

بهبود دقت تعیین مدار اجرام فضایی مبتنی بر مشاهدات اپتیکی زمین پایه به کمک شبکه عصبی مصنوعی

تاریخ دریافت: ۱۴۰۲/۰۶/۳۰

تاریخ پذیرش: ۱۴۰۲/۱۲/۰۴

بهمن قربانی واقعی^۱، مصطفی آخوندی^۲

۱- استادیار، دانشکده مهندسی راه آهن/فناوری‌های نوین، دانشگاه علم و صنعت، تهران، bahman_gh@iust.ac.ir

۲- کارشناس ارشد، دانشکده فناوری‌های نوین، دانشگاه علم و صنعت، تهران

چکیده

یکی از مهم‌ترین گام‌ها جهت استفاده بهینه از فرصت‌های فضا و کسب ایمنی در مقابل مخاطرات فضایی، تعیین موقعیت و تخمین وضعیت اجرام موجود در آن می‌باشد. با توجه به وجود اغتشاشات مداری در ارتفاعات مختلف که پیش‌بینی دقیق مسیر حرکت اجرام فضایی را برای مدت طولانی ناممکن می‌سازند، دستیابی به روش‌هایی پایدار جهت تعیین مدار دقیق این اجرام ضرورتی غیرقابل اجتناب است. با استقبال روزافزون استفاده از ابزارهای اپتیکی برای پایش فضا به علت قیمت پایین و دسترسی آسان و درعین حال وجود محدودیت‌های ذاتی در تعداد مشاهدات اپتیکی و دقت تخمین مدار با روش‌های کلاسیک، در این پژوهش توانمندی شبکه‌های عصبی مصنوعی به‌منظور بهبود دقت تعیین مدار اجرام فضایی مبتنی بر مشاهدات اپتیکی زمین پایه مورد بررسی قرار خواهد گرفت. به منظور آموزش و ارزیابی شبکه، بستر شبیه‌سازی توسط داده‌های واقعی موقعیت یک ماهواره و سپس اعمال مدل مشاهدات اپتیکی روی آن‌ها فراهم می‌گردد. شبکه حاصل، موفق به افزایش چشم‌گیر دقت تعیین مدار در زمان مشاهده و همچنین کاهش چندین برابری خطای انتشار مدار در زمان‌های آتی گردید که استفاده‌های علمی و عملیاتی مهمی را به‌ویژه برای بهره‌گیری در مبحث مدیریت ترافیک فضایی و آگاهی وضعیت فضا پوشش می‌دهد.

واژه‌های کلیدی: تعیین مدار، ماهواره، پایش اپتیکی فضا، شبکه عصبی مصنوعی

Improving accuracy of orbit determination by ground-based optical observations based on artificial neural network

Bahman Ghorbani Vaghei¹, Mostafa Akhondi²

1- Assistant Prof., School of Railway Eng./Modern Technologies, Iran University of Science and Technology, Tehran, bahman_gh@iust.ac.ir

2- Graduated Student, School of Modern Technologies, Iran University of Science and Technology, Tehran

Abstract

One of the most important steps to utilize space opportunities and dealing with space threats is to determine the position and estimate the condition of the objects in it. Due to the existence of orbital disturbances at different altitudes that make it impossible to accurately predict the trajectory of space objects for a long time, achieving stable methods to determine the exact orbit of these objects with the aim of managing space traffic and also optimally using space resources is an unavoidable necessity. Considering increasingly use of optical tools for space monitoring due to low price and easy access, besides inherent limitations in the number of observations and the accuracy of orbit estimation with classical methods, in this research we will investigate the ability of artificial neural network (ANN) to improve the accuracy of orbit determination of Space objects based on ground-based optical observations. Because of ANN's universal approximation capability and flexible network structures, it has been found that the trained ANNs can achieve good performance in various situations, In the intended application of this research, the artificial neural network succeeded in significantly increasing the accuracy of satellite orbit determining at the epoch of observation, as well as reducing the orbit propagation error by several orders in the future epochs, which has important scientific and operational applications, especially for use in the field of Space Traffic Management and Space Situational Awareness.

Keywords: orbit determination, satellite, optical space surveillance, artificial neural network

۱۲۹

سال ۱۳ - شماره ۱

پاییز و زمستان ۱۴۰۳

نشریه علمی

دانش و فناوری هوا فضا



به منظور انجام اقدامات پیشگیرانه نظیر اجرای مانورهای مداری، از اهمیت بسیار بالایی برخوردار خواهد بود. تعیین مدار اجرام فضایی با استفاده از روش‌های اپتیکی و همچنین راداری قابل اجراست؛ اما به علت هزینه‌ی بسیار بالای رادارهای فضانگر، استفاده از ابزارهای اپتیکی به دلیل قیمت پایین و دسترسی آسان، طی دهه‌ی اخیر بسیار مورد توجه قرار گرفته‌است. با توجه به وجود محدودیت‌های ذاتی در تعداد مشاهدات و دقت تعیین مدار اپتیکی کلاسیک، افزودن روش‌های هوشمند به فرایندهای مرسوم، به عنوان رهیافتی نوین مورد بررسی این پژوهش خواهد بود.

طی سال‌های اخیر به‌ویژه پس از موفقیت شگفت‌انگیز برنامه آلفاگو^۴، توجه‌ها به شبکه‌های عصبی مصنوعی خصوصاً نوع عمیق آن معطوف گردید [۴]. امروزه اثبات شده است که شبکه‌های عصبی مصنوعی برتری قابل ملاحظه‌ای نسبت به هوش انسان در حل مسائلی نظیر طبقه‌بندی^۵ به‌ویژه در خروجی‌های گسسته از خود نشان می‌دهند. همچنین در مسائل دارای خروجی پیوسته یا رگرسیون نیز شبکه‌های عصبی موفق شده‌اند کارایی بسیار بالایی از خود نشان دهند و چنین بیان شده است که این شبکه‌ها قادرند هر تابع نرمی را در صورت به‌کارگیری تعداد نورون‌ها و لایه‌های کافی، با بیشترین دقت ممکن تخمین بزنند [۵، ۶، ۷].

در حیطه پروژه‌های مرتبط فضایی، طی مطالعه‌ای که سال ۱۹۹۱ توسط ویلیامز انجام شد، شبکه عصبی با دولایه پنهان به‌منظور پیش‌بینی فعالیت‌های خورشیدی بر مبنای داده‌های مشاهداتی بلندمدت مورد بررسی قرار گرفت [۸]. با استفاده از پیش‌بینی حاصل از این شبکه، دقت تخمین عمر مداری ماهواره‌ی مورد بررسی، چندین برابر افزایش یافت. سپس در سال ۱۹۹۵ این روش توسط مکفرسون و همکاران

امروزه با توجه به گسترش روزافزون کاربرد سامانه‌های فضایی و محیط فضا در مباحث تجاری، صنایع نظامی و غیرنظامی، اهمیت چشمگیر موضوع «آگاهی وضعیتی فضا یا SSA»^۱ برای استفاده بهینه از فرصت‌های حوزه فضا و کسب ایمنی مؤثر نسبت به مخاطرات فضایی بر کسی پوشیده نیست؛ لذا روزبه‌روز نیازهای بین‌المللی و ملی برای داشتن موقعیت فعلی اجرام فضایی و همچنین پیش‌بینی موقعیت و وضعیت آن‌ها در زمان‌های آتی، بیشتر و بیشتر می‌گردد. تعداد اجرام فضایی مصنوعی با ابعاد بزرگ‌تر از ۱۰ سانتیمتر هم‌اکنون به بیش از ۳۴ هزار قطعه رسیده است. همچنین تعداد اجرام دارای ابعاد بین ۱ تا ۱۰ سانتیمتر بیش از ۷۶۰ هزار عدد و اجرام زیر ۱ سانتیمتر بیش از ۱۷۰ میلیون تخمین زده شده است [۱]. این اجرام از مدارهای پایینی زمین تا کره‌ی ماه گسترده شده و امنیت ماهواره‌ها و سرمایه‌های فضایی کشورهای مختلف را تهدید می‌کنند [۲].

یکی از مهم‌ترین چالش‌ها در مبحث SSA، تعیین مدار و پیش‌بینی موقعیت اجرام موجود در مدار زمین با دقت مناسب می‌باشد. روش‌های مرسوم کلاسیک برای تعیین مدار و انتشار آن که تنها بر پایه مدل‌های فیزیکی اغتشاشات بنا شده، بارها در رسیدن به دقت مذکور شکست خورده‌اند؛ نظیر برخورد مداری سال ۲۰۰۹ که طی آن ماهواره زنده مخابراتی منظومه ایریدیوم^۲ با ماهواره غیرفعال روسی کازموز^۳ ۲۲۵۱ برخورد کرد و در پی آن علاوه بر نابودی هر دو ماهواره، هزاران زباله جدید در مدار پایین تولید شد [۳]. در دهه‌های آتی تعداد این اجرام فضایی و در نتیجه تعداد برخوردهای محتمل، به مراتب افزایش خواهند یافت و لذا توانایی ما برای تخمین دقیق موقعیت اجرام فضایی در زمان‌های مختلف



توسعه پیدا کرد تا بتواند فعالیت‌های خورشیدی و ژئومغناطیسی را به صورت هم‌زمان پیش‌بینی نماید [۹]. آن‌ها از یک شبکه عصبی با تنها یک لایه پنهان متشکل از ۱۰ نورون بهره گرفتند و موفقیت شبکه در بهبود پیش‌بینی فعالیت‌های مذکور را به اثبات رساندند. طی پژوهشی در سال ۲۰۰۴ روش‌های مبتنی بر شبکه عصبی به‌منظور بهبود دقت ماژول GPS در فیلتر کالمن مورد استفاده قرار گرفت [۱۰]. در سال ۲۰۱۶ سانچز و ایزو از شبکه‌های عصبی عمیق به‌منظور یافتن مسیر بهینه فرود استفاده کردند؛ به‌گونه‌ای که محاسبات لحظه‌ای با نرخ بالا، روی برد قابل پیاده‌سازی و دستیابی باشد [۱۱ و ۱۲]. مرتا نیز در سال ۲۰۱۷ روش‌های مختلف یادگیری ماشین از جمله شبکه‌های عصبی مصنوعی را به‌منظور دستیابی به تخمین اولیه از جرم نهایی بهینه برای مسیرهای بین سیارکی کم‌پیش‌ران مورد بررسی قرار داد [۱۳].

در مجموعه پژوهش‌هایی که طی سال ۲۰۱۷ تا ۲۰۱۹ در دانشگاه نیوجرسی آمریکا انجام شد، موفقیت فرایندهای یادگیری ماشین در بهبود دقت مدل‌های دینامیک مداری مورد بررسی قرار گرفت و اثبات شد. در مورد اول، اطلاعات مربوط به نسبت جرم-به-سطح یک ماهواره، از خطای ثابت پیش‌بینی موقعیت آن در یک انتشارگر مشخص با موفقیت استخراج گردید [۱۵]. در مطالعه بعدی، توانمندی و محدودیت‌های ماشین بردار پشتیبان^۶ به‌منظور بهبود دقت پیش‌بینی مدار در یک محیط دینامیکی شبیه‌سازی‌شده از فضا مورد بررسی قرار گرفت [۱۴ و ۱۶]. در یک پژوهش نیز میزان موفقیت شبکه‌های عصبی مصنوعی در بهبود دقت پیش‌بینی مدار به‌دست‌آمده از مشاهدات راداری در بستر شبیه‌سازی نرم‌افزاری مورد ارزیابی قرار گرفت و موفقیت چشمگیر آن به اثبات رسید [۱۷، ۱۸].

در میان منابع داخلی نیز توسط آقای فرشاد شاملو و ابوالقاسم نقاش، پیش‌بینی موقعیت مداری ماهواره با استفاده از شبکه عصبی، در سال ۱۳۹۵ مورد بررسی قرار گرفته که از تاریخچه ۲ ساله TLE یک ماهواره و روش سری‌های زمانی به‌منظور بهبود دقت انتشار مدار بهره برده و موفقیت شبکه عصبی در کاهش خطای پیش‌بینی موقعیت مداری در زمان‌های آتی را نشان داده [۳۶]. هر چند به بحث مهم تعیین مدار و تخمین پارامترهای مداری با استفاده از مشاهدات زمین‌پایه اشاره‌ای نداشته است. آقای دانیال بوستان طی مقاله‌ای در سال ۱۳۹۷، پیش‌بینی بردار حالت مداری ماهواره با استفاده از سری‌های زمانی و شبکه‌های عصبی را مورد بررسی قرار داد [۳۸] و نیز آقای دکتر شریفی و همکاران در سال ۱۴۰۱ طی پژوهشی ضرایب تصحیح‌کننده چگالی اتمسفری را با استفاده از شبکه‌های عصبی تخمین زده‌اند [۳۷].

در این پژوهش توانمندی شبکه‌های عصبی مصنوعی به‌منظور بهبود دقت تعیین مدار اجرام فضایی مبتنی بر مشاهدات اپتیکی زمین‌پایه به عنوان موضوعی نوین مورد بررسی قرار خواهد گرفت. در این راستا پس از بیان مسئله و تشریح نحوه مدل‌سازی مشاهدات اپتیکی، بستر شبیه‌سازی با استفاده از داده‌های واقعی موقعیت یک ماهواره و اعمال مدل مشاهدات اپتیکی روی آن‌ها فراهم می‌گردد. سپس به کمک روش‌های تعیین مدار کلاسیک مبتنی بر مشاهدات اپتیکی زمین‌پایه، پارامترهای مداری محاسبه و استخراج می‌شوند. در مرحله بعد فرایند آموزش شبکه عصبی با استفاده از مجموعه دادگان اجرا گردیده و در نهایت میزان موفقیت شبکه عصبی به‌منظور کاهش خطای مدار در مبدأ زمانی مشاهدات و همچنین مبدأهای آتی (خارج از محدوده دادگان آموزش) ارزیابی خواهد شد.



۲. بیان مسئله

موقعیت تمامی اجرام فضایی که در بند گرانش زمین قرار دارند، با در اختیار داشتن پارامترهای مداری آن‌ها (مثلاً در قالب TLE^۷) در زمان‌های متخلف قابل پیش‌بینی و محاسبه است. به علت وجود نیروهای غیرقابل‌پیش‌بینی ناشی از اغتشاشات مداری، اجرام فضایی و در نتیجه پارامترهای مداری آن‌ها پیوسته در حال تغییر می‌باشد. این اغتشاشات غالباً مربوط به ناهمگونی‌های شکلی و الگوی گرانش زمین، اصطکاک ناشی از جو ناچیز موجود در مدارهای پایین، یا طوفان‌های خورشیدی و گرانش جسم سوم (ماه، مشتری و سیارک‌های بزرگ) در مدارهای بالا هستند. مقدار تأثیر این اغتشاشات، برای ماهواره‌های مختلف متفاوت است و به عواملی از جمله ارتفاع و شکل ظاهری ماهواره بستگی به دارد. همچنین در صورت استفاده از پیش‌رانش، پارامترهای مداری ماهواره به سرعت تغییر می‌کند. لذا با یک‌بار تعیین موقعیت و تخمین مدار اجرام فضایی، نمی‌توان انتظار داشت که با روش‌های تعیین مدار کلاسیک، بتوان موقعیت آن‌ها را برای زمان‌های طولانی مدت در آینده با دقت مناسب پیش‌بینی کرد.

محدودیت‌های موجود در روش‌های فعلی تخمین موقعیت اجرام مداری، غالباً ناشی از ضعف مدل‌های دینامیکی اغتشاشات، محدودیت و خطای مشاهدات و همچنین خطای تعیین مدار می‌باشد؛ در سامانه‌های امروزی وزن مورد اول بیشتر از سایر موارد برآورد شده است. یادآوری می‌گردد که در واقعیت با استفاده از سامانه‌های رصد و پایش اجرام، بشر قادر است تنها اطلاعات محدودی از وضعیت فضا برداشت نماید و همچنین این مشاهدات محدود در فرایند انتشار مدار با مدل‌های غیر کامل مواجه شده و به مراتب پیش‌بینی را با خطای بیشتر مواجه می‌کنند.

به‌عنوان مثال، مدل‌های فشار تابشی خورشید^۸ و پسای اتمسفری^۹، فقط تعداد محدودی از پارامترهای فعالیت‌های خورشیدی و جوی در واقعیت را در برمی‌گیرند و در نتیجه افزایش دقت مشاهدات بیش از یک مقدار مشخص، هیچ بهبودی در دقت تخمین و پیش‌بینی مدار در صورت استفاده از روش‌های کلاسیک رقم نخواهد زد. به بیان دیگر می‌توان گفت همه‌ی اطلاعات نهفته در داده‌های مشاهداتی بلندمدت از اجرام فضایی، علی‌رغم اینکه حاوی اطلاعات ارزشمندی از مدل واقعی رفتار طبیعت هستند، در روش‌های کلاسیک تخمین و انتشار مدار که مبتنی بر مدل‌های فیزیکی محدود و غیر پویاست، به کارگیری نمی‌شوند. طی دهه‌ی گذشته یکی از روش‌های موفق برای جبران ضعف مدل‌های مداری و همچنین محدودیت‌های مشاهدات پیوسته، توسعه‌ی الگوریتم‌های مبتنی بر هوش مصنوعی جهت استحصال اطلاعات پنهان موجود در داده‌های مشاهداتی بلندمدت مطرح شده است؛ لذا هدف ما در این پژوهش بررسی و پیشنهاد یک روش مبتنی بر شبکه‌های عصبی مصنوعی به‌عنوان یک شاخه از یادگیری ماشین و هوش مصنوعی به منظور استخراج و به کارگیری اطلاعات نهفته در مشاهدات بلندمدت می‌باشد. در این روش بهبود دقت تخمین و پیش‌بینی مدار بدون نیاز به توسعه‌ی مدل‌های عددی پیچیده از نیروهای اغتشاشات مداری، بلکه تنها با تکیه بر یادگیری ماشین مبتنی بر داده‌های مشاهدات اپتیکی بلندمدت صورت می‌پذیرد.

۳. مدل‌سازی مشاهدات اپتیکی

در این پژوهش، آموزش شبکه توسط داده‌های واقعی موقعیت یک ماهواره در مدار LEO و اعمال مدل مشاهدات اپتیکی روی آن‌ها صورت می‌پذیرد. هدف این بخش بررسی عوامل مهم ایجاد خطا و محدودیت‌های سامانه‌های اپتیکی



۲-۱-۲. محدودیت زاویه فراز

به علت بروز تضعیف نسبتاً زیاد نور هنگام عبور از اتمسفر در زمان حضور ماهواره در زوایای فراز پایین، تقویت اثرات غیرخطی شکست نور و افزایش اثرات ناشی از تلاطم جوی، در این پژوهش بخش‌هایی از گذر ماهواره که در زاویه فراز کمتر از 10^+ درجه هستند، حذف می‌گردند.

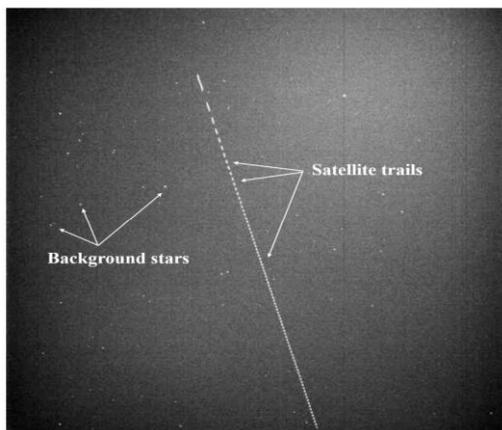
۲-۳. خطای مشاهدات

۱-۲-۳. خطای آشکارسازی در تصویر

در یک مشاهده گر الکترواپتیکی، فرم هندسی ثبت هدف در تصویر، به پارامترهای اپتیکی سیستم تصویربرداری شامل تفکیک فضایی تصویر، طول زمان نوردهی و مُد حرکتی آن (ردیابی هدف، ردیابی نجومی یا ایستا) و نیز سرعت زاویه‌ای ظاهری هدف (از دید ناظر) بستگی دارد و می‌تواند به یکی از این دو روش باشد:

الف) نقطه‌ای (Point-Like)

ب) رگه (Streak یا Trail) مانند شکل ۱



شکل ۱. ردهای ناشی از عبور ماهواره در پس‌زمینه ستارگان آسمان

در این مطالعه فرض بر این است که حداکثر دقت قابل دسترس در مختصات پیکسلی برابر با ۱ پیکسل ($\pm 0.5 \text{ pixel}$) می‌باشد. اما در برخی منابع تلاش‌هایی برای توسعه روش‌های دستیابی به دقت

پایش اجرام فضایی جهت دستیابی به مدل صحیح برای اعمال روی داده‌های موقعیت ماهواره می‌باشد. سپس با اعمال این مدل بر روی داده‌های موقعیت ماهواره Landsat7 طی سال ۲۰۱۸ میلادی، بستر دادگان مورد نیاز جهت آموزش و ارزیابی شبکه تشکیل خواهد شد. در ادامه، محدودیت‌ها و خطاهای رایج در ثبت مشاهدات اپتیکی از اجرام فضایی با ذکر توضیحات مختصر ارائه می‌گردد.

۱-۳. محدودیت‌ها

۱-۱-۳. محدودیت روشنایی

مبنای وجود قابلیت ثبت و آشکارسازی اپتیکی به روش غیرفعال، برقراری سه شرط زیر در نظر گرفته می‌شود:

الف) ماهواره در تابش مستقیم نور خورشید قرار داشته باشد. لازم به ذکر است تنها منبع نوری که سامانه اپتیکی مدنظر این پژوهش بدان تکیه دارد، نور خورشید در طیف مرئی تا فرورسرخ نزدیک^{۱۰} می‌باشد.

ب) اتمسفر مکان موردنظر از حیث تابش خورشیدی در شب باشد. رسیدن زاویه فراز خورشید به کمتر از 12^- درجه در محل رصد، به عنوان معیار ورود به تاریکی کامل فرض می‌شود.

ج) روشنایی بازتابیده از ماهواره و رسیده به پیکسل‌های آشکارساز، حداقل ۲ برابر سطح نوین آشکارساز (جمع نوین جریان تاریک^{۱۱} و نوین مدار خوانش^{۱۲}) باشد. انتخاب این مقدار بر مبنای حداقل SNR لازم برای تشخیص رد ماهواره از زمینه تصویر می‌باشد که در روش‌های رایج حداقل 6dB در نظر گرفته می‌شود [۲۰، ۱۹].



زیرپیکسل (sub-pixel) نیز بیان شده است [۲۲] تا [۲۵].

۳-۲-۲. خطای زمان‌سنجی

اندازه‌گیری موقعیت هدف بدون برچسب زمانی را نمی‌توان برای تعیین مدار به‌کار برد. به‌طور معمول برچسب زمانی در سیستم UTC (با استفاده از ساعت اتمی یا زمان GPS) مورد استفاده قرار می‌گیرد. در بخشی از تبدیلات مختصات مورد نیاز، تفاوت UTC با زمان دینامیکی (پارامتر dUT1) نیز مورد نیاز است که بایستی اعمال شود.

به‌هر حال خطای برچسب‌زنی زمانی و نیز خطا در تصحیح آن (dUT1) مستقیماً به خطا در تعیین مدار منجر می‌گردد. به‌عنوان یک گزاره کلی، خطاهایی از مرتبه میلی‌ثانیه و به‌ویژه بزرگ‌تر از ۱۰ میلی‌ثانیه در زمان‌سنجی، به خطاهای قابل توجه در تعیین مدار با داده‌های اپتیکی منجر می‌گردد. دقت زمانی بهتر از ۱ میلی‌ثانیه برای سیستم مفروض که از قابلیت تریگر سخت‌افزاری^{۱۳} برخوردار است، در نظر گرفته می‌شود. [۲۱].

۳-۲-۳. خطای تبدیل مختصات تصویر به مختصات سماوی

در فرآیند تعیین مدار به موقعیت زاویه‌ای هدف در یک دستگاه مختصات لخت زمین‌مرکز (یک چارچوب مرجع ECI نظیر EME2000 یا ICRF و در حالت خاص برای تعیین مدار مبتنی بر مدل SGP4/TLE دستگاه TEME) نیاز است. تبدیل مختصات از چارچوب پیکسلی به سماوی، دو مبنای متمایز می‌تواند داشته باشد:

(الف) آسترومتری تصویر به کمک الگوی ستاره‌ای در پس‌زمینه تصویر

(ب) تخمین موقعیت بر مبنای فیدبک جهت‌گیری توپوسنتریک سیستم تصویربرداری

روش اول که مورد نظر ما نیز می‌باشد، برای تصویربرداری در مدردیایی نجومی بسیار رایج است و به صورت بالقوه دقت بالاتری را فراهم می‌آورد. در این روش تعدادی ستاره مرجع در تصویر شناسایی شده و یک نگاشت جبری برای تبدیل مختصات پیکسلی (X,Y) به مختصات سماوی (RA, Dec) به دست می‌آید. کاتالوگ‌های ستاره‌ای کلاسیک عموماً دقتی در محدوده ۰/۵ تا ۱/۵ ثانیه قوسی دارند. مختصات سماوی تولیدشده در دستگاه مختصات مرجع کاتالوگ ستاره‌ای (مثلاً مبدأ J2000) به دست می‌آید و باید به دستگاه مختصات در زمان مشاهده (True-Of-Date ECI) تبدیل شود. برای دستیابی به دقت‌های بالا، تبدیل نسبتاً پیچیده‌ای مورد نیاز است که شامل انبوهی از ضرایب عددی به‌دست‌آمده از مدل‌های تجربی (شامل اثرات مربوط به تغییر جهت‌گیری محور زمین در فضا) است. این تبدیل اگر به‌درستی اعمال شود خطای قابل توجهی نخواهد داشت، در غیر این صورت (به‌ویژه عدم اعمال ضرایب Earth Orientation Parameters) می‌تواند منشأ خطاهایی تا چند ثانیه قوسی باشد. در مرجع [۲۶] گزارش شده که برای تصاویر با تفکیک ۲/۲ ثانیه قوسی، داده‌های آسترومتریک تولیدشده، با دقت ۱.۶ ثانیه قوسی (شامل کلیه خطاها) با مقادیر واقعی تطبیق دارد؛ درحالی‌که دقت کاتالوگ ستاره‌ای مورد استفاده، یک مرتبه اعشار بهتر بوده است. در این مقاله از نتایج مرجع [۲۶] برای مدل‌سازی خطای تبدیلات مختصات سماوی بهره‌گیری خواهد شد.

۳-۳. مدل نهایی مشاهدات

با توجه به خطاهای مطرح‌شده بخش ۳-۲ و همچنین مشخصات فنی سامانه اپتیکی مفروض (شکل ۲)، مدل سامانه رصد با مشخصات جدول ۱ برای اعمال به داده‌های مشاهداتی در نظر گرفته

می‌شود. لازم به ذکر است از منحنی توزیع نرمال برای شبیه‌سازی رفتار هر یک از خطاهای این مدل استفاده شده است.

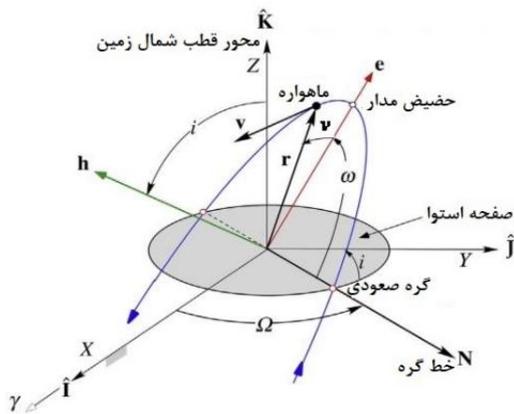
جدول ۱. جدول مشخصات سامانه اپتیکی و مدل خطا

ردیف	نام پارامتر	مقدار
۱	طول جغرافیایی	۳۰.۲۶۴ درجه
۲	عرض جغرافیایی	۵۹.۸۹۴ درجه
۳	ارتفاع از سطح دریا	۱۲۳۵ متر
۴	حداکثر قدر قابل مشاهده	۱۲
۵	رزولوشن زاویه‌ای	۱۳ ثانیه قوسی
۶	حداکثر ارتفاع خورشید هنگام ثبت	۱۲- درجه
۷	انحراف معیار خطای زاویه سمت	۰.۱۵ درجه
۸	میانگین خطای زاویه سمت	۰.۱ درجه
۹	انحراف معیار خطای زاویه فراز	۰.۱۵ درجه
۱۰	میانگین خطای زاویه فراز	۰.۱ درجه
۱۱	انحراف معیار خطای زمان	۱ میلی ثانیه
۱۲	میانگین خطای زمان	۱۰۰ میکروثانیه

تعبیر فیزیکی آن‌ها در شکل ۳ نمایش داده شده و نام‌گذاری آن‌ها به صورت زیر است:

- a نیم‌قطر اصلی^{۱۴}
- e خروج از مرکز^{۱۵}
- i زاویه شیب مداری^{۱۶}
- Ω زاویه بعد گره صعودی^{۱۷}
- ω زاویه آرگومان حضیض مداری^{۱۸}
- γ زاویه آنومالی حقیقی^{۱۹}

با در اختیار داشتن بردارهای سرعت و موقعیت ماهواره می‌توان المان‌های مداری متناظر ماهواره را به دست آورد. همین‌طور اگر e المان مداری در دسترس باشند، بردارهای سرعت و موقعیت متناظر ماهواره قابل محاسبه خواهند بود.



شکل ۳. تعبیر فیزیکی المان‌های مداری کپلری

فرآیند تعیین مدار اپتیکی در شکل کلاسیک آن شامل دو گام متمایز است:

(۱) تعیین مدار اولیه (یا به اختصار IOD^{۲۰}) که در این پژوهش از روش گاوس مطابق مرجع [۲۹] بهره‌گیری شده است (شکل ۴). لازم به ذکر است از سه مشاهده (مشاهده ابتدایی، میانی و پایانی) هر گذر ماهواره برای اجرای روش گاوس استفاده می‌گردد.

(۲) تصحیح دیفرانسیلی که به صورت حداقل مربعات دسته‌ای (Batch Least Square) روی خروجی مرحله قبل پیاده‌سازی می‌گردد



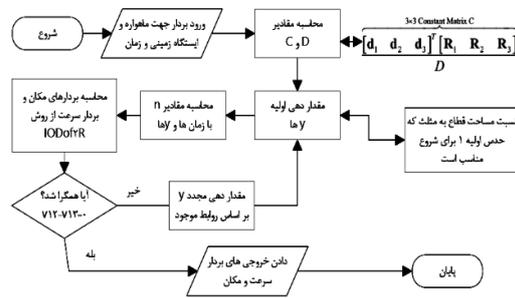
شکل ۲. نمایی از تلسکوپ اپتیکی مفروض در مدل مشاهدات جهت ثبت اجرام فضایی و تعیین مدار

۴. تعیین مدار اپتیکی به روش کلاسیک

یکی از معمول‌ترین روش‌های بیان مدار اجرام فضایی، «المان‌های مداری کپلری» هستند که



و همه‌ی مشاهدات طول گذر را در تخمین مدار دخیل می‌نماید.



شکل ۴. الگوریتم تعیین مدار اولیه گاوس

روش‌های IOD هرگز قادر به تولید یک جواب دقیق برای حرکت مداری نیستند، زیرا گذشته از اینکه این روش‌ها از تعداد کمینه مشاهدات استفاده می‌کنند و نسبت به خطاهای مشاهداتی حساس هستند، جواب تولیدشده در IOD یک مدار کپلری می‌باشد که در یک نقطه زمانی بر مسیر واقعی مماس است و اصطلاحاً یک مدار تماسی (Osculating) نامیده می‌شود، درحالی‌که مسیر واقعی یک مدارگرد هرگز یک مدار کپلری ایده‌آل نیست.

متداول‌ترین روش برای تصحیح دیفرانسیلی پارامترهای حاصل از تعیین مدار، روش کمترین مربعات خطی (Linear Least Square) است. روش LLS در اصل به‌وسیله گاوس و برای حل مسئله تعیین مدار یک سیارک گم‌شده در قرن ۱۸ ابداع و معرفی شده است. در مرجع [۳۳] و [۳۵] توصیفی از فرآیند تصحیح دیفرانسیلی متداول برای تولید TLE که بر استفاده از تخمین گر LLS و انتشارگر مداری SGP4 استوار است، ارائه شده که مورد استفاده‌ی ما در این پژوهش قرار خواهد گرفت.

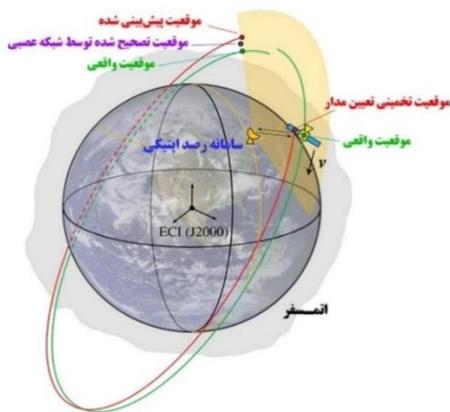
۵. طراحی شبکه عصبی مصنوعی

در این بخش ابتدا فرایند پیشنهادی جهت بهبود دقت تعیین و پیش‌بینی مدار مبتنی بر

داده‌های مشاهدات اپتیکی ارائه می‌شود. سپس متغیرهای یادگیری شبکه عصبی و ساختار دسته‌بندی داده‌ها ارائه می‌گردد. در گام بعد، مفاهیم و معماری شبکه موردنظر بیان خواهد شد. در پایان نیز شبکه با داده‌های حاصل از مشاهدات اپتیکی آموزش دیده و نتایج تعمیم‌پذیری در دو مبحث تعیین مدار و انتشار مدار مورد ارزیابی قرار خواهد گرفت.

۵-۱. اصول علمی فرایند بهبود دقت مدار

نمای کلی روش مبتنی یادگیری ماشین پیشنهادی جهت تصحیح خطای تعیین و انتشار مدار (پیش‌بینی پارامترهای مداری در زمان‌های آتی)، در شکل ۵ نشان داده شده است. هنگامی که جرم فضایی در میدان دید سامانه اپتیکی زمین پایه قرار می‌گیرد و شرایط رصد مهیاست، داده‌های مشاهدات اپتیکی استخراج شده و سپس تعیین مدار بر مبنای روش‌های کلاسیک انجام می‌شود. سپس این مدار تخمین زده شده، در محیط SGP4 به مبداهای آتی انتشار می‌یابد تا یک پیش‌بینی برای بردار حالت ماهواره در زمان‌های آتی حاصل شود. این پیش‌بینی با افزایش زمان انتشار، انحراف بیشتری از واقعیت پیدا می‌کند که علت اصلی آن، محدودیت‌های مشاهدات اپتیکی دخیل در تعیین مدار و همچنین ضعف مدل انتشار یعنی عدم انطباق کامل با واقعیت می‌باشد.



شکل ۵. روش بهبود دقت مدار مبتنی بر شبکه عصبی

با این فرض که اثر نیروهای مدل نشده در داده‌های مشاهداتی بلندمدت پنهان است، فرایند یادگیری ماشین پیشنهادی باید قادر باشد ارتباط بین متغیرهای دانسته با خطای تخمین مدار را با بهره‌گیری از این داده‌های بلندمدت پیدا کند. هنگامی که شبکه به‌خوبی آموزش دید، با حذف کردن مقادیر خطای پیش‌بینی شده توسط شبکه عصبی از بردار حالت اصلی، بردار حالت تصحیح شده حاصل خواهد شد. این نکته یادآوری می‌گردد که فرایند یادگیری ماشین هیچ وابستگی به مدل‌های دینامیک مداری و روابط پیچیده‌ی درون آن ندارد، بلکه مستقیماً ارتباط بین متغیرهای ورودی یعنی داده‌های مشاهداتی بلندمدت را با نتیجه مطلوب یعنی مقدار خطاهای تخمین مدار، کشف می‌نماید.

روش‌های هوشمند و یادگیری ماشین متعددی برای حل این مسئله قابل به‌کارگیری و ارزیابی است. در این پژوهش با تکیه بر موفقیت‌های حاصله در مسائل مشابه ذکر شده در مراجع [۱۷] و [۱۴]، تمرکز بر روی بهره‌گیری از «شبکه‌های عصبی مصنوعی» خواهد بود.

۲-۵. طراحی و پیاده‌سازی فرایند یادگیری

مراحل اجرا و ارزیابی فرایند یادگیری که این پژوهش استفاده خواهد شد، در شکل ۶ نمایش داده شده است. چهار بلوک بالایی که در واقع فرایندهای مرسوم تعیین مدار اپتیکی را نشان می‌دهند عبارتند از:

۱- داده‌های موقعیت ماهواره Landsat7

۲- داده‌های مشاهدات اپتیکی از این ماهواره در ایستگاه‌های زمینی

۳- فرایند تعیین مدار بر مبنای روش‌های کلاسیک (گاوس+حداقل مربعات)

۴- پیش‌بینی مدار در بستر انتشارگر SGP4 سه بلوک پایین نیز فرایند یادگیری مبتنی بر شبکه عصبی را نشان می‌دهند.

به‌منظور شبیه‌سازی مشاهدات اپتیکی، از یک ایستگاه با مشخصات ذکر شده در جدول ۱ استفاده می‌شود. سامانه‌های اپتیکی موجود در این ایستگاه، هرزمانی که ماهواره قابل رصد باشد، مشاهدات گسسته با نرخ ۱ بار بر ثانیه در قالب زاویه سمت α و زاویه فراز η را از هدف ثبت می‌نماید. خطای مشاهدات به صورت تابع توزیع نرمال با میانگین μ_α و انحراف معیار σ_α برای زاویه سمت و به‌طور مشابه μ_η و σ_η برای زاویه فراز در نظر گرفته می‌شود. پس از هر عبور قابل رصد ماهواره از آسمان این ایستگاه، فرایند تعیین مدار با استفاده از روش گاوس و حداقل مربعات دسته‌ای انجام شده و بردار حالت ماهواره در مبدأ زمانی میانه هر عبور، محاسبه می‌گردد. لازم به یادآوری است بردار حالت شامل مؤلفه‌های بردار موقعیت و سرعت می‌باشد. سپس این بردار حالت با استفاده از بستر SGP4 به زمان‌های آتی انتشار می‌یابد و خطای پیش‌بینی، با مقایسه‌ی این بردار حالت با وضعیت واقعی ماهواره در آن زمان حاصل می‌گردد. حداکثر زمان برای انتشار مدار (Δt_{max}) در این پژوهش ۶ روز در نظر گرفته شده است که بر اساس محدودیت‌های سامانه‌های اپتیکی برای کاهش بازه زمانی بین دو مشاهده متوالی از یک ماهواره، مقدار مناسبی می‌باشد. کلیه شبیه‌سازی‌ها به کمک برنامه‌های توسعه‌یافته در نرم‌افزار MATLAB انجام شده و همچنین به‌منظور صحت سنجی بخش‌های مرتبط با دینامیک مداری از نرم‌افزار STK بهره‌گیری شده است.

۳-۵. ساختار مجموعه داده

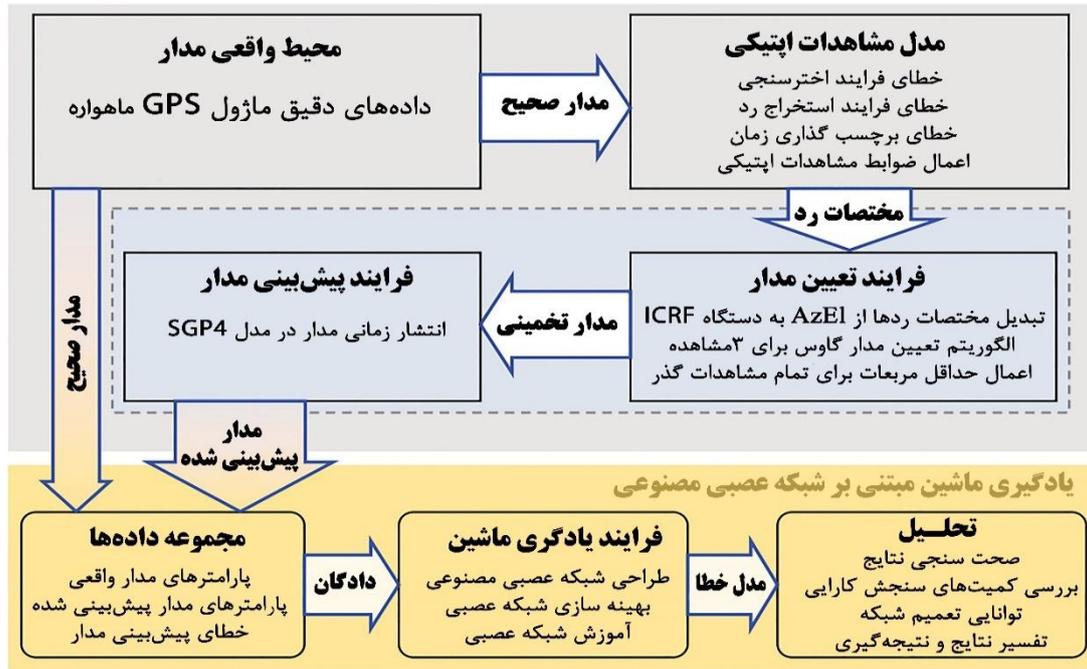
در ابتدا نحوه نمادگذاری متغیرهای مورد نیاز به‌طور قراردادی زیر ارائه می‌گردد:

$X(t)$: بردار حالت ماهواره در زمان t بدون ذکر

دستگاه مختصات

$COE X(t)$: بردار حالت ماهواره در زمان t در قالب





شکل ۶. ساختار محیط شبیه‌سازی برای اجرا و ارزیابی فرایند یادگیری ماشین

پارامترهای مداری کپلری به صورت:

$${}^{COE}X(t)=[a,e,i,\omega,\Omega,v] \quad (1)$$

${}^{ECI}X(t)$: بردار حالت ماهواره در زمان t در

دستگاه مختصات اینرسی به صورت:

$${}^{ECI}X(t)=[X,Y,Z,V_x,V_y,V_z] \quad (2)$$

$\delta X(t)$: اختلاف دو حالت $X(t)$ و $X(t)$ در دستگاه

RSW به صورت:

$${}^{RSW}\delta X(t)=[\delta x,\delta y,\delta z,\delta V_x,\delta V_y,\delta V_z] \quad (3)$$

دستگاه RSW همان دستگاه مختصات مداری

ماهواره است که در آن محور X (مؤلفه شعاعی^{۲۱})

در جهت شعاع مدار، محور Y (مؤلفه راستای

حرکت^{۲۲}) عمود بر X در راستای سرعت ماهواره و

محور Z (مؤلفه عمود بر حرکت^{۲۳}) در جهت بردار

تکانه زاویه‌ای می‌باشد. نمادهای ذکر شده در

صورت دارا نبودن کلاه مانند $X(t_i)$ مربوط به

داده‌های واقعی ماهواره و اگر دارای نماد کلاه

باشند مانند $\hat{X}(t_i)$ معرف مقادیر پیش‌بینی شده

خواهند بود. همچنین در متغیرهای پیش‌بینی

شده، به منظور نمایش بردار حالتی که از مبدأ

زمانی t_i به زمان t_j انتشار پیدا کرده است، از نماد

$\hat{X}(t_j; t_i)$ استفاده شده است. متغیرهای مورد

استفاده در ورودی فرایند یادگیری، به گونه‌ی

زیر انتخاب می‌گردند:

۱- زمان انتشار $\Delta t = t_j - t_i$ برحسب ثانیه

(مدت پیش‌بینی در t_j بر مبنای مبدأ زمانی

t_i)

۲- زمان مبدأ t_i (زمان مشاهده میانی از هر گذر)

در قالب تعداد ثانیه‌های گذشته از شروع روز

۳- زوایای سمت و ارتفاع مشاهداتی ماهواره در

لحظه‌ی بیشینه فراز از گذر i ام بیان شده به

$$\theta_i = [\alpha, \eta]^T$$

۴- حالت پیش‌بینی شده برای ماهواره در زمان t_j

بر مبنای حالت در مبدأ فعلی t_i ، بیان شده

$$\text{در قالب } {}^{ECI}\hat{X}(t_j; t_i)$$

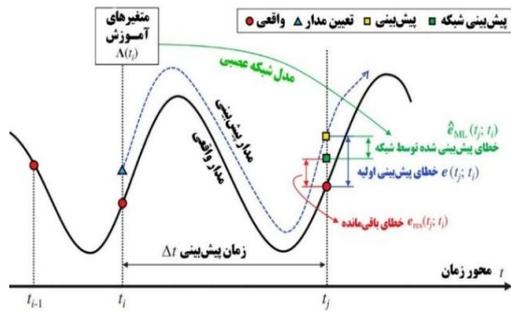
۵- حالت تخمین زده شده برای ماهواره در مبدأ

$$\text{زمانی } t_i \text{ بیان شده در قالب } {}^{COE}X(t)$$

همه متغیرهای ورودی در زمان t_i با بردار

$\Lambda(t_i)$ نمایش داده شده که برای هر زمان معادل

۱۶ سطر داده خواهد بود. در نهایت متغیر خروجی

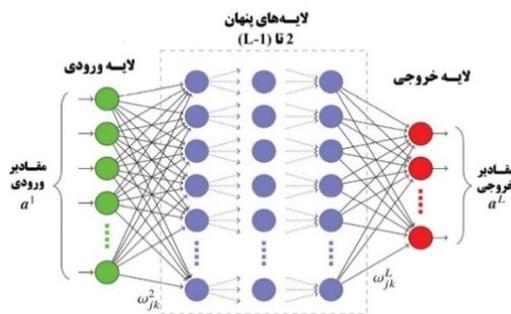


شکل ۷. فرایند کاهش خطای تعیین و انتشار مدار

۴-۵. ساختار شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی به صورت بالقوه توانایی تخمین هر تابع انتقال نرمی را در صورت بهره‌گیری از تعداد نورون و لایه‌های کافی دارا هستند [۵]. در این بخش مقدماتی از ساختار شبکه عصبی بیان می‌گردد. جزئیات بیشتر در مراجع [۵] و [۶] قابل مشاهده است.

شکل ۸ یک شبکه عصبی با ۱ لایه را نشان می‌دهد. لایه اول که حاوی متغیرهای آموزش $\Lambda(t_i, t_j)$ است به‌عنوان لایه ورودی شناخته شده و لایه آخر نیز حاوی متغیرهای هدف $e(t_j; t_i)$ است که لایه خروجی می‌باشد.



شکل ۸. ساختار کلی شبکه‌های عصبی مصنوعی

لایه‌های میان این دو لایه نیز لایه‌های پنهان نامیده می‌شوند. شبکه عصبی در حین آموزش تلاش می‌کند تا ارتباط پنهان موجود بین ورودی‌های $\Lambda(t_i, t_j)$ و خروجی $e(t_j; t_i)$ را کشف نماید که بتوان از آن برای تعمیم در ورودی‌های دیگر بهره برد. اگر خروجی نورون j ام

هدف ما که در واقع همان مؤلفه‌های خطای واقعی پیش‌بینی است به این صورت تعریف می‌شود:

$$e^{RSW}(t_j; t_i) = [e_x, e_y, e_z, e_{vx}, e_{vy}, e_{vz}]^T \quad (4)$$

از آنجایی که متغیر خروجی یعنی e^{RSW} دارای ۶ مؤلفه است، لذا ۶ شبکه عصبی مستقل برای تخمین هر یک از آن‌ها آموزش داده می‌شوند. نحوه‌ی انتخاب متغیرهای ورودی به صورت سعی و خطا و همچنین تکیه بر تجربیات بیان شده در بخش سوابق پژوهش انتخاب شده‌اند و به شکلی انجام شده که همه‌ی اطلاعات موجود را در برگیرد؛ لذا ممکن است در پژوهش‌های آتی حالت‌های بهینه‌تری نیز در انتخاب این مجموعه متغیرها به دست آید.

فرایند آموزش و آزمودن شبکه در شکل ۷ به نمایش گذاشته شده است. در طول تولید داده‌های آموزش، هر بردار حالت تخمین زده شده برای ماهواره، تا ۶ روز آتی انتشار می‌یابند. سپس به همراه $e(t_j; t_i)$ به‌عنوان مقدار خروجی هدف، برای آموزش شبکه استفاده می‌شوند. لازم به یادآوریست علت «انتشار» این است که هدف ما در کاربرد عملیاتی این پژوهش، علاوه بر تصحیح خطای تعیین مدار در مبدأ زمان مشاهده، کاهش خطای انتشار مدار در مبدأهای زمانی آتی نیز می‌باشد. پس از تکمیل فرایند آموزش، این شبکه قادر است با گرفتن ورودی‌های خارج از دادگان استفاده شده برای آموزش، خطای تخمینی $\hat{e}(t_j; t_i)$ را ارائه نماید. در حالت ایده‌آل مقدار خطای باقی‌مانده یعنی مقدار عبارت $e_{res}(t_j; t_i) = e(t_j; t_i) - \hat{e}(t_j; t_i)$ را صفر می‌کند. اما در عمل مقدار خطای باقی‌مانده صفر نمی‌شود و به‌عنوان پارامتری برای سنجش میزان کارایی و موفقیت عملکرد شبکه مورد استفاده و ارزیابی قرار خواهد گرفت.



در لایه L ام را با نماد a_j^L نشان دهیم، رابطه زیر برقرار است:

$$a_j^L = F_j^L \left(\sum_k \omega_{jk}^L a_k^{L-1} + b_j^L \right) \quad (5)$$

که در آن a_k^{L-1} خروجی نورون k ام در لایه (L-1) ام، ω_{jk}^L وزن نورون k ام در لایه (L-1) ام تا نورون j ام در لایه L ام و در نهایت $F_j^L(\cdot)$ تابع فعال‌سازی یا تابع انتقال لایه L ام می‌باشد. این روابط دولایه‌ی مجانب در شبکه را به هم متصل می‌نمایند. تابع فعال‌سازی F می‌تواند از بین توابع مرسوم متعدد انتخاب شود که کارایی و راندمان شبکه را تغییر خواهد داد. برحسب تابع فعال‌سازی انتخاب‌شده، شبکه عصبی می‌تواند برای حل مسائل طبقه‌بندی و همچنین رگرسیون به کارگیری شود. موضوع بهبود دقت تعیین و انتشار مدار که در این پژوهش به آن پرداخته شده به‌عنوان یک مسئله رگرسیون مدل می‌گردد. پس از بررسی منابع مذکور در بخش ۱، توابع انتقال log-sigmoid و tan-sigmoid به‌منظور به کارگیری در لایه‌های پنهان این شبکه مورد بررسی قرار گرفته و در نهایت تابع tan-sigmoid با نشان دادن توانمندی بهتر به‌عنوان گزینه نهایی انتخاب می‌گردد. در لایه خروجی نیز تابع همانی به‌عنوان تابع فعال‌ساز قرار می‌گیرد. رابطه ریاضی هر از این توابع در ادامه قابل مشاهده است:

$$\text{تابع انتقال log-sigmoid: } F_j^L(\xi) = \frac{1}{1 + e^{-\xi}}$$

$$\text{تابع انتقال tan-sigmoid: } F_j^L(\xi) = \frac{2}{1 + e^{-2\xi}} - 1$$

$$\text{تابع انتقال همانی: } F_j^L(\xi) = \xi$$

مقدار میانگین مجذور خطای باقیمانده نیز به‌عنوان تابع هزینه شبکه در نظر گرفته می‌شود و رابطه ریاضی آن به صورت زیر است:

$$C_{MSE} = \frac{1}{N} \left(\sum_{i=1}^N \frac{\|e_i - a_i^L\|^2}{2} \right) \quad (6)$$

که در آن N تعداد نقاط آموزش، e_i خطای واقعی و a_i^L تخمین زده‌شده توسط شبکه می‌باشد. هدف الگوریتم آموزش شبکه، کمینه کردن مقدار تابع هزینه C_{RMSE} می‌باشد. در این پژوهش از تکنیک انتشار به عقب^{۲۴} به‌منظور حل گرادیان تابع هزینه با توجه به وزن‌ها (ω_{jk}^L) و بایاس‌های (b_j^L) مختلف استفاده‌شده و از روش لونیبرگ-مارکوارت^{۲۵} به‌منظور به‌روزرسانی وزن‌ها و بایاس‌های شبکه بهره‌گیری شده است. انعطاف بالای شبکه‌های عصبی به‌ویژه هنگام استفاده از نورون‌های زیاد، باعث می‌شود احتمال بروز بیش‌برازش (Overfitting) افزایش یابد. به‌منظور جلوگیری از این مشکل، مجموع داده‌های آموزش به دو دسته‌ی آموزش و صحت‌سنجی^{۲۶} تقسیم می‌شوند. داده‌های صحت‌سنجی در واقع در فرایند یادگیری شبکه شرکت داده نمی‌شوند؛ بلکه در هنگام پیشرفت روند یادگیری با داده‌های آموزش، کارایی شبکه به کمک این داده‌های صحت‌سنجی مورد ارزیابی قرار می‌گیرد تا در صورت تشخیص نزدیک شدن به بیش‌برازش، فرایند بهینه‌سازی متوقف شود. روش متداول برای تشخیص این رخداد، کاهش تابع هزینه روی داده‌های آموزش در عین افزایش تابع هزینه روی داده‌های صحت‌سنجی است و در این پژوهش از همین ضابطه استفاده‌شده است.

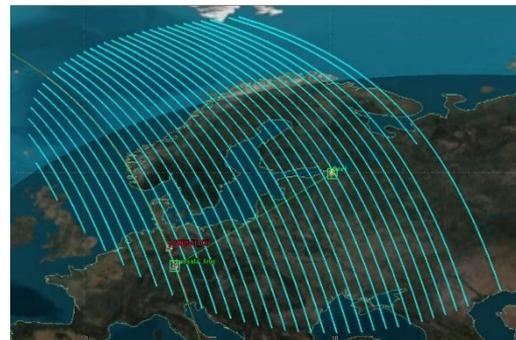
۵-۵. آموزش شبکه

به‌منظور آموزش شبکه از داده‌های واقعی ماهواره Landsat7 در طول ماه ۵ و ۶ سال ۲۰۱۸ میلادی استفاده می‌کنیم که مدل مشاهدات اپتیکی طبق جدول ۱ روی آن اعمال می‌گردد. بر اساس اعلام سرویس‌دهنده خدمات این ماهواره، خطای کمتر از ۱۰ متر در بردار موقعیت برای این داده‌ها تضمین شده است. مشخصات مداری این ماهواره برای روز اول سال ۲۰۱۸ در جدول ۲ قابل مشاهده است. داده‌های

دقیق موقعیتی این ماهواره در وبگاه USGS^{۲۷} در دسترس می‌باشد و زمان‌های انجام مانور طی گزارش‌های رسمی اعلام شده است. این ماهواره در طول سال ۲۰۱۸ مانور تصحیح مداری نداشته و داده‌های موقعیتی نیز در دستگاه ECI با مبدأ J2000 ارائه گردیده است. در شکل ۹ نمایی از نتیجه اعمال مدل مشاهدات اپتیکی روی این داده‌ها قابل مشاهده است.

جدول ۲. مشخصات مداری ماهواره Landsat7 [۲۷]

ردیف	نام پارامتر	مقدار
۱	کد اختصاصی NORAD	۲۵۶۸۲
۲	شیب مدار	۹۸.۱۹۰ درجه
۳	زاویه بعد گره صعودی	۷۴.۳۵۳ درجه
۴	خروج از مرکز	۰.۰۰۰۱
۵	آرگومان حضيض	۶۴.۳۲۴ درجه
۶	آنومالی میانگین	۲۹۵.۸۰۹ درجه
۷	ارتفاع مدار	۷۰۲ کیلومتر
۸	حرکت میانگین	۱۴.۵۷۱۲



شکل ۹. نتیجه اعمال مدل مشاهدات اپتیکی طبق جدول ۱ بر روی کل گذرهای واقعی ماهواره Landsat7 در طول ۲ هفته با نرم‌افزار STK. منحنی‌های آبی‌رنگ در واقع بخش‌هایی از مدار ماهواره هستند که سامانه اپتیکی مذکور می‌تواند آن را با هدف تعیین مدار مشاهده و ثبت نماید.

پارامترهای دادگان ورودی مطابق الگوی بیان شده در بخش ۳-۵ برای بازه زمانی ۶ هفته با شروع از تاریخ ۱ آوریل ۲۰۱۸ تولید می‌شود. در طول این ۶ هفته، ۶۰ گذر اپتیکی قابل ثبت

توسط سامانه اپتیکی مستقر در ایستگاه رصد استخراج شده و سپس مدل مشاهدات اپتیکی مطابق جدول بر روی آن اعمال می‌گردد. در مرحله بعد الگوریتم تعیین مدار گوس برای تعیین مدار اولیه^{۲۸} با استفاده از ۳ مشاهده‌ی اول، میانی و آخر هر گذر انجام شده و در نهایت با روش حداقل مربعات دسته‌ای^{۲۹}، همه‌ی داده‌های هر گذر به منظور تصحیح پارامترهای مداری به کار گرفته می‌شود. این مدار سپس به فواصل زمانی ۲۴ ساعت تا ۶ روز در بستر SGP4 انتشار می‌یابد و در هر مرحله با مقدار واقعی اعلام شده توسط ماهواره مقایسه شده و خطای مؤلفه‌های موقعیت و سرعت آن در دستگاه بدنه ماهواره، جهت درج در مجموعه دادگان هدف محاسبه می‌گردد. این مجموعه داده‌ها به صورت تصادفی به ۳ بخش زیر تقسیم می‌شوند:

۱- داده‌های آموزش (۸۰ درصد)

۲- داده‌های صحت‌سنجی (۱۰ درصد)

۳- داده‌های آزمایش (۱۰ درصد)

در نهایت نیز فرایند آموزش ۶ شبکه مستقل برای هر خروجی هدف، طبق مراحل بیان شده در بخش قبل طی شده و نمودارهای ارزیابی عملکرد شبکه رسم می‌گردند.

۶. ارزیابی عملکرد شبکه عصبی

۶-۱. بررسی تأثیر تعداد نورون‌ها و لایه‌ها بر عملکرد شبکه

هدف این بخش بررسی تأثیر تعداد نورون‌ها و لایه‌های پنهان بر عملکرد کلی شبکه و موفقیت آن در تخمین پارامترهای هدف که همان مؤلفه‌های خطای موقعیت و سرعت هستند می‌باشد.

در گام اول، فرایند آموزش و ارزیابی شبکه با تعداد نورون‌های متفاوت انجام می‌گیرد. بدین منظور معماری شبکه را با یک لایه‌ی پنهان و

تعداد نورون‌های ۱، ۲، ۴، ۸ و ۱۶ نورون برای «مؤلفه‌ی دوم خطای موقعیت» (خطای راستای حرکت ماهواره) به‌عنوان نمونه تشکیل داده و نتایج خروجی ارزیابی می‌گردد. در گام دوم نیز، فرایند آموزش و ارزیابی شبکه با تعداد نورون‌های ثابت و تعداد لایه‌های متفاوت انجام پذیرفت. بدین منظور معماری شبکه را با ۴ نورون و تعداد لایه‌های پنهان ۱، ۲، ۳ لایه برای «مؤلفه‌ی دوم خطای موقعیت» به‌عنوان نمونه تشکیل داده و نتایج خروجی بررسی خواهد شد. صفحه پیشرفت فرایند آموزش و ارزیابی شبکه عصبی در نرم‌افزار MATLAB که با استفاده از دستور *newff* فراخوانی می‌گردد در شکل ۱۰ قابل مشاهده است. پارامتر مورد استفاده برای ارزیابی میزان موفقیت شبکه، مقدار RMSE خطای باقی‌مانده در داده‌های آزمون^{۳۰} می‌باشد که جهت سهولت در انجام مقایسه، در جدول ۳ درج گردیده است.

افزایش بیش‌ازحد تعداد نورون‌ها و لایه‌های پنهان، موجب بروز بیش‌برازش روی داده‌های آموزش شده و شبکه از تخمین صحیح داده‌های آزمایش دور می‌شود. این فرایند بر روی ۵ خروجی دیگر نیز تکرار شده و نتایج مشابهی حاصل گردید که از تکرار آن‌ها اجتناب می‌کنیم.

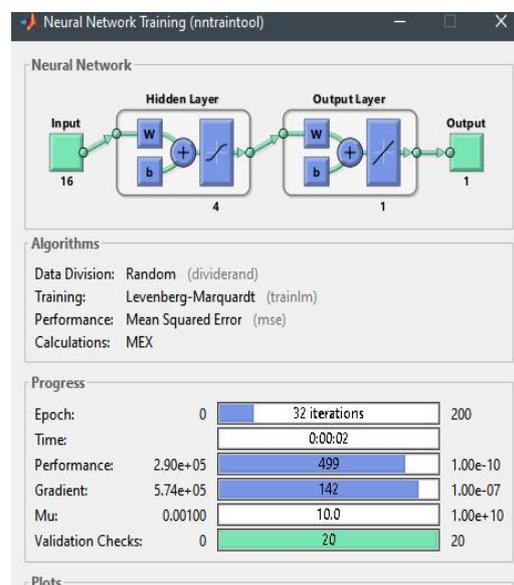
جدول ۳. مقایسه خطای باقیمانده در معماری‌های مختلف

ردیف	معماری شبکه	مقدار RMSE باقیمانده در داده‌های آزمون
۱	۱ لایه پنهان با ۱ نورون	۲۲.۹۰۸
۲	۱ لایه پنهان با ۲ نورون	۱۸.۰۹۲
۳	۱ لایه پنهان با ۴ نورون	۱۷.۷۳۳
۴	۱ لایه پنهان با ۸ نورون	۲۳.۲۵۱
۵	۱ لایه پنهان با ۱۶ نورون	۳۲.۱۹۸
۶	۱ لایه پنهان با ۴ نورون	۱۷.۷۳۳
۷	۲ لایه پنهان با ۴ نورون	۲۴.۱۱۱
۸	۳ لایه پنهان با ۴ نورون	۳۶.۱۴۶

۶-۲. بررسی توانایی تعمیم‌پذیری شبکه برای تعیین مدار در مبداهای زمانی آتی

مهم‌ترین کاربرد مطلوب از فرایند آموزش شبکه عصبی، توانایی تعمیم‌پذیری آن برای شرایطی خارج از محدوده داده‌های مورد استفاده برای آموزش می‌باشد. بدین منظور در این بخش به بررسی توانمندی تعمیم‌پذیری شبکه برای افزایش دقت تعیین مدار در مبداهای زمانی ۱ تا ۷ روز بعد از آخرین داده‌ی آموزش می‌پردازیم.

پارامترهای دادگان ورودی مطابق الگوی بیان شده در بخش ۵-۵ برای بازه زمانی ۶ هفته با شروع از تاریخ ۱ آوریل ۲۰۱۸ تولید می‌شود. در این بخش نیاز به انتشار مدار در بستر SGP4 نیست؛ بلکه بردار حالت فقط در مبدأ زمان مشاهده در هر مرحله با مقدار واقعی اعلام‌شده توسط ماهواره مقایسه شده و خطای مؤلفه‌های موقعیت و سرعت آن در دستگاه بدنه ماهواره،



شکل ۱۰. نمای کلی معماری و روند آموزش شبکه

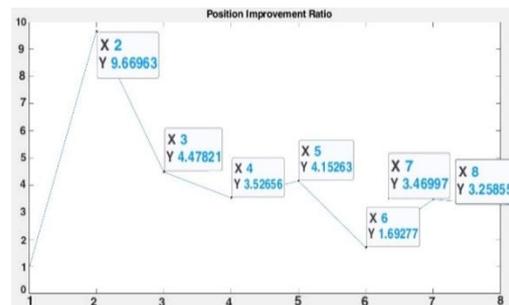
همان‌طور که از مشاهده جدول ۳ پیداست، بهترین نتیجه برای حالت ۴ نورون با ۱ لایه پنهان حاصل شده است. کاهش تعداد نورون‌ها از این مقدار، موجب عدم توانایی شبکه در انطباق کامل با داده‌های آموزش می‌گردد؛ همچنین

جهت درج در مجموعه دادگان هدف محاسبه می‌گردد.

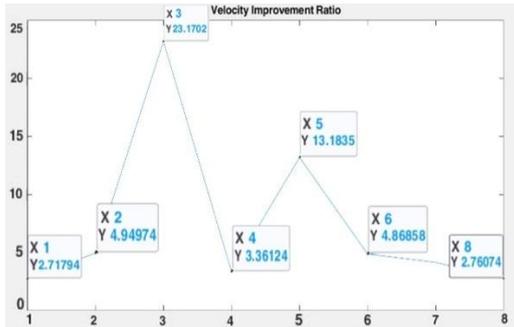
مجموعه داده‌های حاصل شده به‌عنوان ورودی عبارتند از ۱۵ پارامتر که در ۶۰ گذر مختلف تولید شده و هر یک برای زمان مبدأ محاسبه می‌گردند. لذا مجموعه دادگان ورودی به شکل یک ماتریس ۱۵ سطر در ۶۰ ستون خواهد بود. برای هر یک از ۶ پارامتر خطا، یک شبکه مجزا آموزش داده شده و تعداد لایه‌ها و نورون‌های بهینه مورد نیاز در هر شبکه مانند بخش قبل استنتاج می‌گردد. تعداد ۲ لایه پنهان با ۸ نورون به‌عنوان معماری بهینه برای هر یک از ۶ شبکه انتخاب شد.

در نهایت داده‌های مشاهداتی با مبدأهای زمانی ۱ تا ۷ روز بعد از آخرین داده‌ی آموزش، با روش گاوس و حداقل مربعات به پارامترهای مداری تبدیل شده و به‌عنوان ورودی به شبکه داده می‌شود تا توانمندی تعمیم‌پذیری شبکه برای تخمین مدار در مبدأهای زمانی آتی مورد ارزیابی قرار گیرد. به‌منظور رسیدن به درک صحیح از

میزان موفقیت فرایند، پارامتر $\alpha = \frac{e(t_j; t_i)}{e_{res}(t_j; t_i)}$ یعنی چند برابر بودن خطای اولیه نسبت به خطای باقی‌مانده‌ی نهایی، به‌عنوان بهترین ملاک قضاوت انتخاب می‌گردد. بدیهی است با افزایش این مقدار، موفقیت شبکه نیز بیشتر ارزیابی می‌شود. نتایج ارزیابی پارامتر فوق برای اندازه بردار خطای موقعیت و اندازه بردار خطای سرعت به صورت زیر حاصل شد:



شکل ۱۱. نمودار نسبت افزایش دقت بردار موقعیت ماهواره برای ۱ تا ۷ روز پس از آخرین داده آموزش



شکل ۱۲. نمودار نسبت افزایش دقت بردار سرعت ماهواره برای ۱ تا ۷ روز پس از آخرین داده آموزش

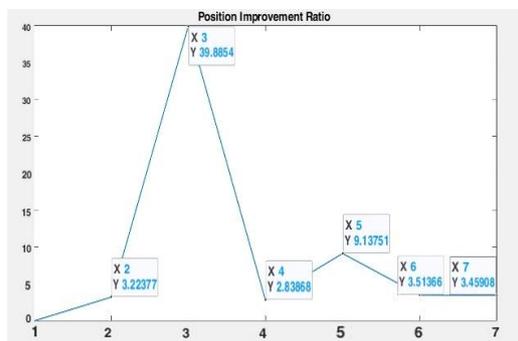
با توجه به نمودارهای شکل ۱۱ و شکل ۱۲، نتایج خروجی بیان‌گر افزایش دقت تخمین موقعیت مداری بین ۱.۶ تا ۹.۶ برابر و افزایش دقت تخمین سرعت مداری بین ۲.۷ تا ۲۳.۱ برابر می‌باشد که مقادیر بسیار نویدبخشی است. نکته‌ی قابل توجه دیگر، کاهش میزان بهبود دقت با افزایش زمان گذشته از آخرین داده‌ی آموزش می‌باشد. پیشنهاد می‌شود در مطالعات آتی این موضوع با به‌روزرسانی آموزش شبکه پس از هر بار دریافت مشاهده جدید، مورد بررسی قرار گیرد.

۳-۶. بررسی توانایی تعمیم‌پذیری شبکه برای انتشار مدار در مبدأهای زمانی آتی

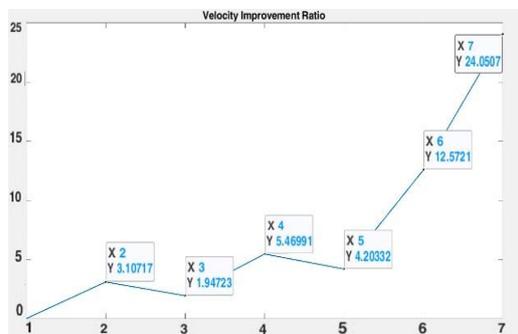
در این بخش به بررسی توانمندی تعمیم‌پذیری شبکه برای افزایش دقت انتشار مدار در مبدأهای زمانی ۱ هفته و ۱ ماه بعد از آخرین داده‌ی آموزش می‌پردازیم. پارامترهای دادگان ورودی مطابق الگوی بیان شده در بخش ۵-۵ می‌باشد؛ لذا مجموعه دادگان ورودی به شکل یک ماتریس ۱۶ سطر در ۴۲۰ ستون خواهد بود. در نهایت داده‌های مشاهداتی با مبدأهای زمانی ۱ هفته و ۱ ماه بعد از آخرین داده‌ی آموزش، با روش گاوس و حداقل مربعات به پارامترهای مداری تبدیل شده و سپس به فواصل زمانی ۲۴ ساعت تا ۶ روز در بستر SGP4 انتشار می‌یابند. سپس این مدار به‌عنوان ورودی به شبکه داده می‌شود تا توانمندی تعمیم‌پذیری شبکه برای انتشار مدار در مبدأهای زمانی آتی مورد ارزیابی



دقت تخمین سرعت مداری انتشار یافته، بین ۲ تا ۲۴ برابر می‌باشد.



شکل ۱۵. نمودار نسبت افزایش دقت بردار موقعیت برای انتشار ۳۰ تا ۳۷ روز پس از آخرین داده آموزش

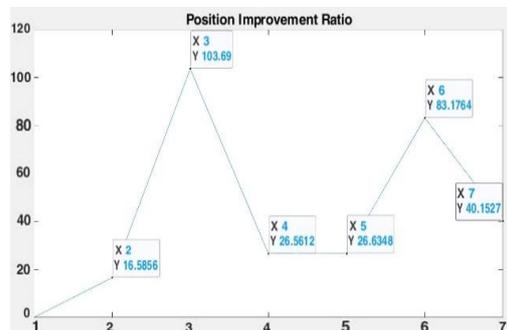


شکل ۱۶. نمودار نسبت افزایش دقت بردار سرعت ماهواره برای انتشار ۳۰ تا ۳۷ روز پس از آخرین داده آموزش

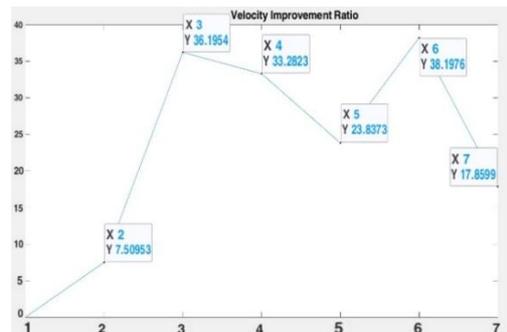
۷. جمع‌بندی و نتیجه‌گیری

در این پژوهش توانمندی شبکه‌های عصبی مصنوعی به منظور بهبود دقت تعیین مدار اجرام فضایی مبتنی بر مشاهدات اپتیکی زمین پایه و همچنین کاهش خطای انتشار مدار مورد بررسی قرار گرفت. طی این مطالعه پس از بررسی اثرات معماری شبکه، انتخاب حالت بهینه و سپس آموزش شبکه، توانایی تعمیم‌پذیری آن برای تخمین مدار و انتشار مدار در مبداهای زمانی ۱ هفته و ۱ ماه پس از آخرین داده آموزش، مورد بررسی قرار گرفت که در همه‌ی حالات شبکه موفق به کاهش خطای بردار موقعیت و بردار سرعت ماهواره به میزان بیش از ۶۰٪ شده است.

قرار گیرد. نتایج ارزیابی پارامتر α تعریف شده در بخش ۶-۲، برای اندازه بردار خطای موقعیت و اندازه بردار خطای سرعت در انتشار ۱ هفته‌ای به صورت زیر حاصل شد:



شکل ۱۳. نمودار نسبت افزایش دقت بردار موقعیت برای انتشار ۱ تا ۷ روز پس از آخرین داده آموزش



شکل ۱۴. نمودار نسبت افزایش دقت بردار سرعت ماهواره برای انتشار ۱ تا ۷ روز پس از آخرین داده آموزش

نمودارهای شکل ۱۳ و شکل ۱۴ بیان‌گر افزایش دقت تخمین موقعیت مداری انتشار یافته بین ۱۶ تا ۱۰۳ برابر و افزایش دقت تخمین سرعت مداری انتشار یافته بین ۷ تا ۳۸ برابر می‌باشند.

و در نهایت نتایج محاسبه پارامتر ارزیابی مذکور، برای اندازه بردار خطای موقعیت و اندازه بردار خطای سرعت در انتشار ۱ ماهه به صورت نمودارهای شکل ۱۵ و ۱۶ حاصل شد.

همان‌طور که در شکل‌های ۱۵ و ۱۶ قابل مشاهده است، در حالت انتشار ۱ ماهه نتایج خروجی بیان‌گر افزایش دقت تخمین موقعیت مداری انتشار یافته بین ۳ تا ۳۹ برابر و افزایش

- Random Hidden Nodes, IEEE Transactions on Neural Networks, Vol. 17, No. 4, 2006.
- [8] K. Williams, Prediction of Solar Activity with a Neural Network and Its Effect on Orbit Prediction, Johns Hopkins APL Technical Digest, Vol. 12, No. 4, 1991.
- [9] K. P. Macpherson and A. J. Conway, Prediction of Solar and Geomagnetic Activity Data Using Neural Networks, Journal of Geophysical Research: Space Physics, Vol. 100, No. A11, 1995.
- [10] D.-J. Jwo and C.-S. Chang, Neural Network Aided Adaptive Kalman Filtering for GPS Applications, 2004 IEEE International Conference on Systems, Man and Cybernetics, Vol. 4, IEEE Publ., Piscataway, NJ, 2004.
- [11] C. Sánchez-Sánchez and D. Izzo, Real-Time Optimal Control via Deep Neural Networks: Study on Landing Problems, Journal of Guidance, Control and Dynamics, Vol. 41, 2016.
- [12] C. Sánchez-Sánchez and D. Izzo, Learning the Optimal State-Feedback Using Deep Networks, 2016 IEEE Symposium Series on Computational Intelligence (SSCI), IEEE Publ., Piscataway, NJ, 2016.
- [13] A. Mereta and D. Izzo, Machine Learning of Optimal Low-Thrust Transfers Between Near-Earth Objects, International Conference on Hybrid Artificial Intelligence Systems, Springer, 2017.
- [14] H. Peng and X. Bai, Improving Orbit Prediction Accuracy Through Supervised Machine Learning, Advances in Space Research, Vol. 61, pp. 1–30, 2018.
- [15] H. Peng and X. Bai, Recovering Area-to-Mass Ratio of Resident Space Objects Through Data Mining, Acta Astronautica, Vol. 142, Jan. 2018.
- [16] H. Peng and X. Bai, Limits of Machine Learning Approach on Improving Orbit Prediction Accuracy, Advanced Maui Optical and Space Surveillance Technologies (AMOS) Conference, Maui Economic Development Board, Wailea Marriott, Sept. 2017.
- [17] H. Peng and X. Bai, Artificial Neural Network-Based Machine Learning Approach to Improve Orbit Prediction Accuracy, Journal of Spacecraft and Rockets, Vol. 55, pp. 1-13, 2018.
- [18] J. Yu, S. Cho and J. H. Jo, KOSPAW Test bed—A Phased Array Radar for Space Situational Awareness, 2020 IEEE International Radar Conference (RADAR), pp. 786-791, 2020.
- [19] M. A. Steindorfer, Space debris science at the satellite laser ranging station Graz,

در پژوهش‌های آتی، مدت‌زمان داده‌های ورودی به شبکه می‌تواند از ۶ هفته به چند سال افزایش پیدا کند تا رفتارهای متناوب کندتغییر در خطای تعیین مدار و خطای مدل انتشارگر نیز توسط شبکه تشخیص داده‌شده و تصحیح گردد. همچنین به‌جای در نظر گرفتن یک ایستگاه مشاهده اپتیکی می‌توان از مدل چند ایستگاهی استفاده کرد تا تعداد داده‌های بیشتری برای آموزش شبکه فراهم‌شده و همچنین خطای کمتری در تعیین مدار اولیه ایجاد شود. پیشنهاد بعدی، بررسی توانایی تعمیم‌پذیری شبکه برای سایر اجرام فضایی که در صفحات یا ارتفاعات مداری متفاوت نسبت به ماهواره‌ی فراهم‌کننده‌ی داده‌های آموزش قرار دارند، می‌باشد. در گام بعدی نیز می‌توان از سایر روش‌های هوشمند مانند ماشین بردار پشتیبان، سری‌های زمانی و همچنین الگوریتم ژنتیک به‌منظور تخمین خطای مدار بهره برد و نتایج را با خروجی این پژوهش مقایسه کرد.

۸. مآخذ

- [1] C. Pardini and L. Anselmo, Evaluating the impact of space activities in low earth orbit, Acta Astronautica, Vol. 184, pp. 11-22, 2021.
- [2] Y. Wang and P. Gurfil, Dynamical Modeling and Lifetime Analysis of Geostationary Transfer Orbits, Acta Astronautica, Vol. 128, Nov.–Dec. 2016.
- [3] T.S. Kelso, Analysis Iridium 33 Cosmos 2251 Collision, Proceedings of the 19th AIAA/AAS Astrodynamics Specialist Conference, Vol. 135, 2009.
- [4] A. Huang, Mastering the Game of Go with Deep Neural Networks and Tree Search, Nature, Vol. 529, No. 7587, 2016.
- [5] Y. Abu-Mostafa and M. Magdon-Ismail, Learning from Data, AMLBook, Chapter 7: Neural Networks, 2015.
- [6] K.-L. Du and M. N. S. Swamy, Neural Networks and Statistical Learning, Springer, London, 2014.
- [7] G.-B. Huang and L. Chen, Universal Approximation Using Incremental Constructive Feedforward Networks with



- Term Orbit Prediction. Remote Sensing, Vol. 15, No. 133, 2023.
- [36] F. Shamlu and A. Naghash, Satellite Orbit Prediction Through Observation Data and the Artificial Neural Networks. Space Science and Technology, Vol. 10, No. 2, 2017.
- [37] S. Farzaneh, M.A. Sharifi and A. Abdolmaleki, Prediction of atmospheric density correction coefficients using neural networks, SEPEHR, Vol. 31, No. 121, 2022.
- [38] D. Boostan, Predicting Orbital State Vector of Satellites Using Time-Series Neural Networks, Space Science and Technology, Vol. 11, No. 3, 2018.

۹. پی نوشت

1. Space Situational Awareness
 2. Iridium
 3. Cosmos
 4. AlphaGo
 5. Classification
 6. Support Vector Machine
 7. Two-Line Elements
 8. Solar Radiation Pressure
 9. Atmospheric Drag
 10. Near Infrared
 11. Dark Current Noise
 12. Read-Out Noise
 13. External Triggering
 14. Semi-Major Axis
 15. Eccentricity
 16. Inclination
 17. Right Ascension of Ascending Node
 18. Argument of Perigee
 19. True Anomaly
 20. Initial Orbit Determination
 21. Radial
 22. Along-Track
 23. Cross-Track
 24. Back Propagation
 25. Levenberg-Marquardt
 26. Validation
 27. https://landsat.usgs.gov/landsat/definitive_ephemeris/ephemeris/
 28. Gauss Initial Orbit Determination
 29. Batch Least Square
 30. Test Data
- International Conference on Environment and Electrical Engineering, pp. 1-5, 2017.
- [20] T. Schildknecht, Improved Space Object Observation Techniques using CMOS Detectors'', 6th European Conference on Space Debris, 2013.
- [21] J. Choi and J. H. Jo, Optical Tracking Data Validation and Orbit Estimation for Sparse Observations of Satellites by the OWL-Net'', Sensors, Vol. 18, no. 6, 2018.
- [22] L. Simms, Autonomous subpixel satellite track end point determination for space-based images, Applied optics, Vol. 50, 2011.
- [23] D. T. Renshaw and J. A. Christine, Subpixel Localization of Isolated Edges and Streaks in Digital Images, Journal of Imaging, Vol. 6, 2020.
- [24] R. Haussmann, Streak detection of space debris by a passive optical sensor, 8th European Conference on Space Debris, Vol. 8, 2021.
- [25] S. Jing , A Sub-Pixel Centroid Algorithm for Star Image Based on Gaussian Distribution, Trans. Japan Soc. Aero. Space, Vol. 53, 2011.
- [26] B. Jilete, OPTICAL OBSERVATIONS IN ESA'S SSA PROGRAMME, RMxAA (Serie de Conferencias), Vol. 51, pp. 139-143, 2019.
- [27] P. Gurfil, Modern Astrodynamics, Elsevier Astrodynamics Series, 1st ed., 2006.
- [28] D. Vallado, Fundamentals of Astrodynamics and Applications, 4th ed., Microcosm Press, 2013.
- [29] P. R. Escobal, Methods of Orbit Determination, John Wiley and Sons, Inc., New York, 1965.
- [30] M. Mahooti, Initial orbit determination (Angles-only Method), Available at mathworks.com, v1.1.1.1, 2020.
- [31] H. D. Curtis, Orbital Mechanics for engineering students, Elsevier Aerospace Engineering Series, 3rd ed., 2014.
- [32] O. Montenbruck and E. Gill, Satellite Orbits: Models, Methods and Applications, Springer-Verlag, 2005.
- [33] B. D. Abbeele, Comparing IOD methods on very short arc observations of GEO objects from the MeerLICHT telescope, Master Thesis, Delft University of Technology, 2021.
- [34] F.R. Hoots and R.A. Glover, History of Analytical Orbit Modeling in the U. S. Space Surveillance System, Journal of Guidance, Control and Dynamics, AIAA, Vol. 27, No. 2, 2004.
- [35] K. Wang and J Liu, Real-Time LEO Satellite Orbits Based on Batch Least-Squares Orbit Determination with Short-

