فصلنامه علمی - پژوهشی فرماندهی و کنترل، سال هفتم، شماره دو، تابستان ۱۴۰۲

پشتیبانی تصمیم گیری مبتنی بر یادگیری تقویتی عمیق در مانور نبردهای هوایی

مهدی ذوالفقاری[*۱]*، حجت نورمحمدی*[*۲]*، گئورگ قره‌پتیان*[۳]*، حمید رادمنش*[۴]

تاریخ دریافت: ۱۴۰۲/۰۲/۲۲ **تاریخ پذیرش:** ۱۴۰۲/۰۵/۲۸

چکیده

در سال های اخیر، نبردهای هوایی گروهی و جمعی با استفاده از پهپادها در نیروهای مسلح کشورهای توسعه، یافته رواج پیدا کرده است. در این گونه از نبردها انتظار می‌رود که پهپادها، مانورهای چابک و ایمنی را با توجه محیط پویا و پیچیده میدان نبرد انجام دهند. تکنیک یادگیری تقویتی عمیق[۵](DRL)، که ابزاری مناسب برای تصمیم گیری های پیوسته در محیط های پویا و با عدم قطعیت بالا می‌باشد، گزینه ای مناسب برای پشتیبانی تصمیم گیری در مانورهای نبردهای هوایی[۶](ACMD) خواهد بود. علیرغم مطالعات فراوان در سال های اخیر بر روی کارکردهای یادگیری تقویتی در پشتیبانی تصمیم گیری، تاکنون نقشه راهی برای بکارگیری این تکنیک در پشتیبانی تصمیم گیری نبردهای هوایی ترسیم نگردیده است. بنابراین در این مقاله ابتدا تصویر کاملی از موضوعات موجود در این حوزه ترسیم خواهد شد. ابتدا یادگیری تقویتی عمیق تشریح خواهد شد و سپس کارکرد آن در پشتیبانی تصمیم گیری نبردهای هوایی بیان خواهد شد. سپس یک تکنیک تصمیم گیری در نبردهای هوایی یک به یک برای پیروزی پهپادها در مانور نبردهای هوایی ارائه خواهد شد. در طراحی مدل پیشنهادی از الگوریتم **DQN** که حالت پیشرفته ای از یادگیری تقویتی عمیق است، بهره گرفته شده است. آموزش مدل در سه حالت توازن، ضعف و برتری پهپاد در نبرد هوایی انجام شده است. همچنین یک تابع پاداش متناسب با حوزه پژوهش طراحی شده و در نهایت طراحی و ساخت مدل و ارزیابی آن نیز اجرا گردیده است. در شبیه سازی انجام شده، مدل ایجاد شده با هفت مانور مختلف پهپاد مورد آزمایش و ارزیابی قرار گرفته است. ارزیابی مدل ایجاد شده بیانگر عملکرد مطلوب آن در مدیریت مانورهای پهپادها در نبردهای هوایی پیچیده و با عدم قطعیت بالا دارد.

واژگان کلیدی: یادگیری تقویتی عمیق، مانور هوایی، پشتیبانی تصمیم.

[۱] استاد پژوهشگر همکار، مرکز بهره‌برداری ایمن شبکه، دانشگاه صنعتی امیرکبیر، تهران (mahdizolfaghari@aut.ac.ir)

[*۲] مدرس مهندسی نرم‌افزار، گروه مهندسی کامپیوتر دانشگاه فنی و حرفه‌ای لرستان، خرم‌آباد (hz657091@gmail.com)

[۳] استاد دانشکده مهندسی برق، دانشگاه صنعتی امیرکبیر، تهران (grptian@aut.ac.ir)

[۴] دانشیار، دانشکده مهندسی برق، دانشگاه علوم . فنون هوایی شهید ستاری، تهران، ایران (radmanesh@ssau.ac.ir)

[5] Deep Reinforcement Learning

[6] Air Combat Maneuver Decision-Making

۱. مقدمه

تکنیک‌های تصمیم‌گیری هوشمند برای پهپادها در انجام مأموریت‌های مختلف (مانند شناسایی، هشدار اولیه، اقدامات متقابل الکترونیکی و غیره) و در عین حال بقای خود ضروری است.[۱] تجهیزات هوایی سرنشین دار نیز می‌تواند از چنین تکنیک هایی استفاده نمایند. این قابلیت به فرماندهان و خلبانان اجازه می‌دهد تا به جای برنامه ریزی های پیچیده، انتخاب های خود را از لیست پیشنهادات بهینه انجام دهند و تمرکز خود را بر روی کلیت ماموریت حفظ نمایند. تصمیم گیری هوشمند برای پهپادها از سه مرحله اصلی تشکیل می‌شود، آگاهی از موقعیت، برنامه ریزی ماموریت و تصمیم گیری مانور.[۲][۳] [٤] [٥]آگاهی از موقعیت به پهپاد این امکان را می‌دهد تا موقعیت دقیق خود و تهدیدات را در فضای میدان نبرد درک نماید. برنامه ریزی ماموریت، طرح ها و برنامه های عملیاتی مناسبی را متناسب با محیط پویای نبرد ارائه می‌دهد. تصمیم گیری مانور نیز پهپاد را قادر می‌سازد تا اقدامات تاکتیکی حیاتی مانند فرار از صحنه یا حمله به اهداف را مطابق سیاست های تعیین شده انجام دهد. یک پهپاد با آگاهی موقعیتی کامل، برنامه ریزی ماموریت قوی و توانایی های تصمیم گیری مانور، شانس بیشتری برای پیروزی در نبرد هوایی دارد.

۱-۱.انواع الگوریتم های تصمیم گیری در نبرد هوایی

الگوریتم های تصمیم گیری جنگ هوایی هوشمند را می‌توان به چهار دسته تقسیم بندی کرد. اولین دسته، الگوریتم های مبتنی بر نظریه بازی[۷](GT) است. دومین دسته، الگوریتم های بهینه سازی اکتشافی هستند که شامل الگوریتم ژنتیک[۸](GA)، الگوریتم کلونی مورچه ها[۹](ACA)، الگوریتم مصونیت مصنوعی[۱۰](AIA) می‌شود. دسته سوم روش های مبتنی بر دانش مانند استنتاج بیزی[۱۱](BI) و سیستم های خبره[۱۲](ES) هستند. چهارمین دسته نیز روش های مبتنی بر شبکه عصبی مانند شبکه عصبی تابع پایه شعاعی[۱۳](RBFNN) و یادگیری تقویتی عمیق هستند. سیر زمانی توسعه این الگوریتم ها در شکل ۱ نشان داده شده است.

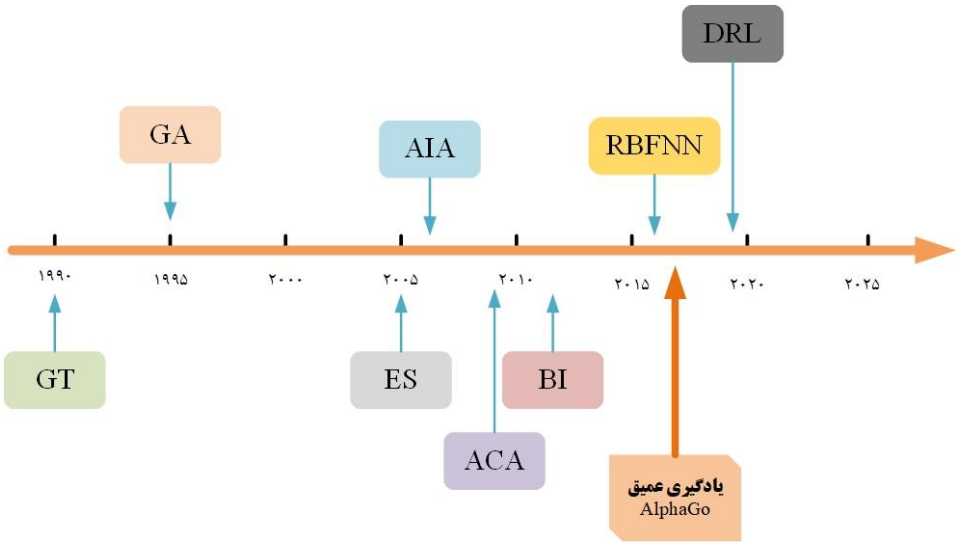

شکل ۱. سیر زمانی توسعه الگوریتم های تصمیم گیری

۱-۱-۱. الگوریتم های مبتنی بر نظریه بازی

نظریه بازی، روشی سیستماتیک برای تجزیه و تحلیل مسائل تصمیم گیری با چندین عامل است که هر عامل هدف خود را دنبال می‌کند. نتیجه بازی، ارزش پرداختی شرکت کنندگان است. در این نظریه می‌توانیم بهترین استراتژی برای یک بازیکن را در مقابل رقبایش تعیین نمائیم.[٦] در این رویکرد معمولاً از روش

[7] Game Theory
[8] Genetic Algorithm
[9] Ant Colony Algorithm
[10] Artificial Immunity Algorithm
[11] Bayesian Inference
[12] Expert Systems
[13] Radial Basis Function Neural Network

ماتریس بازی و استراتژی تعادل نش[14] برای اتخاذ تصمیمات هوشمند برای پهپاد استفاده می‌شود. یک برنامه کامپیوتری فرآیند تصمیم گیری را در بصورت بلادرنگ انجام می‌دهد تا حالت پیش بینی شده را محاسبه نماید. سپس امتیازات محاسبه شده برای انتخاب بهترین استراتژی مقایسه می‌شوند. به عنوان مثال در کار [۷]، انهدام مواضع دشمن به عنوان هدف پهپاد در نظر گرفته شده است. این پهپاد از رویکرد تئوری بازی پویا با جمع غیر صفر برای مدل‌سازی تابع هدف، متغیرهای کنترل و متغیرهای حالت استفاده می‌کند و تصمیمات هوشمندانه ای برای پهپاد به دست می‌آورد. همچنین در کار [۸] ، از یک رویکرد ماتریس بازی برای ایجاد تصمیمات هوشمند برای پرواز پهپادها در ارتفاع کم در نبردهای هوایی یک به یک و در زمین های تپه ای استفاده شده است. با این حال استقرار مدل های ریاضی مبتنی بر نظریه بازی دشوار است و اثبات کارایی و ضرورت راه حل های آنها دشوار است.

۲-۱-۱. الگوریتم های بهینه سازی اکتشافی

الگوریتم‌های بهینه‌سازی اکتشافی به دنبال راه‌حل‌های عملی خوب برای مسائل بهینه‌سازی در شرایطی هستند که مشکل پیچیده است یا حالتی که زمان برای محاسبه یک راه‌حل دقیق محدود است. [۹] این الگوریتم ها مسائل نبرد هوایی را به مسائل بهینه سازی نگاشت می‌کنند و راه حل های بهینه را پیدا می‌کنند. روند نبرد بین پهپاد و دشمن را می‌توان با تابع هزینه ارزیابی کرد. در نهایت پهپاد بهترین راه حل را دریافت می‌کند. به عنوان مثال، یک الگوریتم ژنتیک همجوشی مجارستانی در کار [۱۰] برای یک مدل تخصیص هدف با چند پهپاد پیشنهاد شده است. هو و همکارانش از یک الگوریتم کلونی مورچه های بهبود یافته استفاده کرده‌اند که بهبودهایی را در قوانین انتخاب مسیر، به روز رسانی فرومون و فاصله غلظت فرومون ایجاد می‌کند تا از مشکل بهینه محلی این الگوریتم سنتی جلوگیری کند. آنها مشکل تخصیص سلاح به هدف را در نبرد هوایی مشترک با چند پهپاد حل کرده‌اند و تصمیم گیری هوشمندانه چند پهپادی را در میدان جنگ پیچیده و متغیر ایجاد کرده‌اند. کریشناکومار و همکارانش [۱۱] نیز از الگوریتم **AIA** برای توانمند کردن پهپادها برای تسلط بر استراتژی های واکنش پیشرفته برای موقعیت های مختلف نبرد هوایی استفاده کرده‌اند. آن ها پایگاه داده ای از سناریوهای موفقیت و شکست ماموریت ایجاد کرده‌اند تا زمانی که پهپاد در آینده با موقعیت های مشابه مواجه می‌شود، به سرعت پاسخ دهد. با این حال در حالتی که ابعاد نبرد هوایی بالاست، اکثر الگوریتم‌های بهینه‌سازی اکتشافی نمی‌توانند بصورت بلادرنگ اجرا شوند و با محدودیت‌های عملی سازگار شوند.

۳-۱-۱. الگوریتم های مبتنی بر دانش

روش‌های مبتنی بر دانش، حجم زیادی از داده‌ها را ادغام می‌کنند و تجربه را برای سیستم‌های استدلال خودکار فراهم می‌کنند.[۱۲] دانش ارتباط بین داده ها در پایگاه داده، به شکل قوانین ارتباطی بیان می‌شود. رایانه از قوانین تداعی برای محاسبه بهترین استراتژی برای موقعیت مربوطه استفاده می‌کند. در مطالعه هوانگ و همکارانش[۱۳] ، نبرد هوایی به عنوان یک فرآیند مارکوف مدل‌سازی شده است و از **BI** برای محاسبه وضعیت نبرد هوایی استفاده می‌شود. بر اساس نتایج ارزیابی موقعیتی، وزن عوامل تأثیرگذار به طور انطباقی تنظیم می‌شود تا تابع هدف معقول تر شود.

٤-۱-۱. الگوریتم های مبتنی بر شبکه های عصبی

الگوریتم‌های مبتنی بر شبکه‌های عصبی در پشتیبانی تصمیم‌گیری نبرد هوایی را می‌توان به دو زیرمجموعه، یعنی یادگیری تحت نظارت و یادگیری تقویتی عمیق طبقه‌بندی کرد. هدف یادگیری تحت نظارت پیش بینی نتایج با داده های برچسب گذاری شده است.[١٤] ژائو و هوانگ اطلاعات پهپاد و دشمن را به عنوان ورودی درخت تصمیم برای ارزیابی وضعیت نبرد هوایی از جنبه های مختلف مدل سازی کرده‌اند. نتایج مطالعه آن ها نشان می‌دهد که روش درخت تصمیم جدید در مقایسه با شبکه سنتی بیزی عملکرد بهتری دارد.[۱۵] یادگیری تقویتی عمیق(**DRL**) یک سیاست تصمیم گیری را با مکانیسم

[14] Nash equilibrium strategy

آزمون و خطا می‌آموزد. یو و همکارانش[۱۶] با استفاده از چارچوب تصمیم گیری ناوبری مبتنی بر **DRL** در یک چارچوب مبارزه الکترونیکی شناختی، یک شبیه ساز ردیابی هدف ایجاد کرده‌اند. ردیابی اهداف توسط پهپادها در محیط های مختلف محقق می شود. به منظور مقابله با فضای بزرگ حالت در طول نبرد هوایی، لی و همکارانش الگوریتمی را برای بهبود عملکرد تعمیم تصمیمات کنترل پهپاد پیشنهاد کرده‌اند. نتایج شبیه‌سازی نشان می‌دهد که الگوریتم بهبودیافته می‌تواند تصمیم گیری در مانور نبردهای هوایی و اشتراک استراتژی را در محیط‌های عملیاتی متعدد تحقق بخشد. اگر شبکه عصبی به خوبی آموزش داده شود، الگوریتم های مبتنی بر شبکه عصبی می‌توانند تصمیمات بلادرنگ با کیفیت بالا را ارائه دهند.

۲-۱. سازماندهی مقاله

ادامه مقاله در پنج بخش تنظیم گردیده است. در بخش اول مروری بر مطالعات انجام شده مربوط به **ACMD** مبتنی بر **DRL** شده است. در این بخش ابتدا توصیف مختصری از **DRL** آمده است، سپس به کاربرد آن در تصمیم‌گیری‌های جنگ هوایی هوشمند پرداخته شده است. در بخش دوم، پشتیبانی تصمیم در مانور نبردهای هوایی مبتنی بر یادگیری تقویتی با سه روش مختلف تشریح شده است. در بخش چهارم طراحی تابع پاداش مورد ارزیابی قرار گرفته است که هسته **ACMD** مبتنی بر **DRL** است. در این بخش همچنین یک نمونه پیاده سازی **ACMD** مبتنی بر **DRL** بر اساس سناریوی نبرد سگ(**dogfight**) آورده شده است. بخش پنجم مؤلفه های کلیدی برای ساخت مدل تصمیم گیری مانور، از جمله فضای حالت، فضای عمل و طراحی تابع پاداش را شرح می‌دهد.

۲. بررسی یادگیری تقویتی عمیق

یادگیری تقویتی عمیق در سال های اخیر به یکی از موضوعات مورد توجه در هوش مصنوعی تبدیل شده است. لاکهید از روشی مبتنی بر معماری سلسله مراتبی و حداکثر یادگیری تقویت آنتروپی در آزمایش‌های **AlphaDogfight Trials (ADT)** دارپا استفاده کرده است. این روش در رقابت نهایی **ADT** در رتبه دوم قرار گرفت و فارغ التحصیل دوره مربی اسلحه **F-16** نیروی هوایی ایالات متحده را شکست داد.[۱۷] هر یک از این مثال‌ها نشان می‌دهد که **DRL** دارای پتانسیل بالایی در سرعت و دقت تصمیم‌گیری است، بنابراین بسیاری از متخصصان و محققان تلاش کرده‌اند تا **DRL** را در زمینه نبرد هوایی اعمال کنند و به دستاوردهای قابل توجهی نیز دست یافته‌اند.

۲-۱. مفاهیم پایه یادگیری تقویتی عمیق

فرآیند تصمیم گیری مارکوف[15] (**MDP**) معمولاً به عنوان چارچوب نظری برای یادگیری تقویتی استفاده می‌شود. در مسائل یادگیری تقویتی بدون مدل، **MDP** با یک ۵ تایی (**S,A,P,R,γ**) توصیف می‌شود، که در آن **S** نشان‌دهنده فضای حالت، **A** نشان‌دهنده فضای رفتار، **P** نشان‌دهنده احتمال انتقال از حالت **S** به حالت بعدی **S`** است. **R** نشان دهنده تابع پاداش و γ نشان دهنده ضریب تخفیف است. فرآیند اجرای یادگیری تقویتی به این شرح است. در زمان **t**، پس از انجام یک عمل توسط عامل در محیط، حالت از S_t به S_{t+1} تغییر می‌کند و عامل در لحظه بعد مقدار پاداش R_{t+1} را دریافت می‌کند. ساختار کلی یادگیری تقویتی در شکل نشان داده شده است.

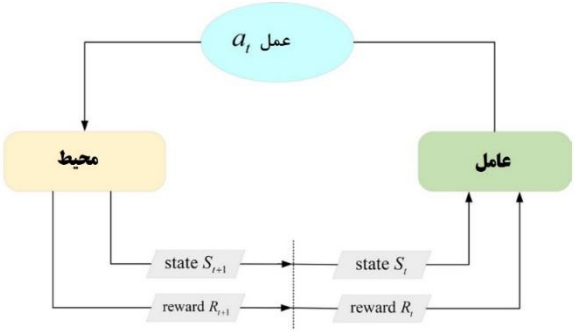

شکل ۲. ساختار کلی یادگیری تقویتی.

یادگیری تقویتی روشی برای عامل با هدف بهینه سازی رفتار خود در یک محیط ناشناخته است.[۱۸] با توجه به هدف بهینه‌سازی، الگوریتم‌های یادگیری تقویتی را می‌توان به

[15] Markov Decision Process

الگوریتم‌های مبتنی بر تابع ارزش و مبتنی بر گرادیان خط مشی تقسیم کرد. الگوریتم های مبتنی بر تابع ارزش، خط مشی بهینه را با به حداکثر رساندن تابع ارزش–حالت یا تابع ارزش–عمل پیدا می‌کنند. از جمله این الگوریتم ها، **Q-Learning** و **SARSA** هستند. الگوریتم های مبتنی بر خط مشی از یک تابع غیرخطی برای پارامترسازی خط مشی استفاده می‌کنند. حداکثر کردن پاداش تجمعی با تکرار خط مشی، مانند گرادیان خط مشی (**PG**)، **REINFORCE** و سایر الگوریتم ها به دست می‌آید. الگوریتم های مبتنی بر گرادیان خط مشی از شبکه های عصبی عمیق (**DNN**) برای تقریب خط مشی استفاده می‌کنند و از روش گرادیان خط مشی برای یافتن خط مشی بهینه استفاده می‌کنند. به طور گسترده ای در مسائل یادگیری تقویتی در فضای پیوسته استفاده می‌شود. هدف از یادگیری تقویتی یادگیری یک خط مشی برای به حداکثر رساندن پاداش است. خط مشی، رفتار عامل را در یادگیری تقویتی تعیین می‌کند، که به صورت نگاشت حالت های مشاهده شده به اقدامات اجرایی مختلف بیان می‌شود. الگوریتم های مبتنی بر تابع ارزش از **DNN** برای تقریب تابع ارزش پاداش استفاده می‌کنند. تابع ارزش پاداش بلندمدت مورد انتظار از هر حالت را تخمین می‌زند. این اقدام، عامل را قادر می‌سازد تا ارزش هر حالت را ارزیابی کند و اقداماتی را انتخاب کند که پاداش تجمعی آینده را در یک فرآیند تصمیم گیری متوالی به حداکثر می‌رساند. اقدامات انتخاب شده با توجه به تابع ارزش پاداش، آینده نگر هستند و خط مشی به دست آمده از نظر تئوری در دراز مدت بهینه است. یک سیاست بهینه وجود دارد که پاداش انباشته بلند مدت را به حداکثر می‌رساند:

$$\pi^*(a|s) = \underset{a \in A}{arg\,max}\, Q_\pi(s,a) \qquad (۱)$$

بهترین خط مشی از طریق تکرارها پیدا می‌شود.

۲-۲. کاربرد DRL در تصمیم گیری نبرد هوایی

پهپادها در نبردهای هوایی با فضای حالت عظیمی در فضای سه بعدی مواجه هستند که توانایی تعمیم شبکه های عصبی با ساختارهای ثابت را به چالش می‌کشد. **DRL** بازخورد پاداش فوری و بازخورد پاداش آتی را در نظر می‌گیرد که پهپاد را قادر می‌سازد تا سیاست بهینه را در دراز مدت یاد بگیرد. کاربردهای **DRL** در نبرد هوایی در شکل (۳) نشان داده شده است. این کاربردها عبارت اند از: برنامه ریزی مسیر([۱۹] و [۲۰])، ردیابی هدف([۲۱] و [۲۲])، فرود خودکار([۲۳])، کنترل آرایش([۲٤] و [۲۵])، تخصیص هدف([۲٦] و [۲۷]) و ارزیابی موقعیت([۲۸]).

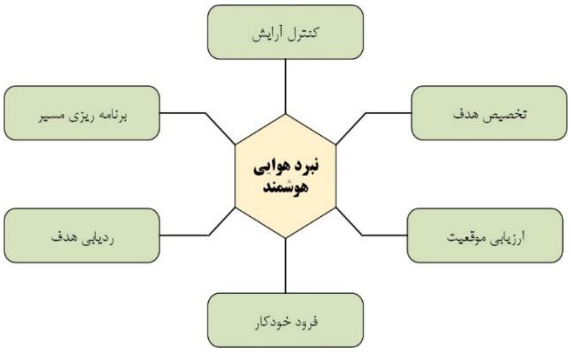

شکل ۳. کاربردهای DRL در نبرد هوایی

همراه با توسعه تجهیزات نظامی، روش های جدید استفاده از پهپاد مانند تبدیل جنگنده های از رده خارج شده به حالت بدون سرنشین ، عملیات مشترک تجهیزات سرنشین دار/ بدون سرنشین و فناوری خوشه ای پدیدار شده است. پهپادها می‌توانند مانورهای چابک تری نسبت به پرنده های سرنشین دار انجام دهند، زیرا محدودیت های فیزیکی خلبانان را ندارند. همچنین در شرایط پیچیده نبرد هوایی، پهپادها با قابلیت تصمیم گیری مانور با کیفیت بالا می‌توانند در نبردهای هوایی برتری محسوسی داشته باشند. در حال حاضر، **DRL** به طور فزاینده ای در زمینه پشتیبانی تصمیم گیری در مانورهای هوایی استفاده می‌شود. اگرچه آموزش شبکه های عصبی به تعداد زیادی منابع محاسباتی نیاز دارد، مکانیسم آزمون و خطای منحصر به فرد یادگیری تقویتی و همچنین قابلیت تطبیق داده های قدرتمند شبکه های عصبی عمیق به **DRL** اجازه می‌دهد تا از استراتژی های مانور با کیفیت بالا بهره برداری کند.

۳. طراحی تابع پاداش در پشتیبانی تصمیم مانور نبردهای هوایی مبتنی بر یادگیری تقویتی عمیق

یادگیری تقویتی دارای چالش هایی در آموزش الگوریتم و کنترل دقت می‌باشد. در پشتیبانی تصمیم نبردهای هوایی که استقلال عامل بالاترین اولویت را دارد، طراحی تابع پاداش از اهمیت ویژه ای برخوردار است.[۲۹] پاداش پراکنده، مشکل رایج **DRL** در حل وظایف عملی است. طراحی تابع پاداش نبرد هوایی ساده، آسان است اما آموزش الگوریتم ضعیف و عملکرد پائینی خواهد داشت. پهپاد قادر به یادگیری استراتژی های تصمیم گیری مانور نیست. به عنوان مثال، عامل تنها بر اساس پیروزی یا شکست در پایان نبرد هوایی پاداش دریافت می‌کند. به دلیل سیگنال پاداش پراکنده، دستیابی به نمونه های آموزشی موثر برای عامل دشوار است و در نتیجه زمان زیادی صرف آموزش تعداد زیادی نمونه بی معنی می‌شود. نبردهای هوایی دارای فضای بزرگی هستند که طراحی تابع پاداش متمرکز را دشوار می‌کند. بنابراین نحوه طراحی پاداش در حین نبرد هوایی و راهنمایی عامل برای تصمیم گیری در جهت پیروزی در نبرد هوایی، تمرکز و دشواری عملکرد پاداش است.[۳۰] حل مشکل پاداش پراکنده می‌تواند به عامل کمک کند تا تعامل کمتری با محیط داشته باشد و از نمونه ها بهتر استفاده کند. پژوهش هایی در مورد حل مشکل پاداش پراکنده **ACMD** مبتنی بر **RL** صورت گرفته است که شامل موارد زیر است.

۳-۱. طراحی تابع پاداش

در مطالعات [۳۱]، [۳۲] و [۳۳] یک مکانیسم کلیدی شکل‌دهی پاداش در خلال نبرد هوایی پیشنهاد شده است. در این مطالعات، پاداش های پراکنده اما عینی را فراتر از سیگنال برد یا باخت اپیزودیک برای تسریع فرآیند یادگیری تقویتی ارائه شده است. در کنار آنها، لیو و همکارانش[۳۱] از یک تابع پیاده سازی توزیع شده و روش آموزشی متمرکز برای بهبود تصمیم گیری پهپاد در یک شبیه سازی واقعی نبرد هوایی فراتر از برد بصری استفاده کرده‌اند. آنها زاویه انحراف، سرعت، ارتفاع و فاصله سازندهای پهپاد و مناطق حمله موشکی را در نظر گرفته‌اند. فن و همکارانش نیز یک مکانیسم پاداش دو لایه را با ترکیب پاداش های داخلی و پراکنده برای بهبود سرعت همگرایی مدل با در نظر گرفتن وضعیت نبرد هوایی طراحی کرده‌اند.

۳-۲. مکانیسم تکرار تجربه اولویت

مکانیسم تکرار تجربه اولویت به این معنی است که نمونه هایی با خطای **TD** بزرگتر در مجموعه تجربه ترجیحاً نمونه برداری می‌شوند. این به عامل اجازه می‌دهد تا به طور موثرتری از تجربیات مهم بیاموزد و راه حل موثری برای رسیدگی به ناکارآمدی های نمونه است.[۳٤] در کار [۲۲] ، الگوریتم **DDPG** با ساخت مخزن تجربه موفقیت و مخزن تجربه شکست برای بهینه‌سازی استراتژی نمونه‌گیری موفق بوده است. آنها از مجموعه تجربه شکست و مجموعه تجربه موفقیت به نسبت معینی نمونه می‌گیرند. نتایج شبیه سازی نشان می‌دهد که الگوریتم بهبود یافته از نظر همگرایی و پایداری بهتر عمل می‌کند. ژانگ و همکارانش[۳۵] یک روش تصمیم گیری مانور نبرد هوایی را بر اساس تخمین پاداش نهایی پیشنهاد کرده‌اند. آنها از تخمین پاداش نهایی و الگوریتم **PPO** برای جایگزینی تابع تخمین برتری اصلی با تخمین پاداش نهایی استفاده می‌کنند. این روش، عملکرد آموزشی یادگیری تقویتی را بهبود می بخشد.

۳-۳. وظیفه کمکی

عامل می‌تواند با کارهای ساده و مرتبط شروع کند و سپس برای یادگیری استراتژی های پیچیده تر، سختی کارها را افزایش دهد. در کار[۳٦] ، به منظور حل چالش بار محاسباتی عظیم مورد نیاز برای نبرد هوایی، ابتدا "مقابله اساسی" با مسیرهای ثابت جنگنده های دشمن انجام می‌شود. سپس اطلاعات دشمن ارتقاء می‌یابد و عامل در سطح "مقابله اساسی" بازآموزی می‌شود. این مکانیزم در نهایت پهپاد را قادر می‌سازد تا تصمیمات هوشمندانه ای در نبرد هوایی بگیرد و استراتژی های موثری برای شکست دادن حریف به دست آورد. نبرد هوایی یک مسئله چالش برانگیز با فضای حالت بزرگ است. برای کنار آمدن با این چالش، سه روش بصورت خلاصه بیان می‌شود که می‌توانند نرخ یادگیری نمونه را افزایش دهند و از نیاز به طراحی تابع پاداش پیچیده اجتناب کنند.همچنین این سه روش را می‌توان ترکیب کرد تا پهپادها بتوانند استراتژی های هوشمند را سریعتر یاد بگیرند.

۴.مدل پشتیبان تصمیم گیری مانور نبردهای هوایی پیشنهادی

Dogfight یک نوع از نبرد هوایی است که در آن مسلسل سلاح اصلی است و هر دو جنگنده سعی می‌کنند برای هدف گیری و شلیک پشت سر یکدیگر قرار بگیرند. علیرغم پیشرفت‌هایی که در موشک‌ها و رادارها در انجام عملیات فراتر از برد بصری صورت گرفته است، **Dogfight** در نبرد هوایی اجتناب‌ناپذیر است.[۳۷] نبرد هوایی فرآیندی پیچیده و پویا است. با بهبود عملکرد پهپاد، تاکتیک های نبرد هوایی نیز تکامل یافته اند. هسته اصلی تصمیم گیری مانور هوشمند، تولید و ارزیابی توالی مانورهای رزمی متعدد بر اساس تجربه رزمی و موقعیت بلادرنگ است.[۳۸] پهپاد باید مانورهای خود را انتخاب کند و بر اساس تغییرات موقعیتی در طول ماموریت های رزمی، توالی های رزمی مؤثری را تشکیل دهد.

٤-١. معادلات حرکتی پهپاد

پهپاد دارای شش درجه آزادی حرکت در طول پرواز است. می‌توان آن را به یک نقطه جرم تقلیل داد که در سه بعد با مقادیر فیزیکی مانند سرعت پرواز، مختصات سه بعدی و زوایای نگرش توصیف می‌شود. وضعیت لحظه ای پهپاد را می‌توان مطابق شکل (٤) تجسم کرد. بردار واحد **V** نشان دهنده سرعت پهپاد است. **x** و **y** و **z** به ترتیب مختصات پهپاد را در فضای سه بعدی در مقایسه با زمین به عنوان سیستم مرجع نشان می‌دهند. **θ**، **ψ** و **φ** به ترتیب زاویه گام، زاویه انحراف و زاویه چرخش پهپاد هستند. زاویه گام، زاویه بین جهت سرعت پرواز **V** پهپاد و صفحه افقی است. زاویه انحراف نشان دهنده زاویه بین برآمدگی **V** بردار سرعت و جهت محور **Y** است.

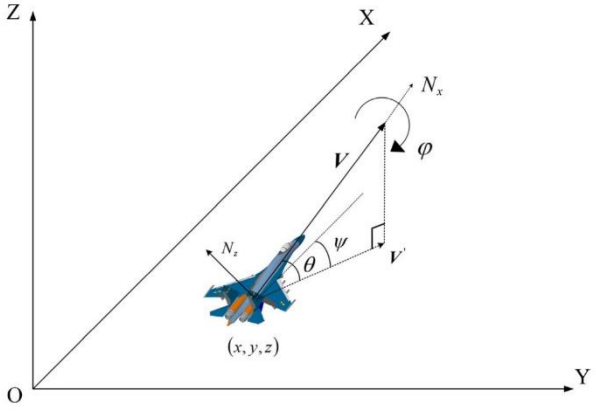

شکل ٤. شرح وضعیت پهپاد در فضای سه بعدی

زاویه گردش زاویه اطراف بردار سرعت است(بدنه به سمت راست مثبت است). **θ**، **ψ** و **φ** در مجموع به عنوان زوایای اویلر[16] پهپاد نامیده می‌شوند که منعکس کننده نگرش پهپاد نسبت به سیستم مختصات اینرسی زمین هستند. برای ساده‌تر کردن فرآیند تحلیل، معادلات حرکت فضایی سه‌بعدی پهپاد در سیستم مختصات اینرسی زمین به‌صورت زیر تعریف می‌شوند:

$$\begin{cases} \dot{v} = g(N_x - \sin\theta) \\ \dot{\psi} = \dfrac{gN_z \sin\varphi}{v\cos\theta} \\ \dot{\theta} = \dfrac{g}{v}(N_z\cos\varphi - \cos\theta) \\ \dot{x} = v\cos\theta\cos\psi \\ \dot{y} = v\cos\theta\sin\psi \\ \dot{z} = v\sin\theta \end{cases} \qquad (۲)$$

هر عبارت در مجموعه معادلات به ترتیب بیانگر یک معادله دیفرانسیل مرتبه اول برای مقادیر سرعت پرواز، زاویه انحراف، زاویه گام و مقادیر مختصات فضایی سه بعدی پهپاد است. این عبارات روش محاسبه و به روز رسانی وضعیت پهپاد را در حین نبرد تعیین می‌کنند. **g** نشان دهنده شتاب گرانش است. $\mathbf{N_x}$ اضافه بار مماسی در جهت سرعت است که نیروی رانش و کاهش سرعت پهپاد را تعیین می‌کند. $\mathbf{N_x}$ کنترل شتاب، کاهش سرعت، یا سرعت یکنواخت پهپاد را امکان پذیر می‌کند. $\mathbf{N_z}$ اضافه بار معمولی پهپاد است که نشان دهنده اضافه بار رو به بالا عمود بر هواپیمای بدنه آن است که قادر است بالابر مورد نیاز پهپاد را

[16] Euler

تامین کند. N_z می‌تواند شیرجه را کنترل کند و برای تغییر ارتفاع عمودی پهپاد بالا بکشد. این مدل به طور گسترده در مطالعات مختلفی استفاده شده است.([۳۹])

۲-٤. فضای حالت

با ترکیب حالات پهپاد قرمز و آبی می‌توان وضعیت نبرد هوایی را ارزیابی کرد. با توجه به تنظیمات در نظر گرفته شده در کار[۳۱]، فضای حالت ۱۲ بعدی زیر را انتخاب می‌کنیم:

$$S = \{v_r x_r y_r z_r \theta_r \psi_r v_b x_b y_b z_b \theta_b \psi_b\} \quad (۳)$$

که در آن عناصر با زیرنویس **r** و **b** نشان دهنده وضعیت **w.r.t** سمت قرمز و آبی هستند. در اجرای نبرد هوایی هوشمند، از وضعیت لحظه ای رنگ قرمز و آبی به عنوان منبع سیگنال پاداش استفاده خواهد شد. دو بردار واحد (یعنی v_r و v_b) برای نشان دادن جهت پرواز دو طرف استفاده می‌شود. و d_r و d_b نشان دهنده بردار موقعیت نسبی بین دو طرف هستند. این متغیرها را می‌توان به صورت زیر بیان کرد:

$$\begin{cases} v_r = [cos\,\psi_r \;\; cos\,\theta_r \; sin\,\psi_r \; cos\,\theta_r \;\; sin\,\theta_r] \\ v_b = [cos\,\psi_b \;\; cos\,\theta_b \; sin\,\psi_b \; cos\,\theta_b \;\; sin\,\theta_b] \\ d_r = -d_b = [x_b - x_r \; y_b - y_r \; z_b - z_r] \end{cases} \quad (٤)$$

رابطه بین اطلاعات موقعیتی نسبی و سیستم مختصات زمین در معادله (۵) نشان داده شده است.

$$\begin{cases} d = |d_r| \\ q_r = cos^{-1} \dfrac{v_r . d_r}{d} \\ q_b = cos^{-1} \dfrac{v_b . d_b}{d} \end{cases} \quad (۵)$$

که در آن q_r و q_b به ترتیب زاویه بین بردار سرعت و مرکز را نشان می‌دهند. **d** نشان دهنده فاصله نسبی بین قرمز و آبی است. هدف از نبرد هوایی کوتاه برد، مانور دادن پهپاد به موقعیتی است که بتواند به هدف حمله کند و در عین حال از محدوده حمله هدف نیز جلوگیری کند. محدوده حمله پهپاد در این مقاله در شکل (۵) نشان داده شده است. با فرض اینکه حداکثر فاصله حمله سلاح d_{max} باشد، حداکثر زاویه پرتاب خارج از محور **q** است، پس برد حمله پهپاد یک منطقه مخروطی **Ω** است.

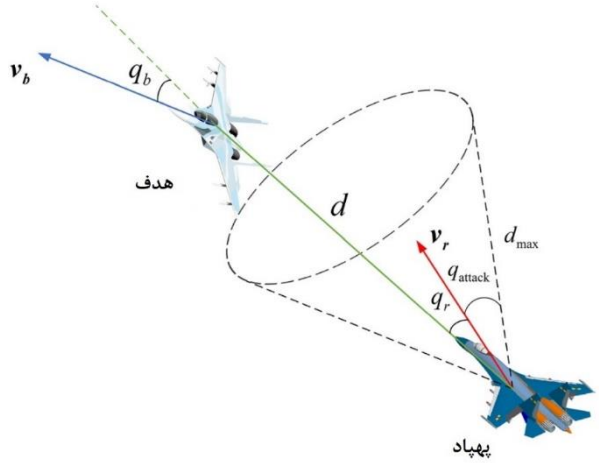

شکل ۵. محدوده حمله پهپاد

۳-٤. فضای عمل

مانورهای تاکتیکی پهپادهای با بال ثابت را می‌توان به طور کلی به دو دسته تقسیم کرد. دسته اول، مانورهای پیچیده تر مانند سالتو، کبرا، رول و غیره است. دسته دیگر، مانورهای اساسی است که مانورهای پیچیده را تشکیل می‌دهند، یعنی مجموعه مانورهای پایه مبارزه (**BFM**[17]) پیشنهاد شده توسط اداره ملی هوانوردی و فضایی(ناسا)، که شامل هفت الگوی اساسی است که در شکل (٦) نشان داده شده است. چنین انتخابی به طور گسترده در مطالعات [۳۲] و [٤٠] استفاده شده است.

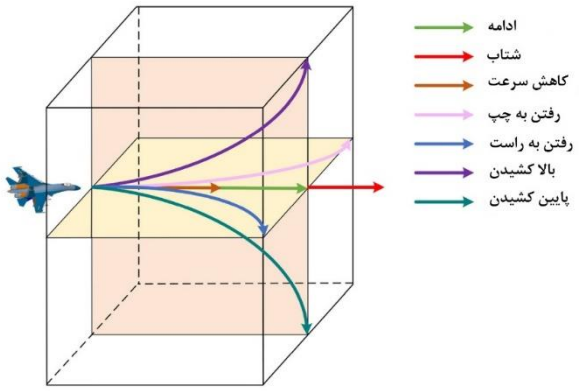

شکل ٦. مانورهای پایه پهپاد

[17] Basic Fight Maneuvering

برای هفت مانور فوق، اضافه بار مماسی، اضافه بار معمولی و زاویه چرخش پهپاد را برای کنترل مانور انتخاب می‌کنیم. سه گانه $[N_x, N_z, \varphi]$ برای نمایش اقدامات انجام شده توسط پهپاد در هر لحظه در شبیه سازی استفاده می‌شود. با توجه به محدودیت های فیزیکی که پهپاد با آن ها روبرو است، فرامین مربوط به هفت مانور مختلف در جدول ۱ نشان داده شده است.

جدول ۱. دستورات مانورهای اساسی مبارزه

مانور انتخابی	فرامین		
	N_x	N_z	φ
پرواز عادی	۰	۱	۰
افزایش شتاب	۲	۱	۰
کاهش شتاب	-۲	۱	۰
چرخش به چپ	۰	۵	$-\pi/3$
چرخش به راست	۰	۵	$\pi/3$
بالا کشیدن	۰	۵	۰
پائین کشیدن	۰	-۵	۰

معادله حرکتی پهپاد در فضای سه بعدی و به روزرسانی موقعیت آن در طی شبیه سازی با استفاده از رابطه زیر تعریف می‌شود.

$$S_{t+1} = f(S_t, a_r, a_b) \qquad (٦)$$

در این معادله، a_r و a_b نشان دهنده مانورهای انتخاب شده توسط پهپادهای قرمز و آبی در تصمیم گیری تک مرحله ای هستند. **f** نشان دهنده تابع به روز رسانی حالت است که بر اساس معادله دیفرانسیل حرکتی ساخته شده است. دیفرانسیل مرتبه اول سرعت پهپاد، مقادیر مختصات فضایی سه بعدی، زوایای گام و انحراف را می‌توان با ترکیب حل عددی معادلات دیفرانسیل اویلر به دست آورد. در حالت S_t، با توجه به مانورهای هر دو طرف همراه با واحدهای زمان شبیه سازی d_t می توان حالت جدید S_{t+1} را محاسبه کرد.

٤-٤. توابع پاداش

نبرد هوایی کوتاه برد را به عنوان محیط شبیه سازی در نظر می‌گیریم و فرض می‌کنیم که هر دو طرف قرمز و آبی از مسلسل های هوایی به عنوان سلاح استفاده می‌کنند. عوامل موثر بر وضعیت در طول نبرد هوایی عمدتاً شامل موقعیت فضایی، ارتفاع پرواز، سرعت پهپاد و سایر پارامترهای پرواز است. اطلاعات موقعیتی مانند زاویه، فاصله، ارتفاع و سرعت پهپادهای دو طرف به عنوان شاخصی برای ارزیابی برتری نبرد هوایی استفاده می‌شود.[۳۳] در اینجا دو نوع تابع پاداش را تعریف می‌شود، توابع پاداش فرآیند و نتیجه. تابع پاداش فرآیند هر دو طرف نبرد و موقعیت های مربوط به آن ها را در نظر می‌گیرد، در حالی که تابع پاداش نتیجه به نتیجه هر قسمت بستگی دارد. دو تابع پاداش فوق با هم ترکیب می‌شوند تا مشکل پاداش پراکنده را حل کنند.

١-٤-٤. تابع پاداش فاصله زاویه

فصلنامه علمی - پژوهشی فرماندهی و کنترل، سال هفتم، شماره دو، تابستان ۱۴۰۲

تابع پاداش فاصله زاویه اثرات فاصله، زاویه انحراف $\mathbf{q_r}$ و زاویه انحراف $\mathbf{q_b}$ را بر ارزیابی موقعیت در نظر می‌گیرد. تا حد زیادی نتیجه نبرد هوایی را تعیین می‌کند. هر دو پارامتر $\mathbf{q_r}$ و $\mathbf{q_b}$ مقادیری در بازه $\mathbf{[0, \pi]}$ می‌گیرند. زاویه جداسازی کوچک به این معنی است که دشمن در مقابل جهت پرواز پهپاد قرمز قرار دارد و به طرف قرمز امتیاز حمله و تهدیدی برای پهپاد آبی می‌دهد. این وضعیت مساعدترین موقعیت برای حمله تیم قرمز است. با افزایش تدریجی $\mathbf{q_r}$ از صفر به $\boldsymbol{\pi}$، زاویه حمله قرمز افزایش می‌یابد و شرایط برای حمله نامطلوب می‌شود. با توجه به تاثیر زاویه جداسازی و زاویه انحراف بر تسلط پهپاد قرمز در نبرد، تابع پاداش فاصله زاویه به شرح زیر بیان می‌شود:

$$r_a = \begin{cases} (q_b - q_r)\exp\left(-\left(\frac{d_0 - d_{max}}{d_{max}}\right)^2\right), & q_r \le q_b, d_0 > d_{max} \; and \; q_b \\ (q_b - q_r), & q_r \le q_b, d_0 > d_{max} \; and \; q_b \notin \alpha_m \\ 0, & else \end{cases} \quad (۷)$$

در این معادله، r_a تابع پاداش زاویه است. d_0 و d_{max} نشان دهنده فاصله بین قرمز و آبی و حداکثر فاصله حمله سلاح است. α_m نشان دهنده زاویه ای است که در آن حمله مجاز است.

۲-٤-٤. تابع پاداش سرعت

تابع پاداش سرعت توانایی پهپاد را در استفاده از مزیت سرعت خود برای جلوگیری از تهدید دشمن و رسیدن سریع به منطقه حمله خود ارزیابی می‌کند. تابع پاداش سرعت به صورت زیر تعریف می‌شود:

$$r_v = \begin{cases} exp\left(\frac{v_r - v_{best}}{v_{best}}\right), & v_r \le v_{best} \\ exp\left(\frac{v_{best} - v_r}{v_{best}}\right), & v_r > v_{best} \end{cases} \quad (۸)$$

v_{best} سرعت نبرد هوایی بهینه را نشان می‌دهد که یک مقدار مشخص است.

۳-٤-٤. تابع پاداش ارتفاع

پرواز سه بعدی پهپاد در مقایسه با شبیه سازی پرواز در یک هواپیمای دو بعدی، یک بعد ارتفاع اضافی را شامل می‌شود. در نبرد هوایی در صورتی که پهپاد در ارتفاع معینی بالاتر از هدف قرار گرفته باشد، دارای مزیت انرژی پتانسیل گرانشی است. برتری در ارتفاع مناسب برای پهپاد برای تنظیم موقعیت مکانی مفید است تا دشمن را در محدوده حمله خود قرار دهد. برتری ارتفاع همچنین باعث افزایش انرژی پتانسیل گرانشی می‌شود که می‌تواند برای دستیابی به سرعت پرواز بالاتر به انرژی جنبشی تبدیل شود. تابع پاداش ارتفاع به صورت زیر تعریف می‌شود:

$$r_{h1} = \begin{cases} exp\left(-\left(\frac{z_r - h_{best}}{h_{best}}\right)\right), & z_r \le h_{best} \\ exp\left(\frac{z_r - h_{best}}{h_{best}}\right), & z_r > h_{best} \end{cases} \quad (۹)$$

$$r_{h2} = \begin{cases} exp\left(\frac{\Delta_h - \Delta h_{best}}{\Delta h_{best}}\right), & \Delta_h \le \Delta h_{best} \\ exp\left(\frac{\Delta h_{best} - \Delta_h}{\Delta h_{best}}\right), & \Delta_h > \Delta h_{best} \end{cases} \quad (۱۰)$$

$$r_h = r_{h1} + r_{h2} \quad (۱۱)$$

در این تابع پاداش، r_h بیانگر تابع پاداش ارتفاع، r_{h1} بیانگر تابع پاداش ارتفاع مطلق و r_{h2} نشان دهنده تابع پاداش ارتفاع نسبی می‌باشد. $\Delta h = z_r - z_b$ نشان دهنده اختلاف ارتفاع بین قرمز و آبی است. $h_{best}, \Delta h_{best}$ ارتفاع نبرد هوایی بهینه و ارتفاع نسبی بهینه هستند که کمیت های مشخصی هستند.

٤-٤-٤. تابع پاداش نتیجه

تابع پاداش نتیجه نشان دهنده پاداشی است که عامل زمانی که پهپاد به وضعیت خاصی می‌رسد دریافت می‌کند. این شامل مواردی می‌شود که پهپاد در یکی از حالات برنده یا بازنده، از محدوده خارج می‌شود. تابع پاداش نتیجه به صورت زیر تعریف می‌شود.

$$r_{result} = \begin{cases} r_1, & q_r \in \alpha_m, d < d_{max} \ and \ q_b \in q_0 \\ r_2, & q_b \in \alpha_m \ and \ d < d_{max} \\ r_3, & s \prec s_r \\ r_4, & step = step_{max} \\ r_5, & else \end{cases} \quad (۱۲$$

وقتی پهپاد قرمز شرایط حمله را برآورده می‌کند و برنده می‌شود، عامل یک پاداش نتیجه مثبت r_1 دریافت می‌کند. برعکس، زمانی که پهپاد آبی شرایط حمله را برآورده می‌کند و برنده می‌شود، عامل یک پاداش نتیجه منفی r_2 دریافت می‌کند. همچنین **Sr** محدوده مرزی حرکت پهپاد و **stepmax** حداکثر مراحل تصمیم گیری است. برای بهبود راندمان آموزشی شبکه، زمانی که پهپاد از محدوده مرزی فراتر می‌رود یا تکرارها به حداکثر مراحل تصمیم گیری می‌رسد، عامل پاداش های منفی r_3 یا r_4 را دریافت می‌کند.

۵-٤-٤. تابع پاداش تجمیع شده

بر اساس تجزیه و تحلیل فوق از وضعیت نبرد هوایی، پاداش فاصله زاویه بالا، پاداش ارتفاع و پاداش سرعت به ترتیب به صورت r_a، r_v و r_h نشان داده می‌شود. تابع پاداش تجمیع شده، ترکیبی از این سه مقدار است.

$$r_{process} = \omega_1 r_a + \omega_2 r_v + \omega_3 r_h \quad (۱۳)$$

ضرایب این تابع با شرایط زیر در نظر گرفته می‌شوند.

$$\omega_1 + \omega_2 + \omega_3 = 1 \ (\omega_1, \omega_2, \omega_3 \geq 0)$$

تابع پاداش یکپارچه r برای فرآیند نبرد هوایی به صورت زیر نشان داده می‌شود.

$$r = r_{process} + r_{result} \quad (۱٤)$$

۵- ٤. چارچوب تصمیم گیری در مانور نبرد هوایی مبتنی بر DQN

DQN، یا همان حالت پیشرفته DRL، می‌تواند استراتژی‌های کنترل را مستقیماً از داده‌های خام با ابعاد بالا در نبرد هوایی بیاموزد. ایده کلیدی الگوریتم DQN استفاده از DNN برای تقریب تابع مقدار است. همچنین از خطای TD برای تنظیم پیوسته پارامترهای شبکه عصبی استفاده می‌شود، به طوری که مقدار خروجی شبکه به طور پیوسته به مقدار واقعی $Q(s,a)$ ≈ $Q(s,a|\theta)$ تقریب زده می‌شود. مدل محیط نبرد هوایی، ارزش پاداش پهپاد را بر اساس وضعیت فعلی هر دو طرف محاسبه کرده و آن را به عامل ارسال می‌کند. سپس عامل اقداماتی را برای تغییر حالت در مدل محیط نبرد هوایی انجام می‌دهد. عامل دائماً با محیط نبرد هوایی در تعامل است تا وضعیت لحظه بعدی، عمل و ارزش پاداش را به دست آورد و آنها را در مخزن تجربه ذخیره کند. با انباشت تجربه، مدل DQN استراتژی مانور پهپاد را بر اساس مخزن تجربه به روز می‌کند تا مقادیر عمل را بهینه کند. شکل (۷) مدل تصمیم گیری مبتنی بر DQN را برای نبرد هوایی کوتاه برد پهپاد نشان می‌دهد.

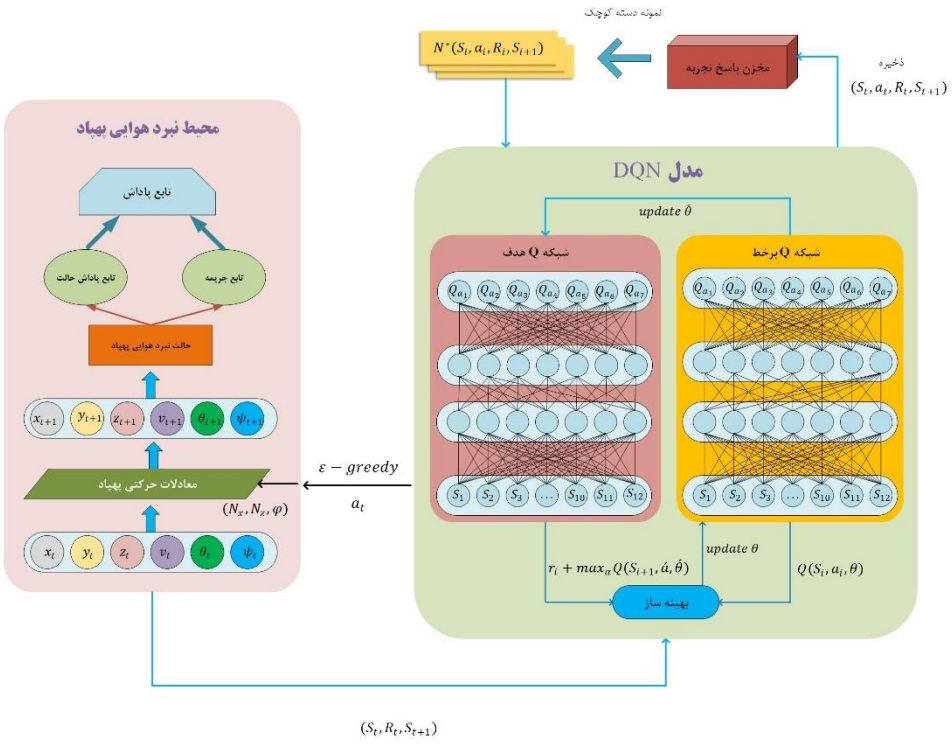

شکل ۷. مدل تصمیم گیری مبتنی بر DQN برای نبردهای هوایی کوتاه برد

وضعیت فعلی نبرد هوایی S_t است، شبکه Q برخط بر اساس استراتژی $\boldsymbol{\varepsilon - greedy}$ عمل می‌کند. پهپاد عملیات را در a_t انجام می‌دهد و هدف طبق استراتژی از پیش تعیین شده پرواز می‌کند. سپس حالت به S_{t+1} تغییر می‌کند و مقدار پاداش R_t برگردانده می‌شود. $(\boldsymbol{S_t, a_t, R_t, S_{t+1}})$ نیز به عنوان یک نمونه تجربه در مخزن تجربه ذخیره می‌شود.

در طول فرآیند یادگیری، مدل DQN از استراتژی بازپخش تجربه اولویت‌دار برای نمونه‌برداری از دسته کوچکی از انتقال‌ها از مجموعه تجربه استفاده می‌کند و پارامترهای شبکه برخط θ را بر اساس اصل گرادیان کاهشی به‌روزرسانی می‌کند. به صورت دوره ای، پارامترهای $\boldsymbol{\theta}$ به شبکه هدف $\hat{\boldsymbol{\theta}}$ اختصاص داده می‌شود. یادگیری و به روز رسانی تا زمانی که خطای **TD** به صفر نزدیک شود ادامه می‌یابد و در نهایت یک استراتژی مانور هوایی کوتاه برد پیشنهاد می‌شود. در طول آموزش رزم هوایی، مشکل اکتشاف[18] و بهره برداری[19] باید حل شود. در این مقاله، از استراتژی $\boldsymbol{\varepsilon - greedy}$ برای ایجاد تعادل بین اکتشاف و بهره برداری استفاده شده است. معادله (۱۵) این موضوع را اثبات می‌کند:

$$\boldsymbol{\varepsilon = \varepsilon_{end} + (\varepsilon_{start} - \varepsilon_{end}) exp(-\frac{frame_{index}}{\varepsilon_{decay}})} \quad (۱۵)$$

در این معادله، $\boldsymbol{\varepsilon_{start}}$ نشان دهنده مقدار اولیه اکتشاف، $\boldsymbol{\varepsilon_{end}}$ نشان دهنده مقدار نهایی اکتشاف، $\boldsymbol{frame_{index}}$ یکی عدد تجمعی و $\boldsymbol{\varepsilon_{decay}}$ بیانگر نرخ فروپاشی است. با افزایش تعداد تکرارهای آموزش، عامل کمتر و کمتر محیط را بررسی می‌کند و بیشتر به تجربه ذخیره شده قبلی تکیه می‌کند. الگوریتم DQN با تناسب تابع Q-value در هر حالت، تفاوت بین پیش‌بینی‌های شبکه و مقدار واقعی را به حداقل می‌رساند. تابع زیان بصورت زیر تعریف می‌شود:

[18] Exploration

[19] Exploitation

$$Loss(\theta) = E_{(S_t,a_t,R_t,S_{t+1})D}\left[(R_t + \gamma \max_{a_{t+1}\epsilon A} Q(S_{t+1},a_{t+1},\theta) - Q(S_t,a_t,\theta))^2\right] \quad (16)$$

در این رابطه، $(S_t, a_t, R_t, S_{t+1})D$ نشان‌دهنده داده‌های نمونه‌برداری تصادفی از مجموعه تجربه **D** است و θ پارامتر مدل شبکه است.

۵. تجزیه و تحلیل نتایج

در این بخش نتایج آزمایش‌های نبرد هوایی هوشمند مبتنی بر DRL به همراه تجزیه و تحلیل نتایج به دست آمده ارائه می‌شود. همچنین تنظیمات پارامتر، فرآیند آموزش و یادگیری پهپاد و نتایج نبرد با دشمن در این بخش تشریح خواهد شد.

۵-۱. تنظیم پارامترها

پارامترهای مدل DQN به صورت زیر تنظیم می‌شوند: ابعاد فضای حالت و فضای عمل به ترتیب ورودی و خروجی شبکه عصبی یادگیری عمیق هستند. شبکه **Q** برخط و شبکه **Q** هدف دارای معماری یکسانی از چهار لایه کاملاً متصل شامل یک لایه ورودی، یک لایه خروجی و دو لایه پنهان هستند. هر لایه مخفی دارای ۳۲ واحد است و از تابع فعال سازی **ReLU** استفاده می‌کند. اندازه دسته کوچک نمونه روی ۲۵۶ و اندازه مخزن تجربه روی 10^6 تنظیم شده است. پارامترهای سناریوی آزمایش و پارامترهای فرآیند آموزش در جداول (۲) و (۳) گزارش شده است.

جدول ۲. پارامترهای سناریوی آزمایش

پارامتر	مقدار	پارامتر	مقدار
d_{max}	5 km	z_{min}	1 km
q_{attack}	$\pi/6$	z_{max}	10 km
α_m	$[-\pi/6, \pi/6]$	v_{best}	300 m/s
q_0	$[2\pi/3, \pi] \cup [-2\pi/3, -\pi]$	h_{best}	5 km
v_{min}	100 m/s	Δh_{best}	1 km
v_{max}	400 m/s		

جدول ۳. پارامترهای فرآیند آموزش

پارامتر	مقدار	پارامتر	مقدار
r_1	8	ω_1	0.5
r_2	-8	ω_1	0.25
r_3	-5	ω_1	0.25
r_4	-1	dt	1 s

r_5	0	$step_{max}$	40

۵-۲. آموزش

این بخش فرآیند آموزش و نتیجه نهایی پهپاد را در مراحل پیش‌آموزشی و تنظیم دقیق نشان می‌دهد. همچنین استراتژی مانور اصلی پهپاد در شرایط ساده و فرآیند یادگیری پهپاد در مرحله تنظیم دقیق هنگام مواجهه با حریف استراتژیک هوشمند را پوشش می‌دهد.

۱-۲-۵. مرحله قبل از آموزش

همانطور که در شکل (۸) نشان داده شده است، آزمایش نبرد هوایی در سه موقعیت اولیه مختلف انجام می‌شود: توازن، ضعف و برتری. هدف از مانور هوایی دستیابی به یک موقعیت برتر و رساندن هدف به محدوده سلاح خود و در عین حال دوری از برد سلاح آن است.

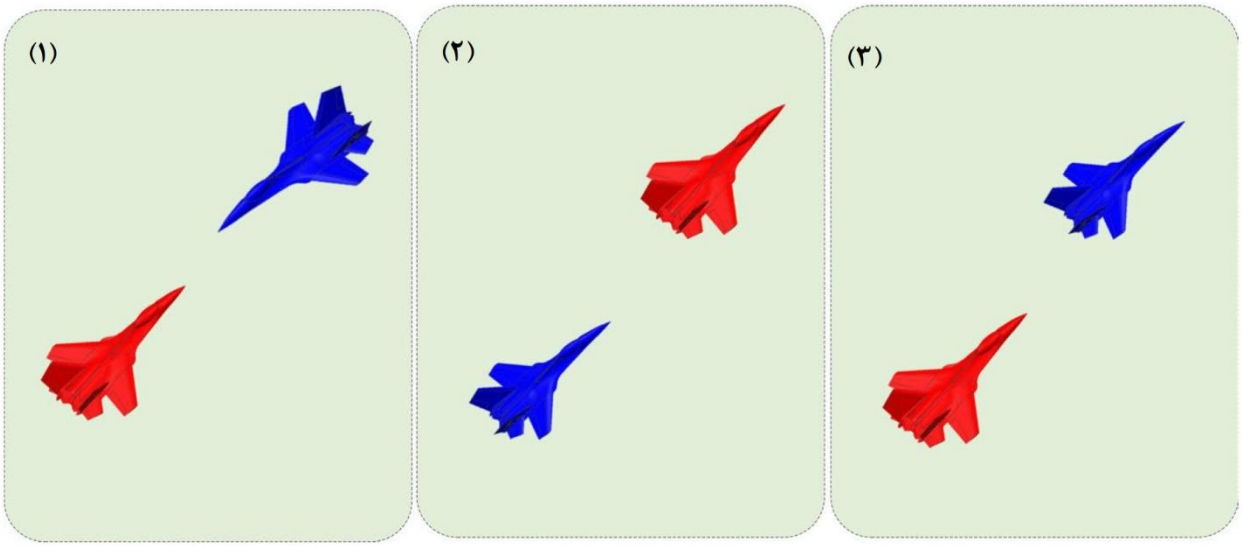

شکل ۸. سه حالت اولیه (۱) توازن، (۲) ضعف و (۳) برتری

ابتدا پهپاد را در سه حالت اولیه آموزش می‌دهیم. فرض بر این است که پهپاد آبی بدون هیچ تداخلی مستقیم و پایدار پرواز می‌کند. پهپاد قرمز از الگوریتم DQN برای یادگیری سیاست استفاده می‌کند. با آموزش ساده، پهپاد می‌تواند استراتژی حمله را در یک ماموریت ساده بیاموزد. جدول ٤ موقعیت اولیه هر دو پهپاد را در یک موقعیت ساده نشان می‌دهد.

جدول ٤. وضعیت اولیه پهپادها در مرحله قبل از آموزش

		مختصات شروع (متر)	سرعت(متر بر ثانیه)	زاویه استقرار (درجه)	زاویه انحراف (درجه)
توازن	قرمز	(۰,۰,٤۰۰۰)	۲۰۰	۰.۰	٤٥
	آبی	(۸۰۰۰,۸۰۰۰,٤۰۰۰)	۲۲۰	۰.۰	-۱۳٥

ضعف	قرمز	(۰,۰,٤۰۰۰)	۲۰۰	۰.۰	-۱۳۵
	آبی	(٤۰۰۰,٤۰۰۰,٤۰۰۰)	۲۲۰	۰.۰	-۱۳۵
برتری	قرمز	(۰,۰,٤۰۰۰)	۲۰۰	۰.۰	٤۵
	آبی	(٤۰۰۰,٤۰۰۰,٤۰۰۰)	۲۲۰	۰.۰	٤۵

شکل (۹) بخش (۱)، مسیر مانور پهپاد را پس از آموزش در وضعیت توازن نشان می‌دهد. مشاهده می‌شود که پهپاد قادر است در اولین بار به سمت بالا بکشد تا ارتفاع خود را افزایش دهد و برتری ارتفاعی بدست آورد و از برد حمله دشمن دوری کند. سپس با کاهش فاصله بین دو طرف، پهپاد قرمز رنگ یک مانور شیرجه ای انجام می‌دهد تا زاویه حمله را به دست آورد و در نبرد هوایی پیروز شود. شکل (۹) بخش (۲)، میانگین تغییرات پاداش را در حالت توازن نشان می‌دهد. میانگین پاداش با پاداش مربوط به دانه های تصادفی مختلف محاسبه می‌شود.

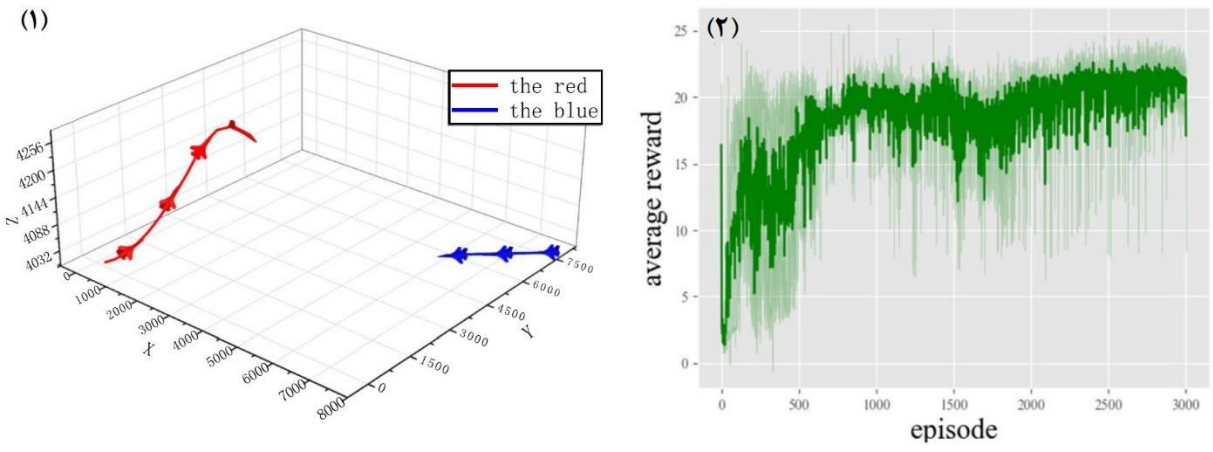

شکل ۹. نتایج تمرین وضعیت توازن (۱) مسیر مانور و (ب) میانگین پاداش

مشاهده می‌شود که پهپاد در مرحله اولیه آموزش نتوانسته بر استراتژی حمله مناسب تسلط پیدا کند. به دلیل سرعت، ارتفاع بیش از مرز منجر به مشکلات و در نتیجه ارزش پاداش کمتر، تکرارها زود به پایان می‌رسد. با این حال، با افزایش تکرارهای آموزش، پهپاد به تدریج استراتژی مانور مناسب را یاد می‌گیرد. مشاهده می‌شود که پس از ۱۰۰۰ تکرار از آموزش، پهپاد توانسته است بر استراتژی مانور اولیه تسلط پیدا کند و ارزش پاداش همگرا شود.

شکل (۱۰) قسمت های (۱) و (۲) مسیر آموزشی پهپاد را به ترتیب در موقعیت های نامطلوب و سودمند نشان می‌دهد. در مرحله پایانی آموزش ضعف ها، پهپاد برای به دست آوردن برتری ارتفاع بالا می‌آید و سپس به سرعت دماغه‌اش را می‌چرخاند و یک مانور تاکتیکی را انجام می‌دهد تا نقطه ضعف را معکوس کند و موقعیت حمله را به دست آورد. در مرحله پایانی آموزش برتری، پهپاد سرعت می‌گیرد و بالا می‌کشد تا موقعیت برتری را به موقعیت ضربه در برابر پهپاد دشمن تبدیل کرده و به پیروزی برسد.

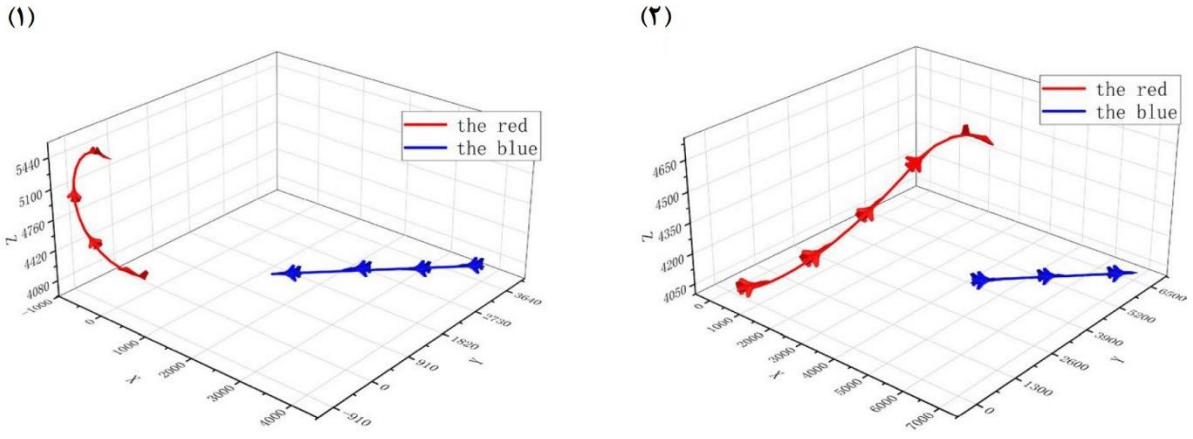

شکل ۱۰. مسیر مانور در موقعیت های مختلف اولیه (۱) ضعف و (۲) برتری

۲-۲-۵. مرحله تنظیم دقیق

پس از آموزش برای سه سناریوی ساده، آموزش در برابر هدف هوشمند انجام می‌شود. پهپاد قرمز از مدل DQN آموزش دیده با سناریوهای ساده برای مانور استفاده می‌کند، در حالی که پهپاد آبی از یک استراتژی مانور قوی بر اساس اصول آماری برای انتخاب مانور استفاده می‌کند. در مرحله تنظیم دقیق، پهپاد قرمز مدل DQN آموزش دیده را برای یک مورد ساده استخراج می‌کند و با استفاده از استراتژی حریصانه($\boldsymbol{\varepsilon - greedy}$) به کشف استراتژی مانور ادامه می‌دهد. همچنین برای اطمینان از تنوع نمونه‌های آموزشی، حالت اولیه هر دو طرف به‌طور تصادفی در محدوده‌ای مشخص، همانطور که در جدول (۵) نشان داده شده است، ایجاد شده است.

جدول ۵. وضعیت اولیه پهپادها در مرحله تنظیم دقیق

	X(m)	Y(m)	Z(m)	V(m/s)	θ(درجه)	ψ(درجه)
قرمز	[-300,300]	[-300,300]	4000	200	0	0
آبی	[7000,9000]	[7000,9000]	[3800,4200]	200	0	[-π,-π/2]

شکل (۱۱) بخش (۱) مسیر رویارویی پهپاد بین دو طرف را در ابتدای مرحله تنظیم دقیق نشان می‌دهد. پهپاد قرمز به دلیل بی تجربگی ، برای به دست آوردن برتری ارتفاع، ابتدا بالا می‌کشد. در همین حال سمت آبی نیز به سرعت بالا می‌آید و برای تنظیم دید به چپ می‌چرخد و به سمت قرمز حمله می‌کند. شکل (۱۱) بخش (۲) مسیر رویارویی را در وسط مرحله تنظیم دقیق نشان می‌دهد، زمانی که طرف قرمز بر برخی از استراتژی های مانور تسلط پیدا کرده است. دو طرف ابتدا سعی می‌کنند ارتفاع را بالا ببرند. طرف آبی پس از ناتوانی در یافتن زاویه حمله مناسب به چپ می‌پیچد و برای بالا بردن ارتفاع در تلاش برای استفاده از برتری ارتفاع شتاب می‌گیرد. اما طرف قرمز سرعت و حرکت خود را به سرعت تنظیم می‌کند و در حین کاهش سرعت، یک مانور چرخش با زاویه بزرگ انجام می‌دهد. موقعیت تعقیب و گریز در برابر دشمن را شکل می‌دهد و پیروز می‌شود. شکل (۱۱) بخش (۳) مسیر رویارویی را در اواخر مرحله تنظیم دقیق نشان می‌دهد، زمانی که هر دو طرف بر استراتژی های مانور مسلط شده اند. هر دو طرف برای به دست آوردن برتری ارتفاع بالا می‌آیند، اما طرف قرمز سریعتر است. سپس طرف آبی دماغه خود را به سمت پایین می‌چرخاند تا از حملات جلوگیری کند و به دنبال فرصتی برای حمله باشد. با

این حال، طرف قرمز شیرجه می‌زند و به سمت چپ می‌رود تا موقعیت هجومی به دست بیاورد و طرف آبی را شکست دهد.

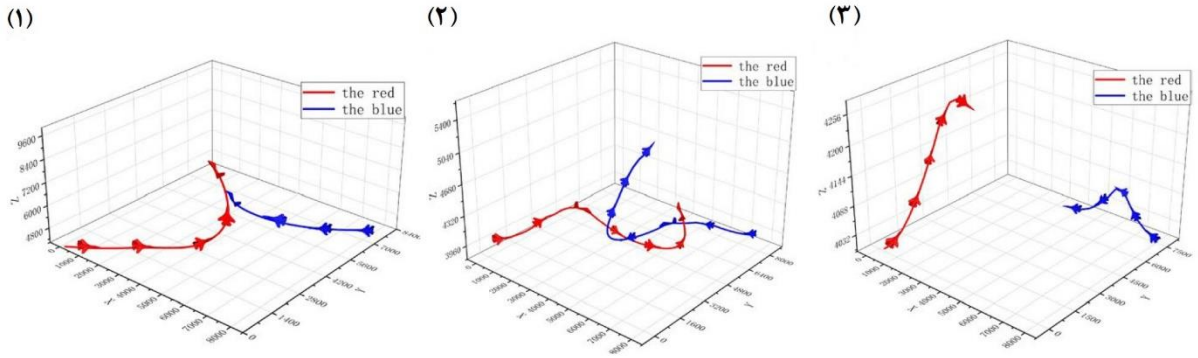

شکل ۱۱. مسیرهای مانور آموخته شده در مرحله تنظیم دقیق، شامل (۱) دوره اولیه، (۲) دوره میانی و (۳) دوره پایانی

شکل ۱۲. نرخ پیروزی تحت دو استراتژی آموزش

۳-۵. تست

به منظور بررسی اثربخشی تنظیم دقیق، از مدل DQN برای انتخاب مانور در سمت قرمز پس از ۱۵۰۰۰ تکرار پیش تمرین و تنظیم دقیق استفاده شده است. شکل (۱۲) مقایسه نرخ پیروزی در ۱۰۰۰ قسمت از آموزش را پس از مرحله قبل از آموزش و تنظیم دقیق نشان می‌دهد.نتایج نشان می‌دهد که پس از بازآموزی در شبکه عصبی آموزش دیده بر روی سناریوهای ساده، نرخ برد عامل از ۱۳ به ۷۸ درصد افزایش می‌یابد. مدل **DQN** با یادگیری تقویتی روند آموزش می‌تواند به طور مداوم تصمیم گیری هوشمند پهپاد را بهبود بخشد.

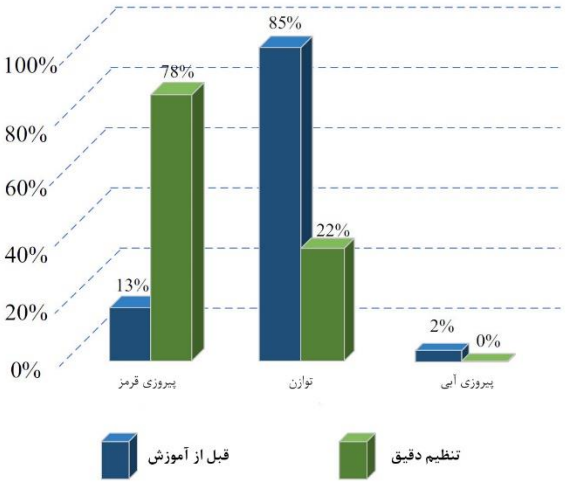

۴-۵. جهت گیری های تحقیقاتی آینده

فناوری هوشمند به ویژه هوش مصنوعی به سرعت در حال پیشرفت و تأثیرگذاری بر حوزه نظامی است. آموزش نبرد هوایی با چالش های زیادی مانند محدودیت های محل، آب و هوا، تجهیزات و پرسنل مواجه است. تکیه صرف به آموزش پرواز روزانه ناکارآمد است. علاوه بر این، با پیچیده‌تر شدن تجهیزات نظامی، خلبانان با بار عملیاتی بیشتری روبرو هستند. بنابراین نیاز شدیدی به پهپاد هوشمند وجود دارد که بتواند سختی و پیچیدگی عملیات را کاهش دهد و به خلبانان کمک کند. جهت توسعه آینده نبرد هوایی هوشمند مبتنی بر **DRL** شامل سه جنبه اصلی است.

۱-۴-۵. عامل رزمی جامع تر

محیط میدان نبرد پیچیده تر و سخت تر می‌شود. عوامل مختلفی مانند انواع مختلف رادار، طیف الکترومغناطیسی، تسلیحات، ظرفیت سوخت، برد، تخصیص هدف چند پهپاد و برنامه ریزی مشارکتی باید در نظر گرفته شوند. می‌توان از یادگیری تقویتی برای بهینه سازی مسیر پهپادها در محیط های خاص که در معرض خطر ردیابی راداری هستند، استفاده کرد.

۲-۴-۵. الگوریتم های آموزشی کارآمدتر

فصلنامه علمی - پژوهشی فرماندهی و کنترل، سال هفتم، شماره دو، تابستان ۱۴۰۲

یادگیری تقویتی یک الگوریتم قدرتمند و کلی است، اما همچنان با چالش هایی در بهبود کارایی نمونه و کاهش هزینه های یادگیری در محیط جنگ هوایی پویا و بلادرنگ مواجه است. برخی از روش‌های بهبود فعلی عبارتند از یادگیری تقویتی برنامه آموزش و طراحی توابع پاداش.

۳-٤-۵. ترکیبی از چندین الگوریتم تصمیم گیری

محیط های پیچیده نبرد هوایی اغلب با فضاهای حالت بزرگ با روابط پیچیده چند عاملی همراه است. یادگیری تقویتی ممکن است به توابع پاداش بسیار پیچیده برای رسیدگی به رویارویی هوایی در مقیاس بزرگ نیاز داشته باشد. بنابراین، ادغام آن با سایر الگوریتم‌ها روشی موثر برای حل چنین مسائلی است.

٦. نتیجه گیری

کنترل نبردهای هوایی مبتنی بر **DRL** در سال های اخیر موفقیت های زیادی کسب کرده و توجه زیادی را به خود جلب کرده است. در مقایسه با روش‌های سنتی، انتظار می‌رود روش‌های مبتنی بر **DRL** مانورهایی با کیفیت بالا را بصورت بلادرنگ ایجاد کنند. در ابتدا یک بررسی سیستماتیک برای درک تصویر کاملی از این زمینه ارائه دادیم. سپس، یک روش تصمیم گیری مانور **dogfight** یک به یک طراحی شد که به پهپاد اجازه می‌دهد در نبرد هوایی کوتاه برد پیروز شود. در نهایت، جهت گیری های احتمالی تحقیقات آینده شرح داده شد. خاطر نشان شده است که تمایل رو به رشدی وجود دارد که ساختارهای شبکه پیشرفته تری در مانورهای نبرد هوایی مبتنی بر **DRL** در حال استفاده می‌باشد که تا حدودی به بهبود کیفیت تصمیم گیری کمک می‌کند. به نظر ما، مطالعات آتی باید بیشتر بر روی بهبود سناریوهای خاص نبرد هوایی متمرکز شود. از یک طرف، برای ایجاد یک محیط شبیه‌سازی واقعی‌تر، باید اجزای جنگی لازم (مانند سنسورها، سلاح‌ها و مدل حرکت پهپاد با شش درجه آزادی) در نظر گرفته شود. از سوی دیگر، تاکتیک های پیچیده تر (مانند حمله هماهنگ چند پهپاد) باید برای انطباق با نیازهای نبرد هوایی مدرن مورد بهره برداری قرار گیرد.

۷. مراجع

[1] A. F. U. Din, I. Mir, F. Gul, and S. Akhtar, "Development of reinforced learning based non-linear controller for unmanned aerial vehicle," *Journal of Ambient Intelligence and Humanized Computing*, vol. 14, no. 4, pp. 4005-4022, 2023.

[2] K. Zhou, R. Wei, Z. Xu, and Q. Zhang, "A brain like air combat learning system inspired by human learning mechanism," in *2018 IEEE CSAA Guidance, Navigation and Control Conference (CGNCC)*, 2018: IEEE, pp. 1-6.

[3] K. Cui, W. Han, Y. Liu, X. Wang, X. Su, and J. Liu, "Model predictive control for automatic carrier landing with time delay," *International Journal of Aerospace Engineering*, vol. 2021, no. 1, p. 8613498, 2021.

[4] X. Gao *et al.*, "Conditional probability based multi-objective cooperative task assignment for heterogeneous UAVs," *Engineering Applications of Artificial Intelligence*, vol. 123, p. 106404, 2023.

[5] L. Wang and H. Wei, "Research on autonomous decision-making of UCAV based on deep reinforcement learning," in *2022 3rd Information Communication Technologies Conference (ICTC)*, 2022: IEEE, pp. 122-126.

[6] J. Poropudas and K. Virtanen, "Game-theoretic validation and analysis of air combat simulation models," *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, vol. 40, no. 5, pp. 1057-1070, 2010.

[7] J. B. Cruz *et al.*, "Game-theoretic modeling and control of a military air operation," *IEEE Transactions on aerospace and electronic systems*, vol. 37, no. 4, pp. 1393-1405, 2001.

[8] F. Austin, G. Carbone, M. Falco, H. Hinz, and M. Lewis, "Game theory for automated maneuvering during air-to-air combat," *Journal of Guidance, Control, and Dynamics*, vol. 13, no. 6, pp. 1143-1149, 1990.

[9] R. Chai, A. Tsourdos, H. Gao, S. Chai, and Y. Xia, "Attitude tracking control for reentry vehicles using centralised robust model predictive control," *Automatica*, vol. 145, p. 110561, 2022.

[10] J. Yan, W. Daobo, B. Tingting, and Y. Zongyuan, "Multi-UAV objective

wireless data harvesting with deep reinforcement learning," *IEEE Open Journal of the Communications Society*, vol. 2, pp. 1171-1187, 2021.

[20] B. Zhu, E. Bedeer, H. H. Nguyen, R. Barton, and J. Henry, "UAV trajectory planning in wireless sensor networks for energy consumption minimization by deep reinforcement learning," *IEEE Transactions on Vehicular Technology*, vol. 70, no. 9, pp. 9540-9554, 2021.

[21] W. Zhao, Z. Meng, K. Wang, J. Zhang, and S. Lu, "Hierarchical active tracking control for UAVs via deep reinforcement learning," *Applied Sciences*, vol. 11, no. 22, p. 10595, 2021.

[22] B. Li and Y. Wu, "Path planning for UAV ground target tracking via deep reinforcement learning," *IEEE access*, vol. 8, pp. 29064-29074, 2020.

[23] J. Xie, X. Peng, H. Wang, W. Niu, and X. Zheng, "UAV autonomous tracking and landing based on deep reinforcement learning strategy," *Sensors*, vol. 20, no. 19, p. 5630, 2020.

[24] D. Xu *et al.*, "PPO-Exp: keeping fixed-wing UAV formation with deep reinforcement learning," *Drones*, vol. 7, no. 1, p. 28, 2022.

[25] W. Zhao *et al.*, "Research on the multiagent joint proximal policy optimization algorithm controlling cooperative fixed-wing UAV obstacle avoidance," *Sensors*, vol. 20, no. 16, p. 4546, 2020.

[26] X. Zhao, R. Yang, Y. Zhang, M. Yan, and L. Yue, "Deep reinforcement learning for intelligent dual-UAV reconnaissance mission planning," *Electronics*, vol. 11, no. 13, p. 2031, 2022.

[27] L. Yue, R. Yang, Y. Zhang, L. Yu, and Z. Wang, "Deep reinforcement learning for UAV intelligent mission planning," *Complexity*, vol. 2022, no. 1, p. 3551508, 2022.

[28] J. Hu, L. Wang, T. Hu, C. Guo, and Y. Wang, "Autonomous maneuver decision making of dual-UAV cooperative air combat based on deep reinforcement learning," *Electronics*, vol. 11, no. 3, p. 467, 2022.

[29] H. Zhou, X. Zhang, and Z. Zhang, "Reinforcement learning technology for air combat confrontation of unmanned aerial assignment using Hungarian fusion genetic algorithm," *IEEE Access*, vol. 10, pp. 43013-43021, 2022.

[11] J. Kaneshige and K. Krishnakumar, "Artificial immune system approach for air combat maneuvering," in *Intelligent Computing: Theory and Applications V*, 2007, vol. 6560: SPIE, pp. 68-79.

[12] R. Chai, A. Tsourdos, A. Savvaris, S. Chai, Y. Xia, and C. P. Chen, "Six-DOF spacecraft optimal trajectory planning and real-time attitude control: a deep neural network-based approach," *IEEE transactions on neural networks and learning systems*, vol. 31, no. 11, pp. 5005-5013, 2019.

[13] H. Changqiang, D. Kangsheng, H. Hanqiao, T. Shangqin, and Z. Zhuoran, "Autonomous air combat maneuver decision using Bayesian inference and moving horizon optimization," *Journal of Systems Engineering and Electronics*, vol. 29, no. 1, pp. 86-97, 2018.

[14] X. Zhifei, L. Yue, K. Yingxin, L. Zhanwu, and L. You, "An online ensemble semi-supervised classification framework for air combat target maneuver recognition," *Chinese Journal of Aeronautics*, vol. 36, no. 6, pp. 340-360, 2023.

[15] K. Zhao and C. Huang, "Air combat situation assessment for UAV based on improved decision tree," in *2018 Chinese Control And Decision Conference (CCDC)*, 2018: IEEE, pp. 1772-1776.

[16] B. Li, Z. Gan, D. Chen, and D. Sergey Aleksandrovich, "UAV maneuvering target tracking in uncertain environments based on deep reinforcement learning and meta-learning," *Remote Sensing*, vol. 12, no. 22, p. 3789, 2020.

[17] L. Lyu, Y. Shen, and S. Zhang, "The advance of reinforcement learning and deep reinforcement learning," in *2022 IEEE International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA)*, 2022: IEEE, pp. 644-648.

[18] J. R. Vázquez-Canteli and Z. Nagy, "Reinforcement learning for demand response: A review of algorithms and modeling techniques," *Applied energy*, vol. 235, pp. 1072-1089, 2019.

[19] H. Bayerlein, M. Theile, M. Caccamo, and D. Gesbert, "Multi-UAV path planning for

vehicle," in *International conference on computer graphics, artificial intelligence, and data processing (ICCAID 2021)*, 2022, vol. 12168: SPIE, pp. 454-459.

[30] S. Parisi, D. Tateo, M. Hensel, C. D'eramo, J. Peters, and J. Pajarinen, "Long-term visitation value for deep exploration in sparse-reward reinforcement learning," *Algorithms*, vol. 15, no. 3, p. 81, 2022.

[31] X. Liu, Y. Yin, Y. Su, and R. Ming, "A multi-UCAV cooperative decision-making method based on an MAPPO algorithm for beyond-visual-range air combat," *Aerospace*, vol. 9, no. 10, p. 563, 2022.

[32] Z. Fan, Y. Xu, Y. Kang, and D. Luo, "Air combat maneuver decision method based on A3C deep reinforcement learning," *Machines*, vol. 10, no. 11, p. 1033, 2022.

[33] H. Piao *et al.*, "Beyond-visual-range air combat tactics auto-generation by reinforcement learning," in *2020 international joint conference on neural networks (IJCNN)*, 2020: IEEE, pp. 1-8.

[34] X. Cao, H. Wan, Y. Lin, and S. Han, "High-value prioritized experience replay for off-policy reinforcement learning," in *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*, 2019: IEEE, pp. 1510-1514.

[35] H. Zhang, H. Zhou, Y. Wei, and C. Huang, "Autonomous maneuver decision-making method based on reinforcement learning and Monte Carlo tree search," *Frontiers in neurorobotics*, vol. 16, p. 996412, 2022.

[36] Q. Yang, J. Zhang, G. Shi, J. Hu, and Y. Wu, "Maneuver decision of UAV in short-range air combat based on deep reinforcement learning," *IEEE Access*, vol. 8, pp. 363-378, 2019.

[37] W. Ruan, H. Duan, and Y. Deng, "Autonomous maneuver decisions via transfer learning pigeon-inspired optimization for UCAVs in dogfight engagements," *IEEE/CAA Journal of Automatica Sinica*, vol. 9, no. 9, pp. 1639-1657, 2022.

[38] B. Li, S. Bai, S. Liang, R. Ma, E. Neretin, and J. Huang, "Manoeuvre decision-making of unmanned aerial vehicles in air combat based on an expert actor-based soft actor critic algorithm," *CAAI Transactions on Intelligence Technology*, vol. 8, no. 4, pp. 1608-1619, 2023.

[39] D. Hu, R. Yang, J. Zuo, Z. Zhang, J. Wu, and Y. Wang, "Application of deep reinforcement learning in maneuver planning of beyond-visual-range air combat," *IEEE Access*, vol. 9, pp. 32282-32297, 2021.

[40] Y. Cao, Y.-X. Kou, Z.-W. Li, and A. Xu, "Autonomous maneuver decision of UCAV air combat based on double deep Q network algorithm and stochastic game theory," *International Journal of Aerospace Engineering*, vol. 2023, no. 1, p. 3657814, 2023.