

بهبود دقت سامانه مکان یاب تفاضلی با استفاده از پیشگویی فاکتورهای خطای مختصات مکان مرجع

محمد حسین رفان^{۱*}، عادل دمشقی^۲ و مهرنوش کمرزین^۳

۱ و ۲- دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت دبیر شهید رجایی

۳- دانشکده مهندسی برق و کامپیوتر، دانشگاه شهید بهشتی

* تهران، لویزان، کدپستی: ۱۶۷۸۸۱۵۸۱۱

refan@srttu.edu

سامانه مکان یاب تفاضلی برای تعیین موقعیت دقیق نیازمند پیشگویی تصحیحات تفاضلی برای زمان های آینده است. این سامانه از دو ایستگاه ثابت و متحرک تشکیل شده است. اگر ماهواره های دو ایستگاه دقیقاً یکسان باشند، منابع خطا در دو ایستگاه تقریباً نزدیک به هم خواهد بود، در این حالت فاکتورهای مختصات مکان مرجع برای جبران خطای مکان یابی ایستگاه کاربر به عنوان فاکتورهای تصحیح شده قابل استفاده است. در این مقاله، از الگوریتم های شبکه عصبی تکاملی، ماشین بردار پشتیبان، خودرگرسیو میانگین متحرک و شبکه عصبی بازگشتی برای پیشگویی تصحیحات استفاده شده است، به منظور آزمایش الگوریتم ها از نمونه برداری ایستا و متحرک داده های موقعیت یک گیرنده ارزان قیمت استفاده شد و تصحیحات خطای مختصات مکان مرجع با یک گام رو به جلو پیشگویی شده و در نقطه ای دیگر اعمال شد. مدل پیشگویی شبکه عصبی تکاملی نسبت به سایر مدل ها دقت بیشتری داشته و خطای RMS آن ۰/۱۲ متر است. آزمایش های انجام شده نشان داد، خطای RMS مکان یابی در حالت ایستا تا ۰/۵ متر و متحرک تا ۰/۶۱ متر کاهش می یابد.

واژه های کلیدی: الگوریتم ژنتیک، مکان یابی تفاضلی، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، خودرگرسیو میانگین متحرک، خطای مختصات مکان مرجع

علائم و اختصارات

$W^0(K)$	بردار وزن خروجی $q \times 1$			خطای مکان مرجع
$V(k)$	بردار فعال سازی نرون داخلی $q \times 1$			مقدار دریافتی X از گیرنده
$O(k)$	بردار نرون خارجی	Dx, Dy, Dz		مقدار دریافتی Y از گیرنده
$y(k)$	خروجی شبکه	X_m		مقدار دریافتی Z از گیرنده
$\varphi(x)$	تابع فعال سازی شبکه	Y_m		مقدار تصحیح شده X
$d(k)$	پاسخ مطلوب	Z_m		مقدار تصحیح شده Y
$\Delta w_{ji}^I(K)$	مقادیر تنظیم شده وزن $w_{ji}^I(k)$	X_{mc}		مقدار تصحیح شده Z
$\Delta w_{ji}^0(k)$	مقادیر تنظیم شده وزن $w_{ji}^0(k)$	Y_{mc}		یک بردار ورودی $p \times 1$
$\Delta w_{ji}^H(K)$	مقادیر تنظیم شده وزن $w_{ji}^H(k)$	Z_{mc}		ماتریس وزن ورودی $p \times q$
η	پارامتر آهنگ آموزش	$X_1(k)$		
τ	زمان نمونه برداری	$W^I(K)$		
$d_j(n)$	پاسخ مطلوب خروجی نرون j			
$y_j(n)$	پاسخ واقعی خروجی نرون j			
c	کل نرون های موجود در لایه خروجی			
a	آهنگ حرکت			

۱. دانشیار (نویسنده مخاطب)

۲. دانشجوی دکتری

۳. کارشناس ارشد

$(Dy(t), Dx(t)Dz(t))$ را برای بهبود و تصحیح مکان‌یابی موقعیت نقطه کاربر به ایستگاه کاربر ارسال می‌کند [۹، ۸]. دریافت سیگنال از ماهواره، محاسبه خطا، ارسال تصحیح‌ها برای گیرنده متحرک، دریافت توسط گیرنده متحرک و محاسبه موقعیت گیرنده متحرک مستلزم صرف زمان است، یک ثانیه تأخیر در تعیین موقعیت برای خودرو در حال حرکت با سرعت $10 \cdot \frac{km}{h}$ موجب خطای حدود ۳۳ متری می‌شود، از این رو به راهکاری برای پیشگویی تصحیحات نیاز است، در این مقاله فاکتورهای RPCE در ایستگاه مرجع محاسبه می‌شود، این مقادیر به عنوان ورودی الگوریتم پیشگویی استفاده می‌شوند و سپس مقادیر پیشگویی شده مطابق با الگوریتم مشخص برای بهبود مقادیر مکانی ایستگاه کاربر به صورت پس‌پردازش در آزمایش ایستا و بلادرنگ در آزمایش متحرک اعمال می‌شود. به‌منظور پیشگویی این فاکتورها از چهار روش شبکه عصبی تکاملی^۴، ماشین بردار پشتیبان^۵، خودرگرسیو میانگین متحرک^۶ و شبکه عصبی بازگشتی^۷ استفاده شد. در مدل ترکیبی از الگوریتم ژنتیک^۸ و شبکه عصبی مصنوعی^۹ بهره گرفته می‌شود، گام زمانی پیشگویی برای هر ۴ مدل یکسان است، هر گام زمانی ۵ ثانیه است. اگرچه ANN یکی از مهم‌ترین فون داده‌کاوی بشمار می‌آید، با این وجود جستجو برای انتخاب ساختار بهینه ANN و با سرعت پیشگویی بالا یک موضوع مهم است. یک ابزار قوی برای یافتن ساختار بهینه شبکه‌های عصبی GA است، دقت تحلیل با این ساختار افزایش می‌یابد. روش SVM روشی است که در آن نقاط قوت روش‌های آماری سنتی که بیشتر نظری محور هستند و از نظر تجزیه و تحلیل ساده هستند، ترکیب شده است و بین دقت و سرعت در این روش مصالحه برقرار شده است. شبکه عصبی که در واحد زمان عمل می‌کند و در هر لحظه با دریافت بردار ورودی و به‌روزرسانی لایه مخفی خود با توابع غیرخطی مقادیر بردار خروجی آینده را پیشگویی می‌کند RNN نامیده می‌شود و ARMANN ترکیب روش آماری با شبکه عصبی برای پیش‌بینی سری‌های زمانی است. بخش‌های مختلف مقاله به این صورت است؛ در بخش دوم این مقاله به ساختار طراحی شده برای DGPS و آزمایش الگوریتم‌های پیشگویی می‌پردازیم. روش ENN در بخش سوم بیان خواهد شد. بخش چهارم و پنجم به ترتیب مدل‌های RNN و SVM معرفی شده است. در بخش ششم به توصیف مدل ARMANN پرداخته شده است. بخش هفتم شبیه‌سازی و مقایسه روش‌های مختلف با یکدیگر در سنجش دقت پیشگویی است، بخش هشتم، دقت DGPS را مورد بررسی قرار می‌دهد و در نهایت بخش نهم نتیجه‌گیری مقاله است.

ξ	تابع هزینه حداقل شده
y_i	ارزش طبقه نمونه آموزشی
$K(X(X_i))$	تابع کرنل
d	درجه چندجمله‌ای
δ	پهنای باند شعاعی
$f(\bar{x})$	تابع خروجی
w	بردار وزن
x	بردار خروجی
b	بایاس
l	تعداد نمونه‌ها
λ	ضریب تنظیم
L^E	تابع تلفات
C	مقدار ثابت از پیش تعیین شده
ξ_1^+, ξ_1^-	متغیرهایی برای محدودیت‌های بالا و پایین خروجی الگوریتم

مقدمه

سامانه موقعیت‌یاب جهانی^۱، از شبکه‌ای با بیش از ۲۴ ماهواره تشکیل شده است. ماهواره‌ها اطلاعاتی را به گیرنده‌های زمینی مخابره می‌کنند، هر گیرنده این اطلاعات را دریافت می‌کند و با مقایسه زمان ارسال سیگنال از ماهواره و زمان دریافت آن، با ضرب این زمان در سرعت نور فاصله گیرنده از ماهواره تعیین می‌شود. سپس این عمل را با داده‌های دریافتی از چند ماهواره دیگر تکرار می‌کند و محل دقیق گیرنده را با اختلافی کمتر از ۱۵ متر تعیین می‌کند [۱]. اما نتایج حاصل از این نوع تعیین موقعیت، دارای دقت و قابلیت اطمینان لازم نیست، از طرفی پیوستگی نتایج مشاهدات در GPS کم و پراکندگی نتایج حول نقطه میانگین زیاد است [۲]. در مراحل مختلف از جمله ارسال سیگنال، انتقال و دریافت خطاهای مختلف بر روند کار تأثیر می‌گذارد [۳]، [۴]. سیگنال‌های ارسال از ماهواره با سه فرکانس حامل $L1$ ، $L2$ و $L5$ (که اخیراً اضافه شده است) ارسال می‌شوند. دو سطح از مکان‌یابی وجود دارد: سرویس مکان‌یابی استاندارد، که فقط از کد C/A و فرکانس حامل $L1$ بهره می‌برد، سرویس مکان‌یابی دقیق که از کد P و فرکانس حامل $L1$ و $L2$ استفاده می‌کند [۵]. برای کاربران معمولی امکان استفاده از سرویس مکان‌یابی دقیق وجود ندارد و این کاربران از گیرنده‌های ارزان قیمت با فرکانس حامل $L1$ استفاده می‌کنند [۶]. برای مقابله با خطاها و بالا بردن دقت سامانه مکان‌یابی از روش مطمئن GPS تفاضلی^۲ استفاده می‌شود [۷]، در حالت DGPS خطای مکان‌یابی از حدود ۱۵ متر به زیر ۱ متر کاهش می‌یابد. در این روش دو ایستگاه به طور همزمان با ماهواره‌ها در ارتباط هستند که یکی از آن‌ها ایستگاه مرجع و دیگری ایستگاه متحرک نامیده می‌شوند. ایستگاه مرجع با استقرار بر روی نقطه‌ای که دارای مختصات معلوم است، فاکتورهای خطای مختصات مکان مرجع^۳

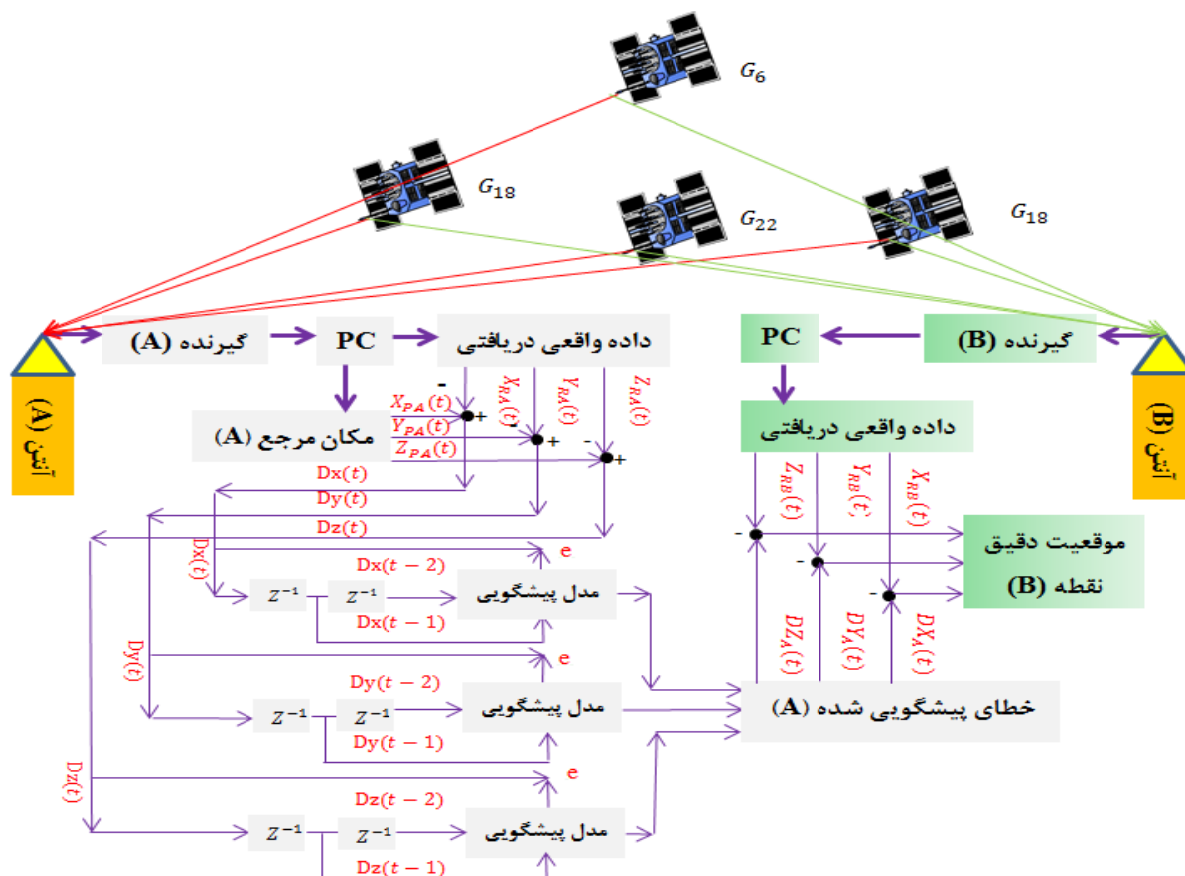
4. Extended Neural Network (ENN)
5. Support Vector Machine (SVM)
6. Autoregressive-Moving-Average Model (ARMA)
7. Recurrent Neural Network (RNN)
8. Genetic Algorithm (GA)
9. Artificial Neural Network(ANN)

1. Global Positioning System (GPS)
2. Differentials Global Positioning System (DGPS)
3. Reference PosItion Component Error (RPCE)

اندازه‌گیری تا ۱۶ ماهواره همزمان و قابلیت انتخاب ماهواره را دارد [۱۰]. این ساختار از سه بخش تشکیل شده است: الف) بخش ماهواره‌ای، ب) بخش ایستگاه مرجع (A)، ج) بخش ایستگاه کاربر (B)

ساختار استفاده از فاکتورهای RPCE

ساختار طراحی شده مطابق با شکل (۱) است، در این ساختار از گیرنده ارزان قیمت U-blox NEO-6M استفاده شده است. این گیرنده ۵۰ کاناله بود و قابلیت‌هایی چون؛ دنبال کردن و

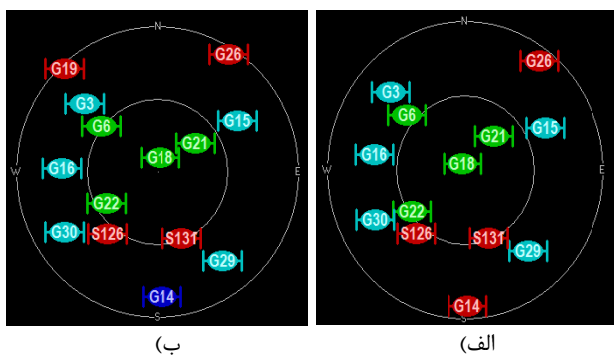


شکل ۱- ساختار طراحی شده برای سامانه مکان‌یاب تفاضلی قابل استفاده در آزمایش الگوریتم‌های پیشگویی

ماهواره‌های به رنگ سبز در مسیریابی انتخاب شده‌اند، ماهواره‌های به رنگ آبی کم رنگ قابلیت استفاده در ناوبری را داشته‌اند.

بخش ماهواره‌ای

برای مشخص شدن مکان، حداقل ۴ ماهواره مورد نیاز است [۱۱]. ترکیب فضایی ماهواره‌ها تأثیر مستقیم بر میزان خطای مختصات نهایی دارد [۱۴-۱۲]. تمامی گیرنده‌ها از الگوریتم‌هایی برای انتخاب زیرمجموعه بهینه‌ای از ماهواره‌ها استفاده می‌کنند. در واقع از بین ماهواره‌هایی که گیرنده می‌بیند مدام در حال انتخاب بهترین حالت هندسی بین آنهاست [۱۵]، [۱۶]، اگر گیرنده‌های دو ایستگاه مرجع و متحرک ماهواره‌های یکسانی را به‌عنوان زیرمجموعه بهینه انتخاب کنند با توجه به ثابت بودن منابع خطا می‌توان از فاکتورهای RPCE برای تصحیح موقعیت‌یابی ایستگاه کاربر بهره برد. در اندازه‌گیری انجام شده در این تحقیق، ماهواره‌های ۶، ۱۸، ۲۱ و ۲۲ در ایستگاه‌ها انتخاب شدند. شکل (۲) تصویر ماهواره‌های استفاده شده است،



شکل ۲- تصاویر ماهواره‌های مشاهده شده توسط الف) گیرنده ایستگاه مرجع و ب) گیرنده ایستگاه متحرک

D, C و E انجام شد. همچنین در این مقاله با توجه به کاربرد سامانه تفاضلی در حالت متحرک ایستگاه کاربر به صورت متحرک نیز در یک مسیر مشخص در نظر گرفته شده است.

مدل شبکه عصبی تکاملی

در ادامه درخصوص مدل شبکه عصبی تکاملی توضیحاتی آمده است.

شبکه عصبی مصنوعی

یک ANN از ترکیب واحدهایی به نام نرون تشکیل شده است. ورودی این نرون‌ها در وزن‌ها ضرب شده و سپس با یک عدد ثابت که بایاس نامیده می‌شود جمع می‌گردد؛ نتیجه نیز از یک تابع غیرخطی عبور می‌کند تا خروجی ساخته شود [۱۷]. شبکه عصبی مصنوعی اطلاعات زیادی را در فرآیند آموزش یاد می‌گیرد که این امر منجر به تمرکز بیش از حد بر روی داده‌های آموزشی می‌شود. دو روش تخریبی و سازنده در گذشته برای طراحی ساختار بهینه وجود داشته‌اند، در طراحی سازنده از شبکه مینی‌مال استفاده شده و به مرور به لایه‌های مخفی، گره‌ها و ارتباطات افزوده می‌شود و در روش تخریبی بر عکس [۱۸-۱۹]. جستجو بهتر GA در فضای نامحدود، چندوجهی و گسترده مسائل، عامل برتری آن است. در این مقاله از GA برای محاسبه وزن‌های شبکه استفاده شده است. نکته مهم شبکه^۱ MLP عدد موجود پس‌خورد است (شکل ۳). طبق تئوری تخمین‌گرهای عمومی ثابت می‌شود که با تعداد صحیحی نرون در لایه میانی، این ساختار هر تابع پیوسته از فضای R^N به فضای R^M را تخمین می‌زند [۲۱]. آموزش شبکه توسط روش باز پس انتشار انجام می‌گیرد، در این روش گرادینان مجموع مربعات خطا به کمک BP حداقل و وزن‌های سیستم به کمک آن بهینه می‌شود، هدف آموزش این است که تفاوت بین خروجی واقعی شبکه و خروجی‌های مطلوب به ازای ورودی‌های دلخواه حداقل شود.

الگوریتم ژنتیک

مفاهیم اصلی الگوریتم ژنتیک شامل عملگرهای سه‌گانه انتخاب، آمیزش و جهش است. در فرآیند تکثیر، کروموزوم‌هایی با شایستگی بالا شانس تکرار بیشتر در جمعیت منتخب را پیدا می‌کنند که این کار توسط فرآیند انتخاب صورت می‌پذیرد. پس از تکمیل فرآیند انتخاب، نوبت به اعمال پیوند به منظور تولید جمعیت فرزندان می‌رسد. در انجام فرآیند پیوند، با انتخاب مقدار ثابت نرخ پیوند، به ترتیب برای هر کروموزوم یک عدد تصادفی تولید می‌شود. اگر عدد تصادفی تولیدشده از نرخ پیوند کمتر باشد، این کروموزوم انتخاب

ایستگاه مرجع (A)

بلوک‌های این بخش با رنگ خاکستری در شکل (۱) مشخص شده‌اند، ساختار طراحی شده برای این بخش متشکل از آنتن (A)، گیرنده GPS، کامپیوتر شخصی، مکان مرجع و سه بلوک پیشگویی در جهت‌های مختصاتی X, Y, Z است. ابتدا، اطلاعات مکانی گیرنده از طریق آنتن در ۳ جهت مختصاتی X, Y, Z دریافت و جمع‌آوری می‌شوند، جمع‌آوری اطلاعات در نرم‌افزار U-Center 7.0 انجام می‌شود، موقعیت نقطه مرجع از طریق متوسط‌گیری مکانی در طول یک ساعت نمونه‌برداری و با آهنگ یک داده در یک ثانیه (۳۶۰۰ داده) به‌دست می‌آید. مختصات مکان مرجع به‌دست آمده در آزمایشگاه GPS دانشگاه تربیت دبیر شهید رجایی برابر با نقطه زیر است:

$$\bar{P}_{TA} = (x_{PA} = 3726206.69, y_{PA} = 4054570.45, z_{PA} = 3709308.96)$$

مختصات حاصل از گیرنده در هر لحظه با $\bar{R}_t = (x_R, y_R, z_R)$ نشان داده شده است. خطای بین مکان مرجع و مکان گیرنده GPS در هر لحظه با رابطه $\bar{E}_t = \bar{P}_t - \bar{R}_t$ محاسبه می‌شود و خطای مکان مرجع نامیده می‌شود. مقادیر به‌دست آمده در زمان t به صورت $Dx(t), Dy(t), Dz(t)$ نشان داده می‌شوند. این مقادیر با به عنوان ورودی مدل پیشگویی استفاده می‌شوند و مدل پیشگویی RPCE را برای زمان‌های آینده پیشگویی می‌کند.

بخش ایستگاه کاربر (B, C, D, E)

این بخش که بلوک‌های آن با رنگ سبز در شکل (۲) نشان داده شده است از یک آنتن، یک گیرنده و یک کامپیوتر شخصی تشکیل شده است. خطای پیشگویی شده در بخش مرجع در هر لحظه به موقعیت واقعی دریافتی از گیرنده در بخش کاربر اعمال می‌شود و موقعیت نهایی با دقت زیاد حاصل می‌شود. در آنجا مطابق با رابطه (۱) مختصات واقعی و دقیق‌تر به‌دست می‌آید. در این رابطه x_m, y_m و z_m مقادیر دریافت شده از گیرنده GPS در ایستگاه متحرک و x_{mc}, y_{mc} و z_{mc} مقادیر تصحیح شده مکانی در ایستگاه کاربر هستند.

$$\begin{aligned} x_{mc} &= x_m - Dx, \\ y_{mc} &= y_m - Dy, \\ z_{mc} &= z_m - Dz \end{aligned} \quad (1)$$

با توجه به تأثیر فاصله دو ایستگاه در تفاوت ماهواره‌های مشترک دو ایستگاه، ۴ آزمایش با تفاوت در فاصله دو ایستگاه مرجع و کاربر طراحی شد؛ در آزمایش اول با فاصله ۸۴۳۷ سانتی‌متر ما بین اطلاعات پیشگویی شده توسط هر ۴ الگوریتم، به صورت پس‌پردازش در ایستگاه کاربر اعمال شد و موقعیت‌یابی انجام شد، سپس سه آزمایش با فاصله‌های ۵۴۵۶۷ سانتی‌متری، ۱۲۵۳۱۲ سانتی‌متری، ۳۳۳۵۵ سانتی‌متری و ۵۴۳۶۸۴ سانتی‌متری و در نقاط

1. Multilayer Perceptron's (MLP)


منجر به نتایج مختلف می‌شوند، بازه وزن‌های اولیه مورد تکامل قرار می‌گیرند؛ که این سبب دور شدن از مینیمم محلی و نزدیک شدن به مینیمم مطلق می‌گردد. مقدار بهینه آهنگ آموزش و اندازه حرکت نیز مورد تکامل قرار می‌گیرند. در نهایت بازه وزن‌های اولیه، آهنگ آموزش، تعداد لایه‌های مخفی، تعداد نرون‌های در لایه مخفی اول، دوم و سوم به زیر رشته فرم ژن گونه نگاشته می‌شوند تا احتمال پیدا کردن مینیمم مطلق افزایش پیدا کند. هر کروموزوم موجود در GA را به صورت باینری با رشته‌ای از صفر و یک در نظر گرفته‌ایم. تنظیمات پارامترهای شبکه عصبی در جدول (۱) آمده است. داده‌ها را به ۲ دسته آزمایش و آموزش تقسیم می‌کنیم، از مجموعه داده‌های آزمایشی به منظور تعیین میزان خطای استفاده و جمعیت اولیه به صورت تصادفی با ۵۰ کروموزوم ساخته می‌شود. سپس هر کروموزوم دزد شده و پرسپترون چند لایه متناظر آن کروموزوم ساخته می‌شود. هر شبکه عصبی ساخته شده با استفاده از الگوریتم پس انتشار با ۱۰۰۰ تکرار آموزش داده می‌شود. پس از آموزش شبکه‌های عصبی متناظر با کروموزوم‌های جمعیت میزان خطاها با ابزار بیان شده محاسبه می‌شود. عمل جفت‌گیری با استفاده از روش چرخ رولت انجام می‌گردد، آهنگ جفت‌گیری با احتمال ۰/۷ و آهنگ جهش ۰/۰۱ و تعداد نسل‌ها ۴۰ در نظر گرفته می‌شود. الگوریتم ENN در ادامه بیان می‌شود:

۱. شروع / ۲. تقسیم داده به دو دسته داده آموزش و آزمایش / ۳. $0 \leftarrow i$
۴. مقداردهی اولیه جمعیت / ۵. ارزیابی اولیه جمعیت Ψ_i / ۶ تا زمانی که $G / i < 1$.
- انتخاب تعداد $P/2$ والد از Ψ_i به منظور انجام عملگرهای الگوریتم ژنتیک $\leftarrow A_i / A_i$ اعمال عملگرهای جفت‌گیری و جهش بر روی تمام اعضای $A_i \leftarrow O_i / 9$. ارزیابی اولاد در مجموعه $O_i / 10$.
- انتخاب $1 - P/2$ بازمانده‌ها از $\Psi_i \leftarrow S_i / 11$. تعیین نسل جدید: $\Psi_i \leftarrow (best(\Psi_i) \cup S_i \cup O_i) / (best(\Psi_i) \cup S_i \cup O_i) / 13$. پایان.
- ارزیابی برای جمعیت Ψ با اندازه P : شروع / ۲. $1 \leftarrow J$.
- تا زمانی که $(j \leq P_{\Psi_i}) / 4$. انتخاب J امین MLP از جمعیت $\Psi_i \leftarrow MLP_j / 5$. آموزش MLP_j با استفاده از داده‌های آموزش با ۱۰۰۰ تکرار / ۶. تعیین فیتنس MLP_j با استفاده از RMSE بر روی داده‌های آزمایشی / ۷. $j + 1 \leftarrow j / 8$. پایان.


جدول ۱- بازه پارامترها و تنظیم‌ها ساختار شبکه عصبی

عنوان	بازه	تعداد بیت نمایش
وزن اولیه	$0 < R < 1$	۷
آهنگ آموزش	$0 < R < 1$	۸
اندازه حرکت	$0 < R < 1$	۱۰
تعداد نرون لایه مخفی ۱	$0 < R < 63$	۶


می‌شود تا با کروموزوم‌های بعدی که شرایط فوق را دارد آمیزش کند. در انجام فرآیند جهش، با انتخاب مقدار ثابت نرخ جهش، برای کلیه بیت‌های کروموزوم‌های جمعیت عدد تصادفی تولید می‌شود. اگر عدد تصادفی تولید شده از نرخ جهش کوچک‌تر باشد، مقدار آن بیت عوض می‌گردد، یعنی مقدار صفر به یک یا بالعکس تبدیل می‌شود. هنگامی که برخی ضوابط مانند تعداد معینی تولید نسل یا میانگین انحراف معیار عملکرد اشخاص جمعیت تأمین شود، الگوریتم ژنتیک به پایان می‌رسد [۲۴، ۲۳].



(الف)



(ب)



(ج)

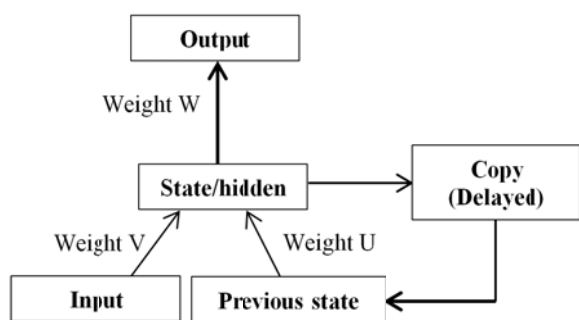
شکل ۳- فاکتور RPCE پیشگویی شده با الگوریتم ENN

الگوریتم ENN

در اغلب مسائل، پیش‌بینی وجود یک لایه مخفی برای پرسپترون چند لایه به منظور پیش‌بینی کفایت می‌کند؛ اما در مسائل پیچیده از دو یا سه لایه مخفی استفاده می‌شود. تعداد نرون‌ها در لایه‌های مخفی به تعداد لایه‌های مخفی وابسته است. تابع فعال‌سازی برای لایه مخفی زیگموید^۲ در نظر گرفته شده است. چون آموزش پرسپترون‌های چندلایه با بازه‌های مختلف وزن‌های اولیه و با ساختار شبکه یکسان

2. Sigmoid Function


باعث می‌شود که حین آموزش شبکه خود را به روز کند [۳۵]. یک شبکه عصبی بازگشتی شبکه‌ای است که در حوزه زمان کار می‌کند. در هر واحد زمان؛ یک بردار ورودی را دریافت می‌کند، لایه مخفی خود را با تابع فعال‌سازی غیرخطی به‌روزرسانی کرده و از آن برای پیشگویی خروجی استفاده می‌کند. این مدل از کلاس مدل‌های غنی است، چون در لایه مخفی خود توانایی ذخیره اطلاعات به صورت گسترده با ابعاد زیاد را دارد (بر خلاف مدل مارکوف که اطلاعات را به صورت $\log(n)$ ذخیره می‌کند) و این الگوریتم قدرت محاسباتی بالایی نیز دارد [۳۷].



شکل ۵- ساختار شبکه RNN ساده [۳۶]

ساختار RNN در پیشگویی RPCE


ساختار شبکه عصبی که در این پیاده‌سازی در نظر گرفته شده است، یک شبکه عصبی جلو سو با اتصالات کامل و لایه‌های ورودی، پنهان و خروجی است. ساختار RNN مطابق با معادلات آموزش در شکل (۶) نشان داده شده است. در اینجا یک RNN را با اتصالات کامل در نظر گرفته‌ایم، که در آن اتصالات بازگشتی کامل از لایه‌های پنهان قبلی به لایه‌های پنهان بعدی وجود دارد. این اتصالات اثر نمونه‌های قبلی را بر روی نمونه‌های فعلی در نظر می‌گیرند. همچنین اتصال کامل از لایه پنهان قبلی به لایه ورودی فعلی وجود دارد که درصدی از ورودی فعلی را از روی نمونه‌های قبلی تخمین می‌زند. معادلات آموزش به اختصار در زیر آمده است [۳۸]، [۳۹]:



شکل ۶- ساختار RNN برای پیشگویی خطای مکان مرجع

پیشگویی RPCE با ENN

شکل (۴) نشان‌دهنده پیشگویی خطا با استفاده از مدل ENN است. در این شکل خط آبی خطای بین گیرنده و مکان مرجع و خط قرمز خطای پیش‌بینی شده با الگوریتم را نشان می‌دهد، همچنین خط سبز تفاوت بین مقدار واقعی و پیشگویی شده خطا را نشان می‌دهد. شاخص‌های آماری خطای مدل پیشگویی (تفاوت بین مقدار واقعی با مقدار پیشگویی شده) ENN در جدول (۲) نشان داده شده است. کل خطای RMS مدل ENN در پیشگویی فاکتورهای $0.12RPCE$ متر است. شکل‌ها (۴-الف)، (۴-ب) و (۴-ج) به ترتیب پیشگویی خطا را در سه جهت مختصات X, Y و Z نشان می‌دهند.




شکل ۴- شبکه عصبی چند لایه

جدول ۲- شاخص‌های آماری خطای مدل ENN


پارامترها	کمینه	بیشینه	میانگین	واریانس	RMS
Dx	۰/۰۰۰۰۰۳	۰/۶۹۹۹۶	-۰/۰۰۰۳۱	-۰/۰۰۴۳۴	-۰/۱۱۱
Dy	۰/۰۰۰۰۰۳	۰/۶۳۱۵۰۳	۰/۰۰۷۸۳۸	-۰/۰۰۳۸۹	-۰/۱۲۸
Dz	۰/۰۰۰۰۰۴	۰/۰۰۴۹۹۶	-۰/۰۰۶۵۲۷	-۰/۰۱۱۶۸۷	-۰/۱۰۸

شبکه عصبی بازگشتی


به‌طور کلی دو تقسیم‌بندی برای ساختار شبکه عصبی مورد استفاده در سیستم‌های دینامیک وجود دارد. یکی شبکه عصبی پیشخور که شامل پرسپترون‌های چند لایه و تابع پایه شعاعی است. تقسیم‌بندی دیگر شامل شبکه عصبی بازگشتی است که برای ساختارهای دینامیک کاربرد دارد. شبکه مورد نظر در سال ۱۹۹۸ برای شناسایی کلاس بزرگی از سامانه‌های غیرخطی معرفی شد [۴۳]. شبکه عصبی بازگشتی یک قابلیت مهم در ذخیره اطلاعات برای استفاده در آینده دارد که این خاصیت در شبکه پیشخور وجود ندارد. یک شبکه RNN ساده که در شکل (۵) نشان داده شده است، یک حافظه کوتاه مدت دارد [۳۴]. RNN نه تنها خود را با اطلاعات ورودی خارجی به‌روز رسانی می‌کند بلکه با اطلاعات پس انتشار ذخیره شده نیز به‌روز رسانی می‌شود، وجود فیدبک در این ساختار



(الف)



(ب)



(ج)

شکل ۷- پیشگویی خطای مکان مرجع با استفاده از مدل RNN

همان‌طور که در جدول (۳) مشاهده می‌شود حداکثر و مقدار میانگین خطای پیشگویی به ترتیب نزدیک به یک و صفر متر شده است.

جدول ۳- شاخص‌های آماری خطای مدل پیشگویی RNN

پارامترها	کمینه	بیشینه	میانگین	واریانس	RMS
Dx	۰/۰۰۰۲۱	۱/۰۴۵۶	۰/۰۰۱۶	۰/۱۲۹۵	۰/۳۵۸۹
Dy	۰/۰۰۰۰۶	۱/۰۸۷۶	۰/۰۰۹۰	۰/۱۳۳۳	۰/۳۶۵۱
Dz	۰/۰۰۰۱۸	۱/۱۸۱۴	۰/۰۷۲۵	۰/۱۳۹۲	۰/۳۷۹۹

ماشین بردار پشتیبان رگرسیونی

روش SVM یکی از روش‌های یادگیری ماشینی است که بر مبنای تئوری یادگیری آماری ارائه شد [۲۵]. در SVM از اصول کمینه‌سازی ریسک ساختاری استفاده شده است، در حالی که سایر روش‌ها از اصول کمینه‌سازی ریسک تجربی بهره می‌برند. استفاده از ریسک تجربی کارایی مدل را بر روی داده‌های آموزشی تضمین می‌کند، اما تضمینی برای قابلیت تعمیم‌یابی مناسب وجود ندارد، به همین دلیل در این روش طراحی مناسب شبکه برای بهبود عملکرد تعمیم‌یابی ضروری است [۲۶].

گام اول: وزن‌دهی اولیه تمام وزن‌های شبکه با اعداد تصادفی کوچک

گام دوم: محاسبات پیشرو

$$v_j(k) = \sum_{i=1}^{i=p} w_{ji}^I(K) X_i(k) = w_j^H(K) O_j(K-1) \quad (2)$$

$$o_j(k) = \varphi_j[v_j(k)] \quad (3)$$

$$y(k) = \sum_{j=1}^{j=q} w_j^O(k) o_j(k) \quad (4)$$

گام سوم: به‌روزرسانی بردار وزن‌ها

$$\Delta w_j^O(k) = \eta(y(k) - d(k)) o_j(k) \quad (5)$$

$$\Delta w_j^H(K) = \eta(y(k) - d(k)) w_j^O(k) \frac{\partial o_j(k)}{\partial w_j^H(k)} \quad (6)$$

$$\frac{\partial o_j(k)}{\partial w_j^H(k)} = \varphi'_j[v_j(k)] \left(o_j(k-1) + w_j^H(K) \frac{\partial o_j(k-1)}{\partial w_j^H(k)} \right) \quad (7)$$

$$\frac{\partial o_j(0)}{\partial w_j^H(0)} = 0 \quad (8)$$

$$\Delta w_{ji}^I(K) = \eta(y(k) - d(k)) w_j^O(k) \frac{\partial o_j(k)}{\partial w_{ji}^I(k)} \quad (9)$$

$$\frac{\partial o_j(k)}{\partial w_{ji}^I(k)} = \varphi'_j[v_j(k)] (X_i(k) + w_j^H(K) \frac{\partial o_j(k-1)}{\partial w_{ji}^I(k)}) \quad (10)$$

$$\frac{\partial o_j(0)}{\partial w_{ji}^I(0)} = 0 \quad (11)$$

در معادلات بالا $X_i(k)$ یک بردار ورودی $p \times 1$ ، $w_j^H(K)$ ماتریس وزن ورودی $p \times q$ ، $W^O(K)$ بردار وزن خروجی $q \times 1$ ، $V(k)$ بردار فعال‌سازی نرون داخلی $q \times 1$ ، $O(k)$ بردار نرون خارجی و $y(k)$ خروجی شبکه است. همچنین $\frac{1}{1+e^{-x}}$ تابع فعال‌سازی شبکه، $d(k)$ پاسخ مطلوب، $\Delta w_{ji}^I(K)$ مقادیر تنظیم شده وزن $w_{ji}^I(k)$ ، $\Delta w_j^O(k)$ مقادیر تنظیم شده وزن $w_j^O(k)$ و $\Delta w_j^H(K)$ مقادیر تنظیم شده وزن $w_j^H(K)$ است. η پارامتر آهنگ آموزش است. همان‌طور که مشاهده می‌شود، شبکه قادر به ذخیره‌سازی حالت‌های سیستم در خود است.

گام چهارم: تکرار افزایش یک واحدی زمان (K) و بازگشت به گام دوم

پیشگویی RPCE با RNN

شکل (۷) نشان‌دهنده پیشگویی خطا با استفاده از مدل RNN است. در این شکل خط آبی خطای بین گیرنده و مکان مرجع و خط قرمز خطای پیش‌بینی شده با الگوریتم را نشان می‌دهد، همچنین خط سبز تفاوت بین مقدار واقعی و پیشگویی شده خطا را نشان می‌دهد. شاخص‌های آماری خطای مدل پیشگویی RNN در جدول (۴) نشان داده شده است، کل خطای RMS مدل RNN در پیشگویی فاکتورهای خطای مکان مرجع ۰/۳۸ متر است. شکل‌ها (۷-الف)، (۷-ب) و (۷-ج) به ترتیب پیشگویی خطا را در سه جهت مختصات X ، Y و Z نشان می‌دهند.

ساختار SVM

مسئله رگرسیون در SVM یک تابع خطی به شکل $f(x) = \langle w, x \rangle + b$ است. این تابع بر روی یک مجموعه شامل 1 نمونه مانند $\{(x_1, y_1), \dots, (x_n, y_n)\} \in R^N, y \in R$ می‌تواند مقدار خروجی را بر مبنای مقادیر ورودی تخمین بزند. در رابطه فوق x بردار مقادیر ورودی است. پارامترهای w و b نیز پارامترهای کنترل تابع f هستند. $\langle w, x \rangle$ نشانگر ضرب داخلی است. برای حل مسئله رگرسیون تابع تلفات Vapnik که در آن حداقل خطایی به میزان ϵ قابل صرف نظر کردن است، مورد استفاده قرار می‌گیرد. تابع تلفات به شکل زیر تعریف می‌شود [۲۷]:

$$L_\epsilon(y) = |f(x) - y|_\epsilon = \begin{cases} 0 & \text{for } |f(x) - y| < \epsilon \\ |f(x) - y| - \epsilon & \text{otherwise} \end{cases} \quad (12)$$

$L_\epsilon(y)$ معرف تابع تلفات و ϵ میزان خطای مجاز در تابع تلفات است. پارامترهای کنترل کننده تابع رگرسیون بهینه با حل مسئله بهینه‌سازی زیر حاصل می‌شوند [۲۸]:

$$\text{Minimise } \Phi(w, \xi, \xi^*) = \frac{1}{2} |w|^2 + c \sum (\xi_i^* + \xi_i) \quad (13)$$

$$y_i - ((w \cdot x_i) + b) \leq \epsilon + \xi_i \quad (14)$$

$$\text{Subject to } ((w \cdot x_i) + b) - y_i \leq \epsilon + \xi_i^* \quad (15)$$

$$\xi_i^*, \xi_i \geq 0 \quad (16)$$

در روابط فوق ξ_i^*, ξ_i متغیرهای slack هستند. این متغیرها به همراه تابع تلفات در شکل (۸) نشان داده شده‌اند. برای حل مسئله بهینه‌سازی فوق به کمک تئوری لاگرانژ، تابع لاگرانژ مطابق با رابطه (۱۷) نوشته می‌شود.

$$L(\alpha^*, \alpha) = -\epsilon \sum_{i=1}^n (\alpha_i^* + \alpha_i) + \sum_{i=1}^n y_i (\alpha_i^* - \alpha_i) - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) (x_i \cdot x_j) \quad (17)$$

با بیشینه‌شدن تابع فوق تحت محدودیت‌های زیر، مقادیر α^*, α به دست می‌آیند.

$$\begin{cases} \sum \alpha_i^* = \sum \alpha_i \\ 0 \leq \alpha_i^* \leq C \text{ for } i=1,2,\dots, \\ 0 \leq \alpha_i \leq C \end{cases} \quad (18)$$

مسئله بهینه‌سازی فوق به کمک روش‌های QP قابل حل است، در نتیجه رسیدن به اکسترمم کلی نیز قطعی خواهد بود و خطر به دام افتادن در اکسترمم محلی وجود ندارد. داده‌هایی که ضرایب لاگرانژ متناظر با آن‌ها غیر صفر باشد، به عنوان بردار پشتیبان شناخته می‌شوند [۲۹]. از نظر هندسی این داده‌ها دارای خطاهای پیش‌بینی بزرگ‌تر از $\pm \epsilon$ هستند، بنابراین بردارهای پشتیبان در درون باند $\pm \epsilon$ قرار نمی‌گیرند، پس مقدار ϵ تعداد بردارهای پشتیبان را کنترل می‌کند [۳۰].


به کمک ضرایب لاگرانژ و بردارهای پشتیبان، پارامترهای

کنترل کننده پاسخ بهینه نیز به صورت زیر محاسبه می‌شوند [۳۲]:

$$w_0 = \sum_{\text{support vectors}} (\alpha_i^* - \alpha_i) x_i \quad (19)$$

$$b_0 = -(1/2) w_0 [x_r + x_s] \quad (20)$$

$$f(x) = \sum_{\text{support vectors}} (\alpha_i^* - \alpha_i) (x_i - x_j) + b_0 \quad (21)$$



شکل ۸- تابع تلفات Vapnik و متغیرهای slack [۳۱]

در روابط بالا x_r, x_s دو بردار پشتیبان هستند. برای ساخت مدل ماشین بردار پشتیبان، پارامترهای C و ϵ توسط کاربر تعریف می‌شوند. پارامتر C یک پارامتر تنظیمی است و می‌تواند مقادیر صفر تا بی نهایت را بپذیرد. نقش این پارامتر ایجاد تعادل میان کمینه کردن ریسک تجربی و بیشینه کردن قابلیت تعمیم‌یابی است [۳۳]. پارامتر ϵ نیز می‌تواند مقادیر صفر تا بی نهایت را بپذیرد. مقدار این پارامتر در وضعیت بردارهای پشتیبان و در نتیجه کارایی مدل بسیار موثر است. مسئله رگرسیون خطی در SVM به آسانی قابل گسترش به رگرسیون غیر خطی است. بدین منظور از توابع کرنل استفاده می‌شود. بدین ترتیب در حالت رگرسیون غیر خطی در SVM پارامترهای کنترل کننده تابع بهینه با روابط زیر محاسبه می‌شوند [۱۵]:

$$w_0 \cdot x = \sum_{\text{support vectors}} (\alpha_i^* - \alpha_i) K(x_i, x) \quad (22)$$

$$b_0 = -(1/2) \sum_{\text{support vectors}} (\alpha_i^* - \alpha_i) [K(x_r, x_i) + K(x_r, x_s)] \quad (23)$$

در روابط بالا K نشان‌دهنده کرنل است. ورودی‌های مدل، داده‌های گذشته Dx, Dy, Dz است و خروجی‌های مدل مقادیر آینده این سه متغیر است. داده‌ها به دو دسته آزمایش و آزمایش تقسیم می‌شوند. تابع کرنل استفاده شده تابع کرنل با پایه شعاعی^۵ است [۳۳].

$$K(x, x_i) = \exp(-1/\sigma^2 (X - X_i)^2) \quad (24)$$

در رابطه (۲۴) σ عرض کانال RBF است. تعیین سه پارامتر σ, ϵ و C بسیار مهم است. عملکرد خوب الگوریتم پیشگویی SVM وابستگی کاملی به تعیین مناسب این پارامترها دارد [۳۳]. این سه پارامتر توسط کاربر تعیین می‌شود. در این مقاله از روش جستجوی هدایت شده برای تعیین این پارامترها استفاده شد [۳۲]، [۳۳]:

۱. یک مقدار ثابت برای دو پارامتر C و ϵ در نظر گرفته شود و سپس مقدار σ تا رسیدن به مقدار حداقل خطای فرآیند آزمون تنظیم شود. مقدار نهایی σ با $\hat{\sigma}$ نشان داده می‌شود.

3. Loss Function
4. Quadratic Programming Method

جدول ۴- شاخص‌های آماری خطای مدل پیشگویی SVM

پارامترها	کمینه	بیشینه	میانگین	واریانس	RMS
Dx	۰/۰۰۰۰۲	۱/۵۸۹۳۰	۰/۰۵۶۱۱۶	۰/۱۷۳۷۷	۰/۱۴۲۵۲۸
Dy	۰/۰۰۰۰۴	۱/۴۱۵۹۴۰	۰/۰۰۰۲۷	۰/۰۴۱۵۵۹	۰/۱۵۳۷۷۸
Dz	۰/۰۰۰۰۲	۱/۵۸۹۳۰۱	-۰/۰۴۸۷۵	۰/۰۲۹۷۳۷	۰/۱۳۹۱۲۱

مدل ARMANN

روش سری‌های زمانی یکی دیگر از روش‌های پیش‌بینی کلاسیک است. در بررسی و تجزیه و تحلیل سری‌های زمانی دو هدف اصلی دنبال می‌شود. هدف اول، تعریف سری‌های زمانی و شناخت طبیعت، خصوصیات و رفتارهای آن‌هاست. هدف دیگر پیش‌بینی وضعیت و رفتار آینده سری زمانی است، که این امر با ایجاد و گسترش مدلی که طبیعت و خصوصیات داده‌های نمونه سری زمانی را بیان می‌نماید، امکان‌پذیر می‌شود. هدف اصلی در این روش استفاده از ترکیب مدل‌های ARMA و شبکه عصبی است، از شبکه عصبی برای تحقق مدل ARMA استفاده می‌شود [۴۰]. در علم آمار و پردازش سیگنال مدل ARMA مدلی است که معمولاً برای سنجش داده‌های سری زمانی مورد استفاده قرار می‌گیرد [۴۱]. این مدل در شناسایی ساختار یک سیستم ناشناخته که شناسایی آن دشوار است کاربرد دارد. مدل به فرم $ARMA(p,q)$ نوشته می‌شود، این مدل یکی از بهترین مدل‌های پیش‌بینی خطی است، p مرتبه اتورگرسیو یا AR که وابستگی یک عنصر در زمان حال به مقادیر قبلی‌اش است. در این مدل، رگرسیون هر عنصر بر حسب مقادیر پیشین خود تعیین می‌شود. فرآیندهای اتورگرسیو در بیان حالت‌هایی مفید هستند که در آن مقدار حال سری زمانی به مقادیر قبلی آن به علاوه یک ضریب تصادفی بستگی دارد. q نیز مرتبه میانگین متحرک را معلوم می‌کند که به وسیله آن وابستگی سری به عناصر تصادفی حال و گذشته‌اش تعریف می‌شود. فرآیندهای میانگین متحرک یا MA در توصیف پدیده‌ای مفیدند که پیشامدها یک اثر آتی را تولید می‌کنند که برای دوره‌های کوتاه زمان باقی می‌ماند [۴۲]. برای داده‌های سری زمانی، مدل ARMA ابزاری برای مطالعه و شاید پیش‌بینی مقادیر آتی چنین سری‌هایی است. فرمول عمومی $ARMA(n,m)$ با رابطه خطی زیر تعریف می‌شود:

$$y(t) + a_1 y(t-T) + a_2 y(t-2T) + \dots + a_n y(t-nT) = \beta_0 u(t) + \beta_1 u(t-T) + \dots + \beta_m u(t-mT) \quad (25)$$


که فرم دیگر آن به صورت زیر است:

$$y(t) + \sum_{k=0}^m a_k y(t-kT) = \sum_{k=0}^m \beta_k u(t-kT) \quad (26)$$


- مقدار ثابتی برای ϵ در نظر گرفته شود و σ روی $\hat{\sigma}$ تنظیم شود. سپس مقدار C برای حداقل خطای فرآیند آزمون تنظیم شود و این مقدار با C' نشان داده شود.
- مقادیر C و σ روی C' و $\hat{\sigma}$ تنظیم شود و مقدار ϵ برای رسیدن به خطای حداقل تنظیم شود.
- پارامترها به ترتیب ۳، ۰/۰۰۲ و ۴/۵ تعیین شد.

پیشگویی RPCE با SVM


خطاهای مکان مرجع در نقطه A را با استفاده از مدل SVM و ساختار پیشگویی شکل (۲) پیشگویی می‌شود. به دلیل عدم نیاز این مدل به بهینه‌سازی پارامترهای مختلف همانند الگوریتم ژنتیک، این مدل دارای سرعت پیشگویی بهتر نسبت به مدل ENN و دارای خطای RMS، ۰/۱۵ متر است. پیشگویی خطای مکان مرجع در شکل (۹) به رنگ قرمز نشان داده شده است و به رنگ آبی که خطای واقعی است، بسیار نزدیک است. شاخص‌های آماری این مدل در جدول (۴) آمده است. ماکزیمم خطای پیشگویی در این روش ۱/۵ متر است و حداقل آن تقریباً به صفر می‌رسد.



(الف)



(ب)



(ج)

شکل ۹- خطای مکان مرجع پیشگویی شده با الگوریتم SVM

که در آن c کل نرون‌های موجود در لایه خروجی است. میانگین مجموع خطای انرژی مطابق با رابطه زیر است که در آن N تعداد نمونه‌هاست.


$$\xi_{av} = \frac{1}{N \sum_{n=1}^N \xi(n)} \quad (29)$$

هدف آموزش تنظیم پارامترها به منظور حداقل سازی رابطه اخیر است. برای این حداقل سازی باید وزن‌ها مطابق با الگوی مشخص به‌روز رسانی شوند. یک الگوی ساده بهینه‌سازی به صورت روابط (۳۰) تا (۳۱) است:

$$w_{ji}(n+1) = w_{ji}(n) - \eta \frac{\xi \partial \xi(n)}{\partial w_{ji}(n)} \quad (30)$$

$$\Delta w_{ji}(n) = -\eta \frac{\xi \partial \xi(n)}{\partial w_{ji}(n)} + \alpha \Delta w_{ji}(n-1) \quad (31)$$

که در آن η آهنگ آموزش، α آهنگ حرکت و ξ تابع هزینه حداقل شده را نشان می‌دهد [۴۵]، [۴۶]. در شکل (۱۰) ساختار ARMANN برای پیش‌بینی نشان داده شده است، برای پیش‌بینی $Dx(t+1)$ مقادیری از ورودی‌ها $Dx(t), Dx(t-1), \dots, Dx(t-n)$ استفاده می‌شوند، که در آن n تعداد داده ورودی است. شبکه عصبی BP سه لایه است و دارای یک لایه ورودی، یک لایه مخفی و یک لایه خروجی است. از تابع فعال‌سازی زیگموئید در لایه پنهان و خروجی استفاده می‌شود. برای سنجش دقت الگوریتم پیشگویی شبکه با ۲۰ داده ورودی تنظیم گردید. در لایه مخفی از ۱۵ داده تشکیل شده و لایه خروجی که نشان‌دهنده پیش‌بینی $Dx(t+1)$ شامل یک داده است. گره بایاس برای ورودی و لایه مخفی ۱ است. شبکه برای پیش‌بینی ۱۰۰۰ ثانیه آینده مقادیر Dx آموزش می‌بیند. پارامترهای تنظیم‌شده برای تحقق مدل ترکیبی شامل بایاس، آهنگ آموزش و ضریب حرکت به ترتیب برابر با ۰/۳، ۰/۵ و ۰/۵ است. در جهت Dy و Dz نیز روند به همین صورت است.



شکل ۱۰- ساختار مدل ARMANN برای پیشگویی خطای مکان مرجع

در روابط (۲۵) و (۲۶) نشان‌دهنده زمان نمونه‌برداری است، $y(t)$ ترکیب خطی از ورودی u و خروجی y است. در سمت چپ معادله (۲۳) بخش خود رگرسیو است، در حالی که سمت راست بخش میانگین متحرک است. پارامتر m و n ناشناخته‌اند و برای شناسایی نیاز به تنظیم اجرای برنامه‌های بهینه‌سازی دارند. هر دو AR و MA در یک مدل خاص ARMA برای پیشگویی استفاده می‌شوند [۴۳].

شبکه عصبی مورد استفاده در مدل پیشگویی ARMA

مدل ARMA با در نظر گرفتن نوسانات سری زمانی با محدودیت‌هایی مواجه است، یکی از الگوهای غیرخطی که توانایی بالقوه خوبی برای پیش‌بینی سری‌های زمانی از خود نشان داده، شبکه‌های عصبی هستند [۴۴]. ترکیب مدل‌های شبکه عصبی به عنوان یک مدل غیرخطی با مدل ARMA به عنوان یک مدل خطی در پیش‌بینی سری‌های زمانی، عملکرد بهتری نسبت به پیش‌بینی صورت گرفته با استفاده از هر یک از مدل‌ها به تنهایی دارد. این روش دارای دو مزیت قابل توجه است: اولاً دو الگوی خطی ARMA و غیرخطی شبکه عصبی ترکیب شده که در این زمینه نقاط ضعف هر یک از الگوها در پیش‌بینی با نقاط قوت الگوی دیگری حذف یا کم رنگ‌تر می‌شود، ثانیاً این روش با در نظر گرفتن سری زمانی، عوامل تأثیرگذار بر روی این سری را نیز در مدل دخیل می‌کند که قاعده‌تاً می‌بایستی قدرت پیش‌بینی سری زمانی را افزایش دهد. از شبکه عصبی BP برای آموزش شبکه عصبی استفاده شده است. ورودی آموزش به لایه ورودی وارد می‌شوند و خروجی مطلوب با خروجی شبکه مقایسه می‌شود. در حین فرآیند آموزش یک فرآیند رفت و برگشت در شبکه برقرار می‌شود و خروجی هر جزء لایه به لایه محاسبه می‌شود. روش به‌طور کلی پیدا کردن یک بردار گرادینان در ساختار شبکه است که به عنوان BP به آن اشاره شده است. اساس کار آموزش شبکه عصبی بر اساس حداقل‌سازی مربعات خطا بین بردار خروجی واقعی و بردار خروجی هدف یا مطلوب است.

الگوریتم آموزشی آن مختصراً به صورت زیر است:

$$e_j(n) = d_j(n) - y_j(n) \quad (27)$$

که در آن $d_j(n)$ پاسخ مطلوب خروجی نرون j و $y_j(n)$ پاسخ واقعی خروجی نرون j است. هدف اصلی BP حداقل سازی این خطا یعنی نزدیک شدن مقدار واقعی به مقدار مطلوب است. به این منظور انرژی خطا را برای هر نرون j به صورت $1/2 e_j^2(n)$ تعریف می‌کنیم. انرژی خطای کل با مجموع رابطه اخیر برای نرون‌های خروجی لایه آخر به دست می‌آید:

$$\xi(n) = 1/2 \sum_{j \in c} e_j^2(n) \quad (28)$$

مقایسه نتایج دقت مدل‌های پیش‌گویی

اغلب در مسائل رگرسیون از شاخص ریشه دوم میانگین مربعات خطا که در معادله (۳۲) آمده است استفاده می‌شود و هر چقدر مقدار آن کمتر باشد مدل پیشگویی بهتر است.

$$RMSE = \sqrt{\sum_{i=1}^K (T_i - P_i)^2 / K} \quad (32)$$


در رابطه ۳۲ تعداد نمونه‌ها، T_i و P_i مقدار پیش‌بینی شده واقعی در نمونه i ام هستند. در جدول (۶) مقایسه فاکتور RMSE را برای چهار روش مختلف استفاده شده در مقاله آورده شده است، روش ENN با مقدار ۰/۱۲ متر بهترین روش به لحاظ دقت پیشگویی است. پس از آن روش‌های SVM، RNN و ARMANN به ترتیب دارای کمترین مقدار RMSE هستند. در سنجش مدل‌های پیشگویی، هر ۴ روش یک گام رو به جلو استفاده شده‌اند. همچنین سرعت پردازش مدل‌های پیشگویی با کامپیوتر شخصی (2.5 GHz i5 CPU) محاسبه شده است، مدل SVM نسبت به سایر مدل‌ها دارای سرعت بیشتری است، عدم نیاز این مدل به بهینه‌سازی مداوم پارامترها و مصالحه بین سرعت و دقت این مدل را گزینه مناسب‌تری برای استفاده در سامانه‌های DGPS کرده است. هر چند دقت این مدل اندکی کمتر از ENN است اما در حالت کلی پایداری بهتری برای DGPS دارد، بنابراین در آزمایش متحرک از این مدل استفاده می‌شود. در شکل (۱۲) خطای پیشگویی این چهار روش با هم مقایسه شده است، در این شکل رنگ‌های قرمز، سبز، مشکی، آبی به ترتیب نشان‌دهنده خطای پیشگویی روش‌های ENN، RNN، ARMANN و SVM هستند. همان‌طور که مشاهده می‌شود روش مدل ENN با رنگ قرمز کمترین میزان خطا را دارد و پس از آن روش SVM با فاصله کمی از ENN دارای خطای اندکی است. روش ARMANN نسبت به ۳ مدل دیگر دارای خطای مکانی بیشتری است.

جدول ۶- مقایسه RMSE و سرعت مدل‌های ENN، SVM، RNN و ARMANN استفاده شده در پیشگویی


ARMANN	RNN	SVM	ENN	پارامترها
۰/۴۸	۰/۳۸	۰/۱۵	۰/۱۲	RMSE (متر)
۱۲	۴/۳	۱/۲	۳/۶	زمان (ثانیه) CPU

پیشگویی RPCE با ARMANN


با استفاده از الگوریتم ARMANN خطای مکان مرجع را در سه جهت مختصات x, y, z مطابق با ساختار شکل (۲) (قسمت A) پیشگویی شد، نتایج پیشگویی برای ۱۰۰۰ داده آزمایش در شکل (۱۱-الف)، (۱۱-ب) و (۱۱-ج) نشان داده شده است.



الف



ب



ج

شکل ۱۱- پیشگویی خطای مکان مرجع با استفاده از مدل ARMANN


جدول (۵) شاخص‌های آماری خطای پیشگویی مدل ARMANN را نشان می‌دهد. کل خطای RMS این مدل پیشگویی ۰/۴۸ متر و حداکثر مقدار خطا حدوداً ۲ متر است.

جدول ۵- شاخص‌های آماری خطای مدل پیشگویی ARMANN


پارامترها	کمینه	بیشینه	میانگین	واریانس	RMS
Dx	۰/۰۰۳۴	۱/۸۳۴۳	۰/۰۶۷۳۰	۰/۳۵۲۰	۰/۴۹۶۸۷
Dy	۰/۰۰۰۱	۱/۹۷۹۸۳	۰/۰۸۹۹۳	۰/۳۵۳۲	۰/۴۷۰۹۲
Dz	۰/۰۰۰۲	۱/۸۱۴۷	۰/۰۶۶۳	۰/۳۴۲۴	۰/۴۸۸۶۰

(تعیین کننده دقت مکان یابی در نقطه B) مشابه است. با استفاده از فاکتورهای خطای مکان مرجع در نقطه A می توان دقت مکان یابی را به صورت تفاضلی در نقطه B افزایش داد. برای این منظور خطای نقطه A را به مشاهدات مکانی نقطه B اعمال کردیم و نتایج مشابه شکل (۱۵) را در پی داشته است. در شکل (۱۵-الف)، (۱۵-ب) و (۱۵-ج) دیده می شود که خطا کاهش یافته و مشاهدات مکانی دارای دامنه تغییرات کم و حول نقطه میانگین متمرکز شده است.


به منظور سنجش دقت از خطای RMS بهره می بریم، خطای این نقطه که در واقع تفاوت بین خطای نقطه A و خطای نقطه B است، دارای خطای کل RMS برابر با ۰/۴۱ متر است. خطای نقطه B بعد از اعمال خطای نقطه A کاهش می یابد. جدول (۷) شاخص های آماری خطای داده اولیه و خطای بهبود یافته را برای ۱۰۰۰ داده آزمایشی نشان می دهد. مشاهده می شود که ماکزیمم مقدار خطای داده اصلی از ۱۸ متر حداکثر به مقدار ۱/۲ متر در خطای بهبود یافته رسیده است، همچنین خطای RMS در هر سه جهت حدود ۰/۴۵ متر است، در حالی که قبل از بهبود حدود ۷ متر بوده است.



(الف)




(ب)




(ج)


شکل ۱۳ - مشاهدات مکانی ۱۰۰۰ داده نمونه از دو ایستگاه مرجع (آزمایشگاه GPS) و ایستگاه متحرک (آزمایشگاه حجر)



(الف)



(ب)



(ج)


شکل ۱۲ - مقایسه خطای پیشگویی مدل ENN، SVM، RNN و ARMANN

بررسی دقت سامانه مکان یاب تفاضلی


در ادامه دقت سامانه مکان یاب تفاضلی شرح داده می شود.

بررسی دقت سامانه مکان یاب با اعمال مقادیر خطای مکان مرجع نقطه A در نقطه B

با استفاده از ساختار شکل (۲) و قراردادن گیرنده در ساختمان آزمایشگاه تحقیقاتی GPS دانشگاه شهید رجایی ۳۶۰۰ داده جمع آوری شد و میانگین نقاط به دست آمده، به عنوان نقطه مرجع در نظر گرفته شد. هم زمان در ساختمان پژوهشی حجر نیز که به فاصله ۸۴ متری این آزمایشگاه واقع شده، نمونه برداری انجام گرفت. در شکل (۱۳) برای ۱۰۰۰ داده آزمایش مشاهدات مکانی در سه جهت مختصاتی X, Y, Z و برای دو نقطه A و B دیده می شود. همان طور که در شکل های (۱۲-الف)، (۱۲-ب) و (۱۲-ج) دیده می شود؛ روند تغییرات مکانی در دو نقطه A و B مشابه است که این موجب می شود خطای مکانی دارای روند تغییرات مشابه و مقادیر نزدیک به هم شود. در شکل های (۱۴-الف)، (۱۴-ب) و (۱۴-ج) این واقعیت دیده می شود. محدود کردن تعداد ماهواره ها موجب افزایش خطا تا حداکثر ۲۵ متر در هر دو نقطه خواهد شد. اما این خطا را به صورت دیفرانسیلی در ایستگاه ساختمان حجر کاهش می دهیم. در شکل (۱۴) نزدیکی دو منحنی نشان دهنده این است که با مقدار کم اختلاف



(ب)



(ج)


شکل ۱۵- مقایسه مقادیر واقعی و اصلاح شده مشاهدات مکانی در ۳ جهت مختصاتی

بررسی دقت مکان‌یابی سامانه DGPS همراه با مدل‌های پیشگویی


مطابق با نتایج بخش دقت سامانه مکان‌یاب با اعمال مقادیر خطای مکان مرجع نقطه A در نقطه B، و صحت پیاده‌سازی سامانه با فاکتورهای خطای مکان مرجع، اگر مقادیر خطای مکانی مرجع که توسط مدل‌های پیشگویی تقریب زده شده نیز بر ایستگاه کاربر اعمال شود، موجب افزایش دقت می‌شود، همان‌طور که در مقدمه گفته شد، پیشگویی این مقادیر به منظور جبران تأخیرهای گوناگون ارسال و اعمال تصحیح‌ها در مشاهدات ایستگاه کاربر است. بنابراین مقادیر پیشگویی شده توسط ۴ مدل مختلف بر ۱۰۰۰ مشاهده مکانی ایستگاه کاربر اعمال شد. دقت سامانه مکان‌یابی تفاضلی همراه مدل‌های پیشگویی (ENN)، (SVM)، (RNN) و (ARMANN) با یکدیگر مقایسه شده است. دقت مکان‌یابی DGPS با مدل ENN ۰/۵ متر است که در مقایسه با مدل‌های دیگر بهتر است، پس از آن مدل SVM در سامانه DGPS با ۰/۸۵ متر بالاترین دقت را دارد. در شکل (۱۶) خطای مکان‌یابی در نقطه B نشان داده شده است که به صورت تفاضل، میانگین مشاهدات مکانی از مشاهدات مکانی برای ۱۰۰۰ داده آزمایشی است، در شکل دیده می‌شود سامانه DGPS با مدل ENN با رنگ قرمز و مدل SVM با رنگ آبی به ترتیب کمترین خطای مکان‌یابی در نقطه B را دارند.

جدول ۷- مقایسه شاخص‌های آماری خطای داده اصلی و خطای بهبود یافته در نقطه B با اعمال خطای مکان مرجع نقطه A


پارامترها	مختصات X		مختصات Y		مختصات Z	
	بهبود یافته	اصلي	بهبود یافته	اصلي	بهبود یافته	اصلي
بیشینه	۱/۳۲	-۱۸/۳۶	-۲/۱۶	۲۱/۵۶	۱/۳۸	۲۴/۴۱۹
کمینه	۰/۰۰۱	-۰/۴۶	۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	۰/۰۰۹
ج.م.م خطا	۰/۴۶۷	۶/۹۸۳	۰/۴۲۰	۹/۵۹۴	۰/۴۶۵	۸/۹۶۸
میانگین	۰/۱۲۹	-۳/۲۵۵	۰/۰۰۸	۲/۴۵۵	-۰/۰۲۲۵	۱/۶۶۱
واریانس	۰/۱۵۲	۴۸/۸۸	۰/۱۳۳	۸۶/۰۲	۰/۱۳۹	۷۷/۷



(الف)




(ب)



(ج)

شکل ۱۴- مقایسه خطای مشاهدات نسبت به نقطه میانگین (در طول یک ساعت) در دو نقطه A و B






(الف)

یافته است. این تست به صورت پس پردازش انجام شده و مقادیر پیشگویی شده RPCE در سه نقطه C، D و E اعمال شده است. نکته قابل ملاحظه برتری SVM در آزمایش نقطه E است، یعنی جایی که فاصله بین دو ایستگاه به حدود ۶ کیلومتر می‌رسد. SVM به سبب پایداری بهتر و سرعت مناسب‌تر نتایج مکان‌یابی بهتری را نسبت به ENN داشته است. در این آزمایش همچنان RNN در هر سه نقطه نسبت به ARMANN برتری دارد. در نقطه آزمایش C تقریباً دقت سامانه بی‌تغییر مانده است و این به سبب آن است که ماهواره‌های دو ایستگاه تغییر چندانی نداشته است.

جدول ۹- مقایسه دقت مکان‌یابی تفاضلی همراه با روش‌های پیشگویی در نقاط کاربری C، D و E

نقطه	روش	DGPS+GAANN	DGPS+SVM
C	دقت (متر)	۰/۵۱۹	۰/۵۸۱
	روش	DGPS+RNN	DGPS+ARMANN
D	دقت (متر)	۰/۷۳۴۳	۰/۹۲۳
	روش	DGPS+RNN	DGPS+ARMANN
E	دقت (متر)	۰/۸۲۶	۰/۸۰۱
	روش	DGPS+RNN	DGPS+ARMANN

با توجه به کاربردهای بلادرنج، سامانه تفاضلی یک آزمایش متحرک طراحی شد؛ ابتدا، ایستگاه مرجع در موقعیت آزمایشگاه GPS دانشگاه شهید رجایی قرار گرفت و مدل SVM در این ایستگاه استفاده شد. با توجه به برد مناسب فرستنده رادیویی ایستگاه مرجع پیام RPCE پیشگویی شده را برای خودرویی ارسال کرد [۴۷]؛ همچنین سخت‌افزار کاربر درون خودرویی با سرعت حدود $20 \frac{km}{h}$ قرار داده و خودرو از حدود ۲۰۰ متری ایستگاه مرجع حرکت داده شد. مختصات دقیق ۱۵ نقطه با استفاده از نمونه‌برداری مکانی مشخص شد. خودرو از این ۱۵ نقطه عبور کرده و مشاهدات مکانی در کارت حافظه این ایستگاه ذخیره گردید. خودرو مسیر طراحی شده برای تست را ۵۰ بار طی کرد و خطای RMS مکان‌یابی برای سنجش دقت مکان‌یابی استفاده می‌شود. جدول (۱۰) نتایج این تست را منعکس می‌کند. شکل (۱۷) آزمایش انجام شده را در سه جهت مختصاتی x، y و z برای ۱ تکرار آزمون نشان می‌دهد. همان‌طور که دیده می‌شود، مکان‌یابی DGPS با مدل SVM



شکل ۱۶- مقایسه الگوریتم‌های پیشگویی در کاهش خطای مکانی نسبت به نقطه میانگین در نقطه B در سامانه DGPS

در جدول (۸) دقت سامانه مکان‌یابی تفاضلی که در آن‌ها چهار روش مختلف پیشگویی برای افزایش دقت استفاده شده آمده است.

جدول ۸- مقایسه دقت مکان‌یابی تفاضلی همراه با روش‌های پیشگویی براساس پارامتر خطای RMS

روش	DGPS+GAANN	DGPS+SVM
دقت (متر)	۰/۵	۰/۵۸
روش	DGPS+RNN	DGPS+ARMANN
دقت (متر)	۰/۷۳	۰/۹۲

بحث و بررسی

در این مقاله، برای پیاده‌سازی DGPS از فاکتورهای RPCE استفاده شد. استفاده از این فاکتورها تا حد زیادی به اشتراک ماهواره‌های دو ایستگاه مرجع و کاربر ارتباط دارد، با افزایش فاصله بین دو ایستگاه، این اشتراک کم می‌شود، به منظور سنجش تأثیر این پارامتر ایستگاه کاربر به ترتیب در نقاط C، D و E و با فاصله‌های تعریف شده قرار گرفت. از شاخص RMS برای مقایسه دقت مکان‌یابی در این نقاط استفاده شده است. مطابق با جدول (۹) ملاحظه می‌شود که در طول ۱۰۰۰ ثانیه با افزایش فاصله دو ایستگاه دقت مکان‌یابی در هر ۴ الگوریتم کاهش

SVM توأم دارای دقت و سرعت مناسبی است که امکان پیاده‌سازی سامانه موقعیت‌یاب بلادرنگ را فراهم می‌کند. اعمال تصحیح‌ها پیشگویی شده روی نقطه کاربر دقت سامانه مکان‌یاب تا ۰/۵ متر افزایش می‌دهد.

مراجع


- [1] Morgan-Owen, G. J. and Johnston, G. T., "Differential GPS Positioning," *IEEE Transactions on Electronics & Communication Engineering*, Vol. 7, Issue 1, 1995, pp.11-21.
- [2] Mosavi, M. R. and Nabavi, H., "Improving DGPS Accuracy using Neural Network Modeling," *Australian Journal of Basic and Applied Sciences*, Vol. 5, No. 5, 2011, pp. 848-856.
- [3] Mosavi, M. R., Mohammadi, K., and Refan, M. H., "A New Approach for Improving of GPS Positioning Accuracy by Using an Adaptive Neuro fuzzy System, Before and After S/A Is Turned Off," *International Journal of Engineering Science, Iran University of Science and Technology*, Vol. 15, No. 1, 2004, pp. 95-108.
- [4] Mosavi S.M.R., Rahemi, N. and Mirza-Kuchaki, S., "Precise Positioning in GPS Receivers for Very High Elocities Using Combination of Recursive Least Squares and Fuzzy Logic," Vol. 7, No. 3, 2015, pp.63-72.
- [5] Kobayashi, K., Ka, C. C., Watanabe, K., and Munekata, F., "Accurate Differential Global Positioning System via Fuzzy Logic Kalman Filter Sensor Fusion Technique," *IEEE Transactions on Industrial Electronics*, Vol. 45, No. 3, 1998, pp.510-518.
- [6] RTCM Special Committee No. 104. "RTCM Recommended Standards for Differential NAVSTAR GPS Service." Radio Technical Committee for Maritime Services. Paper 134-89/SC104- 68. Washington DC (USA), 1990.
- [7] Keith, A., Using Wide Area Differential GPS to Improve Total System Error for Precision Flight Operations, (PhD Thesis) Stanford University (USA), 2000.
- [8] Availabel, [on line]: <http://www.u-blox.com/en/download/documents-a-resources/gps-solutions.html>.
- [9] Refan, M. H., Mohammadi, K. and Mosavi, M. R., "Improvement on a Low Costpositioning Sensor Accuracy," *IEEE Conference on Sensors, Malaysia*, 14-18 July, 2003, pp. 9-14.
- [10] Donald, K. D. Mc., "The Modernization of GPS: Plans, New Capabilities, and the Future Relationship to Galileo," *Journal of Global Positioning System*, Vol. 1, No.1, 2002, pp.1-17.
- [11] Jwo, D. J. and Lai, C. C., "Neural Network-based GPS GDOP Approximation and Classification," *Journal of GPS Solutions*, Vol. 11, No. 1, 2007, pp.51-60.
- [12] Mosavi, M. R. and Azami, H., "Applying Neural Network for Clustering of GPS Satellites," *Journal of Geoinformatics*, Vol. 7, No. 3, 2011, pp. 7-14.
- [13] GÜNGÖR, Z. and ÜNLER, A., "K-harmonic Means Data Clustering with Simulated Annealing Heuristic," *Journal of Applied Mathematics and Computation*, Vol. 184, Issue 2, 2007, pp.199- 209.
- [14] Saraf, M., Mohammadi, K. and Mosavi, M. R., "Bayesian Framework on GPS GDOP Classification,"

بهبود دقت سامانه مکان‌یاب تفاضلی با استفاده از پیشگویی فاکتورهای خطای مختصات مکان مرجع


دقیق‌تر است و مشاهدات در ۱۵ نقطه آزمونی به ۱۵ نقطه مرجع نزدیک‌تر هستند. در حالی که مشاهدات GPS از نقاط مرجع فاصله دارد.

جدول ۱۰- مقایسه شاخص RMS خطای داده اصلی و خطای بهبود یافته ۱۵ نقطه با اعمال RPCE در آزمون پویا با الگوریتم SVM استفاده شده در ایستگاه مرجع


پارامترها	X		Y		Z	
	GPS	DGPS	GPS	DGPS	GPS	DGPS
ج.م.م.خطا	۰/۶۸	۱/۸۰	۰/۷۱	۲/۳۰	۰/۷۳	۲/۶۳



(الف)



(ب)



(ج)

شکل ۱۷- نتایج شبیه‌سازی آزمون پویا

نتیجه‌گیری

در این مقاله، از فاکتورهای خطای مکان مرجع برای افزایش دقت DGPS استفاده و نشان داده شد در صورتی که در ایستگاه مرجع و متحرک از ماهواره‌های یکسانی استفاده شود، خطا در گیرنده متحرک جبران می‌شود، خطای RMS در این حالت از حدود ۷ متر به ۰/۴ متر رسید. برای پیاده‌سازی مدل از یک گیرنده ارزان قیمت بهره گرفته شد، برای پیشگویی فاکتورهای خطای مکان مرجع از ۴ الگوریتم ENN، SVM، RNN و ARMANN استفاده شد، مدل ENN با خطای RMS، ۰/۱۲ متر بهترین عملکرد را داشت. مدل

- [31] Farag, A. and Refaat, M.M., *Regression Using Support Vector Machines: Basic Foundations*, Technical Report, December 2004.
- [32] Minqiang, P., Dehuai, Z. and Gang, X. u., "Temperature Prediction of Hydrogen Producing Reactor Using SVM Regression with PSO-SVM", *Journal of Computers*, Vol. 5, No. 3, 2010, pp. 388-393.
- [33] Cai, X., Zhang, N., Vena, G.K. and Unsch, D.C.W., "Time Series Prediction with Recurrent Neural Networks Trained by a Hybrid PSO-EA Algorithm," *Journal of Neuro Computing*, Vol. 70, Issue 13-15, pp. 2342-2353, 2007.
- [34] Graves, A. and Schmidhuber, J., "Offline Handwriting Recognition with Multi-dimensional Recurrent Neural Networks," *Advances in Neural Information Processing Systems*, 2009.
- [35] Bengio, Y., Simard, P. and Frasconi, P., "Learning Long-Term Dependencies with Gradient Descent is Difficult," *IEEE Transactions on Neural Networks*, Vol. 5, Issue 2, 1994, pp. 157-166.
- [36] Hochreiter, S., Bengio, Y., Frasconi, P. and Schmidhuber, J., "A Field Guide to Dynamical Recurrent Neural Networks, Chapter Gradient flow in Recurrent Nets: the Difficulty of Learning Long-Term Dependencies," *IEEE press*, 2001.
- [37] Bod'en, M. and Wiles, J., "Context-Free and Context-Sensitive Dynamics in Recurrent Neural Networks," *Connection Science*, Vol. 12, No. 3, 2000.
- [38] Mosavi, M.R., "A Comparative Study between Performance of Recurrent Neural Network and Kalman Filter for DGPS Corrections Prediction," *IEEE Conference on Signal Processing, Beijing, China*, 2004.
- [39] Werbos, P.J., *Beyond Regression: "New Tools for Prediction and Analysis in the Behavioral Sciences. Cambridge,"* [Ph.D. Thesis], MA: Harvard University, 1974.
- [40] Zhang, G.P., "Time Series Forecasting using a Hybrid ARIMA and Neural Network Model," *Neuro Computing*, Vol. 50, 2003, pp. 159-175.
- [41] Zhang, S. and Liu, R., "A Rapid Algorithm for Online and Real-time ARMA Modeling," *Signal Processing Proceedings, 2000. WCCC-ICSP 2000, 5th International Conference*, 2003, pp. 230-233,
- [42] Scha, C. and Schroder, D., "An Application of General Regression Neural Network to Nonlinear Adaptive Control," *Processing of 5th European Conference on Power Electronics and Applications*, 1993, pp. 219-224.
- [43] Wang, C.C., "A Comparison Study between Fuzzy Time Series Model and ARIMA Model for Forecasting Taiwan Export," *Expert Systems with Applications*, Vol. 38, Issue 8, 2011, pp. 9296-9304.
- [44] Jwo, D.J., Lee, T.Sh. and Tseng, Y.W., "ARMA Neural Networks for Predicting DGPS Pseudorange Correction", *the Journal of Navigation*, Vol. 57, Issue 02, 2004, pp. 275-286.
- [45] Alsmadi, Kh.M.S., Omar, Kh.B. and Noah, Sh.A., "Back Propagation Algorithm: The Best Algorithm among the Multi-layer Perceptron Algorithm", *Journal of Computer Science and Network Security*, Vol. 9, No. 4, 2009, pp. 378-383.
- [46] Dameshghi, A., *Design and Implementation of RTDGPS by Predictor's Algorithms on Low Cost GPS Receivers, (M.Sc Thesis), Part 6, Jul 2013 (In Persian).*
- Journal of Computers & Electrical Engineering*, Vol. 37, 2011, pp.1009-1018.
- [15] Indriyatmoko, A. T., Kang, Y. J., Lee, G. I., Jee, Y. B., and Kim, J., "Artificial Neural Network for Predicting DGPS Carrier Phase and Pseudo-Range Correction," *Journal of GPS Solutions*, Vol. 12, No. 4, 2008, pp. 237-247.
- [16] Katio, D. and Stankovio, S., "Fast Learning Algorithms for Training of Feedforward Multilayer Perceptrons Based on Extended Kalman Filter," *IEEE Conference on Neural Networks*, Vol. 1, 1996, pp. 196-201.
- [17] Rocha, M., Cortez, P. and Neves, J., "Ensemble of Artificial Networks with Heterogeneous Topologies," *Proceeding of the Fourth Symposium on Engineering of Intelligence Systems*, 2004.
- [18] Yao, X., "Evolving Artificial Neural Networks," *Proceedings of IEEE*, Vol. 87, No. 9, 1999, pp. 1423 - 1447.
- [19] Phansalkar, V. V. and Sastry, P. S., "Analysis of the Back-Propagation Algorithm with Momentum," *IEEE Transactions on Neural Networks*, Vol. 5, No. 3, 1994, pp. 505-506.
- [20] Yao, X., "A Review of Evolutionary Artificial Neural Networks," *Internatoinal Journal Intelligent System*, Vol. 8, No. 4, 1993, pp. 539-567.
- [21] Huang, C. Y., Chen, L., Chen, Y. and chang, M., "Evaluation the Process of a Genetic Algorithm to Improve the Back-Propagation Network: A Mont Carlo Study," *Expert Systems with Applications*, Vol. 36, Issue 2, Part1, 2009, pp. 1459-1465.
- [22] Frank, H. F., Leung, Lam, H. K., Ling, S. H. and Tam, P. K. S., "Tuning of the Structure and Parameters of a Neural Network Using an Improved Genetic Algorithm," *IEEE Transactions on neural networks*, Vol. 14, No. 1, 2003, pp. 79-88.
- [23] Pal, M. and Deswal, S., "Modeling Pile Capacity using Support Vector Machines and Generalized Regression Neural Network," *Journal of Computing in Civil Engineering, ASCE*, Vol. 134, No. 7, 2008, pp. 1021-1024.
- [24] Dibike, Y.B., Velikov, S., Solomatine, D. and Abbot, M.B., "Model Induction with Support Vector Machines- Introduction and Applications," *Journal of Computing in Civil Engineering, ASCE*, Vol. 15, No. 3, 2001, pp. 208-216.
- [25] Corinna, C. and Vapnik, V., *Support-Vector Networks, Machine Learning*, Vol. 20, Kluwer Academic Publishers, Boston, 1995.
- [26] Burgers, C.J.C., "A Tutorial on Support Vector Machines for Pattern Recognition," *Data Mining and Knowledge Discovery*, Vol. 2, 1998, pp. 121-167.
- [27] Cao, L.J. and Tay, F.E.H., "Support Vector Machine with Adaptive Parameters in Financial Time Series Forecasting," *IEEE Transactions on Neural Network*, Vol. 14, No. 6, 2003, pp. 1506-1518.
- [28] Ganapathiraju, A., *Support Vector Machines for Speech Recognition, [PhD Thesis], Mississippi State University, USA*. 2001.
- [29] Drucker, H.C., Burges Kaufman, L., Smola, A. and Vapnik, V., "Support Vector Regression Machines," *MIT Press, Cambridge*, Vol. 9, 1997, pp. 155-161.
- [30] Smola, A.J. and Scolkopf, B., *Tuotorial on Support Vector Regression*, Neuro COLT2 Technical Report Series, NC2-TR-1998-03, 1998.