مجله کنترل
ISSN (print) 2008-8345
ISSN (online) 2538-3752
مقاله پژوهشی
جلد۱۷، شماره ۴، زمستان ۱۴۰۲، صفحه ۴۸-۳۵

کنترل مدل‌آزاد یک هواپیمای بال‌ثابت بر اساس شبکه‌های عصبی کانولوشن

یوسف صیفوری‌پور[۱]، هادی نوبهاری[۲]

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

[۲] استاد، دانشکدهٔ مهندسی هوافضا، دانشگاه صنعتی شریف،تهران، ایران nobahari@sharif.edu

دریافت: ۱۴۰۲/۰۵/۰۸ ویرایش: ۱۴۰۲/۰۸/۲۵ پذیرش: ۱۴۰۲/۰۹/۲۷

چکیده: در این پژوهش یک معماری غیرخطی مدل‌آزاد برای کنترل یک پهپاد با بال‌ثابت ارائه شده‌است. این معماری دارای حلقه‌های درونی و بیرونی است. حلقه‌های درونی که بر اساس شبکه‌های عصبی کانولوشن طراحی شده‌اند، دینامیک درونی هواپیما را به‌صورت مدل‌آزاد کنترل می‌کند. حلقه‌های بیرونی که از کنترل‌کننده‌های متداول خطی استفاده می‌کند، برای کنترل سینماتیک پرنده طراحی شده‌اند. شبکه‌های عصبی استفاده‌شده برای کنترل حلقه‌های درونی به صورت خارج از خط و بر اساس دو پایگاه داده آموزش می‌بینند تا از فرآیندهای یادگیری زمانبر به‌صورت 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 نگاشت‌شده آموزش داده شده‌است. این شبکه‌های آموزش‌دیده، همراه با کنترل‌کننده‌های خطی به صورت آبشاری، به شبیه‌سازی غیرخطی یک پرنده بال‌ثابت اعمال و عملکرد آن بررسی می‌شود. حلقه درونی کنترل‌کننده که دینامیک داخلی پرنده را کنترل می‌کند، به دو صورت تک‌مرحله‌ای و دومرحله‌ای اعمال و عملکرد آن با هم مقایسه شده‌است.

کلمات کلیدی: شبکه‌های عصبی کانولوشن، هواپیمای بال‌ثابت، کنترل‌کننده پرواز، کنترل مدل‌آزاد.

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

Yousef 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.

[Downloaded from joc-isice.ir on 2026-11-01]

[DOI: 10.61186/joc.17.4.35]

۱- مقدمه

در دهه‌های اخیر و با گسترش روزافزون استفاده از وسایل پرنده (به‌ویژه پرنده‌های بدون سرنشین بال‌ثابت)، تلاش زیادی در توسعه خلبان‌های خودکار برای این پرنده‌ها انجام شده‌است. 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 به‌معنای 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، کمی‌کردن مدل (یعنی مقداردهی پارامترهای آن) مشکل است. روش‌های تعیین پارامترهای مدل ممکن است زمانبر، گران‌قیمت، نادرست، ناقص یا در مواردی گمراه‌کننده باشد. علاوه‌بر 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. علاوه‌بر 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 شده‌است. مرجع [۲] یک نمای کلی از کنترل‌کننده‌های تطبیقی با مقایسه رویکردهای مبتنی بر مدل و رویکردهای داده‌محور ارائه داده‌است. 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 شده‌است. در مرجع [۴]، یک کنترل‌کننده تطبیقی مدل مرجع (MRAC[1]) برای فرود یک پرنده بدون سرنشین (پهپاد) با بال ثابت روی یک حامل متحرک اعمال شده‌است. این کنترل‌کننده دارای حلقه‌های درونی (به روش MRAC) و حلقه‌های بیرونی (از نوع PID[2]) برای کنترل وضعیت و موقعیت پهپاد است. روش MRAC برای انجام پرواز گروهی پهپادهای مشابه نیز استفاده شده‌است [۵]. در مرجع [۶]، کنترل‌کننده تطبیقی مدل مرجع ضمنی (IRM[3]) برای استهلاک پدیده ناخواسته بال‌نوسانی[4] یک هواپیمای بال‌ثابت استفاده شده‌است. یک کنترل‌کننده تطبیقی چند مدله نیز در مرجع [۷] برای پرواز یک پهپاد چندپره با بار بیرونی ناشناخته اعمال شده‌است. در مرجع [۸]، یک کنترل‌کننده ردیابی تطبیقی مقاوم برای یک پهپاد چندپره پیشنهاد شده‌است. حلقه‌های درونی کنترل‌کننده بر مبنای تنظیم‌کننده خودتنظیم تطبیقی (STR[5]) برای کنترل نرخ‌های زاویه‌ای پهپاد و حلقه‌های بیرونی از نوع کلاسیک تناسبی-انتگرالی (PI[6]) برای کنترل وضعیت آن طراحی شده‌است.

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[7]) برای یک هواپیمای بال‌ثابت (که تحت آسیب‌های ناخواسته در دم افقی است) پیشنهاد شده که ترکیبی از روش پسگام[8] 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 شده‌است . در این کار، سازکار تطبیقی MRAC به‌عنوان حلقه‌های درونی (برای کنترل سرعت و موقعیت پهپاد) پیاده‌سازی شده‌است 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، پیاده سازی شده‌است. این طرح کنترلی در حضور خرابی عملگرهای سکان عمودی، شهپر [9] و موتور بررسی شده‌است. در مرجع [۱۲] طراحی کنترل‌کننده تطبیقی مدل مرجع مستقیم برای محاسبه برخط پارامترهای کنترل‌کننده ریز پهپادها در حضور نویز و اغتشاش انجام شده‌است.

در کنترل‌کننده‌های تطبیقی از شبکه‌های عصبی مصنوعی (ANN[10]) 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

[1] Model Reference Adaptive Control
[2] Proportional-Integral-Derivative
[3] Implicit Reference Model
[4] wing rock
[5] Self-Tuning Regulator
[6] Proportional-Integral
[7] Adaptive Fault-Tolerant Controller
[8] backstepping
[9] Aileron
[10] Artificial Neural Network

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]

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. علاوه‌بر این، در برخی از کاربردها به‌دلیل 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[1]-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[2]) برای کنترل پرواز یک پهپاد چهارپره استفاده شده‌است. این الگوریتم می‌تواند پهپاد را در پرواز شناوری و نیز در دنبال‌کردن 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[3]) 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 پهپادهای مختلف 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 دنبال‌کردن یک دوچرخه استفاده 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 LSTM[4] [۳۰] توسعه یافته‌است تا نوسانات آتی ارزش سهام را پیش‌بینی کند. در این کار، تاریخچه زمانی نوسانات قیمت به تصاویری با ابعاد ۱۰۰×۴۰ پیکسل (یعنی ماتریس‌هایی با اندازه ۱۰۰ × ۴۰ 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 هوابرها[5] (بر اساس تصویر هندسی آن) به‌کار رفته‌است. تصویر هندسی هوابر به اندازه کافی آموزنده نیست. بنابراین، روشی به نام تابع فاصله علامت‌دار برای تبدیل هندسه ساده هوابرها به تصاویر رنگی با ابعاد ۳۲×۳۲ پیکسل به‌کار رفته‌است که عملکرد CNN را در پیش بینی توزیع فشار بهتر می‌کند. کار مشابهی برای پیش‌بینی میدان‌های جریان غیریکنواخت در اطراف اشکال دوبعدی یا سه‌بعدی بر اساس CNN در مرجع [۳۳] انجام شده است. در مرجع [۳۴]، یک ساختار مبتنی بر CNN برای شناسایی عدم قطعیت‌ها در دینامیک یک بالگرد بدون سرنشین به‌کار رفته‌است. در این کار، تاریخچه زمانی ورودی‌های کنترلی و حالت‌های دینامیکی 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[6] این شبکه‌ها، خطای بین داده‌های آزمایش پرواز و خروجی یک مدل پایه شناسایی‌شده است که ناشی از عدم قطعیت در دینامیک بالگرد می‌باشد. مدل پایه نیز با یک الگوریتم بهینه‌سازی، یعنی روش کمینه مربعات (LSM[7]) شناسایی شده‌است. در این پژوهش، از شش CCN برای تخمین عدم قطعیت در شش درجه آزادی مدل بالگرد استفاده شده‌است. سپس، از مدل‌های شناسایی‌شده (توسط LSM) و عدم قطعیت‌های شناسایی‌شده (توسط CNN) برای توسعه یک کنترل‌کننده مبتنی بر روش پسگام استفاده شده‌است.

[1] Model-Based Control
[2] Proximal Policy Optimization
[3] Convolutional Neural Network
[4] Long Short-Term Memory
[5] Airfoils
[6] Target Output
[7] Least Square Method

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]

در برخی از روش‌های کنترلی، از یک مدل غیرفیزیکی تحت عنوان مدل‌آزاد[1] [۳۵] یا مدل فراموضعی[2] [۳۶] استفاده می‌شود. برخلاف روش‌هایی که کاملا مستقل از مدل است (و به آن روش‌های جعبه‌سیاه[3] گفته می‌شود)، در روش‌های مدل‌آزاد یک مدل متغیر با زمان و ساده (که لزوما 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 مدل‌آزاد برای کنترل یک پهپاد چندپره استفاده شده‌است. در مرجع [۳۸] از روش مدل‌آزاد برای طراحی کنترل‌کننده مود لغزشی (SMC[4]) 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 بال‌ثابت توسعه یافته‌است. رویکرد کنترلی در این مرجع مبتنی بر یک سیستم استنتاج عصبی فازی تطبیقی (ANFIS[5]) برای تخمین مشتق شبه‌جزئی (PPD[6]) و یک راهبرد کنترل تطبیقی بدون مدل برای کنترل زاویه سمت پهپادهای بال‌ثابت 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.

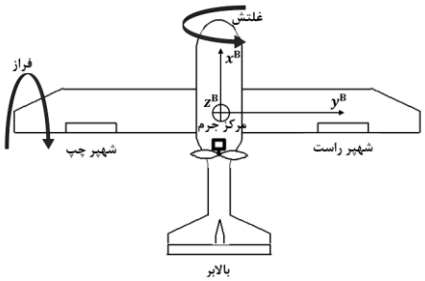
در پژوهش حاضر، یک ساختار مدل‌آزاد مبتنی بر CNN برای کنترل هواپیماهای بال‌ثابت توسعه داده شده‌است. فرض می‌شود که دینامیک هواپیما ناشناخته است و نیز ممکن است در طول زمان تغییر کند. این معماری شامل دو CNN است که با استفاده از یادگیری نظارت‌شده و به صورت خارج از خط آموزش می‌بینند. بنابراین، نیازی به روش‌های 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 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 مدل‌آزاد با استفاده از شبکه‌های کانولوشن
- اعمال روش کنترل مدل‌آزاد به‌صورت دومرحله‌ای

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 مدل‌آزاد در طراحی کنترل‌کننده پرنده بال‌ثابت ارائه شده‌است. این ساختار کنترلی مناسب پرنده‌های بال‌ثابت از نوع غلتش-برای-گردش (BTT[7]) است. در این ساختار از عملگرهای شهپر و بالابر[8] (معرفی‌شده در شکل ۱) برای کنترل کانال غلتش[9] (زاویه و نرخ غلتش) و کانال فراز[10] (زاویه و نرخ فراز) به‌صورت آبشاری 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 بیرونی‌تر خلبان‌خودکار مانند کنترل زاویه سمت و نیز کنترل ارتفاع پرنده بررسی نمی‌شود.



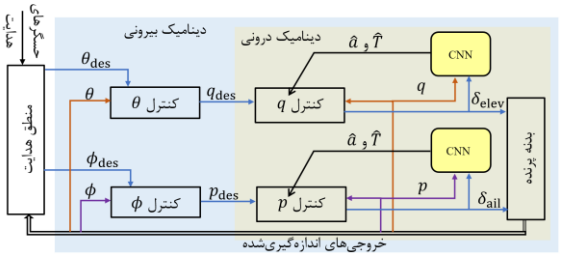
شکل ۱: معرفی محورهای قاب بدنی و سطوح کنترلی پرنده

[1] Model-Free
[2] Ultra-Local Model
[3] Black-Box
[4] Sliding Mode Control
[5] Adaptive Neuro-Fuzzy Inference System
[6] Pseudo Partial Derivative
[7] Bank-To-Turn
[8] Elevator
[9] Roll
[10] Pitch

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]

۲-۱ ساختار کلی کنترل‌کننده

خروجی بسیاری از الگوریتم‌های هدایت در پرنده‌های بال‌ثابت، زوایای غلتش و فراز مطلوب است. بنابراین، ساختار کنترل‌کننده 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 شهپر (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 به‌عنوان ورودی مطلوب به حلقه‌های کنترل درونی داده می‌شود. این حلقه‌های درونی مبتنی بر CNN هستند که بر اساس متغیرهای تخمین‌شده $\hat{a}$ و $\hat{T}$ کار می‌کند و جزئیات آن در بخش‌های بعد ارائه می‌شود. همچنین، حسگرهای پرنده نیز زوایا و نرخ‌های فراز و غلتش را در هر لحظه اندازه‌گیری می‌کند. در این پژوهش، از کنترل‌کننده‌های مبتنی بر CNN و به روش مدل‌آزاد برای کنترل دینامیک درونی هواپیما و از کنترل‌کننده‌های خطی برای کنترل زوایای غلتش و فراز هواپیما استفاده شده‌است.



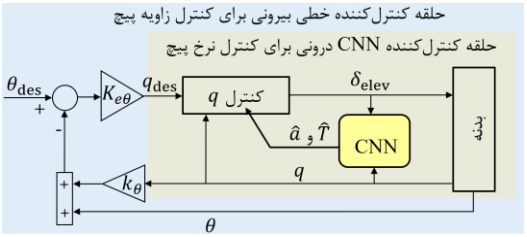
شکل ۲: ساختار انتخاب‌شده برای کنترل‌کننده هواپیمای بال‌ثابت

همانطور که در شکل ۲ آمده‌است، دو کانال غلتش و فراز هواپیما با استفاده از دو کنترل‌کننده آبشاری 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. به‌عنوان مثال، حلقه درونی و حلقه بیرونی کانال فراز در شکل ۳ آمده‌است. این شکل متشکل از دو حلقه کنترل زاویه و نرخ فراز است که ورودی مطلوب فراز در بخش هدایت خلبان‌خودکار محاسبه می‌شود. خروجی نهایی این دو حلقه متوالی آبشاری نیز دستور بالابر است که به پرنده اعمال می‌شود. در این پژوهش، راهبرد کنترل برای حلقه‌های درونی، طراحی کنترل کننده‌های مدل‌آزاد مبتنی بر CNN است به طوری که حلقه‌های بسته درونی از مدل‌های مرجع خود به شرح زیر پیروی کند:

$$\frac{\mathrm{P}(s)}{\mathrm{P}_{\mathrm{des}}(s)}=\frac{1}{\mathrm{d}_p s+1} \qquad (۱)$$

$$\frac{\mathrm{Q}(s)}{\mathrm{Q}_{\mathrm{des}}(s)}=\frac{1}{\mathrm{d}_q s+1} \qquad (۲)$$

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



شکل ۳: ساختار کنترل‌کننده کانال فراز

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

$$K_{e\phi}=\mathrm{d}_{\mathrm{p}}\omega_{\phi_{\mathrm{des}}}^2 \qquad (۳)$$

$$K_{e\theta}=\mathrm{d}_{\mathrm{q}}\omega_{\theta_{\mathrm{des}}}^2 \qquad (۴)$$

$$K_\phi(s)=k_\phi s+1=\frac{2\xi_{\phi_{\mathrm{des}}}\omega_{\phi_{\mathrm{des}}}\mathrm{d}_{\mathrm{p}}-1}{K_{e\phi}}s+1 \qquad (۵)$$

$$K_\theta(s)=k_\theta s+1=\frac{2\xi_{\theta_{\mathrm{des}}}\omega_{\theta_{\mathrm{des}}}\mathrm{d}_{\mathrm{q}}-1}{K_{e\theta}}s+1 \qquad (۶)$$

که در آن $\omega_{i_{\mathrm{des}}}$ و $\xi_{i_{\mathrm{des}}} \ (i=\phi,\theta)$ ثابت‌های مدل مرجع بیرونی و جز متغیرهای طراحی کنترل‌کننده 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:

$$\frac{\Phi(s)}{\Phi_{\mathrm{des}}(s)}=\frac{\omega_{\phi_{\mathrm{des}}}^2}{s^2+2\xi_{\phi_{\mathrm{des}}}\omega_{\phi_{\mathrm{des}}}s+\omega_{\phi_{\mathrm{des}}}^2} \qquad (۷)$$

$$\frac{\Theta(s)}{\Theta_{\mathrm{des}}(s)}=\frac{\omega_{\theta_{\mathrm{des}}}^2}{s^2+2\xi_{\theta_{\mathrm{des}}}\omega_{\theta_{\mathrm{des}}}s+\omega_{\theta_{\mathrm{des}}}^2} \qquad (۸)$$

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 به‌صورت جبری قابل محاسبه است و کنترل‌کننده نیز به‌صورت علّی[1] خواهد بود. ذکر این نکته ضروری است که ثابت‌های d_p، d_q، $\omega_{\phi_{\mathrm{des}}}$، $\xi_{\phi_{\mathrm{des}}}$، $\omega_{\theta_{\mathrm{des}}}$ و $\xi_{\theta_{\mathrm{des}}}$ متغیرهای طراحی کنترل‌کننده هستند که توسط کاربر و متناسب با سرعت و نیز محدودیت‌های دینامیکی پرنده تحت کنترل مقداردهی می‌شوند.

[1] Causal

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]

۲-۲ کنترل مدل‌آزاد حلقه‌های درونی

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

$$y^{\upsilon} = f + \beta u \tag{۹}$$

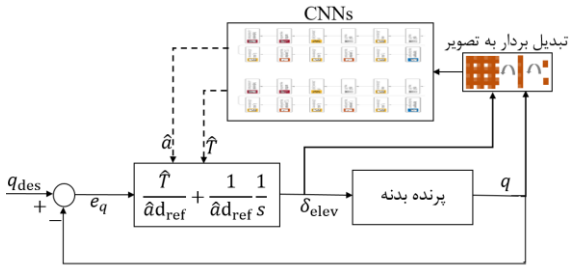
که در آن $\upsilon \geq 1$ درجه مشتق مدل، β یک عدد ثابت غیرفیزیکی (که توسط کاربر مقداردهی می‌شود) و f بیانگر دینامیک ناشناخته سامانه و اغتشاشات وارد بر آن است که باید به‌صورت برخط محاسبه شود. مقدار υ معمولا برابر با یک یا دو (در بیشتر موارد برابر با یک) فرض می‌شود. در این پژوهش، مدل‌آزاد حاکم بر دینامیک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

$$\dot{y} = -\frac{1}{T}y + \frac{a}{T}u \tag{۱۰}$$

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 مدل‌آزاد پایه، در این پژوهش مقدار β غیرثابت فرض شده‌است. در این حالت، اگر بهره کنترلی حلقه‌های درونی به‌صورت زیر اعمال شود (شکل ۴):

$$K_{\text{ideal}}(s) = \frac{\hat{T}s+1}{\hat{a}\,\mathrm{d}_{\text{ref}}s} = \frac{\hat{T}}{\hat{a}\,\mathrm{d}_{\text{ref}}} + \frac{1}{\hat{a}\,\mathrm{d}_{\text{ref}}}\frac{1}{s} \tag{۱۱}$$

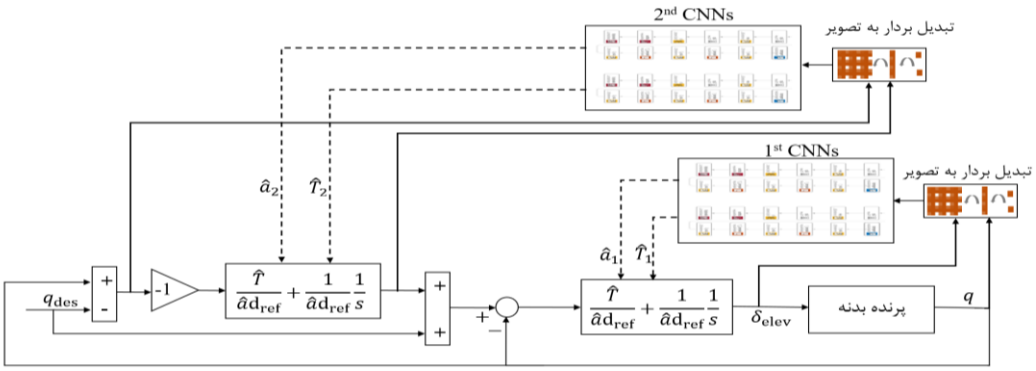
آنگاه تابع تبدیل دینامیک حلقه‌بسته درونی همان توابع ارائه‌شده در روابط (۱) و (۲) خواهد بود. ثابت d_{ref} در این رابطه متغیر طراحی کنترل‌کننده است که در دو رابطه فوق معادل d_p و d_q است.



شکل ۴: ساختار حلقه درونی کنترل‌کننده مبتنی بر CNN برای کنترل نرخ فراز به‌صورت تک‌مرحله‌ای

۲-۳ کنترل دومرحله‌ای حلقه‌های درونی

در کنترل مدل‌آزاد فرض می‌شود که دینامیک سامانه مشابه مدل ارائه‌شده در رابطه (۹) است. در این پژوهش نیز فرض شده‌است که مدل ارائه‌شده در رابطه (۱۰) بر دینامیک داخلی پرنده حاکم است و بر این اساس، کنترل‌کننده 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 کنترل‌کننده K_{ideal}) نیز کماکان مشابه مدل ارائه‌شده در رابطه (۱۰) است و دوباره کنترل‌کننده 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 کاملا یکسان است. مرحله اول این کنترل‌کننده کاملا مشابه بخش قبل است که ورودی مرجع آن (که از خروجی مرحله دوم محاسبه می‌شود) تغییر کرده‌است. در مرحله دوم نیز به‌جای خروجی سامانه (یعنی q)، اختلاف خروجی و ورودی مطلوب (یعنی $e_q = -q_{\text{des}} + q$) و به‌جای ورودی کنترلی (یعنی δ_{elev})، خروجی کنترل‌کننده مرحله دوم به شبکه‌های کانولوشن این مرحله داده می‌شود.



شکل ۵: ساختار حلقه درونی کنترل‌کننده مبتنی بر CNN برای کنترل نرخ فراز به‌صورت دومرحله‌ای

این کار (یعنی کنترل 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 کنترل مجدد کفایت می‌کند و مراحل بیشتر کنترل باعث افزایش بار محاسباتی و نیز شدیدتر شدن دستورات کنترلی می‌شود. لازم به ذکر است که کنترل دومرحله‌ای تنها روی حلقه درونی اعمال می‌شود و حلقه بیرونی (که از نوع خطی است) تغییر نمی‌کند.

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]

۳- تهیه پایگاه داده برای آموزش شبکه‌های کانولوشن

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، n_p مدل آموزشی با پارامترهای مختلف a_t و T_t شبیه‌سازی و با ورودی‌های تصادفی به مدت کافی تحریک می‌شود:

$$G_t(s)=\frac{a_t}{T_t s+1} \qquad (۱۲)$$

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:

$$\begin{aligned}\boldsymbol{U}_j&=\left[u(\delta_d),u(2\delta_d),\dots,u(N_j\delta_d)\right]^T\\&=\left[u_1,u_2,\dots,u_{N_j}\right]^T\\\boldsymbol{Y}_j&=\left[y(\delta_d),y(2\delta_d),\dots,y(N_j\delta_d)\right]^T\\&=\left[y_1,y_2,\dots,y_{N_j}\right]^T\\\boldsymbol{D}_{Y_j}&=\left[d_y(\delta_d),d_y(2\delta_d),\dots,d_y(N_j\delta_d)\right]^T\\&=\left[d_{y_1},d_{y_2},\dots,d_{y_{N_j}}\right]^T\end{aligned} \qquad (۱۳)$$

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، $u_i\ (i=1,2,\dots,N_j)$ تاریخچه ورودی هر مدل و d_{y_i} تاریخچه تفاوت خروجی است که به صورت زیر محاسبه می‌شود.

$$d_{y_i}=y_i-y_{i-1}\ ,\ \ i=1,2,\dots,N_j \qquad (۱۴)$$

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

$$\begin{aligned}\boldsymbol{u}_h(k)&=\left[\boldsymbol{U}_j^T(k)\quad \boldsymbol{U}_j^T(k+1)\quad \dots\quad \boldsymbol{U}_j^T(k+n_h-1)\right]^T\\\boldsymbol{y}_h(k)&=\left[\boldsymbol{Y}_j^T(k)\quad \boldsymbol{Y}_j^T(k+1)\quad \dots\quad \boldsymbol{Y}_j^T(k+n_h-1)\right]^T\\\boldsymbol{d}_{y_h}(k)&=\left[\boldsymbol{D}_{Y_j}^T(k)\quad \boldsymbol{D}_{Y_j}^T(k+1)\quad \dots\quad \boldsymbol{D}_{Y_j}^T(k+n_h-1)\right]^T\end{aligned} \qquad (۱۵)$$

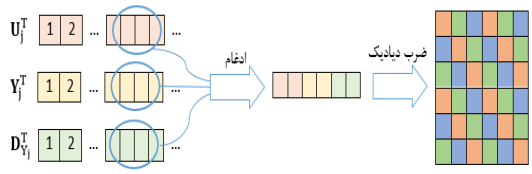
که در آن $k=\left[1,2,\dots,N_j-n_h+1\right]$، $j=1,2,\dots,n_p$ و n_h طول هر بردار است. سپس، این سه بردار با هم ادغام می‌شود تا بردارهای بزرگتر را به صورت زیر ایجاد کند:

$$\boldsymbol{p}_h(k)=\left[\boldsymbol{u}_h^T(k),\boldsymbol{y}_h^T(k),\boldsymbol{d}_{y_h}{}^T(k)\right]^T \qquad (۱۶)$$

و در نهایت، ماتریس‌های مربعی زیر که بیانگر تصاویر ورودی به شبکه است، از ضرب دیادیک[1] بردار $\boldsymbol{p}_h(k)$ به‌صورت زیر محاسبه می‌شود:

$$\boldsymbol{P}_h(k)=\left(\boldsymbol{p}_h(k)\right)\left(\boldsymbol{p}_h(k)\right)^T \qquad (۱۷)$$

که دارای $n_h \times 3$ سطر و $3 \times n_h$ ستون است. این کار برای تمامی n_p 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. به ازای 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

٤- جزئیات اعمال شبکه‌های کانولوشن

علاوه‌بر 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 ۲۷*۲۷ پیکسل (یعنی $n_h=9$)، لایه کانولوشن با ۱۵ فیلتر ۶*۶، لایه تابع فعال‌سازی از نوع ReLU، لایه کانولوشن با ۳۰ فیلتر ۴*۴، لایه تابع فعال‌سازی از نوع ReLU، لایه کانولوشن با ۶۰ فیلتر ۲*۲، لایه تابع فعال‌سازی از نوع علامت[2]، لایه کاملا متصل[3] با ۱۳ گره، لایه بیشینه هموار[4] و لایه طبقه‌بندی[5] است.

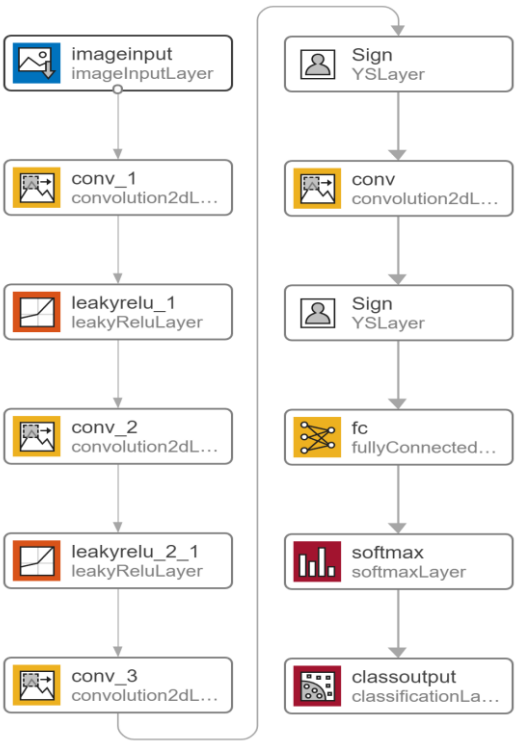
لازم به ذکر است که تعداد لایه‌ها و تعداد گره‌های هر لایه از این شبکه‌ها به روش عمومی‌سازی[6] [۴۵] تعیین شده‌است تا تعمیم‌پذیر باشد؛ به‌این صورت که تعداد لایه‌ها و گره‌ها ابتدا کم در نظر گرفته شده و به مرور آنقدر زیاد می‌شود تا عملکرد شبکه شروع به افت‌کردن کند. این فرآیند در شکل ۸ نشان داده شده‌است. در 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

[1] Dyadic
[2] Sign
[3] fully connected layer
[4] softmax
[5] classification
[6] Generalization

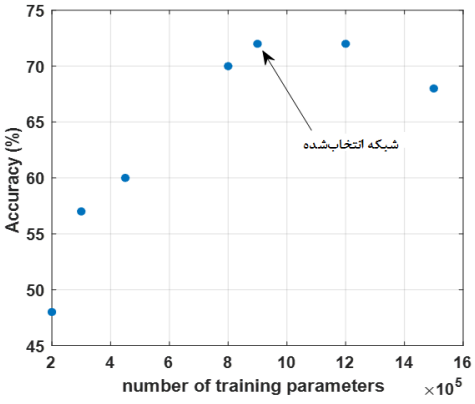
[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]

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

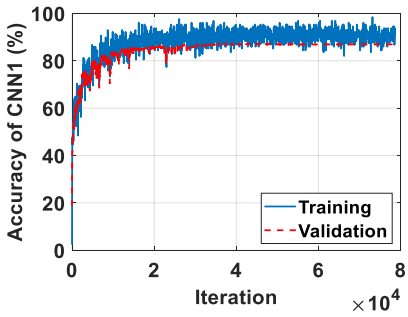


شکل ۷: ساختار هر دو شبکه CNN مورد استفاده

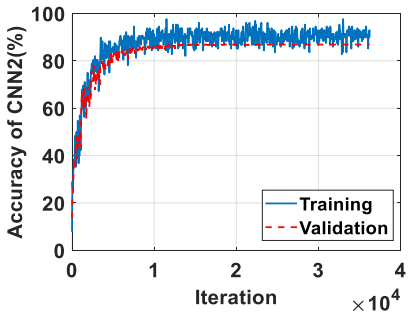
مدل‌های آموزشی با ورودی تصادفی با دامنه 10- تا 10+ تحریک شده و تاریخچه ورودی–خروجی آن‌ها با گام زمانی 0.01 sec نمونه برداری می‌شود. لازم به ذکر است که در این پژوهش، آموزش و پیاده‌سازی شبکه‌ها و نیز شبیه‌سازی‌های پرنده و کنترل‌کننده در محیط نرم‌افزار متلب–سیمولینک انجام شده‌است. برای هر پایگاه داده، ترتیب تمامی جفت ورودی–خروجی‌های آموزشی به هم ریخته می‌شود. سپس، ۸۰٪ از این داده‌های مخلوط‌شده برای آموزش هر شبکه انتخاب می‌شود و بقیه داده‌ها، برای اعتبارسنجی آموزش استفاده می‌شود. این دو شبکه عصبی به‌روش بهینه‌سازی Adam[1] [۴۶] آموزش داده شده‌است. نرخ یادگیری اولیه روی 1e-3 تنظیم شده‌است و با ادامه آموزش در هر دوره[2]، مقدار نرخ یادگیری ۴۰ درصد کاهش می‌یابد. پارامتر تنظیم L2[3] نیز برابر 1e-6 بوده و برای همه لایه‌های شبکه ثابت است. نتایج آموزش این دو شبکه در شکل ۹ و شکل ۱۰ ارائه شده‌است. مشاهده می‌شود که با آموزش شبکه اول دقت آن در تعیین مقدار $\hat{a}_t$ (در واقع، تعیین کلاس آن بین ۲۱ کلاس تعریف‌شده) به ۸۸٪ و با آموزش شبکه دوم دقت آن در تعیین مقدار $\hat{T}_t$ (در واقع، تعیین کلاس آن بین ۱۳ کلاس تعریف‌شده) به ۸۷٪ رسیده‌است.



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 کنترل‌کننده مبتنی بر CNN، از آن برای کنترل یک پهپاد بال‌ثابت در محیط شبیه‌سازی سیمولینک–متلب استفاده می‌شود. این شبیه‌سازی به‌صورت شش درجه آزادی و غیرخطی است. مشخصات هندسی، عملکردی و آیرودینامیکی این پهپاد در جدول ۱ و جدول ۲ آمده‌است. معرفی این ضرایب و مشخصات در مرجع [۴۸] آمده‌است. مدل دینامیکی عملگرهای کنترلی شهپر و بالابر پرنده به‌صورت زیر در نظر گرفته شده‌است:

$$G_{act} = \frac{1}{0.5s + 1} \qquad (۱۸)$$

[1] ADAptive Moment estimation
[2] epoch
[3] L_2 regularization parameter

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]

مقدار لقی[1] 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 $\xi_{i_{des}} = 0.8$ و فرکانس طبیعی حلقه‌های بیرونی $\omega_{i_{des}} = 1$ فرض شده‌است. همچنین، فرض شده‌است که دستوارت کنترل‌کننده با پنج میلی‌ثانیه تاخیر صادر می‌شود.

جدول۱: مشخصات هندسی و عملکردی پهپاد تحت کنترل

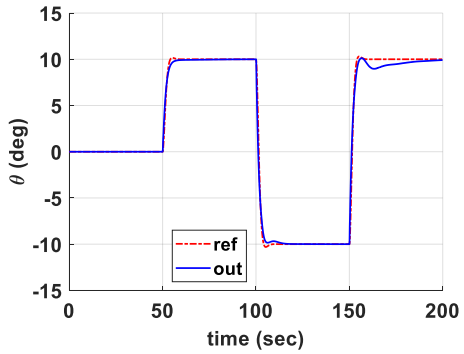
مشخصه	مقدار
طول بدنه	۴.۳ متر
پهنای بال	۵.۱۵ متر
وزن کل	۲۰۵ کیلوگرم
نوع موتور	پیستونی با توان ۲۶ اسب بخار
مداومت پروازی	۵ ساعت
سرعت پرواز	۱۲۰ کیلومتر بر ساعت
حداکثر نرخ اوج‌گیری	۴ متر بر ثانیه
سرعت واماندگی	۸۰ کیلومتر بر ساعت

جدول۲: مشخصات و ضرایب آیرودینامیکی و ممان اینرسی پهپاد تحت کنترل

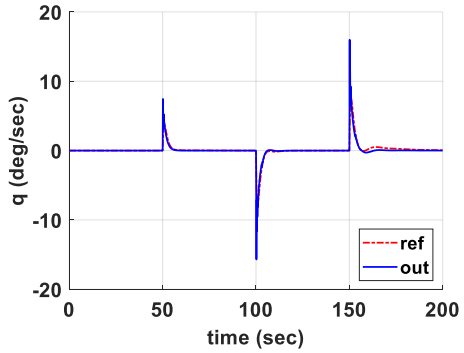
مشخصه	مقدار	مشخصه	مقدار
طول مرجع طولی	۰.۵۵ متر	$C_{L_{\delta e}}$	۰.۴
طول مرجع عرضی	۵.۱۵ متر	C_{L_q}	۸.۱
مساحت مرجع	۲.۸ متر	C_{Y_β}	−۰.۸
Ixx	۴۷ kg.m^2	C_{l_β}	−۰.۰۲
Iyy	۹۱ kg.m^2	C_{l_p}	−۰.۴۵
Izz	۱۱۱ kg.m^2	C_{l_r}	۰.۲۶
Ixy	۵ kg.m^2	$C_{l_{\delta a}}$	−۰.۱۶
Ixz	−۱۰ kg.m^2	C_{m_0}	۰.۰۷
Iyz	−۶ kg.m^2	C_{m_α}	−۲.۱
C_{D_0}	۰.۰۶	$C_{m_{\delta e}}$	−۱.۷۶
C_{D_α}	۰.۴۳	C_{m_q}	−۳۴.۴
$C_{D_{\delta e}}$	۰.۰۲	C_{n_β}	۰.۱۱
C_{L_0}	۰.۳۹	C_{n_p}	−۰.۱۱
C_{L_α}	۴.۸	C_{n_r}	−۰.۲

۵-۱ نتایج شبیه‌سازی با کنترل تک‌مرحله‌ای

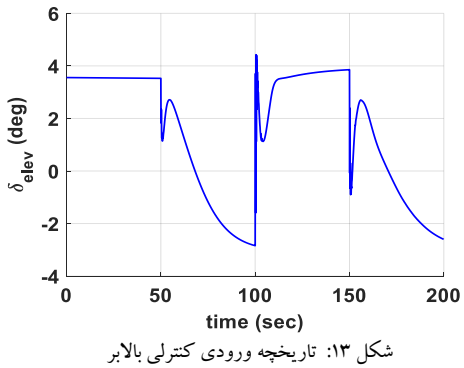
نتایج شبیه‌سازی کنترل‌کننده به‌صورت تک‌مرحله‌ای در شکل ۱۱ تا شکل ۱۶ نشان داده شده‌است. در این سناریوها، پرنده زوایای فراز بین دو مقدار ۱۰- و ۱۰+ درجه و زوایای غلتش بین دو مقدار ۲۰- و ۲۰+ درجه را تجربه می‌کند. مشاهده می‌شود که ورودی‌های کنترلی هموار است و تنشی به سازه هواپیما وارد نمی‌کند. همچنین، خروجی‌های پرنده، در حلقه‌های بیرونی و درونی، به‌خوبی ورودی‌های مطلوب را دنبال می‌کند. با این حال، دقت کنترل در دنبال‌کردن ورودی مطلوب، به‌خصوص در مورد کانال فراز پرنده، کامل نیست و کمی خطای ردیابی وجود دارد.



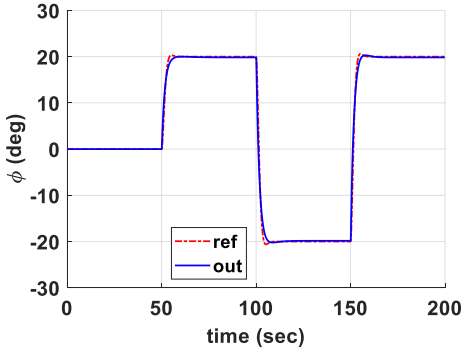
شکل ۱۱: تاریخچه زاویه فراز مطلوب و زاویه فراز خروجی شبیه‌سازی



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



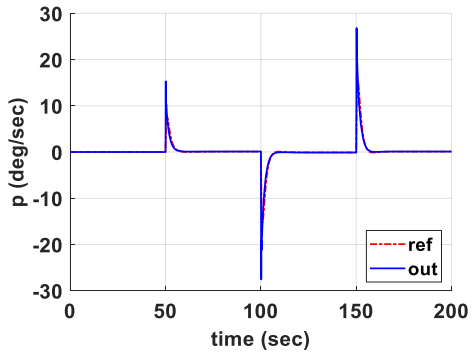
شکل ۱۳: تاریخچه ورودی کنترلی بالابر



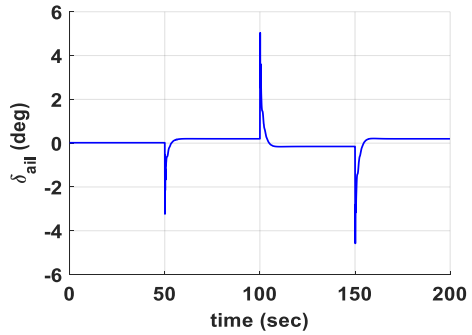
شکل ۱۴: تاریخچه زاویه غلتش مطلوب و زاویه غلتش خروجی شبیه‌سازی

[1] Backlash

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]



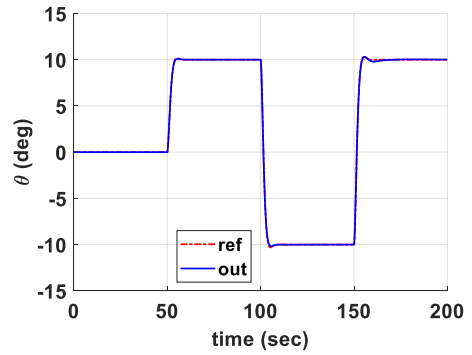
شکل ۱۵: تاریخچه نرخ غلتش مطلوب و نرخ غلتش خروجی شبیه‌سازی



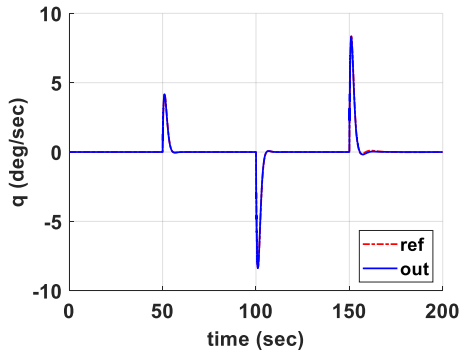
شکل ۱۶: تاریخچه ورودی کنترلی شهپر

۵-۲ نتایج شبیه‌سازی با کنترل دومرحله‌ای

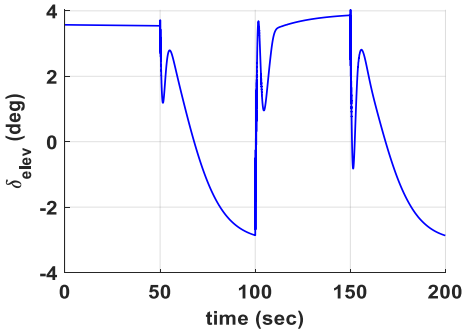
با هدف کم‌کردن خطای ردیابی، حلقه‌های درونی کنترل‌کننده به‌صورت دومرحله‌ای به شبیه‌سازی پرنده اعمال می‌شود. نتایج این شبیه‌سازی، به‌عنوان مثال برای کانال فراز پرنده، در شکل ۱۷ تا شکل ۱۹ آمده‌است. با بررسی این نتایج می‌توان گفت که خطای ردیابی کنترل‌کننده در این حالت بسیار ناچیز است و خروجی کانال نرخ فراز پرنده با کنترل‌کننده دو مرحله‌ای به‌خوبی ورودی مطلوب را دنبال می‌کند. همچنین، ورودی کنترلی بالابر نسبت به کنترل تک‌مرحله‌ای تغییرات کمی داشته و مقادیر آن کمی بیشتر شده‌است. 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 شده‌است.



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



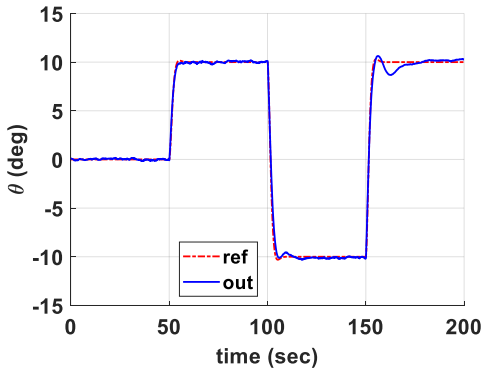
شکل ۱۸: تاریخچه نرخ فراز مطلوب و نرخ فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای



شکل ۱۹: تاریخچه ورودی کنترلی بالابر با حلقه درونی دومرحله‌ای

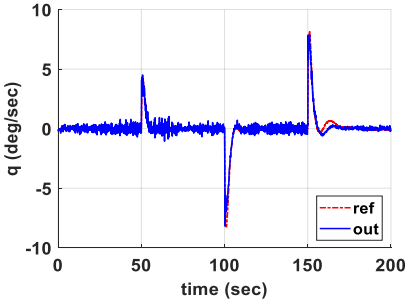
۵-۳ بررسی حساسیت کنترل‌کننده به نویز اندازه‌گیری

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 کنترل‌کننده درونی دومرحله‌ای (ارائه‌شده در شکل ۲۰ تا شکل ۲۲) نشان می‌دهد که عملکرد کنترل‌کننده در دنبال‌کردن ورودی‌های مطلوب مناسب بوده و ورودی‌های کنترلی هموار و ملایم است. این نتایج نشان می‌دهد که کنترل‌کننده در مقابل نویز اندازه‌گیری عملکرد مناسبی دارد. دلیل این امر ناشی از وجود عبارت انتگرال‌گیری در کنترل‌کننده ایده‌آل حلقه درونی (رابطه ۱۱) و عدم وجود عبارت مشتق‌گیر است.

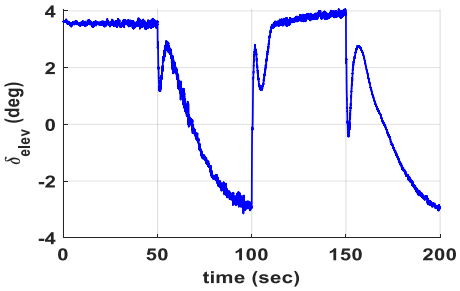


شکل ۲۰: تاریخچه زاویه فراز مطلوب و زاویه فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای در حضور نویز اندازه‌گیری

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]



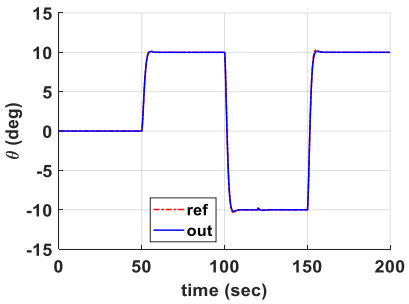
شکل ۲۱: تاریخچه نرخ فراز مطلوب و نرخ فراز خروجی شبیه‌سازی با حلقه درونی دومرحله‌ای در حضور نویز اندازه‌گیری



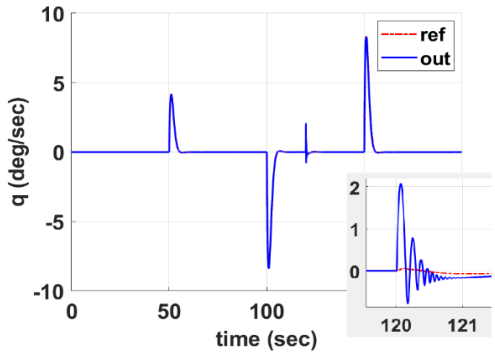
شکل ۲۲: تاریخچه ورودی کنترلی بالابر با حلقه درونی دومرحله‌ای در حضور نویز اندازه‌گیری

۵-۴ بررسی حساسیت کنترل‌کننده به اغتشاش ورودی

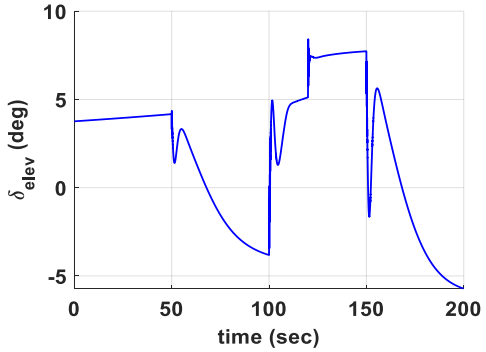
اغتشاش ورودی به‌صورت آسیب در سطح کنترلی بالابر بررسی می‌شود. این آسیب در دو شرایط تغییرات آرام و ناگهانی در مساحت بالابر اتفاق می‌افتد. در شرایط اول، به آرامی و در مدت ۱۲۰ ثانیه، اندازه ضریب کنترلی بالابر یعنی $C_{m_{\delta e}}$ به مقدار ۷۰٪ و اندازه ضریب پایداری طولی پرنده یعنی $C_{m_{\alpha}}$ به مقدار ۵۰٪ کمتر می‌شود. در شرایط دوم، به‌صورت 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 کنترل‌کننده درونی دومرحله‌ای در شکل ۲۳ تا شکل ۲۵ نشان داده شده‌است. مشاهده می‌شود که کنترل‌کننده در مقابل تغییرات آرام کاملا مقاوم است و عملکرد کنترلی تضعیف نمی‌شود. همچنین، در مقابل تغییرات ناگهانی کنترل‌کننده 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



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 کنترل‌کننده

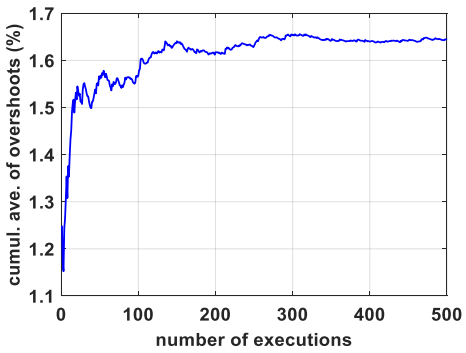
پایداری کنترل‌کننده دومرحله‌ای به‌صورت عددی و با شبیه‌سازی مونت کارلو ارزیابی می‌شود. برای این کار، شبیه‌سازی پرنده به تعداد ۵۰۰ بار در حضور نویزهای سفید اندازه‌گیری (مطابق قبل) اجرا می‌شود. علاوه‌بر این، ضرایب آیرودینامیکی و مشخصه‌های لختی پرنده (ارائه‌شده در جدول ۲) به‌طور تصادفی به مقدار ±۳۰ درصد 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[1] (که در آن، خروجی زاویه فراز به ۵٪ مقدار نهایی خود می‌رسد) و میانگین تجمعی فراجهش[2] برای ۵۰۰ بار اجرا در شکل ۲۶ و شکل ۲۷ نشان داده شده‌است. نتایج ارائه‌شده در این دو شکل نشان می‌دهد که ۵۰۰ بار اجرا برای همگرایی مشخصه‌های آماری در تحلیل مونت‌کارلو کافی است. برای بررسی پایداری کنترل‌کننده به صورت عددی، شاخص زیر برای حلقه کنترل زاویه فراز تعریف شده‌است [۴۷].

$$R_{TE} = \frac{\int_5^{10} \left(\theta_{\text{des}}(t) - \theta(t)\right)^2 dt}{\int_0^5 \left(\theta_{\text{des}}(t) - \theta(t)\right)^2 dt} \qquad (۱۹)$$

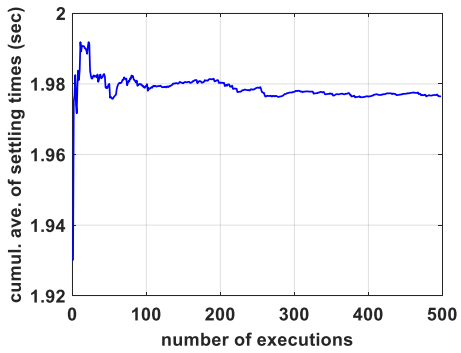
[1] settling time

[2] overshoot

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]



شکل ۲۶: میانگین تجمعی فراجهش خروجی در ۵۰۰ بار اجرای شبیه‌سازی حلقه‌بسته با کنترل درونی دومرحله‌ای



شکل ۲۷: میانگین تجمعی زمان نشست خروجی در ۵۰۰ بار اجرای شبیه‌سازی حلقه‌بسته با کنترل درونی دومرحله‌ای

که در آن $\theta(t)$ تاریخچه زمانی خروجی زاویه فراز و $\theta_{\mathrm{des}}(t)$ 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 به‌صورت عددی تایید می‌کند.

٦- جمع‌بندی و نتیجه‌گیری

در این پژوهش، یک ساختار کنترلی مبتنی بر شبکه‌های CNN برای کنترل یک پهپاد بال‌ثابت 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 بزند. 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 تک‌مرحله‌ای و دومرحله‌ای پیاده‌سازی شد.

اعمال ساختار کنترلی به شبیه‌سازی غیرخطی شش‌درجه‌آزادی پرنده نشان داد که عملکرد آن مناسب است. همچنین، عملکرد اعمال کنترل‌کننده درونی به هر دو صورت تک‌مرحله‌ای و دومرحله ارزیابی و مقایسه شد. به‌علاوه، عملکرد کنترل‌کننده در حضور نویزهای اندازه‌گیری و اغتشاش در ورودی بررسی شد و مقاوم‌بودن کنترل‌کننده در این شرایط بررسی شد. در نهایت، پایداری کنترل‌کننده به‌صورت عددی و با تحلیل مونت‌کارلو نشان داده شد.

مراجع

[1] Perdikis, 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.

[Downloaded from joc-isice.ir on 2026-11-01]

[DOI: 10.61186/joc.17.4.35]

[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] سازدار, امیرمهدی, نجاتی‌جهرمی, 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 Ratons.

[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 کنترل‌کننده غیرخطی پهپاد چهارروتور به کمک روش ترکیبی گرادیان ازدحام ذرات .نشریه مهندسی مکانیک امیرکبیر .998-989 ,(5)50 , 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., & Schmidtlein, 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). 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، سیدمحمدرضا، خزایی پول، پیمان، و خویشه، محمد. (۱۳۹۶). بهبود کیفیت تصاویر در ناوبری پهپاد با استفاده از روش فراتفکیک پذیری مبتنی بر شبکه عصبی کانولوشنی با نگاشت چندلایه. دریافنون، 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*

[Downloaded from joc-isice.ir on 2026-11-01]
[DOI: 10.61186/joc.17.4.35]

[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.

SIGKDD international conference on knowledge discovery and data mining (pp. 481-490).

[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.

[Downloaded from joc-isice.ir on 2026-11-01]

[DOI: 10.61186/joc.17.4.35]