



دانشگاه کاشان
University of Kashan

مجله محاسبات نرم

SOFT COMPUTING JOURNAL

تارنمای مجله: sci.kashanu.ac.ir



مروری بر رویکرد یادگیری عمیق در صنعت هوافضا[✦]

مهلا رئوف مقدم[✉]، دانشجوی دکتری، مسعود ابراهیمی^۱، دانشیار

^۱ دانشکده مهندسی مکانیک، دانشگاه تربیت مدرس، تهران، ایران.

اطلاعات مقاله

چکیده

تاریخچه مقاله:

دریافت ۱۵ دی ماه ۱۴۰۰

پذیرش ۰۴ اردیبهشت ماه ۱۴۰۲

کلمات کلیدی:

یادگیری عمیق

شبکه عصبی مصنوعی

شبکه عمیق

یادگیری انتقالی

یادگیری هندسی

در سال‌های اخیر، یادگیری عمیق به محرک اصلی راه‌حل‌های نوآورانه برای مساله‌های هوش مصنوعی تبدیل گردیده که این امر با افزایش مقدار داده‌های موجود، افزایش منابع محاسباتی و روش‌های بهبود یافته در آموزش شبکه‌های عمیق امکان‌پذیر شده است. پیشرفت و افزایش توان پردازش رایانه‌ها و توانمندتر شدن روش‌های 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 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. شبکه‌های عصبی عمیق ساختارهای متفاوت، انواع مختلف و گونه‌های متنوعی را دارا هستند و با توجه به نوع داده‌ها و هدف مساله از آنها استفاده می‌شود و هر کدام دارای نقاط قوت و ضعف خود را دارند. در این مقاله به بررسی و کاربرد این شبکه‌ها در مساله‌های مختلف هوافضایی پرداخته شده است.

© ۱۴۰۲ نویسندگان. مقاله با دسترسی آزاد تحت مجوز CC-BY

۱. مقدمه

عنوان یک راه‌حل عالی برای کشف معماری پیچیده در داده‌هایی با ابعاد بالا، رشد کرده‌اند. بنابراین، روش‌های یادگیری عمیق می‌توانند نقش کلیدی در ساختن داشته باشند [۱]. در حالت کلی تفاوت‌هایی بین «هوش مصنوعی»^۱، «شبکه‌های عصبی»^۲، «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

امروزه تمرکز اصلی انقلاب صنعتی چهارم، اتوماسیون مبتنی بر فناوری، سیستم‌های هوشمند در حوزه‌های کاربردی مختلف از جمله مراقبت‌های بهداشتی هوشمند، هوش تجاری، شهرهای هوشمند، امنیت سایبری و بسیاری موارد دیگر است. رویکردهای یادگیری عمیق به طور چشمگیری از نظر عملکرد در طیف گسترده‌ای از کاربردها با توجه به فناوری‌های امنیتی، به ویژه به

✦ نوع مقاله: ترویجی

* نویسنده مسئول

پست(های) الکترونیک: m_raoufmoghadam@modares.ac.ir (رئوف مقدم)

ebrahimikm@modares.ac.ir (ابراهیمی)

¹ Artificial intelligence

² Neural network

³ Deep learning

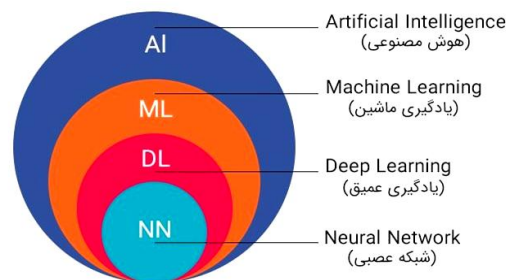
⁴ Machin learning

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 می‌پذیرد. این شبکه‌ها بیشترین استفاده را در برنامه‌هایی دارند که بیان آنها با یک الگوریتم سنتی که از برنامه‌نویسی قاعده-بنیان استفاده می‌کند، دشوار است.

شبکه عصبی مصنوعی، مجموعه‌ای از واحدهای متصل یا گره، به نام نورون‌های مصنوعی (مشابه نورون‌های زیستی در یک مغز زیستی) می‌باشد. هر اتصال (یا سیناپس) میان نورون‌ها می‌تواند سیگنالی را از یک نورون به نورون دیگر انتقال دهد. نورون دریافت‌کننده (پست سیناپتیک) می‌تواند سیگنال‌ها و در ادامه نورون‌های پایین دستی سیگنال متصل به آنها را پردازش کند. نورون‌ها ممکن است دارای حالت باشند، که به طور معمول با اعداد حقیقی بین ۰ و ۱ نمایش داده می‌شوند. 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. به طور معمول 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 مساله 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 به طور معمول از چند هزار تا چند میلیون واحد و اتصال برخوردار بودند. اگرچه این عدد به مراتب کوچک‌تر از تعداد نورون‌های مغز انسان است، اما این شبکه‌ها قادرند فعالیت‌های زیادی را در سطح فرانسانی انجام دهند [۱].

کسب مهارت از طریق تجربه و بدون دخالت کاربر را داشته باشد، از عبارت یادگیری ماشین استفاده می‌شود. در یادگیری ماشین، از دو مفهوم شبکه عصبی (با الهام از ساختار مغز) و یادگیری عمیق استفاده می‌شود. بنابراین، یادگیری عمیق بخشی از یادگیری ماشین و یادگیری ماشین خود بخشی از هوش مصنوعی به حساب می‌آید (شکل (۱)).



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

از طرف دیگر، پیشرفت‌ها و افزایش توان پردازش رایانه‌ها در کنار توانمندتر شدن روش‌های هوش مصنوعی، زمینه را برای استفاده از آنها در بسیاری از طرح‌های هوافضایی راحت‌تر نموده است. استدلال‌های نظری و بیولوژیکی بیانگر نیاز به مدل‌هایی با معماری عمیقی در راستای ساخت سیستمی هوشمند با توانایی استخراج بازنمایی‌های سطح بالا و قدرتمند از داده‌ها است که شامل بسیاری از لایه‌های پردازشی غیرخطی است. شاید بتوان از شبکه‌های عصبی چندلایه به عنوان بهترین و پرکاربردترین نمونه از این شبکه‌ها، به دلیل سازگاری آنها با انواع داده‌ها، نام برد. شبکه‌های عصبی عمیق ساختارهای متفاوت، انواع مختلف و گونه‌های متنوعی دارند و با توجه به نوع داده‌ها و هدف مساله از آنها استفاده می‌شود و هر کدام دارای نقاط قوت و ضعف خاص خود است. با توجه به اهمیت این شبکه‌ها، در این مقاله به بررسی و کاربرد آنها در مساله‌های مختلف هوافضایی پرداخته خواهد شد. برای این منظور ابتدا مفاهیم پایه‌ای بیان شده و در ادامه کاربردها بررسی خواهند شد.

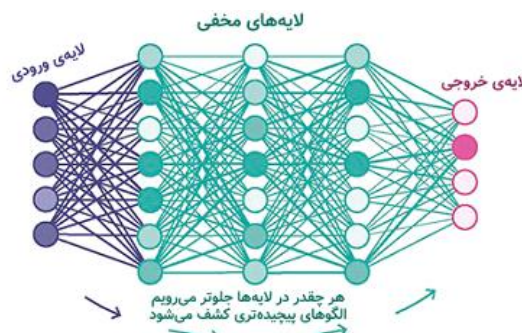
۲. شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی یا سیستم‌های اتصال‌گر، سیستم‌های محاسبه‌گری هستند که از شبکه‌های عصبی زیستی تشکیل‌دهنده

¹ Backpropagation

۳. یادگیری عمیق و شبکه عصبی عمیق

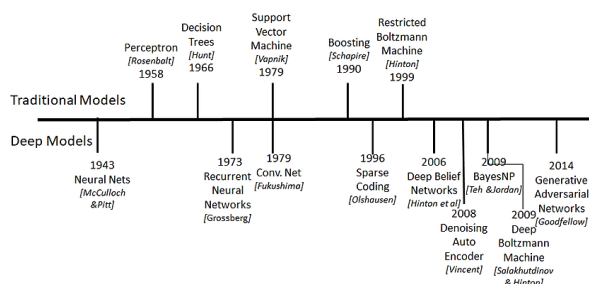
یادگیری عمیق نوعی شبکه عصبی بوده که در آن هر لایه پنهان، مسئول آموزش مجموعه‌ای از ویژگی‌های منحصربفرد است که برپایه خروجی لایه پیشین عمل می‌کند. همانطور که در شکل (۲) مشاهده می‌شود، شبکه عصبی عمیق، یک شبکه عصبی چند لایه با چندین لایه مخفی است.



شکل (۲): نمونه شبکه عصبی عمیق

پیتز و در سال ۱۹۵۷، الگوریتم پرسپترون توسط روزنبلات ارائه شد. سال ۱۹۶۹، مینسکی و پاپرت با چاپ مقاله نشان دادند که پرسپترون قادر به حل مساله‌های خطی است. سپس در سال‌های ۱۹۷۴، ۱۹۸۶ و ۱۹۹۸، سه الگوریتم پس‌انتشار توسط وربوس، روملها و لکان ارائه شدند. فعالیت‌های این سه نفر موجب احیای شبکه عصبی شده و آنها در تحقیقات خود توانستند شبکه چند لایه را آموزش دهند.

در سال ۲۰۱۲، تیمی تحت رهبری دالی، با استفاده از شبکه‌های عصبی چندلایه در چالش فعالیت مولکولی مرک پیروز شد و در سال ۲۰۱۴ از یادگیری عمیق به منظور شناسایی اثرات سمی و نامطلوب مواد شیمیایی در تغذیه، فرآورده‌های خانگی و دارو استفاده شد [۳]. سال‌های ۲۰۱۲ و ۲۰۱۴ را می‌توان به عنوان انقلاب بزرگ در یادگیری عمیق یاد کرد. شکل (۴) تاریخچه پیدایش یادگیری عمیق را نشان می‌دهد.



شکل (۴): نوار زمانی تکنولوژی هوش مصنوعی [۳]

از طرف دیگر، الگوریتم‌های یادگیری عمیق دارای معماری ویژه با تعداد لایه‌های فراوان بوده که در یک شبکه قرار دارند. یادگیری عمیق برخلاف یادگیری ماشین، مساله به قسمت‌های کوچک‌تر تقسیم نشده و به شکل کامل حل می‌شود (شکل (۳)). همچنین همانطور که انسان‌ها از طریق تجربه، چیزهای جدید را فرا می‌گیرند، الگوریتم یادگیری عمیق نیز با هر بار تکرار یک کار، مهارت خود را نسبت به دفعات قبلی بهبود می‌بخشد [۲].

۳.۲. 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 چند لایه هستند. قواعد یادگیری، رویه‌ای برای اصلاح وزن‌ها و بایاس‌ها هستند که در راستای آموزش شبکه برای انجام کار خاصی مورد استفاده قرار می‌گیرد. در ادامه این بخش، پنج دسته اصلی یادگیری‌های عمیق به طور خلاصه، مورد بررسی قرار گرفته است.

یادگیری ماشین (Machine Learning)



یادگیری عمیق (Deep Learning)



شکل (۳): تفاوت یادگیری ماشین و یادگیری عمیق

۳.۱. تاریخچه یادگیری عمیق

در سال ۱۹۴۰ عناوین متفاوتی مانند فرمان‌شناسی و ارتباط‌گرایی و مشهورترین آنها یعنی شبکه عصبی به وجود آمده است. سپس در سال ۱۹۴۳، اولین مدل یادگیری عمیق توسط مک کلاچ و

آموزش در دامنه هدف را کاهش دهد. به همین دلیل استفاده از یادگیری انتقالی در یادگیری عمیق در حال حاضر بسیار محبوب است [۴].

یادگیری عمیق هندسی^{۱۰}: این نوع یادگیری، تقریباً زمینه نوظهور تحقیقاتی است که سعی در تعمیم معماری یادگیری عمیق برای کار با داده‌های غیراقلیدسی دارد، تا این شکاف را پر نماید. داده‌های غیراقلیدسی می‌توانند مفاهیم پیچیده‌تری را با دقت بیشتری نسبت به نمایش‌های یک بعدی و دو بعدی نشان دهند. یکی از ساختارهای غیراقلیدسی مهم، گراف می‌باشد. داده‌ها با ساختار گراف در دنیای واقعی فراوان بوده و در همه جا دیده می‌شوند [۵].

در جدول (۱) خلاصه‌ای از چندین مدل معمول یادگیری عمیق و همچنین معماری‌های پیشرو که در سال‌های اخیر معرفی شده، ذکر شده است.

۳.۳. چالش‌ها

ممکن است مشکلات زیادی برای شبکه‌های عصبی عمیق مانند شبکه‌های عصبی مصنوعی، که بسیار ساده آموزش داده شده‌اند، به وجود آید. دو مساله متداول در این زمینه شامل بیش‌برازش 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 بیش‌برازش آسیب‌پذیر هستند. روش‌های منظم‌سازی از قبیل هرس کردن واحد اوآخنگو یا زوال وزنی (منظم‌سازی نرم ۲) یا تُنکی (منظم‌سازی نرم ۱) را می‌توان طی آموزش برای مقابله با بیش‌برازش استفاده کرد. به عنوان گزینه‌ای دیگر، منظم‌سازی بیرون انداز، طی آموزش، واحدهایی را به طور 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، به گونه‌ای افزون کرد که مجموعه‌های آموزشی کوچکتر اندازه بزرگتری پیدا کنند تا احتمال بیش‌برازش کاهش یابد.

یادگیری بانظارت^۱ عمیق: موفقیت شگفت‌آور یادگیری عمیق، به طور عمده 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 شده و تغییر وزن‌ها تا زمانی انجام می‌شود که اختلاف خروجی شبکه با خروجی مطلوب، در حد قابل قبول باشد.

یادگیری بانظارت بدون نظارت^۵ عمیق: در سال‌های اخیر، علاقه زیادی به یادگیری بدون نظارت با معرفی دو مدل مولد عمیق جدید به ویژه شبکه مولد تخصصی^۶ و شبکه خودرمنگار^۷ متغیر بوجود آمده است. پیش‌بینی می‌شود که یادگیری بدون نظارت نقش مهمی در آینده یادگیری عمیق داشته باشد. در این نوع از یادگیری، باید به دنبال یافتن الگوی شباهت میان داده‌ها و دسته‌بندی آنها درون خوشه‌ها بود. در واقع وزن‌ها بر اساس ورودی‌ها اصلاح می‌شوند و خروجی مطلوب وجود ندارد تا با مقایسه خروجی شبکه با آن و تعیین مقدار خطا، وزن‌ها اصلاح شوند.

یادگیری تقویتی^۸ عمیق: هنگام برخورد با ورودی‌های بسیار بزرگ، یادگیری تقویتی از مشکل نمایش نامناسب ویژگی‌ها رنج می‌برد. بنابراین یادگیری آرامی را به همراه دارد و باید روش‌هایی 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 سیستم‌های هوش مصنوعی تلاش می‌کند.

یادگیری انتقالی^۹ 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 می‌تواند به میزان قابل توجهی نیاز به داده‌های آموزشی و زمان

¹ Supervised learning

² Feedforward neural network

³ Recurrent neural network

⁴ Convolutional neural network

⁵ Unsupervised Learning

⁶ Generative adversarial networks

⁷ Autoencoder

⁸ Reinforcement learning

⁹ Transfer learning

¹⁰ Geometric deep learning

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. در کاربردهای LOT با داده‌های وابسته به زمان مفید است.
RBM	Generative	نظارت نشده و بانظارت	مختلف	مناسب برای استخراج ویژگی، کاهش ابعاد، طبقه‌بندی روش آموزش گران و پرهزینه
DBN	Generative	نظارت نشده و 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. لایه‌های متحرک بزرگترین بخش محاسبات را می‌گیرند.
CNN	Discriminative	بانظارت	دو بعدی (تصویری، صدا و غیره)	اتصال کمتر نسبت به DNN نیاز به یک مجموعه داده‌های آموزشی بزرگ برای وظایف بصری
VAE	Generative	نیمه‌نظارت	مختلف	یک کلاس از Auto-encoder مناسب برای کمبود داده‌های برچسب‌گذاری شده
GAN	ترکیبی	نیمه‌نظارت	مختلف	مناسب برای داده‌های نویزدار متشکل از دو شبکه Generator و Discriminator
Ladder Net	ترکیبی	نیمه‌نظارت	مختلف	مناسب برای داده‌های نویزی متشکل از سه شبکه شامل دو رمز گذار و یک رمز گشا

شبکه‌های عصبی عمیق باید پارامترهای آموزشی فراوانی مانند اندازه (تعداد لایه‌ها و تعداد واحدها در هر لایه)، سرعت یادگیری و وزن‌های اولیه را در نظر بگیرند. جاروب کردن فضای پارامتر برای پیدا کردن پارامترهای بهینه ممکن است به علت هزینه زمانی و منابع محاسباتی، بهینه نباشد. راه کارهای متفاوتی مثل دسته‌سازی (محاسبه گرادیان در چند مثال آموزشی به طور همزمان، نه جداگانه) محاسبه را تسریع می‌کنند. توانایی‌های پردازشی وسیع در معماری‌های با هسته‌های زیاد به علت تناسب این معماری‌های پردازشی با محاسبات ماتریسی و برداری، آموزش را به طور 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 فرآیند 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. به هر حال، 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. با این همه پیشرفت در یادگیری عمیق با اشتباه بی‌پایان انسان‌ها برای قدرت محاسباتی همراه است و توسعه بیشتر، نیاز به روش‌های محاسباتی بسیار کارآمدتر دارد [۶].

یادگیری عمیق به طور تصادفی گران نیست، بلکه طراحی باعث چنین موضوعی شده است. انعطاف‌پذیری یادگیری عمیق، مدل‌سازی پدیده‌های مختلف و کنار زدن مدل‌های دیگر به طور

یادگیری عمیق با این همه پیشرفت در یادگیری عمیق با اشتباه بی‌پایان انسان‌ها برای قدرت محاسباتی همراه است و توسعه بیشتر، نیاز به روش‌های محاسباتی بسیار کارآمدتر دارد [۶].

عصبی است و معمولا الگوریتم پس انتشار با سه مشکل اساسی شامل گرادیان محوشونده، بارمحاسباتی و بیش‌برازش^۳ در فرآیند آموزش شبکه عصبی عمیق مواجه است.

۴. کاربرد یادگیری عمیق در هوافضا

با پیشرفت روزافزون 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.

۴.۱. کاربرد یادگیری عمیق در فضاپیما

در سال‌های اخیر، از یادگیری عمیق به منظور هدایت و کنترل فضاپیماها استفاده شده است [۷]، [۸]. در مرجع [۸]، یک روش جدید به نام هدایت عمیق که از یادگیری تقویتی عمیق استفاده می‌کند، ارائه شده است. همان‌طور که ذکر شد، یادگیری تقویتی عمیق ترکیبی از یادگیری تقویتی و شبکه عصبی عمیق است. به هر حال، روش هدایت عمیق ارائه شده شامل یک استراتژی هدایت است که برای 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

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

- تعداد عملیات نقطه شناور مورد نیاز برای یک گذر در شبکه
 - توانایی محاسباتی سخت‌افزار 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 سخت‌افزارها نیز بهبود پیدا کنند. محققان همچنین متوجه شدند که بار محاسباتی واقعی مدل‌های یادگیری عمیق مقیاس‌پذیری سریع‌تری نسبت به مرزهای پایینی از نقطه نظر تئوری دارند که نشان‌دهنده امکان پیشرفت‌های اساسی در این بخش است. به گفته آنها، پیشرفت‌های یادگیری عمیق در سطح الگوریتمی همیشه در حال رخ دادن است که برخی از آنها شامل شتاب‌دهنده سخت‌افزاری می‌شود.

۳.۴. بهبود شبکه عصبی عمیق

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

به‌رغم 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 پایین شبکه عصبی با لایه‌های عمیق، عدم امکان آموزش مناسب شبکه

¹ Deep belief network

² Boltzmann machine

³ Overfitting

مدل‌های جایگزین برای سیستم‌های دینامیکی هواپیما استفاده شود. در مرجع [۱۳]، شبکه عصبی پیچشی عمیق برای طراحی معکوس ایرفویل مورد استفاده قرار گرفته است.

در مرجع [۱۴]، محیط آموزش برای هدایت فرود هواپیما بر اساس یادگیری تقویتی عمیق طراحی شده است. در این محیط، بررسی‌ها فقط با تغییر زاویه سمت انجام شده است، در حالی که می‌توان علاوه بر زاویه سمت، سرعت هواپیما را نیز تغییر داد. در مرجع [۱۵]، روشی برای کنترل بال‌های مورفینگ با استفاده از یادگیری عمیق ارائه شده است. از رویکرد یادگیری عمیق برای مدل‌سازی داده‌ها و پیش‌بینی تاخیر در پرواز نیز استفاده شده است [۱۶].

۴.۳. کاربرد در وسایل پرنده بدون سرنشین

یادگیری عمیق برای هدایت، کنترل و برنامه‌ریزی مسیر حرکت پرنده‌های بدون سرنشین در پژوهش‌های متعددی مورد استفاده قرار گرفته است. در مرجع [۱۷]، از یادگیری عمیق به منظور برنامه‌ریزی مسیر برای ردیابی هدف زمینی در وسایل پرنده بدون سرنشین بهره برده شده است. در پژوهش [۱۸]، روشی مبتنی بر یادگیری تقویتی عمیق برای ناوبری پرنده بدون سرنشین با استفاده از تکنیک چند ورودی-چند خروجی ارائه شده است. در مرجع [۱۹]، روشی با بهره‌گیری از شبکه‌های عصبی مارکو برای هدایت، کنترل و ناوبری وسایل پرنده پیشنهاد شده است. طراحی و ارزیابی پرواز کنترل‌کننده تطبیقی با استفاده از مدل مرجع عمیق در پژوهش [۲۰] انجام شده است. در مرجع [۲۱]، برنامه‌ریزی و بهینه‌سازی مشترک مسیر پرنده‌های بدون سرنشین بر اساس یادگیری تقویتی چندعامله ارائه شده است. ردیابی هدف پرنده بدون سرنشین با استفاده از یادگیری عمیق در [۲۲] صورت پذیرفته است.

استفاده از شبکه عصبی عمیق برای کنترل ارتفاع و معلق ماندن وسایل پرنده در هوا در مرجع [۲۳] مورد بررسی قرار گرفته است. در این بررسی، شبکه با استفاده از روش یادگیری نظارت شده آموزش دیده است. عملکرد کنترلر بر مبنای سه الگوی مختلف آموزش شامل the standard feedforward method.

سیاست‌های آموزش دیده در شبیه‌سازی اغلب به خوبی به واقعیت منتقل نمی‌شوند. برای این امر یک کنترلر معمولی وظیفه ردیابی را به عهده دارد. در این روش از استراتژی‌های مختلف هدایت برای ردیابی و docking فضاپیما استفاده شده است. در مرجع [۹]، از یادگیری بدون نظارت در مرحله آموزش مقدماتی و الگوریتم پس‌انتشار به عنوان الگوریتم نظارت شده در مرحله پایانی برای تشخیص خطای سیستم پیش‌رانش فضاپیما استفاده شده است. روش ارائه شده در این مقاله، بر معایب روش‌های سنتی غلبه کرده و برای توصیف ویژگی‌های پیچیده و پنهان تجهیزات مناسب‌تر است و شناخت دقیق‌تری از وضعیت سلامت تجهیزات را تحت وظایف نظارت پیچیده امکان‌پذیر می‌کند.

۴.۲. کاربرد یادگیری عمیق در هواپیما

یادگیری عمیق در هواپیماها نیز مورد توجه و استفاده قرار گرفته است. از آن جمله می‌توان به مرجع [۱۰] اشاره کرده که آموزش ترکیبی برخطی برای سرعت بخشیدن به روش یادگیری تقویتی عمیق برای کنترل هواپیماهای تجاری را ارائه کرده است. روش ارائه شده از یادگیری تقویتی عمیق و یادگیری تقلیدی و یک کنترل‌کننده PID برای سرعت بخشیدن به فرآیند یادگیری و همچنین کاهش هزینه استفاده کرده است. نتایج نشان می‌دهد که شبکه آموزش داده شده قوی‌تر از کنترلر PID پایه است. در مرجع [۱۱]، محققان به ارزیابی ایمنی هوانوردی با استفاده از سوابق داده‌های مسیر پرواز پرداخته‌اند. در [۱۲]، از شبکه‌های عصبی بازگشتی عمیق برای شبیه‌سازی دینامیکی هواپیما ۱۰۰-۷۴۷ برای کاهش هزینه‌های آموزش و شبیه‌سازی استفاده شده است. در این روش، از شبکه‌های آموزش دیده برای پیش‌بینی پاسخ هواپیما در اختلالات و ورودی‌های کنترلی دلخواه بهره برداری شده است. نتایج نشان می‌دهد روش پیشنهادی با دقت می‌تواند پاسخ هواپیما را پیش‌بینی کرده و از قابلیت‌های برون‌یابی عالی برخوردار است. علاوه بر این، دارای راندمان محاسبه بهتری در مقایسه با یک روش عددی کلاسیک مانند رانگ کوتا مرتبه چهارم است. این روش می‌تواند به عنوان

عرشه کشتی در شرایط مختلف جوی دریا، فرود روی باندهای مختلف و با حضور نویز نیز استفاده شده است [۳۲]. از یادگیری ترکیبی در شبیه‌سازی دینامیک وسیله هوایی بدون سرنشین [۳۳] و از یادگیری عمیق جهت پیش‌بینی سینماتیک برای هواپیماهای مستقل [۳۴]، بهره برده شده است.

در مرجع [۳۵]، روشی برای شناسایی عیب در سیستم پرنده بدون سرنشین با استفاده از یادگیری عمیق ارائه شده است. این سیستم برای پردازش تصویر و تشخیص الگو از سیستم تعبیه شده سوار بر پرنده استفاده می‌کند که باعث صرفه‌جویی در پهنای باند انتقال و کوتاه شدن زمان واکنش می‌شود. همچنین در این سیستم تشخیص هدف و کنترل پرواز پرنده بر اساس یادگیری عمیق تحقق می‌یابد. تشخیص هدف متحرک مبتنی بر یادگیری عمیق برای وسایل نقلیه هوایی بدون سرنشین در مرجع [۳۶] نیز به عنوان هدف، در نظر گرفته شده است. در روش پیشنهادی این مقاله، از شبکه‌های عصبی پیچشی برای ردیابی هدف متحرک، از فیلتر کالمن برای بهبود دقت اطلاعات و از الگوریتم‌های مختلف برای پردازش سریع تصاویر بهره برده شده است. مشکل این روش آن است که فقط می‌تواند یک تصویر واحد را همزمان پردازش کند و فاقد توجه به روابط بین تصاویر سابق می‌باشد.

روشی بر مبنای یادگیری بدون نظارت برای درک محیط توسط پرنده بدون سرنشین در مرجع [۳۷] ارائه شده است که از شبکه عصبی خودرمزگذار و رمزگشای عمیق برای درک محیط استفاده کرده است. در این روش، الگوریتم کدگذاری عمیق با بهره‌گیری از شبکه سنتی autoencoder پیشنهاد شده و ساختار الگوریتم می‌تواند تصویر را بازسازی کند که برای نمایش محیط مناسب است.

دامنه استفاده از یادگیری عمیق در زمینه پرنده‌های بدون سرنشین بسیار گسترده‌تر است. از آن جمله می‌توان به ردیابی سریع و دقیق مسیر برای وسایل نقلیه هوایی بدون سرنشین [۳۸] - [۴۱]، طراحی مسیر بهینه برای تهیه فیلم توسط UAV [۴۲]، پیاده‌سازی سیستم هشداردهنده موقعیت پرنده بدون سرنشین [۴۳]، کنترل مداوم سیستم‌های مالتی کوپتر [۴۴] - [۴۵]، جلوگیری از برخورد

the greedy layer-wise method و LSTM مقایسه شده است. نتایج نشان می‌دهد روش دوم نتایج بهینه‌تری را ارائه داده است. سنجش بصری-اینرسی مسافت UAV با استفاده از شبکه‌های عصبی پیچشی در مرجع [۲۴] انجام شده است. در کاری مشابه، روشی برای بهینه‌سازی مسیر چند UAV و تجزیه و تحلیل تصاویر مبتنی بر یادگیری عمیق در [۲۵] ارائه شده است. در این روش از الگوریتم Google Vision API Soft OCR برای پردازش تصاویر استفاده شده است. در پژوهش [۲۶]، روشی برای ناوبری پرنده بدون سرنشین در فضاهای خالی ارائه شده است. در مرجع [۲۷]، جستجوی خودکار هدف پرنده بدون سرنشین بر اساس یادگیری تقویتی عمیق در صحنه‌های پیچیده در حوادث ناگوار بررسی شده است.

محققان در [۲۸]، اشیا را که بلادرنگ در حال حرکت هستند با استفاده از یک آشکارساز مبتنی بر یادگیری عمیق، برجسته می‌کنند. پس از آن، برای کنترل هوایی موثر پرنده بدون سرنشین اشیا که شناسایی شده‌اند، توسط عملکرد تفاوت تصویر برجسته می‌شوند. در این بخش، مهمترین وظیفه مشخص کردن متحرک بودن اشیا و میزان حرکت آنها است.

از یادگیری تقویتی عمیق برای ارائه روشی جهت کنترل موقعیت پرنده بدون سرنشین بال ثابت نیز استفاده شده است [۲۹]. در این روش، یک کنترلر تقویتی عمیق برای حل مساله کنترل غیرخطی بکار برده شده است و با یک کنترلر PID مقایسه شده که نتایج بهتری را ارائه داده است. همچنین این روش از الگوریتم LSTM برای طراحی کنترلر تقویتی عمیق استفاده کرده است.

در مرجع [۳۰]، محققان از شبکه‌های بازگشتی و پیچشی عمیق برای طراحی سیستم کنترل فرود خودکار تحمل‌ناپذیر خطا در شرایط سخت بهره برده‌اند. در کاری مشابه، محققان [۳۱]، در فرود خودمختار پرنده بدون سرنشین از یادگیری تقویتی عمیق استفاده کرده‌اند. در این پژوهش، آموزش شبکه در یک محیط پیچیده‌تر با نویز بیشتر و انتقال شبکه آموزش دیده به کارهای دنیای واقعی صورت پذیرفته است. از الگوریتم‌های یادگیری عمیق برای شبیه‌سازی فرود ایمن و پایدار ناوگان حمل و نقل هوایی بدون سرنشین در شرایط مختلف از جمله فرود بر روی

با مانع برای پرنده‌های بدون سرنشین با دانش محیطی محدود [۴۶]-[۴۸]، کنترل موثر انرژی برای پوشش ارتباطی موثر [۴۹]، بینایی ماشین [۵۰]-[۵۱]، طبقه‌بندی و تشخیص میکرو UAS با استفاده از رادارهای تشخیصی و یادگیری عمیق [۵۲]، مکانیسم انتقال برای وسایل پرنده بدون سرنشین [۵۳] و توسعه سیستم مانیوتورینگ UAV [۵۴]، اشاره کرد.

۴.۴. کاربرد در پرواز آرایشمند وسایل پرنده

پس از بررسی منابع که به استفاده از یادگیری عمیق در مساله‌های هوافضایی پرداخته‌اند، در ادامه مطالعاتی که در راستای پرواز آرایشمند وسایل پرنده هوایی و فضایی مختلف انجام شده است، مرور می‌شود.

در مرجع [۵۵]، ارتباط تعاملی مداوم UAVها با اولویت در پرواز آرایشی با استفاده از یادگیری تقویتی عمیق بررسی شده است. در روش ارائه شده، امکان اشتراک اطلاعات بین دو پرنده بدون سرنشین در صورت عدم وجود ماموریت بررسی شده است. همچنین سه نوع الگوریتم یادگیری تقویتی شامل یادگیری Q، DQN و LSTM+DQN مورد مطالعه قرار گرفته و نتایج تجربی نشان می‌دهد در مقایسه با روش Q-Learning و Q-network عمیق، روش پیشنهادی به همگرایی سریع‌تر و بهینه‌تر می‌رسد. کنترل پرواز آرایشی پرنده‌های بدون سرنشین در مراجع [۵۶]، [۵۷] و [۵۸] نیز مورد هدف قرار گرفته است. کنترل آرایش پرواز بین ماهواره‌ها با استفاده از یادگیری عمیق نیز در مرجع [۵۹] بررسی شده است.

یک روش کنترل بهینه پرواز آرایشی ناهمگن از طریق یادگیری تقویتی برای ردیابی مسیر در پژوهش [۶۰] ارائه شده است. در این مطالعه، یک روش کنترل بهینه توزیع شده از طریق یادگیری تقویتی به منظور رفع مشکل ردیابی مسیر در پرنده‌های بدون سرنشین پیشنهاد شده است. پرواز آرایشی ارائه شده متشکل از یک رهبر مجازی با تعداد محدود ورودی غیرصفر و چندین دنبال‌کننده (پیرو) با دینامیک ناشناخته متفاوت است.

محققان در [۶۱]، روشی برای شناسایی مسیرهای نسبی در مانورهای بدون برخورد پروازهای آرایشی وسایل بدون سرنشین

با استفاده از دینامیک بازسازی شده عصبی ارائه کرده‌اند. در این روش، آنها یک الگوریتم یادگیری تقویتی برای انجام پیکربندی تنظیم و نگهداری در پرواز آرایشی وسایل پرنده و دو الگوریتم یادگیری تقویتی معکوس و شبکه حافظه طولانی کوتاه مدت، برای بازسازی و پیش‌بینی مسیرهای آینده و برای انجام مانورهای بدون برخورد، پیشنهاد داده‌اند. در مرجع [۶۲] یک کنترلر زمان متغیر برای وسایل نقلیه هوایی بدون سرنشین در پرواز آرایشی با استفاده از یادگیری تقویتی عمیق ارائه شده است. در این روش، یادگیری تقویتی عمیق برای هدایت وسایل پرنده به منظور دستیابی به هرگونه آرایش پروازی مورد استفاده قرار گرفته است. در واقع، 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. نتایج نشان می‌دهد، این روش برای توسعه کنترلرهای مقیاس‌پذیر، بهینه و قابل حمل مناسب است.

شناسایی آتش‌سوزی در تصاویر وسایل پرنده بدون سرنشین با استفاده از یادگیری عمیق در مرجع [۶۳] ارزیابی شده است. در روش پیشنهادی این پژوهش، از یادگیری عمیق برای تشخیص رنگ، شکل و بافت آتش (دود، شعله یا هر دو) استفاده شده است. برای نشان دادن کاربرد عملی این روش، محققان آن را بر روی ۴۰ تصویر نمونه در گزارش‌های خبری آتش‌سوزی آزمایش کرده‌اند. نتایج نشان دهنده دقت ۹۸٪ روش آنها است. همچنین روش آنها سرعت پردازش متوسط ۴۱/۵ میلی‌ثانیه در هر تصویر را تضمین می‌کند. بیان این نکته مهم است که یادگیری عمیق در یادگیری ویژگی‌های سطح بالا بسیار موثر است، با این حال، استفاده از مقدار قابل توجهی از مجموعه داده‌های تصاویر آموزشی در بهینه‌سازی مقدار و ضرایب وزن آن الزامی است.

پرواز آرایشمند هواپیماهای مسافربری پتانسیل زیادی برای کمک به صنعت حمل و نقل هوایی دارد که بیشتر از طریق به‌روزرسانی عملیات شبکه پرواز، باعث کاهش مصرف سوخت، تاثیرات زیست محیطی و بار کاری برج مراقبت می‌شود. در نتیجه مفهوم پرواز آرایشی به سرعت در حال پیشرفت است. 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

شرایط موجود در پرواز، باید کنترلگری انتخاب شود که قابلیت بالایی در دفع اغتشاشات وارد بر سیستم و کاهش اثر تداخل بین حلقه‌های کنترلی را داشته باشد. در مطالعات و پژوهشی که توسط نویسندگان مقاله در حال انجام است، طراحی کنترلگر با در نظر گرفتن شرایط نزدیک به واقعیت (تا حد امکان) مد نظر است زیرا عدم توجه به آنها باعث ایجاد فاصله بین شبیه‌سازی‌ها و شرایط واقعی می‌شود که در راستای این هدف از الگوریتم‌های یادگیری عمیق استفاده شده است.

۵. نتیجه‌گیری

در این مقاله پس از تعریف مبانی، تاریخچه، انواع شبکه و معماری‌های یادگیری عمیق، چالش‌های پیش رو 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 از این 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 است، طراحی آن است. همچنین انعطاف‌پذیری یادگیری عمیق، مدل‌سازی پدیده‌های مختلف و کنار زدن مدل‌های دیگر را در پی دارد که به طور 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.

تعارض منافع: نویسندگان اعلام می‌کنند که هیچ تعارض منافعی ندارند.

رشد، تعداد مسافران هوایی در سال ۲۰۳۹ به بیش از ۲ میلیارد نفر خواهند رسید. صنعت هوانوردی که به دلیل کرونا وارد رکود شده است، به زودی احیا خواهد شد. از دیدگاه ترافیک هوایی نیز مهمترین مزیت پرواز دسته‌جمعی افزایش ظرفیت فضای پروازی است. 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 گلخانه‌ای است. 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 دسته‌جمعی را می‌توان بدین شکل برشمرد: کاهش میزان مصرف سوخت و افزایش برد، کاهش آلودگی ناشی از مصرف سوخت هواپیما و همچنین افزایش ظرفیت فضای پروازی.

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 شامل موارد زیر است:

- ۱) تلاطم راحتی مسافر را کاهش می‌دهد، بنابراین پروازهای آرایشمند باید راحتی مسافر را تضمین نمایند.
- ۲) در هنگام شروع و خاتمه آرایش هواپیماها، پرواز بایستی 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، لذا ضروری است تا آرایش پروازی کنترل شود. همان‌طور که در قبل بیان شد، راحتی سواری مسافران در این گونه 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. از طرف دیگر، به دلیل اهمیت و حساسیت بالای سیستم کنترل پرواز، نوع پرواز و

- [1] I.H. Sarker, "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions," *SN Comput. Sci.*, vol. 2, no. 6, p. 420, 2021, doi: 10.1007/s42979-021-00815-1.
- [2] F. He, P.K. Olia, R.J. Oskouei, M. Hosseini, Z. Peng, and T. BaniRostam, "Applications of Deep Learning Techniques for Pedestrian Detection in Smart Environments: A Comprehensive Study," *J. Adv. Transp.*, vol. 2021, no. 1, p. 5549111, 2021, doi: 10.1155/2021/5549111.
- [3] A. Mathew, P. Amudha, and S. Sivakumari, "Deep Learning Techniques: An Overview," in *Advanced Machine Learning Technologies and Applications*, *Adv. Intell. Syst. Comput.*, vol. 1141, Springer, Singapore, 2021, doi: 10.1007/978-981-15-3383-9_54.
- [4] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang, and C. Liu, "A Survey on Deep Transfer Learning," in *27th Int. Conf. Artif. Neural Networks (ICANN)*, Rhodes, Greece, 2018, pp. 270–279, doi: 10.1007/978-3-030-01424-7_27.
- [5] W. Cao, Z. Yan, Z. He, and Z. He, "A Comprehensive Survey on Geometric Deep Learning," *IEEE Access*, vol. 8, pp. 35929-35949, 2020, doi: 10.1109/ACCESS.2020.2975067.
- [6] N.C. Thompson, K.H. Greenewald, K. Lee, and G.F. Manso, "The Computational Limits of Deep Learning," *arXiv, CoRR abs/2007.05558*, 2020.
- [7] A.T. Harris and H. Schaub, "Spacecraft Command and Control with Safety Guarantees using Shielded Deep Reinforcement Learning," *AIAA 2020-0386*, *AIAA Scitech 2020 Forum*, 2020, doi: doi:10.2514/6.2020-0386.
- [8] K. Hovell and S. Ulrich, "On Deep Reinforcement Learning for Spacecraft Guidance," *AIAA 2020-1600*, *AIAA Scitech 2020 Forum*, 2020, doi: 10.2514/6.2020-1600.
- [9] H. Fang, H. Shi, Y. Dong, H. Fan, and S. Ren, "Spacecraft power system fault diagnosis based on DNN," in *2017 Progn. Syst. Health Manag. Conf. (PHM)*, Harbin, China, 2017, pp. 1-5, doi: 10.1109/PHM.2017.8079271.
- [10] M. Xin, Y. Gao, T. Mou, and J. Ye, "Online Hybrid Learning to Speed Up Deep Reinforcement Learning Method for Commercial Aircraft Control," in *3rd Int. Symp. Auton. Syst. (ISAS)*, Shanghai, China, 2019, pp. 305-310, doi: 10.1109/ISASS.2019.8757756.
- [11] X. Zhang and S. Mahadevan, "Aviation Safety Assessment Using Historical Flight Trajectory Data," *AIAA 2019-3415*, *AIAA Aviation 2019 Forum*, 2019, doi: 10.2514/6.2019-3415.
- [12] Y. Yu, H. Yao, and Y. Liu, "A Hybrid Learning Approach for the Simulation of Aircraft Dynamical Systems," *AIAA 2019-0436*, *AIAA Scitech 2019 Forum*, 2019, doi: 10.2514/6.2019-0436.
- [13] 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, 2019, doi: 10.2514/1.J057894.
- [14] 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 *11th Int. Symp. Comput. Intell. Des. (ISCID)*, Hangzhou, China, 2018, pp. 76-79, doi: 10.1109/ISCID.2018.10118.
- [15] V.G. Goecks, P.B. Leal, T. White, J. Valasek, and D.J. Hartl, "Control of Morphing Wing Shapes with Deep Reinforcement Learning," *AIAA 2018-2139*, *AIAA Information Systems-AIAA Infotech Aerospace*, 2018, doi: 10.2514/6.2018-2139.
- [16] Y.J. Kim, S. Choi, S. Briceno, and D. Mavris, "A deep learning approach to flight delay prediction," in *IEEE/AIAA 35th Digit. Avion. Syst. Conf. (DASC)*, Sacramento, CA, USA, 2016, pp. 1-6, doi: 10.1109/DASC.2016.7778092.
- [17] 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.
- [18] 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.
- [19] S. Lim, M. Stoeckle, B.J. Streetman, and M. Neave, "Markov Neural Network for Guidance, Navigation and Control," *AIAA 2020-0375*, *AIAA Scitech 2020 Forum*, 2020, doi: doi:10.2514/6.2020-0375.
- [20] G. Joshi, J. Viridi, and G. Chowdhary, "Design and Flight Evaluation of Deep Model Reference Adaptive Controller," *AIAA 2020-1336*, *AIAA Scitech 2020 Forum*, 2020, doi: doi:10.2514/6.2020-1336.
- [21] 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.
- [22] W. Zhang, K. Song, X. Rong, and Y. Li, "Coarse-to-Fine 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.
- [23] S. Edhah, S. Mohamed, A. Rehan, M. AlDhaheri, A. AlKhaja, and Y. Zweiri, "Deep Learning Based Neural Network Controller for Quad Copter: Application to Hovering Mode," in *Int. Conf. Electr. Comput. Technol. Appl. (ICECTA)*, Ras Al Khaimah, United Arab Emirates, 2019, pp. 1-5, doi: 10.1109/ICECTA48151.2019.8959776.
- [24] H. Lee, M. McCrink, and J.W. Gregory, "Visual-Inertial Odometry for Unmanned Aerial Vehicle using Deep Learning," *AIAA 2019-1410*, *AIAA Scitech 2019 Forum*, 2019, doi: doi:10.2514/6.2019-1410.
- [25] 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," *AIAA 2019-1569*, *AIAA Scitech 2019 Forum*, 2019, doi: doi:10.2514/6.2019-1569.
- [26] O. Walker, F. Vanegas, F. Gonzalez, and S. Koenig, "A Deep Reinforcement Learning Framework for UAV Navigation in Indoor Environments," in *IEEE Aerosp. Conf., Big Sky, MT, USA*, 2019, pp. 1-14, doi: 10.1109/AERO.2019.8742226.
- [27] C. Wu, B. Ju, Y. Wu, X. Lin, N. Xiong, G. Xu, H. Li, and X. Liang, "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.
- [28] J. Choi and W.-C. Park, "Object movement highlighting technique using a deep-learning based object detector for effective UAV control," in *34th Int. Techn. Conf. Circuits/Syst. Comput. Commun. (ITC-CSCC)*, JeJu, Korea (South), 2019, pp. 1-4, doi: 10.1109/ITC-CSCC.2019.8793321.
- [29] E. Bohn, E.M. Coates, S. Moe, and T.A. Johansen, "Deep Reinforcement Learning Attitude Control of Fixed-Wing UAVs Using Proximal Policy optimization," in *Int. Conf. Unmanned Aircraft Syst. (ICUAS)*, Atlanta, GA, USA, 2019, pp. 523-533, doi: 10.1109/ICUAS.2019.8798254.
- [30] C. Sahin, B. Eroglu, N.K. Ure, and H.B. Kurt, "Deep Recurrent and Convolutional Networks for Robust Fault Tolerant Autonomous Landing Control System Design Under Severe Conditions," *AIAA 2019-1665*, *AIAA Scitech 2019 Forum*, 2019, doi: doi:10.2514/6.2019-1665.
- [31] Y. Xu, Z. Liu, and X. Wang, "Monocular Vision based Autonomous Landing of Quadrotor through Deep Reinforcement Learning," in *37th Chinese Control Conf. (CCC)*, Wuhan, China, 2018, pp. 10014-10019, doi: 10.23919/ChiCC.2018.8482830.
- [32] D. Zhou, J. Zhou, M. Zhang, D. Xiang, and Z. Zhong, "Deep learning for unmanned aerial vehicles landing carrier in different conditions," in *18th Int. Conf. Adv. Robotics (ICAR)*, Hong Kong, China, 2017, pp. 469-475, doi: 10.1109/ICAR.2017.8023651.
- [33] Y. Yu and Y. Liu, "A Hybrid Learning Approach for the Simulation of Dynamics of Unmanned Aircraft Vehicle," *AIAA 2019-2940*, *AIAA Aviation 2019 Forum*, 2019, doi:10.2514/6.2019-2940.
- [34] R. Ravishankar and S.R. Chakravarthy, "Kinematic Prediction for Autonomous Aircraft Using Deep Learning Based Optical Detection," *AIAA 2019-3190*, *AIAA Aviation 2019 Forum*, 2019, doi:10.2514/6.2019-3190.
- [35] 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 *Iranian Conf. Electr. Eng. (ICEE)*, Mashhad, Iran, 2018, pp. 988-993, doi: 10.1109/ICEE.2018.8472529.
- [36] H. Yao, Q. Yu, X. Xing, F. He, and J. Ma, "Deep-learning-based moving target detection for unmanned air vehicles," in *36th Chinese Control Conf. (CCC)*, Dalian, China, 2017, pp. 11459-11463, doi: 10.23919/ChiCC.2017.8029186.
- [37] Y. Kaidi, M. Zhaowei, L. Jinhong, S. Sibao, and Z. Yulin, "Unsupervised Representation Learning Method for UAV's Scene Perception," in *IEEE 9th Int. Conf. Softw. Eng. Serv. Sci. (ICSESS)*, Beijing, China, 2018, pp. 323-327, doi: 10.1109/ICSESS.2018.8663930.
- [38] Y. Li, H. Li, Z. Li, H. Fang, A.K. Sanyal, Y. Wang, and Q. Qiu, "Fast and Accurate Trajectory Tracking for Unmanned Aerial Vehicles based on Deep Reinforcement Learning," in *IEEE 25th Int. Conf. Embed. Real-Time Comput. Syst. Appl. (RTCSA)*, Hangzhou, China, 2019, pp. 1-9, doi: 10.1109/RTCSA.2019.8864571.
- [39] U. Challita, W. Saad, and C. Bettstetter, "Deep Reinforcement Learning for Interference-Aware Path Planning of Cellular-Connected UAVs," in *IEEE Int. Conf. Commun. (ICC)*, Kansas City, MO, USA, 2018, pp. 1-7, doi: 10.1109/ICC.2018.8422706.
- [40] T. Watanabe and E.N. Johnson, "Trajectory Generation using Deep Neural Network," *AIAA 2018-1893*, *2018 AIAA Information Systems-AIAA Infotech Aerospace*, 2018, doi: doi:10.2514/6.2018-1893.
- [41] C. Wang, J. Wang, X. Zhang, and X. Zhang,

- “Autonomous navigation of UAV in large-scale unknown complex environment with deep reinforcement learning,” in IEEE Glob. Conf. Signal Inf. Process. (GlobalSIP), Montreal, QC, Canada, 2017, pp. 858-862, doi: 10.1109/GlobalSIP.2017.8309082.
- [42] D. Kwon and J. Kim, “Optimal Trajectory Learning for UAV-BS Video Provisioning System: A Deep Reinforcement Learning Approach,” in Int. Conf. Inf. Networking (ICOIN), Kuala Lumpur, Malaysia, 2019, pp. 372-374, doi: 10.1109/ICOIN.2019.8718194.
- [43] R. Geraldes, A. Goncalves, T. Lai, M. Villerabel, W. Deng, A. Salta, K. Nakayama, Y. Matsuo, and H. Prendinger, “UAV-Based Situational Awareness System Using Deep Learning,” IEEE Access, vol. 7, pp. 122583-122594, 2019, doi: 10.1109/ACCESS.2019.2938249.
- [44] A. Manukyan, M.A. Olivares-Mendez, M. Geist, and H. Voos, “Deep Reinforcement Learning-based Continuous Control for Multicopter Systems,” in 6th Int. Conf. Control Decis. Inf. Technol. (CoDIT), Paris, France, 2019, pp. 1876-1881, doi: 10.1109/CoDIT.2019.8820368.
- [45] S. Raj, M. Dreyer, and S. Gururajan, “Autonomous Quadcopter Navigation Using Vision-Based Landmark Recognition,” in Aviat. Technol. Integr. Oper. Conf., 2018, doi:10.2514/6.2018-4243.
- [46] 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. 22, no. 1, pp. 107-118, 2021, doi: 10.1109/TITS.2019.2954952.
- [47] 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 11th Int. Conf. Wirel. Commun. Signal Process. (WCSP), Xi’an, China, 2019, pp. 1-6, doi: 10.1109/WCSP.2019.8928110.
- [48] 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 IEEE Symp. Series Comput. Intell. (SSCI), Honolulu, HI, USA, 2017, pp. 1-8, doi: 10.1109/SSCI.2017.8285387.
- [49] 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.
- [50] L. Bashmal and Y. Bazi, “Learning Robust Deep Features for Efficient Classification of UAV Imagery,” in 1st Int. Conf. Comput. Appl. Inf. Secur. (ICCAIS), Riyadh, Saudi Arabia, 2018, pp. 1-4, doi: 10.1109/CAIS.2018.8441965.
- [51] G.V. Konoplich, E.O. Putin, and A.A. Filchenkov, “Application of deep learning to the problem of vehicle detection in UAV images,” in XIX IEEE Int. Conf. Soft Comput. Meas. (SCM), St. Petersburg, Russia, 2016, pp. 4-6, doi: 10.1109/SCM.2016.7519666.
- [52] G.J. Mendis, J. Wei, and A. Madanayake, “Deep learning cognitive radar for micro UAS detection and classification,” in Cogn. Commun. Aerosp. Appl. Worksh. (CCAA), Cleveland, OH, USA, 2017, pp. 1-5, doi: 10.1109/CCAAW.2017.8001610.
- [53] H. Yang, B. Hu, and L. Wang, “A deep learning based handover mechanism for UAV networks,” in 20th Int. Symp. Wirel. Pers. Multimedia Commun. (WPMC), Bali, Indonesia, 2017, pp. 380-384, doi: 10.1109/WPMC.2017.8301842.
- [54] H. Kim, D. Kim, S. Jung, J. Koo, J.-U. Shin, and H. Myung, “Development of a UAV-type jellyfish monitoring system using deep learning,” in 12th Int. Conf. Ubiquitous Robots Ambient Intell. (URAI), Goyangi, Korea (South), 2015, pp. 495-497, doi: 10.1109/URAI.2015.7358813.
- [55] 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.
- [56] J. Dunn and R. Tron, “Temporal Siamese Networks for Clutter Mitigation Applied to Vision-Based Quadcopter Formation Control,” IEEE Robotics Autom. Lett., vol. 6, no. 1, pp. 32-39, 2021, doi: 10.1109/LRA.2020.3028056.
- [57] 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,” J. Northw. Polytech. Univ., vol. 38, no. 2, pp. 295-302, 2020, doi: 10.1051/jnwpu/20203820295.
- [58] 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, no. 1, p. 7272387, 2019, doi: 10.1155/2019/7272387.
- [59] Q. Liu, E. Moulay, P. Coirault, and Q. Hui, “Deep Learning Based Formation Control for the Multi-Agent Coordination,” in IEEE 16th Int. Conf. Networking Sensing Control (ICNSC), Banff, AB, Canada, 2019, pp. 12-17, doi:

10.1109/ICNSC.2019.8743254.

- [60] 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: 10.1016/j.neucom.2020.06.040.
- [61] S. Silvestrini and M.R. Lavagna, "Spacecraft Formation Relative Trajectories Identification for Collision-Free Maneuvers using Neural-Reconstructed Dynamics," *AIAA 2020-1918, AIAA Scitech 2020 Forum*, 2020, doi: doi:10.2514/6.2020-1918.
- [62] R. Conde, J. Llata, and C. Torre-Ferrero, "Time-Varying Formation Controllers for Unmanned Aerial Vehicles Using Deep Reinforcement Learning," *arXiv, CoRR abs/1706.01384*, 2017.
- [63] Y. Zhao, J. Ma, X. Li, and J. Zhang, "Saliency Detection and Deep Learning-Based Wildfire Identification in UAV Imagery," *Sensors*, vol. 18, no. 3, p. 712, 2018, doi: 10.3390/s18030712.