



Precipitation Retrieval Using IR Channels Brightness Temperature from SEVIRI

A. Gheiby^{1*}, S. Khwarazmi², and M. Rahnama³

Abstract

This study is performed to retrieve precipitation amount using Spinning Enhanced Visible and InfraRed Imager (SEVIRI) from Meteosat Second Generation (MSG). According to the relationship between the infrared channels brightness temperature and the microphysical and optical properties of the clouds (such as cloud top temperature, cloud top height, optical thickness, particle size, and particle phase), and the influence of changes in these properties on the determination of precipitation amount and intensity, the relationship between brightness temperature and precipitation have been studied for two stations in Hormozgan province. The performance of an artificial neural network and also several regression models to estimate precipitation has been evaluated. The results showed that the exponential Gaussian process regression model with performing principal component analysis by RMSE of 0.44, POD of 0.96 and the HSS of 0.67 for precipitation threshold 0.1 mm for the less than 10 mm precipitation data set have the best performance. The artificial neural network also presented a RMSE of 1.27 which indicates weaker performance in comparison with the regression model but showed good performance in distinguishing precipitation conditions from non-precipitation conditions (POD of 0.85 and HSS of 0.48). By comparing the correlation between precipitation and brightness temperature of infrared channels (average 0.36), and the correlation between observed and retrieved precipitation (0.91 in the regression model and 0.43 in the neural network), it can be concluded that the precipitation products which extracted in this study, show a good correlation between observed and retrieved precipitation.

Keywords: Precipitation, Infrared Brightness Temperature, SEVIRI, Regression Model, Artificial Neural Network.

Received: October 18, 2020

Accepted: April 13, 2021

بازیابی بارش با استفاده از دمای روشنایی کانال‌های SEVIRI فرسرخ سنجنده

ابوالحسن غیبی^{۱*}، سعیده خوارزمی^۲ و مهدی رهنما^۳

چکیده

این مطالعه به منظور بازیابی میزان بارش با استفاده از دمای روشنایی کانال‌های فرسرخ از داده‌های تصویربردار چرخان پیشرفته مرئی و فرسرخ (SEVIRI) از نسل دوم ماهواره‌های (MSG) Meteosat انجام گرفته است. با توجه به ارتباط بین دمای روشنایی کانال‌های فرسرخ ماهواره‌ای با ویژگی‌های میکروفیزیکی و نوری ابرها (مانند دمای قله ابر، ارتفاع قله ابر، ضخامت نوری ابر، اندازه ذرات و همچنین فاز ذرات)، و تأثیر تغییر هر یک از این ویژگی‌ها در تعیین میزان و محدوده شدت بارش، با استفاده از مدل‌های آماری و رگرسیونی و همچنین روش شبکه‌های عصبی مصنوعی ارتباط بین تغییرات دمای روشنایی و بارش در دو ایستگاه هواشناسی استان هرمزگان، مورد مطالعه قرار گرفته و عملکرد روش‌های مذکور برای بازیابی میزان بارش مورد ارزیابی قرار گرفته است. نتایج بررسی مدل‌ها نشان داد مدل رگرسیون فرایند گاوسی نمای پس از انجام تحلیل مؤلفه اصلی با RMSE: ۰/۴۴، POD: ۰/۹۶ و HSS: ۰/۶۷ برای آستانه بارش ۰/۱ میلی‌متر (در طی نیم ساعت) برای مجموعه داده‌های بارش کمتر از ۱۰ میلی‌متر، بهترین عملکرد را دارا می‌باشد. شبکه عصبی مصنوعی نیز با RMSE ۱/۲۷ عملکرد ضعیف‌تری نسبت به مدل رگرسیونی را نشان داد اما عملکرد خوبی را در تفکیک شرایط بارشی از غیربارشی (POD: ۰/۸۵ و HSS: ۰/۴۸) ارائه داد. با مقایسه همبستگی بین بارش و دمای روشنایی (بطور متوسط ۰/۳۶)، و همبستگی بین بارش مشاهده شده و بارش بازیابی شده (در مدل رگرسیونی ۰/۹۱ و در شبکه عصبی ۰/۴۳)، می‌توان نتیجه گرفت محصولات بارشی تولید شده است که می‌تواند همبستگی خوبی را بین بارش مشاهده شده و بارش بازیابی شده نشان دهد.

کلمات کلیدی: بازیابی بارش، دمای روشنایی فرسرخ، سنجنده SEVIRI، مدل رگرسیونی، شبکه عصبی مصنوعی.

تاریخ دریافت مقاله: ۹۹/۷/۲۷

تاریخ پذیرش مقاله: ۱۴۰۰/۱/۲۴

1- Faculty Member of Physics Department, Hormozgan University. Email: abolhassang@yahoo.com

2- Ph.D. Candidate of Meteorology, Hormozgan University. Email: s.khwarazmi@yahoo.com

3- Faculty Member of Atmospheric Science and Meteorological Research Center, Tehran. Email: meh.rahnama@gmail.com

*- Corresponding Author

Dor: [20.1001.1.17352347.1400.17.1.6.7](https://doi.org/10.1001.1.17352347.1400.17.1.6.7)

۱- عضو هیئت علمی گروه فیزیک، دانشگاه هرمزگان.

۲- دانشجوی دکتری هواشناسی، دانشگاه هرمزگان.

۳- عضو هیئت علمی، پژوهشگاه هواشناسی و علوم جو، تهران.

*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان تابستان ۱۴۰۰ امکانپذیر است.

عصبی (NNET)، شبکه‌های عصبی میانگین‌گیری شده (AVNNET) و ماشین‌های بردار پشتیبانی (SVM)) را برای شناسایی مناطق بارشی و تعیین آهنگ بارش در کشور آلمان بکار گرفتند. در نهایت، دریافتند اگرچه در عملکرد الگوریتم‌ها تفاوت اندکی وجود دارد، اما NNET و AVNNET عملکرد بهتری دارند.

اعتبارسنجی دقت برآوردهای بارش ماهواره‌ای نیز در مناطق مختلف جهان و در مقیاس‌های زمانی و مکانی مختلف مورد مطالعه قرار گرفته است (Dinku et al., 2007; Kubota et al., 2007; Kidd et al., 2013; Chen et al., 2009). از ویژگی‌های طیفی و بافتی ابر برگرفته از کانال‌های MSG SEVIRI به‌عنوان ورودی مدل‌های پرسپترون چند لایه جدید (MLP) و ماشین بردار پشتیبانی (SVM) برای تخمین بارش توسط (Sehad and Ameur (2020) استفاده گردید. بارش برآورد شده را با مجموعه داده‌های بارش رادار و شبکه باران‌سنجی اعتبارسنجی کرده و نتایج $Bias=0.31mm$, $RMSE = 2.20mm$ و $MAE = 1.07mm$ را بدست آوردند. (Ghahraman et al. (2019) در حوضه آبریز شاپور اطلاعات بارش مدل‌های PERSIANN و CMORPH را ارزیابی کردند. نتایج نشان داد CMORPH ضریب همبستگی بهتری با داده‌های مشاهداتی دارد اما PERSIANN در آشکارسازی تعداد روزهای بارانی نتایج بهتری را ارائه می‌دهد. (Azizian et al. (2018) به ارزیابی عملکرد مدل ECMWF در گام‌های زمانی روزانه و ماهانه در سطح حوضه آبریز سفیدرود پرداختند و همچنین از منابع بارشی پرکاربرد مانند PERSIAN و TRMM برای بررسی کارایی منبع ECMWF استفاده کردند و دریافتند که این منبع با دارا بودن ضریب همبستگی بالای ۰/۹ در مقیاس روزانه دارای بهترین عملکرد بوده در حالیکه TRMM و PERSIAN به ترتیب دارای ضریب همبستگی ۰/۳۲ و ۰/۴۷ می‌باشند.

یکی از مهم‌ترین کاربردهای محصولات بارش ماهواره‌ای، استفاده از آنها در مدل‌های پیش‌بینی سیل و تخمین حجم ورودی آب به سدها می‌باشد. به‌عنوان مثال، (Yilmaz et al. (2005) از برآوردهای بارش ماهواره‌ای برای پیش‌بینی هیدرولوژیکی استفاده کردند. همچنین (Hong et al. (2007) استفاده از داده‌های ماهواره‌ای را در نزدیکی زمان واقعی با استفاده از ماموریت اندازه‌گیری بارش حاره‌ای (TRMM) در سیستم نظارت جهانی برای هشدار سریع سیل و رانش‌های زمینی پیشنهاد کردند. اخیراً نیز (Atif et al. (2020) با استفاده از داده‌های ماهواره‌ای MSG-SEVIRI و TRMM یک سیستم همرفتی که باران شدید آن منجر به جاری شدن سیل شده بود را بررسی کرده و اظهار داشتند که در جاهایی که اندازه‌گیری‌های

اندازه‌گیری دقیق میزان بارش در مقیاس‌های زمانی و مکانی مختلف، برای محدوده وسیعی از تصمیم‌گیری‌ها و فعالیت‌ها از جمله کشاورزی، آب‌شناسی، مدیریت بحران، صنعت و بسیاری فعالیت‌های دیگر در کشور حائز اهمیت است. برای اندازه‌گیری بارش روش‌های مختلفی از جمله مشاهدات ایستگاهی (باران‌سنج‌ها)، رادارهای زمینی، برآوردهای استنباط شده از مشاهدات ماهواره‌ای و خروجی مدل‌های عددی مختلف، وجود دارد که هر یک معایب و مزایایی دارند. به‌عنوان مثال آشکارترین محدودیت‌های اندازه‌گیری بارش بر اساس مشاهدات ایستگاهی، پراکندگی مکانی و توزیع ناهموار جهانی آنها می‌باشد. در این زمینه، بازیابی‌های بارش از سنجنده‌های نوری بر روی ماهواره‌های هواشناسی می‌تواند با ارائه اطلاعات گسترده‌ای درباره توزیع و مقدار بارش در تفکیک‌های مکانی و زمانی بالا، جایگزینی برای شکاف‌های اطلاعاتی باشد. برای بازیابی بارش از این ماهواره‌ها، الگوریتم‌های زیادی بر مبنای تابش در کانال‌های مرئی، فرورسرخ و همچنین میکروویو توسعه داده شده‌اند. به‌عنوان مثال، (Sanchez et al. (2010) بر پایه ارتباط فیزیکی بین مقدار آب‌شهاب‌های موجود در جو و آهنگ بارش در سطح، الگوریتمی برای آهنگ بارش توسعه دادند که این الگوریتم از روش رگرسیون چندخطی استفاده می‌کند. یک الگوریتم بارش دو طیفی برای اسپکتروراديو متر تصویربرداری با قدرت تفکیک متوسط (MODIS) توسط (Yan and Yang (2007) پیشنهاد شد. آنها از کانال ۰/۶۵ میکرومتر همراه با کانال جذب بخار آب در ۱/۳۸ میکرومتر برای ایجاد منحنی‌های رگرسیونی چندگانه در برآورد بارش استفاده کردند. با استفاده از داده‌های کانال‌های فرورسرخ حرارتی MSG-SEVIRI، (Giannakos and Feidas (2013) یک الگوریتم براساس احتمال بارش همرفتی (PCR) و یک مدل پرسپترون چندلایه‌ای (MLP) شبکه عصبی مصنوعی را برای توسعه تکنیک‌هایی که قادر به طبقه‌بندی مناطقی با باران همرفتی و پوششی در تصاویر ماهواره‌ای باشد، توسعه دادند. مقایسه دو طرح‌واره نشان داد روش‌های MLP عملکرد بهتری نسبت به روش‌های PCR دارند. اخیراً (Cancelada et al. (2020) با استفاده از دمای روشنایی بدست آمده از تصویرساز مابکروویو و رادار بارش TRMM^۱ و همچنین کانال‌های فرورسرخ حرارتی GOES^۲ و داده‌های رادار زمینی هواشناسی، تکنیکی را طراحی کردند که با تعیین آستانه دمای روشنایی، مناطق شروع همرفت‌های شدید را تعیین نماید.

با استفاده از داده‌های MSG SEVIRI، (Meyer et al. (2016) چهار الگوریتم یادگیری ماشینی (جنگل‌های تصادفی (RF)، شبکه‌های

گردید. سپس داده‌های بارش مشاهداتی و همچنین داده‌های ماهواره‌ای مربوطه اخذ و از آنجاییکه داده‌های ماهواره‌ای به صورت بازتابندگی هستند، تبدیل به دمای روشنایی گردیدند. سپس همبستگی بین داده‌های بارش مشاهداتی و دمای روشنایی بررسی شد. با استفاده از این دو مجموعه داده، یک مدل رگرسیونی و یک مدل شبکه عصبی طراحی گردید و خروجی‌های مدل‌ها با روش‌های مختلف اعتبارسنجی، مورد ارزیابی قرار گرفتند. این مراحل به تفصیل در زیر آمده است:

۱-۲- بازه زمانی و مکانی

به دلیل طبیعت غیرخطی بارش، تکنیک‌های بازتابی آن به راحتی قابل تعمیم از محلی به محل دیگر نیستند (Giannakos and Feidas, 2013)، لذا به نظر می‌رسد تنها روش‌های مبتنی بر تکنیک‌های غیرخطی ممکن است برای مکان‌هایی با شرایط تقریباً مشابه قابلیت تعمیم را داشته باشند. برای بررسی این موضوع، منطقه‌ای در جنوب ایران که دارای شرایط آب‌وهوایی خاصی است، برای آموزش و طراحی مدل در نظر گرفته شده است.

طی دو سال گذشته، شهرهای میناب و رودان در استان هرمزگان واقع در جنوب کشور شاهد چندین مورد بارش حدی بوده‌اند. از آنجایی که سدهای مهم هرمزگان (استقلال، جگین) در نزدیکی این دو شهر واقع شده‌اند، برآورد بارش در این منطقه بسیار حائز اهمیت است. موقعیت جغرافیایی ایستگاه‌های هواشناسی این دو شهر در استان هرمزگان در شکل ۱ داده شده است:

زمینی کافی نباشد، می‌توان از اطلاعات ماهواره‌ای به عنوان بخشی از سیستم هشدار سیل استفاده کرد تا پیامدهای یک فاجعه سیل را به حداقل رساند. در ایران نیز Babaei et al. (2019) از داده‌های ماهواره Landsat8 به منظور محاسبه منطقه کلی دریاچه ارومیه و تعیین مرز دقیق بین آب، زمین و نمک حول دریاچه استفاده کردند. Parisooj et al. (2018) با ارزیابی دو محصول بارش ماهواره‌ای TRMM و PERSIANN به توسعه مدل بارش-رواناب پرداختند و دریافتند مدل HEC-HMS برای شبیه‌سازی رواناب پیوسته در حوضه‌های پیچیده مناسب است. Shayeghi et al. (2018) با هدف ارزیابی کارایی پایگاه‌های بارشی باز تحلیل شده ECMWF و PERSIAN جهت مدل‌سازی هیدرولوژیکی با استفاده از مدل بزرگ مقیاس VIC-3L در حوضه آبریز سفیدرود پرداخته شده است.

با توجه به نیاز به اطلاعات در مورد میزان بارش، با قدرت تفکیک زمانی و مکانی مناسب در جنوب ایران، در این مطالعه از دمای روشنایی کانال‌های فرسرخ سنجنده تصویربردار چرخان پیشرفته مرئی و فرسرخ (SEVIRI) از نسل دوم ماهواره‌های متئوست (MSG) با بکارگیری روش‌های رگرسیونی و شبکه عصبی به منظور بازتابی میزان بارش استفاده شده است. قدرت تفکیک مکانی ۳*۳ کیلومتری و فاصله زمانی نیم ساعته در برآورد بارش از جنبه‌های نوآوری این تحقیق می‌باشد.

۲- روش تحقیق

به منظور انجام این مطالعه، ابتدا بازه زمانی و مکانی تحقیق مشخص

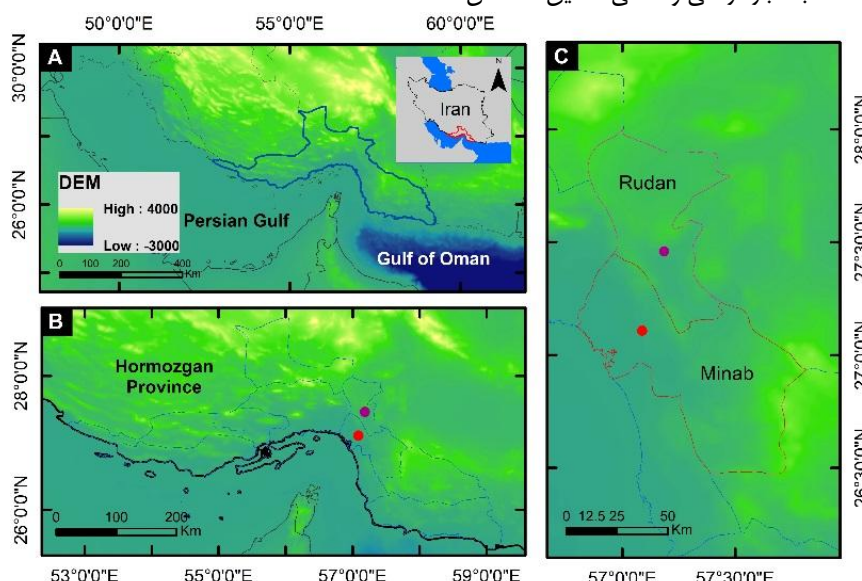


Fig. 1- Study area and meteorological stations, along with DEM data taken from srtn30+

شکل ۱- منطقه مورد مطالعه و ایستگاه‌های هواشناسی، همراه با اطلاعات رقومی ارتفاع بر گرفته از داده‌های srtn30+

میانگین بلندمدت بارش در شهر میناب ۱۹۶/۴ میلیمتر و در شهر رودان ۲۲۲/۹ میلیمتر می‌باشد. این درحالی است که فقط طی ماه‌های دی و بهمن سال ۹۸ در شهر میناب به میزان ۲۱۳/۹ میلیمتر و در شهر رودان به میزان ۳۷۰/۸ میلیمتر باران باریده است. به همین دلیل این دو شهر به‌عنوان مطالعات موردی انتخاب شده‌اند. برای این منظور در مجموع ۴۱ مورد رویداد بارشی (روز) در طی زمستان سال ۹۷ و ۹۸ و همچنین بهار ۹۸ و ۹۹ برای مطالعه انتخاب شدند.

۲-۲- داده‌های مشاهداتی ایستگاهی

داده‌های مورد استفاده در این مطالعه شامل: داده‌های بارشی زمین مینا (ایستگاه‌های خودکار هواشناسی) و مشاهدات ماهواره‌ای (سنجنده SEVIRI) می‌باشند. داده‌های بارش زمین مینا از ایستگاه‌های هواشناسی خودکار (شهرهای رودان و میناب) که بارش باران را در بازه‌های زمانی ۱۰ دقیقه‌ای و بر حسب میلیمتر گزارش می‌کنند، تهیه شده‌اند. به منظور تطبیق داده‌های باران‌سنجی با داده‌های ماهواره‌ای (که بازه زمانی ۱۵ دقیقه‌ای دارند)، داده‌های باران‌سنجی هر نیم ساعت جمع شده‌اند. به دلیل عدم هم‌زمانی داده‌های باران‌سنجی (که در بازه زمانی ۱۰ دقیقه گزارش می‌شوند) و مشاهدات ماهواره‌ای (که در بازه‌های زمانی ۱۵ دقیقه ثبت می‌شوند)، داده‌های باران‌سنجی در بازه‌های زمانی ۳۰ دقیقه جمع و مشاهدات ماهواره‌ای در بازه‌های زمانی ۳۰ دقیقه میانگین‌گیری شده‌اند. این مجموعه داده برای آموزش و آزمون مدل‌ها بکار رفته است.

۲-۳- داده‌های ماهواره‌ای

در حقیقت اندازه‌گیری مستقیم هر متغیری، به‌خصوص بارش، از داده‌های فروسرخ ماهواره‌ای امکان‌پذیر نیست؛ اولاً آنچه که ابزارهای ماهواره‌ای اندازه می‌گیرند، تابش الکترومغناطیسی گسیل شده یا بازتابیده شده از سطح جسم (ابر) است. ثانیاً باید میزان تابش گسیلی یا بازتابی از سطح ابر را به بارشی که در زیر آن فرو می‌ریزد مربوط کرد. یعنی همه چیز باید به‌طور غیرمستقیم از الگوریتم‌هایی که برخی ساده و برخی پیچیده هستند، استنباط شود (Strangeways, 2007). در این مطالعه از داده‌های سطح ۱/۵ از تصویربردار چرخان پیشرفته

مرئی و فروسرخ (SEVIRI) از نسل دوم ماهواره‌های متئوست (MSG) استفاده شده است. داده‌های این سطح از نظر جغرافیایی موقعیت‌یابی شده و پیش‌پردازش رادیومتری نیز بر روی آنها انجام شده است و داده‌ها به صورت بازتابندگی هستند. ابزار سنجنش SEVIRI تابش الکترومغناطیسی را در ۱۲ کانال (باند طیفی) اندازه می‌گیرد که سه کانال آن در ناحیه طول موج‌های مرئی و فروسرخ نزدیک، هشت کانال در محدوده طول موج‌های فروسرخ میانه تا فروسرخ حرارتی و یک کانال با وضوح بالا البته فقط در ناحیه مرئی قرار دارند. به دلیل اینکه کانال‌های مرئی فقط در طول روز قادر به تهیه داده هستند و در این مطالعه بازتابی بارش برای طول شبانه‌روز مورد نیاز است بنابراین، فقط داده‌های تابندگی هشت کانال فروسرخ با قدرت تفکیک مکانی ۳*۳ کیلومتر در Nadir (نقطه زیرین ماهواره) برای بازتابی بارش انتخاب شده‌اند. سپس، داده‌های خام با استفاده از تابع پلانک به دمای روشنایی (بر حسب کلونین) تبدیل شده‌اند. گستره طیفی تقریبی این هشت کانال در جدول ۱ داده شده است. قدرت تفکیک زمانی این سنجنده ۱۵ دقیقه می‌باشد که برای تطبیق با داده‌های ایستگاهی، بین دو دمای اندازه‌گیری شده در ۳۰ دقیقه، میانگین‌گیری شده است.

۲-۳-۱- پیش‌پردازش داده‌های ماهواره‌ای/تبدیل بازتابندگی به دمای روشنایی

داده‌های بارش ماهواره‌ای نیز از مشاهدات سنجنده SEVIRI بر روی نسل دوم ماهواره‌های متئوست بازتابی شده‌اند. به منظور بازتابی بارش از این سنجنده، داده‌های فروسرخ سطح ۱/۵ آن که به صورت مقادیر باینری یا count و با فرمت nc هستند، مورد استفاده قرار گرفتند. آنچه که باید درباره داده‌های ماهواره‌ای مورد توجه قرار گیرد، مقدار تابندگی است. با استفاده از رابطه زیر می‌توان مقادیر بدست آمده از ماهواره را به تابندگی تبدیل کرد:

$$R = CAL_{offset} + CAL_{slope} * count \quad (1)$$

که در آن R تابندگی طیفی و CAL-slope و CALoffset مقادیر ثابت هستند و واحد همه آنها $(cm^{-1})^{-1} mWm^{-2} sr^{-1}$ می‌باشد، و count نیز مقدار رقومی هر پیکسل (بین صفر و ۱۰۲۳) می‌باشد.

Table 1- Approximately range of channels used in this study

جدول ۱- محدوده تقریبی کانال‌های مورد استفاده در این مطالعه

Channel	Approximately range	Channel	Approximately range		
4	IR3.9	3.48 - 4.36 μm	8	IR9.7	9.38 - 9.94 μm
5	WV6.2	5.35 - 7.15 μm	9	IR10.8	9.80 - 11.80 μm
6	WV7.3	6.85 - 7.85 μm	10	IR12.0	11.00 - 13.00 μm
7	IR8.7	8.30 - 9.10 μm	11	IR13.4	12.40 - 14.40 μm

در کانال‌های فرسوخ مقادیر تابندگی باید به دمای روشنایی تبدیل گردد. این کار با استفاده از رابطه زیر (معادله پلانک) امکان پذیر است:

$$T_b = [C_2 v_c / \log \left(\frac{C_1 v_c^3}{R} + 1 \right) - B] / A \quad (2)$$

که در آن T_b دمای روشنایی معادل، R تابندگی، C_1 و C_2 ثابت‌های تابشی بوده که واحدهای آنها به ترتیب $(\text{cm}^{-1})^{-4} \text{mWm}^{-2} \text{sr}^{-1}$ و $(\text{cm}^{-1})^{-1}$ می‌باشد و v_c طول موج مرکزی هر کانال، و A و B ضرایب ثابت برای هر کانال هستند. این ثابت‌ها در www.eumetsat.int قابل دسترس هستند.

به منظور استخراج داده‌های سطح ۱/۵ سنجنده SEVIRI و تبدیل آنها به دمای روشنایی برنامه‌ای در محیط NCL نوشته شده است.

۴-۲- روش‌های آماری و رگرسیونی

در این مطالعه نحوه تغییرات دمای روشنایی و میزان بارش با استفاده از ضریب همبستگی مورد بررسی قرار گرفته است. به منظور تعیین ارتباط بین دمای روشنایی و میزان بارش از مدل‌های مختلف رگرسیونی از جمله رگرسیون خطی، درخت رگرسیونی، ماشین بردار پشتیبان و مدل رگرسیون فرآیند گاوسی نیز استفاده شده است. دماهای روشنایی هشت کانال به‌عنوان متغیرهای مستقل و بارش به‌عنوان متغیر وابسته در نظر گرفته شده‌اند. به منظور کاهش ابعاد ورودی‌های مدل‌های رگرسیونی، از روش تحلیل مؤلفه‌های اصلی (PCA) نیز استفاده شده است. جهت بررسی میزان همبستگی این دو مجموعه داده (بارش ایستگاهی و دمای روشنایی کانال فرسوخ ماهواره‌ای) و یافتن ارتباط بین آنها و همچنین انجام محاسبات آماری مربوط به بخش اعتبارسنجی، از محیط نرم‌افزار متلب (MATLAB) استفاده شده است.

۵-۲- شبکه عصبی مصنوعی

به طور کلی، شبکه‌های عصبی به دو نوع شبکه عصبی پیش‌خور (feedforward) و پس‌خور یا بازگشتی (Feedback or recurrent) تقسیم می‌شوند. یک شبکه عصبی پیش‌خور (FFNN) شبکه عصبی مصنوعی است که در آن اتصالات بین گره‌ها یک چرخه را تشکیل نمی‌دهند. در این شبکه، اطلاعات فقط در یک جهت (به جلو) منتقل می‌شوند، یعنی از گره‌های ورودی آغاز شده، پس از عبور از گره‌های پنهان (در صورت وجود)، به گره‌های خروجی می‌رسد. هیچ چرخه یا حلقه‌ای در شبکه وجود ندارد (Zell, 1994). شبکه عصبی پیش‌خور به سه دسته تقسیم می‌شود: ۱) پرسپترون تک لایه که ساده‌ترین نوع شبکه عصبی است و در آن ورودی‌ها از طریق یک سری وزن‌ها

مستقیماً به خروجی‌ها می‌رسند. ۲) پرسپترون چند لایه (MLP) نوع دیگر FFNN است. علاوه بر لایه‌های ورودی و خروجی، MLP دارای لایه‌های پنهان نیز هست که وظیفه برقراری ارتباط بین لایه‌های ورودی و خروجی را دارند. با استفاده از این لایه‌های پنهان، شبکه می‌تواند روابط غیرخطی را از داده‌های ارائه شده به آن استخراج کند. ۳) شبکه‌های عصبی تابع پایه شعاعی (RBF) مانند MLP از سه لایه ورودی، پنهان و خروجی تشکیل شده‌اند، اما تنها یک لایه پنهان در شبکه وجود دارد. در اینجا از پرسپترون چند لایه برای تقریب توابع و بهینه‌سازی مدل برآورد بارش استفاده شده است.

۶-۲- روش‌های اعتبارسنجی

جهت ارزیابی عملکرد مدل‌ها و شبکه عصبی، از شاخص‌های آماری مختلف، از جمله میانگین خطای مطلق (MAE)، جذر میانگین مربعات خطا (RMSE)، اریبی چندگانه (Multiplicative Bias)، ضریب همبستگی (Correlation) و ضریب تعیین (Coefficient of Determination) استفاده شده است که روابط آنها با استفاده از کتاب روش‌های آماری در علوم جو (Wilks, 2011) به ترتیب در زیر آمده است:

$$MAE = \frac{1}{N} \sum_{i=1}^N |E_i - O_i| \quad (3)$$

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (E_i - O_i)^2 \right]^{1/2} \quad (4)$$

$$\text{Multiplicative Bias} = \frac{\bar{E}}{\bar{O}} = \frac{\frac{1}{N} \sum_{i=1}^N (E_i)}{\frac{1}{N} \sum_{i=1}^N (O_i)} \quad (5)$$

$$R = \frac{\sum_{i=1}^N (E_i - \bar{E})(O_i - \bar{O})}{\left[\sum_{i=1}^N (E_i - \bar{E})^2 \right]^{1/2} \left[\sum_{i=1}^N (O_i - \bar{O})^2 \right]^{1/2}} \quad (6)$$

که در آن E_i مقدار برآورد شده متغیر مورد نظر و O_i مقدار مشاهده شده متناظر با آن است و کمیت N تعداد داده‌ها را نشان می‌دهد. شاخص R به داده‌های نامتعارف حساس است. ضریب تعیین نیز یکی از شاخص‌های برازش مدل است که قدرت برآورد متغیر پیش‌بینی‌شونده را براساس متغیرهای پیش‌بینی‌کننده نشان می‌دهد. مقدار این شاخص بین صفر تا یک می‌باشد و اگر از ۰/۶ بیشتر باشد نشان می‌دهد متغیرهای پیش‌بینی‌کننده (مستقل) تا حد زیادی توانسته‌اند تغییرات متغیر پیش‌بینی‌شونده (وابسته) را تبیین کنند. ضریب تعیین در معادلات رگرسیونی با علامت R^2 نشان داده می‌شود.

از آنجایی که اعتبارسنجی فرایندی است که از طریق مقایسه نتایج آن با مشاهدات متناظر، میزان دقت، کیفیت و مهارت یک برآورد را تعیین می‌کند، برای انجام آن به تابع احتمال مشترک برآورد-دیدبانی نیاز است. یکی از ساده‌ترین راه‌ها برای اعتبارسنجی برآوردها تشکیل جدول توافقی دوحالتی (2×2) می‌باشد. با فرض اینکه برآورد و

دیدبانی به ترتیب با E و O نشان داده شوند، جدول توافقی به صورت جدول ۲ تشکیل می‌شود:

Table 2- Contingency table

	O ₁	O ₂
E ₁	a	b
E ₂	c	d

که متغیرهای آن به ترتیب عبارتند از: O₁ تعداد دفعات وقوع پدیده، O₂ تعداد دفعات عدم وقوع پدیده، E₁ تعداد دفعات برآورد پدیده، E₂ تعداد دفعاتی که پدیده برآورد نشده، a تعداد دفعاتی که پدیده اتفاق افتاده و وقوع آن برآورد شده باشد، b تعداد دفعاتی که پدیده اتفاق نیفتاده ولی وقوع آن برآورد شده باشد، c تعداد دفعاتی که پدیده اتفاق نیفتاده ولی وقوع آن نیز برآورد نشده باشد. بدیهی است که برای یک برآورد خوب باید مقادیر a و d بزرگ و b و c کوچک (صفر) باشند.

برای سنجش عملکرد برآوردها با استفاده از این جدول، کمیت‌های نرده‌ای متعددی بکار می‌روند. این کمیت‌ها شامل احتمال آشکارسازی (POD) و امتیاز مهارتی هایدکه (HSS) می‌شود که:

$$H = POD = \frac{a}{a+c} \quad (7)$$

$$HSS = \frac{2(ad-bc)}{(a+c)(c+d)+(a+b)(b+d)} \quad (8)$$

احتمال آشکارسازی نسبت تعداد برآوردهای درست وقوع پدیده به تعداد کل دیدبانی‌های پدیده مورد نظر را نشان می‌دهد. در بهترین حالت

یک و در بدترین حالت صفر خواهد بود. امتیاز مهارتی هایدکه از منهای بی‌نهایت تا یک تغییر می‌کند. مقدارهای صفر و یک به ترتیب نشان دهنده برآورد بدون مهارت و برآورد کامل هستند.

۳- بحث و تحلیل نتایج

۳-۱- تغییرات دمای روشنایی و میزان بارش

فرضیه اولیه در انجام این تحقیق، بر پایه همبستگی میان تغییرات دمای روشنایی کانال‌های فرسوخ ماهواره‌ای و بارش مشاهداتی ایستگاهی بنا شده است. از این رو ابتدا تغییرات این دو کمیت برای رویداد بارشی سه روزه (۹ تا ۱۱ ژانویه ۲۰۲۰) در شهرهای میناب و رودان به تفکیک بررسی گردید که نمودار آن‌ها در شکل ۲ نشان داده شده است.

همانطور که در شکل ۲ نشان داده شده است به هنگام بارش، دماهای روشنایی کاهش محسوسی دارند که با خواص فیزیکی ابر نیز مطابقت دارد. همبستگی بارش و دمای روشنایی از نظر کمی نیز برای این سه روز در جدول ۳ ارائه شده است. نتایج رابطه معکوس بین بارش و دمای روشنایی (همبستگی منفی) را برای هر دو ایستگاه نشان می‌دهد، یعنی با کاهش دمای روشنایی، مقدار بارش افزایش می‌یابد.

پس از تایید فرضیه اولیه مبنی بر ارتباط بین بارش و دمای روشنایی، و بررسی همبستگی بین آن‌ها، داده‌های مربوط به ۴۱ روز بارشی برای این دو ایستگاه هواشناسی جمع‌آوری گردید.

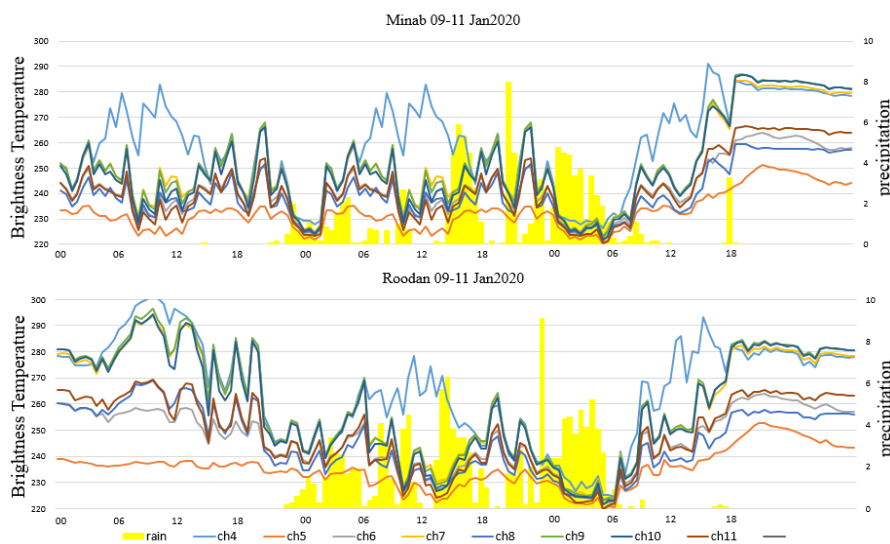


Fig. 2- Precipitation (mm) and brightness temperature (K) time series in various channels

شکل ۲- سری زمانی بارش (میلیمتر) و دمای روشنایی (کلوین) در کانال‌های مختلف

Table 3- Correlation between precipitation and brightness temperature

جدول ۳- ضریب همبستگی بین بارش و دمای روشنایی

Channel	IR3.9	WV6.2	WV7.3	IR8.7	IR9.7	IR10.8	IR12	IR13.4
Correlation coefficient (3days)	-0.487	-0.423	-0.482	-0.484	-0.481	-0.479	-0.472	-0.473
Correlation coefficient (41days)	-0.356	-0.264	-0.375	-0.384	-0.384	-0.381	-0.376	-0.381
R ² (3days)	0.237	0.179	0.232	0.234	0.231	0.230	0.222	0.224
R ² (41days)	0.127	0.070	0.141	0.147	0.147	0.145	0.141	0.145

روزه اندکی کاهش یافته که می‌تواند ناشی از تنوع رویدادهای بارشی- غیربارشی و فراوانی داده‌ها باشد. هدف از انجام این مطالعه، تولید یک محصول از دمای روشنایی است که با داده‌های بارش ایستگاهی همبستگی بهتری داشته باشد. برای این منظور از مدل‌های رگرسیونی و شبکه عصبی استفاده شده است که این الگو ۳۸۰۲ در اجرا و اعتبارسنجی آنها بکار گرفته شده‌اند. نمودار توزیع پراکندگی بارش و دمای روشنایی هر یک از کانال‌های فروسرخ و همچنین خط روند آنها در شکل ۳ نشان داده شده است.

در مجموع، این بازه ۴۱ روزه تعداد ۳۸۰۲ نقطه-زمان (یا الگو) را شامل می‌شود. ضریب همبستگی کلی بین بارش و دمای روشنایی هشت کانال فروسرخ مورد استفاده در بازه ۴۱ روزه (۳۸۰۲ الگو) نیز در جدول ۳ داده شده است. همچنین مقدار p-value آزمون همبستگی محاسبه گردیده است. در تمامی موارد مقدار p-value تا ۳ رقم اعشار صفر می‌باشد و با توجه به اینکه کمتر از مقدار ۰/۰۱ می‌باشد، همبستگی با بازه اطمینان ۰/۹۹ درصد قابل قبول است. همانطور که در جدول مشخص است ضریب همبستگی در بازه ۴۱ روزه نسبت به بازه ۳

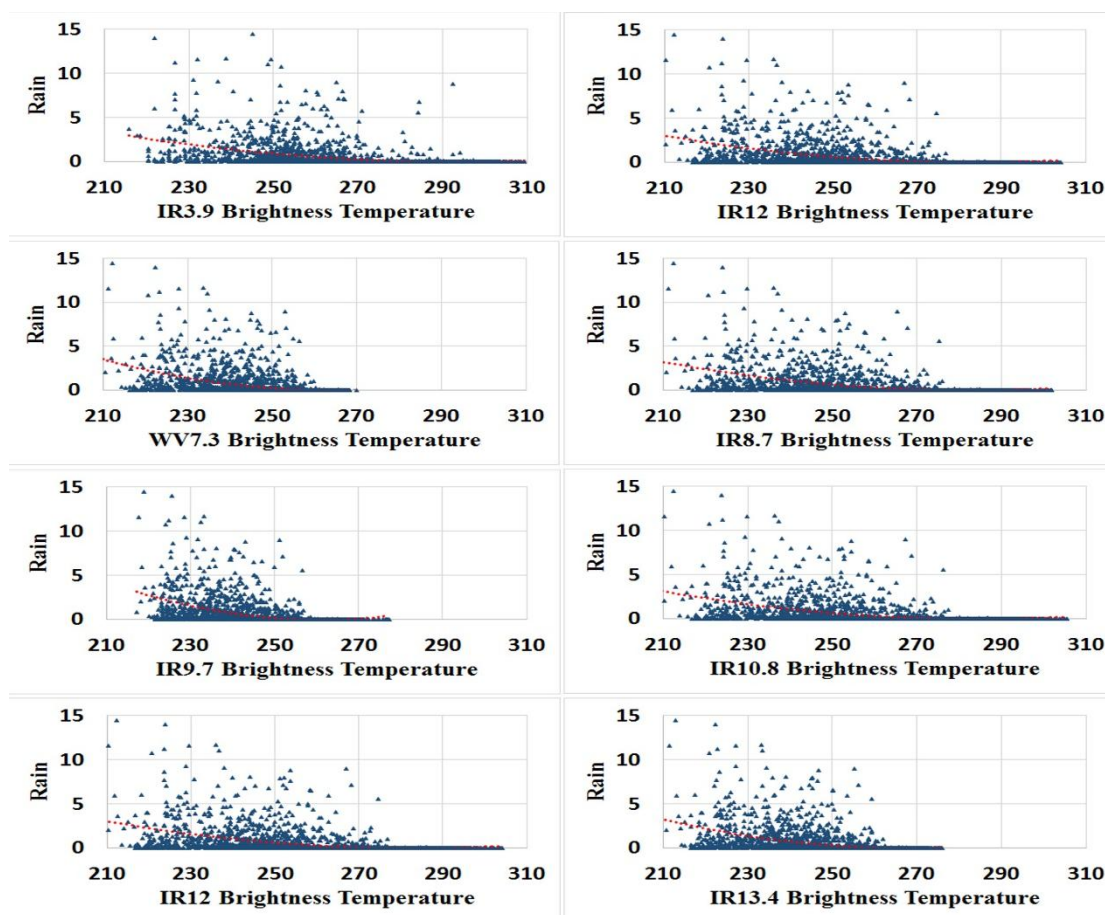


Fig. 3- Precipitation and brightness temperature scatter plots and their trendlines

شکل ۳- نمودار پراکندگی بارش با دمای روشنایی کانال‌های فروسرخ و همچنین خط روند آنها

این فراوانی به سمت دماهای پایین تر میل می‌کند. البته در برخی کانال‌ها مانند ۵ و ۶ که کانال‌های بخار آب هستند، دما در شرایط بارشی و غیر بارشی همپوشانی زیادی دارد. کانال ۵ (WV6.2) نشان‌دهنده رطوبت سطوح بالا (۶۰۰ تا ۳۰۰ هکتوپاسکالی) و کانال ۶ (WV7.3) نشان‌دهنده رطوبت سطوح میانی (۸۵۰ تا ۶۰۰ هکتوپاسکالی - همرفت اولیه) می‌باشد. بنابراین با وجود اینکه این کانال‌ها بسیار مهم بوده و رطوبت در ترازهای بالای جو را نشان می‌دهند، به تنهایی نمی‌توانند برای تفکیک شرایط بارشی و غیربارشی بکار روند و باید در کنار کانال‌های دیگر مورد استفاده قرار گیرند. البته در شرایطی که رطوبت کافی موجود نباشد و یا در آسمان ابری وجود نداشته باشد، این تفاوت در دمای روشنایی به وضوح دیده می‌شود. در این مطالعه، بیشتر رویدادهای قبل، حین و بعد از بارش در نظر گرفته شده است. بنابراین در بیشتر موارد آسمان ابری یا نیمه ابری بوده و به همین دلیل، نزدیکی دماها در شرایط بارشی و غیر بارشی در کانال‌های بخار آب غیر منطقی نیست. این کانال‌های نشان‌دهنده حرکات عمودی جو نیز می‌باشند.

بررسی این نمودارها نیز رابطه معکوس بین این دو کمیت را برای تمامی کانال‌ها به وضوح نشان می‌دهد، بدین معنا که با افزایش دمای روشنایی، میزان بارش کاهش می‌یابد و برعکس. هر چه دمای روشنایی کمتر باشد، نشان‌دهنده قله ابر سردتر و در نتیجه ارتفاع قله ابر بیشتر می‌باشد. بنابراین، احتمال بارش نیز در آن بیشتر خواهد بود. این واقعیت بویژه در نمودارهای پراکندگی کانال‌های IR9.7, IR8.7, IR10.8, IR12, IR13.4 و IR13.4 مشهودتر است.

۳-۲- تفکیک شرایط بارشی و غیر بارشی

از ۳۸۰۲ نقطه - زمان بررسی شده در این مطالعه، ۸۵۷ مورد مربوط به شرایط بارشی (بارش بیش از ۰/۱ میلی‌متر در طی نیم ساعت) و ۲۹۴۵ مورد مربوط به شرایط غیربارشی می‌باشند. برای نشان دادن تفاوت میزان دمای روشنایی در شرایط بارشی و غیر بارشی، هیستوگرام آنها در شکل ۴ نمایش داده شده است.

همانطور که در شکل ۴ دیده می‌شود، برای کلیه کانال‌ها در شرایط غیر بارشی، فراوانی داده‌ها به سمت دمای بالاتر و در شرایط بارشی،

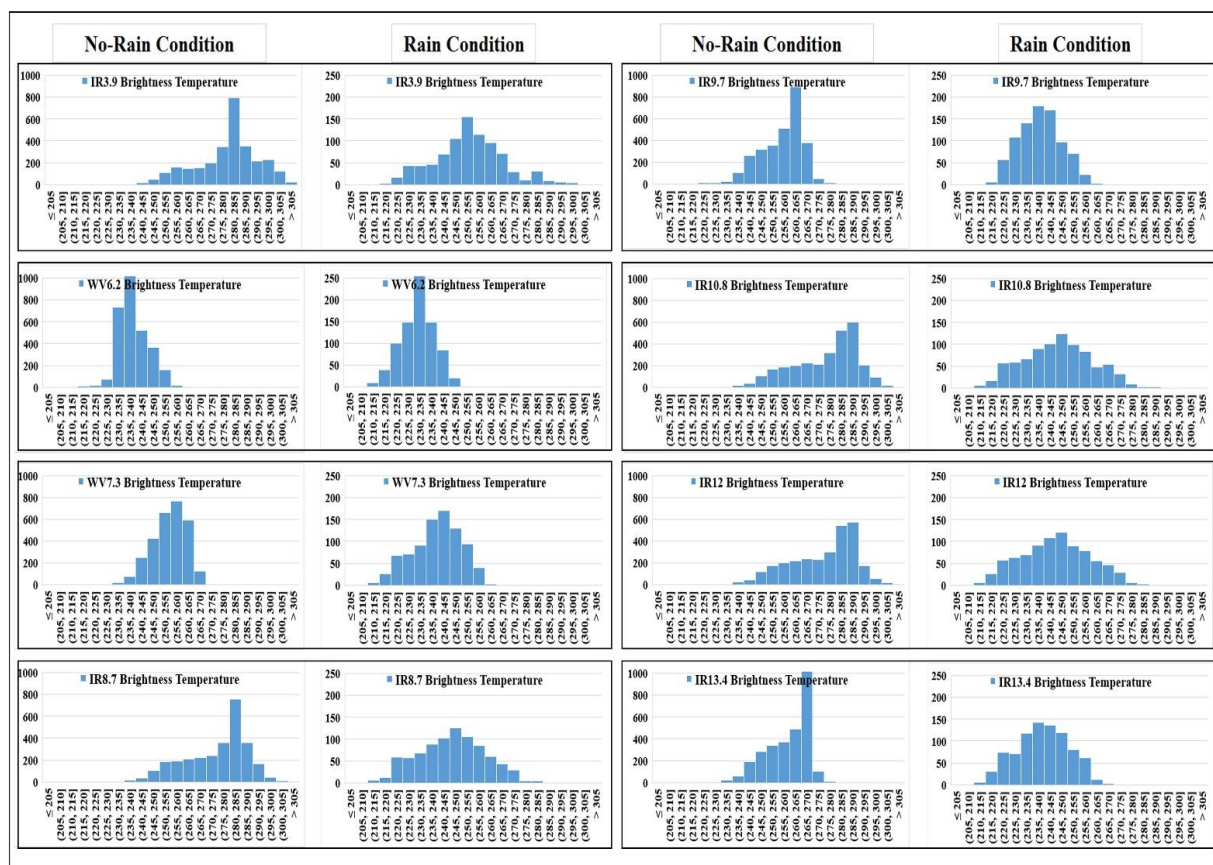


Fig. 4- Brightness temperature histogram in rain and no-rain conditions

شکل ۴- هیستوگرام دمای روشنایی در شرایط بارشی و غیربارشی

کانال ۴ (IR3.9) به اندازه و فاز قطرات بسیار حساس است و ساختار قله ابر را بخوبی نشان می‌دهد. در این کانال، هر چه دما کمتر باشد، نشان‌دهنده ابر یخی با ذرات بزرگتر است. کانال‌های ۷ تا ۱۱ (IR8.7, IR10.8, IR9.7, IR13.4) که تقریباً کانال‌های پنجره جوی می‌باشند، دمای قله ابر، ناپایداری جوی و در صورت کم بودن یا فقدان ابرناکی، دمای سطح را بخوبی نشان می‌دهند. هر چه دمای روشنایی در این کانال‌ها کمتر باشد، بیانگر قله بالاتر ابر است. در این میان کانال ۹ (IR9.7) گسترش عمودی ابر را بهتر نشان می‌دهد.

۳-۳- مدل‌های رگرسیونی

در مدل‌سازی‌های آماری از رگرسیون برای تخمین ارتباط بین متغیرها استفاده می‌شود. در این مطالعه دماهای روشنایی هشت کانال به‌عنوان متغیرهای مستقل و بارش به‌عنوان متغیر وابسته در نظر گرفته شده‌اند و در مدل‌های مختلف رگرسیونی با استفاده از نرم‌افزار متلب، اعمال گردیده‌اند. مدل‌های مختلف مورد بررسی عبارتند از رگرسیون خطی، درخت رگرسیونی، ماشین بردار پشتیبان و مدل رگرسیون فرآیند گاوسی که هر یک نیز زیر مجموعه‌هایی دارند. عملکرد مدل‌های رگرسیونی بدون PCA و با PCA به‌طور جداگانه مورد ارزیابی قرار گرفتند و شاخص‌های آماری مختلف برای این مدل‌ها محاسبه گردید. با مشاهده نتایج حاصل از اعتبارسنجی مدل‌های رگرسیونی مختلف، اعمال شده بر روی ۳۸۰۲ الگو، بهترین نتیجه حاصل از آنها با ذکر مدل رگرسیونی بهینه و شاخص‌های آماری آن در جدول ۴ آورده شده است.

همانطور که در جدول ۴ نیز مشخص است شاخص‌های میزان خطا در مدل گاوسی‌نمایی بدون PCA کوچکتر هستند. اما، شاخص‌های مرتبط با همبستگی نشان‌دهنده نتیجه بهتر در مدل با اعمال PCA می‌باشد. از آنجایی که در برآورد میزان بارش، کمترین میزان خطا

اهمیت بیشتری دارد بنابراین از میان این دو حالت، مدل رگرسیونی نمایی بدون PCA انتخاب گردیده و برای بررسی بیشتر، عملکرد این مدل با استفاده از جدول توافقی مورد ارزیابی قرار گرفت. در جدول توافقی، اگر آستانه بارش و عدم وقوع بارش از ۰/۱ میلیمتر در نظر گرفته شود، a تعداد پدیده‌هایی که بارش بیش از ۰/۱ میلیمتر داشته و برآورد نیز شده‌اند را نشان می‌دهد، b تعداد دفعاتی که بارش کمتر از ۰/۱ میلیمتر بوده ولی بیشتر از آن برآورد شده است، c تعداد دفعاتی که بارش بیشتر از ۰/۱ میلیمتر بوده ولی کمتر از آن برآورد شده است و d تعداد دفعاتی که بارش کمتر از ۰/۱ میلیمتر بوده و کمتر از آن نیز برآورد شده است. مرز سایر دسته‌بندی‌های بارش با T نشان داده شده است. احتمال آشکارسازی و امتیاز مهارتی هایدکه نیز بترتیب با POD و HSS نشان داده شده‌اند. همانطور که در جدول توافقی مشخص است برای آستانه ۰/۱ میلیمتری مدل بهترین عملکرد را نشان می‌دهد. تعداد رخداد‌های بارشی بیش از ۵ و ۱۰ میلیمتر چندان زیاد نیستند، مدل هم در برآورد آنها توانایی زیادی را نشان نمی‌دهد. البته، این عدم توانایی نیز از همان تعداد کم رخدادها و الگوها در فرآیند ایجاد مدل رگرسیونی ناشی شده است. از این رو، بارش‌های بیش از ۱۰ میلیمتر حذف گردید و مدل مجدداً برای ۳۷۹۱ الگو اجرا گردید. بهترین نتیجه حاصل از مدل‌ها در دو شرایط، با PCA و بدون آن، با ذکر مدل رگرسیونی بهینه و شاخص‌های آماری در جدول ۵ آمده است.

با این مجموعه داده، مدل گاوسی‌نمایی با PCA هم از نظر شاخص‌های میزان خطا و هم از نظر شاخص‌های مرتبط با همبستگی، به نتیجه بهتری می‌انجامد. بنابراین برای بررسی جزئیات بیشتر جدول توافقی این مدل برای سه آستانه بارشی تشکیل گردید. هرچند شاخص‌های POD و HSS بهبود چندانی پیدا نکردند، اما MAE و RMSE نسبتاً کاهش یافته است.

Table 4- Evaluation of two better models (for 3802 patterns)

جدول ۴- اعتبارسنجی دو مدل برتر (برای ۳۸۰۲ الگو)

Regression Model		PCA	MAE (mm)	RMSE (mm)	MBias	R	R ²
Exponential Gaussian Without PCA			0.22	0.64	1.000086	0.89	0.79
Exponential Gaussian With PCA			0.28	0.77	0.999975	0.82	0.67
Contingency Table for Exponential Gaussian Model Without PCA	T	a	b	c	d	POD	HSS
	0.1	815	478	42	2467	0.95	0.66
	1	275	132	67	3328	0.80	0.70
	5	13	3	37	3749	0.26	0.39
	10	3	0	8	3791	0.27	0.43

Table 5- Evaluation of two better models (for 3791 patterns- precipitation less than 10mm)

جدول ۵- اعتبارسنجی دو مدل برتر (برای ۳۷۹۱ الگو- بارش کمتر از ۱۰ میلیمتر)

Regression Model		PCA	MAE (mm)	RMSE (mm)	MBias	R	R ²
Rational Quadratic Gaussian		Without PCA	0.31	0.79	0.999818	0.55	0.30
Exponential Gaussian		With PCA	0.17	0.44	0.99937	0.91	0.84
Contingency Table for Exponential Gaussian Model With PCA	T	a	b	c	d	POD	HSS
	0.1	811	478	35	2467	0.96	0.67
	1	266	74	65	3386	0.80	0.77
	5	4	0	35	3752	0.10	0.18

مدل برای بارش‌های کمتر از ۵ یا ۱۰ میلیمتر تفاوت چندانی ندارد لذا به منظور بکارگیری محدوده وسیع‌تری از داده‌های بارش، مدل رگرسیون‌نمایی با PCA برای بارش‌های کمتر از ۱۰ میلیمتر به عنوان مدل منتخب مدل‌های رگرسیونی برگزیده شد. نتایج حاصل از این مدل در نمودار پراکندگی در شکل ۵ داده شده است.




Fig. 5- Scatter plot of exponential regression model with PCA for precipitation less than 10mm

شکل ۵- نمودار پراکندگی مدل رگرسیون‌نمایی با تحلیل مؤلفه اصلی برای بارش کمتر از ۱۰ میلیمتر

مجدداً همین کار با حذف بارش‌های بیش از ۵ میلیمتر و برای ۳۷۵۴ الگو انجام گرفت. نتایج در جدول ۶ آمده است.

در جدول‌های ۴، ۵ و ۶ شاخص‌های آماری مختلفی برای هر سه مجموعه داده بارش محاسبه گردید. این شاخص‌ها به تنهایی برای تشخیص عملکرد یک مدل کافی نیستند و باید در کنار یکدیگر برای ارزیابی مدل مورد استفاده قرار گیرند. در کلیه مدل‌ها ارزیابی چندگانه نزدیک به یک می‌باشد. از نظر شاخص‌های میانگین خطا، مدل رگرسیون‌نمایی با PCA برای بارش‌های کمتر از ۵ میلیمتر با جذر میانگین مربعات خطای ۰/۳۸ و میانگین خطای مطلق ۰/۱۷ بهترین عملکرد را دارد. از نظر شاخص‌های همبستگی، مدل رگرسیون‌نمایی با PCA برای بارش‌های کمتر از ۱۰ میلیمتر با ضریب همبستگی ۰/۹۱ و ضریب تعیین ۰/۸۴ دارای عملکرد بهتری می‌باشد. بررسی جدول توافقی برای این سه مدل نیز عملکرد مناسب‌تر مدل رگرسیون‌نمایی با PCA برای بارش‌های کمتر از ۱۰ میلیمتر را نشان می‌دهد. برای این مدل در آستانه بارش ۰/۱ میلیمتر، احتمال آشکارسازی ۰/۹۶ و امتیاز مهارتی هایدکه ۰/۶۷ بدست آمد و برای آستانه بارش ۱ میلیمتر POD و HSS به ترتیب ۰/۸ و ۰/۷۷ بدست آمدند. با توجه به اینکه

Table 6- Evaluation of two better models (for 3754 patterns- precipitation less than 5mm)

جدول ۶- اعتبارسنجی دو مدل برتر (برای ۳۷۵۴ الگو- بارش کمتر از ۵ میلیمتر)

Regression Model		PCA	MAE (mm)	RMSE (mm)	MBias (mm)	R	R ²
Squared Exponential Gaussian		Without PCA	0.24	0.55	0.999917	0.58	0.34
Exponential Gaussian		With PCA	0.17	0.38	1.000057	0.85	0.72
Contingency Table for Exponential Gaussian Model With PCA	T	a	b	c	d	POD	HSS
	0.1	769	512	40	2433	0.95	0.64
	1	193	54	101	3406	0.65	0.69

۳-۴- شبکه عصبی مصنوعی

تشخیص آستانه بارش نشان می‌دهد و توانایی خوبی برای تفکیک بارش از عدم بارش دارد. در تشخیص بارش‌های محدوده ۱ میلی‌متر نیز عملکرد نسبتاً قابل قبولی دارد. اما برای آستانه‌های بالاتر عملکرد خوبی ندارد که ناشی از کمبود داده در آن محدوده بوده چرا که شبکه برای میزان بارش‌های زیاد به درستی آموزش ندیده است.

۳-۵- تعمیم مدل رگرسیونی و شبکه عصبی

در این مطالعه در دو ایستگاه هواشناسی استان هرمزگان از مدل‌های رگرسیونی مختلف و همچنین شبکه عصبی، برای برآورد بارش استفاده شده است و پس از انجام اعتبارسنجی، بهترین مدل رگرسیونی و شبکه عصبی انتخاب شدند. سپس این مدل‌ها برای کل منطقه استان هرمزگان تعمیم داده شد و بارش مناطقی که فاقد ایستگاه‌های هواشناسی بودند، برآورد شد. به‌عنوان نمونه بارش نیم‌ساعته در چند زمان مختلف در روز ۲۲ مارس ۲۰۲۰ ترسیم گردید. هر دو مدل در طی این زمان‌ها الگوی نسبتاً مشابهی را نشان دادند. ماهیت مدل‌های رگرسیونی به گونه‌ای است که شدت بارش‌های بسیار بالا را کاهش می‌دهد و شدت بارش‌های خیلی کم را افزایش می‌دهد که منجر به کم‌برآورد در آهنگ‌های بارش زیاد و بالا برآورد آهنگ‌های بارش کم می‌شود. شکل‌های مربوط به مدل رگرسیونی نیز بیانگر همین مسأله هستند و بارش هموارتری را نشان می‌دهند. اما شبکه‌های عصبی اگر برای بارش‌های زیاد نیز آموزش ببینند، در تشخیص آنها عملکرد بهتری خواهند داشت.

شبکه‌های عصبی مصنوعی به منظور شبیه‌سازی مسائل غیرخطی و پیچیده مورد استفاده قرار می‌گیرند. در این مطالعه به منظور برآورد بارش از شبکه عصبی پرسپترون چند لایه استفاده شده است. دمای روشنایی هشت کانال به‌عنوان پیش‌بینی‌کننده در لایه ورودی و بارش متناظر با آن به‌عنوان پیش‌بینی شونده در لایه خروجی قرار گرفته‌اند. از ۳۸۰۲ الگوی در دسترس، ۲۹۰۰ الگو برای ساخت و طراحی شبکه و ۹۰۲ الگو نیز برای اعتبارسنجی نهایی شبکه در نظر گرفته شد. ساختار شبکه‌های عصبی مصنوعی به گونه‌ای است که درصدی از الگوها را برای اعتبارسنجی و تست حین طراحی شبکه مورد استفاده قرار می‌دهد. در اینجا از میان ۲۹۰۰ الگو، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای تست در حین طراحی در نظر گرفته شده است. شاخص‌های آماری برای این دو مجموعه داده (۲۹۰۰ الگوی آموزش و ۹۰۲ الگوی اعتبارسنجی) در جدول ۷ داده شده است.

شاخص‌های میانگین خطا برای شبکه عصبی مصنوعی نسبت به روش‌های رگرسیونی بیشتر است و همچنین، ضریب همبستگی کمتری را نسبت به روش‌های رگرسیونی داراست. آریبی چندگانه نیز ضعیف‌تر بوده و حاکی از کم‌برآورد این مدل می‌باشد. برای هر دو مجموعه داده‌های آموزش و اعتبارسنجی جدول توافقی تشکیل و شاخص‌های POD و HSS برای آنها محاسبه گردیده است. همانطور که در جدول ۷ آمده است، شبکه عصبی بهترین عملکرد را برای

Table 7- Evaluation of artificial neural network

جدول ۷- اعتبارسنجی شبکه عصبی مصنوعی

Neural Network		MAE (mm)	RMSE (mm)	MBias	R	R ²	
Train (2900 patterns)		0.32	0.94	0.731	0.62	0.39	
Validation (902 patterns)		0.40	1.27	0.668	0.43	0.18	
Contingency Table for Train (2900 patterns)	T	a	b	c	d	POD	HSS
	0.1	585	476	67	1772	0.90	0.56
	1	106	92	147	2555	0.42	0.43
	5	2	4	30	2864	0.06	0.10
	10	1	0	7	2892	0.13	0.22
Contingency Table for Validation (902 patterns)	T	a	b	c	d	POD	HSS
	0.1	175	176	30	521	0.85	0.48
	1	36	37	53	776	0.40	0.39
	5	1	1	17	883	0.06	0.1
	10	0	0	3	899	0	0

کانال‌های فروسرخ سنجنده تصویربردار چرخان پیشرفته مرئی و فروسرخ (SEVIRI) از نسل دوم ماهواره‌های متئوست (MSG) استفاده شده است. در همین راستا ابتدا ۴۱ پدیده بارشی در زمستان سال ۹۷ و ۹۸ و همچنین بهار ۹۸ و ۹۹ در ایستگاه‌های هواشناسی رودان و میناب در جنوب کشور ایران انتخاب گردیدند. سپس دو مجموعه داده تهیه گردید: (۱) بارش مشاهداتی؛ اطلاعات باران‌سنج‌های ایستگاه‌های خودکار شهرهای میناب و رودان؛ (۲) دمای روشنایی سنجنده SEVIRI. در مجموع ۳۸۰۲ الگو (نقطه-زمان) از داده‌های بارش و دمای روشنایی تهیه گردید و همبستگی بین بارش و دمای روشنایی هشت کانال بطور میانگین ۰/۳۶- بدست آمد.

در بسیاری از مطالعات انجام شده، از محصول ماهواره‌ای GPM^۵ برای اعتبارسنجی‌ها استفاده می‌شود. در اینجا نیز داده‌های بارش این محصول دریافت و تصویر آن در همان زمان و همان منطقه مکانی ترسیم گردید. این تصویر نیز الگوی نسبتاً مشابهی را بویژه برای بارش‌های زیاد نشان می‌دهد. در شکل ۶ تصاویر بارش برآورد شده توسط مدل رگرسیونی و شبکه عصبی و بارش محصول GPM آمده است.

۴- خلاصه و جمع‌بندی

در این مطالعه به منظور بازیابی میزان بارش، از دمای روشنایی

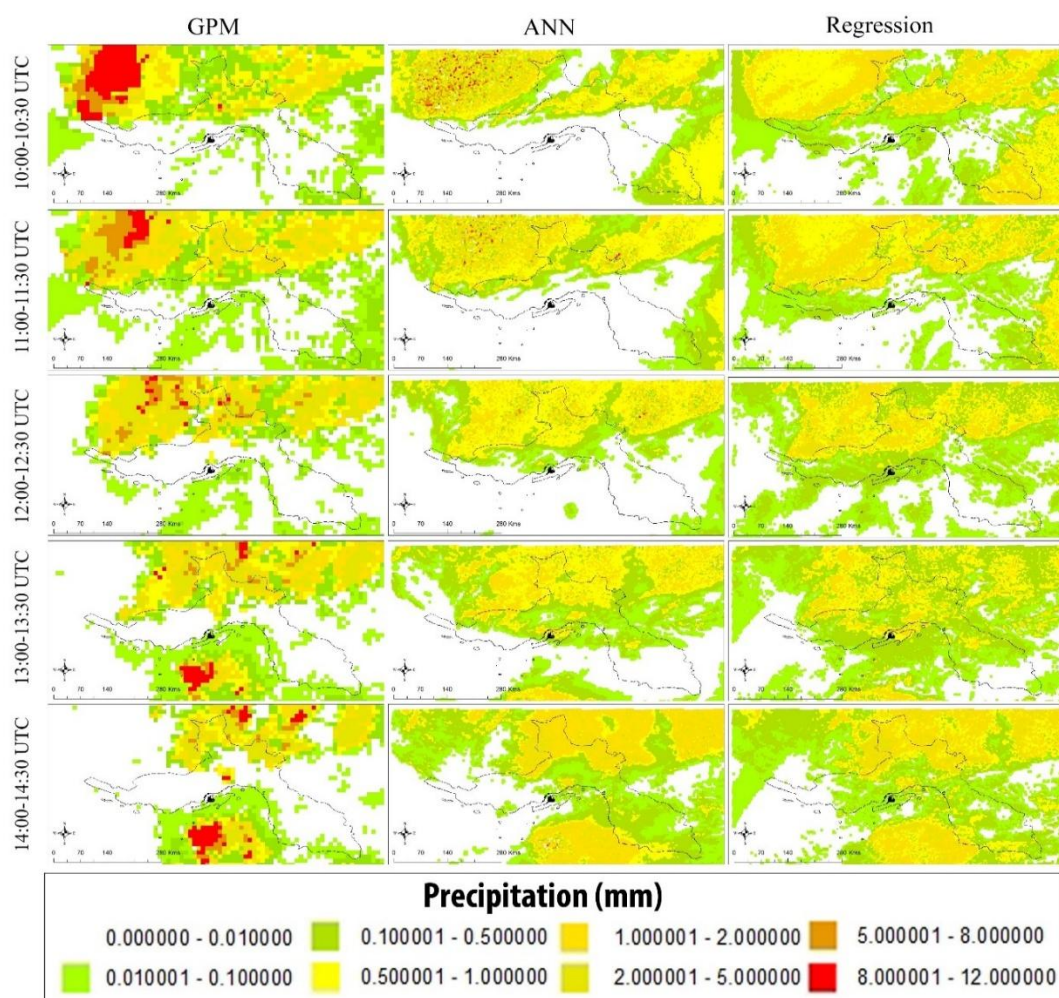


Fig. 6- Retrieval precipitation for 5 half-hour interval between 10:00 to 14:30UTC- 22 March 2020 respectively right to left: Regression model, Artificial neural network, and GPM product

شکل ۶- بارش بازیابی شده برای ۵ بازه زمانی نیم ساعته بین ساعات ۱۰ تا ۱۴:۳۰ گرینویچ ۲۲ مارس ۲۰۲۰ به ترتیب از راست به چپ: برآورده شده توسط مدل رگرسیونی- شبکه عصبی مصنوعی- محصول GPM

پی‌نوشت‌ها

- 1- Microwave Imager & Radar Precipitation Tropical Rainfall Measuring Mission
- 2- Geostationary Operational Environmental Satellite
- 3- Principal Component Analysis
- 4- Multilayer Perceptron
- 5- Global Precipitation Measurement

۵- مراجع

- Atif R M, Siddiqui M H, & Almazroui M (2020) Near-real-time spatiotemporal analysis of convection and extreme rainfall leading to a flash flood using MSG-SEVIRI and TRMM data: A case study of a flash flood in Jeddah, Saudi Arabia on the November 25, 2009. *Journal of Flood Risk Management* 13(3):e12611
- Azizian A, & Ramezani E H (2019) Spatiotemporal assessment of reanalysis and remotely-sensed precipitation datasets. *Iran-Water Resources Research* 15(1):163-177 (In Persian)
- Babaei H, Janalipour M, & Tehrani N A (2019) A simple, robust, and automatic approach to extract water body from Landsat images (Case study: Lake Urmia, Iran). *Journal of Water and Climate Change* 12 (1):238-249
- Cancelada M, Salio P, Vila D, Nesbitt S W, & Vidal L (2020) Backward Adaptive Brightness Temperature Threshold Technique (BAB3T): A methodology to determine extreme convective initiation regions using satellite infrared imagery. *Remote Sensing* 12(2):337
- Chen Y, Ebert E E, Walsh K J, & Davidson N E (2013) Evaluation of TRMM 3B42 precipitation estimates of tropical cyclone rainfall using PACRAIN data. *Journal of Geophysical Research: Atmospheres* 118(5):2184-2196
- Dinku T, Ceccato P, Grover-Kopec E, Lemma M, Connor S J, & Ropelewski C F (2007) Validation of satellite rainfall products over East Africa's complex topography. *International Journal of Remote Sensing* 28(7):1503-1526
- Ghahraman B, & Faridhosseini A (2019) Comparison of observed rainfall and PERSIANN and CMORPH satellite rainfall data in hourly and daily scale (Case study: Shapoor basin). *Iran-Water Resources Research* 14(4):1-13 (In Persian)
- Giannakos A & Feidas H (2013) Classification of convective and stratiform rain based on the spectral and textural features of Meteosat Second Generation infrared data. *Theoretical and Applied Climatology* 113(3-4):495-510

منفی بودن همبستگی نشان می‌دهد که بارش و دمای روشنایی با یکدیگر رابطه معکوس دارند. همچنین بازه تغییرات دمای روشنایی هشت کانال به تفکیک برای شرایط بارشی و غیر بارشی مورد بررسی قرار گرفت. تمامی کانال‌ها بجز کانال‌های بخار آب، در تفکیک شرایط بارشی و غیر بارشی قابلیت زیادی دارند. سپس این مجموعه داده‌ها برای طراحی مدل رگرسیونی و همچنین شبکه عصبی بکار رفتند. طراحی مدل رگرسیونی طی سه مرحله (کلیه رخدادهای بارشی، بارش‌های کمتر از ۱۰ میلی‌متر و بارش‌های کمتر از ۵ میلی‌متر) و با روش‌های رگرسیونی مختلف (رگرسیون خطی، درخت رگرسیونی، ماشین بردار پشتیبان و مدل رگرسیون فرآیند گاوسی) انجام گرفت و اعتبارسنجی شد. در نهایت مدل رگرسیونی نمایشی با PCA برای بارش‌های کمتر از ۱۰ میلی‌متر، با $RMSE=0.44mm$ ، $MAE=0.17mm$ و $POD=0.96$ و $HSS=0.67$ برای آستانه بارش ۱/۰ میلی‌متر و $POD=0.8$ و $HSS=0.77$ برای آستانه بارش ۱ میلی‌متر، و $R=0.91$ و $R^2=0.84$ به عنوان مدل منتخب مدل‌های رگرسیونی برگزیده شدند. مدل برای حالت‌های غیربارشی نیز بارش‌های اندکی را نشان داد، که به افزایش $RMSE$ و همچنین کاهش R منجر گردیده است. از سوی دیگر یک شبکه عصبی پرسپترون چندلایه براساس این مجموعه داده‌ها طراحی گردید. دمای روشنایی هشت کانال بعنوان پیش‌بینی‌کننده در لایه ورودی قرار گرفتند و بارش متناظر با آن بعنوان پیش‌بینی شونده در لایه خروجی قرار گرفت، شبکه اجرا گردید و اعتبارسنجی آن انجام شد. نتایج اعتبارسنجی، $MAE=0.4mm$ ، $RMSE=1.27mm$ ، $R=0.43$ و $R^2=0.18$ را نشان می‌دهد. کمیت $MBias=0.668$ نشان‌دهنده کم‌برآورد این شبکه می‌باشد. شبکه عصبی برای آستانه بارش ۱/۰ میلی‌متر با $POD=0.85$ و $HSS=0.48$ عملکرد خوبی در تعیین و تفکیک شرایط بارشی از غیر بارشی را نشان می‌دهد اما برای آستانه‌های بارش بالاتر عملکرد مطلوبی نداشته است. بطور کلی شبکه عصبی مصنوعی نسبت به روش‌های رگرسیونی شاخص‌های میانگین خطای بیشتر و همبستگی کمتری بین بارش‌های برآورد شده و بارش‌های مشاهده شده بدست می‌دهد.

با مقایسه همبستگی بین بارش و دمای روشنایی کانال‌های فروسرخ، همبستگی بین بارش مشاهده شده و بارش برآورد شده، می‌توان نتیجه گرفت علیرغم اینکه بارش و دمای روشنایی همبستگی نسبتاً کمی دارند، ولی در این مطالعه از این داده‌ها با همبستگی نه چندان مناسب، محصولات بارشی استخراج شد که توانست همبستگی خوبی را بین بارش مشاهده شده و بارش برآورد شده نشان دهد.

- meeting on microwave radiometry and remote sensing of the environment. Washington, DC, USA.
- Sehad M, & Ameer S (2020) A multilayer perceptron and multiclass support vector machine based high accuracy technique for daily rainfall estimation from MSG SEVIRI data. *Advances in Space Research* 65(4):1250-1262
- Shayeghi A, Azizian A, & Brocca L (2019) Evaluating the efficiency of reanalysis and remote-sensing based rainfall data sets for hydrological modeling using VIC-3L large scale model. *Iran-Water Resources Research* 15(2):57-72 (In Persian)
- Strangeways I (2006) *Precipitation: Theory, measurement and distribution*. Cambridge University Press
- Wilks D S (2011) *Statistical methods in the atmospheric sciences (Vol. 100)*. Academic Press
- Yilmaz K K, Hogue T S, Hsu K L, Sorooshian S, Gupta H V, & Wagener T (2005) Intercomparison of rain gauge, radar, and satellite-based precipitation estimates with emphasis on hydrologic forecasting. *Journal of Hydrometeorology* 6(4):497-517
- Yan H, & Yang S (2007) A MODIS dual spectral rain algorithm. *Journal of Applied Meteorology and Climatology* 46(9):1305-1323
- Zell A (1994) *Simulation Neuronaler Netze [Simulation of Neural Networks]* (in German) (1st ed.). Addison-Wesley p. 73, ISBN 3-89319-554-8
- Hong Y, Adler R F, Negri A, & Huffman G J (2007) Flood and landslide applications of near real-time satellite rainfall products. *Natural Hazards* 43(2):285-294
- Hughes D A (2006) Comparison of satellite rainfall data with observations from gauging station networks. *Journal of Hydrology* 327(3-4):399-410
- Kubota T, Shige S, Hashizume H, Aonashi K, Takahashi N, Seto S, ... & Iwanami K (2007) Global precipitation map using satellite-borne microwave radiometers by the GSMaP project: Production and validation. *IEEE Transactions on Geoscience and Remote Sensing* 45(7):2259-2275
- Kühnlein M, Appelhans T, Thies B, & Nauß T (2014) Precipitation estimates from MSG SEVIRI daytime, nighttime, and twilight data with random forests. *Journal of Applied Meteorology and Climatology* 53(11):2457-2480
- Meyer H, Kühnlein M, Appelhans T, & Nauss T (2016) Comparison of four machine learning algorithms for their applicability in satellite-based optical rainfall retrievals. *Atmospheric Research* 169:424-433
- Parisooj P, Goharnejad H, & Moazami S (2018) Rainfall-runoff hydrologic simulation using adjusted satellite rainfall algorithms, a case study: Voshmgir dam basin, Golestan province. *Iran-Water Resources Research* 14(3):174-188 (In Persian)
- Sanchez F, Iturbide SA, Boukabara K, Garrett Ch, Grassotti W, Chen F, Weng (2010) Development and validation of a rainfall rate algorithm based on hydrometeor products derived from passive microwave satellite observations: 11th specialist