

تعیین وضعیت یک ماهواره زمین‌آهنگ مجهز به حسگرهای خورشید و زمین با استفاده از الگوریتم‌های هوش مصنوعی

فرید حاجی ویسه^۱، حسین نجات پیشکناری^{۲*}، طالب عبدالهی^۳

۱- دانشجوی کارشناسی، دانشکده مهندسی مکانیک، دانشگاه صنعتی شریف

۲- استاد، دانشکده مهندسی مکانیک، دانشگاه صنعتی شریف

۳- استادیار، پژوهشگاه فضایی ایران

*: نویسنده مسوول

پست الکترونیکی نویسندگان:

۱- faridhajiwaysa@sharif.edu

۲- nejat@sharif.edu

۳- t.abdollahi@isrc.ac.ir

چکیده:

تعیین وضعیت^۱ یکی از مؤلفه‌های حیاتی در طراحی و عملکرد سامانه‌های فضایی است. در این پژوهش، چارچوبی نوین برای تخمین وضعیت یک ماهواره زمین‌آهنگ^۲ با ترکیب حسگرهای خورشید و زمین و بهره‌گیری از الگوریتم‌های هوش مصنوعی ارائه شده است. روش جبری TRIAD برای پیش‌پردازش داده‌های خام حسگر استفاده شده است. در ادامه، مجموعه‌ای از الگوریتم‌های یادگیری ماشین^۳ و یادگیری عمیق^۴ شامل روش‌های CatBoost، XGBoost و شبکه عصبی چندلایه^۵ (MLP) برای تخمین کواترنیون‌های چرخش مورد ارزیابی قرار گرفته است. نتایج نشان می‌دهد که استفاده همزمان از چهار مدل MLP دو لایه‌ای با داده‌های پیش‌پردازش‌شده، همراه با نرمال‌سازی کواترنیون‌های خروجی، به میانگین خطای مطلق ۰/۵۷٪ درجه منجر می‌شود. این رویکرد، تقریباً ۱۰ درصد برتری عملکردی را در مقایسه با الگوریتم TRIAD از خود نشان داده و دقت مناسبی برای کاربردهای عملی و اجرای بلادرنگ فراهم می‌سازد.

واژگان کلیدی:

تعیین وضعیت، ماهواره، هوش مصنوعی، حسگر خورشید، حسگر زمین.

^۱ Attitude Determination

^۲ Geosynchronous

^۳ Machine Learning

^۴ Deep Learning

^۵ Multi-Layer Perceptron

Attitude Determination of Geosynchronous Satellites with Sun and Earth Sensors Using Artificial Intelligence Algorithms

Farid Hajiwaysa¹, Hossein Nejat Pishkenari², Taleb Abdollahi³

1- Bachelor's Student of Mechanical Engineering of Sharif University of Technology, Tehran, Iran.

2- Professor, Faculty of Mechanic Engineering of Sharif University of Technology, Tehran, Iran.

3- Assistant Professor, Iranian Space Research Center, Tehran, Iran.

Abstract:

In attitude determination system (ADS) of a satellite, using artificial intelligence methods for estimating rotation quaternions based on sensor outputs, reduces computational costs while increasing the speed and accuracy. Additionally, it maintains its efficiency at sensor singularity points and, unlike traditional algebraic methods, enable attitude determination across the entire probable space of satellite positioning. hence, Attitude determination is a critical component in the design and operation of space systems. This study presents a novel framework for estimating the attitude of a geosynchronous satellite by combining Sun and Earth sensors with artificial intelligence algorithm. Using raw data led to inappropriate results in a way that in the best prediction, error of estimating rotation quaternion vector was more than 10 degrees, so to enhance the quality of the learning process, the raw data were augmented as a preprocessing step utilizing the TRIAD algebraic method. Several machine learning and deep learning algorithms, including XGBoost, CatBoost, and multilayer perceptron (MLP) networks, were then employed to estimate the satellite's rotation quaternions. The findings of this research demonstrated that the simultaneous and parallel use of four identical two-layer MLP models, each dedicated to predicting a single component of the quaternions from the preprocessed data, coupled with the normalization of the output quaternions from the neural networks, yields a mean absolute error of 0.9 degrees. This approach achieved approximately 10% performance superiority compared to the best method among those evaluated, namely the TRIAD algorithm, which makes it suitable for practical, real-time applications. This hybrid approach offers a cost-effective and reliable solution for implementing attitude determination systems in satellites.

Keywords: Attitude Determination, Satellite, Artificial Intelligence, Sun Sensor, Earth Sensor.

۱. مقدمه

سیستم تعیین وضعیت^۱ یکی از زیرسامانه‌های حیاتی در معماری فضایی است که تعیین‌کننده جهت‌گیری بدنه‌ی ماهواره نسبت به یک چارچوب مرجع لخت می‌باشد. این پارامترها به‌طور مستقیم بر کیفیت عملکرد زیرسامانه‌های ارتباطی، ناوبری، تصویربرداری و پایدارسازی ماهواره اثرگذار هستند [1]. علاوه بر تعیین وضعیت، طراحی سامانه‌های کنترل وضعیت مقاوم نیز از موضوعات مهم مرتبط با پایداری ماهواره‌هاست [2]. به بیان دیگر، هرگونه خطا در برآورد جهت‌گیری ماهواره می‌تواند منجر به کاهش دقت مأموریت، افزایش مصرف انرژی، یا حتی از دست رفتن کامل کنترل شود.

در سیستم‌های کلاسیک تعیین وضعیت ماهواره، الگوریتم‌هایی نظیر فیلتر کالمن توسعه‌یافته^۲ (EKF)، فیلتر کالمن بدون مدل خطی^۳ (UKF) و روش‌های جبری مانند QUEST، TRIAD و Q-Method مورد استفاده قرار می‌گیرند. این روش‌ها اغلب نیازمند مدل‌سازی دقیق دینامیک ماهواره و مشخص بودن نویز اندازه‌گیری هستند. با اینکه این روش‌ها در مأموریت‌های عملی متعدد نتایج قابل قبولی ارائه داده‌اند، اما در مواجهه با نویزهای وابسته به شرایط محیطی، تأخیرهای سنسوری، یا در نقاط تکینگی مانند تغییر وضعیت‌های ناگهانی، دچار افت عملکرد می‌شوند. [3], [4]

با پیشرفت الگوریتم‌های یادگیری ماشین و شبکه‌های عصبی در دهه‌ی اخیر، رویکردهای نوینی در حل مسائل تعیین وضعیت پیشنهاد شده‌اند که برخلاف روش‌های کلاسیک، نیازی به مدل‌سازی صریح دینامیک ندارند. روش‌هایی نظیر LightGBM, XGBoost, CatBoost و شبکه‌های عصبی عمیق قادرند با یادگیری از داده‌های آموزشی حاصل از شبیه‌سازی، رابطه‌ی پنهان بین داده‌های سنسوری و کوآترنیون‌های چرخش را استخراج کرده و در زمان آزمون عملکردی دقیق و سریع ارائه دهند. [5]

یکی از چالش‌های اصلی در طراحی سیستم تعیین وضعیت، انتخاب نوع و ترکیب حسگرهاست. سنسورهای دقیق مانند ستاره‌یاب‌ها با وجود دقت بالا، هزینه، توان مصرفی و پیچیدگی بالایی

دارند. در مقابل، سنسورهای خورشید^۴ و زمین^۵ با سادگی، ابعاد کوچک و توان مصرفی پایین، گزینه‌هایی مناسب برای ماهواره‌های سبک‌وزن و کم‌هزینه محسوب می‌شوند؛ اما به تنهایی قادر به تعیین کامل جهت‌گیری سه‌محوره نیستند. [6], [7]

در این راستا، پژوهش‌های اخیر نشان داده‌اند که ترکیب داده‌های حسگرها و بهره‌گیری از الگوریتم‌های یادگیری عمیق^۶ می‌تواند دقت و پایداری تعیین وضعیت را به شکل چشمگیری افزایش دهد. برای نمونه، الگوریتمی تلفیقی بر پایه‌ی فیلتر کالمن و روش حداقل مربعات برای ادغام داده‌های ستاره‌یاب و ژيروسکوپ در ماهواره‌ی سنجش از دور TianHui-1 ارائه شده است که با داده‌های واقعی پروازی آزموده شده و دقتی در حدود چند ثانیه‌ی قوسی به‌دست آورده است [8]. همچنین روشی نوین مبتنی بر انرژی تداخل سیگنال‌های ماهواره‌های زمین‌آهنگ و شبکه‌ی عصبی LSTM برای تعیین وضعیت رول وسایل در حال دوران معرفی شده است که با یادگیری رابطه‌ی میان انرژی دریافتی سیگنال GNSS^۷ و زاویه‌ی رول، توانسته است خطای میانگین را نسبت به روش حداقل مربعات تا حدود ۴۹٪ کاهش دهد [9]. همچنین در پژوهشی دیگر، با تلفیق سامانه‌ی ناوبری اینرسی و حسگر ستاره‌نگر (سماوی) به‌کمک فیلتر کالمن درجه‌ی دوم و بهره‌گیری از کوآترنیون‌ها برای کاهش بار محاسباتی و پیشگیری از تکینگی، خطاهای سرعت و موقعیت در ابتدای فعالیت حسگر ستاره‌نگر با دقت مناسبی جبران شده است [10]. این سه مطالعه نشان می‌دهند که ترکیب هوشمند داده‌های چندحسگر و مدل‌های یادگیری عمیق، نه تنها وابستگی به مدل‌سازی دینامیکی صریح را کاهش می‌دهد، بلکه دقت و پایداری تعیین وضعیت را در محیط‌های پرنویز و مأموریت‌های GEO به شکل محسوسی بهبود می‌بخشد.

در این میان، استفاده‌ی ترکیبی از حسگرهای خورشید و زمین به همراه الگوریتم‌های یادگیری عمیق می‌تواند راه‌حلی عملی و کم‌هزینه برای تخمین دقیق وضعیت باشد. پژوهش حاضر با بهره‌گیری از مدل‌سازی دینامیکی حرکت ماهواره و تولید داده‌های مصنوعی بردارهای یکه‌ی خورشید و زمین در چارچوب‌های مداری^۸

^۵ Earth Sensor

^۶ Deep Learning

^۷ Global Navigation Satellite System

^۸ Orbital Frame

^۱ Attitude Determination System

^۲ Extended Kalman Filter

^۳ Unscented Kalman Filter

^۴ Sun Sensor

$$m_s \frac{v_s^2}{r_{se}} = G \frac{m_s m_e}{r_{se}^2} \quad (1)$$

$$v_s = r_{se} \omega \quad (2)$$

$$\omega = \frac{2\pi}{24 \times 3600} \text{ rad/s} \quad (3)$$

که در این روابط m_e بیانگر جرم زمین، m_s جرم ماهواره، r_{se} فاصله مرکز زمین تا ماهواره، G ثابت جهانی گرانش^۴، v_s سرعت خطی ماهواره و ω بیانگر سرعت زاویه‌ای گردش زمین به دور خود یا فرکانس گردش مداری ماهواره می‌باشد.

با استفاده از این روابط شعاع دوران این مدل از ماهواره‌ها حدود ۴۲۰۰۰ کیلومتر به دست خواهد آمد که تقریباً ۶.۶۱ برابر شعاع زمین است. لازم به ذکر است که روابط ۱ تا ۳ بر پایه‌ی فرض مدار دایروی کامل استخراج شده‌اند که برای مدار زمین‌آهنگ مورد بررسی در این پژوهش، تقریب مناسبی محسوب می‌شود. این روابط برای مدارهای غیر دایروی معتبر نیستند و در صورت تعمیم این پژوهش به چنین مدارهایی، لازم است از معادلات دینامیکی عمومی‌تر استفاده شود. ماهواره‌ی بررسی شده در این پژوهش در مداری زمین‌آهنگ با زاویه میل^۵ ۲۳ درجه و ۳۰ ثانیه در گردش است و در واقع در صفحه مدار گردش زمین به دور خورشید قرار دارد.

۲.۱. دستگاه‌های مختصات فضایی

فرایند تعیین وضعیت ماهواره به عنوان تخمین زوایای دوران دستگاه مختصات متصل به ماهواره (دستگاه مختصات بدنی) نسبت به یک دستگاه مختصات مرجع (دستگاه مختصات مداری) تعریف می‌شود:

۱. دستگاه مختصات مداری:

مبدأ این دستگاه در مرکز جرم ماهواره قرار دارد و جهت‌گیری آن به گونه‌ای انتخاب می‌شود که محور z آن همواره به سمت مرکز زمین باشد، محور x در راستای بردار سرعت مداری ماهواره تعریف می‌گردد و محور y مطابق قاعده دست راست نسبت به دو محور دیگر حاصل

و بدنی^۱، یک دیتاست بزرگ با درنظر گرفتن نویز تصادفی ایجاد کرده است. در ادامه، داده‌ها با روش‌هایی مانند الگوریتم کلاسیک TRIAD، تخمین بردار چرخش اولیه و ضرب داخلی و خارجی بردارهای مختلف پیش‌پردازش شده‌اند تا بهبود دقت مدل‌های یادگیرنده حاصل شود. سپس مجموعه‌ای از الگوریتم‌های یادگیری ماشین^۲ و یادگیری عمیق روی این داده‌ها اعمال شده‌اند و عملکرد آن‌ها از نظر دقت در تخمین کواترنیون‌های چرخش مورد مقایسه قرار گرفته است. علاوه بر دقت تخمین، امکان‌پذیری اجرای مدل منتخب در بستر بلادرنگ و بر روی سخت‌افزار پردازشی مشابه با آنچه در ماهواره‌های واقعی به کار می‌رود نیز بررسی شده است تا کاربردپذیری عملی روش پیشنهادی ارزیابی گردد.

نتایج به دست آمده نشان می‌دهد که با ترکیب مناسب پیش‌پردازش بردارهای سنسوری با مدل‌های شبکه عصبی چندلایه (MLP) می‌توان به دقتی در حدود ۰/۵۷ درجه در تخمین بردار چرخش دست یافت. این میزان دقت نه تنها از روش جبری کلاسیک بررسی شده در این پژوهش فراتر است، بلکه از منظر زمان محاسباتی نیز برای کاربردهای عملی و مأموریت‌های با محدودیت‌های منابع کاملاً قابل قبول است. بنابراین، استفاده از روش‌ها و مدل‌های مختلف هوش مصنوعی به‌ویژه در سناریوهایی با محدودیت سخت‌افزاری یا داده‌های ناقص می‌تواند به عنوان رویکردی مؤثر در طراحی نسل جدید سیستم‌های تعیین وضعیت ماهواره‌ها مطرح شود. [11]

۱.۱. مدار زمین‌آهنگ

ماهواره‌های زمین‌آهنگ^۳ در یک مدار دایروی با ارتفاع مداری حدود ۳۶۰۰۰ کیلومتر و زاویه میل مداری غیر صفر درجه (غیر استوایی) گردش می‌کنند. دوره زمانی یک بار چرخش کامل این ماهواره‌ها در مدار خود برابر با دوره تناوب یک گردش زمین به دور خود است که به معنای سرعت دورانی برابر زمین و ماهواره در راستای خط واصل مرکز زمین و شمال جغرافیایی زمین است. از این جهت روابط دینامیکی زیر برای حرکت این ماهواره‌ها برقرار خواهد بود:

^۴ Gravitational Constant

^۵ Inclination Angle

^۱ Body Frame

^۲ Machine Learning

^۳ Geosynchronous Satellite

می‌شود. این دستگاه معمولاً با اندیس r یا o نمایش داده می‌شود.

۱۱. دستگاه مختصات بدنی:

این دستگاه هم‌مرکز با دستگاه مداری است، اما به بدنه ماهواره متصل بوده، محورهای آن هم‌راستا با محورهای اصلی ماهواره بوده و همراه با آن دوران می‌یابد. دستگاه بدنی جهت نمایش وضعیت لحظه‌ای ماهواره به کار می‌رود و معمولاً با اندیس b بیان می‌شود.

۲. مدل‌سازی دینامیکی حرکت اجرام

در فرآیند تحلیل دینامیکی سیستم، برای ساده‌سازی شبیه‌سازی و حذف پیچیدگی‌های غیرضروری، خورشید و زمین در یک بازه زمانی کوتاه (در حد چند روز) به ترتیب به عنوان یک منبع نوری ثابت در فضا و یک منبع بازتابنده‌ی نور ثابت در فضا در نظر گرفته می‌شوند. این فرض از آن‌جا ناشی می‌شود که سرعت زاویه‌ای حرکت مداری زمین به دور خورشید در مقایسه با سرعت زاویه‌ای گردش ماهواره‌ی زمین‌آهنگ به دور زمین بسیار ناچیز است؛ بنابراین در بازه‌های زمانی کوتاه، تغییر موقعیت زاویه‌ای خورشید نسبت به دستگاه مرجع، اثر قابل چشم‌پوشی بر دقت تخمین وضعیت خواهد داشت. با این حال، این فرض برای بازه‌های زمانی بلندمدت معتبر نیست و در چنین شرایطی لازم است حرکت مداری خورشید نیز به‌صراحت در مدل لحاظ شود. در نظر گرفتن حرکت مداری زمین به دور خورشید در مقیاس زمانی کوتاه موردنظر در این پژوهش، تنها منجر به تکرار عملی داده‌ها در مجموعه آموزشی شده و تأثیر معنی‌داری بر دقت مدل ندارد.

علاوه بر این، فرض می‌شود که صفحه‌ی مداری چرخش ماهواره به دور زمین با صفحه‌ی چرخش زمین به دور خورشید منطبق است؛ در نتیجه، سه جسم شامل ماهواره، زمین و خورشید همواره در یک صفحه‌ی مشترک (دایره البروج) قرار دارند. همچنین برای کاهش پیچیدگی‌های هندسی، اشکال خورشید و زمین به صورت کره‌های کامل و ماهواره به صورت یک نقطه‌ی جرم‌دار در نظر گرفته شده‌اند. مدار چرخش ماهواره نیز به صورت دایره‌ای کامل فرض شده‌اند تا

بتوان روابط تحلیلی دوران را با دقت مناسب و پیچیدگی کمتر مدل‌سازی کرد. همچنین در ادامه ذکر می‌شود که ماهواره در یک نقطه از مدار، ثابت در نظر گرفته می‌شود.

با توجه به این فرضیات، تخمین وضعیت برای ماهواره در یک نقطه خاص انجام شده و در پژوهش‌های آینده، با تلفیق نتایج بدست آمده از نقاط مختلف مداری، امکان تعیین وضعیت برای کل مدار فراهم می‌گردد.

لازم به ذکر است که چارچوب پیشنهادی در این پژوهش از نظر ساختاری مستقل از نوع مدار است و اصولاً برای سایر مدارها (از جمله LEO یا مدارهای بیضوی) نیز قابل استفاده است. آنچه در این پژوهش مختص مدار زمین‌آهنگ است، دیتاست تولیدشده و وزن‌های آموزش‌دیده‌ی مدل‌هاست که بر اساس پارامترهای مداری خاص مدار زمین‌آهنگ (شعاع مداری، سرعت زاویه‌ای گردش) ساخته شده‌اند. به کارگیری این چارچوب برای مدارهای دیگر، مستلزم تولید دیتاست متناظر با پارامترهای همان مدار و آموزش مجدد شبکه است، اما نیازی به بازطراحی الگوریتم نیست.

۳. حسگرها^۱

برای تعیین وضعیت ماهواره‌ها از انواع مختلفی از حسگرها از جمله حسگر ستاره، حسگر خورشید، حسگر زمین و مغناطیس‌سنج استفاده می‌شود. انتخاب نوع و ترکیب این حسگرها به عوامل مختلفی نظیر دقت مورد نیاز، محدودیت‌های وزنی و حجمی، پیچیدگی طراحی و همچنین بودجه‌ی در دسترس پروژه بستگی دارد. به‌طور کلی، استفاده‌ی ترکیبی از چند نوع حسگر می‌تواند منجر به افزایش دقت شود، اما همواره چنین نیست؛ چرا که در برخی موارد یک حسگر ستاره‌ی با دقت بالا ممکن است عملکردی بهتر از ترکیب چندین حسگر با دقت پایین‌تر ارائه دهد. از این‌رو، نوع حسگر انتخاب‌شده، یکی از فاکتورهای کلیدی در طراحی سیستم تعیین وضعیت محسوب می‌شود.

در این پژوهش، با هدف کاهش پیچیدگی و هزینه‌ی سخت‌افزاری و در عین حال حفظ قابلیت اطمینان، فرض شده است که سامانه‌ی تعیین وضعیت ماهواره به دو حسگر ساده و متداول،

^۱ Sensors

یعنی حسگر خورشید و حسگر زمین مجهز است. این دو حسگر به شرح زیر معرفی می‌شوند:

۱. حسگر خورشید: این حسگر با استفاده از اختلاف شدت تابش خورشید در میدان دید خود، جهت‌گیری خورشید را نسبت به ماهواره تعیین می‌کند. در چارچوب این پژوهش، خروجی حسگر خورشید به صورت یک بردار یک‌جهت تعریف می‌شود که موقعیت مرکز خورشید را نسبت به ماهواره در دستگاه مختصات بدنی نمایش می‌دهد.

۲. حسگر زمین: این حسگر با جمع‌آوری و تحلیل پرتوهای نوری منتشر شده از سطح زمین، موقعیت نسبی زمین نسبت به ماهواره را تخمین می‌زند. در این مطالعه، خروجی حسگر زمین نیز به صورت یک بردار یک‌جهت در نظر گرفته شده است که موقعیت مرکز زمین را نسبت به ماهواره در چارچوب مختصات بدنی بیان می‌کند.

در طراحی سامانه‌ی تعیین وضعیت این پژوهش، از حسگر مغناطیس‌سنج به عنوان منبع اطلاعاتی استفاده نشده است. دلیل اصلی این انتخاب، ماهیت ضعیف و کم‌دقت میدان مغناطیسی زمین در مدار زمین‌آهنگ است؛ در این ارتفاع مداری، شدت میدان مغناطیسی زمین به شدت کاهش می‌یابد و به مقادیری در حد چند نانوتسلا می‌رسد که نسبت به نویزهای محیطی نسبت سیگنال به نویز پایینی دارد. علاوه بر این، بهره‌گیری از مغناطیس‌سنج مستلزم دسترسی به یک مدل مرجع دقیق میدان مغناطیسی زمین در فاصله‌ی مداری موردنظر است که خود منبع خطای اضافی محسوب می‌شود. بر این اساس، در این پژوهش تمرکز بر حسگرهای خورشید و زمین حفظ شده و بررسی افزودن مغناطیس‌سنج یا سایر حسگرهای تکمیلی به عنوان یکی از موضوعات پژوهش‌های آینده پیشنهاد می‌شود.

۴. جمع‌آوری داده‌ها

داده‌های خام مورد استفاده در این پژوهش شامل چهار بردار یک‌جهت هستند که موقعیت نسبی دو جسم آسمانی خورشید و زمین را

نسبت به ماهواره در دو چارچوب مختصات مختلف نمایش می‌دهند. این بردارها عبارت‌اند از:

۱. بردار یک‌جهت موقعیت خورشید نسبت به ماهواره در دستگاه مختصات مرجع
۲. بردار یک‌جهت موقعیت خورشید نسبت به ماهواره در دستگاه مختصات بدنی
۳. بردار یک‌جهت موقعیت زمین نسبت به ماهواره در دستگاه مختصات مرجع
۴. بردار یک‌جهت موقعیت زمین نسبت به ماهواره در دستگاه مختصات بدنی

با توجه به تعریف دستگاه مختصات مرجع، که در آن مبدأ در مرکز جرم ماهواره قرار داشته و محور z در راستای شعاع مداری به سمت زمین تعریف شده است، بردار موقعیت زمین نسبت به ماهواره در این دستگاه همواره مقداری ثابت دارد که در رابطه ۴ آمده است:

$$E_r = [0 \ 0 \ 1] \quad (4)$$

برای تعیین بردار یک‌جهت موقعیت خورشید نسبت به ماهواره در دستگاه مختصات مرجع، از یک دستگاه میانی استفاده می‌شود که مبدأ آن در مرکز خورشید قرار دارد و با اندیس i نمایش داده می‌شود. این دستگاه مختصات به گونه‌ای تعریف شده است که محور y آن عمود بر صفحه مداری زمین به دور خورشید و هم جهت با محور z دستگاه مداری، محور x درون این صفحه و به سمت زمین در نظر گرفته شده است و محور z طبق قاعده دست راست تعیین می‌گردد.

چون ماهواره، زمین و خورشید در یک صفحه قرار دارند، موقعیت لحظه‌ای خورشید نسبت به ماهواره در دستگاه i به صورت معادله ۵ تعریف می‌گردد:

$$S_i = [-(SS)\cos(\alpha) \ 0 \ -(SS)\sin(\alpha)] \quad (5)$$

که در آن، SS (Sun to Satellite) فاصله بین خورشید و ماهواره، و α موقعیت زاویه‌ای ماهواره نسبت به محور x دستگاه i است.

چون در این پژوهش زمین به صورت یک کره ثابت با موقعیت زاویه‌ای صفر درجه نسبت به محور x دستگاه i در نظر گرفته شده

جابه‌جا کرد و برای هر نقطه، داده‌ی متناظر را بدون نیاز به بازتعریف کامل مدل دینامیکی تولید نمود.

از آن‌جا که در شبیه‌سازی، داده‌های واقعی حسگرها در دسترس نبوده‌اند، بردارهای مربوط به موقعیت خورشید و زمین در دستگاه بدنی از طریق اعمال دوران‌های مختلف در دستگاه بدنی و با استفاده از داده‌های محاسبه‌شده در دستگاه مرجع به‌دست آمده‌اند.

برای انتقال بین دستگاه مرجع و دستگاه بدنی، از چارچوب کواترنیونی برای توصیف دوران استفاده شده است. بر اساس قضیه اوایلر، هر دوران سه‌بعدی را می‌توان با یک بردار جهت (محور دوران) و یک زاویه دوران مشخص نمود. کواترنیون^۱ متناظر با این دوران به‌صورت رابطه ۹ تعریف می‌شود:

$$q = \begin{bmatrix} q_1 \\ q_2 \\ q_3 \\ q_4 \end{bmatrix} = \begin{bmatrix} u_1 \sin(\frac{\phi}{2}) \\ u_2 \sin(\frac{\phi}{2}) \\ u_3 \sin(\frac{\phi}{2}) \\ \cos(\frac{\phi}{2}) \end{bmatrix} \quad (9)$$

که در آن u_i ها مؤلفه‌های بردار واحد جهت دوران، و ϕ زاویه دوران است. کواترنیون‌ها باید نرمالیزه باشند، بنابراین شرط ۱۰ همواره برقرار است:

$$q_1^2 + q_2^2 + q_3^2 + q_4^2 = 1 \quad (10)$$

بردار واحد جهت دوران را می‌توان با استفاده از دو زاویه به صورت رابطه ۱۱ نشان داد:

$$u = \begin{bmatrix} u_1 \\ u_2 \\ u_3 \end{bmatrix} = \begin{bmatrix} \cos(\beta)\cos(\gamma) \\ \cos(\beta)\sin(\gamma) \\ \sin(\beta) \end{bmatrix} \quad (11)$$

در این رابطه β بیانگر زاویه بردار دوران نسبت به صفحه xy دستگاه مرجع و γ بیانگر زاویه تصویر بردار دوران در صفحه xy نسبت به محور x در دستگاه دوران است. این پارامترسازی زاویه‌ای بردار واحد جهت دوران، مبنای تولید نظام‌مند مجموعه داده‌ی آموزشی در این پژوهش است؛ به‌طوری‌که در بخش ۸، فضای کامل

است و واحد نجومی (فاصله بین خورشید و زمین) بیش از ۳۵۰۰ برابر بزرگتر از فاصله بین زمین و ماهواره است موقعیت لحظه‌ای خورشید نسبت به زمین در دستگاه i به صورت معادله ۶ تعریف می‌گردد:

$$(AU \approx SS, \alpha = 0) \rightarrow S_i = [-AU \ 0 \ 0] \quad (6)$$

برای تبدیل این بردار به دستگاه مداری ماهواره، با توجه به هم‌صفحه بودن محورهای y در دو دستگاه، از یک دوران دوبعدی استفاده شده و ماتریس تبدیل رابطه ۷ اعمال می‌شود:

$$R_i^r = \begin{bmatrix} \cos(\theta) & 0 & -\sin(\theta) \\ 0 & 1 & 0 \\ \sin(\theta) & 0 & \cos(\theta) \end{bmatrix} \quad (7)$$

که θ زاویه دوران حول محور y برای تبدیل دستگاه خورشید مرکز به دستگاه مداری است. با اعمال تبدیل رابطه ۷، بردار موقعیت خورشید در دستگاه i به‌صورت رابطه ۸ به‌دست می‌آید:

$$S_r = \frac{R_i^r S_i}{|R_i^r S_i|} \quad (8)$$

در این روابط، پارامتر ورودی صرفاً زاویه θ است که از آن موقعیت لحظه‌ای خورشید نسبت به ماهواره در دستگاه مداری استنتاج می‌شود.

با توجه به ماهیت ایستای ماهواره در مدار زمین آهنگ، در این پژوهش تحلیل‌ها بر مبنای موقعیت ماهواره در زاویه $\theta = 270^\circ$ انجام گرفته است. این فرض موجب ساده‌سازی روابط هندسی و دینامیکی سیستم شده و امکان تمرکز بر روی فرآیند اصلی تعیین وضعیت را فراهم می‌سازد.

با این حال، از آن‌جا که ماهواره در مدار دایره‌ای و در فاصله‌ی ثابتی از زمین قرار دارد، داده‌ها و مدل‌های حاصل را می‌توان با اعمال یک تبدیل زاویه‌ای ساده به سایر نقاط مدار تعمیم داد. به بیان دقیق‌تر دستگاه مداری همراه با گردش ماهواره به دور زمین می‌چرخد، درحالی‌که دستگاه خورشید مرکز نسبت به راستای زمین-خورشید ثابت باقی می‌ماند، پس زاویه‌ی θ در واقع معادل موقعیت زاویه‌ای لحظه‌ای ماهواره روی مسیر مداری آن است. بر این اساس، با تغییر مقدار θ می‌توان موقعیت ماهواره را در نقاط مختلف مدار

^۱ Quaternion

چرخشی میان دستگاه‌های مرجع و بدنی به شکل بهتری برای مدل‌ها قابل درک باشد. در یک لحظه‌ی زمانی ثابت، بردارهای یک‌ه‌ی موقعیت خورشید و زمین نسبت به ماهواره، در دستگاه‌های مرجع و بدنی ثابت هستند و فقط نمایش عددی آن‌ها متفاوت است. بنابراین، زاویه بین دو بردار خورشید و زمین در دستگاه مرجع و بدنی یکسان است. البته نویز سنسورها ممکن است اندکی بر این تساوی اثر بگذارد. با استفاده از این ویژگی، دو ستون جدید شامل ضرب داخلی بین بردارهای خورشید و زمین در دستگاه مرجع و نیز در دستگاه بدنی به مجموعه داده افزوده شدند. این مقادیر به‌طور ضمنی زاویه بین این بردارها را به الگوریتم یادگیری منتقل می‌کنند و به این ترتیب می‌توان بخشی از اطلاعات دوران سه‌بعدی را برای مدل قابل فهم کرد. علاوه بر این، یک راهکار مؤثر دیگر برای آموزش بهتر مدل‌ها، افزودن برداری در راستای محور چرخش دستگاه بدنی نسبت به دستگاه مرجع است. این بردار، که در دستگاه مرجع تعریف می‌شود، با استفاده از ضرب خارجی تفاضل بردارهای زمین و خورشید در دو دستگاه محاسبه می‌شود:

$$R_v = (E_b - E_r) \times (S_b - S_r) \quad (15)$$

این بردار، اختلاف جهت‌گیری صفحه‌ی تشکیل‌شده توسط بردارهای خورشید و زمین در دستگاه بدنی را نسبت به همان صفحه در دستگاه مرجع نمایش می‌دهد و از این‌رو، اطلاعاتی تکمیلی درباره‌ی جهت محور دوران بین دو دستگاه به مدل یادگیری منتقل می‌کند.

از آن‌جا که روابط میان این بردارها به‌صورت جبری بیش‌تعیین‌شده هستند (۴ بردار با ۶ معادله‌ی مستقل)، از الگوریتم کلاسیک TRIAD برای تخمین بهتر ماتریس دوران بین دستگاه‌های مرجع و بدنی استفاده شده است. این الگوریتم که معمولاً در تعیین نگرش کاربرد دارد، یکی از بردارها را به‌عنوان بردار با دقت بالاتر انتخاب می‌کند (در این پژوهش، بردار خورشید به دلیل خطای کمتر حسگر)، و با استفاده از آن ماتریس دوران را تخمین می‌زند. گام‌های تشکیل این ماتریس در معادلات ۱۶ تا ۲۱ آمده است:

$$t_{1b} = S_b \quad (16)$$

$$t_{1r} = S_r \quad (17)$$

دوران با تغییر گام به گام زوایای β و γ (به همراه زاویه‌ی دوران ϕ در رابطه‌ی ۹) در بازه‌های تعریف‌شده پیمایش شده و برای هر ترکیب از این زوایا، یک بردار دوران و در نتیجه یک کواترنیون متناظر تولید می‌گردد.

مزیت اصلی استفاده از کواترنیون‌ها نسبت به پارامترهای اولیه، عدم وجود نقاط تکینگی و پایداری عددی بالاتر در محاسبات است. ماتریس دوران از دستگاه مرجع به دستگاه بدنی با استفاده از کواترنیون به شکل رابطه ۱۲ تعریف می‌شود:

$$R_r^b = \begin{bmatrix} 1-2q_2^2-2q_3^2 & 2q_1q_2+2q_3q_4 & 2q_1q_3-2q_2q_4 \\ 2q_1q_2-2q_3q_4 & 1-2q_1^2-2q_3^2 & 2q_2q_3+2q_1q_4 \\ 2q_1q_3+2q_2q_4 & 2q_2q_3-2q_1q_4 & 1-2q_1^2-2q_2^2 \end{bmatrix} \quad (12)$$

با اعمال این ماتریس، بردارهای موقعیت زمین و خورشید در دستگاه بدنی پس از اضافه کردن نویز به‌صورت روابط ۱۳ و ۱۴ محاسبه می‌شوند:

$$E_b = R_r^b E_r + N(0, 0.006) \quad (13)$$

$$S_b = R_r^b S_r + N(0, 0.004) \quad (14)$$

در این دو رابطه N بیانگر توزیع تصادفی گاوسی (نرمال) می‌باشد. چهار بردار بدست‌آمده در معادلات ۱۳ و ۱۴ تشکیل‌دهنده داده‌های خام مورد استفاده در فرایند یادگیری هستند. با این حال، آزمایش‌ها نشان دادند که استفاده صرف از این داده‌های خام منجر به تخمینی با دقت پایین و خطاهای قابل توجه می‌شود. از این‌رو، برای افزایش دقت تخمین و غنی‌سازی ویژگی‌های ورودی، از پیش‌پردازش داده‌ها استفاده شده است. این پیش‌پردازش شامل ترکیب بردارها، استخراج ویژگی‌های هندسی جدید، و اعمال الگوریتم‌های کلاسیک مانند TRIAD می‌باشند که در ادامه تشریح خواهند شد.

۵. پیش‌پردازش^۱ داده‌های خام

با توجه به تعداد محدود ویژگی‌های اولیه (چهار بردار یک‌ه)، لازم بود که برای بهبود عملکرد مدل‌های یادگیری ماشین و یادگیری عمیق، اطلاعات بیشتری از ساختار هندسی داده‌ها استخراج شود. به همین منظور، با انجام عملیات برداری روی داده‌های خام، ستون‌های جدیدی به مجموعه داده افزوده شده تا الگوهای نهفته در روابط

^۱ Preprocess

به کاررفته در این پژوهش، با دسترسی هم‌زمان به بردارهای خام، خروجی TRIAD و ویژگی‌های هندسی افزوده، عملاً قادرند به صورت داده‌محور یک تصحیح غیرخطی بر پایه‌ی ساختار آماری نوین اعمال کنند.

۶. تخمین کواترنیون‌ها و سنجش خطا

به منظور تخمین دقیق کواترنیون‌های نشان‌دهنده وضعیت ماهواره، از شبکه عصبی چندلایه مبتنی بر یادگیری عمیق و همچنین هفت الگوریتم پرکاربرد در حوزه‌ی یادگیری ماشین استفاده شده است. این الگوریتم‌ها عبارت‌اند از:

- Decision Tree
- Random Forest
- AdaBoost
- CatBoost
- HistGradientBoosting
- XGBoost
- LightGBM

درخت‌های تصمیم^۳ مدل‌هایی غیرپارامتری هستند که با تقسیم‌بندی تکرارشونده فضای ویژگی به نواحی همگن، امکان مدل‌سازی روابط غیرخطی میان ورودی‌ها و متغیر هدف را فراهم می‌کنند. [12]

جنگل‌های تصادفی^۴ از جمله روش‌های تجمیعی هستند که مجموعه‌ای بزرگ از درخت‌های تصمیم را بر روی زیرمجموعه‌های بوت‌استرپ‌شده از داده‌های آموزشی ساخته و خروجی نهایی را از میانگین‌گیری پیش‌بینی‌های آن‌ها به دست می‌آورند. این رویکرد موجب کاهش واریانس و بهبود توان تعمیم مدل در مقایسه با یک درخت منفرد می‌شود. [13]

AdaBoost یک روش تجمیعی است که با ترکیب تکرارشونده مجموعه‌ای از یادگیرنده‌های ضعیف — که معمولاً درخت‌های تصمیم کم‌عمق هستند — و با بازوزن‌دهی تطبیقی نمونه‌های آموزشی بر اساس خطاهای پیشین، یک پیش‌بین قدرتمند ایجاد می‌کند. این سازوکار موجب تمرکز یادگیرنده‌های بعدی بر نمونه‌های دشوار شده و در نهایت دقت مدل را افزایش داده و سوگیری آن را کاهش می‌دهد. [14]

$$t_{2b} = \frac{S_b \times E_b}{|S_b \times E_b|} \quad (18)$$

$$t_{2r} = \frac{S_r \times E_r}{|S_r \times E_r|} \quad (19)$$

$$t_{3b} = t_{1b} \times t_{2b} \quad (20)$$

$$t_{3r} = t_{1r} \times t_{2r} \quad (21)$$

از آن‌جا که بردارهای S_r و S_b در داده‌های خام موجود هستند، تنها کافی بود بردارهای تولیدشده از معادلات ۱۸ تا ۲۱ به عنوان ویژگی‌های جدید به داده‌ها اضافه شوند. در مجموع، ۱۲ ویژگی جدید (سه مؤلفه برای هر بردار خروجی) به ماتریس ویژگی‌ها افزوده شد. این کار باعث شد که مدل‌های پیچیده‌تر هوش مصنوعی (مانند شبکه‌های عصبی چندلایه) بتوانند بدون بروز پدیده‌ی برازش بیش از حد^۱، الگوهای چرخشی را بهتر یاد بگیرند و کواترنیون‌های وضعیت را با دقت بیشتری تخمین بزنند.

لازم به توضیح است که ویژگی‌های افزوده‌شده در فرآیند پیش‌پردازش به طور ذاتی توابعی قطعی و غیرخطی از همان چهار بردار یک‌ه‌ی خام هستند و اندازه‌گیری یا اطلاعات مستقل جدیدی به مجموعه داده اضافه نمی‌کنند. این وابستگی، ناشی از خطای طراحی نیست، بلکه رویکردی متداول در مهندسی ویژگی^۲ است؛ هدف از افزودن این ویژگی‌ها، ارائه‌ی بازنمایی صریح‌تری از روابط هندسی و مثلثاتی نهفته در داده‌های خام به مدل هاست، تا فرآیند یادگیری این روابط غیرخطی تسهیل شود، نه آنکه اطلاعات جدیدی به سیستم اضافه گردد.

لازم به ذکر است که الگوریتم TRIAD، یک تخمین‌گر بهینه از منظر آماری نیست. مسئله‌ی مورد بررسی در این پژوهش به لحاظ جبری بیش‌تعیین‌شده است، و این افزونگی اطلاعاتی می‌تواند برای بهبود دقت تخمین در حضور نویز سنسوری استفاده شود. الگوریتم TRIAD تنها یکی از بردارها (در اینجا بردار خورشید، به دلیل دقت بالاتر حسگر) را به طور کامل معتبر فرض کرده و بردار دوم صرفاً برای تکمیل دستگاه مختصات به کار می‌رود؛ بدین ترتیب، این الگوریتم وزنی متناسب با کوواریانس نویز هر حسگر به بردارها اختصاص نمی‌دهد. در همین راستا، مدل‌های یادگیری ماشین

^۳ Decision Trees

^۴ Random Forests

^۱ Overfitting

^۲ Feature Engineering

CatBoost یک الگوریتم گرادیان بوستینگ است که برای پردازش کارآمد متغیرهای دسته‌ای و کاهش سوگیری پیش‌بینی از طریق ordered boosting و حداقل‌سازی target leakage طراحی شده است. این الگوریتم از درخت‌های تصمیم متقارن^۱ بهره می‌برد که ضمن افزایش کارایی محاسباتی و توان تعمیم، امکان مدل‌سازی روابط پیچیده و غیرخطی را فراهم می‌سازند. [15]

الگوریتم‌های LightGBM و گرادیان بوستینگ مبتنی بر هیستوگرام^۲ بر پایه‌ی بهینه‌سازی مبتنی بر هیستوگرام عمل می‌کنند؛ بدین صورت که متغیرهای پیوسته پیش از آموزش به بازه‌های هیستوگرامی گسسته‌سازی می‌شوند تا جست‌وجوی نقاط تقسیم به‌صورت بسیار کارآمد و با مصرف کمتر حافظه انجام گیرد و سرعت آموزش به طور قابل توجهی افزایش یابد. LightGBM این چارچوب را با نوآوری‌هایی همچون رشد برگ‌محور درخت‌ها، نمونه‌برداری یک‌طرفه مبتنی بر گرادیان^۳ و تجمع انحصاری ویژگی‌ها^۴ گسترش می‌دهد و به‌ویژه در داده‌های پربعد و پرنویز عملکرد قدرتمندی ارائه می‌کند. در مقابل، HGB در نسخه‌ی پیاده‌سازی‌شده در scikit-learn از اصل گسسته‌سازی هیستوگرامی مشابه بهره می‌برد و توانایی مدل‌سازی روابط غیرخطی را در کنار مقیاس‌پذیری محاسباتی بالا فراهم می‌سازد. [16]

XGBoost یک چارچوب بهینه‌سازی‌شده‌ی گرادیان بوستینگ را پیاده‌سازی می‌کند که در آن از اطلاعات گرادیان مرتبه‌ی دوم، منظم‌سازی پیچیدگی درخت‌ها و سازوکارهای کارآمد برای مدیریت ورودی‌های پراکنده بهره گرفته می‌شود. علاوه بر این، این الگوریتم با به‌کارگیری بهینه‌سازی‌های سطح سیستم نظیر ساخت موازی درخت‌ها و تخصیص حافظه مبتنی بر معماری سخت‌افزار، امکان آموزش سریع را بر روی داده‌های پیچیده فراهم می‌سازد. [17]

MLP یک شبکه‌ی عصبی پیش‌خور است که از چندین لایه‌ی کاملاً متصل تشکیل شده و با یادگیری نگاشت‌های سلسله‌مراتبی و غیرخطی بین ورودی‌ها و خروجی‌ها عمل می‌کند. فرایند آموزش این شبکه با استفاده از الگوریتم پس‌انتشار خطا^۵ انجام می‌شود که طی آن وزن‌های شبکه به‌صورت تکراری به‌روزرسانی شده و خطای

پیش‌بینی کاهش می‌یابد. این معماری توانایی مدل‌سازی روابط پیچیده و غیرخطی و همچنین استخراج تعامل‌های نهان میان ویژگی‌های حسگری را دارد؛ ویژگی‌هایی که در مسائل تعیین وضعیت ماهواره به‌طور معمول مشاهده می‌شوند. [18]

هر یک از این مدل‌ها از مکانیزم متفاوتی برای یادگیری داده‌ها بهره می‌برند و ممکن است در شرایط متفاوت (مثلاً استفاده از داده‌های خام یا پیش‌پردازش‌شده) عملکرد بهتری از خود نشان دهند. از این رو، برای ارزیابی دقیق، داده‌ها در سه سناریوی مختلف پیش‌پردازش شامل ویژگی‌های افزوده‌شده مبتنی بر ضرب داخلی، جهت چرخش و یک الگوریتم کلاسیک مورد استفاده قرار گرفته‌اند و مدل‌ها به‌صورت جداگانه برای هر حالت آموزش دیده‌اند.

هر مدل دارای مجموعه‌ای از ابرپارامترها است که تنظیم دقیق آن‌ها می‌تواند به بهبود عملکرد، افزایش دقت تخمین و کاهش خطای نهایی منجر شود. مشخصات کامل پیکربندی و تنظیمات هر مدل در جدول ۱ ارائه شده است.

نکته‌ی قابل توجه در فرآیند تخمین کواترنیون‌ها این است که هر یک از مدل‌های هوش مصنوعی به‌تنهایی قادر به برآورد دقیق و پایدار هر چهار مؤلفه‌ی کواترنیون نبودند. از این رو، برای بهبود دقت تخمین و کاهش هم‌پوشانی خطا میان مؤلفه‌ها، از چهار مدل یکسان به‌صورت موازی استفاده شد؛ به‌گونه‌ای که هر مدل، یکی از مؤلفه‌های کواترنیون را به‌صورت مستقل پیش‌بینی می‌کند.

به منظور همگرایی بهتر مدل‌های MLP در مرحله آموزش، برای هر مدل از یک ساختار مشابه از قبل آموزش‌دیده^۱ استفاده شد و پس از اتمام آموزش اولیه، بهترین وزن‌های بدست آمده جهت مقداردهی اولیه‌ی مدل اصلی به کار گرفته شدند. همچنین برای افزایش سرعت اجرای فرآیند آموزش و تخمین، از تکنیک چندرسمانی^۲ بهره گرفته شد تا محاسبات مربوط به هر مدل به‌صورت هم‌زمان انجام گیرد.

به‌منظور فراهم‌آوردن معیاری منصفانه برای مقایسه‌ی عملکرد مدل‌های یادگیری ماشین با روش کلاسیک، خطای الگوریتم TRIAD نیز دقیقاً بر روی همان مجموعه داده‌ی تست و با استفاده از همان بردارهای نویزدار خورشید و زمین در دستگاه بدنی

^۴ Exclusive Feature Bundling (EFB)

^۵ Back Propagation

^۶ Multi-threading

^۱ Oblivious Trees

^۲ Histogram-based Gradient Boosting (HGB)

^۳ Gradient-based One-side Sampling (GOSS)

محاسبه شد، بدون آن که هیچ مرحله‌ی یادگیری بر روی آن اعمال شود. بدین ترتیب، مقدار خطای ۰/۶۲۲ درجه‌ی گزارش شده برای TRIAD در جدول ۱، مستقیماً بازتاب‌دهنده‌ی اثر همان سطح نویز سنسوری بر دقت این الگوریتم جبری است و مبنای مقایسه‌ای هم‌سطح با سایر مدل‌ها را فراهم می‌سازد.

در میان مدل‌های مورد استفاده، تنها شبکه‌ی عصبی چندلایه عملکردی قابل‌مقایسه و در برخی موارد برتر نسبت به الگوریتم کلاسیک TRIAD از خود نشان داد. به همین دلیل، علاوه بر ساختار چهارمدلی موازی، یک مدل MLP دیگر نیز طراحی و آموزش داده شد که هر چهار مؤلفه‌ی کوآترنیون را به‌طور هم‌زمان در خروجی تولید می‌کند. نتایج این مدل نشان داد که ضمن حفظ دقت مناسب، زمان اجرای آن به‌طور محسوسی کاهش یافته است. تحلیل تفصیلی نتایج این ساختار در بخش بعدی ارائه شده است.

از سوی دیگر، بردار موقعیت زمین در دستگاه مرجع طبق رابطه‌ی ۴ برای تمامی نمونه‌ها مقداری ثابت دارد و به همین دلیل به‌تنهایی حامل اطلاعات متمایزکننده‌ای بین نمونه‌های مختلف نیست. برای اطمینان از عدم تأثیر این بردار ثابت بر نتایج، آزمایش‌های مقایسه‌ای با حذف و بدون حذف این بردار از مجموعه‌ی ویژگی‌های ورودی انجام شد که نشان داد حضور یا عدم حضور آن تأثیر معناداری بر دقت مدل‌ها ندارد.

در مرحله‌ی پس‌پردازش نیز کوآترنیون‌های تخمین‌زده‌شده نرمال‌سازی شدند تا شرط نرمال بودن کوآترنیون‌ها ($|q| = 1$) برقرار باشد و از بروز خطاهای عددی در محاسبات تعیین وضعیت جلوگیری شود.

برای ارزیابی دقت تخمین کوآترنیون‌ها، از خطای زاویه‌ای دقیق بین کوآترنیون حقیقی و کوآترنیون تخمین‌زده‌شده استفاده شده است. این معیار که با واحد درجه بیان می‌شود، از رابطه‌ی ۲۲ محاسبه می‌گردد:

$$Error = 2\cos^{-1}(|q_r \cdot q_e|) \quad (22)$$

که در آن q_r کوآترنیون مرجع (حقیقی) و q_e کوآترنیون تخمین زده‌شده هستند، و علامت $\cdot$ نشان‌دهنده‌ی ضرب داخلی در فضای چهاربعدی است. این شاخص به دلیل ماهیت هندسی کوآترنیون‌ها، ارزیابی دقیقی از فاصله چرخشی بین دو وضعیت ارائه می‌دهد.

۷. ارزیابی امکان‌پذیری اجرای بلادرنگ

با توجه به این که هدف نهایی این پژوهش، ارائه‌ی راهکاری کاربردی برای تعیین وضعیت ماهواره‌های واقعی است، لازم است امکان‌پذیری اجرای مدل‌های پیشنهادی در بستر واقعی و بلادرنگ نیز بررسی شود. از آن‌جا که دسترسی به سخت‌افزار واقعی پردازنده‌ی onboard ماهواره برای این پژوهش فراهم نبود، ارزیابی امکان‌پذیری اجرای بلادرنگ از طریق مقایسه‌ی توان محاسباتی سامانه‌ی توسعه (رایانه مورد استفاده برای آموزش و آزمون مدل‌ها) با یکی از پردازنده‌های استاندارد و پرکاربرد صنعت فضایی انجام شده است.

پردازنده‌ی مبنا برای این مقایسه، RAD750 ساخت شرکت BAE Systems است؛ پردازنده‌ای که به‌طور گسترده در مأموریت‌های فضایی متعدد به‌عنوان واحد پردازش مرکزی onboard مورد استفاده قرار می‌گیرد. طبق گزارش رسمی سازنده، این پردازنده با معماری RISC ابرمقیاسی، عملکردی معادل ۲۴۰ میلیون دستور Dhrystone 2.1 در ثانیه (MIPS) در فرکانس ۱۳۳ مگاهرتز با توان مصرفی کمتر از ۶ وات ارائه می‌دهد. [19]

به‌منظور مقایسه‌ای هم‌سطح و معتبر، توان پردازشی سامانه‌ی توسعه (پردازنده‌ی Intel Core i7-11800H) با استفاده از همان بنچمارک استاندارد صنعتی، یعنی Dhrystone نسخه‌ی ۲.۱، به‌طور مستقیم اندازه‌گیری شد. نتیجه‌ی این اندازه‌گیری، توان پردازشی معادل ۴۲۹۰۶ Dhrystone-MIPS (تک‌هسته) در فرکانس ۲۳۰۰ مگاهرتز را نشان داد.

با توجه به این که فرآیند استنتاج (inference) برای یک نمونه‌ی ورودی به‌صورت تک‌رشته‌ای انجام می‌شود، ضریب کندی پردازنده‌ی RAD750 نسبت به سامانه‌ی توسعه تقریباً برابر با ۱۷۹ می‌شود. با اعمال این ضریب بر روی زمان اجرای بهترین مدل گزارش‌شده در جدول ۱ (مدل MLP چهارمدلی موازی با پیش‌پردازش TRIAD، با زمان اجرای ۰.۲۱ میلی‌ثانیه بر روی سامانه‌ی توسعه)، زمان اجرای تخمینی بر روی پردازنده‌ی RAD750 تقریباً ۳۷/۵ میلی‌ثانیه برآورد می‌شود.

نرخ معمول چرخه‌ی کنترل وضعیت در ماهواره‌های زمین‌آهنگ مخابراتی حدود ۲ هرتز است، هرچند در برخی طراحی‌ها تا ۲۰ هرتز نیز افزایش می‌یابد [20]. این نرخ معادل بودجه‌ی زمانی حدوداً ۵۰ تا ۵۰۰ میلی‌ثانیه برای هر چرخه‌ی پردازش وضعیت است. با توجه

پایداری مدل، مقادیر خروجی با قدرمطلق کمتر از ۰/۰۰۳ پس از پردازش به مقدار صفر تبدیل شدند.

بهترین نتایج مدل‌های مختلف هوش مصنوعی در تخمین کوآترنیون‌های چرخش دستگاه بدنی نسبت به دستگاه مرجع در جدول ۱ و شکل ۳ ارائه شده است. در این جدول تنها برای مدل‌های MLP زمان اجرای پیش‌پردازش در نظر گرفته شده است. عبارات اختصاری مندرج در جدول ۱ در جدول ۲ توصیف شده‌اند.

در این پژوهش، با بهره‌گیری از مدل‌سازی دینامیکی حرکت یک ماهواره زمین‌آهنگ، مجموعه‌ای از داده‌های شبیه‌سازی شده حاصل از حسگرهای خورشید و زمین تولید گردید و الگوریتم‌های متنوع یادگیری ماشین و یادگیری عمیق برای تخمین وضعیت سه‌بعدی ماهواره مورد ارزیابی قرار گرفتند. نتایج به‌دست‌آمده از ارزیابی مدل‌ها نشان می‌دهند که بین دقت تخمین و زمان اجرای هر مدل، رابطه‌ی معکوسی وجود دارد؛ به‌طوری که مدل‌هایی با ساختار ساده‌تر نظیر درخت تصمیم زمان اجرای بسیار کوتاهی دارند، اما از دقت کمتری برخوردارند، در حالی که مدل‌های پیچیده‌تر مانند شبکه‌های عصبی چندلایه با وجود زمان اجرای کمی بیشتر، دقتی به مراتب بالاتر ارائه می‌دهند.

در میان مدل‌های بررسی شده تنها روش پیش‌پردازش TRIAD توانست به‌طور معناداری باعث بهبود عملکرد مدل‌های یادگیرنده شود. سایر روش‌های پیش‌پردازش تأثیر چشمگیری بر کاهش خطای تخمین نداشتند. همچنین مشاهده شد بجز در شبکه‌ی عصبی چندلایه، عملکرد سایر الگوریتم‌ها بدون استفاده از پیش‌پردازش TRIAD ضعیف و غیرقابل قبول بوده است.

مقایسه‌ی مدل‌ها نشان می‌دهد که در میان مدل‌های مبتنی بر درخت تصمیم و روش‌های تقویتی، الگوریتم CatBoost بهترین عملکرد را با میانگین خطای مطلق ۱/۴۸۴ درجه و زمان اجرای ۰/۰۰۴ میلی‌ثانیه برای هر نمونه ارائه داده است. با این وجود، دقت آن همچنان پایین‌تر از شبکه‌های عصبی چندلایه و روش کلاسیک TRIAD باقی مانده است. سایر الگوریتم‌های یادگیری ماشین نظیر Hist Gradient Boost و Random Forest علی‌رغم

به این که زمان اجرای تخمینی مدل پیشنهادی (۳۷.۵ میلی‌ثانیه) کمتر از حد پایین این بودجه‌ی زمانی است، می‌توان نتیجه گرفت که روش پیشنهادی از نظر محاسباتی برای اجرای بلادرنگ بر روی سخت‌افزار واقعی onboard ماهواره‌ای مناسب است.

لازم به ذکر است که این تحلیل یک برآورد نظری مبتنی بر مقیاس‌دهی توان پردازشی اندازه‌گیری شده است و جایگزین پیاده‌سازی و آزمون واقعی بر روی سخت‌افزار embedded نیست. پیاده‌سازی و آزمون واقعی مدل‌های پیشنهادی بر روی سخت‌افزار embedded مشابه با پردازنده‌های onboard ماهواره‌ای، به‌عنوان یکی از محورهای مهم پژوهش‌های آینده پیشنهاد می‌شود.

۸. تحلیل نتایج و نتیجه‌گیری

برای بدست آمدن نتایج این پژوهش، در مجموع از ۱۲۹۹۶ داده‌ی آموزشی استفاده شده است. این تعداد داده به گونه‌ای انتخاب گردید که پوشش کامل فضای دوران و تنوع کافی برای یادگیری مدل را تضمین نماید.

به منظور پوشش تمامی حالت‌های ممکن بردار جهت دوران و زاویه دوران، زوایای γ و ϕ با گام‌های ۱۰ درجه‌ای در بازه‌ی صفر تا ۱۸۰ درجه و زاویه‌ی β با گام ۱۰ درجه‌ای در بازه‌ی صفر تا ۳۶۰ درجه تغییر داده شده‌اند. مجموعه‌ی حاصل به عنوان داده‌های آموزشی مدل‌ها مورد استفاده قرار گرفت.

برای اعتبارسنجی مدل‌ها، تعداد ۲۶۰۰ داده (تقریباً معادل ۰.۲ داده‌های آموزشی) تولید شد که در آن زوایای γ ، ϕ و β به صورت تصادفی^۱ و در بازه‌های تعریف شده انتخاب شده‌اند. درنهایت، برای آزمون نهایی مدل‌ها، تعداد ۱۰۰۰۰۰ داده مشابه داده‌های اعتبارسنجی ولی با نمونه‌گیری تصادفی مستقل تولید شد. انتخاب این حجم از داده‌های تست با هدف افزایش اطمینان از پایداری مدل‌ها و جلوگیری از اثرگذاری داده‌های خاص یا سوگیری احتمالی انجام گرفت.

پس از انجام آزمایش‌های متعدد، مشخص شد که مدل‌های هوش مصنوعی در پیش‌بینی مقادیر بسیار نزدیک به صفر عملکرد دقیقی نداشتند؛ به‌طوری که در اغلب موارد، مقادیر مثبت را منفی و بالعکس پیش‌بینی می‌کردند. به منظور کاهش این اثر و افزایش

^۱ Random

زمان پیش‌بینی بسیار پایین، دقت لازم برای کاربردهای دقیق تعیین وضعیت را تأمین نکرده‌اند.

در خصوص عملکرد برتر شبکه‌ی عصبی چندلایه نسبت به سایر الگوریتم‌ها، به نظر می‌رسد این تفاوت ناشی از ماهیت متفاوت خانواده‌ی مدل‌ها باشد. مدل‌های مبتنی بر درخت تصمیم (از جمله Random Forest، AdaBoost، CatBoost، XGBoost و LightGBM) با تقسیم‌بندی‌های هم‌راستا با محور^۱ فضای ویژگی را مدل می‌کنند و برای تقریب دقیق روابط پیوسته و مثلثاتی حاکم بر ضرب‌های داخلی و خارجی بردارها، به عمق و تعداد زیادی از شاخه‌ها نیاز دارند که با حجم داده‌ی موجود در این پژوهش به‌طور کامل محقق نمی‌شود. در مقابل، شبکه‌ی عصبی چندلایه به دلیل بهره‌گیری از توابع فعال‌سازی پیوسته و بهینه‌سازی مبتنی بر گرادیان، توانایی بیشتری در ترکیب هموار این ویژگی‌های مهندسی‌شده و یادگیری تصحیحی غیرخطی بر پایه‌ی خروجی الگوریتم TRIAD دارد.

در مقایسه‌ی ساختارهای مختلف شبکه‌ی عصبی، نتایج نشان می‌دهد که چهار مدل MLP یکسان که هرکدام یک مؤلفه‌ی کوآترنیون را به صورت موازی تخمین می‌زنند با پیش‌پردازش TRIAD دقیق‌ترین تخمین را با میانگین خطای مطلق ۰/۵۷ درجه و زمان اجرای ۰/۲۱ میلی‌ثانیه ارائه کرده است. در مقابل، ساختار مشابه بدون پیش‌پردازش با خطای ۰/۶۵۶ درجه و زمان اجرای ۰/۰۹۰ میلی‌ثانیه ضمن حفظ دقت قابل‌قبول، سریع‌ترین مدل در میان ساختارهای مبتنی بر شبکه‌ی عصبی بوده است. عملکرد ضعیف‌تر این مدل بیانگر نقش کلیدی داده‌های استخراج‌شده از روش TRIAD در فرآیند یادگیری و عملکرد مناسب MLP بدون پیش‌پردازش نسبت به سایر مدل‌ها می‌باشد. از سوی دیگر، مدل MLP که هر چهار مؤلفه‌ی کوآترنیون را همزمان تخمین می‌زند نیز با خطای مطلق ۰/۶۲۲ درجه و زمان اجرای ۰/۱۵۷ میلی‌ثانیه نسبت به چهار مدل موازی مشابه عملکرد ضعیف‌تر، اما زمان اجرای کمتری داشته است.

به‌طور کلی، می‌توان نتیجه گرفت که ترکیب روش پیش‌پردازش TRIAD با شبکه‌ی عصبی چندلایه، توازن بهینه میان دقت و سرعت محاسباتی ایجاد کرده و روشی کارآمد و پایدار برای تعیین

وضعیت ماهواره‌های زمین‌آهنگ فراهم می‌آورد. این مدل نه تنها نسبت به الگوریتم کلاسیک TRIAD (با خطای ۰/۶۲۲ درجه) دقت بالاتری ارائه می‌دهد، بلکه از قابلیت اجرای بلادرنگ نیز برخوردار است و می‌تواند به‌عنوان جایگزینی عملی برای روش‌های کلاسیک در سامانه‌های ماهواره‌ای کوچک و سبک‌وزن مورد استفاده قرار گیرد. نتایج این تحقیق نشان می‌دهند که ترکیب داده‌های سنجشی ساده و کم‌هزینه مانند خروجی حسگرهای خورشید و زمین با تکنیک‌های هوش مصنوعی، خصوصاً در صورت بهره‌گیری از پیش‌پردازش‌های مناسب، می‌تواند راهکاری عملی و مقرون‌به‌صرفه برای طراحی سیستم‌های تعیین وضعیت در ماهواره‌های کوچک و سبک‌وزن فراهم آورد. این روش‌ها نه تنها هزینه و پیچیدگی سخت‌افزاری را کاهش می‌دهند، بلکه در شرایطی مانند نویز زیاد، فقدان برخی داده‌ها یا وقوع تکیگی‌های هندسی نیز عملکرد قابل اتکایی دارند.

برای تحقیقات آتی، پیشنهاد می‌شود که مدل پیشنهادی بر داده‌های واقعی حاصل از پرتاب‌های آزمایشی یا مدارهای واقعی پیاده‌سازی و آزمون شود. همچنین تخمین وضعیت برای تمامی نقاط مدار انجام شده و بررسی عملکرد این الگوریتم‌ها در حضور تاخیرهای زمانی^۲ و در چارچوب سامانه‌های کنترل وضعیت نیز می‌تواند گامی مؤثر در توسعه سامانه‌های هوشمند ماهواره‌ای باشد.

^۲ Delayed Measurements

^۱ Axis-Aligned Splits

جدول ۱. نتایج تخمین کواترنيون‌ها با استفاده از مدل‌های مختلف هوش مصنوعي

Table 1. Results of estimating quaternions using different artificial intelligence model


Preprocess Method	Model	Model Properties	Mean Absolute Error	Prediction Time Per Sample
TRIAD	LightGBM	Lr=0.03, n-es=10000 Max-depth=8	2.56°	2.243 <i>ms</i>
TRIAD	XGBoost	Lr=0.01, n-es=10000 Max-depth=5	2.94°	0.054 <i>ms</i>
TRIAD	Hist Gradient Boost	Lr=0.08, Max-depth=10	3.34°	0.004 <i>ms</i>
TRIAD	CatBoost	Lr=0.001, n-es=10000 Max-depth=10	1.484°	0.004 <i>ms</i>
TRIAD	Random Forest	Max-depth=17	3.18°	0.013 <i>ms</i>
TRIAD	Decision Tree	-	6.62°	0.001 <i>ms</i>
TRIAD	AdaBoost	Lr=0.03, n-es=1000	15.48°	0.153 <i>ms</i>
-	TRIAD	Algebraic Method	0.622°	0.12 <i>ms</i>
TRIAD	MLP – Single Model (4 Quaternion Outputs)	n-l = 2, w-l = 164, 64 b-s = 256, epochs = 250 act_func = relu, opt = adam	0.622°	0.157 <i>ms</i>
-	MLP – 4 Identical Single-Output Models (Parallel Structure)	n-l = 2, w-l = 164, 64 b-s = 256, epochs = 250 act_func = relu, opt = adam	0.656°	0.090 <i>ms</i>
TRIAD	MLP – 4 Identical Single-Output Models (Parallel Structure)	n-l = 2, w-l = 164, 64 b-s = 256, epochs = 250 act_func = relu, opt = adam	0.57°	0.21 <i>ms</i>

جدول ۲. معادل عبارات کوتاه استفاده شده در جدول نتایج تخمین کواترنيون‌ها

Table 2. Equivalent of the abbreviated expressions used in the quaternion estimation results table

عبارت کامل	علامت اختصاری
Learning rate	Lr
n-estimator	n-es
Number of layers	n-l
Width of layers	w-l
Batch-size	b-s
Activation function	act func
optimizer	Opt

Accuracy–Efficiency Trade-off of Different Estimation Models



شکل ۳. نتایج تخمین کواترنيون‌ها با استفاده از مدل‌های مختلف هوش مصنوعی

Figure 3. Results of estimating quaternions using different artificial intelligence model

- <https://doi.org/10.1016/j.proeng.2011.08.177>.
7. Kikuya, Y., Iwasaki, Y., Yatsu, Y. and Matunaga, S., 2021. Attitude determination algorithm using Earth sensor images and image recognition. *Transactions of the Japan Society for Aeronautical and Space Sciences*, 64(2), pp. 82-90. <https://doi.org/10.2322/TJSASS.64.82>.
 8. Zhu, F., Qin, Y., Cai, Q., Chen, X. and Zhang, X., 2025. Combining star tracker and gyroscope for remote sensing satellite attitude determination: algorithm design and performance evaluation with real data. *IEEE Transactions on Instrumentation and Measurement*, 74, pp. 1-15. <https://doi.org/10.1109/TIM.2025.3548235>.
 9. Li, R., Feng, L., Wu, P., Deng, X. and Shi, H., 2025. A roll attitude determination method based on the jamming energy of GEO satellites and an LSTM neural network. *Scientific Reports*, 15(1), p. 17888. <https://doi.org/10.1038/s41598-025-01174-0>.
 10. Nobahari, H., Ghanbarpour Asl, H. and farhad Abtahi, S.F., 2016. Investigation of Accuracy of Integrated Inertial-Radar Navigation Systems in Autolanding of Unmanned Air Vehicles. *Sharif Journal of Mechanical Engineering (SJME)*, 32.3(2), pp. 53-62. <https://dor.isc.ac/dor/20.1001.1.26764725.1395.323.2.7.8>.
 11. Sun, Z., Simo, J. and Gong, S., 2023. Satellite attitude identification and prediction based on neural network compensation, *Space: Science & Technology*, 3, p. 0009. <https://doi.org/10.34133/SPACE.0009>.
 1. Orozco, M.L. and Giraldo, B.S., 2024. Attitude determination and control in small satellites: A review. *IEEE Journal on Miniaturization for Air and Space Systems*, 5(3), pp. 182-186. <https://doi.org/10.1109/JMASS.2024.3402984>.
 2. Fathi Jegarkandi, M. and Safaei, R., 2024. Fractional Order Sliding Mode Controller (FOSMC) Design for Attitude Control of a Satellite with Coupled Rigid-Flexible Structures Using Fractional Order Transfer Function. *Sharif Journal of Mechanical Engineering (SJME)*, 40(2), pp. 3-14. <https://doi.org/10.24200/j40.2023.62462.1684>.
 3. Soken, H.E., Hajiyeve, C. and Sakai, S.I., 2014. Robust Kalman filtering for small satellite attitude estimation in the presence of measurement faults. *European Journal of Control*, 20(2), pp. 64-72. <https://doi.org/10.1016/j.ejcon.2013.12.002>.
 4. Hajiyeve, C. and Guler, D.C., 2017. Review on gyroless attitude determination methods for small satellites. *Progress in Aerospace Sciences*, 90, pp. 54-66. <https://doi.org/10.1016/j.paerosci.2017.03.003>.
 5. Dos Santos, G.H., Seman, L.O., Bezerra, E.A., Leithardt, V.R.Q., Mendes, A.S. and Stefenon, S.F., 2021. Static attitude determination using convolutional neural networks. *Sensors*, 21(19), p. 6419. <https://doi.org/10.3390/S21196419>.
 6. Ni, S. and Zhang, C., 2011. Attitude determination of nano satellite based on gyroscope, sun sensor and magnetometer. *Procedia Engineering*, 15, pp. 959-963.

- <https://doi.org/10.1038/323533A0;KWRD>.
19. Berger, R.W., Bayles, D., Brown, R., Doyle, S., Kazemzadeh, A., Knowles, K., Moser, D., Rodgers, J., Saari, B., Stanley, D. and Grant, B., 2001. The RAD750TM - A Radiation Hardened PowerPCTM Processor for High Performance Spaceborne Applications. In *IEEE Aerospace Conference Proceedings*, Big Sky, MT, USA, 5, pp. 2263-2272. <https://doi.org/10.1109/AERO.2001.931184>.
 20. Pasetti, A., 2002. Background on Attitude and Orbit Control Systems (AOCS). *AOCS Framework Project*, PnP Software. Available at: <https://www.pnp-software.com/AocsFramework/AocsBackground.html> [Accessed 9 Aug. 2026].
 12. Quinlan, J.R., 1986. Induction of decision trees, *Machine Learning*, 1(1), pp. 81–106. <https://doi.org/10.1007/BF00116251>.
 13. Breiman, L., 2001. Random forests, *Machine Learning*, 45(1), pp. 5–32. <https://doi.org/10.1023/A:1010933404324/METRICS>.
 14. Freund, Y. and Schapire, R.E., 1997. A decision-theoretic generalization of on-line learning and an application to boosting, *Journal of Computer and System Sciences*, 55(1), pp. 119–139. <https://doi.org/10.1006/JCSS.1997.1504>.
 15. Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A.V. and Gulin, A., 2018. CatBoost: unbiased boosting with categorical features. In *Proceedings of the 32nd International Conference on Neural Information Processing Systems*, pp. 6639–6649. <https://dl.acm.org/doi/10.5555/3327757.3327770>.
 16. Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. and Liu, T.Y., 2017. Lightgbm: A highly efficient gradient boosting decision tree. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*, pp. 3149–3157. <https://dl.acm.org/doi/10.5555/3294996.3295074>.
 17. Chen, T. and Guestrin, C., 2016. XGBoost: A Scalable Tree Boosting System. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pp. 785–794. <https://doi.org/10.1145/2939672.2939785>.
 18. Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986. Learning representations by back-propagating errors, *Nature*, 323(6088), pp. 533–536.