**Sharif University of Technology**

***Sharif Mechanical Engineering Journal***

**https://sjme.journals.sharif.edu**

**Research Article**

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

**Farid Hajiwaysa[1], Hossein Nejat Pishkenari*[1] and Taleb Abdollahi[2]**

[1]Faculty of Mechanical Engineering, Sharif University of Technology, Tehran, Iran
[2]Iranian Space Research Center, Tehran, Iran
* Corresponding author:(nejat@sharif.edu)

**Article Info**

**Article history:**

Received: 28 February 2026

Revised: 10 August 2026

Accepted: 2 September 2026

**Keywords:**

Attitude determination,
Satellite,
Artificial intelligence,
Sun sensor,
Earth sensor.

**Abstract**

Attitude determination is a critical component in the design and operation of satellites. This study presents a novel framework for estimating the attitude of a geosynchronous satellite by combining Sun and Earth sensors with artificial intelligence algorithms. Using raw sensor data led to poor or unsatisfactory results, with the best prediction error exceeding 10 degrees; therefore, the raw data were augmented through 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 demonstrated that the simultaneous and parallel use of four identical two-layer MLP models, each predicting a single quaternion component from the preprocessed data, coupled with output normalization, yielded a mean absolute error of 0.57 degrees. This approach outperformed the TRIAD algorithm by approximately 10%, the best classical method evaluated, and its computation time was shown to be compatible with real-time onboard execution. This hybrid approach offers a cost-effective and reliable solution for implementing attitude determination systems in satellites.

## Introduction

The Attitude Determination System (ADS) is a critical subsystem in satellite architecture, directly affecting communication, navigation, imaging, and stabilization performance [1]. Classical methods such as the Extended Kalman Filter (EKF), Unscented Kalman Filter (UKF), and algebraic approaches including TRIAD, QUEST, and Q-Method require precise dynamic modeling and known measurement noise, and their performance degrades under environmental noise, sensor delays, or singularity points [3], [4]. Recent advances in machine learning enable approaches that learn the hidden relationship between sensor data and rotation quaternions directly from training data, without explicit dynamic modeling [5].

Sensor selection is a key design factor: star trackers offer high accuracy but come at the expense of high cost, power, and complexity, while Sun and Earth sensors are simple, compact, and low-power, though individually insufficient for full three-axis determination [6], [7]. Prior studies combining multi-sensor data with deep learning — Kalman-filter-based star tracker and gyroscope fusion for TianHui-1 [8], an LSTM-based roll-angle estimator using GNSS jamming energy [9], and inertial-celestial navigation fusion using quaternions [10] — show that intelligent sensor fusion reduces dependence on explicit dynamics while improving accuracy in noisy, GEO environments.

This study proposes combining Sun and Earth sensors with artificial intelligence as a practical, real-time, low-cost solution for geosynchronous satellite attitude estimation. Synthetic datasets were generated from dynamic modeling of satellite motion, preprocessed using TRIAD and vector-based feature engineering, and used to train and compare multiple learning models for quaternion estimation [11].

**To Cite this article:**
Hajiwaysa, F., Nejat Pishkenari, H. and Abdollahi, T. 2026. Attitude determination of geosynchronous satellites with sun and earth sensors using artificial intelligence algorithms, Sharif Mechanical Engineering Journal, **42**(1), 105-117.
https://doi.org/10.24200/j40.2026.68496.1761

E-ISSN: 2676-4733 © 2026 The Author(s). Sharif Mechanical Engineering Journal, Published by Sharif University of Technology
This is an open access article under the CC-BY 4.0 license.

## Methodology

The satellite is assumed to be in a circular geosynchronous orbit with 23°30′ inclination. Two coordinate frames are defined: an orbital reference frame (index r), with its z-axis pointing toward Earth's center, and a body frame (index b) fixed to the satellite. The Sun and Earth are treated as stationary over short intervals (a few days), with the Sun-satellite-Earth system assumed coplanar and the satellite position fixed.

Raw data consist of four unit vectors representing Sun and Earth positions relative to the satellite in reference and body frames, computed via geometric relations and quaternion-based rotations (Eqs. 4–12), with Gaussian noise added to the body-frame vectors (Eqs. 13–14). Since raw vectors alone proved insufficient, additional features were engineered: dot products between Sun and Earth vectors in each frame, a cross-product vector representing rotation-axis information (Eq. 15), and twelve features derived from the classical TRIAD algorithm (Eqs. 16–21), addressing the algebraically overdetermined nature of the problem.

Eight models were trained and compared: Decision Tree, Random Forest, AdaBoost, CatBoost, HistGradientBoosting, XGBoost, LightGBM, and MLP, the latter in two architectures — four parallel single-output models and one four-output model. Accuracy was evaluated using the exact quaternion angular error (Eq. 22). Training used 12,996 samples generated by systematically varying $\beta$, $\gamma$ (0°–180°) and $\phi$ (0°–360°) in 10° steps; 2,600 random samples were used for validation and 100,000 for testing. Real-time feasibility was assessed by benchmarking local computing power (Dhrystone 2.1) against the RAD750 spaceborne processor [19] and comparing scaled inference time to typical GEO control cycle rates [20].

## Results and Discussion

Using raw sensor vectors without preprocessing gave poor accuracy, with the best prediction error exceeding 10 degrees, motivating the feature engineering described above. Preprocessing with TRIAD proved essential: without it, all models except MLP performed poorly, suggesting that tree-based algorithms struggle to approximate the continuous, trigonometric relationships underlying the raw vectors without explicit geometric guidance, whereas MLP's gradient-based optimization handles such relationships more effectively. The best results of various artificial intelligence models in estimating the rotation quaternions are presented in Table 1 and Figure 3.

Among tree-based and boosting algorithms, CatBoost achieved the best performance (MAE = 1.484°, 0.004 ms/sample), though still less accurate than TRIAD and the neural network models. Other models — LightGBM, XGBoost, HistGradientBoosting, Random Forest, Decision Tree, and AdaBoost — showed higher errors (2.56°–15.48°) despite very low prediction times.

TRIAD, evaluated on the same noisy test data, achieved 0.622° error. The four parallel MLP models trained on TRIAD-preprocessed data achieved the lowest error (0.57°), about 10% better than TRIAD, at 0.21 ms/sample .The same architecture without preprocessing yielded 0.656° error but achieved the fastest execution (0.090 ms), while a single four-output MLP achieved 0.622° at 0.157 ms.

This inverse accuracy-speed relationship, combined with real-time feasibility analysis (approximately 37.5 ms on RAD750, versus a 50–500 ms control-cycle budget), confirms the TRIAD-preprocessed parallel MLP as the most practical configuration.

## Conclusion

This study demonstrated a practical, low-cost framework for attitude determination of geosynchronous satellites using only Sun and Earth sensors combined with artificial intelligence algorithms. TRIAD-based preprocessing combined with a parallel four-model MLP architecture achieved the best balance of accuracy and computational efficiency, yielding a mean absolute error of 0.57° — approximately 10% better than the classical TRIAD algorithm alone — while remaining computationally compatible with real-time onboard execution. These results indicate that combining simple, low-cost sensors with appropriate preprocessing and learning-based estimation can serve as a viable alternative to more complex and expensive classical attitude determination systems. Future work should validate the proposed approach using real flight data, extend the analysis across the full orbital range, evaluate performance under measurement delays, and benchmark against optimal statistical estimators such as QUEST.

**Funding:** This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

**Conflicts of Interest:** The authors declare no conflict of interest.

**Author Contributions:** All authors contributed to the reported work for conceptualization, methodology, validation, writing-review and editing, and supervision.

مجله علمی مهندسی مکانیک شریف

https://sjme.journals.sharif.edu

مقاله‌ی پژوهشی

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

**فرید حاجی ویسه‌ء[۱]، حسین نجات پیشکناری*[۱] و طالب عبدالهی[۲]**

[۱] دانشکده‌ی مهندسی مکانیک، دانشگاه صنعتی شریف، تهران، ایران.

[۲] پژوهشگاه فضایی ایران، تهران، ایران.

*نویسنده مسئول (nejat@sharif.edu)

**اطلاعات مقاله**

**تاریخ دریافت : ۱۴۰۴/۱۲/۰۹**

**تاریخ اصلاحیه : ۱۴۰۵/۰۵/۱۹**

**تاریخ پذیرش : ۱۴۰۵ /۰۶/۱۱**

**واژگان کلیدی:**

تعیین وضعیت،

ماهواره،

هوش مصنوعی،

حسگر خورشید،

حسگر زمین.

**چکیده**

تعیین وضعیت، یکی از مؤلفه‌های حیاتی در طراحی و عملکرد سامانه‌های فضایی است. در پژوهش حاضر، چارچوبی نوین برای تخمین وضعیت یک ماهواره‌ی زمین‌آهنگ با ترکیب حسگرهای خورشید و زمین و استفاده 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 و یادگیری عمیق شامل روش‌های XGBoost، CatBoost، و شبکه‌ی عصبی چندلایه (MLP) برای تخمین کواترنیون‌های چرخش ارزیابی شده و نتایج نشان داده‌اند که استفاده‌ی هم‌زمان از چهار مدل MLP دو لایه‌ای با داده‌های پیش‌پردازش‌شده، همراه با نرمال‌سازی کواترنیون‌های خروجی، به میانگین خطای مطلق ۰/۵۷ درجه منجر می‌شود. رویکرد اخیر، تقریباً ۱۰٪ برتری عملکردی را در مقایسه با الگوریتم TRIAD از خود نشان داده و دقت مناسبی برای کاربردهای عملی و اجرای بلادرنگ فراهم ساخته است.

## ۱. مقدمه

سیستم تعیین وضعیت[1]، یکی از زیرسامانه‌های حیاتی در معماری فضایی است، که تعیین‌کننده‌ی جهت‌گیری بدنه‌ی ماهواره نسبت به یک چارچوب مرجع لَخت است. پارامتر مذکور مستقیماً در کیفیت عملکرد زیرسامانه‌های ارتباطی، ناوبری، تصویربرداری و پایدارسازی ماهواره اثرگذار هستند.[۱] علاوه‌بر تعیین وضعیت، طراحی سامانه‌های کنترل وضعیت مقاوم نیز از موضوع‌های مهم مرتبط با پایداری ماهواره‌هاست.[۲] به بیان دیگر، هرگونه خطا در برآورد جهت‌گیری ماهواره می‌تواند منجر به کاهش دقت مأموریت، افزایش مصرف انرژی، یا حتی از دست‌رفتن کامل کنترل شود.

در سیستم‌های کلاسیک تعیین وضعیت ماهواره، الگوریتم‌هایی نظیر فیلتر کالمن توسعه‌یافته (EKF)[2]، فیلتر کالمن بدون مدل خطی (UKF)[3]، و روش‌های جبری مانند TRIAD، QUEST، و Q-Method استفاده می‌شوند، که اغلب نیازمند مدل‌سازی دقیق دینامیک ماهواره و مشخص‌بودن نویز اندازه‌گیری هستند. با اینکه روش‌های اخیر در مأموریت‌های عملی متعدد نتایج قابل‌قبولی 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.[۳ و ۴]

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: XGBoost، LightGBM، CatBoost و شبکه‌های عصبی عمیق قادرند با یادگیری از داده‌های آموزشی حاصل از شبیه‌سازی، رابطه‌ی پنهان بین داده‌های سنسوری و کواترنیون‌های چرخش را استخراج کنند و در زمان آزمون عملکردی دقیق و سریع ارائه دهند.[۵]

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

[1] Attitude Determination System
[2] Extended Kalman Filter
[3] Unscented Kalman Filter

**استناد به این مقاله:**

حاجی ویسه‌ء، فرید، نجات پیشکناری، حسین و عبدالهی، طالب، ۱۴۰۵. تعیین وضعیت یک ماهواره‌ی زمین‌آهنگ مجهز به حسگرهای خورشید و زمین با استفاده از الگوریتم‌های هوش مصنوعی. مهندسی مکانیک شریف، ۴۲(۱)، صص.۱۰۵-۱۱۷. https://doi.org/10.24200/j40.2026.68496.1761

شاپا الکترونیکی: ۴۷۳۳- ۲۶۷۶

حق مولف © نویسندگان

ناشر: دانشگاه صنعتی شریف

هزینه، توان مصرفی، و پیچیدگی بالایی دارند. در مقابل، سنسورهای خورشید[4] و زمین[5] 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.[۶ و ۷]

در این راستا، پژوهش‌های اخیر نشان داده‌اند که ترکیب داده‌های حسگرها و بهره‌گیری از الگوریتم‌های یادگیری عمیق[6] می‌تواند دقت و پایداری تعیین وضعیت را به شکل چشمگیری افزایش دهد. برای نمونه، الگوریتمی تلفیقی بر پایه‌ی فیلتر کالمن و روش کمینه‌ی مربعات برای ادغام داده‌های ستاره‌یاب و ژیروسکوپ در ماهواره‌ی سنجش از دور TianHui-۱ ارائه شده است، که با داده‌های واقعی پروازی آزموده شده و دقتی در حدود چند ثانیه‌ی قوسی به‌دست آورده است.[۸] همچنین روشی نوین مبتنی بر انرژی تداخل سیگنال‌های ماهواره‌های زمین‌آهنگ[7] و شبکه‌ی عصبی LSTM برای تعیین وضعیت رول وسایل در حال دوران معرفی شده است، که با یادگیری رابطه‌ی میان انرژی دریافتی سیگنال (GNSS)[8] و زاویه‌ی رول، توانسته است خطای میانگین را نسبت به روش کمینه‌ی مربعات تا حدود ۴۹٪ کاهش دهد.[۹] همچنین در پژوهشی دیگر، با تلفیق سامانه‌ی ناوبری اینرسی و حسگر ستاره‌نگر (سماوی) به‌کمک فیلتر کالمن درجه‌ی دوم و بهره‌گیری از کواترنیون‌ها برای کاهش بار محاسباتی و پیشگیری از تکینگی، خطاهای سرعت و موقعیت در ابتدای فعالیت حسگر ستاره‌نگر با دقت مناسبی جبران شده،[۱۰] و سه مطالعه‌ی اخیر نشان داده‌اند که ترکیب هوشمند داده‌های چندحسگره و مدل‌های یادگیری عمیق، نه‌فقط وابستگی به مدل‌سازی دینامیکی صریح را کاهش می‌دهند، بلکه دقت و پایداری تعیین وضعیت را در محیط‌های پرنویز و مأموریت‌های GEO به شکل محسوسی بهبود می‌بخشند.

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. در پژوهش حاضر، با بهره‌گیری از مدل‌سازی دینامیکی حرکت ماهواره و تولید داده‌های مصنوعی بردارهای یکه‌ی خورشید و زمین در چارچوب‌های مداری[9] و بدنی[10]، یک دیتاست بزرگ با درنظرگرفتن نویز تصادفی ایجاد کرده است. در ادامه، داده‌ها با روش‌هایی مانند الگوریتم کلاسیک TRIAD، تخمین بردار چرخش اویلر، و ضرب داخلی و خارجی بردارهای مختلف پیش‌پردازش شده‌اند، تا بهبود دقت مدل‌های یادگیرنده حاصل شود. سپس مجموعه‌ای از الگوریتم‌های یادگیری ماشین[11] و یادگیری عمیق روی داده‌های اخیر اعمال شده‌اند و عملکرد آن‌ها از نظر دقت در تخمین کواترنیون‌های چرخش مقایسه شده است. علاوه‌بر 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 شود.

نتایج به‌دست‌آمده نشان داده‌اند که با ترکیب مناسب پیش‌پردازش بردارهای سنسوری با مدل‌های شبکه‌ی عصبی چندلایه (MLP)[12] می‌توان به دقتی در حدود ۰/۵۷ درجه در تخمین بردار چرخش دست یافت. این میزان دقت نه تنها از دقت روش جبری کلاسیک بررسی‌شده در پژوهش حاضر 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 به‌عنوان رویکردی مؤثر در طراحی نسل جدید سیستم‌های تعیین وضعیت ماهواره‌ها مطرح شود.[۱۱]

### ۱.۱. مدار زمین‌آهنگ

ماهواره‌های زمین‌آهنگ، در یک مدار دایروی با ارتفاع مداری حدود ۳۶۰۰۰ کیلومتر و زاویه‌ی میل مداری غیرصفر درجه (غیراستوایی) گردش می‌کنند. دوره‌ی زمانی یک بار چرخش کامل ماهواره‌های مذکور در مدار خود برابر با دوره‌ی 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 ۱ الی ۳ برای حرکت این ماهواره‌ها برقرار خواهد بود:

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

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

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

که در آن‌ها، $m_e$ بیانگر جرم زمین، $m_s$ جرم ماهواره، $r_{se}$ فاصله‌ی مرکز زمین تا ماهواره، $G$ ثابت جهانی گرانش[13]، $v_s$ سرعت خطی ماهواره، و $\omega$ بیانگر سرعت زاویه‌ای گردش زمین به دور خود و سرعت زاویه‌ای مداری ماهواره هستند.

با استفاده از روابط اخیر، شعاع دوران این مدل از ماهواره‌ها حدود ۴۲۰۰۰ کیلومتر به‌دست خواهد آمد، که تقریباً ۶/۶۱ برابر شعاع زمین است. این تذکر لازم است که روابط ۱ الی ۳ بر پایه‌ی فرض مدار دایروی کامل استخراج شده‌اند، که برای مدار زمین‌آهنگ بررسی‌شده در پژوهش حاضر، تقریب مناسبی محسوب می‌شود. این روابط برای مدارهای غیردایروی معتبر نیستند و در صورت تعمیم پژوهش حاضر به چنین مدارهایی، لازم است از معادله‌های دینامیکی عمومی‌تر استفاده شود.

ماهواره‌ی بررسی‌شده در پژوهش حاضر در مداری زمین‌آهنگ با زاویه‌ی میل[14] ۲۳ درجه و ۳۰ دقیقه در گردش است و در واقع در صفحه‌ی مدار گردش زمین به دور خورشید قرار دارد.

### ۲.۱. دستگاه‌های مختصات فضایی

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

**I. دستگاه مختصات مداری**

[4] Sun Sensor
[5] Earth Sensor
[6] Deep Learning
[7] Geosynchronous
[8] Global Navigation Satellite System
[9] Orbital Frame
[10] Body Frame
[11] Machine Learning
[12] Multi-Layer Perceptron
[13] Gravitational Constant
[14] Inclination Angle

مبدأ دستگاه مختصات مداری در مرکز جرم ماهواره قرار دارد و جهت‌گیری آن به‌گونه‌ای انتخاب می‌شود که محور $z$ آن همواره به سمت مرکز زمین باشد. محور $x$ در راستای بردار سرعت مداری ماهواره قرار دارد و محور $y$ مطابق قاعده‌ی دست راست نسبت به دو محور دیگر حاصل می‌شود. دستگاه مذکور معمولاً با اندیس $r$ یا $o$ نمایش داده می‌شود.

### II. دستگاه مختصات بدنی

دستگاه مختصات بدنی، هم‌مرکز با دستگاه مداری است، اما به بدنه‌ی ماهواره متصل است و محورهای آن هم‌راستا با محورهای اصلی ماهواره هستند و همراه با آن دوران می‌یابد. دستگاه بدنی جهت نمایش وضعیت لحظه‌ای ماهواره به‌کار 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 بازه‌ی زمانی کوتاه (در حد چند روز) به‌ترتیب به‌عنوان 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 قابل‌چشم‌پوشی در 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. درنظرگرفتن حرکت مداری زمین به دور خورشید در مقیاس زمانی کوتاه موردنظر در پژوهش حاضر، فقط منجر به تکرار عملی داده‌ها در مجموعه‌ی آموزشی می‌شود و تأثیر معنی‌داری در دقت مدل ندارد.

علاوه‌بر 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 (دایرة البروج) قرار دارند. همچنین برای کاهش پیچیدگی‌های هندسی، شکل‌های خورشید و زمین به صورت کره‌های کامل و ماهواره به‌صورت یک نقطه‌ی جرم‌دار در نظر گرفته شده‌اند. مدار چرخش ماهواره نیز به‌صورت دایره‌ای کامل فرض شده‌اند، تا بتوان روابط تحلیلی دوران را با دقت مناسب و پیچیدگی کمتر مدل‌سازی کرد. همچنین در ادامه ذکر شده است که ماهواره در یک نقطه از مدار، ثابت در نظر گرفته می‌شود.

با توجه به فرضیات ذکرشده، تخمین وضعیت برای ماهواره در یک نقطه‌ی خاص انجام و در پژوهش‌های آینده، با تلفیق نتایج به‌دست‌آمده از نقاط مختلف مداری، امکان تعیین وضعیت برای کل مدار فراهم می‌شود.

شایان ذکر است که چارچوب پیشنهادی در پژوهش حاضر از نظر ساختاری مستقل از نوع مدار است و اصولاً برای سایر مدارها (از جمله LEO یا مدارهای بیضوی) نیز قابل‌استفاده است. آنچه در پژوهش حاضر مختص مدار زمین‌آهنگ است، دیتاستِ تولیدشده و وزن‌های آموزش‌دیده‌ی مدل‌ها هستند، که براساس پارامترهای مداری خاص مدار زمین‌آهنگ (شعاع مداری، و سرعت زاویه‌ای گردش) ساخته شده‌اند. به‌کارگیری چارچوب اخیر برای مدارهای دیگر، مستلزم تولید دیتاستِ متناظر با پارامترهای همان مدار و آموزش مجدد شبکه است، اما نیازی به بازطراحی الگوریتم نیست.

## ۳. حسگرها[15]

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

در پژوهش حاضر، 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، یعنی حسگر خورشید و حسگر زمین مجهز است و به این شرح معرفی می‌شوند:

**I. حسگر خورشید:** حسگر خورشید با استفاده از اختلاف شدت تابش خورشید در میدان دید خود، جهت‌گیری خورشید را نسبت به ماهواره تعیین می‌کند. در چارچوب پژوهش حاضر، خروجی حسگر خورشید به‌صورت یک بردار یکه تعریف شده است، که موقعیت مرکز خورشید را نسبت به ماهواره در دستگاه مختصات بدنی نمایش می‌دهد.

**II. حسگر زمین:** حسگر زمین با جمع‌آوری و تحلیل پرتوهای نوری منتشرشده از سطح زمین، موقعیت نسبی زمین نسبت به ماهواره را تخمین می‌زند. در مطالعه‌ی حاضر، خروجی حسگر زمین نیز به‌صورت یک بردار یکه در نظر گرفته شده است، که موقعیت مرکز زمین را نسبت به ماهواره در چارچوب مختصات بدنی بیان می‌کند.

در طراحی سامانه‌ی تعیین وضعیت پژوهش، از حسگر مغناطیس‌سنج به‌عنوان منبع اطلاعاتی استفاده نشده است. دلیل اصلی انتخاب اخیر، ماهیت ضعیف و کم‌دقت میدان مغناطیسی زمین در مدار زمین‌آهنگ است؛ در این ارتفاع مداری، شدت میدان مغناطیسی زمین به‌شدت کاهش می‌یابد و به مقادیری در حد چند نانوتسلا می‌رسد، که نسبت به نویزهای محیطی نسبت سیگنال‌به‌نویز پایینی دارد. علاوه‌بر این، استفاده 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 پژوهش حاضر، تمرکز بر حسگرهای خورشید و زمین محفوظ بوده است و بررسی افزودن مغناطیس‌سنج یا سایر حسگرهای تکمیلی به‌عنوان یکی از موضوع‌های پژوهش‌های آینده پیشنهاد می‌شود.

## ۴. جمع‌آوری داده‌ها

داده‌های خام استفاده‌شده در پژوهش حاضر، شامل چهار بردار یکه بوده‌اند، که موقعیت نسبی دو جسم آسمانی خورشید و زمین را نسبت به ماهواره در دو چارچوب مختصات مختلف نمایش می‌دهند. این بردارها عبارت‌اند از:

[15] Sensors

۱. بردار یکه‌ی موقعیت خورشید نسبت به ماهواره در دستگاه مختصات مرجع،

۲. بردار یکه‌ی موقعیت خورشید نسبت به ماهواره در دستگاه مختصات بدنی،

۳. بردار یکه‌ی موقعیت زمین نسبت به ماهواره در دستگاه مختصات مرجع،

۴. بردار یکه‌ی 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 دستگاه مذکور، همواره مقداری ثابت دارد، که در رابطه‌ی ۴ آمده است:

$$E_r = \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} \quad (4)$$

برای تعیین بردار یکه‌ی 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 صفحه‌ی مدار زمین به دور خورشید و هم‌جهت با محور $y$ دستگاه مداری، محور $x$ درون این صفحه و به سمت زمین باشد و محور $z$ طبق قاعده‌ی دست راست تعیین شود.

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

$$S_i = \begin{bmatrix} -(SS)\cos(\alpha) & 0 & -(SS)\sin(\alpha) \end{bmatrix} \quad (5)$$

که در آن، SS (Sun to Satellite) فاصله‌ی بین خورشید و ماهواره، و $\alpha$ موقعیت زاویه‌ای ماهواره نسبت به محور $x$ دستگاه $i$ هستند.

چون در پژوهش حاضر، زمین به‌صورت یک کره‌ی ثابت با موقعیت زاویه‌ای صفر درجه نسبت به محور $x$ دستگاه $i$ در نظر گرفته شده و واحد نجومی (فاصله‌ی بین خورشید و زمین) بیش از ۳۵۰۰ برابر بزرگ‌تر از فاصله‌ی بین زمین و ماهواره بوده است، موقعیت لحظه‌ای خورشید نسبت به زمین در دستگاه $i$ به‌صورت معادله‌ی ۶ تعریف می‌شود:

$$(AU \approx SS, \alpha = 0) \rightarrow S_i = \begin{bmatrix} -AU & 0 & 0 \end{bmatrix} \quad (6)$$

برای تبدیل این بردار به دستگاه مداری ماهواره، با توجه به هم‌صفحه‌بودن محورهای $y$ در دو دستگاه، از یک دوران دوبُعدی استفاده و ماتریس تبدیل رابطه‌ی 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 در آن، $\theta$ زاویه‌ی دوران حول محور $y$ برای تبدیل دستگاه خورشید مرکز به دستگاه مداری است. با اعمال تبدیل رابطه‌ی ۷، بردار موقعیت خورشید در دستگاه $r$ به‌صورت رابطه‌ی ۸ به‌دست می‌آید:

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

در روابط اخیر، پارامتر ورودی فقط زاویه‌ی $\theta$ است، که از آن موقعیت لحظه‌ای خورشید نسبت به ماهواره در دستگاه مداری استنتاج می‌شود.

با توجه به ماهیت ایستای ماهواره در مدار زمین‌آهنگ، در پژوهش حاضر، تحلیل‌ها بر مبنای موقعیت ماهواره در زاویه‌ی $\theta = 270°$ انجام شده‌اند. این فرض موجب ساده‌سازی روابط هندسی و دینامیکی سیستم می‌شود 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، در حالی که دستگاه خورشید مرکز نسبت به راستای زمین- خورشید ثابت باقی می‌ماند، پس زاویه‌ی $\theta$ در واقع معادل موقعیت زاویه‌ای لحظه‌ای ماهواره روی مسیر مداری آن است. بر این اساس، با تغییر مقدار $\theta$ می‌توان موقعیت ماهواره را در نقاط مختلف مدار جابجا کرد. همچنین می‌توان برای هر نقطه، داده‌ی متناظر را بدون نیاز به بازتعریف کامل مدل دینامیکی تولید کرد.

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 دستگاه‌های مرجع و بدنی، از چارچوب کواترنیونی برای توصیف دوران استفاده شده است. بر اساس قضیه‌ی اویلر، هر دوران سه‌بُعدی را می‌توان با یک بردار جهت (محور دوران) و یک زاویه‌ی دوران مشخص کرد؛ که کواترنیون[16] متناظر با آن به‌صورت رابطه‌ی 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 $\phi$ زاویه‌ی دوران هستند. 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 رابطه‌ی ۱۱ نشان داد:

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

که در آن، $\beta$ بیانگر زاویه‌ی بردار دوران نسبت به صفحه‌ی $xy$ دستگاه مرجع و $\gamma$ بیانگر زاویه‌ی تصویر بردار دوران در صفحه‌ی $xy$ نسبت به محور $x$ در دستگاه دوران هستند. این پارامترسازی زاویه‌ای بردار واحد جهت دوران، مبنای تولید نظام‌مند مجموعه‌داده‌ی آموزشی در پژوهش حاضر است؛ به‌طوری که در بخش ۸، پیمایش فضای کامل دوران با تغییر گام‌به‌گام زوایای $\beta$ و $\gamma$ (به‌همراه زاویه‌ی دوران $\phi$ در رابطه‌ی ۹) در بازه‌های تعریف‌شده صورت می‌گیرد و برای هر ترکیب از زوایای اخیر، یک بردار دوران و در نتیجه یک کواترنیون متناظر تولید می‌شود.

[16] Quaternion

مزیت اصلی استفاده از کواترنیون‌ها نسبت به زوایای اویلر، نبود نقاط تکینگی و پایداری عددی بالاتر در محاسبات است. ماتریس دوران از دستگاه مرجع به دستگاه بدنی با استفاده از کواترنیون به شکل رابطه‌ی 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 ماتریس اخیر، بردارهای موقعیت زمین و خورشید در دستگاه بدنی پس از اضافه‌کردن نویز به‌صورت روابط ۱۳ و ۱۴ محاسبه می‌شوند:

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

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

که در آن‌ها، $N$ بیانگر توزیع تصادفی گاوسی (نرمال) است. چهار بردار به‌دست‌آمده در معادله‌های ۴، ۸، ۱۳ و ۱۴، تشکیل‌دهنده‌ی داده‌های خام استفاده‌شده در فرایند یادگیری هستند. با این حال، آزمایش‌ها نشان داده‌اند که فقط استفاده از داده‌های خام مذکور، منجر به تخمینی با دقت پایین و خطاهای قابل‌توجه می‌شود. از این رو، برای افزایش دقت تخمین و غنی‌سازی ویژگی‌های ورودی، از پیش‌پردازش داده‌ها استفاده شده است؛ که شامل: ترکیب بردارها، استخراج ویژگی‌های هندسی جدید، و اعمال الگوریتم‌های کلاسیک مانند TRIAD هستند، که در ادامه تشریح شده‌اند.

## ۵. پیش‌پردازش[17] داده‌های خام

با توجه به تعداد محدود ویژگی‌های اولیه (چهار بردار یکه)، لازم است که برای بهبود عملکرد مدل‌های یادگیری ماشین و یادگیری عمیق، اطلاعات بیشتری از ساختار هندسی داده‌ها استخراج شوند. به همین منظور، با انجام عملیات برداری روی داده‌های خام، ستون‌های جدیدی به مجموعه‌ی داده افزوده شده است، تا الگوهای نهفته در روابط 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، زاویه‌ی 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 ویژگی ذکرشده، دو ستون جدید شامل ضرب داخلی بین بردارهای خورشید و زمین در دستگاه مرجع و نیز در دستگاه بدنی به مجموعه‌ی داده افزوده شده‌اند. این مقادیر به‌طور ضمنی زاویه‌ی بین بردارهای خورشید و زمین را به الگوریتم یادگیری منتقل می‌کنند و به این ترتیب می‌توان بخشی از اطلاعات دوران سه‌بُعدی را برای مدل قابل فهم کرد. علاوه‌بر این، یک راهکار مؤثر دیگر برای آموزش بهتر مدل‌ها، افزودن برداری در راستای محور چرخش دستگاه بدنی نسبت به دستگاه مرجع است؛ که در دستگاه مرجع تعریف می‌شود و با استفاده از ضرب خارجی تفاضل بردارهای زمین و خورشید در دو دستگاه مطابق رابطه‌ی ۱۵ محاسبه می‌شود:

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

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

از آنجا که روابط میان بردارهای مذکور 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. الگوریتم TRIAD، که معمولاً در تعیین نگرش کاربرد دارد، یکی از بردارها را به‌عنوان بردار با دقت بالاتر انتخاب می‌کند (در پژوهش حاضر، بردار خورشید به‌دلیل خطای کمتر حسگر)، و با استفاده از آن، ماتریس دوران را تخمین می‌زند. گام‌های تشکیل ماتریس دوران در معادله‌های ۱۶ تا ۲۱ ارائه شده‌اند:

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

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

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

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

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

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

از آنجا که بردارهای $S_b$ و $S_r$ در داده‌های خام موجود هستند، فقط کافی است بردارهای تولیدشده از معادله‌های ۱۸ الی ۲۱ به‌عنوان ویژگی‌های جدید به داده‌ها اضافه شوند. در مجموع، ۱۲ ویژگی جدید (سه مؤلفه برای هر بردار خروجی) به ماتریس ویژگی‌ها افزوده شده است. این کار باعث شده است که مدل‌های پیچیده‌تر هوش مصنوعی (مانند شبکه‌های عصبی چندلایه) بتوانند بدون بروز پدیده‌ی برازش بیش از حد[18]، 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 به‌طور ذاتی توابعی قطعی و غیرخطی از همان چهار بردار یکه‌ی خام هستند و اندازه‌گیری یا اطلاعات مستقل جدیدی به مجموعه‌داده اضافه نمی‌کنند. این وابستگی، ناشی از خطای طراحی نیست، بلکه رویکردی متداول در مهندسی ویژگی[19] است؛ که هدف از افزودن آن‌ها، ارائه‌ی بازنمایی صریح‌تری از روابط هندسی و مثلثاتی نهفته در داده‌های خام به مدل‌هاست، تا فرآیند یادگیری روابط غیرخطی اخیر تسهیل شود، نه آنکه اطلاعات جدیدی به سیستم اضافه شود.

این تذکر لازم است که الگوریتم TRIAD، یک تخمین‌گر بهینه از منظر آماری نیست. مسئله‌ی بررسی‌شده در پژوهش حاضر به لحاظ جبری بیش‌تعیین‌شده است، و این افزونگی اطلاعاتی می‌تواند برای بهبود دقت تخمین در حضور نویز سنسوری استفاده شود. الگوریتم TRIAD، فقط یکی از بردارها (در اینجا بردار خورشید، به‌دلیل دقت بالاتر حسگر) را کاملاً معتبر فرض کرده و بردار دوم، فقط برای تکمیل دستگاه مختصات به کار رفته است؛ بدین ترتیب، الگوریتم TRIAD، وزنی متناسب با کوواریانس نویز هر حسگر به بردارها اختصاص نمی‌دهد. در همین راستا، مدل‌های یادگیری ماشین به‌کاررفته در پژوهش حاضر، با دسترسی هم‌زمان به بردارهای خام، خروجی TRIAD، و ویژگی‌های

[17] Preprocess
[18] Overfitting
[19] Feature Engineering

هندسی افزوده، عملاً قادرند به‌صورت داده‌محور، یک تصحیح غیرخطی بر پایه‌ی ساختار آماری نویز اعمال کنند.

## ۶. تخمین کواترنیون‌ها و سنجش خطا

به‌منظور تخمین دقیق کواترنیون‌های نشان‌دهنده‌ی وضعیت ماهواره، از شبکه‌ی عصبی چندلایه مبتنی بر یادگیری عمیق و همچنین ۷ الگوریتم پرکاربرد در حوزه‌ی یادگیری ماشین استفاده شده است؛ که عبارت‌اند از:

- Decision Tree
- Random Forest
- AdaBoost
- Cat Boost
- Hist Gradient Boosting
- XGBoost
- Light GBM

درخت‌های تصمیم[۲۰]، مدل‌هایی غیرپارامتری هستند که با تقسیم‌بندی تکرارشونده‌ی فضای ویژگی به نواحی همگن، امکان مدل‌سازی روابط غیرخطی میان ورودی‌ها و متغیر هدف را فراهم می‌سازند.[۱۲]

جنگل‌های تصادفی[۲۱]، از جمله روش‌های تجمیعی هستند که مجموعه‌ای بزرگ از درخت‌های تصمیم را بر روی زیرمجموعه‌های بوت‌استرپ‌شده از داده‌های آموزشی می‌سازند و خروجی نهایی را از میانگین‌گیری پیش‌بینی‌های آن‌ها به‌دست می‌آورند. این رویکرد موجب کاهش واریانس و بهبود توان تعمیم مدل در مقایسه با یک درخت منفرد می‌شود.[۱۳]

AdaBoost یک روش تجمیعی است که با ترکیب تکرارشونده‌ی مجموعه‌ای از یادگیرنده‌های ضعیف — که معمولاً درخت‌های تصمیم کم‌عمق هستند — و با بازوزن‌دهی تطبیقی نمونه‌های آموزشی براساس خطاهای پیشین، یک پیش‌بین قدرتمند ایجاد می‌کند. این سازوکار موجب تمرکز یادگیرنده‌های بعدی بر نمونه‌های دشوار می‌شود و درنهایت، دقت مدل را افزایش و سوگیری آن را کاهش می‌دهد.[۱۴]

Cat Boost یک الگوریتم گرادیان بوستینگ است که برای پردازش کارآمد متغیرهای دسته‌ای و کاهش سوگیری پیش‌بینی از طریق ordered boosting و کمینه‌سازی target leakage طراحی شده است. الگوریتم Cat Boost از درخت‌های تصمیم متقارن[۲۲] بهره می‌برد، که ضمن افزایش کارایی محاسباتی و توان تعمیم، امکان مدل‌سازی روابط پیچیده و غیرخطی را فراهم می‌سازند.[۱۵]

الگوریتم‌های Light GBM و گرادیان بوستینگ مبتنی بر هیستوگرام (HGB)[۲۳] بر پایه‌ی بهینه‌سازی مبتنی بر هیستوگرام عمل می‌کنند؛ بدین صورت که متغیرهای پیوسته پیش از آموزش به بازه‌های هیستوگرامی گسسته‌سازی می‌شوند، تا جستجوی نقاط تقسیم به‌صورت بسیار کارآمد و با مصرف کمتر حافظه انجام شود و سرعت آموزش به‌طور قابل‌توجهی افزایش یابد. Light GBM، چارچوب اخیر را با نوآوری‌هایی همچون رشد برگ‌محور درخت‌ها، نمونه‌برداری یک‌طرفه مبتنی بر گرادیان (GOSS)[۲۴] و تجمیع انحصاری ویژگی‌ها (EFB)[۲۵] گسترش می‌دهد و به‌ویژه در داده‌های پربُعد و پُرنویز عملکرد قدرتمندی ارائه می‌کند. در مقابل، HGB در نسخه‌ی پیاده‌سازی‌شده در scikit-learn از اصل گسسته‌سازی هیستوگرامی مشابه استفاده می‌کند و توانایی مدل‌سازی روابط غیرخطی را در کنار مقیاس‌پذیری محاسباتی بالا فراهم می‌سازد.[۱۶]

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 استفاده می‌شود. علاوه‌بر این، الگوریتم XGBoost با به‌کارگیری بهینه‌سازی‌های سطح سیستم، نظیر ساخت موازی درخت‌ها و تخصیص حافظه‌ی مبتنی بر معماری سخت‌افزار، امکان آموزش سریع بر روی داده‌های پیچیده را فراهم می‌سازد.[۱۷]

MLP یک شبکه‌ی عصبی پیش‌خور است، که از چند لایه‌ی کاملاً متصل تشکیل شده است و با یادگیری نگاشت‌های سلسله‌مراتبی و غیرخطی بین ورودی‌ها و خروجی‌ها عمل می‌کند. فرایند آموزش شبکه‌ی MLP با استفاده از الگوریتم پس‌انتشار خطا[۲۶] انجام می‌شود، که طی آن وزن‌های شبکه به‌صورت تکراری به‌روزرسانی می‌شوند و خطای پیش‌بینی کاهش می‌یابد. معماری اخیر، توانایی مدل‌سازی روابط پیچیده و غیرخطی و همچنین استخراج تعامل‌های نهان میان ویژگی‌های حسگری (ویژگی‌هایی که در مسائل تعیین وضعیت ماهواره معمولاً مشاهده می‌شوند)، را دارد.[۱۸]

هر یک از مدل‌های ذکرشده 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. لذا، برای ارزیابی دقیق، داده‌ها در سه سناریوی مختلف پیش‌پردازش، شامل: ویژگی‌های افزوده‌شده مبتنی بر ضرب داخلی، بردار تقریبی محور دوران، و الگوریتم TRIAD استفاده شده و مدل‌ها به‌صورت جداگانه برای هر حالت آموزش دیده‌اند.

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

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

به منظور همگرایی بهتر مدل‌های MLP در مرحله‌ی آموزش، برای هر مدل از یک ساختار مشابه از قبل آموزش‌دیده و پس از اتمام آموزش اولیه، بهترین وزن‌های به‌دست‌آمده جهت مقداردهی اولیه‌ی مدل اصلی استفاده شده‌اند. همچنین برای افزایش سرعت اجرای فرآیند آموزش و تخمین، از روش

[20] Decision Trees
[21] Random Forests
[22] Oblivious Trees
[23] Histogram-based Gradient Boosting
[24] Gradient-based One-side Sampling
[25] Exclusive Feature Bundling
[26] Back Propagation

**جدول ۱. نتایج تخمین کواترنیون‌ها با استفاده از مدل‌های مختلف هوش مصنوعی.**

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

| Preprocess Method | Model | Model Properties | Mean Absolute Error | Prediction Time Per Sample |
|---|---|---|---|---|
| TRIAD | Light GBM | Lr=0.03, n-es=10000 Max-depth=8 | 2.56° | 2.243 $ms$ |
| TRIAD | XGBoost | Lr=0.01, n-es=10000 Max-depth=5 | 2.94° | 0.054 $ms$ |
| TRIAD | Hist Gradient Boost | Lr=0.08, Max-depth=10 | 3.34° | 0.004 $ms$ |
| TRIAD | Cat Boost | Lr=0.001, n-es=10000 Max-depth=10 | 1.484° | 0.004 $ms$ |
| TRIAD | Random Forest | Max-depth=17 | 3.18° | 0.013 $ms$ |
| TRIAD | Decision Tree | - | 6.62° | 0.001 $ms$ |
| TRIAD | AdaBoost | Lr=0.03, n-es=1000 | 15.48° | 0.153 $ms$ |
| - | TRIAD | Algebraic Method | 0.622° | 0.12 $ms$ |
| 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 $ms$ |
| - | 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 $ms$ |
| 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 $ms$ |

چندریسمانی[۲۷] استفاده شده است، تا محاسبات مربوط به هر مدل به‌صورت هم‌زمان انجام شود.

به‌منظور فراهم‌آوردن معیاری منصفانه برای مقایسه‌ی عملکرد مدل‌های یادگیری ماشین با روش کلاسیک، خطای الگوریتم TRIAD نیز دقیقاً بر روی همان مجموعه‌داده‌ی آزمون و با استفاده از همان بردارهای نویزدار خورشید و زمین در دستگاه بدنی محاسبه شده است، بدون آنکه هیچ مرحله‌ی یادگیری بر روی آن اعمال شود. بدین ترتیب، مقدار خطای ۰/۶۲۲ درجه‌ی گزارش‌شده 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 استفاده‌شده، فقط شبکه‌ی عصبی چندلایه، عملکردی قابل‌مقایسه و در برخی موارد برتر نسبت به الگوریتم کلاسیک TRIAD از خود نشان داده است. به همین دلیل، علاوه‌بر ساختار چهار مدلی موازی، یک مدل MLP دیگر نیز طراحی و آموزش داده شده است، که هر چهار مؤلفه‌ی کواترنیون را به‌طور هم‌زمان در خروجی تولید می‌کند. نتایج مدل اخیر نشان داده است که ضمن حفظ دقت مناسب، زمان اجرای آن به‌طورمحسوسی کاهش یافته است. تحلیل تفصیلی نتایج این ساختار در بخش ۸ 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 بردار ثابت موقعیت زمین در نتایج، آزمایش‌های مقایسه‌ای با حذف و بدون حذف بردار موقعیت زمین از مجموعه‌ی ویژگی‌های ورودی انجام شده است؛ که نشان می‌دهد حضور یا عدم حضور آن تأثیر معناداری در دقت مدل‌ها ندارد.

در مرحله‌ی پس‌پردازش نیز کواترنیون‌های تخمین‌زده‌شده نرمال‌سازی شده‌اند، تا شرط نرمال‌بودن کواترنیون‌ها ($|q|=1$) برقرار باشد و از بروز خطاهای عددی در محاسبات تعیین وضعیت جلوگیری شود.

برای ارزیابی دقت تخمین کواترنیون‌ها، از خطای زاویه‌ای دقیق بین کواترنیون حقیقی و کواترنیون تخمین‌زده‌شده با واحد درجه استفاده شده است، که مطابق رابطه‌ی ۲۲ محاسبه می‌شود:

[27] Multi-threading

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

که در آن، $q_r$ کواترنیون مرجع (حقیقی) و $q_e$ کواترنیون تخمین زده‌شده هستند، و علامت $\cdot$ نشان‌دهنده‌ی ضرب داخلی در فضای چهاربُعدی است. این شاخص به‌دلیل ماهیت هندسی کواترنیون‌ها، ارزیابی دقیقی از فاصله‌ی چرخشی بین دو وضعیت ارائه می‌دهد.

## ۷. ارزیابی امکان‌پذیری اجرای بلادرنگ

با توجه به اینکه هدف نهایی پژوهش حاضر، 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 پژوهش حاضر فراهم نبوده است، ارزیابی امکان‌پذیری اجرای بلادرنگ از طریق مقایسه‌ی توان محاسباتی سامانه‌ی توسعه (رایانه استفاده‌شده برای آموزش و آزمون مدل‌ها) با یکی از پردازنده‌های استاندارد و پرکاربرد صنعت فضایی انجام شده است.

پردازنده‌ی مبنا برای مقایسه‌ی انجام‌شده، RAD750 ساخت شرکت BAE Systems بوده است؛ که به‌طورگسترده در مأموریت‌های فضایی متعدد به‌عنوان واحد پردازش مرکزی onboard استفاده می‌شود. طبق گزارش رسمی سازنده، پردازنده‌ی مذکور 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.[۱۹]

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، مستقیماً اندازه‌گیری شده است؛ که نتیجه‌ی آن، توان پردازشی معادل ۴۲۹۰۶ Dhrystone-MIPS (تک‌هسته) در فرکانس ۲۳۰۰ مگاهرتز را نشان داده است.

با توجه به اینکه فرآیند استنتاج (inference) برای یک نمونه‌ی ورودی به‌صورت تک‌رشته‌ای انجام می‌شود، ضریب کُندی پردازنده‌ی RAD750 نسبت به سامانه‌ی توسعه تقریباً برابر با ۱۷۹ می‌شود. با اعمال ضریب اخیر 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 شده است.

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

شایان ذکر است که این تحلیل یک برآورد نظری مبتنی بر مقیاس‌دهی توان پردازشی اندازه‌گیری‌شده 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 به‌دست‌آمدن نتایج پژوهش حاضر، در مجموع از ۱۲۹۹۶ داده‌ی آموزشی (داده‌هایی که پوشش کامل فضای دوران و تنوع کافی برای یادگیری مدل را تضمین می‌کردند)، انتخاب شده‌اند.

به‌منظور پوشش تمامی حالت‌های ممکن بردار جهت دوران و زاویه‌ی دوران، زوایای $\gamma$ و $\phi$ با گام‌های ۱۰ درجه‌ای در بازه‌ی صفر تا ۱۸۰ درجه و زاویه‌ی $\beta$ با گام ۱۰ درجه‌ای در بازه‌ی صفر تا ۳۶۰ درجه تغییر یافته و مجموعه‌ی حاصل به‌عنوان داده‌های آموزشی مدل‌ها استفاده شده‌اند.

برای اعتبارسنجی مدل‌ها، ۲۶۰۰ داده (تقریباً معادل ۰/۲ داده‌های آموزشی) تولید شده‌اند، که در آن‌ها زوایای $\gamma$، $\phi$، و $\beta$ به‌صورت تصادفی[۲۸] و در بازه‌های تعریف‌شده انتخاب شده‌اند. درنهایت، برای آزمون نهایی مدل‌ها، ۱۰۰۰۰۰ داده‌ی مشابه داده‌های اعتبارسنجی ولی با نمونه‌گیری تصادفی مستقل تولید شده‌اند. انتخاب این حجم از داده‌های آزمون با هدف افزایش اطمینان از پایداری مدل‌ها و جلوگیری از اثرگذاری داده‌های خاص یا سوگیری احتمالی انجام شده است.

پس از انجام آزمایش‌های متعدد، مشخص شد که مدل‌های هوش مصنوعی در پیش‌بینی مقادیر بسیار نزدیک به صفر عملکرد دقیقی نداشته‌اند؛ به‌طوری که در اغلب موارد، مقادیر مثبت را منفی و بالعکس پیش‌بینی کرده‌اند. به‌منظور کاهش این اثر و افزایش پایداری مدل، مقادیر خروجی با قدرمطلق کمتر از ۰/۰۰۳ پس از پردازش به مقدار صفر تبدیل شده‌اند.

بهترین نتایج مدل‌های مختلف هوش مصنوعی در تخمین کواترنیون‌های چرخش دستگاه بدنی نسبت به دستگاه مرجع در جدول ۱ (فقط برای مدل‌های MLP زمان اجرای پیش‌پردازش در نظر گرفته شده است) و شکل ۳ ارائه شده است. عبارت‌های اختصاری مندرج در جدول ۱، در جدول ۲ توصیف شده‌اند.

در پژوهش حاضر، با بهره‌گیری از مدل‌سازی دینامیکی حرکت یک ماهواره‌ی زمین‌آهنگ، مجموعه‌ای از داده‌های شبیه‌سازی‌شده حاصل از حسگرهای

**جدول ۲. معادل عبارات کوتاه استفاده‌شده در جدول نتایج تخمین کواترنیون‌ها.**

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

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

[28] Random

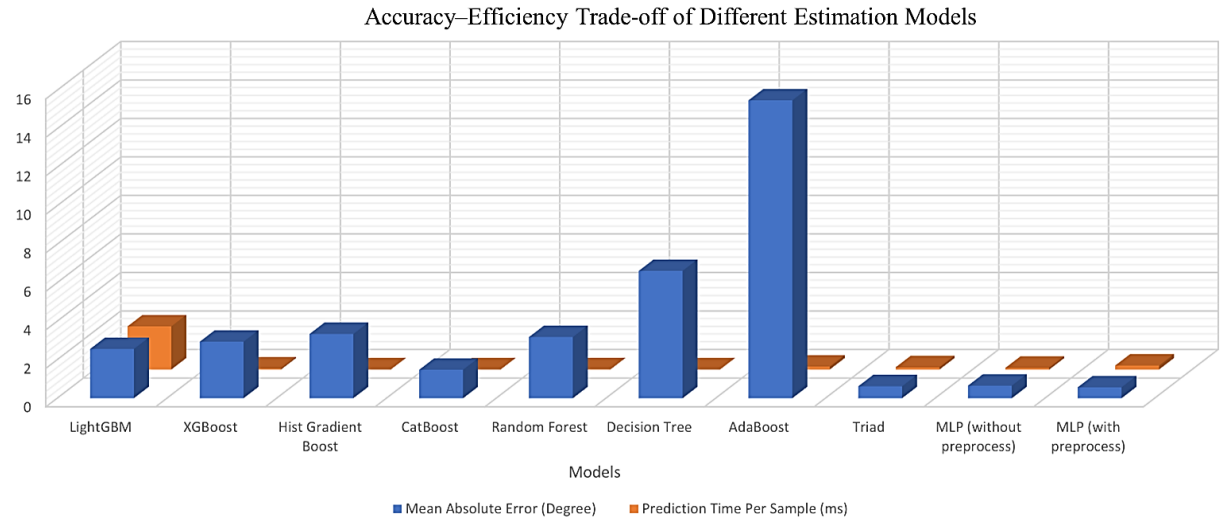


**Figure 3. Results of estimating quaternions using different artificial intelligence model.**

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

خورشید و زمین تولید و الگوریتم‌های متنوع یادگیری ماشین و یادگیری عمیق برای تخمین وضعیت سه‌بُعدی ماهواره ارزیابی شده‌اند. نتایج به‌دست‌آمده از ارزیابی مدل‌ها نشان می‌دهند که بین دقت تخمین و زمان استنتاج هر مدل، رابطه‌ی معکوسی وجود دارد؛ به‌طوری که مدل‌هایی با ساختار ساده‌تر نظیر درخت تصمیم، زمان اجرای بسیار کوتاه ولی با دقت کمتری دارند، در حالی که مدل‌های پیچیده‌تر، مانند شبکه‌های عصبی چندلایه، با وجود زمان اجرای کمی بیشتر، دقتی به مراتب بالاتر ارائه می‌دهند.

در میان مدل‌های بررسی‌شده فقط روش پیش‌پردازش TRIAD توانسته است به‌طور معناداری باعث بهبود عملکرد مدل‌های یادگیرنده شود. سایر روش‌های پیش‌پردازش، تأثیر چشمگیری در کاهش خطای تخمین نداشته‌اند. همچنین مشاهده شده است که بجز در شبکه‌ی عصبی چندلایه، عملکرد سایر الگوریتم‌ها بدون استفاده از پیش‌پردازش TRIAD ضعیف و غیرقابل قبول بوده است.

مقایسه‌ی مدل‌ها نشان می‌دهند 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 وجود این، 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 زمان پیش‌بینی بسیار پایین، دقت لازم برای کاربردهای دقیق تعیین وضعیت را تأمین نکرده‌اند.

درخصوص عملکرد برتر شبکه‌ی عصبی چندلایه نسبت به سایر الگوریتم‌ها، به نظر می‌رسد این تفاوت ناشی از ماهیت متفاوت خانواده‌ی مدل‌ها بوده باشد. مدل‌های مبتنی بر درخت تصمیم (از جمله Random Forest، AdaBoost، CatBoost، XGBoost و LightGBM) با تقسیم‌بندی‌های هم‌راستا با محور[29] 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 پژوهش حاضر، به‌طور کامل محقق نمی‌شود. در مقابل، شبکه‌ی عصبی چندلایه به‌دلیل 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 می‌دهند که چهار مدل MLP یکسان، که هرکدام یک مؤلفه‌ی کواترنیون را به‌صورت 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 مدل اخیر بیانگر نقش کلیدی داده‌های استخراج‌شده از روش TRIAD در فرآیند یادگیری و عملکرد مناسب MLP بدون پیش‌پردازش نسبت به سایر مدل‌هاست. از سوی دیگر، مدل MLP که هر چهار مؤلفه‌ی کواترنیون 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، توازنی بهینه میان دقت و سرعت محاسباتی ایجاد می‌کند و روشی کارآمد و پایدار برای تعیین وضعیت ماهواره‌های زمین‌آهنگ فراهم می‌آورد. این مدل نه فقط نسبت به الگوریتم کلاسیک TRIAD (با خطای ۰/۶۲۲ درجه) دقت بالاتری ارائه می‌دهد، بلکه قابلیت اجرای بلادرنگ نیز دارد و می‌تواند به‌عنوان جایگزینی عملی برای روش‌های کلاسیک در سامانه‌های ماهواره‌ای کوچک و سبک‌وزن استفاده شود.

نتایج پژوهش حاضر نشان می‌دهند که ترکیب داده‌های سنجشی ساده و کم‌هزینه، مانند خروجی حسگرهای خورشید و زمین با روش‌های 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. روش‌های مذکور نه فقط هزینه و

[29] Axis-Aligned Splits

پیچیدگی سخت‌افزاری را کاهش می‌دهند، بلکه در شرایطی مانند نویز زیاد، فقدان برخی داده‌ها یا وقوع تکینگی‌های هندسی نیز عملکرد قابل اتکایی دارند.

برای مطالعه‌های 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 شود و بررسی عملکرد الگوریتم‌های مذکور در حضور تأخیرهای زمانی[30] و در چارچوب سامانه‌های کنترل وضعیت نیز می‌تواند گامی مؤثر در توسعه سامانه‌های هوشمند ماهواره‌ای باشد.

## References – منابع


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., Hajiyev, 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. Hajiyev, 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/10.1016/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.
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.
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*


[30] Delayed Measurements

*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. https://doi.org/10.1038/323533A0.

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 RAD750™ - A Radiation Hardened PowerPC™ 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].

این صفحه عمداً خالی گذاشته شده است.