

## تشخیص آنومالی‌های حرارتی قبل از وقوع زلزله با تلفیق الگوریتم‌های شبکه عصبی مصنوعی و بهینه‌سازی کلونی مورچه



سپهر چوب‌ساز\*

کارشناس ارشد، مهندسی سنجش از دور، گروه مهندسی نقشه‌برداری پردیس دانشکده‌های فنی، دانشگاه تهران، ایران

مه‌دی آخوندزاده هنزائی (makhonz@ut.ac.ir)

استادیار، گرایش سنجش از دور گروه مهندسی نقشه‌برداری پردیس دانشکده‌های فنی، دانشگاه تهران، ایران

محمدرضا سراجیان مارالان (sarajian@ut.ac.ir)

دانشیار، گرایش سنجش از دور گروه مهندسی نقشه‌برداری پردیس دانشکده‌های فنی، دانشگاه تهران، ایران

(تاریخ دریافت ۱۳۹۳/۱۱/۲۹ - تاریخ پذیرش ۱۳۹۴/۶/۲۵)

### چکیده

از آنجا که تشخیص آنومالی‌های لرزه‌ای به دلیل ساختار پیچیده زمین و عدم شناخت کامل سازوکار وقوع زلزله، دشوار است، دسترسی به داده‌های حرارتی متنوع به دست آمده از روش‌های سنجش از دوری سبب شده تا امکان بررسی آنومالی حرارتی قبل از وقوع زلزله‌های بزرگ فراهم شود. آنومالی‌های حاصل از پیش‌نشانگرهای حرارتی، از اصلی‌ترین منابع پیش‌بینی زلزله‌اند. در این مطالعه با استفاده از پیش‌نشانگرهای دمای سطح (Land Surface Temperature)، دمای جو (Atmospheric Temperature)، شار گرمای نهان سطح (Surface Latent Heat Flux) و موج بلند خروجی (Outgoing long-wave radiation) امکان وقوع آنومالی حرارتی قبل از زلزله‌های ورزقان (۱۳۹۱/۰۵/۲۱)، بوشهر (۱۳۹۲/۰۱/۲۰) و سراوان (۱۳۹۲/۰۱/۲۷) بررسی شده است. برای تشخیص آنومالی پیش از وقوع زلزله، سری زمانی مربوط به دمای سطح و دمای جو توسط محصولات سنجنده MODIS، شار گرمای نهان سطح از کتابخانه GLDAS و موج بلند خروجی از محصولات سنجنده AIRS در دوره زمانی قبل و پس از وقوع زلزله تشکیل شد و با تلفیق شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی کلونی مورچه این سری‌های زمانی پیش‌بینی شده و امکان وقوع آنومالی در آنها بررسی شد. همچنین نتایج حاصل از این روش با نتایج روش شبکه عصبی با الگوی آموزش لوبنرگ-مارکارد (Levenberg-Marquardt) مقایسه شده است. نتایج این تحقیق نشان‌دهنده وقوع آنومالی در تغییرات دمای سطح زمین، دمای جو، شار گرمای نهان سطح و موج بلند خروجی ۱۰ تا ۱۳ روز پیش از وقوع زلزله ورزقان، دمای جو و موج بلند خروجی ۹-۶ روز و شار گرمای نهان سطح ۲ روز پیش از وقوع زلزله بوشهر و تشخیص آنومالی در تمامی پیش‌نشانگرهای حرارتی مورد مطالعه ۵ تا ۸ روز پیش از وقوع زلزله سراوان است.

واژه‌های کلیدی: آنومالی، الگوریتم بهینه‌سازی کلونی مورچه، زلزله، شبکه عصبی مصنوعی، پیش‌نشانگرهای حرارتی.

## مقدمه

هر ساله وقوع زلزله در کشورهای مختلف دنیا موجب زیان‌های اقتصادی و تلفات انسانی بسیار زیادی می‌شود. در جوامع مختلف شدت این خسارات و تلفات به میزان توسعه‌یافتگی و تراکم جمعیت، ایمنی ساختمان‌های شهرها و روستاها در برابر زلزله و آگاهی و آمادگی افراد جامعه برای رعایت نکات ایمنی بستگی دارد. زلزله یکی از مهم‌ترین سوانح طبیعی است که در حال حاضر پیش‌بینی وقوع آن به صورت دقیق امکان‌پذیر نیست.

ایران بر روی کمربند لرزه‌ای فعال آلپ هیمالیا قرار گرفته است و از مناطق لرزه‌خیز دنیا محسوب می‌شود. برای رسیدن به راه حلی کلی و جامع برای پیش‌بینی زلزله در مناطق لرزه‌خیزی مانند ایران تحقیقات بسیاری صورت گرفته که سبب افزایش فهم و درک بشر از این پدیده غیرمترقبه شده است.

در حال حاضر، آنومالی‌های حرارتی پیش از زمین‌لرزه، به طور کامل توجیه‌شدنی نیستند؛ با این حال نظریه‌هایی در این مورد ارائه شده‌اند؛ از جمله ایجاد تغییر در سیستم آب‌های زیرزمینی که به افزایش شار گرمایی همرفتی منجر می‌شود [۱]، گاززدایی زمین که سبب ایجاد اثر گلخانه‌ای می‌شود [۲] و تولید بار و انتشار آن در سنگ‌های آذرین دارای حفره‌های P (P-Holes) [۳]. تصویرهای حاصل از امواج مادون قرمز حرارتی برای بررسی شکست و تغییر شکل صخره‌های زیر بار، مطالعه شدند تا بتوان سازوکار احتمالی شرایط غیرمتعارف TIR ماهواره‌ای را پیش از وقوع زلزله‌ها آشکار ساخت؛ این کار توسط سنسور از دور مکانیک سنگ انجام می‌گیرد [۴].

این ایده که آنومالی‌های موجود در اطلاعات حرارتی می‌توانند با فعالیت‌های لرزشی زمین در ارتباط باشند، ابتدا در روسیه، چین و ژاپن مطرح شد؛ در سال ۱۹۸۰ دانشمندان روسی اولین آنومالی حرارتی را پیش از وقوع زلزله‌ای در آسیای مرکزی توسط داده‌های سنسور از دور مشاهده کردند [۵]. پس از این، مطالعات بسیاری مبنی بر وجود آنومالی‌های حرارتی مرتبط با فعالیت‌های لرزه‌ای انجام گرفته، تأیید شد [۸-۴].

بعضی از سنسورهای سنسور از دوری قادر به جمع‌آوری اطلاعات در باندهای حرارتی‌اند که با توجه به توان تفکیک زمانی و مکانی مناسب باندهای حرارتی سنسورهای AVHRR، Aqua-MODIS، Terra-MODIS، Aqua-MODIS، Meteosat-5 و AQUA-AIRS به طور معمول در بررسی‌های مربوط به تشخیص آنومالی‌های حرارتی تجزیه و تحلیل می‌شوند.

آخوندزاده اطلاعات به‌دست‌آمده از سنجنده MODIS برای زلزلهٔ ورزقان (۱۳۹۱) را بررسی کرد. در این تحقیق از روش‌های میانه و (Autoregressive Integrated Moving) ARIMA استفاده شد که به ترتیب چهار و دو روز پیش از زلزله موفق به تشخیص آنومالی شدند. پس از آن با استفاده از روش‌های هوشمندی مانند شبکهٔ عصبی و ماشین‌های بردار پشتیبان آنومالی در دو روز قبل از زلزله و همچنین سه، چهار و شش روز پیش از زلزله آنومالی‌هایی تشخیص داده شدند [۹].

در مطالعهٔ دیگری در مورد زلزلهٔ سراوان، سری‌های زمانی TEC و LST برای این زلزله در بازهٔ زمانی قبل و پس از وقوع زلزله، توسط ادغام روش‌های (Particle Swarm) PSO (Intelligence) و شبکهٔ عصبی صورت گرفت که در مورد داده‌های TEC، چهار روز پیش از زلزله آنومالی مشاهده شده است و در مورد LST نیز هشت روز پیش از وقوع زلزله آنومالی مشخص شده است. در همین تحقیق نشان داده شده است که با استفاده از روش میانه در مورد LST آنومالی یک روز قبل از وقوع زلزله مشاهده می‌شود. در نهایت این تحقیق نشان داده است که روش‌های PSO و ANN با ادغام در هم می‌توانند ضعف‌های یکدیگر را در تشخیص آنومالی و همگرا شدن به جواب نهایی تا حدودی برطرف کنند [۱۰].

این مطالعه بر بررسی سری‌های زمانی مربوط به پیش‌نشانگرهای حرارتی دمای سطح، دمای جو، شار گرمای نهان سطح و موج بلند خروجی با استفاده از شبکهٔ عصبی و ترکیب شبکهٔ عصبی مصنوعی و الگوریتم بهینه‌سازی کلونی مورچه تمرکز دارد. با توجه به نتایج به‌دست‌آمده از ترکیب شبکهٔ عصبی و الگوریتم بهینه‌سازی مورچه در مطالعات دیگر [۱۱] و همچنین توانایی شبکهٔ عصبی در تشخیص آنومالی‌های مربوط به زلزله در پیش‌نشانگرهای حرارتی [۹]، از ترکیب شبکهٔ عصبی و الگوریتم بهینه‌سازی کلونی مورچه برای بررسی توانایی‌های این روش در برابر روش‌های آماری مانند میانه و شبکهٔ عصبی در مورد زلزله‌های یادشده استفاده شد.

### تئوری

در این مطالعه از چهار پیش‌نشانگر حرارتی استفاده شده است که عبارت‌اند از:

**دمای سطح زمین:** این پارامتر با استفاده از روش‌های روز و شب و Split Window با توان تفکیک مکانی یک کیلومتر و با استفاده از اطلاعات حاصل از باندهای ۳۱ و ۳۲ سنجندهٔ MODIS با دقت مناسبی محاسبه می‌شود، در طول دو دههٔ گذشته پیشرفت‌های چشمگیری در تخمین این پارامتر صورت گرفته است [۱۲]. ناهنجاری‌های دمای سطح زمین در بازهٔ ۱ تا

۲۴ روز پیش از وقوع زلزله اهمیت خاصی در میان محققان زلزله دارد و مطالعات بسیاری در مورد این ناهنجاری‌ها در سال‌های اخیر صورت گرفته است [۱۳، ۸، ۲].

**دمای جو:** این پارامتر معیاری برای اندازه‌گیری دما در سطوح مختلف اتمسفر زمین است که شامل فاکتورهای بسیاری مانند تشعشع‌های ورودی از خورشید، رطوبت و ارتفاع است. دمای جو به‌عنوان پیش‌نشانگر زلزله در سال ۱۹۸۶ از طریق بررسی میانگین ماهیانه دمای مربوط به چندین ایستگاه هواشناسی به‌عنوان یک پیش‌نشانگر زلزله معرفی شد و پس از آن نیز در مطالعات دیگر دمای جو به‌عنوان پیش‌نشانگر زلزله بررسی شد [۱۴، ۴].

**شار گرمای نهان سطح:** نشان‌دهنده حرارت آزادشده توسط تغییرات فازی ناشی از انجماد، تبخیر یا ذوب است که به‌شدت به پارامترهای هواشناسی، مانند رطوبت نسبی، سرعت باد و عمق اقیانوس و نزدیکی به اقیانوس وابسته است [۱۵]. اولین بار در سال ۱۹۹۹ چند روز قبل از وقوع چند زلزله آنومالی‌هایی در مقدار شار گرمای نهان سطح دیده شد که در نتیجه آن این پارامتر به‌عنوان یک پیش‌نشانگر زلزله در مناطق ساحلی معرفی شد [۱۶، ۱۵].

**موج بلند خروجی:** یکی از پارامترهای اصلی برای توصیف تابش زمین، تابش موج بلند خروجی (OLR) زمین است که مربوط به لایه‌های بالای جو است و تابش‌های مربوط به لایه‌های پایین جو، ابرها و سطح زمین را به‌صورت یکپارچه نشان می‌دهد. وجود آنومالی در OLR به عوامل متنوعی در زلزله بستگی دارد، اما به‌صورت کلی با بزرگی زلزله مرتبط است [۱۷]. مطالعات زیادی در مورد ارتباط این پیش‌نشانگر با سایر پارامترهای حرارتی نظیر شار گرمای نهان سطح صورت گرفته است و در مجموع رفتار این پارامتر در مناطقی با گسل‌های فعال و تغییرات فصلی آن برای رسیدن به درک بهتری از ناهنجاری‌هایی که در مورد موج بلند خروجی رخ می‌دهد بررسی شده است [۱۹-۱۷].

برای تشخیص آنومالی در یک سری زمانی، روش‌های داده‌کاوی متفاوتی در مطالعات گوناگون پیشنهاد شده است. بسیاری از این روش‌ها برای تشخیص آنومالی در پیش‌نشانگرهای زلزله نیز استفاده شده‌اند. از جمله این روش‌ها روش موجک (Wavelet)، فیلترینگ کالمن (Kalman Filtering)، ماشین بردار پشتیبان (Support Vector Machine) و روش‌های آماری نظیر میانگین و میانگین و ARIMA (Autoregressive Integrated Moving Average) هستند [۱۹-۲۱]. در سال ۲۰۱۳ آخوندزاده از روش شبکه عصبی پرسپترون چندلایه (MLP) برای تشخیص آنومالی در سری زمانی مربوط به داده‌های محتوای تجمعی الکترون (TEC) استفاده کرد [۲۰]. شبکه عصبی می‌تواند بدون نیاز به هرگونه مدلی برای تعریف رفتار فیزیکی یک

پارامتر، به‌عنوان ابزاری توانا در راستای پیش‌بینی یک سری زمانی عمل کند. در بسیاری از پیش‌نشانگرهای مورد مطالعه، آگاهی از مدل رفتاری کامل این پیش‌نشانگرها ممکن نیست. از طرفی رفتار غیرخطی این سری‌های زمانی استفاده از روش‌های هوشمند مانند شبکه عصبی را نسبت به روش‌های سنتی‌تر مانند ARIMA و میانه که به‌صورت خطی با سری زمانی برخورد می‌کنند، توجیه‌پذیرتر می‌کند [۲۲]. همچنین استفاده از ترکیب الگوریتم کلونی مورچه و شبکه عصبی مصنوعی برای بهبود دادن نتایج حاصل از این روش قابل بررسی است.

بهینه‌سازی کلونی مورچه (ACO) یک روش فرااکتشافی (Meta-heuristic) برای یافتن بهترین مسیر گراف با توجه به عملکردهای از پیش تعیین‌شده است. ACO الهام گرفته از جست‌وجوی مورچه‌های واقعی برای غذا و حفظ برخی شرایط زیست‌محیطی آنهاست. برای مثال اصطلاح مورچه، نشان‌دهنده ساده‌ترین حرکت عامل جست‌وجو در طول گراف است، فرومون (Pheromone) نشان‌دهنده وزن یال‌های گراف است. تبخیر فرومون به‌معنای این است که فرومون هر یال در هر دور به‌صورت از پیش تعریف‌شده کاهش می‌یابد. ایده اصلی الگوریتم ACO شامل دو قانون درهم‌پیچیده است. مورچه‌ها به‌طور مداوم در طول گراف حرکت می‌کنند و ناظر بیرونی مسیر هر مورچه را با توجه به تابع کیفیت بررسی می‌کند. پس از آن میزان فرومون هر یال با توجه به نتیجه تابع کیفیت به‌روز خواهد شد [۲۳].

### روش‌شناسی

به‌منظور استفاده از روش‌های هوشمند در زلزله‌های تکتونیکی به‌وسیله پارامترهای دمایی سه نکته باید مورد توجه قرار گیرد:

- زمانی داده حرارتی مورد مطالعه در تاریخی خاص، به‌عنوان آنومالی در نظر گرفته می‌شود که پس از پیش‌بینی توسط روش هوشمند به‌کاررفته، اختلاف مقدار پیش‌بینی‌شده پارامتر و مقدار واقعی آن خارج از بازه مشخص‌شده توسط روش آماری Inter-quartile باشد.
- آنومالی‌های به‌دست‌آمده در پارامترهای دمایی مختلف باید از نظر زمانی به یکدیگر نزدیک باشند (شدت این آنومالی‌ها ممکن است متفاوت باشد اما از نظر زمانی باید به یکدیگر نزدیک باشند).
- این آنومالی‌ها از نظر مکانی باید همگی در محدوده‌ای مشخص در اطراف مرکز زلزله مشاهده شوند؛ به همین دلیل در این مطالعه کانون زلزله مطالعه خواهد شد.

## داده‌ها

برای هر پارامتر دمایی باید از داده مناسب استفاده کرد. از آنجا که وجود عواملی مانند ابرهای ضخیم در منطقه ممکن است سبب شود در روزهایی داده مربوط به بعضی پارامترها قابل دسترسی نباشد. این امر سبب می‌شود در صورتی که آنومالی در این روزها رخ داده باشد، این آنومالی قابل مشاهده نباشد.

داده‌های مربوط به دمای سطح زمین و دمای جو از کتابخانه محصولات سنجنده MODIS واقع بر ماهواره Terra از درگاه سازمان NASA جمع‌آوری شده‌اند؛ این محصولات به صورت روزانه و برای کانون زلزله‌های مورد مطالعه، در زمان وقوع زلزله استخراج شده است. پیکسل‌های تصویر حاصل از این داده‌ها مساحتی برابر با ۰/۰۵ درجه (در عرض و طول جغرافیایی) را پوشش می‌دهند که در استوا به صورت تقریبی برابر ۵/۶ کیلومتر است. داده‌های مربوط به شار گرمای نهان از کتابخانه GLDAS (Global Land Data Assimilation System) که توسط آنالیز داده‌های مختلف ماهواره‌ای، ایستگاهی، سنجنده‌های هوایی و سایر روش‌ها جمع‌آوری شده، تهیه شده است. این داده‌ها در گرید ۰/۲۵ در ۰/۲۵ درجه و به صورت ۳ ساعت یک بار تولید شده‌اند. داده‌های مربوط به موج بلند خروجی نیز از اطلاعات مربوط به کتابخانه محصولات سنجنده AIRS واقع بر ماهواره Aqua از درگاه سازمان ناسا برداشت شده است. اطلاعات مربوط به این محصول نیز به صورت روزانه در گریدهای یک درجه در یک درجه تولید شده‌اند.

ترکیب روش‌های شبکه عصبی مصنوعی و بهینه‌سازی کلونی مورچه برای تشخیص آنومالی قبل از وارد کردن داده‌ها در الگوریتم‌های هوشمند، داده‌های سری زمانی باید نرمال‌سازی شوند. برای این کار ابتدا مقادیر بیشینه و کمینه پارامتر مورد نظر را در بازه زمانی مشخص شده به دست آورده و سپس با استفاده از فرمول ۱ هر داده به بازه ۰ تا ۱ انتقال داده می‌شود.

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

که در این معادله  $X'$  مقدار نرمال شده و  $X$  مقدار اصلی است.

شبکه‌های عصبی مصنوعی به دفعات به عنوان پیش‌بینی‌کننده سری‌های زمانی مورد استفاده قرار گرفته‌اند. اگر تفاوت میان مقدار پیش‌بینی شده توسط شبکه عصبی و مقدار مشاهده شده، از یک میزان آستانه از پیش تعریف شده، بیشتر باشد این مقدار به عنوان آنومالی در نظر گرفته می‌شود.

به عبارت دیگر روش آماری Inter-Quartile را بر روی نمودار اختلاف-زمان (اختلاف میان

مقادیر پیش‌بینی‌شده و مقادیر به‌دست‌آمده توسط سنجنده) اعمال می‌کند و زمانی که این اختلاف خارج از بازه Inter-quartile باشد به‌عنوان آنومالی در نظر گرفته خواهد شد.

شبکه‌های عصبی مصنوعی، دسته‌ای از سیستم‌های هوشمند هستند که می‌توانند با پیش‌فرض‌های اندک الگوها را شناسایی و هرگونه رابطه‌ی اساسی میان داده‌ها را جهت مدل کردن یک رویداد در نظر بگیرند. شبکه‌های عصبی می‌توانند ساختار خودهم‌بستگی در یک سری زمانی را به‌دست آورند، حتی اگر توصیف قانون حاکم بر سری، نامعین یا بسیار پیچیده باشد [۲۴]. در شبکه‌ی عصبی مصنوعی استفاده‌شده در این مطالعه از روش آموزش بهینه‌شده‌ی لونیگ-مارکارد استفاده شده است.

به‌منظور شناسایی آنومالی، تمام داده‌های موجود به دو مجموعه‌ی آموزشی و تست تقسیم می‌شوند. مجموعه‌ی آموزشی (یادگیری) به‌منظور ایجاد شبکه‌ی عصبی استفاده می‌شود، درحالی که مجموعه‌ی تست به‌منظور سنجش خطای پیش‌بینی مدل به‌کار می‌رود. در اصل، فرایند آموزش برای یافتن وزن‌های اتصالات شبکه استفاده می‌شود [۲۴]. اگر خطای پیش‌بینی از مقدار آستانه‌ی تعیین‌شده بزرگ‌تر باشد، می‌توان این مقدار را آنومالی معرفی کرد [۲۰]. برای تابع فعال‌ساز در لایه‌ی خروجی، بهترین نتایج برای تابع خطی به‌دست‌آمده است. تابع انتقالی معادله‌ی ۲ که برای گره‌های لایه‌ی پنهان در نظر گرفته شده است، تابع سیگموئید تانژانتی (Tan sigmoid function) است.

$$f(x) = \frac{2}{1 + e^{-3x}} - 1 \quad (2)$$

الگوهای آموزشی شبکه‌ی پیشنهادی عبارت‌اند از:

$$\begin{aligned} X_5 &= f(X_2, X_3, X_4), \quad X_4 = f(X_1, X_2, X_3) \\ X_N &= f(X_{N-3}, X_{N-2}, X_{N-1}) \end{aligned} \quad (3)$$

فرایند آموزش برای یافتن مقادیر بهینه‌ی وزن‌های اتصالات استفاده می‌شود، به‌شکلی که خطای پیش‌بینی، کمینه شود. معادله‌ی PE را می‌توان به‌صورت معادله‌ی ۴ نوشت:

$$PE = \sum_{i=1}^N (X_i - \hat{X}_i) \quad (4)$$

$\hat{X}_i$  که خروجی از شبکه است.

پس از اجرای مراحل آموزش داده‌ها، شبکه‌ی عصبی مصنوعی آموزش داده‌شده بر روی داده‌های تست اجرا می‌شود و اقدام به پیش‌بینی سری زمانی می‌کند. زمانی که اختلاف مقدار پیش‌بینی‌شده بیش از حد آستانه باشد آنومالی تشخیص داده می‌شود.

الگوریتم مورچه روشی است که سعی در حل مسائل از طریق تکرار برای یافتن راه حل صحیح با استفاده از تابع احتمال دارد. در مسائل بهینه‌سازی گسسته تابع احتمال نیز گسسته است و با استفاده از اطلاعات فرمون مصنوعی به دست می‌آید. یعنی فرمون به‌عنوان حافظه جست‌وجوی این روش، برای پیدا کردن راه حل بهتر عمل می‌کند. در اینجا از یک تابع چگالی احتمال پیوسته برای حل مسئله استفاده شده است که توسط بلوم و سوشا برای کلاس‌بندی داده‌ها پیشنهاد شده است.

برای ساخت یک راه حل، الگوریتم کلونی مورچه به این صورت عمل می‌کند که در مرحله اول این مورچه مجموعه تصمیمات اولیه  $X = \{X_1, \dots, X_n\}$  را به مقدار متغیر موقت  $Z = \{Z_1, \dots, Z_n\}$  تغییر می‌دهد تا با کم کردن همبستگی متغیرهای تصمیم‌گیری این روش را بهبود ببخشد. حال در هر مرحله اجرا (از مرحله اول تا مرحله  $n$ ) مورچه مقداری را برای متغیر تصمیم‌گیری  $Z_i$  انتخاب می‌کند. برای این کار مورچه از یک تابع چگالی احتمال گاوسی استفاده می‌کند که انطباقی وزنی از توابع گاوسی متعددی است. برای متغیر تصمیم‌گیری  $Z_i$  کرنل گاوسی  $G_i$  با استفاده از رابطه ۵ محاسبه می‌شود [۱۱].

$$G^i(x) = \sum_{l=1}^k \omega_l g_l^i(x) = \sum_{l=1}^k \omega_l \frac{1}{\sigma_l \sqrt{\pi}} e^{-\frac{(x-\mu_l)^2}{2\sigma_l^2}} \quad (5)$$

که در آن زامین تابع گاوسی از زامین عضو مجموعه  $P$  نتیجه می‌شود ( $k$  اندازه  $P$  است). باید توجه داشت که  $\bar{\omega}$ ،  $\bar{\sigma}$  و  $\bar{\mu}$  بردارهایی با اندازه  $k$  هستند. در اینجا  $\bar{\omega}$  بردار وزن‌هاست و  $\bar{\sigma}$  و  $\bar{\mu}$  نیز به ترتیب بردارهای انحراف از معیار و میانگین نسبی‌اند.

زمانی که دو ناحیه مجزا از هم داریم از PDF هسته گاوسی بهبودیافته استفاده می‌کنیم که در واقع مجموعی وزن‌دار از چندین تابع گاوسی تک‌بعدی  $g_l^i(x)$  به صورت زیر است [۱۱]:  
هر بُعد جواب دارای PDF هسته گاوسی مخصوص خودش یعنی  $G^i(x)$  است که از وزن‌های همان بعد در آرشو به دست آمده است. برای یافتن مقدار وزن بعد  $i$  (وزن‌های شبکه عصبی) برای یک جواب تازه ساخته شده،  $G^i(x)$  نمونه‌برداری می‌شود. این نمونه‌برداری در دو فاز انجام می‌گیرد.

۱. یکی از توابع گاوسی که PDF هسته گاوسی را تشکیل داده است با احتمال زیر انتخاب می‌شود که در آن  $\omega_j$  وزن تابع گاوسی  $Z_j$  است.



$$p_j = \frac{\omega_j}{\sum_{i=1}^k \omega_i} \quad (6)$$

۲. تابع گاوسی انتخاب‌شده را نمونه‌برداری می‌کنیم تا مقداری برای بُعد به‌دست آید. پس از آنکه یک تابع گاوسی انتخاب شد از همان تابع (اندیس ۱ آرشیو) برای تولید مقادیر تمام ابعاد جواب استفاده می‌شود. هر بار مقادیر  $\mu_l$  و  $\sigma_l$  به‌صورت زیر برای هر  $i$  از جواب ۱ در آرشیو محاسبه می‌شود.

- $i$  امین متغیر تمام جواب‌های آرشیو، المان‌های بردار  $\mu^i$  را تشکیل می‌دهند.
- انحراف معیار به‌صورت میانگین فاصله میان متغیر انتخاب‌شده جواب انتخابی و همان متغیر در سایر جواب‌های آرشیو محاسبه می‌شود که به‌صورت معادله ۷ درمی‌آید.

$$\sigma_l^i = \xi \sum_{e=1}^k \frac{x_e^i - x_l^i}{k-1} \quad (7)$$

در تساوی ۷ انحراف معیار در  $\xi$  ضرب شده است. این ضریب همانند نرخ تبخیر فرمون در ACO برای بهینه‌سازی ترکیبی است. مقادیر بالای  $\xi$  منجر به همگرایی کندتر خواهد شد، بنابراین تمام  $n$  تابع چگالی احتمال هسته گاوسی برای ساخت جواب نمونه‌برداری می‌شوند. این نمونه‌برداری جهت ساخت  $k$  جواب (مجموعه‌های وزن‌های شبکه عصبی) برای هر دوره آموزش، تکرار می‌شود [۱۱].

به‌صورت خلاصه این روش به‌صورت زیر عمل می‌کند:

۱. آرشیو، با مقادیر تصادفی، مقداردهی اولیه می‌شود؛
  ۲. شبکه عصبی ایجاد و اجرا می‌شود تا سازگاری راه‌حل انتخابی در آن سنجیده شود؛
  ۳. با نمونه‌برداری از تابع گاوسی تصادفی پارامتردهی شده، به مرتب‌سازی آرشیو، حذف مقادیر نامناسب و تولید مقادیری که به سمت بهینه‌سازی مجموعه می‌روند، می‌پردازد؛
- مراحل بالا تا موقعی که اختلاف مقادیر آموزشی و نتایج به حداقل برسد، ادامه می‌یابد.

## مشاهدات

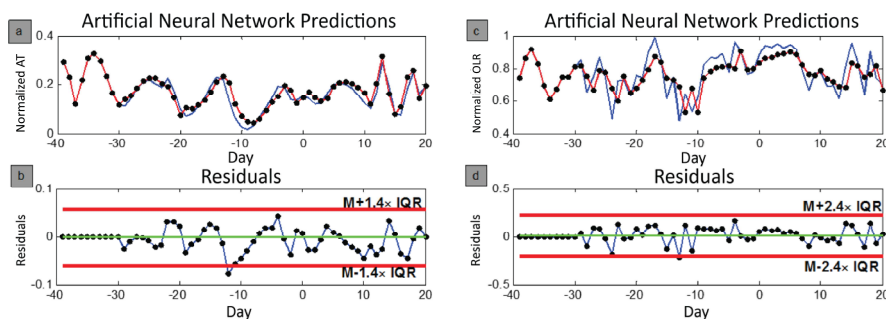
### زلزله ورزقان (۲۱ مرداد ۱۳۹۱)

زلزله ورزقان در ۲۱ مرداد سال ۱۳۹۱ در ساعت ۱۶ و ۵۳ دقیقه در ۱۰ کیلومتری شهر ورزقان (۳۸/۳۲۲ درجه شمالی و ۴۶/۸۸ درجه شرقی) واقع در استان آذربایجان شرقی در عمق حدود ۱۰ کیلومتری و با بزرگای گشتاوری ۶/۳ به وقوع پیوست. نتایج اجرای روش‌های شبکه عصبی با ۲ لایه پنهان که هرکدام شامل ۲ نورون بودند و ترکیب شبکه عصبی مصنوعی و الگوریتم

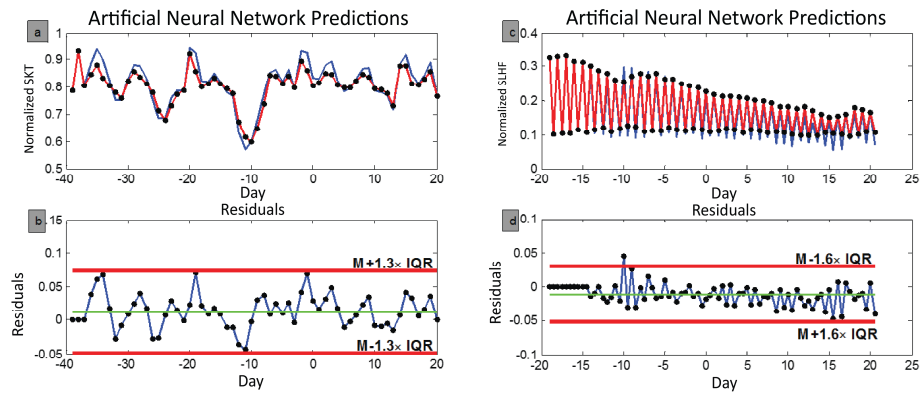
مورچه با ۲ لایه پنهان که لایه اول شامل ۳ نورون و لایه دوم شامل ۲ نورون بوده است در داده‌های سری‌های زمانی پارامترهای دمای جو، موج بلند خروجی، دمای سطح زمین و شار گرمای نهان در تصاویر ۲ تا ۵ نمایش داده شده‌اند. نتایج تشخیص آنومالی در جدول ۱ قرار داده شده است.



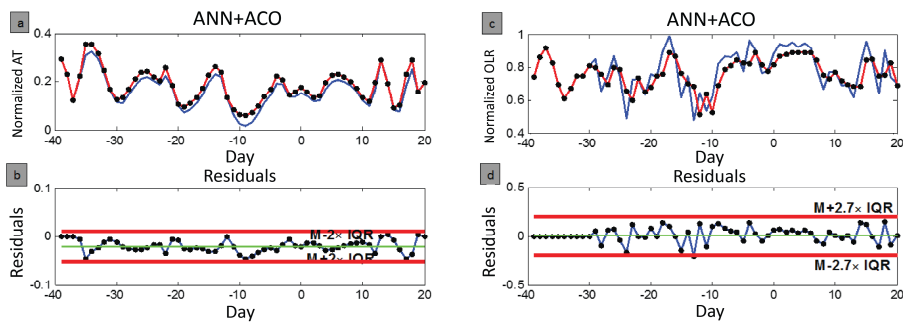
شکل ۱. مرکز زلزله‌های ورزقان، بوشهر و سراوان (تولیدشده توسط نرم‌افزار Google Earth)



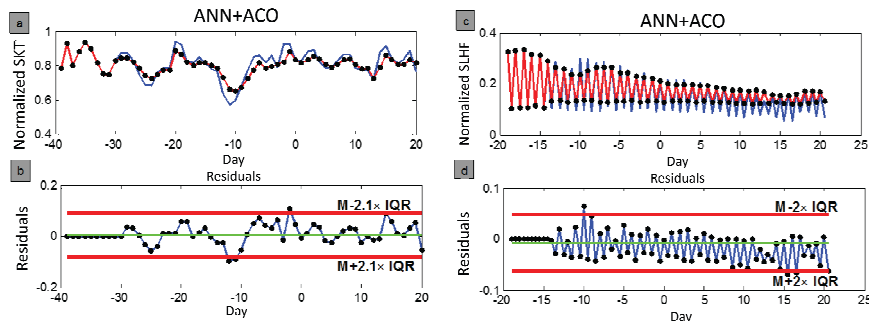
شکل ۲. (a) سری زمانی تغییرات پارامتر دمای جو (نمودار رنگ آبی) و پیش‌بینی آن توسط شبکه عصبی مصنوعی (نمودار رنگ قرمز) (b) اختلاف مقادیر مشاهده‌شده (نمودار رنگ آبی) و پیش‌بینی شده (نمودار رنگ قرمز) دمای جو با استفاده از روش شبکه عصبی مصنوعی (c) سری زمانی تغییرات موج بلند خروجی (نمودار رنگ آبی) و پیش‌بینی آن توسط شبکه عصبی مصنوعی (نمودار رنگ قرمز) (d) اختلاف مقادیر مشاهده‌شده (نمودار رنگ آبی) و پیش‌بینی شده (نمودار رنگ قرمز) موج بلند خروجی با استفاده از روش شبکه عصبی



شکل ۳. الف) سری زمانی تغییرات پارامتر دمای سطح زمین (نمودار رنگ آبی) و پیش‌بینی آن توسط شبکه عصبی مصنوعی (نمودار رنگ قرمز) ب) اختلاف مقادیر مشاهده‌شده (نمودار رنگ آبی) و پیش‌بینی‌شده (نمودار رنگ قرمز) دمای سطح زمین با استفاده از روش شبکه عصبی مصنوعی ج) سری زمانی تغییرات شار گرمای نهان سطح (نمودار رنگ آبی) و پیش‌بینی آن توسط شبکه عصبی مصنوعی د) اختلاف مقادیر مشاهده‌شده (نمودار رنگ آبی) و پیش‌بینی‌شده (نمودار رنگ قرمز) شار گرمای نهان سطح با استفاده از روش شبکه عصبی



شکل ۴. همانند شکل ۳ با استفاده از ترکیب شبکه عصبی مصنوعی و الگوریتم مورچه



شکل ۵. همانند شکل ۳ با استفاده از ترکیب شبکه عصبی مصنوعی و الگوریتم مورچه

جدول ۱. مجموعه نتایج حاصل در مورد زلزله ورزقان

پارامتر	شبکه عصبی	خطای پیش‌بینی	ترکیب شبکه عصبی و مورچه	خطای پیش‌بینی
دمای سطح	۱۱ و ۲ روز قبل	٪۱/۶	۱۱ و ۳ روز قبل	٪۲/۳
دمای جو	۱۱ روز قبل	٪۲/۰۵	-	٪۱/۷۱
شار گرمای نهان سطح	۱۰ روز قبل	٪۱/۷	۱۰ روز قبل	٪۲/۰۶
موج بلند خروجی	۱۳ روز قبل	٪۷/۷	۱۳ روز قبل	٪۶/۶

در مرحله اول با توجه به نتایج پیش‌بینی سری زمانی توسط این دو روش و مقایسه آنها می‌توان دید که در دامنه ۱۰ تا ۱۳ روز پیش از زلزله آنومالی‌هایی در پارامترهای حرارتی نمایان شده‌اند که شرط هم‌زمانی را نیز برقرار می‌کنند. از طرفی در مقایسه دو روش پیش‌بینی می‌توان دید که در مورد این مجموعه داده، هیچ‌یک از این دو روش برتری مطلق نسبت به دیگری ندارد و در مورد موج بلند خروجی و دمای جو، میانگین خطای حاصل از نتایج ترکیب شبکه عصبی و الگوریتم مورچه کمتر از روش شبکه عصبی مصنوعی بوده است. همچنین در دو پیش‌نشانگر دیگر، خلاف این امر ثابت شده است.

در سری زمانی مربوط به پیش‌نشانگر دمای جو در این زلزله ۱۸ روز پیش از وقوع زلزله در حالی دما در حال کاهش بوده که در چند روز میزان این دما به صورت ناگهانی افزایش یافته و سپس دوباره کاهش می‌یابد که این افزایش و کاهش ناگهانی دما ۱۱ روز پیش از وقوع زلزله به عنوان آنومالی تشخیص داده شده است. الگویی مانند الگوی اشاره‌شده در مورد موج بلند خروجی نیز اتفاق می‌افتد که این مورد نیز سبب می‌شود الگوریتم‌های پیش‌بینی آنومالی نشان

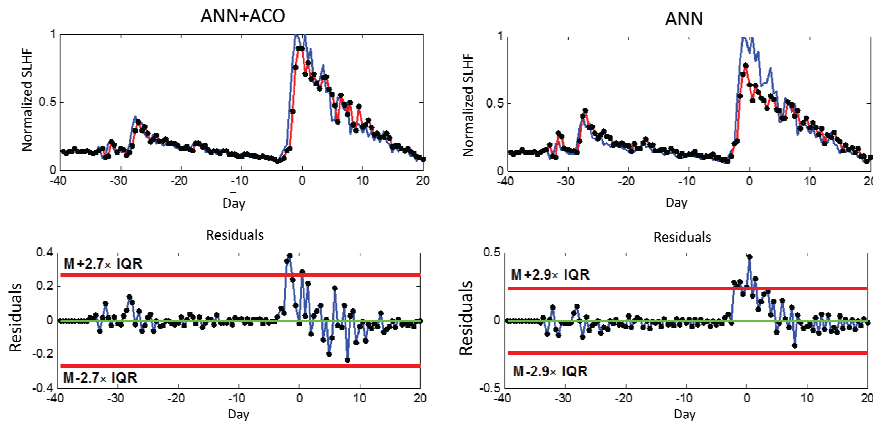
دهند. همچنین ده روز پیش از وقوع زلزله نیز به شار گرمای نهان سطح به‌صورتی واضح افزایش می‌یابد، که این افزایش نیز به‌عنوان آنومالی تشخیص داده شده است. دمای سطح در این دوره رفتاری آرام را نشان می‌دهد، اما تقریباً از همان الگوی دمای جو و موج بلند خروجی پیروی کرده است که در این مورد روش شبکه عصبی قادر به تشخیص آنومالی نیست، اما ترکیب شبکه عصبی و الگوریتم کلونی مورچه ۱۱ روز پیش از وقوع زلزله آنومالی نشان می‌دهد. در مطالعه‌ای که آخوندزاده در سال ۲۰۱۴ بر روی داده‌های LST انجام داد، با استفاده از روش‌های ARIMA و ANN و ماشین بردار پشتیبان آنومالی‌هایی ۲ روز پیش از وقوع زلزله تشخیص داده شدند که با نتایج مطالعه فعلی مطابقت دارد [۱۰].

#### زلزله بوشهر (۲۰ فروردین ۱۳۹۲)

زلزله بوشهر در ۲۰ فروردین ۱۳۹۲ در ساعت ۱۶ و ۲۲ دقیقه در عمق ۱۲ کیلومتری (۲۸/۴۸ درجه شمالی و ۵۱/۵۸ درجه شرقی) با بزرگای گشتاوری ۶/۳ در عمق ۱۲ کیلومتری زیر زمین در شهرستان دشتی استان بوشهر رخ داد، کانون این زمین‌لرزه در نزدیکی شهر شنبه واقع بود. این زمین‌لرزه در کشورهای قطر و بحرین نیز احساس شد. برای پیش‌بینی این داده‌ها در هر دو روش شبکه عصبی و ترکیب شبکه عصبی و الگوریتم مورچه دو لایه پنهان که هر کدام شامل دو نورون بوده‌اند بهترین جواب را دادند که اطلاعات مربوط به شار گرمای نهان نمایش داده شده است.

جدول ۲. مجموعه نتایج حاصل در مورد زلزله بوشهر

خطای پیش‌بینی	ترکیب شبکه عصبی و مورچه	خطای پیش‌بینی	شبکه عصبی	پارامتر
٪۱/۳	-	٪۱/۸	۸ روز قبل	دمای سطح
٪۴/۲	۹ و ۶ روز قبل	٪۵/۶	-	دمای جو
٪۴/۳	۲ روز قبل	٪۲/۳	روز زلزله	شار گرمای نهان سطح
٪۴/۵	۱۳ و ۷ روز قبل	٪۵/۰	-	موج بلند خروجی



شکل ۶. در بالا مقادیر واقعی شار گرمای نهان سطح در زلزله بوشهر (آبی رنگ) و پیش‌بینی روش‌های هوشمند (قرمز رنگ) و در پایین اختلاف میزان این دو سری زمانی آمده است. که با استفاده از مقادیر میانگین و Inter quartile اقدام به تعیین حد آستانه برای تشخیص آنومالی شده است.

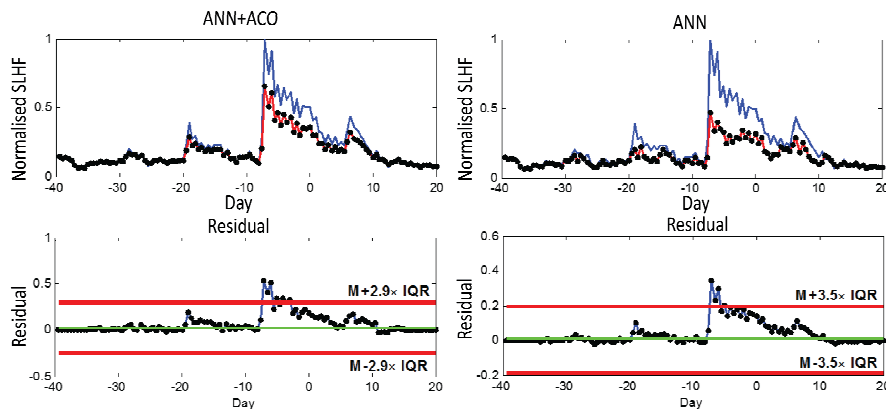
در زلزله بوشهر الگوریتم ترکیب شبکه عصبی و مورچه در تمامی موارد به جز شار گرمای نهان پیش‌بینی را با خطای میانگین کمتری انجام داده است. در زلزله بوشهر نتایج نشان می‌دهد که ۶ تا ۹ روز پیش از وقوع زلزله در پیش‌نشانگرهای دمای سطح زمین و دمای جو، آنومالی‌هایی دیده شده است. همچنین آنومالی شدیدی ۲ روز پیش از زلزله تا روز وقوع زلزله در پیش‌نشانگر شار گرمای نهان سطح دیده شده است. زلزله بوشهر به علت نزدیکی کانون این زلزله به خلیج فارس زلزله‌ای ساحلی محسوب می‌شود که انتظار وجود ناهنجاری در این پیش‌نشانگر را زیاد می‌کند.

#### زلزله سراوان (۲۷ فروردین ۱۳۹۲)

زلزله سراوان در ۲۷ فروردین ۱۳۹۲ در ساعت ۱۵ و ۱۴ دقیقه، مناطق جنوب شرقی ایران (۲۸/۱۰۷ درجه شمالی و ۶۲/۰۵۳ درجه شرقی) را با بزرگای گشتاوری ۷/۸ در عمق ۸۲ کیلومتری زیر زمین لرزاند. کانون این زلزله در نزدیکی شهر گشت از توابع شهرستان سراوان در استان سیستان و بلوچستان قرار داشت. نتایج بررسی پیش‌نشانگرهای حرارتی در این زلزله در جدول ۳ آمده است. برای پیش‌بینی این داده‌ها در هر دو روش شبکه عصبی و ترکیب شبکه عصبی و الگوریتم مورچه دو لایه پنهان که هر کدام شامل دو نورون بوده‌اند بهترین جواب را دادند که اطلاعات مربوط به شار گرمای نهان نمایش داده شده است.

جدول ۳. مجموعه نتایج در مورد زلزله سراوان

پارامتر	شبکه عصبی	خطای پیش‌بینی	ترکیب شبکه عصبی و مورچه	خطای پیش‌بینی
دمای سطح	۵ روز قبل	٪۳/۰	۵ روز قبل	٪۲/۹
دمای جو	۵ و ۸ روز بعد	٪۳/۷	۵ روز بعد	٪۵/۶
شار گرمای نهان سطح	۷ تا ۵ روز قبل	٪۱/۲	۷ تا ۵ روز قبل	٪۲/۶
موج بلند خروجی	۸ و ۱۰ روز قبل	٪۶/۲	۸ و ۱۰ روز قبل	٪۶/۱



شکل ۷. در بالا مقادیر واقعی شار گرمای نهان سطح در زلزله سراوان (آبی) و پیش‌بینی روش‌های هوشمند (قرمز) و در پایین اختلاف میزان این دو سری زمانی آمده است. با استفاده از مقادیر میانگین و Inter quartile حد آستانه برای تشخیص آنومالی تعیین شده است.

در زلزله سراوان در دامنه ۵ تا ۸ روز پیش از وقوع زلزله در تمامی پیش‌نشانگرها آنومالی‌هایی ظاهر شده است. نتایج حاصل از هر دو روش هوشمند بسیار به هم نزدیک‌اند؛ اما در مورد روش ترکیب شبکه عصبی و الگوریتم مورچه این آنومالی‌ها شدیدتر نمایان شده‌اند. برای دمای سطح زمین و موج بلند خروجی نتایج روش ترکیبی دارای میانگین خطای کمتری بوده‌اند. فاصله کانون زلزله سراوان از نزدیک‌ترین ساحل در حدود ۳۰۰ کیلومتر است که انتظار وجود ناهنجاری در پیش‌نشانگر شار گرمای نهان در این محدوده را کاهش می‌دهد؛ با این حال آنومالی شدیدی در مورد این پارامتر در این دامنه زمانی دیده شده است.

آخوندزاده در مطالعه‌ای بر روی داده‌های LST و TEC در همین زمین‌لرزه نیز آنومالی مربوط به LST را پنج روز پیش از وقوع زلزله با استفاده از روش‌های میانه، میانگین، فیلتر کالمن، موجک و ANN+PSO مشاهده کرد که با نتایج مطالعه فعلی همخوانی دارد [۹].

### نتیجه‌گیری

هدف این تحقیق بررسی امکان مشاهده ناهنجاری در تغییرات برخی از پیش‌نشانگرهای حرارتی در حوالی زمان وقوع چند زلزله بزرگ بوده است. به عبارت دیگر امکان‌سنجی مشاهده آنومالی قبل از وقوع زلزله‌های با زمان و موقعیت نامشخص از اهداف ایجاد سیستم‌های هشدار و پیش‌بینی زلزله است که جزو اهداف این تحقیق نیست. به بیان دیگر قبل از به‌کارگیری این روش برای پیش‌بینی زلزله باید در ابتدا امکان وقوع آنومالی در پیش‌نشانگرهای مورد بحث را در مورد زلزله‌های رخ داده بررسی کرد و در صورت دستیابی به نتایج مطلوب، با ایجاد یک سیستم پایش تغییرات پیش‌نشانگرهای حرارتی در مناطق لرزه‌خیز، در پی مشاهده آنومالی و به دنبال آن اخطار وقوع زلزله بود.

استفاده از داده‌های ماهواره‌ای از مزایای این روش است. به عبارت دیگر به دلیل هزینه‌بر بودن و عدم دسترسی به همه مناطق، اندازه‌گیری‌های میدانی دچار محدودیت‌هایی است؛ اگرچه می‌توان از مشاهدات میدانی نیز به منظور تکمیل و بهبود مشاهدات ماهواره‌ای استفاده کرد. استفاده از روش‌های هوشمند مانند شبکه عصبی برای تشخیص آنومالی‌های لرزه‌ای به علت نگاه غیرخطی این روش‌ها و عدم استفاده از پارامترهای فیزیکی مؤثر در مورد پیش‌نشانگرها، برای پیش‌بینی این مقادیر از اهمیت زیادی برخوردار است. کارایی روش شبکه عصبی برای این منظور در مطالعات پیشین نشان داده شده بود و در این مطالعه نیز نتایج مطلوب این روش این بار برای پیش‌نشانگرهای حرارتی تأیید شد.

روش پیشنهادی ترکیب شبکه عصبی مصنوعی و الگوریتم مورچه در این مطالعه اجرا شد و با روش سنتی تر شبکه عصبی مصنوعی با الگوی آموزش لونیگ-مارکارد مقایسه شد. هدف این مطالعه، پیدا کردن ناهنجاری پیش از وقوع زلزله و اطمینان از ناهنجاری تشخیص داده شده است. در نتیجه این تحقیق، ترکیب شبکه عصبی و مورچه توانست در ۵۸ درصد موارد میانگین خطای کمتری را نسبت به روش شبکه عصبی ساده نشان دهد که این موضوع بیانگر وجود پتانسیل مناسب در این روش است.

هم‌زمانی و نزدیکی آنومالی ظاهر شده در پیش‌نشانگر شار گرمای نهان در دو زلزله بوشهر و سراوان، که در شکل‌های ۶ و ۷ با جزئیات بیشتر نشان داده شده است از نتایج مهم این تحقیق



است. از دو روز پیش از زلزله بوشهر تا روز زلزله، افزایش چشمگیری در مقدار این پارامتر رخ داد که با اختلاف یک تا دو روز جلوتر همین الگوی تغییرات در کانون زلزله سراوان نیز اتفاق افتاد. شدت افزایش این پارامتر به حدی است که برای بازگشت به حالت قبلی خود در حدود ۵ تا ۸ روز زمان برد و هر دو روش استفاده شده در این مطالعه، در پیش‌بینی این تغییرات دچار مشکل شدند و در نتیجه آنومالی‌های شدیدی را در این روزها تشخیص دادند. وجود آنومالی شدید همزمان در زلزله‌های متوالی بوشهر و سراوان با الگویی بسیار نزدیک به یکدیگر، بیانگر اهمیت این پیش‌نشانگر و همچنین نیاز به مطالعات بیشتر در مورد این پیش‌نشانگر حتی در مناطقی با فاصله از ساحل است.

### منابع

- [1]. Asteriadis, G. and E. Livieratos (1988). Pre-seismic responses of underground water level and temperature concerning a 4.8 magnitude earthquake in Greece on October 20, 1988. *Tectonophysics*, 170(1), p. 165-169.
- [2]. Zu-ji, Q., X. Xiu-Deng, and D. Chang-Gong (1991). Thermal infrared anomaly precursor of impending earthquakes. *Chinese Science Bulletin*, 36(4), p. 319-323.
- [3]. Freund, F. (2009). Stress-activated positive hole charge carriers in rocks and the generation of pre-earthquake signals. *Electromagnetic Phenomena Associated with Earthquakes*, Transworld Research Network, Trivandrum, p. 41-96.
- [4]. Ouzounov, D., et al. (2006). Satellite thermal IR phenomena associated with some of the major earthquakes in 1999–2003. *Physics and Chemistry of the Earth, Parts A/B/C*, 31(4), p. 154-163.
- [5]. Ouzounov, D. and F. Freund (2004). Mid-infrared emission prior to strong earthquakes analyzed by remote sensing data. *Advances in Space Research*, 33(3), p. 268-273.
- [6]. Tronin, A., et al. (2004). Temperature variations related to earthquakes from simultaneous observation at the ground stations and by satellites in Kamchatka area. *Physics and Chemistry of the Earth, Parts A/B/C*, 29(4), p. 501-506.
- [7]. Tronin, A.A., M. Hayakawa, and O.A. Molchanov (2002). Thermal IR satellite data application for earthquake research in Japan and China. *Journal of Geodynamics*, 33(4), p. 519-534.
- [8]. Saradjian, M. and M. Akhoondzadeh (2011). Thermal anomalies detection before strong earthquakes ( $M > 6.0$ ) using interquartile, wavelet and Kalman filter methods. *Natural Hazards and Earth System Science*, 11(4), p. 1099-1108.
- [9]. Akhoondzadeh, M. (2013). A comparison of classical and intelligent methods to detect potential thermal anomalies before the 11 August 2012 Varzeghan, Iran, earthquake ( $M_w = 6.4$ ). *Natural Hazards and Earth System Science*, 13(4), p. 1077-1083.

- [10]. Akhoondzadeh, M. (2013). Thermal and TEC anomalies detection using an intelligent hybrid system around the time of the Saravan, Iran, (Mw= 7.7) earthquake of 16 April 2013. *Advances in Space Research*, 20 (4) 53. 14., p. 647-655.
- [11]. Blum, C. and K. Socha (2005). Training feed-forward neural networks with ant colony optimization: An application to pattern classification. in *Hybrid Intelligent Systems, 2005. HIS'05. Fifth International Conference on*, IEEE.
- [12]. Wan, Z. and Z.-L. Li (1997). A physics-based algorithm for retrieving land-surface emissivity and temperature from EOS/MODIS data. *Geoscience and Remote Sensing, IEEE Transactions on*, 35(4), p. 980-996.
- [13]. Panda, S., et al. (2007). MODIS land surface temperature data detects thermal anomaly preceding 8 October 2005 Kashmir earthquake. *International Journal of Remote Sensing*, 28(20), p. 4587-4596.
- [14]. Ouzounov, D., et al. (2011). Atmospheric signals associated with major earthquakes. A multi-sensor approach.
- [15]. Dey, S. and R. Singh (1999). Surface latent heat flux as an earthquake precursor. *Natural Hazards and Earth System Science*, 3(6), p. 749-755.
- [16]. Chen, M., et al. (2006). Surface latent heat flux anomalies prior to the Indonesia Mw9. 0 earthquake of 2004. *Chinese Science Bulletin*, 51(8), p. 1010-1013.
- [17]. Ouzounov, D., et al. (2007). Outgoing long wave radiation variability from IR satellite data prior to major earthquakes. *Tectonophysics*, 431(1), p. 211-220.
- [18]. Pulinet, S., et al. (2006). Thermal, atmospheric and ionospheric anomalies around the time of the Colima M7. 8 earthquake of 21 January 2003. in *Annales Geophysicae*.
- [19]. Xiong, P., Y. Bi, and X. Shen (2009). A Wavelet-Based Method for Detecting Seismic Anomalies in Remote Sensing Satellite Data, in *Machine Learning and Data Mining in Pattern Recognition*, Springer, p. 569-581.
- [20]. Akhoondzadeh, M. (2013). A MLP neural network as an investigator of TEC time series to detect seismo-ionospheric anomalies, *Advances in Space Research*, 51(11), p. 2048-2057.
- [21]. Akhoondzadeh, M. and M. Saradjian (2011). TEC variations analysis concerning Haiti (January 12, 2010) and Samoa (September 29, 2009) earthquakes, *Advances in Space Research*, 47(1), p. 94-104.
- [22]. Zhang, G.P. (2001). An investigation of neural networks for linear time-series forecasting. *Computers & Operations Research*, 28(12), p. 1183-1202.
- [23]. Dorigo, M. and L.M. Gambardella (1997). Ant colony system: a cooperative learning approach to the traveling salesman problem, *Evolutionary Computation, IEEE Transactions on*, 1(1), p. 53-66.
- [24]. Pao, H.-T. (2007). Forecasting electricity market pricing using artificial neural networks. *Energy Conversion and Management*, 48(3), p. 907-912.