

پیش‌بینی آنومالی سطح دریا با استفاده از روش تجزیه به توابع حالت‌های ذاتی و شبکه عصبی تابع پایه شعاعی

حامد کیا^{۱*} و بهزاد وثوقی^۲

۱. دانش‌آموخته کارشناسی ارشد، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۲. دانشیار، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

(دریافت: ۱۴۰۰/۳/۲۹، پذیرش نهایی: ۱۴۰۰/۱۰/۲۰)

چکیده

آنومالی سطح دریا (Sea Level Anomaly, SLA) به‌عنوان کمیتی که بیان‌کننده اختلاف ارتفاع سطح لحظه‌ای آب با مقدار متوسط سطح آب در یک بازه زمانی می‌باشد در مطالعه وضعیت سطح آب مناطق مختلف دارای اهمیت چشم‌گیری می‌باشد. منطقه آبی دریاچه خزر به‌عنوان یکی از دو منبع مهم آبی برای کشور ایران از اهمیتی استراتژیک برخوردار است. بدین‌منظور در این پژوهش با استفاده از داده‌های گذر ۹۲ مأموریت‌های ارتفاع‌سنجی ماهواره‌ای (توپکس پوزیدون، جیسون ۱، جیسون ۲ و جیسون ۳)؛ عبوری از منطقه آبی خزر به مشاهده تغییرات کمیت آنومالی سطح دریا در این منطقه از سال ۱۹۹۳ تا سال ۲۰۲۰ پرداخته شده است. سپس این کمیت با استفاده از روش تجزیه به حالت‌های ذاتی (Empirical Mode Decomposition, EMD) به‌عنوان روشی کارا در جداسازی فرکانس‌های تشکیل‌دهنده یک سیگنال مورد آنالیز قرار گرفته‌است و سپس با استفاده از شبکه عصبی تابع پایه شعاعی (Radial Basis Function, RBF) یک شبکه به‌منظور پیش‌بینی آنومالی سطح دریا ایجاد شده است. ۹ فرکانس غالب به‌همراه یک ترند نتیجه تجزیه سیگنال مدنظر در این پژوهش می‌باشد که در نهایت منجر به پارامترهای؛ مجذور میانگین خطا به میزان ۰/۰۲۹ متر و ۰/۰۳۴ متر به‌همراه ضریب همبستگی ۰/۹۹ و ۰/۹۷ به‌ترتیب در دو مرحله آموزش و تست شبکه عصبی می‌شود.

واژه‌های کلیدی: ارتفاع‌سنجی ماهواره‌ای، آنالیز سیگنال، روش تجزیه به حالت‌های ذاتی، تابع حالت‌ذاتی، شبکه عصبی تابع پایه شعاعی.

۱. مقدمه

پرداخت و بیان کرد که تغییرات سطح آب در مناطق آبی محلی می‌تواند اختلاف زیادی با تغییرات سطح آب در مقیاس جهانی داشته باشند و از شرایط خاص آب‌وهوایی به‌عنوان دلیل عمده این تغییرات نام برد. همچنین در مقیاس بزرگ جهانی می‌توان از مدل‌های پویا با توجه به عوامل مهمی همچون دما، برای پیش‌بینی‌های طولانی مدت استفاده کرد (ویلند و همکاران، ۲۰۰۳).

با استفاده از داده‌های تایدگیج (چرچ و وایت، ۲۰۰۶ و هولگیت، ۲۰۰۷) میزان افزایش ارتفاع سطح آب را در قرن بیستم سالانه بین ۱/۵ تا ۲ میلی‌متر در سال تقریب زدند. با روی کارآمدن ارتفاع‌سنجی ماهواره‌ای، استفاده از داده‌های ارتفاع‌سنجی به‌منظور مطالعه تغییرات سطح آب مدنظر محققین قرار گرفت. با استفاده از داده‌های ماهواره‌های توپکس پوزیدون و جیسون ۱ در بازه زمانی

تأثیرات افزایش یا کاهش سطح دریا بر محیط‌زیست و سایر مسائل مهم باعث شد تا تحقیقاتی برای اندازه‌گیری میزان افزایش یا کاهش سطح آب در مقیاس جهانی و محلی انجام گیرد (بنداس و همکاران، ۲۰۱۶؛ کازناوه و کوزانت، ۲۰۱۴؛ ایمانی و همکاران، ۲۰۱۴). به‌گونه‌ای که شناخت قوانین حاکم بر دریا و پیش‌بینی تغییرات آینده آن اصلی اساسی می‌باشد (اسلانگن و همکاران، ۲۰۱۲). استفاده از مدل‌های دینامیکی، داده‌های تایدگیج و داده‌های ماهواره‌ای برای مطالعه ارتفاع سطح آب بسیار رواج یافته‌است. با استفاده از یک مدل دینامیکی پویا و استفاده از آنالیزهای موجک به‌منظور حذف ترند از سری زمانی سطح آب، و استفاده از مدل میانگین متحرک، به بررسی ارتفاع سطح آب پرداخته شد (ژیانوفن، ۲۰۱۴). استامر (۲۰۱۸) به بررسی تغییرات محلی ارتفاع سطح آب

(Square) برای حذف روند و تغییرات پرریودیک سری زمانی آنومالی سطح دریا استفاده شد و از شبکه‌های عصبی برای پیش‌بینی مقادیر باقی‌مانده استفاده شد (ژائو و همکاران، ۲۰۱۹).

در سال‌های اخیر، تأثیر تغییر سطح دریا بر محیط زندگی انسان بیشتر و بیشتر مورد توجه جامعه جهانی و دولت‌های کشورهای ساحلی قرار گرفته و افزایش سطح دریا به یک موضوع مهم زیست‌محیطی جهانی تبدیل شده است. هدف از مطالعه تغییر سطح دریا شناسایی قوانین تغییرات سطح دریا و پیش‌بینی تغییرات آینده و تأثیر بالقوه آن بر جامعه بشری است. برای پیش‌بینی یک سری زمانی نیاز است تا این سری به حالت ایستا (Stationary) درآید و روند و تغییرات فصلی از مشاهدات حذف شوند تا وابستگی و رینانس و میانگین به زمان کنار گذاشته شود. بدین منظور استفاده از روش‌های مختلفی برای ایستاکردن یک سری زمانی پیشنهاد و استفاده شده است. استفاده از روش تجزیه به حالت‌های ذاتی (EMD) یک سیگنال که زمینه‌ساز تشکیل توابع حالت ذاتی (IMF، Intrinsic Mode Function) که شامل بخش‌هایی از سیگنال با فرکانس تقریباً یکسان هستند؛ جهت آنالیز و تجزیه و جداسازی روند و تغییرات فصلی سیگنال مدنظر قرار گرفته است.

دریاچه خزر به‌عنوان بزرگ‌ترین دریاچه جهان و یا به اصطلاح بزرگ‌ترین منطقه آبی محصور در جهان در شمال ایران قرار گرفته است. این منطقه آبی مهم به‌عنوان یکی از اصلی‌ترین منابع درآمد برای کشورهای حاشیه خود تبدیل شده است. به‌طوری‌که دارای منابع مهم نفتی و گازی و همچنین اصلی‌ترین منبع ماهیان خاویاری به‌عنوان یکی از گران‌ترین منابع خوراکی در دنیا می‌باشد. این منطقه استراتژیک به‌عنوان واسطه‌ای برای اتصال شرق و غرب کره زمین شناخته می‌شود. علاوه بر بعد اقتصادی و تجاری، از بعد نظامی نیز دریاچه خزر دارای اهمیت فراوانی می‌باشد؛ به‌گونه‌ای که مانورهای متعدد نظامی هر ساله توسط کشورهای حاشیه آن برگزار می‌شود. به دلایل

۱۹۹۳ تا ۲۰۰۳ میانگین افزایش متوسط ۲/۸ میلی‌متری در ارتفاع سطح آب را تخمین زدند. در مطالعات انجام شده بسیاری از محققین روند خطی تغییرات سطح دریا را برآورد و پیش‌بینی کردند (لولیت و همکاران، ۲۰۰۴). اما تغییرات سطح دریا دارای پیچیدگی بیشتری می‌باشد و بنابراین باید روند غیرخطی و تغییرات پرریودیک و تغییرات تصادفی آن را مدنظر قرار داد. در مطالعه پیش‌بینی غیرخطی، الگوریتم‌های موجود در حال حاضر عمدتاً شامل تجزیه و تحلیل سری‌های زمانی، شبکه عصبی (Neural Network)، روش‌های ماشین بردار پشتیبان (SVM) و ترکیبات این روش‌ها است (سان و وانگ، ۲۰۱۲). رامستورف در سال ۲۰۰۷ با استفاده از روش تجربی پیش‌بینی کرد که تا سال ۲۱۰۰ افزایش ۷۰ تا ۱۳۰ سانتی‌متری در ارتفاع آب سطح دریا داشته باشیم (رامستورف، ۲۰۰۷).

استفاده از شبکه‌های عصبی مصنوعی به‌منظور پیش‌بینی ارتفاع سطح آب در مناطق مختلف نیز رو به رشد بوده است. برای نخستین بار شبکه‌های عصبی را برای بهبود پیش‌بینی ارتفاع سطح آب در سواحل شمالی آلمان مورد استفاده قرار گرفت (راسکه، ۱۹۹۷). به‌همین ترتیب وزیر (۱۹۹۷) با استفاده از شبکه عصبی مصنوعی و مدل ARIMA به پیش‌بینی یک ماهانه ارتفاع سطح آب دریای خزر از طریق داده‌های تاییدگیج از ژانویه ۱۹۸۶ تا دسامبر ۱۹۹۳ در بندرانزلی اقدام کرد. ایمانی و همکاران (۲۰۱۴) به پیش‌بینی آنومالی سطح دریا با استفاده از داده‌های ۱۵ ساله مأموریت توپکس پوزیدون و جیسون ۱ پرداختند. این محققین از شبکه‌های عصبی مصنوعی پرسپترون و تابع پایه شعاعی برای این منظور استفاده کردند. قربانی و همکاران (۲۰۱۰) با استفاده از برنامه‌نویسی ژنتیک (Genetic Programming) و مقایسه آن با شبکه‌های عصبی مصنوعی به پیش‌بینی ارتفاع سطح آب پرداخت (قربانی و همکاران، ۲۰۱۰). همچنین از روش ترکیبی کمترین مربعات و شبکه عصبی به پیش‌بینی آنومالی سطح دریای چین پرداخته شد. از روش کمترین مربعات (Least

هواشناسی ECMWF در اختیار کاربران قرار می‌گیرد. تصحیح بایاس وضعیت دریا ΔR_{ssb} که حاکی از این امر می‌باشد که بخش قعر موج پالس دریافتی از ماهواره را با توان بیشتری باز می‌گرداند، نیز به‌عنوان یکی دیگر از تصحیحات جوی شناخته می‌شود که با استفاده از مدل‌های مختلف پارامتریک و غیرپارامتریک متأثر از عواملی مانند سرعت باد و اختلاف ارتفاع سطح آب می‌توان محاسبه کرد. h_{tides} بیان‌کننده تصحیحات جزرومدی، h_{atm} نشان‌دهنده تصحیحات بارگزاری جو می‌باشد که بیان‌کننده این حقیقت است که سطح آب بدین‌صورت عمل می‌کند که در هنگامی که فشار جو بالا باشد، سطح آب پایین می‌آید و هنگامی که فشار جو کم شود سطح آب بالا می‌آید. تمامی داده‌های فوق در فایل‌های مربوط به داده‌های ارتفاع‌سنجی ماهواره‌ای که به فرمت NetCDF ارائه می‌شود، موجود است. این داده‌ها به‌عنوان داده‌های سطح دو یا داده‌های GDR در پایگاه‌های داده‌های ارتفاع‌سنجی موجود می‌باشد. این اطلاعات از طریق همکاری و ارتباط با پایگاه‌ها و نهادهای مختلفی در اختیار کاربران قرار می‌گیرد. به‌عنوان مثال داده‌های مرتبط با تصحیحات تروپوسفری تر و خشک از طریق داده‌های ECMWF و همچنین داده‌های تصحیحات یونسفری توسط مدل‌های جهانی یونسفری (GIM) به‌عنوان بخشی از اطلاعات موجود در فایل‌های ارتفاع‌سنجی با کاربران به اشتراک گذاشته می‌شود.

قابل ذکر است که بخشی از رابطه (۱) که در داخل براکت قرار گرفته است، تحت عنوان ارتفاع لحظه‌ای سطح آب (Sea Surface Height, SSH) شناخته می‌شود.

در صورت اعمال تصحیحات ژئوفیزیکی مانند تصحیحات جزرومدی که خود شامل سه بخش جزرومد الاستیک اقیانوسی، جزرومد زمین جامد و جزرومد قطبی می‌شود، به‌همراه تصحیح ناشی از بارگزاری جو و کسر موارد گفته شده از سطح متوسط دریا که توسط مدل‌هایی مانند مدل CLS2015 به‌عنوان آخرین مدل ارائه‌شده حاصل از

فوق، اطلاع و آگاهی از ارتفاع سطح آب و تغییرات آن به‌خصوص در طی چند دهه گذشته اهمیتی روزافزون پیدا کرده است، اما بر خلاف این اهمیت، مطالعات زیادی برای بررسی ارتفاع سطح آب صورت نگرفته است؛ بنابراین در این پژوهش با استفاده از داده‌های ارتفاع‌سنجی ماهواره‌ای پایشی بر تغییرات سطح آب در این منطقه صورت گرفته است. به‌گونه‌ای که پوششی بر پارامتر آنومالی سطح دریا و تغییرات آن از سال ۱۹۹۳ تا سال ۲۰۲۰ ارائه شده است. سپس با استفاده از روش تجزیه به حالت‌های ذاتی، سیگنال آنومالی سطح دریا مورد تجزیه قرار گرفته است و به کمک شبکه عصبی تابع پایه شعاعی، فرآیند ایجاد یک شبکه پیش‌بینی انجام گرفت.

۲. کمیت آنومالی سطح دریا

در پژوهش‌های مختلف، محققین از کمیت‌های مختلفی برای مطالعات سطح دریا استفاده می‌کنند. کمیت آنومالی سطح دریا که به‌طور تقریبی عبارت است از اختلاف بین سطح لحظه‌ای آب و سطح متوسط آن به‌عنوان پارامتری مورد توجه برای پژوهش‌گران، معرفی می‌شود. این پارامتر را می‌توان به‌طور دقیق طبق رابطه (۱) بیان کرد:

$$SLA = [H - R_{obs} - (\Delta R_{dry} + \Delta R_{wet} + \Delta R_{iono} + \Delta R_{ssb})] - (h_{tides} + h_{atm}) - h_{MSS} \quad (1)$$

در این رابطه H عبارت است از فاصله بین ماهواره تا سطح مرجع که یک بیضوی می‌تواند تعریف شود. R_{obs} عبارت است از فاصله اندازه‌گیری شده بین آنتن ماهواره ارتفاع‌سنج تا سطح بازتابنده، که در این‌جا سطح آب می‌باشد. این کمیت به‌دلیل عبور از جو زمین دچار یک‌سری تأخیرها می‌شود و بنابراین نیاز است تا یک‌سری تصحیحات به این مقدار مشاهده‌شده اعمال شود. این تصحیحات که به تصحیحات جوی معروف می‌باشند شامل تصحیح یونسفری ΔR_{iono} ؛ با استفاده از مدل‌هایی مانند نقشه‌های یونسفری جهانی، تصحیحات تروپوسفری خشک ΔR_{dry} و تر ΔR_{wet} با استفاده از داده‌های

داده‌های ارتفاع‌سنجی ماهواره‌ای، می‌توان به کمیت آنومالی سطح دریا دسترسی پیدا کرد (آندرسن و شارو، ۲۰۱۱).

۳. روش تجزیه سیگنال به حالت‌های ذاتی

روش‌های مختلفی برای آنالیز یک سیگنال وجود دارد. نمایش یک تابع بر حسب مجموعه کاملی از توابع فوریه اولین بار توسط ژوزف فوریه، ریاضی‌دان و فیزیک‌دان فرانسوی بین سال‌های ۱۸۰۶-۱۸۰۲ طی رساله‌ای در آکادمی علوم فرانسه راجع به پخش گرما، به کار گرفته شد. یک تبدیل فوریه برای تجزیه فرکانسی سیگنال استفاده می‌شود؛ اما نمایش مکانی-زمانی از وقوع آن فرکانس ارائه نمی‌شود. بدین منظور تبدیل فوریه پنجره کوتاه به عنوان راه‌حلی برای حل این موضوع مورد استفاده قرار گرفت. در این تبدیل با قراردادن تعدادی پنجره با طول یکسان در طول یک سیگنال از هرکدام از این بخش‌های سیگنال تبدیل فوریه گرفته می‌شود. اما ایراد بزرگ این روش در این است که یک سیگنال ممکن است دارای فرکانس‌های مختلفی باشد و همچنان پریود هرکدام از این فرکانس‌ها نیز متفاوت خواهد بود؛ بنابراین تبدیل فوریه پنجره کوتاه نیز نمی‌تواند به خوبی چنین سیگنال‌هایی را پردازش کند؛ بنابراین در سال ۱۹۰۸ میلادی با تلاش‌های آلفرد هار و با ارائه موجک هار که یک تابع قطعه‌وار ثابت می‌باشد توانست به یک نمایش طیفی-زمانی مناسب از سری‌های زمانی دسترسی پیدا کند (هوآنگ و همکاران، ۱۹۹۸). در تبدیل موجک سری در دامنه زمان را از فیلترهای بالاگذر و پایین گذر عبور می‌دهند که سری را به دو قسمت فرکانس بالا و پایین تقسیم می‌کند. این روند برای هر قسمت تکرار می‌شود و در هر مرحله قسمتی از سری که معمولاً قسمت فرکانس بالا است، تجزیه نمی‌شود. اما مهم‌ترین ایراد تبدیل موجک عدم تشخیص فرکانس لحظه‌ای می‌باشد؛ یعنی به جای ارائه مقدار عددی فرکانس سیگنال، یک بازه ارائه می‌دهد. بنابراین به روشی نیاز است تا بتوان ویژگی‌های یک

سیگنال را بدون هیچ‌گونه پیش‌فرضی به دست آورد و همچنین به تعیین فرکانس لحظه‌ای سیگنال نیز دست یابیم. هوآنگ و همکاران (۱۹۹۸) روش تجزیه به حالت‌های ذاتی را ارائه دادند که با تجزیه سیگنال به توابع حالت ذاتی یا مودها به آنالیز سیگنال می‌پردازند. تجزیه بر اساس استخراج مستقیم انرژی مرتبط با مقیاس زمانی مختلف ذاتی می‌باشد که مهم‌ترین پارامتر سیستم می‌باشد. این توابع حالت ذاتی را می‌توان با استفاده از تبدیل هیلبرت آنالیز کرد و به فرکانس لحظه‌ای رسید. تبدیل هیلبرت یک تبدیل خطی می‌باشد که نخستین بار توسط هیلبرت برای حل مسئله‌ای موسوم به ریمان-هیلبرت از آن استفاده کرد. کاربرد این تبدیل در آنالیز سیگنال یافتن فرکانس لحظه‌ای می‌باشد. بنابراین ما می‌توانیم هر رویدادی را در زمان بر روی محور فرکانس محلی‌سازی کنیم. به تجزیه می‌توان به عنوان گسترش داده‌ها به صورت حالت‌های ذاتی نگاه کرد. سپس این حالت‌های ذاتی که بر اساس منتج از داده‌ها می‌باشند، به عنوان پایه برای گسترش خطی و غیرخطی داده‌ها می‌باشند. می‌توان گفت محلی بودن و سازگاری شرط اساسی برای گسترش سری‌های زمانی غیرخطی و غیرثابت می‌باشند. اصل این پایه بر اساس مقیاس‌های زمانی فیزیکی است که تغییرات پدیده‌ها را مشخص می‌کند. انرژی محلی و فرکانس لحظه‌ای به عنوان پارامترهایی است که از تبدیل هیلبرت حاصل می‌شود و یک توزیع کامل زمان-فرکانس-انرژی از داده‌ها در اختیار می‌گذارد. چنین نمایشی به عنوان طیف هیلبرت شناخته می‌شود و برای تجزیه و تحلیل داده‌های غیرثابت و غیرایستا ایده‌آل خواهد بود (هوآنگ و همکاران، ۱۹۹۸). یک تابع حالت ذاتی تابعی است که دو شرط زیر را تأمین می‌کند:

- در کل مجموع داده‌ها تعداد موارد اکستریم و صفر باید برابر باشد یا حداکثر اختلاف یک داشته باشد.
- در هر نقطه مقدار متوسط پوش توسط ماکزیمم محلی و پوش تعریف شده توسط مینیمم محلی صفر باشد.
- نام عملگر حالت ذاتی به این دلیل است که نشان‌دهنده

فرکانس لحظه‌ای به هر IMF از روش تجزیه به حالت‌های ذاتی استفاده کنیم.

در هر زمان مشخص، داده‌ها ممکن است بیش از یک حالت نوسانی یا یک فرکانس را شامل شوند و بنابراین نمی‌توان همه داده‌ها را IMF دانست. بنابراین استفاده از تبدیل ساده هیلبرت در آنالیز فرکانسی برای این گونه داده‌ها نمی‌تواند مفید باشد. در نتیجه باید ابتدا داده‌ها را تجزیه کرد. این تجزیه بر اساس فرض‌های زیر می‌باشد:

الف) سیگنال حداقل دارای دو اکستریم باشد، یک ماکزیمم و یک مینیمم.

ب) مشخصه مقیاس زمانی با گذشت زمان بین دو اکستریم قابل بیان است.

ج) اگر داده‌ها عاری از اکستریم باشند و دارای نقطه عطف؛ می‌توان با چندبار تفکیک آنها نقاط اکستریم‌شان را کشف کرد. نتایج نهایی با ادغام مؤلفه‌های تجزیه شده به دست می‌آید.

در استفاده از روش EMD مراحل زیر به ترتیب انجام خواهد شد:

در استفاده از روش EMD مراحل زیر به ترتیب انجام خواهد شد:

- تعیین نقاط ماکزیمم و مینیمم محلی سیگنال ورودی
- ایجاد منحنی پوش بالا با استفاده از برازش یک منحنی چندجمله‌ای بر نقاط ماکزیمم محلی
- ایجاد منحنی پوش پایین با استفاده از برازش یک منحنی چندجمله‌ای بر نقاط مینیمم محلی
- میانگین‌گیری از منحنی‌های پوش بالا و پوش پایین
- تفریق میانگین منحنی پوش بالا و پوش پایین از سیگنال ورودی

$$X(t) - m_1 = h_1 \quad (8)$$

که در این رابطه m_1 بیان‌کننده میانگین پوش بالا و پوش پایین می‌باشد و h_1 که حاصل اختلاف سیگنال اصلی و میانگین پوش بالا و پایین است تحت عنوان مؤلفه اول شناخته می‌شود.

سپس فرآیند غربال را به منظور مقارن کردن پروفیل‌های

حالت نوسانی است که در داده‌ها موجود می‌باشد. با این تعریف هر IMF در هر سیکل در هر عبور از نقطه صفر فقط شامل یک نوسان است و هیچ موج پیچیده‌ای در کار نخواهد بود. با این تعریف یک IMF فقط به یک نوار باریک محدود نمی‌شود و می‌تواند دامنه و فرکانس را مدوله کند. در حقیقت می‌تواند غیرایستا باشد. فرکانس‌های مطلق یا دامنه‌های مدوله شده نیز می‌تواند یک IMF باشد. می‌توان بهترین تعریف برای فرکانس لحظه‌ای را از رابطه زیر به دست آورد:

$$\omega = \frac{d\theta(t)}{dt} \quad (2)$$

که در این رابطه خواهیم داشت:

$$\theta(t) = \arctan\left(\frac{Y(t)}{X(t)}\right) \quad (3)$$

خواهد بود به طوری که $X(t)$ سری زمانی مد نظر و $Y(t)$ تبدیل هیلبرت آن با رابطه:

$$Y(t) = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{X(t')}{t-t'} dt' \quad (4)$$

به دست می‌آید. P در این رابطه بیان‌کننده مقدار اصلی کوشی است که روشی برای مقدار دادن به انتگرال‌های ناسره فاقد مقدار می‌باشد. با استفاده از سری زمانی و تبدیل هیلبرت آن می‌توان یک جفت مختلط به صورت

$$Z(t) = X(t) + iY(t) = a(t)e^{i\theta(t)} \quad (5)$$

نوشت که این رابطه، رابطه یک IMF بعد از تبدیل هیلبرت نیز می‌باشد. ضریب $a(t)$ به صورت زیر قابل تعریف است:


$$a(t) = [X^2(t) + Y^2(t)]^{1/2} \quad (6)$$

اگر تبدیل فوری را روی رابطه انجام دهیم خواهیم داشت:

$$W(\omega) = \int_{-\infty}^{\infty} a(t)e^{i\theta(t)}e^{-i\omega t} dt = \int_{-\infty}^{\infty} a(t)e^{i(\theta(t)-\omega t)} dt \quad (7)$$

بدین منظور برای استفاده از فرکانس لحظه‌ای می‌بایست با کاهش داده‌ها به مجموعه‌ای از IMFها و اختصاص یک

که با $\varphi(r)$ نمایش داده می‌شود و به‌عنوان تابع فعالیت غیرخطی آن می‌باشد. j_1 در اصل تعداد گره‌های لایه ورودی، و به‌همین ترتیب j_2 و j_3 تعداد گره‌های لایه‌های مخفی و خروجی می‌باشند. طبق شکل (۱) خواهیم داشت:



شکل ۱. شبکه عصبی تابع پایه شعاعی (دو و سوآمی، ۲۰۰۶).

لایه پنهان تبدیل غیرخطی ورودی را انجام می‌دهد و لایه خروجی یک ترکیب خطی است که از غیرخطی بودن به یک فضای جدید ترسیم می‌شود. بایاس‌های نورون لایه‌های خروجی توسط یک نورون اضافی در لایه پنهان مدل می‌شود که تابع فعالیت ثابت $\varphi_0(r) = 1$ را دارا می‌باشد. شبکه عصبی RBF می‌تواند با استفاده از روش بهینه‌سازی خطی، به یک راه‌حل بهینه به‌صورت جهانی (Global) برای وزن‌های قابل سرشکنی در دست‌یابی به کمترین میزان مربعات خطا (MSE) برسد. برای یک الگوی ورودی x خروجی شبکه به‌صورت زیر خواهد بود:

$$y_i(x) = \sum_{k=1}^{j_2} \omega_{ki} \phi(\|x - c_k\|) \quad (12)$$

که در این رابطه برای $i=1 \dots j_3$ در صورتی که $y_i(x)$ خروجی i ام شبکه باشد، ω_{ki} ماتریس وزن ارتباط از واحد پنهان k ام به واحد خروجی i ام می‌باشد. c_k مرکز k ام واحد پنهان و عملگر $\|\cdot\|$ نشان‌دهنده نرم اقلیدسی می‌باشد. تابع پایه شعاعی $\phi(\cdot)$ معمولاً به‌صورت یک تابع گوسی انتخاب می‌شود.

همانند یادگیری شبکه عصبی پرسپترون چندلایه، آموزش شبکه RBF نیز بر مبنای مینیمم‌سازی تابع مجذور میانگین خطا فرموله شده است. خواهیم داشت:

امواج سیگنال ادامه داده و از h_1 به‌عنوان داده استفاده می‌شود تا در نهایت با توجه به شرط زیر بعد از k مرتبه فرآیند غربال، h_{1k} به‌عنوان نخستین IMF انتخاب شود. برای بیان این موضوع روابط زیر را خواهیم داشت:

$$h_1 - m_{11} = h_{11} \quad (9)$$

$$h_{1(k-1)} - m_{1k} = h_{1k} \quad (10)$$

- بررسی شرط IMF بودن و معیار توقف.

$$SD = \sum_{t=0}^T \left[\frac{|(h_{1(k-1)}(t) - h_{1k}(t))|^2}{h_{1(k-1)}^2(t)} \right] \quad (11)$$

مقدار SD را می‌توان بین $0/2$ تا $0/3$ تنظیم کرد.

- در صورت عدم‌ارضای شرط ششم، جای‌گذاری سیگنال حاصل از مرحله پنجم به جای سیگنال اصلی و ادامه فرآیند از اول.

اگر شرط مرحله ششم برقرار باشد فرآیند غربال پایان یافته و $C_1 = h_{1k}$ به‌عنوان اولین IMF در نظر گرفته می‌شود که در واقع مؤلفه فرکانس بالای سیگنال $X(t)$ می‌باشد. باقی‌مانده به‌صورت $r_1 = X(t) - C_1^k$ تعریف شده و اگر خود، شرط IMF بودن را ارضا کند، یک IMF

محسوب شده و در غیر این‌صورت اگر شرط الف را داشته باشد به‌عنوان سیگنال اولیه فرض شده و گام‌های یک الی پنجم تکرار می‌شود تا IMF بعدی به‌دست آید و اگر شرط الف را نداشته باشد به‌عنوان باقی‌مانده r در نظر گرفته می‌شود. سیگنال اصلی مجموع IMF ها بعلاوه باقی‌مانده (هوانگ و همکاران، ۱۹۹۸).

۴. شبکه عصبی تابع پایه شعاعی

شبکه عصبی تابع پایه شعاعی یکی از انواع شبکه‌های عصبی می‌باشد که به‌دلیل ساختار ساده‌تر و آموزش سریع‌تر نسبت به شبکه عصبی پرسپترون چندلایه بسیار مورد توجه قرار گرفته است. شبکه عصبی تابع پایه شعاعی یک شبکه عصبی پیش‌خور موسوم به $j_3-j_2-j_1$ می‌باشد. هر گره در لایه مخفی از یک تابع پایه شعاعی استفاده می‌کند

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n [\hat{h}(t_i) - h(t_i)]^2} \quad (15)$$

۶. پیش‌بینی آنومالی سطح دریا با استفاده از روش

ترکیبی RBF-EMD

داده‌های ارتفاع‌سنجی ماهواره‌ای از سال ۱۹۹۳ میلادی با شروع به فعالیت مأموریت توپکس-پوزیدون به‌عنوان یک منبع غنی داده برای مطالعه آب‌ها در سطح زمین مطرح شد. این داده‌ها با گستردگی عظیم مکانی و همچنین پوشش مناسب زمانی، مورد توجه قرار گرفت. پس از آن به‌ترتیب ماهواره‌های جیسون ۱، جیسون ۲ و در نهایت جیسون ۳ در همان مدار اولیه به فعالیت پرداختند و به‌طور مرتب داده‌های ارتفاع‌سنجی از طریق مراکز ماندن Aviso در بازه‌های زمانی حدود ده روزه در اختیار کاربران قرار می‌گیرد. در این مقاله از داده‌های چهار مأموریت فوق که در یک خانواده از مأموریت‌های ارتفاع‌سنجی قرار می‌گیرند استفاده شده است. بدین منظور یک سری زمانی از داده‌های ارتفاع لحظه‌ای سطح آب در منطقه خزر با استفاده از داده‌های گذر ۹۲ این چهار مأموریت تشکیل شد. سپس با استفاده از رابطه (۱) کمیت آنومالی سطح دریا با استفاده از اطلاعات موجود در فایل داده‌های ارتفاع‌سنجی مورد محاسبه قرار گرفت و سری زمانی آن در بازه سال‌های ۱۹۹۳ تا ۲۰۲۰ تشکیل شد. این دو سری زمانی در قالب شکل‌های ۲ و ۳ که به ترتیب بیانگر سری زمانی ارتفاع لحظه‌ای سطح آب و سری زمانی آنومالی سطح دریا می‌باشد، ارائه شده است.

$$E = \frac{1}{N} \sum_{i=1}^N \|y_p - W^T f_p\|^2 = \frac{1}{N} \|Y - W^T \phi\|_F^2 \quad (13)$$

که در این رابطه $y_i, Y = [y_1, y_2, \dots, y_N]$ عبارت‌است از خروجی هدف برای نمونه نام در مجموعه آموزش و $\|\cdot\|_F$ نرم فروبینیوس تعریف شده به‌صورت $\|A\|_F^2 = \text{tr}(A^T A)$ می‌باشد.

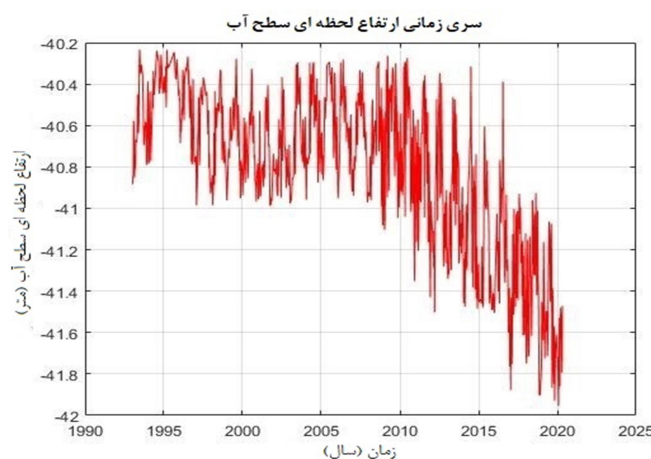
آموزش شبکه عصبی RBF به معرفی مراکز و وزن‌های توابع پایه شعاعی نیاز دارد. انتخاب بردار مرکز تابع پایه شعاعی عاملی بسیار مهم در پیاده‌سازی شبکه عصبی RBF می‌باشد. این مراکز را می‌توان در زیرمجموعه‌ای تصادفی با تمام نمونه‌های آموزش قرار داد، یا با استفاده از خوشه‌بندی یا از طریق روش یادگیری تعیین کرد.

تابع پایه مورد استفاده در شبکه عصبی RBF به نام تابع گوسی و به‌صورت $\phi(r) = e^{-\frac{r^2}{2\sigma^2}}$ می‌باشد که در آن $r > 0$ بیان‌کننده فاصله یک نقطه در مجموعه داده x نسبت به مرکز c است. پارامتر σ بیان‌کننده کنترل صافی تابع درونی می‌باشد (دو و سوآمی، ۲۰۰۶).

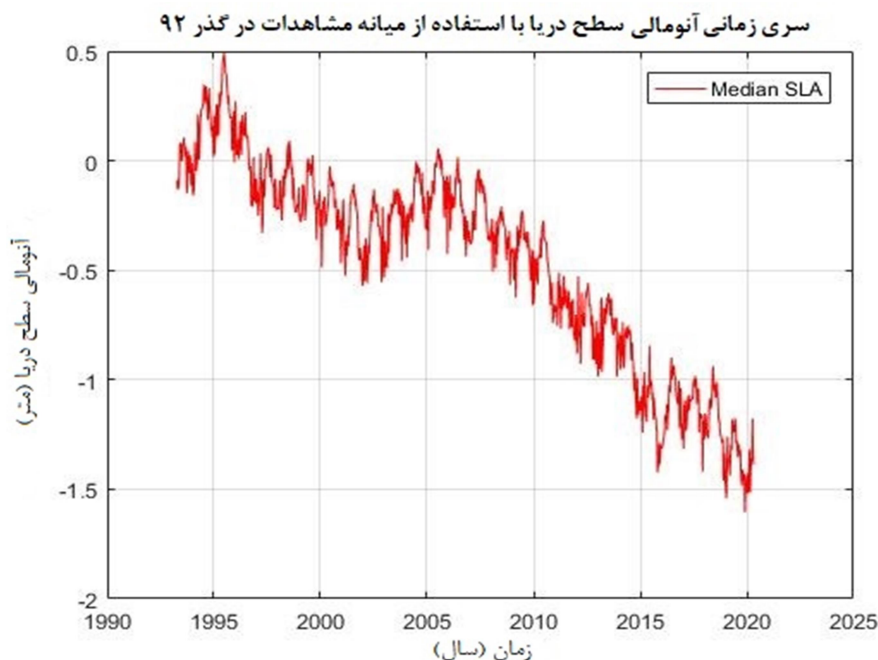
۵. پارامترهای ارزیابی نتایج

در این پژوهش از دو پارامتر ارزیابی خطای مجذور کمترین مربعات و ضریب همبستگی استفاده شد. روابط (۱۴) و (۱۵) به ترتیب بیان‌کننده این دو پارامتر ارزیابی می‌باشد (ژائو و همکاران، ۲۰۱۹).

$$R = \left[\frac{\sum_{i=1}^n (h(t_i) - \bar{h}(t)) (\hat{h}(t_i) - \bar{\hat{h}}(t))}{\sqrt{\sum_{i=1}^n (h(t_i) - \bar{h}(t))^2 \sum_{i=1}^n (\hat{h}(t_i) - \bar{\hat{h}}(t))^2}} \right] \quad (14)$$



شکل ۲. سری زمانی ارتفاع لحظه‌ای سطح آب گذر ۹۲ با استفاده از میانه مشاهدات.

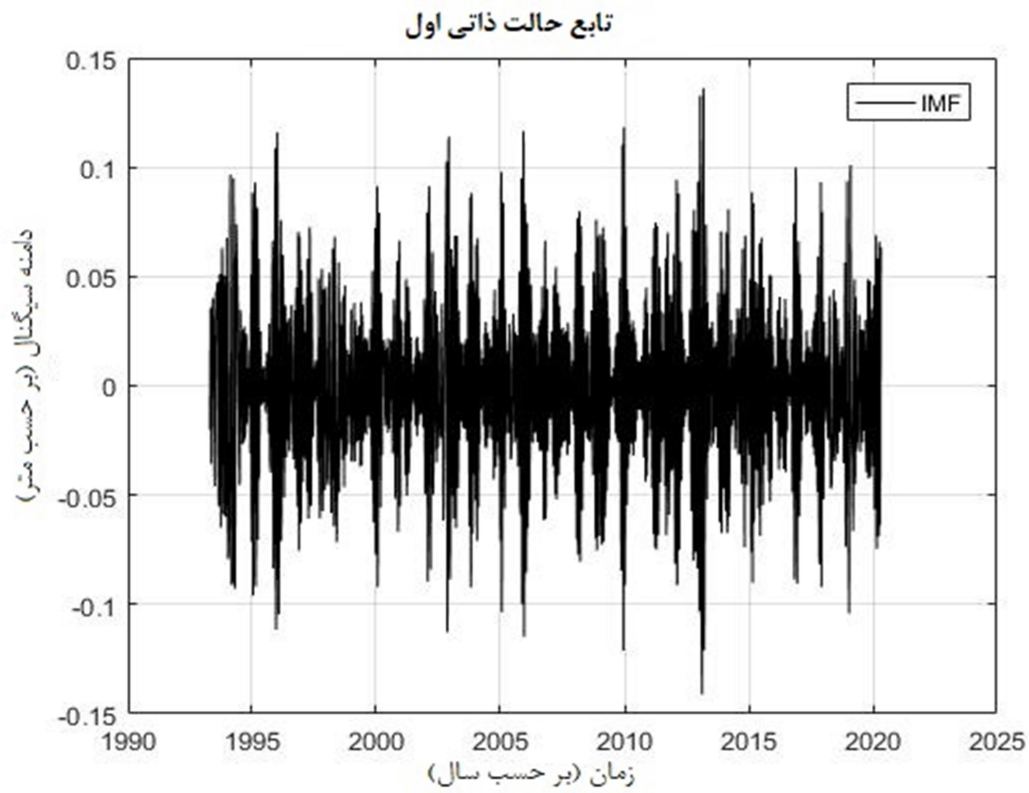


شکل ۳. سری زمانی آنومالی سطح دریا برای گذر ۹۲ با استفاده از میانگین مشاهدات.


در مداری بین دو مدار اصلی خود قرار گرفته تا آن که به مأموریت خود پایان دهد. این اختلاف برای دو ماهواره توپکس پوزیدون و جیسون ۱ برابر $0/1105$ متر و برای دو مأموریت جیسون ۱ و جیسون ۲ برابر $0/1612$ متر و برای دو مأموریت جیسون ۲ و جیسون ۳ برابر $0/0251$ متر محاسبه شد.

سری زمانی آنومالی سطح دریا در گذر ۹۲ با استفاده از روش تجزیه به حالت‌های ذاتی، تجزیه شد. در روش تجزیه به حالت‌های ذاتی ابتدا فرکانس‌های بالا یا پرپود کوتاه تجزیه می‌شود و سپس آخرین IMF که به باقی‌مانده معروف است همان ترند سری زمانی مدنظر می‌باشد. شکل‌های ۴ تا ۱۳، بیان‌کننده توابع حالت‌های ذاتی در سری زمانی آنومالی سطح دریا مربوط به منطقه مطالعاتی خزر در بازه زمانی سال‌های ۱۹۹۳ تا ۲۰۲۰ میلادی می‌باشد که هرکدام از این توابع بیان‌کننده دامنه سیگنال در یک فرکانس خاص می‌باشد.

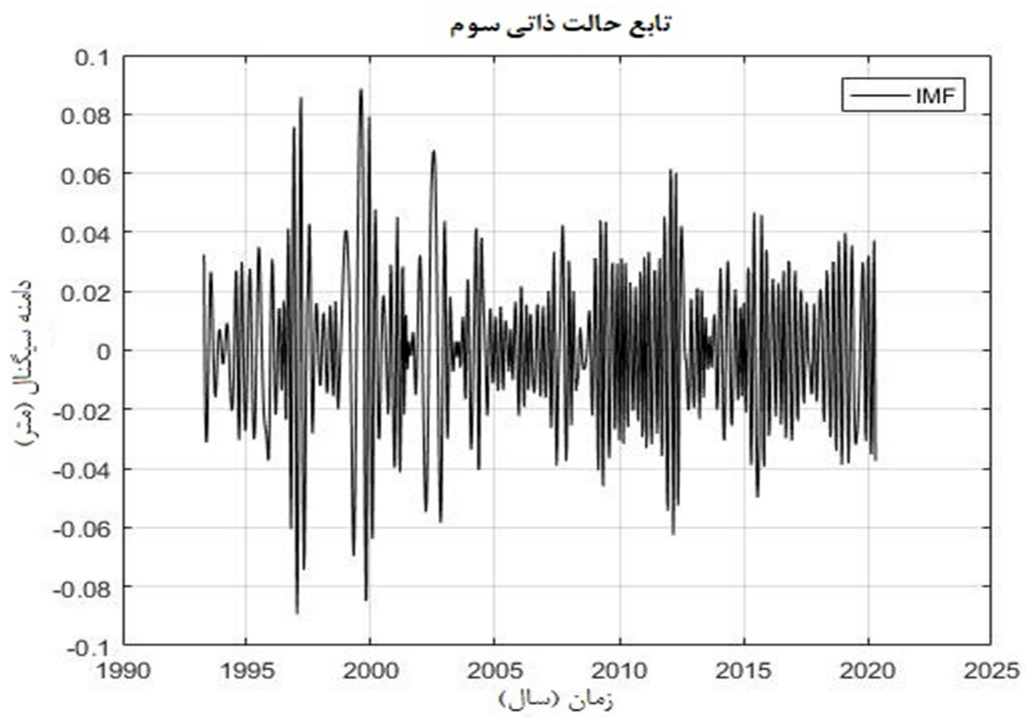
جهت استفاده از داده‌های ارتفاع‌سنجی چند ماهواره می‌بایست ابتدا تصحیحی به داده‌های ماهواره بعدی داده شود و این تصحیح با استفاده از محاسبه اختلاف مشاهدات دو ماهواره در سیکل‌های ابتدایی مأموریت بعدی می‌باشد که به فاز برداشت پشت‌سرهم معروف است (هاندوکو و همکاران، ۲۰۱۷). این بازه برای مأموریت توپکس پوزیدون و جیسون ۱ به صورت سیکل‌های ۳۴۳ تا ۳۶۴ توپکس پوزیدون و ۱ تا ۲۰ برای مأموریت جیسون ۱؛ ۲۴۰ تا ۲۵۹ برای مأموریت جیسون ۱ و ۱ تا ۲۰ برای مأموریت جیسون ۲ و در نهایت سیکل‌های ۲۷۳ تا ۲۹۲ برای جیسون ۲، و ۱ تا ۲۰ برای مأموریت جیسون ۳ می‌باشد. این مرحله از مأموریت‌های ارتفاع‌سنجی جهت از بین بردن بایاس‌های موجود بین داده‌های دو مأموریت و یکسان‌سازی داده‌های آنها انجام می‌شود و چیزی حدود ۲۰ هفته را شامل می‌شود و پس از آن مأموریت قدیمی‌تر




شکل ۴. تابع حالت ذاتی شماره یک سیگنال سری زمانی آنومالی سطح دریا.



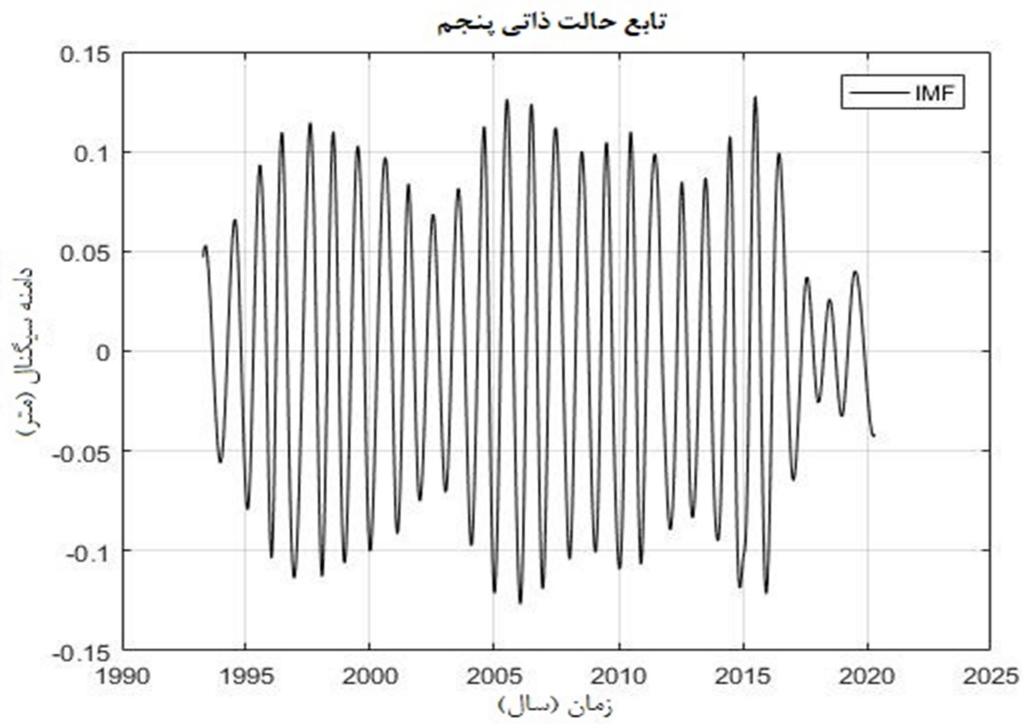
شکل ۵. تابع حالت ذاتی شماره دو سیگنال سری زمانی آنومالی سطح دریا.




شکل ۶. تابع حالت ذاتی شماره سه سیگنال سری زمانی آنومالی سطح دریا.




شکل ۷. تابع حالت ذاتی شماره چهار سیگنال سری زمانی آنومالی سطح دریا.




شکل ۸. تابع حالت ذاتی شماره پنج سیگنال سری زمانی آنومالی سطح دریا.




شکل ۹. تابع حالت ذاتی شماره شش سیگنال سری زمانی آنومالی سطح دریا.



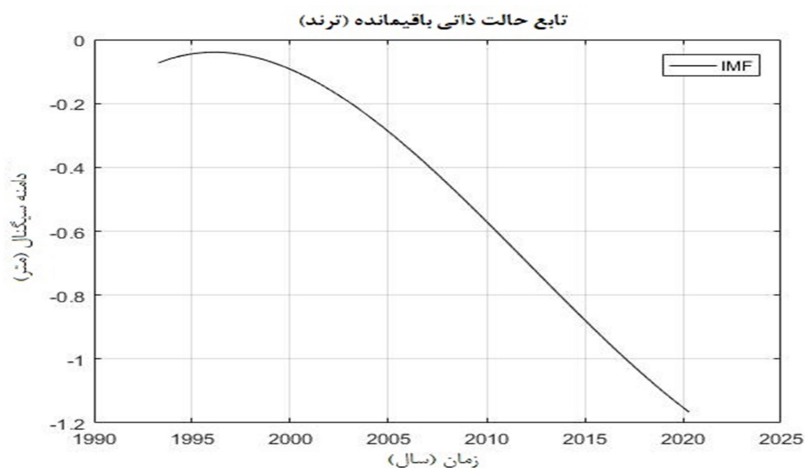
شکل ۱۰. تابع حالت ذاتی شماره هفت سیگنال سری زمانی آنومالی سطح دریا.



شکل ۱۱. تابع حالت ذاتی شماره هشت سیگنال سری زمانی آنومالی سطح دریا.



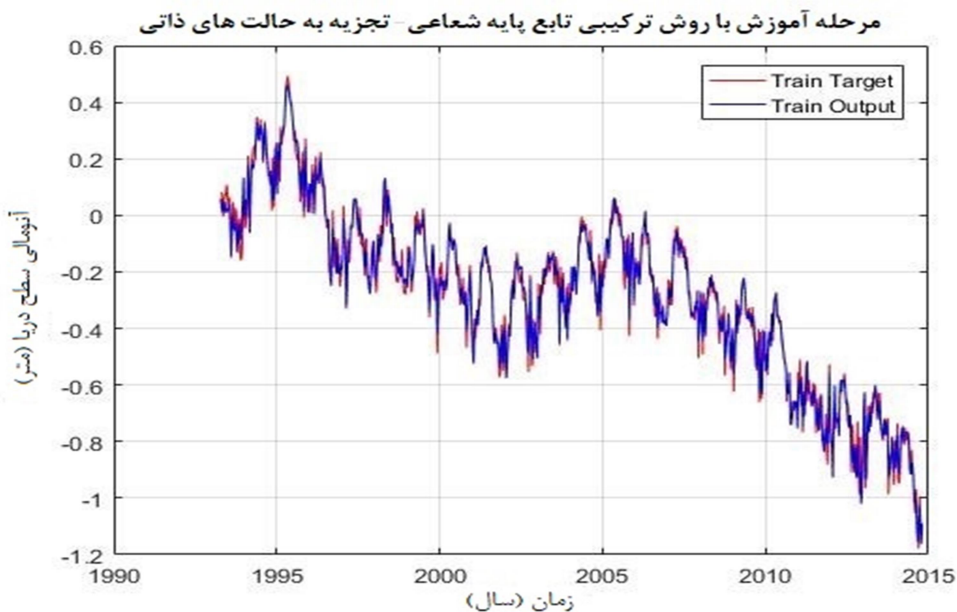
شکل ۱۲. تابع حالت ذاتی شماره نه سیگنال سری زمانی آنومالی سطح دریا.



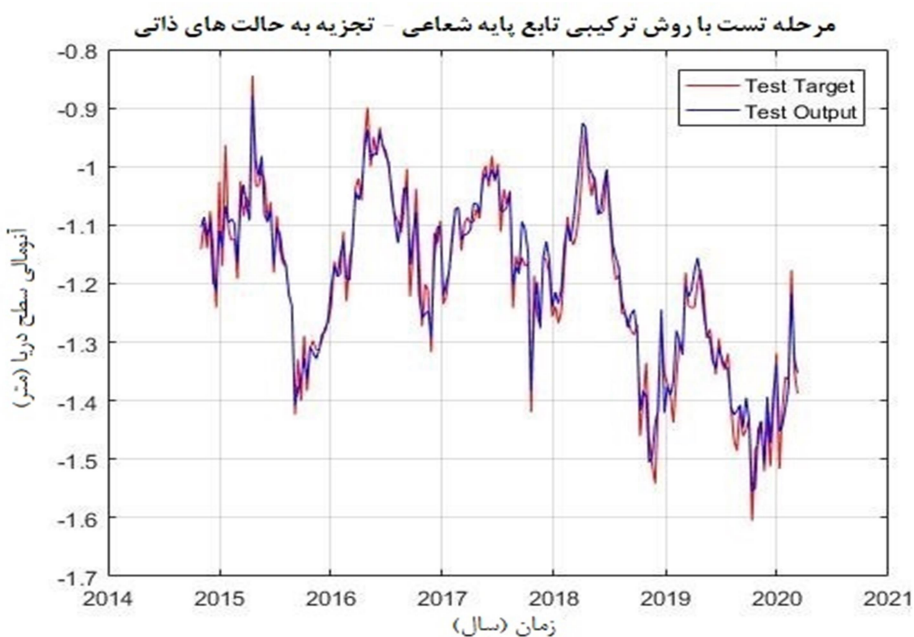
شکل ۱۳. سیگنال باقی‌مانده (ترند) سری زمانی آنومالی سطح دریا.

به وجود آمد. بدین ترتیب شبکه عصبی تابع پایه شعاعی با ورودی‌ها و مقادیر هدف ایجاد و در نهایت نتایج به دست آمده در دو مرحله تست و آموزش با پارمترهای ارزیابی گفته شده به دست آمد. شکل‌های ۱۴ و ۱۵، به ترتیب نشان‌دهنده مراحل آموزش و تست و همچنین مقادیر پیش‌بینی شده توسط این شبکه ایجاد شده می‌باشد.

در این پژوهش برای ایجاد یک شبکه پیش‌بینی، تک‌تک توابع حالت‌های ذاتی، به صورت جداگانه به عنوان داده‌های شبکه عصبی تابع پایه شعاعی مورد استفاده قرار گرفت و نحوه اعمال این ورودی‌ها بدین ترتیب بود که داده مربوط به پنج سیکل گذشته گذر ۹۲ عبوری از دریاچه خزر به عنوان ورودی و سیکل ششم به عنوان مقدار هدف مورد استفاده قرار گرفت و در نتیجه شبکه عصبی تابع پایه شعاعی با قابلیت پیش‌بینی یک سیکل آینده



شکل ۱۴. مرحله آموزش با روش ترکیبی تابع پایه شعاعی-تجزیه به حالت‌های ذاتی.



شکل ۱۵. مرحله تست با روش ترکیبی تابع پایه شعاعی-تجزیه به حالت‌های ذاتی.

نتایج پارامترهای ارزیابی به دست آمده از این دو مرحله به صورت جدول ۱ می‌باشد:

جدول ۱. پارامترهای ارزیابی نتایج ناشی از شبکه عصبی تابع پایه شعاعی-تجزیه به حالت‌های ذاتی.

مرحله آموزش		مرحله تست		
مجدور میانگین مربعات (متر)	ضریب همبستگی	مجدور میانگین مربعات (متر)	ضریب همبستگی	
۰/۰۲۹	۰/۹۹	۰/۰۳۴	۰/۹۷	روش ترکیبی ارائه شده

۷. نتیجه‌گیری

کمیت آنومالی سطح دریا به‌عنوان کمیتی که بیان‌کننده اختلاف بین سطح لحظه‌ای آب و سطح متوسط آب است در مطالعات مربوط به دریا بسیار مهم و کارآمد می‌باشد. در این پژوهش با بررسی داده‌های مربوط به مأموریت‌های چهارگانه توپکس-پوزیدون، جیسون ۱، جیسون ۲ و جیسون ۳ مقادیر ارتفاع سطح لحظه‌ای آب مربوط به مقادیر میانه گذر ۹۲ در منطقه دریاچه خزر تعیین و سپس آنومالی سطح دریا مورد محاسبه قرار گرفت. نتایج بررسی‌ها نشان داد که آنومالی سطح دریا در این منطقه با کاهشی چشم‌گیر مواجه بوده است. به‌گونه‌ای که در دریاچه خزر برخلاف بیشتر مناطق آبی جهان با کاهش سطح مواجه هستیم. این کاهش سطح از سال ۲۰۰۵ میلادی تا سال ۲۰۲۰ به‌صورت مستمر ادامه داشته است و سالیانه حدود ده سانتی‌متر با کاهش سطح در کمیت آنومالی سطح دریا مواجه بودیم.

سری زمانی آنومالی سطح دریا در منطقه مطالعاتی با این روش مورد تجزیه قرار گرفت و ۹ فرکانس غالب برای این سیستم کشف شد و این فرکانس‌های غالب با دامنه‌های خاص خود، تحت عنوان توابع حالت‌های ذاتی شناخته می‌شود و در نهایت آخرین مقدار تابع حالت‌های ذاتی که تابع حالت‌های ذاتی دهم بود به نام مقادیر باقی‌مانده یا همان ترند سری زمانی مدنظر می‌باشد. کاهش چشم‌گیر آنومالی سطح آب با استفاده از این تابع حالت‌های ذاتی به وضوح قابل رؤیت می‌باشد. این سیگنال‌ها در توابع حالت‌های ذاتی به‌صورت جداگانه و در غالب داده‌های مختلف با شبکه عصبی تابع پایه شعاعی ساخته شده مورد پردازش قرار گرفت و نتایج این آنالیز در غالب دو مرحله آموزش و تست شبکه عصبی ارائه شد. نقش بسیار مهم در یک شبکه عصبی تابع پایه شعاعی کمیت نرخ گسترش می‌باشد که باید این مقدار با تعداد نوروهای موجود در لایه پنهان تنظیم شود تا آموزش این شبکه با دقت مناسبی انجام گیرد.

در نهایت یک شبکه عصبی RBF خواهیم داشت که

از بررسی سری زمانی آنومالی سطح دریا می‌توان به این نتیجه رسید که با کاهش چشم‌گیر حدود ده سانتی‌متری در سال در این پارامتر در منطقه خزر مواجه خواهیم بود. این بررسی برخلاف عمده مناطق جهان که با افزایش ارتفاع سطح آب مواجهیم در منطقه خزر به‌صورت معکوس و نزولی می‌باشد.

با استفاده از انواع روش‌های آنالیز سیگنال از جمله آنالیز فوریه، موجک و هیلبرت می‌توان به تعیین فرکانس‌ها پرداخت که مزایا و معایب آنها مورد بررسی قرار گرفت. هرکدام از این ۹ تابع حالت‌های ذاتی به‌همراه تابع حالت‌های ذاتی ترند نشان‌دهنده یک فرکانس خاص می‌باشد. بدین‌گونه که تابع حالت‌های ذاتی نخست نشان‌دهنده پریودهای کوچک‌تر چند ماهه تا تابع حالت‌های ذاتی ترند که پریود طولانی را نشان می‌دهد، می‌باشد. هرکدام از این توابع ذاتی به‌صورت جداگانه در دو مرحله آموزش و تست مورد پردازش قرار گرفت و در نهایت با جمع همه آنها به نتایج حاصل در دو مرحله آموزش و تست در کل دست یافتیم. بهبود عملکرد در دو پارامتر میانگین مجذور مربعات خطا و ضریب همبستگی در مقایسه با تنها مورد مطالعه‌شده در این منطقه (ایمانی و همکاران، ۲۰۱۴) که در آن سیگنال مورد تجزیه قرار نگرفته بود، به میزان ۳ سانتی‌متر در مرحله آموزش و ۲/۶ سانتی‌متر در مرحله تست به‌همراه بهبود ضریب همبستگی به میزان ۷ درصد در هر دو مرحله تست و آموزش از مزایای روش ترکیبی مورد استفاده بود. همچنین استفاده از روش تجزیه به حالت‌های ذاتی زمینه‌ساز تسهیل پیش‌بینی سیگنال با ایستاد کردن سری زمانی مدنظر بود.

در استفاده از یک شبکه عصبی تابع پایه شعاعی پارامتر نرخ گسترش نقش بسیار تعیین‌کننده‌ای در دقت نتایج حاصل خواهد داشت. بدین ترتیب می‌بایست با افزایش و کاهش این پارامتر در تکرارهای مختلف به نتایج قابل قبول دست یافت. در این پژوهش از نرخ گسترش به میزان ۶ مورد استفاده قرار گرفت.

دارای ضریب همبستگی ۰/۹۹ و ۰/۹۷ نیز به ترتیب در مراحل آموزش و تست می‌باشد.

مراجع

- Ali Ghorbani, M., Khatibi, R., Aytek, A., Makarynsky, O. and Shiri, J. 2010, Sea water level forecasting using genetic programming and comparing the performance with Artificial Neural Networks. *Computers & Geosciences*, 36, 620-627.
- Andersen, O. B. and Scharroo, R., 2011, Range and Geophysical Corrections in Coastal Regions: And Implications for Mean Sea Surface Determination. In: Vignudelli, S., Kostianoy, A. G., Cipollini, P. & Benveniste, J. (eds.) *Coastal Altimetry*. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Bonaduce, A., Pinardi, N., Oddo, P., Spada, G. and Larnicol, G., 2016, Sea-level variability in the Mediterranean Sea from altimetry and tide gauges. *Climate Dynamics*, 47, 2851-2866.
- Cazenave, A. and Cozannet, G. L., 2014, Sea level rise and its coastal impacts. *Earth's Future*, 2, 15-34.
- Curch, J. A. and White, N. J., 2006, A 20th century acceleration in global sea-level rise. *Geophysical Research Letters*, 33.
- DU, K. L. and Swamy, M. N. S., 2006, Radial Basis Function Networks. In: DU, K. L. & Swamy, M. N. S. (eds.) *Neural Networks in a Softcomputing Framework*. London: Springer London.
- Handoko, E. Y., Fernandes, M. J. and Lázaro, C., 2017, Assessment of Altimetric Range and Geophysical Corrections and Mean Sea Surface Models—Impacts on Sea Level Variability around the Indonesian Seas. *Remote Sensing*, 9.
- Holgate, S. J., 2007, On the decadal rates of sea level change during the twentieth century. *Geophysical Research Letters*, 34.
- Huang, N. E., Shen, Z., Long, S. R., WU, M. C., Shih, H. H., Zheng, Q., Yen, N.-C., Tung, C. C. and Liu, H. H., 1998, The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 454, 903-995.
- Imani, M., You, R. J. and Kuo, C. Y., 2014, Caspian Sea level prediction using satellite altimetry by artificial neural networks. *International Journal of Environmental Science and Technology*, 11, 1035-1042.
- Leuliette, E. W., Nerem, R. S. and Mitchum, G. T., 2004, Calibration of TOPEX/Poseidon and Jason Altimeter Data to Construct a Continuous Record of Mean Sea Level Change. *Marine Geodesy*, 27, 79-94.
- Rahmstorf, S., 2007, A Semi-Empirical Approach to Projecting Future Sea-Level Rise. *Science*, 315, 368.
- Röske, F., 1997, Sea level forecasts using neural networks. *Deutsche Hydrographische Zeitschrift*, 49, 71-99.
- Slangen, A. B. A., Katsman, C. A., Van de wal, R. S. W., Vermeersen, L. L. A. and Riva, R. E. M., 2012, Towards regional projections of twenty-first century sea-level change based on IPCC SRES scenarios. *Climate Dynamics*, 38, 1191-1209.
- Stammer D, C. A., 2018, *Satellite Altimetry Over Oceans And Land Surfaces*.
- Sun, W. and Wang, Q., 2012, Sea level anomaly forecasting based on combined model of least square and arma. *Journal of Geodesy and Geodynamics*, 32, 91-94.
- Vaziri, M., 1997, Predicting Caspian Sea Surface Water Level by ANN and ARIMA Models. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 123, 158-162.
- Wild, M., Calanca, P., Scherrer, S. C. and Ohmura, A., 2003, Effects of polar ice sheets on global sea level in high-resolution greenhouse scenarios. *Journal of Geophysical Research: Atmospheres*, 108.
- Xiao-Fen, D., 2014, *Methodology and Case Study of Sea Level Prediction Based on Secular Tide Gauge Data*. 2014.
- Zhao, J., Fan, Y. and Mu, Y. 2019, Sea Level Prediction in the Yellow Sea From Satellite Altimetry With a Combined Least Squares-Neural Network Approach. *Marine Geodesy*, 42, 344-366.

Sea level anomaly prediction using Empirical Mode Decomposition and Radial Basis Function Neural Networks

kia, H.^{1*} and Voosoghi, B.²

1. M.Sc. Graduated, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

2. Associate Professor, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

(Received: 19 June 2021, Accepted: 10 Jan 2020)

Summary

Sea level anomaly as a parameter that expresses the difference between the instantaneous water level height and the average amount of water level in a period of time is of great importance in studying the water level situation in different regions. Predicting a time series requires that the series be static and that seasonal trends and changes be removed from the observations to eliminate the dependence of variance and mean on time. For this purpose, the use of various methods to static a time series has been suggested and used. Using the method of decomposition into the intrinsic modes of a signal that underlies the formation of intrinsic mode functions that include parts of the signal with approximately the same frequency; in order to analyze and isolate the trend and seasonal changes of the signal have been considered. Caspian sea as the largest lake in the world or the so-called largest enclosed water area in the world is located in northern Iran. This important water area has become one of the main sources of income for its peripheral countries. It has important oil and gas resources as well as the main source of sturgeon as one of the most expensive food sources in the world. This strategic region is known as a medium for connecting the East and the West of the world. In addition to the economic and commercial dimension, the Caspian Sea is of great importance from the military point of view, as numerous military maneuvers are held every year by the neighboring countries. For the above reasons; awareness of the water level and its changes has become increasingly important, especially over the past few decades, but despite this importance, not many studies have been conducted to study the water level. Therefore, in this research, using satellite altimeter data, the monitoring of water level changes in this area has been done. In this study a coverage of the sea anomaly parameter and its changes from 1993 to the present has been provided. The Caspian Sea water region as one of the two important water sources for Iran, is strategically important. For this purpose, in this study, using the transit data of 92 satellite altimetric missions passing through the Caspian Sea region, the changes in the sea level anomaly in this region since 1993 have been observed. This quantity is then analyzed using the method of analysis of intrinsic modes as an efficient method in separating the frequencies that make up a signal and then, using a neural network, a network of radial base functions has been created in order to predict sea level anomaly. 9 dominant frequencies along with a trend are the result of signal analysis considered in this study. Finally, it leads to the parameters of the mean square error of 0.029 m and 0.034 m with a correlation coefficient of 0.99 and 0.97, respectively, in the two stages of neural network training and testing.

Keywords: Satellite Altimetry, Signal Analysis, Empirical Mode Decomposition Method, Intrinsic Mode Function, Radial Basis Function Neural Network.

* Corresponding author:

hamedkia1989@email.kntu.ac.ir