

Short-term Streamflow Forecast by Wet Snow Using Fusion Satellite Images Approach and Developed Artificial Intelligence Methods

Reza Esmaeelzadeh¹, Samad Emamgholizadeh^{2*}, Behnaz Bigdeli³

Ph.D. Student, Department of Civil Engineering, Shahrood University of Technology, Shahrood, Iran, sre_esmaeelzadeh@yahoo.com.

^{2*} Professor, Department of Civil Engineering, Shahrood University of Technology, Shahrood, Iran, s_gholizadeh517@yahoo.com.

³ Associate Professor, Department of Civil Engineering, Shahrood University of Technology, Shahrood, Iran, bigdeli@shahroodut.ac.ir.



[10.22125/IWE.2023.392196.1713](https://doi.org/10.22125/IWE.2023.392196.1713)

Received:
April 8, 2023
Accepted:
September 3, 2023
Available online:
May 5, 2024

Keywords:
Streamflow
forecast, Latiyan
Basin, AI methods,
Sentinel I&II,
fusion approach

Abstract

Streamflow forecasting models play a crucial role in hydrological issues, such as the determination of reservoir inflows and flood forecasting. In this research, artificial intelligence hybrid models including ANFIS and GA-ANN have been used for short-term (daily) streamflow forecasting. This research aims to predict the outlet of the Latiyan basin, Tehran province, from 2017 to 2018. For this purpose, a snow-covered area (SCA) is obtained from the processing of Sentinel-2 optical satellite images. Then, in order to extract the effective snow, the fusion algorithm is applied for Sentinel-1 and 2 integrations. Finally, the artificial intelligence model with the help of the effective snow parameter along with other daily hydrometric and meteorological data including daily precipitation, temperature, and discharge is applied to forecast the daily outlet of the basin. Also, to improve the model performance, the seasonal index has been used to identify streamflow trends and better model training. The results showed that the prediction model using satellite data has improved its performance by 37%, which shows the direct effect of the snow parameter on the basin runoff. In addition, the trend of changes in the effective snow parameter has a favorable agreement with the flow trend of the basin, especially in the peak flows. Also, using seasonal information as an input parameter can improve the results of the prediction models by approximately 22%. In addition, the AI method based on fuzzy inference (ANFIS) showed better performance than the developed neural network method (GA-ANN) based on statistical indices.

* **Corresponding Author:** Samad Emamgholizadeh
Address: Department of Civil Engineering, Shahrood University of Technology, Shahrood, Iran.

Email: s_gholizadeh517@yahoo.com
Tel: 09111194389

Introduction

Flow forecasting has a constructive role in water resource management activities. Theoretically, accurate flow prediction can be done through several hydrological and meteorological variables. Also, the snow parameter is another important factor in streamflow prediction. Therefore, the knowledge of remote sensing in snow estimation is a great help in appropriate forecasting models.

The proposed model has focused on the effect of snow melting in the runoff basin. In general, the present study consists of two steps, the first step includes the processing of satellite images and the second step is the preparation of the flow forecasting model. In fact, the output of the processed image, the effective snowmelt in the runoff, is included as the input of the model prediction along with other in-situ parameters and the seasonal index.

Materials and Methods

Latiyan Basin is one of the mountainous regions of Central Alborz, Iran. The data used in this study includes two types of ground and satellite data. The ground data used in this research are: Digital Elevation Model (DEM) of SRTM radar sensor of Latiyan Basin, daily discharge, precipitation, temperature, and snow measurement of the basin. The satellite data of the Sentinel sensors. In order to short-term streamflow forecast in the Latiyan basin, AI hybrid methods (GA-ANN and ANFIS) have been used. These models predict the basin outlet by ground and satellite data using modern cross-validation methods.

Results

As can be seen, SCA(T) shows superiority compared to SCA(II) in both AI models. In addition, the ANFIS-SCA(T) model has shown the best performance in identifying the peak points. Therefore, the approach of fusion satellite images and considering both ground and satellite data in the forecasting model will be fruitful in the reliability and efficiency of the model.

Discussion and Conclusion

The proposed methods have been applied to the study area of Latiyan basin, Iran, and the following results have been obtained:

- 1) In general, the ANFIS method has better performance than GA-ANN in the streamflow forecast.
- 2) Use of satellite images along with other ground data improved the streamflow forecasting results in both GA-ANN and ANSIF models.
- 3) The results showed that using seasonal information, as an input parameter, can increase the accuracy of both AI models.
- 4) Previous hydrological studies with an emphasis on the total SCA, obtained from optical sensors, led to overestimation and error in forecasting models. The wet snow method, derived from the optical and radar fusion approach, showed favorable results based on statistical indices.

Six important references

- 1) Conde, V., Nico, G., Mateus, P., Catalão, J., Kontu, A. and Gritsevich, M., 2019. On the estimation of temporal changes of snow water equivalent by spaceborne SAR interferometry: A new application for the Sentinel-1 mission. *Journal of Hydrology and Hydromechanics*.
- 2) Dariane, A.B. and Azimi, S., 2016. Forecasting streamflow by a combination of a genetic input selection algorithm and wavelet transforms using ANFIS models. *Hydrological Sciences Journal*, 61(3), pp.585-600
- 3) Esmaeelzadeh, S.R., Adib, A. and Alahdin, S., 2015. Long-term streamflow forecasts by Adaptive Neuro-Fuzzy Inference System using satellite images and K-fold cross-validation (Case study: Dez, Iran). *KSCE Journal of Civil Engineering*, 19, pp.2298-2306.
- 4) Esmaeelzadeh, R., Golian, S., Sharific, S. and Bigdeli, B., 2021. Enhanced Long-term and Snow-based Streamflow Forecasting by Artificial Intelligent Methods Using Satellite Imagery and Seasonal Information. *Russian Meteorology and Hydrology*, 46, pp.396-402
- 5) Snapir, B., Momblanch, A., Jain, S.K., Waive, T.W. and Holman, I.P., 2019. A method for monthly mapping of wet and dry snow using Sentinel-1 and MODIS: Application to a

Himalayan River basin. International Journal of Applied Earth Observation and Geoinformation, 74, pp.222-230.

- 6) Tsai, Y.L.S., Dietz, A., Oppelt, N. and Kuenzer, C., 2019. A combination of PROBA-V/MODIS-based products with Sentinel-1 SAR data for detecting Wet and Dry snow cover in mountainous areas. Remote Sensing, 11(16), p.1904.

Conflict of Interest

The Authors declare no conflict of interest.

پیش‌بینی کوتاه‌مدت جریان با استفاده از رویکرد ادغام تصاویر ماهواره‌ای و مدل هوش مصنوعی توسعه یافته

سیدرضا اسمعیل زاده^۱، صمد امامقلی زاده*^۲، بهناز بیگدلی^۳

تاریخ ارسال: ۱۴۰۲/۰۱/۱۹

تاریخ پذیرش: ۱۴۰۲/۰۶/۱۲

مقاله پژوهشی

چکیده

با توجه به ضرورت پیش‌بینی جریان در مسائل هیدرولوژی از قبیل تعیین ورودی مخازن و پیش‌بینی سیل، مدل‌های پیش‌بینی جریان در علم هیدرولوژی بسیار مورد توجه قرار گرفته‌اند. در این تحقیق، از مدل‌های ترکیبی هوش مصنوعی شامل: ANFIS و GA-ANN برای پیش‌بینی کوتاه‌مدت جریان (روزانه) استفاده شده است. هدف این پژوهش پیش‌بینی جریان خروجی حوضه لتیان، استان تهران، در بازه مطالعاتی ۱۳۹۸-۱۳۹۷ می‌باشد. برای این منظور ابتدا، با بهره‌گیری از رویکرد تلفیق شاخص‌گذاری و روش‌های طبقه‌بندی، سطح پوشش برف حاصل از پردازش ماهواره نوری Sentinel-2 تهیه می‌شود. سپس به منظور استخراج سطح پوشش برف موثر، الگوریتم ادغام تصاویر با تصاویر ماهواره راداری Sentinel-1 اعمال می‌شود. نهایتاً، مدل هوش مصنوعی با کمک پارامتر برف موثر در کنار سایر داده‌های روزانه هیدرومتری و هواشناسی شامل: بارش، دما و جریان پیش‌بینی روزانه جریان خروجی حوضه می‌پردازد. همچنین، به منظور ارتقاء عملکرد مدل پیش‌بینی از شاخص فصلی در جهت شناسایی تغییرات و آموزش بهتر مدل استفاده شده است. نتایج نشان داد، مدل پیش‌بینی با استفاده از داده‌های ماهواره‌ای تا میزان ۳۷ درصد بهبود عملکرد داشته است. این امر نشان‌دهنده تاثیر مستقیم پارامتر برف موثر بر روند رواناب حوضه می‌باشد. علاوه بر این، روند تغییرات سطح پوشش برف موثر هم‌خوانی مطلوبی با روند جریان حوضه، مخصوصاً در نقاط پیک جریان، دارد. همچنین، استفاده از اطلاعات فصلی به عنوان پارامتر ورودی می‌تواند نتایج مدل‌های پیش‌بینی، بر پایه تست-آموزش، را به میزان حدود ۲۲٪ افزایش دهد. در نهایت، روش هوش مصنوعی برپایه استنتاج فازی (ANFIS) عملکرد بهتری نسبت به روش شبکه عصبی بهینه (GA-ANN) برپایه شاخص‌های آماری نشان داد.

واژه‌های کلیدی: مدل پیش‌بینی جریان، حوضه لتیان، روش‌های هوش مصنوعی، سنجنده Sentinel-1 and 2، رویکرد ادغام تصاویر.

^۱ دانشجوی دکتری مهندسی و مدیریت منابع آب، دانشکده عمران، دانشگاه صنعتی شاهرود، ایران، شماره تماس: ۰۹۱۵۱۷۳۱۰۸۴.

Sre_esmaealzadeh@yahoo.com

^۲ استاد گروه عمران، دانشگاه صنعتی شاهرود، ایران، شماره تماس: ۰۹۱۱۱۱۹۴۳۸۹، S.gholizadeh517@gmail.com (نویسنده مسئول)

^۳ دانشیار گروه عمران، دانشگاه صنعتی شاهرود، ایران، شماره تماس: ۰۹۱۹۷۵۲۹۲۶۶، Behnaz_bigdeli@yahoo.com

مقدمه

سازمان‌هایی چون ^۱ESA، ^۲NASA در این زمینه تحقیقات متعددی انجام داده‌اند (Tsai et al., 2019).

با توجه به سابقه و مزایای سنجنده‌های نوری، رویکرد استفاده از این نوع سنجنده‌ها در مطالعات برف‌سنجی بسیار مورد توجه قرار گرفته است (De Gregorio et al., 2019; Salzano et al., 2019).

سنجنده نوری قادر به استخراج سطح پوشش برف فارغ از نوع برف (خشک یا مرطوب) می‌باشد که این امر منجر به بیش‌برآورد سطح برف مشارکتی می‌شود. مطالعاتی در این زمینه انجام شده و به این نتیجه رسیده است که فاز ذوب برف با کاهش در عمق برف اتفاق می‌افتد، اما کاهش ناچیزی در سطح برف به همراه دارد. همچنین، این رخداد با شروع فصل ذوب شدت می‌گیرد. علاوه بر این، تحقیقات نشان داده که تغییرات توده برف کلی نسبت به نوسانات جریان حوضه دارای یک وقفه زمانی می‌باشد و این وقفه در مدل‌های پیش‌بینی هیدرولوژیکی تاثیر منفی خواهد داشت (Snapir et al., 2019).

از آنجا که برف مرطوب (برف آماده ذوب) نقش سازنده‌ای در پدیده‌های هیدرولوژی دارد، تفاوت‌هایی برای برف مرطوب و خشک وجود دارد که از جمله به موارد زیر می‌توان اشاره کرد:

۱) برپایه حجم آب موجود (VWC^3)، که به VWC بالای ۱٪ برف مرطوب و به حجم آب موجود زیر ۱٪ برف خشک اطلاق می‌گردد (Stiles and Ulaby, 1980).

۲) برپایه دمای توده برف، که بیش از صفر درجه برف مرطوب و زیر صفر درجه برف خشک نامیده می‌شود. این روش به مراتب آسان‌تر و کاربردی‌تر از روش VWC برای استخراج برف مرطوب می‌باشد

(Besic and Stankovic, 2014).

از طرفی، تصاویر نوری دارای معایبی از جمله: تاثیرپذیری از اثرهای محیطی (عدم کارایی مناسب در مقابل ابر و مه)، برآورد اشتباه بین ابر، برف و یخ، پرهزینه‌بودن و آسیب‌پذیر بودن از لحاظ فیزیکی می‌باشد. بنابراین داده‌های رادار ^۴SAR، به خاطر استقلال از پوشش ابر و موقعیت روشنایی،

سطح پوشش برف بر اکثر پدیده‌های هیدرولوژی از جمله تعادل انرژی جهانی و منطقه‌ای، آب زیرزمینی، رواناب و یخچال‌های طبیعی دارد. همچنین، برف یکی از منابع بزرگ تامین‌کننده آب در بیشتر کشورهای جهان به‌ویژه مناطق کوهستانی می‌باشد (Tsai et al., 2019).

در ایران تنها بارش برف، به واسطه تاثیر بلندمدت آن در ارتفاعات، کمک شایانی به پرشدن چاه‌های زیرزمینی و ذخیره آب در سدها می‌کند.

برف به دلیل وجود فاصله زمانی بین نزول آن تا زمان پیوستن به آب سطحی و یا زیرزمینی از اهمیت ویژه‌ای برخوردار است. مطالعات نشان می‌دهد که آب حاصل از ذوب برف بر رژیم رواناب در پایین‌دست مناطق نه‌تنها بر مقدار کمی آن، بلکه بر توزیع، کیفیت و فصلی‌بودن آن نیز تاثیر می‌گذارد. بنابراین این پارامتر منجر به کنترل منابع آب موجود می‌شود.

باید اذعان داشت که حوضه‌های برف‌گیر زیادی وجود دارد که اساساً در آنها برف‌سنجی صورت نمی‌گیرد و یا به‌دلیل تعداد محدود نمونه‌برداری، اندازه‌گیری‌ها نمی‌تواند مبنا و ملاک اندازه‌گیری مناسبی برای محاسبات و برآورد حجم آب معادل پوشش برفی باشند. همچنین، ایستگاه‌های اندازه‌گیری در حوضه‌های بزرگ به صورت غیریکنواخت توزیع شده‌اند. بنابراین توزیع زمانی و مکانی نامناسب ایستگاه‌ها، منجر به برآورد ناصحیح و غیرقابل اطمینان از پوشش برف می‌شود (Esmaeelzadeh et al., 2021).

بنابراین، با توجه به پوشش وسیع حوضه، تنوع زمانی و عدم دسترسی به مناطق صعب‌العبور در بسیاری از مناطق پوشیده از برف، سنجنش از دور یک روش مطلوب و ایده‌آل برای پایش روند تغییرات پوشش برف در مقیاس مکانی و زمانی می‌باشد. برخلاف اندازه‌گیری‌های زمینی، داده‌های ماهواره‌ای محدوده وسیع‌تری را در برمی‌گیرد. بنابراین با رویکرد علم سنجنش از دور، نواقص ایستگاه‌های زمینی مرتفع خواهد شد. در چند سال اخیر، توجه ویژه‌ای به علم سنجنش از دور برای برآورد پوشش برف شده است. از این رو

³ Volume Water Content

⁴ Synthetic Aperture Radar

¹ European Space Agency

² National Aeronautics and Space Administration



عامل مهم دیگر در پیش‌بینی دقیق جریان در حوضه‌های کوهستانی، بارش برف است. با توجه به تاثیر مستقیم برف بر رژیم رواناب حوضه و کارایی مطلوب علم سنجش از دور در تخمین میزان برف (پوشش، عمق و آب معادل برف) مدل‌های مناسب پیش‌بینی بر این اساس ارائه شده است. در دهه‌های اخیر، رویکردهای نوین در زمینه کاربرد تصاویر ماهواره‌ای به همراه متغیرهای هیدرولوژیکی و هواشناسی منجر به پیشرفت در مدل‌های پیش‌بینی شده است (Esmaelzadeh et al., 2015).

Brombacher و همکاران در سال ۲۰۲۰ در مطالعه خود از هر دو نوع سنجنده سنتینل ۱ و ۲ برای ارائه یک رویکرد جدید برای تخمین دبی رودخانه (Thjorsa) (Pjorsa) ایسلند، برپایه اندازه‌گیری روزانه استفاده کردند. نتایج نشان داد که تخمین دبی مبتنی بر ماهواره می‌تواند در کنار اندازه‌گیری دبی مشاهداتی، مخصوصاً در دوران یخبندان، بسیار ارزشمند باشد.

اسمعیل زاده و همکاران (۲۰۲۱) در مطالعه‌ای با بهره‌گیری از تصاویر سنجنده‌ی نوری MODIS و روش‌های تلفیقی هوش مصنوعی به پیش‌بینی بلندمدت جریان حوضه تله‌زنگ، ایران، پرداختند. نتایج نشان‌دهنده بهبود عملکرد مدل با بهره‌گیری از پارامتر برف در مدل بود.

در مطالعه حاضر، مدل پیشنهادی مبتنی بر پتانسیل نهفته در رواناب حاصل از ذوب برف بوده و تاثیر آن بر رواناب حوضه در نظر گرفته می‌شود.

به طور کلی مطالعه حاضر، شامل دو مرحله می‌باشد، که مرحله اول شامل پردازش تصاویر ماهواره‌ای و مرحله دوم تهیه مدل پیش‌بینی جریان می‌باشد. در واقع، مرحله اول به منظور تهیه بخشی از داده‌ها برای مدل پیش‌بینی می‌باشد.

در گام اول برای استخراج برف موثر، از تلفیق تصاویر راداری و نوری سنجنده سنتینل و روش‌های نوین کلاسه‌بندی، به منظور افزایش دقت و کارایی مدل، استفاده شده است.

انتخاب داده، تاثیری شگرف بر عملکرد مدل پیش‌بینی در روند آموزش-تست مدل‌های هوش مصنوعی دارد. لذا در

می‌تواند گزینه ارزشمندی برای بهبود برآورد سطح پوشش برف باشد (Orlíková and Horák, 2019; Conde et al., 2019).

Tsai و همکاران در سال ۲۰۱۹ در مطالعه‌ای به ارائه روشی برای برآورد برف کل و مرطوب با استفاده از داده‌های SAR پرداختند. نتایج، نشان داد دقت و اعتبار مدل با بهره‌گیری از توپوگرافی، ارتفاع، پارامترهای قطبی به همراه

اطلاعات نوع پوشش منطقه، افزایش داشته است. با صحت‌سنجی تصاویر با تصاویر سطح پوشش برف حاصل از تصاویر نوری و مشاهده زمینی، نقشه‌های حاصله قابلیت استفاده و اجرا برای ماه‌های مختلف را دارد. رویکرد دیگر در بهبود و افزایش دقت تصاویر، استفاده از چند نوع سنجنده و ترکیب آن‌هاست. برای محاسبه سطح پوشش-برف SCA^۱، با روش تلفیق معادلات و مشاهدات ماهواره‌ای کوشش‌هایی انجام شده است (Esmaelzadeh et al., 2021).

پیش‌بینی جریان یک موضوع مهم در پدیده‌های هیدرولوژیکی می‌باشد و همچنین نقش سازنده-ای در فعالیت‌های مدیریت منابع آب شامل کنترل سیل، مدیریت خشکسالی و بهره‌برداری از مخازن دارد. همچنین، در نظر گرفتن بازه پیش‌بینی، فرصتی برای اتخاذ سیاست‌های بهره‌برداری و اتخاذ تصمیم‌های مدیریت منابع آب در مقوله دبی و سیلاب و خشکسالی فراهم می‌آورد.

مروری بر تحقیقات گذشته نشان می‌دهد که تنوع گسترده-ای از مدل‌های متنوع جعبه‌سیاه برای توسعه مدل‌های پیش‌بینی جریان ارائه شده است. که این مدل‌ها شامل روش‌های مبتنی بر رگرسیون (Liu et al., 2018) مدل‌های سری‌زمانی (Jain et al., 2001)، شبکه‌های عصبی-مصنوعی (ANN) (Uysal and Şorman, 2017)، سیستم استنباط عصبی‌فازی-تلفیقی (Chang and Dariane and Chang, 2006) و روش‌های ترکیبی (Azimi, 2016; Nourani, et al., 2014) می‌باشند. به طور کلی، عملکرد مناسب در سیستم‌های پیچیده و داشتن نتایج قابل اعتماد و بی‌طرفانه را می‌توان از مزایای اصلی روش‌های جعبه سیاه ذکر کرد.

¹ Snow Covered Area

- داده‌های ایستگاه هیدرومتری حوضه، به منظور برآورد خروجی حوضه.

- داده‌های ایستگاه بارش روزانه حوضه.

- داده‌های ایستگاه هواشناسی ($^{\circ}\text{C}$) حوضه لتیان. همچنین، به منظور استخراج روابط منطقه‌ای از دوره بلند مدت بیست ساله داده هواشناسی نیز استفاده شده است.

- داده‌های ایستگاه‌های برف‌سنجی که شامل عمق و چگالی برف می‌باشد. این مقادیر به منظور صحت‌سنجی تصاویر پردازش شده مورد استفاده قرار می‌گیرد.

- نقاط شاهد و ثابت در حوضه مطالعاتی (دریاچه، فضای شهری...) به منظور کنترل پردازش تصاویر ماهواره‌ای.

داده ماهواره‌ای

برای برآورد SCA، دسترسی آسان به اطلاعات، رایگان بودن داده، دقت مکانی بالا، بازه زمانی کوتاه در تصویربرداری مجدد و به روز بودن تصاویر بسیار مهم می‌باشد.

با در نظر گرفتن موارد فوق، سنجنده سنتینل (با توجه به دربرداشتن هر دو نوع سنجنده راداری و نوری) مطلوب و کارآمد به نظر می‌رسد. بنابراین، در تحقیق حاضر از سنجنده سنتینل-1 و ۲ استفاده شده است.

بازه پیش‌بینی، محدوده برف‌گیر نوامبر 2018 تا ژوئن 2019 می‌باشد. در بازه پیشنهادی، هم‌زمانی تصاویر اخذ شده راداری و نوری، تصاویر با قابلیت پردازش، تصاویر با کم‌ترین خطا و عوامل بازدارنده و پایش منظم تغییرات پوشش برقی از ملاک‌های انتخاب تاریخ تصاویر بوده است.

پردازش تصاویر ماهواره‌ای

به منظور تهیه داده ماهواره‌ای برای مدل پیش‌بینی، پردازش تصاویر خام سنجنده سنتینل ۱ و ۲ توسط نرم-افزارهای SNAP، ENVI در کنار ARC-MAP به همراه افزونه‌های جانبی انجام گرفته است.

پردازش تصاویر نوری

با توجه به اینکه سنجنده‌های چندطیفی نقش مهمی در شناسایی سطح پوشش برف ایفا می‌کنند، از این رو برای استخراج سطح پوشش برف سطحی لازم است تا فرایندهایی

این مطالعه، از روش‌های نوین cross-validation و شاخص فصلی (Seasonality index) که منجر به برآیندی دقیق از روند داده‌ها می‌شود، استفاده شده است. همچنین رویکرد داده‌های سطحی (Areal Data) به جای روش متداول ایستگاهی، در رفع مشکل توزیع مکانی نامناسب ایستگاه‌های هیدرومتری می‌تواند راه‌گشا باشد. در گام دوم، خروجی تصویر پردازش‌شده، برف موثر (snowmelt) در رواناب، به عنوان ورودی مدل پیش‌بینی در کنار سایر پارامترهای دخیل در رواناب حوضه و شاخص فصلی لحاظ شده است.

مواد و روش‌ها

حوضه مطالعاتی

استان تهران در جنوب بخش مرکزی رشته‌کوه البرز قرار دارد. حوضه مطالعاتی لتیان بین طول‌های 51° - 50° تا 23° - 21° و عرض‌های 46° - 35° تا 05° - 36° جزء مناطق کوهستانی البرز مرکزی، استان تهران، می‌باشد (شکل 1). مساحت این حوضه حدود 800 کیلومتر مربع و محیط آن 193 کیلومتر می‌باشد.

شیب متوسط حوضه آبریز $19/3\%$ بوده و ارتفاع حوضه بین 4280 و 1570 متر متغیر می‌باشد. نقشه‌های هیپسومتر نشان می‌دهد که بیش از 60% حوضه در ارتفاعی بالاتر از 2400 متر قرار دارد. بنابراین، می‌توان گفت که حوضه لتیان در یک منطقه کوهستانی واقع شده است (وزارت نیرو، ۱۳۸۸)

داده

داده‌های مورد استفاده در این مطالعه شامل دو نوع داده زمینی و ماهواره‌ای می‌باشد.

داده زمینی

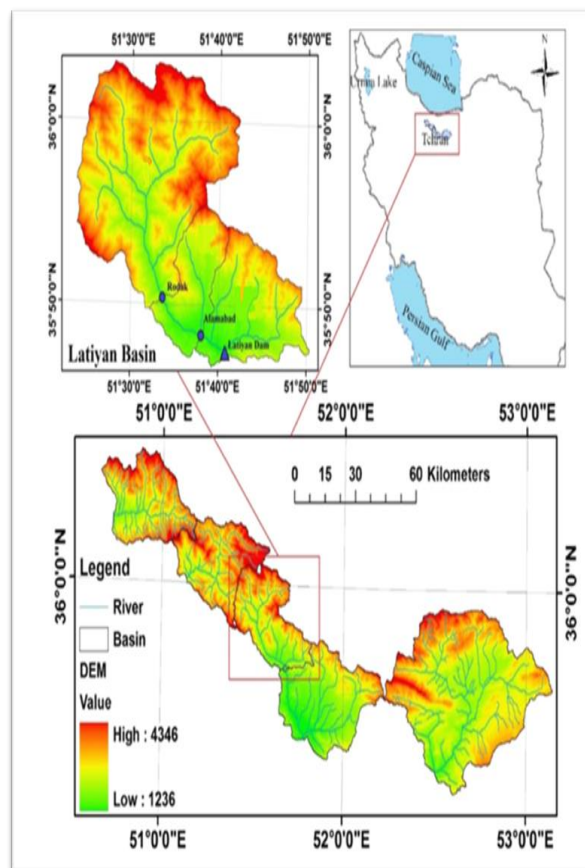
در تحقیق حاضر، به منظور پیش‌بینی روزانه خروجی حوضه، از داده‌های زمینی در محدوده سال آبی ۱۳۹۸-۱۳۹۷ استفاده شده است. این داده‌ها عبارتند از:

- مدل رقومی ارتفاعی (DEM) سنجنده راداری SRTM¹ حوضه لتیان.

¹ Shuttle Radar Topography Mission

به منظور شناسایی عوارض زمین با دقت بالاتر، رویکرد پن-شارپ کردن تصاویر و ادغام باندهای چندطیفی و باندهای مکانی، براساس باند پانکروماتیک، ارائه شده است. در بین شیوه‌های پن‌شارپینگ از الگوریتم متوسط محلی و انطباق واریانس (LMVM^۲) استفاده شده است. در واقع، این الگوریتم یک کانال شبه طیفی جدید با وضوح مکانی بهبودیافته، با بهره‌گیری از باند پانکروماتیک

هم‌چون پیش‌پردازش، پن‌شارپ کردن^۱ تصاویر و استخراج شاخص‌های برف انجام گیرد. هم‌چنین، برای ارتقاء عملکرد پردازش تصاویر، از رویکرد نوین طبقه‌بندی و ادغام طبقه‌بندی‌کننده‌ها استفاده شده است. عملیات پیش-پردازش شامل تصحیحات اتمسفریک (جهت اصلاح اثرات اتمسفریک)، تصحیحات رادیومتریک (برای اصلاح انرژی رسیده به سنجنده) و تصحیحات هندسی (به منظور اصلاح اعوجاج، جابجایی، عدم توازن رنگ‌ها در تصاویر) می‌باشد.



شکل (۱): حوضه مطالعاتی

به عنوان مهم‌ترین پارامتر در تشخیص برف می‌باشد که در آن از باندهای مرئی (Green) و امواج کوتاه مادون قرمز (SWIR) استفاده می‌شود. این شاخص توانایی تفکیک برف و ابر، در صورت نبود ابر زیاد در تصویر، را دارد.

با طول موج مشخص، را ایجاد می‌کند (Cornet and Nadasdi, 2001). سپس به منظور استخراج سطح پوشش برف از شاخص‌های تفکیک برف متداول استفاده می‌شود.

³ Normalized difference snow index

¹ Pansharpening

² Local Mean and Variance Matching

به کیفیت و کمیت نمونه‌ها توجه ویژه‌ای داشت. بنابراین، مقادیر نادرست و پرت، منجر به اختلال در فرآیند یادگیری طبقه‌بندی کننده‌ها می‌شود و دقت خروجی را بسیار کاهش می‌دهد. پس از انتخاب مناسب طبقه‌بندی کننده، نوبت به انتخاب نقاط آموزشی می‌رسد. تشخیص کلاس و برچسب گذاری پیکسل‌ها دو اصل مهم و اساسی در طبقه‌بندی داده‌ها می‌باشد. به منظور آموزش روش‌های طبقه‌بندی نظارت شده از تلفیق شاخص‌های برف برای تشخیص پیکسل‌های برفی از پیکسل‌های غیربرفی استفاده شده است. روش‌های طبقه‌بندی کننده استفاده شده در این تحقیق شامل:

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان (SVM) اولین بار توسط Boser و Vapnik برای طبقه بندی داده های خطی (Vapnik, 1998) معرفی شد. SVM یک الگوریتم یادگیری نظارت-شده است که داده‌ها را به دو دسته تقسیم می‌کند. با مجموعه‌ای از داده‌ها که قبلاً طبقه‌بندی شده‌اند آموزش داده‌ها انجام شده و ساختار مدل براساس آموزش داده‌ها تشکیل می‌شود. از آنجایی که مطالعه شامل دو طبقه (برف/ غیربرف) می‌باشد، بنابراین طبقه‌بندی کننده SVM بسیار کارآمد به نظر می‌رسد.

شبکه عصبی مصنوعی (ANN)

این طبقه‌بندی کننده نظارت شده به دلیل استقلال از توزیع نرمال در طبقه‌بندی و ساختار ناپارامتریک، در مطالعات سنجش از دور بسیار مورد توجه قرار گرفته است. از میان روش‌های هوش مصنوعی، شبکه‌های عصبی پس انتشار

مقاوم (Rprop) به دلیل مزایایی شامل آموزش سریع تر بیشتر مورد توجه محققان قرار گرفته است (Strobl and Forte, 2007).

نزدیک ترین همسایه-K

طبقه‌بندی کننده نزدیک ترین همسایه یکی از ساده ترین طبقه‌بندی کننده‌های نظارت شده است که در آن داده‌ها بر اساس نزدیک ترین همسایه‌ها طبقه‌بندی می‌شوند، بنابراین

اگر $NDSI > 0.4$ باشد، آن پیکسل به عنوان برف تلقی می‌شود. (Negi et al., 2009)

به منظور جلوگیری از برآورد کم برف، مخصوصاً در نقاط جنگلی، می‌توان از شاخص $NDVI$ نیز استفاده کرد. نقاطی که در آن $NDSI < 0.4$ اما $NDVI$ تقریباً 0.1 باشد،

آن پیکسل می‌تواند به عنوان برف تلقی شود (Dietz et al., 2012).

$$NDSI = \frac{Green - SWIR}{Green + SWIR} \quad (1)$$

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (2)$$

از نسبت شاخص $NIR/SWIR$ برای تفکیک برف از آب استفاده می‌شود (Nagajothi et al., 2019) در این شاخص از باندهای مادون قرمز نزدیک (NIR) و مادون قرمز کوتاه استفاده شده است. با در نظر گرفتن هم‌زمان این شاخص و پارامتر $NDSI$ ، مقدار عددی $NIR/SWIR > 0.38$ به عنوان آستانه تفکیک برف از آب برای این شاخص در نظر گرفته شد.

$$NIR / SWIR = \frac{NIR - SWIR}{NIR + SWIR} \quad (3)$$

با توجه به وجود مناطق جنگلی و پوشش گیاهی، شاخص S_3 برای تشخیص برف زیر پوشش گیاهی نیز معرفی شده است. در این شاخص از انعکاس باندهای مرئی (Red)، مادون قرمز نزدیک و مادون قرمز کوتاه استفاده شده است. Shimamura و همکاران در سال ۲۰۰۶ مقدار آستانه ۰.۱۸ برای تشخیص برف زیر پوشش گیاهی را پیشنهاد دادند.

$$S_3 = \frac{NIR(Red - SWIR)}{(NIR + Red)(NIR + SWIR)} \quad (4)$$

طبقه‌بندی تصاویر

بدون شک ضروری ترین مرحله در پایش پوشش برفی، طبقه بندی دقیق برف می‌باشد. در فرآیند طبقه‌بندی باید

¹ Normalized Difference Vegetation Index

² Resilient Backpropagation

اعتبارسنجی

پس از طبقه‌بندی داده‌ها، نوبت به بررسی و محاسبه صحت هر طبقه‌بندی‌کننده می‌رسد. برای ارزیابی دقت طبقه‌بندی‌کننده‌ها، از شاخص (CM³) استفاده می‌شود. هم‌چنین، دقت کلی (OA⁴) و ضریب کاپا به عنوان معیارهای آماری برای اعتبارسنجی مدل استفاده شده است.

پردازش تصاویر راداری

با توجه به ماهیت ماهواره‌ی SAR در تمایز بین برف خشک و مرطوب، براساس تفاوت در بازپراکنش طول موج-های متفاوت برای برف مرطوب و خشک، استفاده از ماهواره‌های راداری نقش بسزایی در بهبود استخراج سطح برف موثر در مدل‌های برفایی دارد.

در این گام، از تصاویر سنجنده سنتینل-۱ استفاده می‌شود. در روند تشخیص برف مرطوب با شروع روند ذوب برف، ضریب پراکنش (BS⁵) به طور قابل ملاحظه‌ای افت می‌کند. در روش BS از دو تصویر، یک تصویر شامل پوشش برف (σ_{ws}^0) و دیگری تصویر عاری از برف یا برف خشک به عنوان تصویر مرجع (σ_{ref}^0) استفاده می‌شود (Nagler and Rott, 2000). بعد از کالیبره کردن و سایر تصحیحات، نسبت این دو مشاهده محاسبه شده و برپایه مقیاس لگاریتمی با واحد دسی بل (dB) بیان می‌شود. با توجه به پایش منطقه‌ای و روند تغییرات، 11 آگوست ۲۰۱۸ به عنوان تصویر مرجع در این مطالعه انتخاب شد.

به طور خلاصه، روند استخراج برف مرطوب طبق روش پیشنهادی (شکل ۲)، به شرح زیر طبقه‌بندی می‌شود:

مرحله اول: پوشش برف (برف خشک و مرطوب)
SCA(II) حاصل از پردازش تصاویر نوری (سنتینل-II)
مرحله دوم: پوشش برف مرطوب SCA(I) حاصل از پردازش تصویر رادار (سنتینل-I)

مرحله سوم: ادغام تصاویر راداری و نوری
SCA(I,II) به منظور استخراج برف مرطوب

بهترین حالت زمانی رخ می‌دهد که تعداد محله‌ها از یک همسایه بیشتر شود (Keller et al., 1985).

AdaBoost¹

AdaBoost یک روش تقویت تطبیقی، تکنیکی در یادگیری ماشینی است که به عنوان روش گروهی شناخته می‌شود و توسط Freund معرفی شده است. این ساختار مدل بر اساس الگوریتم درختی است و از این الگوریتم برای حل مسائل طبقه‌بندی و رگرسیون استفاده می‌شود (Freund, 1995).

ترکیب طبقه بندی

رویکرد تلفیقی، تصمیمات مختلف طبقه‌بندی‌کننده‌ها را با هم ادغام می‌کند که در نتیجه منجر به برآورد دقیق طبقه‌بندی می‌شود. در این تحقیق، دو روش برای ادغام تصاویر ارائه شده است:

رای اکثریت (MV²)

یکی از مهم‌ترین و پرکاربردترین روش‌ها در رویکرد ترکیب داده‌ها، روشی مبتنی بر مفهوم رأی‌گیری است. ساده‌ترین شکل این روش مبتنی بر حداکثر آراء می‌باشد. در این روش، اگر همه نتایج وزن و دقت یکسانی داشته باشند، نتیجه همه طبقه‌بندی‌کننده‌ها با هم ترکیب شده و تصمیمی که بیشترین آراء را داشته باشد انتخاب می‌شود (Kuncheva et al., 2003).

Dempster-Shafer (D-S)

D-S به عنوان یک نظریه ریاضی مبتنی بر توابع و استدلال قابل قبول برای استدلال منطقی، بر پایه عدم قطعیت، معرفی می‌شود.

D-S یکی از قوی‌ترین روش‌ها برای یکپارچه‌سازی نتایج طبقه‌بندی‌کننده‌ها می‌باشد. یکی از مهم‌ترین و اساسی‌ترین ویژگی‌های روش فیوژن D-S، در نظر گرفتن

نتایج طبقه‌بندی‌کننده‌ها با در نظر گرفتن وزن آن هاست (Dempster, 2008).

⁴ Overall Accuracy

⁵ Backscatter coefficient

¹ Adaptive Boosting

² Majority Voting

³ Confusion Matrix

در زمان مورد نظر بدست می‌آید. بنابراین، به جای یک مقدار ایستگاهی، یک مقدار سطحی برای حوضه مورد نظر بدست می‌آید. در این مطالعه، نتایج برای هر ماه محاسبه و در (جدول ۱) نشان داده شده است.

که، y نشان‌دهنده میانگین دمای ماهانه در هر پیکسل و x ارتفاع مربوطه می‌باشد.

معیارهای ارزیابی مدل:

برای ارزیابی کارایی مدل‌ها، معیارهای آماری شامل: ضریب همبستگی (R)، ریشه میانگین مربعات خطا ($RMSE$) و ضریب کارایی نش ساتکلیف ($NASH$) استفاده شده است.

$$NASH = 1 - \frac{\sum_{t=1}^n (Y_t - y_t)^2}{\sum_{t=1}^n (Y_t - \bar{Y}_t)^2} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - y_t)^2}{n}} \quad (6)$$

$$R = \frac{\sum_{t=1}^n (Y_t - \bar{Y}_t)(y_t - \bar{y}_t)}{\sqrt{\sum_{t=1}^n (Y_t - \bar{Y}_t)^2 \sum_{t=1}^n (y_t - \bar{y}_t)^2}} \quad (7)$$

که در آن Y_t مقدار مشاهداتی، y_t مقدار محاسباتی، \bar{Y}_t ، \bar{y}_t مقادیر میانگین محاسباتی و مشاهداتی و n تعداد داده می‌باشد.

مدل پیش‌بینی

با توجه به این‌که هدف مطالعه، تهیه مدل پیش‌بینی روزانه جریان می‌باشد. لذا، در میان مدل‌های مرسوم، روش‌های مبتنی بر هوش مصنوعی بسیار پرکاربرد می‌باشد. همچنین، به منظور تنظیم وزن‌ها، بهبود آموزش شبکه و نهایتاً ارتقا و بهبود عملکرد شبکه‌های هوش مصنوعی، در این مطالعه تلفیق شبکه ANN با الگوریتم بهینه‌ساز ژنتیک (در قالب GA-ANN) و سیستم نرو-فازی (ANFIS)^۱ پیشنهاد شده است.

در تحقیق حاضر علاوه بر تصاویر راداری و نوری، از پارامترهای کمکی مانند (DEM، دمای سطح زمین، نقاط کنترل و اندازه‌گیری برف شامل: تراکم، عمق ...) برای پایش دقیق برف استفاده می‌شود.

روابط منطقه‌ای

در روش‌های متداول از داده‌های ایستگاهی به عنوان ورودی-خروجی مدل پیش‌بینی استفاده می‌شود. از مشکلات مربوط به ایستگاه‌های زمینی توزیع مکانی نامناسب ایستگاه‌ها می‌باشد که این عامل دقت مدل‌های پیش‌بینی را کاهش می‌دهد. همچنین، در حوضه‌هایی که اختلاف ارتفاعی آن زیاد می‌باشد، یک نقطه نمی‌تواند معرف کل خصوصیت هیدرولوژی و توپوگرافی منطقه باشد و این مشکل زمانی که پارامترهای بارش و دما وارد مدل شوند، تشدید می‌گردد. بنابراین، کمبود و توزیع نامناسب ایستگاه‌های هیدرومتری و هواشناسی می‌تواند به عنوان یکی دیگر از موضوعات مهم در مطالعات هیدرولوژیکی ذکر شود. این امر اغلب منجر به کاهش دقت مدل، به خصوص برای پیش‌بینی طولانی مدت می‌شود (Nagler et al., 2016).

بنابراین در این مطالعه برای غلبه بر این مشکل از رویکرد داده سطحی برای دو پارامتر دما و بارش استفاده می‌شود.

بارش

تقسیم منطقه به زیرحوضه‌های کوچک‌تر می‌تواند راه-کاری مناسب برای رفع مشکلات داده‌های ایستگاهی باشد. بنابراین از روش تیسن برپایه ایستگاه‌های بارش برای زیرحوضه‌بندی منطقه استفاده شده است. نهایتاً با در نظر گرفتن مساحت هر زیرحوضه و اعمال وزن مربوط به آن، داده‌های نقطه‌ای، تبدیل به بارش معادل کل حوضه در بازه زمانی مشخص می‌شود.

دما

در این رویکرد، ابتدا با برقراری روابط رگرسیون بین ایستگاه اندازه‌گیری دما (میانگین ماهانه ۲۰ ساله) و کد-ارتفاعی پیکسل ایستگاه مربوطه، رابطه جامعی برای آن حوضه محاسبه می‌شود. نهایتاً با تعمیم این رابطه به کل حوضه، مقدار هر پارامتر در هر پیکسل به دست می‌آید. در گام بعدی، با میانگین‌گیری در کل حوضه، مقدار عددی دما

¹ Adaptive Neuro Fuzzy Inference System

این تحقیق دوره 8 ماهه (نوامبر ۲۰۱۸ تا ژوئن 2019) انتخاب شده است.

این تاریخ بر اساس تطابق تصاویر Sentinel-1 and 2، در دسترس بودن هر دو تصویر، مقدار نویز و عوامل مخرب قابل قبول (اثر، مه و...) انتخاب شده است. به طور کلی مراحل استخراج برف مرطوب به سه بخش تقسیم می‌شوند که به شرح زیر می‌باشد:

sentinel-2

داده های Sentinel-2: Level-1C از سایت Copernicus Open Access Hub دانلود شده و سپس با استفاده از افزونه Sen2cor اصلاحات رادیومتری و اتمسفری تصویر انجام شده است. برای مطالعه حاضر، باندهای ۲، ۳، ۴، ۸ و ۱۱ تصویر cloud confidence، به منظور استخراج کل SCA استفاده شده است

روش هوش مصنوعی - الگوریتم ژنتیک (GA-ANN)

الگوریتم ژنتیک (GA) جزء کارآمدترین روش بهینه‌سازی بوده که در بسیاری از زمینه‌ها استفاده شده است (Agrawal et al., 2021; Reddy et al., 2020). این الگوریتم در مطالعات گسترده‌ای مربوط به مسائل مختلف بهینه‌سازی، تحلیل غیرخطی در حالات محدود و غیرمحدود مورد استفاده قرار می‌گیرد.

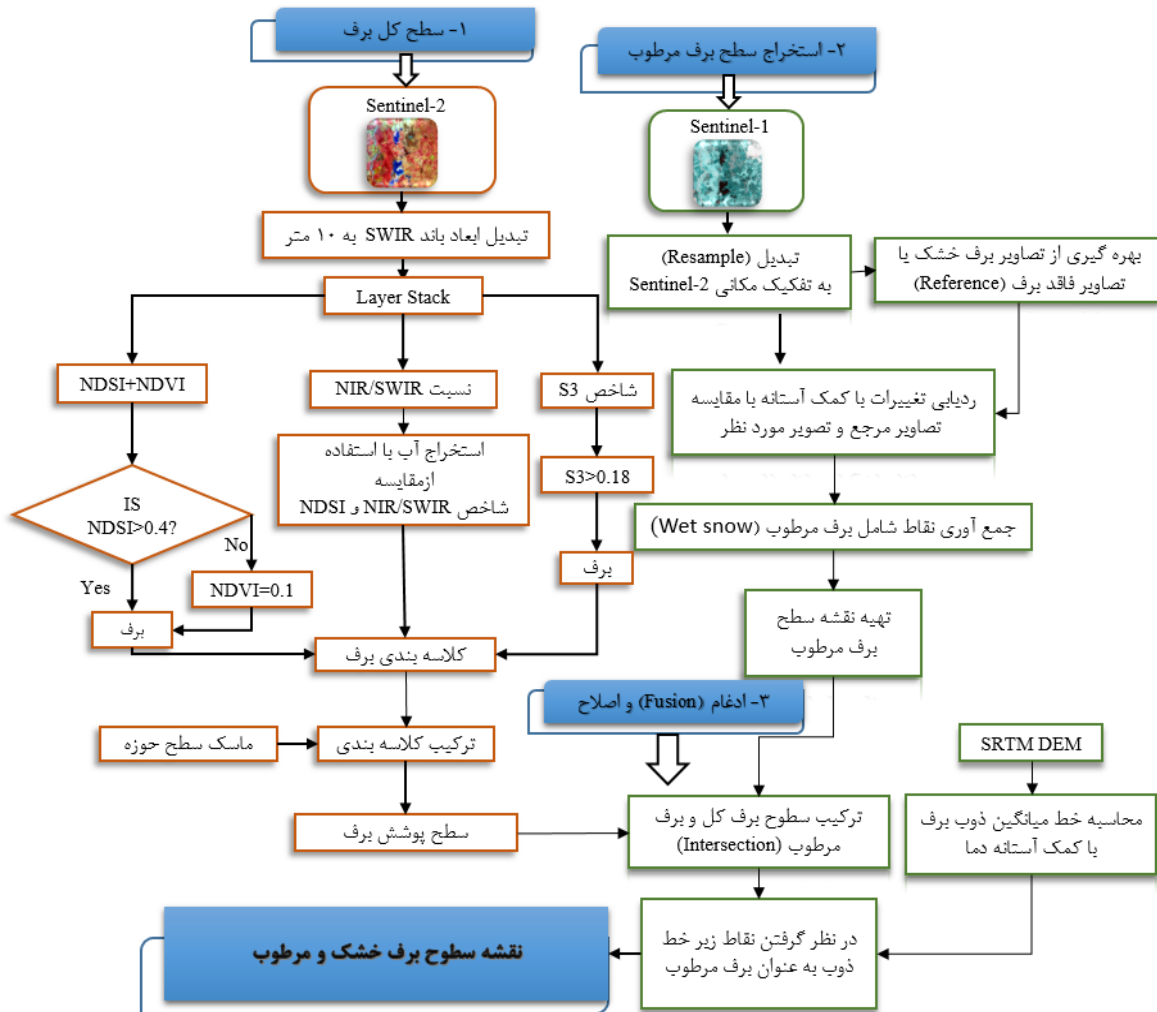
چندین مطالعه از مدل‌های ترکیبی مبتنی بر GA-ANN برای پیش‌بینی جریان استفاده شده است که نشان‌گر برتری این رویکرد نسبت به سایر تکنیک‌های مرسوم بوده است (Adib and Jahanbakhshan, 2013; Zangeneh Sirdari and Zangeneh Sirdari, 2015). در این مطالعه، از تلفیق الگوریتم GA با روش ANN پیش‌خور چند لایه، با یک لایه پنهان، به منظور انتخاب پارامترهای بهینه مدل ANN استفاده شده است. همچنین، روش (Levenberg-Marquardt) برای آموزش ANN استفاده شده است. به منظور دستیابی به یک راه حل بهینه‌کلی و کارآمدتر و اجتناب از گیرافتادن در نقاط بهینه محلی، انتخاب و بهینه‌سازی پارامترها به طور همزمان انجام می‌شود.

ANFIS

سیستم استنتاج عصبی- فازی از ترکیب سیستم فازی، به منظور ارائه دانش، و یک شبکه عصبی استفاده می‌کند. یکی دیگر از مزایای ANFIS این است که می‌تواند فرآیند آموزشی پایدارتری را فراهم کند، زیرا قادر به استفاده از توانایی‌های خودآموزی و حافظه شبکه‌های عصبی می‌باشد (Khazaei Poul et al., 2019). بنابراین شبکه قابلیت یادگیری به منظور تنظیم پارامترهای توابع عضویت و قواعد زبانی به طور مستقیم از داده‌ها را دارا می‌باشد. لذا، این امر منجر به افزایش عملکرد سیستم می‌شود (Wang et al., 2006).

نتایج و بحث

همان‌طور که در بخش مواد و روش‌ها اشاره شد، در این تحقیق از دو سنجنده راداری و نوری Sentinel برای تشخیص برف مرطوب استفاده شده است. بازه مطالعاتی در



شکل (۲): فلوجارت روش پیشنهادی

جدول (۲): معیارهای آماری برای تصاویر بر اساس رویکردهای MV و DS

Date	DS		MV	
	OA (%)	Kappa (%)	OA (%)	Kappa (%)
۲۰۱۸.۱۱.۰۴	۰.۹۱۵	۹۱.۹۵۸	۰.۸۷۹	۸۸.۲۷۹
۲۰۱۸.۱۲.۰۴	۰.۹۲۵	۹۱.۹۵۸	۰.۸۸۸	۸۸.۲۷۹
۲۰۱۸.۱۲.۱۹	۰.۹۳۵	۹۱.۹۵۸	۰.۸۹۸	۸۸.۲۷۹
۲۰۱۹.۰۱.۱۳	۰.۹۱۵	۹۱.۹۵۸	۰.۸۷۹	۸۸.۲۷۹
۲۰۱۹.۰۱.۲۳	۰.۸۲۸	۸۶.۹۵۰	۰.۷۹۵	۸۳.۴۷۲
۲۰۱۹.۰۲.۰۷	۰.۸۹۹	۹۱.۵۷۶	۰.۸۶۳	۸۷.۹۱۳
۲۰۱۹.۰۲.۲۲	۰.۹۲۱	۹۱.۵۴۶	۰.۸۸۴	۸۷.۸۸۴
۲۰۱۹.۰۳.۱۵	۰.۹۱۵	۹۱.۳۶۱	۰.۸۷۹	۸۷.۷۰۶
۲۰۱۹.۰۳.۲۹	۰.۹۰۲	۹۱.۵۷۸	۰.۸۶۶	۸۷.۹۱۵
۲۰۱۹.۰۴.۰۸	۰.۸۶۸	۸۹.۹۵۳	۰.۸۳۳	۸۶.۳۵۵
۲۰۱۹.۰۴.۲۳	۰.۹۰۶	۹۰.۸۶۷	۰.۸۷۰	۸۷.۲۳۳
۲۰۱۹.۰۳.۰۵	۰.۸۸۴	۹۰.۲۳۴	۰.۸۴۹	۸۶.۶۲۴
۲۰۱۹.۰۶.۱۷	۰.۸۸۶	۹۰.۰۵۹	۰.۸۵۱	۸۶.۴۵۶

جدول (۱): دمای ماهانه سطحی

Month	Equation
January	$y=12.68 - (0.007 \times x)$
February	$y=12.52 - (0.006 \times x)$
March	$y=16.48 - (0.006 \times x)$
April	$y=19.85 - (0.005 \times x)$
May	$y=26.73 - (0.006 \times x)$
June	$y=34.99 - (0.008 \times x)$
July	$y=37.50 - (0.007 \times x)$
August	$y=37.01 - (0.007 \times x)$
September	$y=33.66 - (0.007 \times x)$
October	$y=28.01 - (0.006 \times x)$
November	$y=19.58 - (0.006 \times x)$
December	$y=13.91 - (0.006 \times x)$

وجود لحاظ‌شدن سایر شاخص‌ها، پیکسل به عنوان برف تلقی نخواهد شد (Hagolle et al., 2021).

نهایتاً با اعمال شاخص‌ها و آستانه‌های برف‌سنجی، تصویر باینری شامل: برف و غیربرف به دست می‌آید. اعمال آستانه‌های متداول برای مناطق کوهستانی، با توجه به مختصات جغرافیایی، با خطا همراه می‌باشد، لذا در این مطالعه، به منظور افزایش دقت و اعتمادپذیری مدل برای منطقه موردنظر از روش‌های نوین طبقه‌بندی (شامل: SVM، ANN، Adaboost و KNN) نیز استفاده می‌شود. در روش‌های مرسوم، برای آموزش روش‌های طبقه‌بندی از رویکرد ROI به منظور انتخاب مناطق آموزش استفاده می‌شود. این روش شامل برخی مسائل چالش برانگیز از جمله: خطاهای عملیاتی، کمی و کیفی می‌باشد.

در این مطالعه، برای ارتقا کیفی و کمی داده‌های آموزش از تشکیل پنجره‌ای به ابعاد ۵۰۰ پیکسل در ۵۰۰ استفاده می‌شود. با این رویکرد نوین، کمیت و کیفیت پیکسل‌های انتخابی بیشتر شده و در نتیجه، کمک قابل توجهی به آموزش روش‌های طبقه‌بندی می‌شود. به منظور تهیه نقشه پوشش برفی حاصل از روش‌های طبقه‌بندی‌کننده، رویکرد ادغام روش‌ها Data Fusion با بهره‌گیری از دو روش

به‌منظور اعمال فیلترهای پردازش تصاویر، باندهای عملی می‌بایست دارای تفکیک مکانی واحد (resampling) باشد. بدین منظور از روش LMVM برای تبدیل تفکیک مکانی ۲۰ متری به ۱۰ متری استفاده شده است. کل پردازش داده‌ها با استفاده از نرم افزار OrfeoToolBox که یک پردازشگر تصاویر سنجنش از راه دور معتبر است، انجام شده است.

پس از فرآیند resampling پردازش تصاویر توسط شاخص‌های: NDSI، NIR/SWIR، NDVI و S₃ انجام می‌شود. با توجه به روش پیشنهادی (شکل ۲)، پس از اعمال آستانه بر روی شاخص‌ها، تصاویر باینری (پیکسل‌های برفی و غیر برف) به دست می‌آیند.

هم‌چنین به منظور افزایش دقت تشخیص برف، از بازتاب باندهای B4 و B8 نیز استفاده شده است. رفع ابر و مه به عنوان مهم‌ترین عامل خطا ضروری به نظر می‌رسد. طبیعتاً، تصویر با پوشش ابری بالای ۹۰ درصد در مطالعات برف‌سنجی استفاده نمی‌شود و اگر پوشش ابر بیش از ۵۰ درصد و بازتاب $B8 > 0.3$ باشد، پیکسل به عنوان برف در نظر گرفته می‌شود. علاوه بر این، اگر بازتاب $B4 < 0.2$ باشد، با



منطقه ای (جدول ۱) به DEM اعمال شده و در نهایت میانگین دمای ماهانه روی هر پیکسل به دست آمد.

به منظور پیاده سازی دما بر تصویر، از رویکرد اعمال دمای آستانه (صفر درجه) بر روی تصویر نهایی، SCA(I,II)، استفاده شده است (SCA(T)). این رویکرد، سایر مناطق که به اشتباه به عنوان برف مرطوب در نظر گرفته شده است را حذف می‌کند. (شکل ۳). تصویری با دقت مطلوب و کارآمد برای مدل پایش برف در حال ذوب را ارائه می‌دهد، که حاصل اعمال رویکرد شاخص‌های برف‌سنجی، ادغام روش‌های طبقه‌بندی، ادغام تصاویر راداری و نوری و اعمال پارامتر دما می‌باشد.

پس از پردازش و استخراج SCA، سطح پوشش برف در حالت‌های مختلف مورد ارزیابی قرار گرفت. برای بررسی و تحلیل تصاویر پردازش شده در حالت‌های مختلف، از ایستگاه خروجی حوضه (سد لتیان) در دوره ۸ ماهه نیز استفاده شد. (شکل ۴) تغییرات روند SCA (II) را نشان می‌دهد، همان‌طور که مشاهده می‌شود بیشترین مقدار SCA (II) در ماه‌های ژانویه و فوریه رخ داده است. این روند به دلیل بارش حداکثر منطقی به نظر می‌رسد. ناسازگاری بین روند SCA (II) و خروجی حوضه باعث ایجاد خطا در مدل‌های پیش‌بینی و هیدرولوژیکی می‌شود. در واقع، عدم تطابق روند داده‌های زمینی و ماهواره‌ای، منجر به چالش‌هایی در مطالعات برف‌سنجی می‌شود.

همان‌طور که قبلاً اشاره شد، SCA (II) برف خشک و مرطوب را به طور هم‌زمان در نظر می‌گیرد. سطح برف خشک در رواناب کوتاه‌مدت (روزانه) مشارکت نمی‌کند. بنابراین، SCA (II) منجر به بیش‌برآورد برای مدل برف-سنجی کوتاه‌مدت می‌شود. با توجه به مشارکت برف مذاب در رواناب خروجی حوضه با توجه به شکل ۴، فاصله زمانی حداکثر مقدار SCA(II) و پیک جریان خروجی حوضه بیش از ۲ ماه می‌باشد که طبیعتاً، این امر نشان‌دهنده ضعف استفاده از SCA(II) در مدل پیش‌بینی کوتاه‌مدت جریان می‌باشد. بنابراین، این نقص باید به کمک یک رویکرد موثر اصلاح شود. از این رو، SCA (I)، که برف مرطوب را از برف خشک جدا می‌کند ارائه شده است.

MV و DS در نظر گرفته شده است. طبق (جدول 2)، دقت و کارایی روش‌های ادغام براساس دو معیار اساس دو معیار OA و ضریب کاپا سنجیده شده است. نتایج، نشان دهنده برتری مدل DS نسبت به مدل MV می‌باشد. در نهایت، کل تصویر سطح پوشش برف (برف خشک و مرطوب) حاصل از سنجنده Sentinel-2 به روش DS، تحت عنوان SCA (II) در نظر گرفته می‌شود.

sentinel-1

بعد از فرایند پیش‌پردازش تصاویر، با بهره‌گیری از نسبت $(\sigma_{ws}^0 / \sigma_{ref}^0)$ ، پوشش برف مرطوب به دست می‌آید (شکل ۲). برای این منظور، براساس مطالعات انجام شده (Snapir et al., 2019) و نقاط کنترل (سد و مناطق شهری...) پیکسل‌هایی با مقدار نسبت $< -2 \text{ dB} / \sigma_{ref}^0$ شهری (σ_{ws}^0) به عنوان برف مرطوب علامت‌گذاری شده و تحت عنوان SCA(I) در نظر گرفته می‌شود.

ادغام داده

با اعمال ماسک برف مرطوب SCA(I) بر روی پوشش برف کلی SCA(II)، پوشش برف مرطوب SCA(I,II) استخراج می‌شود.

پوشش SCA(II) خارج از ماسک برف مرطوب SCA (I) به عنوان برف خشک در نظر گرفته می‌شود. همچنین، پیکسل‌های برف مرطوب خارج از SCA(II) که به اشتباه توسط Sentinel-1 به عنوان برف شناسایی شده‌اند، به عنوان پیکسل‌های بدون برف در نظر گرفته می‌شوند. از لحاظ هیدرولوژیکی، پارامتر دما بر روند ذوب برف تاثیر بسزایی دارد، لذا در نظرگرفتن دما در استخراج نقشه برف مرطوب بر دقت مدل تاثیر بسزایی خواهد داشت.


به منظور استخراج نقشه ذوب برف که نقش اساسی در رواناب حوضه دارد، از پارامتر دما استفاده شده است. بدین منظور از تصاویر با وضوح بالا SRTM1 sec HGT به منظور تشکیل DEM منطقه استفاده شد. سپس روابط دمای


می‌رسد. در ماه‌های سرد (نوامبر تا فوریه) به دلیل عدم ذوب برف، جریان پایه نقش اساسی در جریان حوضه دارد. برعکس در ماه‌های گرم، ذوب برف آغاز شده و وارد رواناب حوضه می‌شود. روند ذوب برف به تغییرات درجه حرارت بستگی دارد، بنابراین با معرفی رویکرد جدید SCA(T) برف مشارکتی در رواناب حوضه مدل‌سازی می‌شود (شکل ۴).

نتایج نشان‌دهنده بهبود قابل توجه مدل پیشنهادی است. به عنوان مثال، روند ذوب برف و رواناب حوضه تا حدودی مشابه شده و این شباهت‌ها در مقدار پیک (ماه آوریل) نیز مشاهده می‌شود. همچنین فاصله زمانی بین پیک هر دو نمودار، SCA(T) و رواناب حوضه، به ۳ روز کاهش یافته که این فاصله زمانی برای اتصال رواناب حاصل از ذوب برف به خروجی حوضه منطقی می‌باشد. همچنین، ثبات مدل و هم‌خوانی با تغییرات روند جریان، به ویژه در مقدار پیک، به طور قابل توجهی بهبود یافته‌است. بنابراین، از مقادیر پارامتر ورودی، برای پیش بینی کوتاه مدت حوضه استفاده خواهد شد

مقدار SCA (I) در مقایسه با SCA(II) در فصل سرد به طور قابل توجهی کاهش یافته است، در صورتی که این روند در ماه‌های گرم (آوریل-ژوئیه) معکوس شده است، به این معنی که خروجی SCA (I) برف بیشتری را نشان می‌دهد. لذا، بکارگیری SCA(I) برای مدل پیش‌بینی در فصول گرم غیر منطقی به نظر می‌رسد. از این رو، برای حل این مشکل، ادغام تصاویر نوری و راداری SCA(I,II) پیشنهاد شده - است. نتایج نشان می‌دهد که مقدار SCA (I,II) در مقایسه با تخمین SCA(I) و SCA(II) کاهش معناداری داشته - است، زیرا اشتراکات هر دو تصویر را در نظر گرفته است، بنابراین خطا، به خاطر اینکه از مزایای هر دو تصویر در تهیه نقشه برف‌سنجی استفاده می‌شود، تا حدودی تعدیل شده است. بنابراین، برآورد مطلوب‌تری از سهم ذوب برف در جریان کوتاه مدت ارائه می‌دهد. اما همچنان، روند تغییرات پوشش برفی با رواناب حوضه مخصوصاً در ماه‌های سرد (نوامبر تا فوریه) تطابق ندارد.

همان‌طور که گفته شد، تغییرات ذوب برف به پارامتر دما بستگی دارد، بنابراین در نظر گرفتن پارامتر دما در تخمین سطح پوشش برف، SCA (T)، اجتناب ناپذیر به نظر





شکل (۳): روند تغییرات پوشش برف مرطوب، پیکسل‌های سفید به برف اشاره دارند و پیکسل‌های سیاه بدون برف را معرفی می‌کنند.

مدل پیش بینی

براساس ارزیابی های اولیه، خروجی حوضه لتیان، ورودی سد لتیان، برای مدل پیش‌بینی جریان، به منظور اتخاذ سیاست‌های بهره‌برداری و اتخاذ تصمیم‌های مدیریت منابع آب انتخاب گردید.

به منظور در نظر گرفتن پارامترهای موثر در رواناب کوتاه مدت، داده‌های روزانه جریان با توالی سه روزه (Shiri and Kisi, 2010) (Q_t : m^3/sec)، بارش روزانه (P_t : mm)، که با روش تیسن به صورت سطحی محاسبه شده، و مقادیر روزانه (SCA(T): Km^2) برای دوره ۸ ماهه (2018-2019) استفاده شده‌است. براساس دوره بلندمدت، دوره برفگیر حوضه محدوده نوامبر تا جولای می‌باشد.

براساس داده‌های سری زمانی بلندمدت، جریان اندازه‌گیری شده در حوضه رابطه معناداری با تغییرات فصول سال دارد. بنابراین، بکارگیری یک پارامتر فصلی به منظور آموزش بهتر، ضروری به نظر می‌رسد. بدین منظور، از تقویم سالانه برای در نظرگیری اثرات تغییرات فصلی بارندگی بر رواناب تحت عنوان شاخص فصلی استفاده شده است. شاخص فصلی شامل دو سری زمانی، که نماینده ۱۲ ماه چرخه‌ی سال هستند، در نظر گرفته شده است. این دو سری با یک جفت منحنی سینوسی و کسینوس نوسانی نشان داده شده است. برای هر ماه، یک جفت داده منحصر به فرد (t_1, t_2) وجود دارد، بنابراین، کل چرخه سالانه با ۱۲ جفت داده سینوسی نشان داده می‌شود (شکل ۵).



GA-ANN

در این مطالعه، برای تعداد نسل (n) که به عنوان معیار توقف در نظر گرفته شده است، مقدار ۵۰ در نظر گرفته می‌شود. مدل ترکیبی GA-ANN، راه‌حل بهینه نهایی را با توجه به معیار توقف ارائه داده‌است. حداقل مقدار RMSE برابر با ۰,۰۵۲۵۳ بوده که بهترین برازش در بین تمام نسل‌ها می‌باشد. همچنین، مقدار تابع تناسب متوسط هر نسل GA پس از تعداد نسل ۱۰ بدون تغییر باقی مانده است. براساس آزمون و خطا، تعداد ۳۱ نوروں به عنوان لایه پنهان بهترین عملکرد را دارا می‌باشد. تابع فعال‌ساز پیوسته و یکنواخت، tan-sigmoidal، به طور بهینه برای لایه خروجی و لایه پنهان انتخاب شده و همچنین، مقدار بهینه $\mu=43$ در الگوریتم لونیبرگ-مارکوارت برای مدل GA-ANN انتخاب شده است.

(جدول ۳) عملکرد مدل براساس شاخص‌های مختلف آماری را نشان می‌دهد. همانطور که انتظار می‌رفت، عملکرد مدل در دوره تست با افزودن پارامترهای جدید بهبود می‌یابد. این روند منطقی به نظر می‌رسد، زیرا با افزایش پارامترها جزئیات و اعتمادپذیری مدل ارتقا یافته و در نتیجه، جامعیت مدل بهبود می‌یابد. به عنوان مثال، ضریب همبستگی R در مدل (IV) بهبود قابل توجه 0.34 نسبت به مدل (I) را نشان می‌دهد. روند مشابه در سایر شاخص‌های آماری نیز مشاهده می‌شود. لذا می‌توان نتیجه گرفت، تأثیر پارامترهای (دبی، بارش و برف) به طور هم‌زمان، تصویر قابل اعتمادی از مدل پیشنهادی ارائه می‌دهد

در این مطالعه، با توجه به نوسانات دبی حوضه (شکل ۶) روش اعتبار سنجی K-fold، با توجه به پویایی و پوشش جامع داده‌ها، در مرحله آموزش-تست مدل استفاده شده است. در این روش با تکرار الگوریتم به میزان K بار، $1/K$ داده برای تست و مابقی برای آموزش داده استفاده می‌شود. (شکل ۶).

مدل پیش‌بینی به منظور بررسی تاثیر پارامترها در دقت و اعتبار مدل، طی چهار مرحله تدریجی تکمیل می‌شود. ابتدا فقط از داده‌های سه جریان آخر استفاده می‌شود

(مدل (I))، سپس بارش روزانه به مدل اضافه می‌شود (مدل (II))، درگام بعد سطح برف در حال ذوب (مدل (III)) لحاظ شده و نهایتاً شاخص فصلی به عنوان پارامتر نهایی به مدل افزوده می‌شود (مدل (IV)).


$$Q_{t+1} = f\left(\sum_{k=0}^2 Q_{t-k}\right) \quad (I)$$

$$Q_{t+1} = f\left(\sum_{k=0}^2 Q_{t-k}, P_t\right) \quad (II)$$


$$Q_{t+1} = f\left(\sum_{k=0}^2 Q_{t-k}, P_t, SAC(T)_t\right) \quad (III)$$

$$Q_{t+1} = f\left(\sum_{k=0}^2 Q_{t-k}, P_t, SAC(T)_t, t_1, t_2\right) \quad (IV)$$


هدف مدل پیش‌بینی، برآورد جریان روزانه خروجی حوضه در گام زمانی t+1 می‌باشد.



شکل (۴): روند تغییرات روزانه SCA و خروجی حوضه مطالعاتی



شکل (۵): تغییرات فصلی به صورت دو سری زمانی



شکل (۶): ساختار روش K-fold



همچنین براساس شاخص‌های آماری برتری کامل روش ANFIS نسبت به GA-ANN بطور مشهود مشخص است. این برتری در مدل‌های پیچیده‌تر (مدل IV) با بهره‌گیری از داده‌های ایستگاهی و ماهوره‌ای بیشتر نمایان می‌شود. این برتری نشانگر عملکرد برتر روش ANFIS نسبت به ANN در مدل‌های پیش‌بینی بوده که به خاطر بهره‌گیری از مزایای روش فازی (دخاله دانش بشری) و شبکه عصبی (روند آموزش شبکه) می‌باشد.

در تحقیق حاضر، با بهره‌گیری از رویکرد ادغام تصاویر مرئی و راداری و اعمال فیلتر دما، بیش‌برآورد و خطای مدل پیش‌بینی به حداقل رسید. (شکل ۷) عملکرد مدل پیش-بینی روزانه در دو حالت زیر را نشان می‌دهد:

۱) استفاده از پارامتر SCA(II)، تصاویر نوری.
۲) استفاده از پارامتر SCA(T)، حاصل از ادغام تصاویر ماهواره‌ای مرئی-راداری و فیلتر دما.

همانطور که در (شکل ۷) ملاحظه می‌شود، عملکرد مدل (IV) در هر دو روش پیش‌بینی (ANFIS و GA-ANN) به میزان قابل توجهی بهبود یافته است که این بهبود در مدل ANFIS بیشتر مشهود می‌باشد. نقاط بیشینه و کمینه جریان، به دلیل این که در سیاست‌های تصمیم‌گیری و برنامه‌ریزی مدیریت منابع آب مورد توجه قرار گرفته است، جزء نقاط بحرانی می‌باشد. بنابراین قدرت و دقت مدل پیش‌بینی در این نقاط سنجیده می‌شود. همان‌طور که ملاحظه می‌شود، مدل ANFIS-SCA(T) بهترین عملکرد را در شناسایی نقاط پیک از خود نشان داده است و تا حد مطلوبی این خواسته را برآورد کرده است. بنابراین رویکرد استفاده از ادغام تصاویر ماهواره‌ای و اعمال فیلترها در امر اعتمادپذیری و کارایی مدل مثر ثمر می‌باشد.

نتیجه‌گیری

این تحقیق، روشی برای توسعه مدل‌های دقیق پیش‌بینی جریان کوتاه‌مدت حوضه لتیان با استفاده از روش‌های ترکیبی GA-ANN و نو-فازی ANFIS ارائه داده است. به منظور ارائه مدلی کارآمد با اعتمادپذیری بالا، استفاده از داده‌های هیدرومتری (دبی، بارش، دما، پارامترهای اندازه‌گیری شده برف (چگالی، ارتفاع...))، در کنار

همچنین، نتایج نشان داد با افزودن پارامتر شاخص فصلی به مدل پیش‌بینی، روند آموزش مدل بهبود یافته و باعث ارتقا شاخص‌های آماری در مرحله تست می‌شود. به عنوان مثال، خطای RMSE در مدل (IV) با بهره‌گیری از شاخص فصلی حدود ۲۲٪ بهبود عملکرد در مقایسه با مدل (III) نشان می‌دهد. این بهبود نشان‌دهنده تاثیر بسزای شاخص فصلی در روند آموزش شبکه می‌باشد.

ANFIS

در مدل‌های نروفازی، توابع عضویت متفاوتی مورد استفاده قرار می‌گیرد که در این مطالعه از تابع عضویت گوسین استفاده شد که به صورت زیر تعریف می‌شود.

$$f(x, \sigma, c) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (8)$$


که c عبارتست از مرکز تابع عضویت و σ انحراف معیار دسته را نشان می‌دهد.

مراحل ارزیابی مدل ANFIS همانند مراحل ارزیابی مدل GA-ANN می‌باشد (جدول ۳). با توجه به نتایج مدل، روند بهبود عملکرد مدل ANFIS با افزایش پارامترها، در مرحله تست، برای گام پیش‌بینی روزانه مشاهده می‌شود. بطوری که شاخص RMSE برای مدل (IV) به میزان ۱۸۵٪ بهبود عملکرد در مقایسه با مدل (I) از خود نشان می‌دهد. این روند برای شاخص‌های R و NASH نیز مشاهده می‌شود. با توجه به نتایج مدل‌های ANFIS و GA-ANN می‌توان برداشت نمود که افزودن پارامتر به مدل پیش‌بینی منجر به ارتقا عملکرد مدل می‌شود و مدل را قادر به شناسایی بیشتر جزئیات می‌سازد. در مدل ANFIS نیز هم-چون مدل شبکه عصبی، که در بالا بحث شد، عملکرد مدل با افزودن پارامتر فصلی بهبود چشمگیری پیدا می‌کند، بطوریکه حداقل مقدار شاخص RMSE در مدل بدون پارامتر فصلی ۱۰۴۳ می‌باشد که این مقدار با لحاظ کردن پارامتر فصلی به مقدار حدود ۶ واحد کاهش یافته است. این بهبود در شاخص‌های R و NASH نیز مشهود می‌باشد. با توجه به نتایج مدل می‌توان بیان نمود که پارامتر فصلی همانند پارامترهای مرسوم در مدل‌های پیش‌بینی (بارش، جریان،...) ضروری به نظر می‌رسد.





تصاویر ماهواره‌ای به عنوان پارامتر ورودی برای مدل معرفی شد.

a)



b)





شکل (۷): عملکرد مدل پیش‌بینی در (a) مدل GA-ANN با استفاده از سطح پوشش SCA(II) (b) مدل GA-ANN با استفاده از سطح پوشش SCA(II) (c) مدل ANFIS با استفاده از سطح پوشش SCA(II) (d) مدل ANFIS با استفاده از سطح پوشش SCA(T) برف در حال ذوب

برف در حال ذوب SCA(T)

جدول (۳): عملکرد مدل ANFIS و GA-ANN در مرحله تست

Forecast intervals	Model	GA-ANN			ANFIS		
		R	RMSE	NASH	R	RMSE	NASH
Daily	(I)	۰.۵۲	۹.۶۸	۰.۴	۰.۵۳	۱۳.۰۹	۰.۵۲
	(II)	۰.۷۱	۵.۷۶	۰.۶۵	۰.۶۵	۱۲.۸۸	۰.۵
	(III)	۰.۸۵	۶.۴۷	۰.۷۷	۰.۸۹	۱۰.۴۳	۰.۵۱
	(IV)	۰.۸۶	۵.۰۵	۰.۷۸	۰.۹۱	۴.۵۹	۰.۸۲

عنوان پارامتر موثر در رواناب مورد توجه قرار گرفت. بدین منظور، رویکرد ادغام تصاویر Sentinel-1 and 2 در کنار شاخص‌های تفکیک برف و بهره‌گیری از روش‌های نوین طبقه‌بندی به همراه فیلتر آستانه دما منجر به تهیه نقشه برف در حال ذوب تحت عنوان SCA(T) گردید.

همچنین، اطلاعات فصلی که باعث بهبود روند آموزش مدل می‌شود، به عنوان رویکرد نوین در این مطالعه به مدل پیشنهادی اضافه شد.

برآورد مناسب و مستمر برف (پوشش برف) به منظور پایش روند پوشش برف و در نظر گرفتن برف مرطوب به



- نتایج نشان داد که استفاده از اطلاعات فصلی به عنوان پارامتر ورودی می‌تواند نتایج مدل‌های پیش‌بینی را افزایش دهد.
- مطالعات پیشین در زمینه هیدرولوژی با تاکید بر تصاویر پوشش برف کلی، حاصل از سنجنده نوری، بوده که منجر به بیش برآورد نتایج و تاخیر زمانی در مدل‌سازی شده است. نتایج نشان داد بهره‌گیری از پوشش برف موثر در رواناب، منجر به هم‌خوانی مطلوب روند جریان با پوشش برف و برآورد دقیق مدل برف‌سنجی شده است. همچنین عملکرد مدل در جریان‌های بیشینه و کمینه با بهره‌گیری از SCA(T) به طور قابل توجه بهبود یافت.
- توزیع نامناسب مکانی ایستگاه‌های زمینی مشکل عمده مدل‌های هیدرولوژی می‌باشد. لذا، استفاده از تبدیل حوضه‌ای داده‌های ایستگاهی، برآورد قابل اعتمادی از پارامتر موردنظر در سطح حوضه می‌دهد. در این مطالعه، این رویکرد برای پارامتر دما و بارش استفاده شد.
- روش‌های پیشنهادی برای حوضه مطالعاتی اعمال شد و نتایج زیر به دست آمد:
- به طور کلی، روش ANFIS در پیش‌بینی جریان از GA-ANN عملکرد بهتری داشته است.
- استخراج پارامتر حاصل از تصاویر ماهواره‌ای و استفاده از آن در کنار سایر داده‌های ایستگاهی نتایج پیش‌بینی جریان در هر دو مدل GA-ANN و ANSIF را بهبود بخشید.

منابع

وزارت نیرو، شرکت مدیریت منابع آب ایران، شرکت آب منطقه‌ای تهران. ۱۳۸۸. طرح سامان دهی آبهای سطحی جنوب تهران (مطالعات کمی و کیفی)، جلد هشتم: گزارش مطالعات آب‌های سطحی جنوب تهران (مطالعات کمی و کیفی) کد گزارش: TWM/DWRP-02.

Adib, A. and Jahanbakhshan, H., 2013. Stochastic approach to determination of suspended sediment concentration in tidal rivers by artificial neural network and genetic algorithm. *Canadian Journal of Civil Engineering*, 40(4), pp.299-312.

Agrawal, S., Sarkar, S., Alazab, M., Maddikunta, P.K.R., Gadekallu, T.R. and Pham, Q.V., 2021. Genetic CFL: hyperparameter optimization in clustered federated learning. *Computational Intelligence and Neuroscience*, 2021.

Besic, N., Vasile, G., Dedieu, J.P., Chanussot, J. and Stankovic, S., 2014. Stochastic approach in wet snow detection using multitemporal SAR data. *IEEE Geoscience and Remote Sensing Letters*, 12(2), pp.244-248.

Brombacher, J., Reiche, J., Dijkma, R. and Teuling, A.J., 2020. Near-daily discharge estimation in high latitudes from Sentinel-1 and 2: A case study for the Icelandic Þjórsá river. *Remote sensing of Environment*, 241, p.111684.

Chang, F.J. and Chang, Y.T., 2006. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. *Advances in water resources*, 29(1), pp.1-10.

Cornet, Y., de Béthune, S., Binard, M., Muller, F., Legros, G. and Nadasdi, I., 2001, November. RS data fusion by local mean and variance matching algorithms: their respective efficiency in a complex urban context. In *IEEE/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas* (Cat. No. 01EX482) (pp. 105-111). IEEE.

Conde, V., Nico, G., Mateus, P., Catalão, J., Kontu, A. and Gritsevich, M., 2019. On the estimation of temporal changes of snow water equivalent by spaceborne SAR interferometry: A new application for the Sentinel-1 mission. *Journal of Hydrology and Hydromechanics*.



- Dariane, A.B. and Azimi, S., 2016. Forecasting streamflow by combination of a genetic input selection algorithm and wavelet transforms using ANFIS models. *Hydrological Sciences Journal*, 61(3), pp.585-600.
- De Gregorio, L., Günther, D., Callegari, M., Strasser, U., Zebisch, M., Bruzzone, L. and Notarnicola, C., 2019. Improving SWE estimation by fusion of snow models with topographic and remotely sensed data. *Remote Sensing*, 11(17), p.2033.
- Dempster, A.P., 2008. Upper and lower probabilities induced by a multivalued mapping. *Classic works of the Dempster-Shafer theory of belief functions*, 219(2), pp.57-72.
- Dietz, A.J., Kuenzer, C., Gessner, U. and Dech, S., 2012. Remote sensing of snow—a review of available methods. *International Journal of Remote Sensing*, 33(13), pp.4094-4134.
- Esmaeelzadeh, S.R., Adib, A. and Alahdin, S., 2015. Long-term streamflow forecasts by Adaptive Neuro-Fuzzy Inference System using satellite images and K-fold cross-validation (Case study: Dez, Iran). *KSCE Journal of Civil Engineering*, 19, pp.2298-2306.
- Esmaeelzadeh, R., Golian, S., Sharific, S. and Bigdel, B., 2021. Enhanced Long-term and Snow-based Streamflow Forecasting by Artificial Intelligent Methods Using Satellite Imagery and Seasonal Information. *Russian Meteorology and Hydrology*, 46, pp.396-402.
- Freund, Y., 1995. Boosting a weak learning algorithm by majority. *Information and computation*, 121(2), pp.256-285.
- Hagolle, O., Colin, J., Coustance, S., Kettig, P., d'Angelo, P., Auer, S., Doxani, G. and Desjardins, C., 2021. Sentinel-2 surface reflectance products generated by CNES and DLR: methods, validation and applications. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp.9-15.
- Jain, A., Kumar Varshney, A. and Chandra Joshi, U., 2001. Short-term water demand forecast modelling at IIT Kanpur using artificial neural networks. *Water resources management*, 15, pp.299-321.
- Keller, J.M., Gray, M.R. and Givens, J.A., 1985. A fuzzy k-nearest neighbor algorithm. *IEEE transactions on systems, man, and cybernetics*, (4), pp.580-585.
- Khazaei Poul, A., Shourian, M. and Ebrahimi, H., 2019. A comparative study of MLR, KNN, ANN and ANFIS models with wavelet transform in monthly stream flow prediction. *Water Resources Management*, 33, pp.2907-2923.
- Kuncheva, L.I., Whitaker, C.J., Shipp, C.A. and Duin, R.P., 2003. Limits on the majority vote accuracy in classifier fusion. *Pattern Analysis & Applications*, 6, pp.22-31.
- Liu, Y., Ye, L., Qin, H., Hong, X., Ye, J. and Yin, X., 2018. Monthly streamflow forecasting based on hidden Markov model and Gaussian Mixture Regression. *Journal of Hydrology*, 561, pp.146-159.
- Nagler, T. and Rott, H., 2000. Retrieval of wet snow by means of multitemporal SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 38(2), pp.754-765.
- Nagler, T., Rott, H., Ripper, E., Bippus, G. and Hetzenecker, M., 2016. Advancements for snowmelt monitoring by means of Sentinel-1 SAR. *Remote Sensing*, 8(4), p.348.
- Negi, H.S., Kulkarni, A.V. and Semwal, B.S., 2009. Estimation of snow cover distribution in Beas basin, Indian Himalaya using satellite data and ground measurements. *Journal of Earth System Science*, 118, pp.525-538.
- Nagajothi, V., Priya, M.G. and Sharma, P., 2019. Snow cover estimation of western himalayas using sentinel-2 high spatial resolution data. *Indian Journal of Ecology*, 46(1), pp.88-93.
- Nourani, V., Baghanam, A.H., Adamowski, J. and Kisi, O., 2014. Applications of hybrid wavelet-artificial intelligence models in hydrology: a review. *Journal of Hydrology*, 514, pp.358-377.
- Orlíková, L. and Horák, J., 2019, May. Land cover classification using sentinel-1 SAR data. In 2019 International Conference on Military Technologies (ICMT) (pp. 1-5). IEEE.
- Reddy, G.T., Reddy, M.P.K., Lakshmana, K., Rajput, D.S., Kaluri, R. and Srivastava, G., 2020. Hybrid genetic algorithm and a fuzzy logic classifier for heart disease diagnosis. *Evolutionary Intelligence*, 13, pp.185-196.



- Salzano, R., Salvatori, R., Valt, M., Giuliani, G., Chatenoux, B. and Ioppi, L., 2019. Automated classification of terrestrial images: the contribution to the remote sensing of snow cover. *Geosciences*, 9(2), p.97.
- Shimamura, Y., Izumi, T. and Matsuyama, H., 2006. Evaluation of a useful method to identify snow-covered areas under vegetation-comparisons among a newly proposed snow index, normalized difference snow index, and visible reflectance. *International journal of remote sensing*, 27(21), pp.4867-4884.
- Shiri, J. and Kisi, O., 2010. Short-term and long-term streamflow forecasting using a wavelet and neuro-fuzzy conjunction model. *Journal of Hydrology*, 394(3-4), pp.486-493.
- Snapir, B., Momblanch, A., Jain, S.K., Waite, T.W. and Holman, I.P., 2019. A method for monthly mapping of wet and dry snow using Sentinel-1 and MODIS: Application to a Himalayan River basin. *International Journal of Applied Earth Observation and Geoinformation*, 74, pp.222-230.
- Strobl, R.O. and Forte, F., 2007. Artificial neural network exploration of the influential factors in drainage network derivation. *Hydrological Processes: An International Journal*, 21(22), pp.2965-2978.
- Stiles, W. H., & Ulaby, F. T., 1980. The active and passive microwave response to snow parameters: 1. Wetness. *Journal of Geophysical Research: Oceans*, 85(C2), pp.1037-1044.
- Tsai, Y.L.S., Dietz, A., Oppelt, N. and Kuenzer, C., 2019. Remote sensing of snow cover using spaceborne SAR: A review. *Remote Sensing*, 11(12), p.1456.
- Tsai, Y.L.S., Dietz, A., Oppelt, N. and Kuenzer, C., 2019. Wet and dry snow detection using Sentinel-1 SAR data for mountainous areas with a machine learning technique. *Remote Sensing*, 11(8), p.895.
- Tsai, Y.L.S., Dietz, A., Oppelt, N. and Kuenzer, C., 2019. A combination of PROBA-V/MODIS-based products with Sentinel-1 SAR data for detecting Wet and Dry snow cover in mountainous areas. *Remote Sensing*, 11(16), p.1904.
- Uysal, G. and Şorman, A.Ü., 2017. Monthly streamflow estimation using wavelet-artificial neural network model: A case study on Çamlıdere dam basin, Turkey. *Procedia computer science*, 120, pp.237-244.
- Vapnik, V., 1998. *Statistical Learning Theory*: New York etc.
- Wang, Z., Palade, V. and Xu, Y., 2006, September. Neuro-fuzzy ensemble approach for microarray cancer gene expression data analysis. In *2006 international symposium on evolving fuzzy systems* (pp. 241-246). IEEE.
- Zangeneh Sirdari, Z. and Zangeneh Sirdari, N., 2015. Bedload transport predictions based on field measurement data by combination of artificial neural network and genetic programming. *Pollution*, 1(1), pp.85-94.