

پیش‌بینی جریان ورودی به مخزن سد با استفاده مدل شبکه عصبی مصنوعی بر مبنای داده‌های ماهواره‌محور-PERSIANN  
CDR و CMC (مطالعه موردی: سد زاینده‌رود)

۱- رامتین معینی\*، دانشیار، گروه عمران، دانشکده عمران حمل و نقل، دانشگاه اصفهان، اصفهان، ایران (نویسنده مسئول)

تلفن: ۰۳۱-۳۷۹۳۵۲۹۳، فاکس: ۰۳۱-۳۶۶۹۹۵۱۵، ایمیل: [r.moeini@eng.ui.ac.ir](mailto:r.moeini@eng.ui.ac.ir)

۲- محمدعلی علیجانیان، استادیار، گروه عمران، دانشکده عمران حمل و نقل، دانشگاه اصفهان، اصفهان، ایران

تلفن: ۰۳۱-۳۷۹۳۵۳۱۷، فاکس: ۰۳۱-۳۶۶۹۹۵۱۵

ایمیل: [m.alijanian@eng.ui.ac.ir](mailto:m.alijanian@eng.ui.ac.ir)

۳- مینا مرادی زاده، استادیار، گروه نقشه برداری، دانشکده عمران حمل و نقل، دانشگاه اصفهان، اصفهان، ایران

تلفن: ۰۳۱-۳۷۹۳۵۳۱۲، فاکس: ۰۳۱-۳۶۶۹۹۵۱۵

ایمیل: [m.moradzadeh@eng.ui.ac.ir](mailto:m.moradzadeh@eng.ui.ac.ir)

1- Ramtin Moeini, Associate Professor, Department of Civil Engineering, Faculty of civil engineering and transportation, University of Isfahan, Isfahan, Iran (corresponding author)

Email: [r.moeini@eng.ui.ac.ir](mailto:r.moeini@eng.ui.ac.ir), Tel: 031-37935293, Fax: 031-36699515

ORCID: 0000-0003-0544-7090

2- Mohammadali Alijanian, Assistant Professor, Department of Civil Engineering, Faculty of civil engineering and transportation, University of Isfahan, Isfahan, Iran

Email: [m.alijanian@eng.ui.ac.ir](mailto:m.alijanian@eng.ui.ac.ir), Tel: 031-37935317, Fax: 031-36699515

ORCID: 0000-0002-4702-9375

3- Mina moradzadeh, Assistant Professor, Surveying and Geomatics Engineering Department , Faculty of civil engineering and transportation, University of Isfahan, Isfahan, Iran

Email: [m.moradzadeh@eng.ui.ac.ir](mailto:m.moradzadeh@eng.ui.ac.ir), Tel: 031-37935312, Fax: 031-36699515

ORCID: 0000-0003-3163-5853

27  
 28 تعیین مقدار واقعی جریان ورودی به مخزن، به عنوان یکی از منابع اصلی تامین آب، از مولفه‌های اساسی تصمیم‌سازی در  
 29 حوزه مدیریت منابع آب می‌باشد. به دلیل محدودیت عدم توزیع مناسب مکانی و زمانی داده‌های مستخرج از ایستگاه‌های  
 30 زمینی، بکارگیری داده‌های ماهواره‌محور مورد توجه می‌باشد. ولیکن مقیاس داده‌های ماهواره محور و لزوم ریز مقیاس نمایی  
 31 آنها از جمله عدم قطعیت‌های این داده‌ها می‌باشد. در این تحقیق، عملکرد داده‌های ماهواره محور PERSIANN-CDR و  
 32 CMC (Canadian Meteorological Centre) در تخمین بارش و تعیین جریان ورودی به مخزن سد بررسی شده است.  
 33 لذا، با ترکیب مختلف داده‌های ورودی، مدل‌هایی معرفی و با استفاده از مدل شبکه عصبی مصنوعی جریان ورودی به مخزن  
 34 سد پیش بینی شده و با نتایج داده‌های زمینی مقایسه شده است. در این تحقیق، مخزن سد زاینده رود از حوضه آبریز گاوخونی  
 35 به عنوان مطالعه موردی انتخاب شده است. بررسی نتایج نشان دهنده آنست که بهترین نتایج شاخص  $R^2$  و RMSE برای  
 36 داده‌های تخمین بارندگی (برف) ماهواره محور PERSIANN-CDR (CMC)  $0/49$  ( $0/34$ ) و  $60/90$  ( $41/56$ ) میلی‌متر  
 37 می‌باشد. به عبارت دیگر، نتایج نشان دهنده عملکرد مناسب داده‌های ماهواره محور در تخمین بارندگی و برف می‌باشد.  
 38 بنابراین از این داده‌ها در ساخت شبکه عصبی مصنوعی به منظور تعیین جریان ورودی به مخزن سد زاینده رود استفاده شده  
 39 است. بررسی نتایج مدل شبکه عصبی مصنوعی نشان داد که مقادیر شاخص  $R^2$ ، RMSE و NSE برای داده‌های آموزش  
 40 (صحت سنجی و آزمایش) به ترتیب برابر با  $0/72$  ( $0/74$ )،  $56/08$  ( $75/178$ ) میلیون متر مکعب (MCM) و  $0/85$  ( $0/86$ )  
 41 می‌باشد که نشان‌دهنده عملکرد مناسب این مدل در تعیین و پیش بینی جریان ورودی به مخزن سد زاینده رود می‌باشد.

42 **کلمات کلیدی:** داده‌های ماهواره محور، بارندگی، آب معادل برف، شبکه عصبی مصنوعی، سد زاینده رود

## 43 ۱- مقدمه

44 در دهه‌های اخیر، با پیشرفت علم و افزایش جمعیت، تقاضای آب در مناطق مختلف بویژه مناطق خشک و نیمه‌خشک افزایش  
 45 یافته است. از طرفی محدودیت منابع آب، برطرف کردن تمامی نیازهای آبی را غیر ممکن کرده است. به همین دلیل نیاز به  
 46 یک مدیریت صحیح و بلندمدت در این زمینه بیش از پیش احساس می‌شود. یکی از مهم‌ترین منابع آبی قابل استفاده توسط  
 47 بشر، منابع آب سطحی است که سدها برای استفاده از آنها احداث می‌شوند. تعیین مقدار بهینه خروجی از مخازن سدها  
 48 نیازمند تعیین دقیق میزان جریان ورودی به آنها می‌باشد. به عبارت دیگر، تصمیم‌گیری در خصوص منابع آب موجود، فرایندی  
 49 پیچیده و مهم است که احتیاج به اطلاعات اولیه از جمله میزان جریان ورودی به مخزن سد، دارد. از این رو، معرفی روش‌های  
 50 دقیق و مناسب در پیش‌بینی جریان ورودی به مخزن، یکی از مهم‌ترین چالش‌های پیش‌روی مدیران و بهره‌برداران منابع آب  
 51 است. عوامل زیادی از جمله میزان بارش بر جریان یک رودخانه تاثیر گذارند که بسیاری از آنها فاکتورهای غیرقطعی و  
 52 ناپایدار هستند و بنابراین تحلیل این پدیده را دشوار می‌سازند. در حالت کلی، روش‌های متداول تحلیل جریان رودخانه شامل  
 53 مدل‌های فیزیکی و مفهومی، سری‌های زمانی و رگرسیون می‌باشند که با وجود محدودیت اطلاعات و حقیقت غیر قطعی این  
 54 پدیده، معمولاً با خطا همراه هستند. امروزه مدل‌های هوشمند داده محور کاربرد فراوانی در زمینه تحلیل پدیده‌های پیچیده و

55 غیرقطعی دارند، که از جمله آن‌ها می‌توان به مدل‌های هوش مصنوعی از جمله مدل شبکه مصنوعی<sup>1</sup> (ANN) اشاره نمود  
56 (Pishgah Hadiyan et al., 2022).

57 بارش (به مفهوم عام بارندگی و برف) یکی از مولفه‌های مهم چرخه هیدرولوژی و اولین ورودی مدل‌های هیدرولوژی، به  
58 منظور توسعه استراتژی‌های مدیریتی است. بطور کلی، دو رویکرد برای بدست آوردن داده‌های بارش پیشنهاد شده است که  
59 عبارتند از ۱) مشاهدات و اندازه‌گیری آن بوسیله ایستگاه‌های باران‌سنجی و برف‌سنجی زمینی (به ترتیب برای اندازه‌گیری  
60 باران و آب معادل برف) و ۲) استفاده از داده‌های تخمین بارندگی ماهواره‌محور. با وجود آنکه داده‌های زمینی (داده‌های  
61 مشاهداتی) صحت بالاتری دارند، ولیکن راه‌اندازی ایستگاه‌های زمینی هزینه‌بر بوده و در برخی مناطق همانند نقاط کوهستانی  
62 با سختی همراه است. علاوه بر این، محدودیت‌های اندازه‌گیری‌های زمینی مانند نقطه‌ای بودن مشاهدات از یک سو و توسعه  
63 و در دسترس بودن داده‌های ماهواره‌محور از سوی دیگر مدیران و محققین منابع آب را به سمت استفاده از آن‌ها تشویق  
64 نموده است. بررسی پیشینه تحقیقات نشان دهنده آنست که، داده‌های تخمین بارندگی ماهواره‌محور (SRE<sup>2</sup>) در موارد مختلف  
65 بطور مستقل و یا در مقایسه با داده‌های زمینی استفاده شده است (Dinku et al., 2007). اخیراً، داده ماهواره‌محور  
66 <sup>3</sup>PERSIANN-CDR (Ashouri et al., 2014) بدلیل آنکه توانایی تخمین بارندگی در دوره‌های دراز مدت و حتی نزدیک  
67 به زمان حاضر را دارند، بسیار مورد توجه محققین قرار گرفته است. در این راستا، ارزیابی تولیدات ماهواره‌ای تخمین بارندگی  
68 براساس داده‌های مبتنی بر مشاهدات زمینی در مقیاس‌های مختلف زمانی و مکانی از جمله در ایران، نشان‌دهنده دقت و  
69 صحت نتایج می‌باشد. از جمله این مدل‌ها می‌توان به TRMM-3B42V7، TRMM-3B42، TRMM-3B42RT،  
70 PERSIANN و MSWEP، TRMM-3B42RTV6، adjusted-PERSIANN، CMORPH، TRMM-3B42  
71 اشاره نمود که از آنها برای تخمین بارندگی در نقاط مختلف ایران از جمله در امتداد رشته کوه زاگرس، در مناطق جنوب غرب  
72 ایران و نیز حاشیه خلیج فارس استفاده شده است (Smith et al. 2006; Dinku et al., 2007; Javanmard et al.,  
73 2010; Katiraie-Boroujerdy et al., 2013; Tan et al., 2015; Alijanian et al., 2017; Alijanian et al.,  
74 2022). با این وجود، تحقیقات در خصوص عملکرد داده‌های ماهواره‌محور در تخمین برف محدود می‌باشد (Moradizadeh  
75 et al., 2023).

76 تخمین و پیش‌بینی صحیح میزان جریان ورودی به مخازن سدها به منظور مدیریت کارآمد آنها به ویژه در شرایط آینده لازم  
77 و ضروری است. در این راستا، تحقیقات متعددی در زمینه تخمین و پیش‌بینی جریان رودخانه‌ها و آب ورودی به مخزن سده  
78 ها انجام شده است (Guo et al., 2023; Pishgah Hadiyan et al., 2022). بدین منظور روش‌های مختلفی پیشنهاد  
79 شده است که هر یک مزایا و معایب مختلفی دارند. به طور کلی روش‌ها به دو دسته روش‌های متریک یا داده‌محور و روش  
80 های پارامتریک یا مفهومی تقسیم بندی می‌شود. تفاوت اصلی دو روش مذکور در میزان وابستگی آن‌ها به داده‌های ورودی  
81 است. در روش‌های متریک، مدلساز برای پیش‌بینی جریان تنها به سری زمانی داده‌های رواناب و در نهایت بارش و دما متکی  
82 است. اما اساس کار روش‌های پارامتریک، درک دقیق از سازوکار فیزیکی حاکم بر فرآیندهای هیدرولوژیک حوضه است. از  
83 این رو، روش‌های پارامتریک برای مدل‌سازی و پیش‌بینی جریان، نیازمند طیف وسیعی از داده‌های هیدرولوژیک و هواشناسی  
84 حوضه هستند. به صورت کلی، انتخاب روش مناسب برای پیش‌بینی و مدلسازی جریان به شرایط مساله و داده‌های در دسترس

<sup>1</sup>Artificial neural network

<sup>2</sup>Satellite based Rainfall Estimates

<sup>3</sup>PERSIANN-Climate Data Record

85 وابسته است. اما وابستگی کمتر روش‌های متریک به حجم داده‌های ورودی و همچنین پیچیدگی کمتر این مدل‌ها باعث  
86 مقبولیت گسترده این روش‌ها شده است. بررسی سوابق تحقیقاتی نشان‌دهنده عملکرد خوب مدل‌های داده‌محور بر مبنای  
87 هوش مصنوعی، از جمله مدل شبکه عصبی مصنوعی، در پیش‌بینی جریان رودخانه‌ها و آب ورودی به سد‌ها می‌باشد ( )  
88 Partal and Kişi, 2007; Pramanik and Panda, 2009; Adamowski and Sun, 2010; Kisi and Partal,  
89 2011; Kalteh, 2013; Karthikeyan and Nagesh Kumar, 2013; Budu, 2014; Kalteh, 2015; Ravansalar  
90 et al., 2017; Babaei et al., 2019; Khazae Poul et al., 2019; Noorbeh et al., 2020; Apaydin et al.,  
91 2020; Latif et al., 2021; Suriya et al., 2021; PishgahHadiyan et al., 2022; Gupta and Kumar, 2022;  
92 (Anctil et al., 2004).

93 با توجه به عملکرد خوب مدل شبکه عصبی مصنوعی در پیش‌بینی جریان رودخانه‌ها و آب ورودی به مخزن سد‌ها  
94 (PishgahHadiyan et al., 2022) بر مبنای داده‌های مشاهداتی ایستگاه‌های زمینی، در این تحقیق، از این مدل برای  
95 پیش‌بینی جریان ورودی به مخزن سد زاینده رود و بر مبنای داده‌های ماهواره‌محور استفاده شده است. بدین منظور از  
96 داده‌های ماهواره‌محور برای ساخت داده‌های ورودی این مدل استفاده شده است، که از نوآوری‌های تحقیق حاضر می‌باشد.  
97 نتایج با نتایج بدست آمده از ساخت مدل بر مبنای داده‌های زمینی مقایسه شده است. شایان ذکر است که برای محدوده  
98 مطالعاتی (بالادست سد زاینده‌رود)، محققین تحقیق حاضر از دو دسته داده تخمین بارش ماهواره‌محور PERSIANN-CDR  
99 و CMC<sup>4</sup> به ترتیب جهت بررسی دو متغیر بارندگی و برف برای بازه سال‌های ۱۹۹۹ تا ۲۰۱۹ استفاده نمودند (Alijanian  
100 et al., 2022). عملکرد این دو دسته داده ماهواره‌محور، با مقایسه آنها با داده‌های ایستگاه‌های زمینی (در مجموع ۱۶ ایستگاه  
101 باران سنجی و ۱۴ ایستگاه برف سنجی) در ناحیه بالادست سد زاینده‌رود و در مقیاس زمانی ماهانه در بازه زمانی بیست و  
102 یک ساله ۱۳۷۸ تا ۱۳۹۸ (۱۹۹۹-۲۰۱۹) ارزیابی شده است. با توجه به نتایج بدست آمده، در این تحقیق، عملکرد این داده‌ها  
103 در مقایسه با داده‌های زمینی در پیش‌بینی جریان ورودی به مخزن سد زاینده رود با استفاده از مدل شبکه عصبی مصنوعی  
104 بررسی شده است.

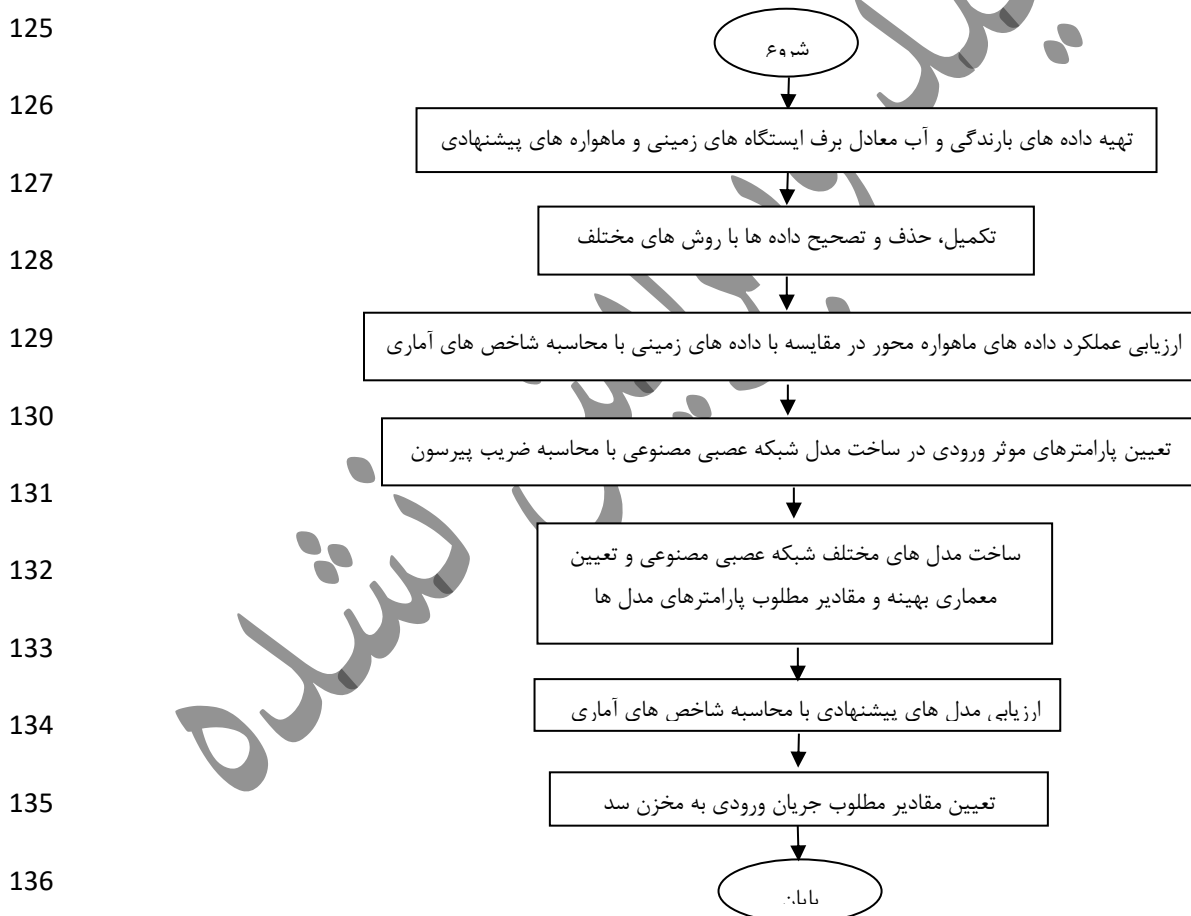
105 در حالت کلی پیش‌بینی‌ها همواره با عدم قطعیت همراه است. خطاهای تقریبی‌های به کاررفته در اندازه‌گیری داده‌های ورودی،  
106 مقادیر پارامترها، ساختار مدل و الگوریتم روابط مابین پارامترها و متغیرها در مدل، همگی منابع عدم قطعیت هستند. با توجه  
107 به این موارد، منابع عدم قطعیت در این مدل‌ها را می‌توان در سه دسته، استفاده از پارامترها، ساختار مدل و داده‌های مورد  
108 استفاده، تقسیم بندی نمود. به عنوان نمونه، در مدل شبکه عصبی مصنوعی، پارامترهای مدل (از جمله وزن‌ها) فاقد مبنای  
109 فیزیکی هستند و بنابراین از ابتدا نمیتوان برای آنها همانند پارامترهای فیزیکی، دامنه‌ای از مقادیر فرض کرد. بلکه، مقادیر  
110 اولیه این پارامترها به صورت تصادفی انتخاب شده و سپس با استفاده از روش مقدار مناسب آنها تعیین میشود. بنابراین، عدم  
111 قطعیتی که در نتایج خروجی مدل‌ها مشاهده میشود را می‌توان به آن نسبت داد. در این تحقیق نیز، منابع عدم قطعیت جریان  
112 پیش‌بینی شده ورودی به مخزن سد زاینده، مربوط به داده‌های مدل (بارش و آب معادل برف) و پارامترها و ساختار مدل  
113 های شبکه عصبی مصنوعی می‌باشد. در انتها ذکر این نکته ضروری است که ناقص بودن و صحت داده‌های زمینی به ویژه  
114 داده‌های آب معادل برف و جدا سازی داده‌های بارندگی از برف از مهمترین محدودیت‌های تحقیق حاضر می‌باشد. علاوه

<sup>4</sup>Canadian Meteorological Centre (CMC) Daily Snow Depth Analysis Data

115 بر این، دسترسی آزاد به داده‌های سایر ماهواره ها نیز به راحتی امکانپذیر نمی باشد. بنابراین امکان صحت سنجی نتایج  
116 داده‌های ماهواره محور مورد استفاده با مشکل همراه بود که سعی شده است با روش‌های مختلف این محدودیت برطرف شود.  
117 همچنین، شناسایی عوامل خطا در ساخت مدل های شبکه عصبی مصنوعی (به ویژه تعیین جریان طبیعی رودخانه و حذف  
118 جریان های ناشی از طرح های انتقال آب در بالادست) و زمانبر بودن آموزش مدل ها از جمله سایر محدودیت های تحقیق  
119 حاضر می باشد.

## 120 ۲- مواد و روش ها:

121 در این تحقیق، مدلهایی بر مبنای داده‌های ماهواره محور برای پیش بینی و تعیین جریان ورودی به مخزن سد پیشنهاد شده  
122 است. روندنمای کلی تحقیق در شکل (۱) ارائه شده است. در این بخش، در ابتدا مطالعه موردی معرفی شده است. در ادامه،  
123 داده های ماهواره محور مورد استفاده در تحقیق ارائه شده است. در نهایت، توضیحاتی مختصر در خصوص مدل شبکه عصبی  
124 مصنوعی ارائه شده است.



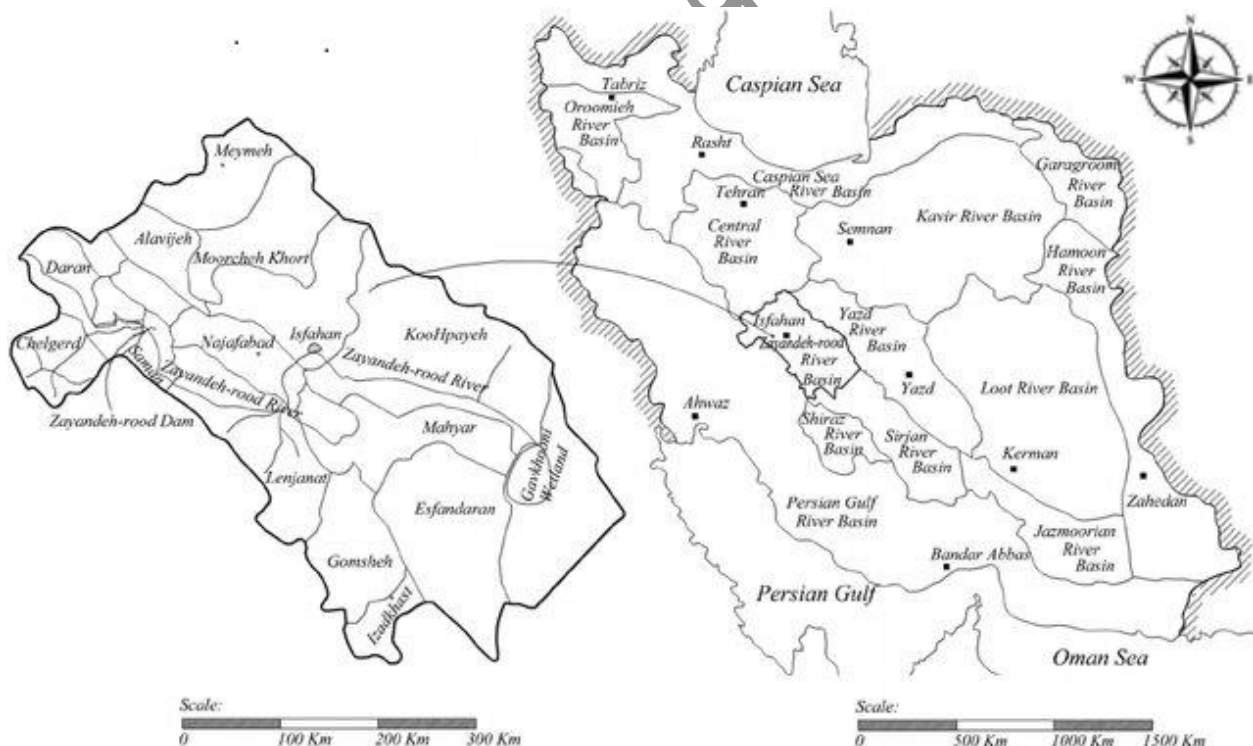
136 شکل ۱: روندنمای کلی تحقیق

## ۱-۲- معرفی مطالعه‌ی موردی

138

139 **محدوده** مطالعاتی تحقیق حاضر، حوضه آبریز گاوخونی یا زاینده‌رود واقع در فلات مرکزی ایران **می‌باشد**. رودخانه جاری در  
140 این حوضه مهمترین منبع تأمین آب مورد نیاز بخش‌های کشاورزی، صنعت و شرب استان‌های چهارمحال و بختیاری و  
141 اصفهان و نیز انتقال آب بین‌حوضه‌ای آب این رودخانه به استان‌های یزد و کرمان برای مصارف شرب و صنعت می‌باشد.  
142 بیشتر بارشهای حوضه زاینده‌رود به صورت یخ و برف تا فرارسیدن ماه فروردین و افزایش درجه حرارت باقی می‌ماند. تأثیر  
143 برفاب بهاره به صورت **دبی‌های** حداکثر در فصل بهار و هنگام **حداکثر نیاز بخش** کشاورزی می‌باشد. رشد جمعیت و فعالیت  
144 انسانی و توسعه از مهمترین چالش‌های این حوضه است. عدم هماهنگی توسعه صنعت و رشد جمعیت با منابع آب در این  
145 حوضه منجر به عدم توازن منابع و مصارف آب **شده** است به نحوی که تقریباً در اکثر سال‌ها تأمین مطمئن آب شرب و صنعت  
146 با فشار به بخش‌های کشاورزی و محیط زیست همراه بوده است. بنابر این نیاز به انجام یک مدیریت صحیح و بهره‌برداری  
147 بهینه از مخزن به منظور مقابله با بحران آب لازم و ضروری بنظر می‌رسد. با توجه به مطالب مذکور، پیش‌بینی جریان ورودی  
148 به مخزن سد به منظور برآورد میزان خروجی از سد و مدیریت مقدار آب ورودی از اهمیت زیادی، به ویژه در شرایط بحرانی  
149 سیل و خشک‌سالی، برخوردار است. در شکل (۲) موقعیت این حوضه در کشور نشان داده شده است.

150



151

152 شکل ۲: موقعیت حوضه آبریز گاوخونی (زاینده‌رود) در ایران (Safavi et al., 2010)

153

Figure 1: Location of Gavkhoni watershed (ZayndehRoud) in Iran (Safavi et al., 2010)

154



155 در تحقیق حاضر، داده‌های روزانه بارندگی ایستگاه‌های زمینی از دو منبع؛ الف) شبکه ایستگاه‌های سینوپتیکی و ب) داده‌های  
 156 ایستگاه‌های اقلیم شناسی اداره هواشناسی تهیه شده است. بطور کلی در محدوده بالادست سد زاینده رود ایستگاه‌های  
 157 باران‌سنجی به دو دسته باران‌سنجی معمولی (۲۷ عدد) و سینوپتیکی (۷ عدد) تقسیم می‌شوند که داده‌های آنها برای یک دوره  
 158 بیست ساله ۱۹۹۹ تا ۲۰۱۹ بصورت ماهانه جمع آوری شده است. در جدول (۱) بطور خلاصه و برای نمونه داده‌های میانگین  
 159 بارندگی ماهانه برای ایستگاه‌های سینوپتیکی ارائه شده است. همچنین، در شکل ۳ توزیع مکانی ایستگاه‌های باران‌سنجی  
 160 نسبت به مرزهای حوضه آبریز زاینده‌رود نیز نشان داده شده است. با توجه اطلاعات موجود، ۲۴ ایستگاه برای آنالیزهای  
 161 داده‌کاوی و صحت‌سنجی بررسی شده است. در این بین، ۷ ایستگاه آپیونه، افوس، دولت آباد گل سفید، فریدونشهر، سنگبران،  
 162 فراسان و خوانسار نیز بدلیل اینکه داده‌های بدون برداشت متوالی فراوانی داشته و اساساً راه اندازی آنها غالباً بعد از سال ۲۰۰۳  
 163 است، قابلیت استفاده را نداشته و بنابراین مورد استفاده قرار نخواهند گرفت و تنها ۱۷ ایستگاه برای تحلیل داده انتخاب شد.  
 164 در بین ایستگاه‌های باقیمانده نیز ۴ ایستگاه بارده، صالح آباد زری، رستم آباد و رارا نیز دارای داده‌های مفقودی محدودی بودند  
 165 که با استفاده از روش نسبت نرمال، داده‌های مفقودی مذکور با توجه به اطلاعات سایر ایستگاه‌ها جایگزین شد. در نهایت،  
 166 ۱۷ ایستگاه برای آنالیز آماری انتخاب و با استفاده از روش جرم مضاعف سازگاری هریک با سایر ایستگاه‌ها بررسی شد که  
 167 نتایج آن پیش آن ارائه شده است (Alijanian et al., 2022).

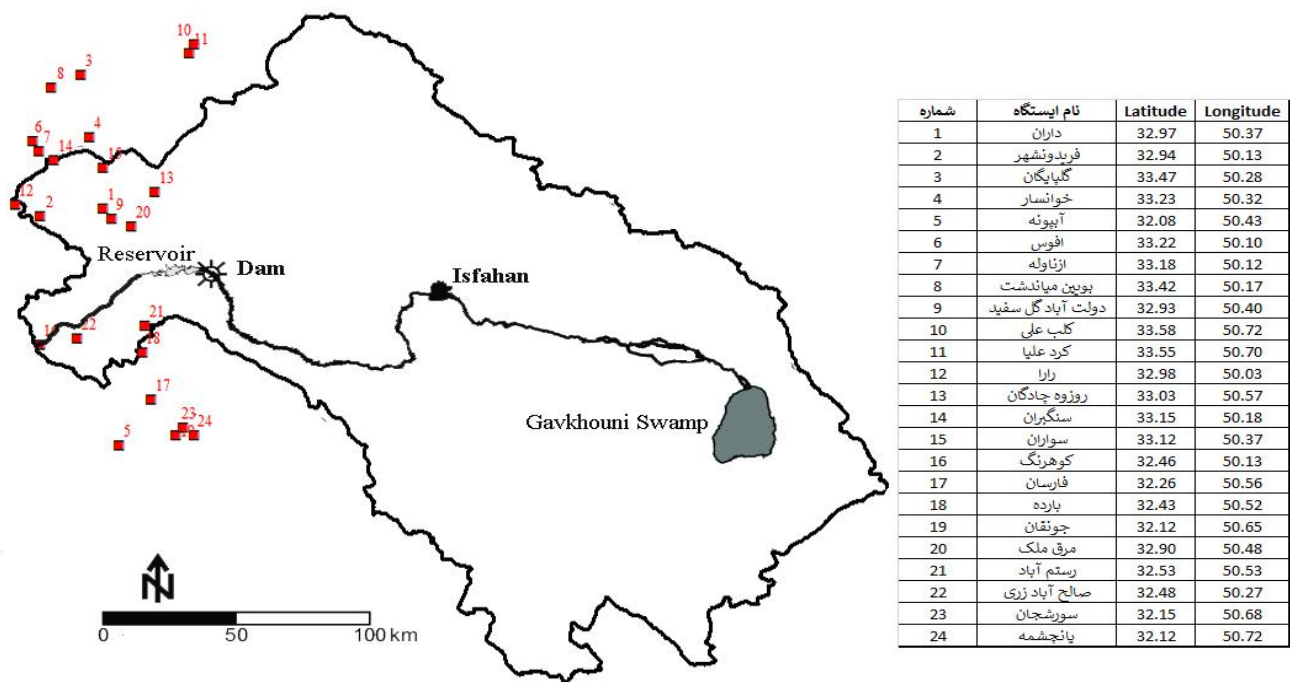
168  
 169 جدول ۱: میانگین بارندگی ماهانه گزارش شده از ایستگاه‌های سینوپتیکی مستقر در محدوده مطالعاتی (بالادست سد زاینده رود)

170 Table 1: Average monthly rainfall observation of synoptic stations located in the study area (upstream of ZayandehRoud  
 171 dam)

نام ایستگاه station	استان state	دوره قرائت duration	میانگین بارندگی ماهانه (میلیمتر) Average monthly rainfall (mm)
داران Daran	اصفهان Isfahan	۲۰۱۹-۱۹۹۹	۲۷/۱۴
فریدونشهر Fereidunshahr	اصفهان Isfahan	۲۰۱۹-۲۰۰۴	۴۴/۳۶
گلیایگان Golpayegan	اصفهان Isfahan	۲۰۱۹-۱۹۹۹	۱۹/۸۸
خوانسار Khansar	اصفهان Isfahan	۲۰۱۹-۲۰۰۶	۳۲/۲۹
کوهرنک Kuhrang	چهارمحال و بختیاری Chaharmahalva Bakhtiari	۲۰۱۹-۱۹۹۹	۱۰۲/۷۰
فارسان Farsan	چهارمحال و بختیاری Chaharmahalva Bakhtiari	۲۰۱۹-۲۰۱۰	۳۰/۰۴

173  
 174 علاوه بر این، به منظور بررسی اثر آب معادل برف در میزان رواناب ورودی به مخزن سد، داده‌های برف‌سنجی چهارده  
 175 ایستگاه مختلف، که تحت نظر شرکت‌های آب منطقه‌ای استان‌های اصفهان و چهارمحال و بختیاری هستند، در بازه  
 176 زمانی بیست ساله (۱۹۹۹-۲۰۱۹) جمع آوری شده‌اند. داده‌های مذکور مربوط به ثبت چگالی برف و آب معادل برف ۱۴  
 177

178 ایستگاه مختلف است. در شکل ۴ توزیع مکانی ایستگاه‌های برف‌سنجی نسبت به مرزهای حوزه آبریز زاینده‌رود نشان  
 179 داده شده است. همچنین، در جدول (۲) برای نمونه داده‌های مربوط به مشاهدات برف زمستان به صورت میانگین برای  
 180 دوره آماری ارائه شده است. شایان ذکر است که برداشت‌های مربوط به آب معادل برف تنها در سه ماه دی، بهمن و اسفند  
 181 انجام شده است. نحوه عملکرد آن به گونه‌ای است که مقدار برف جمع‌آوری شده در ظروف مربوطه در دمای صفر درجه  
 182 اتاق تبدیل به آب شده و میزان آب معادل برف بصورت روزانه قرائت شده است.




184 شکل ۲: ایستگاه‌های باران‌سنجی مورد استفاده در تحقیق نسبت به مرزهای حوزه آبریز گاوخونی (زاینده‌رود)  
 185 Figure 2: Rain gauge stations used in the research in relation with the boundaries of the Gavkhouni drainage basin  
 186 (ZayandehRoud).

187  
 188 جدول ۲: مقادیر میانگین مشاهداتی ایستگاه‌های برف‌سنجی مستقر در ناحیه مورد مطالعه  
 189 Table 2: Average observed values of snow stations located in the study area

ماه Month	Average monthly snow (mm)				میانگین ماهانه برف (میلیمتر)		
	چلگرد Chelgerd	نصیرآباد Nasir Abad	محمدآباد Mohammad Abad	شیخ شaban Sheykh Shaban	قلعه مرغ Ghale Morgh	دره گاو Dare Gav	سودجان Soodejan
Jan	۱۱۸/۵۱۹	۵۸/۵۷	۹۰/۶۸	۲۲/۶۹	۶۰/۴۹	۳۴/۹۱	۳۷/۱
Feb	۱۷۹/۱	۱۰۱/۶۲	۱۵۵/۴۳	۵۷/۳۸	۱۰۴/۰۲	۳۸/۸۶	۴۴/۳۸
Mar	۸۰/۵	۱۶/۳۱	۴۲/۸۴	۹/۰۱	۱۳/۸	۴/۲۳	۴/۲۹
ماه	Average monthly snow (mm)				میانگین ماهانه برف (میلیمتر)		



Month	بارده Bardeh	بادیجان Badijan	گردنه اوشن Gardane Oshen	اسلام آباد Eslam Abad	قلعه شاهرخ GhalehSharokh	گردنه بوئین Gardane Buin	سینجرد Singerd
Jan	۳۴/۶۸	۲۵/۶۶	۲۰/۱۹	۱۵/۴۸	۱۵/۷۸	۳۲/۴۳	۱۹/۸۵
Feb	۸۱/۷۴	۵۹/۲۴	۳۲/۷۶	۳۶/۳۳	۴۳/۱۷	۶۹/۰۵	۵۴/۲۹
Mar	۲۸/۲۶	۱۴/۴۸	۳/۶۲	۴/۵۲	۳/۸۶	۳۴/۲۱	۹/۰۵



شکل ۲: ایستگاه‌های برف سنجی مورد استفاده در تحقیق نسبت به مرزهای حوزه آبریز گاوخونی (زاینده‌رود)

Figure 2: Snow gauge stations used in the research in relation with the boundaries of the Gavkhoni drainage basin (ZayandehRoud).


## ۲-۲- داده های ماهواره محور

در تحقیق حاضر از دو دسته داده شامل بارندگی و آب معادل برف در محدوده بالا دست سد زاینده‌رود استفاده شده است که از دو منبع ایستگاه‌های زمینی (ایستگاه‌های آب و هواشناسی) و تولیدات ماهواره‌محور تأمین شده است. با توجه به توصیه سایر پژوهشگران (Alijanian et al., 2022) در خصوص صحت و نیز قابلیت دسترسی مناسب **داده‌ها** (از سال ۱۳۸۳ بدون محدودیت برای کاربران ایرانی)، از داده‌های تخمین بارندگی دراز مدت اقلیمی PERSIANN-CDR به عنوان داده ماهواره‌محور تخمین بارش استفاده شده است. همچنین، به منظور بررسی میزان آب معادل برف نیز از داده‌های تخمین آب معادل برف CMC (در دسترس از سال ۱۹۹۹ به بعد) استفاده شده است.

در این بخش، ابتدا توضیحاتی در خصوص این دو داده **ماهواره‌محور** ارائه شده است. به منظور دسترسی مناسب به داده‌های تخمینی بارندگی، نسل جدیدی از داده‌ها به نام **داده‌های** اقلیمی PERSIANN-CDR در سال ۲۰۱۴ ارائه شد. از مزیت‌های این داده در مقایسه با دیگر داده‌ها، امکان دسترسی در بازه زمانی طولانی‌تری، بیش از ۳۰ سال، در محدوده تقریباً سراسری (60°S- 60°N) بصورت روزانه و با درشت‌نمایی مکانی ۰/۲۵ درجه می باشد. علاوه بر این، با انجام

205 آنالیزهای عمق برف روزانه جهانی در مرکز هواشناسی کانادا (CMC)، مجموعه داده برای تخمین آب معادل برف در  
206 نیم کره شمالی تولید شده است. اصلی ترین محصولات این مجموعه داده، شامل عمق برف روزانه، میانگین عمق برف  
207 ماهیانه (در واحد سانتی متر) و آب معادل برف ماهیانه (در واحد میلی متر) از سال ۱۹۹۸ تا ۲۰۲۰ است. در تولید این نوع  
208 داده، از درجه حرارت و بارش پیش بینی شده شش ساعته، به دست آمده از یک مدل کانادایی استفاده شده است. در این  
209 مدل اگر درجه حرارت کمتر از صفر درجه سانتیگراد باشد، بارش به صورت برف فرض می شود (Alijanian et al.,  
210 2022).

211 در این تحقیق، تعداد ۱۲ سلول (با درشت نمایی مکانی ربع درجه) برای ارزیابی عملکرد داده تخمین بارندگی ماهواره محور  
212 PERSAINN-CDR بصورت سلول به سلول انتخاب شده است. در ادامه، میانگین بارندگی های ماهانه کلیه ایستگاه های  
213 درون هر سلول به عنوان مقدار بارندگی مشاهداتی سلول منظور و با مقادیر تخمینی از داده های ماهواره محور مقایسه شده  
214 است. در خصوص داده تخمین آب معادل برف CMC نیز تعداد ۸ سلول (با درشت نمایی ربع درجه) انتخاب شد که در آنها  
215 مقادیر آب معادل برف ایستگاه های مشاهداتی با مقادیر تخمینی مقایسه شده است. نتایج ارزیابی عملکرد داده ها، توسط  
216 محققین حاضر ارائه شده است (Alijanian et al., 2022). آرایش این سلول ها در شکل ۵ ارائه شده است. در ادامه، با  
217 استفاده از داده های ماهواره محور بدست آمده، از روش های هوش مصنوعی به منظور پیش بینی جریان ورودی به مخزن  
218 سد زاینده رود استفاده شده است. بدین منظور، از مدل شبکه عصبی مصنوعی استفاده شده است. همچنین، از داده های  
219 زمینی نیز بدین منظور استفاده شده و نتایج با نتایج داده های ماهواره محور مقایسه شده است.



220  
221 شکل ۵: آرایش سلول های با داده های تخمین بارندگی ماهواره محور نسبت به موقعیت ایستگاه های باران سنجی برف سنجی مورد استفاده در تحقیق  
222

223 Figure 2: Snow gauge stations used in the research in relation with the boundaries of the Gavkhoni drainage  
224 basin (ZayandehRoud).  
225

### ۳-۲ - مدل شبکه عصبی مصنوعی

226 شبکه‌های عصبی مصنوعی زیرمجموعه‌ای از علم هوش مصنوعی هستند. این سیستم، یک سیستم داده‌پردازی اطلاعات  
227 است که با هدف شبیه‌سازی شبکه‌های عصبی طبیعی معرفی شده‌است. شبکه‌های عصبی مصنوعی تحت عنوان سیستم‌های  
228 دینامیکی هوشمند مدل آزاد<sup>۵</sup> طبقه‌بندی می‌شوند. دلیل اینکه این روش‌ها هوشمند نامیده می‌شوند این است که، به وسیله‌ی  
229 پردازش داده‌های عددی تجربی، رابطه موجود بین داده‌ها آموزش داده می‌شود و از روابط آموزش دیده برای پیش‌بینی پدیده‌ها  
230 در آینده استفاده می‌شود (Gurney, 2000).

231 شبکه‌های عصبی پرسپترون، پرکاربردترین شبکه‌های عصبی هستند که با در نظرگیری تعداد مناسب لایه‌ها و سلول‌های  
232 عصبی، یک نگاشت غیرخطی با دقت مناسب تعریف می‌شود. شبکه عصبی پرسپترون تک لایه معمولاً در طبقه‌بندی الگوها  
233 کاربرد دارد. شیوه آموزش این شبکه از نوع یادگیری بانظارت است که در آن اطلاعاتی نظیر تابع محرک، ورودی و خروجی  
234 مطلوب، پاسخ درست، الگو و اینکه الگو متعلق به چه طبقه‌ای می‌باشد، مشخص است. همچنین عملاً خطای یادگیری برای  
235 مدل تعریف می‌شود و شبکه در هر مرحله، از خطای یادگیری به منظور تنظیم پارامترهای شبکه به شکلی استفاده می‌شود که  
236 اگر مجدداً همان ورودی‌ها به مدل اعمال شود، خطای یادگیری کمتری حاصل شود. روش یادگیری پرسپترون تنها برای شبکه  
237 عصبی تک‌لایه و نرون‌ها با تابع تبدیل آستانه دو مقدار حدی، کاربرد دارد و برای طبقه بندی بردارهایی که به طور خطی از  
238 هم مستقل هستند، استفاده می‌شود. پرسپترون چند لایه (MLP<sup>۶</sup>) شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه  
239 خروجی است که تعداد لایه‌های پنهان و تعداد نرون‌ها در هر لایه ثابت نمی‌باشد. تعداد نرون‌های هر لایه بسته به نوع کار و  
240 وظیفه آن ممکن است متفاوت باشد و کاربر با توجه به مساله و هدف آن باید تعیین کند که شبکه چند لایه و چند نرون احتیاج  
241 دارد. تعداد بهینه لایه‌ها و نرون‌ها معمولاً با روش سعی و خطا تعیین می‌شود (Menhaj, 2021).

### ۴- نتایج

242 در این تحقیق، به منظور بررسی عملکرد داده‌های ماهواره‌محور تخمین بارندگی و آب معادل برف در پیش‌بینی میزان جریان  
243 ورودی به مخزن سد زاینده رود، از مدل مدلی شبکه عصبی مصنوعی استفاده شده است. نتایج با نتایج حاصل از داده‌های  
244 ایستگاه‌های زمینی مقایسه شده است. برای بررسی نتایج از شاخص‌های آماری جذر میانگین مربعات خطا (RMSE)، ضریب  
245 تبیین (هم‌بستگی،  $R^2$ ) و شاخص نش- ساتکلیف (NSE) استفاده شده است. همچنین از ضریب هم‌بستگی پیرسون به منظور  
246 بررسی وابستگی پارامترهای ورودی تأثیرگذار و مقادیر آن‌ها بر نتایج استفاده شده است. داده‌های مدل‌ها شامل جریان ورودی  
247 به مخزن سد، بارندگی و آب معادل برف می‌باشد. همچنین، به منظور بررسی اثرات تأخیرهای زمانی بردارهای ورودی، اطلاعات  
248 مربوط به مقدار دبی ورودی به سد زاینده‌رود از یک تا ۱۲ ماه تأخیر (t-1, t-2, ... t-12) و همچنین اطلاعات هواشناسی نیز  
249 مشابه با اطلاعات مربوط به دبی، از یک تا ۱۲ ماه تأخیر (t-1, t-2, ... t-12) به علاوه داده‌های مربوط به همان ماه به عنوان  
250 ورودی‌های احتمالی در محاسبات ضریب هم‌بستگی پیرسون منظور شده است. داده خروجی نیز جریان ورودی به مخزن سد  
251 زاینده‌رود تعریف شده است. در جدول (۳) داده‌های در دسترس برای انجام تحقیق ارائه شده است. تمامی داده‌ها به صورت

<sup>5</sup>Model free

<sup>6</sup>Multi Layer Perceptron

254 ماهانه ثبت شده‌اند. برای بارش از داده‌های زمینی و ماهواره PERSIANN-CDR استفاده شده‌است. همچنین برای برف نیز  
 255 از داده‌های زمینی و ماهواره CMC استفاده شده‌است. در ابتدا به منظور انتخاب داده‌های مناسب به عنوان ورودی برای مدل‌های  
 256 پیش‌بینی کننده، از روش ضریب هم‌بستگی پیرسون استفاده شده‌است. در این تحقیق، با تعیین ضریب هم‌بستگی پیرسون،  
 257 فقط از **داده‌های** ورودی موثر در ساخت مدل‌ها استفاده شده‌است. دلیل این کار، کاهش حجم داده‌های ورودی مدل‌های  
 258 پیش‌بینی می‌باشد که به کاهش چشمگیر مدت زمان محاسبات و همچنین افزایش دقت<sup>7</sup> و کارایی مدل‌ها منتهی می‌شود.

259  
 260  
 261

جدول ۳: داده‌های ورودی و خروجی مساله  
 Table 3: Input and output data of the problem

بازه زمانی (سال)	واحد	پارامتر
Period (year)	unit	parameter
۲۰۱۹ تا ۲۰۰۳	میلیون متر مکعب (MCM)	مقدار دبی حجمی
	Million cubic meter	Discharge
۲۰۱۹ تا ۲۰۰۳	میلیمتر (mm)	بارش ماهانه (ایستگاه باران سنجی زمینی)
	Millimeter	Monthly rainfall (ground rain gauge station)
۲۰۱۹ تا ۲۰۰۳	میلیمتر (mm)	بارش ماهانه (داده‌های ماهواره PERSIANN-CDR)
	Millimeter	Monthly rainfall (PERSIANN-CDR satellite data)
۲۰۱۹ تا ۲۰۰۳	میلیمتر (mm)	برف (ایستگاه برف سنجی زمینی)
	Millimeter	Snow (ground snow gauge station)
۲۰۱۹ تا ۲۰۰۳	میلیمتر (mm)	برف (داده‌های ماهواره CMC)
	Millimeter	Snow (CMC satellite data)

262 در ابتدا، بررسی و تحلیل نتایج **داده‌های** ماهواره محور در مقایسه با **داده‌های** ایستگاه‌های زمینی نشان دهنده عملکرد مناسب  
 263 **داده‌های** ماهواره محور PERSIANN-CDR و CMC در تخمین میزان بارندگی و برف می‌باشد. به عبارت دیگر، بهترین  
 264 نتایج ارزیابی داده‌های تخمین بارندگی PERSIANN-CDR برای شاخص  $R^2$  و RMSE به ترتیب برابر  $۰/۴۹$  و  $۶۰/۹۰$   
 265 میلیمتر می‌باشد. همچنین نتایج ارزیابی داده‌های تخمین آب معادل برف CMC نشان‌دهنده آنست که بهترین نتایج برای  
 266 شاخص  $R^2$  و RMSE برابر با  $۰/۳۴$  و با  $۴۱/۵۶$  میلیمتر می‌باشد. بنابراین، از این **داده‌ها** به عنوان داده‌های ورودی در ساخت  
 267 مدل‌های شبکه عصبی مصنوعی استفاده شده است.  
 268

269 در ادامه، با شناسایی پارامترهای تاثیرگذار ورودی بر مبنای مقادیر ضریب پیرسون و ترکیب آنها **مدل‌های** مختلفی پیشنهاد  
 270 و عملکرد آنها بررسی شده است. در این تحقیق فقط نتایج بهترین مدل ارائه شده است. در بهترین مدل (مدل II)، پارامترهای

<sup>7</sup>Accuracy

271 ورودی شامل جریان ورودی به مخزن با تاخیرهای زمانی یک، ۱۱ و ۱۲ ماهه (t-1, t-11, t-12)، داده‌های بارش ماهواره  
 272 PERSIANN-CDR در ماه هدف و با تاخیرهای زمانی ۲، ۳ و ۴ ماهه (t-2, t-3, t-4) و داده‌های آب معادل برف ماهواره  
 273 CMC با تاخیرهای ۵ و ۶ (t-5, t-6) ماهه می‌باشد. علاوه بر این، به منظور مقایسه عملکرد داده‌های ماهواره محور در مقایسه  
 274 با داده‌های زمینی، مدلی بر مبنای داده‌های زمینی نیز معرفی شده است که در این مدل (مدل I)، پارامترهای ورودی مشابه  
 275 مدل II منظور شده است.

276 در حالت کلی، مدل شبکه عصبی مصنوعی دارای یک یا چند لایه پنهان و یک لایه خروجی است که لایه‌های پنهان در  
 277 شبکه عصبی توسط نرون‌ها به یکدیگر متصل می‌شوند. تعداد لایه‌های پنهان و همچنین تعداد نرون‌های اتصال‌دهنده لایه‌ها  
 278 در دقت نتایج بدست‌آمده از مدل شبکه عصبی تاثیرگذار است. پارامترهای مذکور، همچنین در مدت‌زمان انجام محاسبات و  
 279 رخ‌دادن پدیده بیش‌برازش نیز موثر هستند. بنابراین، در این تحقیق با استفاده از روش سعی و خطا (آنالیز حساسیت) تعداد  
 280 لایه‌های پنهان، تعداد نرون‌های اتصال‌دهنده لایه‌ها و توابع انتقال و آموزش تعیین شده‌است. در جدول (۴) مقدار مطلوب  
 281 پارامترهای مدل شبکه عصبی مصنوعی ارائه شده‌است. در مدل‌سازی با مدل شبکه عصبی مصنوعی، ۷۰ درصد داده‌های ابتدایی  
 282 به عنوان داده‌های آموزش و ۳۰ درصد انتهایی به عنوان داده‌های صحت‌سنجی و آزمایش منظور شده‌است. همچنین تمامی  
 283 داده‌ها نرمال‌سازی شده‌است.

284 مدل‌های I و II با استفاده از روش شبکه عصبی مصنوعی، ۱۰ مرتبه اجرا شده‌است. با انجام آنالیز حساسیت، تعداد نرون  
 285 مناسب مدل‌ها برابر سه انتخاب شده است. در جدول (۵) میانگین مقادیر به‌دست‌آمده برای ۱۰ بار اجرای مدل‌های مختلف ارائه  
 286 شده‌است. بررسی نتایج نشان‌دهنده آنست که با استفاده از مدل دوم پیشنهادی پیش‌بینی مقدار دبی ورودی به مخزن سد  
 287 زاینده‌رود (مدل II)، که در آن از داده‌های بارش ماهواره‌محور PERSIANN-CDR، آب معادل برف ماهواره‌محور CMC و  
 288 جریان ورودی به مخزن سد به صورت هم‌زمان استفاده شده است، در مقایسه با داده‌های زمینی عملکردی قابل قبول داشته به  
 289 گونه‌ای که مقادیر  $R^2$ ، RMSE و NSE برای داده‌های آموزش به ترتیب برابر ۰/۷۲، ۵۶/۰۸ MCM و ۰/۸۵ برای داده‌های  
 290 آزمایش و صحت‌سنجی به ترتیب ۰/۷۴ و ۷۵/۱۷۸ MCM و ۰/۸۶ می‌باشد. به عبارت دیگر، مقدار  $R^2$  برای داده‌های آموزش  
 291 و آزمایش و صحت‌سنجی در این مدل نسبت به مدل I به ترتیب ۲۵/۳۸ درصد و ۲/۸۹ درصد کاهش یافته است که این  
 292 مقادیر قابل قبول می‌باشد.

293 علاوه بر این، در شکل ۶ مقادیر بدست آمده برای جریان ورودی به مخزن سد برای مدل‌های I و II با استفاده از مدل  
 294 ANN در مقایسه با داده‌های مشاهداتی ارائه شده است. بررسی نتایج نشان‌دهنده عملکرد مناسب و قابل قبول داده‌های  
 295 ماهواره‌محور در ساخت مدل‌های بر مبنای روش ANN در تعیین و پیش‌بینی جریان ورودی به مخزن سد زاینده رود می‌باشد.

296

297 جدول ۴: مقادیر مطلوب پارامترهای مدل ANN

298 Table 4: Proper values of ANN model parameters

299

پارامتر	مقدار
---------	-------

value	parameter
۱	تعداد لایه پنهان Number of hidden layers
۱ و ۳ و ۵	تعداد نورون Number of neuron
Levenberg - marquardt	تابع آموزش Training function
tansig	تابع انتقال Transfer function
Pureline	تابع انتقال (لایه پنهان به لایه خروجی) Transfer function (output and hidden layer)

300

301

302

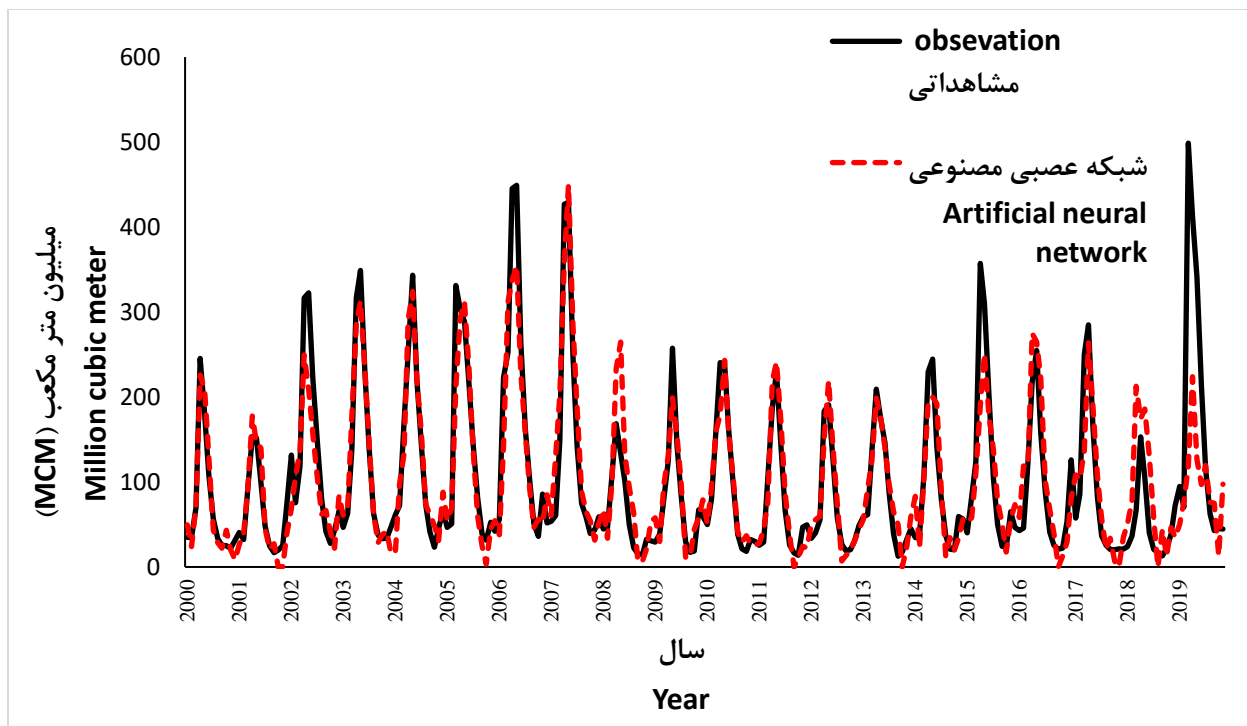
303

جدول ۵: میانگین نتایج به دست آمده از ۱۰ بار اجرای مدل‌های پیشنهادی ANN  
Table 5: The average results obtained from 10 times run of the proposed ANN models

NSE	R <sup>2</sup>	RMSE (MCM)	داده ها data	مدل model
۰/۹۸	۰/۹۶۵	۲۴/۹۹۸	آموزش Training	<b>I</b>
۰/۸۷	۰/۷۶۲	۶۳/۸۳۴	آزمایش و صحت سنجی Test and validation	
۰/۸۵	۰/۷۲	۵۶/۰۸	آموزش Training	<b>II</b>
۰/۸۶	۰/۷۴	۷۵/۱۷۸	آزمایش و صحت سنجی Test and validation	

304





شکل ۴: مقادیر بدست آمده برای جریان ورودی به مخزن سد زاینده رود با استفاده از مدل II روش ANN در مقایسه با داده های مشاهداتی  
 Figure 4: The obtained values of the inflow into the ZayandehRoud dam reservoir using model II of the ANN method compared to the observed data

## ۵- جمع بندی و نتیجه گیری

در این تحقیق، عملکرد استفاده از داده‌های ماهواره محور در تعیین مقدار جریان واقعی ورودی به مخزن سد زاینده رود بررسی شد. بدین منظور، از داده‌های ماهواره محور PERSIANN-CDR (در دسترس از سال ۱۹۸۳ به بعد)، CMC (در دسترس از سال ۱۹۹۹ به بعد) به منظور تعیین میزان دقیق بارندگی و آب معادل برف استفاده و نتایج با نتایج داده‌های زمینی نتایج مقایسه شد. بررسی نتایج داده‌های ماهواره محور نشان داد که با استفاده از داده ماهواره محور تخمین بارندگی PERSIANN-CDR و تخمین برف ماهواره CMC دقت نتایج قابل قبول بود. به عبارت دیگر، کمترین خطای RMSE برای داده‌های تخمین بارندگی ماهواره محور PERSIANN-CDR و تخمین برف CMC  $۶۰/۹۰$  و  $۴۱/۵۶$  میلی‌متر بود. در ادامه، با ترکیب مختلف داده‌های ماهواره محور و زمینی ورودی شامل بارندگی، برف و جریان ورودی به مخزن سد به همراه تاخیرهای زمانی آنها، مدل معرفی و از مدل شبکه عصبی مصنوعی برای تعیین جریان ورودی به مخزن سد استفاده شد. بررسی نتایج نشان داد که نتایج بدست آمده با استفاده از مدل II بر مبنای شبکه عصبی قابل قبول بود. به عبارت دیگر، مقادیر RMSE و  $R^2$  و NSE به ترتیب برای داده های آموزش (آزمایش و صحت سنجی) برابر با  $۵۶/۰۸$  MCM(۷۵/۱۷۸) ،  $۰/۷۲$  ،  $۰/۷۴$  ) و  $۰/۸۵$  (  $۰/۸۶$  ) بود. در حالت کلی، بررسی نتایج نشان دهنده عملکرد مناسب مدل های پیشنهادی شبکه عصبی مصنوعی بر مبنای داده های ماهواره محور در تعیین و پیش بینی میزان جریان ورودی به مخزن سد زاینده رود بود.

## ۶- قدردانی

324 این مقاله خروجی طرح تحقیقاتی مصوب با شماره‌ی ۹۸۰۲۰۰۰۱ صندوق حمایت از پژوهشگران و فناوران کشور بوده و  
325 بنابراین نویسندگان از حمایت مالی آن صندوق در انجام این تحقیق کمال تشکر و قدردانی را دارند

326 - منابع و مأخذ

327 - Adamowski J. & Sun, K. (2010). Development of a coupled wavelet transform and neural  
328 network method for flow forecasting of non-perennial rivers in semi-arid watersheds, *Journal of*  
329 *Hydrology*, 390(1): 85-91. <https://doi.org/10.1016/j.jhydrol.2010.06.033>

330 - Alijanian, M.A., Moradzadeh, M., Moeini, R. (2022). Estimation of precipitation using  
331 PERSIANN-CDR and CMC-based satellite productions (Case study: upstream of the  
332 Zayandehroud dam), *EcoHydrology*, 9(1): 157-172 [ in Persian]

333 - Alijanian, M., Rakhshandehroo, G. R., Mishra, A. K., & Dehghani, M. (2017). Evaluation of  
334 Satellite Rainfall Climatology using CMORPH, PERSIANN-CDR, PERSIANN, TRMM,  
335 MSWEP over Iran. *International Journal of Climatology*. 37: 4896-4914.  
336 <https://doi.org/10.1002/joc.5131>

337 - Alijanian, M., Rakhshandehroo, G. R., Mishra, A. K., & Dehghani, M. (2019). Evaluation of  
338 remotely sensed precipitation estimates using PERSIANN-CDR and MSWEP for spatio-temporal  
339 drought assessment over Iran. *Journal of Hydrology*. 579: 124189.  
340 <https://doi.org/10.1016/j.jhydrol.2019.124189>

341 - Anctil, F. Michel, C. Perrin, C. & Andréassian, V. (2004). A soil moisture index as an auxiliary  
342 ANN input for stream flow forecasting," *Journal of Hydrology*, 286(1): 155-167.  
343 <https://doi.org/10.1016/j.jhydrol.2003.09.006>

344 - Apaydin, H. Feizi, H. Sattari, M. T. Colak, M. S. Shamshirband, S. & Chau, K.-W. (2020).  
345 Comparative Analysis of Recurrent Neural Network Architectures for Reservoir Inflow  
346 Forecasting, *Water*, 12, (5): 1500 .<https://doi.org/10.3390/w12051500>

347 - Ashouri H., Hsu K. L., Sorooshian S., Braithwaite D.K., Knapp K.R., Cecil L.D., Nelson B. R.,  
348 & Prat O. P. (2014). PERSIANN-CDR: daily precipitation climate data record from multi-satellite  
349 observations for hydrological and climate studies. *Bulletin of the American Meteorological*  
350 *Society*. 96(1): 69-84. <https://doi.org/10.1175/BAMS-D-13-00068.1>

351 - Babaei, M. Moeini, R. & Ehsanzadeh, E. (2019). Artificial Neural Network and Support Vector  
352 Machine Models for Inflow Prediction of Dam Reservoir (Case Study: Zayandehroud Dam  
353 Reservoir), *Water Resources Management*, 33(6): 2203-2218. <https://doi.org/10.1007/s11269-019-02252-5>

355 - Budu, K. (2014). Comparison of Wavelet-Based ANN and Regression Models for Reservoir  
356 Inflow Forecasting, *Journal of Hydrologic Engineering*, 19(7): 1385-1400.  
357 [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000892](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000892)

- 358 - Dinku, T., Ceccato, P., Grover, K. E., Lemma, M., Connor, S. J., & Ropelewski, C. F. (2007).  
359 Validation of satellite rainfall products over East Africa's complex topography. *International*  
360 *Journal of Remote Sensing*, 28(7):1503-1526. <https://doi.org/10.1080/01431160600954688>
- 361 - Gurney, K. (2000). Kevin Gurney, An Introduction to Neural Networks, University College  
362 London (UCL) Press, 1997. ISBN 1-85728-673-1 HB.£ 14.95. xi+ 234 pages, *Natural Language*  
363 *Engineering*, 6(2) : 203-204. <https://doi.org/10.1017/S1351324900002540>
- 364 - Guo W.D., Chen W.B., Chang, C.H. (2023). Prediction of hourly inflow for reservoirs at  
365 mountain catchments using residual error data and multiple-ahead correction technique, *Hydrology*  
366 *Research* 54 (9): 1072–1093. <https://doi.org/10.2166/nh.2023.072>
- 367 - Gupta, A. and Kumar A. (2022). Two-step daily reservoir inflow prediction using ARIMA-  
368 machine learning and ensemble models, *Journal of Hydro-environment Research*, 45: 39-52.  
369 <https://doi.org/10.1016/j.jher.2022.10.002>
- 370 - Javanmard, S. Yatagai, A. Nodzu, M. I. BodaghJamali, J. & Kawamoto, H. (2010). Comparing  
371 high-resolution gridded precipitation data with satellite rainfall estimates of TRMM\_3B42 over  
372 Iran. *Advances in Geosciences*. 25: 119- 125. <https://doi.org/10.5194/adgeo-25-119-2010>
- 373 - Kalteh, A. M. (2013). Monthly river flow forecasting using artificial neural network and support  
374 vector regression models coupled with wavelet transform, *Computers & Geosciences*, 54: 1-8.  
375 <https://doi.org/10.1016/j.cageo.2012.11.015>
- 376 - Kalteh, A.M. (2015). Wavelet Genetic Algorithm-Support Vector Regression (Wavelet GA-  
377 SVR) for Monthly Flow Forecasting, *Water Resources Management*, 29 (4): 1283-1293.  
378 <https://doi.org/10.1007/s11269-014-0873-y>
- 379 - Katiraie-Boroujerdy, P. S., Nasrollahi, N., Hsu, K. L., & Sorooshian, S. (2013). Evaluation of  
380 satellite-based precipitation estimation over Iran. *Journal of Arid Environments*, 97: 205-219.  
381 <https://doi.org/10.1016/j.jaridenv.2013.05.013>
- 382 - Khazae Poul, A. Shourian, M. & Ebrahimi, H. (2019), A Comparative Study of MLR, KNN,  
383 ANN and ANFIS Models with Wavelet Transform in Monthly Stream Flow Prediction, *Water*  
384 *Resources Management*, 33(8): 2907-2923. <https://doi.org/10.1007/s11269-019-02273-0>
- 385 - Kisi O. & Partal, T. (2011). Wavelet and neuro-fuzzy conjunction model for streamflow  
386 forecasting, *Hydrology Research*, 42, (6): 447-456. <https://doi.org/10.2166/nh.2011.048>
- 387 - Latif, S. D. Ahmed, A. N. Sathiamurthy, E. Huang, Y. F. & El-Shafie, A. (2021). Evaluation of  
388 deep learning algorithm for inflow forecasting: a case study of Durian Tunggal Reservoir,  
389 Peninsular Malaysia, *Natural Hazards*, 109(1): 351-369. [https://doi.org/10.1007/s11069-021-](https://doi.org/10.1007/s11069-021-04839-x)  
390 04839-x
- 391 - Menhaj, M.B. (2021). Computational Intelligence (vol. 1), fundamental of neural networks,  
392 Amirkabir University of Technology (Tehran Polytechnic), Tehran [in Persian]
- 393 - Moradzadeh, M., Alijanian M.A., Moeini, M. (2023). Spatial Downscaling of Snow Water  
394 Equivalent Using Machine Learning Methods Over the Zayandehroud River Basin, Iran, *PFG* –

395 *Journal of Photogrammetry, Remote Sensing and Geoinformation Science* (In press).  
396 <https://doi.org/10.1007/s41064-023-00249-9>

397 - Noorbeh, P. Roozbahani, A. & Kardan Moghaddam, H. (2020), Annual and Monthly Dam Inflow  
398 Prediction Using Bayesian Networks, *Water Resources Management*, 34(9): 2933-2951.  
399 <https://doi.org/10.1007/s11269-020-02591-8>

400 - Partal T. and Kişi, Ö. (2007). Wavelet and neuro-fuzzy conjunction model for precipitation  
401 forecasting, *Journal of Hydrology*, 342(1): 199-212.

402 - Pramanik N. & Panda, R. K. (2009). Application of neural network and adaptive neuro-fuzzy  
403 inference systems for river flow prediction, *Hydrological Sciences Journal*, 54(2): 247-260.  
404 <https://doi.org/10.1623/hysj.54.2.247>

405 - Ravansalar, M. Rajaei, T. & Kisi, O. (2017). Wavelet-linear genetic programming: A new  
406 approach for modeling monthly streamflow, *Journal of Hydrology*, 549: 461-549.  
407 <https://doi.org/10.1016/j.jhydrol.2017.04.018>

408 - Pishgah Hadiyan, P., Moeini, R., Ehsanzadeh, E., & Karvanpour, M. (2022) Trend Analysis of  
409 Water Inflow Into the Dam Reservoirs under future Conditions Predicted By Dynamic NAR and  
410 NARX Models, *Water Resources Management*, 36(8), pp. 2703–2723.  
411 <https://doi.org/10.1007/s11269-022-03170-9>

412 - Safavi, H. R., Darzi, F., and Mariño, M. A. (2010). Simulation-optimization modeling of  
413 conjunctive use of surface water and groundwater. *Water Resource Management*, 24(10), 1965–  
414 1988. <https://doi.org/10.1007/s11269-009-9533-z>

415 - Smith T, Arkin P, Bates J, & Huffman J. (2006). Estimating Bias of Satellite-Based Precipitation  
416 Estimates. *Journal of Hydrometeorology*, 7 (5): 841-856.

417 - Suriya, S. Saran, K. Anto, L. C. Anbalagan, C. & Vinodh, K. (2021). Inflow Forecasting of  
418 Bhavanisagar Reservoir Using Artificial Neural Network (ANN): A Case Study, In: Ramanagopal,  
419 S., Gali, M., Venkataraman, K. (eds) Sustainable Practices and Innovations in Civil Engineering.  
420 Lecture Notes in Civil Engineering, 79: 119-131. [https://doi.org/10.1007/978-981-15-5101-7\\_12](https://doi.org/10.1007/978-981-15-5101-7_12)

421 - Tan, M. L., Ibrahim, A. L., Duan, Z., Cracknell, A. P., & Chaplot, V. (2015). Evaluation of Six  
422 High-Resolution Satellite and Ground-Based Precipitation Products over Malaysia. *Remote*  
423 *Sensing*. 7: 1504-152. <https://doi.org/10.3390/rs70201504>

424

425

426

427

428 **Predicting the inflow into the dam reservoir using artificial neural network**  
429 **model based on PERSIANN-CDR and CMC data (case study: ZayandehRoud**  
430 **Dam)**

431

432 **Abstract**

433 Determining the actual amount of inflow values into the dam reservoir, as one of the main sources  
434 of water supply, is one of the basic components of decision-making in the field of water resources  
435 management. Due to limitations of the lack of proper spatial and temporal distribution of data  
436 extracted from ground stations, the use of satellite-based data is attractive and interesting.  
437 However, the scale of satellite-based data and the need for their exponential scaling are the  
438 uncertainties of these data. In this research, the performance of PERSIANN-CDR and CMC  
439 (Canadian Meteorological Centre) satellite data for rainfall and snow estimation and determining  
440 the inflow values into the dam reservoir is investigated. Therefore, by considering different  
441 combinations of input data, different models are proposed and the input flow to the dam reservoir  
442 is predicted using the artificial neural network (ANN) model. Here, the ZayandehRoud dam  
443 reservoir of the Gavkhoni drainage basin is selected as a case study. The results shows that the  
444 best  $R^2$  and RMSE values for rainfall (snow) estimation data based on the PERSIANN-CDR  
445 satellite (CMC) are 0.49 (0.34) and 60.90 (41.56) mm. In other words, the results show the proper  
446 performance of satellite-based data for rainfall and snow estimation. Therefore, these data are used  
447 for creating the ANN model to determine the inflow values into the reservoir of ZayandehRoud  
448 dam reservoir. The results show that the values of  $R^2$ , RMSE and NES for training data (validation  
449 and testing) of ANN model are equal to 0.72 (0.74), 56.08 (75.178) MCM, and 0.85 (0.86)  
450 respectively. In other words, the results show the proper performance of satellite-based data for  
451 estimating and determining the inflow into the ZayandehRoud dam reservoir using ANN model.

452

453 **Keywords:** satellite-based data, rainfall, water equivalent to snow, artificial neural network,  
454 Zayandeh Roud Dam

455