیت پایگاه داده آموزشی آن بستگی دارد. برای تولید پایگاه آموزشی، در مرحله اول، مدل آموزشی با پارامترهای مختلف T_t و a_t شبیه‌سازی و با ورودی‌های تصادفی به مدت کافی تحریک می‌شود:

$$G_t(s) = \frac{a_t}{T_t s + 1} \quad (12)$$

که در آن a_t بیانگر اندازه حالت پایای پاسخ مدل آموزشی به اندازه ورودی پله و T_t بیانگر سرعت پاسخ آن است. سپس، براساس تاریخچه ورودی-خروجی این مدل‌ها، بردارهای زیر تولید می‌شود:

$$\begin{aligned} U_j &= [u(\delta_d), u(2\delta_d), \dots, u(N_j \delta_d)]^T \\ &= [u_1, u_2, \dots, u_{N_j}]^T \\ Y_j &= [y(\delta_d), y(2\delta_d), \dots, y(N_j \delta_d)]^T \\ &= [y_1, y_2, \dots, y_{N_j}]^T \\ D_{Y_j} &= [d_y(\delta_d), d_y(2\delta_d), \dots, d_y(N_j \delta_d)]^T \\ &= [d_{y_1}, d_{y_2}, \dots, d_{y_{N_j}}]^T \end{aligned} \quad (13)$$

که در آن $j = 1, 2, \dots, n_p$ شماره مدل آموزشی، δ_d گام زمانی داده‌برداری، N_j طول تاریخچه داده‌برداری هر مدل، y_i تاریخچه خروجی هر مدل، u_i تاریخچه ورودی هر مدل و d_{y_i} تاریخچه تفاوت خروجی است که به صورت زیر محاسبه می‌شود.

$$d_{y_i} = y_i - y_{i-1}, \quad i = 1, 2, \dots, N_j \quad (14)$$

در مرحله بعد، بر اساس داده‌های ورودی-خروجی ثبت شده از هر مدل آموزشی، بردارهای زیر ایجاد می‌شود:

$$\begin{aligned} u_h(k) &= [U_1^T(k) \quad U_2^T(k+1) \quad \dots \quad U_{n_p}^T(k+n_h-1)]^T \\ y_h(k) &= [Y_1^T(k) \quad Y_2^T(k+1) \quad \dots \quad Y_{n_p}^T(k+n_h-1)]^T \\ d_{y_h}(k) &= [D_{Y_1}^T(k) \quad D_{Y_2}^T(k+1) \quad \dots \quad D_{Y_{n_p}}^T(k+n_h-1)]^T \end{aligned} \quad (15)$$

که در آن $k = [1, 2, \dots, N_j - n_h + 1]$ و $j = 1, 2, \dots, n_p$ و n_h طول هر بردار است. سپس، این سه بردار با هم ادغام می‌شود تا بردارهای بزرگتر را به صورت زیر ایجاد کند:

$$p_h(k) = [u_h^T(k), y_h^T(k), d_{y_h}^T(k)]^T \quad (16)$$

و در نهایت، ماتریس‌های مربعی زیر که بیانگر تصاویر ورودی به شبکه است، از ضرب دایادیک^۱ بردار $p_h(k)$ به صورت زیر محاسبه می‌شود:

⁴ softmax

⁵ classification


⁶ Generalization

¹ Dyadic


² Sign

³ fully connected layer


۸۸٪ و با آموزش شبکه دوم دقت آن در تعیین مقدار T_t (در واقع، تعیین کلاس آن بین ۱۳ کلاس تعریف شده) به ۸۷٪ رسیده است.



شکل ۸: دقت شبکه برحسب تعداد پارامترهای یادگیری شبکه



شکل ۹: نتیجه آموزش شبکه کانولوشن اول بر اساس پایگاه داده اول



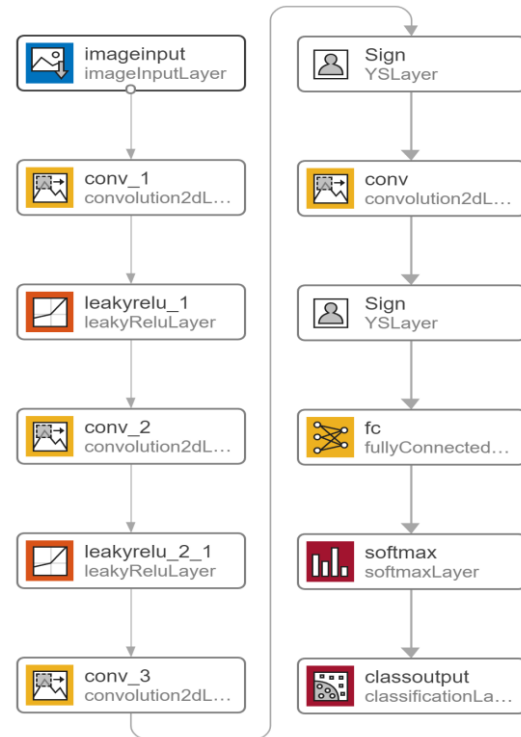
شکل ۱۰: نتیجه آموزش شبکه کانولوشن دوم بر اساس پایگاه داده دوم

۵- نتایج شبیه‌سازی‌ها

برای بررسی عملکرد کنترل کننده مبتنی بر CNN، از آن برای کنترل یک پهپاد بال ثابت در محیط شبیه‌سازی سیمولینک-متلب استفاده می‌شود. این شبیه‌سازی به صورت شش درجه آزادی و غیرخطی است. مشخصات هندسی، عملکردی و آیرودینامیکی این پهپاد در جدول ۱ و جدول ۲ آمده است. معرفی این ضرایب و مشخصات در مرجع [۴۸] آمده است. مدل دینامیکی عملگرهای کنترلی شهپر و بالابر پرنده به صورت زیر در نظر گرفته شده است:

$$G_{act} = \frac{1}{0.5s + 1} \quad (18)$$

مقدار مختلف برای T_t ایجاد می‌شود. از پایگاه داده اول برای آموزش شبکه اول (به منظور تخمین مقدار a_t بین ۲۱ مقدار تعریف شده) و از پایگاه داده دوم برای آموزش شبکه دوم (به منظور تخمین مقدار T_t بین ۱۳ مقدار تعریف شده) استفاده می‌شود. مقادیر a_t و T_t به گونه‌ای انتخاب شده است تا در ایجاد پایگاه داده‌های آموزشی، از مدل‌های آموزشی مختلف با سرعت و دامنه پاسخ کم و زیاد استفاده شود.



شکل ۷: ساختار هر دو شبکه CNN مورد استفاده


مدل‌های آموزشی با ورودی تصادفی با دامنه ۱۰ تا ۱۰+ تحریک شده و تاریخچه ورودی-خروجی آن‌ها با گام زمانی ۰.۰۱ sec نمونه برداری می‌شود. لازم به ذکر است که در این پژوهش، آموزش و پیاده‌سازی شبکه‌ها و نیز شبیه‌سازی‌های پرنده و کنترل کننده در محیط نرم‌افزار متلب-سیمولینک انجام شده است. برای هر پایگاه داده، ترتیب تمامی جفت ورودی-خروجی‌های آموزشی به هم ریخته می‌شود. سپس، ۸۰٪ از این داده‌های مخلوط شده برای آموزش هر شبکه انتخاب می‌شود و بقیه داده‌ها، برای اعتبارسنجی آموزش استفاده می‌شود. این دو شبکه عصبی به روش بهینه‌سازی Adam^۱ [۴۶] آموزش داده شده است. نرخ یادگیری اولیه روی $1e-3$ تنظیم شده است و با ادامه آموزش در هر دوره^۲، مقدار نرخ یادگیری ۴۰ درصد کاهش می‌یابد. پارامتر تنظیم L_2 نیز برابر $1e-6$ بوده و برای همه لایه‌های شبکه ثابت است. نتایج آموزش این دو شبکه در شکل ۹ و شکل ۱۰ ارائه شده است. مشاهده می‌شود که با آموزش شبکه اول دقت آن در تعیین مقدار T_t (در واقع، تعیین کلاس آن بین ۲۱ کلاس تعریف شده) به

³ L_2 regularization parameter


¹ ADaptive Moment estimation

² epoch


تنشی به سازه هواپیما وارد نمی‌کند. همچنین، خروجی‌های پرنده، در حلقه‌های بیرونی و درونی، به‌خوبی ورودی‌های مطلوب را دنبال می‌کند. با این حال، دقت کنترل در دنبال کردن ورودی مطلوب، به‌خصوص در مورد کانال فراز پرنده، کامل نیست و کمی خطای ردیابی وجود دارد.




شکل ۱۱: تاریخچه زاویه فراز مطلوب و زاویه فراز خروجی شبیه‌سازی



شکل ۱۲: تاریخچه نرخ فراز مطلوب و نرخ فراز خروجی شبیه‌سازی



شکل ۱۳: تاریخچه ورودی کنترلی بالابر



شکل ۱۴: تاریخچه زاویه غلتش مطلوب و زاویه غلتش خروجی شبیه‌سازی

مقدار لقی^۱ عملگرها نیز برابر 0.05 درجه فرض شده‌است. در اعمال این کنترل‌کننده گام زمانی گسسته‌سازی $\delta_d = 0.5$ ، ثابت طراحی حلقه‌های درونی کنترل $d_{ref} = d_p = d_q = 0.5$ ، ضریب استهلاک حلقه‌های بیرونی کنترل $\xi_{ides} = 0.8$ و فرکانس طبیعی حلقه‌های بیرونی $\omega_{ides} = 1$ فرض شده‌است. همچنین، فرض شده‌است که دستورات کنترل‌کننده با پنج میلی‌ثانیه تاخیر صادر می‌شود.

جدول ۱: مشخصات هندسی و عملکردی پهپاد تحت کنترل

مشخصه	مقدار
طول بدنه	۴.۳ متر
پهنای بال	۵.۱۵ متر
وزن کل	۲۰۵ کیلوگرم
نوع موتور	پیستونی با توان ۲۶ اسب بخار
مدادومت پروازی	۵ ساعت
سرعت پرواز	۱۲۰ کیلومتر بر ساعت
حداکثر نرخ اوج‌گیری	۴ متر بر ثانیه
سرعت واماندگی	۸۰ کیلومتر بر ساعت


جدول ۲: مشخصات و ضرایب آپرودینامیکی و ممان اینرسی پهپاد تحت کنترل

مشخصه	مقدار	مشخصه	مقدار
طول مرجع طولی	۰.۵۵ متر	$C_{L_{\delta_e}}$	۰.۴
طول مرجع عرضی	۵.۱۵ متر	C_{L_q}	۸.۱
مساحت مرجع	۲.۸ متر	$C_{Y_{\beta}}$	-۰.۸
I_{xx}	۴۷ kg.m ²	$C_{l_{\beta}}$	-۰.۰۲
I_{yy}	۹۱ kg.m ²	C_{l_p}	-۰.۴۵
I_{zz}	۱۱۱ kg.m ²	C_{l_r}	۰.۲۶
I_{xy}	۵ kg.m ²	$C_{l_{\delta_a}}$	-۰.۱۶
I_{xz}	-۱۰ kg.m ²	C_{m_0}	۰.۰۷
I_{yz}	-۶ kg.m ²	$C_{m_{\alpha}}$	-۲.۱
C_{D_0}	۰.۰۶	$C_{m_{\delta_e}}$	-۱.۷۶
$C_{D_{\alpha}}$	۰.۴۳	C_{m_q}	-۳۴.۴
$C_{D_{\delta_e}}$	۰.۰۲	$C_{n_{\beta}}$	۰.۱۱
C_{L_0}	۰.۳۹	C_{n_p}	-۰.۱۱
$C_{L_{\alpha}}$	۴.۸	C_{n_r}	-۰.۲


۵-۱ نتایج شبیه‌سازی با کنترل تک‌مرحله‌ای

نتایج شبیه‌سازی کنترل‌کننده به‌صورت تک‌مرحله‌ای در شکل ۱۱ تا شکل ۱۶ نشان داده شده‌است. در این سناریوها، پرنده زوایای فراز بین دو مقدار ۱۰- و ۱۰+ درجه و زوایای غلتش بین دو مقدار ۲۰- و ۲۰+ درجه را تجربه می‌کند. مشاهده می‌شود که ورودی‌های کنترلی هموار است و


¹ Backlash




شکل ۱۸: تاریخچه نرخ فراز مطلوب و نرخ فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای



شکل ۱۵: تاریخچه نرخ غلتش مطلوب و نرخ غلتش خروجی شبیه‌سازی



شکل ۱۹: تاریخچه ورودی کنترلی بالابر با حلقه درونی دومرحله‌ای




شکل ۱۶: تاریخچه ورودی کنترلی شهپر

۵-۲ نتایج شبیه‌سازی با کنترل دومرحله‌ای


با هدف کم کردن خطای ردیابی، حلقه‌های درونی کنترل کننده به صورت دومرحله‌ای به شبیه‌سازی پرنده اعمال می‌شود. نتایج این شبیه‌سازی، به عنوان مثال برای کانال فراز پرنده، در شکل ۱۷ تا شکل ۱۹ آمده است. با بررسی این نتایج می‌توان گفت که خطای ردیابی کنترل کننده در این حالت بسیار ناچیز است و خروجی کانال نرخ فراز پرنده با کنترل کننده دو مرحله‌ای به خوبی ورودی مطلوب را دنبال می‌کند. همچنین، ورودی کنترلی بالابر نسبت به کنترل تک‌مرحله‌ای تغییرات کمی داشته و مقادیر آن کمی بیشتر شده است. ذکر این نکته ضروری است که با کنترل دومرحله‌ای و افزایش دقت ردیابی در حلقه درونی (کنترل نرخ فراز)، دقت ردیابی در حلقه بیرونی (کنترل زاویه فراز) نیز بهتر شده است.

۵-۳ بررسی حساسیت کنترل کننده به نویز اندازه‌گیری


به اندازه‌گیری زاویه فراز و نرخ فراز پرنده نویزهای سفید تصادفی با میانگین صفر و انحراف معیار ۰.۵ درجه و ۰.۵ درجه بر ثانیه اضافه می‌شود. نتایج شبیه‌سازی پرنده با کنترل کننده درونی دومرحله‌ای (ارائه شده در شکل ۲۰ تا شکل ۲۲) نشان می‌دهد که عملکرد کنترل کننده در دنبال کردن ورودی‌های مطلوب مناسب بوده و ورودی‌های کنترلی هموار و ملایم است. این نتایج نشان می‌دهد که کنترل کننده در مقابل نویز اندازه‌گیری عملکرد مناسبی دارد. دلیل این امر ناشی از وجود عبارت انتگرال‌گیری در کنترل کننده ایده آل حلقه درونی (رابطه ۱۱) و عدم وجود عبارت مشتق‌گیر است.




شکل ۲۰: تاریخچه زاویه فراز مطلوب و زاویه فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای در حضور نویز اندازه‌گیری



شکل ۱۷: تاریخچه زاویه فراز مطلوب و زاویه فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای



شکل ۲۴: تاریخچه نرخ فراز مطلوب و نرخ فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای در حضور اغتشاش ورودی




شکل ۲۵: تاریخچه ورودی کنترلی بالابر با حلقه درونی دومرحله‌ای در حضور اغتشاش ورودی


۵-۵ بررسی پایداری کنترل کننده

پایداری کنترل کننده دومرحله‌ای به صورت عددی و با شبیه‌سازی مونت کارلو ارزیابی می‌شود. برای این کار، شبیه‌سازی پرنده به تعداد ۵۰۰ بار در حضور نویزهای سفید اندازه‌گیری (مطابق قبل) اجرا می‌شود. علاوه بر این، ضرایب آیرودینامیکی و مشخصه‌های لختی پرنده (ارائه شده در جدول ۲) به طور تصادفی به مقدار $\pm 3\%$ درصد تغییر داده می‌شود. در حالتی که پرنده ابتدا در زاویه فراز صفر درجه قرار دارد، خلبان خودکار آن یک ورودی پله زاویه فراز را با دامنه ۱۰ درجه و در مدت ۱۰ ثانیه اجرا می‌کند. در این حالت، میانگین تجمعی زمان‌های نشست^۱ (که در آن، خروجی زاویه فراز به ۵٪ مقدار نهایی خود می‌رسد) و میانگین تجمعی فراجهش^۲ برای ۵۰۰ بار اجرا در شکل ۲۶ و شکل ۲۷ نشان داده شده‌است. نتایج ارائه شده در این دو شکل نشان می‌دهد که ۵۰۰ بار اجرا برای همگرایی مشخصه‌های آماری در تحلیل مونت کارلو کافی است. برای بررسی پایداری کنترل کننده به صورت عددی، شاخص زیر برای حلقه کنترل زاویه فراز تعریف شده‌است [۴۷].

$$R_{TE} = \frac{\int_5^{10} (\theta_{des}(t) - \theta(t))^2 dt}{\int_0^5 (\theta_{des}(t) - \theta(t))^2 dt} \quad (19)$$




شکل ۲۱: تاریخچه نرخ فراز مطلوب و نرخ فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای در حضور نویز اندازه‌گیری



شکل ۲۲: تاریخچه ورودی کنترلی بالابر با حلقه درونی دومرحله‌ای در حضور نویز اندازه‌گیری

۴-۵ بررسی حساسیت کنترل کننده به اغتشاش ورودی

اغتشاش ورودی به صورت آسیب در سطح کنترلی بالابر بررسی می‌شود. این آسیب در دو شرایط تغییرات آرام و ناگهانی در مساحت بالابر اتفاق می‌افتد. در شرایط اول، به آرامی و در مدت ۱۲۰ ثانیه، اندازه ضریب کنترلی بالابر یعنی $C_{m\delta_e}$ به مقدار ۷۰٪ و اندازه ضریب پایداری طولی پرنده یعنی $C_{m\alpha}$ به مقدار ۵۰٪ کمتر می‌شود. در شرایط دوم، به صورت ناگهانی و در ثانیه ۱۲۰، اندازه $C_{m\delta_e}$ به مقدار ۵۰٪ و اندازه $C_{m\alpha}$ به مقدار ۳۵٪ کمتر می‌شود. در این حالت، نتایج شبیه‌سازی پرنده با کنترل کننده درونی دومرحله‌ای در شکل ۲۳ تا شکل ۲۵ نشان داده شده‌است. مشاهده می‌شود که کنترل کننده در مقابل تغییرات آرام کاملاً مقاوم است و عملکرد کنترلی تضعیف نمی‌شود. همچنین، در مقابل تغییرات ناگهانی کنترل کننده به سرعت اغتشاش را مستهلک می‌کند و خروجی‌های سامانه منطبق بر ورودی‌های مطلوب می‌شود.



شکل ۲۳: تاریخچه زاویه فراز مطلوب و زاویه فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای در حضور اغتشاش ورودی


² overshoot

¹ settling time


اعمال ساختار کنترلی به شبیه‌سازی غیرخطی شش درجه آزادی پرنده نشان داد که عملکرد آن مناسب است. همچنین، عملکرد اعمال کنترل‌کننده درونی به هر دو صورت تک مرحله‌ای و دو مرحله ارزیابی و مقایسه شد. به علاوه، عملکرد کنترل‌کننده در حضور نویزهای اندازه‌گیری و اغتشاش در ورودی بررسی شد و مقاومت بودن کنترل‌کننده در این شرایط بررسی شد. در نهایت، پایداری کنترل‌کننده به صورت عددی و با تحلیل مونت کارلو نشان داده شد.

مراجع

- [1] Perdakis, T., & Psarakis, S. (2019). A survey on multivariate adaptive control charts: Recent developments and extensions. *Quality and Reliability Engineering International*, 35(5), 1342-1362.
- [2] Benosman, M. (2018). Model-based vs data-driven adaptive control: an overview. *International Journal of Adaptive Control and Signal Processing*, 32(5), 753-776.
- [3] Landau, I. D., Lozano, R., M'Saad, M., & Karimi, A. (2011). *Adaptive control: algorithms, analysis and applications*. Springer Science & Business Media.
- [4] Zhen, Z., Tao, G., Yu, C., & Xue, Y. (2019). A multivariable adaptive control scheme for automatic carrier landing of UAV. *Aerospace Science and Technology*, 92, 714-721.
- [5] Zhen, Z., Tao, G., Xu, Y., & Song, G. (2019). Multivariable adaptive control based consensus flight control system for UAVs formation. *Aerospace Science and Technology*, 93, 105336.
- [6] Andrievsky, B., Kudryashova, E. V., Kuznetsov, N. V., & Kuznetsova, O. A. (2020). Aircraft wing rock oscillations suppression by simple adaptive control. *Aerospace Science and Technology*, 105, 106049.
- [7] Outeiro, P., Cardeira, C., & Oliveira, P. (2021). Multiple-model adaptive control architecture for a quadrotor with constant unknown mass and inertia. *Aerospace Science and Technology*, 117, 106899.
- [8] Lei, W., Li, C., & Chen, M. Z. (2018). Robust adaptive tracking control for quadrotors by combining PI and self-tuning regulator. *IEEE Transactions on Control Systems Technology*, 27(6), 2663-2671.
- [9] Miao, Y., Wang, X., Miao, Y., & Wang, S. (2020). Dynamics and adaptive fault-tolerant flight control under structure damage of horizontal stabilizer. *Aerospace Science and Technology*, 106, 106135.
- [10] Xue, Y. X., Zhen, Z. Y., Yang, L. Q., & Wen, L. D. (2020). Adaptive fault-tolerant control for carrier-based UAV with actuator failures. *Aerospace Science and Technology*, 107, 106227.



شکل ۲۶: میانگین تجمعی فراجهش خروجی در ۵۰۰ بار اجرای شبیه‌سازی حلقه بسته با کنترل درونی دو مرحله‌ای



شکل ۲۷: میانگین تجمعی زمان نشست خروجی در ۵۰۰ بار اجرای شبیه‌سازی حلقه بسته با کنترل درونی دو مرحله‌ای

که در آن $\theta(t)$ تاریخچه زمانی خروجی زاویه فراز و $\theta_{des}(t)$ تاریخچه زمانی زاویه فراز مطلوب است. این شاخص بیانگر نسبت خطای ردیابی در نیمه دوم بازه زمانی شبیه‌سازی به خطای ردیابی در نیمه اول است. میانگین، بدترین، بهترین و انحراف معیار این شاخص برای ۵۰۰ بار اجرا به ترتیب $2.1e-4$ ، $1.9e-3$ ، $3.4e-5$ و $2.5e-4$ است که پایداری کنترل‌کننده را به صورت عددی تایید می‌کند.

۶- جمع بندی و نتیجه گیری

در این پژوهش، یک ساختار کنترلی مبتنی بر شبکه‌های CNN برای کنترل یک پهپاد بال ثابت به روش مدل آزاد توسعه داده شد. برای طراحی کنترل‌کننده فرض شد که دینامیک و مشخصات هواپیما (به عنوان مثال، جرم، گشتاور لختی و نیروها و گشتاورهای آیرودینامیکی و پیشرانشی) ناشناخته است. بنابراین، یک مدل آزاد برای دینامیک داخلی پرنده در نظر گرفته شد و دو شبکه کانولوشن آموزش داده شد تا پارامترهای این مدل را تخمین بزنند. از پارامترهای تخمینی نیز برای طراحی کنترل‌کننده درونی استفاده شد. حلقه‌های بیرونی ساختار کنترلی نیز به روش خطی طراحی شد. برای آموزش شبکه‌های کانولوشن، از شبیه‌سازی مدل‌های آموزشی ساده استفاده شد و تاریخچه‌های ورودی-خروجی این شبیه‌سازی‌ها به شکل قابل استفاده برای شبکه‌های کانولوشن تبدیل شد. حلقه‌های درونی کنترل‌کننده به دو صورت تک مرحله‌ای و دو مرحله‌ای پیاده‌سازی شد.

- DroNet: Efficient convolutional neural network detector for real-time UAV applications. *In 2018 Design, Automation & Test in Europe Conference & Exhibition (DATE)* (pp. 967-972). IEEE.
- [22] Shao, W., Kawakami, R., Yoshihashi, R., You, S., Kawase, H., & Naemura, T. (2020). Cattle detection and counting in UAV images based on convolutional neural networks. *International Journal of Remote Sensing*, 41(1), 31-52.
- [23] Padhy, R. P., Verma, S., Ahmad, S., Choudhury, S. K., & Sa, P. K. (2018). Deep neural network for autonomous uav navigation in indoor corridor environments. *Procedia computer science*, 133, 643-650.
- [24] Chhikara, P., Tekchandani, R., Kumar, N., Chamola, V., & Guizani, M. (2020). DCNN-GA: A deep neural net architecture for navigation of UAV in indoor environment. *IEEE Internet of Things Journal*, 8(6), 4448-4460.
- [۲۶] آقابابایی، مجید، موسوی، سیدمحمد رضا، خزایی پول، پیمان، و خوشه، محمد. (۱۳۹۶). بهبود کیفیت تصاویر در ناوبری پهپاد با استفاده از روش فراتفکیک پذیری مبتنی بر شبکه عصبی کانولوشنی با ننگاشت چندلایه. *دریافتون*، ۴ (۱)، ۱-۱۱. SID. <https://sid.ir/paper/251899/fa>
- [25] Back, S., Cho, G., Oh, J., Tran, X. T., & Oh, H. (2020). Autonomous UAV trail navigation with obstacle avoidance using deep neural networks. *Journal of Intelligent & Robotic Systems*, 100(3), 1195-1211.
- [26] Dai, X., Mao, Y., Huang, T., Qin, N., Huang, D., & Li, Y. (2020). Automatic obstacle avoidance of quadrotor UAV via CNN-based learning. *Neurocomputing*, 402, 346-358.
- [27] Zhang, Z., Zohren, S., & Roberts, S. (2019). Deeplob: Deep convolutional neural networks for limit order books. *IEEE Transactions on Signal Processing*, 67(11), 3001-3012.
- [28] Brownlee, J. (2017). *Long short-term memory networks with python: develop sequence prediction models with deep learning*. Machine Learning Mastery.
- [29] Al-Emadi, S., & Al-Senaid, F. (2020, February). Drone detection approach based on radio-frequency using convolutional neural network. *In 2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT)* (pp. 29-34). IEEE.
- [30] Hui, X., Bai, J., Wang, H., & Zhang, Y. (2020). Fast pressure distribution prediction of airfoils using deep learning. *Aerospace Science and Technology*, 105, 105949.
- [31] Guo, X., Li, W., & Iorio, F. (2016, August). Convolutional neural networks for steady flow approximation. *In Proceedings of the 22nd ACM*
- [۱۱۱] نوابی، محمد، و ردایی، محمد. (۱۳۹۳). کنترل تطبیقی سیستم‌های کنترل پرواز در حضور خرابی عملگرها. مهندسی مکانیک مدرس، ۱۴(۱۶) (فوق العاده اسفند)، ۸۳-۹۳. SID. <https://sid.ir/paper/177867/fa>
- [۱۲] سازداره امیرمهدی، نجاتی جهرمی، منصور، شمس، آرش. (۱۴۰۰). کنترل پهپاد کوادروتور با استفاده از روش کنترل تطبیقی مدل مرجع. علوم رایانش و فناوری اطلاعات (۱) ۱۹-.
- [12] Bevrani, H. and Hiyama, T. (2011) *Intelligent Automatic Generation Control*. (pp. 95-121), CRC Press, Boca Raton.
- [13] Gu, W., Valavanis, K. P., Rutherford, M. J., & Rizzo, A. (2020). UAV model-based flight control with artificial neural networks: A survey. *Journal of Intelligent & Robotic Systems*, 100(3), 1469-1491.
- [14] Yuksek, B., & Inalhan, G. (2021). Reinforcement learning based closed-loop reference model adaptive flight control system design. *International Journal of Adaptive Control and Signal Processing*, 35(3), 420-440.
- [15] Koch, W., Mancuso, R., West, R., & Bestavros, A. (2019). Reinforcement learning for UAV attitude control. *ACM Transactions on Cyber-Physical Systems*, 3(2), 1-21.
- [16] Dooraki, A. R., & Lee, D. J. (2021). An innovative bio-inspired flight controller for quadrotor drones: Quad-rotor drone learning to fly using reinforcement learning. *Robotics and Autonomous Systems*, 135, 103671.
- [۱۷] شهبازی، حامد & تیکنی، وحید. (۱۳۹۷). طراحی کنترل کننده غیرخطی پهپاد چهارروتور به کمک روش ترکیبی گرادیان ازدحام ذرات. نشریه مهندسی مکانیک امیرکبیر. 50(5), 989-998. doi: 10.22060/mej.2016.859
- [18] Nobahari, H., & Seifouripour, Y. (2019, November). A Nonlinear Controller Based on the Convolutional Neural Networks. *In 2019 7th International Conference on Robotics and Mechatronics (ICRoM)* (pp. 362-367). IEEE.
- [19] Dara, S., & Tumma, P. (2018, March). Feature extraction by using deep learning: A survey. *In 2018 Second International Conference on Electronics, Communication and Aerospace Technology (ICECA)* (pp. 1795-1801). IEEE.
- [20] Schiefer, F., Kattenborn, T., Frick, A., Frey, J., Schall, P., Koch, B., & Schmidlein, S. (2020). Mapping forest tree species in high resolution UAV-based RGB-imagery by means of convolutional neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 170, 205-215.
- [21] Kyrkou, C., Plastiras, G., Theocharides, T., Venieris, S. I., & Bouganis, C. S. (2018, March).

- [44] Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [45] Nobahari, H., Alizad, M., & Nasrollahi, S. (2021). A nonlinear model predictive controller based on the gravitational search algorithm. *Optimal Control Applications and Methods*, 42(6), 1734-1761.
- [46] Zipfel, P. H. (2007). *Modeling and simulation of aerospace vehicle dynamics*. Aiaa.
- [32] Kang, Y., Chen, S., Wang, X., & Cao, Y. (2018). Deep convolutional identifier for dynamic modeling and adaptive control of unmanned helicopter. *IEEE transactions on neural networks and learning systems*, 30(2), 524-538.
- [33] Fliess, M. (2009). Model-free control and intelligent PID controllers: towards a possible trivialization of nonlinear control?. *IFAC Proceedings Volumes*, 42(10), 1531-1550.
- [34] Fliess, M., & Join, C. (2013). Model-free control. *International Journal of Control*, 86(12), 2228-2252.
- [35] Al Younes, Y., Drak, A., Noura, H., Rabhi, A., & El Hajjaji, A. (2014, May). Model-free control of a quadrotor vehicle. In *2014 International conference on unmanned aircraft systems (ICUAS)* (pp. 1126-1131). IEEE.
- [36] Wang, H., Ye, X., Tian, Y., Zheng, G., & Christov, N. (2016). Model-free-based terminal SMC of quadrotor attitude and position. *IEEE Transactions on Aerospace and Electronic Systems*, 52(5), 2519-2528.
- [37] Younes, Y. A., Drak, A., Noura, H., Rabhi, A., & Hajjaji, A. E. (2016). Robust model-free control applied to a quadrotor UAV. *Journal of Intelligent & Robotic Systems*, 84, 37-52.
- [38] Zhao, S., Wang, X., Zhang, D., & Shen, L. (2017). Model-free fuzzy adaptive control of the heading angle of fixed-wing unmanned aerial vehicles. *Journal of Aerospace Engineering*, 30(4), 04017019.
- [39] Bekcheva, M., Join, C., & Mounier, H. (2018, June). Cascaded Model-Free Control for trajectory tracking of quadrotors. In *2018 international conference on unmanned aircraft systems (ICUAS)* (pp. 1359-1368). IEEE.
- [40] Barth, J. M., Condomines, J. P., Bronz, M., Moschetta, J. M., Join, C., & Fliess, M. (2020). Model-free control algorithms for micro air vehicles with transitioning flight capabilities. *International Journal of Micro Air Vehicles*, 12, 1756829320914264.
- [41] Khosravi Samani M, Basohbat Novinzadeh A. A Multi-body Control Approach for Flapping Wing Micro Aerial Vehicles. *JoC* 2022; 16 (1) :73-87, URL: <http://joc.kntu.ac.ir/article-1-763-fa.html>
- [42] Glida, H. E., Abdou, L., Chelihi, A., Sentouh, C., & Perozzi, G. (2022). Optimal model-free fuzzy logic control for autonomous unmanned aerial vehicle. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 236(5), 952-967.
- [43] Hagan, M. T., Demuth, H. B., & Beale, M. (1997). *Neural network design*. PWS Publishing Co.