

پیش بینی عمق بستر دریا با استفاده از مدل های عصبی - فازی: مطالعه ای تطبیقی با تلفیق داده های ژئودزی و بهینه سازی بر اساس داده های محلی

محمدعلی محمد^۱، ایرج جزیریان^{۲*}، محمود پیروزیان^۳

۱- دانشجوی دکتری ژئودزی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۲- استادیار گروه ژئودزی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

۳- استادیار گروه مهندسی نقشه برداری، دانشکده عمران، آب و محیط زیست، دانشگاه شهید بهشتی

تاریخ دریافت مقاله: ۱۴۰۴/۰۷/۰۸ تاریخ پذیرش مقاله: ۱۴۰۴/۰۹/۲۹

چکیده

اطلاع دقیق از عمق بستر دریا نقش مهمی در درک فرآیندهای اقیانوسی، اقیانوس شناسی فیزیکی، زیست شناسی دریایی، اکوهیدرولیک و زمین شناسی دریایی دارد. روش های مرسوم مدلسازی عمق معمولاً با استفاده از داده های ارتفاع سنجی ماهواره ای، مدل ثقل یا داده های ثقل سنجی دریایی انجام می شوند که دقت یا قدرت تفکیک مکانی مناسبی ندارند. در این پژوهش، یک مطالعه تطبیقی بین مدل های عصبی فازی برای مدل سازی منطقه ای عمق بستر در خلیج فارس و دریای عمان انجام شده و نتایج با کمک داده های محلی بهینه سازی شده است. برای این منظور، استنتاج عصبی-فازی تطبیقی (ANFIS) و درخت مدل خطی محلی (LOLIMOT) به عنوان مدل های غیرخطی برای شناسایی رابطه بین ورودی ها و خروجی استفاده شده اند. ورودی های مدل شامل داده های ژئودزی یعنی ارتفاع ژئوئید، گرادیان ثقل و آنومالی ثقل و خروجی آن مدل عمق سنجی GEBCO است. نتایج نشان داد مدل LOLIMOT انطباق بهتری با داده های آزمون دارد. لذا مدل پایه مذکور با داده گزاری مشاهدات عمق دریایی از طریق روش بهینه سازی متغیر سه بعدی (3DVAR) بهبود یافته و مدل نهایی عمق سنجی حاصل شده است. مدل پیشنهادی با داده های عمق سنجی مسیرهای کنترل مناطق چابهار، گناوه و علمشاه اعتبارسنجی شد و نتایج دقت بالای آن را در این مناطق به ترتیب با $RMSE$ حدود ۴٫۰ متر، ۰٫۸ متر و ۰٫۹ متر نشان می دهد. این مدلسازی، روش دقیقی برای تحلیل و پیش بینی عمق بستر دریا در مطالعات علمی و کاربردی ارائه می دهد.

کلیدواژه ها: مدل سازی عمق دریا، ارتفاع سنجی ماهواره ای، ثقل دریایی، یادگیری ماشین، مدل عصبی-فازی.

* نویسنده مکاتبه کننده: تهران، خیابان ولیعصر، تقاطع میرداماد غربی، دانشکده مهندسی نقشه برداری دانشگاه صنعتی خواجه نصیرالدین طوسی.

تلفن: ۰۲۱۸۸۸۷۷۰۷۰

۱- مقدمه

جریان‌های آبی و جزرومدها به‌طور کلی تحت تأثیر شکل کلی حوضه‌های اقیانوسی و همچنین برآمدگی‌ها^۱ و کوه‌های دریایی^۲ کوچک‌تر قرار می‌گیرند [۱]. اندازه‌گیری مستقیم توپوگرافی بستر دریا معمولاً با استفاده از کشتی‌های مجهز به عمق‌یاب صوتی انجام می‌شود که می‌توانند داده‌های عمق‌سنجی بسیار دقیقی ارائه دهند. با این حال، هزینه‌های عملیاتی بالا و صرف زمان طولانی، استفاده از این روش را برای پوشش وسیع مناطق، از نظر اقتصادی غیرعملی می‌سازد [۲]. از این رو، امروزه اندازه‌گیری‌های غیرمستقیم مبتنی بر فناوری‌های سنجش از دور توجه زیادی را در حوزه پایش و مدل‌سازی عمق بستر دریاها و منابع طبیعی به خود جلب کرده است [۳ و ۴]. در مطالعات سالیان اخیر مشخص شده ثقل‌سنجی می‌تواند برای مدل‌سازی شکل بستر دریا بکار رود [۵]. در واقع تغییرات عمق را می‌توان به‌عنوان تغییرات ارتفاعی عناصر جرمی در نظر گرفت که با اختلاف چگالی میان سنگ بستر و آب دریا تعیین می‌شود. لذا، این تغییرات عمقی بر میدان ثقل محلی اثر می‌گذارند.

پارکر (۱۹۷۳) بیان کرد که ارتباطی قوی میان توپوگرافی بستر دریا و آنومالی‌های ثقل در سطح دریا وجود دارد و این تغییرات عمق با ایجاد اعوجاج‌های گرانشی مؤثر بر ارتفاع سطح دریا و امکان بازسازی ویژگی‌های زیرسطحی مانند کوه‌های دریایی و برآمدگی‌ها را فراهم می‌کند [۶ و ۷]. رایج‌ترین روابط مورد استفاده در تعیین عمق با استفاده از تغییرات ثقلی، عمدتاً بر اساس مدل مشهور پارکر، اولدنبرگ است [۸ و ۹]. این مدل بر پایه اختلاف چگالی میان آب دریا و بستر دریا، ضخامت میانگین پوسته، عمق میانگین آب دریا و چگالی‌های منتل^۳ و پوسته زمین

استوار است. یکی از مشکلات ذاتی در کاربرد مدل پارکر، کمبود اطلاعات کافی برای برآورد پارامترهای مدل و همچنین تقریب خطی شده در فرآیند اجرا است که می‌تواند باعث ایجاد بایاس و خطاهای محاسباتی شود. علاوه بر این، عمق‌سنجی از آنومالی ثقل اساساً یک مسئله معکوس ناپایدار بوده و نیازمند نوعی پایدارسازی^۴ است [۹، ۱۰، ۱۱ و ۱۲]. در چنین شرایطی، خروجی مدل عمق‌سنجی مرتبط با مولفه‌های فرکانس بالا بسیار نوسانی است و باید یک فیلتر پایین‌گذر برای پایدارسازی نتایج اعمال شود [۱۳ و ۱۴].

ارتفاع‌سنجی ماهواره‌ای، پیشرفت چشمگیری در مدل‌سازی ثقل دریایی در مقیاس جهانی ایجاد کرده است [۱۵ و ۱۶]. ماهواره‌های متوالی مجهز به ارتفاع‌سنج، داده‌های دقیق و مترابسته از ارتفاع سطح دریا فراهم کرده‌اند که می‌توان آن‌ها را به توپوگرافی بستر دریا تبدیل کرد. لکورز و همکاران (۲۰۱۶) مروری جامع بر روش‌ها، فناوری‌ها و مجموعه داده‌های به‌کاررفته در مدل‌سازی عمق‌سنجی ارائه کرده‌اند [۱۷].

اخیراً، تکنیک‌های یادگیری ماشین، به ویژه شبکه‌های عصبی، کاربرد گسترده‌ای در مدل‌سازی بستر دریا یافته‌اند [۱۸ و ۱۹]. مدل‌های جهانی، بستر دریا را با استفاده از پرسپترون‌های چندلایه^۵ (MLP) و داده‌های ژئودزی دریایی چندمنبعی توسعه دادند و توانایی شبکه‌های عصبی در برآورد توپوگرافی بستر دریا در مقیاس بزرگ را نشان دادند. ژو و همکاران (۲۰۲۴) با استفاده از MLP در یک مطالعه موردی منطقه‌ای در دریای کارائیب پتانسیل شبکه‌های عصبی برای مدل‌سازی بستر دریا در مقیاس محلی را تأیید نمودند. علاوه بر این، رویکردهای یادگیری عمیق مانند شبکه‌های عصبی کانولوشنی^۶ عملکرد قوی در معکوس‌سازی توپوگرافی بستر دریا از داده‌های گرانشی

⁴ regularization⁵ Multilayer Perceptrons⁶ CNNs¹ ridges² seamounts³ mantel

هر یک از مناطق با کادر قرمز رنگ مشخص شده است. به منظور برآورد ژئوئید دریایی، از اندازه‌گیری‌های تکراری ارتفاع‌سنجی در نقاط مکانی ثابت، استفاده شده است. ژئوئید یک سطح هم‌پتانسیل است که توزیع جرم داخلی زمین را مشخص کرده و تحت تأثیر ناهمگونی‌های جرم، با توزیع جرم و شکل خارجی زمین مرتبط است. در واقع شکل خارجی به توپوگرافی یا عمق‌سنجی و توزیع جرم با ساختارهای زمین‌شناسی زیرسطحی پیوند دارد. ژئوئید کلاسیک نسبت به توزیع جرم در سراسر زمین حساس است و تغییرات آن ممکن است ناشی از عوارض بستر دریا مانند کوه‌های دریایی، دره‌ها یا برآمدگی‌ها، تغییرات جانبی چگالی در ناحیه لیتوسفری، آنومالی‌های عمیق درون زمین و یا ترکیبی از این عوامل باشد [۲۵].

برای تعیین ارتفاع ژئوئید از داده‌های ارتفاع‌سنجی ماهواره‌ای، ابتدا داده‌ها پردازش می‌شوند تا ارتفاع سطح دریا از تفاضل ارتفاع ماهواره و فاصله مشاهداتی^۴ و اصلاح شده به دست آید. سپس میانگین ارتفاع سطح دریا^۵ (MSS) با استفاده از روش تحلیل طیفی کمترین مربعات (LSSA) تعیین می‌شود [۲۶ و ۲۷]. در مرحله بعد، با کسر MSS از مدل توپوگرافی دینامیک میانگین^۶ (MDT)، ارتفاع ژئوئید و در نهایت با استفاده از فرمول معکوس استوکس آنومالی‌های ثقل محاسبه می‌شود [۲۸].

منابع داده در این مطالعه عبارتند از:

- داده‌های ارتفاع‌سنجی ماهواره‌ای (GDR)
- مأموریت‌های مختلف برای برآورد ارتفاع ژئوئید و آنومالی ثقل مطابق جدول (۱)
- داده‌های ثقل دریایی برای تعیین آنومالی ثقل محلی
- مدل MDT-DTU-2018 دانشگاه فنی دانمارک برای

نشان داده‌اند [۲۰]. همچنین، شبکه‌های عصبی عمیق کاملاً متصل (FCDNNs) برای پیش‌بینی عمق بستر با استفاده از آنومالی‌های گرانشی به کار رفته و نتایج امیدوارکننده‌ای در مطالعات منطقه‌ای ارائه کرده‌اند [۲۱].

با توجه به اینکه مدل‌های عصبی-فازی علاوه بر توان یادگیری و تقریب روابط بسیار پیچیده و غیرخطی در داده‌ها، از شفافیت، سازگاری و تفسیرپذیری بالایی نیز برخوردارند، این تحقیق با هدف ارتقای دقت مدل‌سازی عمق بستر دریا در جنوب ایران بر پایه پارامترهای میدان ثقل و دو روش استنتاج عصبی-فازی انجام شده است. در این پژوهش ابتدا منطقه مطالعه و داده‌های مورد استفاده معرفی می‌شود؛ سپس دو روش مدل استنتاج عصبی-فازی تطبیقی^۲ (ANFIS) و درخت مدل خطی محلی^۳ (LOLIMOT) که در این تحقیق به کار گرفته شده‌اند تشریح می‌گردند. در پایان، نتایج مدل‌سازی ارائه شده و تحلیل خروجی‌ها به همراه مقایسه کارایی دو مدل انجام می‌پذیرد.

۲- مواد و روش‌ها

در این بخش، به تشریح داده‌های مورد استفاده در پژوهش و روش انجام کار پرداخته می‌شود. منطقه مطالعاتی این تحقیق شامل خلیج فارس و دریای عمان است. مدل‌سازی با استفاده از دو مدل عصبی-فازی برای کل این منطقه انجام می‌گیرد و با بهره‌گیری از داده‌های محلی و داده‌گذاری در سه منطقه مشخص، تلاش می‌شود تا مدل‌های مذکور بهینه‌سازی شوند.

۲-۱- داده‌ها و منطقه مطالعاتی

به دلیل دسترسی به داده‌های عمق‌سنجی محلی در مناطق گناوه و علمشاه در خلیج فارس و منطقه چابهار در دریای عمان این نواحی به عنوان منطقه مطالعاتی در این تحقیق انتخاب شده است. در شکل (۱) محدوده

⁴ range

⁵ mean sea surface

⁶ mean dynamic topography

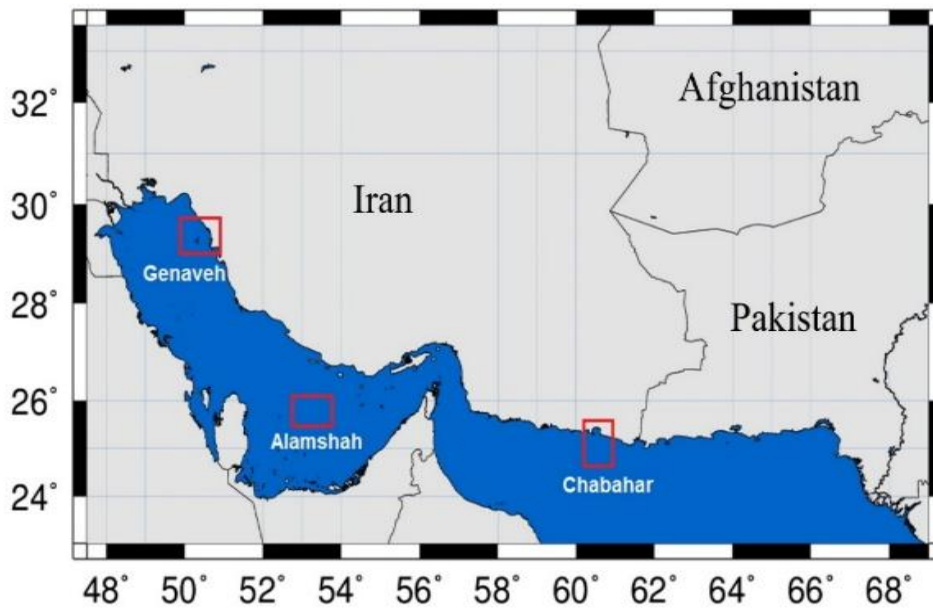
¹ Fully Connected Deep Neural Networks

² Adaptive Neuro-Fuzzy Inference System

³ Local Linear Model Tree

• مدل جهانی عمق سنجی *GEBCO_2019* به عنوان
 ثقل تا درجه و مرتبه ۵۳۹۹
 خروجی مدل پایه

• تعیین ژئوئید با استفاده از داده‌های ارتفاع سنجی
 داده‌های عمق سنجی دریایی در مناطق گناوه،
 علمشاه و چابهار برای فرآیند داده‌گذاری
 مدل ثقل *XGM2019e* برای تعیین گرادیان‌های



شکل ۱: منطقه مورد مطالعه

جدول ۱: ماموریت های ارتفاع سنجی مورد استفاده در این مطالعه

ماموریت	دوره	بازه زمانی
<i>Envisat</i>	۰۹۴ - ۰۰۸	ساعت ۲۱:۳۹:۳۶ تا ۰۲:۵۶:۰۷، ۲۰۰۲/۰۷/۲۲
<i>Jason-1</i>	۲۵۹ - ۰۰۱	ساعت ۰۶:۲۹:۴۹ تا ۰۸:۴۹:۴۲، ۲۰۰۲/۰۱/۱۵
<i>Jason-2</i>	۳۰۳ - ۰۰۱	ساعت ۰۱:۲۵:۳۹ تا ۱۱:۴۵:۵۴، ۲۰۰۸/۰۷/۱۲
<i>Jason-3</i>	۰۳۳ - ۰۰۱	ساعت ۱۰:۲۸:۵۳ تا ۱۵:۴۰:۰۸، ۲۰۱۶/۰۲/۱۷
<i>Topex</i>	۳۶۵ - ۰۰۱	ساعت ۰۵:۲۴:۴۲ تا ۱۷:۴۴:۳۷، ۱۹۹۲/۰۹/۲۵
<i>Poseidon</i>	۳۶۱ - ۰۰۱	ساعت ۲۱:۳۹:۳۶ تا ۰۲:۵۶:۰۷، ۲۰۰۲/۰۷/۲۲
<i>SARAL</i>	۰۳۵ - ۰۰۱	ساعت ۱۱:۰۴:۳۷ تا ۰۰:۱۲:۵۰، ۲۰۱۶/۰۷/۰۴

ژئوئید حاصل از ارتفاع سنجی ماهواره‌ای، گرادیان ثقل
 از مدل *XGM2019e*، آنومالی ثقل محاسبه شده از
 داده‌های ارتفاع سنجی و اندازه‌گیری‌های ثقل دریایی و

۲-۲- مدل سازی عمق سنجی

در مدل سازی عمق با مدل‌های عصبی- فازی مورد
 استفاده در این پژوهش داده‌های ورودی شامل ارتفاع

داراست [۲۹ و ۳۰]. نظریه مجموعه‌های فازی^۲ به‌طور مؤثری عدم دقت در سناریوهای تصمیم‌گیری که شامل عدم قطعیت و ابهام در کاربردهای واقعی می‌باشد را مدیریت می‌کند. استنتاج فازی^۳ داده‌های ورودی را بر اساس اصول مجموعه‌های فازی به یک مجموعه خروجی نگاشت می‌کند. دانش سیستم از طریق مجموعه‌ای از قواعد زبانی روشن بیان می‌شود که برای افراد بدون پیش‌زمینه فنی نیز قابل درک است. سیستم‌های فازی در صورت وجود دانش کافی درباره سیستم، می‌توانند فرآیندهای غیرخطی را با استفاده از متغیرهای زبانی مدل‌سازی کنند. جزء منطق فازی به‌عنوان ابزاری برای مدیریت عدم قطعیت‌ها در تصمیمات گرفته شده توسط شبکه‌های عصبی عمل می‌کند [۳۰ و ۳۱]. شکل (۲) نمونه‌ای از ساختار ANFIS را نشان می‌دهد که از مدل فازی سوگنو^۴ استفاده می‌کند و شامل سه ورودی، یک خروجی و سه قاعده است که در پنج لایه سازمان‌دهی شده‌اند. اگر سیستم دارای سه ورودی، سه قاعده و یک خروجی باشد، رابطه (۱) برقرار خواهد بود. داریم:

در رابطه (۱)، x_1 ، x_2 و x_3 ورودی‌ها، A_i ، B_i و C_i پارامترهای توابع عضویت، a_i ، b_i ، c_i و d_i پارامترهای عملکردی، w_i وزن‌های هر قاعده، \bar{w}_i وزن‌های نرمال شده و f_i خروجی هر قاعده می‌باشد.

داده‌های خروجی عمق‌سنجی مدل جهانی *GEBCO* هماهنگ با توزیع مکانی آنومالی ثقل محاسبه شده می‌باشند. همچنین به منظور داده‌گذاری و بهینه‌سازی مدل پایه عصبی-فازی، این مدل با داده‌های عمق-سنجی دریایی حاصل از عمق‌یابی با اکوساندر تلفیق شد. برای این کار از روش بهینه‌سازی تغییرات سه‌بعدی (*3DVAR*) استفاده می‌شود تا دقت مدل نهایی افزایش یابد. هدف این رویکرد ترکیبی با بهره‌گیری همزمان از داده‌های غیرمستقیم (میدان ثقل) و مستقیم (اندازه‌گیری‌های میدانی) غلبه بر محدودیت‌های مدل‌های صرفاً ثقل‌محور و افزایش دقت و قابلیت اعتماد در عمق‌سنجی است.

۲-۳- مدل‌های غیرخطی عصبی-فازی

هدف این بخش، یافتن یک مدل عصبی-فازی مناسب بین پارامترهای میدان گرانشی زمین و عمق-سنجی بر اساس یک معیار خطا است. مسئله شناسایی سیستم به صورت یافتن تابعی برای ارتباط بین داده‌های ورودی و خروجی، تعریف می‌شود. مدل‌سازی غیرخطی عصبی-فازی موضوعاتی از قبیل نظریه تقریب، نظریه برآورد، الگوریتم‌ها و موضوعات نوین همچون شبکه‌های عصبی و مدل‌های فازی را در برمی‌گیرد. این روش‌ها ارتباط نزدیکی با تکنیک‌های آماری سنتی در رگرسیون غیرپارامتریک و برآورد چگالی دارند [۳]. در این مطالعه، دو روش سیستم استنتاج عصبی-فازی تطبیقی (*ANFIS*) و درخت مدل خطی محلی (*LOLIMOT*) برای ارتباط متغیرها و مدل‌سازی استفاده شده است.

۲-۳-۱- سیستم استنتاج عصبی-فازی تطبیقی^۱ (*ANFIS*)

ANFIS ترکیبی از شبکه عصبی مصنوعی و منطق فازی است که هم مزیت یادگیری خودکار شبکه عصبی و هم قابلیت استدلال زبانی منطق فازی را

^۲ fuzzy set theory

^۳ fuzzy inference

^۴ sugeno fuzzy model

^۱ Adaptive Neuro-Fuzzy Inference System

$$x_1 = A_1 \cdot x_2 = B_1 \cdot x_3 = C_1 \Rightarrow f_1 = a_1 x_1 + b_1 x_2 + c_1 x_3 + d_1$$


$$x_1 = A_2 \cdot x_2 = B_2 \cdot x_3 = C_2 \Rightarrow f_2 = a_2 x_1 + b_2 x_2 + c_2 x_3 + d_2$$

$$x_1 = A_3 \cdot x_2 = B_3 \cdot x_3 = C_3 \Rightarrow f_3 = a_3 x_1 + b_3 x_2 + c_3 x_3 + d_3$$

$$w_i = \mu_{A_i}(x_1) \times \mu_{B_i}(x_2) \times \mu_{C_i}(x_3), \quad i = 1, 2, 3. \quad \text{رابطه (۱)}$$

$$\bar{w}_i = \frac{w_i}{w_1 + w_2 + w_3}$$

$$f = \frac{f_1 w_1 + f_2 w_2 + f_3 w_3}{w_1 + w_2 + w_3} = \bar{w}_1 f_1 + \bar{w}_2 f_2 + \bar{w}_3 f_3$$



شکل ۲: ساختار ANFIS

می‌شود، درجه عضویت (MF) را برای هر قانون با استفاده از عملگر AND محاسبه می‌کند. هر گره خروجی در اینجا نشان‌دهنده قدرت شلیک^۷ قانون متناظر خود است.

• لایه سوم که به نام گره نرمال‌سازی شناخته می‌شود، یک فرآیند نرمال‌سازی انجام می‌دهد و نسبت درجه‌ی فعالیت هر قانون نام را به مجموع درجات فعالیت تمام قوانین محاسبه می‌کند. خروجی این لایه به عنوان قدرت شلیک نرمال‌شده شناخته می‌شود.

• لایه چهارم مسئول غیرفازی‌سازی است، جایی که مقادیر پارامترهای نتیجه را در ترکیب با قدرت‌های شلیک نرمال‌شده از لایه قبل محاسبه می‌کند.

• لایه اول به‌عنوان مرحله ورودی و فازی‌سازی^۱ عمل می‌کند. هر گره در این لایه نمایانگر یک مجموعه فازی است و خروجی این گره‌ها نشان‌دهنده درجه عضویت می‌باشد که توسط تابع عضویت (MF) مجموعه فازی تعیین می‌شود [۳۱]. به‌طور کلی، تابع عضویت^۲ در لایه‌ی اول معمولاً به صورت تابع زنگوله‌ای^۳ تعمیم‌یافته^۴ یا تابع گاوسی^۴ مورد استفاده قرار می‌گیرد.

• لایه دوم که محاسبه درجه انطباق هر قاعده^۵ با استفاده از عملگر AND و به نام گره قانون^۶ شناخته

¹ fuzzification

² membership function

³ generalized Bell MF

⁴ gaussian MF

⁵ rule

⁶ rule node

⁷ Firing Strength

می‌شود و این امکان را فراهم می‌کند که پارامترهای مقدماتی^۷ از طریق روش گرادیان نزولی تنظیم شوند. در این مطالعه، همان‌طور که پیش‌تر اشاره شد، ورودی‌ها و خروجی‌ها شامل عرض جغرافیایی، طول جغرافیایی، ارتفاع ژئوئید، آنومالی جاذبه، گرادیان‌های جاذبه و عمق هستند. تابع زنگوله‌ای تعمیم‌یافته به‌عنوان تابع عضویت مورد استفاده قرار گرفته و الگوریتم یادگیری ترکیبی برای آموزش مدل *ANFIS* و تنظیم پارامترها استفاده شده است. همچنین، تعداد بهینه توابع عضویت و تعداد دوره‌های آموزشی با آزمون و خطا و تحلیل *MSE* تعیین شد.

۲-۳-۲- درخت مدل خطی محلی (*LOLIMOT*)

امروزه سیستم‌های عصبی فازی به عنوان یک رویکرد قدرتمند و مؤثر در مدل‌سازی داده‌ها پدیدار شده‌اند، زیرا اصول یادگیری تثبیت‌شده شبکه‌های عصبی را با قابلیت تفسیر روشن منطق فازی ترکیب می‌کنند. با این حال با چالش‌هایی مربوط به مشکل بُعد^۸ مواجه هستند. برای رفع مسائل مربوط به ابعاد بالا و در عین حال حفظ ویژگی‌های مفید سیستم‌های نوروفازی مانند خطی‌بودن در وزن‌ها، شفافیت و تقسیم‌یکنواخت، استفاده از روشی برای کاهش پیچیدگی مدل ضروری است تا مدل‌های ساده‌تر و کارآمدتری ایجاد شوند. یکی از ملاحظات کلیدی برای موفقیت مدل درخت خطی محلی (*LOLIMOT*) راهبرد تقسیم و غلبه^۹ است [۳۳]. همان‌طور که نلس (۲۰۰۱) و سایر پژوهشگران نشان داده‌اند، *LOLIMOT* یک الگوریتم افزایشی برای ساخت درخت‌هاست که فضای ورودی را با استفاده از تقسیم‌بندی‌های هم‌راستا با محور^{۱۰} بخش‌بندی می‌کند. مفهوم اصلی مدل‌های عصبی - فازی خطی محلی شامل تقسیم فضای ورودی به

• در لایه نهایی (گره خروجی)، میانگین وزنی همه سیگنال‌های ورودی از لایه قبلی محاسبه می‌شود [۳۲].

ANFIS از توابع عضویت فازی برای بخش‌بندی هر بُعد ورودی استفاده می‌کند، به طوری که توابع عضویت همپوشان اجازه می‌دهند تا یک ورودی واحد چندین ناحیه محلی را فعال کند. از آنجایی که در چارچوب *ANFIS* مدل‌های محلی ساده به کار گرفته می‌شوند، توانایی تقریب آن بستگی به دقت تقسیم‌بندی فضای ورودی دارد؛ که تحت تأثیر تعداد توابع عضویت و تعداد لایه‌ها می‌باشد. به‌طور معمول، از توابع عضویت زنگوله‌ای شکل به صورت رابطه (۲) استفاده می‌شود که مقدار بیشینه آن‌ها برابر با ۱ و مقدار کمینه‌ی آن‌ها برابر با صفر است [۳۰، ۳ و ۳۱]:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\frac{x - e_i}{h_i} \right]^2} g_i \quad \text{رابطه (۲)}$$

در رابطه (۲)، $\{e_i, g_i, h_i\}$ پارامترهای توابع عضویت^۱ $\mu_{A_i}(x)$ هستند که بر شکل آن‌ها تأثیر می‌گذارند.

در معماری *ANFIS* لایه‌های اول و چهارم شامل گره‌های تطبیقی^۲ هستند. برای بهینه‌سازی این پارامترها، به یک الگوریتم یادگیری نیاز است. پیرونه و همکاران (۲۰۲۳) دو الگوریتم یادگیری ترکیبی^۳ و پس‌انتشار خطا^۴ را ارائه کرده‌اند. در الگوریتم یادگیری ترکیبی از ترکیب دو روش کمترین مربعات^۵ و گرادیان نزولی^۶ استفاده می‌شود که شامل دو مرحله انتشار رو به جلو و انتشار رو به عقب است. در مرحله انتشار رو به جلو، ورودی شبکه تا لایه چهارم عبور می‌کند، جایی که پارامترهای خروجی با استفاده از روش کمترین مربعات تعیین می‌شوند. در مرحله‌ی انتشار رو به عقب، پس از محاسبه خطا، سیگنال خطا به عقب ارسال

¹ membership function

² adaptive nodes

³ Hybrid Learning Algorithm

⁴ backpropagation

⁵ least squares

⁶ gradient descent

⁷ premise parameters

⁸ Local Linear Model Tree

⁹ curse of dimensionality

¹⁰ divide and conquer

¹¹ axis-aligned splits

شکل (۳) ساختار شبکه درخت محلی خطی را نشان می‌دهد. رابطه ورودی-خروجی مدل‌های عصبی-فازی خطی محلی طبق رابطه (۳) می‌باشد.


در رابطه (۳)، Q تعداد نورون‌ها، $x = [x_1, x_2, \dots, x_n]^T$ ورودی مدل، n تعداد ابعاد ورودی، N تعداد نمونه‌های ورودی و وزن‌های پارامترهای مدل خطی محلی برای نورون q ام و ورودی n ام می‌باشند Φ_q وزن نرمال‌شده نورون q و μ_q تابع عضویت مدل q است، که طبق رابطه (۴) و (۵) است. در این روابط ریاضی، c_q بردار مرکز مدل و σ_q^2 بردار واریانس هر بعد برای نورون q ام می‌باشد.

زیرفضاهای کوچکتر است که توسط توابع اعتبار فازی تعریف می‌شوند. هر بخش خطی حاصل، همراه با تابع اعتبار مربوط به خود، می‌تواند به عنوان یک نورون فازی در نظر گرفته شود. در نتیجه، کل مدل مانند یک شبکه عصبی-فازی با یک لایه پنهان عمل می‌کند که در لایه خروجی آن یک نورون خطی قرار دارد و مجموع وزنی خروجی‌های مدل‌های خطی محلی را محاسبه می‌کند. خروجی کلی شبکه به صورت یک مجموع وزنی از خروجی‌های مدل‌های خطی محلی تعیین می‌شود که در آن تابع اعتبار به عنوان ضریب وزنی عمل می‌کند و وابسته به نقطه عملکرد است. معمولاً توابع اعتبار به صورت توزیع‌های گاوسی نرمال شده نمایش داده می‌شوند [۳۳ و ۳۴].

$$\hat{y}_q = w_{q0} + w_{q1}x_1 + w_{q2}x_2 + \dots + w_{qn}x_n \cdot \hat{y} = \sum_{q=1}^Q y_q \Phi_q(x) \quad \text{رابطه (۳)}$$

$$\Phi_q(x) = \frac{\mu_q(x)}{\sum_{n=1}^Q \mu_n(x)} \quad \text{رابطه (۴)}$$

$$\mu_q(x) = \exp\left(\frac{(x_1 - c_{q1})^2}{-2\sigma_{q1}^2}\right) + \dots + \exp\left(\frac{(x_n - c_{qn})^2}{-2\sigma_{qn}^2}\right) \quad \text{رابطه (۵)}$$



شکل ۳: پیکربندی یک شبکه نوروفازی خطی محلی ایستا با Q نورون برای N ورودی [۳۵]

نورون LLM برای تقسیم انتخاب می‌گردد. در مرحله دوم، تمام تقسیم‌های ممکن این LLM در فضای ورودی تولید و ارزیابی می‌شوند و در مرحله سوم آموزش و بهینه‌سازی مدل‌های جدید با روش حداقل مربعات انجام می‌شود [۳۶].

شکل (۴)، پنج تکرار اول الگوریتم $LOLIMOT$ را بر روی یک فضای ورودی دوبعدی نشان می‌دهد. مزیت $LOLIMOT$ نسبت به $ANFIS$ ، کارایی بهتر در ابعاد بالاتر و جلوگیری از پیچیدگی بیش از حد مدل است. در این مدل‌سازی نیز ورودی‌ها همان پارامترهای میدان ثقل و خروجی عمق سنجی بوده است.

۲-۴- داده گوازی

برای بهبود مدل‌سازی ریاضی عمق‌سنجی با استفاده از داده‌های محلی، در این مقاله از روش $3DVAR$ استفاده شده است [۳۷]. این روش، برآورد بهینه عمق را از طریق کمینه‌سازی تابع هزینه^۴ (رابطه (۱۰)) فراهم می‌کند [۳۸ و ۳۹].

در رابطه (۱۰)، x بردار وضعیت شامل عمق بهبودیافته، x^b عمق‌سنجی حاصل از مدل پایه، B ماتریس کوواریانس خطای مدل، R ماتریس کوواریانس خطای مشاهدات است. در اینجا، ماتریس A اپراتور درونیاب، ماتریس B ماتریس کوواریانس ارتفاع‌سنجی با استفاده از مدل عصبی-فازی است و با استفاده از میانگین مربعات خطا به دست آمده از مدل به عنوان عناصر قطری آن تخمین زده می‌شود، ماتریس R نیز ماتریس کوواریانس مشاهدات اکوساندر است که در تقریب مرتبه اول به شکل یک ماتریس قطری است که عناصر قطری آن دقت ابزار می‌باشند.

$LOLIMOT$ روشی افزایشی برای ساخت مدل‌های خطی محلی در زیرناحیه‌های ورودی است که بر اساس توابع اعتبار^۱ فازی، فضای ورودی را به بخش‌های کوچک‌تر تقسیم می‌کند [۳۳ و ۳۴]. هر بخش دارای یک مدل خطی و یک تابع اعتبار است که به صورت توزیع گاوسی نرمال شده تعریف می‌شود. نرمال‌سازی برای تفسیر دقیق این توابع اعتبار ضروری است.

هر تابع اعتبار گاوسی با دو پارامتر مرکز c_{qn} و انحراف معیار σ_{qn} تعریف می‌شود. بهینه‌سازی محلی پارامترهای خطی با استفاده از روش کمترین مربعات انجام می‌گیرد. ماتریس رگرسیون متناظر و ماتریس وزن برای نمونه داده‌های اندازه‌گیری شده به صورت رابطه (۶) و رابطه (۷) تعریف می‌شود:

$$X = \begin{bmatrix} 1 & x_1(1) & \dots & x_n(1) \\ 1 & x_1(2) & \dots & x_n(2) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_1(N) & \dots & x_n(N) \end{bmatrix} \quad \text{رابطه (۶)}$$

$$P_q = \begin{bmatrix} \Phi_q(x(1)) & 0 & 0 & 0 \\ 0 & \Phi_q(x(2)) & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \Phi_q(x(N)) \end{bmatrix} \quad \text{رابطه (۷)}$$

بنابراین، بردار پارامترهای خطی قانون محلی q ام بصورت رابطه (۸) و خروجی پیش‌بینی شده برای قانون مذکور از رابطه (۹) حاصل می‌گردد:

$$W_q = [w_{q0} \ w_{q1} \ w_{q2} \ \dots \ w_{qn}]^T \quad \text{رابطه (۸)}$$

$$\hat{y}_q = XW_q; \hat{W}_q = (X^T P_q X)^{-1} X^T P_q y_q \quad \text{رابطه (۹)}$$

$LOLIMOT$ یک الگوریتم افزایشی است که شامل سه مرحله تکراری می‌باشد. ابتدا، کمترین مدل خطی محلی مؤثر^۲ بر اساس توابع خطای محلی^۳ شناسایی و

^۱ validity functions

^۲ Least Effective Local Linear Model

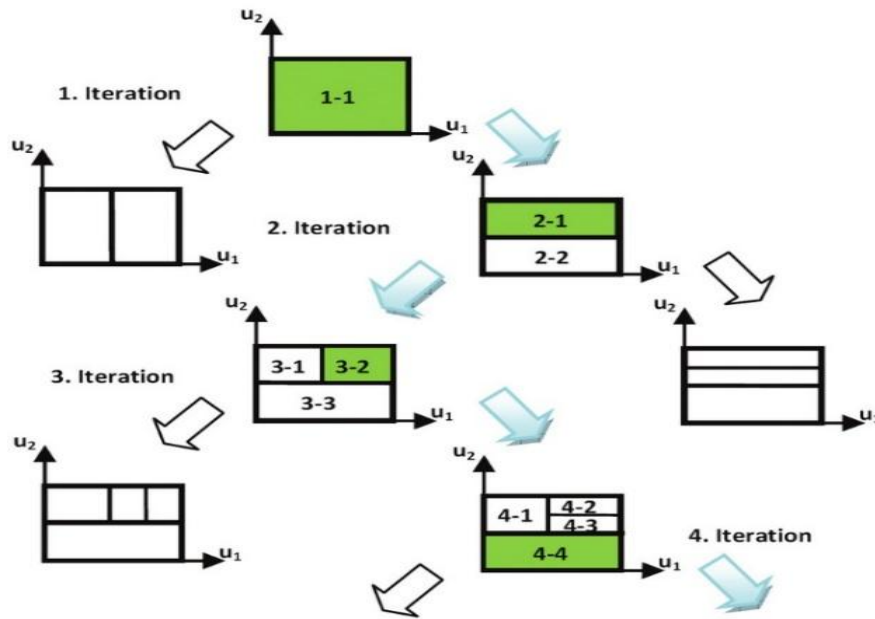
^۳ Local Loss Functions

^۴ custom function

$$J = \frac{1}{2}(x - x^b)^T B^{-1}(x - x^b) + \frac{1}{2}(y - Ax^b)^T R^{-1}(y - Ax^b)$$

$$x = x^b + W(y - Ax^b) \quad \text{رابطه (۱۰)}$$

$$W = BA^T(ABA^T + R)^{-1}$$



شکل ۴: عملکرد الگوریتم LOLIMOT در پنج تکرار اولیه برای یک فضای ورودی دوبعدی

۳- نتایج و تحلیل

همان طور که پیش تر ذکر شد، رابطه غیرخطی فیزیکی بین پارامترهای میدان جاذبه مانند ارتفاع ژئوئید، آنومالی جاذبه و گرادیان‌های جاذبه با ارتفاع سنجی کف دریا و دشواری دستیابی به یک راه حل قطعی^۱، اثبات شده است [۲۴]. بنابراین، یک روش داده محور مبتنی بر الگوریتم‌های هوش مصنوعی برای مدل سازی ارتفاع سنجی کف دریا در این پژوهش پیشنهاد شده است. در این راستا، ورودی‌های الگوریتم‌های هوش مصنوعی شامل ارتفاع ژئوئید تعیین شده توسط ارتفاع سنجی ماهواره‌ای، گرادیان‌های جاذبه مدل XGM2019e و داده‌های آنومالی جاذبه استخراج شده از

ارتفاع سنجی ماهواره‌ای و اندازه گیری‌های دریایی و خروجی مدل، ارتفاع سنجی بستر دریا GEBCO می باشد. به طور کلی، برای مدل سازی ارتفاع سنجی بستر دریا دو مرحله اصلی زیر انجام می شود:

۱- شناسایی الگوریتم‌های مناسب هوش مصنوعی، برای مدل سازی ارتفاع سنجی بستر در خلیج فارس و دریای عمان.

۲- بهبود مدل ارتفاع سنجی کف دریا با داده گواری داده‌های عمق محلی.

بدین ترتیب مدل سازی در دو گام انجام شده است.

۳-۱- گام اول: مدل سازی با مدل عصبی- فازی

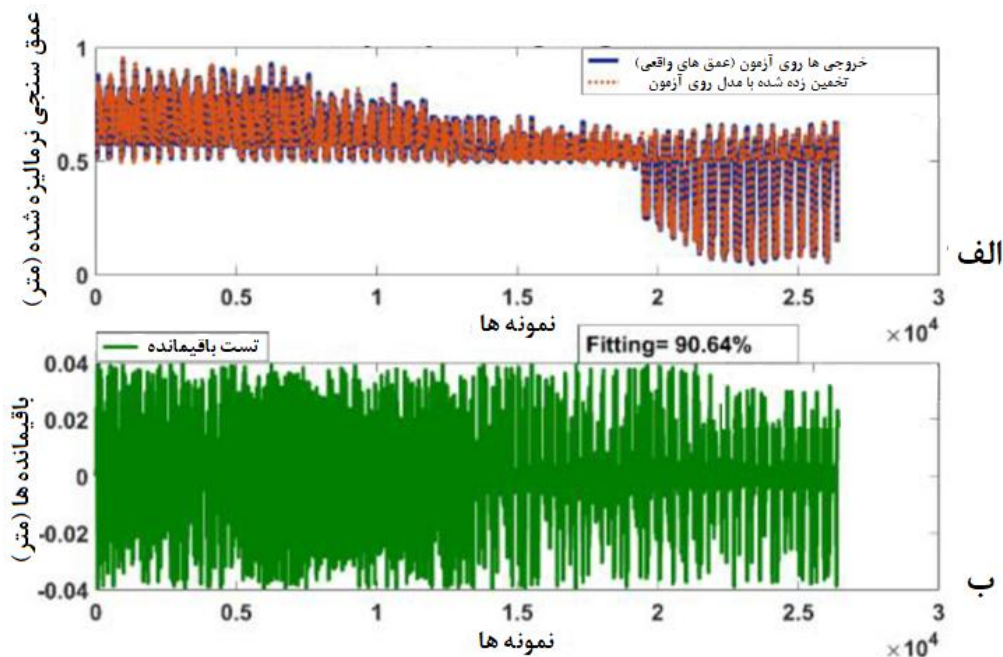
دو مدل ANFIS و LOLIMOT با داده‌های ورودی و خروجی فوق آموزش داده شدند. کل نقاط نمونه برداری در حدود ۹۰,۰۰۰ نقطه می باشد که برای هر مدل، داده‌ها به دو بخش آموزش (۷۰٪) و آزمون (۳۰٪)

¹ deterministic solution

۳-۱-۲- مدل سازی با مدل *LOLIMOT*

برای استفاده از *LOLIMOT* بایستی موارد زیر در نظر گرفته شود: مشابه مدل سازی قبلی، داده های ورودی و خروجی به دو بخش آموزش و آزمون تقسیم شوند، داده های ورودی و خروجی نرمال سازی شوند و تعداد

بهینه اپوک و نرون انتخاب گردد. شکل (۶) مدل سازی عمق سنجی با استفاده از *LOLIMOT* روی داده های آزمون را نشان می دهد که با دقت ۹۰٫۶۴٪ هم خوانی دارد.



شکل ۶: مدل سازی عمق سنجی با استفاده از *LOLIMOT* روی داده های آزمون شامل (الف) عمق نرمالیزه شده و (ب) باقیمانده های بین عمق حاصل از داده های واقعی و برآورد شده با مدل

جاذبه *XGM2019e* و داده های عمق سنجی *GEBCO* که در مدل پایه به کار گرفته شدند، نتایج تحت تأثیر دقت داده های ورودی و خروجی به ویژه در آب های کم عمق قرار گرفتند، برای بهبود مدل پایه از طریق مشاهدات محلی عمق، از روش داده گواری استفاده شد. در این راستا، ما سه نوع داده عمق سنجی در مناطق چابهار، گناوه و علمشاه در اختیار داریم: الف- عمق برداشت شده از اندازه گیری های اکوساندر ب- عمق به دست آمده از مدل پایه ج- عمق سنجی حاصل از مدل جهانی *GEBCO*. برای اعتبار سنجی مدل نهایی استخراج شده از داده گواری، دو پروفیل عمق سنجی اندازه گیری شده توسط اکوساندر در محاسبات استفاده نشدند و صرفاً برای مقایسه و به عنوان نقاط کنترل به

به طور خلاصه هدف از گام ۱، مشاهده جزئیات کامل تعیین ساختار مدل ورودی-خروجی، مدل سازی عمق-سنجی در خلیج فارس و دریای عمان و استفاده از این مدل به دست آمده در گام بعدی برای داده گواری است.


۳-۲- گام دوم - داده گواری

پس از شناسایی ساختار مدل ها در گام اول، با توجه به آن که مدل *LOLIMOT* با دقت بهتری مدلسازی عمق را انجام می دهد، این مدل به عنوان مدل پایه مورد استفاده قرار گرفت. به دلیل قدرت تفکیک متوسط داده های ورودی و خروجی برای فرآیند مدل سازی داده های ارتفاع ژئوئید استخراج شده از ارتفاع سنجی ماهواره ای و آنومالی جاذبه، همچنین محدودیت های موجود در گردان های جاذبه بر اساس مدل جهانی


از فقدان داده‌های عمق و دقت پایین ارتفاع سنجی ماهواره‌ای و محدودیت‌های مدل‌های جهانی جاذبه در نواحی ساحلی است. در بخش‌های عمیق‌تر اقیانوس، به دلیل افزایش دقت ارتفاع سنجی ماهواره‌ای، تطابق بسیار خوبی بین عمق سنجی مدل‌سازی شده و داده‌های محلی مشاهده می‌شود. در مناطق چابهار، گناوه و علمشاه، صخره‌ها و تپه‌هایی در مدل نهایی دیده می‌شوند. شکل (۸) مدل نهایی حاصل از داده‌گذاری را در این مناطق نشان می‌دهد. این مدل می‌تواند از داده‌های ورودی برای تولید داده‌های عمق استفاده کند. علاوه بر این، لازم است مدل نهایی به‌طور مناسب برای در نظر گرفتن تغییرات ناگهانی زمین‌شناسی زیرسطحی در مناطق فراساحل تنظیم شود. همچنین دسترسی به داده‌های ارتفاع سنجی با تفکیک‌پذیری بالاتر می‌تواند پیش‌بینی‌های عمق سنجی را بهبود دهد.

کار رفتند. شکل (۷) نمونه‌ای از مقایسه بین مدل نهایی و داده‌های عمق سنجی اکوساندر را در امتداد یک پروفیل در منطقه چابهار نشان می‌دهد. مقایسه بین مدل نهایی و اندازه‌گیری‌های عمق اکوساندر در مناطق چابهار، گناوه و علمشاه (پروفیل کنترلی که در فرآیند داده‌گذاری استفاده نشده بود) به ترتیب به مقادیر $RMSE$ ۴۰ متر، ۰/۸ متر و ۰/۹۲ متر منجر شد. پیش از داده‌گذاری، مقادیر $RMSE$ در همان مناطق به ترتیب در حدود ۶/۱ متر، ۲/۵ متر و ۲/۰ متر بودند. این موضوع نشان می‌دهد که مدل نهایی نمی‌تواند به‌طور کامل داده‌های عمق سنجی اکوساندر را بازتولید کند، سایر مطالعات نیز این موضوع را تأیید کرده‌اند [۴۰ و ۴۱].


مدل نهایی قادر است بخش عمده‌ای از ویژگی‌های بستر دریا با فرکانس بالا مانند کوه‌های دریایی را استخراج کند، اما همچنان دارای نوسانات زیادی ناشی




شکل ۷: یک مقایسه‌ی معمول بین داده‌های عمق سنجی اکوساندر و مدل نهایی در امتداد مسیر در منطقه چابهار



(الف)



(ب)



(ج)

شکل ۸: مدل نهایی در مناطق (الف) چابهار (ب) گناوه (ج) علمشاه با استفاده از داده گواری مشاهدات محلی اکوساندر

۴- نتایج، بحث و پیشنهادها

رویکردهای سنتی در مدل‌سازی توپوگرافی بستر دریا عمدتاً بر فرمول‌های شناخته‌شده‌ای مانند مدل پارکر تکیه داشته‌اند. این روش‌ها با دشواری‌های ذاتی نظیر نداشتن دانش کافی برای برآورد دقیق پارامترهای مدل و استفاده از تقریب‌های خطی در فرآیند اجرا که می‌تواند منجر به بروز خطا و سوگیری محاسباتی شود، مواجهند. علاوه بر این، تعیین بستر دریا بر اساس آنومالی گرانشی اساساً یک مسئله معکوس ناپایدار است و حل آن نیازمند به‌کارگیری تکنیک‌های پایدارسازی است.

با معرفی روش‌های هوش مصنوعی، ابزارهای مدل‌سازی از رویکردهای فیزیکی به روش‌های ریاضی تغییر مسیر داده‌اند. بر این اساس، در این مقاله نیز روشی جایگزین برای مدل‌سازی توپوگرافی بستر دریا معرفی شده است. مهم‌ترین مزیت این روش، انعطاف‌پذیری و سرعت بالای آن در استفاده از داده‌های متنوع و بزرگ‌ترین چالش آن، وابستگی شدید به داده‌های ورودی است. بنابراین، نیازمند پایش و کنترل کیفی دقیق داده‌های ورودی برای حصول نتایج قابل اعتماد است.

نتایج این مطالعه، تاثیر ترکیب منابع مختلف داده‌های گرانشی با تکنیک‌های مدل‌سازی عصبی-فازی را برای برآورد بستر دریا نشان داد. در مقایسه با رویکردهای سنتی، این روش امکان نمایش بهتر روابط غیرخطی بین پارامترهای گرانشی و توپوگرافی بستر دریا را فراهم می‌سازد.

در حالی که مطالعات قبلی از رویکردهای مشابهی بهره برده‌اند، مزیت این پژوهش، ادغام داده‌های ارتفاع سنجی ماهواره‌ای، ثقل‌سنجی و داده‌های دریایی برای افزایش دقت به‌ویژه در مناطق با مشاهدات محدود تأکید دارد. برخلاف تحقیقات پیشین که معمولاً به یک مدل تکیه داشتند، این پژوهش دو تکنیک مدل‌سازی عصبی-فازی *ANFIS* و *LOLIMOT* را به‌عنوان مدل‌های اصلی ارزیابی کرده و سپس داده‌های بستر دریا از اندازه‌گیری‌های اکوساندر از طریق روش *3DVAR*

به مدل اضافه می‌شود. این راهبرد ترکیبی منجر به بهبود دقت و وضوح محلی عمق‌سنجی گردید.

از جمله محدودیت‌های ارتفاع‌سنجی ماهواره‌ای در نواحی ساحلی تحت تأثیر شکل موج قرار می‌گیرند، در حالی که در آب‌های آزاد از مدل براون پیروی می‌کنند. در مناطق ساحلی، عواملی همچون عمق کم باعث پیچیدگی این مدل و ایجاد خطا در تعیین فاصله می‌شوند؛ بنابراین، تصحیحات بازتعقیب موجود در فایل‌های داده ژئوفیزیکی (*GDR*) تا فاصله ۱۰ کیلومتری از ساحل برای مشاهدات اعمال شده است. بر خلاف داده‌های ثقل حاصل از ارتفاع‌سنجی ماهواره‌ای که دقت آن‌ها در نزدیکی مناطق ساحلی به‌طور قابل توجهی کاهش می‌یابد، داده‌های ثقل‌سنجی دریایی عموماً دقت بالاتری دارند، هرچند ممکن است تحت تأثیر عوامل محیطی محلی قرار گیرند. برای کاهش این اثرات، از تکنیک‌های هوش مصنوعی استفاده شده تا وزن بیشتری به اندازه‌گیری‌های میدانی ثقل و داده‌های مدل ثقل در مناطق ساحلی اختصاص داده شود. با وجود این اقدامات، دقت برآورد عمق در نواحی ساحلی همچنان کمتر از نواحی فراساحلی است. لذا می‌توان از تکنیک‌های نوین بازتعقیب در افزایش دقت مناطق ساحلی در مطالعات آتی استفاده کرد. پیش‌بینی‌های بهبودیافته محلی و منطقه‌ای از توپوگرافی بستر دریا، داده‌های ارزشمندی فراهم می‌کنند که می‌توانند در بهبود مدل‌های جهانی بستر دریا مانند *ETOPO5* و *GEBCO* مورد استفاده قرار گیرند.

نتایج نشان دهنده کارایی بالای این روش بوده و در میان الگوریتم‌های بررسی‌شده، مدل *LOLIMOT* با برآزش ۹۰٫۶۴ درصد بر روی داده‌های آزمون، دقیق‌ترین عملکرد را دارد. برای بهبود بیشتر مدل عمق‌سنجی، اندازه‌گیری‌های عمق‌سنجی اکوساندر با استفاده از روش *3DVAR* در مدل تلفیق شدند. مقایسه بین مدل نهایی و داده‌های اکوساندر در مسیرهای کنترلی که در آموزش دخیل نبودند نشان داد که

اختصاصی برای هر ناحیه، توانایی بیشتری در تقریب روابط غیرخطی داده‌ها دارد. در مقابل، ANFIS به ساختار ثابت و انتخاب اولیه توابع عضویت وابسته است و در صورت عدم تطابق کامل با الگوی داده‌ها، دقت آن محدود می‌شود. بنابراین برتری LOLIMOT می‌تواند ناشی از انعطاف‌پذیری بیشتر آن در یادگیری محلی و بهینه‌سازی مرحله‌به‌مرحله باشد.

این مطالعه بر اهمیت ترکیب همزمان داده‌های ژئودتیکی و داده‌های محلی برای توسعه مدل‌های دقیق و قابل اعتماد عمق‌سنجی تأکید می‌کند. همچنین روش ارائه‌شده می‌تواند برای کاربردهایی چون اقیانوس‌شناسی فیزیکی، زمین‌شناسی دریایی و اکوهیدرولیک که نیازمند شناخت جزئی الگوهای عمق‌سنجی منطقه‌ای هستند، ارزشمند باشد. علاوه بر این، به بهبود درک فرایندهای اقیانوسی، ارتقاء مدلسازی بستر دریاها و اقیانوسها و پشتیبانی از مدیریت پایدار منابع دریایی کمک می‌کند.

خطای $RMSE$ در مناطق چابهار، گناوه و علمشاه به ترتیب حدود ۴/۰ متر، ۰/۸ متر و ۰/۹۲ متر است. این نتایج دقت و قابلیت اعتماد روش پیشنهادی را نشان می‌دهد.

با توجه به اینکه گناوه و علمشاه در منطقه خلیج فارس واقع شده‌اند، حداکثر عمق ثبت شده در پروفیل‌های برداشت شده حدود ۷۰ متر است. با این حال، هرچه به سمت شرق پیش می‌رویم، عمق افزایش می‌یابد، بطوری‌که در منطقه چابهار عمق در نقاط کنترل تا ۱۲۰۰ متر نیز گزارش شده است. بنابراین، افزایش $RMSE$ در این منطقه قابل توجیه است، لیکن دقت نسبی در بیشتر نقاط تقریباً مشابه و نزدیک به هم باقی مانده است.

همچنین دقت بالاتر مدل LOLIMOT نسبت به مدل ANFIS می‌تواند به نحوه تقسیم‌بندی تطبیقی فضای ورودی در LOLIMOT مربوط باشد. این مدل با ایجاد نواحی محلی و آموزش مدل‌های خطی ساده اما

مراجع

- [1] W.M. Wollheim, T.K. Harms, A.L. Robison, L.E. Koenig, A.M. Helton, C. Song, W.B. Bowden and J.C. Finlay, "Superlinear scaling of riverine biogeochemical function with watershed size", *Nature communications*, 13(1), 1-9, 2022, <https://doi.org/10.1038/s41467-022-28630-z>.
- [2] Q. Peng, S.P. Xie, D. Wang, R.X. Huang, G. Chen, Y. Shu, J. R. Shi, and W. Liu, "Surface warming-induced global acceleration of upper ocean currents", *Science advances*, 8(16), eabj8394, 2022, <https://doi.org/10.1126/sciadv.abj839>.
- [3] D. Pirone, L. Cimorelli, G. Del Giudice and D. Pianese, "Short-term rainfall forecasting using cumulative precipitation fields from station data: a probabilistic machine learning approach", *J. Hydrol*, 128949, 2023, <https://doi.org/10.1016/j.jhydrol.2022.128949>.
- [4] S.G. Jin, A. Camps, Y. Jia, F.Wang, M. Martin-Neira, F. Huang, Q. Yan, S. Zhang, Z. Li, K. Edokossi, D.Yang, , Z. Xiao, , Z. Ma, and W. Bai, "Remote sensing and its applications using GNSS reflected signals: Advances and prospects", *Satell. Navig.*, 5, 19, 2024, <https://doi.org/10.1186/s43020-024-00139-4>.
- [5] Q. Zhu and P.L Wiberg, "The importance of storm surge for sediment delivery to micro-tidal marshes", *Journal of Geophysical Research: Earth Surface*, 127(9), e2022JF006612, 2022, <https://doi.org/10.1029/2022JF006612>.
- [6] R. L Parker, "The Rapid Calculation of Potential Anomalies", *Geophys. J. R. astr. Soc.* 31,447-455, 1973, <https://doi.org/10.1111/j.1365-246X.1973.tb06513.x>.
- [7] S. Wiehle, B. Martinez, K. Hartman, M. Verlaan, T. Thornton, S. Lewis and D. Schaap, "The BASE-platform project:

- Deriving the bathymetry from combined satellite data*, 2016, URL: www.base-platform.com.
- [8] D.W. Oldenburg, "The inversion and interpretation of gravity anomalies", *Geophysics*, 39(4), 526–536, 1974.
- [9] R.N. Mitchell, N. Zhang, J. Salminen, Y. Liu, C.J. Spencer, B. Steinberger, B. Murphy, and Z.X. Li, "The supercontinent cycle. *Nature Reviews Earth & Environment*, 2(5), 2021, 358-374. <https://doi.org/10.1038/s43017-021-00160-0>.
- [10] R. Tenzer, W. Chen and S.G. Jin, "Effect of the upper mantle density structure on the Moho geometry", *Pure Appl. Geophys.*, 172(6), 1563-1583, 2015, doi: 10.1007/s00024-014-0960-2.
- [11] W.A. Yonkee and A.B. Weil, "Tectonic evolution of the Sevier and Laramide belts within the North American Cordillera orogenic system", *Earth-Science Reviews* 150, 531-593, 2015, <https://doi.org/10.1016/j.earscirev.2015.08.001>.
- [12] W.H.F. Smith, D. T. Sandwell and R. K. Raney, "Bathymetry from satellite altimetry: Present and future", *Proceedings of OCEANS 2005 MTS/IEEE, IEEE, Washington, DC, USA*, 2586-2589, 2005, <https://doi.org/10.1109/OCEANS.2005.1640160>.
- [13] A. Abulaitijiang, O.B. Andersen, D. Sandwell, "Improved Arctic Ocean bathymetry derived from DTU17 gravity model", 2019, *Earth and Space Science*, 6(8), 1336-1347, <https://doi.org/10.1029/2018EA000502>.
- [14] J.A. Olive, M.D. Behn, G. Ito, W.R. Buck, J. Escartin and S. Howell, "Sensitivity of seafloor bathymetry to climate-driven fluctuations in mid-ocean ridge magma supply", *Science*, 350(6258), 310-313, 2015, <https://doi.org/10.1126/science.aad0715>.
- [15] X. Wan, J. Ran and S. Jin, "Sensitivity analysis of gravity anomalies and vertical gravity gradient data for bathymetry inversion", *Marine Geophysical Research*, 40, 87-96, 2019, <https://doi.org/10.1007/s11001-018-9361-8>.
- [16] C. Xu, J. Li, G. Jian, Y. Wu and Y. Zhang, "An adaptive nonlinear iterative method for predicting seafloor topography from altimetry-derived gravity data", *Journal of Geophysical Research: Solid Earth*, e2022JB025692, 2023, <https://doi.org/10.1029/2022JB025692>.
- [17] V. Lecours, M.F. Dolan, A. Micallef and V.L. Lucieer, "A review of marine geomorphometry, the quantitative study of the seafloor", *Hydrology and Earth System Sciences*, 20(8), 3207-3244, 2016, <https://doi.org/10.5194/hess-20-3207-2016>.
- [18] S. Zhou, X. Li, Y. Sun, X. Chang, Y. Jia, J. Guo, and h. Sun, "Predicting bathymetry using multisource differential marine geodetic data with multilayer perceptron neural network", *Earth System Science Data, International Journal of Digital Earth*, 17(1), 2024, <https://doi.org/10.1080/17538947.2024.2393255>.
- [19] S. Zhou, J. Guo, H. Zhang, Y. Jia, H. Sun, X. Liu and D. An, "SDUST2023BCO: A global seafloor model determined from a multi-layer perceptron neural network using multi-source differential marine geodetic data", *Earth System Science Data*, 17(1), 165–179, 2025, <https://doi.org/10.5194/essd-17-165-2025>.
- [20] X. Ge, L. Wang, Y. Liu, and Z. Zhang, "Seafloor topography inversion from multi-source marine gravity data using multi-channel convolutional neural network", *Engineering Applications of Artificial Intelligence*, 139, 109567, 2025, <https://doi.org/10.1016/j.engappai.2024.109567>.
- [21] Z. Yuan, H. Chen, Y. Wang, and X. Li, "Seabed depth prediction using multi-scale

- gravity anomalies and fully connected deep neural networks: A novel approach applied to the South China Sea", *Remote Sensing*, 17(3), 412, 2025, <https://doi.org/10.3390/rs17030412>.
- [22] X. An, Y. Zhang, J. Li and H. Wang, "Improved gravity-geologic method reliably removing the long-wavelength gravity effect of regional seafloor topography: A case of bathymetric prediction in the South China Sea", *IEEE Transactions on Geoscience and Remote Sensing*, 60, 4211912, 2022, <https://doi.org/10.1109/TGRS.2022.3223047>.
- [23] J. Lei, R. Schaefer, P. Colarusso, A. Novak, J.C. Simpson, P. Masqué, H.M. Nepf, "Spatial heterogeneity in sediment and carbon accretion rates within a seagrass meadow correlated with the hydrodynamic intensity. *Science of the total environment*", 854, 158685, 2023, <https://doi.org/10.1016/j.scitotenv.2022.158685>.
- [24] D. Fan, S. Li, X. Li, J. Yang and X. Wan, "Seafloor Topography Estimation from Gravity Anomaly and Vertical Gravity Gradient Using Nonlinear Iterative Least Square Method", *Remote Sens*, 13, 64, 2021, <https://doi.org/10.3390/rs13010064>.
- [25] T.J. Majumdar and S. Chander, "Simulation of SARAL (Satellite with ARGOS and ALtika) resolution gravity over the western Indian offshore for geological/structural interpretation", *Geocarto International*, 26(1), 21-34, 2011, <https://doi.org/10.1080/10106049.2010.535617>.
- [26] A. Soltanpour, M. Pirooznia, S. Aminjafari and P. Zareian, "Persian Gulf and Oman sea tide modeling using satellite altimetry and tide gauge-data (TM-IR01)", *Marine Georesources & Geotechnology*, 1-11, 2017, <https://doi.org/10.1080/1064119x.2017.1366608>.
- [27] M. Pirooznia, S.R. Emadi, and M.N. Alamdari, "The Time Series Spectral Analysis of Satellite Altimetry and Coastal Tide Gauges and Tide Modeling in the Coast of Caspian Sea", *Open Journal of Marine Science*, 6, 258-269, 2016, <http://dx.doi.org/10.4236/ojms.2016.62021>.
- [28] R. Rummel, L.E. R. Sjöberg, "The determination of gravity anomalies from geoid heights using the inverse Stokes' formula, Fourier transforms, and least squares collocation". NASA Contract Report 141442, Department of Geodetic Science, The Ohio State University, Columbus, Ohio, USA, p 65,1978.
- [29] M. Zounemat-Kermani, E.Matta, A. Cominola, X. Xia, Q. Zhang, Q. Liang and R. Hinkelmann, "Neurocomputing in surface water hydrology and hydraulics: A review of two decades retrospective, current status and future prospects", *Journal of Hydrology*, 588, 125085, 2020. <https://doi.org/10.1016/j.jhydrol.2020.125085>
- [30] S. Yang, D. Yang, J. Chen and B. Zhao, "Real-time reservoir operation using recurrent neural networks and inflow forecast from a distributed hydrological model", *Journal of Hydrology*, 579, 124229, 2019, <https://doi.org/10.1016/j.jhydrol.2019.124229>
- [31] W. Suparta, and K. M. Alhasa, "A comparison of ANFIS and MLP models for the prediction of precipitable water vapor" 2013 IEEE International Conference on Space Science and Communication (IconSpace), 29, 243-248, 2013, doi:10.1109/iconspace.2013.6599473.
- [32] M.A. Shoorehdeli, M. Teshnehlab and A.K. Sedigh, "Novel Hybrid Learning Algorithms for Tuning ANFIS Parameters Using Adaptive Weighted PSO" 2007 IEEE International Fuzzy Systems Conference, 2007, <https://doi.org/10.1109/fuzzy.2007.4295571>
- [33] L. Duncanson, J.R. Kellner, J. Armston and R. Dubayah, "Aboveground biomass

- density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission", *Remote Sensing of Environment* 270, 112845, 2022, <https://doi.org/10.1016/j.rse.2022.113180>.
- [34] O. Nelles, "Nonlinear local optimization", *Nonlinear System Identification*, 79-112, 2001, doi:10.1007/978-3-662-04323-3_4.
- [35] A. Hajian, H. Zomorrodian, P. Styles, F. Greco, and C. Lucas, "Depth estimation of cavities from microgravity data using a new approach: the local linear model tree (LOLIMOT)", *Near Surface Geophysics*, 10: 221-234, 2012, <https://doi.org/10.3997/1873-0604.20111039>.
- [36] D. Schwingshackl, J. Rehrl, M. Horn, J. Belz, and O. Nelles, "Model extension for model-based MIMO control in HVAC systems", *Journal of Building Engineering*, 11, 224-229, 2017, <https://doi.org/10.1016/j.jobe.2017.04.015>.
- [37] A. Teruzzi, S. Dobricic, C. Solidoro and G. Cossarini, "A 3-D variational assimilation scheme in coupled transport-biogeochemical models: Forecast of Mediterranean biogeochemical properties", *Journal of Geophysical Research: Oceans*, 119(1), 200-217, 2014, <https://doi.org/10.1002/2013JC009277>.
- [38] M. Pirooznia, M. Raoofian Naeeni, and M.J. Tourian, "Modeling total surface current in the Persian Gulf and the Oman Sea by combination of geodetic and hydrographic observations and assimilation with in situ current meter data", *Acta Geophys.* 71, 2839-2863, 2023, <https://doi.org/10.1007/s11600-022-00985-3>.
- [39] M. Pirooznia, B. Voosoghi, D. Poreh and A. Amini, "Integrating Hydrography Observations and Geodetic Data for Enhanced Dynamic Topography Estimation", *Remote Sens.* 16, 527, 2024, <https://doi.org/10.3390/rs16030527>.
- [40] L. Vrdoljak and T. Bašić, "Bathymetry estimation from satellite altimeter-derived gravity data", *Satellite Altimetry - Theory, Applications and Recent Advances*, 2023, <https://doi.org/10.5772/intechopen.108511>
- [41] W.H.F. Smith and R.E. Moose, "Comparison of marine gravity anomalies measured by ships and estimated from satellite altimetry in near-shore areas", *Eos Trans. AGU, Spring Meet. Suppl.*, S103, 1997.



Prediction of bathymetry Using Neuro-Fuzzy Models: A Comparative Study with Geodetic Data fusion and Optimization Based on Local Data

Mohammad Ali Mohammad¹, Iraj Jazireeyan^{2*}, Mahmoud Pirooznia³

1- Ph.D. student in Geodesy, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

2- Assistant Professor, Department of Geodesy, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

3- Assistant Professor, Department of Geomatics Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University

Abstract

Accurate knowledge of seabed depth plays a crucial role in understanding oceanic processes, physical oceanography, marine biology, ecohydraulics, and marine geology. Conventional depth modeling methods are commonly based on satellite altimetry, gravity models or marine gravimetry data, which often lack sufficient accuracy or spatial resolution. In this study, a comparative analysis of neuro-fuzzy models was conducted for regional bathymetry modeling in the Persian Gulf and the Oman Sea, and the results were optimized through using the local datasets. For this purpose, Adaptive Neuro-Fuzzy Inference System (ANFIS) and Local Linear Model Tree (LOLIMOT) were applied as nonlinear models to identify the relationship between the inputs and outputs. The model inputs consisted of geodetic data, including geoid height, gravity gradient, and gravity anomaly, while the output was the GEBCO bathymetric dataset. The results indicated that the LOLIMOT model showed a better agreement with the test data. Consequently, the baseline model was refined by assimilating in-situ depth observations using the three-dimensional variational (3DVAR) optimization method, which led to the development of the final bathymetric model. The proposed approach was validated along the control track soundings from Chabahar, Genaveh, and Alamshah regions, demonstrating high accuracy with RMSE values of approximately 0.4 m, 0.8 m, and 0.9 m, respectively. This modeling framework provides a robust and accurate method for seabed depth analysis and prediction in both scientific and applied studies.

Key words: Bathymetry Modeling, Satellite Altimetry, Marine Gravity, Machine Learning, Neuro-Fuzzy Model.

Correspondence Address: Geomatics Engineering Faculty, K. N. Toosi University of Technology, Tehran, Iran.

Tel: +98 21 88877070

Email: jazirian@kntu.ac.ir