

مقایسه روش رگرسیون غیرخطی با روش‌های هوش محاسباتی در برآورد توزیع مکانی آب معادل برف در سراب کارون

حسین طبری^۱، صفر معروفی^{۱*}، حمید زارع ایبانه^۱، رضا امیری چایجان^۱، محمدرضا شریفی^۲

و علی محمد آخوندعلی^۳

(تاریخ دریافت: ۱۳۸۷/۵/۲؛ تاریخ پذیرش: ۱۳۸۷/۱۰/۱۶)

چکیده

معمولاً برای ارزیابی منابع آب مرتبط با برف در حوضه‌های کوهستانی، از آب معادل برف استفاده می‌شود. در این تحقیق، با بهره‌گیری از داده‌های مشاهده‌ای، کاربرد رگرسیون غیرخطی، شبکه عصبی مصنوعی و هم‌چنین بهینه‌سازی پارامترهای شبکه با روش الگوریتم ژنتیک در برآورد ضخامت برف و آب معادل آن بررسی شد. بدین منظور مقادیر برآورد شده با شبکه عصبی مصنوعی، روش تلفیقی شبکه عصبی-الگوریتم ژنتیک و روش رگرسیونی با مقادیر مشاهده شده مقایسه گردید. بدین منظور اندازه‌گیری‌های صحرایی در بهمن سال ۱۳۸۴ در سراب کارون انجام گردید. هم‌چنین ضریب هم‌بستگی، میانگین مربع خطا و میانگین خطای مطلق برای ارزیابی کارایی مدل‌های مختلف شبکه‌های عصبی مصنوعی و رگرسیون غیرخطی مورد استفاده قرار گرفت. با توجه به نتایج به دست آمده، روش‌های شبکه عصبی مصنوعی و شبکه عصبی تلفیق‌یافته با الگوریتم ژنتیک در برآورد آب معادل برف مناسب تشخیص داده شدند. به طور کلی از میان روش‌های به کار رفته، روش شبکه عصبی تلفیق‌یافته با الگوریتم ژنتیک بهترین نتیجه ($r=0/84$ ، $MSE=0/041$ و $MAE=0/051$) را در بر داشته است. با توجه به پارامترهای مورد بررسی، ارتفاع از سطح دریا، مهم‌ترین پارامتر مؤثر جهت برآورد آب معادل برف است.

واژه‌های کلیدی: آب معادل برف، شبکه عصبی مصنوعی، الگوریتم ژنتیک، رگرسیون غیرخطی، حوضه کارون

مقدمه

معادل برف (Snow Water Equivalent, SWE) برآورد شود. تخمین توزیعی آب معادل برف در سطح می‌تواند نقش مؤثری در مدیریت بهره‌برداری از این منابع ایفا کند. عدم اطلاع از توزیع مکانی آب معادل برف، سبب خطای زیادی در تخمین حجم آب می‌گردد. بنابراین برای برآورد دقیق‌تر حجم و رواناب حاصل از ذخایر برفی، دستیابی به توزیع مکانی

در مناطق کوهستانی بخش قابل توجهی از بارش به صورت برف است. اطلاعاتی در مورد حجم آب ذخیره شده در برف انباشت، در بسیاری جنبه‌ها مانند: ارزیابی خطر سیلاب، تولید برقابی و شرایط مرزی در مدل‌های پیش‌بینی هوا بسیار مهم است (۱۷). برای ارزیابی مقدار آب به شکل برف، باید آب

۱. به ترتیب دانشجوی سابق کارشناسی ارشد و استادیاران آبیاری و زه‌کشی، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان

۲. استادیار مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه صنعتی جندی شاپور، دزفول

۳. دانشیار مهندسی علوم آب، دانشکده کشاورزی، دانشگاه شهید چمران، اهواز

*: مسئول مکاتبات، پست الکترونیکی: smarofi@yahoo.com

به ساختار شبکه منتقل می‌کنند و ابزار مؤثری برای مدل کردن سیستم‌های غیرخطی و پیچیده هستند (۲). در دهه‌های اخیر شبکه عصبی مصنوعی و روش‌های رگرسیونی در بسیاری از مطالعات جهت برآورد پارامترهای هیدرولوژیکی به کار رفته‌اند (۳ و ۷). ولی مطالعات اندکی در زمینه برآورد پارامترهای برف انجام شده است (۴، ۱۴، ۲۰ و ۲۱). اربلین و همکاران (۱۰) در مدل‌سازی تغییرات ضخامت برف با استفاده از مدل رگرسیون خطی در حوضه‌ای بدون پوشش گیاهی، به نتیجه ضریب تعیین $6/8$ درصد رسیدند. آنها هم‌چنین در دو حوضه دیگر با پوشش گیاهی جنگلی نیمه‌انبوه و انبوه ضرایب تعیینی به‌ترتیب $25/8$ درصد و $10/4$ درصد را برای برآورد ضخامت برف به دست آوردند. رابر و همکاران (۱۹) جهت پیش‌بینی بارش برف از شبکه عصبی مصنوعی استفاده نمودند و نتیجه گرفتند که شبکه عصبی مصنوعی دقت پیش‌بینی بارش برف را بهبود می‌بخشد. تدسکو و همکاران (۲۲) از شبکه عصبی مصنوعی برای برآورد آب معادل برف و عمق برف از طریق داده‌های SSMI (Special Sensor Microwave Imager) استفاده نمودند و نتایج آن را با الگوریتم (Spectral Polarization Difference:SDP)، الگوریتم مبتنی بر HUT snow emission model-based iterative) HUT inversion algorithm) و الگوریتم چانگ (Chang) مقایسه نمودند و دریافتند که نتایج به دست آمده از شبکه عصبی مصنوعی بهتر از نتایج الگوریتم‌های فوق‌الذکر و یا قابل مقایسه با آنها می‌باشد.

هدف از این تحقیق، بررسی کارایی روش‌های رگرسیونی غیرخطی، شبکه عصبی مصنوعی و شبکه عصبی-الگوریتم ژنتیک در برآورد ضخامت برف و آب معادل آن و هم‌چنین تعیین مناسب‌ترین روش از میان سه روش مزبور است.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های به کار رفته

حوضه آبریز صمصامی یکی از زیرحوضه‌های اصلی حوضه آبریز کارون می‌باشد. این حوضه با مساحتی در حدود 246

آب معادل برف ضروری است. هم‌چنین آگاهی از توزیع مکانی خصوصیات برف، می‌تواند نقش قابل توجهی در مدل‌های بارش-رواناب داشته باشد. از دیگر کاربردهای مهم توزیع مکانی برف انباشت در هیدرولوژی برف، نقش آب معادل برف به عنوان یکی از ورودی‌های مهم در شبیه‌سازی رواناب ناشی از ذوب برف است (۱۶).

مقدار آب معادل برف به چگالی آن بستگی دارد. چگالی برف تازه از حدود (50 gr cm^{-3}) در دمای 10° - درجه سانتی‌گراد تا حدود (200 gr cm^{-3}) در دمای هوای صفر درجه سانتی‌گراد تغییر می‌کند. متأسفانه اندازه‌گیری چگالی برف به ویژه در عوارض پیچیده و در فصل انباشت برف، زمان‌بر، سخت و حتی خطرناک است و به همین دلیل مقدار آن به ندرت اندازه‌گیری می‌شود و بیشتر از فرمول‌های تجربی استفاده می‌گردد (۶). برای محاسبه آب معادل برف از رابطه زیر استفاده می‌شود:

$$SWE = D \cdot \frac{\rho_S}{\rho_W} \quad [1]$$

که در این رابطه، SWE آب معادل برف، D عمق برف، ρ_S چگالی برف و ρ_W چگالی آب می‌باشند (۱).

تعیین الگو و ساختار تغییرات مکانی آب معادل برف به دلیل فرآیندهای مؤثر بر آن مانند جابه‌جایی برف در اثر باد (۱۵)، بهمن و لغزیدن (۵ و ۸) و نیز فرآیند پیچیده برف‌انباشت (Snow Accumulation) و رایش، یک مسأله پیچیده به‌شمار می‌آید که به سادگی قابل مدل‌شدن نیست. بنابراین با توجه به پیچیدگی فرآیند برآورد آب معادل برف و مشکلات موجود در اندازه‌گیری پارامترهای برف در مناطق کوهستانی و هم‌چنین ناکافی بودن ایستگاه‌های برف‌سنجی در مناطق مرتفع، استفاده از روش‌هایی مانند شبکه عصبی مصنوعی و روش‌های آماری توصیه می‌گردد.

شبکه عصبی مصنوعی بر اساس ارتباطات داخلی بسیار گسترده همانند سیستم عصبی مغز انسان بنا نهاده شده است. شبکه‌های عصبی مصنوعی جزء سیستم‌های دینامیکی هستند که با پردازش داده‌های تجربی، قانون نهفته در ورای اطلاعات را

نقطه ضخامت‌سنجی، به عنوان نقاط چگالی‌سنجی انتخاب گردید. بدین منظور ابتدا ضخامت برف مشاهده‌ای در هر یک از ۱۸ نقطه، به دو قسمت (لایه فوقانی و تحتانی) تقسیم شد. سپس چگالی هر قسمت به طور جداگانه مورد اندازه‌گیری قرار گرفت. با محاسبه میانگین وزنی چگالی هر یک از لایه‌های فوقانی و تحتانی (مطابق با رابطه ۲)، چگالی برف در هر نقطه به دست آمد. شکل ۴-ب، آرایش نقاط چگالی‌سنجی را روی نقشه محدوده مورد مطالعه نشان می‌دهد.

$$\rho_{\text{point}} = \frac{\rho_u D_u + \rho_d D_d}{D_u + D_d} \quad [2]$$

در این رابطه، ρ_{point} چگالی نقطه مورد نظر (gr.cm^{-3})، D_u ضخامت لایه فوقانی برف (cm)، D_d ضخامت لایه تحتانی برف (cm) و ρ_u و ρ_d به ترتیب چگالی لایه فوقانی و تحتانی (gr.cm^{-3}) می‌باشند. شکل ۳، مقادیر چگالی برف در نقاط اندازه‌گیری را نشان می‌دهد.

محاسبه آب معادل برف

برف‌سنجی شامل اندازه‌گیری ضخامت و چگالی برف می‌باشد که با معلوم بودن این پارامترها، آب معادل برف قابل برآورد است. بررسی‌های آماری در این تحقیق نشان می‌دهد که در بین نقاط اندازه‌گیری شده ضخامت برف و چگالی آن، چگالی برف با ضریب تغییرات ۱۲٪ نسبت به مقدار نظیر آن در ضخامت برف به میزان ۴۱٪، از تغییرات مکانی بسیار کمتری برخوردار است. از طرفی، عدم وجود رابطه معنی‌دار چگالی با عوامل توپوگرافی و نرمال بودن توزیع آن سبب شد که اولاً توزیع آب معادل را با توزیع ضخامت برف یکسان فرض نموده و ثانیاً برای برآورد چگالی نقاط مختلف، از مقدار میانگین وزنی آن استفاده شود. ۴۶۸/۰

بدین ترتیب پس از تعیین زمان مناسب برای برف‌سنجی، علاوه بر ضخامت برف، پارامترهای ارتفاع از سطح دریا، میزان شیب، جهت شیب و شاخص بادپناهی (Wind Shelter Index) نیز برای ۲۵۸ نقطه نشان داده شده در شکل ۴-الف، اندازه‌گیری و محاسبه گردید. سپس به منظور دستیابی به توزیع

کیلومتر مربع در قسمت غربی استان چهارمحال و بختیاری و در مختصات جغرافیایی $2^{\circ} 10' 50''$ تا $18^{\circ} 26' 50''$ طول شرقی و $32^{\circ} 51' 17''$ تا $32^{\circ} 15' 11''$ عرض شمالی واقع شده و ارتفاع متوسط آن حدوداً ۲۵۰۰ متر است. میانگین بارش سالانه در این حوضه برابر ۱۱۷۵ میلی‌متر بوده که از این میزان ۶۱ درصد آن به شکل برف و ۳۹ درصد آن به شکل باران نازل می‌شود. در این تحقیق محدوده‌ای به مساحت ۵/۲ کیلومتر مربع از حوضه مزبور برای نمونه‌برداری در نظر گرفته شده است (شکل ۱).

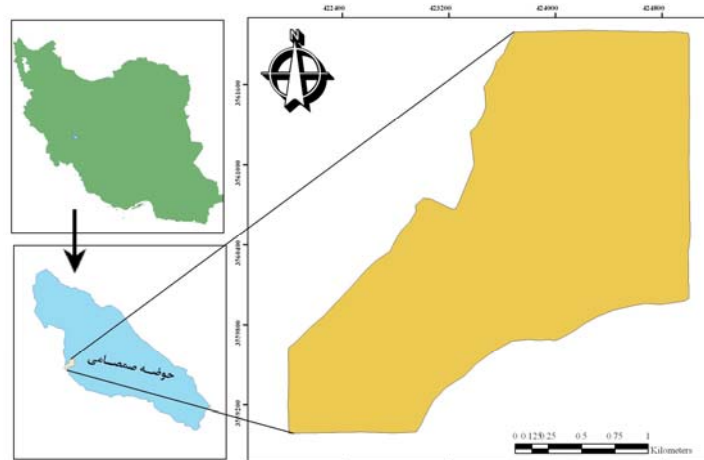
نمونه‌برداری

تعیین ضخامت‌سنجی برف

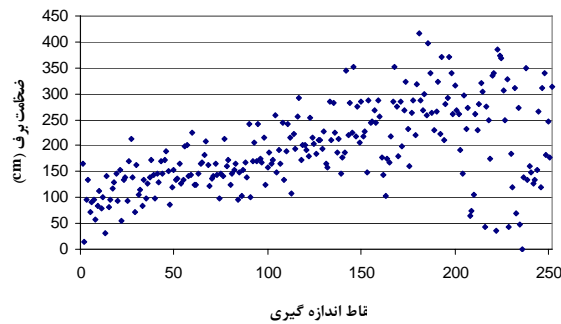
انتخاب نقاط نمونه‌برداری ضخامت برف، قبل از آن که تابع یک سیستم پایه‌ای (Grid Base) ثابت باشد، تابع شرایط توپوگرافی و امکانات دسترسی به منطقه است. به همین دلیل قضاوت مهندسی در این زمینه نقش اصلی را در بردارد (۱). در تحقیق حاضر، برای محل‌هایی که تغییرات عوامل توپوگرافی زیاد بود، فواصل نمونه‌گیری کوچک‌تر انتخاب گردید و بر عکس، برای محل‌هایی که تغییرات مذکور کمتر بود، فواصل بین نقاط بزرگ‌تر انتخاب شد. برای این منظور نقاط نمونه‌برداری ضخامت برف به صورت شبکه نامنظم و غیرسیستماتیک صورت گرفت. بدین ترتیب جمعاً تعداد ۲۵۸ نقطه که موقعیت آنها در شکل ۴-الف نشان داده شده است، مورد اندازه‌گیری قرار گرفتند. شکل ۲، مقادیر ضخامت برف در نقاط اندازه‌گیری را نشان می‌دهد.

تعیین نقاط چگالی‌سنجی برف

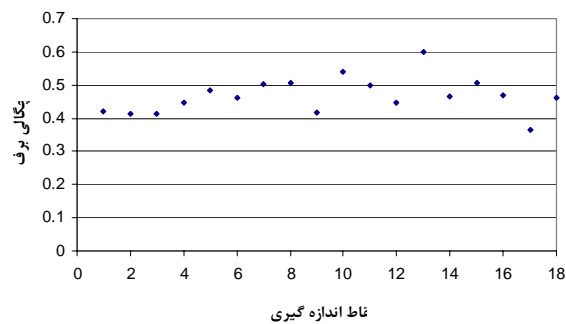
نقاط چگالی‌سنجی نیز به همان شیوه نقاط ضخامت‌سنجی برف انتخاب شد. با این تفاوت که به دلیل تغییرات خیلی کم چگالی برف در مقایسه با ضخامت برف (۹ و ۱۲)، تعداد بسیار کمتری برای ارائه تغییرات مکانی آن در سطح، مورد نیاز است. با توجه به شرایط توپوگرافی محدوده مورد نظر، تعداد ۱۸ نقطه از ۲۵۸



شکل ۱. موقعیت مکانی محدوده مورد مطالعه



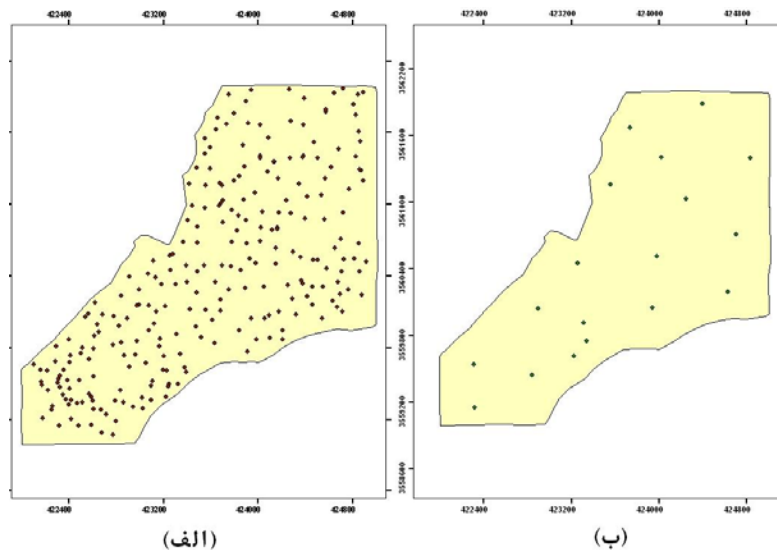
شکل ۲. مقادیر ضخامت برف در نقاط اندازه گیری



شکل ۳. مقادیر چگالی برف در نقاط اندازه گیری

ضخامت برف، آب معادل برف در نقاط مختلف و یا به عبارت دیگر توزیع مکانی آن به دست آمد. لازم به ذکر است که برای محاسبه شاخص بادپناهی یک نقطه، ابتدا می‌بایست محدوده تأثیر در بالادست نقطه مورد نظر،

مکانی آب معادل برف، ابتدا ضخامت برف با روش شبکه عصبی مصنوعی، شبکه عصبی تلفیق یافته با الگوریتم ژنتیک و رگرسیون غیرخطی در نقاط مختلف برآورد گردید. در مرحله بعد، با ضرب نمودن میانگین چگالی در مقادیر برآورد شده



شکل ۴. موقعیت نقاط نمونه برداری: الف) نقاط عمق سنجی برف ب) نقاط چگالی سنجی برف

برخوردار بودند. همان‌گونه که ملاحظه می‌شود جهت شیب در مقیاس مذکور به گونه‌ای است که یک مفهوم جغرافیایی معین یعنی رو به شمال بودن با دو مقدار عددی متفاوت یعنی صفر و ۳۶۰ درجه بیان شده، که این به دلیل خاصیت دایره‌ای بودن آزیموت جهت شیب است. برای رفع این مشکل دو راستای شمالی-جنوبی و شرقی-غربی از میان کلیه راستاهای ممکن، به عنوان امتدادهایی که بیشترین تغییرات دامنه برف انباشت ناشی از جهت شیب را باعث می‌شوند، انتخاب گردید. سپس دامنه صفر تا ۳۶۰ درجه جهت شیب به دو دامنه صفر تا ۱۸۰ درجه شمال-جنوب و شرق-غرب مبدل و آنگاه با قرار دادن صفر برای شمال و عدد ۱ برای جنوب (در امتداد شمال-جنوب) و هم‌چنین صفر برای شرق و ۱ برای غرب (در راستای شرق-غرب) و با استفاده از تناسب خطی به طور جداگانه و برای هر یک از امتدادهای مذکور، مقادیر صفر تا ۱۸۰ درجه به اعداد صفر تا ۱ تبدیل شدند.

اجرای شبکه عصبی مصنوعی

شبکه عصبی مصنوعی (Artificial Neural Network: ANN) به عنوان یک ابزار ریاضی مناسب برای برآورد ضخامت برف

تعیین گردد. منطقه مزبور عبارت از قطاعی از یک دایره به شعاع d_{max} و زاویه مرکزی θ است که در بالادست نقطه و به طرف جهت باد غالب گسترده شده است. شعاع مرکزی قطاع مزبور منطبق بر امتداد باد غالب خواهد بود. درون محدوده مورد نظر، با مشخص نمودن امتدادهای معینی با فاصله زاویه‌ای یکسان ۵ درجه، به ازای هر یک از امتدادها، شاخص بادپناهی از طریق رابطه ۳ محاسبه گردید.

$$Sx_{A,d_{max}}(x_i, y_i) = \max \left[\text{tg}^{-1} \left(\frac{El \times (x_y, y_y) - El \times (x_i, y_i)}{\left[(x_y - x_i)^2 + (y_y - y_i)^2 \right]^{1/2}} \right) \right] \quad [3]$$

در این رابطه، Sx شاخص بادپناهی (درجه)، A آزیموت امتداد در نظر گرفته شده برای محاسبه Sx ، d_{max} حداکثر طول تأثیر (متر)، El ارتفاع نسبت به سطح دریا (متر)، x_i و y_i مختصات نقطه مورد نظر (UTM)، x_y و y_y مختصات نقاط قرار گرفته در امتداد A و تا حداکثر فاصله d_{max} از نقطه مورد نظر (UTM) می‌باشند (۱).

جهت شیب نیز برای پیکسل‌ها بر حسب آزیموت یعنی زاویه در جهت عقربه‌های ساعت نسبت به شمال جغرافیایی به دست آمد. بدین ترتیب مقادیر عددی درج شده در نقشه رقمی جهت شیب از دامنه صفر درجه (شمال) تا ۳۶۰ درجه (شمال)

داروین است. الگوریتم‌های ژنتیک عملگرهای به‌گزینی و تولید مثل، تلاقی (Cross over) و جهش (Mutation) را با هدف یافتن بهترین راه‌حل برای مسئله تلفیق می‌کنند. راه‌حل یک مسئله کروموزوم نامیده می‌شود. یک کروموزوم از مجموعه‌ای از ژن‌ها تشکیل شده است که به سادگی پارامترهای شبکه عصبی را بهینه می‌کنند. الگوریتم ژنتیک، یک توده اولیه (مجموعه‌ای از کروموزوم‌ها) را ایجاد می‌کند و سپس این توده را با آموزش یک شبکه عصبی برای هر کروموزوم ارزیابی می‌نمایند و پس از آن توده را از طریق تولید مثل چندگانه (با استفاده از عملگرهای ژنتیک) در جستجو برای یافتن بهترین پارامترهای شبکه تکامل می‌بخشد. تفاوت عمده این روش با دیگر روش‌های جستجو این است که به جای تمرکز بر یافتن مقادیر تک تک نقاطی که ممکن است مجموعه جواب را تشکیل دهند با توده‌ای از نقاط کدگذاری شده سر و کار دارد (۱۱).

یکی از کاربردهای مهم الگوریتم ژنتیک، ترکیب آن با سایر روش‌های هوش محاسباتی مانند شبکه عصبی مصنوعی است. الگوریتم ژنتیک یک یا بیش از یک پارامتر را در شبکه عصبی مصنوعی بهینه می‌سازد. معمول‌ترین پارامترهایی که بهینه می‌شوند، عبارت‌اند از: ستون‌های ورودی، تعداد عناصر پردازش لایه یا لایه‌های پنهان، تعداد گام‌های حافظه (Memory Taps) و مقادیر یادگیری. در این تحقیق از الگوریتم ژنتیک برای بهینه‌سازی پارامترهای شبکه عصبی مصنوعی و سپس برآورد پارامترهای مربوط به آب معادل برف استفاده شد. در حقیقت الگوریتم اول، شبکه عصبی مصنوعی و الگوریتم دوم، روش تلفیقی شبکه عصبی و الگوریتم ژنتیک می‌باشد. در این روش مقادیر پارامترهای شبکه عصبی مصنوعی با استفاده از الگوریتم ژنتیک به خوبی بهینه می‌شوند که نتایج برآورد شده و نتایج حاصله از فرمول‌های تجربی در مرحله آزمون شبکه عصبی مصنوعی، بهترین برازش را با یکدیگر داشته باشند. واضح است که در این حالت، تابع هدف (Objective Function) الگوریتم ژنتیک، تابعی از نتایج آماری شبکه عصبی مصنوعی است.

با استفاده از اطلاعات توپوگرافی و اقلیمی مرتبط با ضخامت برف انتخاب گردید. پارامترهای انتخاب شده جهت ورودی شبکه عصبی مصنوعی شامل طول و عرض جغرافیایی، ارتفاع از سطح دریا، زاویه شیب، جهت‌های شیب شمالی-جنوبی و شرقی-غربی و هم‌چنین شاخص بادپناهی هستند. مقادیر ضخامت برف اندازه‌گیری شده خروجی تمامی شبکه‌ها بود. داده‌های به کار رفته در شبکه عصبی مصنوعی، به سه بخش آموزش، اعتبارسنجی و آزمون داده‌ها به ترتیب هفتاد، ده و بیست درصد تقسیم شدند و وارد نرم‌افزار NeuroSolution 5 گردید. شبکه عصبی مصنوعی دارای توابع فعالیت مختلفی از جمله گشتاور (Momentum) و مرحله‌ای (Step) و قوانین یادگیری متفاوتی مانند سیگموئید (Sigmoid)، تانژانت هایپربولیک (Tan-h) و لئونبرگ مارکوئید (Levenberg Marquardt) است که از طریق فرایند سعی و خطا انتخاب می‌گردند. برای ارزیابی کارایی مدل‌های مختلف شبکه‌های عصبی مصنوعی با توپولوژی‌های متفاوت و هم‌چنین برای تعیین تعداد تکرارهای مطلوب از آماره‌های ضریب هم‌بستگی (Correlation Coefficient: r)، میانگین مربع خطا (Mean Square Error: MSE) و میانگین خطای مطلق (Mean Absolute Error: MAE) استفاده شد (روابط ۴، ۵ و ۶).

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad [4]$$

$$MSE = \frac{1}{n} \sum [\hat{Z}(x_i) - Z(x_i)]^2 \quad [5]$$

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad [6]$$

که در فرمول (۴ و ۶)، X_i و Y_i ، i امین داده واقعی یا برآورد شده و \bar{X} و \bar{Y} متوسط داده‌های X_i و Y_i هستند و در رابطه (۵)، $Z(X_i)$ مقدار مشاهده شده در نقطه i ام، $\hat{Z}(X_i)$ مقدار برآورد شده در نقطه i ام، n تعداد نمونه‌های ارزیابی X_i و Y_i می‌باشند.

الگوریتم ژنتیک (Genetic Algorithm)، یک الگوریتم جستجوی موازی بر اساس انتخاب طبیعی اصلاح و نظریه تکامل

روش رگرسیون غیرخطی

مدل‌های آماری مانند رگرسیون، برای اندازه نمونه کوچک و در هنگامی که تئوری یا آزمایش، یک رابطه اصولی بین متغیرهای وابسته و مستقل نشان می‌دهد، بهتر اجرا می‌شوند (۱۸). رگرسیون غیرخطی توسط محققین بسیاری (۱۸ و ۲۳) برای برآورد پارامترهای مختلف مورد استفاده قرار گرفته است. در این تحقیق نیز از این روش (رگرسیون غیرخطی) و در محیط نرم‌افزار SPSS استفاده شده است. نهایتاً برای یافتن جواب‌های واقعی و هم‌چنین برآورد پارامترهای مربوط به ضخامت برف و آب معادل آن، عملکرد این سه روش با هم مقایسه شدند.

نتایج و بحث

نتایج شبکه عصبی مصنوعی و الگوریتم ژنتیک

مقادیر ضخامت برف با استفاده از شبکه عصبی مصنوعی و روش تلفیقی شبکه عصبی و الگوریتم ژنتیک (GA) برآورد شد. جهت دست‌یابی به بهترین شبکه عصبی مصنوعی، مدل‌ها و توابع متفاوت با آرایش نرون‌های مختلفی آزمایش شدند و به منظور ارزیابی و مقایسه عملکرد شبکه‌ها با یکدیگر از داده‌های آزمون استفاده شد. مقادیر خروجی از هر شبکه با مقادیر مشاهده‌ای متناظر آن مقایسه شد و جزئیات آن بر اساس ضریب هم‌بستگی، میانگین خطای مطلق و میانگین مربع خطا استخراج گردید که بهترین نتایج به دست آمده برای مدل‌های شبکه عصبی در جدول ۱ ارائه شده است. هم‌چنین هم‌بستگی بین مقادیر ضخامت برف برآورد شده با شبکه عصبی مصنوعی و روش تلفیقی شبکه عصبی - الگوریتم ژنتیک و مقادیر مشاهده‌ای در شکل‌های ۵ و ۶ نشان داده شده است.

بر اساس نتایج ارائه شده در جدول ۱، بهترین شبکه با مدل پرسپترون چند لایه (Multilayer Perceptron: MLP) و تابع فعالیت سیگموئید و قانون یادگیری مرحله‌ای می‌باشد. هم‌چنین بهترین آرایش برای یک لایه پنهان ۱-۴-۷ است و تعداد تکرار (Epoch) و ضریب گشتاور (Momentum Coefficient) برای بهترین شبکه، به ترتیب ۱۰۰۰ و ۰/۷ هستند. هم‌چنین با توجه

به نتایج به دست آمده، تقریباً برای تمامی شبکه‌ها، مقادیر آماره‌های میانگین مربع خطا، میانگین خطای مطلق و ضریب هم‌بستگی در روش تلفیقی الگوریتم ژنتیک - شبکه عصبی مصنوعی بهتر از اجرای شبکه عصبی مصنوعی به تنهایی بوده است.

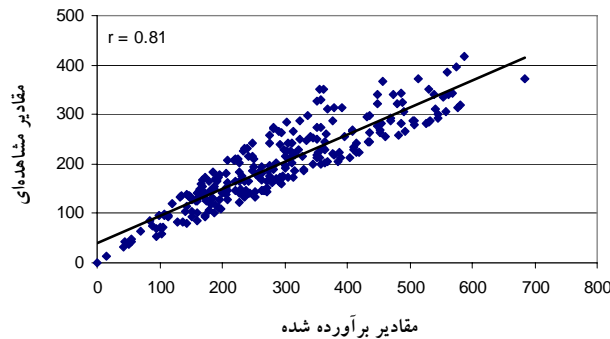
نتایج رگرسیون غیرخطی

مدل‌های مختلف رگرسیون غیرخطی که از ترکیب‌های متفاوت عوامل ورودی حاصل شده‌اند، در جدول ۲ همراه با نتایج آماری آنها ارائه شده است. اگرچه r یک معیار معمول برای بررسی میزان هم‌بستگی مدل‌های رگرسیون است، ولی به تنهایی نمی‌تواند روش مناسبی برای قضاوت در خصوص کارکرد مدل باشد (۱۸). به همین دلیل، در این تحقیق، علاوه بر r قدرت برآورد مدل‌ها با مقایسه خطاهای پیش‌بینی برآورد شد. همان‌طور که در جدول ۲ مشاهده می‌گردد، مدل ۵ با ضریب هم‌بستگی ۰/۵۴، میانگین مربع خطای ۰/۰۴۵۱، میانگین خطای مطلق ۰/۰۵۶۴ و انحراف معیار رگرسیون (Standard Error of Regression: SER) ۰/۲۱۴۶، بهترین مدل رگرسیون غیرخطی می‌باشد. هم‌بستگی بین مقادیر ضخامت برف برآورد شده با مدل ۵ و مقادیر مشاهده‌ای در شکل ۷ نشان داده شده است.

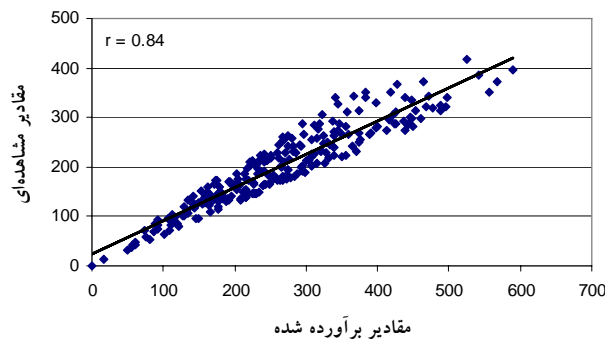
همان‌طور که در جدول ۲ مشاهده می‌گردد، مدل ۵ با ضخامت برف به عنوان پارامتر وابسته و ارتفاع از سطح دریا (E.I.)، شاخص بادپناهی (Sx)، جهت شیب شمالی - جنوبی (N-S)، طول جغرافیایی (X) و شیب به عنوان پارامترهای مستقل، بهترین مدل می‌باشد. با افزودن دو پارامتر عرض جغرافیایی (Y) و جهت شیب شرقی - غربی (E-W) به پارامترهای مستقل قبلی (مدل‌های ۶ و ۷)، مقادیر ضریب هم‌بستگی بدون تغییر باقی ماند و مقادیر میانگین مربع خطا (MSE) و انحراف معیار رگرسیون (SER) افزایش یافته است. این موضوع نشان‌دهنده آن است که دو پارامتر مزبور، پارامترهای چندان مؤثری بر ضخامت برف نمی‌باشند. بنابراین

جدول ۱. جزئیات ساختار شبکه‌های مطلوب در مرحله آموزش و آزمون

مرحله آزمون			مرحله آموزش			قانون یادگیری	تابع فعالیت	آرایش شبکه	مدل عصبی	الگوریتم
MAE	MSE	r	MAE	MSE	r					
۰/۰۷۴	۰/۰۵۹	۰/۷۲	۰/۰۳۱	۰/۰۲۵	۰/۹۳	گشتاور	تانژانت‌های	۷-۴-۱	MLP	ANN
۰/۰۶۴	۰/۰۵۱	۰/۸۱	۰/۰۲۸	۰/۰۲۲	۰/۹۳		هایپربولیک			ANN+GA
۰/۰۵۶	۰/۰۴۵	۰/۷۸	۰/۰۶۵	۰/۰۵۲	۰/۹۷	لونبرگ	سیگموئید	۷-۴-۱	MLP	ANN
۰/۰۵۸	۰/۰۴۶	۰/۷۸	۰/۰۵۴	۰/۰۴۳	۰/۹۸	مارکوئٹ				ANN+GA
۰/۱۲۴	۰/۰۹۹	۰/۸۰	۰/۰۳۸	۰/۰۳۰	۰/۹۱	مرحله‌ای	تانژانت‌های	۷-۴-۱	MLP	ANN
۰/۰۵۴	۰/۰۴۳	۰/۸۱	۰/۰۳۳	۰/۰۲۶	۰/۹۱		هایپربولیک خطی			ANN+GA
۰/۰۵۸	۰/۰۴۶	۰/۸۱	۰/۰۲۱	۰/۰۱۷	۰/۹۷	مرحله‌ای	سیگموئید	۷-۴-۱	MLP	ANN



شکل ۵. هم‌بستگی بین مقادیر برآورده شده با شبکه عصبی مصنوعی و مقادیر مشاهده‌ای




شکل ۶. هم‌بستگی بین مقادیر برآورده شده با روش تلفیقی شبکه عصبی - الگوریتم ژنتیک و مقادیر مشاهده‌ای

با مقایسه جداول ۱ و ۲ می‌توان نتیجه گرفت که از میان سه روش به کار رفته، روش تلفیقی شبکه عصبی - الگوریتم ژنتیک، بهترین روش برای برآورد ضخامت برف و آب معادل آن در منطقه مورد مطالعه است. این روش دارای ضریب

از میان عوامل به کار رفته به عنوان پارامترهای مستقل، عوامل مورد استفاده در مدل ۵، بهترین ترکیب ورودی برای اجرای رگرسیون غیرخطی برای پیش‌بینی ضخامت برف یا آب معادل برف می‌باشند.

جدول ۲. نتایج آماری مدل‌های مختلف رگرسیون غیرخطی

SER	MAE	MSE	r	مدل‌های رگرسیون غیرخطی
۰/۲۴۲	۰/۰۷۳	۰/۰۵۸	۰/۲۹	مدل (۱): El.
۰/۲۳۰	۰/۰۶۵	۰/۰۵۲	۰/۴۱	مدل (۲): Sx و El.
۰/۲۲۳	۰/۰۶۱	۰/۰۴۹	۰/۴۸	مدل (۳): N-S و Sx و El.
۰/۲۱۳	۰/۰۵۶	۰/۰۴۵	۰/۵۳	مدل (۴): X و N-S و Sx و El.
۰/۲۱۴	۰/۰۵۶	۰/۰۴۵	۰/۵۴	مدل (۵): S و X و N-S و Sx و El.
۰/۲۱۵	۰/۰۵۶	۰/۰۴۵	۰/۵۴	مدل (۶): Y و S و X و N-S و Sx و El.
۰/۲۱۵	۱۴۴۸۷۱۰	۱۱۵۸۹۶۸	۰/۵۴	مدل (۷): E-W و Y و S و X و N-S و Sx و El.



شکل ۷. هم‌بستگی بین مقادیر برآورده شده با مدل ۵ رگرسیون غیرخطی و مقادیر مشاهده‌ای

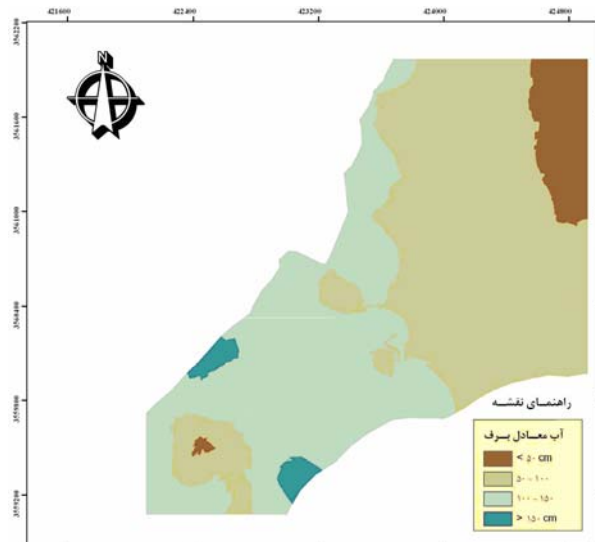
به عبارت دیگر هر چه این مقدار به صفر نزدیک‌تر باشد، نشان‌دهنده دقت بیشتر آن روش می‌باشد (۱۳). برای انتخاب روش مناسب درون‌یابی از تکنیک ارزیابی استفاده شد. روش کریگینگ معمولی با مدل کروی دارای کمترین خطا ($MAE=16/25$ cm) و مناسب‌ترین روش درون‌یابی بوده است، که برای تبدیل نقشه نقطه‌ای به نقشه رستری آب معادل برف از همین روش درون‌یابی استفاده شد و سپس به کمک نرم افزار ArcGIS 9.2 نقشه توزیعی آب معادل برف تهیه گردید (شکل ۸).

همان‌طور که در نقشه توزیع مکانی آب معادل برف مشاهده می‌گردد، مقدار آب معادل برف در محدوده مورد مطالعه از شرق به غرب افزایش می‌یابد. این موضوع را می‌توان به افزایش ارتفاع از شرق به غرب محدوده مورد مطالعه مرتبط دانست. به

هم‌بستگی ۰/۸۴، میانگین مربع خطای ۰/۰۴۱ و میانگین خطای مطلق ۰/۰۵۱ بوده است.

نقشه توزیعی آب معادل برف

با توجه به این‌که روش تلفیقی شبکه عصبی - الگوریتم ژنتیک بهترین نتایج را ارائه داده است، برای ارائه توزیع مکانی آب معادل برف از نتایج این روش استفاده شد. برای تعیین نقشه توزیعی آب معادل برف برآورد شده با روش شبکه عصبی مصنوعی - الگوریتم ژنتیک، ابتدا آب معادل برف در ۲۵۸ نقطه مربوط به اندازه‌گیری ضخامت برف، محاسبه گردید. سپس از درون‌یابی برای تبدیل نقشه نقطه‌ای به رستری آب معادل برف استفاده شد. روش‌های مختلفی برای درون‌یابی یک متغیر وجود دارد که مناسب‌ترین روش، دارای کمترین مقدار خطاست. یا



شکل ۸. نقشه توزیع مکانی آب معادل برف

جدول ۳. معیارهای آماری مربوط به عوامل مؤثر بر ضخامت برف

عوامل	R ²	RMSE
طول جغرافیایی	۰/۳۱	۳۲۷
عرض جغرافیایی	۰/۱۸	۱۴۴۲۹۸/۲
ارتفاع از سطح دریا	۰/۲۶	۷۰/۳
شاخص بادپناهی	۰/۲۰	۷۲/۳
زاویه شیب	۰/۰۲	۸۰/۱
جهت شیب شمالی جنوبی	۰/۱۳	۷۵/۵
جهت شیب شرقی - غربی	۰/۰۴	۶۲۵/۴

برف و آب معادل آن یکسان می‌باشند و در جدول ۳ ارائه شده-اند. با توجه به مقادیر ضریب تعیین (Determination Coefficient: R²) و جذر میانگین مربع خطا (Root Mean Square Error: RMSE)، می‌توان دریافت که عوامل ارتفاع زمین، شاخص بادپناهی و جهت شیب شمالی-جنوبی، به ترتیب مؤثرترین عوامل در حوضه مورد مطالعه می‌باشند.

نتیجه گیری

در این تحقیق امکان استفاده از رگرسیون غیرخطی، شبکه

عبارت دیگر، با افزایش ارتفاع در محدوده مورد مطالعه، آب معادل برف نیز افزایش می‌یابد.

تعیین مؤثرترین عامل بر ضخامت برف و آب معادل برف

برای تعیین مؤثرترین عوامل بر ضخامت برف و آب معادل برف در محدوده مورد مطالعه، از رگرسیون خطی استفاده شده است. با توجه به این که عوامل مؤثر بر ضخامت برف و آب معادل برف یکسان می‌باشند، این عوامل برای دو وضعیت ضخامت

پس از بررسی‌های به عمل آمده، از بین کلیه پارامترهای به کار رفته، مهم‌ترین پارامترهای مؤثر بر تغییرات مکانی ضخامت برف و آب معادل برف در محدوده مورد مطالعه، به ترتیب اهمیت، ارتفاع زمین، شاخص بادپناهی و جهت شیب شمالی-جنوبی به دست آمدند.

سپاسگزاری

این تحقیق با حمایت‌های همه جانبه مرکز تحقیقات کشاورزی و منابع طبیعی استان چهارمحال و بختیاری، مرکز تحقیقات حفاظت خاک و آبخیزداری کشور، اداره هواشناسی استان چهارمحال و بختیاری و سازمان آب و برق خوزستان صورت گرفته است، که بدین وسیله از مسئولین ذی‌ربط تقدیر و تشکر می‌گردد.

عصبی مصنوعی و بهینه‌سازی پارامترهای آن از طریق الگوریتم ژنتیک در برآورد آب معادل برف بررسی شد. به طور کلی می‌توان گفت که شبکه عصبی مصنوعی در این مسئله مانند بسیاری از مسائل هیدرولوژی به طور نسبی موفق بوده است. تداکسو و همکاران (۲۲) نیز قابلیت‌های شبکه عصبی مصنوعی در برآورد آب معادل برف را مورد تأیید قرار دادند. هم‌چنین تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک به منظور بهینه‌سازی شرایط اجرای شبکه عصبی مصنوعی، مثبت ارزیابی می‌شود و در همه موارد برتری خود را نسبت به اجرای شبکه عصبی مصنوعی بدون بهینه‌سازی نشان می‌دهد. به نظر می‌رسد که اگر ماهیت شبکه عصبی مصنوعی و پارامترهای ورودی به آن از طریق به‌گزینی شبکه عصبی مصنوعی (با استفاده از الگوریتم ژنتیک) صورت گیرد، به جواب‌های بهتری دست می‌یابیم. به طور کلی روش شبکه عصبی-الگوریتم ژنتیک، از بین سه روش مورد استفاده، بهترین نتایج را ارائه داده است.

منابع مورد استفاده

۱. شریفی، م. ر. ۱۳۸۶. بررسی توزیع مکانی آب معادل برف با استفاده از روش‌های ترکیبی. پایان‌نامه دکتری، دانشگاه شهید چمران اهواز.
۲. منهای، م. ب. ۱۳۸۶. هوش محاسباتی. جلد دوم، مبانی شبکه‌های عصبی. انتشارات دانشگاه صنعتی امیرکبیر، تهران.
3. Ahmad, S. and S. P. Simonovic. 2005. An artificial neural network model for generating hydrograph from hydro-meteorological parameters. *J. Hydrol.* 315: 236-251.
4. Agarwal, A., S. K. Mishra, S. Ram and J. K. Singh. 2006. Simulation of runoff and sediment yield using artificial neural networks. *Biosys. Eng.* 94(4): 597-613.
5. Blochl, G., R. Kirnbauer and D. Gutknecht. 1991. Distribution Snowmelt simulations in an alpine catchment's: 1. Model evaluation on the basis of snow cover patterns. *Water Resour. Res.* 27: 3171-3179.
6. Bocchiola, D. and R. Rosso. 2007. The distribution of daily snow water equivalent in the central Italian Alps. *Adv. in Water Resour.* 30: 135-147.
7. Chen, J. and B. J. Adams. 2006. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. *J. Hydrol.* 318: 232-249.
8. Elder, K., J. Dozier and J. Michaelsen. 1991. snow accumulation and distribution in an alpine watershed. *Water Resour. Res.* 27: 1541-1552.
9. Elder, K., J. Michaelsen and J. Dozier. 1995. Small Basin Modeling of Snow Water Equivalent Using Binary Regression Tree Methods, IAHS Pub., No. 228.
10. Erxleben, J., K. Elder and R. Davis. 2002. Comparison of spatial interpolation methods for estimating snow distribution in Colorado Rocky Mountains. *Hydrol. Proc.* 16: 3627-3649.
11. Goldberg, D. E. 1989. Genetic algorithm in search, optimization and machine learning, Addison-Wesley, reading, MA, 412 PP.
12. Gray, D. M. and D. H. Male. 1981. Handbook of Snow: Principle, Processes, Management and US. Willowdale, Ontario: Pergamon Press, Canada.
13. Hutchinson, M.F. 1992. Spline A and LAPPNT, Center for Resource and Environmental Studies. Australian

- National University, Canberra, Australia.
14. Iliadis, L. and F. Maris. 2007. An Artificial Neural Network model for mountainous water-resources management: The case of Cyprus mountainous watersheds. *Environ. Model. & Software* 22: 1066-1072.
 15. Kind, R. J. 1981. Snow drifting. PP: 338-359. *In*: Gray, D.M and Male, D.H. (Eds.), *Handbook of Snow: Principles, Processes, Management and Use*. Elsevier Pub., New York.
 16. Lang, H. and L. Braun. 1985. Schmelzwasser-Abfluss-Modelle für Schnee- und Gletschergebiete, *Mitteilungen der Arbeitsgruppe. Schneedecke und Hydrologie* 1: 40-45.
 17. Pulliainen, J. and M. Hallikainen. 1999. Retrieval of Regional snow water equivalent from space-borne passive microwave observations. *Remote Sens. Environ.* 75: 76-85.
 18. Razi, M. A. and K. Athappilly. 2005. A comparative predictive analysis of neural networks (NNs), nonlinear regression and classification and regression tree (CART) models. *Expert Sys. with Appl.* 29: 65-74.
 19. Roebber, P. J., S. L. Bruening, D. M. Schultz and J. V. Cortinas JR. 2002. Improving snowfall forecasting by diagnosing snow density. *Weather and Forecast.* 18: 264-287.
 20. Simpson, J. J. and T. J. McIntire. 2001. A Recurrent Neural Network Classifier for Improved Retrievals of Areal Extent of Snow Cover. *Ieee Transactions on Geoscience and Remote Sens.* 39(10): 2135-2147.
 21. Tappeiner, U., G. Tappeiner, J. Aschenwald, E. Tasser and B. Ostendorf. 2001. GIS-based modelling of spatial pattern of snow cover duration in an alpine area. *Ecol. Model.* 138: 265-275.
 22. Tedesco, M., J. Pulliainen, M. Takala, M. Hallikainen and P. Pampaloni. 2004. Artificial neural network-based techniques for the retrieval of SWE and snow depth from SSM/I data. *Remote Sens. Environ.* 90: 76-85.
 23. Yang, H., P. R. Griffiths and J. D. Tate. 2003. Comparison of partial least squares regression and multi-layer neural networks for quantification of nonlinear systems and application to gas phase Fourier transform infrared spectra. *Anal. Chimica Acta* 489: 125-136.