



دانشگاه صنعتی سهند

DOR:

20.1001.1.23223146.1399.7.2.5.9

نشریه علمی-فصلنامه‌ای در زمینه برق

دوره ۷ - شماره ۲

بهار و تابستان ۱۳۹۹

صفحات ۱۰۸ الی ۱۲۹

ISSN: 2322-3146

http://journals.sut.ac.ir/jnsee

یک روش ترکیبی هوشمند جدید مبتنی بر فیلتر کالمن و شبکه عصبی رگرسیون تعمیم یافته برای تلفیق سیستم ناوبری اینرسی ارزان قیمت و سیستم ناوبری ماهواره‌ای جهانی

کاظم شکوهی مهر^۱، محسن فرشاد^۲، رمضان هاونگی^۳ و ناصر مهرشاد^۴

^۱ دانشجوی دکترا، دانشکده مهندسی برق و کامپیوتر - دانشگاه بیرجند - بیرجند - ایران

K.Shokoohi-Mehr@birjand.ac.ir

^۲ نویسنده مسئول، دانشیار، دانشکده مهندسی برق و کامپیوتر - دانشگاه بیرجند - بیرجند - ایران

mfarshad@birjand.ac.ir

^۳ دانشیار، دانشکده مهندسی برق و کامپیوتر - دانشگاه بیرجند - بیرجند - ایران havangi@birjand.ac.ir

^۴ دانشیار، دانشکده مهندسی برق و کامپیوتر - دانشگاه بیرجند - بیرجند - ایران nmehrshad@birjand.ac.ir

(تاریخ دریافت مقاله: ۱۳۹۸/۰۶/۲۳ تاریخ پذیرش مقاله: ۱۳۹۹/۱۱/۰۷)

چکیده

واژه‌های کلیدی

شبکه عصبی رگرسیون تعمیم یافته، فیلتر کالمن مقاوم، ناوبری تلفیقی، قطع شدن سیگنال‌های ناوبری ماهواره‌ای جهانی.

با توجه به عدم کارایی مناسب روش‌های مبتنی بر فیلتر کالمن برای تلفیق داده‌های سیستم ناوبری اینرسی ارزان قیمت و سیستم‌های ناوبری ماهواره‌ای جهانی در زمان قطع شدن سیگنال‌های ماهواره‌ای، استفاده از تکنیک‌های هوش مصنوعی در معماری تلفیق مرسوم شده است. از این رو در این مقاله ضمن ارائه یک معماری ترکیبی مؤثر، از شبکه عصبی رگرسیون تعمیم یافته برای پیش‌بینی مشاهدات مورد نیاز فیلتر کالمن در شرایط قطع شدن طولانی مدت سیگنال‌های ماهواره‌ای استفاده شده است. در مدل پیشنهادی، برای آموزش شبکه عصبی، سرعت‌ها و موقعیت‌های سیستم اینرسی به‌عنوان ورودی‌ها و نیز سرعت‌ها و موقعیت‌های سیستم موقعیت‌یاب جهانی به‌عنوان خروجی‌های شبکه در نظر گرفته شده‌اند. این رویکرد در عین کاربردی و عملیاتی بودن، سبب کاهش زمان محاسباتی و افزایش دقت و سرعت آموزش و تخمین شبکه شده است. نتایج شبیه‌سازی‌ها نشان می‌دهند که به‌دلیل ساختار ساده و در عین حال مقاوم معماری پیشنهادی و البته انتخاب یک شبکه عصبی کارآمد چند ورودی - چند خروجی با قابلیت کشف ارتباط مؤثر میان ورودی‌ها و خروجی‌های تعیین شده و به تبع آن اصلاح مناسب خطاهای مربوط به سرعت‌ها و موقعیت‌های سیستم ناوبری اینرسی، می‌توان از آن برای ناوبری زمان واقعی، خوداتکا، با قابلیت اطمینان و دقت بالا استفاده نمود.



Sahand University
of Technology

DOR:

[20.1001.1.23223146.1399.7.2.5.9](https://doi.org/10.1001.1.23223146.1399.7.2.5.9)

Journal of Nonlinear
Systems in Electrical
Engineering

Vol.7, No.2

Autumn and Winter 2020

ISSN: 2322 – 3146

<http://journals.sut.ac.ir/jnsee>

A New Intelligent Hybrid Method Based on Kalman Filter and Generalized Regression Neural Network for Low-Cost Inertial Navigation System and Global Satellite Navigation System Integration

Kazem Shokoohi-Mehr¹, Mohsen Farshad², Ramazan Havangi³ and Nasser Mehrshad⁴

¹Ph.D. Candidate, Faculty of Electrical and Computer Engineering, University of Birjand, Birjand, Iran, K.Shokoohi-Mehr@birjand.ac.ir

²**Corresponding Author**, Associate Prof., Faculty of Electrical and Computer Engineering, University of Birjand, Birjand, Iran, mfarshad@birjand.ac.ir

³Associate Prof., Faculty of Electrical and Computer Engineering, University of Birjand, Birjand, Iran, havangi@birjand.ac.ir

⁴Associate Prof., Faculty of Electrical and Computer Engineering, University of Birjand, Birjand, Iran, nmehrshad@birjand.ac.ir

ABSTRACT

Keywords

Generalized Regression
Neural Network,
Robust Kalman Filter,
Integrated Navigation,
Global Satellite Navigation
Signals outage.

Due to the inefficiency of Kalman filter-based methods for combining low-cost inertial navigation system data and global satellite navigation systems when satellite signals are outage, the use of artificial intelligence techniques in integrated architecture has become a common issue. Therefore, in this paper, while presenting an effective hybrid architecture, the generalized regression neural network is used to predict the required observations of the Kalman filter at the event of long-term outage of satellite signals. In the proposed model, for training the neural network, the velocities and positions of the inertial system are considered as inputs and also the velocities and positions of the global positioning system are considered as network outputs. This approach, while being practical and operational, has reduced computational time and increased the accuracy and speed of training and network estimation. The simulation results show that due to the simple yet robust structure of the proposed architecture and of course the selection of an efficient multi-input-multi-output neural network with the ability to detect the effective relationship between inputs and specified outputs and consequently correct errors related to speeds and situations, inertial navigation system can be used for real-time navigation, self-reliant, with high reliability and accuracy.

۱- مقدمه

سیستم‌های ناوبری اینرسی (INS)^۱ به دلیل عدم وابستگی به ارسال و دریافت سیگنال و به تبع آن عدم تأثیرپذیری از عوامل خارجی نظیر اغتشاش یا جمینگ می‌توانند در ناوبری هوایی، دریایی و یا زمینی به‌عنوان سیستمی خوداتکا مورد استفاده قرار گیرند. این سیستم‌ها قادرند علاوه بر مؤلفه‌های مربوط به سرعت‌ها و موقعیت‌های یک وسیله، مؤلفه‌های مربوط به وضعیت آن شامل رول، پیچ و یاو را نیز با نرخ بالایی به‌روزرسانی کنند. علی‌رغم این مزایا، در سنسورهای اینرسی ارزان قیمت میکروالکترومکانیکی (MEMS)^۲ عواملی نظیر نویزهای تصادفی، رانش ژيروسکوپ‌ها، بایاس شتاب‌سنج‌ها و خطاهای ناشی از شرایط اولیه، می‌توانند با گذشت زمان باعث انباشتگی خطا و در نتیجه کاهش دقت INS شوند. یک راهکار غلبه بر این مشکلات، استفاده از سنسورهای دقیق اینرسی است که با توجه به تکنولوژی ساخت آن‌ها، در بسیاری از کاربردها، با محدودیت‌هایی از قبیل عدم صرفه اقتصادی، محدودیت تکنولوژی ساخت و عدم دسترسی تجاری آن مواجه می‌باشند. از طرفی سیستم‌های ناوبری ماهواره‌ای جهانی (GNSS)^۳ نیز علی‌رغم دقت بالا و طولانی مدت، با محدودیت‌هایی نظیر تداخلات الکترومغناطیس، اثرات چند مسیری، لزوم در خط دید بودن حداقل ۴ ماهواره‌ی GNSS برای موقعیت‌یابی صحیح، اختلالات رادیویی و جمینگ مواجه می‌باشند [۱]. از این رو استفاده از سنسورهای اینرسی ارزان قیمت و تلفیق اطلاعات آن با GNSS مرسوم شده است. تکنیک تلفیق می‌تواند ضمن استفاده از مزایای نسبی INS و GNSS، مزایای متعدد دیگری نظیر کاهش انباشتگی خطاهای INS و افزایش دقت طولانی مدت آن، عدم وابستگی به سنسورهای دقیق اینرسی، افزایش قابلیت اطمینان و کاهش زمان جستجوی سیگنال‌های GNSS را به همراه داشته باشد [۲].

در سال‌های اخیر استفاده از روش‌های مختلف فیلترینگ، هوش مصنوعی و روش‌های ترکیبی تلفیق اطلاعات INS/GNSS مورد توجه بسیاری از پژوهشگران حوزه‌ی هدایت و ناوبری واقع شده است. با توجه به دینامیک سیستم ناوبری اینرسی، مرسوم‌ترین روش استفاده از انواع مختلف نسخه‌های^۴ فیلتر کالمن است [۳]. فیلتر کالمن شامل دو فاز به‌روزرسانی زمانی و به‌روزرسانی اندازه‌گیری است و فیلتر کالمن گسسته و فیلتر کالمن توسعه یافته (EKF)^۵ از رایج‌ترین روش‌های به‌کار رفته در ناوبری تلفیقی است. EKF مبتنی بر خطی‌سازی دینامیک‌های سیستم با بسط تیلور و ماتریس ژاکوبین بوده و با چالش‌های پیچیدگی تنظیم پارامترها و نیازمند بودن به مدل دقیق خطای سیستم مواجه است. این چالش‌ها می‌توانند سبب مشکلاتی نظیر کاهش دقت ناوبری، افزایش خطا، کاهش عملکرد فیلتر و یا واگرایی و ناپایداری الگوریتم ناوبری شوند [۴-۵]. علاوه بر این، روش‌های مبتنی بر فیلتر کالمن با چالش‌های دیگری نظیر ضرورت داشتن دانش قبلی از سیستم و ماتریس کواریانس نویز اندازه‌گیری و فرآیند، وجود مسأله‌ی رؤیت‌پذیری متغیرهای حالت پنهان، لزوم تنظیم پارامترهای فیلتر برای هر نوع سنسور جدید و از همه مهم‌تر دقت و کارآیی ضعیف هنگام قطع شدن طولانی مدت سیگنال‌های GNSS مواجه‌اند [۶].

¹ Inertial navigation system

² Micro electro mechanical system

³ Global navigation satellite system

⁴ Line of sight

⁵ Versions

⁶ Extended Kalman filter

از دیگر روش‌های فیلترینگ مورد استفاده در تلفیق اطلاعات INS/GNSS می‌توان به روش تخمین افق حرکت^۱ [۷] اشاره نمود. در این روش به ازای مقادیر مختلف مربوط به طول افق حرکت، خطای سرعت‌ها، موقعیت‌ها و وضعیت‌های ناوبری تلفیقی ارزیابی و مشخص گردیده به ازای افزایش مقدار طول افق حرکت، جذر میانگین مربعات خطا (RMSE)^۲ و سرعت محاسباتی کاهش یافته است. به همین دلیل طول افق حرکتی برابر با یک، برای ناوبری زمان واقعی در نظر گرفته شده است. علاوه بر این به دلیل مشکلات فیلتر کالمن نظیر وجود خطاهای قابل توجه در مدل دینامیک وسیله و تداخلات نامشخص، روش تخمین تطبیقی عوامل محوشونده چندگانه^۳ ارائه شده است [۸]. در این روش از فیلتر محوشونده برای کنترل تأثیر خطاهای مدل و از فیلتر H-infinity به منظور رفع عدم قطعیت‌ها با به حداقل رساندن خطای تخمین استفاده شده است. بررسی‌ها نشان دادند که فیلتر H-infinity مبتنی بر فیلتر کالمن مکعبی به میزان قابل توجهی تحت تأثیر خطاهای مدل بوده ولی استفاده از آن در کنار فیلتر محوشونده‌ی چندگانه، باعث بهبود نتایج شده است. همچنین فیلتر مقاوم تطبیقی بهبود یافته‌ی مبتنی بر فاصله‌ی ماحالانوبیس^۴ (برای تضعیف اثرات انحراف مدل در اندازه‌گیری‌ها و کنترل تأثیر خطاهای مدل دینامیک) [۹] و روش ترکیبی مبتنی بر فرآیند خودرگرسیو ترکیبی، فرآیند گاوس مارکوف مرتبه اول و سطح‌های تجزیه تبدیل موجک (جهت حذف نویز سنسورهای اینرسی) و نیز به کارگیری سیستم استنتاج فازی^۵ (برای تنظیم کوواریانس نویز فرآیند فیلتر کالمن توسعه یافته‌ی مرتبه‌ی دوم^۶) ارائه شده است [۱۰]. برای تلفیق داده‌های سیستم ناوبری اینرسی و بیدو^۷ نسخه‌ی بهبود یافته‌ی فیلتر کالمن بی‌اثر مخلوط گوسی^۸ مبتنی بر استفاده از تجزیه مقدار تکین به‌عنوان جایگزین محاسبه ریشه مربعات کوواریانس در تولید نقاط سیگمای UKF و نیز تقریب مجدد تابع تراکم احتمال برای پایان دادن به تعداد فزاینده‌ی توزیع گوسی و افزایش سرعت محاسباتی پیشنهاد شده است [۱۱]. روش IAE-AKF^۹ مبتنی بر فاکتور میرایی^{۱۰}، به دلیل بازسازی ساختار فیلتر کالمن، تنظیم مناسب مقادیر واریانس و بهره فیلتر و بالاخره حذف اثر نویز محیط، باعث بهبود دقت ناوبری یکپارچه شده است [۱۲]. علاوه بر این، فیلتر کالمن مکعبی بهبود یافته مبتنی بر ماتریس خطای نقاط سیگمای پسین^{۱۱} [۱۳]، ترکیب فیلتر ذره‌ای با الگوریتم ژنتیک [۱۴]، فیلتر کالمن با بهره‌های چندانتگرالی^{۱۲} و بهره‌ی متناسب^{۱۳} [۱۵] و نیز ساختاری با دو فیلتر کالمن تعمیم یافته [۱۶] برای ناوبری تلفیقی ارائه شده است. این قبیل روش‌های مبتنی بر فیلترینگ، با چالش اساسی عدم کارایی مناسب در شرایط قطع شدن اطلاعات سیستم‌های ناوبری ماهواره‌ای جهانی مواجه می‌باشند.

یک راهکار رایج غلبه بر مشکلات فیلتر کالمن و روش‌های فیلترینگ مبتنی بر مشاهدات GNSS در زمان قطع شدن سیگنال‌های ناوبری ماهواره‌ای، استفاده از شبکه‌های عصبی مصنوعی (ANN)^{۱۴} است. رویکرد کلی روش‌های تلفیقی مبتنی بر

¹ Moving Horizon Estimation

² Root mean square error

³ Adaptive Estimation of Multiple Fading Factors

⁴ Mahalanobis

⁵ Fuzzy Inference System (FIS)

⁶ Second-Order Extended Kalman Filter (SOEKF)

⁷ BeiDou

⁸ Gaussian Mixture Unscented Kalman Filter

⁹ Innovation-based adaptive estimation adaptive Kalman filtering

¹⁰ Attenuation

¹¹ Posterior sigma-points

¹² Multi-integral

¹³ Proportional

¹⁴ Artificial neural networks

شبکه‌های عصبی بدین گونه است که در زمان در دسترس بودن سیگنال‌های ماهواره‌ای، بخش هوش مصنوعی آموزش داده می‌شود تا با توجه به ورودی‌ها و خروجی‌های آن، دینامیک وسیله با خطای سرعت‌ها و موقعیت‌ها مطابقت پیدا کند. سپس در زمان قطع شدن سیگنال‌های GNSS بخش هوشمند آموزش داده شده، خطاهای INS را پیش‌بینی و تصحیح می‌کند. از این رو با توجه به فاکتورهایی نظیر سرعت، دقت و قابلیت تعمیم‌پذیری شبکه‌های عصبی، روش‌های مختلفی در این زمینه ارائه شده است. از میان شبکه‌های عصبی مرسوم، شبکه‌های MLP و RBF به ترتیب با مشکلات اجرای زمان واقعی و عدم یادگیری مناسب دینامیک خطا مواجه بوده و کارایی شبکه ANFIS نیز به دلیل مشکلاتی نظیر پیچیدگی محاسباتی، زمان طولانی اجرا و مشکل بهینه‌سازی و تنظیم پارامترها کاهش یافته است [۱۷-۱۸]. در همین راستا، تبدیل موجک گسسته برای حذف نویزهای فرکانس بالای شتاب‌سنج‌ها و ژيروسکوپ‌ها و اثر بخشی آن با روش هوشمند ماشین یادگیری مفرد^۱ و روش ترکیبی مبتنی بر ANFIS و الگوریتم خوشه‌بندی کاهش^۲ بررسی شده است [۱۸و۲]. همچنین شبکه عصبی بازگشتی^۳ [۶]، DS-SVM^۴ [۱۹]، دمپستر شافر [۲۰]، شبکه‌های عصبی تأخیر ورودی [۲۱] و شبکه عصبی خودرگرسیو غیرخطی [۲۲] برای تلفیق هوشمند اطلاعات INS و GPS^۵ در شرایط قطع شدن سیگنال‌های سیستم ناوبری ماهواره‌ای جهانی مورد بررسی واقع شده است. در روش‌های تلفیق با استفاده از شبکه‌های عصبی، معمولاً برای هر مؤلفه‌ی سرعت و یا موقعیت از یک شبکه عصبی استفاده شده و زمان آموزش و تخمین مؤلفه‌های ناوبری برای کاربردهای زمان واقعی مورد بررسی واقع نشده است.

علاوه بر این اخیراً توجه بسیاری از محققان به بررسی اثربخشی معماری ترکیبی تلفیق مبتنی بر روش‌های فیلترینگ و شبکه‌های عصبی در شرایط قطع شدن GPS معطوف شده است. در اکثر این روش‌ها، بخش هوش مصنوعی در زمان در دسترس بودن GPS، اختلاف میان مشاهدات GPS و INS را قبل از اعمال به فیلتر کالمن فرا گرفته و در هنگام قطع شدن سیگنال‌های ماهواره‌ای، مشاهدات مورد نیاز فیلتر کالمن را پیش‌بینی نموده و چالش مهم آن‌ها محدودیت برای استفاده در ناوبری تلفیقی زمان واقعی است. از روش‌های ترکیبی مبتنی بر فیلترینگ و شبکه‌های عصبی نیز، ترکیب فیلتر کالمن مجذور مکعبی^۶ با شبکه عصبی عمیق LSTM^۷ با هدف دستیابی به الگوریتمی خود فراگیر^۸ و مقاوم در برابر قطع شدن GPS ارائه شده است [۴]. در این روش از LSTM برای مینیمم کردن خطای خروجی سنسورهای اینرسی و برقراری ارتباط بین گین داخلی فیلتر و مشاهدات سیستم تلفیقی استفاده شده است. علاوه بر این حذف نویز با تبدیل موجک مبتنی بر تجزیه‌ی حالت تجربی^۹ و سپس ترکیب فیلتر کالمن تعمیم یافته‌ی چند مدلی تعاملی^{۱۰} با ماشین یادگیری مفرد انجام گردیده است [۲۳]. همچنین معماری ترکیبی مبتنی بر فیلتر کالمن و رویکرد یادگیری گروهی^{۱۱} [۵]، فیلتر کالمن و شبکه عصبی پس انتشار^{۱۲} [۲۴]، فیلتر فیدینگ^{۱۳} و ماشین یادگیری مفرد [۲۵]، فیلتر کالمن تعمیم یافته و شبکه عصبی پیوند کاربردی بردار تصادفی [۲۶]، فیلتر کالمن ردیاب قوی (برای تخمین خطاهای INS) و شبکه عصبی

¹ Extreme learning machine

² Subtractive clustering

³ Recurrent

⁴ Dempster-Shafer Support Vector Machines

⁵ Global Positioning System

⁶ Square root cubature kalman filter

⁷ Long short term memory

⁸ Self-learning

⁹ Empirical mode decomposition

¹⁰ Interactive multi-model

¹¹ Ensemble learning

¹² Back propagation

¹³ Fading

موجکی (برای پیش‌بینی خطاهای INS در هنگام قطع شدن GPS) [۲۷]، فیلتر کالمن و شبکه عصبی عمیق [۲۸] و فیلتر کالمن و شبکه عصبی موجکی فازی بازگشتی [۲۹] ارائه شده است. این روش‌ها نیز معمولاً بر اساس دقت تخمین ارزیابی شده و در آن‌ها زمان محاسباتی برای کاربردهای زمان واقعی مورد بررسی واقع نشده است.

در این مقاله برای حفظ کارایی الگوریتم ناوبری تلفیقی در شرایط قطع شدن GPS، یک معماری ترکیبی مؤثر مبتنی بر فیلتر کالمن و GRNN ارائه شده است. این معماری می‌تواند به دلیل دارا بودن دانشی غنی میان ورودی‌ها و خروجی‌های بخش هوش مصنوعی و نیز به کارگیری GRNN به موازات عملکرد فیلتر کالمن در فاز آموزش شبکه، باعث حفظ کارایی الگوریتم ناوبری در هنگام در دسترس نبودن مشاهدات GNSS شود.

ادامه‌ی مقاله بدین گونه است که در بخش دوم پیش زمینه تحقیق ارائه شده است. در بخش سوم روش ترکیبی پیشنهادی مبتنی بر فیلتر کالمن و شبکه عصبی رگرسیون تعمیم یافته (GRNN-KF) تشریح گردیده است. در بخش چهارم به شبیه‌سازی روش ترکیبی پیشنهادی و مقایسه‌ی نتایج آن با روش مرسوم فیلتر کالمن (KF) و نیز روش ترکیبی مبتنی بر فیلتر کالمن و شبکه عصبی RBF (RBF-KF) پرداخته شده است. در بخش پنجم نیز جمع‌بندی و نتیجه‌گیری آورده شده است.

۲- پیش‌زمینه‌ی تحقیق

۲-۱- مدل دینامیک INS

سنسورهای اینرسی ارزان قیمت میکروالکترومکانیکی از دو بخش اصلی شامل ژيروسکوپ‌ها و شتاب‌سنج‌ها تشکیل شده‌اند. از طریق اندازه‌گیری‌های مربوط به این سنسورها و حل معادلات ناوبری در پردازشگرهای کامپیوتری، وضعیت‌ها (رول، پیچ و یاو)، سرعت‌ها (در سه جهت شمال، شرق و پایین) و موقعیت‌های وسیله (طول جغرافیایی، عرض جغرافیایی و ارتفاع) قابل محاسبه است. معادلات ناوبری اینرسی بر اساس نرخ تغییرات سرعت زمینی نسبت به دستگاه ناوبری (\dot{v}_e^n) مطابق روابط (۱) حاصل می‌گردد [۲۹ و ۳۰]:

$$\begin{aligned} \dot{v}_e^n &= C_b^n \cdot f^b - [2w_{ie}^n + w_{en}^n] \times v_e^n + g_l^n \\ v_e^n &= [v_N \quad v_E \quad v_D]^T \\ g_l^n &= [0 \quad 0 \quad g]^T \end{aligned} \quad (1)$$

در روابط بیان شده C_b^n ماتریس دوران از دستگاه بدنی به ناوبری، f^b نیروی مخصوص شتاب‌سنج‌ها در دستگاه بدنی، w_{ie}^n نرخ دوران دستگاه زمینی نسبت به دستگاه اینرسی، w_{en}^n نرخ دوران دستگاه ناوبری نسبت به زمینی، v_e^n بردار سرعت‌ها در دستگاه ناوبری و g_l^n بردار جاذبه‌ی محلی است. در رابطه‌ی (۱) ماتریس دوران وسیله از دستگاه بدنی به ناوبری مطابق رابطه‌ی (۲) و با توجه به فرم چهار پارامتری کواترنین به صورت $q = [q_0 \quad q_1 \quad q_2 \quad q_3]^T$ حاصل می‌گردد.

$$C_b^n = \begin{bmatrix} (q_0^2 + q_1^2 - q_2^2 - q_3^2) & 2(q_1q_2 - q_0q_3) & 2(q_1q_3 + q_0q_2) \\ 2(q_1q_2 + q_0q_3) & (q_0^2 - q_1^2 + q_2^2 - q_3^2) & 2(q_2q_3 - q_0q_1) \\ 2(q_1q_3 - q_0q_2) & 2(q_2q_3 + q_0q_1) & (q_0^2 - q_1^2 - q_2^2 + q_3^2) \end{bmatrix} \quad (2)$$

همچنین معادلات مربوط به w_{en}^n و w_{ie}^n مطابق روابط (۳) قابل محاسبه است.

$$\begin{aligned} w_{ie}^n &= [w_e \cos L \quad 0 \quad -w_e \sin L]^T \\ w_{en}^n &= [\dot{L} \cos L \quad -\dot{L} \quad -\dot{L} \sin L]^T \\ w_e &= 7.292115 \times 10^{-5} \text{ rad/sec} \end{aligned} \quad (3)$$

در روابط بیان شده Ω نرخ چرخش زمین، l طول جغرافیایی و L عرض جغرافیایی می‌باشند. از این رو معادلات مربوط به سرعت‌ها و موقعیت‌های وسیله مطابق روابط (۴) و (۵) قابل محاسبه‌اند [۳۰]:

$$\begin{aligned} \dot{v}_N &= f_N - v_E(2\Omega + \dot{L}) \sin L + v_D \dot{L} \\ \dot{v}_E &= f_E + v_N(2\Omega + \dot{L}) \sin L + v_D(2\Omega + \dot{L}) \cos L \\ \dot{v}_D &= f_D - v_E(2\Omega + \dot{L}) \cos L - v_N \dot{L} + g \end{aligned} \quad (4)$$

$$\begin{aligned} \dot{L} &= \frac{v_N}{R_M + h} \\ \dot{h} &= -v_D \\ \dot{h} &= -v_D \end{aligned} \quad (5)$$

در روابط بیان شده v_N ، v_E و v_D به ترتیب سرعت‌های وسیله در سه جهت شمال، شرق و عمود بوده و f_N ، f_E و f_D مؤلفه‌های نیروی ویژه در دستگاه مرجع جغرافیای محلی، g شتاب جاذبه، h ارتفاع وسیله و R_M شعاع انحنای نصف‌النهار^۱، R_N شعاع انحنای عرضی^۲ بوده و مطابق روابط (۶) از روی میزان پهنی بیضی گون (f) قابل محاسبه می‌باشند.

$$\begin{aligned} R_M &= R_e(1 - 2f + 3f \sin^2 L) \\ R_N &= R_e(1 + f \sin^2 L) \\ f &= 1/298.257223563 \\ R_e &= 6378137m \\ R_0 &= \sqrt{R_N R_M} \end{aligned} \quad (6)$$

۲-۲- شبکه عصبی رگرسیون تعمیم یافته

شبکه عصبی رگرسیون تعمیم یافته (GRNN)^۳ یک الگوریتم یادگیری پیش روی خودمختار^۴، سریع و یک مرحله‌ای^۵ است [۳۱-۳۳]. این شبکه‌ی مبتنی بر رگرسیون کرنل، دارای حافظه‌ی انجمنی^۶ و الگوریتم آموزش بسیار ساده بوده و می‌تواند پیچیدگی درونی‌یابی‌اش را بر اساس اطلاعات منتقل شده توسط نمونه‌های آموزشی کنترل نماید [۳۳-۳۵].

تکنیک اصلی به کار رفته در GRNN مبتنی بر ساخت تابع چگالی احتمال پیوسته‌ی مشترک^۷ (PDF) از روی داده‌های آموزشی و با استفاده از پارامترهای مستقل بردار ورودی و پارامترهای وابسته بردار خروجی است [۳۶]. از این رو اگر $f(X, Y)$ یک

¹ Meridian radius of curvature

² Transverse radius of curvature

³ Generalized regression neural network

⁴ Autonomous

⁵ One-pass

⁶ Associative

⁷ Joint probability density function

PDF مشترک از X (بردار متغیر تصادفی ورودی) و Y (متغیر تصادفی اسکالر خروجی) باشد، رگرسیون Y روی X به صورت رابطه‌ی (۷) بیان می‌شود [۳۵ و ۳۷]:

$$\hat{Y}(X) = E[Y|X] = \frac{\int_{-\infty}^{\infty} Y \cdot f(X, Y) \cdot dy}{\int_{-\infty}^{\infty} f(X, Y) \cdot dy} \quad (7)$$

این بدان معناست که وقتی $f(X, Y)$ شناخته شده باشد می‌توان با استفاده از تخمین‌گرهای پارزن^۱ مقدار Y را متناسب با ورودی X پیش‌بینی نمود [۳۳]. از این رو اگر k ابعاد بردار متغیر تصادفی x و n تعداد مشاهدات بردار y باشد؛ آنگاه PDF تخمین زده به صورت روابط بیان شده در (۸) می‌باشد:

$$x_i = (x_1, x_2, \dots, x_N), y_i = (y_1, y_2, \dots, y_N)^T$$

$$\hat{f}(x, y) = \frac{\sum_{i=1}^n \frac{D(x_i)}{2\sigma^2} \cdot e^{-\frac{D(x_i)}{2\sigma^2}}}{n(2\pi)^{(P+1)/2} \cdot \sigma^{(P+1)}} \quad (8)$$

$$D(x_i) = (x - x_i)^T (x - x_i)$$

$$D(y_i) = (y - y_i)^T (y - y_i)$$

که در آن $D(x_i)$ فاصله‌ی اقلیدسی^۲ بین نمونه‌ی آموزشی x و ورودی x_i ، $D(y_i)$ فاصله‌ی اقلیدسی بین نمونه‌ی آموزشی y و ورودی y_i و σ پارامتر یکنواختی^۳ (گسترش^۴) است. با قرار دادن رابطه‌ی PDF تخمین زده شده‌ی ارائه شده در (۸) در رابطه‌ی میانگین بیان شده در (۷)، می‌توان به رابطه‌ی میانگین تخمین دست پیدا نمود [۳۳].

$$\hat{y}(x_0) = \frac{\sum_{i=1}^n y_i \cdot \exp\left(-\frac{D(x_i)}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D(x_i)}{2\sigma^2}\right)} \quad (9)$$

بر همین اساس در معماری GRNN از چهار لایه شامل لایه‌های ورودی، الگو^۵ (رگرسیون پنهان)، جمع‌بندی^۶ و خروجی استفاده شده است [۳۵]. لایه‌ی ورودی با تعداد نرون‌های برابر با تعداد متغیرهای ورودی (P نرون)، اطلاعات ورودی را دریافت نموده و به لایه‌ی الگو منتقل می‌کند. لایه‌ی الگو دارای n گره از نمونه‌های آموزشی بوده، که در نرون‌های آن از توابع فعال‌ساز گوسی استفاده شده است [۳۴ و ۳۷]. در هر نرون لایه‌ی الگو، فاصله‌ی اقلیدسی بین نمونه تخمینی x_0 و نمونه آموزشی x_i محاسبه و سپس کرنل گوسی تعیین می‌گردد. از این رو بدیهی است نمونه‌ی آموزشی نزدیک‌تر به x_0 وزن بالاتری در تخمین خروجی داشته باشد [۳۳]. خروجی لایه الگو نیز به لایه جمع‌بندی رسیده که مطابق رابطه (۱۰)، خود شامل دو بخش صورت کسر (مجموع وزن‌دهی شده‌ی خروجی‌های لایه‌ی الگو) و مخرج است.

¹ Parzen

² Euclidean distance

³ Smoothing

⁴ Spread

⁵ Pattern

⁶ Summation

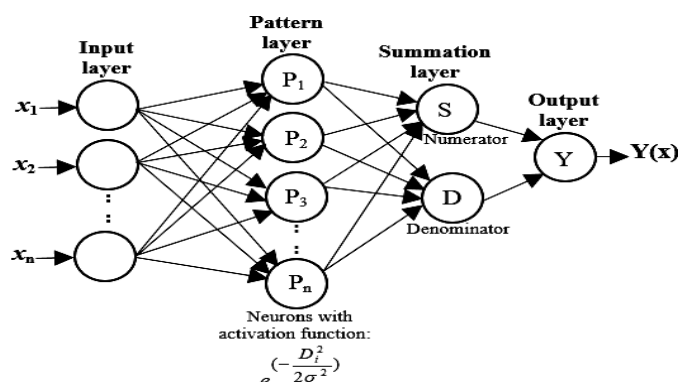
$$S_n = \sum_{i=1}^n w_i \cdot \exp\left(-\frac{D(x_i)}{2\sigma^2}\right)$$

$$S_d = \sum_{i=1}^n \exp\left(-\frac{D(x_i)}{2\sigma^2}\right)$$
(۱۰)

که در آن n تعداد نرون‌ها و w_i وزن اتصال i امین نرون لایه‌ی الگو به لایه‌ی جمع‌بندی است. در لایه‌ی خروجی مطابق رابطه‌ی (۱۱) دو بخش مربوط به لایه‌ی جمع‌بندی بر هم تقسیم شده و خروجی نهایی حاصل می‌گردد [۳۴].

$$\hat{y}(x_0) = \frac{S_n}{S_d}$$
(۱۱)

پس از آموزش شبکه به شیوه‌ای مؤثر و با الگوهای کافی از ورودی و هدف آموزشی، شبکه قادر به تعمیم و یافتن خروجی از روی الگوهای ذخیره شده است [۳۷]. از GRNN به دلیل استفاده از کرنل‌های گوسی نرمالیزه شده در لایه‌ی پنهان می‌توان برای تقریب و تخمین دقیق، رگرسیون، کلاس‌بندی، مدل‌سازی و پیش‌بینی سیستم‌هایی با نویز ورودی و تعداد داده‌های کم نیز استفاده نمود [۳۵]. در شکل (۱) ساختار شبکه عصبی رگرسیون تعمیم یافته نشان داده شده است.



شکل ۱. ساختار شبکه عصبی رگرسیون تعمیم یافته

شبکه GRNN دارای پارامترهای آموزشی کمتری نسبت به RBF بوده و عرض تابع پایه‌ای شعاعی^۱، تنها پارامتر قابل تنظیم آن می‌باشد [۳۷]. برای تعیین مقدار مناسب پارامتر یکنواختی می‌توان از روش سعی و خطا و یا معیارهایی نظیر MSE یا MAE استفاده نمود [۳۳ و ۳۸ و ۳۹].

۳- طراحی فیلتر کالمن مقاوم با استفاده از GRNN

در تلفیق اطلاعات INS/GNSS، فیلتر کالمن روشی مرسوم و زمان واقعی است. در این روش بازگشتی می‌توان بر اساس مدل دینامیک INS و مشاهدات GNSS در قالب دو فاز پیش‌بینی و تصحیح خطاهای سرعت‌ها و موقعیت‌های INS را پیش‌بینی و تصحیح نمود. مدل ریاضی تلفیق اطلاعات INS/GPS با استفاده از فیلتر کالمن و معادلات حالت سیستم مطابق روابط (۱۲) و (۱۳) است [۳۰]:

$$\delta\dot{x} = F \cdot \delta x + G \cdot \delta w$$
(۱۲)

^۱ Radial base function

$$\delta x = [\delta\alpha \ \delta\beta \ \delta\gamma \ \delta v_N \ \delta v_E \ \delta v_D \ \delta L \ \delta l \ \delta h]^T \quad (13)$$

$$\delta w = [\delta w_x \ \delta w_y \ \delta w_z \ \delta f_x \ \delta f_y \ \delta f_z]^T$$

که در آن F و G به ترتیب بیانگر ماتریس‌های انتقال حالت و نویز سیستم، δw بردار نویز سفید فرآیند و δx بردار حالات خطای INS است. ماتریس انتقال حالت و نویز سیستم مطابق روابط (۱۴) تا (۲۴) حاصل می‌گردند.

$$F = \begin{bmatrix} F_{11} & F_{12} & F_{13} \\ F_{21} & F_{22} & F_{23} \\ F_{31} & F_{32} & F_{33} \end{bmatrix} \quad (14)$$

$$F_{11} = \begin{bmatrix} 0 & -(\Omega \sin L + \frac{v_E \tan L}{R_0}) & \frac{V_N}{R_0} \\ (\Omega \sin L + \frac{v_E \tan L}{R_0}) & 0 & \Omega \cos L + \frac{v_E}{R_0} \\ -\frac{V_N}{R_0} & -\Omega \cos L - \frac{v_E}{R_0} & 0 \end{bmatrix} \quad (15)$$

$$F_{12} = \begin{bmatrix} 0 & \frac{1}{R_0} & 0 \\ -\frac{1}{R_0} & 0 & 0 \\ 0 & -\frac{\tan L}{R_0} & 0 \end{bmatrix} \quad (16)$$

$$F_{13} = \begin{bmatrix} -\Omega \sin L & 0 & -\frac{V_E}{R_0^2} \\ 0 & 0 & \frac{V_N}{R_0^2} \\ -\Omega \cos L - \frac{v_E}{R_0 \cos^2 L} & 0 & \frac{v_E \tan L}{R_0^2} \end{bmatrix} \quad (17)$$

$$F_{21} = \begin{bmatrix} 0 & -f_D & f_E \\ f_D & 0 & -f_N \\ -f_E & f_N & 0 \end{bmatrix} \quad (18)$$

$$F_{22} = \begin{bmatrix} \frac{V_D}{R_0} & -2(\Omega \sin L + \frac{v_E \tan L}{R_0}) & \frac{V_E}{R_0} \\ 2\Omega \sin L + \frac{v_E \tan L}{R_0} & \frac{1}{R_0}(v_N \tan L + v_D) & 2\Omega \cos L + \frac{v_E}{R_0} \\ -\frac{2V_N}{R_0} & -2(\Omega \cos L + \frac{v_E}{R_0}) & 0 \end{bmatrix} \quad (19)$$

$$F_{23} = \begin{bmatrix} -v_E(2\Omega \cos L + \frac{v_E}{R_0 \cos^2 L}) & 0 & \frac{1}{R_0^2}(v_E^2 \tan L - v_N v_D) \\ 2\Omega(v_N \cos L - v_D \sin L) + \frac{v_N v_E}{R_0 \cos^2 L} & 0 & -\frac{v_E}{R_0^2}(v_N \tan L + v_D) \\ 2\Omega v_E \sin L & 0 & \frac{1}{R_0^2}(v_N^2 + v_E^2) \end{bmatrix} \quad (20)$$

$$F_{31} = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (21)$$

$$F_{32} = \begin{bmatrix} \frac{1}{R_0} & 0 & 0 \\ 0 & \frac{1}{R_0 \cos L} & 0 \\ 0 & 0 & -1 \end{bmatrix} \quad (22)$$

$$F_{33} = \begin{bmatrix} 0 & 0 & \frac{-v_E}{R_0^2} \\ \frac{v_E \tan L}{R_0 \cos L} & 0 & \frac{-v_E}{R_0^2 \cos L} \\ 0 & 0 & 0 \end{bmatrix} \quad (23)$$

$$G = \begin{bmatrix} -C_b^n & 0_{3 \times 3} \\ 0_{3 \times 3} & C_b^n \\ 0_{3 \times 3} & 0_{3 \times 3} \end{bmatrix} \quad (24)$$

همچنین معادله‌ی مربوط به اندازه‌گیری‌های سیستم به صورت رابطه‌ی (۲۵) می‌باشد:

$$z = H \cdot \delta x + v \quad (25)$$

که در آن z بردار اندازه‌گیری، H ماتریس مشاهدات و v مبین بردار نویز مشاهدات است. از آنجا که اندازه‌گیری‌ها در فاصله‌های گسسته‌ی زمانی صورت می‌گیرد؛ از فرم گسسته‌ی معادلات (۱۲) و (۲۵) استفاده می‌شود [۲۹ و ۳۰]:

$$\begin{aligned} x_{k+1} &= \phi_k \cdot x_k + B_k \cdot w_k \\ z_k &= C_k \cdot x_k + v_k \end{aligned} \quad (26)$$

به طوری که ϕ_k ماتریس انتقال حالت سیستم در لحظه‌ی t_k ، w_k نویز سیستم در لحظه‌ی t_k ، C_k ماتریس اندازه‌گیری در لحظه‌ی t_k و v_k نویز اندازه‌گیری در t_k است. در فیلتر کالمن در زمان‌های دریافت اطلاعات GNSS، بردار اندازه‌گیری z_k مطابق رابطه‌ی (۲۷) و متناسب با اختلاف سرعت‌ها و موقعیت‌های INS و GNSS به‌روزرسانی می‌شود.

$$z_k = \begin{bmatrix} L_{INS} - L_{GNSS} \\ l_{INS} - l_{GNSS} \\ h_{INS} - h_{GNSS} \\ v_{N_{INS}} - v_{N_{GNSS}} \\ v_{E_{INS}} - v_{E_{GNSS}} \\ v_{D_{INS}} - v_{D_{GNSS}} \end{bmatrix} \quad (27)$$

همچنین ماتریس مشاهدات C_k مطابق رابطه‌ی (۲۸) حاصل می‌گردد.

$$C_k = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (28)$$

از این رو روابط ریاضی مربوط به دو فاز پیش‌بینی و به‌روزرسانی فیلتر کالمن مطابق روابط (۲۹) تا (۳۳) می‌باشد.

$$\hat{x}_k^- = \phi_{k-1} \hat{x}_{k-1} \quad (29)$$

$$P_k^- = \phi_{k-1} P_{k-1} \phi_{k-1}^T + Q_{k-1} \quad (30)$$

$$K_k = P_k^- C_k^T [C_k P_k^- C_k^T + R_k]^{-1} \quad (31)$$

$$\hat{x}_k = \hat{x}_k^- + K_k [z_k - C_k \hat{x}_k^-] \quad (32)$$

$$P_k = [I - K_k C_k] P_k^- \quad (33)$$

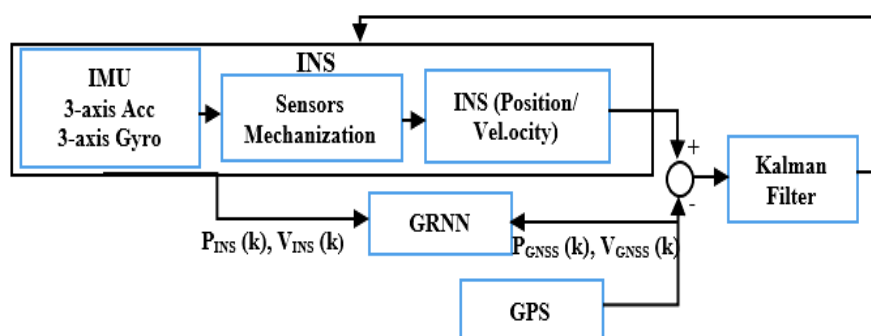
که در آن k مرحله‌ی اندازه‌گیری، K_k ماتریس بهره‌ی کالمن، \hat{x}_k تخمین حالت بهینه، P_k ماتریس کوواریانس تصحیح شده و Q_k و R_k ماتریس کوواریانس فرآیند و اندازه‌گیری می‌باشند. با توجه به تخمین خطاهای INS از روی معادلات فیلتر کالمن، سرعت‌ها و موقعیت‌ها مطابق روابط (۳۴) اصلاح می‌شوند.

$$\begin{aligned} v_N^{Corrected} &= v_N^{INS} - \delta \hat{v}_N \\ v_E^{Corrected} &= v_E^{INS} - \delta \hat{v}_E \\ v_D^{Corrected} &= v_D^{INS} - \delta \hat{v}_D \\ L^{corrected} &= L^{INS} - \delta \hat{L} \\ l^{corrected} &= l^{INS} - \delta \hat{l} \\ h^{corrected} &= h^{INS} - \delta \hat{h} \end{aligned} \quad (34)$$

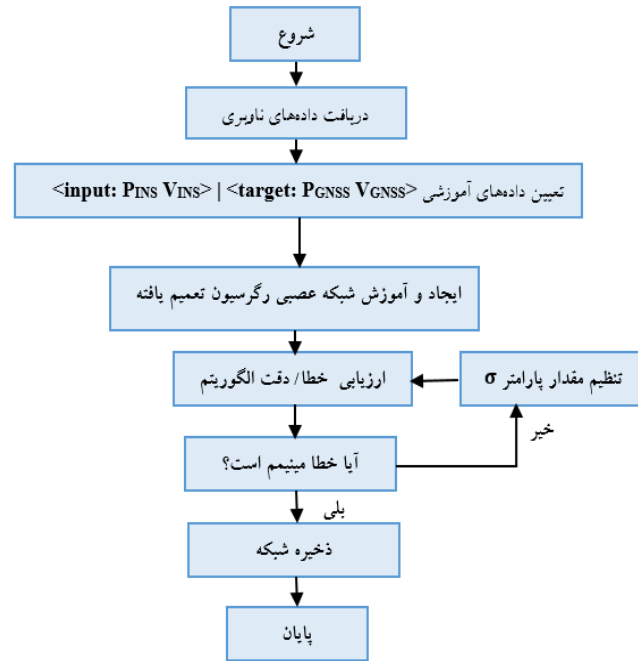
با توجه به معادلات ریاضی مربوط به فیلتر کالمن، مهم‌ترین ضعف آن مطابق رابطه (۲۷)، کاهش کارایی الگوریتم ناوبری تلفیقی در زمان بلاک شدن مشاهدات GNSS است. قطع شدن سیگنال‌های ماهواره‌ای در ناوبری تلفیقی GPS/INS با استفاده از سنسورهای اینرسی ارزان قیمت، باعث می‌شود خطای سرعت‌ها و موقعیت‌ها در طول زمان به میزان قابل توجهی افزایش یابد.

در این مقاله برای غلبه بر این چالش اجتناب‌ناپذیر، از شبکه عصبی رگرسیون تعمیم یافته برای مقاوم نمودن فیلتر کالمن در مقابل قطع شدن سیگنال‌های GNSS استفاده شده است. از آنجا که دقت و سرعت الگوریتم تلفیق در به‌روزرسانی داده‌های ناوبری حائز اهمیت است؛ GRNN با ورودی‌ها و اهداف آموزشی مؤثر و غنی در نظر گرفته شده است.

نحوه‌ی عملکرد الگوریتم ترکیبی مبتنی بر فیلتر کالمن و GRNN بدین گونه است که در فاز آموزش و در مدت زمان در دسترس بودن سیگنال‌های ماهواره‌ای، مطابق شکل (۲)، فیلتر کالمن استاندارد در دو فاز پیش‌بینی و تصحیح عملیات تلفیق را انجام می‌دهد. به موازات عملکرد فیلتر کالمن و در زمان‌های در دسترس بودن اطلاعات GNSS، شبکه عصبی رگرسیون تعمیم یافته بر اساس سرعت‌ها و موقعیت‌های INS در لحظه‌ی K به‌عنوان ورودی‌های شبکه و سرعت‌ها و موقعیت‌های GNSS در لحظه‌ی K به‌عنوان خروجی‌های شبکه، آموزش داده می‌شود. انتخاب این ورودی‌ها و اهداف آموزشی به دلیل دارا بودن اطلاعات و دانش غنی بین ورودی/خروجی شبکه سبب کاهش چشمگیر پیچیدگی الگوریتم، کاهش بار محاسباتی و افزایش دقت تخمین می‌گردد. همچنین با توجه به ویژگی‌های ذاتی و برجسته‌ی GRNN، انتخاب آن در معماری تلفیق، سبب دستیابی به تخمینی مناسب و سریع می‌شود. در شکل (۳) الگوریتم کلی آموزش شبکه عصبی رگرسیون تعمیم یافته نشان داده شده است.




شکل ۲. فاز آموزش GRNN در الگوریتم تلفیق ترکیبی



شکل ۳. الگوریتم کلی آموزش شبکه عصبی رگرسیون تعمیم یافته

در ادامه مطابق شکل (۴) و در زمان بلاک شدن سیگنال‌های ناوبری ماهواره‌ای جهانی، GRNN بر اساس دانش غنی فرا گرفته از فاز آموزش و با توجه به ورودی‌های اعمال شده به شبکه، اطلاعات مربوط به سرعت‌ها و موقعیت‌های GNSS را پیش‌بینی نموده و مطابق رابطه‌ی (۲۷) مشاهدات مورد نیاز فیلتر کالمن فراهم می‌شود. این معماری می‌تواند با کمک به بهبود عملکرد فیلتر کالمن، از انباشتگی خطای سیستم ناوبری اینرسی ارزان قیمت جلوگیری نماید.



شکل ۴. فاز پیش‌بینی GRNN برای ناوبری تلفیقی.


۴- نتایج

در این بخش به آنالیز نتایج روش ترکیبی مبتنی بر فیلتر کالمن و شبکه عصبی رگرسیون تعمیم یافته پرداخته شده است. شبیه‌سازی‌ها در محیط نرم‌افزار متلب و با هدف مقایسه‌ی میزان دقت و سرعت به‌روزرسانی داده‌های ناوبری سیستم تلفیقی فیلتر کالمن، با دو روش ترکیبی RBF-KF و GRNN-KF از زمان قطع سیگنال GNSS در لحظه‌ی $t=165$ ثانیه تا لحظه‌ی $t=320$ ثانیه انجام پذیرفته است. همچنین برای سیستم ناوبری اینرسی نرخ نمونه‌برداری برابر $0/02$ ثانیه و برای GPS $0/2$ ثانیه در نظر گرفته شده است.


برای GRNN پارامتر فشار انتخاب (آلفا) برابر ۰/۲ و برای RBF برابر ۰/۳ انتخاب شده است. همچنین برای آموزش وزن‌های لایه خروجی شبکه‌ی RBF (با تعداد ۱۵ نرون در لایه مخفی) از روش گرادیان نزولی استفاده شده است. مطابق رابطه‌ی (۳۵) جذر میانگین مربعات خطا (RMSE)^۱ معیار ارزیابی دقت و کارایی GRNN بوده و سائز شبکه بر اساس اولویت مهم زمان واقعی بودن روش‌ها در نظر گرفته شده است.

$$RMSE = \sqrt{\frac{1}{P} \sum_{n=1}^P (Y - Y_n)^2} \quad (35)$$


در رابطه‌ی فوق P تعداد نمونه‌ها، Y داده‌ی ناوبری مرجع و Y_n داده‌ی خروجی مربوط به هر روش ترکیبی است. در شکل‌های (۵) تا (۱۰) تغییرات داده‌های مربوط به مؤلفه‌های موقعیت و سرعت حاصل از سیستم ناوبری تلفیقی مبتنی بر GRNN-KF در بازه‌های قطع شدن طولانی مدت سیگنال‌های GNSS نشان داده شده است. این شکل‌ها نشان می‌دهند که علی‌رغم قطع شدن داده‌های GNSS، شبکه عصبی GRNN با پیش‌بینی و تصحیح مناسب مشاهدات GPS مورد نیاز فیلتر کالمن، توانسته به خوبی کارآمدی فیلتر کالمن را حفظ نماید.




شکل ۵. تغییرات طول جغرافیایی سیستم تلفیقی GRNN-KF نسبت به مرجع.




شکل ۶. تغییرات عرض جغرافیایی سیستم تلفیقی GRNN-KF نسبت به مرجع.




شکل ۷. تغییرات ارتفاع سیستم تلفیقی GRNN-KF نسبت به مرجع



شکل ۸. تغییرات V_N سیستم تلفیقی GRNN-KF نسبت به مرجع



شکل ۹. تغییرات V_E سیستم تلفیقی GRNN-KF نسبت به مرجع.



شکل ۱۰. تغییرات V_D سیستم تلفیقی GRNN-KF نسبت به مرجع.

در جدول (۱) نتایج مربوط به شاخص RMSE هر مؤلفه‌ی ناوبری با سه روش مختلف ارائه گردیده است.

جدول ۱. مقایسه‌ی RMSE راهبرد تلفیق در شرایط بازه‌های زمانی قطع شدن داده‌های GNSS.

	KF	RBF-KF	GRNN-KF
l (deg)	۰/۰۰۵	$1/80 \times 10^{-5}$	$3/44 \times 10^{-6}$
L (deg)	۰/۰۰۹	$7/92 \times 10^{-5}$	$2/73 \times 10^{-6}$
H (m)	۵/۰۲۸	۰/۰۱۹	۰/۰۱۴
V_N (m/s)	۱۷/۲۴۵	۰/۲۰۲	۰/۰۹۱
V_E (m/s)	۶/۵۲۱	۰/۲۹۳	۰/۰۹۵
V_D (m/s)	۷/۹۹۲	۰/۱۳۷	۰/۰۷۳


نتایج نشان می‌دهد که روش ترکیبی هوشمند مبتنی بر GRNN می‌تواند به دلیل معماری مناسب و تعیین ورودی-خروجی‌های مناسب برای فاز آموزش شبکه عصبی، با دقتی مناسب در شرایط خاص قطع شدن سیگنال‌های ماهواره‌ای مورد استفاده قرار گیرد. علاوه بر دقت هر مؤلفه، مهم‌ترین شاخصی که می‌تواند در عمل برای یک روش هوشمند ارائه شده در ناوبری مدنظر قرار گیرد سرعت به‌روزرسانی هر نمونه از دیتای ناوبری است. از این رو برای مقایسه کارآیی عملیاتی روش‌ها، میانگین سرعت به‌روزرسانی نمونه‌ها نیز مطابق جدول (۲) مورد ارزیابی واقع شده است.

جدول ۲. مقایسه‌ی میانگین سرعت به‌روزرسانی داده‌ها.


Time to update samples (s)			
	KF	RBF-KF	GRNN-KF
زمان آموزش	-	۰/۰۳۵	۰/۰۲
زمان پیش‌بینی	۰/۰۰۶	۰/۰۰۷	۰/۰۰۶

با توجه به نتایج جدول (۲) و سرعت بالای به‌روزرسانی نسبت به زمان به‌روز رسانی INS (۰/۰۲ ثانیه) می‌توان از رویکرد کلی معماری تلفیق در ناوبری زمان واقعی استفاده نمود.


در شکل‌های (۱۱) تا (۱۶) خطای موقعیت‌ها و سرعت‌های سیستم‌های تلفیقی در طول زمان نشان داده شده است.



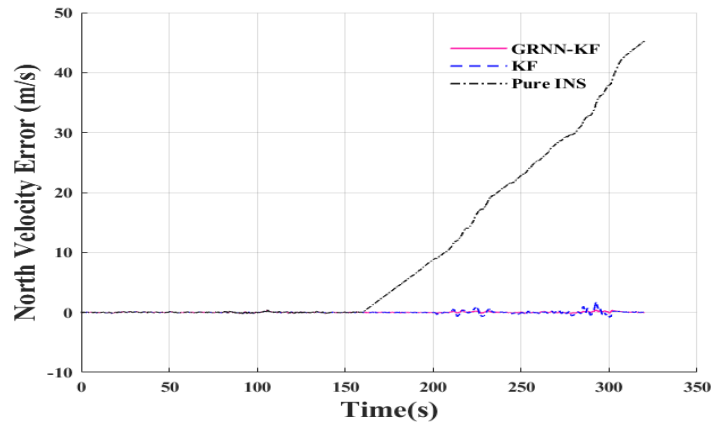
شکل ۱۱. مقایسه‌ی تغییرات مربوط به خطای طول جغرافیایی پس از قطع شدن GPS.




شکل ۱۲. مقایسه‌ی تغییرات مربوط به خطای عرض جغرافیایی پس از قطع شدن GPS.




شکل ۱۳. مقایسه‌ی تغییرات مربوط به خطای ارتفاع پس از قطع شدن GPS.



شکل ۱۴. مقایسه‌ی تغییرات مربوط به خطای V_N پس از قطع شدن GPS.



شکل ۱۵. مقایسه‌ی تغییرات مربوط به خطای V_E پس از قطع شدن GPS.



شکل ۱۶. مقایسه‌ی تغییرات مربوط به خطای V_D پس از قطع شدن GPS.

۵ - نتیجه گیری

دقت و قابلیت اطمینان سیستم یکپارچه‌ی INS/GPS مبتنی بر فیلتر کالمن، می‌تواند تحت تأثیر شرایط قطع شدن سیگنال‌های GNSS کاهش یابد. از این رو در این مقاله برای حفظ کارآیی و مقاوم نمودن فیلتر کالمن در زمان قطع شدن سیگنال‌های GPS،

یک معماری ترکیبی مبتنی بر فیلتر کالمن و هوش مصنوعی ارائه گردید. در این معماری، به دلیل قابلیت‌هایی نظیر ساختار ساده، حافظه‌ی انجمی، تعداد پارامتر قابل تنظیم محدود و از همه مهم‌تر سرعت و دقت بالای پیش‌بینی، از شبکه عصبی رگرسیون تعمیم یافته استفاده گردید. علاوه بر این شبیه‌سازی‌ها نشان داد به دلیل انتخاب ورودی‌ها و خروجی‌های مناسب برای فاز آموزش شبکه، در عین کاهش پیچیدگی محاسباتی، سرعت و دقت تخمین نیز به میزان قابل ملاحظه‌ای افزایش یافت. از این رو این ساختار می‌تواند ضمن حفظ کارایی فیلتر کالمن در زمان قطع شدن سیگنال‌های GPS و تصحیح خطاهای سرعت‌ها و موقعیت‌های سیستم ناوبری اینرسی ارزان قیمت، با سرعت، دقت و قابلیت اطمینان بالا در ناوبری زمان واقعی استفاده شود.

مراجع

- [1] M. M. Atia, S. Liu, H. Nematallah, T. B. Karamat, and A. Noureldin, "Integrated indoor navigation system for ground vehicles with automatic 3-D alignment and position initialization", *IEEE Transactions on Vehicular Technology*, vol. 64, no. 4, pp. 1279_1292, 2015.
- [2] E.S. Abdolkarimi, and M.R. Mosavi, "Wavelet-adaptive neural subtractive clustering fuzzy inference system to enhance low-cost and high-speed INS/GPS navigation system", *GPS Solutions*, vol. 24, no. 2, 2020.
- [3] J. Li, N. Song, G. Yang, M. Li, and Q. Cai, "Improving positioning accuracy of vehicular navigation system during GPS outages utilizing ensemble learning algorithm", *Information Fusion*, vol. 35, pp. 1-10, 2017.
- [4] C. Shen, Y. Zhang, X. Guo, X. Chen, H. Cao, J. Tang, J. Li, and J. Liu, "Seamless GPS/inertial navigation system based on self-learning square-root cubature Kalman filter", *IEEE Transactions on Industrial Electronics*, 2020.
- [5] C. Zhang, C. Guo, and M.Z. Guo, "Information Fusion Based on Artificial Intelligence Method for SINS/GPS Integrated Navigation of Marine Vessel", *Journal of Electrical Engineering & Technology*, pp. 1-12, 2020.
- [6] H.F. Dai, H.W. Bian, R.Y. Wang, and H. Ma, "An INS/GNSS integrated navigation in GNSS denied environment using recurrent neural network", *Defence Technology*, pp. 1-6, 2019.
- [7] F. Gırrbach, J. D. Hol, G. Bellusci, and M. Diehl, "Optimization-Based Sensor Fusion of GNSS and IMU Using a Moving Horizon Approach", *Sensors*, vol. 17, no. 5, pp. 1159-1176, 2017.
- [8] C. Jiang, S. B. Zhang, and Q. Z. Zhang, "Adaptive Estimation of Multiple Fading Factors for GPS/INS Integrated Navigation Systems", *Sensors*, vol 17, no. 6, 2017.
- [9] C. Jiang, and S. B. Zhang, "A Novel Adaptively-Robust Strategy Based on the Mahalanobis Distance for GPS/INS Integrated Navigation Systems", *Sensors*, vol. 18, no. 3, 2018.
- [10] N. Navidi, R. Landry Jr, J. Cheng, and D. Gingras, "A new technique for integrating MEMS-based low-cost IMU and GPS in vehicular navigation", *Journal of Sensors*, vol. 2016, pp. 1-16, 2016.
- [11] Q. Dai, L. Sui, L. Wang, T. Zeng, and Y. Tian, "An efficiency algorithm on Gaussian mixture UKF for BDS/INS navigation system", *Geodesy and Geodynamics*, vol. 9, no. 2, pp. 169-174, 2018.
- [12] Y. Liu, X. Fan, C. Lv, J. Wu, L. Li, and D. Ding, "An innovative information fusion method with adaptive Kalman filter for integrated INS/GPS navigation of autonomous vehicles", *Mechanical Systems and Signal Processing*, vol. 100, pp. 605-616, 2018.
- [13] B. Cui, X. Chen, and X. Tang, "Improved cubature Kalman filter for GNSS/INS based on transformation of posterior sigma-points error", *IEEE Transactions on Signal Processing*, vol. 65, no. 1, pp. 2975-2987, 2017.
- [14] X. Chen, C. Shen, and Y. Zhao, "Study on GPS/INS system using novel filtering methods for vessel attitude determination", *Mathematical Problems in Engineering*, vol. 2013, pp. 1-8, 2013.
- [15] M. Zhong, J. Guo, and Q. Cao, "On designing PMI Kalman filter for INS/GPS integrated systems with unknown sensor errors", *IEEE Sensors Journal*, vol. 15, no. 1, pp. 535-544, 2015.
- [16] J. Rohac, J.M. Hansen, M. Alam, M. Sipos, T.A Johansen and T.I Fossen, "Validation of nonlinear integrated navigation solutions", *Annual Reviews in Control*, vol. 43, pp. 91-106, 2017.

- [17] K. Saadeddin, M.F. Abdel-Hafez, M.A. Jaradat, and M.A. Jarrah, "Optimization of intelligent approach for low-cost INS/GPS navigation system", *Journal of Intelligent & Robotic Systems*, vol. 73, pp.325-348, 2014.
- [18] 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, 2018.
- [19] D. Bhatt, P. Aggarwal, V. Devabhaktuni, and P. Bhattacharya, "A novel hybrid fusion algorithm to bridge the period of GPS outages using low-cost INS", *Expert Systems with Applications*, vol. 41, no. 5, pp. 2166-2173, 2014.
- [20] P. Aggarwal, D. Bhatt, V. Devabhaktuni, and P. Bhattacharya, "Dempster Shafer neural network algorithm for land vehicle navigation application. *Information Sciences*", vol. 253, pp. 26-33, 2013.
- [21] M. Malleswaran, V. Vaidehi, A. Saravanaselvan, and M. Mohankumar, "Performance analysis of various artificial intelligent neural networks for GPS/INS integration", *Applied Artificial Intelligence*", vol. 27, no. 5, pp. 367-407, 2013.
- [22] M. A. K. Jaradat, and M. F. Abdel-Hafez, "Non- linear autoregressive delay- dependent INS/GPS navigation system using neural networks", *IEEE Sensors Journal*, vol. 17, no. 4, pp. 1105-1115, 2017.
- [23] 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, pp. 53984-53996, 2020.
- [24] G. Wang, X. Xu, Y. Yao, and J. Tong, "A Novel BPNN-Based Method to Overcome the GPS Outages for INS/GPS System", *IEEE Access*, vol. 7, pp. 82134-82143, 2019.
- [25] D. Wang, X. Xu, and Y. Zhu, "A Novel Hybrid of a Fading Filter and an Extreme Learning Machine for GPS/INS during GPS Outages. *Sensors*", vol. 18, no. 11, pp. 1-22, 2018.
- [26] D. Liu, S. Zhang, and J. Zhang, "A Robust EMD-Based RVFL Network Fusion Algorithm for Low-Cost GPS/INS Integrated System. *Mathematical Problems in Engineering*", vol. 2019, 2019, pp. 1-12.
- [27] X. Chen, C. Shen, W.B. Zhang, M. Tomizuka, Y. Xu, and K. Chiu, "Novel hybrid of strong tracking Kalman filter and wavelet neural network for GPS/INS during GPS outages", *Measurement*, vol. 46, no. 10, pp. 3847-3854, 2013.
- [28] Y. Zhang, "A Fusion Methodology to Bridge GPS Outages for INS/GPS Integrated Navigation System", *IEEE Access*, vol. 7, pp. 61296-61306, 2019.
- [29] P. Doostdar, J. Keighobadi, and M.A. Hamed, "INS/GNSS integration using recurrent fuzzy wavelet neural networks", *GPS Solutions*, vol. 24, no. 1, 2020.
- [30] D. Titterton, J. L. Weston, "Strapdown inertial navigation technology", *The Institution of Electrical Engineers, Michael Faraday House, Six Hills Way, Stevenage, United Kingdom*, 2004.
- [31] S. Golnaraghi, Z. Zangenehmadar, O. Moselhi, and S. Alkass, "Application of artificial neural network(s) in predicting formwork labour productivity", *Advances in Civil Engineering*, vol. 2019, pp. 1-11, 2019.
- [32] F. Modaresi, S. Araghinejad, and K. Ebrahimi, "A comparative assessment of artificial neural network, generalized regression neural network, least-square support vector regression, and K-nearest neighbor regression for monthly streamflow forecasting in linear and nonlinear conditions", *Water resources management*, vol. 32, no. 1, pp. 243-258, 2018.
- [33] Y. Xie, C. Li, Y. Lv, and C. Yu, "Predicting lightning outages of transmission lines using generalized regression neural network", *Applied Soft Computing*, vol. 78, pp. 438-446, 2019.
- [34] T. Lan, C. Tong, H. Yu, X. Shi, and L. Luo, "Nonlinear process monitoring based on decentralized generalized regression neural networks", *Expert Systems with Applications*, vol. 150, 2020.
- [35] Q. Yuan, H. Xu, T. Li, H. Shen, H. and L. Zhang, "Estimating surface soil moisture from satellite observations using a generalized regression neural network trained on sparse ground-based measurements in the continental US. ", *Journal of Hydrology*, vol. 580, 2020.
- [36] Y. He, B. Yang, H. Lin, and J. Zhang, "Modeling Polarized Reflectance of Natural Land Surfaces Using Generalized Regression Neural Networks. *Remote Sensing*", vol. 12, no. 2, 2020.
- [37] A.J. Al-Mahasneh, S.G. Anavatti, M.A. Garratt, and M. Pratama, "Stable adaptive controller based on generalized regression neural networks and sliding mode control for a class of nonlinear time-varying systems", *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2019.

- [38] J.P. Paulos, and J.N. Fidalgo, "Load and electricity prices forecasting using Generalized Regression Neural Networks", International Conference on Smart Energy Systems and Technologies (SEST), pp. 1-6, 2018.
- [39] M. Foroughi, M.H.A. Azqhandi, and S. Kakhki, "Bio-inspired, high, and fast adsorption of tetracycline from aqueous media using Fe₃O₄-g-CN@ PEI-β-CD nanocomposite: Modeling by response surface methodology (RSM), boosted regression tree (BRT), and general regression neural network (GRNN)", Journal of Hazardous Materials, vol. 388, 2020.