

# Predicting Orbital State Vector of Satellites Using Time-Series Neural Networks

**D. Boostan<sup>1\*</sup>**

1. Department of Electrical Engineering, Ghouchan University of Technology

\*Postal Code: 94771-67335, Ghouchan, IRAN

**d.bustan@qiet.ac.ir**

*Prediction of satellite orbital position is a critical requirement for all satellite ground stations. In this paper, a new viewpoint for predicting orbital position of satellites is presented. In contrast to traditional methods which are based on Kepler's law, the proposed method, is solely based on past observation of a given satellite. In contrast to traditional algorithms which have neglected some of the orbital perturbations, the most important feature of this method is considering all orbital perturbations by using real data. TLEs (Two Line Element sets) are the most available real data and are used in this research as the main data source. Using the capability of neural networks for time series prediction over available data, results in a fast and accurate orbital position predictor. The comparison between the output of our proposed method, SPG4 (Simplified General Perturbation version 4) propagator and real orbital position of a given satellite, shows the effectiveness of this algorithm.*

**Keywords:** Time series prediction, Artificial neural networks, TLE (Two Line Elements), Satellite orbital position

---

1. Assistant Professor (Corresponding Author)

# پیش‌بینی بردار حالت مداری ماهواره با استفاده از سری‌های زمانی و شبکه‌های عصبی

دانیال بوستان\*

۱- گروه مهندسی برق، دانشکده فنی و مهندسی برق، دانشگاه صنعتی قوچان

قوچان، کدپستی: ۶۷۳۳۵-۹۴۷۷۱

d.bustan@qiet.ac.ir

در این مقاله، روشی نوین برای پیش‌بینی موقعیت مداری ماهواره با استفاده از سری‌های زمانی و شبکه‌های عصبی معرفی شده است. در این روش، بر خلاف روش‌های معمول پیش‌بینی مدار، از قوانین کپلر استفاده نشده و از قدرت پیش‌بینی سری‌های زمانی در شبکه‌های عصبی برای پیش‌بینی موقعیت مداری استفاده شده است. مهمترین مزیت روش پیشنهادی نسبت به روش‌های موجود، در استفاده از داده‌های واقعی است. چرا که روش‌های موجود عموماً با ساده سازی روابط و نیز حذف برخی از اغتشاشات معمولاً دارای خطا بوده و استفاده از معادلات بازگشتی نیز به‌طور افزاینده‌ای این خطا را افزایش می‌دهد. در دسترس ترین داده واقعی، TLE بوده و دقت آنها نیز در پژوهش‌های مختلف به اثبات رسیده است. لذا در روش پیشنهادی استفاده از این داده‌ها در دستور کار قرار گرفته است. نتایج شبیه‌سازی و مقایسه این روش با الگوریتم SGP4 و داده‌های واقعی، نشان از کارآمدی روش پیشنهادی دارد.

واژه‌های کلیدی: پیش‌بینی سری زمانی، شبکه‌های عصبی، TLE، بردار حالت مداری

Ascending Node (RAAN)

Simplified Deep-space  
Perturbation Version 4 (SDP4)

Simplified General Perturbation  
version 4 (SGP4)

True Anomaly (TA)

Two line element set (TLE)

Periapsis Radius (PR)

Unscented Kalman Filter (UKF)

اغتشاشات ساده‌سازی شده

فضای عمیق

اغتشاشات کلی ساده‌سازی

شده

ناهنجاری واقعی

المان دو خطی

شعاع حضیض

فیلتر کالمن خنثی

## مقدمه

پیش‌بینی موقعیت مداری ماهواره یکی از ضروری ترین نیازهای هر ایستگاه زمینی است. محاسباتی مانند زمان طلوع و غروب ماهواره در ایستگاه زمینی دریافت، محاسبه زمان و چگونگی پوشش مناطق مورد نظر توسط یک ماهواره خاص، پیش‌بینی تقرب [۱] و... وابسته

## علائم و اختصارات

Adaptive Network-based Fuzzy  
Inference System (ANFIS)

Argument of Perigee (AP)

Global Positioning System (GPS)

High precision orbit propagator  
(HPOP)

Inclination (i)

Mean Anomaly (MA)

Mean Motion (MM)

Nonlinear Auto-Regressive  
(NAR)

Nonlinear Auto-Regressive with  
eXogenous input (NARx)

Right Ascension of the

سیستم استنتاج فازی -

عصبی تطبیقی

آرگومان حضیض

سیستم موقعیت‌یابی جهانی

تخمین مدار با دقت بالا

شیب مداری

ناهنجاری متوسط

حرکت متوسط

رگرسیون خودکار غیرخطی

رگرسیون خودکار غیرخطی  
با ورودی خارجی

بعد گرہ صعودی

هدف از این مقاله، توسعه روش پیشنهادی معرفی شده در [۱۳] بوده که توسط نویسنده معرفی شده است. این ایده در [۱۴] نیز مورد استفاده قرار گرفته و تاثیر فشار تشعشعات خورشیدی بر دقت روش مطالعه شده است. در [۱۳] نگرشی نوین به مقوله پیش‌بینی موقعیت ماهواره معرفی شده است. در این نگرش تلاش بر آن بوده است که برای پیش‌بینی موقعیت یک ماهواره، از داده‌های واقعی همان ماهواره استفاده شود. مزیت این روش در آن است که تمامی اغتشاشات موثر بر مدار ماهواره در نظر گرفته خواهد شد. با توجه به اینکه در دسترس‌ترین داده‌های واقعی از موقعیت مداری ماهواره‌ها، پارامترهای TLE آنها می‌باشد، روش پیشنهادی این مقاله و [۱۳-۱۴]، استفاده از این داده‌ها را در دستور کار قرار داده است.

برای آشنایی با TLE و داده‌های موجود در آن، علاقه‌مندان می‌توانند به مرجع [۱۷] مراجعه نمایند.

در این روش، با استفاده از قدرت پیش‌بینی سری زمانی در شبکه‌های عصبی، با در اختیار داشتن چند موقعیت مداری در روزهای متوالی، موقعیت مداری ماهواره در روزهای آینده تخمین زده می‌شود.

مقایسه نتایج روش پیشنهادی با داده‌های واقعی نشان از صحت عملکرد و دقت بالای آن دارد.

این مقاله از جهات زیر با [۱۳] و [۱۴] متفاوت است:

۱- در [۱۳] و [۱۴] مستقیماً از داده‌ها TLE استفاده شده است. درحالی‌که در این پژوهش داده‌های TLE، ابتدا به بردار حالت (داده‌های مختصات کارتزین  $(r, v)$ ) تبدیل شده و پیش‌بینی بر حسب این بردارها صورت می‌گیرد. داده‌های موقعیت مداری بر حسب بردار حالت، نسبت به پارامترهای موجود در TLE هموارتر بوده و لذا دقت تخمین با استفاده از این داده‌ها بیشتر خواهد بود.

۲- در این پژوهش از شبکه‌های عصبی مصنوعی استفاده شده است در حالی‌که در [۱۳] از anfis استفاده شده بود.

۳- نگاهت غیرخطی به کار رفته در این مقاله در تبدیل داده‌های موجود در TLE به بردار حالت، امکان استفاده از ورودی افزونه را فراهم می‌کند. بدیهی است که استفاده از ورودی افزونه، می‌تواند به افزایش دقت پیش‌بینی منجر شود.

۴- بر خلاف [۱۳] و [۱۴]، تمام شبکه‌های عصبی پیش‌بینی‌کننده، از ساختار یکسانی استفاده می‌کنند.

۵- در [۱۳] و [۱۴]، به منظور یکسان‌سازی فواصل زمانی داده‌ها از درون‌یابی خطی استفاده شد. اما در این مقاله، از الگوریتم SGP4 به این منظور استفاده شده است.


به دقت بالای پیش‌بینی موقعیت مداری آینده ماهواره دارد. تاکنون تلاش‌های زیادی در خصوص پیش‌بینی دقیق موقعیت ماهواره صورت گرفته است. مرجع [۲] لیست تقریباً جامعی از این روش‌ها ارائه کرده است. از مهمترین این روش‌ها می‌توان به روش‌های عمومی مانند SGP4 برای ماهواره‌های با پریود مداری کمتر از ۲۲۵ دقیقه و SDP4 برای ماهواره‌های با پریود مداری بیش از ۲۲۵ دقیقه [۳] و روش‌های اختصاصی مانند HPOP [۴] و مانند آن اشاره کرد. وجه تمایز عمده این روش‌ها در الگوریتم‌های محاسباتی و میزان در نظر گرفتن انواع اغتشاشات مداری و استفاده از مدل‌هایی با جزئیات متفاوت می‌باشد. این موارد باعث تفاوت در خروجی محاسبات و در نتیجه تفاوت دقت در روش‌های مختلف شده است. بدیهی است که استفاده از جزئیات بیشتر در پیاده‌سازی الگوریتم‌ها باعث افزایش دقت محاسبات شده و در نتیجه خروجی الگوریتم به داده‌های واقعی نزدیک‌تر خواهد بود.

در کنار روش‌های ذکر شده، تلاش‌هایی نیز به منظور پیش‌بینی موقعیت مداری ماهواره با استفاده از داده‌های واقعی صورت گرفته است. عمده این تلاش‌ها مربوط به تعیین مدار به صورت برخط و با استفاده از داده‌های GPS موجود در ماهواره بوده است [۴-۷]. اشکال عمده این تلاش‌ها، در اختیار نبودن داده‌های GPS مورد استفاده و خاص بودن روش‌های پیشنهادی برای ماموریت‌های ذکر شده برای هر ماهواره بوده که امکان تعمیم روش‌های ذکر شده را برای سایر مدارها از بین برده است.

از آنجاکه الگوریتم‌های ارائه شده برای پیش‌بینی موقعیت مداری عموماً روش‌های تقریبی بوده و محاسبات آنها همواره با خطا همراه است، تلاش‌هایی به منظور افزایش دقت این الگوریتم‌ها صورت گرفته است. از آن جمله می‌توان به [۸] اشاره کرد که از فیلتر کالمن خنثی (UKF) در مدل غیرخطی دینامیک مداری بهره برده است. مرجع [۹] نیز با مطالعه ماهواره‌هایی با رد زمینی تکراری، به تعیین مشخصات مداری آنها پرداخته است. اصلاح انحراف، روش پیشنهادی [۱۰] برای افزایش دقت پیش‌بینی موقعیت مداری ماهواره است. در مرجع [۱۱] نیز از ماشین بردار پشتیبان برای بهبود پیش‌بینی بهره گرفته شده است. ابزار به کار رفته برای افزایش دقت تخمین مدار، در مرجع [۱۲] الگوریتم‌های یادگیری ماشین با ناظر است.

هر مدار توسط شش عنصر کپلری به طور کامل تعریف خواهد شد و مقدار «مبدأ» زمان اعتبار پارامترها را مشخص می‌کند. مدار واقعی اجرام (و عناصر مداری آن) هنگامی که در معرض آشفتگی‌های گرانشی قرار می‌گیرند تغییر می‌کند بنابراین مدار تعریف شده بوسیله عناصر مداری فقط تقریب ریاضی مداری در یک زمان خاص است که مشخصه مبدأ (اپوک (epoch)) بیان‌کننده آن است. شکل ۱، مشخص‌کننده پارامترهای مداری است که در زیر تعریف شده اند.

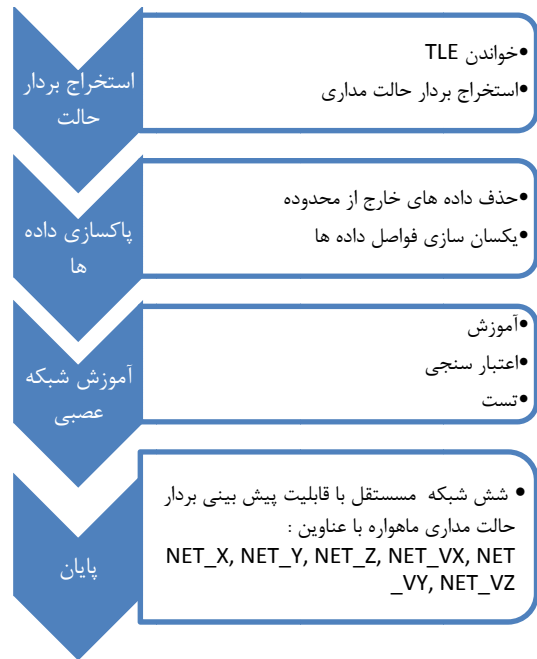
خروج از مرکز (e)، نیم‌قطر بزرگ (a)، شیب مداری (i)، بعد گره صعودی ( $\Omega$ )، آرگومان حضیض ( $\omega$ )، که جهت بیضی را در صفحه مداری مشخص می‌کند و ناپهنجاری متوسط ( $M_0$ ) که موقعیت مداری جرم را بر روی بیضی مشخص می‌کند.



شکل ۱۳- پارامترهای مداری

عموماً برای بیان موقعیت مداری ماهواره، از دو روش می‌توان استفاده می‌شود: روش اول، بیان موقعیت مداری به کمک TLE بوده و روش دوم، بیان موقعیت با استفاده از بردار حالت. در روش اول، اطلاعات مورد نیاز برای تعیین موقعیت مداری ماهواره، به صورت پارامترهایی در یک فرمت از پیش تعیین شده به نام TLE قرار می‌گیرند.

TLE، که با نام (NORAD two-line element set) نیز شناخته می‌شود، مشتمل بر دو خط بوده که در هر خط ۶۹ کاراکتر وجود دارد. با استفاده از شش پارامتر مداری موجود در TLE (شیب مداری، بعد گره صعود، خروج از مرکز، آرگومان حضیض، ناپهنجاری متوسط و حرکت متوسط) و به کمک مدل مدار NORAD's SGP4/SDP4، می‌توان موقعیت و سرعت یک ماهواره را در فضا بدست آورد. تنها کاراکترهای مجاز در این فرمت، کاراکترهای عددی ۰-۹، حروف بزرگ A-Z، نقطه، فاصله و علامت‌های مثبت و منفی است جدول‌های (۱) و (۲) محل قرارگیری پارامترهای مداری را در TLE نشان می‌دهد [۱۵]. در شکل ۱۴، یک نمونه TLE، نشان داده شده است.



شکل ۱۲- بلوک دیاگرام روش پیشنهادی

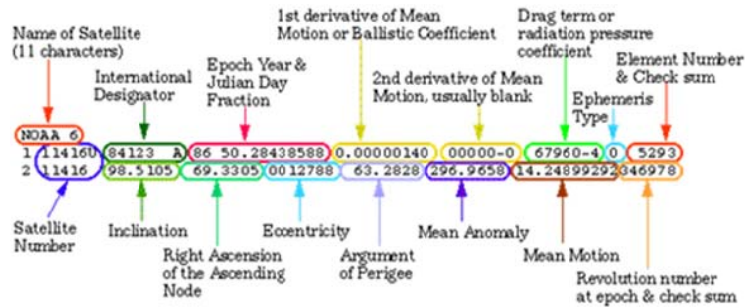
این تغییرات منجر به افزایش دقت روش پیشنهادی این پژوهش نسبت به [۱۳] و [۱۴] شده است. شایان ذکر است که TLE، به عنوان میانگینی از مشاهدات رادارهایی که به منظور پایش فضای بالای زمین ایجاد شده‌اند، گزارش می‌شود. در حقیقت این داده‌ها، موقعیت دقیق نیستند و به تخمینی از موقعیت واقعی استفاده می‌شوند. اما به توجه به اثبات دقت این داده‌ها و نیز بهره‌گیری از این داده‌ها در ایستگاه‌های زمینی، استفاده از این داده‌ها در این پژوهش در دستور کار قرار گرفته است.

لازم به ذکر است که هدف از ارایه این روش، به هیچ عنوان به معنای معرفی روشی جایگزین برای الگوریتم‌هایی مانند SGP4 نیست. بلکه صرفاً نگرشی نوین به مکانیک مداری بوده و با هدف فراهم آوردن بستر اولیه به منظور امکان استفاده از هوش مصنوعی در این زمینه ارائه شده است.

در ادامه، ابتدا پارامترهای مداری ماهواره تعریف و سپس شبکه عصبی پیش‌بینی کننده سری زمانی معرفی شده است. پس از آن روش پیشنهادی بیان شده و در قسمت شبیه‌سازی، به مقایسه روش پیشنهادی با الگوریتم SGP4 و نیز داده‌های واقعی پرداخته شده است.


## پارامترهای مداری

موضوع علم مکانیک مداری، تعیین و یا پیش‌بینی موقعیت مداری ماهواره در بازه‌های زمانی مشخص است.



شکل ۱۴- یک TLE و محل قرار گیری پارامترهای مداری در آن [۱۵]

در روش دوم، موقعیت مداری ماهواره به کمک دو بردار بیان می‌شود. به این بردارها، بردار حالت نیز گفته می‌شود. در هر لحظه زمانی، بردار حالت مداری یک ماهواره شامل بردار سرعت ( $v$ ) و بردار مکان ( $r$ ) آن ماهواره نسبت به مرکز زمین است. این دو بردار به همراه زمان، که به آن اپوک گفته می‌شود، می‌توانند مسیر حرکت یک ماهواره در فضا را بصورت منحصر به فرد مشخص کند. مؤلفه‌های این بردارها باید در دستگاه مختصاتی اندازه‌گیری شود که به زمین متصل بوده و ثابت باشد. یکی از معمول ترین دستگاه‌های مختصاتی که برای این منظور به کار می‌رود، دستگاه مختصات زمین مرکز (geo-centric) نشان داده در شکل ۴ است. در این دستگاه، محور  $x$  به سمت نقطه اعتدال بهاری اشاره کرده و صفحه  $x-y$  همان صفحه استواست. در این دستگاه محور  $z$  نیز همان محور چرخش زمین بوده و به سمت شمال اشاره دارد [۱۶].



شکل ۱۵- دستگاه مختصات زمین مرکز [۱۶]

لازم به ذکر است که می‌توان به کمک الگوریتم SGP4 [۱۷] بردار حالت ماهواره را از روی داده‌های TLE محاسبه نمود.

### شبکه عصبی پیش‌بینی کننده سری زمانی

مسئله پیش‌بینی سری‌های زمانی، در حقیقت یافتن رابطه میان داده‌های گذشته است که در فواصل یکسان نمونه‌برداری شده‌اند. در

جدول ۵- پارامترهای موجود در خط اول TLE و محل قرار گیری آنها

Description	Column
Line Number of Element Data	01
Satellite Number	03-07
Classification	08
Last two digits of launch year	10-11
Launch number of the year	12-14
Piece of the launch	15-17
Last two digits of epoch year	19-20
Epoch	21-32
First Time Derivative of the Mean Motion	34-43
Second Time Derivative of Mean Motion	45-52
BSTAR drag term	54-61
Ephemeris type	63
Element number	65-68
Checksum	69

جدول ۶- پارامترهای موجود در خط دوم TLE و محل قرار گیری آنها

Description	Column
Line Number of Element Data	01
Satellite Number	03-07
Inclination [Degrees]	09-16
Right Ascension of the Ascending Node [Degrees]	18-25
Eccentricity (decimal point assumed)	27-33
Argument of Perigee [Degrees]	35-42
Mean Anomaly [Degrees]	44-51
Mean Motion [Revs per day]	53-63
Revolution number at epoch	64-68
Checksum	69

و این پارامتر کاملاً وابسته به مسئله و داده‌ها می‌باشد. عموماً سعی و خطا برای تعیین این پارامتر به کار گرفته می‌شود.

پارامتر بعدی، گام زمانی است. این پارامتر در سری‌های زمانی، مشخص‌کننده ابعاد بردار ورودی است. گام زمانی کاملاً وابسته به خودهمبستگی داده‌هاست. متأسفانه برای تعیین این پارامتر نیز قاعده مشخصی وجود نداشته و عموماً از سعی و خطا برای انتخاب مقدار مناسب این پارامتر استفاده می‌شود.

خوشبختانه در تعیین گام زمانی مناسب، می‌توان از برخی معیارهای آماری استفاده کرد. یکی از این معیارها، خودهمبستگی سیگنال خطاست. در یک پیش‌بینی ایده‌آل، خودهمبستگی خطا تنها در گام زمانی صفر، مقدار غیرصفر داشته و در سایر زمان‌ها، صفر است. زیرا در پیش‌بینی ایده‌آل خطای پیش‌بینی در گام‌های زمانی مختلف کاملاً غیر مرتبط با یکدیگر است. در حالت غیر ایده‌آل، خطای پیش‌بینی در گام‌های مختلف عددی غیر صفر خواهد بود. در این حالت می‌توان با تعیین یک سطح اطمینان (confidence level) میزان اعتبار پیش‌بینی را سنجید. در صورتیکه خودهمبستگی خطا از این سطح فراتر رود، می‌توان به تغییر پارامترهای مدل اقدام کرد. به عنوان مثال می‌توان گام زمانی را بیشتر کرد تا زمانی که خطای خودهمبستگی به سطح مطلوب نرسیده است، می‌توان این روند را تکرار نمود [۱۹].

## پیش‌بینی موقعیت مداری ماهواره

در دسترس‌ترین داده‌های موجود از موقعیت مداری ماهواره‌ها، TLE است و دقت این داده‌ها در [۲۰] مورد بررسی قرار گرفته و اثبات شده است. هر TLE شامل ۶ پارامتر مداری است که موقعیت ماهواره را در زمان epoch اعلام شده در TLE به طور یکتایی مشخص می‌کند. خطای موقعیت مداری TLE که با استفاده از الگوریتم SGP4 بدست می‌آید در زمان اپوک حدود ۱ کیلومتر است و این خطا بین ۱ تا ۳ کیلومتر در هر روز افزوده می‌شود [۲۱].

مهم‌ترین علت این خطا نیز اغتشاشات مدل نشده در الگوریتم SGP4 و نیز خطای اندازه‌گیری است. با توجه به بازگشتی بودن الگوریتم SGP4، این خطا در هر تکرار انباشته شده و به تدریج با مرور زمان و با فاصله گرفتن از زمان اپوک افزوده می‌شود. برای کم‌کردن تاثیر این خطا، TLE ماهواره‌ها مرتباً بروزرسانی می‌شود.

واضح است که کمترین میزان خطا، در زمان اپوک واقع شده است. لذا در صورتی که بتوان همواره در زمان‌های نزدیک اپوک از الگوریتم SGP4 استفاده کرد، خطای الگوریتم کمینه خواهد شد.

این نکته، ایده اصلی بکار رفته در این مقاله است. در روش پیشنهادی، با استفاده از داده‌های گذشته، داده‌های آینده با دقت

صورت یافت شدن این رابطه، می‌توان از آن برای پیش‌بینی داده‌ای که هنوز رخ نداده است، استفاده کرد.

یکی از مهمترین ویژگی‌های هر سری زمانی، خاصیت خودهمبستگی (auto-correlation) آن است. خودهمبستگی، همبستگی و ارتباط میان داده‌های یک زمان مشخص با همان داده اما در زمان‌های گذشته است. معمولاً خودهمبستگی در داده‌های با فواصل کم بیشتر بوده و هر چه فاصله زمانی داده‌ها از هم بیشتر شود، این مقدار کاهش می‌یابد. در سری‌های زمانی، این ویژگی عموماً برای تشخیص روندهای تکراری در داده‌ها بکار می‌رود. تعداد داده‌های متوالی که ارتباط بیشتری با یکدیگر دارند، گام نامیده می‌شود. در سری‌های زمانی، به این عدد، گام زمانی گویند [۱۸].

شبکه عصبی پس‌خور با یک لایه پنهان، یکی از ساده‌ترین مدل‌ها برای پیش‌بینی سری‌های زمانی است. این مدل ساده، توانایی انجام یک نگاشت غیرخطی میان داده‌های گذشته و داده‌های آینده را داراست. این نگاشت را می‌توان به کمک رابطه (۱) نمایش داد:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}, w) + e_t \quad (1)$$

در رابطه فوق،  $w$  برداری است که شامل تمام پارامترهای مدل بوده و  $f$ ، نگاشتی است که توسط شبکه ایجاد شده است و  $e_t$ ، نمایانگر خطاست. در حقیقت، این شبکه عصبی، یک رابطه رگرسیون غیرخطی (NAR) است.

در برخی از مسائل، استفاده از اطلاعات یک متغیر دیگر می‌تواند دقت پیش‌بینی را بهبود بخشد. در این حالت، این متغیر باید مستقل از داده مورد پیش‌بینی باشد. این متغیر اما باید همبستگی مناسبی با داده مورد نظر داشته باشد. استفاده از متغیر مستقل خارجی، مسئله NAR را به یک مسئله NARx تبدیل می‌کند. در این مسئله، می‌توان از رابطه (۲) برای بیان رابطه میان داده‌های گذشته و آینده استفاده کرد.

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}, u_{t-1}, u_{t-2}, \dots, u_{t-p}, w) + e_t \quad (2)$$

در رابطه فوق،  $u$  متغیر مستقل اما همبسته با  $y$  است. در طراحی یک شبکه عصبی پیش‌بینی‌کننده سری‌های زمانی، دو پارامتر مهم وجود دارد. پارامتر اول، تعداد نرون‌های لایه پنهان بوده و پارامتر دوم، گام زمانی است.

یک شبکه عصبی با تعداد نرون‌ها کم در مسائل کوچک پاسخ‌های قابل قبولی دارد اما مهمترین نقص این شبکه کوچک، احتمال حفظ کردن الگوهای آموزش دیده شده و عدم توانایی در تعمیم داده‌هایی است که شبکه با آنها مواجه نشده است. متأسفانه برای انتخاب تعداد نرون‌های لایه پنهان قاعده مشخصی وجود ندارد

نکته بعدی در خصوص داده‌های TLE، فواصل زمانی نامنظم آنهاست. از آنجایی که یکی از پیش‌نیازها در تحلیل و پیش‌بینی سری‌های زمانی، فواصل یکسان داده‌هاست، این مسئله در روند پیش‌بینی مشکلات زیادی ایجاد خواهد کرد. به همین منظور باید داده‌های موجود همزمان‌سازی شوند. در [۱۳] این مسئله به کمک درون‌یابی رفع شده بود. اما با توجه به اینکه دقت همزمان‌سازی تاثیر بسزایی در دقت کلی روش دارد، در این مقاله، استفاده از الگوریتم SGP4 برای همزمان‌سازی داده‌ها در دستور کار قرار گرفت. لازم به ذکر است که با توجه به این نکته که اختلاف زمان TLEها با زمان مدنظر در حدود چند ساعت می‌باشد، استفاده از SGP4 خطای زیادی به داده‌ها تزریق نخواهد کرد. خروجی این مرحله، بردارهای حالتی است که با فواصل زمانی یکسان محاسبه شده است.

### آموزش شبکه

در این مرحله، داده‌های بدست آمده در فاز قبل، برای آموزش شبکه‌های عصبی پیش‌بینی کننده استفاده خواهد شد. همانطور که پیشتر نیز ذکر شد، با توجه به استقلال پارامترهای بردار حالت مداری، از شش شبکه عصبی مستقل برای پیش‌بینی این پارامترها استفاده شده است. لذا مسئله پیش‌بینی موقعیت مداری ماهواره، به شش زیر مسئله مستقل پیش‌بینی سری زمانی شکسته شده و هر یک از این مسائل شامل یک شبکه عصبی پیش‌بینی کننده خواهد بود. لذا خروجی این مرحله شش شبکه عصبی مستقل با نام‌های  $\{NET\_X, NET\_Y, NET\_Z, NET\_VX, NET\_VY, NET\_VZ\}$  بوده که هر یک وظیفه پیش‌بینی یکی از پارامترهای بردار حالت مداری را بر عهده‌دار خواهد بود.

### ساختار شبکه‌های عصبی

در این مقاله از ساختار NARX برای شبکه‌های عصبی استفاده شده است. زیرا به منظور افزایش دقت پیش‌بینی، از ورودی خارجی نیز استفاده شده است. به همین منظور، برای پیش‌بینی پارامتر  $X$  در بردار حالت مداری، علاوه بر داده‌های گذشته این پارامتر، از پارامتر  $Vx$  نیز به عنوان ورودی خارجی استفاده شده است. زیرا اطلاع از  $Vx$  می‌تواند به افزایش دقت  $X$ ، منجر شود. همین روند برای  $Y$  و  $Z$  نیز برقرار است. در خصوص پارامتر  $Vx$ ، پارامتر  $X$  به عنوان ورودی خارجی انتخاب گردیده است. زیرا اطلاع از این پارامتر منجر به افزایش دقت پیش‌بینی  $Vx$  خواهد شد. این روند برای  $Vy$  و  $Vz$  نیز تکرار شده است. در روش پیشنهادی، بر خلاف [۱۳]، از ساختار یکسانی برای تمامی شبکه‌ها استفاده شده است. تمامی شبکه‌ها ۶ نرون در لایه

بالایی پیش‌بینی می‌شود. در نتیجه تا قبل از انتشار موقعیت مداری جدید برای ماهواره، می‌توان از این الگوریتم برای کمینه کردن خطای پیش‌بینی استفاده کرد.

روش پیشنهادی شامل دو فاز اصلی است. فاز اول پیش‌پردازش داده‌هاست. ورودی این فاز، TLEهایی است که در فواصل زمانی نامنظم گزارش شده است و خروجی آن، بردارهای حالتی است که در فواصل یکسان قرار گرفته است. در فاز بعدی که فاز آموزش است، داده‌های خروجی فاز قبل، برای آموزش شش شبکه عصبی استفاده شده و خروجی این فاز، شش شبکه عصبی خواهد بود که هر یک از آنها برای پیش‌بینی یکی از پارامترهای بردار حالت بکار خواهد رفت. ترکیب خروجی این شش شبکه، موقعیت مداری ماهواره را در زمان مشخص، تعیین خواهد کرد.

### پیش پردازش داده‌ها

در این مقاله، داده‌های مربوط به موقعیت مداری ماهواره، از [۲۲] تهیه شده است. این داده‌ها به فرمت TLE بوده و لذا جهت استفاده از الگوریتم پیشنهادی، باید به فرمت بردار حالت مداری تبدیل شوند. به همین منظور، از الگوریتم SGP4 برای تبدیل TLE به بردار حالت استفاده شده است. همانطور که پیشتر نیز ذکر شد، خطای SGP4 در لحظه اپوک کمترین مقدار خود را داراست. لذا استفاده از این الگوریتم، برای تبدیل TLE به بردار حالت توجیه پذیر است.

از آنجایی که بردار حالت مداری، شامل ۶ پارامتر است (۳ پارامتر مربوط به موقعیت و ۳ پارامتر مربوط به سرعت)، و به دلیل استقلال این ۶ پارامتر از یکدیگر، می‌توان مسئله پیش‌بینی موقعیت مداری ماهواره را به ۶ زیر مسئله پیش‌بینی پارامترهای بردار حالت مداری تبدیل نمود. با توجه به استفاده از شبکه‌های عصبی برای پیش‌بینی سری‌های زمانی، برای هر پارامتر بردار حالت، یک شبکه عصبی تخصیص داده خواهد شد. در نتیجه ۶ شبکه عصبی وظیفه پیش‌بینی ۶ پارامتر بردار حالت را بر عهده خواهند داشت و خروجی این ۶ شبکه بطور همزمان مشخص کننده موقعیت مداری ماهواره در زمان تعیین شده خواهند بود.

به منظور افزایش دقت روش و جلوگیری از انحراف روند آموزش شبکه‌های عصبی، باید داده‌های موجود را پاک‌سازی کرد [۲۳]. به همین منظور آنالیز داده‌های خارج از محدوده (outlier analysis) روی داده‌ها باید انجام شده و داده‌های خارج از محدوده از روند آموزش شبکه کنار گذاشته شوند. برای حفظ یکپارچگی داده‌ها، اگر داده‌ای در یکی از پارامترها به عنوان داده خارج از محدوده شناسایی شد، سایر پارامترهای همزمان با آن داده نیز باید از روند آموزش کنار گذاشته شوند.

جدول ۸- خواص آماری داده‌ها (کواریانس)

Vz	Vy	Vx	Z	Y	X	
-0.02	-0.01	0.00	1.37	-8.68	22.53	X
0.01	0.00	0.00	3.64	4.03	-8.68	Y
0.00	-0.01	0.02	25.39	3.64	1.37	Z
0.00	0.00	0.00	0.02	0.00	0.00	Vx
0.00	0.00	0.00	-0.01	0.00	-0.01	Vy
0.00	0.00	0.00	0.00	0.01	-0.02	Vz

مقایسه در دو مرحله انجام شده است. در مرحله اول، پیش‌بینی کوتاه مدت (پیش‌بینی موقعیت مداری ماهواره در روز بعد) انجام شده و در مرحله دوم، پیش‌بینی بلند مدت (پیش‌بینی موقعیت مداری ماهواره در چند روز آینده) صورت گرفته است. در هر دو مرحله ساختار شبکه‌های عصبی پیش‌بینی کننده یکسان بوده و از گام زمانی ۴ در تمام شبکه‌ها استفاده شده است. این بدان معناست که شبکه عصبی پیش‌بینی کننده، با در اختیار داشتن موقعیت مداری در ۴ روز گذشته، موقعیت مداری را در روز پنجم (در پیش‌بینی کوتاه مدت) و روزهای پنجم به بعد (در پیش‌بینی بلندمدت تخمین) خواهد زد. لازم به ذکر است که برای پیش‌بینی بلندمدت، آموزش شبکه مجدداً تکرار شده است.

### پیش‌بینی کوتاه مدت

در این مرحله، با داشتن ۴ موقعیت مداری در ۴ روز متوالی، روز پنجم پیش‌بینی شده است. در جدول ۹ مقایسه عملکرد شبکه‌ها با الگوریتم SGP4 در فاز آموزش نشان داده است. عملکرد شبکه، با معیار میانگین مربعات خطا (تفاضل میان مقدار واقعی و مقدار پیش‌بینی شده) محاسبه شده است. در این جدول مشخص است که روش پیشنهادی، بجز در پارامترهای Y و Vx، در سایر پارامترها عملکرد بهتری در پیش‌بینی کوتاه مدت (یک روزه) از الگوریتم SGP4 دارد. به عبارت دیگر، خطای روش پیشنهادی از SGP4 در بازه پیش‌بینی یک‌روزه کمتر است. شکل ۱۶، ساختار شبکه NET\_X را در پیش‌بینی کوتاه مدت نشان می‌دهد. مقایسه داده‌های واقعی با روش پیشنهادی و الگوریتم SGP4 در مختصات کارتزین در شکل ۱۷ و خروجی تمامی شبکه‌ها و خطای آنها در شکل ۹ و شکل ۲۱ آورده شده است.

### پیش‌بینی بلند مدت

در این مرحله، باید شبکه را به گونه‌ای تغییر داد تا بتواند گام‌های بیشتری را پیش‌بینی کند. این مهم به راحتی و با برقراری یک مسیر پس‌خور میان خروجی و ورودی امکان پذیر است. ساختار شبکه در پیش‌بینی بلندمدت در شکل ۷ نشان داده شده است.

برقراری پس‌خور میان خروجی و ورودی، امکان استفاده از خروجی‌های شبکه را به عنوان ورودی جدید فراهم می‌کند. این ویژگی باعث می‌شود تا امکان پیش‌بینی بلندمدت در شبکه ایجاد

پنهان داشته و از گام زمانی ۴ برای ورودی خود استفاده می‌کنند. همچنین تابع تانژانت سیگموئید به عنوان تابع فعال‌ساز لایه پنهان و تابع خطی به عنوان تابع فعال‌ساز نرون خروجی انتخاب شده است. در شکل ۱۶ ساختار شبکه عصبی NET\_X نشان داده شده است. ساختار سایر شبکه‌ها نیز یکسان بوده و تنها در متغیرهای ورودی با یکدیگر متفاوت هستند.

در این مقاله، الگوریتم آموزش شبکه‌ها نیز Levenberg-Marquardt [۲۴] بوده و از جعبه ابزار شبکه عصبی نرم‌افزار متلب برای پیش‌بینی سری‌های زمانی به کمک شبکه‌های عصبی استفاده شده است.

## شبیه‌سازی

به منظور اثبات کارایی روش پیشنهادی، در این بخش، به مقایسه نتایج بدست آمده از این روش با نتایج الگوریتم SGP4 و نیز داده‌ها بدست آمده از TLE پرداخته شده است.

ماهواره مورد مطالعه، ماهواره هندی تصویر برداری IRS-P6 بوده که با نام ResourceSat-1 نیز شناخته می‌شود. داده‌های موقعیت مداری این ماهواره در بازه سال‌های ۲۰۰۳ تا ۲۰۰۴ از مرجع [۲۳] تهیه شده است. در این بازه حدود ۱۶۰۰ TLE از این ماهواره وجود داشته که بازه‌های زمانی نامنظم گزارش شده است.

ابتدا این TLEها به بردار حالت مداری تبدیل شده و سپس یکسان‌سازی فواصل این بردارهای حالت انجام گردید. بنا بر آنچه که پیشتر گفته شد، لازمه پیش‌بینی سری‌های زمانی، وجود داده‌هایی با فواصل زمانی یکسان است. به همین منظور و با توجه به فاصله زمانی کم TLEها با زمان مورد نظر (ساعت ۱۲:۰۰ بعد از ظهر هر روز) به کمک الگوریتم SGP4 این داده‌ها به فواصل زمانی یکسان تبدیل شد. به منظور فراهم کردن امکان مقایسه با داده‌های در دسترس و نیز تهیه معیاری برای محاسبه دقت روش پیشنهادی و SGP4، هدف، پیش‌بینی موقعیت به صورت روزانه (یک موقعیت در یک روز و در ساعت ۱۲:۰۰ بعد از ظهر) تعیین گردید.

پس از تبدیل داده‌ها به فواصل مساوی و پس از پاکسازی داده‌ها از داده‌های خارج از محدوده، در مجموع ۴۴۲ موقعیت مداری به فرمت بردار حالت، بدست آمد. از این تعداد، ۲۰۰ بردار حالت به منظور استفاده در فاز آموزش (train)، ۳۰ بردار برای اعتبار سنجی روند آموزش (validation) و سایر بردارهای باقی‌مانده برای تست عملکرد روش انتخاب شد. خواص آماری این داده‌ها در جدول ۷ و ۴ آورده شده است.


جدول ۷- خواص آماری داده‌ها (میانگین و واریانس)

X	Y	Z	Vx	Vy	Vz	
-0.02	0	-0.03	0	0	0	میانگین
22.53	4.03	25.39	0	0	0	واریانس

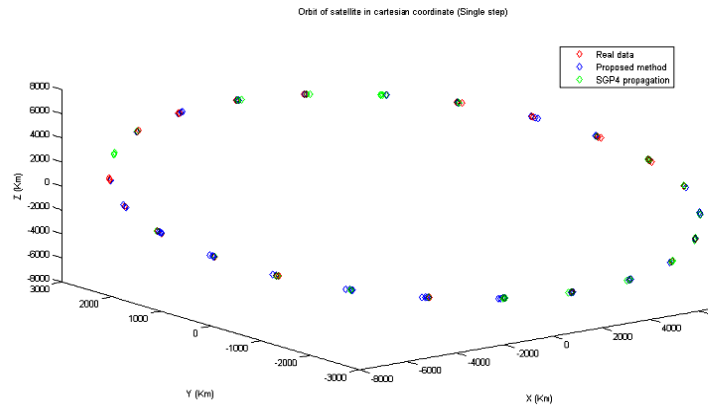


می‌توان با استفاده از موقعیت تخمین زده شده روز پنجم، این مشکل را برطرف کرد. لذا با استفاده از خروجی شبکه به عنوان ورودی، امکان پیش‌بینی بلندمدت فراهم خواهد شد. تکرار این روند، امکان پیش‌بینی بلندمدت را به تعداد گام‌های دلخواه برای شبکه فراهم می‌کند.

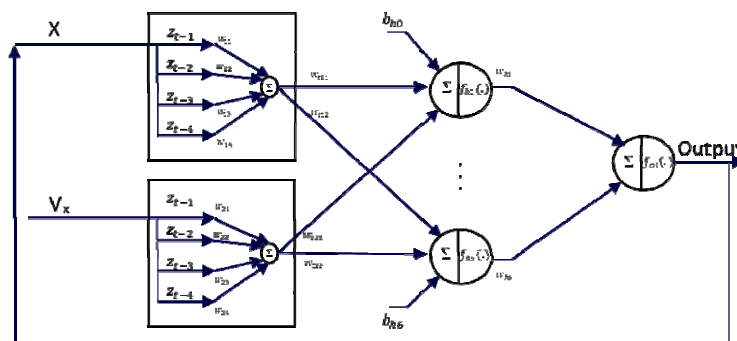
شود. پیش‌بینی بلند مدت در این شبکه به این صورت است که با داشتن اطلاعات مداری در ۴ روز متوالی، موقعیت مداری در روز پنجم توسط شبکه تخمین زده می‌رود. حال برای پیش‌بینی روز ششم، به موقعیت مداری واقعی روز پنجم نیاز است که در اختیار نیست. اما



شکل ۱۶- ساختار شبکه عصبی NET\_X



شکل ۱۷- مقایسه داده‌ها در فضای کارترین- پیش‌بینی کوتاه مدت



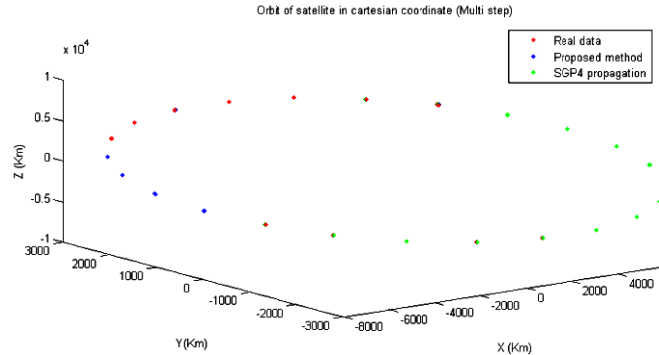
شکل ۱۸- ساختار شبکه NET\_X در پیش‌بینی بلندمدت

نتیجه عملکرد شبکه‌ها در فاز آموزش و در پیش‌بینی بلندمدت، در جدول ۵ گزارش شده است. مشاهده می‌شود که در پیش‌بینی بلند مدت، روش پیشنهادی عملکرد به مراتب بهتری را از الگوریتم SGP4 در تمامی پارامترهای بردار حالت مداری از خود نشان داده است.

در این مقاله، از ۱۰ بردار حالت مداری گذشته برای شروع پیش‌بینی بلندمدت استفاده شده است. لازم به ذکر است که شبکه برای عملکرد خود تنها به چهار موقعیت مداری گذشته نیاز داشته و استفاده از ۱۰ موقعیت مداری گذشته برای شروع پیش‌بینی، تناقضی با این مطلب ندارد.

است. در این شکل‌ها مشاهده می‌شود که خطای شبکه‌ها با افزایش گام پیش‌بینی زیاد شده است. این مسئله کاملاً قابل پیش‌بینی بوده زیرا پیش‌بینی هرگام با خطایی همراه است و استفاده از نتیجه پیش‌بینی شده، این خطا را به پیش‌بینی مرحله بعد منتقل خواهد کرد. لذا یک خطای جمع شونده در شبکه وجود داشته که با افزایش گام پیش‌بینی، به این خطا افزوده خواهد شد.

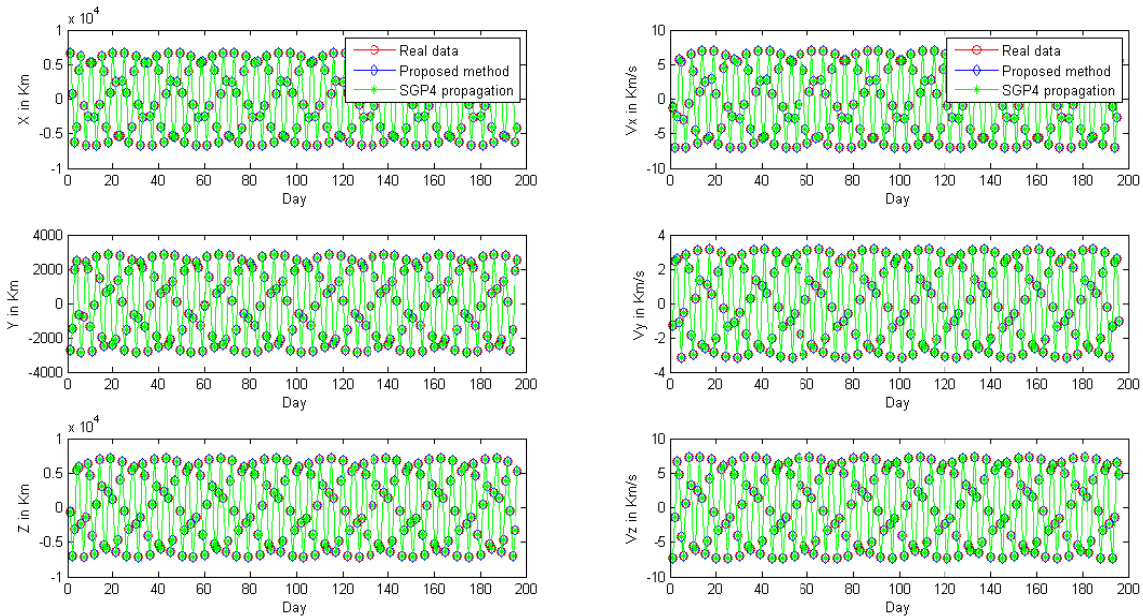
برای نشان دادن عملکرد شبکه‌های پیش‌بینی کننده در پیش‌بینی بلندمدت، خروجی این شبکه‌ها در پیش‌بینی پارامترهای بردار حالت در ۴۰ گام بعد (۴۰ روز بعد) با یکدیگر مقایسه شده است. مقایسه داده‌های واقعی با روش پیشنهادی و الگوریتم SGP4 در مختصات کارتزین در شکل ۸ و خروجی تمامی شبکه‌ها و خطای آنها در این بازه زمانی در شکل ۱۱ و شکل ۱۲ نشان داده شده




شکل ۱۹- مقایسه داده‌ها در فضای کارتزین - پیش‌بینی بلند مدت

جدول ۹- مقایسه عملکرد شبکه‌ها در فاز آموزش با الگوریتم SGP4. اعداد پررنگ، عملکرد بهتر را نشان می‌دهد.

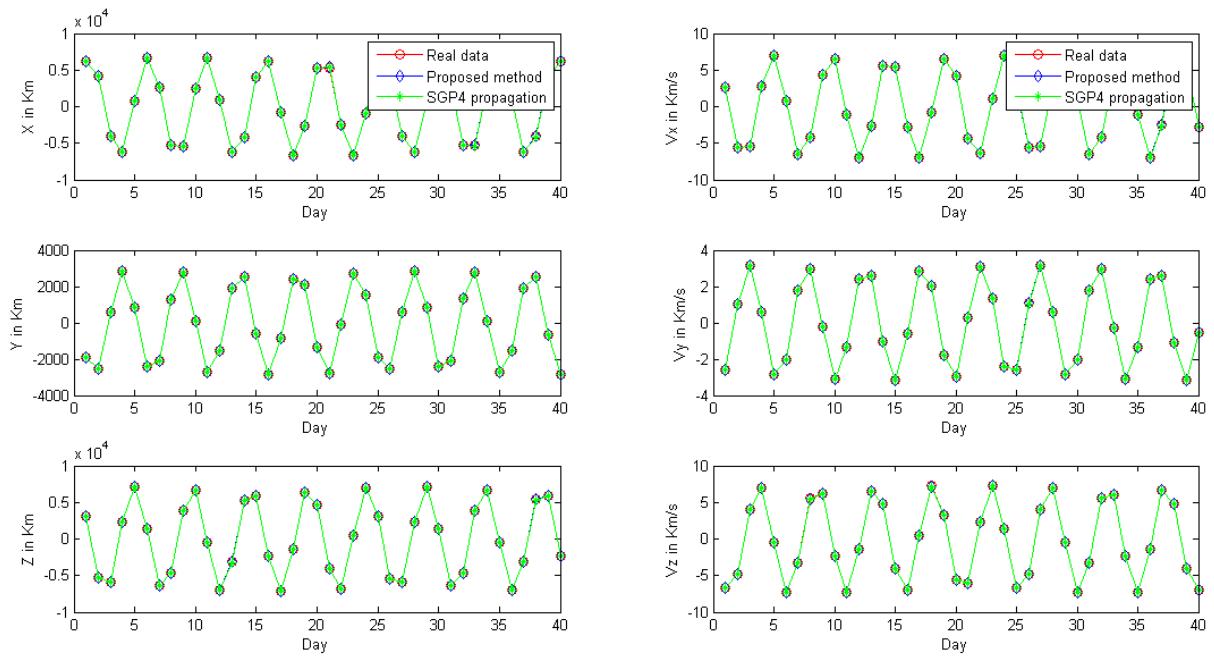
پیش‌بینی بلند مدت (۴۰ روز)		پیش‌بینی کوتاه مدت		
SGP4	روش پیشنهادی	SGP4	روش پیشنهادی	
44.77	<b>16.16</b>	0.56	<b>0.38</b>	X (km)
7.45	<b>0.80</b>	0.11	0.14	Y (km)
53.01	<b>0.71</b>	0.99	<b>0.64</b>	Z (km)
4.82e-02	<b>1.34e-03</b>	9.79e-04	1.11e-03	Vx (km/s)
9.01e-03	<b>5.70e-04</b>	1.58e-04	<b>1.31e-04</b>	Vy (km/s)
5.43e-02	<b>9.51e-03</b>	6.57e-04	<b>3.94e-04</b>	Vz (km/s)



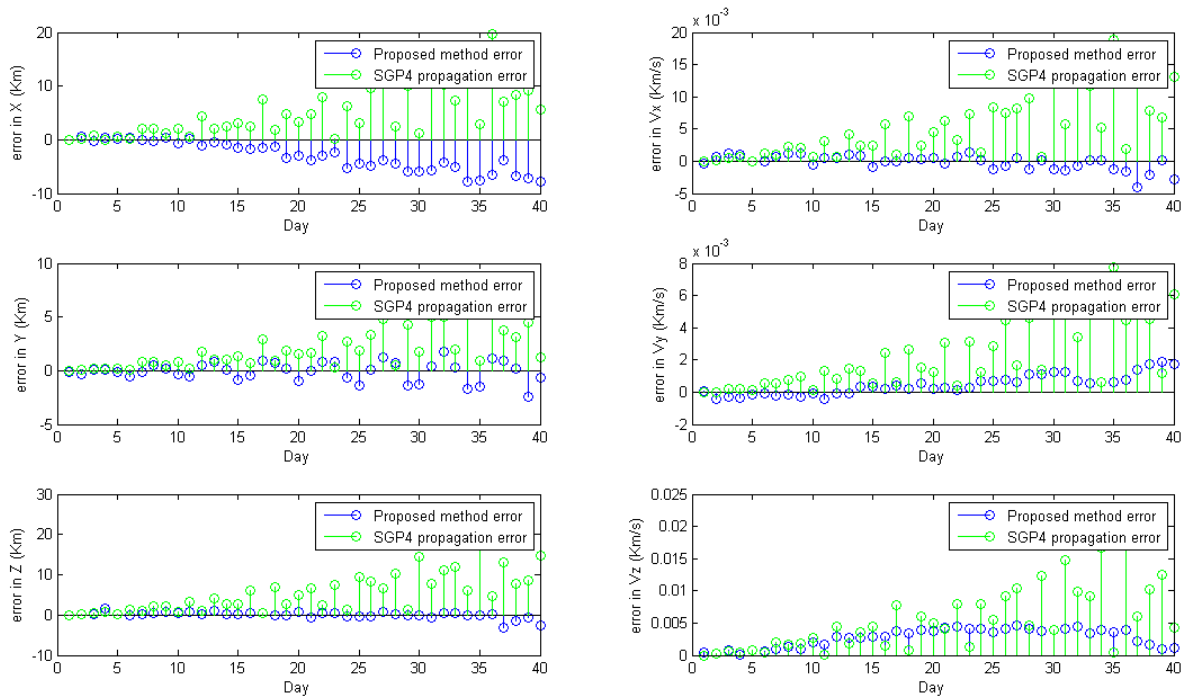
شکل ۲۰- خروجی شبکه‌های پیش‌بین در مرحله پیش‌بینی کوتاه مدت



شکل ۲۱- خطای شبکه‌های پیش‌بین در مرحله پیش‌بینی کوتاه مدت



شکل ۲۲- خروجی شبکه‌های پیش‌بین در مرحله پیش‌بینی بلند مدت (۴۰ روز)



شکل ۲۳ - خطای شبکه‌های پیش‌بین در مرحله پیش‌بینی بلند مدت (۴۰ روز)

بالاتری از روش پیشنهادی (بیان شده در مختصات مداری) داشته باشند. در جدول ۱ مقایسه برای یک نقطه انجام شده است.

جدول ۱ - مقایسه دو روش برای یک نقطه در نمایش پارامترهای مداری

بردار حالت مداری	پارامترهای مداری	مختصات نقطه مورد مطالعه
$r=[-443.5, 6006, -3955]$ (Km) $v=[1.63, -3.90, -6.11]$ (Km/s)	PR: $7.19e+06$ (km) e: $9.81e-04$ i: $1.72$ (rad) RAAN: $4.89$ (rad) AP: $1.07$ (rad) TA: $2.65$ (rad)	
SGP4	روش پیشنهادی	
۸.۳۳	۳.۷۹	نرم خطای موقعیت
۷.۹۸	۴.۳۸	نرم خطای سرعت
۴.۳۰	۱۳.۶۵	نرم خطای پارامترهای مداری

در انتها، زمان مورد نیاز برای محاسبات در روش پیشنهادی با روش SGP4، در جدول ۷ مقایسه شده است. در این جدول مشاهده می‌شود که اگر چه در پیش‌بینی کوتاه مدت، زمان محاسبات در روش پیشنهادی تقریباً با روش SGP4 برابر است، اما در پیش‌بینی بلندمدت، این زمان کمتر خواهد شد. علت این امر نیز قابلیت پردازش موازی در شبکه‌های عصبی است.

جدول ۱۱ - مقایسه زمان مورد نیاز محاسباتی در روش محاسباتی با SGP4

زمان محاسباتی	کوتاه مدت		بلند مدت	
	SGP4	روش پیشنهادی	SGP4	روش پیشنهادی
	۰.۰۰۱۴	۰.۰۰۱۵	۰.۳۱۹	۰.۱۳۸

به‌منظور مقایسه بیشتر، نتایج بدست آمده در نمایش پارامترهای مداری نیز در روش پیشنهادی و الگوریتم SGP4 با یکدیگر مقایسه گردید. برای این منظور، از آنجایی که مقایسه باید در زمان‌های یکسان صورت پذیرد، لذا نیاز است که کلیه نتایج در مختصات کارتیزین بیان شده و سپس این داده‌ها به نمایش پارامترهای مداری تغییر مختصات پیدا کند. با توجه به الگوریتم‌های موجود در تبدیل داده‌های کارتیزین به پارامترهای مداری، مجموعه «شعاع حضيض، خروج از مرکز، شیب مداری، بعد گره صعودی، آرگومان حضيض و ناهنجاری واقعی» به عنوان مجموعه پارامترهای مداری انتخاب شد. نتایج این مقایسه در شکل‌های ۱۳ تا ۱۶ گزارش شده است.

در این شکل‌ها مشاهده می‌شود که در نمایش پارامترهای مداری، خطای روش SGP4 از روش پیشنهادی کمتر است. اما تبدیل معکوس این پارامترهای مداری به مختصات کارتیزین، مجدداً نشان از دقت بالاتر روش پیشنهادی دارد. دلیل این موضوع را باید در ارتباط تنگاتنگ پارامترهای مداری با یکدیگر جستجو کرد. موقعیت یک ماهواره با ترکیب همزمان این شش پارامتر تعیین می‌گردد و از آنجایی که این پارامترها بازه‌های متفاوتی دارند، دقت کمتر یک پارامتر الزاماً به معنای دقت بهتر در مختصات ماهواره نیست. با دقت در شکل‌های ۱۳ تا ۱۶ نیز مشاهده می‌شود که دقت بهتر در مختصات SGP4، در یک زمان مشخص، تنها مربوط یک یا دو پارامتر بوده و تقریباً زمانی یافت نمی‌شود که هر شش پارامتر دقت

## نتیجه گیری

در این مقاله، روشی جدید در پیش‌بینی موقعیت مداری ماهواره با استفاده از شبکه‌های عصبی و سری‌های زمانی معرفی شد. این نگرش که در ابتدا در [۱۳] معرفی گردید، در این پژوهش توسعه داده شد و دقت آن بهبود یافت. در این نگرش، بجای استفاده از روابط کلاسیک مداری مانند قوانین کپلر و...، از داده‌های واقعی و در اختیار مانند TLE بهره گرفته شده است. مهمترین مزیت این روش، در نظر گرفتن تمامی اغتشاشات مداری است. زیرا تمامی اغتشاشات مداری در داده‌های واقعی نهفته شده است و استفاده از این داده‌ها به معنای در نظر گرفتن تمامی اغتشاشات مداری در پیش‌بینی موقعیت مداری آینده است.


در روش پیشنهادی، با استفاده از قدرت پیش‌بینی سری‌های زمانی توسط شبکه عصبی، با داشتن تعدادی موقعیت مداری در روزهای آینده پرداخت. با تبدیل داده‌های TLE به بردار حالت مداری، مزایایی همچون هموارسازی داده‌ها و نیز امکان استفاده از ورودی خارجی در شبکه‌های عصبی و استفاده از مدل NARx فراهم خواهد شد. نتایج مقایسه این روش با الگوریتم مشهور و مورد اعتماد SGP4، نشان از بالاتر بودن دقت روش پیشنهادی نسبت به روش‌های کلاسیک دارد. به منظور مقایسه بیشتر، دقت روش پیشنهادی با الگوریتم SGP4 در نمایش پارامترهای مداری نیز مقایسه گردید. اگر چه در نمایش المان‌های مداری، خطای SGP4 از روش پیشنهادی کمتر است، اما در

نمایش بردار حالت، خطای روش پیشنهادی به مراتب کمتر از روش SGP4 مشاهده شد. علت این امر نیز این نکته است که برای تعیین دقت موقعیت باید هر شش پارامتر به طور همزمان در نظر گرفته شوند. لذا در یک زمان اگر چه ممکن است یک یا چند پارامتر مداری خطای بیشتری داشته باشند، اما ممکن است سایر پارامترها، تاثیر منفی پارامترهای مخرب را جبران نمایند. لازم به ذکر است که برای مقایسه دقت روش‌های معمولاً از نمایش بردار حالت استفاده می‌شود و پارامترهای مداری عمدتاً به عنوان شرایط اولیه برای الگوریتم‌های تعیین مدار استفاده می‌شوند.

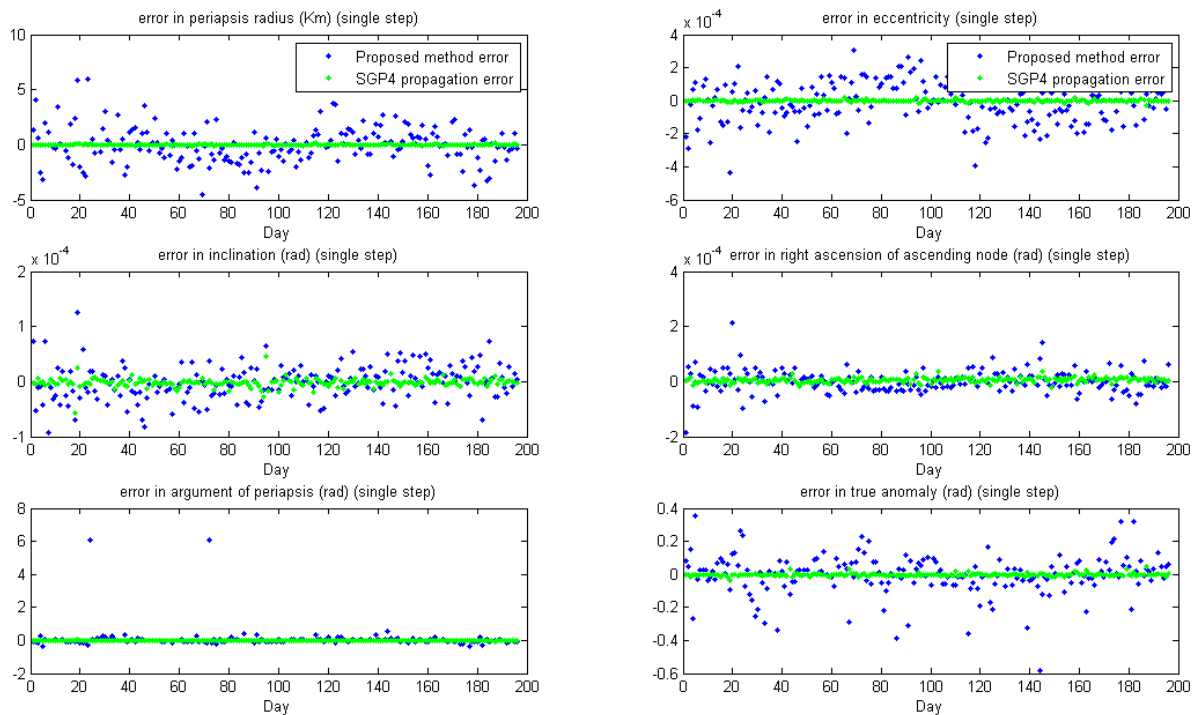
لازم به ذکر است که دقت روش پیشنهادی، محدود به داده‌های به کار رفته است و در صورتیکه این داده‌ها اعتبار کافی داشته باشند، نتایج این روش نیز، معتبر خواهد بود. در انتها مجدداً تاکید می‌شود که ارایه این روش، به معنای معرفی روشی جایگزین برای الگوریتم‌هایی مانند SGP4 نیست. بلکه صرفاً نگرشی نوین به مکانیک مداری بوده و با هدف فراهم آوردن بستر اولیه به منظور امکان استفاده از هوش مصنوعی در این زمینه ارائه شده است.

## تشکر و قدردانی


این مقاله با حمایت دانشگاه صنعتی قوچان و با گرنت شماره ۳۰/۷۷۳۳-۹-۹۵ به انجام رسیده است.




شکل ۲۴- خروجی شبکه‌های پیش‌بین در مرحله پیش‌بینی کوتاه مدت در نمایش پارامترهای مداری



شکل ۲۵- خطای شبکه‌های پیش‌بین در مرحله پیش‌بینی کوتاه مدت در نمایش پارامترهای مداری



شکل ۲۶- خروجی شبکه‌های پیش‌بین در مرحله پیش‌بینی بلند مدت (۴۰ روز) در نمایش پارامترهای مداری



شکل ۲۷- خطای شبکه‌های پیش‌بین در مرحله پیش‌بینی بلند مدت (۴۰ روز) در نمایش پارامترهای مداری

- [8] Seppänen, M., Ala-Luhtala, J., Piché, R., Martikainen, S. and Ali-Löytty, S., Autonomous Prediction of GPS and GLONASS Satellite Orbits, *Navig. J. Inst. Navig.*, Vol. 59, 2012, pp.119–134.
- [9] Amiri, M.A., Gazerpour, A, H., Roghangir, S. A. R., Orbit Determination Via a Deeply- Coupled UKF/GNSS Filter, *Journal of Space Science and Technology (JSST)*, Vol. 9, No. 3, 2016, pp. 13-26, (In Persian).
- [10] Torabi, P. and Naghash, A., Determining orbital element on Earth Observation Repeat-Ground-Track orbit, *Journal of Space Science and Technology (JSST)*, Vol. 9, No. 2, 2016, pp. 77-83, (In Persian).
- [11] Bennett, J., Sang, J., Smith, C., Zhang, K., Improving Low-Earth Orbit Predictions Using Two-line Element Data with Bias Correction, *Advanced Maui Optical and Space Surveillance Technologies Conference*, 2012.
- [12] Peng, H. and Bai, X., Improving Orbit Prediction Accuracy Through Supervised Machine Learning, *Advances in Space Research*, Vol 10, No. 9, 2018, pp. 2628-2646
- [13] D. Bustan, N. Pariz, S.K. Hosseini Sani, Intelligent Satellite Orbit Prediction Based on Time Series Analysis, *Journal of Space Science and Technology (JSST)*, Vol 7, No 3, 2014, 43–49 (In Persian)
- [14] Shamlu, F. and Naghash, A. “Satellite Orbit Prediction Through Observation Data and the Artificial Neural Networks,” *Journal of Space*

## مراجع

- [1] Navabi, M. and Hamrah, R., Modeling of Space Objects Propagation, Prediction of Closest Approaches among Satellites, and Assessment of Maximum Collision Probability, *Journal of Space Science and Technology (JSST)*, Vol. 6, No. 1, 2013, 57-67 (in Persian).
- [2] Neta, B., Partial List of Orbit Propagators, Naval Postgraduate School.
- [3] Miura, N.Z., Comparison and Design of Simplified General Perturbation Models (SGP4) and Code for NASA Johnson Space Center, (Thesis M. Sc.) 2009.
- [4] Chao, C.C., Warner, L.F., Cox, J., Thompson, R.C., Starchville, T.F., Cook, J.W. and Woodburn, J., “IV&V of Three Astrodynamics Functions of the Satellite Tool Kit, AAS/AIAA Astrodyn,” *Spec. Conf.*, 2000, pp. 70–81.
- [5] Aorpimai, M., Malayavej, V. and Navakitkanok, P., High-fidelity Orbit Propagator for Precise Antenna Pointing in LEO Satellite Operation, 20<sup>th</sup> Asia-Pacific Conf. Commun., 2014, pp. 223–226..
- [6] Fang, L. and Nagarajan, N., Neural Network Based Orbit Propagation for Small Satellite Missions, *Small Satell. Conf.*, 2004, pp. 1–9. <http://digitalcommons.usu.edu/smallsat/2004/All2004/47/>.
- [7] Greene, M.R. and Zee, R.E., “Increasing the Accuracy of Orbital Position Information from NORAD SGP4 Using Intermittent GPS Readings,” *Small Satell. Conf.*, 2009.

- [19] Beale, M.H., Demuth, H.B., Hagan, M.T. and Chen, Q., *Neural network toolbox<sup>TM</sup> 8*, Natick, Massachusetts, 2014.
- [20] Kelso, T.S., Validation of SGP4 and IS-GPS-200D Against GPS Precision Ephemerides, *Adv. Astronaut. Sci.*, 2007, pp. 427-440.
- [21] Wikipedia Contributors, "Two-line element set," Wikipedia, The Free Encyclopedia, [https://en.wikipedia.org/w/index.php?title=Two-line\\_element\\_set&oldid=790226837](https://en.wikipedia.org/w/index.php?title=Two-line_element_set&oldid=790226837)
- [22] Kelso, T.S., No Title, (n.d.). Celestrak.com.
- [23] Han, J. and Kamber, M., *Data Mining: Concepts and Techniques*, 2006,
- [24] Lourakis, M.I.A., A Brief Description of the Levenberg-Marquardt Algorithm Implemented By Levmar, *Foundation of Research and Technology*, 2005, pp. 1-6.
- Science and Technology (JSST)*, Vol 10, No 2, 2017, pp. 1-8 (In Persian)
- [15] [https://spaceflight.nasa.gov/realdata/sightings/SSa pplications/Post/JavaSSOP/SSOP\\_Help/tle\\_def.html](https://spaceflight.nasa.gov/realdata/sightings/SSa pplications/Post/JavaSSOP/SSOP_Help/tle_def.html)
- [16] H.D. Curtis, *Orbital Mechanics for Engineering Students*, 2014.
- [17] Vallado, D.A., Crawford, P., Hujsak, R., Kelso, T.S., *Revisiting Spacetrack Report #3*, AIAA, 2006.
- [18] Samarasinghe, S., *Neural Networks for Applied Sciences and Engineering: From Fundamentals to Complex Pattern Recognition*, Auerbach Publications, Boston, 2006.