



## Research Paper;



# Optimal Air Taxi Design Using Reinforcement Learning via the Q-Learning Algorithm

Iman Fozouni Talouki<sup>1</sup>, Alireza Toloei<sup>2</sup>

1. Faculty of Aerospace, University of Shahid Beheshti, Tehran, Iran. E-mail: taloukifi@gmail.com

2. Faculty of Aerospace, University of Shahid Beheshti, Tehran, Iran. E-mail: [toloei@sbu.ac.ir](mailto:toloei@sbu.ac.ir)

### Article Information

### Abstract

**Accepted:**  
2025/05/26

**Received:**  
2025/03/19

#### Keywords:

Q-Learning Algorithm; Aircraft Design Optimization; Wing and Tail Surface Optimization; Efficiency; Air Taxi; Weight

**Corresponding Author: Alireza Toloei**

**Email:**

[toloei@sbu.ac.ir](mailto:toloei@sbu.ac.ir)

**Introduction:** Urban air mobility and air taxi systems have emerged as promising solutions for future transportation demands due to their potential for reducing travel time and improving transportation efficiency. However, achieving an optimal balance among aircraft weight, aerodynamic performance, fuel efficiency, and mission requirements remains a significant challenge during the conceptual design phase. Therefore, the development of intelligent optimization approaches integrated with conventional design methodologies is of considerable importance.

**Methods:** This study presents the optimal design of an 18-passenger air taxi through the integration of classical aircraft design methods and a Q-learning-based reinforcement learning framework. Initially, baseline parameters, including maximum takeoff weight, empty weight, fuel consumption, and wing area, were estimated using established conceptual design relations. A simulation environment was then developed in which the state space was defined by key nondimensional parameters, including thrust-to-weight ratio, wing area ratio, fuel weight ratio, and empty-weight-to-maximum-weight ratio. The action space consisted of bounded modifications to wing area, aspect ratio, and thrust-to-weight ratio. The reinforcement learning agent was trained for 2000 episodes with a maximum of 40 design steps per episode using an  $\epsilon$ -greedy policy under a fixed mission profile defined by cruise altitude, cruise speed, range requirements, and field length constraints.

**Findings:** The optimization process resulted in a 3.8% reduction in wing area and a 2.1% increase in aspect ratio. Furthermore, the horizontal and vertical tail areas decreased by 2.9% and 3.2%, respectively. These geometric refinements led to reductions in empty weight (4.1%) and fuel consumption (5%). Significant improvements in aerodynamic and performance characteristics were also observed, including increases in lift-to-drag ratio (20%), rate of climb (33.3%), and cruise speed (6.7%). Consequently, the flight range increased by 14.5%.

**Conclusion:** The findings demonstrate that integrating classical aircraft design methodologies with reinforcement learning provides an effective and data-driven framework for improving air taxi design. The proposed approach successfully achieved simultaneous reductions in aircraft weight and fuel consumption while enhancing aerodynamic efficiency and mission performance, indicating its potential for future intelligent conceptual aircraft design applications.



## فصلنامه علمی دفاع هو فضایی

دوره ۴ شماره ۱  
بهار ۱۴۰۴  
صفحات ۱۲۰ - ۲۶



مقاله پژوهشی؛  doi

### طراحی بهینه تاکسی هوایی به کمک یادگیری تقویتی به واسطه الگوریتم یادگیری Q

ایمان فزونی تلوکی<sup>۱</sup>، علیرضا طلوعی<sup>۲\*</sup>

۱. دانشجو، گروه هوافضا، دانشگاه شهید بهشتی، استان تهران، ایران. رایانامه: taloukifi@gmail.com

۲. دانشیار، گروه هوافضا، دانشگاه شهید بهشتی، استان تهران، ایران. رایانامه: toloei@sbu.ac.ir

#### اطلاعات مقاله

#### چکیده

تاریخ دریافت:

۱۴۰۴/۱۲/۲۸

تاریخ پذیرش:

۱۴۰۵/۰۳/۲

کلیدواژه‌ها:

الگوریتم یادگیری Q،  
بهینه‌سازی طراحی هواپیما،  
بهینه‌سازی سطح بال و دم‌ها،  
کارایی، تاکسی هوایی

**مقدمه:** تاکسی‌های هوایی به‌عنوان یکی از راهکارهای نوین حمل‌ونقل هوایی شهری، به دلیل قابلیت کاهش زمان سفر و افزایش بهره‌وری سامانه‌های حمل‌ونقل، مورد توجه گسترده قرار گرفته‌اند. با این حال، دستیابی به تعادل بهینه میان وزن هواپیما، عملکرد آپروندینامیکی، مصرف سوخت و الزامات مأموریتی در مرحله طراحی مفهومی، همچنان یک چالش اساسی محسوب می‌شود. از این‌رو، بهره‌گیری از روش‌های هوشمند در کنار رویکردهای متداول طراحی هواپیما از اهمیت بالایی برخوردار است.

**روش‌ها:** این پژوهش به طراحی بهینه یک تاکسی هوایی ۱۸ نفره با تلفیق روش‌های کلاسیک طراحی هواپیما و چارچوب یادگیری تقویتی مبتنی بر Q-learning پرداخته است. در گام نخست، پارامترهای پایه شامل بیشینه وزن برخاست، وزن خالی، مصرف سوخت و مساحت بال با استفاده از روابط طراحی مفهومی کلاسیک برآورد شدند. سپس یک محیط شبیه‌سازی توسعه داده شد که در آن فضای حالت با نسبت‌های بی‌بعد کلیدی شامل نسبت تراست، نسبت مساحت بال، نسبت وزن سوخت و نسبت وزن خالی به بیشینه وزن تعریف شد و فضای عمل شامل تغییرات کران‌دار در مساحت بال، ضریب منظری و نسبت تراست به وزن بود. عامل یادگیرنده با استفاده از سیاست ε-greedy طی ۲۰۰۰ اپیزود و حداکثر ۴۰ گام طراحی در هر اپیزود، تحت یک سناریوی مأموریتی ثابت شامل ارتفاع کروز، سرعت کروز هدف، برد طراحی و قیود طول باند آموزش داده شد.

**یافته‌ها:** نتایج بهینه‌سازی نشان داد که مساحت بال ۳.۸٪ کاهش و ضریب منظری ۱.۲٪ افزایش یافته است. همچنین، مساحت دم افقی و دم عمودی به ترتیب ۹.۲٪ و ۲.۳٪ کاهش یافتند. این اصلاحات هندسی منجر به کاهش وزن خالی به میزان ۱.۴٪ و کاهش مصرف سوخت به میزان ۵٪ شد. علاوه بر این، بهبودهای قابل توجهی در ویژگی‌های آپروندینامیکی و عملکردی مشاهده شد؛ به طوری که نسبت برا به پسا ۲۰٪، نرخ اوج‌گیری ۳.۳٪ و سرعت کروز ۷.۶٪ افزایش یافتند. در نتیجه، برد پروازی نیز ۵.۱۴٪ افزایش پیدا کرد.

**نتیجه‌گیری:** یافته‌های این پژوهش نشان می‌دهد که تلفیق روش‌های کلاسیک طراحی هواپیما با یادگیری تقویتی، رویکردی داده‌محور و کارآمد برای بهبود هم‌زمان وزن، کارایی آپروندینامیکی و عملکرد مأموریتی تاکسی‌های هوایی فراهم می‌کند و می‌تواند به‌عنوان ابزاری مؤثر در طراحی هوشمند هواپیماهای آینده مورد استفاده قرار گیرد.

نویسنده مسئول: علیرضا  
طلوعی

ایمیل:

toloei@sbu.ac.ir

استناد: ایمان فزونی تلوکی، علیرضا طلوعی، (۱۴۰۵). طراحی بهینه تاکسی هوایی به کمک یادگیری تقویتی به واسطه الگوریتم یادگیری Q. مجله دفاع

هوافضایی، دوره ۵ (شماره ۱)، صفحه ۵۶-۲۶.

## ۱- مقدمه

طراحی هواپیما به عنوان یکی از پیچیده ترین فرایندهای مهندسی شناخته می شود که مستلزم درک عمیق و هم زمان اصول آیرودینامیک، سازه، پیشرانه و سامانه های کنترلی است [۱]. این فرایند در مرحله طراحی مفهومی و اولیه، شامل مجموعه ای از تحلیل های پارامتریک و ارزیابی های تکرارشونده است که از شکل گیری ایده اولیه تا تعیین پیکربندی پایه هواپیما را دربر می گیرد. در این مسیر، ابزارها و روش های متعددی به منظور افزایش دقت تخمین ها و بهبود کیفیت تصمیم گیری های طراحی توسعه یافته اند [۲]. در کنار رویکردهای کلاسیک، نگرش مهندسی سیستم نقش مهمی در ساماندهی فرایند طراحی ایفا کرده است؛ زیرا با ایجاد چارچوبی ساختاریافته، ارتباط میان حوزه های مختلف مهندسی را منظم ساخته و امکان ارزیابی هماهنگ میان اجزای آیرودینامیکی، سازه ای و عملکردی را فراهم آورده است [۳]. در این ساختار، استفاده از روابط عملکردی نظیر سرعت واماندگی، سرعت برخاست، نرخ اوج گیری و شاخص های مأموریتی، به عنوان ابزارهای کلیدی تحلیل، جایگاه ویژه ای دارد. این روابط، مبنای تحلیل های کمی در طراحی اولیه بوده و در تخمین کارایی کلی هواپیما نقش تعیین کننده ای ایفا می کنند [۴]. در فرآیند طراحی هواپیما، تمرکز اصلی بر توسعه سامانه هایی است که نه تنها قادر به تامین طیف متنوعی از الزامات عملکردی و عملیاتی مشتریان باشند، بلکه فراتر از انتظارات آنها عمل کنند. در سال های اخیر، حوزه طراحی سامانه های هوایی تجاری با دگرگونی های بنیادینی مواجه شده است. این تحولات منجر به شکل گیری رویکرد هایی شده اند که به طور فزاینده بر شاخص هایی نظیر بهروری عملکردی، پایداری زیست محیطی و بهینه سازی منابع تاکید دارند. ادغام این ملاحظات در فرآیند طراحی می تواند کارایی عملیاتی یک محصول یا سیستم را افزایش دهد [۵]. در سال های اخیر، مفهوم تاکسی هوایی جایگاه ویژه ای در صنعت هوانوردی به دست آورده است. این دسته از هواپیماهای کوچک و کارآمد، با هدف جابه جایی مسافر در مسیرهای کوتاه تا متوسط توسعه یافته اند و قابلیت بهره برداری از باندهای کوتاه یا زیرساخت های محدود را فراهم می کنند. چنین ویژگی هایی، آنها را به گزینه ای مناسب برای حمل و نقل سریع، شخصی و نقطه به نقطه تبدیل کرده است. مطالعات انجام شده نشان می دهد که طراحی این هواگردها در مرحله مفهومی نیازمند توجه ویژه به ابعاد بهینه، قابلیت نشست و برخاست کوتاه و مصرف سوخت کارآمد است و بهینه سازی این پارامترها تأثیر مستقیمی بر کاهش هزینه های عملیاتی و افزایش بهره وری مأموریتی دارد [۶]. طراحی این نوع از وسایل نقلیه حتی به صورت شهری، با چالش های فراوانی در فاز مفهومی و یکپارچه سازی زیر سیستم ها مواجه هست [۷]. در پاسخ به این نیازها، طی سال های اخیر رویکردهای مختلف بهینه سازی در طراحی هواپیما مورد استفاده قرار گرفته اند. به ویژه روش های بهینه سازی چند پارامتری، امکان بررسی هم زمان مجموعه ای از متغیرهای کلیدی طراحی را فراهم ساخته اند. این رویکردها با تحلیل هم زمان پارامترهای آیرودینامیکی و عملکردی، دید جامع تری نسبت به رفتار کلی پرنده ارائه داده و محدودیت های ناشی از بررسی تک معیاره را کاهش داده اند. در این چارچوب، به جای تمرکز بر یک

شاخص منفرد، مجموعه‌ای از قیود و اهداف طراحی به صورت هم‌زمان ارزیابی شده و نتایج آن به طرح‌هایی با کارایی عملیاتی بالاتر و عملکرد پروازی بهبودیافته منجر شده است [۸]. ادامه این مسیر پژوهشی نشان داد که استفاده از بهینه‌سازی چند پارامتری می‌تواند به کاهش مصرف سوخت، بهبود شاخص‌های عملکردی و افزایش کارایی کلی هواپیماهای منطقه‌ای و تاکسی‌های هوایی بینجامد [۹]. در همین راستا، توسعه ابزارهای محاسباتی و نرم‌افزارهای طراحی، فرایند تحلیل هم‌زمان پارامترهای کلیدی را تسهیل کرده و امکان کاوش گسترده‌تر فضای طراحی را فراهم آورده است [۱۰]. این ابزارها با کاهش زمان تکرارهای طراحی و افزایش انسجام تحلیلی، زمینه ارائه راه‌حل‌های کارآمدتر در مرحله طراحی مفهومی را فراهم ساخته‌اند. پیشرفت این ساختارهای تحلیلی، بستر مناسبی برای ارزیابی فناوری‌های نوین در هواپیماهای منطقه‌ای ایجاد کرده است. این رویکردها با فراهم کردن امکان تحلیل دقیق‌تر رفتار آیرودینامیکی و عملکرد مأموریتی، به طراحان اجازه داده‌اند تا تعامل میان پارامترهای کلیدی را با دقت بیشتری بررسی کنند و تصمیم‌های طراحی را بر پایه تحلیل عددی منسجم‌تری اتخاذ نمایند [۱۱]. هم‌زمان با این تحولات، استفاده از روش‌های هوشمند، به‌ویژه یادگیری تقویتی، در مسائل هوانوردی رشد قابل توجهی داشته است. این رویکردها با مدل‌سازی مسئله به صورت تصمیم‌گیری متوالی و یادگیری از تعامل با محیط شبیه‌سازی شده، امکان تحلیل و بهبود عملکرد سامانه‌های پروازی را به صورت تطبیقی فراهم کرده‌اند [۱۲]. در میان این روش‌ها، هوش مصنوعی توانسته است یک چارچوبی در برنامه‌ریزی مسیر مبتنی بر یادگیری تقویتی عمیق (DRL) با استفاده از الگوریتم *Soft Actor – Critic (SAC)* ارائه دهد. این روش با بهره‌گیری از داده‌های محیطی، دقت مانورها و توانایی اجتناب از موانع را به طور چشمگیری بهبود بخشید و کارایی الگوریتم‌های *DRL* متداول را در سناریوهای عملیاتی پیچیده به چالش کشید [۱۳]. علاوه بر کاربردهای مستقیم در طراحی هواپیما، رویکردهای مبتنی بر یادگیری تقویتی در حوزه‌های مختلف هوانوردی نیز توسعه یافته‌اند. در سامانه‌های دارای جرم متغیر، استفاده از یادگیری تقویتی عمیق موجب بهبود پایداری و افزایش دقت کنترل شده است [۱۴]. در حوزه نگهداری و تعمیرات ناوگان هوایی نیز به کارگیری روش‌های یادگیری ماشینی، ارتقای فرایندهای تشخیصی و کاهش هزینه‌های عملیاتی را به همراه داشته است [۱۵]. در زمینه کنترل پرواز، این رویکردها به عنوان ابزاری مقاوم برای طراحی کنترل‌کننده‌های هواپیماهای سبک مورد توجه قرار گرفته‌اند و نتایج آزمایشگاهی نشان داده‌اند که می‌توانند کیفیت پاسخ و پایداری سامانه را بهبود بخشند [۱۶]. همچنین در اجزای فعال بال و سامانه‌های کنترلی هوشمند، یادگیری تقویتی به عنوان ابزار تصمیم‌گیری تطبیقی مورد استفاده قرار گرفته است [۱۷]. کاربرد این روش‌ها در فرایندهای پیچیده‌تر نظیر فرود خودکار هواپیماهای بال ثابت نیز نتایج موفقیت‌آمیزی داشته و عملکرد پایدار در محیط‌های دینامیکی را نشان داده است [۱۸]. افزون بر این، در مرحله آزمایش‌های پروازی و ارزیابی‌های پیش پرواز، روش‌های مبتنی بر یادگیری ماشینی به بهینه‌سازی عملیات و کاهش زمان آماده‌سازی کمک کرده‌اند [۱۹]. فراتر از حوزه کنترل، برخی پژوهش‌ها نشان داده‌اند که الگوریتم‌های یادگیری تقویتی می‌توانند در فرایندهای تصمیم‌سازی مهندسی نیز به کار

گرفته شوند و در شرایط عدم قطعیت، انتخاب‌های طراحی سازگارتر و کارآمدتری ارائه دهند [۲۰]. همچنین رویکردهای یادگیری تقویتی پارامتری در مسائل بهینه‌سازی مهندسی عملکرد قابل توجهی از خود نشان داده‌اند [۲۱]. ترکیب این روش‌ها با الگوریتم‌های تکاملی برای مسائل غیر مشتق‌پذیر نیز موجب بهبود نرخ همگرایی و کیفیت پاسخ‌ها شده است [۲۲]. در کنار این پیشرفت‌ها، استفاده از چارچوب‌های شبیه‌سازی پیشرفته برای مدیریت تعامل میان پارامترهای طراحی، بستر مناسبی برای تحلیل منسجم‌تر فرایند طراحی فراهم کرده است [۲۳]. مطالعات اخیر در حوزه بهینه‌سازی طراحی مهندسی نیز نشان می‌دهد که رویکردهای چندمتغیره که امکان ارزیابی هم‌زمان پارامترهای طراحی را فراهم می‌کنند، از نظر مفهومی با سازوکار یادگیری تقویتی هم‌راستا هستند [۲۴]. این هم‌راستایی نشان می‌دهد که می‌توان از منطق تصمیم‌گیری تطبیقی برای بهبود روند طراحی مفهومی استفاده کرد، بدون آنکه الزاماً چارچوب‌های رسمی بهینه‌سازی چندرشته‌ای به طور کامل پیاده‌سازی شوند. از سوی دیگر، کاهش وزن عملیاتی همواره یکی از اهداف کلیدی در طراحی هواپیماهای منطقه‌ای و تاکسی‌های هوایی بوده است. کاهش وزن موجب بهبود نسبت بار مفید، کاهش نیاز به توان پیشران، بهبود عملکرد برخاست و فرود و در نهایت کاهش مصرف سوخت در مأموریت‌های مشابه می‌شود. این بهبودها به افزایش برد و مداومت پروازی انجامیده و تأثیر اقتصادی قابل توجهی در چرخه عمر هواپیما دارند [۲۵]. با توجه به این پیشینه، می‌توان نتیجه گرفت که روش‌های مبتنی بر یادگیری ماشین، در اصل ابزارهای تصمیم‌سازی و تحلیل هستند که قابلیت ادغام با فرایندهای طراحی مفهومی را دارند. در پژوهش حاضر، یک تاکسی هوایی ابتدا با استفاده از روابط و روش‌های کلاسیک طراحی مفهومی پیکربندی شد. سپس این مدل پایه در یک محیط شبیه‌سازی عددی تحت چرخه‌های یادگیری تقویتی قرار گرفت تا پارامترهای کلیدی طراحی به صورت تطبیقی اصلاح شوند. در این چارچوب، الگوریتم یادگیرنده از طریق تعامل مستمر با مدل عملکردی هواپیما، نسخه‌ای بهبودیافته از طرح اولیه ارائه داد. این رویکرد نشان می‌دهد که بهره‌گیری از یادگیری تقویتی می‌تواند فرایند طراحی مفهومی را از یک روند تکرارشونده مبتنی بر تنظیم دستی، به یک فرایند تصمیم‌گیری خودآموز و کارآمد تبدیل کند.

در مجموع، با وجود توسعه روش‌های بهینه‌سازی متعدد و کاربرد گسترده یادگیری تقویتی در کنترل و هدایت سامانه‌های پروازی، استفاده از یادگیری تقویتی به عنوان یک چارچوب تصمیم‌گیری خودکار در مرحله طراحی مفهومی و اولیه هواپیما، به ویژه در کلاس تاکسی‌های هوایی منطقه‌ای، به صورت ساختاریافته و یکپارچه کمتر مورد توجه قرار گرفته است. شکاف موجود در ادبیات، عدم وجود یک سامانه طراحی خودکار است که بتواند بدون اتکا به تنظیمات تکراری مبتنی بر تجربه و نمودارخوانی‌های سنتی، به صورت تطبیقی در فضای طراحی حرکت کرده و نسبت‌های کلیدی وزنی، هندسی و کارایی را به صورت هم‌زمان بهینه نماید.

هدف این پژوهش، توسعه و ارزیابی یک چارچوب طراحی خودکار مبتنی بر الگوریتم *Q-learning* در محیط شبیه‌سازی شده طراحی مفهومی و اولیه است که بتواند پارامترهای

اصلی یک تاکسی هوایی در بازه ظرفیتی ۶ تا ۴۰ نفر را به صورت هم‌زمان بر اساس شیوه‌های روز طراحی و متداول بهینه کند. نوآوری اصلی پژوهش حاضر در تبدیل فرایند طراحی هواپیما از یک‌روند ترتیبی مبتنی بر حدس مهندسی به یک فرایند تصمیم‌گیری متوالی خودآموز است که در آن عامل یادگیرنده با تعامل مستقیم با مدل فیزیکی، به همگرایی طراحی بهینه دست می‌یابد قابل ذکر می‌باشد که این روند به راحتی برای طراحی هواپیماها در اوزان و بیش‌تر و همچنین شرایط پیچیده‌تر قابل ارتقا می‌باشد. به منظور تبیین سهم علمی پژوهش حاضر، لازم به اشاره است که برخلاف اغلب مطالعات اخیر که یادگیری تقویتی را در حوزه کنترل، هدایت مسیر یا بهینه‌سازی موضعی شکل آیرودینامیکی به کار گرفته‌اند، در این پژوهش چارچوب *Q-learning* به سطح طراحی مفهومی و ساینینگ اولیه هواپیما منتقل شده است. این انتقال، منجر به بهبودهای قابل‌اندازه‌گیری در شاخص‌هایی نظیر نسبت برآ به پسا، مصرف سوخت و برد پروازی نسبت به طرح کلاسیک مبنا شده است که نتایج آن در بخش تحلیل ارائه شده است. از این منظر، نوآوری پژوهش حاضر در کاربرد صرف الگوریتم نیست، بلکه در بازتعریف فرایند طراحی سنتی به صورت یک مسئله تصمیم‌گیری تطبیقی و خودآموز در مرحله مفهومی نهفته است.

## ۲- طراحی سنتی هواپیما

در این بخش، در محیط پایتون به طراحی هواپیمای ۲۱ سرنشین، متشکل از ۱۸ مسافر، دو خلبان و یک مهماندار، مندرج در «جدول ۵» پرداخته شده است. ابتدا در مرحله مفهومی، وزن اولیه هواپیما با استفاده از روش‌های استاندارد تخمین وزنی و بر اساس داده‌های هندسی و مأموریتی، تخمین زده شده است (۱-۲). سپس به بررسی کارایی پرداخته شده است (۳-۷)، به گونه‌ای که پارامترهای کلیدی عملکردی شامل نسبت‌های آیرودینامیکی، الزامات مسافت باند، رفتار هواپیما در شرایط بحرانی و محدوده‌های مأموریتی ارزیابی شده تا از برآورده شدن نیازمندی‌های عملیاتی اطمینان حاصل شود. در انتها نیز مساحت ناخالص بال و نیروی موردنیاز پیشران بر اساس شرایط طراحی، ضرایب برآ و پسا و همچنین الزامات صعود و کروز محاسبه گردیده است (۸-۹). سپس به ترتیب، محاسبات در مرحله اولیه که شامل طراحی و تحلیل المان‌های اصلی سازه‌ای و آیرودینامیکی است انجام شده و مؤلفه‌های بال (۱۰)، دم‌های افقی و عمودی (۱۱)، بدنه (۱۲) و ارباه فرود (۱۳) با استفاده از روابط تجربی، مدل‌های تحلیلی و داده‌های تطبیقی مورد ارزیابی و ابعاد اولیه آن‌ها تعیین گردیده است. این روند، چارچوبی سلسله‌مراتبی و منظم را برای حصول طرح اولیه هواپیما ارائه می‌کند که امکان توسعه بیشتر در مراحل بعدی طراحی تفصیلی را نیز فراهم می‌سازد.

$$W_{TO} = W_{PL} + W_{Crew} + W_F + W_E \quad (1)$$

$$W_{Pass} = 180(Ib) \times (n) = (x) Ib \quad (2)$$

$$W_{Pilot} = (n) \times 200(Ib) = (x) Ib$$

$$W_{Attendant} = (n) \times 180(Ib) = (x) Ib$$

$$W_{Cargo} = (n) \times 40(Ib) = (x) Ib$$

$$W_{Crew} = W_{Pilot} + W_{Attendant}$$

$$W_{Payload} = W_{Pass} + W_{Cargo} = (x) Ib$$

$$\left(\frac{T_{SL}}{W}\right)_{V_{max}} = \rho V_{max}^2 C_{D0} + \frac{1}{2} \left(\frac{W}{S}\right) + \frac{2K}{\rho \sigma V_{max}^2} \left(\frac{W}{S}\right) \quad (۳)$$

$$\left(\frac{W}{S}\right)_{V_S} = \frac{1}{2} \rho V_S^2 C_{Lmax} (F - 2) \quad (۴)$$

$$\left(\frac{T}{W}\right)_{ROC} = \frac{ROC_{max}}{\sqrt{\frac{2W}{\rho S} \sqrt{\frac{C_{D0}}{K}} \left(\frac{W}{S}\right)}} + \frac{1}{\left(\frac{L}{D}\right)_{max}} (jet)(F - 3 - b) \quad (۵)$$

$$\left(\frac{T}{W}\right)_{STO} = \frac{\mu - \left(\mu + \frac{C_{Dg}}{C_{LR}}\right) \left[\exp\left(0.6\rho g C_{Dg} S_{TO} \frac{S}{W}\right)\right]}{1 - \left[\exp\left(0.6\rho g C_{Dg} S_{TO} \frac{S}{W}\right)\right]} \quad (۶)$$

$$\left(\frac{T}{W}\right)_{hc} = \frac{ROC_c}{\sigma_c \sqrt{\frac{2}{\rho_c} \sqrt{\frac{C_{D0}}{K}} \left(\frac{W}{S}\right)}} + \frac{1}{\sigma_c \left(\frac{L}{D}\right)_{max}} \quad (۷)$$

$$\left(\frac{W}{S}\right)_{V_S} = \frac{1}{2} \rho V_S^2 C_{Lmax} \quad (۸)$$

$$\left(\frac{T_{SL}}{W}\right)_{V_{max}} - \frac{2KW}{\rho \sigma V_{max}^2} = \rho V_{max}^2 C_{D0} + \frac{S}{2W} \quad (۹)$$

$$S_{wing} = \frac{W_{TO}}{W} \quad (۱۰)$$

$$V_H = \frac{l_H S_H}{\bar{C} S} \quad (11)$$

$$V_V = \frac{l_V S_V}{b S}$$

$$L_{fuse} = L_{nose} + L_{cabin} + L_{tail} \quad (12)$$

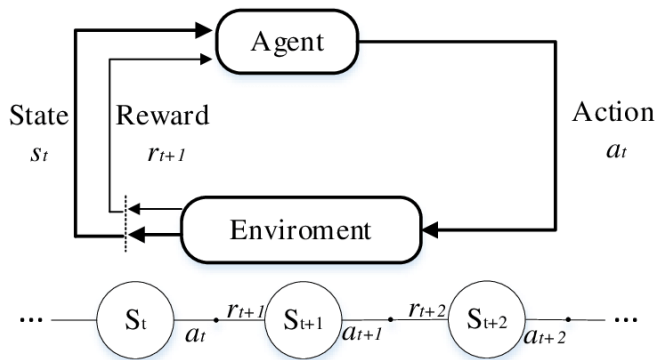
$$X_{MG} = X_{CG} + (0.1 - 0.15)l_{fuse} \quad (13)$$

### ۳- یادگیری تقویتی

یادگیری تقویتی «جدول ۱» شاخه‌ای از یادگیری ماشین است که در آن یک عامل با تعامل مستقیم با محیط می‌آموزد که چگونه دنباله‌ای از اقدامات (عمل) را انتخاب کند تا پاداش تجمعی را در طول زمان به حداکثر برساند. «شکل ۱» در این فرایند، عامل بر اساس بازخورد دریافتی از محیط (پاداش یا جریمه) <sup>۱</sup>، استراتژی خود را بهبود می‌بخشد [۲۶].

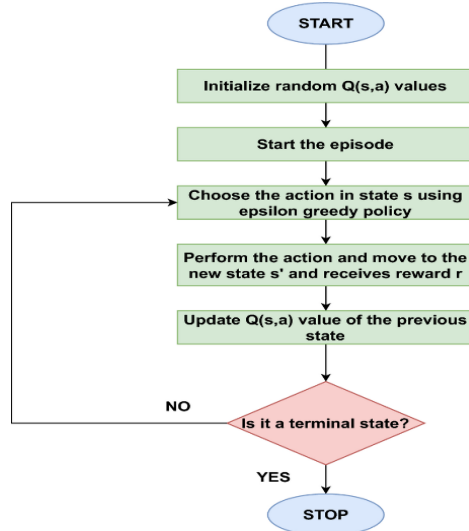
نام	پارامتر	علائم	تعریف
۱	عامل	<i>Agent</i>	تصمیم‌گیرنده
۲	محیط	<i>Environment</i>	فضای عمل عامل
۳	حالت	<i>States</i>	بازنمایی وضعیت کنونی محیط
۴	عمل	<i>Actions</i>	مجموعه کارهایی منسوب به عامل
۵	پاداش	<i>Rewards</i>	بازخورد دریافتی که عامل پس از انجام یک اقدام
۶	سیاست	<i>Policy</i>	نقشه راه عامل برای اقدامات در هر حالت
۷	تابع ارزش	<i>Value Function</i>	انتظار پاداش تجمعی در یک حالت خاص

جدول (۱). اجزای تشکیل‌دهنده یادگیری تقویتی



شکل ۱: نمایی از تعامل عامل و محیط با عمل و پاداش‌های حاصل در حالت‌های مختلف

در حقیقت این روش بدین‌گونه عمل می‌کند که پاداش فوری برای انجام اقدام  $a$  در حالت  $S$  توسط تابع پاداش مشخص می‌شود. (۴) و تابع ارزش حالت نیز انتظار پاداش تجمعی از حالت  $S$  را نشان می‌دهد که تعریف ریاضی آن به صورت رابطه بلمن است. (۵) در ادامه نیز تابع ارزش حالت اقدام، انتظار پاداش تجمعی از انجام اقدام  $a$  در حالت  $S$  است. (۶) رابطه بازگشتی بلمن همان ارتباط بین ارزش حالت و ارزش حالت اقدام را نشان می‌دهد که برای سیاست بهینه استفاده می‌شود. (۷) برای بهبود سیاست عامل و دستیابی به سیاست بهینه، ارزش حالت اقدام نیز با استفاده از معادله بلمن به‌روزرسانی می‌شود. (۸) در نهایت نیز مقادیر  $Q$  «شکل ۲» به‌روزرسانی خواهند شد. (۹) در مجموع می‌توان این‌گونه هم بیان نمود، یادگیری تقویتی به طراحان اجازه می‌دهد تا به طور هم‌زمان چندین هدف مختلف را در طراحی بهینه کنند.



شکل ۲: روندنمای یادگیری  $Q$

$$r_t = R(s_t, a_t) \quad (14)$$

$$V_{\pi(s)} = E_{\pi} \left[ \sum_{t=0}^{\infty} \gamma^t r | S_0 = S \right] \quad (15)$$

$$Q_{\pi}(s, a) = E_{\pi} \left[ \sum_{t=0}^{\infty} \gamma^t r | S_0 = S, a_0 = a \right] \quad (16)$$

$$V_{\pi(s)} = E_{\pi} [r_t + \gamma V_{\pi}(s_{t+1})] \quad (17)$$

$$Q_{\pi}(s, a) = E_{\pi} r_t + \gamma Q_{\pi}(s_{t+1}, a_{t+1}) \quad (18)$$

$$Q(s, a) \rightarrow Q(s, a) + \alpha [r + \gamma \max_{\hat{a}} Q(s, \hat{a}) - Q(s, a)] \quad (19)$$

که در آن  $s$  حالت کنونی محیط،  $\alpha$  اقدام انجام شده توسط عامل،  $r_t$  پاداش فوری عامل پس از عمل،  $R(s_t, a_t)$  تابع پاداش،  $V_{\pi(s)}$  انتظار پاداش تجمعی از حالت تحت سیاست،  $Q(s, a)$  انتظار پاداش تجمعی از حالت تحت سیاست،  $\gamma$  سیاست حاکم بر عامل،  $\alpha$  نرخ یادگیری که میزان تأثیر پاداش جدید بر مقدار فعلی را تعیین می‌کند،  $\gamma$  ضریب تخفیف که اهمیت پاداش‌های آینده نسبت به پاداش‌های کنونی را تعیین می‌کند،  $Q$  حالت بعدی پس از انجام اقدام  $a$  در حالت  $s$ ،  $\alpha$  اقدام ممکن بعدی در حالت  $Q$ ،  $\max_{\hat{a}} Q(s, \hat{a})$  بیشینه ارزش اقدام‌ها در حالت بعدی برای سیاست بهینه می‌باشد.

#### ۴- روند پژوهش

در این پژوهش ابتدا با توجه به ورودی‌های «جدول ۲» هواپیما با شیوه سنتی طراحی شده و محاسبات خروجی‌های مهم و قابل کاربرد با شیوه سنتی در ادامه روند در «جدول ۳» به‌نمایش درآمده است. سپس با استفاده از الگوریتم یادگیری  $Q$  برای طراحی تاکسی هوایی جت با ورودی‌های مشخص که همان خروجی کد سنتی می‌باشد، مورد استفاده قرار گرفته است [۲۷]. این روش ترکیبی از مدل‌سازی دقیق و شبیه‌سازی به کمک یادگیری تقویتی است که به‌منظور بهینه‌سازی پارامترهای کلیدی طراحی شامل وزن برخاست، عملکرد آیرودینامیکی، کارایی و محاسبات هندسی هواپیما به کار گرفته شده است [۲۸]. ابتدا مدل پایه طراحی تاکسی هوایی با استفاده از معادلات عملکردی و هندسی مطابق با معادلات (۴-۱۳) ایجاد شده است. این مدل شامل تخمین وزن‌ها، نسبت‌های آیرودینامیکی، کارایی و معیارهای سازه‌ای است که در مراحل اولیه

طراحی هواپیما مورد نیاز است. سپس، یادگیری  $Q$  برای بهینه‌سازی پارامترهای اصلی طراحی در یک محیط شبیه‌سازی شده اعمال شده است [۲۹]. روش به این صورت است که با ایجاد مدل پایه طراحی و به‌روزرسانی محیط شبیه‌سازی و پیاده‌سازی الگوریتم یادگیری  $Q$  به طور متوالی و یکپارچه اجرا شده است [۳۰]. در ابتدا مدل پایه طراحی با استفاده از معادلات عملکردی، شامل بیشینه وزن برخاست، وزن خالی، وزن سوخت و ابعاد هندسی تعریف شده است. (۲۳-۲۰) و سپس محاسبات اولیه انجام شده و در پیرو آن نیز سناریوهای مختلف نوشته و نهایتاً مراحل بعدی انجام شده است [۳۱]. همچنین قابل ذکر است، یادگیری مبتنی بر داده در سال‌های اخیر به‌عنوان یک ابزار مکمل برای بهینه‌سازی طراحی مهندسی مطرح شده است. در این راستا، چارچوب‌های یادگیری‌محور که فرایند طراحی را به‌صورت تصمیم‌گیری متوالی مدل می‌کنند، امکان جستجوی کارتر در فضای طراحی‌های پیچیده را فراهم ساخته‌اند و نشان داده‌اند که می‌توانند در کنار روش‌های کلاسیک  $MDO$  عملکرد رقابتی داشته باشند [۳۲]. در حوزه آیرودینامیک نیز استفاده از یادگیری تقویتی عمیق برای بهینه‌سازی شکل سازه‌ها و پروفیل‌های جریان مورد توجه قرار گرفته است. این مطالعات نشان داده‌اند که عامل یادگیرنده قادر است بدون نیاز به گرادینان صریح، بهبودهای معناداری در معیارهای عملکردی ایجاد کند و در مسائل غیرخطی و چندمنظوره کارآمد باشد [۳۳]. علاوه بر این، پژوهش‌های اخیر به طور مستقیم به به‌کارگیری یادگیری تقویتی در بهینه‌سازی چندرشته‌ای سامانه‌های هوافضایی پرداخته‌اند. این مطالعات نشان می‌دهند که  $RL$  می‌تواند به‌عنوان یک چارچوب تصمیم‌گیری تطبیقی، تعامل میان زیرسامانه‌های آیرودینامیکی، سازه‌ای و پیشرانی را مدیریت کرده و به همگرایی پایدار در مسائل طراحی پیچیده دست یابد [۳۴].

ورودی		
مشخصات	مقدار	واحد
مسافر	۱۵	نفر
خدمه	۳	نفر
بیشینه سرعت	۳۸۵	نات
سرعت کروز	۳۰۰	نات
برد پرواز	۱۱۰۶	ناتیکال مایل
حداکثر ارتفاع	۳۰۰۰۰	فوت
مسافت برخاست	۵۹۰۵	فوت
مسافت فرود	۴۵۹۳	فوت

جدول (۲). ورودی هواپیمای مورد طراحی

خروجی		
مشخصات	مقدار	واحد
بیشینه وزن برخاست	۱۹۶۸۰	پوند

وزن خالی	۱۲۰۰۰	پوند
نرخ صعود	۱۵۰۰	فوت بر دقیقه
مساحت بال	۳۲۰	فوت مربع
مساحت دم افقی	۴۱.۲۳	فوت مربع
مساحت دم عمودی	۳۲.۱۵	فوت مربع
نسبت برآ به پسا	۱۵	-

جدول (۳). خروجی‌های هواپیمای مورد طراحی

$$W_E = W_{gear} + W_{wing} + W_{ht} + W_{vt} + W_{engine} + W_{fuselage} \quad (20)$$

$$W_{Total} = W_{Empty} + W_{fuel} + W_{payload} + W_{crew} \quad (21)$$

$$W_{fuel} = W_T \left( 1 - e^{-\frac{SFC_{cruise} L}{V_{cruise} D}} \right) \quad (22)$$

$$\frac{L}{D} = \frac{C_L}{C_D} \quad (23)$$

قابل توجه می‌باشد، به‌منظور شفاف‌سازی روش‌شناسی، چارچوب یادگیری تقویتی به‌کاررفته در این پژوهش به‌صورت صریح تعریف شده است. فضای حالت بر اساس نسبت‌های بی‌بعد کلیدی طراحی هواپیما شامل کسر وزن خالی، کسر وزن سوخت، بارگذاری بال و نسبت تراست به وزن تعریف گردیده است. این متغیرها وضعیت پیکربندی هواپیما را در فرایند بهینه‌سازی توصیف می‌کنند و نمایانگر توزیع وزنی و ویژگی‌های آیرودینامیکی سامانه هستند. فضای عمل شامل تغییرات گسسته و کران‌دار در متغیرهای اصلی طراحی است. در هر گام تصمیم‌گیری، عامل یادگیرنده مجاز است مساحت بال، ضریب منظری یا نسبت تراست به وزن را در بازه‌های ازپیش‌تعیین‌شده اندکی افزایش یا کاهش دهد. این قیود اعمال‌شده، از بروز تغییرات غیرواقعی جلوگیری کرده و پایداری فرایند طراحی را تضمین می‌کند. ساختار پاداش به‌صورت چندهدفه تعریف شده است، به‌گونه‌ای که افزایش کارایی آیرودینامیکی و بهبود عملکرد مأموریتی تشویق شده و افزایش وزن‌های تخمین زده شده و مصرف سوخت مشمول جریمه می‌شود. معیار ارزیابی پاداش نسبت به طرح کلاسیک اولیه نرمال‌سازی شده است تا میزان بهبودها به‌صورت سازگار و قابل‌مقایسه سنجیده شود. آموزش عامل تحت یک سناریو مأموریتی ثابت شامل ارتفاع کروز، محدودیت‌های طول باند و... انجام شده است. فرایند آموزش طی ۲۰۰۰ اپیزود و با حداکثر ۴۰ گام طراحی در هر اپیزود صورت گرفته است. نرخ یادگیری برابر ۰.۱ و ضریب تنزیل ۰.۹ در نظر گرفته شده است. همچنین از سیاست اکتشاف *greedy* -  $\epsilon$  استفاده شده که در آن نرخ اکتشاف به‌صورت تدریجی از مقدار اولیه ۱.۰ به ۰.۰۵

کاهش یافته است. برای بررسی همگرایی، روند تغییرات پاداش تجمعی در طول آموزش پایش گردید و پایدار شدن آن پس از حدود ۱۵۰۰ اپیزود مشاهده شد که بیانگر دستیابی عامل به سیاست بهینه و ثبات یادگیری است.

محیط شبیه‌سازی در نرم‌افزار پایتون تولید شد و تمامی پارامترهای طراحی شامل آیرودینامیک، سازه، و کارایی در این محیط مدل‌سازی شده است. برای این منظور، متغیرهای اصلی طراحی شامل مساحت بال، نسبت منطری و توان پیشران تعریف شده است. محیط شبیه‌سازی به نحوی عمل کرد که امکان اجرای الگوریتم یادگیری  $Q$  و تعامل آن با مدل طراحی فراهم باشد. در این محیط، پنج پارامتر مهم در روند طراحی که در کتاب‌های مختلف طراحی هواپیما از آنها یاد شده و همچنین بازه و نقطه حدودی مطلوب آن نیز معین شده است، با توجه به نزدیکی و دوری به بازه و نقطه تعیین شده، به‌عنوان پاداش و جریمه (پاداش منفی) تعریف شده است «جدول ۴». به بیان کامل‌تر و همچنین ساده‌تر می‌توتن این‌گونه بیان نمود بر اساس بهینه‌سازی طراحی هواپیما در گرو کنترل و هدایت نسبت‌های کلیدی وزنی و هندسی است که به‌عنوان شاخص‌های اصلی در فرایند یادگیری تقویتی عمل می‌کنند. نسبت  $\frac{W_E}{W_{TO}}$  تعیین‌کننده سهم وزن خالی از کل وزن برخاست است. دستیابی به مقادیر مطلوب این نسبت منجر به کاهش وزن کلی و افزایش ظرفیت بار و سوخت می‌شود که در نهایت بیشینه وزن برخاست، مساحت بال، و سطوح کنترلی افقی و عمودی را بهینه و متعادل می‌سازد. نسبت  $\frac{W_F}{W_{TO}}$  به‌عنوان شاخصی از کارایی مأموریتی و مدیریت مصرف سوخت شناخته می‌شود؛ کاهش این نسبت در محدوده بهینه، با بهبود آیرودینامیک و کاهش پسا همراه بوده و موجب افزایش نسبت برآ به پسا، افزایش برد و کاهش هزینه‌های عملیاتی می‌گردد. نسبت‌های بارگذاری بال  $\frac{W_{TO}}{S}$  تعیین‌کننده رابطه میان وزن هواپیما و مساحت بال هستند. تنظیم صحیح این نسبت‌ها، سرعت واماندگی و ویژگی‌های برخاست و فرود را بهبود داده و از طریق کاهش بارگذاری، امکان استفاده از بال کوچک‌تر و سبک‌تر را فراهم می‌کند. این موضوع به طور مستقیم بر کاهش وزن کلی، کاهش مصرف سوخت، و بهینه‌سازی سطوح کنترلی نظیر دم افقی و دم عمودی اثرگذار است. نسبت  $\frac{T}{W_{TO}}$  شاخص اصلی توانایی پیشران در غلبه بر وزن است «جدول ۵». بهینه‌سازی این نسبت، نرخ اوج‌گیری و سقف پروازی را افزایش داده و عملکرد هواپیما را در شرایط بحرانی همچون برخاست، صعود تک‌موتوره و سرعت کروز تضمین می‌نماید. علاوه بر این، ترکیب متعادل این نسبت با بارگذاری بال منجر به دستیابی به سرعت کروز اقتصادی و افزایش بهره‌وری در مصرف سوخت می‌شود. به‌طورکلی، هنگامی که نسبت‌های بیان شده از طریق الگوریتم‌های یادگیری تقویتی به مقادیر بهینه هدایت شوند، تمامی پارامترهای کلیدی طراحی شامل بیشینه وزن برخاست، وزن خالی، مساحت بال، ابعاد دم افقی و عمودی، مصرف سوخت، نسبت برآ به پسا، نرخ اوج‌گیری و سرعت کروز به‌صورت هم‌زمان در نقطه تعادل عملکردی قرار می‌گیرند. این هم‌راستایی نشان می‌دهد که یادگیری تقویتی نه‌تنها قادر به کاهش وزن و سوخت است، بلکه با بهینه‌سازی پارامترهای هندسی و آیرودینامیکی، بستری برای افزایش بازده کلی سامانه پروازی فراهم می‌آورد

«جدول ۶». در حقیقت شبیه‌سازی یک‌روند میان محاسباتی ای است که با توجه به روابط خاص (۲۵،۲۴) مبنی بر تعریف نسبت‌ها برای پاداش‌های مثبت و منفی، می‌توان با آن یک مرجع اولیه مطمئن را تعریف کرد «جدول ۷».

شماره	نسبت	تعریف	بازه	مطلوب	پاداش/جریمه
۱	$\frac{W_E}{W_{TO}}$	نسبت وزن خالی به وزن برخاست	۰.۶-۰.۵	۰.۵۵	$\langle x \in [0.53 - 0.58] = +20 \rangle$ $\langle [0.65 < x < 0.50] = -20 \rangle$
۲	$\frac{W_F}{W_{TO}}$	نسبت وزن سوخت به وزن برخاست	-۰.۱۵ ۰.۲۵	۰.۲۰	$x \in [0.17 - 0.22] = +20$ $\langle [0.30 < x < 0.12] = -20 \rangle$
۳	$\frac{W_{TO}}{S}$	بارگذاری بال بر حسب وزن به سطح	-۳۵۰ ۵۰۰	۴۰۰	$\langle x \in [380 - 425] = +20 \rangle$ $\langle [500 < x < 300] = -20 \rangle$
۴	$\frac{T}{W_{TO}}$	نسبت تراست به وزن برخاست	-۰.۲۵ ۰.۴۰	۰.۳۰	$\langle x \in [0.28 - 0.034] = +20 \rangle$ $\langle [0.40 < x < 0.25] = -20 \rangle$ (Jet) $\langle x \in [0.23 - 0.027] = +20 \rangle$ $\langle [0.0.30 < x < 0.20] = -20 \rangle$

جدول (۴). پاداش و جریمه برای نسبت‌های کلیدی طراحی هواپیما

نسبت کلیدی	اثرات مستقیم	اثرات غیرمستقیم بر بهینه‌سازی پارامترهای طراحی
$\frac{W_E}{W_{TO}}$	کاهش وزن سازه‌ای و افزایش ظرفیت بار و سوخت	کاهش مساحت بال و سطوح کنترلی (دم افقی و عمودی)، کاهش مصرف سوخت، افزایش برد
$\frac{W_F}{W_{TO}}$	شاخص بهره‌وری مأموریتی و مدیریت سوخت	افزایش نسبت برآ به پسا، کاهش هزینه عملیاتی، افزایش مداومت و برد
$\frac{W_{TO}}{S}$	تعیین‌کننده سرعت واماندگی و عملکرد برخاست/فرود	بهبود ایمنی عملیاتی، کاهش مساحت بال موردنیاز، کاهش وزن کلی هواپیما
$\frac{T}{W_{TO}}$	افزایش نرخ اوج‌گیری و سقف پروازی	بهبود عملکرد برخاست، صعود تک‌موتوره، تضمین سرعت کروز و کاهش مصرف سوخت

جدول (۵). تاثیرات نسبت‌های کلیدی طراحی بر پارامترهای طراحی

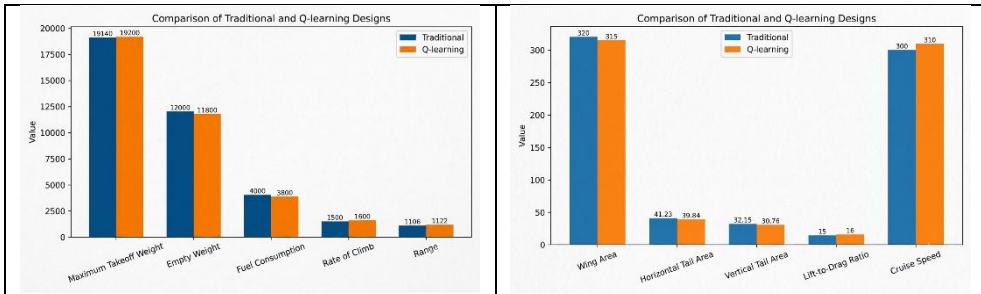
$$r = \sum_1^n k_n \frac{0.1}{e_n + \varepsilon} \quad (24)$$

$$e = |x_n - x_{ave}| \quad (25)$$

واحد	مقادیر شبیه‌سازی شده	مقادیر طراحی سنتی	پارامتر	
پوند	۱۹۲۰۰	۱۹۱۴۰	بیشینه وزن برخاست	۱
پوند	۱۱۸۰۰	۱۲۰۰۰	وزن خالی	۲
فوت مربع	۳۱۵	۳۲۰	مساحت بال	۳
فوت مربع	۳۹.۸۴	۴۱.۲۳	مساحت دم افقی	۴
فوت مربع	۳۰.۷۶	۳۲.۱۵	مساحت دم عمودی	۵
پوند	۳۹۰۰	۴۰۰۰	مصرف سوخت	۶
-	۱۶	۱۵	نسبت برآ به پسا	۷
فوت بر دقیقه	۱۶۰۰	۱۵۰۰	نرخ صعود	۸
نات	۳۱۰	۳۰۰	سرعت کروز	۹
ناتیکال مایل	۱۱۷۲	۱۱۰۶	برد پرواز	۱۰

جدول (۶). مقایسه بین طراحی سنتی و شبیه‌سازی شده

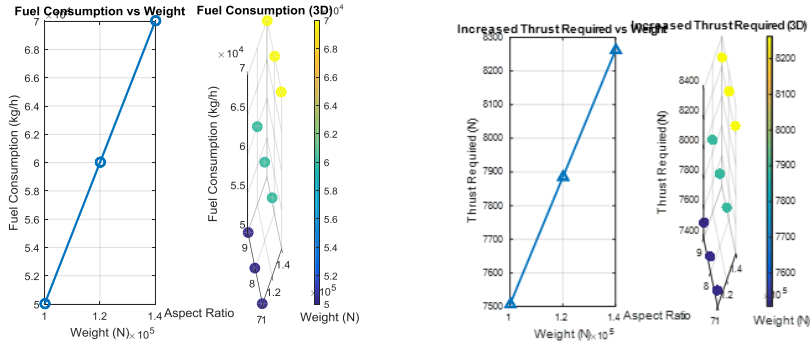
همچنین نقاط قوت و ضعف طراحی سنتی را شناسایی نموده و در نهایت ورودی برای الگوریتم بهینه ساز هم مشخص تر شده است. یعنی داده‌های حاصل از شبیه‌سازی به‌عنوان ورودی برای فرایند بهینه‌سازی استفاده شده است. این داده‌ها به تنظیم دقیق پارامترهای طراحی کمک می‌کنند. نمودارهای شبیه‌سازی نتایج اولیه فرایند طراحی را قبل از اعمال روش‌های بهینه‌سازی جهت آموزش به سیستم یادگیرنده را نشان می‌دهند. «شکل ۳». این نمودارها رفتار متغیرهای کلیدی مانند مصرف سوخت، سرعت برخاست و عملکرد را بر اساس وزن هواپیما و نسبت منظری بال تحلیل می‌کنند.



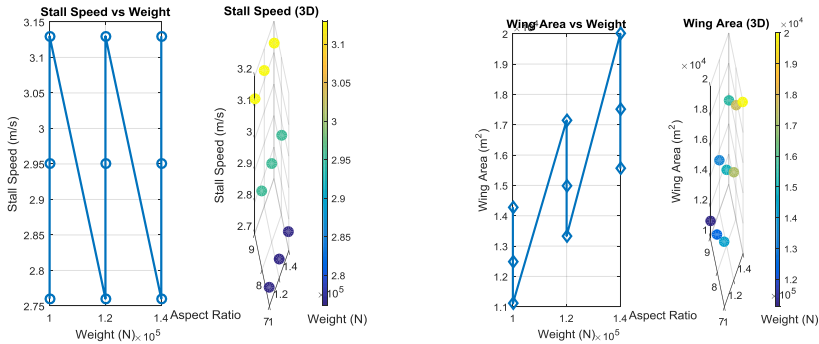
شکل ۳: مقایسه بین مقادیر طراحی سنتی و شبیه‌سازی شده

نمودارها نشان‌دهنده تغییرات مصرف سوخت بر اساس وزن هواپیما هستند. همان‌طور که انتظار می‌رود، با افزایش وزن هواپیما، مصرف سوخت افزایش می‌یابد. این رابطه به طور غیرخطی و با تأثیر نسبت ابعاد بال بر راندمان آیرودینامیکی تغییر می‌کند «شکل ۴». سرعت برخاست هواپیما به‌عنوان تابعی از وزن و نسبت منظری بال بررسی شده است. این بار مشخص شد که افزایش وزن باعث کاهش سرعت برخاست می‌شود. اما افزایش نسبت منظری بال تأثیر مثبتی در کاهش این افت سرعت دارد «شکل ۵». تغییرات سرعت واماندگی نیز بر اساس وزن نشان داده شده است. همان‌طور که مشاهده می‌شود، افزایش وزن باعث افزایش سرعت واماندگی می‌شود. این یافته نشان‌دهنده اهمیت بهینه‌سازی وزن برای دستیابی به عملکرد بهتر در سرعت‌های پایین است «شکل ۶». راندمان موتور بر اساس وزن و نسبت منظری بال بررسی شده است. این نمودار نشان می‌دهد که راندمان موتور با افزایش وزن کاهش می‌یابد. اما این کاهش با نسبت بالای نسبت منظری بال و مساحت آن قابل‌تعدیل است «شکل ۷». برد هواپیما به طور مستقیم به وزن و نسبت ابعاد بال بستگی دارد. بهینه‌سازی این دو پارامتر می‌تواند منجر به بهبود عملکرد کلی هواپیما شود. از این رو، در فرایند طراحی هواپیما، توجه به این دو عامل به‌ویژه برای دستیابی به برد بهینه ضروری است «شکل ۸».

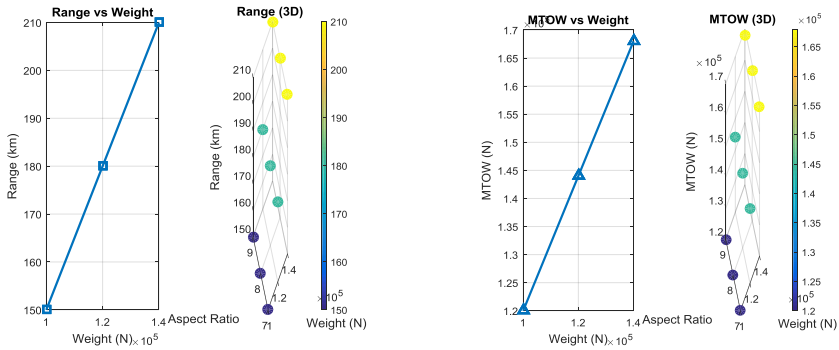
تغییرات بیشینه وزن برخاست نسبت به سایر پارامترها نیز تحلیل شده است. افزایش وزن برخاست منجر به تأثیر مستقیم بر مصرف سوخت و تراست موردنیاز می‌شود «شکل ۹». بار مفید و قابل حمل نیز به طور مستقیم با وزن و نسبت منظری بال مرتبط است. از آنجایی که افزایش وزن هواپیما موجب افزایش بار مفید خواهد شد، مدیریت بهینه این پارامترها در فرایند طراحی اهمیت ویژه‌ای دارد. علاوه بر این بهینه‌سازی نسبت منظری بال می‌تواند به بهبود ظرفیت بار مفید کمک کند. نتایج نشان می‌دهند که برای بهینه‌سازی عملکرد باید ترکیب مناسبی از وزن و نسبت منظری بال انتخاب شود تا به حداکثر ظرفیت بار مفید دست‌یافته شد «شکل ۱۰».



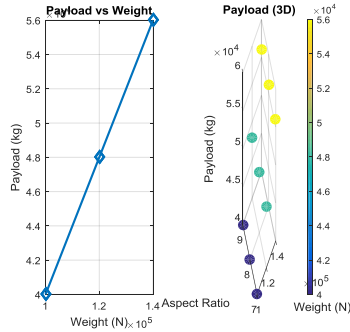
شکل ۴: تغییرات مصرف سوخت بر اساس وزن هواپیما و نسبت منطری بال شکل ۵: سرعت برخاست تابعی از وزن و نسبت منطری بال



شکل ۶: تغییرات سرعت واماندگی بر اساس وزن راندمان موتور بر اساس وزن



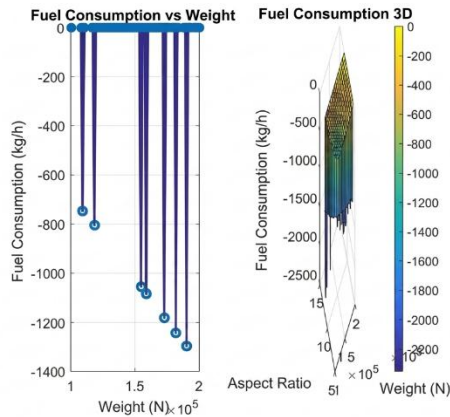
شکل ۸: تراست موردنیاز بر اساس برد پروازی شکل ۹: تغییرات بیشینه وزن برخاست نسبت به سایر پارامترها



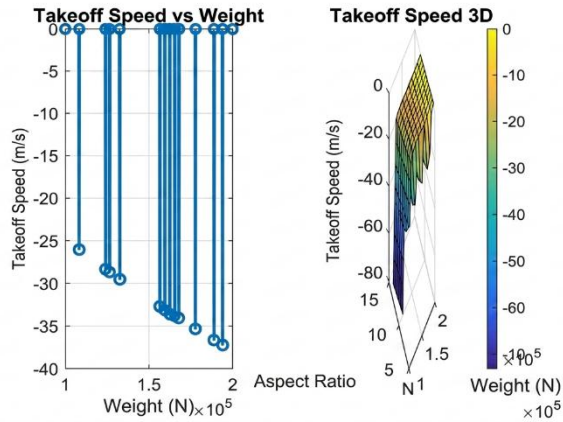
شکل ۱۰: ارتباط بار مفید و قابل حمل با وزن و نسبت منظری بال

در ادامه پس از شبیه‌سازی فرایند طراحی هواپیما و آموزش به سیستم الگوریتم یادگیری Q برای طراحی پارامترهای اساسی و موردنظر این پژوهش استفاده شده است. این الگوریتم بهینه‌ساز خودکار به عامل اجازه می‌دهد تا از طریق تعامل با محیط، استراتژی بهترین را برای طراحی تاکسی هوایی بیاموزد. در این فرایند، پاداش‌ها بر اساس معیارهایی نظیر کاهش وزن، بهبود نسبت برآ به پسا  $\left(\frac{L}{D}\right)$  و کاهش مصرف سوخت تعیین شده است. در گام بعد مقادیر بهینه متغیرهای طراحی با استفاده از الگوریتم یادگیری Q و روش‌های همگرایی میان دیسیپلین‌ها تعیین شده است. شرط همگرایی تضمین کرد که خروجی هر دیسیپلین با سایر بخش‌ها سازگار بوده و طراحی نهایی یکپارچه باشد. این فرایند تا زمانی ادامه یافت که شرایط توقف، مانند حداقل تغییرات در مقادیر تابع هدف یا بهبود ناچیز در پاداش تجمعی، محقق شود. در این راستا برای هر دیسیپلین مقدار پاداش یا جریمه (پاداش منفی) به طور خاص محاسبه شده است. این مقادیر به‌عنوان بخشی از تابع پاداش وارد مدل شده و به الگوریتم کمک کرده‌اند تا بهترین ترکیب از پارامترهای طراحی را برای بهبود عملکرد کلی هواپیما بیاموزد. (جدول ۷) در ادامه روند بهینه‌سازی با استفاده از یادگیری Q به نمودارهای دیگری دست‌یافته شد که به شرح بیان شده است. بر مصرف سوخت بهینه بر اساس وزن و نسبت منظری بال پس از بهینه‌سازی نشان داده شده است. یافته‌ها کاهش چشمگیر مصرف سوخت را نسبت به مرحله شبیه‌سازی اولیه تأیید می‌کنند «شکل ۱۱». در ادامه نیز سرعت برخاست بهینه پس از اعمال الگوریتم یادگیری Q بررسی شده است. بهینه‌سازی باعث کاهش سرعت برخاست و دستیابی به مقادیر بهینه‌تر شده است «شکل ۱۲». سرعت واماندگی بهینه‌شده نیز به‌وضوح نشان می‌دهد که بهینه‌سازی باعث کاهش سرعت استال در مقایسه با مقادیر شبیه‌سازی شده است «شکل ۱۳». همچنین عملکرد موتور پس از بهینه‌سازی بررسی شده و بهبود قابل‌توجهی در راندمان مشاهده می‌شود که ناشی از نسبت منظری بال بهینه است «شکل ۱۴». تغییرات تراست موردنیاز هم پس از بهینه‌سازی نشان می‌دهد که استفاده از روش‌های بهینه‌سازی، نیاز به تراست را به حداقل ممکن کاهش داده است. «شکل ۱۵» نمودار بیشینه وزن برخاست بهینه‌شده نشان می‌دهد که استفاده از روش Q-Learning به کاهش وزن هواپیما و بهبود عملکرد کلی منجر شده است «شکل ۱۶». مساحت بال بهینه‌شده نیز به‌وضوح نشان می‌دهد که

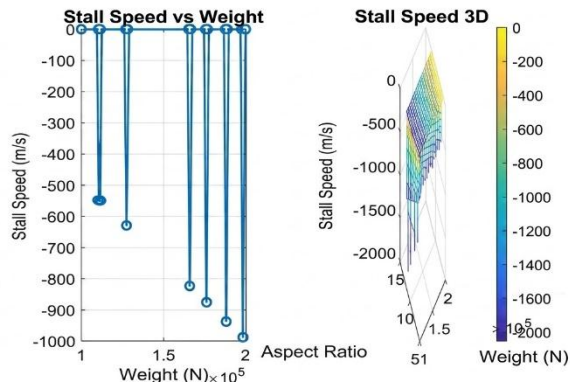
بهینه‌سازی سطح بال در دستیابی به عملکرد بهتر نقش کلیدی دارد «شکل ۱۷». در ادامه روند طراحی در مرحله ساختاری، دم‌ها نیز بهینه شدند. نمودارها مربوط به دم افقی، تغییرات مساحت این بخش را نسبت به پارامترهای وزن و نسبت منظری نشان می‌دهد. کاهش مساحت دم افقی نشان‌دهنده بهینه‌سازی موفق در کاهش وزن ساختاری این بخش است. این تغییرات، به کاهش کلی وزن هواپیما و بهبود توزیع بار کمک کرده و در نهایت عملکرد آیرودینامیکی و پایداری پروازی را ارتقا داده است. به‌ویژه، نتایج نشان می‌دهد که تنظیم دقیق پارامترهای طراحی دم افقی باعث دستیابی به حداکثر بهره‌وری در شرایط مختلف پروازی شده است «شکل ۱۸». نمودارهای مرتبط با دم عمودی، تأثیر بهینه‌سازی بر کاهش مساحت این بخش سازه‌ای را نمایش می‌دهد. این کاهش مساحت، ضمن حفظ پایداری جانبی و کنترل‌پذیری، به کاهش نیروهای مقاوم و بهبود بهره‌وری سوخت کمک کرده است. نتایج نشان می‌دهد که بهینه‌سازی دم عمودی به طور مستقیم به کاهش نیروی پیشران موردنیاز و افزایش عملکرد دینامیکی کلی هواپیما منجر شده است. این دستاوردها، تأثیر مهمی در کاهش هزینه‌های عملیاتی و افزایش قابلیت پروازهای بلندمدت داشته‌اند «شکل ۱۹». یکی از نکات مهم در این پژوهش برد پروازی است. این پارامتر پس از بهینه‌سازی بررسی شده است. یافته‌ها حاکی از افزایش برد با کاهش مصرف سوخت و بهبود راندمان هستند «شکل ۲۰».




شکل ۱۱: مصرف سوخت بهینه بر اساس وزن و نسبت منظری بال پس از بهینه‌سازی



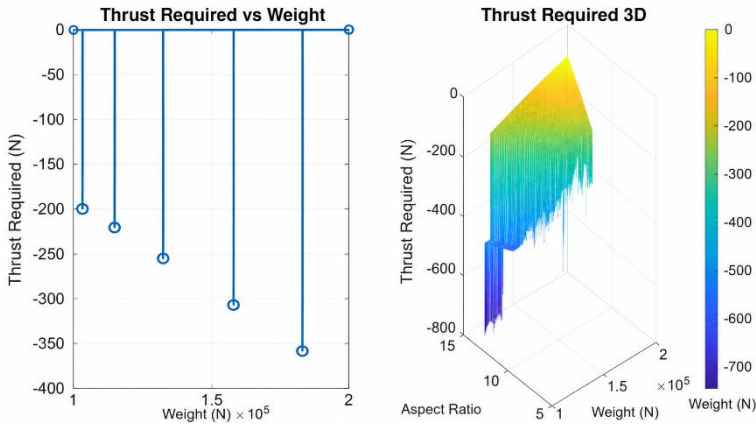
شکل ۱۲: سرعت برخاست بهینه پس از اعمال الگوریتم یادگیری Q



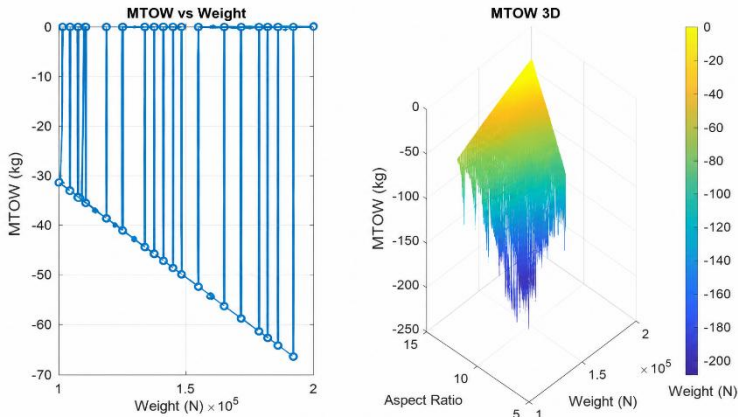
شکل ۱۳: سرعت واماندگی بهینه شده



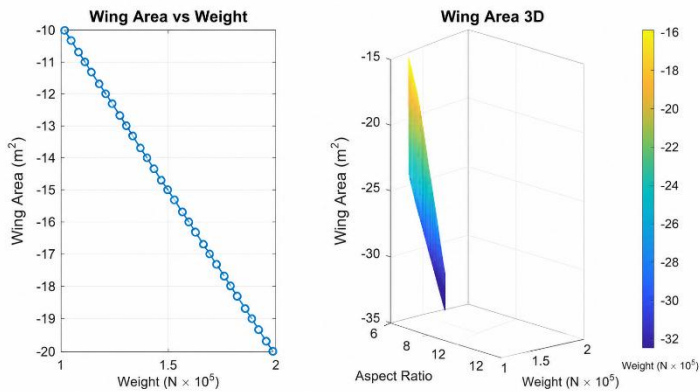
شکل ۱۴: عملکرد موتور پس از بهینه‌سازی



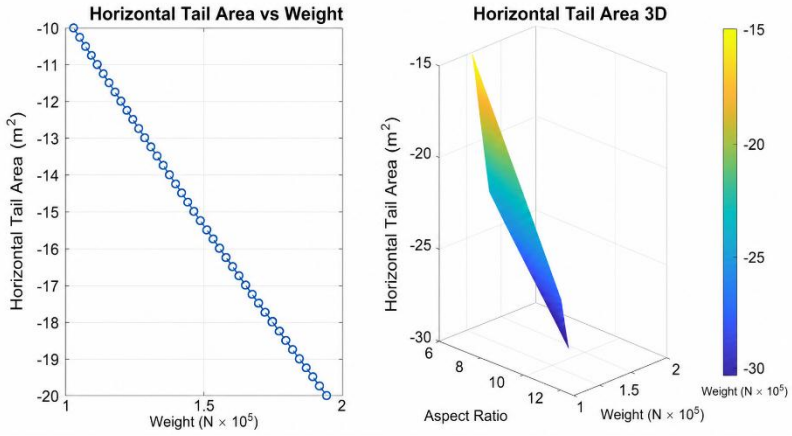
شکل ۱۵: تغییرات تراست موردنیاز بعد از بهینه سازی



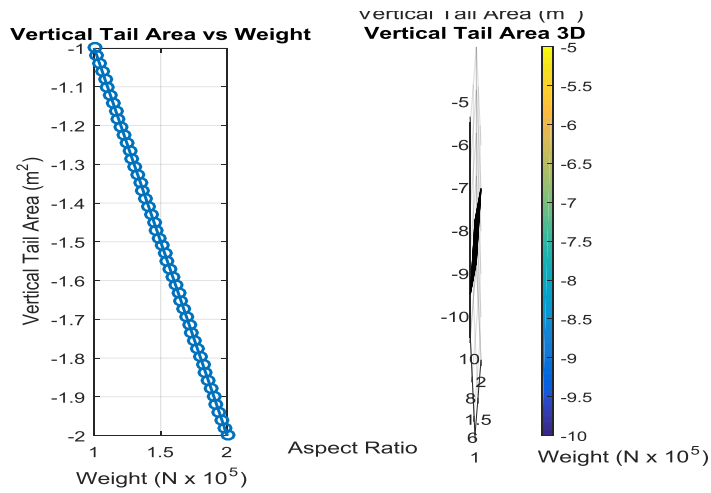
شکل ۱۶: بیشینه وزن برخاست بعد از بهینه سازی



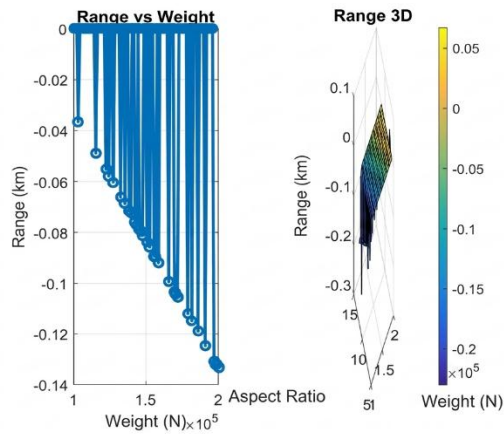
شکل ۱۷: مساحت بال بعد از بهینه سازی




شکل ۱۸: مساحت دم افقی بعد از بهینه سازی



شکل ۱۹: مساحت دم عمودی بعد از بهینه سازی



شکل ۲۰: برد پروازی بعد از بهینه سازی

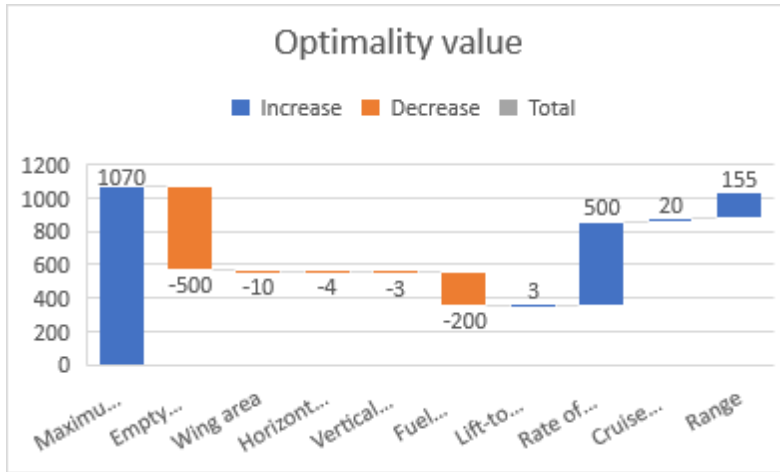


شکل ۲۱: مقایسه طراحی سنتی و عملکرد یادگیری (Q) در طراحی هواپیما

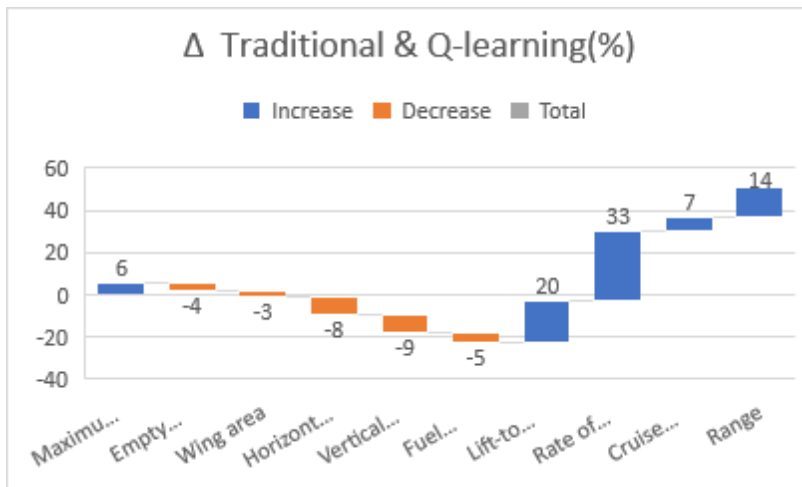
در نهایت در این پژوهش، کاربرد الگوریتم یادگیری Q یک طراح خودکار در روند طراحی توانست به‌عنوان یک بهینه ساز دست به طراحی بهینه بزند، بررسی شد و نتایج نشان داده است، این روش می‌تواند در حل مسائل پیچیده مهندسی، بسیار مؤثر باشد. (جدول ۹) مقایسه اعداد استخراج شده از محیط پایتون به‌عنوان فضای عمل الگوریتم یادگیری تقویتی (Q) با محاسبات عادی نشان از مطلوبیت روند کار داشته است «شکل ۲۱» و همچنین کاملاً مشهود بود که این رویه می‌تواند با دانش امروزی درصد بهینگی را تا حد مطلوبی که در اختیار بشر قرار دارد، تغییر دهد «شکل ۲۲-۲۳».

ردیف	پارامترها	محاسبه سنتی	محاسبه شبیه‌سازی شده	محاسبه بهینه شده	مقدار بهینه شده	درصد تغییرات سنتی و بهینه شده (%)	واحد
۱	بیشینه وزن برخاست	۱۹۱۴۰	۱۹۲۰۰	۲۰۲۱۰	۱۰۷۰	۵.۵۹	پوند
۲	وزن خالی	۱۲۰۰۰	۱۱۸۰۰	۱۱۵۰۰	-۵۰۰	-۴.۱۷	پوند
۳	مساحت بال	۳۲۰	۳۱۵	۳۱۰	-۱۰	-۳.۱۲۵	فوت مربع
۴	مساحت دم افقی	۴۱.۲۳	۳۹.۸۴	۳۷.۹۲	-۳.۳۱	-۸.۳	فوت مربع
۵	مساحت دم عمودی	۳۲.۱۵	۳۰.۷۶	۲۹.۴۸	-۲.۶۷	-۸.۷	فوت مربع
۶	مصرف سوخت	۴۰۰۰	۳۹۰۰	۳۸۰۰	-۲۰۰	-۵	کیلوگرم/ساعت
۷	نسبت برآ به پسا	۱۵	۱۶	۱۸	۳	۲۰	-
۸	نرخ اوج‌گیری	۱۵۰۰	۲۰۰۰	۲۰۰۰	۵۰۰	۳۳.۳۳	فوت/دقیقه
۹	سرعت کروز	۳۰۰	۳۲۰	۳۲۰	۲۰	۶.۶۶	نات
۱۰	برد پرواز	۱۱۰۶	۱۱۷۲.۶	۱۲۶۰.۸۴	۱۵۴.۸۴	۱۴	ناتیکال مایل

جدول (۷). نتایج حاصل از طراحی بهینه با الگوریتم یادگیری Q




شکل ۲۲: نمودار مقدار بهینگی پارامترها

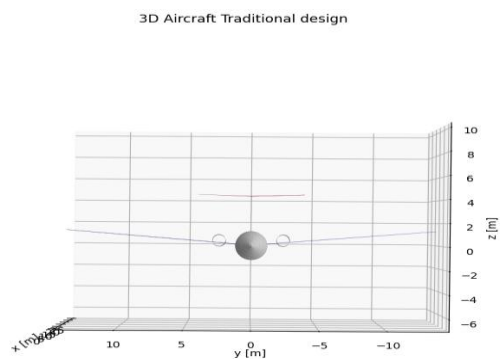


شکل ۲۳: نمودار نتایج حاصل از بهینه سازی به درصد (%)


بنابراین طراحی در محیط پایتون به یک سری از طرح‌ها و پلات‌ها دست‌یافته شده است که در دو گروه طراحی سنتی «شکل ۲۴-۲۷» و همچنین طراحی خودکار به وسیله الگوریتم یادگیری (Q) «شکل ۲۸-۳۱» به نمایش درآمده است. این پلات‌ها نیز به نوبه خود نشان‌دهنده بهینه شدن پارامترهای مورد نظر طراحی در این پژوهش هستند.



شکل ۲۴: نمای بالای هواپیمای طراحی شده با شیوه سنتی




شکل ۲۵: نمای روبروی هواپیمای طراحی شده با شیوه سنتی




شکل ۲۶: نمای جانبی هواپیمای طراحی شده با شیوه سنتی

3D Aircraft Traditional design




شکل ۲۷: نمای سه بعدی هواپیمای طراحی شده با روش سنتی

3D Aircraft Q-Learning Design




شکل ۲۸: نمای بالای هواپیمای طراحی شده با الگوریتم (QL)

3D Aircraft Q-Learning Design




شکل ۲۹: نمای روبروی هواپیمای طراحی شده با الگوریتم (QL)

3D Aircraft Q-Learning Design



شکل ۳۰: نمای جانبی هواپیمای طراحی بهینه شده با الگوریتم (QL)

3D Aircraft Q-Learning Design



شکل ۳۱: نمای سه بعدی هواپیمای طراحی بهینه شده با الگوریتم (QL)

## ۵- نتیجه

این پژوهش با هدف ارتقای طراحی مفهومی یک تاکسی هوایی جت ۱۸ نفره (۱۵ مسافر، ۲ خلبان و ۱ مهماندار) انجام شد و چارچوبی ارائه داد که در آن روش‌های کلاسیک طراحی با الگوریتم Q-learning در یک محیط شبیه‌سازی عددی ادغام شده‌اند. در این ساختار، پیکربندی اولیه هواپیما بر پایه روابط و قیود طراحی سنتی شکل گرفت و سپس از طریق فرایند یادگیری تعاملی، پارامترهای کلیدی طراحی به صورت تطبیقی اصلاح شدند. نتایج ارائه شده در جدول ۹ نشان می‌دهد که به‌کارگیری Q-learning در مرحله طراحی اولیه توانسته است با تنظیم هم‌زمان پارامترهای اصلی بال و سطوح کنترلی، شاخص‌های عملکردی را بهبود دهد. کاهش مصرف سوخت، ارتقای کارایی آیرودینامیکی و بهینه‌سازی وزن عملیاتی از جمله دستاوردهای این فرایند بوده‌اند. این

بهبودها در چارچوب طراحی مفهومی و بدون اتکا به تحلیل‌های مرتبه بالا حاصل شده‌اند که بیانگر کارآمدی رویکرد پیشنهادی در سطح اولیه طراحی است. ادغام منطق تصمیم‌گیری تطبیقی Q-learning با ساختار محاسباتی طراحی کلاسیک، محدودیت‌های رویکردهای ترتیبی و مبتنی بر تنظیم دستی را کاهش داده است. در این چارچوب، فرایند طراحی از یک مسیر خطی وابسته به تجربه به یک فرایند خودآموز مبتنی بر تعامل با مدل عملکردی تبدیل شده است. این تحول امکان کاوش هدفمند فضای طراحی، کاهش وابستگی به حدس‌های اولیه و افزایش انسجام در تصمیم‌گیری پارامتری را فراهم می‌کند. رویکرد پیشنهادی نشان می‌دهد که استفاده از Q-learning در طراحی مفهومی هواپیماهای ۶ تا ۴۰ نفره با کاربرد تاکسی هوایی، می‌تواند فرایند بهبود تدریجی پارامترهای طراحی را تسریع کرده و عدم قطعیت در انتخاب مقادیر اولیه را کاهش دهد. بدون آنکه نیاز به چارچوب‌های پیچیده بهینه‌سازی رسمی باشد. این ویژگی، سامانه ارائه‌شده را به گامی عملی در مسیر توسعه فرایندهای طراحی خودکار در صنعت هوانوردی تبدیل می‌کند. در مجموع، نتایج این پژوهش بیانگر آن است که ترکیب طراحی کلاسیک با الگوریتم Q-learning می‌تواند چرخه طراحی را کوتاه‌تر کرده، سازگاری طرح با قیود عملکردی را افزایش دهد و مسیر دستیابی به پیکربندی‌های کارآمدتر را در مرحله مفهومی هموار سازد. این چارچوب می‌تواند مبنایی برای توسعه سامانه‌های طراحی خودآموز نسل آینده در هواپیماهای سبک و منطقه‌ای و همچنین هواپیماهای سنگین‌تر با بردهای بالاتر باشد. شایان‌ذکر است که چارچوب پیشنهادی در این پژوهش در سطح طراحی مفهومی و اولیه تعریف است و تعمیم آن به مراحل طراحی تفصیلی و تحلیل‌های بادقت بالا مستلزم توسعه مدل‌های پیشرفته‌تر و اعتبارسنجی‌های تکمیلی خواهد بود.

## ۶- منابع

- [1] Roskam, J., *Airplane Design*, DARcorporation, 1985.
- [2] Raymer, D. P., *Aircraft Design: A Conceptual Approach*, AIAA Education Series, 2012.
- [3] Sadraey, M. H., *Aircraft Design: A Systems Engineering Approach*, Wiley, 2012.
- [4] Sadraey, M. H., *Flight Mechanics: Theory and Applications*, Wiley, 2013.

- [5] S. A. Iman Shafiei Nejad. (2025). Optimal Design of an Air Taxi Using Metaheuristic Algorithms and Fuzzy Logic. *Aerospace Defense*. Vol4(Issue1), Page 49–81.
- [6] Jamshidi, F., *Air Taxi in Iran and the World*, Tandis Publications, 2019.
- [7] Shafieenejad Iman, Adavi Hayatollah. V-Model Systematic Design of Fixed-Wing Air Taxis Regarding Aerodynamic Performance Improvement. *Journal of Aerospace Defense*, Vol4(Issue3), Page 24-47
- [8] Hosseini, S., Vaziri-Zanjani, M. A., and Ovesy, H. R., “Conceptual design and analysis of an affordable truss-braced wing regional jet aircraft,” *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 2020, doi:10.1177/0954410020923060.
- [9] Hosseini, S., Vaziri-Zanjani, M. A., and Ovesy, H. R., “Multi-Objective Multidisciplinary Design Optimization of Regional Truss-Braced Wing Jet Aircraft,” *Aerospace Europe Conference 2023 (EUCASS/CEAS)*, 2023.
- [10] Roshaniyan, J., Batalbloo, A. A., Ebrahimi, B., and Faghardani, M. H., “Development of Design Optimization Software for a General Aviation Aircraft with a Multidisciplinary Approach.”
- [11] Trifari, V., “Development of a Multi-Disciplinary Analysis and Optimization Framework and Applications for Innovative Efficient Regional Aircraft,” Ph.D. Dissertation, University of Naples Federico II, Department of Aerospace Engineering, 2020.
- [12] Zhao, B., Huo, M., Yu, Z., Qi, N., and Wang, J., “Model-reference reinforcement learning for safe aerial recovery of unmanned aerial vehicles,” *Aerospace*, Vol. 10, No. 1, Article 34, 2023, doi:10.3390/aerospace10010034.
- [13] Guo, J., Zhou, G., Huang, H., and Huang, C., “Advancements in UAV Path Planning: A Deep Reinforcement Learning Approach with Soft Actor-Critic for Enhanced Navigation,” *Unmanned Systems*, 2024, doi:10.1142/S2301385025500669.
- [14] Qiu, X., Gao, C., Wang, K., and Jing, W., “Attitude control of a moving mass-actuated UAV based on deep reinforcement learning,” *Journal of Aerospace Engineering*, Vol. 35, No. 3, Article 04022006, 2022, doi:10.1061/JAEGER.1943-5525.0000389.
- [15] Karaoğlu, U., Mbah, O., and Zeeshan, Q., “Applications of machine learning in aircraft maintenance,” *Journal of Engineering Management Systems Engineering*, Vol. 7, No. 2, pp. 145–162, 2023, doi:10.47852/ems.2023.00042.

- [16] Zahmatkesh, M., Emami, S. A., Banazadeh, A., and Castaldi, P., “Robust attitude control of an agile aircraft using improved Q-learning,” *Actuators*, Vol. 11, No. 2, Article 57, 2022.
- [17] Hommels, T. C., “Control of a wing flap using 3D printed flow sensors and reinforcement learning,” Master’s thesis, University of Twente, 2022.
- [18] Li, J., Xu, S., Wu, Y., and Zhang, Z., “Automatic landing control for fixed-wing UAV in longitudinal channel based on deep reinforcement learning,” *Drones*, Vol. 8, No. 1, Article 45, 2024, doi:10.3390/drones8010045.
- [19] Walker, J. R., and Claudio, D., “Machine learning opportunities in flight test: Preflight checks,” *SN Computer Science*, Vol. 5, No. 1, Article 15, 2024, doi:10.1007/s42979-023-01567-0.
- [20] Giahi, R., MacKenzie, C. A., and Bijari, R., “Dynamic Decision Making in Engineering System Design: A Deep Q-Learning Approach,” *arXiv preprint*, arXiv:2312.17284, 2023.
- [21] Wankerl, H., Stern, M. L., Mahdavi, A., Eichler, C., and Lang, E. W., “Parameterized Reinforcement Learning for Optical System Optimization,” *arXiv preprint*, arXiv:2010.05769, 2020.
- [22] Vulpio, I., Burghignoli, L., Palma, G., Iemma, U., and Serani, A., “An Evolutionary Variant of Q-Learning Applied to Derivative-Free Optimization,” *Multidisciplinary Design Optimization*, AIAA, 2023.
- [23] Gray, J. S., Hwang, J. T., Martins, J. R. R. A., Moore, K. T., and Naylor, B. A., “OpenMDAO: An Open-Source Framework for Multidisciplinary Design, Analysis, and Optimization,” *Structural and Multidisciplinary Optimization*, Vol. 59, No. 4, pp. 1075–1104, 2019, doi:10.1007/s00158-019-02211-z.
- [24] Martins, J. R. R. A., and Ning, A., *Engineering Design Optimization*, Cambridge University Press, 2022, doi:10.1017/9781108980647.
- [25] de Weck, O., and Willcox, K., *Multidisciplinary System Design Optimization*, MIT OpenCourseWare, 2010.
- [26] Sutton, R. S., and Barto, A. G., *Reinforcement Learning: An Introduction*, 2nd ed., MIT Press, 2018.
- [27] Pérez-Hernández, F., and García-García, J., “Q-Learning Algorithms: A Comprehensive Classification and Applications,” *IEEE Latin America Transactions*, Vol. 16, No. 4, pp. 1209–1217, 2018, doi:10.1109/TLA.2018.8362172.

- [28] Li, S., Snaiki, R., and Wu, T., “A knowledge-enhanced deep reinforcement learning-based shape optimizer for aerodynamic mitigation of wind-sensitive structures,” *Computer-Aided Civil and Infrastructure Engineering*, Vol. 36, No. 10, pp. 1152–1169, 2021, doi:10.1111/mice.1265527.
- [29] Nguyen, T. D., Kasmarik, K. E., and Abbass, H. A., “Q-Learning with Differential Entropy of Q-Tables,” *arXiv preprint*, arXiv:2006.14795, 2020.
- [30] Jiang, Y., Tran, T. H., and Williams, L., “Machine learning and mixed reality for smart aviation: Applications and challenges,” *Journal of Air Transport Management*, Vol. 111, 102437, 2023, doi:10.1016/j.jairtraman.2023.102437.
- [31] De Marco, A., D’Onza, P. M., and Manfredi, S., “A deep reinforcement learning control approach for high-performance aircraft,” *Nonlinear Dynamics*, Vol. 111, pp. 17037–17077, 2023, d
- [32] Lam, R., Willcox, K., and Wolpert, D., “Learning-Based Optimization for Engineering Design,” *AIAA Journal*, Vol. 61, No. 3, 2023, pp. 987–1003, doi:10.2514/1.J061234.
- [33] Yonekura, K., and Hattori, H., “Framework for aerodynamic shape optimization using deep reinforcement learning,” *Structural and Multidisciplinary Optimization*, Vol. 64, 2021, pp. 1909–1923, doi:10.1007/s00158-021-02933-0.
- [34] Li, X., Zhang, Y., and Martins, J. R. R. A., “Reinforcement Learning for Multidisciplinary Design Optimization of Aerospace Systems,” *Aerospace Science and Technology*, Vol. 135, 2023, 108223, doi:10.1016/j.ast.2023.108223.