



سجش از دور

GIS ایران



سنجش از دور و GIS ایران
Iranian Remote Sensing & GIS

سال هشتم، شماره دوم، تابستان ۱۳۹۵
Vol.8, No. 2, Summer 2016

۵۳-۷۲

کاربست روش شبکه‌های عصبی در پیش‌بینی دمای سطح زمین، با استفاده از تصاویر حرارتی مادیس

فرحناز تقوی^{۱*}، عباس احمدی^۲، زهرا زرگران^۳

۱. استادیار مؤسسه ژئوفیزیک، دانشگاه تهران
۲. استادیار دانشکده مهندسی صنایع و سیستم‌های مدیریت، دانشگاه صنعتی امیرکبیر، تهران
۳. دانشجوی کارشناسی‌ارشد مهندسی دانش و علوم تصمیم، دانشگاه علوم اقتصادی، تهران

تاریخ پذیرش مقاله: ۱۳۹۵/۶/۲۱

تاریخ دریافت مقاله: ۱۳۹۳/۷/۱۵

چکیده

در این مطالعه، مدلی ترکیبی از شبکه‌های عصبی ماژولار و پردازش تصاویر مادیس برای محاسبه دمای سطح زمین، در منطقه‌ای شامل شهر تهران، ارائه شده است. در این مدل، داده‌های تصاویر حرارتی با تکیه بر ویژگی‌های دمای درخشندگی در باندهای حرارتی ۳۱ و ۳۲ میکرومترسنجنده مادیس، به‌منزله ورودی در شبکه‌های عصبی ماژولار به‌کار رفته و روش جدیدی براساس ترکیبی از شبکه عصبی نگاشت خودسازمانده و الگوریتم بهینه‌سازی تجمع ذرات پیشنهاد شد. نتایج به‌دست‌آمده نشان می‌دهد استفاده از این الگوریتم سبب توزیع مناسب داده‌های ورودی شبکه‌های عصبی می‌شود. در آخر، نتایج نهایی با مدل‌های شبکه‌های عصبی با آموزش و ساختار غیرماژولار نیز مقایسه شده است. نتایج این مقایسه نشان می‌دهد که زمان آموزش مدل در پیش‌بینی دمای سطح زمین کاهش، و دقت مدل افزایش یافته است. اختلاف کم بین مقادیر پیش‌بینی شده و مقادیر واقعی دما در منطقه نشان می‌دهد که دما با دقت مناسبی در این مدل پیش‌بینی شده است، به‌طوری‌که میانگین خطای مدل ترکیبی مقدار 0.0081 و درصد خطای مطلق نیز $10/59$ است.

کلید واژه‌ها: تصاویر ماهواره، شبکه عصبی ماژولار، دمای سطح زمین.

* نویسنده عهده‌دار مکاتبات: تهران، کارگر شمالی، مؤسسه ژئوفیزیک، دانشگاه تهران، تلفن: ۶۱۱۱۸۲۰۱

۱- مقدمه

یکی از سرفصل‌های مهم علمی و تحقیقاتی به‌شمار می‌رود (علوی‌پناه، ۱۳۸۲) و براساس نوع تصاویر ماهواره‌ای، الگوریتم‌های متفاوتی برای محاسبه آن معرفی شده است (Behbahani et al., 2009؛ شکیبا و همکاران، ۱۳۸۸). هرچند تخمین مستقیم LST از تابش گسیل شده در ناحیه طیفی فروسرخ با دقت بالا مشکل است، زیرا رادینانس‌های اندازه‌گیری شده به وسیله رادیومترهای متصل به ماهواره‌ها هم به پارامترهای سطحی دما و گسیلندگی و هم به آثار جوی بستگی دارد. بنابراین، افزون‌بر کالیبراسیون رادیومتریک و صفحه‌بندی ابر^۲، تعیین LST از فضا براساس اندازه‌گیری در ناحیه طیفی فروسرخ به تصحیحات جوی و گسیلندگی، هر دو، نیاز دارد. در این ارتباط، مطالعات بسیاری با روش‌های متفاوت، برای تخمین و بازبایی LST انجام شده و الگوریتم‌های متفاوتی پیشنهاد شده است. به‌طورکلی، این روش‌ها به سه دسته روش تقسیم شده است: روش تک‌کاناله که از سوی ساسکیند و همکاران^۳ (۱۹۸۳) و پرایس^۴ (۱۹۸۴ و ۱۹۸۳) استفاده شده است و روش چندزویه‌ای (Sobrino, 1996) و تکنیک پنجره مجزا^۵ (روزنه دوگانه). اگرچه قدیمی‌ترین مطالعه مروری درمورد بازبایی دمای سطحی را پراتا و همکاران^۶ (۱۹۹۵) و دس و همکاران^۷ (۲۰۰۲) انجام داده‌اند. سوپرینو و همکاران^۸ (۲۰۰۴) دمای سطح زمین را براساس داده‌های ماهواره‌ای هواشناسی نسل دوم^۹ (MSG/SEVIRI)، به‌همراه تصویربرداری مرئی و فروسرخ براساس روش اندازه‌گیری دودمایی^۱ (TTM) بازبایی کرده‌اند. شکیبا و همکاران (۱۳۸۸) LST و ویژگی‌های بودجه انرژی

دمای سطح زمین (LST) تابع اصلی در تبادل امواج تابشی طول موج بلند و شارهای حرارتی تلاطمی در سطح مشترک جو و زمین است که یکی از پارامترهای اصلی در فرایندهای فیزیکی سطحی در چرخه انرژی و توازن آب در سامانه جو-زمین، در مقیاس‌های محلی و جهانی به‌شمار می‌رود (Anderson et al., 2008; Kustas & Anderson, 2009; Karnieli et al., 2010). افزون‌براین، دمای سطح زمین نشانگر خوبی برای بررسی تغییرات اقلیمی و فرسایش خاک است و در توازن انرژی و فرایندهای تبخیر و تعرق و بیابان‌زایی مؤثر است و داده‌های آن در مدل‌های اقلیمی و هواشناسی کاربرد گسترده‌ای دارد. همان‌گونه که LST در حوزه وسیعی از موضوعات، همچون تغییر اقلیم، چرخه هیدرولوژی، پایش پوشش گیاهی، اقلیم شهری و مطالعات محیطی استفاده می‌شود، از پارامترهای بسیار مهم در برنامه بین‌المللی زیست‌کره- زمین‌کره (IGBP International Geosphere- Biosphere Programme) به‌شمار می‌رود. دمای سطح زمین، به‌علت ناهمگنی شدید در ویژگی‌های سطحی، مانند پوشش گیاهی، توپوگرافی و خاک، در مکان و زمان تغییرات گسترده‌ای دارد و برای تخمین توزیع آن، به اندازه‌گیری‌های دقیق مکانی و نمونه‌برداری زمانی کافی نیاز است. با وجود پیچیدگی‌های دمای سطحی، اندازه‌گیری‌های زمینی عملاً ممکن نیست مقادیر روی مناطق وسیعی را پوشش دهد و با گسترش دانش سنجش از دور، داده‌های ماهواره‌ای امکان اندازه‌گیری LST را روی کل کره زمین، با دقت مکانی کافی، با میانگیری مکانی مناسب به‌جای مقادیر نقطه‌ای فراهم کرده است (Li, et al., 2013). از آنجاکه داده‌های فروسرخ حرارتی ماهواره‌ها از طریق معادله انتقال تابشی، با LST ارتباط مستقیم دارد، از سال ۱۹۷۰ بازبایی LST از این داده‌ها بسیار مورد توجه قرار گرفته است (McMillin, 1975). دمای سطح زمین دمایی است که هر پدیده روی سطح زمین دارد و به‌دلیل اهمیت آن در مطالعات محیطی،

1 land surface temperature

2 cloud screening

3 Susskind et al.

4 Price

5 split window

6 Prata et al.

7 Dash et al.

8 Sobrino et al.

9 METEOSAT Second Generation (MSG) /Spinning Enhanced Visible and Infrared Imager

تصاویر ماهواره، توسعه دادند. از آنجاکه طبیعت جو متغیر است و به قدرت محاسباتی بالایی برای پیش‌بینی نیاز دارد، استفاده از مدل‌های عددی پیش‌بینی وضع هوا (Kalnay, 2003; Lynch, 2006) باعث کاهش خطا و افزایش دقت پیش‌بینی می‌شود. از دیگر سو، به‌علت اینکه شرایط جوی کامل درک نمی‌شود، مدل‌های موجود برای پیش‌بینی جوی خیلی دقیق عمل نمی‌کنند. برای بهبود این خطاها تلاش‌هایی انجام شده است و سعی شده از داده‌های عددی مستخرج از تصاویر ماهواره‌ای و رادار و تکنیک‌هایی مانند گوارد داده و ریزمقیاس کردن استفاده شود. برای نمونه، سو و همکاران^۷ (۲۰۰۹) پیش‌بینی‌های مدل WRF^۸ را با گوارد داده ماهواره‌ای، در منطقه جنوب‌غرب آسیا، برای کمیت‌های دمای دو متری، بارش و باد ارزیابی کردند. نتایج تحقیق آنها نشان می‌دهد که به‌دلیل پیچیدگی نواحی مرتفع و نبود دانش کافی در تخمین فرایندهای فیزیکی در این ناحیه، پیش‌بینی‌ها باید از محدودیت‌های این مدل در پیش‌بینی وضع هوا در این ناحیه آگاهی کامل و به آن توجه داشته باشند. افزون‌براین، تقوی و نیستانی (۲۰۱۱)، با توجه به توپوگرافی پیچیده ایران، خطاهای پیش‌بینی مدل WRF را برای دمای دو متری در این منطقه بررسی کردند. نتایج مطالعه آنها بیان می‌کند که خطای اریبی^۹ مدل که به‌وسیله پارامترسازی نامناسب فرایندهای فیزیکی ایجاد شده، با خطاهای

شهری را با استفاده از سنجش از دور مطالعه کرده و به نقش مطالعات سنجش از دور برای مطالعات محیطی و فعالیت‌های مدیریتی و نیاز فراوان به این اطلاعات اشاره داشته‌اند و استخراج جزایر حرارتی را در مناطق شهری، با استفاده از داده‌های ماهواره و تعیین اثر نوع پوشش و کاربری زمین در دمای سطحی را بررسی کرده‌اند. پرس و همکاران^۲ (۲۰۱۳) در مطالعه‌ای، حساسیت روش‌های گوناگون بازیابی تابع گسیل و دمای سطح زمین را، با استفاده از داده‌های MSG/SEVIRI تحلیل کرده‌اند. در تحقیق دیگری، لی و همکاران^۳ (۲۰۱۳) الگوریتم‌های گوناگون تخمین LST را بررسی کرده‌اند. با وجود این، روش‌های جدیدی نیز در این سال‌ها معرفی شده است، همچون مطالعه جامع لیو و همکاران^۴ (۲۰۱۳) در بررسی پیشرفت‌ها، مزایا و معایب روش‌های متفاوت. سهرابی‌نیا و همکاران (۲۰۱۵) نیز، به‌تازگی، تحلیل زمان-مکان رابطه بین LST مستخرج از سنجنده مادیس و دمای هوا را در نیوزلند بررسی کرده‌اند. از دیگر سو، در سال‌های اخیر، به‌علت طبیعت بی‌نظم جو و پویا بودن آن، استفاده از تصاویر ماهواره و تکنیک‌های گوارد داده‌های ماهواره‌ای برای بهبود پیش‌بینی وضع هوا به چالشی مهم و بحث‌برانگیز تبدیل شده است. در این زمینه کارهای بسیاری با الگوریتم‌های داده‌کاوی و یا مدل‌های هواشناسی انجام شده است اما کارهای انجام‌شده تا کنون دقت خوبی نداشته‌اند و عملکرد مدل‌ها مناسب نبوده است. علت این نقص‌ها گاه از مدل و گاه از به‌کار نبردن امکانات جوی و تصاویر لحظه‌ای ماهواره‌ها ناشی می‌شود. در اینجا به برخی از این مطالعات اشاره می‌شود. برای نمونه، آتسکا و همکاران^۵ (۲۰۰۰) براساس تصاویر رادار و روش مبتنی بر حافظه، میزان رطوبت را پیش‌بینی کردند. در این مطالعه، نخست ویژگی‌های تصاویر مورد نظر استخراج، و سپس از طریق بازیابی تصاویر ذخیره‌شده در پایگاه داده و مقایسه آن با تصویر جدید، پیش‌بینی انجام شده است. یایپراسرت و همکاران^۶ (۲۰۰۷) پیش‌بینی وقوع باران در تایلند را، براساس فرایند استخراج مقدار پیکسل از

1. Two Temperature Method
2. Peres et al.
3. Li et al.
4. Liu et al.
5. Otsuka et al.
6. Yaiprasert et al.
7. Xu et al.
8. Weather Research Forecasting
9. bias

غیرسیستماتیک که ناشی از عدم قطعیت در شرایط اولیه است قابل مقایسه و حتی در برخی مناطق، بسیار بزرگ‌تر است. خطای کلی پیش‌بینی دمای سطح

مقصود و همکاران^{۱۰} (۲۰۰۴)، برای پیش‌بینی هوا در کانادا، از چهار شبکه RBF، MLP، و شبکه عصبی بازگشتی المان (ERNN)^{۱۱} و هاپفیلد^{۱۲} به صورت شبکه عصبی همادی^{۱۳} استفاده کردند. در این مدل شبکه RBF نتیجه بهتر، و شبکه هاپفیلد نتیجه بدتری داشته است. در ادامه، روش‌های میانگین وزنی (WA)^{۱۴} و انتخاب برنده (WTA)^{۱۵} را با چند معیار با هم مقایسه کردند و نتیجه گرفتند که روش انتخاب برنده نتیجه بهتری داشته است. حیاتی و همکاران (۲۰۰۷)، برای پیش‌بینی دمای شهر کرمان برای روز آینده، از شبکه MLP و داده‌های سرعت باد، دمای خشک، دمای تر، رطوبت، فشار، ساعت آفتابی و تابش به‌منزله ورودی شبکه در دوره‌ای ده‌ساله (۲۰۰۶-۱۹۹۶) استفاده کردند. نتایج کار آنها بیان می‌کند استفاده از این شبکه روش خوبی برای پیش‌بینی دماست. پارس و همکاران^{۱۶} (۲۰۰۷) با استفاده از روش شبکه عصبی MLP مبتنی بر انتخاب ویژگی به پیش‌بینی هوا پرداختند. نتایج تحقیق آنها نشان می‌داد پیش‌بینی با دقت بالاتری انجام شده است. شانکار و همکاران^{۱۷} (۲۰۰۷)، براساس داده‌های ورودی برخط دمای تر، پیش‌بینی ۱ تا ۱۲ ساعته دمای تر را، با روش شبکه عصبی در بیست ایستگاه در ایالت جورجیا امریکا، انجام دادند. نتایج ارزیابی مدل خطای

ناهمگونی فضایی چشمگیری را نشان می‌دهد، یعنی در مناطق کوهستانی، به‌ویژه در قله‌های مرتفع، خطاهای نسبتاً بزرگ‌تر وجود داشت و بنابراین، ضرورت استفاده از تصاویر ماهواره‌ای برای بهبود پیش‌بینی دمای سطحی را خاطرنشان کردند. در ادامه، پیشینه تحقیقات مرتبط با کاربرد شبکه‌های عصبی در پیش‌بینی جوی مرور می‌شود.

شبکه عصبی از قوی‌ترین روش‌های هوش مصنوعی است که به شیوه‌های گوناگون برای پیش‌بینی شرایط جوی به‌کار رفته است. برای نمونه، در این زمینه سانتوش و شریف^۱ (۲۰۱۰) ضرورت استفاده از تکنیک‌های جدید مبتنی بر روش‌های غیر خطی و سیستم‌های هوشمند را در پیش‌بینی وضع هوا، به‌سبب ماهیت بی‌نظم جو و ساختار غیرخطی معادلات حاکم بر آن یادآور شدند. هال^۲ (۱۹۹۸) از شبکه‌های عصبی برای به‌دست آوردن تابع احتمال رخداد بارش و مقدار آن در تگزاس استفاده کرده است. بودری و سرمک^۳ (۲۰۰۰) شبکه‌های عصبی را برای پیش‌بینی رطوبت به‌کار بردند. آنها از شبکه عصبی پرسپترون چندلایه (MLP)^۴ که با استفاده از انتشار به‌عقب (BP)^۵ آموزش داده شده است، برای داده‌های ثبت‌شده به‌وسیله ایستگاه‌های هواشناسی، استفاده کردند. نتایج ارزیابی این شبکه عصبی دقت بالا در این بررسی را بیان می‌کند. تیلور و همکاران^۶ (۲۰۰۲)، با استفاده از روش شبکه‌های عصبی، از چند سناریوی انتخاب ویژگی برای متغیرهای هواشناسی استفاده کردند. یاروشویچ و مادزیوک^۷ (۲۰۰۲) از شبکه عصبی برای پیش‌بینی دمای هوا در روز بعد استفاده کردند. در این مطالعه، آنها داده‌های هواشناسی با هفده ویژگی مربوط به سه روز گذشته را به‌کار بردند و دمای روز چهارم را براساس دو روش پیش‌بینی کردند. دل‌آکونا و گامبا^۸ (۲۰۰۳)، برای مدل‌سازی پیش‌بینی کوتاه‌مدت رفتار بارندگی، از شبکه عصبی تابع پایه شعاعی (RBF)^۹ و روش هرمی و داده‌های به‌دست‌آمده از تصاویر رادار استفاده کردند.

1. Santhosh and Shreef
2. Hall
3. Bodri and Cermak
4. multi layer perseptron
5. back-propagation
6. Taylor
7. Jaruszewicz and Madziuk
8. Gamba Dell'Acqua and
9. radial basis function
10. Maqsood et al.
11. elman recurrent neural network
12. Hopfield
13. ensemble
14. weighted averaging
15. winner take all
16. Paras et al.
17. Shankar et al.

می‌شود و قابلیت تعمیم ضعیف خواهد شد. اما اگر چند شبکه مجزا به همراه یک شبکه ورودی تصمیم‌گیرنده به کار رود، نتایج بهتر خواهد شد. ادوئه و کمل^{۱۱} (۱۹۹۹) شبکه عصبی ماژولار را بررسی، و دلایل ایجاد این شبکه‌ها و کارهای صورت‌گرفته در این زمینه را بیان کردند. جیمنس^{۱۲} (۱۹۹۸) اهمیت روش نهایی راه، برای ترکیب خروجی شبکه‌ها در شبکه هایماژولار و همادی، مطرح کرد و نشان داد که این مسئله در دقت شبکه بسیار مؤثر است. او از شبکه‌ای همادی استفاده، و خروجی شبکه‌ها را به صورت پویا با هم ترکیب کرد. جیمنس روش‌های گوناگونی را برای ترکیب نتایج عنوان، و با روش پیشنهادی مقایسه کرده است. مندوسا و همکاران^{۱۳} (۲۰۰۹) تفاوت شبکه‌های ماژولار و همادی را بیان کردند. در این مطالعه، آنها شبکه عصبی ماژولار را به کار بردند و در آخر، برای ترکیب نتایج شبکه‌ها از روش فازی استفاده کردند. برای ماژولار کردن آموزش در برخی از مطالعات، از شبکه SOM^{۱۴} استفاده شده است. برای نمونه، چیانو و همکاران^{۱۵} (۲۰۰۳، ۲۰۰۴) برای خوشه‌بندی روشی ترکیبی را مطرح کردند. در این الگوریتم، پس از آموزش اولیه SOM و مشخص شدن ساختار اولیه آن، بردار وزن SOM با الگوریتم بهینه‌سازی تجمع ذرات (PSO)^{۱۶} که به الگوریتم ازدحام پرنندگان نیز معروف است، خوشه‌بندی می‌شود. این الگوریتم یک الگوریتم بهینه‌سازی تصادفی مبتنی بر جمعیت است که کندی و ابرهارت^{۱۷} در سال ۱۹۹۵ آن را توسعه دادند. هر ذره در

کمی را نشان می‌داد. لوک و همکاران^۱ (۲۰۰۷)، برای پیش‌بینی باران، از سه شبکه MLP، شبکه بازگشتی جزئی (PRNN)^۲ و شبکه تأخیر زمانی (TDNN)^۳ استفاده کردند. در این بررسی، آنها کارآیی این سه شبکه را با هم مقایسه کردند و نشان دادند که هر شبکه با چه ساختاری عملکرد بهتری خواهد داشت. مس و فلورس^۴ (۲۰۰۸) کاربرد روش شبکه‌های عصبی در تخمین داده‌های سنجش از دور را بررسی کرده‌اند. هونگ و همکاران^۵ (۲۰۰۹) برای پیش‌بینی باران، انواع گوناگون شبکه‌های عصبی را امتحان کردند و به این نتیجه رسیدند که شبکه MLP بهتر است. رادیکا و ششی^۶ (۲۰۰۹)، برای پیش‌بینی دمای بیشینه، از روش ماشین بردار پشتیبان (SVM)^۷ و سری زمانی دمای بیشینه روزانه استفاده کردند تا این دما را برای روز بعد پیش‌بینی کنند. آنها نتایج را با شبکه MLP که با BP آموزش دیده است، مقایسه کردند اما روش SVM نتایج بهتری نشان می‌داد. سانتوش و شریف (۲۰۱۰) با استفاده از شبکه MLP و داده‌های موجود در ایستگاه‌های هواشناسی، یک سیستم پیش‌بینی هوا با عملکرد بسیار مناسب معرفی کردند. سانتانام و همکاران^۸ (۲۰۱۱) برای پیش‌بینی هوا از شبکه RBF براساس چند ویژگی از داده‌های جمع‌آوری شده استفاده کردند. سپس نتایج را با شبکه MLP مقایسه کردند و به این نتیجه رسیدند که عملکرد شبکه RBF از شبکه MLP بهتر بوده است. با توجه به رشد و گستردگی منابع و مطالعات در این زمینه در سال‌های اخیر، برای مطالعه بیشتر به زرگران (۱۳۹۱) مراجعه شود.

در تحقیقات در زمینه شبکه‌های عصبی، شبکه پیمان‌های یا ماژولار^۹ به سرعت رشد کرده است. شبکه عصبی ماژولار در جهت افزایش قابلیت تعمیم و سرعت آموزش کمک می‌کند. تحقیقاتی در این زمینه انجام شده است. برای نمونه، نولان و هینتون^{۱۰} (۱۹۹۰) عملکرد یک ساختار ماژولار را که از چند شبکه تشکیل شده، با شبکه‌ای چندلایه مقایسه کردند و نشان دادند که اگر برای آموزش شبکه‌ای چندلایه، برای کاربرد در موارد گوناگون، از روش BP استفاده شود، آموزش کند

1. Luk et al.
2. partial recurrent neural network
3. time delay neural network
4. Mas and Flores
5. Hung et al.
6. Radhika and Shashi
7. support vector machine
8. Santhanam et al.
9. modular
10. Nowlan and Hinton
11. Adua and Kamel
12. Jimenez
13. Mendoza et al.
14. self-organizing map
15. Xiao et al.
16. particle swarm optimization
17. Kennedy and Eberhart

بخار آب بوده است و در زمینه پیش‌بینی دمای سطح زمین کار چندانی انجام نشده است. با توجه به موارد یادشده در بالا، بررسی تأثیر این پیچیدگی‌ها در کیفیت پیش‌بینی دمای مدل‌های عددی وضع هوا در مناطق با توپوگرافی پیچیده و تلاش برای بهبود پیش‌بینی که هم از لحاظ علمی جهت اصلاح مدل عددی، و هم از لحاظ اقتصادی مهم است، از ضرورت‌های این مطالعه به‌شمار می‌رود. هدف طراحی مدل ترکیبی جدیدی براساس تصاویر ماهواره و شبکه‌های عصبی برای پیش‌بینی دمای سطح زمین است. در واقع، مدل پیشنهادی برای پیش‌بینی دما مدلی ترکیبی از روش‌های پیش‌پردازش و شبکه‌های عصبی و مفاهیم آماری است و دو ماژول کلی را دربر می‌گیرد. در ماژول نخست، روش جدیدی براساس شبکه‌های عصبی همدادی، با استفاده از داده‌های عددی، برای پیش‌بینی دمای سطح زمین معرفی شده است (زرگران و همکاران، ۲۰۱۴). در ماژول دوم، از تصاویر ماهواره استفاده می‌شود. بدین‌منظور، در این بررسی با به‌کار بردن روشی جدید و با استفاده از داده‌های تصاویر حرارتی سنجنده مادیس (MODIS) و شبکه‌های عصبی ماژولار، دمای سطح زمین پیش‌بینی می‌شود.


۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه شامل شهر تهران که بین طول جغرافیایی ۵۱.۲۰ و ۵۱.۴۰ و عرض جغرافیایی ۳۵.۴۰ و ۳۵.۵۰ (شکل ۱.الف) و در مجاورت ایستگاه سینوپتیکی مهرآباد است که با یک کادر قرمز مشخص شده است و از سایت مذکور در زمان گذر سنجنده مادیس در تاریخ‌های مورد نظر قابل برداشت است. و شکل ۱.ب تصویر اصلی مادیس از ناحیه مشخص شده با تفکیک مکانی ۱ کیلومتر که از نصف النهار ۵۰ درجه شرقی و از جنوب خزر تا شمال خلیج فارس کشیده شده است را نشان می‌دهد.

1. O'Neill and Brabazon
2. Sharma et al.
3. Liu and Zhang
4. moderate resolution imaging spectra-radiometer

PSO از حافظه خود و دانش به‌دست‌آورده از جمعیت استفاده می‌کند تا بهترین راه‌حل را بیابد. همه ذرات به‌وسیله تابع ارزیابی بررسی می‌شوند. هر ذره این مقدار و سرعت و جهت حرکت را با خود دارد. در طول حرکت، ذره موقعیت خود را براساس بهترین موقعیت به‌دست‌آمده از سوی خود و همسایه‌اش تنظیم می‌کند. برای ایجاد آموزش ماژولار در این مدل از این روش استفاده می‌شود که ترکیب جدیدی است. با استفاده از این شبکه، داده‌های آموزشی خوشه‌بندی می‌شوند و این داده‌ها در دو گروه قرار می‌گیرند. علت این موضوع آن است که از دو شبکه در این ماژول استفاده می‌شود. داده‌های هر گروه به شبکه مناسب برای آنها وارد می‌شوند و شبکه برگزیده برای هر گروه آموزش داده می‌شود. در این صورت، زمان آموزش شبکه‌ها کاهش می‌یابد و این امر، به‌علت خوشه‌بندی، پیش از ورود داده‌ها به شبکه انجام می‌شود. در این روش، هر ذره شامل همه وزن‌های SOM است و وزن‌ها با PSO برای خوشه‌بندی بهبود داده می‌شوند. اونیل و برابازن^۲ (۲۰۰۶) روشی ترکیبی از SOM و PSO برای آموزش بدون ناظر ارائه کردند. در این الگوریتم، در حین اجرای الگوریتم PSO، خوشه‌بندی مبتنی بر SOM انجام می‌شود. آنها این روش را برای چهار مجموعه داده اجرا کردند و با به‌دست آوردن میزان دقت، نشان دادند که این روش عملکرد مناسبی داشته است. شارما و همکاران^۳ (۲۰۰۸) از ترکیب الگوریتم PSO و SOM برای خوشه‌بندی استفاده کردند. ابتدا با استفاده از SOM خوشه‌بندی انجام شد و سپس، با استفاده از PSO، مرز خوشه‌ها مشخص می‌شود. لیو و ژانگ^۴ (۲۰۱۰) برای خوشه‌بندی، از دو الگوریتم PSO و SOM استفاده کردند. به این صورت که ابتدا با استفاده از SOM خوشه‌بندی انجام می‌شود، سپس، وزن‌های به‌دست‌آمده از SOM به‌منزله مقدار اولیه برای موقعیت ذره در PSO به‌کار می‌رود و PSO برای خوشه‌بندی نهایی اجرا می‌شود. همان‌گونه که در مرور ادبیات موضوع بیان شد، مطالعات پیش‌بینی جوی با استفاده از شبکه‌های عصبی و تصاویر ماهواره، بیشتر در زمینه پیش‌بینی باران، رطوبت و خشکسالی و براساس تصاویر



شکل ۱. (ب)

شکل ۱. (الف)

شکل ۱. (الف) تصویر منطقه مورد مطالعه شامل شهر تهران. (ب) تصویر سنجنده مادیس برای ناحیه مشخص شده از ایران در تاریخ ۲۰۱۲/۸/۲۸ در ساعت ۹:۵۰ UTC یکی از تصاویر مورد استفاده در شبکه

۲-۲- داده‌های مورد استفاده

دمای سطح زمین برای روز بعد پیش‌بینی می‌شود. پیش‌بینی در این قسمت نیز با استفاده از مدل ماژولار صورت می‌گیرد. در این ماژول، تصاویر حرارتی مادیس در فرمت اچ‌دی‌اف (فرمت ENVI) به کار می‌روند. در بخش‌هایی از تصویر، ارزیابی در نزدیکی ایستگاه مهرآباد انجام شده و نتایج در جدول‌ها آورده شده است. در واقع، در این ماژول خروجی یک تصویر است. با پیش‌بینی تصاویر، مقادیر دمای سطح زمین برآورد می‌شود.

جدول ۱. ویژگی باندهای استفاده‌شده در این مطالعه

Primary Use	Band	Bandwidth	Spectral Radiance
Surface/Cloud	31	10.780 - 11.280	9.55(300K)
Temperature	32	11.770 - 12.270	8.94(300K)

منبع: <http://modis.gsfc.nasa.gov/about/specifications.php>.

۲-۳- پردازش تصاویر و استخراج مقادیر مورد نیاز

در این مطالعه، برای محاسبه LST از رابطه (۱) استفاده می‌شود.

1. Terra
2. Aqua
3. reflectance
4. radiance
5. emissive
6. Hierarchical Data Format
7. <http://modis.gsfc.nasa.gov/about/specifications.php>.

در این مطالعه از تصاویر مربوط به سنجنده مادیس که روی هر دو ماهواره ترا^۱ و آکوا^۲ نصب شده، استفاده می‌شود. تصاویر دارای سه گروه مقادیرند: بازتابش^۳، تابایی^۴ و گسیلمندی^۵. در این مطالعه، از باندهای ۳۱ و ۳۲ با طول‌موج‌های ۱۱ و ۱۲ میکرومتر در مجموعه گسیلمندی، با پسوند فرمت داده سلسله‌مراتبی (HDF)^۶، استفاده می‌شود. HDF در واقع، کتابخانه و فرمت پوشه چندمنظوره برای انتقال داده گرافیکی و عددی است که برای هر تصویر چند تفکیک مکانی شامل ۲۵۰، ۵۰۰ متر و یک کیلومتر وجود دارد. در این بررسی، از داده‌های تصویر با تفکیک مکانی یک کیلومتر استفاده شده است و پنج تصویر در زمان‌های متفاوت، در ماه‌های شهریور و مهر و آبان، به‌منزله داده آموزشی برای آموزش شبکه و تصویری در ماه آذر، برای آزمایش مدل انتخاب شده است. جدول ۱ که از سایت مادیس گرفته شده است^۷، ویژگی باندهای استفاده‌شده در این مطالعه را نشان می‌دهد. مدل پیشنهادی برای پیش‌بینی دما، مدلی ترکیبی از روش‌های پیش‌پردازش و شبکه‌های عصبی و مفاهیم آماری، و شامل دو ماژول کلی است. در ماژول نخست، از داده‌های عددی استفاده شده که در مقاله زرگران و همکاران (۲۰۱۴) ارائه شده است. در ماژول دوم این مدل، از تصاویر ماهواره استفاده می‌شود و با کاربرد این داده‌ها و مدلی ماژولار،

رابطه (۱)

$$LST=0.39(BT31^2)+(2.34(BT31))-$$

$$(0.78(BT31*BT32))-$$

$$(1.34(BT32))+(0.39(BT32^2))+0.56$$

در این رابطه، BT31 و BT32 دمای درخشندگی^۱ مربوط به باندهای ۳۱ و ۳۲ باند حرارتی سنجنده مادیس است. براساس تعریف سالبی^۲ (۱۹۹۶)، دمای درخشندگی هر شیء یا پدیده عبارت از دمای معادل جسم سیاهی است که انرژی تابشی گسیل شده از آن به سنجنده می‌رسد و اندازه‌گیری می‌شود. روش محاسبه دماهای درخشندگی و مراحل استخراج داده‌ها در نمودار (شکل ۲) نشان داده شده است. بعد از زمین‌مرجع کردن تصاویر، باید مقدار هر پیکسل در این تصاویر که اعداد رقومی (DN)^۳ هستند، به دمای درخشندگی تبدیل شود. DN بازتاب پدیده‌ها به سنجنده مورد نظر است. براساس مقادیر دمای درخشندگی مربوط به هر باند ۳۱ و ۳۲ به‌دست‌آمده، دمای سطح زمین محاسبه می‌شود. بدین منظور، پس از تصحیح هندسی تصاویر، مقادیر رادیانس تصاویر به دمای درخشندگی تبدیل شد. سپس، با استفاده از رابطه (۱) LST محاسبه شد. در این بررسی با به‌کار بردن روشی مناسب، با استفاده از داده‌های تصاویر حرارتی سنجنده مادیس و شبکه‌های عصبی ماژولار دمای سطح زمین پیش‌بینی می‌شود، بدین‌گونه که نخست، تصاویر مربوط به پنج روز متفاوت در ماه‌های شهریور، مهر و آبان پردازش شد و مقادیر دمای درخشندگی و دمای سطح زمین استخراج شدند. سپس، داده‌های دمای درخشندگی مربوط به این تصاویر، به‌منزله داده ورودی وارد شبکه عصبی می‌شود و مقادیر دمای سطح زمین به‌منزله خروجی، از شبکه بازیابی می‌شود. از این طریق، شبکه‌ها آموزش می‌بینند و وزن‌های آنها استخراج می‌شود. پس از آن، ساختار بهینه برای شبکه‌ها به‌دست می‌آید. ساختار بهینه شامل تعداد نرون‌های بهینه در هر لایه و وزن‌های آنهاست. پس از آنکه ساختار بهینه برای شبکه‌ها محاسبه شد،

مقادیر دمای درخشندگی تصویر آزمایشی مربوط به ششم آذر به شبکه بهینه وارد، و مقادیر دمای سطح زمین برای این روز پیش‌بینی می‌شود. در این راستا، برای آموزش شبکه‌ها، مجموعه‌ای از داده‌های دمای درخشندگی برای هر پیکسل و برای پیش‌بینی مجموعه دیگری از مقادیر استفاده می‌شود. دو مقدار مورد نظر در نمودار (شکل ۲) با کادر قرمز مشخص شده است. با اعمال این نمودار، درنهایت، تصاویر مورد نیاز به‌دست می‌آیند.

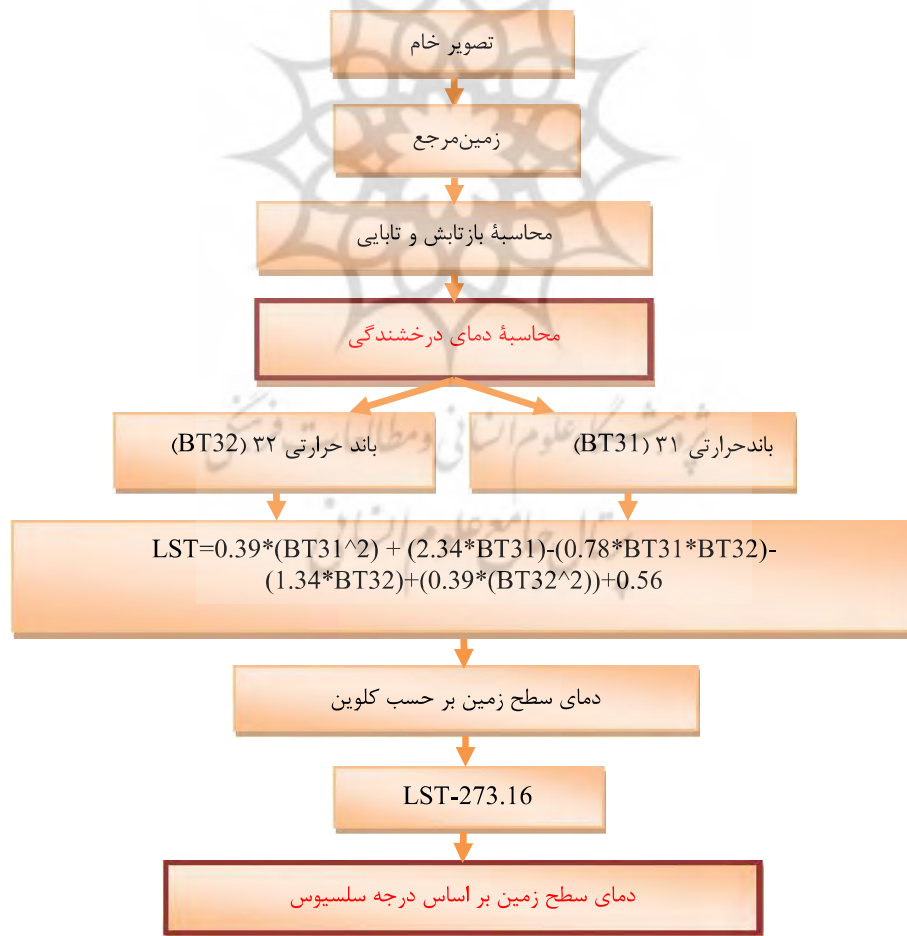
۲-۴- روش شبکه‌های عصبی ماژولار

در این مطالعه، پس از استخراج مقادیر دمای سطح زمین براساس نمودار (شکل ۲)، از روش شبکه‌های عصبی ماژولار برای پیش‌بینی دمای سطح زمین در آینده استفاده می‌شود. در شبکه‌های عصبی ماژولار شبکه‌های مورد استفاده با هم ترکیب می‌شوند. ایده ترکیب شبکه‌ها به‌منظور برطرف کردن ضعف هر شبکه در یادگیری قسمتی از مسئله ایجاد شده است. در شبکه ماژولار، میان شبکه‌های مورد استفاده هیچ همکاری وجود ندارد و هر یک روی قسمتی از مسئله عمل می‌کنند. در هر دو حالت، یک شبکه ماژولار خواهیم داشت که در آخر باید با هم ترکیب شوند. به‌طور کلی، برای ماژولار کردن شبکه عصبی دو شیوه وجود دارد: آموزش ماژولار و ساختار ماژولار. در حالت نخست، آموزش شبکه به‌صورت ماژولار انجام می‌شود که ساختار شبکه ممکن است ماژولار باشد یا نباشد. روش‌های بسیاری برای آموزش ماژولار وجود دارد. در حالت دوم، ساختار شبکه ماژولار است و مسئله مورد نظر میان این ماژول‌ها تقسیم می‌شود. یکی از راه‌های آموزش ماژولار استفاده از الگوریتمی بدون ناظر (خوشه‌بندی) است. در این مطالعه، از روش ترکیبی برای این منظور استفاده شده. برای ایجاد ساختاری

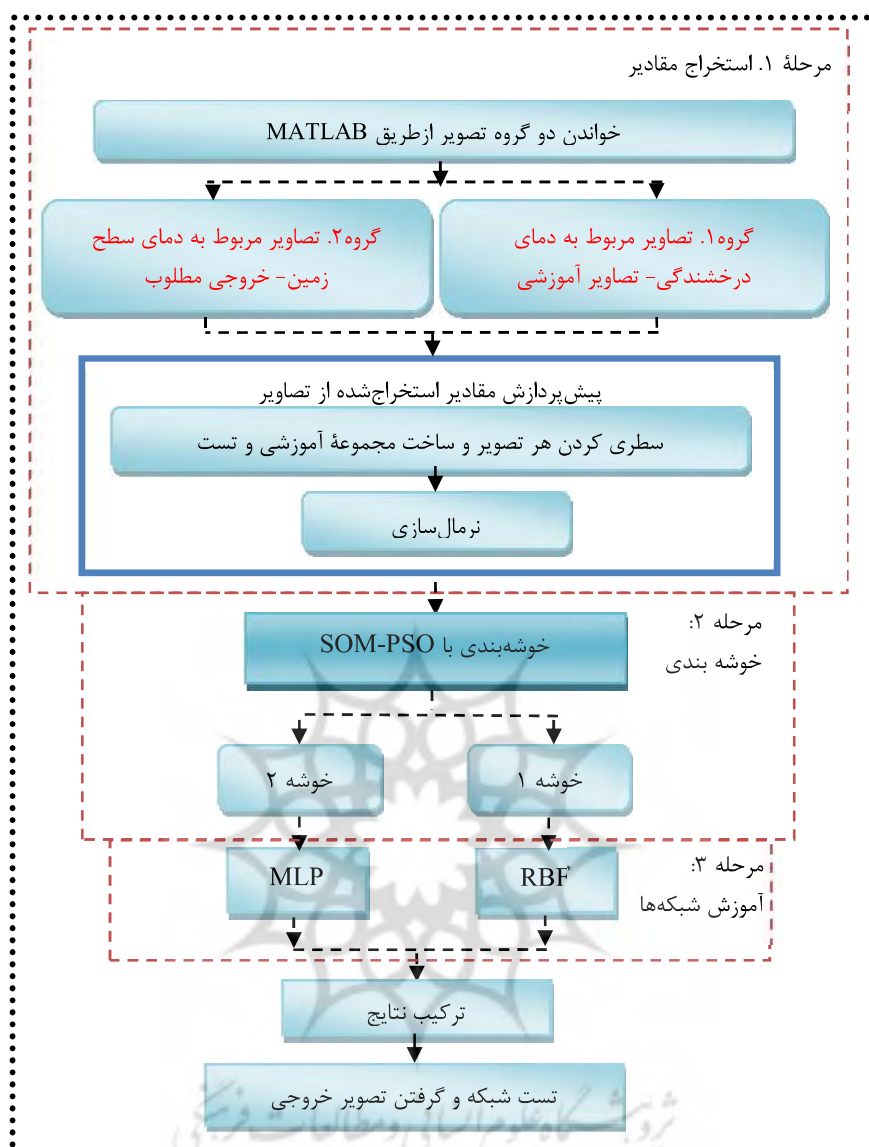
1. brightness temperature
2. Salby
3. digital number

استفاده از روش SOM-PSO، خوشه‌بندی انجام می‌شود و در مرحله بعدی، با ترکیب دو روش SOM و PSO، داده‌ها میان دو خوشه توزیع می‌شوند. در واقع، شبکه با این روش آموزش ماژولار خواهد شد. ساختار کلی شبکه عصبی SOM که در خوشه‌بندی کاربردهای فراوانی دارد، در شکل ۴ مشاهده می‌شود. این شبکه به دسته شبکه‌های بدون ناظر تعلق دارد و با الگوریتم رقابتی آموزش داده می‌شود. بدین معنا که نرون‌های لایه خروجی برای یک بردار ورودی با یکدیگر رقابت می‌کنند. هر بردار وزن نماینده یک خوشه است. بردار وزنی که به الگوی ورودی نزدیک‌تر است، به‌منزله بردار برنده انتخاب می‌شود.


ماژولار، از دو شبکه عصبی استفاده شده که در نمودار (شکل ۳) نمایش داده شده است. همان‌طور که در نمودار مشاهده می‌شود، در نخستین مرحله پس از استخراج مقادیر طبق نمودار (شکل ۲)، داده‌ها به دو دسته آموزشی و تست (آزمایشی) تقسیم می‌شوند. برای بهبود نتایج، داده‌ها پس از تبدیل به ماتریس سطری نرمال می‌شوند. در این مرحله، مقادیر به‌دست‌آمده از هر تصویر به ماتریسی ستونی تبدیل می‌شود. در ابتدا، این داده‌ها به روش Max-Min نرمال می‌شود. به این صورت که هر داده از مقدار کمینه کم می‌شود و بر اختلاف میان کمینه و بیشینه تقسیم می‌شود. در نتیجه، خروجی مورد نظر بین ۰ و ۱ قرار می‌گیرد و برای شبکه عصبی مناسب می‌شود. سپس با



شکل ۲. نمودار استخراج دمای سطح زمین




شکل ۳. نمودار مراحل روش مورد استفاده




شکل ۴. ساختار شبکه خودسازمانده (SOM)

الگوریتم PSO انجام می‌شود. در این صورت، داده‌ها به گونه‌ای مناسب میان خوشه‌ها تقسیم می‌شوند. مطابق نمودار (شکل ۳)، در مرحله سوم، شبکه‌های مورد استفاده آموزش داده می‌شوند. در این مطالعه، ساختار شبکه عصبی نیز ماژولار است و از دو شبکه عصبی MLP و RBF استفاده می‌شود. شمای کلی برای شبکه MLP در شکل ۵، و برای شبکه RBF در شکل ۶ مشاهده می‌شود. شبکه MLP از سه لایه ورودی، میانی و خروجی متشکل است. تعداد لایه‌های پنهان در این شبکه به نوع مسئله مورد نظر بستگی دارد. اگرچه تعداد بیشتر لایه‌های پنهان باعث می‌شود سیستم کلاس‌های بیشتری را اداره کند، ممکن است این افزایش درمورد ویژگی‌های دیگری هزینه زمانی ایجاد کند که در همگرا بودن الگوریتم تأثیر دارند.

برای معیار انتخاب معمولاً فاصله اقلیدسی به کار می‌رود. سپس وزن نرون برنده و همسایه‌های آن طبق تعدادی که از پیش مشخص شده است، به روز می‌شود. بدین ترتیب، این شبکه گروهی از بردارهای ورودی را تشخیص می‌دهد که به هم شبیه‌اند و خوشه‌ها شکل می‌گیرند. این شبکه به بردارهای وزنی وابستگی شدیدی دارد که در ابتدا، به صورت تصادفی تعیین می‌شود. اگر روی روش به کاررفته برای تقسیم مسئله و ایجاد آموزش ماژولار هیچ محدودیتی اعمال نشود، ممکن است اندازه یک ماژول از دیگری بزرگ‌تر شود. بنابراین، مسئله‌ای مهم در تقسیم مسئله میان ماژول‌ها اندازه آنهاست. در مطالعات پیش از این، روش SOM به کار رفته است. این روش اندازه یک خوشه را بزرگ‌تر از خوشه دیگر تعیین می‌کند. در این مطالعه، در هر مرحله، برای محاسبه وزن‌ها ترکیب الگوریتم رقابتی و



شکل ۵. طرح کلی از شبکه MLP



شکل ۶. طرح کلی از شبکه RBF

۳- نتایج و یافته‌ها

نتایج اولیه نشان داد هنگامی که از الگوریتم SOM برای خوشه‌بندی استفاده شود، داده‌ها در یکی از خوشه‌ها بیشتر تجمع می‌یابند و این برای ماژولار کردن شبکه‌ها مناسب نیست. نتایج خوشه‌بندی برای این روش در شکل ۷-الف مشاهده می‌شود. در یک خوشه 128,243 داده و در خوشه دیگر 69,137 داده قرار گرفته است. در این مطالعه، برای محاسبه وزن‌ها در هر مرحله ترکیب الگوریتم رقابتی و الگوریتم PSO انجام می‌شود. در این صورت، داده‌ها به‌گونه‌ای مناسب میان خوشه‌ها تقسیم می‌شود. زمانی که در این الگوریتم از الگوریتم PSO استفاده می‌شود، بهبود حاصل می‌شود و از طریق این روش، آموزش شبکه‌ها بهتر انجام می‌شود. در شکل ۷-ب این موضوع نشان داده شده است. همان‌طور که مشاهده می‌شود، در یکی از خوشه‌ها 99,484 و در دیگری 97,896 داده قرار گرفته است که توزیع مناسب به‌وسیله این الگوریتم را نشان می‌دهد. در مرحله بعد ساختار بهینه برای شبکه MLP و RBF به‌دست می‌آید. ساختار بهینه به مسئله مورد نظر بستگی دارد. برای این منظور، با تغییر تعداد نرون‌ها در لایه میانی، به‌طور میانگین، سه معیار مناسب برای هر تعداد محاسبه می‌شود. این معیارها عبارت‌اند از: زمان آموزش شبکه برحسب ثانیه (t)، درصد میانگین خطای مطلق (MAPE)^۲ و میانگین مربع خطا (MSE)^۳. در واقع، زمان آموزش شبکه نشان‌دهنده سرعت آموزش شبکه است. محاسبات یادشده برای هر خوشه در هر شبکه انجام می‌شود که هم ساختار بهینه برای هر شبکه به‌دست آید و هم شبکه مناسب برای هر خوشه تعیین شود. تعداد مناسب برای نرون‌های لایه میانی باید برای هر یک از این معیارها کمترین مقدار را داشته باشد. پس از انجام دادن این محاسبات، ساختار بهینه و خوشه


شبکه RBF طبقه‌بندی خاصی از ساختار روبه‌جلو را در شبکه‌های عصبی نمایش می‌دهد. این مدل برای تقریب توابع و نگاشت غیرخطی فرایندهای آماری توسعه پیدا کرد. این شبکه سه لایه گوناگون دارد: لایه ورودی، لایه پنهان با نرون‌های کافی که از طریق تابع شعاعی، تبدیلی غیرخطی از ورودی‌ها را انجام می‌دهند، لایه خروجی که تبدیلی خطی از ورودی حاصل از لایه پنهان را انجام می‌دهد. تکنیکی که برای آموزش این شبکه استفاده می‌شود، روشی ترکیبی است.

علت استفاده از این دو شبکه نتایج خوبی است که در مورد این تصاویر داشته‌اند. با آزمایش چند شبکه، این دو انتخاب می‌شوند و ساختار بهینه برای هر شبکه، روی گروه اختصاص یافته به آن تعیین می‌شود. در شبکه RBF مورد استفاده، تعداد نرون‌های لایه میانی با استفاده از الگوریتم K-means تعیین می‌شود. با استفاده از این الگوریتم، نرون‌های لایه میانی و مراکز و شعاع آنها مشخص می‌شود. در این شبکه، عملکرد منطقی یا تابع لاجستیک^۱ به کار می‌رود (Karray et al., 2004). در شبکه MLP، الگوریتم لونیبرگ برای آموزش، تابع سیگموئید برای لایه میانی و تابع خطی برای نرون لایه خروجی استفاده می‌شود. هر شبکه به‌صورت مستقل و موازی با گروه مناسب برای آن آموزش داده می‌شود. به‌علت اینکه داده‌ها پیش از ورود به شبکه‌ها خوشه‌بندی شده‌اند، آموزش آنها سریع‌تر از حالتی انجام می‌شود که شبکه ماژولار نباشد. پس از آموزش شبکه و محاسبه وزن‌ها و پارامترهای دیگر، مرحله ترکیب فرامی‌رسد. در شبکه ماژولار تقسیم مسئله میان شبکه‌ها، در ابتدا، و ترکیب نتایج، در انتها، در کارایی و عملکرد مدل بسیار مؤثر است. برای ترکیب نتایج در این قسمت، روش جدیدی به کار می‌رود. بدین صورت که برای ترکیب از قسمتی از هر شبکه استفاده می‌شود که در آن قسمت خوب عمل کرده است. در این روش، ترکیبی از میانگین و انتخاب برنده استفاده می‌شود. هر یک از شبکه‌ها نتایج متفاوتی دارند و در این صورت، به تصمیم‌گیری مناسبی در مورد ترکیب دست خواهیم یافت.

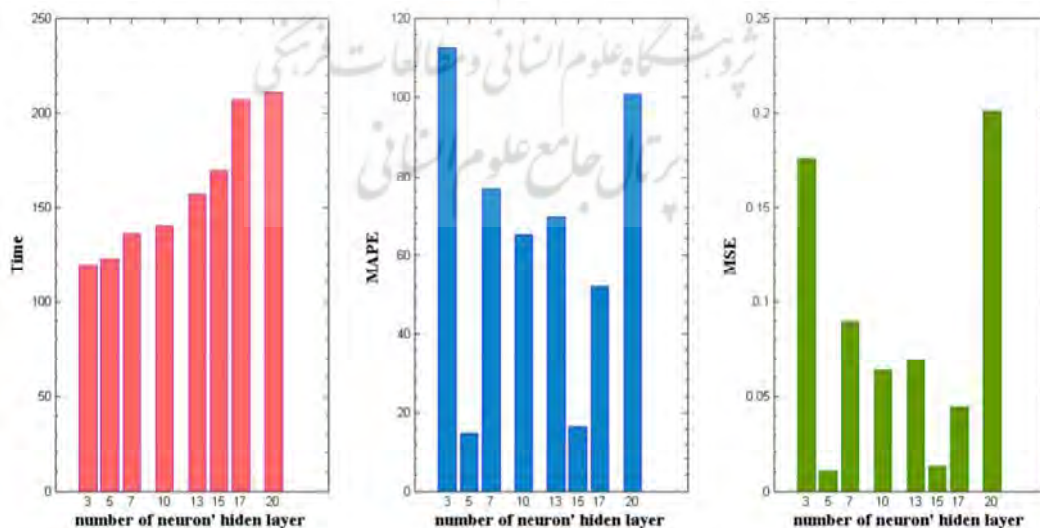
1. logistic function
2. Mean Absolute Percentage Error
3. Mean Square Error

خواهد بود. مقایسه نتایج برای شبکه RBF نشان می‌دهد که خوشه اول برای این شبکه مناسب‌تر است و در نتیجه، این خوشه برای آموزش شبکه RBF انتخاب می‌شود. با بررسی شکل ۹ مشخص می‌شود که سه نرون در لایه میانی مناسب‌تر است. در این حالت، زمان آموزش کمی از دو نرون در لایه میانی بیشتر است اما، با توجه به کمتر بودن دو معیار دیگر، می‌شود سه نرون را مناسب‌تر در نظر گرفت. هر یک از شبکه‌ها با خوشه مورد نظر به صورت مستقل آموزش داده می‌شوند.


مناسب برای هر شبکه تعیین می‌شود. با مقایسه نتایج، مشخص می‌شود که شبکه MLP، در مقایسه با خوشه اول، روی خوشه دوم نتایج بهتری دارد. بنابراین، خوشه دوم برای شبکه MLP مناسب‌تر است. شکل ۸ مقایسه سه معیار مورد نظر را برای تعداد متفاوت نرون‌ها در لایه میانی، در شبکه MLP، برای خوشه دوم نشان می‌دهد. همان‌طور که در شکل مشخص است، این سه معیار در پنج نرون در لایه میانی کمترین مقدار را دارند. بنابراین، تعداد نرون مناسب برای این شبکه پنج



شکل ۷. تفاوت روش برای خوشه‌بندی. الف) خوشه‌بندی با SOM، ب) خوشه‌بندی با SOM-PSO



شکل ۸. مقایسه سه معیار برای تعداد متفاوت نرون‌های لایه میانی در MLP برای خوشه دوم



شکل ۹. مقایسه سه معیار برای تعداد متفاوت نرون‌های لایه میانی در RBF برای خوشه اول

انتخاب، و خروجی نهایی یا پیش‌بینی محاسبه می‌شود. مدل پیشنهادی ترکیبی از دو شبکه MLP و RBF است. در جدول ۳ مدل پیشنهادی با شبکه MLP و RBF به کاررفته در این مدل، با استفاده از معیار MAPE مقایسه شده است و می‌بینیم که مقدار این معیار برای مدل پیشنهادی ۸/۷۵ است. این مقدار از دو مقدار دیگر کمتر است و نشان می‌دهد مدل پیشنهادی ترکیبی توانسته است عملکرد این دو شبکه را بهبود دهد. به‌علاوه استفاده از روش SOM-PSO، آموزش ماژولار می‌شود و سرعت آموزش برای هر یک از شبکه‌ها کاهش می‌یابد. طبق نمودار (شکل ۱۰)، در حالت غیرماژولار که الگوریتم SOM-PSO به کار نمی‌رود، زمان آموزش بسیار بیشتر از حالتی است که از این الگوریتم استفاده شده است. همچنین در جدول ۴، این دو حالت با مقادیر MAPE و MSE با هم مقایسه شده‌اند. مشاهده می‌شود با اینکه از الگوریتم خوشه‌بندی برای هر دو شبکه استفاده شده، این دو معیار مقدار کمتری دارند و این مطلب بیان می‌کند که استفاده از الگوریتم خوشه‌بندی، پیش از ورود داده‌ها به شبکه، کارایی شبکه را افزایش داده است.

آموزش این شبکه‌ها از طریق کاربرد الگوریتم خوشه‌بندی ماژولار صورت گرفته است و سرعت آموزش آنها، در مقایسه با حالتی که آموزش ماژولار ندارند، افزایش می‌یابد. حتی اگر دقت بالا نرود، داشتن مدلی سریع برای پیش‌بینی اهمیت ویژه‌ای دارد. پس از آموزش شبکه‌ها، نتایج آنها برای رسیدن به پیش‌بینی نهایی با هم ترکیب می‌شود. در این مطالعه، روش انتخاب برنده و میانگین وزنی با هم ترکیب می‌شوند. جدول ۲ مقدار MAPE مدل پیشنهادی را با چهار روش ترکیب نشان می‌دهد. همان‌طور که مشاهده می‌شود، مقدار MAPE برای روش پیشنهادی ۸/۷۵ است و برای ترکیب نتایج، در مقایسه با سه روش دیگر، مدل مورد نظر عملکرد بهتری دارد. روش WTA روش انتخاب برنده، و روش WA میانگین وزنی است. برای ترکیب نتایج، روش SOM که در مرور ادبیات بیان شده است، داده‌های آزمایش را ورودی در نظر می‌گیرد و برچسب آن را مشخص می‌کند. هر داده آزمایشی براساس برچسب اختصاص داده شده به آن، به شبکه مورد نظر می‌رود و بدین صورت، نتیجه نهایی تولید می‌شود. با این مقایسه، روش پیشنهادی برای ترکیب

فرحناز تقوی و همکاران

جدول ۲. مقایسه مدل مورد نظر با سه روش ترکیب

روش	Winner Take All(WTA)	Weighted Averaging (WA)	SOM	روش پیشنهادی (WTA&WA)
MAPE	۱۴/۰۵	۱۵/۳۷	۳۷/۳۲	۸/۷۵

جدول ۳. مقایسه مدل پیشنهادی با MLP و RBF مورد استفاده در مدل

مدل	ماژول پیشنهادی	MLP	RBF
MAPE	۸/۷۵	۳۷/۳۲	۱۸/۵۷

جدول ۴. مقایسه MLP و RBF در دو حالت ماژولار و غیرماژولار


مدل	MSE	MAPE
MLP	۰/۰۶۶۴	۶۹/۱۱
SOM-PSO-MLP	۰/۰۲۴۰	۳۷/۳۲
RBF	۰/۰۱۶۱	۱۹/۶۱
SOM-PSO-RBF	۰/۰۱۵۳	۱۸/۵۷

جدول ۵. مقایسه ماژول پیشنهادی با در نظر گرفتن روش خوشه‌بندی و بدون روش خوشه‌بندی

مدل	معیار	MAPE
ساختار ماژولار		۱۴/۷۷
ساختار و آموزش ماژولار		۸/۷۵

صورت است. همان‌طور که در شکل نشان داده شده، در حالت ماژولار بودن ساختار و آموزش، مقدار MAPE برابر با ۸/۷۵، و برای حالتی که از SOM-PSO استفاده نشده، این مقدار ۱۴/۷۷ است. مقایسه این مقادیر نشان می‌دهد در مدل پیشنهادی، کارایی شبکه بهتر است. اکنون ماژول پیشنهادی با ۳ مدل مقایسه می‌شود:

در مدل پیشنهادی، ابتدا خوشه‌بندی صورت می‌گیرد و سپس، نتایج با هم ترکیب می‌شود. در جدول ۵، برای نشان دادن تأثیر استفاده از روشی بدون ناظر پیش از آموزش شبکه‌ها، مدل پیشنهادی را با حالتی مقایسه می‌کنیم که در آن حالت، ابتدا از روش SOM-PSO استفاده نشود ولی مراحل دیگر به همان



شکل ۱۰. مقایسه MLP و RBF برای دو حالت آموزش ماژولار و غیرماژولار

نتایج تصویر را با دمایی مقایسه کرد که ثبت شده است. این تصویر متعلق به ششم آذر ۱۳۹۱ است. میانگین مقادیر واقعی مشخص شده در کادر ۲۶/۱۲، و میانگین مقادیر پیش‌بینی شده برای همین کادر ۲۵/۶۲ است. با توجه به اختلاف اندک بین این مقادیر، مشاهده می‌شود که این مدل توانسته دما را به خوبی پیش‌بینی کند. قابلیت تعمیم این مدل با استفاده از روش اعتبارسنجی ضربدری نیز بررسی شد. قابلیت تعمیم به این معناست که شبکه عصبی بتواند در مقابل داده ورودی که در داده‌های آموزشی نبوده است، دقت مناسبی داشته باشد. این معیار نشان می‌دهد که شبکه چقدر می‌تواند برای داده‌های دیگر خوب عمل کند. نتایج اعتبارسنجی ضربدری برای مدل مورد نظر در جدول ۷ بیان شده است. طبق این جدول، میانگین خطای MSE برابر با ۰/۰۰۸۱ و درصد خطای مطلق MAPE نیز ۱۰/۵۹ است.

- حالتی که شبکه MLP به تنهایی روی کل داده‌ها اجرا شود. در این حالت، ساختار و آموزش ماژولار نیست.
- حالتی که شبکه RBF به تنهایی روی کل داده‌ها اجرا شود. در این حالت نیز ساختار و آموزش ماژولار نیست.
- حالتی که ساختار ماژولار باشد ولی آموزش ماژولار نباشد. یعنی در ابتدا، از شبکه SOM استفاده نشود. در این حالت، هر چهار روش ترکیب با هم مقایسه می‌شود. نتایج در جدول ۶ بیان شده و مشاهده می‌شود که مقدار MAPE برای مدل پیشنهادی کمتر است، در نتیجه، مدل مورد نظر در مقایسه با روش‌های دیگر بهتر عمل کرده است.

در شکل ۱-الف ناحیه‌ای از تصویر که به ایستگاه هواشناسی مهرآباد تهران نزدیک است، مشخص شده است. این کار برای این منظور انجام می‌شود تا بشود

جدول ۶. مقایسه ماژول پیشنهادی با مدل‌های دیگر

مدل	معیار ارزیابی	MAPE
MLP		۶۹/۱۱
RBF		۱۹/۶۱
WA		۲۶/۸۰
WTA		۱۹/۰۱
SOM		۶۹/۱۱
مدل پیشنهادی		۸/۷۵

جدول ۷. نتایج اعتبارسنجی ضربدری برای مدل مورد نظر

تصاویر آموزشی و تست	معیارها	MSE	MAPE
۱،۲،۳،۴،۵-۶		۰/۰۰۲۱	۸/۷۵
۱،۲،۳،۴،۶-۵		۰/۰۰۱۵	۶/۳۷
۱،۲،۳،۵،۶-۴		۰/۰۰۲۰	۱۱/۱۰
۱،۲،۴،۵،۶-۳		۰/۰۰۱۶	۱۳/۰۰
۱،۳،۴،۵،۶-۲		۰/۰۰۵۱	۱۲/۵۳
۲،۳،۴،۵،۶-۱		۰/۰۰۲۳	۱۱/۹۴
میانگین		۰/۰۰۱۸	۱۰/۵۹

۴ - بحث و نتیجه‌گیری

تا کنون بیشتر مطالعات در زمینه پیش‌بینی شرایط جوی با استفاده از شبکه‌های عصبی درمورد پیش‌بینی باران، رطوبت و خشکسالی بوده و در زمینه پیش‌بینی دمای سطحی کارهای چندانی انجام نشده است. به همین منظور، در این تحقیق برای نخستین بار، از مدلی شامل مجموعه‌ای از شبکه‌های عصبی ماژولار برای پیش‌بینی دمای سطح زمین در شهر تهران براساس داده‌های تصاویر ماهواره استفاده شده است. مدل مورد نظر ساختار و آموزش ماژولار دارد. به‌علت حجم بالای تصاویر، زمان آموزش شبکه‌ها هنگام استفاده از تصاویر ماهواره دارای اهمیت ویژه‌ای است. به همین دلیل، برای کاهش زمان آموزش و افزایش سرعت آموزش و دقت، از آموزش ماژولار استفاده می‌شود. برای این منظور، الگوریتمی متفاوت به کار می‌رود که تا کنون در زمینه شبکه‌های عصبی ماژولار استفاده نشده است. در این الگوریتم، در هر مرحله در شبکه SOM از الگوریتم PSO استفاده می‌شود. بنابراین، داده‌ها میان شبکه‌ها تقسیم می‌شود و زمان آموزش شبکه‌ها کاهش می‌یابد. در این مدل، با استفاده از دو شبکه MLP و RBF، ساختار ماژولار می‌شود و این شبکه‌ها روی هر خوشه آموزش داده می‌شوند و در نهایت، نتایج با روشی متفاوت ترکیب می‌شوند. این روش ترکیب WA و WTA است. مطابق نتایج، درمقایسه با شبکه‌هایی که ساختار و آموزش ماژولار ندارند، مدل مورد نظر عملکرد بهتری داشته و توانسته در پیش‌بینی دمای سطح دقت را افزایش دهد. اختلاف کم بین مقادیر پیش‌بینی شده و مقادیر واقعی در منطقه نشان می‌دهد که این مدل توانسته دما را به‌خوبی پیش‌بینی کند. افزون‌براین، زمان پیش‌بینی را از طریق به‌کار بردن آموزش ماژولار کاهش داده است.

۵- تشکر و قدردانی

نویسندگان از معاونت پژوهشی مؤسسه ژئوفیزیک دانشگاه تهران که در تأمین بخشی از هزینه این پژوهش از طریق طرح پژوهشی به شماره ۶۲.۲.۱۳/۱/۰۲ همکاری داشته‌اند، تشکر می‌نمایند.

منابع

تقوی، ف.، اولاد، ا.، صفراد، ط.، ایران‌نژاد، پ.، ۱۳۹۲، تشخیص و پایش توفان گردوغبار غرب ایران با استفاده از تکنیک‌های سنجش از دور، مجله فیزیک زمین و فضا، دوره ۳۹، شماره ۳، صص. ۹۶-۸۳.

سایت تصاویر سنجنده مادیس، ۲۰۱۰.
rapidfire.sci.gsfc.nasa.gov/realtime

شکیبا، ع.، ضیائی‌ان فیروزآبادی، پ.، عاشورلو، د.، نامداری، سودابه.، ۱۳۸۸، تحلیل رابطه کاربری و پوشش اراضی و جزایر حرارتی شهر تهران با استفاده از داده‌های ETM+، سنجش از دور و GIS ایران، سال اول، شماره ۱، صص. ۵۶-۳۹.

علوی‌پناه، س.ک.، ۱۳۸۲، کاربرد سنجش از دور در علوم زمین (علوم خاک)، تهران، انتشارات دانشگاه تهران.

Anderson, M.C., Norman, J.M., Kustas, W.P., Houborg, R., Starks, P.J & Agam, N., 2008, **A Thermal-Based Remote Sensing Technique for Routine Mapping of Land-Surface Carbon, Water and Energy Fluxes from Field to Regional Scales**, Remote Sensing of Environment, Vol. 112, No. 12, PP. 4227-4241.

Auda, G.K. & Kamel, M., 1999, **Modular Neural Networks: A Survey**, International Journal of Neural Systems, Vol. 9, Issue 2, PP. 129-151.

Behbahani, S.M.R., Rahimikhoob, A. & Nazarifar, M.H., 2009, **Comparison of Some Split-Window Algorithms to Estimate Land Surface Temperature from AVHRR Data in South eastern Tehran, Iran: Desert**, Vol. 14, No. 2, PP. 157-161.

Bodri, L.C. & Cermak, V., 2000, **Prediction of Extreme Precipitation Using a Neural Network: Application to Summer Flood Occurrence in Moravia**, Advances Eng. Software, Vol. 31, No. 5, PP. 311-321.

- Dell'Acqua, F.G. & Gamba, P., 2003, **Pyramidal Rain Field Decomposition Using Radial Basis Function Neural Networks for Tracking and Forecasting Purposes**, IEEE Trans. on Geoscience and Remote Sensing, Vol. 41, No. 4, PP. 853-862.
- Hall, T.H., 1998, **Precipitation Forecasting Using a Neural Network**, Weather and Forecasting, Vol. 14, PP. 338-345.
- Hayati, M.M. & Mohebi, Z., 2007, **Temperature Forecasting Based on Neural Network**, World Applied Sciences, Vol. 2, No. 6, PP. 613-620.
- Hierarchical Data Format, HDF: <http://www.hdfgroup.org/HDF-FAQ.html>
- Hung, N.Q., Babel, M.S., Weesakul, S. & Tripathi, N.K., 2009, **An Artificial Neural Network Model for Rainfall Forecasting in Bangkok, Thailand**, Hydrol. Earth Syst. Sci, Vol. 13, No. 8, PP. 1413-1425.
- Jaruszewicz, M.M. & Madziuk, J., 2002, **Application of PCA Method to Weather Prediction Task**, IEEE, Neural Information Processing, Vol. 5, PP. 2359-2363.
- Jimenez, D., 1998, **Dynamically Weighted Ensemble Neural Networks for Classification**, Neura Networks, Vol. 1, PP. 753-756.
- Kalnay, E., 2003, **Atmospheric Modeling, Data Assimilation and Predictability**, Cambridge University Press.
- Karray, F.O. & de Silva, C., 2004, **Soft Computing and Intelligent Systems Design**, Harlow, England: Pearson Education Limited.
- Karnieli, A., Agam, N., Pinker, R.T., Anderson, M., Imhoff, M.L. & Gutman, G.G., 2010, **Use of NDVI and Land Surface Temperature for Drought Assessment, Merits and Limitations**, Journal of Climate, Vol. 23, No. 3, PP. 618-633.
- Kustas, W. & Anderson, M., 2009, **Advances in Thermal Infrared Remote Sensing for Land Surface Modeling**, Agricultural and Forest Meteorology, Vol. 149, Issue 12, PP. 2071-2081.
- Kattekola, S., 2010, **Weather Radar Image Based Forecasting Using Joint Series Prediction**, Thesis, University of New Orleans .
- Knorr, W.P., Ioannis, P., George, P. & Nadine, G., 2011, **Combined Use of Weather Forecasting and Satellite Remote Sensing Information for Fire Risk, Fire and Fire Impact Monitoring**, Computational Ecology and Software, Vol.1, No. 2, PP.112-120.
- Li, Z.L., Tang, B.H., Wu, H., Ren, H., Yan, G., Wan, ZH., Trigo, I.F. & Sobrino, J.A., 2013, **Satellite-Derived Land Surface Temperature: Current Status and Perspectives**, Remote Sensing of Environment, Vol. 131, PP. 14-37.
- Liu, C.X. & Zhang, C.F., 2010, **Cluster Algorithm Based on Hybrid SOM and PSO**, Communications Technology.
- Luk, K.C., Ball, J.E. & Sharma, A., 2007, **An Application of Artificial Neural Networks for Rainfall Forecasting, Modelling and Simulation Society of Australia and New Zealand**.
- Lynch, P., 2006, **The Emergence of Scientific Weather Forecasting**, Cambridge University Press.
- Maqsood, I.R., Riaz, M. & Abraham, Kh., 2004, **An Ensemble of Neural Networks for Weather Forecasting**, Neural Comput & Applic, Vol. 13, No. 2, PP. 112-122.
- Mas, J.F. & Flores, J.J., 2008, **The Application of Artificial Neural Networks to the Analysis of Remotely Sensed Data**, International Journal of Remote Sensing, Vol. 29, No. 3, PP. 617-663.
- Mendoza, O.M., Melin, P. & Castillo, O., 2009, **Interval Type-2 Fuzzy Logic and Modular Neural Networks for Face Recognition**

- Applications**, Applied Soft Computing, Vol. 9, No. 4, PP. 1377-1387.
- Nowlan, S.J. & Hinton, G.E., 1990, **Evaluation of Adaptive Mixtures of Competing Experts**, Neural Information Processing Systems, PP. 774-780.
- O'Neill, M.B. & Brabazon, A., 2006, **Self-Organizing Swarm (SOSwarm): A Particle Swarm Algorithm for Unsupervised Learning**, IEEE, Evolutionary Computation, PP. 634-639.
- Otsuka, K.H., Horikoshi, T., Suzuki, S. & Kojima, H., 2000, **Memory-Based Forecasting for Weather Image Patterns**, Artificial Intelligence, PP. 330-336.
- Paras, S.M., Mathur, S., Kumar, A. & Chandra, M., 2007, **A Feature Based Neural Network Model for Weather Forecasting**, World Academy of Science, Engineering and Technology, Vol. 34, PP. 66-73.
- Peres, L.F., Carlos, C. & DaCamara, 2013, **Land Surface Temperature and Emissivity Estimation Based on the Two-Temperature Method: Sensitivity Analysis Using Simulated MSG/SEVIRI Data**, Remote Sensing of Environment, Vol. 91, No. 3, PP. 377-389.
- Prata, A J., Caselles, V., Coll, C., Sobrino, J.A. & Otlé, C., 1995, **Thermal Remote Sensing of Land Surface Temperature from Satellites, Current Status and Future Prospects**, Remote Sensing Reviews, Vol. 12, Issue 3-4, PP. 175-224.
- Price, J.C., 1983, **Estimating Surface Temperatures from Satellite Thermal Infrared Data: A Simple Formulation for the Atmospheric Effect**, Remote Sensing of Environment, Vol. 13, PP. 353-361.
- _____, 1984, **Land Surface Temperature Measurements from the Split Window Channels of the NOAA 7 AVHRR**, Journal of Geophysical Research, Vol. 89, Issue D5, PP. 7231-7237.
- Principe, J.C., Euliano, N.R. & Lefebvre, W.C., 2000, **Neural and Adaptive Systems**, New York, John Wiley and Sons.
- Radhika, Y.S. & Shashi, M., 2009, **Atmospheric Temperature Prediction Using Support Vector Machines**, International Journal of Computer Theory and Engineering, Vol. 1, No. 1, PP. 55-58.
- Salby, M.L., 1996, **Fundamentals of Atmospheric Physics**, International Geophysics series, Elsevier.
- Santhanam, T.S. & Subhajini, A.C., 2011, **An Efficient Weather Forecasting System using Radial Basis Function Neural Network**, Computer Science, Vol. 7, Issue 7, PP. 962-966.
- Santhosh Baboo, S. & Shereef, I.K., 2010, **An Efficient Weather Forecasting System Using Artificial Neural Network**, Environmental Science and Development, Vol. 1, No. 4, PP. 321-326.
- Santurette, P. & Georgiev, C., 2005, **Weather Analysis and Forecasting: Applying Satellite Water Vapor Imagery and Potential Vorticity Analysis**, Elsevier Academic Press.
- Shank, D.B., Hoogenboom, G. & McClendon, R.W., 2008, **Dewpoint Temperature Prediction Using Artificial Neural Networks**, J. Appl. Meteor. Climatol, Vol. 47, PP. 1757-1769.
- Sharma, A.O. & Omlin, Ch.W., 2008, **Determining Cluster Boundaries Using Particle Swarm Optimization**, World Academy of Science, Engineering and Technology, Vol. 2, No. 10, PP. 1106-1110.
- Sobrino, J.A. & Romaguera, M., 2004, **Land Surface Temperature Retrieval from MSG1-SEVIRI Data**, Remote Sensing of Environment, Vol. 92, PP. 247-254.
- Sohrabinia, M., Zavar-Reza, P., Rack, W., 2015, **Spatio-Temporal Analysis of the Relationship between LST from MODIS and Air Temperature in New Zealand**, Theor. Appl. Climatol., Vol. 119, Issue 3., PP. 567-583.

- Su, M.B. & Basu, M., 2001, **Gating Improves Neural Network Performance**, Neural Networks, Vol. 3, PP. 2159-2164.
- Taghavi, F. & Neyestani, A., 2011, **Short Range Temperature Forecast Verification of WRF Model over Iran, Abstract Proceedings of XXV IUGG General Assembly, Earth on the Edge**, Science for a Sustainable Planet Melbourne, Australia, www.iugg.com
- Taylor, J.B. & Buizza, R., 2002, **Neural Network Load Forecasting with Weather Ensemble Predictions**, IEEE Trans. on Power Systems, Vol. 17, No. 3, PP. 626-632.
- Xiao, X.D., Dow, E.R., Eberhart, R., Miled, Z.B. & Oppelt, R.J., 2003(a), **Gene-Clustering Using Self-Organizing Maps and Particle Swarm**, IEEE International Parallel and Distributed Processing Symposium, PP. 22-26.,
- _____, 2004(b), **A Hybrid Self-Organizing Maps and Particle Swarm Optimization Approach: Concurrency and Computation**, Practice and Experience, Vol. 16, No. 9, PP. 895-915.
- Xu, J., Rugg, S., Byerle, L. & Liu, Z., 2009, **Weather Forecasts by the WRF-ARW Model with the GSI Data Assimilation System in the Complex Terrain Areas of Southwest Asia: Weather and Forecasting**, Vol. 24, No. 4, PP. 987-1008.
- Yaiprasert, C.J., Jaroensutasinee, K. & Jaroensutasinee, M., 2007, **The Pixel Value Data Approach for Rainfall Forecasting Based on GOES-9 Satellite Image Sequence Analysis**, Engineering & Technology, Vol. 36, P. 186.
- Zargaran, Z., Ahmadi, A., Mohebi, A. & Taghavi, F., 2014, **Hybrid Model for Weather Forecasting Using Ensemble of Neural Networks and Mutual Information**, IEEE International Geoscience and Remote Sensing symposium, Quebec, July 13-18, Academy of Science, Engineering and Technology, 186-191, www.igarss2014.org.

