

بهبود دقت الگوریتم فیلتر کالمن در سامانه AHRS با بکارگیری شبکه عصبی عمیق LSTM

محمد سبزواری^۱، مسعودرضا آقابزرگی^{۲*}

اطلاعات مقاله	چکیده
<p>نوع مقاله: پژوهشی دریافت مقاله: ۱۴۰۰/۱۱/۰۴ بازنگری مقاله: ۱۴۰۱/۰۲/۲۴ پذیرش مقاله: ۱۴۰۱/۰۴/۰۷</p>	<p>استفاده از سامانه AHRS دقیق مبتنی بر سنسورهای تکنولوژی MEMS، با حجم کم و قیمت ارزان، نقش به سزایی در ناوبری و هدایت وسایل بدون سرنشین ایفا می‌کند. امروزه استفاده از الگوریتم‌ها و روش‌های گوناگون از جمله فیلترهای وقتی، شبکه‌های عصبی و فیلترهای تخمینگر جهت افزایش دقت این سامانه‌ها و کاهش نویز سنسورهای آن بسیار مورد توجه محققان قرار گرفته است. در این مقاله از ترکیب شبکه عصبی عمیق LSTM و فیلترکالمن جهت بهبود دقت سامانه AHRS استفاده شده است. در این روش، ابتدا شبکه عمیق مورد استفاده تحت آموزش قرار گرفته و سپس به عنوان یک تصحیح‌گر، ضرایب موثر فیلتر کالمن را تصحیح می‌کند. این روش تمامی محدودیت‌های فیلتر کالمن از جمله خطی بودن و حافظه‌دار نبودن آن را برطرف کرده و بدون استفاده از سامانه GPS دقت زوایای خروجی را بهبود بخشیده است. نتایج این تحقیق بر روی داده‌های واقعی سنسور IMU مبتنی بر تکنولوژی MEMS که نسبت به سنسورهای مورد استفاده در کارهای مشابه دارای دقت کمتری بوده، نصب شده بر روی هواپیمای بدون سرنشین با مانور بالا، انجام شده و بیانگر بهبود ۳۵ درصدی دقت زوایای وضعیت سامانه AHRS و بهبود ۴۰ درصدی کاهش نویز خروجی سنسورها می‌باشد.</p>
<p>واژگان کلیدی: ناوبری، AHRS، فیلتر کالمن، شبکه عصبی عمیق LSTM، هواپیمای بدون سرنشین.</p>	

۱- مقدمه

تکنولوژی MEMS^۳ به وفور استفاده می‌شود. یکی از سامانه‌های مورد استفاده بر روی هواپیمای بدون سرنشین که از سنسورهای برپایه تکنولوژی MEMS استفاده می‌کند، سامانه AHRS^۴ می‌باشد که جایگزین ژایروسکوپ‌های مکانیکی^۵ قدیمی شده است [۱]. سامانه AHRS از سه سنسور شتاب سنج^۶، ژایروسکوپ^۷ و مغناطیس سنج^۸ در هر محور تشکیل شده

امروزه استفاده از وسایل بدون سرنشین همچون هواپیما^۹، زیردریایی^{۱۰} و خودروهای بدون سرنشین^{۱۱} بسیار مورد توجه قرار گرفته است. تمامی این وسایل جهت ناوبری و هدایت خود نیازمند دانستن زوایای دقیق وضعیت^{۱۲} خود می‌باشند. با توجه به قیمت و حجم سامانه‌های ناوبری اینرسی قدیمی، امروزه از سنسورهای ارزان قیمت، کم حجم و سبک بر پایه

* پست الکترونیک نویسنده مسئول: aghabozorgi@yazd.ac.ir

۱. دانشجوی دکتری، دانشکده مهندسی برق، دانشگاه یزد

۲. دانشیار، دانشکده مهندسی برق، دانشگاه یزد

³Unmanned Aerial Vehicle(UAV)

⁴Autonomous Underwater Vehicles(AUV)

⁵Autonomous Ground Vehicles(AGV)

⁶Attitude angle

⁷Micro Electro Mechanical System

⁸Attitude and Heading Reference System

⁹Mechanical Vertical Gyro

¹⁰Accelerometer

¹¹Gyroscope

¹²Magnetometer

سنسورهای این سامانه بوده تا بتوان از این طریق خطای زوایای خروجی این سنسور بر پایه MEMS را بهبود بخشید. این سامانه پیشنهادی به عنوان یک تصحیح‌گر عمل کرده و پارامترهای فیلتر کالمن استفاده شده در سامانه AHRS را تصحیح می‌کند.

امروزه با توجه به پیشرفت تکنولوژی MEMS و به کارگیری این سنسورها در تلفن همراه، خودرو و غیره، محققان به دنبال افزایش دقت این سنسورها بوده تا بتوانند در مکان‌هایی که سیگنال‌های کمکی همچون GPS وجود ندارد موقعیت‌یابی کنند. یکی از این روش‌ها، استفاده از شبکه عصبی حافظه‌دار LSTM می‌باشد تا بتواند جایگزین مناسبی برای سیگنال GPS باشد.

اکثر تحقیقات انجام شده در این حوزه، بر روی تلفن همراه افراد، خودرو و کشتی و در عدم حضور سیگنال GPS^{۱۰} در مدت زمان محدود انجام شده است. مرجع [۱۳] با استفاده از شبکه عصبی عمیق LSTM و فیلتر کالمن توسعه یافته در سامانه ناوبری اینرسی به دنبال بهبود دقت در موقعیت خودرو در زمان عدم وجود سیگنال GPS می‌باشد و موفق به بهبود دقت این سامانه به میزان ۹۳ درصد شده است. در مرجع [۱۴] استفاده از شبکه‌های عصبی عمیق بر روی اطلاعات سنسور IMU موجود بر روی گوشی تلفن همراه افراد در یک فروشگاه انجام شده است و سعی در تخمین موقعیت افراد در مناطق سرپوشیده دارد. در مرجع [۱۵] با ترکیب شبکه عصبی CNN^{۱۱} و GRU^{۱۲} به دنبال مدل کردن خطای سنسورهای IMU جهت کاهش خطا بوده و در مرجع [۱۶] با استفاده از این شبکه‌ها، زوایای وضعیت یک کشتی بر روی دریا با استفاده از سامانه AHRS محاسبه گردیده است.

الگوریتم پیشنهادی در این مقاله بر روی داده‌های واقعی پرواز از یک سنسور IMU بر پایه MEMS با ۹ درجه آزادی که شامل شتاب‌سنج، مغناطیس‌سنج و ژيروسکوپ در هر سه محور می‌باشد، انجام شده است و با سامانه ناوبری اینرسی دقیق تلفیقی با GPS بر پایه FOG مقایسه گردیده است. این آزمایشات بر روی محیط سه بعدی انجام شده است و برخلاف اکثر تحقیقات، تغییرات در هر سه محور

است و هدف آن تخمین ارتباط بین دستگاه بدنه و دستگاه ناوبری می‌باشد که این ارتباط به صورت زوایای اوایلر^۱، کوآترنیون^۲ و ماتریس کسینوس‌ها^۳ نمایش داده می‌شود. علت خطای این سامانه‌ها، وجود نویز در سنسورهای اینرسی بوده که با مرور زمان به علت انباشتگی، این خطا افزایش می‌یابد [۲].

دو راهکار جهت بهبود دقت سامانه AHRS وجود دارد که یکی از آنها استفاده از سنسورهای دقیق با تکنولوژی FOG^۴ و RLG^۵ می‌باشد که بسیار گران‌قیمت، حجیم و سنگین می‌باشند و دیگری استفاده از فیلترهای تخمین‌گر همچون فیلتر کالمن جهت مدل کردن خطای سنسورها می‌باشد [۳-۵].

امروزه از شبکه‌های عصبی نیز جهت مدل کردن خطای سنسورها استفاده می‌شود. به عنوان نمونه، در مرجع [۶] با استفاده از شبکه‌های عصبی RBF^۶، دما را که عنصر اصلی خطا در سنسورهای MEMS می‌باشد مدل کرده است. در مرجع [۷] نیز از شبکه عصبی BP^۶ برای جبران خطای بایاس ژایروسکوپ‌ها استفاده شده است. در مرجع [۸] با مدل کردن خطای ژایروسکوپ‌ها و شتاب‌سنج‌ها سعی در تخمین خطای سامانه ناوبری اینرسی کرده و با مقایسه روش پیشنهادی با فیلتر کالمن توانسته دقت در موقعیت و وضعیت را بهبود بخشد. خطاهای IMU در مرجع [۹] با استفاده از MLP در حضور GPS، در مرجع [۱۰] با استفاده از روش ANFIS و در مرجع [۱۱] با بکارگیری Fuzzy logic مدل شده است.

استفاده از شبکه‌های عصبی عمیق، با پیشرفت سخت افزارها، بسیار مورد توجه قرار گرفته و توانسته بسیاری از محدودیت‌های شبکه‌های عصبی قبل را برطرف کند. شبکه عصبی عمیق بازگشتی^۸ یکی از این شبکه‌ها می‌باشد که جهت مدل کردن رفتار سامانه‌های سری زمانی بسیار استفاده می‌گردد که شبکه LSTM^۹ به علت دارا بودن حافظه، بسیار کارآمد است [۱۲].

در این مقاله با توجه به متغیر با زمان بودن داده‌های خروجی سنسور IMU سامانه AHRS، با استفاده از شبکه عصبی عمیق LSTM به دنبال مدل کردن خطای

⁷Back Propagation Neural Network

⁸Recurrent Neural Network(RNN)

⁹Long Short Term Memory

¹⁰ Global Positioning System(GPS)

¹¹ Convolutional Neural Network(CNN)

¹² Gated Recurrent Unit(GRU)

¹Euler angle

²Quaternion angle

³Direction cosine Matrix(DCM)

⁴Fiber Optical Gyroscope

⁵Ring Laser Gyroscope

⁶Radial Basis Function Neural Network

شبکه عصبی عمیق LSTM آموزش دیده می‌باشد، پارامتر بهره‌بردار فیلتر کالمن واحد اندازه‌گیری تصحیح می‌گردد. این سه قسمت که ارتباط بین آن‌ها در شکل (۱) مشاهده می‌شود در ادامه مورد بررسی قرار خواهند گرفت.

۲-۱- واحد IMU

همانگونه که بیان شد، سنسورهای IMU بر پایه تکنولوژی FOG و RLG نسبت به تکنولوژی MEMS دارای دقت بالاتری بوده ولی دارای حجم، وزن و قیمت بالاتری هستند. امروزه با توجه به استفاده فراوان از سنسورهای MEMS، بالا بردن دقت آن‌ها از طریق الگوریتم‌های تخمین بسیار مورد توجه قرار گرفته است [۱۷ و ۱۸].

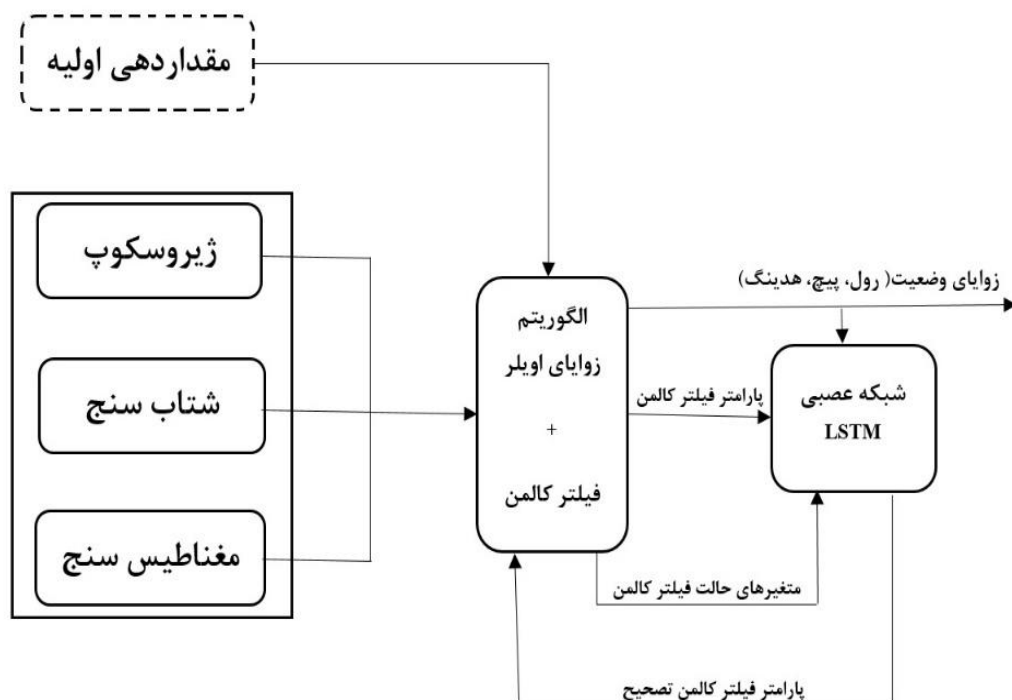
در این مقاله از سنسور IMU بر پایه تکنولوژی MEMS استفاده شده است [۱۹]. این سنسور با ۹ درجه آزادی شامل شتاب‌سنج خطی، مغناطیس‌سنج وژیروسکوپ می‌باشد که هر کدام از این سنسورها در سه محور عمود بر هم قرار گرفته‌اند. خروجی این واحد شامل شتاب خطی، سرعت زاویه‌ای و میدان مغناطیسی در سه محور و در دستگاه بدنه می‌باشد که با فرکانس ۵۰ هرتز بروزسانی می‌شوند. مشخصات فنی سنسور استفاده شده در این تحقیق در جدول ۱ آمده است.

سنسورها وجود دارد و همچنین از هیچ سنسور کمکی همچون GPS استفاده نشده است. نتایج نشان می‌دهد الگوریتم پیشنهادی توانسته دقت زوایای وضعیت سامانه AHRS و نویز خروجی آن را در مقابل فیلتر کالمن به تنهایی، به ترتیب ۳۵ و ۴۰ درصد بهبود بخشد.

در ادامه این مقاله و در بخش دوم، مدل و ساختار سامانه پیشنهادی که شامل سه واحد IMU، اندازه‌گیری و تصحیح می‌باشد مورد بررسی قرار گرفته و سپس در بخش سوم، ساختار شبکه عصبی عمیق LSTM مورد استفاده در واحد تصحیح توضیح داده شده و نهایتاً در قسمت چهارم و پنجم، نتایج این تحقیق ارائه می‌گردد.

۲-۲ مدل و ساختار سامانه پیشنهادی

سامانه پیشنهادی در این مقاله دارای سه قسمت اساسی بوده که شامل واحد IMU، واحد اندازه‌گیری و واحد تصحیح می‌باشد. در واحد IMU از سنسورهای اینرسی بر پایه MEMS استفاده شده است که شامل شتاب‌سنج، مغناطیس‌سنج وژیروسکوپ در هر محور می‌باشد. در واحد اندازه‌گیری، با اعمال معادلات ناوبری اینرسی و فیلتر کالمن بر روی داده‌های خروجی واحد IMU، زوایای وضعیت در سه محور محاسبه می‌شود و در قسمت تصحیح‌گر که شامل



شکل ۱: نمای کلی سامانه پیشنهادی

$$\begin{bmatrix} \psi \\ \theta \\ \phi \end{bmatrix} = \frac{1}{\cos\theta} \begin{bmatrix} \sin\phi & 0 & -\cos\phi \\ \cos\theta\cos\phi & 0 & \cos\theta\sin\phi \\ \sin\theta\sin\phi & 1 & \sin\theta\cos\phi \end{bmatrix} \begin{bmatrix} w_{nbx}^b \\ w_{nby}^b \\ w_{nbz}^b \end{bmatrix} \quad (1)$$

در این معادله Ψ, θ, ϕ به ترتیب نشان‌دهنده زوایای پیچ، رول و یاو بوده و $w_{nbx}^b, w_{nby}^b, w_{nbz}^b$ بیانگر سرعت زاویه‌ای در دستگاه بدنه و محورهای X, Y, Z می‌باشند که این مقادیر، داده‌های خروجی سنسور ژيروسکوپ می‌باشند.

با استفاده از معادله (۱)، مقادیر زوایای اویلر بدست آمده با مرور زمان دچار افزایش خطا می‌شوند که علت آن خطای سنسور ژيروسکوپ بوده که با انتگرال‌گیری از آن، خطای جمع‌شوندگی ایجاد می‌شود. در صورتی که خطای سنسور ژيروسکوپ مورد استفاده خیلی کم باشد، سامانه AHRS استفاده کننده از این سنسور می‌تواند تا مدت زمان محدودی، دقت مناسب داشته باشد ولی اصولاً سنسورهای ژيروسکوپ بر پایه MEMS دارای دقت کافی نبوده و دارای بایاس زیادی می‌باشند. لذا نیاز است برای این‌گونه از سنسورها، خطای آن‌ها مدل گردد و در طول زمان حذف شود.

اصولاً جهت مدل کردن خطای سنسورها از فیلتر کالمن استفاده می‌شود. در این مقاله نیز از فیلتر کالمن جهت مدل کردن خطای سنسورها استفاده شده و متغیرهای حالت استفاده شده در آن مطابق معادله‌های (۲) و (۳) تعریف شده است [۲۱ و ۲۲].

$$x_{\epsilon,k} = A_k x_{\epsilon,k-1} + w_k \quad (2)$$

$$x_{\epsilon,k} = \begin{bmatrix} \theta_{\epsilon,k} \\ b_{\epsilon,k} \\ a_{\epsilon,k}^b \\ d_{\epsilon,k}^b \end{bmatrix} = A_k \begin{bmatrix} \theta_{\epsilon,k-1} \\ b_{\epsilon,k-1} \\ a_{\epsilon,k-1}^b \\ d_{\epsilon,k-1}^b \end{bmatrix} + w_k \quad (3)$$

در این معادلات $\theta_{\epsilon,k}, b_{\epsilon,k}, a_{\epsilon,k}^b, d_{\epsilon,k}^b$ بردارهای 3×1 می‌باشند که به ترتیب نشانگر خطای زوایای وضعیت تخمین زده شده، بایاس سنسورهای ژيروسکوپ، خطای سنسورهای شتاب‌سنج خطی در دستگاه بدنه و خطای اغتشاشات میدان مغناطیس سنسور مغناطیس‌سنج در دستگاه بدنه می‌باشند. همچنین w_k بردار 1×12 می‌باشد که بیانگر نویز فرآیند می‌باشد.

جدول ۱: مشخصات فنی سنسور مورد استفاده [۱۹]

مقدار	مشخصه	
$450^\circ/sec$	محدوده اندازه‌گیری	ژيروسکوپ
$20^\circ/h$	In-Run Bias Stability	
$3^\circ/\sqrt{h}$	Angular Random Walk	
$54^\circ/\sqrt{h^3}$	Rate Random Walk	
$0.16^\circ/sec$	نویز خروجی	شتاب‌سنج
$18g$	محدوده اندازه‌گیری	
$0.1mg$	In-Run Bias Stability	
$0.029m/sec/\sqrt{h}$	Velocity Random Walk	
$1/5mg$	نویز خروجی	مغناطیس‌سنج
$2/5Gauss$	محدوده اندازه‌گیری	
$0/45mGauss$	نویز خروجی	

۲-۲- واحد اندازه‌گیری

استفاده از سامانه AHRS بر پایه سنسورهای MEMS جهت بدست آوردن زوایای وضعیت در هواپیماهای بدون سرنشین بسیار مورد توجه قرار گرفته است. با توجه به دقت نبودن سنسورهای MEMS، خطای سامانه AHRS مناسب نمی‌باشد که علت آن انتگرال‌گیری از این سنسورها و خطای جمع‌شوندگی با گذشت زمان می‌باشد. برای رفع این مشکل غالباً از فیلترهای تخمینگر همچون فیلتر کالمن جهت مدل کردن خطای این سنسورها استفاده می‌شود.

واحد اندازه‌گیری سیستم مورد مطالعه شامل دو قسمت می‌باشد که در قسمت اول بر پایه معادلات ناوبری، زوایای وضعیت محاسبه می‌شود و در قسمت دوم با استفاده از فیلتر کالمن و مدل کردن خطای این سنسورها، خطای این زوایا مرتفع می‌گردد.

جهت بدست آوردن زوایای وضعیت، سه روش وجود دارد که شامل زوایای اویلر، کواترنیون و ماتریس کسینوس‌ها بوده که هر کدام از این روش‌ها دارای مزایا و معایب خاص خود می‌باشند [۲۰]. در این مقاله از زوایای اویلر جهت بدست آوردن زوایای وضعیت استفاده شده است که بر اساس معادله شماره (۱)، زوایای اویلر که شامل زوایای رول^۱، پیچ^۲ و یاو^۳ می‌باشد با مقادیر سرعت زاویه‌ای ژيروسکوپ قابل محاسبه می‌باشند.


^۳Yaw

^۱Roll
^۲Pitch

با توجه به معادلات فیلتر کالمن بیان شده، می‌توان از خطای انباشتگی سامانه AHRS جلوگیری کرد. زوایای وضعیت خروجی واحد اندازه‌گیری در مقایسه با سامانه دقیق GPS/INS^۱ بر پایه سنسور FOG در شکل (۲) نشان داده شده است. همانگونه که مشاهده می‌شود، خروجی این واحد دارای نویز بیشتری نسبت به داده‌های مرجع بوده که علت آن نویز سنسورهای IMU آن می‌باشد و همچنین مقادیر زوایای وضعیت آن در گردش‌های^۲ هواپیما دچار عقب ماندگی و خطا می‌باشد.

همچنین در این مقاله فرایند اندازه‌گیری $Z_{\varepsilon,k}^b$ مطابق معادله (۴) به صورت یک بردار 6×1 بیان می‌شود که در آن $g_{a,k}^b$ و $g_{g,k}^b$ بردارهای 3×1 بوده که به ترتیب نشان‌دهنده نیروی جاذبه زمین محاسبه شده در دستگاه بدنه از سنسورهای ژيروسکوپ و شتاب سنج می‌باشد و $m_{g,k}^b$ و $m_{m,k}^b$ نیز بردارهای 3×1 بیانگر بردار جاذبه زمین محاسبه شده در دستگاه بدنه از سنسورهای مغناطیس سنج و ژيروسکوپ می‌باشند.

$$Z_{\varepsilon,k}^b = \begin{bmatrix} g_{a,k}^b - g_{g,k}^b \\ m_{m,k}^b - m_{g,k}^b \end{bmatrix} \quad (۴)$$



شکل ۲: خروجی واحد اندازه‌گیری در مقایسه با مرجع الف) زاویه رول ب) زاویه پیچ

دیگر، این خطاها باید به صورت زمانی و در زمان مدل شوند. در صورتی که با استفاده از شبکه‌های عصبی تنها می‌تواند پدیده‌های ساده را مدل نمود و سیستم‌های پیچیده باید توسط شبکه‌های عصبی عمیق مدل شوند [۲۳]. همچنین فیلترهایی از قبیل فیلتر کالمن و یا فیلتر ذره‌ای دارای محدودیت‌هایی می‌باشند که باعث ایجاد خطاهای محاسباتی می‌گردند. به عنوان مثال، فیلتر کالمن مرسوم یک فیلتر خطی می‌باشد و نمی‌تواند منابع خطای غیرخطی را مدل کند. فیلترهای دیگری همچون EKF^۳ و UKF^۴ نیز به منظور رفع این محدودیت با فرضیات ثابت خود دچار مشکلاتی می‌باشند [۲۴].

۲-۳- واحد تصحیح

وظیفه واحد تصحیح استفاده شده در سامانه پیشنهادی، تصحیح بهره فیلتر کالمن می‌باشد به نحوی که این فیلتر بتواند زوایای وضعیت را اصلاح کند. استفاده از شبکه‌های عصبی جهت مدل‌سازی خطا و تصحیح آن بسیار کاربرد دارد. به نحوی که این شبکه‌ها با استفاده از اطلاعات معتبر، آموزش دیده و سپس با استفاده از شبکه آموزش دیده می‌تواند رفتار سیستم را شبیه‌سازی نماید. استفاده از این شبکه‌ها جهت مدل‌سازی خطای سنسورهای IMU و زوایای وضعیت، دقت کافی ندارد که علت آن بررسی نشدن وابستگی زمانی و حافظه‌دار نبودن آن می‌باشد. به عبارت

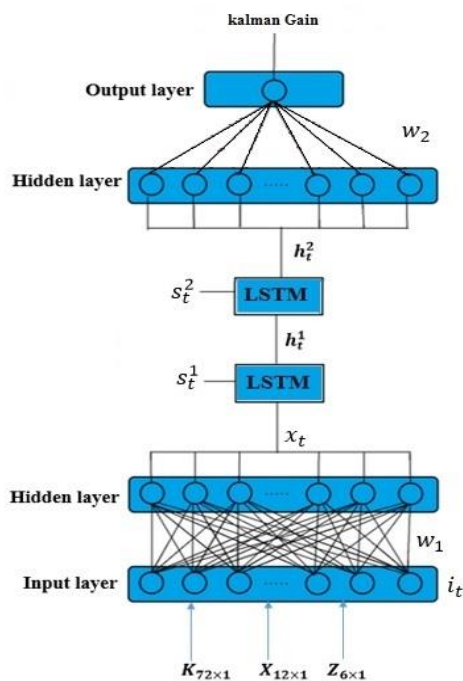
^۳ Extended Kalman Filter

^۴ Unscented Kalman Filter

^۱ Global Positioning System/Inertial Navigation System

^۲ Loitering

داده‌های ورودی در زمان t می‌باشد و همچنین w_1 و b_x به ترتیب ماتریس وزن و بایاس از لایه ورودی به لایه مخفی می‌باشند. پس از استخراج ویژگی‌های x_t ، از دو لایه شبکه عصبی عمیق بازگشتی LSTM استفاده شده است که علت آن عملکرد بهتر دو لایه شبکه عصبی LSTM نسبت به یک و سه لایه در آزمایشات می‌باشد که نتایج آن در جدول ۳ آمده است.



شکل ۳: ساختار شبکه عصبی عمیق پیشنهادی

هر شبکه عصبی عمیق LSTM دارای ۴ لایه می‌باشد که تشکیل یک واحد حافظه را می‌دهند. این واحد حافظه شامل یک دروازه ورودی^۲ و یک دروازه خروجی^۳ می‌باشد که سرعت ورود و خروج داده‌های این واحد را کنترل می‌کند. دروازه مهم دیگری که در این واحد وجود دارد، دروازه فراموشی^۴ می‌باشد که وظیفه آن فراموش کردن و یا تنظیم مجدد^۵ سلول حافظه می‌باشد. طبق این تعاریف و معادلات شبکه LSTM، s_t^1 و s_t^2 ، توسط معادلات زیر به c_t و h_t وابستگی دارند [۲۸].

$$h_t^1 = \sigma(w_0^1[h_{t-1}^1, x_t] + b_0^1) \otimes \tanh(c_t^1) \quad (6)$$

$$h_t^2 = \sigma(w_0^2[h_{t-1}^2, h_t^1] + b_0^2) \otimes \tanh(c_t^2) \quad (7)$$

باتوجه به اینکه معادلات دینامیکی هواپیما بسیار پیچیده و غیرخطی می‌باشند لذا نیاز است تا از شبکه‌های عصبی عمیق برای مدل کردن رفتارها استفاده نمود. شبکه‌های عصبی عمیق دارای انواع مختلف بوده که هر کدام دارای ویژگی‌های خاص خود می‌باشند [۲۶ و ۲۵]. شبکه‌های عصبی بازگشتی یکی از انواع شبکه‌های عصبی عمیق می‌باشد که ساختاری متفاوتی نسبت به سایر شبکه‌های موجود دارد. آموزش این شبکه‌ها توسط حلقه‌های بازگشتی انجام می‌گیرد. این شبکه‌ها با داشتن حافظه کوتاه مدت در درون خود، از اطلاعات ورودی قبلی نیز برای داده‌های جدید استفاده می‌کنند. لذا این شبکه‌ها برای داده‌های دنباله‌دار و زمان‌دار مناسب می‌باشند. یکی از مدل‌های پرمشهور در یادگیری عمیق در داده‌های زمان‌دار، مدل LSTM می‌باشد. این شبکه نوع خاصی از شبکه‌های بازگشتی می‌باشد که از توابع پیچیده‌تری نسبت به شبکه‌های بازگشتی استفاده می‌کند که این امر باعث شده قابلیت تنظیم حافظه را داشته باشد و مشکل وابستگی بلند مدت در داده‌ها را برطرف کند [۲۷].

۳- شبکه عصبی عمیق LSTM پیشنهادی

با توجه به دلایل بیان شده در قسمت قبل، در این مقاله از شبکه عصبی عمیق LSTM جهت مدلسازی خطای سنسورها و زوایای وضعیت استفاده شده که دارای ساختار شکل (۳) و پارامترهای ساختار انتخابی اشاره شده در جدول ۲ می‌باشد. در این ساختار i_t نشان‌دهنده داده‌های ورودی سیستم بوده که شامل $x_{12 \times 1}$ ، $z_{6 \times 1}$ و $K_{72 \times 1}$ می‌باشد. مقادیر این داده‌ها که به ترتیب نشان‌دهنده متغیرهای حالت، ماتریس اندازه‌گیری و بهره فیلتر کالمن می‌باشد، در قسمت ۲-۲ بیان شده است. لازم به ذکر است ماتریس $K_{72 \times 1}$ یک ماتریس 6×12 می‌باشد که با بردارسازی^۱، به یک ماتریس خطی 72 ستونی تبدیل شده است و ورودی i_t یک ماتریس سطری 90 ستونه در زمان t می‌باشد.

$$x_t = w_1 \times i_t + b_x \quad (8)$$

در این معادله x_t نشانگر بردار لایه مخفی شبکه پیشنهادی می‌باشد که وظیفه آن استخراج مشخصه‌ها و ویژگی‌ها از

⁴ Forget gate

⁵ Reset

¹ Vectorization

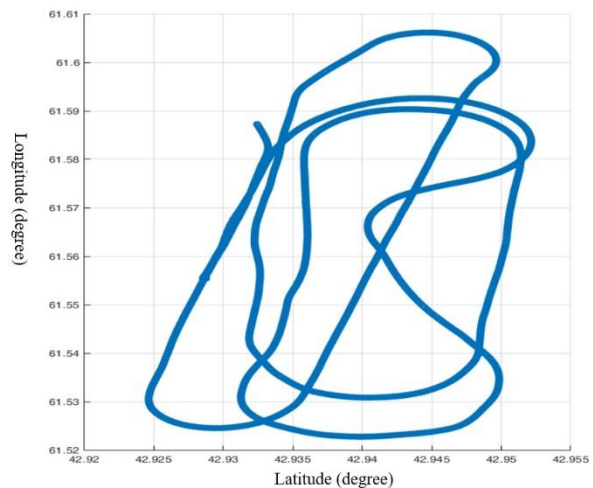

² Input gate

³ Output gate

خطی، سرعت دورانی و مغناطیس زمین بوده که خروجی یک سنسور IMU بر پایه تکنولوژی MEMS می‌باشد و همچنین به منظور مقایسه و آموزش شبکه عصبی از زوایای وضعیت یک سامانه دقیق GPS/INS با دقت ۰/۵ درجه نیز استفاده شده است. در ابتدای امر با استفاده از داده‌های دو پرواز که هر کدام از آن‌ها در حدود ۸ ساعت پرواز و ۳,۰۰۰,۰۰۰ نمونه می‌باشد، شبکه عصبی عمیق LSTM بیان شده در قسمت ۲-۳ آموزش داده می‌شود.

جدول ۲: پارامترهای ساختار شبکه انتخابی

مقدار	مشخصه
sigmoid	تابع فعال
۲۰۰	تعداد نورون
۰/۱	نرخ یادگیری
۱۰۰	بیشترین تعداد دوره ^۳
۵۰	اندازه هر دسته ^۴



شکل ۴: مسیر پروازی و ارتفاع جسم پرنده در داده‌های آموزش

جدول ۳: نتایج شبیه‌سازی ساختارهای مختلف شبکه عصبی انتخابی

تابع فعال	تعداد لایه مخفی	تعداد نورون هر لایه	نرخ یادگیری	بهبود خطای آموزش (زاویه پیچ (%))	بهبود خطای آزمایش (زاویه رول (%))	بهبود خطای کل (آزمایش کل (%))
Linear	۱	۱۵۰	۰/۰۵	۳۲/۸۹	۳۴/۱۲	۳۳/۵۰
Sigmoid	۱	۱۵۰	۰/۰۵	۳۳/۸۷	۳۶/۱۸	۳۵/۰۳
Linear	۲	۱۵۰	۰/۰۵	۳۲/۹۲	۳۴/۱۵	۳۳/۵۳
Sigmoid	۲	۱۵۰	۰/۰۵	۳۳/۹۰	۳۶/۲۴	۳۵/۰۷
Linear	۳	۱۵۰	۰/۰۵	۳۲/۹۱	۳۴/۱۴	۳۳/۵۲
Sigmoid	۳	۱۵۰	۰/۰۵	۳۳/۸۹	۳۶/۲۰	۳۵/۰۵
Linear	۱	۲۰۰	۰/۰۵	۳۲/۹۱	۳۴/۱۴	۳۳/۵۲
Sigmoid	۱	۲۰۰	۰/۰۵	۳۳/۸۹	۳۶/۲۰	۳۵/۰۵

در این معادلات h_t^1 خروجی LSTM لایه اول و ورودی لایه دوم می‌باشد و همچنین h_t^2 خروجی لایه دوم می‌باشد که اندازه آن با بردار x_t برابر می‌باشد. در نهایت، خروجی شبکه پیشنهادی به صورت زیر بیان می‌گردد.

$$kalmanGain = w_2 h_t^2 + b_s \quad (۸)$$

جهت دستیابی به عملکرد بهتر واحد تصحیح بیان شده، ساختارهای متفاوتی با تغییر تعداد نورون‌های لایه‌های مخفی، توابع فعال^۱ و نرخ یادگیری^۲ مورد بررسی قرار گرفته و بهترین ساختار استفاده شده است. پارامترهای ساختار انتخابی در این واحد در جدول ۲ آمده است.

۴- شبیه‌سازی و نتایج آزمایشات

جهت ارزیابی سامانه AHRS پیشنهادی، از داده‌های پروازی واقعی استفاده شده است. این داده‌ها که با نرخ بروز ۵۰ هر تیز مورد استفاده قرار گرفته است، شامل شتاب

³ Maximum number of epochs

⁴ Batch size

¹ Activation functions

² Learning rate


۳۳/۷۳	۳۴/۳۵	۳۳/۱۱	-/۰.۵	۲۰۰	۲	Linear
۳۵/۲۷	۳۶/۴۵	۳۴/۱۰	-/۰.۵	۲۰۰	۲	Sigmoid
۳۳/۶۳	۳۴/۲۵	۳۳/۰.۱	-/۰.۵	۲۰۰	۳	Linear
۳۵/۱۶	۳۶/۳۲	۳۴/۰.۰	-/۰.۵	۲۰۰	۳	Sigmoid
۳۳/۶۳	۳۴/۲۵	۳۳/۰.۱	-/۰.۵	۲۵۰	۱	Linear
۳۵/۱۶	۳۶/۳۲	۳۴/۰.۰	-/۰.۵	۲۵۰	۱	Sigmoid
۳۳/۷۳	۳۴/۳۵	۳۳/۱۱	-/۰.۵	۲۵۰	۲	Linear
۳۵/۲۷	۳۶/۴۵	۳۴/۱۰	-/۰.۵	۲۵۰	۲	Sigmoid
۳۳/۷۳	۳۴/۳۵	۳۳/۱۱	-/۰.۵	۲۵۰	۳	Linear
۳۵/۲۶	۳۶/۴۳	۳۴/۱۰	-/۰.۵	۲۵۰	۳	Sigmoid
۳۳/۶۳	۳۴/۲۵	۳۳/۰.۱	۰/۱	۱۵۰	۱	Linear
۳۵/۱۶	۳۶/۳۲	۳۴/۰.۰	۰/۱	۱۵۰	۱	Sigmoid
۳۳/۶۳	۳۴/۲۵	۳۳/۰.۱	۰/۱	۱۵۰	۲	Linear
۳۵/۱۷	۳۶/۳۴	۳۴/۰.۰	۰/۱	۱۵۰	۲	Sigmoid
۳۳/۵۳	۳۴/۱۵	۳۲/۹۲	۰/۱	۱۵۰	۳	Linear
۳۵/۰.۶	۳۶/۲۲	۳۰/۹۰	۰/۱	۱۵۰	۳	Sigmoid
۳۳/۸۲	۳۴/۴۴	۳۳/۲۰	۰/۱	۲۰۰	۱	Linear
۳۵/۳۶	۳۶/۵۲	۳۴/۱۹	۰/۱	۲۰۰	۱	Sigmoid
۳۳/۸۴	۳۴/۴۶	۳۳/۲۲	۰/۱	۲۰۰	۲	Linear
۳۵/۳۹	۳۶/۵۷	۳۴/۲۱	۰/۱	۲۰۰	۲	Sigmoid
۳۳/۸۴	۳۴/۴۶	۳۳/۲۲	۰/۱	۲۰۰	۳	Linear
۳۵/۳۸	۳۶/۵۴	۳۴/۲۱	۰/۱	۲۰۰	۳	Sigmoid
۳۳/۸۱	۳۴/۴۳	۳۳/۱۹	۰/۱	۲۵۰	۱	Linear
۳۵/۳۵	۳۶/۵۱	۳۴/۱۸	۰/۱	۲۵۰	۱	Sigmoid
۳۳/۸۲	۳۴/۴۴	۳۳/۲۰	۰/۱	۲۵۰	۲	Linear
۳۵/۳۷	۳۶/۵۵	۳۴/۱۹	۰/۱	۲۵۰	۲	Sigmoid
۳۳/۸۲	۳۴/۴۴	۳۳/۲۰	۰/۱	۲۵۰	۳	Linear
۳۵/۳۶	۳۶/۵۲	۳۴/۱۹	۰/۱	۲۵۰	۳	Sigmoid
۳۳/۵۳	۳۴/۱۵	۳۲/۹۲	-/۱.۵	۱۵۰	۱	Linear
۳۵/۰.۶	۳۶/۲۲	۳۳/۹۰	-/۱.۵	۱۵۰	۱	Sigmoid
۳۳/۵۳	۳۴/۱۵	۳۲/۹۲	-/۱.۵	۱۵۰	۲	Linear
۳۵/۰.۷	۳۶/۲۴	۳۳/۹۰	-/۱.۵	۱۵۰	۲	Sigmoid
۳۳/۵۳	۳۴/۱۵	۳۲/۹۲	-/۱.۵	۱۵۰	۳	Linear
۳۵/۰.۶	۳۶/۲۲	۳۳/۹۰	-/۱.۵	۱۵۰	۳	Sigmoid
۳۳/۶۳	۳۴/۲۵	۳۳/۰.۱	-/۱.۵	۲۰۰	۱	Linear
۳۵/۱۶	۳۶/۳۲	۳۴/۰.۰	-/۱.۵	۲۰۰	۱	Sigmoid
۳۳/۶۳	۳۴/۲۵	۳۳/۰.۱	-/۱.۵	۲۰۰	۲	Linear
۳۵/۱۷	۳۴/۳۶	۳۴/۰.۰	-/۱.۵	۲۰۰	۲	Sigmoid
۳۳/۶۳	۳۴/۲۵	۳۳/۰.۱	-/۱.۵	۲۰۰	۳	Linear
۳۵/۱۶	۳۶/۳۲	۳۴/۰.۰	-/۱.۵	۲۰۰	۳	Sigmoid
۳۳/۶۱	۳۴/۲۳	۳۲/۹۹	-/۱.۵	۲۵۰	۱	Linear
۳۵/۱۴	۳۶/۳۰	۳۳/۹۸	-/۱.۵	۲۵۰	۱	Sigmoid
۳۳/۶۱	۳۴/۲۳	۳۲/۹۹	-/۱.۵	۲۵۰	۲	Linear
۳۵/۱۵	۳۶/۳۲	۳۳/۹۸	-/۱.۵	۲۵۰	۲	Sigmoid
۳۳/۶۱	۳۴/۲۳	۳۲/۹۹	-/۱.۵	۲۵۰	۳	Linear
۳۵/۱۴	۳۶/۳۰	۳۳/۹۸	-/۱.۵	۲۵۰	۳	Sigmoid

گردید و در ادامه مورد بررسی قرار میگیرد. یکی از ایرادات این نوع سامانه‌ها، خطای اندازه‌گیری زاویه وضعیت آن‌ها بوده که علت آن استفاده از شتاب‌سنج و ژایروسکوپ‌های با دقت پایین می‌باشد. در زمانی که جسم پرنده در مسیر مستقیم حرکت می‌کند استفاده از شتاب‌سنج در بدست آوردن زوایای وضعیت، مناسب‌تر می‌باشد زیرا ژایروسکوپ‌ها با گذر زمان دچار بایاس شده و باعث ایجاد خطا در خروجی می‌شوند. این موضوع در شکل (۶) که قسمتی از پرواز جسم پرنده در حالت کروز می‌باشد قابل مشاهده است. همانگونه که مشاهده می‌شود به علت خطای بایاس ژایروسکوپ، خروجی زوایای رول و پیچ دچار خطای جمع‌شوندگی شده و خطای آن با گذشت زمان افزایش یافته است ولی الگوریتم پیشنهادی توانسته با این خطا مقابله کند. از طرف دیگر در زمانی که جسم پرنده در حال دور زدن و چرخش به سمت راست و چپ می‌باشد، شتاب جانب مرکز وارد شده به آن باعث ایجاد خطا در شتاب‌سنج‌ها شده و متعاقب آن خطا در زوایای وضعیت می‌شود. این موضوع نیز در شکل (۷) به صورت آشکار قابل مشاهده می‌باشد. همانگونه که مشاهده می‌شود این اختلاف زاویه در حدود ۱۰ درجه می‌باشد که این مقدار خطا برای سیستم‌های کنترل جسم پرنده بسیار خطرناک می‌باشد.

جهت یادگیری بهتر شبکه عصبی سعی بر آن شده تا داده‌های پروازی استفاده شده شامل فازهای مختلف پروازی مانند کروز^۱، افزایش ارتفاع^۲، کاهش ارتفاع^۳، گردش به طرفین و غیره باشد. در شکل (۴)، مسیر پروازی یکی از داده‌های پروازی نشان داده شد که بیانگر مانورپذیری و تغییرات زیاد داده‌های مورد استفاده می‌باشد.

به منظور ارزیابی الگوریتم پیشنهادی، داده‌های مربوط به پرواز متفاوتی از داده‌های آموزش مورد استفاده قرار گرفته است. این داده‌ها شامل ۱،۵۰۰،۰۰۰ نمونه و ۹ ساعت پرواز بوده که شامل تمامی فازهای مختلف پروازی می‌باشد. جهت مقایسه زوایای وضعیت به دست آمده از الگوریتم پیشنهادی و داده‌های مرجع از معیار خطای میانگین مربعات^۴ استفاده شده است. در شکل (۵) خروجی زوایای وضعیت رول و پیچ سامانه پیشنهادی را در مقایسه با سیستم AHRS با فیلتر کالمن نشان می‌دهد که در هر دو این سیستم‌ها از سنسور IMU بر پایه MEMS استفاده شده و همچنین خروجی زوایای وضعیت سامانه GPS/INS بر پایه FOG به منظور مقایسه نشان داده شده است.

همانگونه که بیان شد سامانه AHRS بر پایه MEMS و فیلتر کالمن دارای دو عیب در محاسبه زوایای وضعیت می‌باشد که هر دوی این معایب در این آزمایش نیز مشاهده




شکل ۵: خروجی سامانه پیشنهادی در مقایسه با فیلتر کالمن و سنسور مرجع (الف) زاویه رول (ب) زاویه پیچ

³ Descent


⁴ Root Mean Square Error (RMSE)

¹ Cruise

² Climb




شکل ۶: خروجی سامانه پیشنهادی در مقایسه با فیلتر کالمن و سنسور مرجع در فاز کروز (الف) زاویه رول (ب) زاویه پیچ



شکل ۷: خروجی سامانه پیشنهادی در مقایسه با فیلتر کالمن و سنسور مرجع در فاز لویتر (الف) زاویه رول (ب) زاویه پیچ

نویز بالای خروجی سامانه AHRS بر پایه MEMS و فیلتر کالمن بوده که علت آن نویز بالای سنسورهای ژيروسکوپ استفاده شده در این سامانه می باشد. در قسمت ۲-۱ مقادیر نویزهای سطح بالا و پایین و بایاس سنسور ژيروسکوپ مورد استفاده در این آزمایش، که با استفاده از روش Allan Variance محاسبه شده، بیان گردید. در این روش، داده های خروجی سنسور به n قسمت مساوی با طول t

همانگونه که مشاهده شد، سامانه پیشنهادی در این مقاله، با این دو پدیده که در اکثر زمانها اتفاق افتاده است مقابله کرده و خطای زوایای وضعیت رول و پیچ را در حدود ۳۵ درصد بهبود بخشیده است و توانسته با سنسورهای IMU بر پایه MEMS، به سامانه AHRS نسبتا دقیقی دست یابد. عیب دیگری که در این مقاله مورد بررسی قرار گرفته است،



شکل ۸: محاسبه نویزهای سنسور با روش آلن واریانس

ببخشد تا بتوان از مقادیر آن جهت کنترل جسم پرنده استفاده کرد. در جدول ۴ مقادیر نویزهای هر سه سامانه مورد آزمایش نشان داده شده که بیانگر بهبود این مقادیر توسط سامانه پیشنهادی به میزان ۴۰ درصد می‌باشد.


جدول ۴: مقایسه نویز سامانه پیشنهادی در یک محور

الگوریتم پیشنهادی	فیلتر کالمن	IMU	Parameters
۱۲	۱۴	۲۰	In-Run Bias Stability ($^{\circ}/h$)
۱/۹	۲/۶۵	۳	Angular Random Walk ($^{\circ}/\sqrt{h}$)
۳۵	۴۹	۵۴	Rate Random Walk ($^{\circ}/\sqrt{h^3}$)


تقسیم شده و میانگین هر بخش (a) گرفته خواهد شد و بر اساس معادله (۹) نمودار آن در مقیاس log-log رسم می‌شود و مطابق شکل (۸) مقادیر نویز مورد نیاز محاسبه می‌گردد [۲۹].

$$AVAR(t) = \frac{1}{2 \times (n-1)} \sum_i (a(t)_{i+1} - a(t)_i)^2 \quad (9)$$

همانگونه که در شکل (۹)، که بیانگر آزمایش Allan Variance سامانه پیشنهادی در مقایسه با سنسور ژيروسکوپ می‌باشد، مشاهده می‌شود سامانه پیشنهادی در این مقاله توانسته با کاهش میزان نویز سنسورهای ژيروسکوپ، علاوه بر بدست آوردن زوایای وضعیت با دقت مناسب، دقت سرعت زاویه خروجی این سامانه را نیز بهبود



(ب)



(الف)

شکل ۹: خروجی آزمایش Allan Variance در یک محور (الف) سامانه پیشنهادی (ب) سنسور IMU

مرجع، آموزش داده شده است. شبکه عصبی پیشنهادی به عنوان یک تصحیح‌گر عمل کرده و بر اساس داده‌های ورودی، بهره فیلتر کالمن استفاده شده در سامانه AHRS را تصحیح می‌کند. بهره فیلتر کالمن تصحیح شده توسط شبکه عصبی پیشنهادی، باعث می‌شود علاوه بر این که زوایای وضعیت خروجی این سامانه بهبود بخشیده شود، نویز خروجی ژيروسکوپ و همچنین زوایای وضعیت منتج از آن نیز در حدود ۴۰ درصد کاهش یابد. به منظور ارزیابی سامانه پیشنهادی، از داده‌های پروازی متفاوت از داده‌های آموزش استفاده شده و خروجی آن با داده‌های سامانه GPS/INS بر پایه سنسور FOG مقایسه گردیده است. نتایج نشان می‌دهد که سامانه پیشنهادی توانسته دقت زوایای وضعیت خروجی را در حدود ۳۵ درصد افزایش دهد.

۴- نتیجه‌گیری

امروزه استفاده از سنسورهای IMU با تکنولوژی MEMS جهت بدست آوردن زوایای وضعیت به علت ابعاد، حجم و قیمت پایین این سنسورها بسیار مورد توجه قرار گرفته است. یکی از روش‌های استفاده شده جهت بهبود دقت این سامانه‌ها، استفاده از فیلتر کالمن جهت مدل‌سازی خطای این سنسورها و حذف آن می‌باشد. در این مقاله با استفاده از شبکه عصبی عمیق LSTM، عملکرد فیلتر کالمن مورد استفاده در سامانه AHRS و در نتیجه دقت زوایای وضعیت خروجی آن سامانه مورد تحقیق قرار گرفته است. ورودی این شبکه عصبی، متغیرهای حالت، ماتریس اندازه‌گیری و بهره فیلتر کالمن می‌باشد که با استفاده از داده‌های دو پرواز و خروجی سامانه GPS/INS بر پایه سنسور FOG به عنوان

مراجع

- [1] Z. Liu and Y. Wang, "Implementation and Evaluation of Attitude Heading and Reference System Based on MEMS", Control and Decision Conference (CCDC), Chinese, 2020, pp. 5404-5408.
- [2] J. Hidalgo-Carrió, S. Arnold and P. Poulakis, "On the Design of Attitude-Heading Reference Systems Using the Allan Variance", IEEE Transactions On Ultrasonic, Ferroelectrics, and Frequency Control, Vol.63, No.4, 2016, pp.656-665.
- [3] Q.Fangjun, Ch.Lubin, S.Feng, "A Sequential Multiplicative Extended Kalman Filter for Attitude Estimation Using Vector Observations", Sensors, Vol.18, 2018,pp.1414.
- [4] J.Crassidis, F.Markley, Y. Cheng, "Survey of Nonlinear Attitude Estimation", Guidance Control and Dynamic, Vol.30, 2007, pp.12-28.
- [5] M.Grewal, L.Weill and A. Andrews, Global positioning systems, inertial navigation, and integration, 2nd ed., Wiley, 2007.
- [6] G.Araghi, R.Landry, "Temperature compensation model of MEMS inertial sensors based on neural network", IEEE/ION Position, Location and Navigation Symposium (PLANS), Monterey(USA), 2018, pp. 301-309.
- [7] J.Shiau, C.Huang and M.Chang, "Noise Characteristics of MEMS Gyro's Null Drift and Temperature Compensation", Journal of Applied Science and engineering, vol.15, 2012, pp. 239-246.
- [8] R.Song, X.Chen, "Error estimation of airborne Strap down Inertial Navigation System based on neural network", IEEE International Workshop on Metrology for AeroSpace (MetroAeroSpace), Padua, 2017, pp. 201-205.
- [9] A.Noureldin, A.ElShafie, M.Bayoumi, "GPS/INS Integration Utilizing Dynamic Neural Networks for Vehicular Navigation", Information Fusion, Vol.12, 2011, pp.48-57.
- [10] L.Zhang, J.Liu and Z.Xiong, "Performance Analysis of Adaptive Neuro Fuzzy Inference System Control for MEMS Navigation System", Math. Probl. Eng., Vol.14, 2014, pp. 96-102.
- [11] C.Toth, D.A.Grejner-Brzezinska and S.Moafipoor, "Pedestrian Tracking and Navigation Using Neural Networks and Fuzzy Logic", IEEE International Symposium on Intelligent Signal Processing, Alcalá de Henares, Spain, 2007, pp. 1-6.
- [12] S.Hosseinyalamdary, "Deep Kalman Filter: Simultaneous Multi-Sensor Integration and Modelling; A GNSS/IMU Case Study", sensors, Vol.18, 2018, pp.1316.
- [13] J.Liu and G.Guo, "Vehicle Localization during GPS Outages with Extended Kalman Filter and Deep Learning", IEEE Transactions on Instrumentation and Measurement, Vol.70, 2021, pp.1-10.

- [14] C. Chen, C. X. Lu, J. Wahlström, A. Markham and N. Trigoni, "Deep Neural Network Based Inertial Odometry Using Low-Cost Inertial Measurement Units", *IEEE Transactions on Mobile Computing*, Vol.20, 2021, pp.1351-1364.
- [15] Y. Liu, Q. Luo and Y. Zhou, "Deep Learning-enabled Fusion to Bridge GPS Outages for INS/GPS Integrated Navigation", *IEEE Sensors*, Vol.10, 2022, pp.1-12.
- [16] Fa.Ciaccio, P. Russo and S. Troisi, "DOES: A Deep Learning-Based Approach to Estimate Roll and Pitch at Sea", *IEEE access*, Vol.10, 2022, pp.29307 – 29321.
- [17] A.Angrisano, "GNSS/INS integration methods", PhD Thesis in Science Geodetics and Topographic, Messina university, 2010, Naple.
- [18] B.Ristic, S. Arulampalam and N. Gordon, "Beyond the Kalman filter", *IEEE Aerospace and Electronic Systems Magazine*, Vol.19, 2004, pp.37- 38.
- [19] <https://www.analog.com/en/adis16448/datasheet.html>
- [20] B.Lim, S.Zohren and S.Roberts, "Recurrent Neural Filters: Learning Independent Bayesian Filtering Steps for Time Series Prediction", *International Joint Conference on Neural Networks (IJCNN)*, 2019, pp.1-7.
- [۲۱] ن.عزتی، ح.طاهری، "سنجش طیف توزیع شده با تهیه نقشه های جغرافیائی رادیوئی در شبکه های رادیوشناختی"، *مدلسازی در مهندسی*، دوره ۱۷، شماره ۵۶، ۱۳۹۸، صفحه ۲۲۳-۲۳۳.
- [22] K.Chandrasekaran, G.vijay, "Pitch and Roll angle estimation using partial DCM model approach for a high performance aircraft", *Control Conference Hyderabad, India*, 2016, pp.140-149.
- [23] R.Mahony, T. Hamel and J. Pflimlin, "Nonlinear Complementary Filters on the Special Orthogonal Group", *IEEE Transactions on Automatic Control*, vol. 53, no. 5, 2008, pp. 1203-1218.
- [24] M.brossard, A.silvère, "Denoising IMU Gyroscopes with Deep Learning for Open-Loop Attitude Estimation", *IEEE Robotics and Automation*, Vol.PP, 2020, pp.1-8.
- [25] M. K. Al-Sharman, Y. Zweiri, M.Jaradat, R. Al-Husari, D. Gan and L. D. Seneviratne, "Deep-Learning-Based Neural Network Training for State Estimation Enhancement: Application to Attitude Estimation", *IEEE Transactions on Instrumentation and Measurement*, vol.69, no.1, 2020, pp. 24-34.
- [۲۶] ر.راستگو، ک.کیانی، "شناسایی چهره با استفاده از تنظیم دقیق شبکه های کانولوشنی عمیق و رویکرد یادگیری انتقالی"، *مدلسازی در مهندسی*، دوره ۱۷، شماره ۵۸، ۱۳۹۸، صفحه ۱۰۳-۱۱۱.
- [27] N.El-Sheimy, A.Youssef, "Inertial sensors technologies for navigation applications: state of the art and future trends", *SatellNavig*, Vol.1, 2020, pp.1-7.
- [۲۸] م.معلم، ع.پویان، "کشف ناهنجاری با استفاده از کد کننده خودکار مبتنی بر بلوکهای LSTM"، *مدلسازی در مهندسی*، دوره ۱۷، شماره ۵۶، ۱۳۹۸، صفحه ۱۹۱-۲۱۱.
- [29] I. Board, "IEEE standard specification format guide and test procedure for single-axis interferometric fiber optic gyros", *IEEE Std*, 1998, pp. 952-1997.