

## Improving INS/GPS Integration with Artificial Intelligence during GPS Outage

A. Ebrahimi, M. Sadeghi, M. Shahbodaghi, M. R. Mosavi\*, E. S. Abdolkarimi

\*Iran University of Science and Technology

(Received: 01/10/2020, Accepted: 11/01/2021)

### ABSTRACT

*The importance of navigation precision in high dynamic environments has led to integrating the inertial navigation system (INS) with satellite navigation systems. In one of those integration methods in which INS is integrated with GPS, GPS outage is an unavoidable challenge. Moreover, due to significant noisy signals existing in low-cost MEMS sensors, navigation precision severely decreases, and the INS error will diverge in the long term. This paper improves the INS/GPS navigation system using artificial intelligence (AI) during GPS outage. In this approach, the INS outputs at  $t$  and  $t-1$  are injected to the AI module as the positioning and timing information. While GPS is available, the AI module is trained, and its output is compared with the GPS output. The AI module indeed intends to drive the INS output to the GPS output during GPS outage. To evaluate this approach and compare the detection precision of some different intelligence systems by five different methods, we have utilized multilayer perceptron (MLP), radial basis function (RBF), support vector regression (SVR), and wavelet neural networks (NNs), and also the adaptive neuro-fuzzy inference system (ANFIS), as AI modules. The required dataset to compare all five mentioned methods is gathered in a real environment by a mini-airplane. The results of all five methods demonstrate that the proposed method has superior performance compared to other traditional methods, and among the five AI modules the wavelet NN outperforms others by approximately 30%.*

**Keywords:** Navigation, GPS, Outage, INS, Artificial Intelligence, Neural Network

---

\* Corresponding Author Email: M\_Mosavi@iust.ac.ir

## علمی - پژوهشی

## بهبود ناوبری INS/GPS در زمان قطعی GPS با استفاده از هوش مصنوعی

امیر ابراهیمی<sup>۱</sup>، مریم صادقی<sup>۲</sup>، محسن نژادشاهداعی<sup>۳</sup>، سید محمدرضا موسوی میرکلایی<sup>۴\*</sup> و الهه سادات عبدالکریمی<sup>۵</sup>

۱- دانشجوی کارشناسی ارشد، ۲- دانشجوی کارشناسی، ۳- دانشجوی دکتری، ۴- استاد، ۵- دانشجوی دکتری، دانشکده مهندسی برق،

دانشگاه علم و صنعت ایران، تهران، ایران

(دریافت: ۱۳۹۹/۰۷/۱۰، پذیرش: ۱۳۹۹/۱۰/۲۲)

## چکیده

با توجه به اهمیت دقت ناوبری در کاربردهایی با سرعت بالا، اغلب سامانه ناوبری اینرسی (INS) را با یکی از سامانه‌های ناوبری ماهواره‌ای تلفیق می‌کنند. در یکی از انواع این روش‌ها که در آن INS با GPS تلفیق می‌شود، مسئله قطعی GPS یک چالش مهم و غیرقابل اجتناب است. مضاف بر قطعی GPS، استفاده از حسگرهای ارزان قیمت میکرو الکترومکانیکی (MEMS) در INS که دارای کیفیت پایین بوده و خروجی نویزی دارند، دقت ناوبری خالص INS را به شدت کاهش داده و با طولانی شدن قطعی GPS، آن را به واگرایی می‌کشاند. در این مقاله با استفاده از هوش مصنوعی، ناوبری INS/GPS را در زمان قطعی GPS بهبود داده‌ایم. بدین صورت که بلوک هوشمند، خروجی INS را در زمان  $t-1$  و  $t-2$  دریافت می‌کند، لذا ورودی آن شامل اطلاعات مکانی و زمانی INS می‌باشد. خروجی بلوک هوشمند نیز مبتنی بر خروجی GPS در زمان  $t$  است. در طول مدتی که GPS در دسترس است، بلوک هوشمند در فاز آموزش است. در این فاز، خروجی بلوک هوشمند با مقدار مطلوب که همان خروجی GPS می‌باشد، مقایسه می‌شود. در زمان قطعی GPS، عملاً بلوک هوشمند خروجی INS را به سمت خروجی GPS میل می‌دهد. به منظور سنجش این رویکرد و نیز مقایسه دقت تخمین تعدادی از سامانه‌های هوشمند متفاوت، در پنج روش مختلف، از شبکه‌های عصبی MLP، RBF، SVR، موجک و نیز سامانه استنتاج فازی-عصبی تطبیقی به عنوان بلوک هوشمند استفاده کرده‌ایم. همچنین داده‌هایی که در این مقاله برای سنجش روش‌های بیان شده، استفاده شده است، از یک محیط واقعی توسط یک مینی هواپیما جمع‌آوری شده است. نتایج به دست آمده برای هر پنج روش، نشان‌دهنده آن است که ناوبری تحت این رویکرد در زمان قطعی GPS، نسبت به ناوبری خالص INS به صورت چشم‌گیری بهبود یافته است. در میان پنج بلوک هوشمند نیز، شبکه عصبی موجک توانسته است حدوداً بیش از ۳۰ درصد نسبت به دیگر روش‌ها دقت داشته باشد.

کلیدواژه‌ها: ناوبری، GPS، قطعی، INS، هوش مصنوعی، شبکه عصبی، ANFIS

## ۱- مقدمه

محاسبه می‌گردد [۱]. اگرچه عدم استفاده از سیگنال‌های خارجی برای ناوبری، INS را به سامانه‌ای قابل اعتماد تبدیل کرده است و دیگر به راحتی با پخش پارازیت<sup>۲</sup> قابل مختل شدن نمی‌باشد، اما مشکل اصلی این سامانه خطای جمع‌شونده آن است. به دلیل این ایراد، INS در بلندمدت کار آبی مناسبی نداشته و به واگرایی کشیده می‌شود. از طرفی سامانه موقعیت‌یابی جهانی (GPS<sup>۳</sup>) دارای نرخ خروجی کم و دقت مناسب در بلندمدت است و به همین علل می‌تواند مکمل مناسبی برای INS باشد. لذا تلفیق INS/GPS در تحقیقات بسیاری تا به امروز مورد بررسی قرار گرفته است. یک چالش اساسی در این نوع از ناوبری تلفیقی، موضوع قطع شدن<sup>۴</sup> GPS است. GPS با داشتن

سامانه ناوبری اینرسی (INS<sup>۱</sup>) به صورت گسترده‌ای در ربات‌ها، موشک‌ها، هواپیماها، زیردریایی‌ها و فضاپیماها به کار می‌رود. مزایای اصلی این سامانه، عدم نیاز به هیچ‌گونه اطلاعات از دنیای خارج و نیز پهنای باند زیاد در ناوبری می‌باشد. در این سامانه، ناوبری به کمک حسگرهای اینرسی مانند شتاب‌سنج‌ها، ژيروسکوپ‌ها و نیز حسگرهای غیر اینرسی به مانند ارتفاع‌سنج‌ها و فشارسنج‌ها، انجام می‌گیرد. به این صورت که توسط اندازه‌گیری‌های این حسگرها و نیز محاسبات معادلات مکانیزاسیون، موقعیت نسبی مکان نسبت به یک نقطه مرجع

<sup>۲</sup> Jamming

<sup>۳</sup> Global Positioning System

<sup>۴</sup> Outage

\* رایانامه نویسنده مسئول: M\_Mosavi@iust.ac.ir

<sup>۱</sup> Inertial Navigation System

را از ماهواره‌های باقیمانده به دست آورد. با این حال، در زمانی که وسیله نقلیه از محل‌هایی مانند تونل‌ها و زیر پل‌ها عبور می‌کند و هیچ ماهواره‌ای در دید نیست، این روش تلفیق سخت نیز نمی‌تواند کار آیی مناسبی داشته باشد و عملاً بی‌اثر می‌شود. در شرایط دینامیک بالا که دست‌یابی به سیگنال GPS دشوار است، روش تلفیق عمیق<sup>۱۱</sup> GPS/INS مورد استفاده قرار می‌گیرد. در این روش، پهنای باند حلقه ردگیری<sup>۱۲</sup> به مقدار قابل توجهی کاهش می‌یابد. این امر سبب می‌شود که نسبت سیگنال به نویز در خروجی حلقه ردگیری افزایش یابد و این عامل باعث می‌شود که سیستم ناوبری در مقابل تداخل و مسدودیت<sup>۱۳</sup>، مصونیت بیشتری داشته باشد؛ اما این روش نیازمند آن است که طراحان سیستم، به سخت‌افزار و حامل<sup>۱۴</sup> حلقه‌های ردگیری دسترسی داشته باشند که در عمل کار مشکلی است. لذا روش تلفیق عمیق نمی‌تواند به سهولت توسط کاربرهای عمومی مورد استفاده قرار گیرد.

یک راه‌حل دیگر برای مشکل قطعی GPS استفاده از هوش مصنوعی<sup>۱۵</sup> برای بهبود تلفیق در روش‌های سنتی تلفیق GPS/INS است. زمانی که سیگنال GPS در دسترس است، بلوک هوشمند موجود در سیستم آموزش داده می‌شود تا دینامیک‌های متناظر با خطای مکان و سرعت INS را شناسایی کند. سپس این بلوک هوشمند که آموزش یافته است، اندازه‌گیری‌های INS را در طول قطعی GPS تصحیح می‌کند. محققین رویکردهای مختلفی را برای بخش هوشمند به کار گرفته‌اند، به طوری که از ورودی‌ها و خروجی‌های مختلفی برای آن استفاده می‌کنند. اولین بار آقای نورالدین و گروه ایشان [۱۱]، مکان محاسبه شده INS را به عنوان ورودی و اختلاف مکان INS و GPS به عنوان خروجی بلوک هوشمند لحاظ کردند. بعداً اندازه‌گیری‌های شتاب‌سنج‌ها، ژيروسکوپ‌ها و نیز داده‌های وضعیت<sup>۱۶</sup> به عنوان ورودی‌های اضافه در نظر گرفته شدند تا به کار آیی بهتری دست یابند [۱۲]. در آخرین کار همین گروه تحقیقاتی، نمونه‌های قبلی<sup>۱۷</sup> مکان و سرعت INS را در طراحی اضافه و یک رابطه‌ای بین خروجی قبلی و خروجی فعلی پیدا کردند [۱۳]. محققین دیگری از همین ورودی‌های مشابه به عنوان ورودی بلوک هوشمند استفاده کرده‌اند، اما حالت‌های فیلتر تخمین را به عنوان خروجی در نظر گرفته‌اند [۱۴ و ۱۵].

در این مقاله بلوک هوشمند، خروجی INS را در زمان  $t - 1$  و نیز  $t - 2$  دریافت می‌کند، لذا ورودی آن شامل اطلاعات مکانی و

حداقل چهار سیگنال مستقیم<sup>۱</sup> (LOS)، یعنی سیگنال‌هایی که به طور دقیق از ماهواره‌ها به گیرنده می‌رسند، می‌تواند یک ناوبری صحیح را انجام دهد. بدون مشاهده حداقل چهار LOS، یک موقعیت‌یابی درست را نمی‌توان انتظار داشت [۲]. ممکن است به دلایل مختلفی، چهار LOS در دسترس نباشد. به طور مثال، در نواحی متراکم شهری با ساختمان‌های بلند، زیرگذرها و یا داخل تونل‌ها، سیگنال ارسالی ماهواره‌ها ممکن است به موانع برخورد کنند و کاملاً مسدود<sup>۲</sup> شوند. این یکی از مشکلات اساسی GPS است، زیرا باعث وقفه<sup>۳</sup> و یا قطع GPS می‌شود که به طبع باعث مختل شدن ناوبری می‌گردد [۳ و ۴]. حال اگر مدت قطعی GPS طول بکشد، ناوبری INS به دلیل همان خطای جمع‌شونده، به واگرایی کشیده می‌شود. مدت‌زمانی که INS در زمان قطعی GPS می‌تواند به یک ناوبری با دقت مناسب ادامه دهد، وابسته به فناوری حسگرهای واحد اندازه‌گیری اینرسی (IMU<sup>۴</sup>) و نیز میزان همواری مسیر می‌باشد. برای حسگرهای ارزان‌قیمت میکرو الکترومکانیکی (MEMS<sup>۵</sup>)، این مدت‌زمان می‌تواند حتی کمتر از یک دقیقه باشد. لذا پژوهشگران برای تلفیق INS/GPS و حل مشکل قطعی GPS، رویکردهای زیادی را تا به امروز ارائه داده‌اند.

یک روش ساده اضافه نمودن حسگرهای کمکی بیشتر به INS می‌باشد. به عنوان مثال، این حسگرهای کمکی می‌توانند ارتفاع سنج، حسگر سرعت چرخ و حسگر زاویه فرمان<sup>۶</sup> باشند. هرچند که در این روش، در زمان قطعی GPS دقت ناوبری INS بیشتر می‌شود، اما روشی پرهزینه است [۵]. استفاده از فیلتر کالمن (KF<sup>۷</sup>) برای تلفیق INS/GPS روشی بسیار متداول است [۶]. اما این فیلتر در مسائلی با شرایط غیرخطی، کار آیی مناسبی را از خود به نمایش نمی‌گذارد [۷]. بنابراین، بعدها برای کار در محیط‌هایی با نویزهای شدید و نیز در سامانه‌های غیرخطی، استفاده از مشتقات فیلتر کالمن مانند EKF [۸]، UKF [۹]، CKF [۱۰] پیشنهاد شد. اگرچه در همه این روش‌ها تلفیق صورت می‌گیرد، ولی در شرایط قطعی ناوبری GPS، INS بایستی به تنهایی ناوبری را انجام دهد. لذا تلفیق سخت<sup>۸</sup> GPS/INS تا حدودی می‌تواند این مشکل را حل کند. با استفاده از داده‌های خام GPS، یعنی اندازه‌گیری‌های شبه‌فاصله<sup>۹</sup> و دلتا فاصله<sup>۱</sup>، در زمانی که تعداد کافی ماهواره برای به دست آوردن داده ناوبری GPS در دسترس نباشد، تلفیق سخت می‌تواند اطلاعات بیشتری

<sup>1</sup> Line-of-Sight

<sup>2</sup> Block

<sup>3</sup> Interrupt

<sup>4</sup> Inertial Measurement Unit

<sup>5</sup> Micro Electro Mechanic System

<sup>6</sup> Steering Angle Sensor

<sup>7</sup> Kalman Filter

<sup>8</sup> Tightly-Coupled

<sup>9</sup> Pseudo-Range

<sup>10</sup> Delta-Range

<sup>11</sup> Deeply-Coupled

<sup>12</sup> Tracking Loop


<sup>13</sup> Jamming

<sup>14</sup> Carrier

<sup>15</sup> Artificial Intelligence

<sup>16</sup> Attitude

<sup>17</sup> Past Samples



شکل (۱): مرحله یادگیری بلوک هوشمند در زمان دسترسی به GPS.



شکل (۲): مرحله تخمین توسط بلوک هوشمند در زمان قطعی GPS.

مطابق شکل (۱) در زمان دسترسی به خروجی ناوبری GPS، بلوک هوشمند با گرفتن خروجی ناوبری INS در دو گام قبلی، برای تخمین خروجی فعلی GPS آموزش داده می‌شود. این مرحله تا زمانی که GPS در دسترس است، ادامه خواهد یافت و مقادیر پارامترهای بلوک هوشمند به نحوی به‌روزرسانی می‌شوند که خطای تخمین به صفر میل کند. سپس در زمان قطعی GPS نیز مطابق با شکل (۲)، بلوک هوشمند عملاً خروجی INS را به سمت خروجی GPS میل داده و ناوبری بهتری را نتیجه می‌دهد. شایان‌ذکر است که چون در این رویکرد، صرفاً از خروجی ناوبری GPS استفاده‌شده است و سیگنال خام GPS برای آموزش بلوک هوشمند به کار نرفته است، لذا این رویکرد هیچ وابستگی به نوع سامانه ماهواره‌ای ندارد و برای سامانه‌های ماهواره‌ای دیگر نیز قابل‌اعمال و استفاده می‌باشد.

### ۳- هوش مصنوعی

با الهام از ساختار زیستی مغز انسان و سامانه پردازش اطلاعات آن، محققین توانستند شبکه‌های عصبی مصنوعی ارائه دهند. این شبکه‌ها طی فرآیند یادگیری و با استفاده از پردازشگرهایی به نام نورون، می‌توانند با دقت مناسب نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهند. در حقیقت نورون‌ها با سعی در شناخت روابط ذاتی بین داده‌ها، نگاشت از ورودی به خروجی را استخراج می‌کنند [۱۶]. در این مقاله به‌منظور تخمین خروجی ناوبری GPS در زمان قطعی آن، از هوش مصنوعی استفاده‌شده است. بدین‌صورت که در پنج روش مختلف، شبکه‌های عصبی MLP، RBF، SVR، موجک و نیز سامانه استنتاج فازی-عصبی تطبیقی به‌عنوان بلوک هوشمند به‌کاررفته‌اند.

زمانی INS می‌باشد. خروجی بلوک هوشمند نیز می‌تواند خروجی GPS در لحظه  $t$  است. یا به بیانی دیگر بلوک هوشمند خروجی INS را به سمت خروجی GPS میل می‌دهد. در طول زمانی که خروجی ناوبری GPS در دسترس است، بلوک هوشمند در فاز آموزش است و خروجی بلوک هوشمند با مقدار مطلوب مقایسه می‌شود. این در حالتی است که خروجی مطلوب را از داده‌های GPS می‌گیرد. خطای تخمین بلوک هوشمند، تفاوت بین خروجی بلوک هوشمند و خروجی GPS است. برای کاهش این خطا، بلوک هوشمند تعلیم داده می‌شود تا پارامترهای آن را مرتباً تنظیم کند. این کار تا زمانی ادامه می‌یابد که به مقدار مشخصی از حداقل مربعات خطا ( $MSE^1$ ) برسد. این مدت‌زمان تعلیم تا زمان قطعی GPS ادامه پیدا می‌کند. در زمان قطعی GPS، بلوک هوشمند با استفاده از آخرین وزن‌های به‌دست‌آمده در زمان تعلیم، خروجی GPS را برای ورودی‌های INS پیش‌بینی می‌نماید. برای رسیدن به یک پاسخ ناوبری کامل، طول، عرض و ارتفاع جسم به‌صورت جداگانه به شبکه عصبی اعمال می‌گردد تا مقدار MSE در حالت‌های مختلف تخمین زده شود. ضمناً تحت پنج روش مختلف، از شبکه عصبی پرسپترون چندلایه ( $MLP^2$ )، شبکه عصبی تابع پایه شعاعی ( $RBF^3$ )، شبکه عصبی رگرسیون بردار پشتیبان ( $SVR^4$ )، موجک<sup>۵</sup> و نیز سامانه فازی-عصبی تطبیقی ( $ANFIS^6$ ) به‌عنوان بلوک هوشمند استفاده کرده‌ایم.

سازمان‌دهی مقاله به این شرح می‌باشد که بخش دوم به رویکرد پیشنهادی پرداخته است. در بخش سوم، بلوک‌های هوشمند استفاده‌شده در تحقیق معرفی شده‌اند. بخش چهارم نیز نتایج شبیه‌سازی‌ها را به تفصیل در نمودارها و جداول نشان داده است. در بخش پنجم، به مقایسه روش‌های مختلف پرداخته‌شده است. بخش آخر نیز نتیجه‌گیری مقاله را ارائه می‌دهد.

### ۲- رویکرد پیشنهادی

رویکرد پیشنهادی ما که با بهره‌گیری از هوش مصنوعی به دنبال یافتن روابطی بین خروجی ناوبری INS و GPS است، شامل دو مرحله می‌باشد؛ مرحله یادگیری و مرحله تخمین. شکل‌های (۱) و (۲) این دو مرحله را نمایش می‌دهند.

<sup>1</sup> Mean Square Error

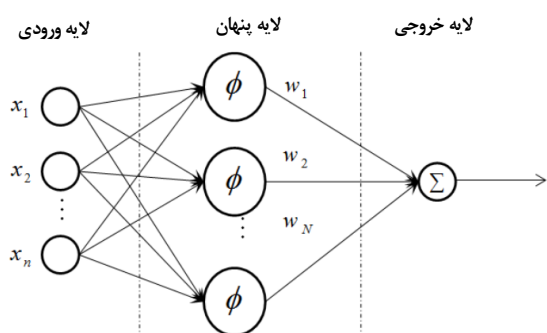
<sup>2</sup> Multi-Layer Perceptron

<sup>3</sup> Radial Basis Function

<sup>4</sup> Support Vector Regression

<sup>5</sup> Wavelet

<sup>6</sup> Adaptive Neural-Fuzzy Inference System



شکل (۴): شبکه عصبی RBF.

ورودی می‌تواند به‌عنوان یک بردار از اعداد حقیقی مدل شود و خروجی این شبکه یک تابع اسکالر از بردار ورودی است که به‌صورت زیر محاسبه می‌شود:

$$\phi(x) = \sum_{i=1}^N a_i \rho(\|x - c_i\|) \quad (۳)$$

شبکه‌های RBF معمولاً به‌وسیله یک الگوریتم آموزش داده می‌شوند. در مرحله اول، بردارهای مراکز  $c$  برای توابع RBF لایه مخفی انتخاب می‌شوند. در مرحله بعد با یک مدل خطی، ضرایب  $w$  با توجه به تابع هدف متناسب می‌شوند. ضمناً تعیین مراکز RBF قاعده خاصی ندارد، لذا با آزمون و خطا و یا به کمک الگوریتم‌های تکاملی تعیین می‌شوند [۱۹]. در این مقاله از روش آزمون و خطا استفاده شده است.


### ۳-۳- شبکه عصبی SVR

شبکه عصبی SVR یک نوع سامانه یادگیری نظارت‌شده است که برخلاف انواع دیگر شبکه‌های عصبی، به‌جای آنکه خطای مدل‌سازی را کمینه کند، ریسک عملیاتی را به‌عنوان تابع هدف در نظر می‌گیرد و مقدار بهینه آن را محاسبه می‌کند. این روش بر مبنای تئوری یادگیری آمار استوار است که از اصل کمینه‌سازی خطای ساختاری بهره می‌جوید و موجب یک جواب بهینه عمومی می‌شود. هدف SVR این است که تابع  $f(x)$  را برای الگوهای آموزشی  $x$  طوری تشخیص دهد که بیشینه حاشیه را از مقادیر آموزشی  $y$  داشته باشد. به‌عبارت‌دیگر مدل SVR، مدلی است که منحنی با ضخامت  $\epsilon$  را به داده‌ها برازش می‌دهد به‌نحوی که کمترین خطا در داده‌های آزمون صورت گیرد. در مدل SVR از مجموعه توابع به فرم  $f(x)=w.x+b$  برای پیش‌بینی استفاده می‌شود که  $w$  وزن بردار  $x$  و  $b$  مقدار بایاس می‌باشد [۲۰].

به‌طورکلی رگرسیون‌گیری داده‌ها به شیوه خطی به‌ندرت اتفاق می‌افتد و در عمل نحوه قرارگیری داده‌ها به‌صورت غیرخطی است. در این شرایط از روش غیرخطی رگرسیون بردار پشتیبان استفاده می‌شود. در این حالت الگوهای ورودی به فضایی با ابعاد

### ۳-۱- شبکه عصبی MLP

MLP یکی از انواع شبکه‌های عصبی مصنوعی پیش‌خور است که شامل حداقل سه لایه گره می‌باشد: لایه ورودی، لایه پنهان و لایه خروجی. به‌جز گره‌های ورودی، هر گره یک نورون است که از یک تابع فعال‌سازی غیرخطی استفاده می‌کند [۱۷]. شکل (۳) یک نمونه شبکه عصبی MLP را نشان می‌دهد.



شکل (۳): یک شبکه عصبی MLP با دو لایه پنهان.

در این تحقیق، شبکه عصبی MLP به روش پس انتشار<sup>۱</sup> و با الگوریتم گرادین-نزولی<sup>۲</sup> تعلیم داده‌شده است. داشتن لایه‌های متعدد و توابع فعال‌سازی غیرخطی موجب شده است که MLP بتواند داده‌هایی را متمایز کند که به‌صورت خطی قابل تفکیک نیستند. ضمناً دو تابع فعال‌ساز سیگموئیدی معمول برای MLP در روابط (۱) و (۲) توصیف شده‌اند.

$$y(v_i) = \tanh(v_i) \quad (۱)$$

$$y(v_i) = \frac{1}{1 + e^{-v_i}} \quad (۲)$$

رابطه (۱) مبین تابع تانژانت هایپربولیک است که بین منفی یک تا یک تغییر می‌کند و رابطه (۲) تابع لجستیک می‌باشد که بین صفر تا یک متغیر است. در این تحقیق، از تابع فعال‌ساز تانژانت هایپربولیک در نورون‌های MLP استفاده شده است.

### ۳-۲- شبکه عصبی RBF

شبکه RBF که بر پایه تئوری درون‌یابی شکل گرفته است، از توابع پایه‌ای شعاعی به‌عنوان توابع فعال‌ساز استفاده می‌کند. خروجی این شبکه یک ترکیب خطی از توابع پایه شعاعی برای پارامترهای ورودی و نورون‌ها است [۱۸]. در شکل (۴) یک شبکه عصبی RBF که شامل سه لایه جداگانه می‌باشد، نشان داده شده است.

<sup>۱</sup> Back Propagation  
<sup>۲</sup> Gradient-Descented

$$f_0(x) = \sum_k a_{0,k} \phi_{0,k}(x) \quad (۶)$$

$$W_{a,b}(f) = \tilde{f}_{(a,b)} = \langle \psi_{a,b}(t), \quad (۷)$$

$$f(t) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi^* \left( \frac{t-b}{a} \right) dt$$

در آن، a پارامتر گسترش است و متناسب با فرکانس می‌باشد. به عبارت دیگر مقدار کوچک a متناظر با فرکانس بالا و مقدار بزرگ a متناظر با فرکانس پایین می‌باشد. پارامتر b نیز پارامتر انتقال بوده و متناسب با زمان است. برای آسان تر شدن کار با تبدیل موجک، معمولاً گسسته سازی آن به صورت دودویی انجام می‌گردد. بدین ترتیب که مقیاس و مکان به صورت توان‌های صحیح از ۲ می‌باشد. شایان ذکر است که در تبدیل موجک، هم تفکیک‌پذیری فرکانسی و هم تفکیک‌پذیری زمانی در نمودار زمان-فرکانس تغییر می‌کند [۲۲].

اکثر سیگنال‌ها در عمل سیگنال‌هایی در حوزه زمان هستند؛ اما در اکثر کاربردهای مرتبط با پردازش سیگنال، نمایش زمانی همیشه بهترین نمایش از یک سیگنال نیست. در بسیاری از موارد، اطلاعات مهم و تشخیص سیگنال در محتوای فرکانسی آن نهفته است. برای دستیابی به محتوای فرکانسی سیگنال می‌توان از تبدیل فوریه سیگنال استفاده نمود؛ اما نقص و مشکل جدی که تحلیل فوریه در انتقال به حوزه فرکانسی دارد، این است که اطلاعات زمانی سیگنال گم می‌شود. این نقص برای یک سیگنال ساکن خیلی مهم نیست؛ اما اکثر سیگنال‌های واقعی، سیگنال‌های غیر ساکن هستند و بدین صورت تحلیل فوریه برای تحلیل گذرای این نوع سیگنال‌ها ناکارآمد است. لذا در این موارد استفاده از تبدیل موجک گزینه بهتری است [۲۲]. تفاوت تبدیل موجک با تبدیل فوریه زمان کوتاه این است که پهنای پنجره برای هر یک از اجزای طیفی تغییر می‌کند. این روش در فرکانس‌های بالا، تفکیک‌پذیری زمانی خوب و تفکیک‌پذیری فرکانسی ضعیف و در فرکانس‌های پایین، تفکیک‌پذیری فرکانسی خوب و تفکیک‌پذیری زمانی ضعیف به دست می‌دهد؛ بنابراین، از ابزار قدرتمند دیگری به نام تبدیل موجک جهت تحلیل این نوع از سیگنال‌ها استفاده می‌شود.

تلفیق تئوری موجک با مفاهیم شبکه عصبی منجر به ایجاد شبکه عصبی موجک می‌گردد و به کارگیری آن می‌تواند جایگزین مناسبی در شبکه‌های عصبی پیش‌خور جهت تخمین و تقریب توابع غیرخطی باشد. شبکه‌های عصبی پیش‌خور، دارای تابع فعال‌سازی سیگموئید در لایه پنهان می‌باشند، درحالی‌که در شبکه‌های عصبی موجک، توابع موجک به‌عنوان تابع فعال‌سازی لایه پنهان شبکه پیش‌خور در نظر گرفته می‌شوند. در این شبکه‌ها هر دو پارامتر انتقال و تغییر مقیاس موجک‌ها در کنار

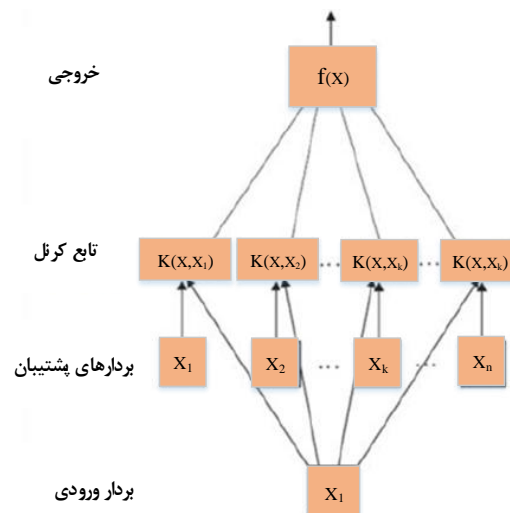
بیشتر نگاشت می‌یابند، به طوری که در فضای نگاشت یافته می‌توان به صورت خطی رگرسیون گیری کرد. معمولاً یافتن نگاشتی که مربوط به تابع کرنل خاصی باشد و یا پیدا کردن تابع کرنل مربوط به نگاشتی ویژه، سخت و حتی غیرممکن است. انتخاب تابع کرنل موضوع مهمی است که بر اساس آزمون، اطلاع از مسائل رگرسیون و همچنین ملاحظات نظری صورت می‌پذیرد. از توابع کرنل شناخته‌شده می‌توان کرنل‌های خطی و پایه شعاعی را نام برد. کرنل گاوسی که به‌عنوان تابع RBF شناخته می‌شود، به صورت هوشمند تعیین می‌کند از چند تابع کرنل استفاده نماید و سپس بهترین حالت آن را انتخاب می‌کند. کرنل گاوسی مطابق رابطه (۴) می‌باشد.

$$k(u, v) = \exp \left( -\frac{\|u - v\|^2}{2\sigma^2} \right) \quad (۴)$$

شکل (۵) نیز طرح‌واره شبکه‌های SVR را نشان می‌دهد.

### ۳-۴- شبکه عصبی موجک

شبکه‌های عصبی مبتنی بر موجک از ترکیب دو تئوری موجک‌ها و شبکه‌های عصبی به وجود آمده‌اند. این شبکه‌ها هم از مزایا و ویژگی‌های شبکه‌های عصبی برخوردارند و هم از طرفی دیگر، جذابیت‌ها، انعطاف‌پذیری‌ها، مبانی ریاضی مستحکم موجک‌ها و تحلیل چند مقیاسی را دارا می‌باشند [۲۱]. در حالت کلی همه توابع فیزیکی را می‌توان به کمک موجک‌ها و توابع مقیاس به صورت روابط (۵) و (۶) بیان نمود. تبدیل موجک برای توابع پیوسته نیز با رابطه (۷) محاسبه می‌شود.




شکل (۵): طرح‌واره شبکه SVR

$$f(x) = f_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^0 d_{m,k} \psi_{m,k} \quad (۵)$$

پنج لایه‌ای ANFIS در شکل (۷) نشان داده شده است. در شکل (۷) لایه اول مبتنی بر توابع عضویت<sup>۲</sup> است. برای ورودی  $x_1$  دو تابع عضویت  $A_{11}$  و  $A_{12}$  و برای ورودی  $x_2$  نیز دو تابع عضویت  $A_{21}$  و  $A_{22}$  در نظر گرفته شده است. معمولاً این توابع عضویت را به صورت گاوسی قرار می‌دهند که مقدار بیشینه آن یک و مقدار کمینه آن صفر است. با عبور ورودی‌ها از لایه اول، میزان عضویت آن‌ها در توابع عضویت مربوطه مشخص می‌شود. به عنوان مثال،  $\mu_{A_{11}}(x_1)$  نشان‌دهنده میزان عضویت متغیر  $x_1$  در تابع عضویت  $A_{11}$  می‌باشد. بلوک‌های لایه دوم از ورودی‌هایشان کمینه می‌گیرند و در حقیقت درجه صحت بخش مقدم قاعده را محاسبه می‌کنند. البته به جای کمینه گرفتن می‌توان از حاصل ضرب نیز استفاده کرد. وظیفه بلوک‌های لایه سوم نرمال کردن وزن‌های به دست آمده از لایه قبلی است. گره‌های لایه چهارم نیز وزن نرمال شده بخش مقدم قانون‌ها را در بخش تالی متناظرشان ضرب می‌کند و گره لایه پنجم نیز خروجی‌های لایه قبلی را جمع کرده و به شبکه می‌دهد. لذا با نظر در ساختمان لایه‌ای شکل (۷) مشخص است که از لحاظ ساختاری مشابه یک شبکه عصبی است. ضمناً پارامترهای طراحی  $p$ ،  $q$  و  $r$  در طول فرآیند یادگیری تعیین می‌شوند. یکی از نکات مهم در طراحی سامانه فازی، استخراج تعدادی قواعد مورد نیاز برای داده مربوطه است. انتخاب قواعد زیاد و اضافی منجر به پیچیدگی بیشتر سامانه می‌شود. این در حالی است که انتخاب تعداد کم قواعد نیز موجب کاهش دقت سامانه خواهد شد. لذا در این تحقیق برای استخراج قواعد مورد نیازمان از دو روش خوشه‌بندی کاهشی فازی (FSC<sup>۳</sup>) و خوشه‌بندی فازی سی-مینز (FCM<sup>۴</sup>)، به منظور گروه‌بندی زوج‌های ورودی-خروجی در خوشه‌های مختلف و به کارگیری یک قانون برای هر خوشه، استفاده شده است.

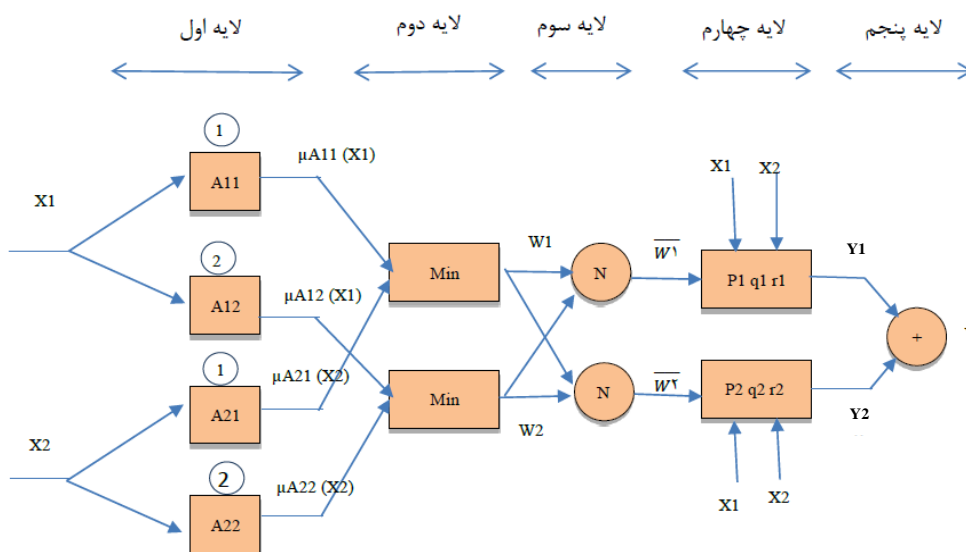
وزن‌هایشان بهینه می‌گردند [۲۳]. شکل (۶) طرح‌واره یک شبکه عصبی موجک را نشان می‌دهد.



شکل (۶): طرح‌واره یک شبکه عصبی موجک [۲۲].

### ۳-۵- سامانه استنتاج فازی-عصبی تطبیقی

تاکاگی-سوگینو برای اولین بار مدل‌سازی و شناسایی فازی را مطرح کردند که بعدها به طور گسترده‌ای در زمینه‌های کنترل، شناسایی و پیش‌بینی مورد استفاده قرار گرفت. در سال ۱۹۹۳ با تلفیق سامانه فازی و شبکه عصبی، سامانه استنتاج فازی-عصبی تطبیقی ایجاد شد. این سامانه هم دارای توانایی سامانه فازی در مدل‌سازی جنبه‌های کیفی دانش و فرآیندهای توصیفی-استدلالی است، هم از طرفی خواص یادگیری شبکه‌های عصبی را دارا می‌باشد. در ساختار ANFIS تنها محدودیتی که بر توابع گرهی وجود دارد آن است که به طور قطعی مشتق‌پذیر باشند. در این سامانه، قوانین فازی به صورت تاکاگی-سوگینو در نظر گرفته می‌شوند. بدین معنا که اگر  $x$  و  $y$  دو متغیر در بخش مقدم قانون نام باشند، تالی این قانون به صورت ترکیبی خطی از  $x$  و  $y$  و یک مقدار ثابت خواهد بود [۲۴]. با استفاده از فرآیند یادگیری هیبرید<sup>۱</sup> می‌توان پارامترهای ANFIS را برای مدل‌سازی سامانه‌ها بر اساس داده‌های ورودی و خروجی موجود تنظیم کرد. ساختار



شکل (۷): ساختار پنج لایه‌ای ANFIS [۲۴].

<sup>۲</sup> Membership Function  
<sup>۳</sup> Subtractive Fuzzy Clustering  
<sup>۴</sup> Fuzzy C-Means Method

Hybrid

مرکز برنده نمی‌تواند یک داده را به‌طور کامل از آن خود کند. به‌عبارتی‌دیگر، هر داده با درجه‌های عضویت متفاوتی در خوشه‌های مختلف قرار می‌گیرد. در الگوریتم k-means انتخاب اولیه مراکز خوشه‌ها به‌طور تصادفی انجام می‌شود. این امر می‌تواند در نتیجه پایانی به‌شدت تأثیرگذار باشد و الگوریتم را در تله‌های محلی<sup>۱</sup> متوقف کند. اگرچه این نقص به‌طور ذاتی در الگوریتم FCM نیز وجود دارد، اما به علت ماهیت فازی FCM، معمولاً به جواب بهینه می‌رسد و کمتر از k-means در تله‌های محلی گیر می‌کند. فرمول‌بندی این الگوریتم به شرح زیر می‌باشد:

اگر مجموعه داده n عضوی را به‌صورت  $X = \{x_1, \dots, x_n\}$  و مراکز اولیه c خوشه که به‌طور تصادفی انتخاب شده‌اند را به‌صورت  $C = \{c_1, \dots, c_c\}$  در نظر بگیریم، آنگاه درجه عضویت عضو  $x_i$  در خوشه  $j$ ام که با  $w_{i,j}$  نشان داده شده است، مطابق رابطه (۱۰) محاسبه می‌شود.

$$w_{i,j} = \frac{1}{\sum_{k=1}^c \left( \frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (10)$$

در این الگوریتم که ماهیتاً فازی است، درجه عضویت هرکدام از اعضا مطابق رابطه (۱۱) بین صفر و یک قرار می‌گیرد.

$$W = w_{i,j} \in [0,1] \quad (11)$$

$$i = 1, 2, \dots, n \quad j = 1, 2, \dots, c$$

شایان‌ذکر است که در الگوریتم k-means درجه عضویت اعضا در مجموعه  $\{1, \dots, c\}$  قرار می‌گیرد. ضمناً برای هر دو الگوریتم FCM و k-means، رابطه (۱۲) همواره برقرار است.

$$\sum_j w_{ij} = 1 \quad (12)$$

یعنی مجموع درجه عضویت عضو  $x_i$  در همه خوشه‌ها برابر یک است. به بیانی دیگر  $w_{i,j}$  معرف میزان تأثیرگذاری عضو  $x_i$  در تعیین مرکز خوشه  $j$ ام می‌باشد. مرکز خوشه  $j$ ام مطابق رابطه (۱۳) قابل محاسبه است.

$$c_j = \frac{\sum_i (w_{ij})x_i}{\sum_i w_{ij}} \quad (13)$$

برای آگاهی جامع‌تر از الگوریتم خوشه‌بندی FCM، می‌توانید به [۲۴] مراجعه کنید.

### ۳-۵-۱- خوشه‌بندی کاهشی فازی

رویکرد کلی این روش در یافتن خوشه‌ها و مراکز آن‌ها در سه مرحله قابل توضیح است. ابتدا تراکم همسایه‌ها برای تمام نقاط محاسبه می‌شود. آن نقطه‌ای که در یک شعاع معین، بیشتر از بقیه نقاط دارای همسایه باشد، به‌عنوان مرکز خوشه اول در نظر گرفته می‌شود. سپس در مرحله دوم و برای یافتن خوشه بعدی، این نقاط واقع در خوشه اول کنار گذاشته می‌شوند. در گام بعد، مرحله اول برای شعاع بزرگ‌تری تکرار می‌شود. این روند تا جایی ادامه می‌یابد که همه نقاط در خوشه‌های معینی قرار گیرند. فرمول‌بندی این مراحل به شرح زیر می‌باشد:

اگر مجموعه n داده را به‌صورت  $\{x_1, x_2, \dots, x_n\}$  در فضای M بعدی در نظر بگیریم، در مرحله اول تراکم همسایگی برای هرکدام از اعضاء طبق رابطه (۸) محاسبه می‌شود:

$$D_i^{(1)} = \sum_{j=1}^n e^{-\frac{4}{r_{(1)}^2} \|x_i - x_j\|^2} \quad (8)$$

که در آن،  $r_{(1)}$  شعاع دایره‌ای به مرکز آن نقطه‌ای است که میزان تراکم همسایگی‌اش محاسبه می‌شود. پس از محاسبه تراکم همسایگی برای تمامی نقاط مجموعه، آن نقطه‌ای را که دارای بیشترین تراکم همسایگی می‌باشد، به‌عنوان مرکز خوشه اول و به نام  $x_{c1}$  در نظر می‌گیریم. مقدار تراکم همسایگی  $x_{c1}$  نیز  $D_{c1}$  می‌نامیم. سپس در مرحله دوم و برای یافتن مرکز خوشه دوم، از رابطه (۹) مجدداً برای همگی نقاط مجموعه، تراکم همسایگی را محاسبه می‌کنیم.

$$D_i^{(2)} = D_i - D_{c1} * e^{-\frac{4}{r_{(2)}^2} \|x_i - x_{c1}\|^2} \quad (9)$$

همان‌طور که از رابطه (۹) مشهود است، این بار میزان تراکم همسایگی برای مرکز خوشه اول ( $x_{c1}$ ) برابر صفر است؛ یعنی مرکز خوشه اول برای انتخاب به‌عنوان مرکز خوشه دوم، هیچ شانس ندارد. البته برای تمامی نقاطی نیز که در خوشه اول و نزدیک مرکز خوشه هستند، در مرحله دوم میزان تراکم همسایگی‌شان کم می‌شود و به‌احتمال‌زیاد به‌عنوان مرکز خوشه دوم انتخاب نمی‌شوند و این همان مطلوب ما است. ضمناً  $r_{(2)}$  را نیز به‌طور معمول حدود ۱/۵ برابر  $r_{(1)}$  انتخاب می‌کنند تا تداخل خوشه‌ها کم شود. این روند تا جایی ادامه می‌یابد که تراکم همسایگی مرکز آخرین خوشه به حدود ۱۵٪ مقدار  $D_{c1}$  برسد و عملاً همه نقاط در خوشه‌های متناظرشان قرار گیرند [۲۵].


### ۳-۵-۲- خوشه‌بندی FCM

خوشه‌بندی FCM در حقیقت همان خوشه‌بندی k-means به‌صورت فازی است [۲۴]. یعنی در رقابت بین مراکز خوشه‌ها،

<sup>۱</sup> Local Trap



کمکی ناوبری نشان داده است. سپس در زیر بخش‌های بعدی، تک‌تک بلوک‌های هوشمند و پارامترهایشان را معرفی خواهیم کرد و نتایجشان به تفصیل جداول و شکل‌ها بیان می‌کنیم.



شکل (۹): مسیر پرواز واقعی (رنگ سبز): GPS در دسترس و رنگ قرمز: قطعی GPS.

ضمناً برای رسیدن به یک پاسخ ناوبری کامل، طول، عرض و ارتفاع جسم به صورت جداگانه به هر پنج نوع بلوک هوشمند اعمال گشته است تا مقدار RMSE در حالت‌های مختلف تخمین زده شود. شایان‌ذکر است که تمامی شبیه‌سازی‌ها در نرم‌افزار متلب ۲۰۱۸ و بر روی پردازنده اینتل پنج- هسته‌ای، با فرکانس کاری ۱/۶ گیگاهرتز و حافظه داده ۸ گیگابایت انجام گرفته است.

#### ۴-۱- نتایج ناوبری خالص INS


واحد IMU مورد استفاده در این تحقیق، صرفاً از سه حسگر ژيروسکوپ و سه حسگر شتاب سنج تشکیل شده است. خطای بایاس اولیه برای هر ژيروسکوپ و شتاب سنج به ترتیب برابر با  $\pm 3 \frac{deg}{s}$  و  $\pm 50 mg$  است. ژيروسکوپ‌ها سرعت زاویه‌ای را حول سه محور اندازه‌گیری می‌کنند. با استفاده از سرعت‌های زاویه‌ای اندازه‌گیری شده، شتاب‌هایی که توسط شتاب سنج‌ها در مختصات بدنه اندازه‌گیری شده‌اند، به شتاب‌هایی در مختصات ناوبری تبدیل می‌شوند. سپس با یک و دو بار انتگرال‌گیری از این شتاب‌ها، به ترتیب سرعت و مکان جسم محاسبه می‌شود و ناوبری انجام می‌گیرد. ایراد سامانه INS همین انتگرال‌گیری و طبعاً جمع شوندگی خطای آن می‌باشد. لذا در صورتی که صرفاً توسط INS ناوبری انجام گردد، پس از مدت‌زمانی واگرا می‌شود. شایان‌ذکر است که طول مدت‌زمان ناوبری خالص INS تا قبل از وقوع واگرایی، وابسته به فناوری حسگرهای به کار رفته در INS و نیز میزان همواری و یکنواختی مسیر حرکت جسم می‌باشد [۲۵]. در این تحقیق حسگرها از نوع MEMS هستند. در شکل (۱۰) که نتیجه ناوبری خالص INS می‌باشد، به وضوح دیده می‌شود که ناوبری پس از مدتی واگرا شده و عملاً مختل گشته است.

#### ۴- نتایج شبیه‌سازی

در این مقاله از پارامتر ریشه مربعات خطا (RMSE<sup>۱</sup>) برای ارزیابی نتایج سامانه استفاده شده است. تعریف پارامتر RMSE نیز در رابطه (۱۴) بیان گردیده است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^m (y_i - ay_i)^2}{m}} \quad (14)$$

به منظور محاسبه دقت تخمین بلوک هوشمند، از یک مجموعه داده عملی با ۱۵۰۰۰ نمونه که توسط یک مینی هواپیما جمع‌آوری شده است، استفاده کرده‌ایم. شایان‌ذکر است که مینی هواپیمای مذکور که دارای تجهیزات ناوبری GPS/INS می‌باشد، متعلق به شرکت هواپیمایی معراج است که در شکل (۸) نشان داده شده است.



شکل (۸): مینی هواپیمای آزمایشی با تجهیزات ناوبری [۲۲].


در این داده، نرخ خروجی INS ۵۰ هرتز، نرخ GPS یک هرتز و دو بار قطع GPS را لحاظ نموده‌ایم. مسیر پرواز واقعی مینی هواپیما در شکل (۹) نشان داده شده است. ضمناً در این آزمایش، میانگین سرعت در حدود ۱۲۰ (km/h) است. پرواز واضح است که خطاهای بزرگ مکان‌یابی در سرعت‌های بالا، مانند همین شرایطی که در این تحقیق است، بیشتر از سرعت‌های پایین وسایل نقلیه در محیط‌های شهری رخ می‌دهد. داده‌ها به دو بخش جهت انجام بررسی کار آیی عملیات پیش‌بینی تقسیم شده‌اند. بخش اول شامل ۷۰۰۰ داده و بخش دوم شامل ۸۰۰۰ داده مکان‌یابی است. در هر دو بخش، ۸۰ درصد داده‌ها به عنوان داده‌های آموزش و بقیه به عنوان داده‌های آزمون لحاظ شده‌اند. زیر بخش بعدی، در ابتدا به معرفی سامانه INS مورد استفاده در این تحقیق پرداخته است. سپس نتایج ناوبری خالص INS را به منظور درک عمیق علت نیاز به یک سامانه

<sup>1</sup> Root Mean Square Error


جدول (۱): خطاهای مؤثر طول، عرض، ارتفاع با استفاده از شبکه

عصبی MLP		
خطای مؤثر	شبکه عصبی MLP بهینه	مؤلفه‌های موقعیت
۵e-۶/۶۶۴۳	۲ لایه، ۳ ورودی و ۵ نورون لایه مخفی	طول جغرافیایی (rad)
۵e-۵/۴۵۷۹	۲ لایه، ۳ ورودی و ۵ نورون لایه مخفی	عرض جغرافیایی (rad)
۵/۱۳۶۳	۲ لایه، سه ورودی و ۱۰ نورون لایه مخفی	ارتفاع (m)


در شکل (۱۱) نیز خروجی‌های مطلوب و خروجی‌های تخمین زده‌شده توسط شبکه عصبی MLP بهینه، نشان داده شده است.



(الف)




(ب)




(ج)


شکل (۱۱): نتایج خروجی ناوبری تلفیقی INS/GPS توسط شبکه عصبی MLP و خروجی مطلوب برای: (الف) طول جغرافیایی، (ب) عرض جغرافیایی و (ج) ارتفاع.



(الف)



(ب)




(ج)


شکل (۱۰): نتایج خروجی ناوبری INS و خروجی مطلوب برای (الف) طول جغرافیایی، (ب) عرض جغرافیایی و (ج) ارتفاع.

#### ۴-۲- نتایج تلفیق INS/GPS با شبکه عصبی MLP

در این شبیه‌سازی از ۲، ۳ و ۴ ورودی برای پرسپترون دولایه، با تعداد ۵، ۱۰ و ۱۵ نورون در لایه مخفی و نیز پرسپترون سه لایه با تعداد ۵، ۱۰ و ۱۵ نورون در لایه مخفی اول و ۵ نورون در لایه مخفی دوم استفاده شده است. خلاصه نتایج این شبیه‌سازی که مربوط به حالت‌های بهینه می‌باشد، در جدول (۱) آمده است. لازم به ذکر است، از تابع تانژانت هیپربولیک به‌عنوان تابع فعال‌ساز استفاده شده است.



(ب)



(ج)

شکل (۱۲): نتایج خروجی ناوبری تلفیقی INS/GPS توسط شبکه عصبی RBF و خروجی مطلوب برای: (الف) طول جغرافیایی، (ب) عرض جغرافیایی و (ج) ارتفاع.

#### ۴-۴- نتایج تلفیق GPS/INS با استفاده از شبکه عصبی SVR

مقادیر پارامترهای شبکه عصبی SVR به صورت زیر انتخاب شده‌اند:

$$\text{Epsilon} = 0.1, \quad C = 5000, \quad \text{Sigma} = 1$$


شایان ذکر است که برای تنظیم فاکتور C، قاعده خاصی وجود ندارد و این یکی از ضعف‌های شبکه عصبی SVR است. لذا مقادیر بهینه را می‌توان به روش آزمون و خطا و یا با استفاده از الگوریتم‌های تکاملی تعیین نمود. در این تحقیق از روش آزمون و خطا استفاده شده است. ضمناً برای یک شبکه عصبی SVR با ۲، ۳ و ۴ ورودی و نیز با ۱۰ نورون لایه مخفی شبیه‌سازی صورت گرفته است. خلاصه نتایج این شبیه‌سازی که مربوط به حالت‌های بهینه می‌باشد، در جدول (۳) نشان داده

#### ۳-۴- نتایج تلفیق INS/GPS با شبکه عصبی RBF


مزیت استفاده از شبکه عصبی RBF در آرایش ساده و ساختار سه لایه (با احتساب لایه ورودی) آن است که از روش آموزش روبه جلو و الگوریتم‌های ساده‌ای مثل حداقل مربعات خطا استفاده می‌کند. این روش نسبت به اندازه شبکه‌های دیگر ساختار فشرده‌تری دارد و از سرعت یادگیری نسبتاً خوبی برخوردار است که در محاسبات نرم کاربرد فراوان دارد [۲۶]؛ اما مشکل استفاده از شبکه عصبی RBF در این است که از یک توپولوژی ثابت استفاده می‌کند. از این رو، نمی‌تواند به عنوان یک سامانه پویا عمل کند [۲۷]. در این شبیه‌سازی از RBF سه لایه با تعداد ۲، ۳ و ۴ ورودی و با ۱۰ نورون لایه مخفی استفاده شده است. خلاصه نتایج این شبیه‌سازی که مربوط به حالت‌های بهینه می‌باشد، در جدول (۲) آمده است. شکل (۱۲) نیز خروجی‌های مطلوب و خروجی‌های شبکه عصبی RBF بهینه را نشان می‌دهد و در آن مشهود است که این شبکه عصبی با مشخصات بیان شده، در تخمین ارتفاع دچار واگرایی شده است.

جدول (۲): خطاهای مؤثر طول، عرض، ارتفاع با استفاده از شبکه عصبی RBF

مؤلفه‌های موقعیت	شبکه عصبی RBF بهینه	خطای مؤثر
طول جغرافیایی (rad)	۳ لایه، ۴ ورودی و ۱۰ نورون لایه مخفی	$4e-2/503$
عرض جغرافیایی (rad)	۳ لایه، ۲ ورودی و ۱۰ نورون لایه مخفی	$4e-2/599$
ارتفاع (m)	۳ لایه، ۴ ورودی و ۱۰ نورون لایه مخفی	$5e+5/416$



(الف)



(ج)

شکل (۱۳): نتایج خروجی ناوبری تلفیقی INS/GPS توسط عصبی SVR و خروجی مطلوب برای: (الف) طول جغرافیایی، (ب) عرض جغرافیایی و (ج) ارتفاع.

شده است. شکل (۱۳) نیز خروجی‌های مطلوب و خروجی‌های شبکه عصبی SVR بهینه را نشان داده می‌دهد.

جدول (۳): خطاهای مؤثر طول، عرض، ارتفاع با استفاده از شبکه عصبی SVR.


خطای مؤثر	شبکه عصبی SVR بهینه	مؤلفه‌های موقعیت
$4e-2/1435$	۳ ورودی و ۱۰ نرون لایه مخفی	طول جغرافیایی (rad)
$4e-2/3693$	۲ ورودی و ۱۰ نرون لایه مخفی	عرض جغرافیایی (rad)
$59/6621$	۴ ورودی و ۱۰ نرون لایه مخفی	ارتفاع (m)

#### ۴-۵- نتایج تلفیق INS/GPS با شبکه عصبی موجک


در این تحقیق از توابع موجک Haar، Dubshies8 و Symlet10 برای ایجاد شبکه عصبی موجک استفاده شده است. در این شبیه‌سازی از شبکه عصبی موجک ۱۰ نرونی، ۴ لایه‌ای با ۲ ورودی اولیه استفاده شده است. خلاصه نتایج این شبیه‌سازی که مربوط به حالت‌های بهینه می‌باشد، در جدول (۴) بیان شده است. شکل (۱۴) نیز خروجی‌های مطلوب و خروجی‌ها شبکه عصبی موجک بهینه را نشان می‌دهد.

جدول (۴): خطاهای مؤثر طول، عرض، ارتفاع با استفاده از شبکه عصبی موجک.

خطای مؤثر			مؤلفه‌های موقعیت
Symlet10	Daubchies8	Haar	
$5e-6/98$	$4e-1/33$	$4e-1/1047$	طول جغرافیایی (rad)
$4e-1/128$	$4e-2/0739$	$4e-2/5379$	عرض جغرافیایی (rad)
$13/1136$	$27/3250$	$19/9122$	ارتفاع (m)



(الف)



(ب)

#### ۴-۶- نتایج تلفیق INS/GPS با ANFIS

در این روش از سامانه استنتاج فازی-عصبی تطبیقی برای تخمین خروجی سامانه GPS استفاده شده است. برای خوشه‌بندی داده‌ها نیز از دو روش خوشه‌بندی کاهشی فازی و FCM بهره‌برده‌ایم. پارامترهای روش خوشه‌بندی کاهشی فازی به روش آزمون و خطا و به شرح زیر تعیین شده‌اند:

شعاع مؤثر = ۰/۲، حداکثر تعداد دوره = ۱۰۰، خطای هدف = ۰، اندازه گام اولیه = ۰/۰۱، نرخ کاهش گام = ۰/۹ و نرخ افزایش گام = ۱/۱.


پارامترهای روش خوشه‌بندی FCM نیز به روش آزمون و خطا و به شرح زیر طراحی شده‌اند:

تعداد خوشه‌ها = ۱۲، حداکثر تعداد تکرارها = ۱۰۰، حداقل بهبودیافتگی =  $1e-5$ ، حداکثر تعداد دوره = ۱۰۰، خطای هدف = ۰، اندازه گام اولیه = ۰/۰۱، نرخ کاهش گام = ۰/۹ و نرخ افزایش گام = ۱/۱.


خلاصه نتایج این شبیه‌سازی که مربوط به حالت‌های بهینه می‌باشد، در جدول (۵) نشان داده شده است. در شکل‌های (۱۵) و (۱۶) نیز خروجی‌های مطلوب و خروجی‌های سیستم استنتاج فازی-عصبی تطبیقی که به ترتیب مبتنی بر خوشه‌بندی کاهشی فازی و FCM هستند، نشان داده شده است.

جدول (۵): خطاهای مؤثر طول، عرض، ارتفاع با استفاده از شبکه عصبی ANFIS.


خطای مؤثر		مؤلفه‌های موقعیت
FCM	Sub_Clus	
$4e-1/6541$	$4e-1/6554$	طول جغرافیایی (rad)
$5e-6/3632$	$5e-6/4102$	عرض جغرافیایی (rad)
$101/6242$	$103/6661$	ارتفاع (m)



(الف)




(ب)




(ج)


شکل (۱۴): خروجی ناوبری تلفیقی INS/GPS توسط شبکه عصبی موجک و خروجی مطلوب برای: (الف) طول جغرافیایی، (ب) عرض جغرافیایی و (ج) ارتفاع.




(الف)




(ب)




(ج)



(د)



(ه)



(و)

شکل (۱۶): خروجی ناوبری تلفیقی INS/GPS با استفاده از ANFIS با خوشه‌بندی FCM و خروجی مطلوب برای: (الف) طول جغرافیایی، (ب) عرض جغرافیایی و (ج) ارتفاع.

شکل (۱۵): خروجی ناوبری تلفیقی INS/GPS با استفاده از ANFIS با خوشه‌بندی کاهشی فازی و خروجی مطلوب برای: (الف) طول جغرافیایی، (ب) عرض جغرافیایی و (ج) ارتفاع.

## ۵- مقایسه نتایج

به‌عنوان تابع فعال‌سازی لایه پنهان پیش‌خور در نظر گرفته می‌شوند که جزئیات بیشتری از سیگنال را می‌توانند استخراج کنند و در نتیجه کار آبی بهتری دارند. برای مقایسه دو شبکه RBF و SVR می‌توان به این واقعیت استناد کرد که در شبکه عصبی SVR مراکز توابع گوسی به‌صورت هوشمند انتخاب می‌گردد، در حالی که انتخاب مراکز در شبکه RBF با آزمون و خطا صورت می‌گیرد و همین امر موجب برتری شبکه SVR نسبت به RBF می‌شود. در مورد ANFIS به نظر می‌رسد به دلیل بهینه نبودن تنظیمات پارامترهای آن، نتوانسته است که به برتری محرزی در پاسخ نسبت به بقیه برسد و این ضعف روش آزمون و خطا در طراحی پارامترها را نشان می‌دهد.

در بخش قبلی نتایج همه روش‌های مورد استفاده به تفصیل جداول و شکل‌ها گزارش شد. به‌وضوح مشاهده شد که نتیجه هر پنج روش مورد استفاده بهتر از نتیجه حاصل از ناوبری خالص INS هست. حال به‌منظور مقایسه دقت روش‌ها با یکدیگر، در جدول (۶) خلاصه نتیجه همه روش‌ها به‌صورت یکجا گزارش شده است. همان‌طور که از جدول (۶) مشاهده می‌شود، شبکه عصبی موجک در مقایسه با شبکه عصبی MLP، تحت شرایط یکسان، عملکرد بهتری را از خود نشان می‌دهد. می‌دانیم که شبکه‌های عصبی پیش‌خور، دارای تابع فعال‌سازی سیگموئید در لایه پنهان می‌باشند، در حالی که در شبکه‌های عصبی موجک، توابع موجک

جدول (۶): بهترین نتایج به‌دست‌آمده در محاسبات خطاهای طول جغرافیایی، عرض جغرافیایی و ارتفاع.

زمان اجرا (sec)	خطا (RMS)			روش	
	ارتفاع (m)	عرض جغرافیایی (rad)	طول جغرافیایی (rad)		
۵e-۱/۴۶۶۱	۱۹/۳۵۲۳	۵e-۷/۲۴۰۹	۵e-۹/۸۰۴۲	شبکه عصبی MLP	
۵e-۲/۱۵۸۶	۱۳/۴۵۶۱	۵e-۴/۷۴۲۱	۵e-۸/۶۸۹۲	شبکه عصبی موجک	
۲e-۱/۹۹۰۰	۶e+۱/۵۸۸	۴e-۲/۵۹۹	۴e-۲/۵۰۳۷	شبکه عصبی RBF	
۲e-۲/۸۲۰۰	۶۰۲	۴e-۲/۳۶۹۳	۴e-۲/۱۵۵۷	شبکه عصبی SVR	
۳e-۵/۱۰۰۰	۱۰۳/۶۶۱	۵e-۶/۴۱۰۲	۴e-۱/۶۵۵۴	Sub_Clus	ANFIS
۳e-۶/۱۰۰۰۰	۱۰۴/۰۴۰۴	۵e-۶/۳۶۳۲	۴e-۱/۶۵۴۱	FCM	

## ۶- نتیجه‌گیری

۱- نتایج رویکرد پیشنهادی نسبت به نتایج ناوبری خالص INS بهبود چشمگیری داشته و مشکل واگرایی ناوبری در زمان قطعی GPS حل شده است.

۲- از بین پنج روش استفاده‌شده در این مقاله، بهترین نتیجه برای شبکه عصبی موجک حاصل شده است؛ اما برای سامانه ANFIS چون که پارامترها به‌صورت سعی و خطا طراحی شده‌اند، به نظر می‌رسد که به بهینگی نرسیده‌ایم. لذا در کارهای آینده با استفاده از الگوریتم‌های تکاملی می‌توان با یافتن مقادیر بهینه برای پارامترهای طراحی، به این مطلوب دست یافت.

در این مقاله به‌منظور حل مشکل واگرایی ناوبری INS در زمان قطعی GPS، رویکردی مبتنی بر هوش مصنوعی ارائه شده است. مطابق این رویکرد در زمان دسترسی به GPS، بلوک هوشمند با دریافت اطلاعات مکانی و زمانی INS، برای تخمین خروجی ناوبری GPS تعلیم داده می‌شود. سپس این بلوک هوشمند در زمان قطعی GPS، عملاً خروجی INS را به سمت خروجی GPS میل می‌دهد. در این سناریو و طی پنج روش، از شبکه‌های عصبی MLP، RBF، SVR، موجک و نیز سامانه استنتاج فازی-عصبی تطبیقی به‌عنوان بلوک هوشمند استفاده شده است. در این مقاله با در نظر گرفتن پارامتر RMSE به‌عنوان پارامتر ارزیابی و پس از مقایسه نتایج شبیه‌سازی‌ها نتایج زیر استنتاج شده است:

## ۷- مراجع

- [14] Z. Xu, Y. Li, C. Rizos, and X. Xu, "Novel Hybrid of LS-SVM and Kalman Filter for GPS/INS Integration," *Journal of Navigation*, vol. 63, no. 2, pp. 289-299, 2010.
- [15] Y. Xu, X. Chen, and Q. Li, "INS/WSN-Integrated Navigation Utilizing LS-SVM and  $H_{\infty}$  Filtering," *Mathematical Problems in Engineering*, vol. 74, pp. 1-19, 2012.
- [16] D. L. Hudson and M. E. Cohen, "Neural Networks and Artificial Intelligence for Biomedical Engineering," New York: Institute of Electrical and Electronics Engineers, Second Edition, 2000.
- [17] K. L. Du and M. N. S. Swamy, "Neural Networks and Statistical Learning," London: Springer London, First Edition, 2019.
- [18] L. Semeniuk and A. Noureldin, "Bridging GPS Outages Using Neural Network Estimates of INS Position and Velocity Errors," *Measurement Science and Technology*, vol. 17, no. 10, pp. 2783-2798, 2006.
- [19] J. K. Jeon and M. S. Rahman, "Fuzzy and Neural Network Models for Geotechnical Problems," Raleigh, NC: North Carolina Dept. of Transportation Research and Analysis Group, Second Edition, 2008.
- [20] C. N. Ko and C. M. Lee, "Short-Term Load Forecasting Using SVR (Support Vector Regression)-Based Radial Basis Function Neural Network with Dual Extended Kalman Filter," *Energy*, vol. 49, no. 7, pp. 413-422, 2013.
- [21] M. Santhosh, C. Venkaiah, and D. V. Kumar, "Ensemble Empirical Mode Decomposition Based Adaptive Wavelet Neural Network Method for Wind Speed Prediction," *Energy Conversion and Management*, vol. 168, no. 9, pp. 482-493, 2018.
- [22] E. S. Abdolkarimi, G. Abaei, and M. R. Mosavi, "A Wavelet-Extreme Learning Machine for Low-Cost INS/GPS Navigation System in High-Speed Applications," *GPS Solutions*, vol. 22, no. 1, pp. 1-13, 2017.
- [23] M. Rafiei, T. Niknam, J. Aghaei, M. Shafie-Khah, and J. P. S. Catalao, "Probabilistic Load Forecasting Using an Improved Wavelet Neural Network Trained by Generalized Extreme Learning Machine," *IEEE Transactions on Smart Grid*, vol. 9, no. 6, pp. 6961-6971, 2018.
- [24] E. S. Abdolkarimi, "GPS/IMU Integration Using Artificial Intelligence," Master Thesis, Iran University Science and Technology (IUST), 2014. (In Persian)
- [25] D. Titterton and J. L. Weston, "Strapdown Inertial Navigation Technology," The Institution of Electrical Engineers, Second Edition, 2004.
- [26] M. R. Mosavi and M. Khishe, "Use of Functional Neural Networks of Radial Bridges Based on Gravitational Search Algorithm with General Guide to Classify Sonar Data," *Journal of Electrical & Cyber Defence*, vol. 4, no. 2, pp. 39-52, 2017. (In Persian)
- [27] M. Malleswaran, V. Vaidehi, and M. Jebari, "Neural Networks Review for Performance Enhancement in GPS/INS Integration," *IEEE Conference on Recent Trends in Information Technology*, pp. 34-39, 2012.
- [1] E. Rezaifard and P. Abbasi, "Inertial Navigation System Calibration using GPS Based on Extended Kalman Filter," *Proceedings of the Iranian Conference on Electrical Engineering (ICEE)*, pp. 778-782, 2017.
- [2] R. Ercek, P. Doncker, and F. Grenez, "Study of Pseudo-range Error due to Non-Line-of-Sight-Multipath in Urban Canyons," *Proceedings of ION GNSS*, pp. 1083-1094, 2005.
- [3] Q. Xu, X. Li, and C. Chan, "Enhancing Localization Accuracy of MEMS-INS/GPS/In-Vehicle Sensors Integration during GPS Outages," *IEEE Transactions on Instrumentation and Measurement*, vol. 67, no. 8, pp. 1966-1978, 2018.
- [4] L. Chen and J. Fang, "A Hybrid Prediction Method for Bridging GPS Outages in High-precision POS Application," *Journal of Navigation*, vol. 63, no. 1, pp. 417-430, 2011.
- [5] Y. Zhang, "A Fusion Methodology to Bridge GPS Outages for INS/GPS Integrated Navigation System," *IEEE Access*, vol. 7, no. 12, pp. 61296-61306, 2019.
- [6] D. Li, X. Jia, and J. Zhao, "A Novel Hybrid Fusion Algorithm for Low-Cost GPS/INS Integrated Navigation System During GPS Outages," *IEEE Access*, vol. 8, no. 5, pp. 53984-53996, 2020.
- [7] D. Li, X. Jia, and J. Zhao, "A Novel Hybrid Fusion Algorithm for Low-Cost GPS/INS Integrated Navigation System During GPS Outages," *IEEE Access*, vol. 8, no. 12, pp. 53984-53996, 2020.
- [8] H. Cao and J. Li, "Dual-Mass MEMS Gyroscope Structure, Design, and Electrostatic Compensation," *MEMS Sensors - Design and Application*, vol. 24, no. 2, pp. 677-688, 2018.
- [9] H. Cao, Y. Zhang, C. Shen, Y. Liu, and X. Wang, "Temperature Energy Influence Compensation for MEMS Vibration Gyroscope Based on RBF NN-GA-KF Method," *Shock and Vibration*, vol. 20, no. 5, pp. 1-10, 2018.
- [10] Y. Zhang, C. Shen, J. Tang, and J. Liu, "Hybrid Algorithm Based on MDF-CKF and RF for GPS/INS System During GPS Outages," *IEEE Access*, vol. 6, no. 4, pp. 35343-35354, 2018.
- [11] R. Sharaf, A. Noureldin, A. Osman, and N. El-Sheimy, "Online INS/GPS Integration with a Radial Basis Function Neural Network," *IEEE Aerospace and Electronic Systems Magazine*, vol. 20, no. 3, pp. 8-14, 2005.
- [12] W. Abdel-Hamid, A. Noureldin, and N. El-Sheimy, "Adaptive Fuzzy Prediction of Low-Cost Inertial-Based Positioning Errors," *IEEE Transactions on Fuzzy Systems*, vol. 15, no. 3, pp. 519-529, 2007.
- [13] A. Noureldin, A. El-Shafie, and M. Bayoumi, "GPS/INS Integration Utilizing Dynamic Neural Networks for Vehicular Navigation," *Information Fusion*, vol. 12, no. 1, pp. 48-57, 2011.



