



## بر آورد عمق برف به عنوان یکی از پیامدهای تغییرات آب و هوایی با استفاده از رویکرد مدل ترکیبی حداقل مربعات ماشین بردار پشتیبان و الگوریتم ژنتیک

مصطفی آصفی<sup>۱</sup>، علی فتح‌زاده<sup>۲\*</sup>، روح‌اله تقی‌زاده مهرجردی<sup>۳</sup>، محمدعلی زارع چاهوکی<sup>۴</sup>

<sup>۱</sup> کارشناس‌ارشد آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، ایران

<sup>۲</sup> دانشیار، دانشکده دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، ایران،

<sup>۳</sup> استادیار، دانشکده دانشکده کشاورزی و منابع طبیعی، دانشگاه اردکان، ایران

<sup>۴</sup> دانشیار، دانشکده مهندسی کامپیوتر، دانشگاه یزد، ایران

تاریخ دریافت: ۱۴۰۱/۸/۲۰ ؛ تاریخ پذیرش: ۱۴۰۱/۱۲/۷

### چکیده

از جمله اثرات مستقیم و مشهود تغییرات آب و هوایی، دگرش در میزان بارش برف در مناطق مختلف جغرافیایی است. این در حالی است که بارش برف در حوضه‌های کوهستانی همواره به‌عنوان مهم‌ترین منبع تأمین منابع آب در فصول خشک تلقی می‌شود. یکی از آشکارترین ویژگی‌های پوشش برف کوهستان، ناهمگنی مکانی آن می‌باشد. به‌دلیل محدودیت‌های عملی، جمع‌آوری داده‌ها به‌ویژه در مقیاس‌های وسیع، دشوار و گاهی غیرممکن بوده و استفاده از روش‌های غیرمستقیم توصیه می‌شود. در این پژوهش کارایی حداقل مربعات ماشین بردار پشتیبان در مدل‌سازی عمق برف و همچنین اثر کاهش ویژگی با مدل الگوریتم ژنتیک در منطقه کوهستانی چلگرد ایران مورد بررسی قرار گرفت. ابتدا با استفاده از روش هایپرکیوب محل ۱۰۰ نقطه مشخص و داده‌های عمق برف در نقاط موردنظر و همچنین در ۱۹۵ نقطه دیگر به‌صورت تصادفی برداشت گردید. سپس با استفاده از مدل رقومی ارتفاع ۲۵ پارامتر ژئومورفومتری استخراج گردید و همراه با شش تصاویر ماهواره لندست هشت و شاخص تفاوت نرمال شده برف به‌عنوان ورودی‌های مدل‌ها انتخاب گردید. در این پژوهش از الگوریتم ژنتیک برای افزایش سرعت و آماده‌سازی شبکه ماشین بردار پشتیبان که به‌عنوان یک دسته‌بندی‌کننده عمل می‌کند و همچنین انتخاب متغیرهایی که بیشترین همبستگی را با عمق برف دارند استفاده گردید. از آنجایی که کاهش ویژگی‌های غیر مؤثر می‌تواند سبب افزایش دقت یادگیری شود، در این پژوهش از الگوریتم ژنتیک برای فرایند بهینه‌سازی استفاده گردید. نتایج نشان داد روش حداقل مربعات ماشین بردار پشتیبان با میزان ضریب تعیین ۰/۳۶ و جذر میانگین مربعات خطای ۱۷/۸ مدل‌سازی عمق برف را انجام داده است؛ اما الگوریتم ژنتیک با انتخاب ویژگی‌های مؤثر توانست با ضریب تعیین ۰/۹۵ و جذر میانگین مربعات خطا برابر با ۳/۹۷ سانتی‌متر و بادقت بهتری نسبت به استفاده از تمامی ویژگی‌ها تغییرات عمق برف را مدل کند.

**واژه‌های کلیدی:** عمق برف، هوش مصنوعی، سنجش از دور، هایپرکیوب، چلگرد

### مقدمه

بیش از چند دهه است که دانشمندان علوم اقلیمی در خصوص تغییرات آب و هوایی و اثرات مستقیم و غیرمستقیم آن بر زندگی بشر هشدار می‌دهند. بارش برف و پراکنش مکانی و زمانی آن نیز به نحو مستقیمی متأثر از این تغییرات اقلیمی بوده به

گونه‌ای که این دگرش را به راحتی می‌توان در آمار و ارقام ایستگاه‌های هواشناسی دریافت. ذخیره‌گاه‌های برفی از دیرباز تاکنون به‌عنوان اصلی‌ترین منبع تأمین منابع آب در مناطق کوهستانی به‌ویژه در فصول خشک سال تلقی می‌شود. یکی از آشکارترین ویژگی‌های پوشش برفی کوهستانی، ناهمگنی مکانی آن می‌باشد (مک کی و گری، ۱۹۸۱: ۱۷۵). این ناپایداری مکانی، در سطح وسیعی از مقیاس‌ها وجود

پوشش برف می‌باشد (استیوارت و همکاران، ۲۰۰۵؛ ۱۱۳۸).

اندازه‌گیری و سنجش برف در حوضه‌های کوهستانی و شناخت تغییرات آن به دلیل عدم دسترسی مناسب، تأثیر تنوع ویژگی‌های توپوگرافی و فیزیوگرافی در برآورد پارامترهای هیدرولوژیک برف و ناکافی بودن ایستگاه‌های هواشناسی در مناطق مرتفع، ضرورت کاربرد روش‌های غیرمستقیم از جمله تحلیل داده‌های دورسنجی را نشان می‌دهد. باتوجه به ضرورت و اهمیت برف به‌عنوان مهم‌ترین منبع آبی مناطق کوهستانی، تصاویر ماهواره‌ای ابزار ارزشمندی در بررسی سطح پوشش برف و تغییرات آن در طول زمان به حساب می‌آید. از این رو در روند مدیریت کارآمد منابع آبی، به کارگیری داده‌های سنجش‌از دور باهدف کسب اطلاعات دقیق از پوشش برف و یا تغییرات آن به‌صورت عملیاتی اجرا می‌گردد (ژانگ و همکاران، ۲۰۲۰؛ ۱؛ ساودرا و همکاران، ۲۰۱۸؛ ۱۰۲۷).

در طی سال‌های اخیر پژوهشگران سعی کرده‌اند الگو و ساختار تغییرات مکانی عمق برف را که از ملزومات پهنه‌بندی برف به شمار می‌آید با تکنیک‌های مختلفی مدل‌سازی کنند (الدر و همکاران، ۱۹۹۸؛ ۱۸۰۶). از جمله این روش‌ها، روش‌های مبتنی بر هوش مصنوعی، روش‌های زمین آمار و آمار کلاسیک می‌باشد. تدسکو و همکاران (۲۰۰۴؛ ۷۶)، از شبکه عصبی مصنوعی برای برآورد ضخامت برف و آب معادل برف استفاده نمودند. نتایج آن‌ها مؤید صحت و دقت بالای شبکه عصبی مصنوعی در مقایسه با الگوریتم‌های پردازش تصاویر ماهواره‌ای بود. قزایی‌منش و همکاران (۲۰۱۶؛ ۲۶)، به مقایسه شبکه عصبی مصنوعی و درخت تصمیم در مدل‌سازی توزیع مکانی عمق برف در یک منطقه نیمه‌خشک در ایران پرداختند و دریافتند درخت تصمیم نتایج بهتری را در بر دارد. مهم‌ترین پارامترهای ورودی آن‌ها سطح اساس شبکه زهکشی، قدرت آبراهه، شاخص رطوبتی و ارتفاع بود که همگی از مدل رقومی ارتفاع استخراج گردیده بودند. تسی و همکاران (۲۰۱۹؛ ۱) و وردا و همکاران (۲۰۱۹؛ ۳۰۳۱) به مناسب بودن تصاویر

دارد که از مقیاس کمتر از یک متر تا صدها کیلومتر رده‌بندی می‌شود. ناهمگنی پوشش برفی کوهستان، تأثیر شگرفی بر شکل‌گیری بهمن (اسچوایزر و همکاران، ۲۰۰۳؛ ۱)، اکولوژی محلی (لیتاتور و همکاران، ۲۰۰۸؛ ۱) و به‌ویژه هیدرولوژی دارد (بالک و الدر، ۲۰۰۰؛ ۲۴؛ لاندکوئیست و دینگر، ۲۰۰۵؛ ۱؛ باوای و همکاران، ۲۰۱۳؛ ۱۰). مقدار آب ذخیره شده در پوشش برفی و پراکندگی فضایی آن، تأثیر مهمی بر زمان‌بندی، مقدار و مدت تخلیه مربوط به ذوب برف (پومری و همکاران، ۱۹۹۸؛ ۲۳۵۰؛ لندکوئیست و دینگر، ۲۰۰۵؛ ۹؛ لهینگ و همکاران، ۲۰۰۶؛ ۲۱۲۰) و یخ دارد (دادیک و همکاران، ۲۰۰۸؛ ۲۴). برآورد دقیق رواناب حاصل از برف، نیاز به توزیع مکانی ذخایر برفی دارد؛ اما دستیابی به توزیع مکانی عمق برف باید از راه اطلاعات مشاهده‌ای و در مقیاس فشرده صورت گیرد (کلین و همکاران، ۱۹۹۸؛ ۱۲۷۵) که باتوجه به محدودیت‌های عملی در جمع‌آوری اطلاعات دشوار و گاهی غیرممکن است (الدر و همکاران، ۱۹۹۱؛ ۱۵۴۲)، بنابراین استفاده از روش‌هایی که بتوانند عمق برف را در مناطق فاقد آمار، برآورد نماید ضروری است. در سال‌های اخیر شاهد پیشرفت‌هایی در مدل‌سازی پراکندگی‌های برف با استفاده از مدل‌های فیزیکی پیچیده بوده‌ایم (پومری و لی، ۲۰۰۰؛ ۲۶۶۲۰؛ لیستون و الدر، ۲۰۰۶؛ ۱۲۶۱؛ لهینگ و همکاران، ۲۰۰۸؛ ۱؛ اسنایدربوئر و پراکپ، ۲۰۱۱؛ ۵۲۶). معمولاً در اکثر این مدل‌سازی‌ها از مدل رقومی ارتفاع و پارامترهای مستخرج از آن استفاده شده است. توپوگرافی، تأثیر شدیدی بر پراکندگی برف دارد؛ اما به‌تنهایی یک عامل سبب شونده نمی‌باشد (مک‌کی و گری، ۱۹۸۱؛ ۱۷۰). پراکندگی مکانی پوشش برف، مربوط به تعدادی از فرایندهای مختلفی است که در مقیاس‌های گوناگون عمل می‌کنند. مقادیر بارش در یک منطقه به‌شدت تحت تأثیر تعامل زمین و آب‌وهوای آن منطقه (چولارتون و پری، ۱۹۸۶؛ ۳۳۶؛ بنیستون و همکاران، ۲۰۰۳؛ ۲۰؛ موت و همکاران، ۲۰۱۳؛ ۱۴۱۹) و همچنین عوامل مربوط به اقلیم مانند دما و بارش نیز از عوامل تأثیرگذار بر نوع و میزان بارش

و تصاویر ماهواره‌ای به‌عنوان ورودی‌ها برای انجام تخمینی هرچه دقیق‌تر عمق برف بهره گرفته شده و عملکرد آن با یکی از روش‌های پایه در مدل‌سازی عمق برف مقایسه گردد.

### مواد و روش‌ها

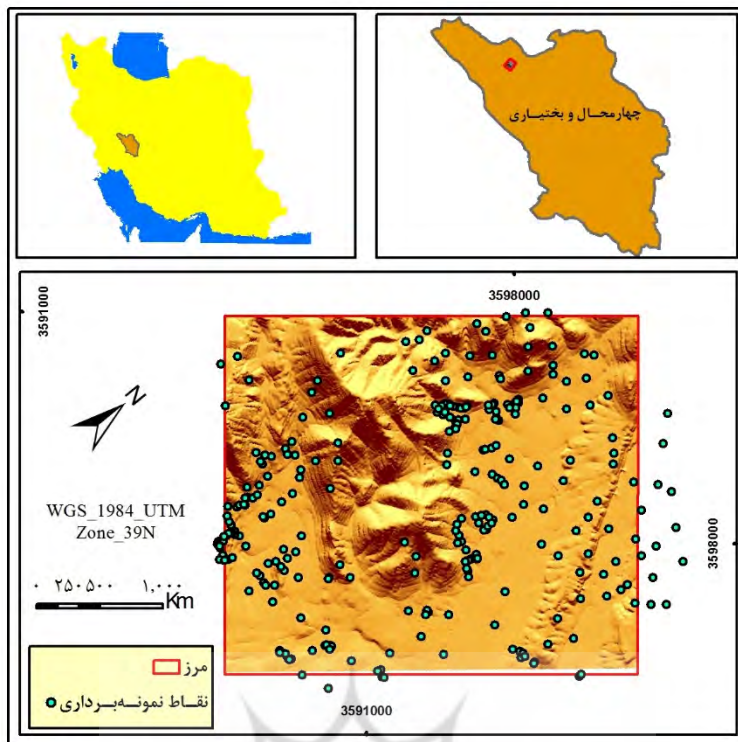
**منطقه مورد مطالعه:** منطقه کوه‌رنگ با مساحتی بالغ بر ۳۷۰۰ کیلومترمربع در غرب کشور ایران و استان چهارمحال و بختیاری قرار دارد که از نظر اقلیم‌شناسی، هیدرولوژی و توپوگرافی یک منطقه منحصربه‌فرد در کشور ایران محسوب می‌شود. دمای متوسط سالانه این منطقه ۸/۵ درجه سانتی‌گراد، بارش ۱۴۳۰ میلی‌متر، طول دوره یخبندان ۱۳۰ روزه و رژیم بارش زمستانه قرار دارد. این شهرستان به‌تنهایی ۱۰ درصد از کل آب کشور ایران را تأمین می‌کند و همچنین سرچشمه سه رودخانه بزرگ و حیاتی ایران یعنی زاینده‌رود، کارون و دز در این شهرستان قرار دارد.

**نمونه‌برداری صحرائی:** در این تحقیق محل ۱۰۰ نقطه جهت نمونه‌برداری در حوضه چلگرد به کمک روش هایپرکیوب که یک مدل تصادفی طبقه‌بندی‌شده است مشخص شد. با استفاده از این روش می‌توان نمونه‌برداری بهتری به کمک توزیع چند متغیر ایجاد نمود. این تکنیک که به‌طور کلی یک روش مدرن است داده‌های محیطی را به همان تعداد داده‌های نمونه‌های خواسته شده به‌صورت خوشه تقسیم نموده و سپس،  $n$  مقدار به‌دست‌آمده برای هر متغیر با متغیرهای دیگر جفت می‌شود. علاوه بر آن، تعداد ۱۹۵ نقطه دیگر نیز به‌صورت تصادفی از حوضه مورد مطالعه جمع‌آوری شد. سپس پارامترهای کمی موردنیاز برای پهنه‌بندی که شامل اطلاعات مرتبط با تصاویر ماهواره‌ای لندست ۸ و پارامترهای مشتق شده از مدل رقومی ارتفاع (رزولوشن ۱۰ متر) می‌باشد به کمک نرم‌افزار ساگا (SAGA) استخراج گردید جدول (۱). قبل از استخراج پارامترهای مذکور بر روی مدل رقومی ارتفاع فیلتری به نام Simple Filter گذاشته شد تا خطاهای آن برطرف شود. بدین ترتیب ۳۲ پارامتر به‌عنوان ورودی مدل‌ها در نظر گرفته شد.

راداری در برآورد عمق برف به‌دلیل بالابودن قدرت تفکیک مکانی بالای این تصاویر پی برده‌اند.

روش ماشین بردار پشتیبان ابتدا در سال ۱۹۹۲ توسط وپنیک معرفی گردید که بر پایه تئوری یادگیری آماری بنا نهاده شده است. در سال ۱۹۹۹، سویکنز و وندوال مدل حداقل مربعات ماشین بردار پشتیبان را معرفی نمودند (سویکنز و همکاران، ۲۰۰۲: ۸۵). این مدل محدودیت‌های یکسانی با روش ماشین بردار پشتیبان کلاسیک دارد؛ اما نسبت به این روش از پیچیدگی محاسباتی کمتر و دقت و سرعت بالاتری برخوردار است. هرچند این مدل‌ها نیازمند طیف وسیعی از داده‌های ورودی هستند؛ اما باید در نظر داشت که تخمین عمق برف با استفاده از لیست کاملی از ویژگی‌های در دسترس به‌عنوان ورودی‌های ماشین بردار پشتیبان، ممکن است به کاهش دقت تخمین مدل منجر شود (کیونگ، ۲۰۰۸: ۴۷۹). به همین دلیل یکی از مسائلی که در مبحث یادگیری ماشین مطرح است مسئله کاهش ویژگی است. این مسئله در بسیاری از کاربردها اهمیت دارد، زیرا در این کاربردها تعداد زیادی ویژگی وجود دارد که بسیاری از آن‌ها اضافی و بی‌ربط هستند. حذف نکردن این ویژگی‌ها علاوه بر اینکه بار محاسباتی را برای کاربرد موردنظر بالا می‌برد، باعث می‌شود که اطلاعات غیرمفید زیادی به همراه داده‌های مفید ذخیره شود.

منطقه کوه‌رنگ یکی از مناطق کوهستانی و برف‌گیر کشور ایران است که با توجه به حجم بالای نزولات آسمانی و همچنین رواناب ناشی از ذوب برف، نقش مهمی در تأمین آب موردنیاز جهت شرب، صنعت و کشاورزی شهرستان، استان‌های هم‌جوار و حتی کشور ایران را دارد به‌طوری‌که ۱۰ درصد از کل آب کشور ایران را تأمین می‌کند. با توجه به اهمیت فراوان تغییرات عمق برف و برآورد دقیق آن اگرچه تاکنون از روش‌های زیادی استفاده شده است؛ اما ضرورت محاسبه دقیق‌تر آن که با استفاده از روش‌های مدرنی نظیر یادگیری ماشین و پیاده‌سازی روش‌های انتخاب ویژگی و استفاده از پارامترهای ژئومورفومتری



شکل ۱: موقعیت مکانی منطقه مورد مطالعه و نقاط نمونه برداری شده

جدول ۱: پارامترهای کمکی به کاررفته در مدل

تراکم جریان	ارتفاع شیب	ارتفاع حوضه
شیب	مساحت اصلاح شده حوضه آبخیز	ارتفاع استاندارد شده
جهت جغرافیایی	طول شیب	موقعیت میانی شیب
شاخص همگرایی	شاخص قدرت آبراهه	شاخص همواری قله
سطح ویژه حوضه آبخیز	نیمرخ عرضی انحناء	شاخص همواری دره
شاخص رطوبتی توپوگرافی	نیمرخ طولی انحناء	شاخص تفاوت نرمال شده برف
فاکتور طول شیب	انحناء عمومی	عمق چاله‌ها
سطح اساس شبکه زهکشی	اثر باد	ارتفاع نرمال شده
باند های (۲،۳،۴،۵،۶،۷)	شیب حوضه آبخیز	مدل رقومی ارتفاع

مدل را بر روی داده‌های تست (۲۰ درصد داده‌ها) آزمایش گردید تا دقت این مدل برای پیش‌بینی عمق برف مورد نظر مشخص شود.

**انتخاب پارامترها با استفاده از همبستگی:** آنالیز حساسیت برای تعیین میزان حساسیت یک پارامتر خروجی به تغییرات در پارامترهای ورودی استفاده می‌شود. در این روش هرچه پارامتری مؤثرتر واقع شود دارای ضریب بزرگ‌تری نسبت به پارامترهای دیگر می‌باشد و همچنین اگر علامت ضریب مورد استفاده مثبت

**مدل‌سازی رگرسیون خطی چند متغیره:** تجزیه رگرسیون یک مدل آماری است که برای تعیین ارزش یک متغیر کمی باتوجه به رابطه‌اش با یک یا چند متغیر کمی دیگر به کار می‌رود. پس از استخراج پارامترهای کمکی در نقاط مورد مطالعه، بین ۳۲ پارامترهای ورودی و عمق برف، آنالیز رگرسیون چندمتغیره خطی صورت گرفت. به منظور برآزش معادله رگرسیون چندمتغیره، ۲۹۵ داده‌های عمق برف به عنوان متغیر پاسخ و پارامترهای فیزیکی به عنوان متغیر توصیفی در نظر گرفته شد. بعد از به دست آوردن رابطه رگرسیونی مرتبط، این

باشد، با عمق برف رابطه مستقیم خواهد داشت و اگر دارای علامت منفی باشد این رابطه عکس خواهد شد.

**مدل سازی به روش حداقل مربعات ماشین بردار پشتیبان:** اساس روش ماشین بردار پشتیبان توسط وینیک (۱۹۹۵) بر پایه یادگیری آماری ارائه گردید که از حداقل سازی ریسک ساختاری تبعیت می کند. در سال ۱۹۹۹ سویکنس و وندوال روش حداقل مربعات ماشین بردار پشتیبان را ارائه نمودند. این مدل برخلاف سایر ماشین های بردار پشتیبان به جای مسئله برنامه نویسی درجه دوم در حل معادلات از معادلات خطی استفاده می نماید، بنابراین از پیچیدگی محاسباتی کمتری و دقت بالاتری نسبت به ماشین بردار کلاسیک برخوردار می باشد (سیفی و ریاحی مدوار، ۲۰۱۲: ۸). مدل رگرسیونی حداقل مربعات ماشین بردار پشتیبان از رابطه (۱) تبعیت می کند:

که طرح آن برگرفته از طبیعت و بر اساس بقای برترین ها یا انتخاب طبیعی استوار می باشد. (میخائیل، ۱۹۹۹: ۱۱).

الگوریتم ژنتیک یک جمعیت اولیه تصادفی ایجاد می کند، اعضا در برابر مجموعه ای از آزمون ها مورد سنجش قرار می گیرند و مناسب ترین ها باقی می ماندند و بقیه کنار گذاشته می شوند. در واقع، الگوریتم ژنتیک یک روش برنامه نویسی است که از تکامل ژنتیکی به عنوان یک الگوی حل مسئله استفاده می کند. (سیواناندام و دپا، ۲۰۰۸: ۲؛ سوماسی و همکاران، ۲۰۰۸: ۱۲). در ادامه، نقطه داده های منحنی های نوری با تکیه بر الگوریتم ژنتیک کاهش داده می شوند. مراحل انجام این کار به صورت زیر است:

$$y(x_i) = W^T \cdot \varphi(x_i) + b \quad (1)$$

$W$  و  $b$  به ترتیب مقادیر وزن ها و بایاس تابع رگرسیون هستند که از طریق حداقل ساز تابع هدف در رابطه (۲) تعیین می گردند:

$$\text{Min}_{w,e,b} j(w, e) = \frac{1}{2} W^T w \frac{y}{2} \sum_{i=1}^N e_i^2 \quad (2)$$

با محدودیت:

$$y_i = W^T \sigma(x_i) + b + e_i \quad (3)$$

که  $y$  نشان دهنده پارامتر تنظیم کننده بخش خطا است و  $e_i$  نشان دهنده خطا داده های آموزشی می باشد. شکل لاگرانژی این مسئله به صورت رابطه (۴) می باشد:

$$L(w, b, e; a) = j(w, e) - \sum_{i=1}^N a_i \{W^T \varphi(x_i) + b + e_i - y_i\} \quad (4)$$

$\sigma_1$  ها ضرایب لاگرانژی می باشند. براساس شرایط کان-تاکر (KKT) مدل حداقل مربعات ماشین بردار پشتیبان به منظور تابع تخمین در رابطه (۵) ارائه گردیده است (سویکنس و همکاران، ۲۰۰۲: ۸).

$$y(x) = \sum_{i=1}^N a_i K(x, x_i) \quad (5)$$

به طوری که  $K(x, x_i) = \phi(x_i)^T \phi(x)$  به تابع کرنل معروف است.

**انتخاب ویژگی با استفاده از روش الگوریتم ژنتیک:** الگوریتم ژنتیک یک الگوریتم جستجوی تصادفی است

الف) آزمون های آماری (مجموع، بیشینه، کمینه، انحراف معیار، کجی، کشیدگی و پارامترهای شکل و میانه مربوط به برازش تابع توزیع لوگ نرمال) تمامی منحنی های نوری محاسبه می شوند و عمق برف داده های اولیه به عنوان فضای ویژگی منحنی های نوری به الگوریتم ژنتیک معرفی می شوند.

ب) از رگرسیون در الگوریتم ژنتیک برای استخراج ۵ نقطه داده از داده ها با طول ۳۲ نقطه داده استفاده می شود. بدین منظور متغیرهای را که بیشترین همبستگی (حداقل ۸۰ درصد) را با فضای ویژگی مرحله الف) دارند، انتخاب می کند.

ج) ۷۰ درصد از داده ها به عنوان داده های آموزشی به شبکه ماشین بردار پشتیبان معرفی می شوند و از عمق برف مربوط به هر کدام از داده ها به عنوان برچسب استفاده می شود، ۳۰ درصد از داده ها به عنوان تست به شبکه معرفی می شوند تا عمق آن ها به وسیله ماشین بردار پشتیبان پیش بینی شود.

د) در این مسئله از الگوریتم ژنتیک با تعداد نسل های ۱۰۰، جهش ۰/۰۰۱، احتمال تلفیق ۰/۶ و اندازه جمعیت ۵۰ استفاده شد.

**روش کریجینگ معمولی (O.K):** کریجینگ معمولی از جمله برآورد کننده های زمین آماری است که برای برآورد عمق در مقیاس های محلی مورد استفاده قرار می گیرد (کارول و کریسی، ۱۹۹۶: ۲۶۷). کریجینگ معمولی را به صورت یک جمع خطی وزن دار نشان

$$MRE_i = \frac{|X_i - Y_i|}{X_i} \quad (10)$$

که در آن،  $X_i$  و  $Y_i$  به ترتیب مربوط به مقادیر اندازه‌گیری شده و برآورد شده می‌باشد.  $\bar{x}$  و  $\bar{y}$  به ترتیب میانگین مقادیر مشاهداتی و برآوردی هستند و  $n$  تعداد داده‌ها را نشان می‌دهد. جذر میانگین مربعات خطا مبین اختلاف کلی بین مقادیر اندازه‌گیری شده و برآورد شده می‌باشد. درصد خطای نسبی در حالت بهینه یا حالتی که مقادیر اندازه‌گیری شده و برآورد شده مساوی باشند برابر صفر است. ضریب تبیین نیز هر چه به یک نزدیکتر باشد بهتر می‌باشد.

### نتایج و بحث

**خلاصه آماری داده‌ها:** در جدول (۲) خلاصه آماری داده‌های عمق برف آورده شده است. میانگین، انحراف معیار و دامنه تغییرات داده‌های عمق برف به ترتیب برابر ۳۹/۷۹، ۲۸/۱۱ و ۱۲۹ می‌باشد؛ و همچنین بیشینه و کمینه پارامتر عمق برف نیز به ترتیب برابر ۱۳۰ و ۱ سانتی‌متر می‌باشد.

می‌دهد که هدف یافتن وزن‌های آماری نمونه‌ها است به طوری که علاوه بر ناریب بودن برآورد، واریانس برآورد نیز حداقل گردد.

$$Z(X_i) = \sum_{i=1}^m \lambda_i Z(X_i) \quad (6)$$

در این رابطه  $Z(X_i)$  برآورد آماری از متغیر مورد نظر و  $\lambda_i$  وزن آماری اختصاص داده شده به نمونه است.  $M$  تعداد نمونه‌های قرار گرفته در همسایگی نقطه مورد نظر می‌باشد.

**پارامترهای ارزیابی مدل:** بدین منظور با کمک مدل حداقل مربعات ماشین بردار پشتیبان و انتخاب ویژگی با الگوریتم ژنتیک عمق برف در نقاط مورد نظر بررسی گردید و سپس جذر میانگین مربعات خطا (RMSE)، ضریب تبیین ( $R^2$ ) و مقدار میانگین درصد خطای نسبی (MMRE) در رابطه‌های (۷)، (۸) و (۹) محاسبه شده‌اند.

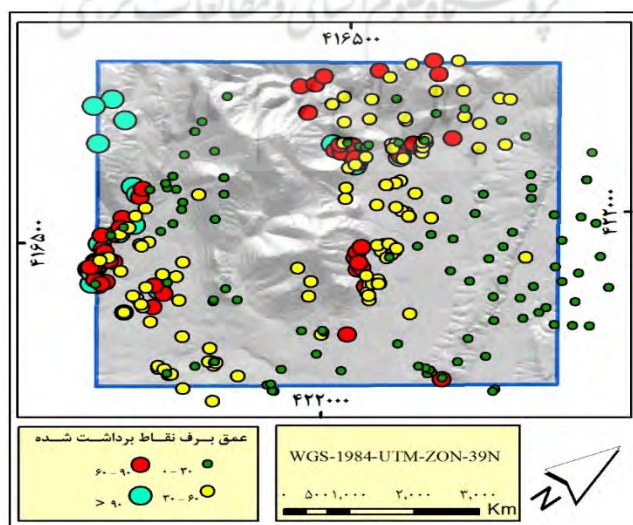
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (7)$$

$$R^2 = \frac{\sum (x_i - \bar{x})^2 (y_i - \bar{y})^2}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}} \quad (8)$$

$$MMRE = \frac{100}{N} \sum_{i=1}^N MRE_i \quad (9)$$

جدول ۲- خلاصه آماری داده‌های عمق برف


عامل	میانگین (سانتی‌متر)	انحراف معیار (سانتی‌متر)	کمینه (سانتی‌متر)	بیشینه (سانتی‌متر)	دامنه تغییرات (سانتی‌متر)	کشیدگی	چولگی	واریانس
عمق برف	۳۹/۷۹	۲۸/۱۱	۱	۱۳۰	۱۲۹	۳/۳۸	۰/۹۸	۷۹۰/۲۲



شکل ۲- نحوه پراکنش داده‌های عمق برف اندازه‌گیری شد

نتایج آنالیز حساسیت: انجام آنالیز حساسیت اطلاعات ارزشمندی درباره میزان حساسیت مدل نسبت به متغیرهای ورودی موردنظر در اختیار قرار می‌دهد (شکل ۴). مهم‌ترین پارامترها با توجه به درصدشان آورده شده است. مهم‌ترین پارامترهای مؤثر در مدل‌سازی عمق برف با استفاده از روش رگرسیون خطی به ترتیب اهمیت عبارت‌اند از: نیمرخ عرضی انحنا، شاخص تفاوت نرمال شده برف، انحنا عمومی و ارتفاع نرمال شده است، لذا به دلیل کم بودن تأثیر سایر پارامترها از آوردن آن‌ها خودداری شده است. در شکل (۴) نمونه‌ای از مؤثرترین پارامترها در مدل‌سازی عمق با استفاده از روش رگرسیون خطی چندمتغیره قابل مشاهده است.

نتایج رگرسیون خطی چندمتغیره: به منظور برآزش معادله رگرسیون خطی چندمتغیره، داده‌های نمونه‌برداری شده عمق برف به‌عنوان متغیر پاسخ و پارامترهای فیزیکی به‌عنوان متغیر توصیفی در نظر گرفته شد. بعد از به‌دست‌آوردن رابطه رگرسیون مرتبط، این مدل را بر روی داده‌های آزمون (۲۰ درصد داده‌ها) آزمایش کرده تا دقت این مدل برای پیش‌بینی عمق برف موردنظر مشخص شود؛ بنابراین با مشخص‌شدن مقادیر پیش‌بینی شده توسط مدل رگرسیون خطی این مقادیر (مقادیر تست) با مقادیر مشاهده‌ای مقایسه شد و نتایج در شکل (۳) آورده شده است. همچنین به‌منظور بررسی کارایی این مدل از معیارهای آماری که در جدول (۳) آمده است استفاده شده است.



شکل ۳- همبستگی مقادیر مشاهده شده و برآوردی عمق برف با استفاده از روش رگرسیون خطی چندمتغیره

جدول ۳- معیارهای آماری صحت‌سنجی رگرسیون خطی چندمتغیره

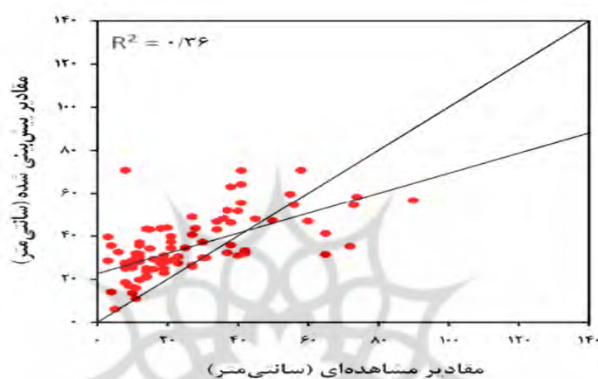
معیارهای آماری	r(%)	R2	RMSE(cm)	MMRE
مدل رگرسیون خطی	۶۷/۸	۰/۴۶	۲۱/۰۹	۸۶/۵۱



شکل ۴: نتایج اهمیت متغیرهای ورودی در پیش‌بینی عمق برف با استفاده از روش رگرسیون خطی چندمتغیره (بر حسب درصد)

میانگین مربعات خطا و درصد میانگین خطای نسبی استخراج گردید که در جدول (۴) و شکل (۵) قابل مشاهده است.

با توجه به جدول (۴) مشاهده می‌شود که میزان ضریب تبیین این مدل ۰/۳۶ می‌باشد؛ بنابراین این مدل تنها ۳۶ درصد از تغییرات عمق برف را توانسته است به درستی مدل کند همچنین میزان جذر میانگین مربعات خطا و درصد خطای نسبی هم تا حدودی زیاد می‌باشد؛ بنابراین این مدل دقت مناسبی جهت مدل‌سازی تغییرات عمق برف نداشته است.



شکل ۵: همبستگی مقادیر داده‌های تست مشاهده شده و برآوردی عمق برف با استفاده از روش حداقل مربعات ماشین بردار پشتیبان

جدول ۴: معیارهای آماری صحت‌سنجی حداقل مربعات ماشین بردار پشتیبان

معیارهای آماری	مدل
MMRE (%)	۱۱۶/۶۰
RMSE (cm)	۱۷/۸
R <sup>2</sup>	۰/۳۶
r (%)	۶۰
ماشین بردار پشتیبان	

عمق دره) کاهش می‌یابند. ابتدا پارامترهای شبکه داده‌های آموزشی را پیش‌بینی کرده که بهترین نتایج به‌ازای پارامترهای  $\text{gam}=10$  و  $\text{sig2}=0.2$  به دست آمد سپس با استفاده از این پارامترها داده‌های تست نیز پیش‌بینی شدند که نتایج در شکل (۶) و جدول (۵) آورده شده است؛ بنابراین با توجه به اینکه نتایج روش انتخاب ویژگی با الگوریتم ژنتیک و تلفیق آن با روش حداقل مربعات ماشین بردار پشتیبان نسبت به نتایج روش حداقل مربعات ماشین بردار پشتیبان بهتر بود اقدام به تهیه نقشه پهنه‌بندی عمق برف با استفاده از روش تلفیق شده حداقل مربعات ماشین بردار پشتیبان

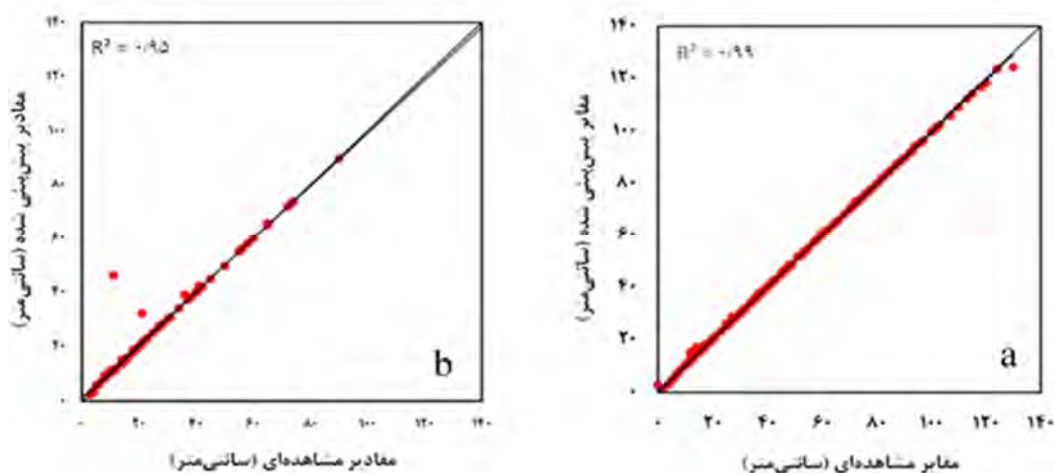
**نتایج روش حداقل مربعات ماشین بردار پشتیبان:** این روش یکی از روش‌های توسعه‌یافته ماشین بردار پشتیبان می‌باشد که در این مدل دو پارامتر  $\text{gam}$  و  $\text{sig2}$  نقش تعیین‌کننده در پیش‌بینی عمق برف دارد؛ بنابراین جهت تعیین بهترین مقادیر این دو پارامتر از روش سعی خطا استفاده شد و بهترین مقادیر برای این دو پارامتر به ترتیب ۲/۱۵ و ۱۵۰/۸ انتخاب گردید. مقادیر خروجی این مدل با مقادیر مشاهده‌ای متناظر آن مقایسه شد و جزئیات آن بر اساس ضریب همبستگی، ضریب تعیین، جذر

**نتایج تلفیق الگوریتم ژنتیک و حداقل مربعات ماشین بردار پشتیبان:** با استفاده از الگوریتم ژنتیک برای افزایش سرعت پردازش و آماده‌سازی برای شبکه ماشین بردار پشتیبان که به‌عنوان یک پیش‌بینی‌کننده عمل می‌کند تعداد ورودی‌ها کاهش داده شد. بسته نرم‌افزاری شبکه ماشین بردار پشتیبان با داده‌های به طول ۵ بسیار مناسب اجرا شد. بدین منظور تعداد متغیرها که تعداد آن‌ها ۳۲ می‌باشد ۵ نقطه داده که بیشترین همبستگی (حداقل ۸۰ درصد) را با عمق برف دارند (باند ۵ تصاویر ماهواره‌ای، سطح اساس شبکه زهکشی، شیب حوضه آبخیز، ارتفاع شیب و



عمق برف از دو ترانسکت شمال شرقی - جنوب غربی و شمال غربی - جنوب شرقی استفاده شد.

و الگوریتم ژنتیک نمودیم (شکل ۷)؛ همچنین جهت مشخص شدن رابطه عمق برف با پارامترهای مؤثر در



شکل ۶- همبستگی مقادیر مشاهده شده و برآوردی عمق برف داده‌های آموزش (a) و تست (b) با استفاده از روش تلفیق حداقل مربعات ماشین بردار پشتیبان و الگوریتم ژنتیک

جدول ۵- معیارهای آماری صحت‌سنجی روش تلفیق شده الگوریتم ژنتیک و حداقل مربعات ماشین بردار پشتیبان

مدل	معیارهای آماری	r(%)	R <sup>2</sup>	RMSE(cm)	MMRE (%)
تلفیق شده الگوریتم ژنتیک و حداقل مربعات ماشین بردار پشتیبان		۹۷	۰/۹۵	۳/۹۷	۶/۷۹


خلاف این را نشان داد. اما آن چیزی که در ارتفاعات و دامنه‌ها در تله اندازی و تجمع برف تأثیرگذار است پارامتر انحناء می‌باشد که شامل انحنای مسطح یا نیمرخ عرضی انحناء و قائم یا نیمرخ طولی انحناء است (قرایی‌منش و همکاران، ۲۰۱۶: ۳۰). اما باتوجه به شکل‌های (۸، a، ۹، d و ۱۰، d) در خط‌القع‌رهای موجود در ارتفاعات که محل مناسبی برای انباشت برف می‌باشد نیز مشاهده می‌شود عمق برف کم می‌باشد که رابطه معکوس عمق برف و عمق دره در منطقه مورد مطالعه به چشم می‌خورد بنابراین، این می‌تواند مؤید این مطلب باشد که ارتفاعات تحت‌تأثیر تابش خورشید و شیب قرار گرفته و ذوب در این مناطق اتفاق افتاده است که رواناب ناشی از ذوب برف باعث کاهش عمق برف در این مناطق شده است. کم‌ترین میزان عمق برف در منطقه هم در مناطق شرقی که پست و هموار می‌باشند همچنین مسیره‌های

با توجه به شکل (۷) مشاهده می‌شود که بیشترین میزان عمق برف در مناطق غربی منطقه مورد مطالعه می‌باشد که علت آن می‌تواند وجود ارتفاعات در این مناطق و جهت باد غالب منطقه که عمدتاً جهت شرقی - غربی دارند، باشد. تأثیر جهت روی عمق برف به ازاء بازه‌های مختلف جهت، متفاوت است. بر اساس نتایج حاصل، صرفاً جهت‌هایی از شیب با عمق برف رابطه دارند، که از موقعیت بادپناهی بیشتری برخوردار بودند؛ بنابراین جهت‌های شرقی به علت بادرویی، عمق برف کمتر و جهت‌های غربی به علت بادپناهی عمق برف بیشتری دارند. این نتیجه عکس نتیجه‌ای می‌باشد که مارچاند و کیلینگویست (۲۰۰۱: ۷)، در منطقه مورد مطالعه خود واقع در نروژ، منتشر نموده‌اند. آن‌ها ذکر نموده‌اند که در شیب‌های رو به باد، همبستگی بیشتری بین عمق برف و جهت شیب برقرار است حال آنکه نتایج مشاهدات در این تحقیق

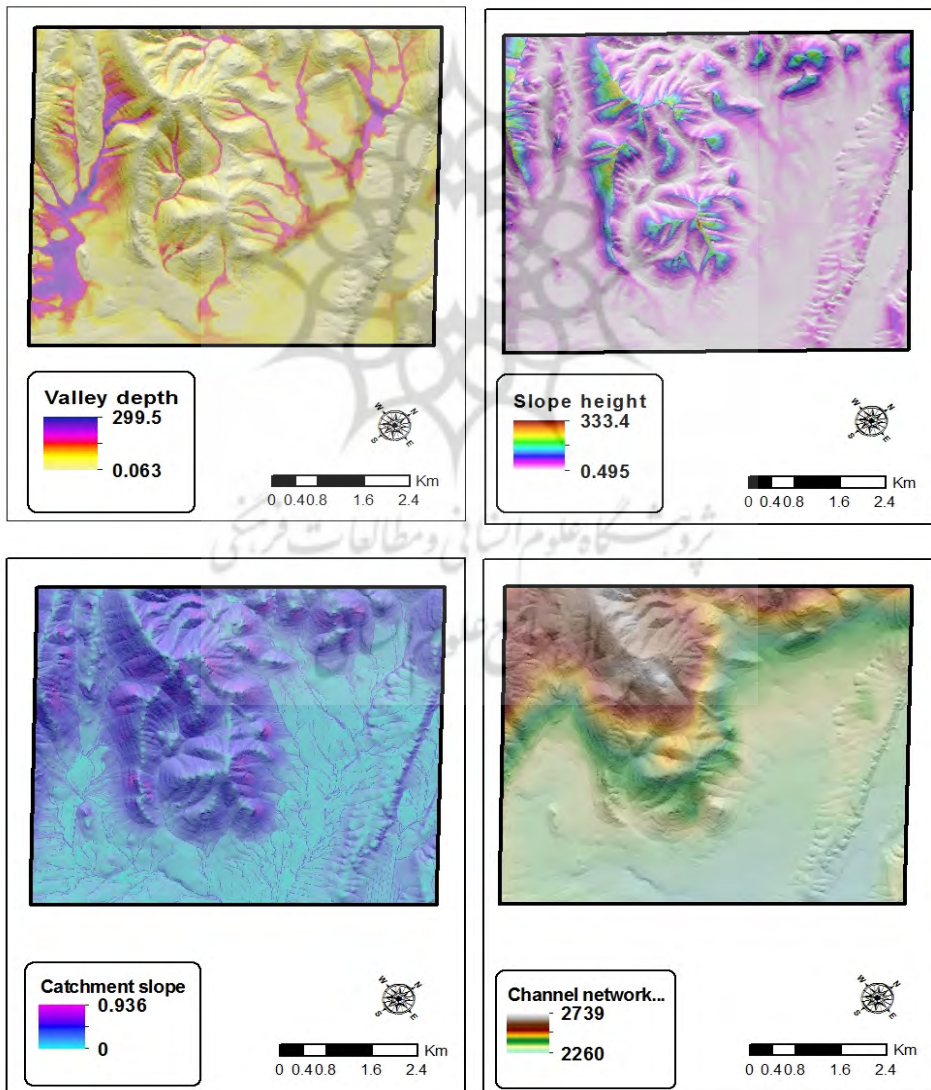
شیب حوضه آبخیز در این مطالعه و مقایسه با نتایج برخی از محققین نظیر (بلوچل و همکاران، ۱۹۹۱: ۳۱۷۵؛ شابان و همکاران، ۲۰۰۴: ۶۵۰)، که رابطه عمق برف با زاویه شیب را معکوس و برخی دیگر مستقیم (اریکسون و همکاران، ۲۰۰۵: ۱۲؛ مارچاند و کیلینگویت، ۲۰۰۱) به دست آورده‌اند، همچنین قرایی‌منش و همکاران (۲۰۱۶: ۳۰) نیز شیب را به‌عنوان یکی از عوامل مؤثر در عمق برف معرفی نمودند؛ بنابراین می‌توان گفت که رابطه عمق برف با زاویه شیب، تحت تأثیر شرایط منطقه‌ای قرار دارد. باتوجه به شکل (۸، d) یکی دیگر از ویژگی‌هایی که با استفاده از روش تلفیق شده حداقل مربعات ماشین بردار پشتیبان و الگوریتم ژنتیک در مدل‌سازی عمق برف مناسب تشخیص داده شد پارامتر سطح اساس شبکه زهکشی می‌باشد که این نتیجه مشابه نتیجه‌ای است که قرایی‌منش و همکاران (۲۰۱۶: ۳۰)، این پارامتر را به‌عنوان مهم‌ترین پارامتر در مدل‌سازی عمق برف اعلام نمودند. این‌گونه اختلاف‌ها در نتایج تحقیقات در زمینه برف، بیان‌کننده این موضوع است که تأثیر عوامل توپوگرافی، به‌عنوان بخشی از عواملی که قابلیت توصیف تغییرات مکانی خصوصیات برف را دارند، بر تغییرات برف انباشته، تابع شرایط اقلیمی و جغرافیایی بوده و در مناطق مختلف، متفاوت است به‌طوری‌که ساودرا و همکاران (۲۰۱۸: ۱۰۲۷) همبستگی بالای ماندگاری برف با عوامل اقلیمی من جمله دما و بارش و تأثیرگذاری عرض جغرافیایی و ارتفاع را بر این عوامل تأیید کرده است.

جریان آب و عمق دره‌ها می‌باشد که کم بودن عمق برف در این مناطق چند علت می‌تواند داشته باشد که آن‌ها را می‌توان این‌گونه بیان کرد:

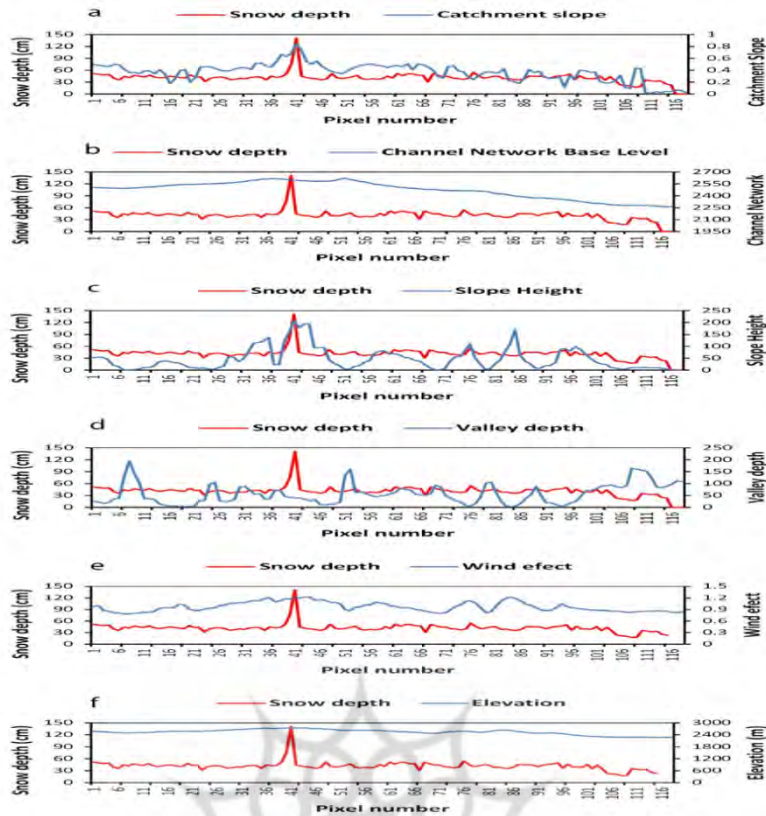
۱- جهت بادهای غالب منطقه که عمدتاً شرقی- غربی می‌باشند؛ بنابراین وزش باد در این مناطق باعث شده است تا برف از این مناطق برداشته شده و در ارتفاعات موجود در غرب منطقه انباشته شده است. ۲- عامل دیگری که باعث شده است عمق برف در مناطق پست و هموار کم باشد احتمالاً کاربری منطقه باشد که عمدتاً کشاورزی و مسکونی می‌باشد؛ بنابراین باتوجه به اینکه دما و بیلان انرژی در این مناطق بیشتر است امکان دارد در این مناطق ذوب اتفاق افتاده باشد و عمق برف کاهش یافته باشد. رابطه عمق برف با ارتفاع در حوضه مطالعاتی، تحت تأثیر سطوح ارتفاعی می‌باشد. به‌گونه‌ای که در ارتفاعات پایین، عمق برف کم و در ارتفاعات بالاتر عمق برف بیشتر است و باتوجه به شکل‌های (۹، f) و (۱۰، f) که نحوه تغییرات عمق برف نسبت به ارتفاع را نشان می‌دهد می‌توان به این موضوع پی برد. این نتیجه از آن جهت مورد اهمیت است که در مطالعاتی نظیر بلوچل و همکاران (۱۹۹۱: ۳۱۷۵) و مارچاند و کیلینگویت (۲۰۰۱: ۷)، معنی‌دار بودن رابطه خطی عمق برف با ارتفاع به اثبات رسیده است. هرچند در خصوص ارتباط بین عمق برف و ارتفاع نتایج متفاوتی نیز ارائه گردیده است. به‌طوری‌که برخی آن را کلاً مستقیم (شابان و همکاران، ۲۰۰۴: ۶۴۸) و برخی معکوس (اریکسون و همکاران، ۲۰۰۵: ۸) ذکر کرده‌اند. باتوجه به شکل‌های (۸، c؛ ۹، a و ۱۰، a) و ارتباط مستقیم عمق برف با



شکل ۷- نقشه پهنه‌بندی عمق برف با استفاده از روش تلفیق شده حداقل مربعات ماشین بردار پشتیبان و الگوریتم ژنتیک



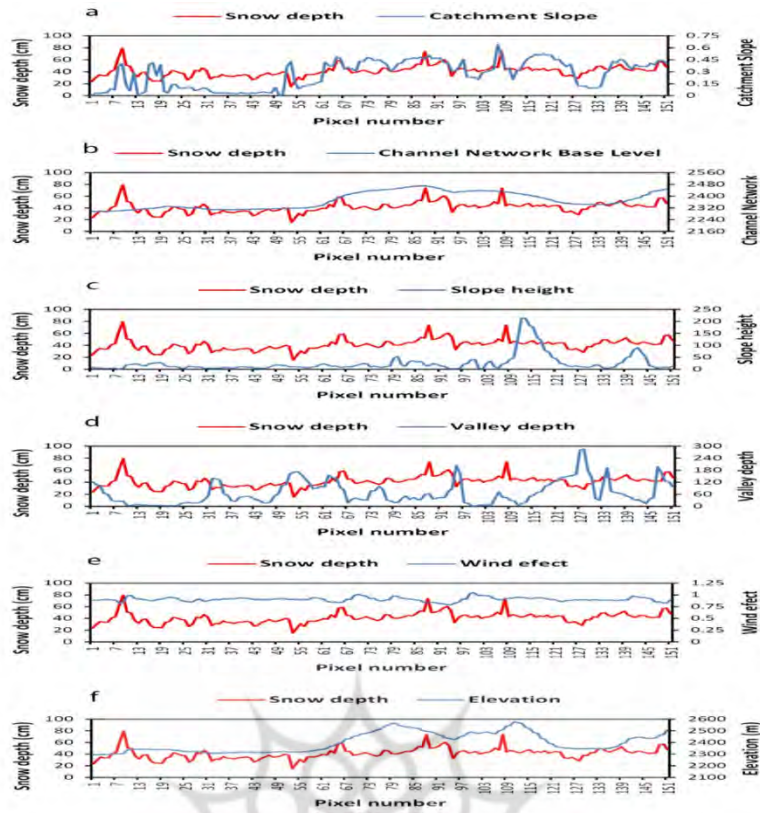
شکل ۸- نمونه‌ای از ویژگی‌های انتخاب شده با استفاده از روش الگوریتم ژنتیک



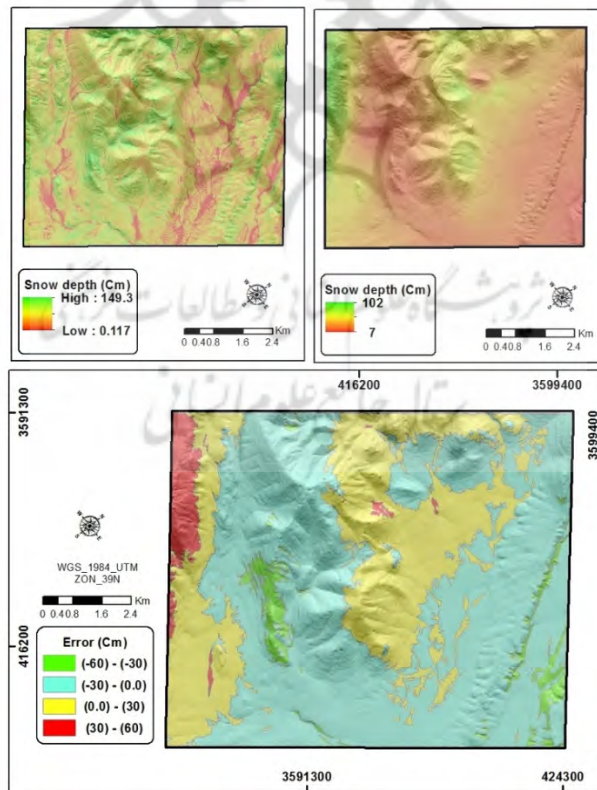
شکل ۹- نمودار تغییرات افقی عمق برف و تعدادی از پارامترهای ژئومورفومتری

ژنتیک در مدل‌سازی تغییرات عمق برف می‌باشد. در نهایت از تفاوت خروجی مدل تلفیق شده حداقل مربعات ماشین بردار پشتیبان با الگوریتم ژنتیک و کریجینگ معمولی یک نقشه تهیه گردید (شکل ۱۱، C). توانایی مدل تلفیق شده حداقل مربعات ماشین بردار پشتیبان با الگوریتم ژنتیک در مدل‌سازی عمق برف، در مناطق مسطح و دارای شیب کم به دلیل یکنواختی عمق برف نقاط برداشت شده و تعداد نقاط بیشتر نمونه‌برداری بهتر از مناطق مرتفع و دارای شیب‌های زیاد می‌باشد به این دلیل که در مناطق مرتفع هم میزان عمق برف متغیر می‌باشد و هم به دلیل صعب‌العبور بودن تعداد کمتری نقاط برداشت شده است؛ بنابراین مدل در آموزش داده‌های این مناطق دقت کمتری داشته است.

با توجه به اینکه مدل تلفیق شده حداقل مربعات ماشین بردار پشتیبان با الگوریتم ژنتیک نتایج بهتری را در مدل‌سازی عمق برف ارائه کرده است؛ بنابراین نقشه پهنه‌بندی عمق برف با استفاده از این مدل ترسیم گردید (شکل ۱۱، a). جهت بررسی کارایی این مدل اقدام به مقایسه این مدل با مدل کریجینگ معمولی شد. در جدول (۶) مشخصات واریوگرام بهترین روش کریجینگ معمولی و در شکل (۱۱، b) نقشه پهنه‌بندی عمق برف با مدل کریجینگ معمولی مشاهده می‌گردد. همچنین تفاوت اختلاف میانگین مدل کریجینگ معمولی و مدل تلفیق شده حداقل مربعات ماشین بردار پشتیبان با الگوریتم ژنتیک برابر با ۶/۰۶- شد که حاکی از توانایی مدل تلفیق شده حداقل مربعات ماشین بردار پشتیبان با الگوریتم



شکل ۱۰- نمودار تغییرات عمودی عمق برف و تعدادی از پارامترهای ژئومورفومتری



شکل ۱۱- نقشه پهنه‌بندی عمق برف با استفاده از مدل تلفیق شده حداقل مربعات ماشین بردار پشتیبان با الگوریتم ژنتیک (a) و کریجینگ معمولی (b)، تفاوت ارزش رقومی مدل تلفیق شده حداقل مربعات ماشین بردار پشتیبان با الگوریتم ژنتیک و کریجینگ معمولی (c)

جدول ۶- مشخصات وار یوگرام کریجینگ معمولی

RMSE	Partial Sill	Nugget	Model	Type
18.78	0.61	0.30	Exponential	O.K

### نتیجه‌گیری

در این مطالعه پتانسیل پارامترهای ژئومورفومتری، شاخص‌های ماهواره‌ای و تصاویر ماهواره‌ای در ارزیابی توزیع مکانی عمق برف از طریق الگوریتم‌های مبتنی بر یادگیری ماشین سنجدیده شد. پارامترهای ژئومورفومتری و شاخص‌های ماهواره‌ای متغیرند که به‌سادگی از روی مدل رقومی ارتفاع و تصاویر ماهواره‌ای قابل استخراج هستند؛ بنابراین روش حداقل مربعات ماشین بردار پشتیبان با استفاده از ۳۲ پارامتر مستخرج از مدل رقومی ارتفاع و تصاویر ماهواره‌ای توانست مدل‌سازی عمق برف را با ضریب تبیین ۰/۳۶ و جذر میانگین مربعات خطای ۱۷/۸ انجام دهد، بنابراین شبکه ماشین بردار پشتیبان بدون کاهش تعداد متغیرها نتایج ضعیفی را به ما ارائه کرد. با وجود تعداد زیاد این پارامترها، با استفاده از روش تلفیق یافته حداقل مربعات ماشین بردار پشتیبان و الگوریتم ژنتیک پارامترهایی چون سطح اساس شبکه زهکشی، عمق دره‌ها یا چاله‌ها، ارتفاع شیب، شیب حوضه آبخیز و باند ۵ تصاویر ماهواره‌ای که بیشترین همبستگی را با عمق برف داشتند به‌عنوان ویژگی‌های مؤثر در مدل‌سازی عمق برف انتخاب شدند در صورتی که قرایی‌منش و همکاران (۲۰۱۶: ۲۶)، پارامترهای سطح اساس شبکه زهکشی، قدرت آبراهه، شاخص رطوبتی و ارتفاع را به‌عنوان مهم‌ترین پارامترهای مؤثر در عمق برف معرفی کردند. روش‌های یادگیری ماشین و هوش مصنوعی کاربردهای بسیاری را در علم هیدرولوژی دارند و محققان زیادی نیز از این روش‌ها در موضوعات مختلف و به‌خصوص برف استفاده کرده و نتایج متفاوتی نیز به دست آوردند به گونه‌ای که قرایی‌منش و همکاران (۲۰۱۶: ۲۶)، که به مقایسه شبکه عصبی مصنوعی و درخت تصمیم در مدل‌سازی توزیع مکانی عمق برف در یک منطقه نیمه‌خشک در ایران پرداختند به این نتیجه رسیدند که درخت تصمیم

نتایج بهتری را در بر دارد همچنین تدسکو و همکاران (۲۰۰۴: ۷۶)، از شبکه عصبی مصنوعی برای برآورد ضخامت برف و آب معادل برف استفاده نمودند. نتایج آن‌ها مؤید صحت و دقت بالای شبکه عصبی مصنوعی در مقایسه با الگوریتم‌های پردازش تصاویر ماهواره‌ای بود. بنابراین این پژوهش روشی جدید را برای توزیع مکانی عمق برف ارائه کرده است که برای اولین بار در این محبت استفاده شده است. از آنجایی که روش‌های انتخاب ویژگی ابعاد دادگان را کاهش می‌دهند، الگوریتم‌های یادگیری ماشین می‌توانند سریع‌تر عمل کرده و بهترین خروجی را ارائه دهند؛ بنابراین روش تلفیق یافته حداقل مربعات ماشین بردار پشتیبان و الگوریتم ژنتیک با انتخاب ۵ ویژگی ذکر شده در بالا از بین ۳۲ ویژگی ورودی، توانست مدل‌سازی عمق برف را با ضریب تبیین ۰/۹۵ و جذر میانگین مربعات خطا ۳/۹۷ انجام دهد.

در این پژوهش از پارامترهایی چون کاربری اراضی و بازتابش خورشید استفاده نشده است؛ بنابراین باتوجه‌به اینکه احتمال دارد این عوامل نیز در مدل‌سازی عمق برف مؤثر باشند پیشنهاد می‌گردد در سایر مطالعات از این پارامترها نیز استفاده گردد، همچنین باتوجه‌به اینکه منطقه مورد مطالعه از لحاظ مساحت یک منطقه وسیعی می‌باشد و لذا از لحاظ کاربری اراضی، ارتفاع، شیب و جهت متغیر می‌باشد پیشنهاد می‌گردد در مطالعات بعدی منطقه از لحاظ همگنی بررسی شود.

بنابراین، در تحقیق حاضر بر خلاف مطالعات گذشته سعی شد از تعداد پارامترهای بیشتری که به نظر می‌رسد در مدل‌سازی عمق برف تأثیر داشته باشد و همچنین از مدل رقومی ارتفاع و تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالاتر استفاده گردید تا سعی شود مدل‌سازی عمق برف با دقت بهتری انجام شود.

## منابع

1. Balk, Benjamin, and Elder, Kelly. (2000). Combining binary decision tree and geostatistical methods to estimate snow distribution in a mountain watershed, *Water Resources Research*, 36(1), 13–26.
2. Bavay, M., Grunewald, T., and Lehning, M. (2013). Response of snow cover and runoff to climate change in high Alpine catchments of Eastern Switzerland, *Advances in Water Resources*, 55(1), 4–16.
3. Beniston, M., Keller, F., and Goyette, S. (2003). Snow pack in the Swiss Alps under changing climatic conditions: an empirical approach for climate impacts studies, *Theoretical and Applied Climatology*, 74, 19–31.
4. Blöschl, G., Kirnbauer, R., and Gutknecht, D. (1991). Distributed Snowmelt Simulations in an Alpine Catchment: 1. Model Evaluation on the Basis of Snow Cover Patterns, *Water Resources Research*, 27(12), 3171–3179.
5. Carrol, S.S., and Cressie, N. (1996). A comparison of geostatistical methodologies used to estimate snow water equivalent. *Water Resources Bull*, 32, 267–278.
6. Choulaton, T.W., and Perry, S.J. (1986). A model of the orographic enhancement of snowfall by the seeder-feeder mechanism, *Quarterly Journal of the Royal Meteorological Society*, 112(472), 335–345.
7. Cline, D.W., Bales, R.C., and Dozier, J. (1998). Estimating the spatial distribution of snow in mountain basins using remote sensing and energy balance modeling. *Water Resources Research*, 34(5), 1275–1285.
8. Dadić, R., Corripio, J.G., and Burlando, P. (2008). Mass-balance estimates for Haut Glacier d'Arolla, Switzerland, from 2000 to 2006 using DEMs and distributed mass-balance modeling, *Annals of Glaciology*, 49, 22–26.
9. Elder, k., Dozier, J., and Michaelsen, J. (1991). Snow accumulation and distribution in an Alpin Watershed. *Water Resources Research*, 27(7), 1541–1552.
10. Elder, K., Rosenthal, R., and Davis, R.E. (1998). Estimating the spatial distribution of snow water equivalent in a mountain watershed. *Hydrology Processes*, 12, 1793–1808.
11. Erickson, T.A., Williams, M.W., and Winstral, A. (2005). Persistence of topographic controls on the spatial distribution of snow in rugged mountain, Colorado, United States, *Water Resources Research*, 41(04014), 1–17.
12. Gharaei-Manesh, S., Fathzadeh, A., Taghizadeh-Mehrjardi, R. (2016). Comparison of artificial neural network and decision tree models in estimating spatial distribution of snow depth in a semi-arid region of Iran. *Cold Regions Science and Technology*, 122, 26–35.
13. Iman R.L., and Conover, W.J. (1982). A Distribution-Free Approach to Inducing Rank Correlation Among Input Variables, *Communications in Statistics, Simulation and Computation* 11(3), 311–334.
14. Keung, J.W., Kitchenham, B., and Jeffery, D.R. (2008). Analogy-x: providing statistical inference to analogy-based software cost estimation, *IEEE Transactions on Software Engineering*, 34(4), 471–484.
15. Lehning, M., Lowe, H., Ryser, M., and Raderschall, N. (2008). Inhomogeneous precipitation distribution and snow transport in steep terrain, *Water Resources Research*, 44(7).
16. Lehning, M., Volksch, I., Gustafsson, D., Nguyen, T.A., Stahli, M., and Zappa, M. (2006). ALPINE3D: a detailed model of mountain surface processes and its application to snow hydrology, *Hydrological Processes*, 20(1), 2111–2128.
17. Liston, G.E., and Elder, K. (2006). A distributed snow-evolution modeling system (SnowModel), *Journal of Hydrometeorology*, 7(6), 1259–1276.
18. Litaor, M.I., Williams, M., and Seastedt, T.R. (2008). Topographic controls on snow distribution, soil moisture, and species diversity of herbaceous alpine vegetation, Niwot Ridge, Colorado, Featured in *Journal of Geophysical Research: Biogeosciences*, 113(11).
19. Lundquist, J.D., and Dettinger, M.D. (2005). How snowpack heterogeneity

- affects diurnal streamflow timing, *Water Resources Research*, 41(5), 1-14.
20. Marchand, W.D., and Killingtveit, A. (2001). Analyses of the Relation Between Spatial Snow Distribution and Terrain Characteristics, 58<sup>th</sup> Eastern Snow Conference Ottawa, Ontario, Canada.
  21. McKay, G.A., and Gray, D.M. (1981). The distribution of the snow cover, in: *Handbook of Snow*, edited by: Gray, D. and Hale, D., Pergamon Press Canada Ltd, 153–190.
  22. McKay, M.D., Conover W.J., and Beckman, R.J. (1979). A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code, *Technometrics*, 21(2), 239-245.
  23. Michael, D. (1999). *The simple Genetic Algorithm: Foundation and Theory*. The MIT Press.
  24. Mott, R., Scipion, D., Schneebeli, M., Dawes, N., Berne, A., and Lehning, M. (2014). Orographic effects on snow deposition patterns in mountainous terrain, *Journal of Geophysical Research: Atmospheres*, 119, 1419-1439.
  25. Pomeroy, J.W., and Li, L. (2000). Prairie and arctic areal snow cover mass balance using a blowing snow model, *Journal of Geophysical Research: Atmospheres*, 105(21), 26619–26634.
  26. Pomeroy, J.W., Gray, D M., Shook, K.R., Toth, B., Essery, R.L.H., Pietroniro, A., and Hedstrom, N. (1998). An evaluation of snow accumulation and ablation processes for land surface modelling, *Hydrol. Process.*, 12(15), 2339–2367.
  27. Saavedra, F., Kampf, S., and Sibold, J. (2018). Changes in Andes snow cover from MODIS data, 2000–2016. *The Cryosphere*, Vol. 12, pp. 1027-1046.
  28. Schneiderbauer, S., and Prokop, A. (2011). The atmospheric snow-transport model: SnowDrift3D, *Journal of Glaciology*, 57(203), 526–542.
  29. Schweizer, J., Jamieson, J.B., and Schneebeli, M. (2003). Snow avalanche formation, *Reviews of Geophysics*, 41(3).
  30. Seifi, A., and Riahi-Madvar, H. (2012). Input Variable Selection in expert systems based on hybrid Gamma Test-Least Square Support Vector Machine, ANFIS and ANN models. Provisional chapter. INTECH.
  31. Shaban, A., Faour, G., Khawlie, M., and Abdallah, C. (2004). Remote sensing application to estimate the volume of water in the form of snow on Mount Lebanon, *Hydrological Sciences Journal*, 49(4), 643-653.
  32. Sivanandam, S.N., and Deepa, S.N. (2008). *Introduction to Genetic Algorithms*, Springer Germany.
  33. Stewart, I. T., Cayan, D.R., and Dettinger, M.D. (2005). Changes toward earlier streamflow timing across western North America. *J. Clim*, Vol. 18, pp. 1136-1155.
  34. Sumathi, S., Hamsapriya, T., and Surekha, P. (2008). *Evolutionary Intelligence*, Springer, Indi.
  35. Suykens, J.A.K., Gestel, T.V., Brabanter, J.D., Moor, B.D., and Vandewalle, J. (2002). *Least Squares Support Vector Machines*. Copyright by World Scientific Publishing Co. Pie. Ltd. PP 308.
  36. Tedesco, M., Pulliainen, J., Takala, M., Hallikainen, M., and Pampaloni, P. (2004). Artificial neural network-based techniques for the retrieval of SWE and snow depth from SSM/I data. *Remote Sens. Environ*, 90, 76-85.
  37. Tsai, Y., Dietz, A., Oppelt, N., and Kuenzer, C. (2019). Remote sensing of snow cover using Spaceborne SAR: A review. *Remote Sensing*, 11, 1-44.
  38. Varade, D., Maurya, A.K., Dikshit, O., Singh, G., and Manickam, S. (2019). Snow depth in Dhundi: An estimate based on weighted bias corrected differential phase observations of dual polarimetric bi-temporal Sentinel-1 data. *International Journal of Remote Sensing*, 41(8), 3031-3053.
  39. Zhang, H., Zhang, F., Che, T., and Wang, S. (2020). Comparative evaluation of VIIRS daily snow cover product with MODIS for snow detection in China based on ground observations, *Science of The Total Environment*, pp.138-156.