

مروری بر رویکرد یادگیری عمیق در صنعت هوافضا

مهلا رئوف مقدم^{*}، دانشجوی مقطع دکتری، مسعود ابراهیمی^۲، دانشیار

^۱ دانشکده مهندسی مکانیک - دانشگاه تربیت مدرس - تهران - ایران - m_raoufmoghadam@modares.ac.ir

^۲ دانشکده مهندسی مکانیک - دانشگاه تربیت مدرس - تهران - ایران - ebrahimikm@modares.ac.ir

چکیده: در سال‌های اخیر، یادگیری عمیق به محرک اصلی راه‌حل‌های نوآورانه برای مسائل هوش مصنوعی تبدیل گردیده که این امر با افزایش مقدار داده‌های موجود، افزایش منابع محاسباتی و تکنیک‌های بهبودیافته در آموزش شبکه‌های عمیق امکان‌پذیر شده است. پیشرفت و افزایش توان پردازش رایانه‌ها و توانمندتر شدن تکنیک‌های هوش مصنوعی مانند یادگیری ماشین و یادگیری عمیق، زمینه را برای اجرا-شدن بسیاری از طرح‌های هوافضایی آسان‌تر نموده است. استدلال‌های نظری و بیولوژیکی نشان می‌دهند که در راستای ساخت سیستمی هوشمند با توانایی استخراج بازنمایی‌های سطح بالا و قدرتمند از داده‌ها، نیاز به مدل‌هایی با معماری عمیقی است که شامل بسیاری از لایه-های پردازشی غیرخطی می‌باشد. شاید بتوان گفت، بهترین و پرکاربردترین نمونه از این شبکه‌ها، به دلیل سازگاری آن با انواع داده‌ها، شبکه‌های عصبی چندلایه هستند. شبکه‌های عصبی عمیق ساختارهای متفاوت، انواع مختلف و گونه‌های متنوعی را دارا هستند و با توجه به نوع داده‌ها و هدف مسئله از آنها استفاده می‌شود و هر کدام دارای نقاط قوت و ضعف خود را دارا هستند. در این مقاله به بررسی و کاربرد این شبکه‌ها در مسائل مختلف هوافضایی پرداخته شده است.

واژه‌های کلیدی: یادگیری عمیق، شبکه عصبی مصنوعی، شبکه عمیق، یادگیری انتقالی، یادگیری هندسی

* مهلا رئوف مقدم، m_raoufmoghadam@modares.ac.ir

Application of deep learning in aerospace industry

Mahla Raouf Moghadam ^{1*}, PhD student, Masoud Ebrahimi ², Associate Professor

¹ Aerospace Department. Faculty of Mechanical Engineering, Tarbiat Modares, Tehran, Iran,
m_raoufmoghadam@modares.ac.ir

² Aerospace Department. Faculty of Mechanical Engineering, Tarbiat Modares, Tehran, Iran, ebrahimikm@modares.ac.ir

Abstract: In recent years, deep learning has become the main motive of innovative solutions to artificial intelligence problems, which is made possible by increasing the amount of data available, increasing computing resources, and improving techniques in deep network training. The development and increase of computer processing power and the empowerment of artificial intelligence techniques such as machine learning and deep learning have made it easier for many aerospace projects to be implemented. Theoretical and biological arguments show that in order to build an intelligent system with the ability to extract high-level and powerful representations from data, models with deep architecture that include many nonlinear processing layers are needed. Arguably, the best and most widely used examples of these networks are multilayer neural networks due to their compatibility with data types. Deep neural networks have different structures, different types, and species, and they are used according to the type of data and the purpose of the problem, and each has its strengths and weaknesses. In this article, the study and application of these networks in various aerospace issues are discussed.

Keywords: *deep learning, artificial neural network, deep network, transfer learning, geometric learning*

* Mahla Raouf Moghadam, m_raoufmoghadam@modares.ac.ir

۱. مقدمه

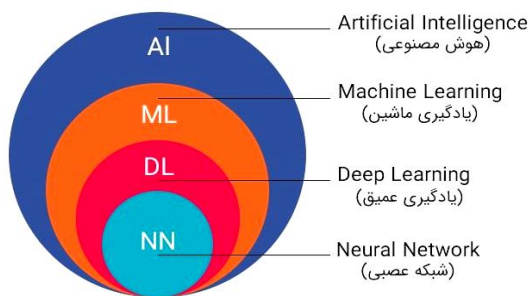
در سال‌های اخیر، یادگیری عمیق به محرک اصلی برای راه‌حل‌های نوآورانه در مسائل هوش مصنوعی تبدیل گردیده که این امر با افزایش مقدار داده‌های موجود، افزایش منابع محاسباتی و تکنیک‌های بهبودیافته در آموزش شبکه‌های عمیق امکان‌پذیر شده است [1].

در حالت کلی تفاوت‌هایی بین «هوش مصنوعی»، «شبکه‌های عصبی»، «یادگیری عمیق»^۳ و «یادگیری ماشینی»^۴ وجود دارد. اصطلاح هوش مصنوعی زمانی به کار می‌رود که یک دستگاه توانایی انجام کارها بدون نیاز به هوش بشری را دارد. درون هوش مصنوعی، یک مفهوم جدید با نام یادگیری ماشینی خلق شده است. زمانی که ماشین قابلیت فراگیری موارد جدید و کسب مهارت از طریق تجربه و بدون دخالت کاربر را داشته باشد، از عبارت یادگیری ماشینی استفاده می‌شود. در یادگیری ماشینی، از دو مفهوم شبکه عصبی (با الهام از ساختار مغز) و یادگیری عمیق استفاده می‌شود. بنابراین، یادگیری عمیق

بخشی از یادگیری ماشینی، و یادگیری ماشینی خود بخشی از هوش مصنوعی به حساب می‌آید.

۲. شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی یا سیستم‌های اتصال‌گر، سیستم‌های محاسبه‌گری هستند که از شبکه‌های عصبی زیستی تشکیل دهنده ذهن حیوانات الهام گرفته شده‌اند. این سیستم‌ها، با بررسی مثال‌ها، فعالیت‌ها را یاد می‌گیرند (به عبارت دیگر عملکرد خود را در انجام فعالیت‌ها به مرور بهبود می‌دهند) و عموماً این اتفاق بدون هیچ برنامه‌نویسی خاصی انجام می‌شود. این شبکه‌ها بیشترین استفاده را در برنامه‌هایی دارند که بیان آنها با یک الگوریتم سنتی که از برنامه‌نویسی قاعده‌بنیان استفاده می‌کند، دشوار است.



شکل (۱): ارتباط بین هوش مصنوعی و یادگیری ماشینی و عمیق

شبکه عصبی مصنوعی، مجموعه‌ای از واحدهای متصل یا گره، به نام نورون‌های مصنوعی (مشابه نورون‌های زیستی در یک مغز

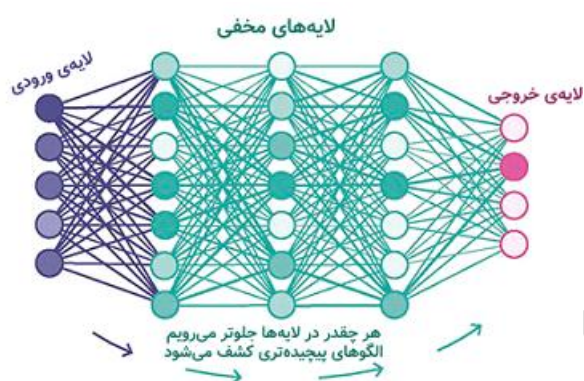
¹ Artificial intelligence

² Neural network

³ Deep learning

⁴ Machin learning

یادگیری عمیق یک نوع شبکه عصبی بوده که در آن هر لایه‌ی پنهان، مسئول آموزش مجموعه‌ای از ویژگی‌های منحصربفرد بوده که براساس خروجی لایه پیشین عمل می‌کند. شبکه عصبی عمیق، یک شبکه عصبی چند لایه است که چندین لایه مخفی دارد (شکل ۲). شبکه عصبی عمیق در جایگاه نتیجه نهایی یادگیری ماشین قرار دارد و قانون یادگیری، الگوریتمی است که مدل (شبکه عصبی عمیق) را از داده‌های آموزش استخراج می‌کند [3]. الگوریتم‌های یادگیری عمیق، دارای معماری ویژه با تعداد لایه‌های فراوان بوده که در یک شبکه قرار دارند.



شکل (۲): نمونه شبکه عصبی عمیق [4]

در یادگیری عمیق بر خلاف یادگیری ماشین، مساله به قسمت‌های کوچکتر تقسیم نشده و به صورت کامل حل می‌شود (شکل ۳). همانطور که انسان‌ها از طریق تجربه، چیزهای جدید یاد می‌گیرند، الگوریتم یادگیری عمیق نیز با هر بار تکرار یک کار، مهارت خود را نسبت به دفعات قبلی بهبود می‌بخشد [5].

یادگیری ماشین (Machine Learning)



یادگیری عمیق (Deep Learning)



زیستی)، می‌باشد. هر اتصال (سیناپس) میان نورون‌ها می‌تواند سیگنالی را از یک نورون به نورون دیگر انتقال دهد. نورون دریافت‌کننده (پست سیناپتیک) می‌تواند سیگنال(ها) و سپس نورون‌های پایین دستی سیگنال متصل به آن(ها) را پردازش کند. نورون‌ها ممکن است دارای حالت باشند، که معمولاً با اعداد حقیقی بین ۰ و ۱ نمایش داده می‌شود. نورون‌ها و سیناپس‌ها نیز ممکن است وزن داشته باشند که با پیشرفت یادگیری، تنظیم می‌شوند. این وزن منجر به کاهش یا افزایش قدرت سیگنال‌های ارسالی به نورون‌های پایین دستی می‌شود.

معمولاً نورون‌ها در لایه‌ها سازماندهی می‌شوند. لایه‌های مختلف ممکن است تبدیلات مختلفی روی ورودی خود، اعمال کنند. سیگنال‌ها از اولین لایه (ورودی) به آخرین لایه (خروجی) سفر می‌کنند، و در این میان ممکن است بعضی لایه‌ها چندین بار طی شوند.

هدف آغازین رویکرد شبکه‌های عصبی، حل مسئله به روش ذهن انسان بود. به مرور زمان، توانایی‌های خاص ذهنی مورد توجه قرار گرفت، و منجر به تمایلات به سمت زیست‌شناسی، مثل پس‌انتشار^۱، یا انتقال داده‌ها در جهت عکس و تنظیم شبکه برای انعکاس این اطلاعات، گردید.

تا سال ۲۰۱۷، شبکه‌های عصبی معمولاً از چند هزار تا چند میلیون واحد و اتصال برخوردار بودند. گرچه این عدد به مراتب کوچکتر از تعداد نورون‌های مغز انسان است، اما این شبکه‌ها می‌توانند فعالیت‌های زیادی را در سطح فرآیند انسانی انجام دهند [2].

۳. یادگیری عمیق و شبکه عصبی عمیق

¹ Backpropagation

شکل (۳): تفاوت یادگیری ماشین و یادگیری عمیق [6]

شکل (۴): نوار زمانی تکنولوژی هوش مصنوعی [8]


۱.۳. تاریخچه یادگیری عمیق

- ۱۹۴۰: با عناوین متفاوتی مانند فرمان‌شناسی و ارتباط-گرایی و مشهورترین آن، یعنی شبکه عصبی وجود داشته است.
 - ۱۹۴۳: اولین مدل توسط مک کلاچ و پیترز ارائه گردید.
 - ۱۹۵۷: الگوریتم پرسپترون توسط روزنبلات ارائه شد.
 - ۱۹۶۹: مینسکی و پاپرت با چاپ مقاله نشان دادند که پرسپترون فقط مسائل خطی را حل می‌کند.
 - ۱۹۷۴: الگوریتم پس‌انتشار توسط وربوس ارائه شد.
 - ۱۹۸۶: الگوریتم پس‌انتشار توسط روملهاث ارائه شد.
 - ۱۹۹۸: الگوریتم پس‌انتشار توسط لکان ارائه شد.
- وربوس، روملهاث و لکان سبب احیای شبکه عصبی شده و در تحقیقات خود توانستند شبکه چندلایه را آموزش دهند [1].
- ۲۰۱۲: تیمی تحت رهبری دالی، با استفاده از شبکه‌های عصبی چندلایه در چالش فعالیت مولکولی مرک پیروز شد.
 - ۲۰۱۴: از یادگیری عمیق در شناسایی اثرات سمی و نامطلوب مواد شیمیایی در تغذیه، فرآورده‌های خانگی و دارو استفاده شد. [7].
- سال‌های ۲۰۱۲ و ۲۰۱۴ را می‌توان به عنوان انقلاب بزرگ در یادگیری عمیق یاد کرد. شکل ۴ تاریخچه پیدایش یادگیری عمیق را نشان می‌دهد.

۲.۳. انواع یادگیری عمیق

استدلال‌های نظری و بیولوژیکی نشان می‌دهند که در راستای ساخت سیستمی هوشمند با توانایی استخراج بازنمایی‌های سطح بالا و قدرتمند از داده‌ها، نیاز به مدل‌هایی با معماری عمیق است که شامل بسیاری از لایه‌های پردازشی غیرخطی می‌باشد. شاید بتوان گفت، بهترین و پرکاربردترین نمونه از این شبکه‌ها، به دلیل سازگاری آن با انواع داده‌ها، شبکه‌های عصبی چندلایه هستند. قواعد یادگیری، رویه‌ای برای اصلاح وزن‌ها و بایاس‌ها هستند که در راستای آموزش شبکه برای انجام کار خاصی مورد استفاده قرار می‌گیرد.

- **یادگیری بانظارت^۱ عمیق:** موفقیت شگفت‌آور یادگیری عمیق، عمدتاً با الگوریتم‌های بانظارت، حاصل شده است. در این نوع یادگیری شبکه‌های عصبی مانند پیش‌خور^۲، بازگشتی^۳ و همگشتی یا پیچشی^۴ به ازای ورودی‌ها، خروجی متناظر به شبکه نشان داده می‌شود و تغییر وزن‌ها تا موقعی صورت می‌گیرد که اختلاف خروجی شبکه با خروجی مطلوب، در حد قابل قبول باشد.
- **یادگیری بازنمایی بدون نظارت^۵ عمیق:** اخیراً، علاقه زیادی به یادگیری بدون نظارت با معرفی دو مدل مولد عمیق جدید به ویژه، شبکه مولد تخصصی^۶ و



¹ Supervised learning

² Feedforward Neural Network

³ Recurrent Neural Network

⁴ convolutional neural network

⁵ Unsupervised Learning

⁶ Generative Adversarial Networks

شکل (۵): یادگیری تقویتی، یادگیری عمیق و یادگیری تقویتی عمیق [1]

- **یادگیری انتقالی^۳ عمیق:** ایده اصلی یادگیری انتقالی این است که با یک شبکه یادگیری عمیق، فرآیند یادگیری آغاز شود که از قبل برای یک مساله مشابه آموزش داده شده است. همین امر، می تواند به میزان قابل توجهی نیاز به داده های آموزشی و زمان آموزش در دامنه هدف را کاهش دهد. به همین دلیل استفاده از یادگیری انتقالی در یادگیری عمیق در حال حاضر بسیار محبوب است [9].

- **یادگیری عمیق هندسی^۴:** یادگیری عمیق هندسی، تقریباً زمینه نوظهور تحقیقاتی است که سعی در تعمیم معماری یادگیری عمیق برای کار با داده های غیراقلیدسی دارد، تا این شکاف را پر کند. داده های غیراقلیدسی می توانند مفاهیم پیچیده تری را با دقت بیشتری نسبت به نمایش های یک بعدی و دو بعدی نشان دهند. یکی از ساختارهای غیراقلیدسی مهم، گراف می باشد. داده ها با ساختار گراف در دنیای واقعی فراوان و در همه جا دیده می شوند [10].

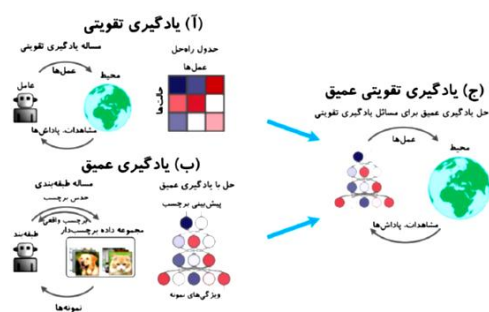
۳.۳. ساختارهای اصلی یادگیری عمیق

ساختارهای مهم و اصلی یادگیری عمیق (شکل ۶) عبارتند از:

- پیش خوران
- پس خوران
- دوجتهی

شبکه خودرمننگار^۱ متغیر بوجود آمده است. پیش بینی می شود که یادگیری بدون نظارت نقش مهمی در آینده یادگیری عمیق داشته باشد. در این نوع یادگیری، باید به دنبال یافتن الگوی شباهت میان داده ها و دسته بندی آنها درون خوشه ها بود [8]. در واقع وزن ها بر اساس ورودی ها اصلاح می شوند و خروجی مطلوب وجود ندارد تا با مقایسه خروجی شبکه با آن و تعیین مقدار خطا، وزن ها اصلاح شوند.

- **یادگیری تقویتی^۲ عمیق:** هنگام برخورد با ورودی های بسیار بزرگ، یادگیری تقویتی از مشکل نمایش نامناسب ویژگی ها رنج می برد. بنابراین، یادگیری آرامی را به همراه دارد و باید تکنیک هایی برای سرعت بخشیدن به روند یادگیری، طراحی شود. به همین سبب، زمینه جدیدی با عنوان یادگیری تقویتی عمیق برای کمک به حل یادگیری تقویتی در مسائل با ابعاد بالا ظاهر شد. یادگیری تقویتی عمیق، با ترکیب مزایای یادگیری عمیق و یادگیری تقویتی در جهت ساخت سیستم های هوش مصنوعی تلاش می کند (شکل ۵).




³ Transfer Learning

⁴ Geometric deep learning

¹ Autoencoder

² Reinforcement Learning

شکل (۶): ساختارهای اصلی یادگیری عمیق



۴.۳. معماری‌های یادگیری عمیق

در جدول ۱ خلاصه‌ای از چندین مدل معمول یادگیری عمیق و همچنین معماری‌های پیشرو که در سال‌های اخیر معرفی شده، آمده است [12-15].

جدول (۱): خلاصه مدل‌های یادگیری عمیق

مدل	دسته‌بندی	مدل یادگیری	نوع داده‌های ورودی	مشخصات
AE	Generative	نظارت نشده	مختلف	مناسب برای استخراج ویژگی، کاهش ابعاد تعداد واحدهای ورودی و خروجی برابر خروجی داده ورودی را بازسازی می‌کند. با داده‌های بدون برچسب کار می‌کند.
RNN	Discriminative	با نظارت	سریال، سری زمانی	توالی داده‌ها از طریق حافظه داخلی پردازش می‌شود. با داده‌های LOT در کاربردهای وابسته به زمان مفید است.
RBM	Generative	نظارت نشده، بانظارت	مختلف	مناسب برای استخراج ویژگی، کاهش ابعاد، طبقه‌بندی روش آموزش گران و پرهزینه
DBN	Generative	نظارت نشده، بانظارت	مختلف	مناسب برای کشف ویژگی سلسله مراتبی آموزش لایه به لایه شبکه
LSTM	Discriminative	بانظارت	سریال، سری زمانی، داده‌های وابسته به زمان طولانی	کارایی خوب با داده با تاخیر طولانی دسترسی به سلول حافظه توسط دروازه محافظت می‌شود.
CNN	Discriminative	بانظارت	دوبعدی (تصویری، صدا و غیره)	لایه‌های متحرک بزرگترین بخش محاسبات را می‌گیرند. DNN اتصال کمتر نسبت به نیاز به یک مجموعه داده‌های آموزشی بزرگ برای وظایف بصری
VAE	Generative	نیمه نظارت	مختلف	Auto-encoder یک کلاس از مناسب برای کمبود داده‌های برچسب گذاری شده

GAN	ترکیبی	نیمه نظارت	مختلف	مناسب برای داده‌های نویزدار متشکل از دو شبکه: 1-Generator 2-Discriminator
Ladder Net	ترکیبی	نیمه نظارت	مختلف	مناسب برای داده‌های نویزی متشکل از سه شبکه: دو رمز گذار و یک رمزگشا

تناسب این معماری‌های پردازشی با محاسبات ماتریسی و برداری، آموزش را بطور چشمگیری تسریع کرده‌اند.

به عنوان گزینه‌ای دیگر، ممکن است مهندسان به دنبال انواع دیگری از شبکه‌های عصبی با الگوریتم‌های آموزشی همگراتر باشند. کنترلگر محاسباتی مدل مخچه چنین شبکه عصبی است و نیازمند نرخ یادگیری یا وزن‌های اولیه تصادفی نیست. همگرایی فرایند آموزشی را با یک دسته داده جدید می‌توان در یک گام تضمین کرد، و پیچیدگی محاسباتی الگوریتم آموزشی نسبت به تعداد نورون‌های درگیر، خطی است.

محققان در دانشگاه ام‌آی‌تی، آزمایشگاه هوش مصنوعی واتسون، کالج بین‌المللی آندروود و دانشگاه برزیلیا به این موضوع پی برده‌اند که در حال نزدیک شدن به محدودیت‌های محاسباتی برای یادگیری عمیق هستند.

در این تحقیق جدید اعلام شده که پیشرفت در یادگیری عمیق، با اشتهای بی‌پایان انسان‌ها برای قدرت محاسباتی همراه است و توسعه بیشتر، نیاز به روش‌های محاسباتی بسیار کارآمدتر دارد.

یادگیری عمیق به طور تصادفی گران نیست، بلکه طراحی باعث چنین موضوعی می‌شود. انعطاف‌پذیری یادگیری عمیق، مدل‌سازی پدیده‌های مختلف و کنار زدن مدل‌های دیگر بطور چشمگیری محاسبات را گران‌تر می‌کند..

محققان برای پی بردن به این موضوع که چرا یادگیری عمیق از نظر محاسباتی گران است، مقیاس‌پذیری آماری و محاسباتی آن‌ها را به صورت تئوری تحلیل کردند.

آن‌ها چنین کاری را با دو تحلیل جداگانه از الزامات محاسباتی انجام دادند:

۵.۳. چالش‌ها

ممکن است مشکلات زیادی برای شبکه‌های عصبی عمیق همانند شبکه‌های عصبی مصنوعی، که بسیار ساده آموزش داده شده‌اند، بوجود آید. دو مسئله متداول، بیش-برازش و زمان محاسبه هستند.

به دلیل اضافه شدن لایه‌های انتزاعی، که امکان مدل‌سازی وابستگی‌های نادر را در داده‌های آموزش ایجاد می‌کند، شبکه‌های عصبی عمیق مقابل بیش-برازش آسیب‌پذیر هستند. روش‌های منظم‌سازی از قبیل هرس کردن واحد اواخنکو، یا زوال وزنی (منظم سازی نرم ۲) یا تُنکی (منظم سازی نرم ۱) را می‌توان طی آموزش برای مقابله با بیش-برازش استفاده کرد. به عنوان گزینه‌ای دیگر، منظم‌سازی بیرون انداز، طی آموزش، واحدهایی را بطور تصادفی از لایه‌های پنهان حذف می‌کند. این کار به حذف وابستگی‌های نادر کمک می‌کند. در نهایت، داده‌ها را می‌توان با روش‌هایی مثل برش و چرخش، بگونه‌ای افزون کرد که مجموعه‌های آموزشی کوچکتر اندازه بزرگتری پیدا کنند تا احتمال بیش-برازش کاهش یابد.

شبکه‌های عصبی عمیق باید پارامترهای آموزشی فراوانی را در نظر بگیرند، مثل اندازه (تعداد لایه‌ها و تعداد واحدها در هر لایه) سرعت یادگیری و وزن‌های اولیه. جاروب کردن فضای پارامتر برای پیدا کردن پارامترهای بهینه ممکن است به علت هزینه زمانی و منابع محاسباتی، بهینه نباشد. راهکارهای متفاوتی مثل دسته‌سازی (محاسبه گرادیان در چند مثال آموزشی بطور همزمان، نه جداگانه) محاسبه را تسریع می‌کنند. توانایی‌های پردازشی وسیع در معماری‌های با هسته‌های زیاد به علت

پایین شبکه عصبی با لایه‌های عمیق، عدم امکان آموزش مناسب شبکه عصبی است و معمولاً الگوریتم پس‌انتشار با سه مشکل اساسی زیر در فرآیند آموزش شبکه عصبی عمیق مواجه است:

- گرادیان محوشونده
- بار محاسباتی
- بیش برآش^۳

۴. کاربرد یادگیری عمیق در هوافضا

با پیشرفت روز افزون علم بشر، یادگیری عمیق جایگاه ویژه‌ای در صنعت هوافضا پیدا کرده است. به طور کلی از کاربردهای الگوریتم‌های یادگیری عمیق در صنعت هوافضا می‌توان به موارد زیر اشاره کرد:

- شبیه‌سازی مسیر پرواز
 - سیستم‌های کنترلی و هدایت وسایل پرنده
 - ناوبری وسایل پرنده
 - خلبان‌های خودکار
 - شبیه‌سازی اجزای وسایل پرنده
 - تشخیص خطا در اجزای وسایل پرنده
 - پردازش تصاویر
- همچنین می‌توان به کاربرد این فناوری در وسایل مختلف پرنده اشاره کرد:

۱.۴ کاربرد یادگیری عمیق در موشک و فضاپیما

در سال‌های اخیر، یادگیری عمیق در موشک و فضاپیماها تأثیر بسزایی داشته است که می‌توان به تحقیقات زیر اشاره کرد:

- تعداد عملیات‌های نقطه شناور موردنیاز برای یک گذر در شبکه
- توانایی محاسباتی سخت افزار مورد استفاده در آموزش مدل

محققان پس از تحلیل خود به این موضوع پی بردند که تنها سه سال بهبود الگوریتمی معادل افزایش ۱۰ برابری قدرت محاسباتی است. اگر پیشرفت در این زمینه با چنین سرعتی دنبال شود، الزامات محاسباتی یادگیری عمیق از نظر فنی، اقتصادی و محیط زیستی به سرعت تبدیل به مانع می‌شوند. با این وجود شاید سخت افزارها نیز بهبود پیدا کنند.

آنها متوجه شدند که بار محاسباتی واقعی مدل‌های یادگیری عمیق مقیاس‌پذیری سریع‌تری نسبت به مرزهای پایینی در تئوری دارند که نشان‌دهنده امکان پیشرفت‌های اساسی در این بخش است.

به گفته محققان، پیشرفت‌های یادگیری عمیق در سطح الگوریتمی همیشه در حال رخ دادن است که برخی از آنها شامل شتاب‌دهنده سخت افزاری می‌شود.

۶.۳ بهبود شبکه عصبی عمیق

بیشتر مدل‌های یادگیری عمیق مدرن، مبتنی بر شبکه‌های عصبی مصنوعی هستند، گرچه ممکن است شامل فرمول‌های گزاره‌ای یا متغیرهای پنهان سازمان یافته لایه‌ای در مدل‌های مولد همچون گره‌ها در شبکه‌های باور عمیق^۱ و ماشین‌های بولتزمن^۲ عمیق نیز باشند.

به رغم موفقیت‌های چشمگیر، یادگیری عمیق در حقیقت فناوری ویژه‌ای برای عرضه ندارد و ابداع شبکه عصبی عمیق، نتیجه تجمیع تعداد زیادی بهبود فنی کوچک است. دلیل کارایی

¹ Deep belief Network

² Boltzmann Machine

³ overfitting

جدول (۲): یادگیری عمیق در موشک و فضاپیما

ردیف	موضوع	نوع یادگیری
۱	فرمان و کنترل فضاپیما	یادگیری تقویتی عمیق [15]
۲	هدایت فضاپیما	یادگیری تقویتی عمیق استفاده از یک تکنیک جدید بنام هدایت عمیق که از یادگیری تقویتی عمیق استفاده می‌کند. یادگیری تقویتی عمیق ترکیبی از یادگیری تقویتی و شبکه عصبی عمیق است. روش هدایت عمیق شامل یک استراتژی هدایت است. تئوری کنترل به منظور کاهش بار یادگیری و تسهیل انتقال سیستم آموزش دیده از شبیه‌سازی به واقعیت با یادگیری تقویتی عمیق همراه است. شکاف شبیه‌سازی به واقعیت دیکته می‌کند که سیاست‌های آموزش دیده در شبیه‌سازی اغلب به خوبی به واقعیت منتقل نمی‌شوند. برای این امر یک کنترلر معمولی وظیفه ردیابی را بر عهده دارد. از استراتژی‌های مختلف هدایت همراه با یادگیری تقویتی عمیق برای ردیابی و docking فضاپیما استفاده شده است. [16]
۳	طبقه‌بندی موشک‌های برد متوسط پس از پرتاب	شبکه‌های عصبی عمیق برای طبقه‌بندی سریع سیستم موشکی برد متوسط مورد استفاده قرار گرفته‌اند. در ۲۰ ثانیه اول پس از تشخیص برای طبقه‌بندی بسیار دقیق از شبکه‌های عصبی عمیق استفاده شده است. هدف نهایی این کار، شناسایی سریع ویژگی‌های موشک‌های ناشناخته هنگام پرواز است. مراحل اولیه و ورودی‌های شبکه به توصیف‌های حاصل از تعداد زیادی تاریخچه پرواز یا مسیرهای شبیه‌سازی شده که توسط کلاس‌های مختلف مشخص شده‌اند، وابسته هستند. شبکه‌های عصبی عمیق و همچنین سایر روش‌های آماری، که پیش‌بینی‌های کاملاً دقیقی از کلاس مورد نظر را همراه داشتند، به کار گرفته شدند. در مقایسه با شبکه‌های عصبی تک لایه نتایج بسیار خوبی را ارائه داده‌اند اما با سایر روش‌های دیگر باید مقایسه شوند [17].

۴	طبقه‌بندی و تقسیم‌بندی تصاویر ماهواره‌ای	یادگیری انتقالی عمیق [18]
۵	بهینه‌سازی مسیر برای وسایل نقلیه هابرسونیک	یادگیری عمیق [19]
۶	انتخاب زمان پرتاب آنلاین دردرگیری	یادگیری عمیق یک روش برای تخمین زمان پرتاب بهینه ارائه و ارزیابی شده است. به عنوان سناریو در آن یک هواپیما به عنوان هدف و یک موشک به عنوان مدافع و رهگیر قرار دارند. مشکل تخمین زمان بهینه پرتاب با استفاده از یادگیری عمیق مورد بررسی قرار گرفته است و برای آموزش داده‌ها از یک شبکه عصبی پیچشی استفاده شده است. این روش شامل به دست آوردن زمان بهینه پرتاب و سایر ویژگی‌های سناریو، مانند مسیر و تلاش کنترلی به عنوان تابعی از زمان، از طریق یک شبیه‌سازی با شرایط اولیه تصادفی است. از دو استراتژی Wait-and-Decide (دقت پیش‌بینی ۹۵٪) و Assess-and-Decide (دقت پیش‌بینی بسیار ضعیف) برای انتخاب زمان پرتاب استفاده شده است [20].
۷	هدایت میانی موشک رهگیر	شبکه بازگشتی عمیق با توجه به شرایط گوناگون، قوانین هدایت یادگیری عمیق متفاوت به کار برده شده است. مسیر نمونه مورد استفاده برای آموزش شبکه‌های عمیق مسیرهای بهینه به دست آمده با روش شبه‌طیفی است. از شبکه‌های عصبی بازگشتی عمیق برای تولید قانون هدایت میانی استفاده شده است. اضافه کردن زاویه مسیر پرواز با زمان به بردار ورودی یا در نظر گرفتن زاویه پیچ به عنوان خروجی می‌تواند موشک را با دقت بیشتری به منطقه مورد نظر منتقل کند. هنگامی که فضای نمونه از فضای شبیه‌سازی بزرگتر است، میانگین و انحراف استاندارد فاصله از دست رفته می‌تواند نتیجه بهتری کسب کند. مسیرها را با توجه به نقاط پیش‌بینی شده مختلف رهگیری به سرعت و به طور دقیق شبیه‌سازی کند و فاصله

<p>خطا اندک است [21].</p> <ul style="list-style-type: none"> ○ کاهش MD¹ ○ بهبود روش هدایت با تغییر سه آیتم زیر: <ul style="list-style-type: none"> • The Density of the Selected Sample Trajectory • The Size of the Sample Airspace • The Size of the Simulation Airspace 		
<p>شبکه عصبی عمیق پیچشی</p> <p>استفاده از یادگیری تقویتی عمیق و شبکه‌های عصبی پیچشی برای پردازش هوشمند تصاویر استفاده شده است. ۲۶۸۹ تصویر قابل مشاهده و بارگیری شده از تجهیزات نوری به طور تصادفی بین مجموعه آموزش، مجموعه اعتبار سنجی و مجموعه آزمایش تقسیم شده‌اند.</p> <p>همچنین بررسی و بهبود مشکل طبقه‌بندی هدف از طریق بهبود مدل، بهبود داده‌ها و تغییر نوع الگوریتم یادگیری امکان پذیر شده است [22].</p>	<p>طبقه‌بندی تصاویر موشک</p>	<p>۸</p>
<p>یادگیری عمیق بدون نظارت</p> <p>از یادگیری بدون نظارت در مرحله آموزش مقدماتی و الگوریتم پس‌انتشار به عنوان الگوریتم نظارت شده در مرحله پایانی استفاده استفاده شده است.</p> <p>این روش بر معایب روش‌های سنتی غلبه می‌کند. علاوه بر این، روش پیشنهادی برای توصیف ویژگی‌های پیچیده و پنهان تجهیزات مناسب‌تر است، که شناخت دقیق‌تری از وضعیت سلامت تجهیزات را تحت وظایف نظارت پیچیده امکان-پذیر می‌کند [23].</p>	<p>تشخیص خطای سیستم پیش‌رانش فضاپیما</p>	<p>۹</p>

¹ Miss distance

بررسی‌ها فقط با تغییر زاویه سمت انجام شده است. می‌توان علاوه بر زاویه سمت سرعت هواپیما را نیز تغییر داد.	
۶	کنترل بال‌های مورفینگ با استفاده از یادگیری عمیق [29]
۷	رویکرد یادگیری عمیق برای پیش‌بینی تاخیر در پرواز [30] از شبکه‌های عصبی بازگشتی عمیق برای مدل‌سازی داده‌ها استفاده شده است.

۲.۴. کاربرد یادگیری عمیق در هواپیما

یادگیری عمیق نیز در هواپیماها نیز مورد توجه و استفاده قرار گرفته است.

جدول (3): یادگیری عمیق در هواپیما

۳.۴. کاربرد یادگیری عمیق در وسایل پرنده بدون

سرنشین

جدول (4): یادگیری عمیق در وسایل پرنده بدون سرنشین

ردیف	موضوع
۱	برنامه‌ریزی مسیر برای ردیابی هدف زمینی با استفاده از یادگیری عمیق در پرنده بدون سرنشین [31]
۲	یادگیری تقویتی عمیق برای ناوبری پرنده بدون سرنشین با استفاده از تکنیک چند ورودی-چند خروجی [32]
۳	شبکه‌های عصبی مارکو برای هدایت، کنترل و ناوبری [33]
۴	طراحی و ارزیابی پرواز کنترل‌کننده تطبیقی با استفاده از مدل مرجع عمیق [34]
۵	برنامه‌ریزی و بهینه‌سازی مشترک مسیر پرنده‌های بدون سرنشین و براساس یادگیری تقویتی چندعامله [35]
۶	ردیابی هدف پرنده بدون سرنشین با استفاده از یادگیری تقویتی عمیق [36]
۷	کنترل هاور یک کوادکوپتر با استفاده از شبکه عصبی عمیق [37] استفاده از شبکه عصبی عمیق برای کنترل ارتفاع و معلق ماندن در هوا. شبکه با استفاده از تکنیک یادگیری نظارت شده آموزش دیده است. عملکرد کنترلر با سه الگوی مختلف آموزش مقایسه شده است: ❖ the standard feedforward method ❖ the greedy layer-wise method ❖ the Long Short-Term Memory (LSTM) method روش دوم نتایج بهینه‌تری را ارائه داده است. داده‌های آموزشی مورد نیاز برای کنترلر مبتنی بر شبکه عصبی عمیق از کنترلر کلاسیک LQR به یک پاسخ کنترلر شده از ارتفاع و سرعت حاصل می‌شود، بدست می‌آیند. برای افزایش عملکرد فیلتر نویز شبکه، به داده‌های آموزش نویز تزریق شود. اجرای کنترلر در یک مجموعه فیزیکی واقعی می‌تواند برای ارزشمندی بیشتر این کار در نظر گرفته شود.

ردیف	موضوع
۱	آموزش ترکیبی آنلاین برای سرعت بخشیدن به روش یادگیری تقویتی عمیق برای کنترل هواپیماهای تجاری [24] استفاده از یادگیری تقویتی عمیق و یادگیری تقلیدی و یک کنترل‌کننده PID برای سرعت بخشیدن به روند یادگیری و همچنین کاهش هزینه. الگوریتم یادگیری ترکیبی قادر است به سرعت و با هزینه کم به سرعت و به صورت آنلاین یاد بگیرد. نتایج نشان می‌دهد که شبکه آموزش داده شده قوی‌تر از کنترلر PID پایه است. استفاده از شبکه‌های عصبی بازگشتی عمیق تا بتوان از یک کنترل‌کننده واقع‌گرایانه‌تر استفاده کرد که چندین مرحله از حالت‌ها را در نظر بگیرد.
۲	ارزیابی ایمنی هوانوردی با استفاده از سوابق داده‌های مسیر پرواز [25]
۳	یادگیری ترکیبی برای شبیه‌سازی سیستم‌های دینامیکی هواپیما [26] استفاده از شبکه‌های عصبی بازگشتی عمیق برای شبیه‌سازی دینامیکی هواپیما ۱۰۰-۷۴۷ برای کاهش هزینه‌های آموزش و شبیه‌سازی. سپس استفاده از شبکه‌های آموزش دیده برای پیش‌بینی پاسخ هواپیما در اختلالات و ورودی‌های کنترلی دلخواه. استفاده از شبکه‌های عصبی بازگشتی عمیق با دقت می‌تواند پاسخ هواپیما را پیش‌بینی کند و از قابلیت‌های برون‌یابی عالی برخوردار است. علاوه بر این دارای راندمان محاسبه بهتری در مقایسه با یک روش عددی کلاسیک مانند رانگ کوتاه مرتبه چهارم است. این روش می‌تواند به عنوان مدل‌های جایگزین برای سیستم‌های دینامیکی هواپیما باشد.
۴	طراحی معکوس ایرفویل با استفاده از شبکه‌های عصبی پیچشی عمیق [27]
۵	طراحی محیط آموزش برای هدایت فرود هواپیما بر اساس یادگیری تقویتی عمیق [28] استفاده از یادگیری تقویتی عمیق برای محیط آموزشی هدایت فرود هواپیما استفاده شده است.

۲۱	یادگیری تقویتی عمیق برای طراحی مسیر بهینه برای تهیه فیلم توسط UAV [51]
۲۲	سیستم هشداردهنده موقعیت پرنده بدون سرنشین با استفاده از یادگیری تقویتی عمیق [52]
۲۳	کنترل مداوم برای سیستم‌های مالتی کوپتر بر اساس یادگیری تقویتی عمیق [53]
۲۴	یادگیری تقویتی عمیق جهت جلوگیری از برخورد با مانع برای پرنده‌های بدون سرنشین با دانش محیطی محدود [54]
۲۵	تصمیم‌گیری هوشمندانه برای جلوگیری از برخورد UAV با مانع متحرک سه‌بعدی با استفاده از یادگیری تقویتی عمیق [55]
۲۶	تصمیم‌گیری برای نبردهای هوایی کوتاه‌برد UAVها بر اساس یادگیری تقویتی عمیق؛ کنترل بهینه بلادرنگ از طریق شبکه‌های عصبی عمیق (مطالعه در مورد مشکلات فرود) [56]
۲۷	فرود خودمختار کوآدروتور از طریق یادگیری تقویتی عمیق [57] از یادگیری تقویتی عمیق برای حل مشکل فرود کوآدروتور استفاده شده است. راه حل‌های قبلی عمدتاً براساس محاسبه موقعیت نسبی یا شناسایی نقاط عطف است، یا به حسگرهای اضافی نیاز دارد و فاقد هوش است. آموزش شبکه در یک محیط پیچیده تر با نوبز بیشتر و انتقال شبکه آموزش دیده به کارهای دنیای واقعی صورت پذیرفته است.
۲۸	شناسایی هواپیما با استفاده از شبکه عصبی پیچشی عمیق برای سیستم‌های هواپیماهای کوچک بدون سرنشین [58]
۲۹	تشخیص هدف و کنترل پرواز وسیله پرنده بدون سرنشین با استفاده از یادگیری عمیق [59]
۳۰	شناسایی عیب در سیستم پرنده بدون سرنشین با استفاده از یادگیری عمیق [60] این سیستم برای پردازش تصویر و تشخیص الگو از سیستم تعبیه‌شده سوار بر پرنده استفاده می‌کند، که باعث صرفه‌جویی در پهنای باند انتقال و کوتاه شدن زمان واکنش می‌شود. تشخیص هدف و کنترل پرواز پرنده بر اساس یادگیری عمیق تحقق می‌یابد.
۳۱	یادگیری بدون نظارت برای درک محیط توسط پرنده بدون سرنشین [61] شبکه عصبی خودرمز گذار و رمزگشای عمیق برای درک محیط استفاده شده است. الگوریتم کدگذاری عمیق با استفاده از شبکه سنتی autoencoder پیشنهاد شده و ساختار الگوریتم می‌تواند تصویر را بازسازی کند، که برای نمایش محیط مناسب است.

۸	سنجش بصری-اینرسی مسافت UAV با استفاده از یادگیری عمیق [38] از شبکه‌های عصبی پیچشی استفاده شده است.
۹	بهینه‌سازی مسیر چند UAV و تجزیه و تحلیل تصاویر مبتنی بر یادگیری عمیق [39] استفاده از شبکه‌های عصبی پیچشی برای ردیابی و بهینه‌سازی مسیر و استفاده از الگوریتم Google Vision API Soft OCR برای پردازش تصاویر
۱۰	کنترل یک پرنده بدون سرنشین مورفینگ با استفاده از یادگیری تقویتی عمیق [40]
۱۱	یادگیری تقویتی عمیق برای ناوبری پرنده بدون سرنشین در فضاهای خالی [41]
۱۲	جستجوی خودکار هدف پرنده بدون سرنشین براساس یادگیری تقویتی عمیق در صحنه‌های پیچیده حوادث ناگوار [42]
۱۳	تکنیک برجسته‌سازی حرکت شی با استفاده از یک آشکارساز مبتنی بر یادگیری عمیق برای کنترل موثر پرنده‌های بدون سرنشین [43] اشیاء را که بلادرنگ در حال حرکت هستند با استفاده از یک آشکارساز مبتنی بر یادگیری عمیق، برجسته می‌کند. پس از آن، برای کنترل هوایی موثر هواپیماهای بدون سرنشین اشیاء که شناسایی شده‌اند، توسط عملکرد تفاوت تصویر برجسته می‌شوند. در این بخش، مهمترین کار این است که متوجه شد کدام شی حرکت کرده و چه مقدار حرکت کرده است.
۱۴	یادگیری تقویتی عمیق برای کنترل موقعیت پرنده بدون سرنشین بال ثابت با استفاده از بهینه‌سازی [44] یک کنترلر تقویتی عمیق برای حل مسئله کنترل غیرخطی بکار برده شده که با یک کنترلر PID مقایسه شده و نتایج بهتری را ارائه داده است. از الگوریتم LSTM برای طراحی کنترلر تقویتی عمیق استفاده شده است.
۱۵	هدایت UAV برای فرود مستقل با استفاده از شبکه عصبی عمیق [42]
۱۶	ردیابی و آشکارسازی خودکار یک وسیله نقلیه زمینی سرعت بالا با استفاده از کوآدروتور [46]
۱۷	شبکه‌های بازگشتی و پیچشی عمیق برای طراحی سیستم کنترل فرود خودکار تحمل‌ناپذیر خطا در شرایط سخت [47]
۱۸	یادگیری ترکیبی برای شبیه‌سازی دینامیک وسیله هوایی بدون سرنشین [48]
۱۹	پیش‌بینی سینماتیک برای هواپیماهای مستقل با استفاده از یادگیری عمیق [49]
۲۰	ردیابی سریع و دقیق مسیر برای وسایل نقلیه هوایی بدون سرنشین بر اساس یادگیری تقویتی عمیق [50]

۴.۴. کاربرد یادگیری عمیق در پرواز آرایشمندها^۱

وسایل پرنده

پس از بررسی منابع که به یادگیری عمیق در مسائل هوافضایی پرداخته‌اند و مطالعاتی که در راستای پرواز آرایشمندها وسایل پرنده هوایی و فضایی مختلف انجام شده است، به بررسی تعدادی مرجع پرداخته می‌شود که به موضوع کاربرد یادگیری عمیق در پرواز آرایشی پرداخته‌اند و عبارتند از:

جدول (5): یادگیری عمیق در پرواز آرایشمندها وسایل پرنده

ردیف	موضوع
۱	تصویربرداری هوایی با استفاده از چندین پرنده بدون سرنشین و با استفاده از یادگیری تقویتی عمیق [76]
۲	استفاده از شبکه‌های عصبی عمیق برای کنترل پرواز آرایشی کوادکوپترها [77]
۳	پرواز آرایشی چندین پهپاد با استفاده از شبکه عصبی عمیق بهبود یافته [78]
۴	ارتباط تعاملی مداوم UAVها با اولویت در پرواز آرایشی با استفاده از یادگیری تقویتی عمیق [79] <ul style="list-style-type: none"> ○ با استفاده از یادگیری تقویتی عمیق و با تعامل مداوم UAVها استراتژی بهینه بدست می‌آید. ○ دو نوع روش‌های ارتباطی تشکیل پهپاد مورد بررسی قرار گرفته است. ○ بررسی امکان اشتراک اطلاعات بین دو پهپاد در صورت عدم وجود ماموریت ○ سه نوع الگوریتم یادگیری تقویتی مورد مطالعه قرار گرفته است، یادگیری Q ، DQN و LSTM + DQN پیشنهادی ○ الگوریتم نتایج تجربی نشان می‌دهد که، در مقایسه با روش Q-Learning و Q-network عمیق، روش پیشنهادی به همگرایی سریعتر و بهتر می‌رسد.
۵	کنترل پرواز آرایشی ناهمگن با استفاده از یادگیری تقویتی [80] یک روش کنترل بهینه از طریق یادگیری تقویتی برای ردیابی مسیر ارائه شده است. <ul style="list-style-type: none"> ○ در این مطالعه، یک روش کنترل بهینه توزیع شده از طریق یادگیری تقویتی برای رفع مشکل ردیابی مسیر شکل‌گیری هواپیمای بدون سرنشین هوایی بدون

۳۲	ناوبری کوادکوپترهای مستقل با استفاده از تشخیص نقاط [62]
۳۳	یادگیری تقویتی عمیق برای برنامه‌ریزی مسیر پرنده‌های بدون سرنشین [63]
۳۴	کنترل موثر انرژی پرنده بدون سرنشین برای پوشش ارتباطی موثر: با استفاده از رویکرد یادگیری عمیق [64]
۳۵	تولید مسیر با استفاده از شبکه عصبی عمیق [65]
۳۶	ویژگی‌های یادگیری تقویتی عمیق برای طبقه‌بندی تصاویر [66]
۳۷	طبقه‌بندی و تشخیص میکروUAS با استفاده از رادارهای تشخیصی و یادگیری عمیق [67]
۳۸	بینایی مبتنی بر یادگیری تقویتی عمیق برای فرودمستقل مالی‌روتور بر روی یک بستر متحرک [68]
۳۹	یادگیری عمیق برای فرود ناوگان حمل و نقل هوایی بدون سرنشین در شرایط مختلف [69] از الگوریتم‌های یادگیری عمیق برای شبیه‌سازی فرود ایمن و پایدار در شرایط مختلف از جمله فرود بر روی عرشه کشتی در شرایط مختلف جوی دریا، فرود بر روی باندهای مختلف و با حضور نویز استفاده شده است.
۴۰	ناوبری خودکار وسایل پرنده بدون سرنشین در محیط‌های بزرگ و ناشناخته با استفاده از یادگیری تقویتی عمیق [70]
۴۱	کار هماهنگ بین وسایل نقلیه بدون سرنشین زمینی و هوایی با استفاده از شبکه‌های عمیق با نظارت [71]
۴۲	مکانیسم انتقال مبتنی بر یادگیری عمیق برای وسایل بدون سرنشین [72]
۴۳	تشخیص هدف متحرک مبتنی بر یادگیری عمیق برای وسایل نقلیه هوایی بدون سرنشین [73] استفاده از شبکه‌های عصبی پیچشی برای ردیابی هدف متحرک و استفاده از فیلتر کالمن برای بهبود دقت اطلاعات و استفاده از الگوریتم‌های مختلف برای پردازش سریع تصاویر. این روش فقط می‌تواند یک تصویر واحد را همزمان پردازش کند و فاقد توجه به روابط بین تصاویر سابق می‌باشد.
۴۴	کاربرد یادگیری عمیق برای تشخیص وسیله نقلیه در تصاویر وسایل پرنده بدون سرنشین [74] استفاده از شبکه‌های عصبی ترکیبی نتایج بهتری را با سایر روش‌ها ارائه داده است. این شبکه تمام وسایل نقلیه را به مدت ۴ تا ۵ ثانیه ردیابی می‌کند.
۴۵	توسعه سیستم مانیتورینگ UAV با استفاده از یادگیری عمیق [75]

¹ Formation flight

<p>نمونه در گزارش‌های خبری آتش سوزی آزمایش شده و همه آنها با دقت مشخص شده‌اند.</p> <ul style="list-style-type: none"> ○ سرعت پردازش متوسط ۴۱٫۵ میلی ثانیه در هر تصویر را تضمین می‌کند. 		<p>سرنشین پیشنهاد شده است.</p> <ul style="list-style-type: none"> ○ پرواز آرایشی متشکل از یک رهبر مجازی با تعداد محدود ورودی غیرصفر و چندین دنبال کننده(پیرو) با دینامیک ناشناخته متفاوت ○ در آینده نیز، یک بستر آزمایشی از کوادروتورها ایجاد خواهد شد. یادگیری تقویتی پیشنهادی مبتنی بر روش کنترل بهینه خواهد بود و مشکل کنترل بهینه برای سیستم‌های غیرخطی حل خواهد شد. 	
<p>کنترلر زمان متغیر برای وسایل نقلیه هوایی بدون سرنشین در پرواز آرایشی با استفاده از یادگیری تقویتی عمیق [85]</p> <p>یادگیری تقویتی عمیق می‌تواند برای هدایت پهپادها به منظور دستیابی به هرگونه شکل‌گیری مورد استفاده قرار گیرد. با استفاده از شبکه عصبی عمیق می‌توان تخمین زد که حالت مورد نظر چقدر خوب است و عامل بر این اساس اقدامات را انتخاب کند.</p> <ul style="list-style-type: none"> ○ استفاده از یادگیری تقویتی عمیق در سیستم‌های چند عامله برای هدایت پهپادها به منظور دست یابی به هرگونه آرایش ○ با استفاده از شبکه عصبی عمیق تخمین زده شده که یک آرایش چقدر مناسب است و عامل بر این اساس اقدامات لازم را انجام داده است. ○ استفاده از یادگیری تقویتی عمیق برای توسعه کنترل‌های مقیاس پذیر، بهینه و قابل حمل برای پهپادها. 	<p>۱۰</p>	<p>شناسایی مسیرهای نسبی در مانورهای بدون برخورد پروازهای آرایشی فضاپیماها با استفاده از دینامیک بازسازی شده عصبی [81]</p> <p>یک الگوریتم یادگیری تقویتی برای انجام پیکربندی تنظیم و نگهداری در پرواز آرایشی فضاپیمای پیشنهاد شده است. علاوه بر این، دو الگوریتم، یعنی یادگیری تقویتی معکوس و شبکه حافظه طولانی کوتاه مدت، برای بازسازی و پیش‌بینی مسیرهای آینده و برای انجام مانورهای بدون برخورد، پیشنهاد می‌شود.</p> <ul style="list-style-type: none"> ○ استفاده از الگوریتم یادگیری تقویتی برای تنظیم مجدد و نگهداری فضاپیما در پرواز آرایشی(ایجاد مسیر و کنترل) ○ استفاده از دو الگوریتم یادگیری تقویتی معکوس و حافظه طولانی کوتاه مدت^۱، برای بازسازی و پیش‌بینی مسیرهای آینده، برای انجام مانورهای بدون تصادف در هنگام تنظیم مجدد همزمان، پیشنهاد شده اند(تضمین عملیات بدون برخورد). ○ استفاده از یادگیری عمیق در پرواز آرایشی متشکل از چندین میکرو ماهواره برای افزایش قابلیت‌های ماموریت، انعطاف پذیری و کاهش هزینه. 	<p>۶</p>
<p>پرواز آرایشمند هواپیماهای مسافربری پتانسیل زیادی برای کمک به صنعت حمل و نقل هوایی دارد که بیشتر از طریق به-روزرسانی عملیات شبکه پرواز، باعث کاهش مصرف سوخت، تأثیرات زیست محیطی و بار کاری برج مراقبت می‌شود. در نتیجه، مفهوم پرواز آرایشی به سرعت در حال پیشرفت است.</p> <p>یاتا پیش‌بینی کرده است که سفرهای هوایی تا سال ۲۰۳۹ بین ۳/۲ تا ۵/۳ درصد رشد خواهند داشت. به این ترتیب و با کمترین میزان رشد، تعداد مسافران هوایی در سال ۲۰۳۹ به بیش از ۲ میلیارد نفر خواهند رسید. صنعت هوانوردی که بدلیل کرونا وارد رکود شده است بزودی احیا خواهد شد. از دیدگاه ترافیک هوایی نیز مهم‌ترین مزیت پرواز دسته‌جمعی افزایش ظرفیت فضای پروازی است.</p> <p>با افزایش تقاضا برای پروازهای اقتصادی و اکولوژیکی بیشتر و پیشرفت فناوری هدایت، سیستم‌های ناوبری و کنترل، پرواز آرایشمند در حال تبدیل شدن به یکی از امیدوارکننده‌ترین استراتژی‌های عملیاتی برای کاهش مصرف سوخت و انتشار گازهای هوایی است.</p>	<p>کنترل پرواز آرایشی ماهواره‌ها با استفاده از یادگیری عمیق [82]</p>	<p>۷</p>	
	<p>کنترل پیش‌بین مبتنی بر شبکه عصبی بازگشتی برای پرواز آرایشی کوادروتورهای بدون سرنشین [83]</p> <p>سیستم کنترلی پیش‌بین برای هر زیرسیستم ارائه شده است و برای بهبود دقت مدل‌سازی، یک قانون به روزرسانی تطبیقی برای تنظیم وزن آنلاین برای RNN تهیه شده است.</p>	<p>۸</p>	
	<p>شناسایی آتش‌سوزی در تصاویر پهپادها با استفاده از یادگیری عمیق [84]</p> <p>یادگیری عمیق در یادگیری ویژگی‌های سطح بالا بسیار مؤثر است، با این حال، مقدار قابل توجهی از مجموعه داده‌های تصاویر آموزشی در بهینه‌سازی مقدار و ضرایب وزن آن الزامی است.</p> <ul style="list-style-type: none"> ○ استفاده از یادگیری عمیق برای رنگ، شکل، بافت آتش (دود، شعله یا هر دو) ○ استفاده از یک شبکه عصبی ۱۵ لایه DCNN ○ این روش دارای دقت ۹۸٪ بوده است. ○ برای نشان دادن کاربرد عملی خود، بر روی ۴۰ تصویر 	<p>۹</p>	

¹ LSTM

واقعیت (تا حد امکان) مدنظر است زیرا عدم توجه به آنها باعث ایجاد فاصله^۲ بین شبیه‌سازی‌ها و شرایط واقعی می‌شود. که در راستای این هدف از الگوریتم‌های یادگیری عمیق استفاده شده است.

۵. نتیجه

در این مقاله پس از تعریف مبانی، تاریخچه، انواع شبکه و معماری‌های آنها، چالش‌های پیش‌رو بیان گردید. به رغم موفقیت‌های چشمگیر، یادگیری عمیق، دلیل کارایی پایین شبکه عصبی با لایه‌های عمیق، عدم امکان آموزش مناسب شبکه عصبی است. صنعت هوافضا نیز ازین فناوری بهره زیادی برده است. به عنوان مثال در شبیه‌سازی مسیر پرواز، سیستم‌های کنترلی و هدایت وسایل پرنده، ناوبری وسایل پرنده، خلبان‌های خودکار، شبیه‌سازی اجزای وسایل پرنده، تشخیص خطا در اجزای وسایل پرنده و پردازش تصاویر در پروازهای انفرادی و گروهی استفاده فراوان کرده و به نتایج بسیار خوبی نیز دست یافته است. عاملی که باعث هزینه‌های بالای این فناوری شده طراحی آن است. همچنین انعطاف‌پذیری یادگیری عمیق، مدل‌سازی پدیده‌های مختلف و کنار زدن مدل‌های دیگر را در پی دارد که بطور چشمگیری محاسبات را گران‌تر می‌کند. احتمال آن نیز هست که با گذر زمان هزینه‌های این فناوری کاهش یابد و یا فناوری‌های جدیدتر جایگزین آنها شوند.

مراجع

- [1] وزان، میلاد، یادگیری عمیق، اصول، مفاهیم و رویکردها، چاپ اول. تهران: میعاد اندیشه، ۱۳۹۹.
- [2] رئوف مقدم، مهلا، "تخمین مدهای پروازی و ضرایب

اما پرواز آرایش‌یافته در هواپیماها علاوه بر استفاده از مزایای آیرودینامیکی از نظر استراتژیک، مدیریت عملیات و قدرت مانور نیز اهمیت زیادی دارد..

به طور کلی مزایای پرواز دسته جمعی را می‌توان بدین صورت برشمرد: کاهش نیروی پسا^۱ و در نتیجه کاهش میزان مصرف سوخت و افزایش برد، کاهش آلودگی ناشی از مصرف سوخت هواپیما و همچنین افزایش ظرفیت فضای پروازی و...

در کنار مزایای بیان شده، پروازهای آرایش‌مند با مخاطرات و چالش‌هایی مواجه هستند که نیازمند بررسی‌های بیشتر می‌باشند. خطرات اصلی مشخص شده برای مفهوم پرواز آرایش‌مند در حمل و نقل هوایی غیرنظامی به شرح زیر می‌باشند:

۱- تلاطم راحتی مسافر را کاهش می‌دهد. پروازهای آرایش‌مند باید راحتی مسافر را تضمین نمایند.

۲- هنگام شروع و خاتمه آرایش هواپیماها، پرواز ایمن باشد.

۳- قوانین باید تسهیل و در بعضی موارد تصحیح شوند تا هواپیماهای غیرنظامی بتوانند به صورت آرایش‌مند پرواز کنند.

به منظور ایجاد یک پرواز آرایش‌مند، الزامات متفاوتی وجود دارد. به همین دلیل ضروری است تا آرایش پروازی کنترل شود. همانطور که در قبل بیان شد، راحتی سواری مسافران در اینگونه پروازها بسیار مهم است. از این رو استفاده از یک کنترلگر به نحوی که بتواند پرواز را در حضور عدم قطعیت‌ها به نحو مطلوبی کنترل نماید، از اهمیت ویژه‌ای برخوردار خواهد بود.

به دلیل اهمیت و حساسیت بالای سیستم کنترل پرواز، نوع پرواز و شرایط موجود در پرواز، باید کنترلگری انتخاب شود که قابلیت بالایی در دفع اغتشاشات وارد بر سیستم و کاهش اثر تداخل بین حلقه‌های کنترلی داشته باشد.

در مطالعات و پژوهشی که توسط نویسندگان مقاله در حال انجام است، طراحی کنترلگر با در نظر گرفتن شرایط نزدیک به

² Gap

¹ Drag

- ارشد، دانشگاه شیراز، ۱۳۹۶.
- [14] شرافتی، ماندانا، "بررسی حافظه بینایی با استفاده از روش یادگیری عمیق"، پایان نامه کارشناسی ارشد، دانشگاه گوازننگ-زنجان، ۱۳۹۶.
- [15] حاجی عباسی، میلاد، "تحلیل تصویری محیط های غیر ساختار یافته با کمک یادگیری عمیق برای عامل تصمیم یار چند بخشی"، پایان نامه کارشناسی ارشد، دانشگاه غیردولتی خاتم، ۱۳۹۷.
- [16] A. T. Harris and H. Schaub, "Spacecraft Command and Control with Safety Guarantees using Shielded Deep Reinforcement Learning," Jan. 2020, doi: doi:10.2514/6.2020-0386.
- [17] K. Hovell and S. Ulrich, "On Deep Reinforcement Learning for Spacecraft Guidance," in *AIAA Scitech 2020 Forum*, American Institute of Aeronautics and Astronautics, 2020.
- [18] J. Eckert, M. Carpenter, R. Hartfield, and N. Cervantes, "Classification of Intermediate Range Missiles During Launch," Jan. 2020, doi: doi:10.2514/6.2020-1852.
- [19] R. Giorgiani do Nascimento and F. Viana, "Satellite Image Classification and Segmentation with Transfer Learning," Jan. 2020, doi: doi:10.2514/6.2020-1864.
- [20] Y. Shi and Z. Wang, "A Deep Learning-Based Approach to Real-Time Trajectory Optimization for Hypersonic Vehicles," Jan. 2020, doi: doi:10.2514/6.2020-0023.
- [21] V. Shalumov, "Online Launch-Time Selection Using Deep Learning in a Target-Missile-Defender Engagement," *J. Aerosp. Inf. Syst.*, vol. 16, no. 6, pp. 224-236, Mar. 2019, doi: 10.2514/1.1010668.
- [22] L. Huang and W. Chen, "Deep Learning Midcourse Guidance for Interceptor Missile," in *2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC)*, 2019, pp. 1129-1134, doi: 10.1109/ITNEC.2019.8729311.
- [23] L. Zhang, Z. Chen, J. Wang, and Z. Huang, "Rocket Image Classification Based on Deep Convolutional Neural Network," in *2018 10th International Conference on Communications, Circuits and Systems (ICCCAS)*, 2018, pp. 383-386, doi: 10.1109/ICCCAS.2018.8769176.
- [24] H. Fang, H. Shi, Y. Dong, H. Fan, and S. Ren, "Spacecraft power system fault diagnosis based on DNN," in *2017 Prognostics and System Health Management Conference (PHM-Harbin)*, 2017, pp. 1-5, doi: 10.1109/PHM.2017.8079271.
- [25] M. Xin, Y. Gao, T. Mou, and J. Ye, "Online Hybrid
- پایداری و کنترل یک هواپیما"، پایان نامه کارشناسی ارشد، دانشگاه صنعتی مالک اشتر، ۱۳۹۶.
- [3] م. هادی، ق. سپیدنامو ا. ولیپور، "تشخیص نفوذ به شبکه با استفاده از ترکیب درخت تصمیم و الگوریتم یادگیری عمیق"، *سومین کنفرانس ملی در مهندسی کامپیوتر، فناوری اطلاعات و پردازش داده ها*، 1397, pp. 1-9.
- [4] K. Hauptfleisch, "elearning industry," 2016. .
- [5] آبادی قره بابا، رحمان، "یادگیری عمیق در شبکه های عصبی"، پایان نامه کارشناسی ارشد، موسسه آموزش عالی غیاث الدین جمشید کاشانی، ۱۳۹۶.
- [6] D. Bhavsar, "Dispelling Myths: Deep Learning vs. Machine Learning," *MERKLE*, 2020. .
- [7] سجنوسکی، ترنس جوزف، ترجمه روح رضی، مراد و محمدیان اصل، علی، *انقلاب یادگیری عمیق*، چاپ اول. تهران: علمیران، ۱۳۹۸.
- [8] تیموری بانسری، رمضان، میرزازضایی، میترا، صادقی، مهدی، نجار اعرابی، بابک، «پیشبینی زمان بقا عاری از بیماری تهاجمی در بیماران مبتال به سرطان پستان با بهکارگیری روشهای یادگیری ماشین نیمه نظارتی مبتنی بر گراف»، *مجله محاسبات نرم*، جلد ۰۱، شماره ۰، ص ۸۴-۹۶، بهار و تابستان ۰۸۱۱.
- [9] N. Kumar, "What is the difference between Machine Learning and Deep Learning?," 2017. .
- [10] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, and C. Liu, "A Survey on Deep Transfer Learning," in *Artificial Neural Networks and Machine Learning -- ICANN 2018*, 2018, pp. 270-279.
- [11] Z. He, "A Comprehensive Survey on Geometric Deep Learning," *IEEE Access*, vol. 8, pp. 35929-35949, 2020, doi: 10.1109/ACCESS.2020.2975067.
- [12] محمدی امین، فاطمه، "طراحی و ساخت یک وسیله نقلیه هدایت خودکار و کنترل آن توسط یک سیستم یادگیری عمیق و بینایی ماشین"، پایان نامه کارشناسی ارشد، دانشگاه تبریز، ۱۳۹۶.
- [13] جعفری، عارف، "یادگیری ویژگی با نظارت به کمک شبکه های عصبی عمیق"، پایان نامه کارشناسی

- UAV Target Tracking With Deep Reinforcement Learning," *IEEE Trans. Autom. Sci. Eng.*, vol. 16, no. 4, pp. 1522–1530, 2019, doi: 10.1109/TASE.2018.2877499.
- [38] S. Edhah, S. Mohamed, A. Rehan, M. AlDhaheeri, A. AlKhaja, and Y. Zweiri, "Deep Learning Based Neural Network Controller for Quad Copter: Application to Hovering Mode," in *2019 International Conference on Electrical and Computing Technologies and Applications (ICECTA)*, 2019, pp. 1–5, doi: 10.1109/ICECTA48151.2019.8959776.
- [39] H. Lee, M. McCrink, and J. W. Gregory, "Visual-Inertial Odometry for Unmanned Aerial Vehicle using Deep Learning," Jan. 2019, doi: doi:10.2514/6.2019-1410.
- [40] Y. Choi, M. Martel, S. I. Briceno, and D. N. Mavris, "Multi-UAV Trajectory Optimization and Deep Learning-based Imagery Analysis for a UAS-based Inventory Tracking Solution," Jan. 2019, doi: doi:10.2514/6.2019-1569.
- [41] D. Xu, Z. Hui, Y. Liu, and G. Chen, "Morphing control of a new bionic morphing UAV with deep reinforcement learning," *Aerosp. Sci. Technol.*, vol. 92, pp. 232–243, 2019, doi: <https://doi.org/10.1016/j.ast.2019.05.058>.
- [42] O. Walker, F. Vanegas, F. Gonzalez, and S. Koenig, "A Deep Reinforcement Learning Framework for UAV Navigation in Indoor Environments," in *2019 IEEE Aerospace Conference*, 2019, pp. 1–14, doi: 10.1109/AERO.2019.8742226.
- [43] C. Wu *et al.*, "UAV Autonomous Target Search Based on Deep Reinforcement Learning in Complex Disaster Scene," *IEEE Access*, vol. 7, pp. 117227–117245, 2019, doi: 10.1109/ACCESS.2019.2933002.
- [44] J. Choi and W.-C. Park, "Object movement highlighting technique using a deep-learning based object detector for effective UAV control," in *2019 34th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC)*, 2019, pp. 1–4, doi: 10.1109/ITC-CSCC.2019.8793321.
- [45] E. Bøhn, E. M. Coates, S. Moe, and T. A. Johansen, "Deep Reinforcement Learning Attitude Control of Fixed-Wing UAVs Using Proximal Policy optimization," in *2019 International Conference on Unmanned Aircraft Systems (ICUAS)*, 2019, pp. 523–533, doi: 10.1109/ICUAS.2019.8798254.
- [46] Y. Bicer, M. Moghadam, C. Sahin, B. Eroglu, and N. K. Üre, "Vision-based UAV Guidance for Autonomous Landing with Deep Neural Networks," Jan. 2019, doi: doi:10.2514/6.2019-0140.
- [47] A. K. Shastry, H. Sinha, and M. Kothari, "Autonomous Detection and Tracking of a High-Speed Ground Vehicle using a Quadrotor UAV," Jan. 2019, doi: doi:10.2514/6.2019-1188.
- [48] C. Sahin, B. Eroglu, N. K. Üre, and H. B. Kurt, "Deep Learning to Speed Up Deep Reinforcement Learning Method for Commercial Aircraft Control," in *2019 3rd International Symposium on Autonomous Systems (ISAS)*, 2019, pp. 305–310, doi: 10.1109/ISASS.2019.8757756.
- [26] X. Zhang and S. Mahadevan, "Aviation Safety Assessment Using Historical Flight Trajectory Data," Jun. 2019, doi: 10.2514/6.2019-3415.
- [27] Y. Yu, H. Yao, and Y. Liu, "A Hybrid Learning Approach for the Simulation of Aircraft Dynamical Systems," Jan. 2019, doi: 10.2514/6.2019-0436.
- [28] V. Sekar, M. Zhang, C. Shu, and B. C. Khoo, "Inverse Design of Airfoil Using a Deep Convolutional Neural Network," *AIAA J.*, vol. 57, no. 3, pp. 993–1003, Jan. 2019, doi: 10.2514/1.J057894.
- [29] Z. Wang, H. Li, H. Wu, F. Shen, and R. Lu, "Design of Agent Training Environment for Aircraft Landing Guidance Based on Deep Reinforcement Learning," in *2018 11th International Symposium on Computational Intelligence and Design (ISCID)*, 2018, vol. 02, pp. 76–79, doi: 10.1109/ISCID.2018.10118.
- [30] V. G. Goecks, P. Camara Leal, T. White, J. Valasek, and D. Hartl, "Control of Morphing Wing Shapes with Deep Reinforcement Learning," Jan. 2018, doi: 10.2514/6.2018-2139.
- [31] Y. J. Kim, S. Choi, S. Briceno, and D. Mavris, "A deep learning approach to flight delay prediction," in *2016 IEEE/AIAA 35th Digital Avionics Systems Conference (DASC)*, 2016, pp. 1–6, doi: 10.1109/DASC.2016.7778092.
- [32] B. Li and Y. Wu, "Path Planning for UAV Ground Target Tracking via Deep Reinforcement Learning," *IEEE Access*, vol. 8, pp. 29064–29074, 2020, doi: 10.1109/ACCESS.2020.2971780.
- [33] H. Huang, Y. Yang, H. Wang, Z. Ding, H. Sari, and F. Adachi, "Deep Reinforcement Learning for UAV Navigation Through Massive MIMO Technique," *IEEE Trans. Veh. Technol.*, vol. 69, no. 1, pp. 1117–1121, 2020, doi: 10.1109/TVT.2019.2952549.
- [34] S. Lim, M. Stoeckle, B. J. Streetman, and M. Neave, "Markov Neural Network For Guidance, Navigation and Control," Jan. 2020, doi: doi:10.2514/6.2020-0375.
- [35] G. Joshi, J. Viridi, and G. Chowdhary, "Design and Flight Evaluation of Deep Model Reference Adaptive Controller," Jan. 2020, doi: doi:10.2514/6.2020-1336.
- [36] H. Qie, D. Shi, T. Shen, X. Xu, Y. Li, and L. Wang, "Joint Optimization of Multi-UAV Target Assignment and Path Planning Based on Multi-Agent Reinforcement Learning," *IEEE Access*, vol. 7, pp. 146264–146272, 2019, doi: 10.1109/ACCESS.2019.2943253.
- [37] W. Zhang, K. Song, X. Rong, and Y. Li, "Coarse-to-Fine

- [59] S. Hwang, J. Lee, H. Shin, S. Cho, and D. H. Shim, "Aircraft Detection using Deep Convolutional Neural Network in Small Unmanned Aircraft Systems," Jan. 2018, doi: doi:10.2514/6.2018-2137.
- [60] C. Wang, R. Zhao, X. Yang, and Q. Wu, "Research of UAV target detection and flight control based on deep learning," in *2018 International Conference on Artificial Intelligence and Big Data (ICAIBD)*, 2018, pp. 170–174, doi: 10.1109/ICAIBD.2018.8396188.
- [61] M. H. Olyaei, H. Jalali, A. Noori, and N. Eghbal, "Fault Detection and Identification on UAV System with CITFA Algorithm Based on Deep Learning," in *Electrical Engineering (ICEE), Iranian Conference on*, 2018, pp. 988–993, doi: 10.1109/ICEE.2018.8472529.
- [62] Y. Kaidi, M. Zhaowei, L. Jinhong, S. Sibbo, and Z. Yulin, "Unsupervised Representation Learning Method for UAV's Scene Perception," in *2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS)*, 2018, pp. 323–327, doi: 10.1109/ICSESS.2018.8663930.
- [63] S. Raj, M. Dreyer, and S. Gururajan, "Autonomous Quadcopter Navigation Using Vision-Based Landmark Recognition," Jun. 2018, doi: doi:10.2514/6.2018-4243.
- [64] U. Challita, W. Saad, and C. Bettstetter, "Deep Reinforcement Learning for Interference-Aware Path Planning of Cellular-Connected UAVs," in *2018 IEEE International Conference on Communications (ICC)*, 2018, pp. 1–7, doi: 10.1109/ICC.2018.8422706.
- [65] C. H. Liu, Z. Chen, J. Tang, J. Xu, and C. Piao, "Energy-Efficient UAV Control for Effective and Fair Communication Coverage: A Deep Reinforcement Learning Approach," *IEEE J. Sel. Areas Commun.*, vol. 36, no. 9, pp. 2059–2070, 2018, doi: 10.1109/JSAC.2018.2864373.
- [66] T. Watanabe and E. N. Johnson, "Trajectory Generation using Deep Neural Network," Jan. 2018, doi: doi:10.2514/6.2018-1893.
- [67] L. Bashmal and Y. Bazi, "Learning Robust Deep Features for Efficient Classification of UAV Imagery," in *2018 1st International Conference on Computer Applications & Information Security (ICCAIS)*, 2018, pp. 1–4, doi: 10.1109/CAIS.2018.8441965.
- [68] G. J. Mendis, J. Wei, and A. Madanayake, "Deep learning cognitive radar for micro UAS detection and classification," in *2017 Cognitive Communications for Aerospace Applications Workshop (CCAA)*, 2017, pp. 1–5, doi: 10.1109/CCAAS.2017.8001610.
- [69] A. Rodriguez-Ramos, C. Sampedro, H. Bavle, I. G. Moreno, and P. Campoy, "A Deep Reinforcement Learning Technique for Vision-Based Autonomous Multirotor Landing on a Moving Platform," in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2018, pp. 1010–1017, doi: Recurrent and Convolutional Networks for Robust Fault Tolerant Autonomous Landing Control System Design Under Severe Conditions," Jan. 2019, doi: doi:10.2514/6.2019-1665.
- [49] Y. Yu and Y. Liu, "A Hybrid Learning Approach for the Simulation of Dynamics of Unmanned Aircraft Vehicle," Jun. 2019, doi: doi:10.2514/6.2019-2940.
- [50] R. Ravishankar and S. R. Chakravarthy, "Kinematic Prediction for Autonomous Aircraft Using Deep Learning Based Optical Detection," Jun. 2019, doi: doi:10.2514/6.2019-3190.
- [51] Y. Li *et al.*, "Fast and Accurate Trajectory Tracking for Unmanned Aerial Vehicles based on Deep Reinforcement Learning," in *2019 IEEE 25th International Conference on Embedded and Real-Time Computing Systems and Applications (RTCSA)*, 2019, pp. 1–9, doi: 10.1109/RTCSA.2019.8864571.
- [52] D. Kwon and J. Kim, "Optimal Trajectory Learning for UAV-BS Video Provisioning System: A Deep Reinforcement Learning Approach," in *2019 International Conference on Information Networking (ICOIN)*, 2019, pp. 372–374, doi: 10.1109/ICOIN.2019.8718194.
- [53] R. Gerald *et al.*, "UAV-Based Situational Awareness System Using Deep Learning," *IEEE Access*, vol. 7, pp. 122583–122594, 2019, doi: 10.1109/ACCESS.2019.2938249.
- [54] A. Manukyan, M. A. Olivares-Mendez, M. Geist, and H. Voos, "Deep Reinforcement Learning-based Continuous Control for Multicopter Systems," in *2019 6th International Conference on Control, Decision and Information Technologies (CoDIT)*, 2019, pp. 1876–1881, doi: 10.1109/CoDIT.2019.8820368.
- [55] A. Singla, S. Padakandla, and S. Bhatnagar, "Memory-Based Deep Reinforcement Learning for Obstacle Avoidance in UAV With Limited Environment Knowledge," *IEEE Trans. Intell. Transp. Syst.*, vol. PP, pp. 1–12, Nov. 2019, doi: 10.1109/TITS.2019.2954952.
- [56] X. Han, J. Wang, J. Xue, and Q. Zhang, "Intelligent Decision-Making for 3-Dimensional Dynamic Obstacle Avoidance of UAV Based on Deep Reinforcement Learning," in *2019 11th International Conference on Wireless Communications and Signal Processing (WCSP)*, 2019, pp. 1–6, doi: 10.1109/WCSP.2019.8928110.
- [57] C. Sánchez-Sánchez and D. Izzo, "Real-Time Optimal Control via Deep Neural Networks: Study on Landing Problems," *J. Guid. Control. Dyn.*, vol. 41, no. 5, pp. 1122–1135, Mar. 2018, doi: 10.2514/1.G002357.
- [58] Y. Xu, Z. Liu, and X. Wang, "Monocular Vision based Autonomous Landing of Quadrotor through Deep Reinforcement Learning," in *2018 37th Chinese Control Conference (CCC)*, 2018, pp. 10014–10019, doi: 10.23919/ChiCC.2018.8482830.

- 38, pp. 295–302, Apr. 2020, doi: 10.1051/jnwpu/20203820295.
- [80] Y. Lin, M. Wang, X. Zhou, G. Ding, and S. Mao, "Dynamic Spectrum Interaction of UAV Flight Formation Communication With Priority: A Deep Reinforcement Learning Approach," *IEEE Trans. Cogn. Commun. Netw.*, vol. 6, no. 3, pp. 892–903, 2020, doi: 10.1109/TCCN.2020.2973376.
- [81] H. Liu, Q. Meng, F. Peng, and F. L. Lewis, "Heterogeneous formation control of multiple UAVs with limited-input leader via reinforcement learning," *Neurocomputing*, vol. 412, pp. 63–71, 2020, doi: <https://doi.org/10.1016/j.neucom.2020.06.040>.
- [82] S. Silvestrini and M. R. Lavagna, "Spacecraft Formation Relative Trajectories Identification for Collision-Free Maneuvers using Neural-Reconstructed Dynamics," Jan. 2020, doi: doi:10.2514/6.2020-1918.
- [83] Q. Liu, E. Moulay, P. Coirault, and Q. Hui, "Deep Learning Based Formation Control for the Multi-Agent Coordination," May 2019, pp. 12–17, doi: 10.1109/ICNSC.2019.8743254.
- [84] B. Zhang, X. Sun, S. Liu, and X. Deng, "Recurrent Neural Network-Based Model Predictive Control for Multiple Unmanned Quadrotor Formation Flight," *Int. J. Aerosp. Eng.*, vol. 2019, p. 7272387, 2019, doi: 10.1155/2019/7272387.
- [85] Y. Zhao, J. Ma, X. Li, and J. Zhang, "Saliency Detection and Deep Learning-Based Wildfire Identification in UAV Imagery," *Sensors*, vol. 18, p. 712, Feb. 2018, doi: 10.3390/s18030712.
- [86] R. Conde, J. Llata, and C. Torre-Ferrero, "Time-Varying Formation Controllers for Unmanned Aerial Vehicles Using Deep Reinforcement Learning," Jun. 2017, doi: 10.1109/IROS.2018.8594472.
- [70] D. Zhou, J. Zhou, M. Zhang, D. Xiang, and Z. Zhong, "Deep learning for unmanned aerial vehicles landing carrier in different conditions," in *2017 18th International Conference on Advanced Robotics (ICAR)*, 2017, pp. 469–475, doi: 10.1109/ICAR.2017.8023651.
- [71] C. Wang, J. Wang, X. Zhang, and X. Zhang, "Autonomous navigation of UAV in large-scale unknown complex environment with deep reinforcement learning," in *2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 2017, pp. 858–862, doi: 10.1109/GlobalSIP.2017.8309082.
- [72] H. T. Nguyen, M. Garratt, L. T. Bui, and H. Abbass, "Supervised deep actor network for imitation learning in a ground-air UAV-UGVs coordination task," in *2017 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2017, pp. 1–8, doi: 10.1109/SSCI.2017.8285387.
- [73] H. Yang, B. Hu, and L. Wang, "A deep learning based handover mechanism for UAV networks," in *2017 20th International Symposium on Wireless Personal Multimedia Communications (WPMC)*, 2017, pp. 380–384, doi: 10.1109/WPMC.2017.8301842.
- [74] H. Yao, Q. Yu, X. Xing, F. He, and J. Ma, "Deep-learning-based moving target detection for unmanned air vehicles," in *2017 36th Chinese Control Conference (CCC)*, 2017, pp. 11459–11463, doi: 10.23919/ChiCC.2017.8029186.
- [75] G. V. Konoplich, E. O. Putin, and A. A. Filchenkov, "Application of deep learning to the problem of vehicle detection in UAV images," in *2016 XIX IEEE International Conference on Soft Computing and Measurements (SCM)*, 2016, pp. 4–6, doi: 10.1109/SCM.2016.7519666.
- [76] H. Kim, D. Kim, S. Jung, J. Koo, J. Shin, and H. Myung, "Development of a UAV-type jellyfish monitoring system using deep learning," in *2015 12th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*, 2015, pp. 495–497, doi: 10.1109/URAI.2015.7358813.
- [77] K. C. W. Goh, R. B. C. Ng, Y.-K. Wong, N. J. H. Ho, and M. C. H. Chua, "Aerial filming with synchronized drones using reinforcement learning," *Multimed. Tools Appl.*, 2021, doi: 10.1007/s11042-020-10388-5.
- [78] J. Dunn and R. Tron, "Temporal Siamese Networks for Clutter Mitigation Applied to Vision-Based Quadcopter Formation Control," *IEEE Robot. Autom. Lett.*, vol. 6, no. 1, pp. 32–39, 2021, doi: 10.1109/LRA.2020.3028056.
- [79] W. Xie, K. Wu, F. Yan, H. Shi, and X. Zhang, "A Formation Flight Method with an Improved Deep Neural Network for Multi-UAV System," *Xibeigongye Daxue Xuebao/Journal Northwest. Polytech. Univ.*, vol.