

ارزیابی مدل‌های پیش‌بینی جریان رودخانه

مژگان باقری‌نیا^۱، علیرضا برهانی‌داریان^۲

تاریخ دریافت: ۹۰/۰۶/۱۶

تاریخ پذیرش: ۹۱/۱۰/۲۰

مقاله برگرفته از پایان نامه کارشناسی ارشد

چکیده:

برف نقش مهمی در میزان و توزیع جریان رودخانه در مناطق کوهستانی دارد. بنابراین، ارزیابی مدل‌های پیش‌بینی جریان که شاخصی از برف را در ساختار خود استفاده می‌کنند ضروری است. در این مطالعه مجموعه‌ای از مدل‌های پیش‌بینی جریان که از دهه‌های گذشته در سطح جهان مطرح بوده است، تهیه و بررسی شده است. این بررسی روش‌های سنتی ساده با داده‌های محدود تا روابط پیچیده و هوشمند نظیر شبکه عصبی مصنوعی و استفاده از داده‌ها و ابزار سنجش از دور و GIS را در بر می‌گیرد. در استفاده از داده‌های سنجش از دور برای تشخیص سطح پوشش برفی، از تصاویر ماهواره NOAA و روش تشخیص آستانه‌ای استفاده شده است. با توجه به اهمیت تست مدل‌ها، روشی متفاوت و کامل برای این منظور در نظر گرفته شده و مقایسه‌ای میان روش‌های مختلف در حوزه دز صورت گرفته است. سپس، نقش بارش‌های بهاری و استفاده همزمان از آن‌ها در پیش‌بینی جریان در همان دوره بررسی شده است.

واژه‌های کلیدی: پیش‌بینی جریان، پوشش برفی، سنجش از دور، شبکه عصبی، حوزه دز

۱- کارشناسی ارشد مدیریت منابع آب دانشگاه صنعتی خواجه نصیرالدین طوسی - تهران - ایران - ۸۸۷۷۹۴۷۳ bagherinia.m@gmail.com

۲ - دانشیار منابع آب - دانشکده عمران دانشگاه صنعتی خواجه نصیرالدین طوسی - تهران - ایران - ۸۸۷۷۹۴۷۳ dariania@gmail.com

مقدمه

پیش‌بینی جریان رودخانه جایگاه ویژه‌ای در مدیریت و برنامه‌ریزی منابع آب دارد. با استفاده از پیش‌بینی‌ها می‌توان و خسارات ناشی از خشکسالی‌ها و سیل‌ها را در حد قابل توجهی کاهش داد. از میان بارش‌های جوی، برف با توجه به فاصله زمانی میان بارش تا ذوب آن، نقش بسزایی در تولید رواناب در فصول کم باران دارد. ذوب تدریجی برف منابع آب‌های سطحی و زیرزمینی را تغذیه نموده و بخش مهمی از جریان در ماه‌های بعد را تشکیل می‌دهد. از طرفی، کاربرد برف در پیش‌بینی‌ها همواره با دشواری‌هایی همراه بوده است. از جمله، آمار و اطلاعات مربوط به برف به دلایلی نظیر شرایط سخت دسترسی به ایستگاه‌ها در مناطق کوهستانی، و فصل زمستان همواره ناقص و مورد تردید است. این‌گونه اطلاعات در صورت تهیه نیز تنها داده‌های نقطه‌ای و مربوط به زمانی مشخص بوده و کاربرد فرآگیری ندارند.

روش‌های گوناگونی در پیش‌بینی جریان رودخانه وجود دارد. روش‌های سنتی پیش‌بینی جریان شامل استفاده از پارامترهای ساده و در دسترس حوزه در قالب یک مدل رگرسیونی می‌باشد. این روش‌ها غالباً از داده‌های نقطه‌ای استفاده می‌کنند. در این زمینه زازل و کاکس ۱۹۷۸ انواع مدل‌های برف‌بایی پیش‌بینی جریان مطرح در دهه ۷۰ میلادی در آمریکا را بررسی کرده‌اند. در این مدل‌ها که سابقاً در آمریکا به صورت کاربردی استفاده می‌شد، از اندازه‌گیری‌های آب معادل برف (SWE)^۳ در ایستگاه‌هایی که آمار بهتری دارند به عنوان پارامتر برف‌بایی حوزه استفاده شده است. گارن در ۱۹۹۲، برخی روش‌های ریاضی بهبود نتایج رگرسیون را با استفاده از انتخاب پارامترهای موثر در مدل، شرح می‌دهد. اهمیت این موضوع از آن جهت است که ممکن است جهش‌های غیرمنتظره‌ای در مدل‌های رگرسیونی نه به دلیل تغییرات هیدرولوژیک، بلکه به دلیل تغییرات آماری به وجود می‌آید (۶). استدینگر و همکاران در ۱۹۸۸ پیشنهاد داده‌اند که به منظور بهتر شدن پیش‌بینی‌ها، از متغیرهای همزمان با دوره پیش‌بینی در مدل استفاده شود. از جمله این متغیرها استفاده از بارش همزمان در تخمین بهنگام رواناب بهار و

تابستان می‌باشد. فریمن در ۱۹۹۹ رواناب حاصل از ذوب برف را یکی از عوامل مهم عدم قطعیت در پیش‌بینی جریان مطرح نموده، عنوان می‌کند که برای کاهش خطای عدم قطعیت در پیش‌بینی‌ها بررسی تغییرات پرئودیک آب و هوا در مناطق کوهستانی، حرکت جبهه‌های هوا و پایش زمان ذوب برف ضروری است.

امروزه استفاده از فن‌سنجش از دور (RS)^۴ کمک موثری به برآورد پوشش برفی در مناطق برفخیز می‌نماید. اطلاعات حاصل از تصاویر ماهواره‌ای در کنار سیستم اطلاعات جغرافیایی (GIS)^۵ بستر مناسبی را برای پردازش اطلاعات و تحلیل داده‌ها فراهم می‌کند. تصاویر ماهواره‌ای در برآورد پوشش سطح برفی (SCA)^۶ (آب معادل برف (SWE))، و عمق برف (SD)^۷ استفاده می‌شوند. گروه مهندسی ارتش آمریکا (USACE) در ۲۰۰۷ طی مطالعاتی در حوزه هلمند (هیرمند) افغانستان با استفاده از تصاویر ماهواره‌ای آب معادل برف حوزه را در بالادست مخزن کاجاکایی^۸ و در حوزه بالادست نقطه ورود رودخانه به ایران برآورد نمودند. سپس بر اساس دستورالعملی و ضمن استفاده از نرم افزار HEC-ResSim بهره برداری از مخزن را مورد بررسی قرار دادند. برای استخراج برف از تصاویر ماهواره‌ای الگوریتم‌های مختلفی پیشنهاد شده است. رومانو و همکاران در ۲۰۰۲ مروری بر این الگوریتم‌ها در ماهواره‌های مختلف و مقایسه صحت نتایج آن‌ها با یکدیگر داشته‌اند.

در ایران نیز از اوایل دهه ۱۳۸۰ تحقیقاتی در زمینه استفاده از تصاویر ماهواره‌ای در مدل‌های پیش‌بینی جریان انجام شده است. برهانی و همکاران (۱۳۸۳) با استفاده از اطلاعات ماهواره‌ای در تشخیص برف، مدل‌های برف‌بایی پیش‌بینی جریان در حوزه دز را برای دوره آماری ۱۳۵۰ تا ۱۳۷۶ توسعه دادند. آن‌ها مدل‌های بلند مدت برف‌بایی را به دو صورت با استفاده از سنجش از دور و بدون آن در حوزه دز تهیه کرده و نشان دادند استفاده از سنجش از دور تأثیر بسزایی در بهبود نتایج دارد. طوسی (۱۳۸۳) نیز در زمینه برفسنجی در تصاویر ماهواره‌ای به روش‌های طبقه بندی

⁴ Remote Sensing

⁵ Geographic Information System

⁶ Snow Covered Area

⁷ Snow Depth

⁸ Kajakai

³ Snow Water Equivalent

استفاده شده است. حوزه آبریز رودخانه دز به مساحت ۱۷۱۶۳ کیلومتر مربع، بخشی از ارتفاعات زاگرس میانی را در برمی گیرد و در تقسیم بندی کلی ایران جزئی از حوزه آبریز خلیج فارس است. این منطقه در محدوده ۳۲/۵ تا ۳۴ درجه عرض جغرافیایی شمالی و ۴۸/۳ تا ۵۰/۳ طول جغرافیایی شرقی، در جنوب غربی ایران واقع شده است و به لحاظ توپوگرافی و آب و هوایی از پیچیده ترین حوزه های آبریز ایران محسوب می شود.

الف- برآورد آب معادل برف حوزه از داده های نقطه ای با توجه به کمبود ایستگاه های برفسنجی و پیچیدگی های توپوگرافی در حوزه با بررسی توزیع آب معادل برف منطقه، نقش بسزای طول و عرض و ارتفاع جغرافیایی در این راستا مشخص شد. انتخاب مناطق بر مبنای امکان دستیابی به روابط قوی میان بارش، و طول، عرض و ارتفاع ایستگاه های موجود در هر منطقه است، در این راستا، جهت دستیابی به نواحی همگن بر اساس مطالعات پیشین در این منطقه (برهانی و همکاران، ۱۳۸۳) حوزه دز به سه زیر حوزه تقسیم شد (شکل ۱). سپس، رابطه آب معادل برف در هر زیر حوزه در اوایل اسفند ماه که نمایانگر حداکثر ذخیره برفی سال آبی مربوطه است، با طول، عرض و ارتفاع ایستگاه ها محاسبه شد. روش فوق به روش منطقه بندی موسوم است.



شکل (۱): مناطق سه گانه در تعیین آب معادل برف حوزه دز (۳)

روند استخراج داده های پوشش برف

تصاویر مورد استفاده در این تحقیق مربوط به ماهواره NOAA با سنجنده AVHRR است. برای استخراج پوشش برفی از میان تصاویر اسفند ماه مربوط به هر سال (به عنوان دوره پایان ریزش های برفی و شروع دوره ذوب)، تصویری را


نظارت شده و نظارت نشده تحقیقی انجام داده است. رضایی و مباشری (۱۳۸۵) در مطالعات خود برای تشخیص نوع ابر و جداسازی آن از برف، از روش تشخیص آستانه ای استفاده کردند.

با ظهور الگوریتم های جدید همچون سیستم های فازی و شبکه های عصبی مصنوعی، این علوم جایگاه خود را در مسائل منابع آب نیز پیدا کردند. کارونایتی و همکاران در ۱۹۹۴ ضمن بیان مبانی شبکه عصبی و مقایسه آن با سایر روش های مرسوم، استفاده از آن را در زمینه پیش بینی جریان رودخانه توصیه می کنند. تاپینر و همکاران در ۲۰۰۱ مدل سازی پوشش برف با استفاده از شبکه عصبی را بررسی نمودند. آن ها با مطالعه ناحیه ای با مساحتی در حدود ۲ کیلومتر مربع در منطقه کوه های آلپ از پارامترهای ساده ای نظیر شیب، ارتفاع، پتانسیل بازتابش و تعداد روزهای با حرارت زیر صفر به عنوان مدلی خود استفاده نمودند. آن ها مدل را به دو روش رگرسیون و شبکه عصبی اجرا نموده و نشان دادند که شبکه عصبی نتیجه ضریب همبستگی را ۱۰ درصد بهبود می دهد (۱۳). به منظور بهبود مدل شبکه عصبی، مرادخانی و همکاران در ۲۰۰۴ انواع مدل های شبکه عصبی را برای پیش بینی روزانه جریان بررسی کرده و عنوان می کنند که در استفاده از شبکه عصبی برای پیش بینی جریان، باید توجه ویژه ای به سال های آموزش و صحت یابی و روش کالیبراسیون شبکه شود (۱۰).

در مقاله حاضر ابتدا چگونگی برآورد پارامترهای حوزه آبریز دز و استفاده از سنجنده از دور در برآورد پوشش سطح برفی (SCA)، شرح داده می شود. سپس روش های مختلف و رایج پیش بینی جریان شامل روش های ساده و سنتی رایج در گذشته، روش های مبتنی بر استفاده از داده های سنجنده از دور و در نهایت تلفیق استفاده از سنجنده از دور و شبکه عصبی مصنوعی بررسی و مورد مقایسه قرار گرفته است. در ادامه شیوه تست مدل ها به تفصیل تشریح شده و نقش بارش های همزمان در بهبود نتایج پیش بینی جریان بررسی و تحلیل شده است.

منطقه مطالعاتی و برآورد پارامترها

در این تحقیق از حوزه دز به عنوان الگوی مطالعاتی



شکل (۲): منحنی طیفی ابر و انواع برف - باندهای ۲،۱ مربوط به سنجنده AVHRR

۴- روش‌های سنتی پیش‌بینی جریان

روش‌های سنتی رایج، روش‌های نسبتاً ساده پیش‌بینی جریان هستند. بسیاری از این روش‌ها به طور کاربردی برای پیش‌بینی جریان رودخانه در کشور آمریکا مورد استفاده قرار گرفته است. زازل و کاکس در ۱۹۷۸ تعدادی از این روش‌ها را در قالب مدل‌های رگرسیونی ساده با ورودی‌های محدود معرفی نموده‌اند. آن‌ها اشاره می‌کنند که در مواردی که حوزه کوچک بوده و رفتار هیدرولوژیکی پیچیده‌ای نداشته باشد، این مدل‌ها نتایج مناسبی در بر دارند. در ادامه به تشریح این مدل‌ها می‌پردازیم.

۱- مدل شاخص بارندگی^{۱۱} (PIM):

$$Q_s = aP_w + b \quad (2)$$

به طوری که در رابطه (۲) مشهود است در این مدل رواناب حوزه در فصل پیش‌بینی تنها تابعی از بارش دوره پاییز و زمستان (P_w) می‌باشد. Q_s رواناب حوزه در فصل پیش‌بینی (میلیمتر)، P_w بارش حوزه در دوره قبل از پیش‌بینی (مهر تا اول پیش‌بینی میلیمتر) و a و b ضرایب معادله رگرسیون هستند.

که پوشش ابری کمتری داشت انتخاب نموده و پس از انجام اصلاحات ژئومتری و رادیومتری در نرم افزار ENVI، پوشش برفی آن جدا شد. روش مورد استفاده در جداسازی پوشش برفی، روش تشخیص آستانه‌ای است. همان‌گونه که در شکل ۲ دیده می‌شود منحنی طیفی برف با توجه به عواملی از قبیل درشتی دانه‌های برف و سن برف اندکی متفاوت است. ولی به طور کلی برف در طول موج‌های پایین ناحیه مرئی، بازتابش بالایی دارد که ابر نیز همین ویژگی را داراست و این امر دشواری‌هایی را در تشخیص ابر از برف در ناحیه مرئی پدید می‌آورد. تنها نقطه مشخصی که برای تشخیص ابر از برف وجود دارد، طول موج ۱/۶ میکرون است که در آن برف بازتابش بسیار پایین و ابر بازتابش نسبتاً بالایی دارد. بنابراین، بازتابش در این طول موج در روابطی که برای شناسایی برف ذکر می‌شود، بسیار تعیین‌کننده است. با اعمال الگوریتم زیر به تصویر، پوشش برفی از سایر نواحی جدا می‌شود (۱۱).

$$R_{1.6} < R_{1.6t}$$

$$SI > SI_t$$

$$NDSI > NDSI_t$$

$$Tch4_{t_{min}} < Tch4 < Tch4_{t_{max}}$$

$$SI = R_{.6}/R_{1.6}$$

$$NDSI = (R_{.6} - R_{1.6}) / (R_{.6} + R_{1.6}) \quad (1)$$

در این روابط $R_{1.6}$ و $R_{.6}$ بازتابش در طول موج‌های ۱/۶ و ۰/۶ می‌باشد. $R_{1.6t}$ و $R_{.6t}$ مقدار آستانه بازتابش برف در طول موج ۱/۶ و ۰/۶ می‌باشد. SI_t ضریب برفی و $NDSI_t$ شاخص برفی تفاضلی نرمال بوده و SI_t و $NDSI_t$ نیز به ترتیب مقادیر آستانه هر یک از این پارامترها است. $Tch4_{t_{min}}$ و $Tch4_{t_{max}}$ دمای کمینه و بیشینه سطح برف در باند ۴ سنجنده AVHRR می‌باشد. بدین ترتیب مقادیر آستانه مربوط به برف هر یک از پارامترهای فوق، در تصاویر محاسبه شده، روابط فوق به تصویر اعمال می‌شود و پوشش برفی از تصویر جدا می‌شود.

⁹ Snow Index

¹⁰ Normalized Difference Snow Index

¹¹ Precipitation Index Model

۲- مدل بیلان آبی $(WBM)^{12}$:

$$Q_s = a(P_w - Q_w) + b \quad (3)$$

طبق رابطه (۳) در این مدل فرض شده که بخشی از بارندگی دوره پاییز و زمستان به رواناب در همان دوره (Q_w) ، تبدیل می‌شود. بنابراین برای محاسبه رواناب دوره پیش‌بینی این رواناب باید از مقدار بارش کم شود. $P_w - Q_w$ تخمینی از مقدار آب ذخیره شده در حوزه شامل ذخیره برف، آب زیرزمینی و رطوبت خاک است.

۳- مدل تنگبرن-راسموسن $(TRM)^{13}$

$$Q_s = aP_w + b - Q_w \quad (4)$$

این مدل در واقع رواناب حوزه در کل سال $(Q_s + Q_w)$ را تابعی از بارش در فصل بارندگی در نظر می‌گیرد.

۴- مدل رگرسیون خطی چند متغیره $(MLRM)^{14}$:

در این روش علاوه بر بارندگی، پارامتر آب معادل برف تعدادی از ایستگاه‌ها نیز برای پیش‌بینی جریان در نظر گرفته می‌شود.

$$Q_s = b + a_1P_w + a_2S_1 + a_3S_2 + a_4S_3 + a_5S_4 \quad (5)$$

که در آن S_1 تا S_4 آب معادل برف در چهار ایستگاه برف‌سنجی هستند. سایر پارامترها نیز قبلاً تعریف شده‌اند. زازل و کاکس در ۱۹۷۸ تعداد ایستگاه‌های برف‌سنجی در این مدل را چهار ایستگاه در نظر گرفته‌اند (۱۵). در تحقیق حاضر نیز با استفاده از تحلیل همبستگی به روش پلکانی^{۱۵} مناسب‌ترین مجموعه ایستگاه‌ها از بین ایستگاه‌های برف‌سنجی انتخاب شده است. بدیهی است می‌توان در صورت لزوم تعداد ایستگاه‌های بیشتری را نیز در نظر گرفت.

۵- تهیه مدل‌های پیش‌بینی با استفاده از داده‌های

RS

در این بخش روش تهیه مدل‌های پیش‌بینی برای دوره‌های یک تا شش ماه با استفاده از داده‌های RS، تشریح می‌شود. مدل کلی پیش‌بینی جریان دوره Q_i به شرح زیر می‌باشد:

$$Q_i = f(SWE, P_0, P_1, P_{t-1}, T_0, T_{t-1}, Q_{t-1}, Q_{t-2}) \quad (6)$$

SWE: آب معادل برف حوزه، P_0 : بارش پیش از شروع بارش برف (مهر+آبان+آذر)، P_1 : بارش دوره برفی (دی و بهمن)، T_0 : دمای دوره شروع ذوب (اسفند)، P_{t-1} : بارش ماه قبل، T_{t-1} : دمای ماه قبل، Q_{t-1} : جریان ماه قبل Q_{t-2} : جریان دومین ماه قبل، می‌باشد. ایستگاه داماسنجی مورد استفاده تله زنگ می‌باشد و پیش‌بینی‌ها در محل ورودی به مخزن دز که ایستگاه خروجی حوزه است، انجام شده است. برای برآورد پارامتر آب معادل برف روابط منطقه‌ای فقط در سطوحی از حوزه اعمال شد که با استفاده از تصاویر ماهواره‌ای پوشش برفی آن‌ها محرز گردید. این روش به "روش منطقه بندی تصویر"^{۱۶} IBZOM موسوم شد.

در برازش مدل رگرسیونی ابتدا با نرم افزار مینی تب بهترین زیر مجموعه از پارامترهای ورودی انتخاب و سپس رابطه رگرسیونی به آن‌ها برازش داده شد. این رابطه به کل دوره آماری برازش داده شد و دوره تستی در نظر گرفته نشد. بررسی‌ها نشان داد که پارامتر آب معادل برف از مهم‌ترین پارامترهای حوزه در پیش‌بینی جریان بوده و همان‌طور که انتظار می‌رفت در ماه‌های بهار تأثیر بیشتری نسبت به ماه‌های تابستان در پیش‌بینی جریان رودخانه دارد. از طرفی، بارش پاییز کمترین تأثیر را در پیش‌بینی جریان رودخانه نشان می‌دهد. متغیر جریان در ماه‌های گذشته نیز به ویژه در ماه‌های تابستان از مهم‌ترین متغیرهای پیش‌بینی در مدل بوده و در تمامی مدل‌ها مشارکت دارد.

¹² Water Balance Model

¹³ Tangborn-Rusmussen Model

¹⁴ Multiple Linear Regression Model

¹⁵ Stepwise Regression Analysis

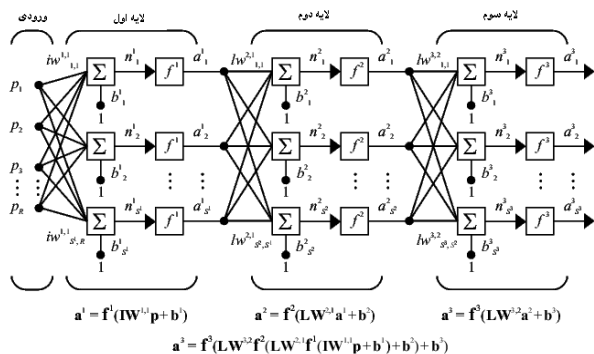
¹⁶ Image Based Zoning Method

استفاده از شبکه عصبی

استفاده از شبکه‌های عصبی مصنوعی در بیش از یک دهه گذشته رشد روزافزونی در حل مسائل مربوط به منابع آب داشته است شبکه‌های عصبی با انعطاف‌پذیری بسیار بالا قادرند رفتار سیستم و پدیده‌های پیچیده را مدل نموده و در جایی که روش‌های رگرسیونی عملکرد قابل قبولی ندارند نتایج رضایت بخشی ارائه نمایند. نحوه عملکرد شبکه عصبی از نحوه عملکرد نرون‌های عصبی انسان الهام گرفته شده است. بدین ترتیب که در نرون‌ها اطلاعات به وسیله دندریت‌ها دریافت می‌شوند و به بدنه سلول رسیده و سلول را تحریک می‌کند. بدنه سلول، انرژی لازم را برای فعالیت نرون تهیه نموده و بر روی سیگنال‌های ورودی عمل می‌کند، که با یک عمل ساده جمع و مقایسه با یک سطح آستانه مدل می‌گردد. نتیجه عمل توسط آکسون‌ها به سلول بعدی انتقال می‌یابد. یک شبکه عصبی مصنوعی نیز تقریباً چنین عملکردی دارد. خروجی یک نرون با معادله زیر تعریف می‌شود:

$$a = f(w.p + b) \quad (7)$$

که P بردار ورودی به نرون، w بردار وزن، b مقدار بایاس و f تابع محرک نرون می‌باشد. پارامترهای w و b قابل تنظیم هستند و با هر بار اجرای شبکه در جهت کاهش خطا، تغییر می‌کنند. شبکه‌های عصبی انواع مختلفی دارد. در این مطالعه از شبکه چند لایه پیشخور^{۱۷} استفاده شده است. در شکل ۳ یک شبکه پیشخور با R ورودی نشان داده شده است.




شکل (۳): شبکه پیشخور چند لایه با R ورودی - (۱)

یکی از مشکلات بارز استفاده از شبکه‌های عصبی موضوع فرابرازش است که باید توجه ویژه‌ای به آن معطوف داشت. از لحاظ تئوریک، مشکل فرابرازش^{۱۸} ممکن است در مدل‌های رگرسیونی نیز پیش آید، اما به دلیل ساختار ساده آن‌ها امکان وقوع چنین مسأله‌ای اندک است. در ادامه شیوه مورد استفاده در این تحقیق برای اجتناب از مشکل فرابرازش شرح داده خواهد شد. در این بخش از داده‌های حاصل از روش منطقه‌بندی تصویر به عنوان ورودی شبکه عصبی استفاده شد. بدین منظور ابتدا همه داده‌ها پیش پردازش شده و به بازه ۱- تا ۱ آورده شدند و سپس شبکه در محیط Matlab طراحی و اجرا شد. به منظور جلوگیری از خطر فرابرازش درصدی از داده‌های دوره کالیبراسیون به عنوان دوره صحت یابی جدا می‌شوند تا هنگامی که خطای این دوره افزایش می‌یابد آموزش متوقف شود. زیرا ممکن است در دوره آموزش، با آموزش بیشتر فرابرازش صورت گرفته و خطای این دوره کاهش یابد، اما مدل حاصله عملاً با داده‌های جدید نتایج مطلوبی نداشته باشد. برای این کار، به طور همزمان خطای آموزش و خطای حاصل از کاربرد مدل آموزش دیده در داده‌های مربوط به دوره صحت یابی ارزیابی شده و آموزش مدل در موقع مطلوب قطع می‌شود. قطع آموزش شبکه زمانی خواهد بود که علی‌رغم کاهش خطای مدل در

¹⁸ Over fitting

¹⁷ Multi Layer Perceptron

مستقل که در دوره آموزش استفاده نشده‌اند و ممکن است در آینده اتفاق بیافتند، داشته باشد. بدین منظور روشی که در این تحقیق معرفی و استفاده می‌شود به نحوی است که طی تکرار، تمام دوره آماری را در دوره های تست ارزیابی می‌کند. در این خصوص طول دوره آماری ۳۳ ساله (۵۰-۸۲) به شش دوره ۵ ساله و یک دوره ۳ ساله تقسیم شده و سپس داده‌های مربوط به هر کدام از این دوره‌ها به طور متناوب از کل دوره آماری کنار گذاشته شده و با باقیمانده آمار، کالیبراسیون انجام می‌شود. سپس، مدل حاصله با داده های دوره کنار گذاشته شده تست می‌شود. پس از آن دوره مذکور به دوره کالیبراسیون اضافه شده و دوره بعدی تست می‌شود. این روند ادامه می‌یابد تا تمام سال‌ها در دوره آماری ارزیابی شوند. بدین ترتیب، طی چند مرحله تکرار تمام دوره آماری با استفاده از ساختار مدل، ارزیابی (تست) می‌شود. شکل ۴ مراحل تست مدل را با این روش نشان می‌دهد. این شیوه استفاده از تمام دوره‌ها در تست مدل در طول مقاله با عنوان "دوره تست متحرک" مشخص خواهد شد.



شکل (۴): نمایش مراحل ارزیابی مدل بروش دوره تست متحرک

در طی بررسی‌های انجام شده ملاحظه می‌شود مطابق انتظار با در نظر گرفتن دوره تست و ارزیابی مدل‌ها در این دوره نتایج حاصله بطورعموم ضعیف‌تر از دوره کالیبراسیون است. این موضوع نشان می‌دهد که نتایج کالیبراسیون مدل‌ها خوش‌بینانه بوده و از واقعیت بدور است. بدیهی است برازش صورت گرفته در دوره کالیبراسیون بر اساس معیار انتخابی (حداقل سازی مربع مجموع خطاها) ایده آل بوده و اختلاف بین نتایج دوره کالیبراسیون و تست قابل انتظار است، لکن ممکن است بخشی از این مشکل ناشی از نامناسب بودن ساختار مدل و بخش مهمی ناشی از فرابرازش آن در دوره کالیبراسیون باشد. همان‌طور که قبلاً اشاره شد

دوره آموزش، با افزایش محسوس خطای مدل در دوره مستقل صحت یابی روبرو شویم.

از آنجایی که همه پارامترهای موجود، در مدل شبکه عصبی موثر نیستند، لذا باید پارامترهای موثر در هر مدل شناسایی شوند. بنابراین، برای یک دوره تست نمونه ترکیبات گوناگون پارامترها را در شبکه وارد می‌کنیم تا مشخص شود کدام مجموعه بهترین نتیجه را می‌دهد. پس از این مرحله چند سری داده ورودی که نتایج بهتری داشتند برای کل دوره به مدل برازش داده شدند تا بهترین مجموعه از پارامترهای ورودی به شبکه در هر دوره بدست آید.

ارزیابی مدل‌ها

نتایج مدل‌ها معمولاً با ضریب همبستگی (R) و جذر میانگین مربعات خطا (RMSE) بیان می‌شود. این نتایج می‌تواند مربوط به دوره تست مدل و یا دوره مستقل کالیبراسیون آن باشد. در بسیاری از تحقیقات برای مدل دوره تست تعیین نمی‌کنند و کل دوره آماری را به عنوان دوره کالیبراسیون و برازش مدل در نظر می‌گیرند (۳)، (۱۵). در این حالت چون از تمام داده‌های آماری برای برازش مدل استفاده می‌شود، مدل مطلوب‌ترین وضعیت برازش را نشان می‌دهد. لکن برای قضاوت صحیح لازم است مدل بدست آمده در کالیبراسیون با استفاده از داده‌های یک یا چند دوره مستقل ارزیابی شود، زیرا ممکن است دوره کالیبراسیون برازش خوبی داشته باشد و دوره تست که داده‌های آن در کالیبراسیون مدل استفاده نشده است نتایج ضعیفی در بر داشته باشد (۹).

برخی مطالعات نیز مانند مطالعه پیش‌بینی جریان توسط مرادخانی و همکاران در ۲۰۰۴، یک دوره زمانی خاص را برای تست مدل در نظر می‌گیرند. هر چند نتایج این روش واقعی‌تر از روش قبل بوده و اقدام صورت گرفته یک گام به جلو محسوب می‌شود ولی با این روش نمی‌توان قضاوتی در مورد سایر دوره های تست داشت. بنابراین، باید روشی را انتخاب نمود که بتواند با استفاده حداکثر از طول دوره آماری برای آموزش، برآورد واقعی از عملکرد مدل در داده های

¹⁹ Coefficient of Correlation

²⁰ Root Mean Square Error

چهار دوره سه ماهه و یک دوره شش ماهه در محدوده ماه‌های فروردین لغایت شهریور در نظر گرفته شد. سپس، مدل‌های پیش‌بینی با استفاده از کالیبراسیون به وسیله روش‌های رگرسیونی و بدون منظور نمودن دوره تست در هر دوره و برای هر مدل مشخص شد. بطوری‌که در جدول (۱) مشاهده می‌شود نتایج حاصل از مدل‌های PIM و MLRM تا حدودی مناسب است اما نتایج مربوط به مدل‌های WBM و TRM ضعیف بوده و رضایت‌بخش نیست ضرایب همبستگی مربوط به روش MLRM در دوره‌های مختلف بین ۸۳ تا ۸۹ درصد و ضرایب همبستگی مربوط به روش TRM بین تقریباً صفر و ۳۱ درصد است.

در مدل‌های مبتنی بر شبکه‌های عصبی موضوع فرابرازش با توجه به قابلیت‌های بالای مدل و خطر برآزش کامل بر روی داده‌ها بیشتر مورد توجه است. اما این موضوع در مدل‌های رگرسیونی اغلب مورد غفلت می‌شود. در بیشتر مدل‌های رگرسیونی کل آمار برای برآزش مدل استفاده شده و ضریب دترمینان (یا همبستگی) و خطای استاندارد دوره کالیبراسیون به غلط برای ارزیابی مدل استفاده می‌شود.

نتایج ارزیابی مدل‌ها

الف-مدل‌های سنتی

برای پیش‌بینی جریان رودخانه با استفاده از این روش‌ها

- نتایج مدل‌های سنتی بدون تست و با دوره تست متحرک و شبکه عصبی - دوره آماری ۱۳۵۰-۱۳۸۲ (واحد داده‌های اصلی میلی‌متر)

RMSE			R(%)			نام مدل	دوره
شبکه عصبی	رگرسیون	رگرسیون	شبکه عصبی	رگرسیون	رگرسیون		
تست متحرک	تست متحرک	بدون تست	تست متحرک	تست متحرک	بدون تست		
68	86	83	7	43	50	PIM	۱. سه ماهه اول فروردین تا خرداد
58	95	90	79	15	32	WBM	
47	71	57	88	7	84	MLRM	
98	118	107	46	13	2	TRM	
48	68	65	78	48	57	PIM	۲. سه ماهه دوم اردیبهشت-تیر
51	89	77	76	-46	17	WBM	
15	72	49	98	56	83	MLRM	
93	125	113	24	-6	-1	TRM	
24	28	25	81	74	80	PIM	۳. سه ماهه سوم خرداد- مرداد
28	50	41	73	-6	17	WBM	
18	31	21	89	7	88	MLRM	
83	113	97	1	-6	-3	TRM	
13	16	14	84	77	82	PIM	۴. سه ماهه چهارم تیر تا شهریور
12	32	24	87	-73	-1	WBM	
10	19	12	9	7	89	MLRM	
107	114	99	-18	-13	-2	TRM	
70	103	99	81	48	55	PIM	۵. شش ماهه فروردین تا شهریور
75	117	111	79	17	35	WBM	
59	88	70	86	68	85	MLRM	
103	134	122	55	22	31	TRM	

آمده است.

در روش رگرسیون بدون دوره تست نتایج تقریباً با نتایج بدست آمده توسط برهانی و همکاران در سال ۱۳۸۳ در حوزه دز هم خوانی داشته و نتایج پیش بینی‌های هر دو تحقیق قابل قبول می‌باشد. از سایر روش‌های تست و مدل شبکه عصبی در تحقیق مذکور استفاده نشده است و امکان مقایسه در این بخش‌ها وجود ندارد.

با انجام تست مشخص می‌شود که این روش در نتایج واقعی مدل بسیار ضعیف است. برای مثال، ضریب همبستگی بین مقادیر پیش‌بینی و مشاهده در ماه اردیبهشت برای رگرسیون بدون تست و با تست از ۷۹ به ۲۶ درصد کاهش می‌یابد که بار دیگر غیر قابل اعتماد بودن نتایج روش بدون دوره تست را ثابت می‌کند. روش‌های رگرسیون بدون دوره تست و با دوره تست، به ویژه در دوره‌های مشتمل بر ماه‌های فروردین و اردیبهشت اختلاف زیادی را نشان می‌دهد. ولی در ماه‌های دیگر این اختلاف کمتر است و در مجموع نتایج مدل‌ها بهبود می‌یابد. این امر ناشی از همبستگی بیشتر جریان در ماه‌های کم بارش به جریان رودخانه در ماه قبل بوده و نشان از وجود روند مارکفی جریان در این ماه‌ها دارد. در ماه‌های فروردین و اردیبهشت حتی با به کار بردن روش‌های هوشمندی مانند شبکه عصبی ضریب همبستگی در سطح کمتر از ۹۰ درصد باقی می‌ماند. این موضوع بیانگر دشواری‌های پیش‌بینی جریان در دوره‌های مشتمل بر این ماه‌هاست. این امر همچنین نشان می‌دهد که پارامترهای موجود در مدل که مربوط به دوره‌های زمانی گذشته‌اند، قادر به پیش‌بینی کامل جریان نبوده و عوامل دیگری در این زمینه مؤثرند. این عوامل شامل مواردی نظیر ذوب زود هنگام برف و بارش‌های بهاری همزمان در حوزه می‌باشد که در میزان جریان این دوره‌ها نقش بسزایی دارند ولی در زمان پیش‌بینی، اطلاعات مربوط به آن‌ها در دسترس نمی‌باشد. در ادامه به ارزیابی این عوامل در کاهش خطای پیش‌بینی جریان رودخانه در دوره‌های شامل این ماه‌ها می‌پردازیم.

در گام بعدی، این کار با استفاده از روش دوره تست متحرک نیز تکرار شد که مطابق انتظار به طور کلی باعث افت نتایج گردید. اما در این بین عملکرد مدل‌های WBM و تا حدودی TRM در چند دوره برخلاف انتظار بود بطوری‌که ضرایب همبستگی دوره‌های تست افزایش نشان داد. علت عمده این مساله وجود همبستگی ضعیف و تقریباً صفر در مرحله کالیبراسیون است به طوری که هرگونه تغییر می‌تواند منجر به افزایش ضرایب همبستگی گردد.

از میان روش‌های سنتی، روش MLRM که در آن پارامتر آب معادل برف دخالت دارد، بهترین نتایج را در همه حالت‌ها می‌دهد. هر چند این پارامتر به صورت داده نقطه‌ای وارد شده است ولی نتایج را در روش رگرسیونی بدون دوره تست و نیز در شبکه عصبی نسبت به سایر روش‌ها بهبود داده است. این موضوع اهمیت پارامتر آب معادل برف را در پیش‌بینی جریان این ناحیه کوهستانی نشان می‌دهد. نتایج نشان می‌دهد که در سطح اطمینان ۹۵٪ روش‌های بیلان آبی (WBM) و تنگبرن-راسموسن (TRM) در مدل‌های رگرسیون بدون دوره تست و با دوره تست متحرک اغلب دارای همبستگی معنادار نیستند و همبستگی آن‌ها در حد صفر می‌باشد. بدیهی است نتایج حاصله محدود به منطقه مطالعاتی دز بوده و ممکن است در مناطق دیگر و بخصوص در حوزه‌های کوچک‌تر نتایج متفاوتی بدست آید. با ارزیابی روش‌های سنتی، در ادامه بررسی روش‌های جدیدتر مبتنی بر استفاده از سنجش از دور و GIS تشریح می‌شود.

ب- روش‌های مبتنی بر سنجش از دور

در این بخش مدل منطقه بندی تصویر به عنوان روشی مبتنی بر استفاده از فنون سنجش از دور و GIS مورد ارزیابی قرار می‌گیرد. کالیبراسیون مدل، مشابه روش‌های قبلی، با استفاده از روش‌های رگرسیونی و شبکه عصبی مصنوعی انجام می‌گیرد. نتایج سه حالت رگرسیون بدون دوره تست، رگرسیون با دوره تست متحرک و شبکه عصبی با دوره تست متحرک به صورت مقایسه‌ای در جدول (۲)

جدول (۲): مقایسه روش‌های منطقه بندی تصویر (واحد داده های اصلی م.م.م).

RMSE			R(%)			مدل
شبکه عصبی تست متحرک	رگرسیون تست متحرک	رگرسیون بدون تست	شبکه عصبی تست متحرک	رگرسیون تست متحرک	رگرسیون بدون تست	
403	651	622	85	46	58	فروردین
452	843	531	84	26	79	اردیبهشت
121	126	102	96	94	97	خرداد
59	47	39	97	97	98	تیر
26	39	34	98	96	97	مرداد
15	30	19	99	94	98	شهریور
717	1181	947	84	48	75	فروردین-اردیبهشت
626	1281	775	87	22	79	اردیبهشت-خرداد
181	189	155	96	95	97	خرداد-تیر
82	78	71	98	97	98	تیر-مرداد
44	74	65	98	95	96	مرداد-شهریور
839	1481	1230	87	49	72	فروردین-خرداد
779	1543	868	84	20	82	اردیبهشت-تیر
214	237	196	96	95	97	خرداد-مرداد
93	116	94	98	96	98	تیر-شهریور
986	1669	1367	88	48	73	فروردین-تیر
731	1653	1029	88	24	78	اردیبهشت-مرداد
232	269	223	97	94	96	خرداد-شهریور
1079	1911	1440	87	37	74	فروردین-مرداد
776	1803	1066	89	24	79	اردیبهشت-شهریور
1169	1824	1391	84	50	78	فروردین-شهریور

ولی در مدل پیش‌بینی لحاظ نشده‌اند. از مهم‌ترین این متغیرها می‌توان به بارش همزمان در این ماه‌ها اشاره کرد که احتمال می‌رود تأثیر بسزایی بر رواناب فروردین و اردیبهشت داشته باشد. بدیهی است با توجه به نامعلوم بودن مقدار متغیرهای آتی نظیر بارش، معمولاً این متغیرها در مدل‌های پیش‌بینی به کار نمی‌روند. لکن در مواردی که بارش نقش

بررسی نقش بارش‌های همزمان در بهبود پیش‌بینی جریان


بررسی نتایج مدل‌ها نشان می‌دهد که عملکرد آن‌ها در دوره‌های مشتمل بر فروردین و اردیبهشت ضعیف‌تر از سایر دوره‌هاست. علت این تفاوت در عملکرد می‌تواند مربوط به متغیرهایی باشد که در تولید رواناب در این دو ماه موثرند

تولید رواناب (به طور مستقیم یا غیرمستقیم از طریق تأثیر بر روند ذوب برف حوزه) در این دوره‌ها دارد. در حالی که با گرم شدن هوا در ماه‌های بعدی، بارش کمتر شده و رواناب حاصل از بارش‌های همزمان کاهش می‌یابد و جریان بیشتر به جریان رودخانه در دوره‌های قبل وابسته می‌باشد. جدول ۳ و شکل ۵ نتایج مقایسه‌ای پیش‌بینی جریان در حالت معمولی و با افزودن بارش همزمان در دوره‌های شامل فروردین و اردیبهشت را برای روش رگرسیون منطقه بندی تصویر و شبکه عصبی نشان می‌دهند. در هر چهار حالت از دوره تست متحرک استفاده شده است بنابراین نتایج حالت واقعی پیش‌بینی را نشان می‌دهند.

اساسی دارد، از جمله برای پیش‌بینی‌های فصلی، می‌توان از بارش همزمان نیز در مدل استفاده نمود. در این صورت می‌توان مقدار آن را بر اساس سناریوهای بارش احتمالی تولید نموده و شرایط احتمالی آینده را بر این اساس بررسی نمود (۷). بنابراین، در مدل رگرسیونی و شبکه عصبی برای کلیه دوره‌های پیش‌بینی که شامل ماه‌های فروردین و اردیبهشت هستند، بارش همزمان این ماه‌ها به عنوان متغیر پیش‌بینی کننده به مدل اضافه شد و بهبود قابل توجهی در نتایج مشاهده گردید. این امر نشان می‌دهد که رواناب دوره‌های شامل فروردین و اردیبهشت تا حد زیادی وابسته به بارش در همین ماه‌هاست و بارش‌های بهاره نقش بسزایی در

جدول (۳): مقایسه پیش‌بینی جریان در حالت معمولی و با بارش همزمان در دوره‌های شامل فروردین و اردیبهشت (تست متحرک)

SE				R(%)				مدل
شبکه عصبی با بارش همزمان	شبکه عصبی	رگرسیون با بارش همزمان	رگرسیون	شبکه عصبی با بارش همزمان	شبکه عصبی	رگرسیون با بارش همزمان	رگرسیون	
311	403	582	651	92	85	62	46	۱. فروردین یک ماهه
410	452	465	843	91	84	81	26	۲. اردیبهشت
485	717	853	1181	97	84	77	48	۳. فروردین-اردیبهشت دو ماهه
517	626	760	1281	93	87	76	22	۴. اردیبهشت-خرداد
554	839	1062	1481	95	87	78	49	۵. فروردین - خرداد سه ماهه
599	779	1016	1543	93	84	69	20	۶. اردیبهشت-تیر
662	986	1208	1669	95	88	77	48	۷. فروردین - تیر چهار ماهه
649	731	1087	1653	93	88	70	24	۸. اردیبهشت - مرداد
748	1079	1280	1911	94	87	77	37	۹. فروردین - مرداد پنج ماهه
657	776	1107	1803	93	89	72	24	۱۰. اردیبهشت - شهریور
769	1169	1305	1824	94	84	78	50	۱۱. فروردین - شهریور شش ماهه

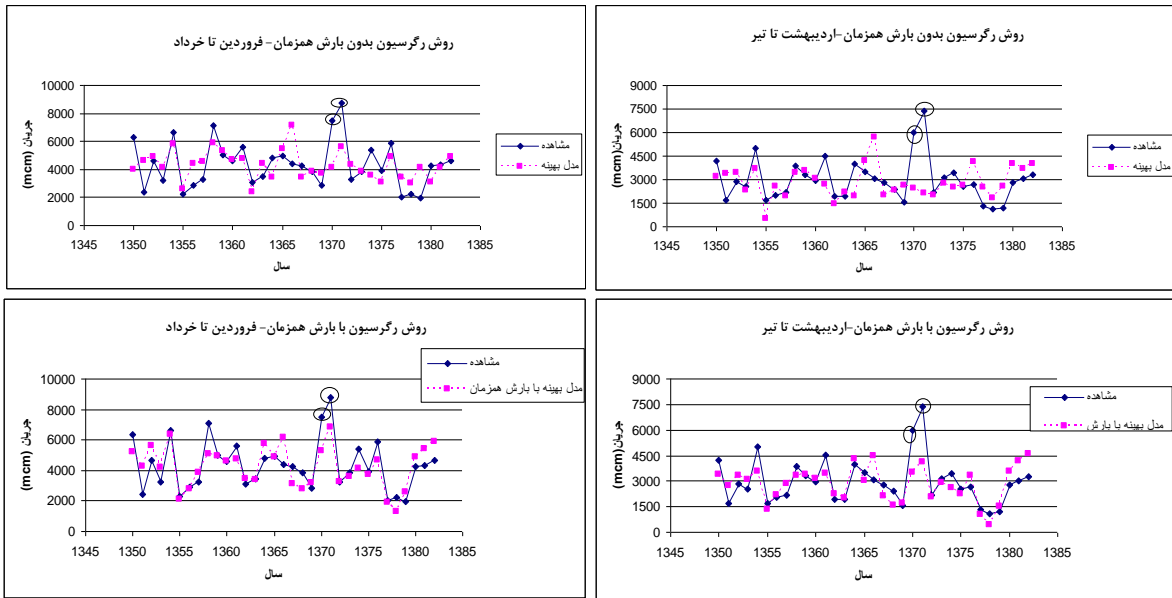


شکل (۵): بهبود ضرایب همبستگی مدل‌های رگرسیونی و شبکه عصبی با افزودن بارش همزمان

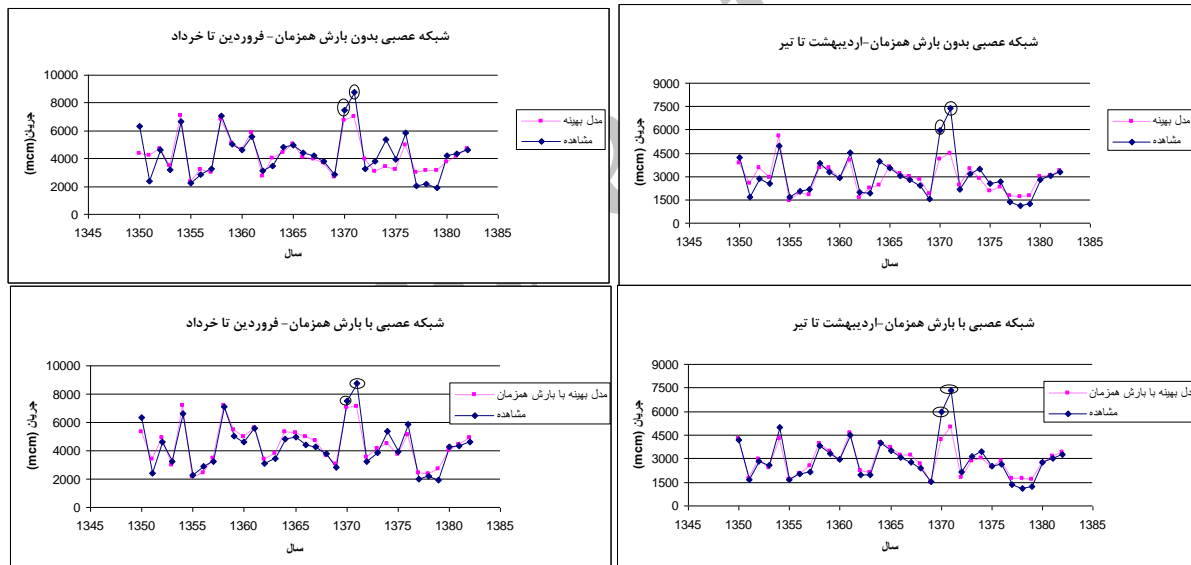
اردیبهشت شروع می‌شود، ضرایب همبستگی تماماً زیر ۵ درصد است. برای بررسی بیشتر چند نمونه از نمودارهای مربوطه در شکل ۶ و ۷ آورده شده است. مشاهده می‌شود که با افزودن بارش‌های همزمان، مدل بهبود قابل توجهی می‌یابد. با این وجود در برخی سال‌ها مانند سال‌های ۷۰ و ۷۱ هنوز اختلاف زیادی میان مدل و رواناب مشاهده شده، وجود دارد. این اختلاف در مورد دوره اردیبهشت تا تیر آشکارتر است. هر چند نتایج شبکه عصبی بسیار بهتر از روش رگرسیونی است، با این وجود از نمودارها مشخص می‌شود که شبکه عصبی نیز در مورد دوره‌هایی که با اردیبهشت شروع می‌شود، در سال‌های ۷۰ و ۷۱ ضعیف عمل می‌کند و در هر دو حالت با بارش همزمان و بدون آن، قادر نیست جریان ایجاد شده در این سال‌ها را پوشش دهد. افزودن بارش‌های همزمان در هر دو دوره و در هر دو مدل رگرسیونی و شبکه عصبی موثر است و خطای مدل را کاهش می‌دهد، ولی در مورد دو سال مذکور و به ویژه در مورد دوره‌هایی که با اردیبهشت شروع می‌شوند، این خطا آشکارتر است. این دو سال نتایج مدل‌ها را تحت تأثیر قرار داده و باعث افت قابل توجه آن‌ها می‌شوند. برای بررسی علت ایجاد این جریان‌ها بررسی‌های بیشتر ضرورت می‌یابد.

افزودن بارش‌های همزمان در شبکه عصبی از ۴ تا ۱۳ درصد و در روش رگرسیونی از ۱۶ تا ۵۵ درصد ضریب همبستگی مدل را بهبود داده است. البته نتایج شبکه عصبی ۹ تا ۳۰ درصد بهتر از نتایج روش رگرسیونی در حالت با بارش همزمان است. از طرفی، نتایج شبکه عصبی بدون بارش همزمان ۳۴ تا ۶۵ درصد بهتر از روش رگرسیونی است. این تحلیل نشان می‌دهد که افزودن بارش همزمان اختلاف این دو روش را بین ۹ تا ۴۸ درصد کم کرده است و نتایج دو مدل را به هم نزدیک‌تر نموده است. میزان بهبود نتایج در دوره‌های زمانی کوتاه مدت مشتمل بر اردیبهشت ماه ملموس‌تر است و هر چه دوره زمانی پیش‌بینی طولانی‌تر می‌شود نقش بارش‌های همزمان کمتر می‌شود. علت این امر مربوط به نقش ویژه بارش در جریان ماه اردیبهشت می‌باشد که با طولانی‌تر شدن دوره پیش‌بینی سهم جریان این ماه کمتر شده و نتایج به طور محسوس کمتر به بارش همزمان وابستگی نشان می‌دهند.

بطوریکه در شکل (۵) به خوبی آشکار است در هر دو مدل و بالاخص در روش رگرسیونی، بطور کلی دوره‌هایی که با ماه اردیبهشت شروع می‌شوند، نسبت به دوره‌هایی که با ماه فروردین شروع می‌شوند، نتایج ضعیف‌تری دارند. مثلاً در مورد رگرسون بدون بارش همزمان، در دوره‌هایی که با



شکل (۶): مقایسه نتایج دوره های شامل فرودین و اردیبهشت با بارش همزمان و بدون آن - روش رگرسیون



شکل (۷): مقایسه نتایج دوره های شامل فرودین و اردیبهشت با بارش همزمان و بدون آن - روش شبکه عصبی

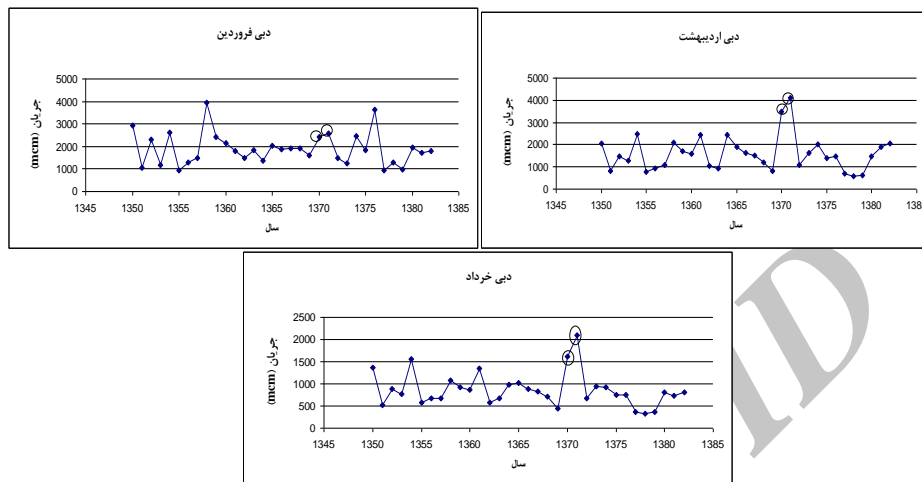
اردیبهشت این روند افزایشی جریان در خرداد نیز ادامه می‌یابد. با بررسی سایر ایستگاه‌های هیدرو متری موجود در منطقه نیز مشخص می‌شود که در سال‌های ۱۳۷۰ و ۱۳۷۱ در اردیبهشت ماه افزایش قابل توجه جریان وجود دارد. این امر صحت درستی جریان اندازه‌گیری شده در اردیبهشت را در ایستگاه خروجی بیان می‌کند. اما با توجه به دانسیته کم ایستگاه‌های بارندگی نمی‌توان در مورد صحت برآوردهای

بررسی سال‌های مشکل‌دار

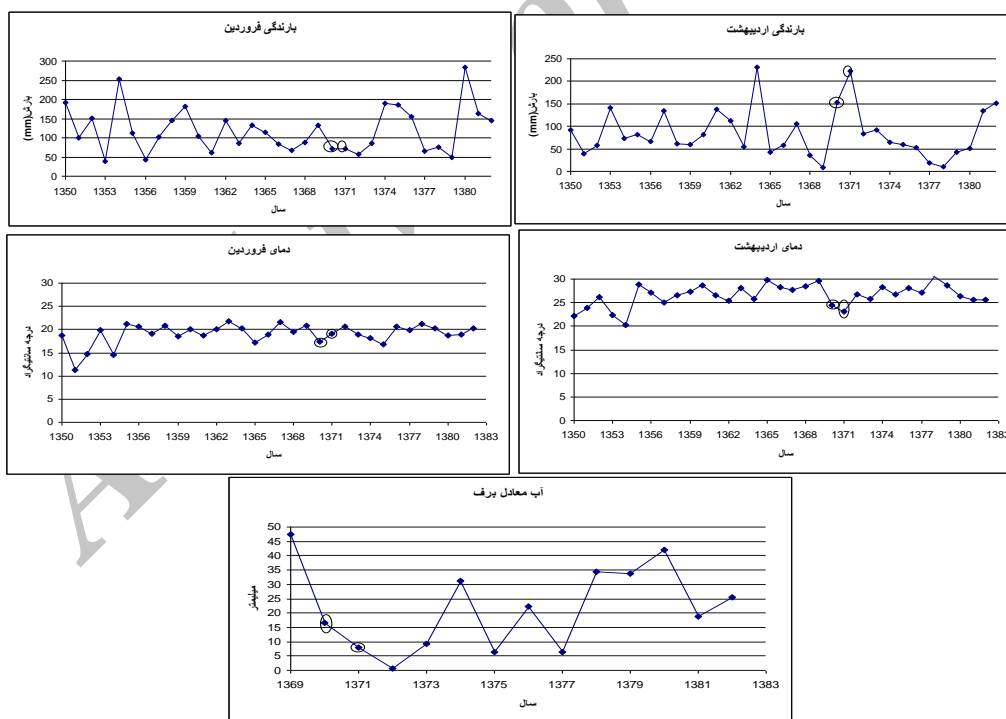
با بررسی جریان مشخص می‌شود که جریان در اردیبهشت ۷۰ و ۷۱ افزایش قابل توجهی داشته است (شکل ۸). با افزودن بارش‌های همزمان، دوره‌هایی که با اردیبهشت شروع می‌شوند نسبت به سایر دوره‌ها بهبود کمتری می‌یابند که علت عمده آن وجود همین جریان در اردیبهشت ۷۰ و ۷۱ است. مشاهده می‌شود پس از ایجاد این جریان در

زود هنگام برف اشاره کرد. که هر کدام از این موارد قابل بررسی است

بارش حوزه ای چنین قضاوتی را عنوان کرد. برای بررسی علت ایجاد این حجم جریان سناریو های مختلفی وجود دارد، که از جمله می توان به وجود بارش در آن سال ها و یا ذوب



شکل (۸): جریان در ماه های فروردین، اردیبهشت و خرداد



شکل (۹): آب معادل برف، بارندگی فروردین، بارندگی اردیبهشت و دمای فروردین و اردیبهشت

این جا با استفاده از روش دوره تست متحرک به نتایج حتی ضعیف تری منجر شدند. در این روش‌ها استفاده از شبکه عصبی بجای روش رگرسیون نیز به نتایج قابل قبولی ختم نگردید. به نظر می‌رسد اگرچه روش‌های فوق ممکن است در حوزه های کوچک با آمار دقیق و تحت شرایط خاص به نتایج قابل قبولی منجر شود، لکن اندازه حوزه دز، دقت آمار موجود و برآورد شده، و شرایط ویژه آن می‌تواند از عوامل ناکامی برخی از روش‌های فوق در این حوزه باشد.

استفاده از روش‌های پیچیده تر مبتنی بر برآوردهای حوزه ای متغیرها با بهره گیری از داده های سنسجش از دور، نظیر روش منطقه بندی تصویر، به نتایج بسیار بهتری منجر شد. همچنین، با به کارگیری شبکه عصبی بجای مدل رگرسیونی در روش منطقه بندی تصویر نتایج به طور محسوس بهبود یافت. این بهبود در برخی موارد به ۶۴ درصد در افزایش ضریب همبستگی نیز رسید. در بررسی‌های بیشتر، استفاده از بارش همزمان به عنوان متغیر موثر بر تولید جریان رودخانه بخصوص در ماه‌های فروردین و اردیبهشت مورد ارزیابی قرار گرفت. نتایج نشان داد که استفاده از بارش همزمان به عنوان متغیر پیش‌بینی کننده، می‌تواند نتایج روش رگرسیون را از ۱۶ تا ۵۵ درصد و روش شبکه عصبی را از ۹ تا ۳۰ درصد بهبود بخشد. با این حال، افزودن بارش همزمان نیز نتوانست خطای احتمالی موجود در داده های برخی از سال‌ها را پوشش دهد. تجربه کار در این حوزه نشان می‌دهد پراکندگی کم و نامتوازن ایستگاه‌های بارانسنجی، بالاخص در نواحی مرکزی که جزو بخش‌های پرباران محسوب می‌شود، در کنار پیچیدگی‌های اقلیمی منطقه می‌تواند از جمله عوامل بروز این گونه خطاها باشد.

با توجه به نمودارهای شکل ۹ مشخص است که آب معادل برف مربوط به سال‌های ۷۰ و ۷۱ چندان قابل توجه نیست. در حالی که بارندگی در اردیبهشت این سال‌ها بالا بوده و احتمالاً جریان به وجود آمده در این سال‌ها به دلیل بارش در این ماه می‌باشد.

در کنار این پدیده، موضوع ذوب زود هنگام برف نیز می‌تواند مطرح شود و یا به عبارت دیگر بارندگی به عنوان عاملی برای ذوب زود هنگام برف قابل بررسی است. اگر امکان پایش زمان ذوب برف وجود داشت و زمان شروع ذوب برف و سرعت ذوب قابل بررسی بود، قضاوت در این مورد با اطمینان بیشتری صورت می‌گرفت و امکان ایجاد پیش‌بینی‌های دقیق تر ذوب برف ایجاد می‌شد. با این وجود به نظر می‌رسد ایستگاه‌های بارانسنجی در این حوزه نتوانسته‌اند میزان واقعی بارش‌ها را در سطح حوزه آبریز پوشش دهند. در واقع بارش‌های ثبت نشده‌ای در طول حوزه وجود دارد که در آمار ایستگاه‌ها منعکس نشده است.

نتیجه گیری

در این تحقیق با طرح طیفی از روش‌های ساده سنتی تا روش‌های نسبتاً پیچیده نسبت به بررسی و ارزیابی نتایج آن‌ها در پیش‌بینی جریان رودخانه در حوزه دز اقدام به عمل آمد. برای این منظور، استفاده از روش‌های رگرسیونی و شبکه عصبی در مدل‌سازی مد نظر قرار گرفت. همچنین، امکان استفاده از داده های سنسجش از دور ماهواره ای در برآورد پوشش برفی حوزه بررسی شد.

نتایج حاصل از مدل‌سازی بر مبنای روش‌های ساده سنتی نشان‌دهنده عدم کارایی مناسب این روش‌ها در پیش‌بینی جریان رودخانه دز است. روش‌های رگرسیونی که به طور رایج بدون دروه تست مورد استفاده قرار می‌گیرند در

منابع

۱. منهای، م. ۱۳۸۶. مبانی شبکه های عصبی. دانشگاه صنعتی امیر کبیر، جلد اول.
۲. طوسی، م. ۱۳۸۲. بررسی سیمای یخچال‌های طبیعی با استفاده از فناوری سنسجش از دور ماهواره‌ای. پایان نامه کارشناسی ارشد، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران.

۳. برهانی، ع.، ج. ضاهرپور و ا. فاتحی مرج. ۱۳۸۳. مدل‌های برفایی پیش بینی جریان حوزه آبریز به کمک سنجش از دور و سیستم اطلاعات جغرافیایی. مجله بین‌المللی علوم و مهندسی، شماره ۲، جلد ۱۵، ص ۲۲۵-۲۴۳.
۴. رضایی، ی. و م.ر. مباشری. ۱۳۸۵. آشکار سازی ابرهای استراتوس در سنجنده MSG-1. نشریه دانشکده فنی، شماره ۸، جلد ۴۰، ۱۱۰۷-۱۱۱۹.
5. Freeman, G.J. 1999. Run off forecast error uncertainty and some of the ways it can effect snowmelt water scheduling decisions in the sierra. Processing of the Western Snow Conference, pp:45-5.
6. Garen, D.C. 1992. Improved Techniques in Regression-Based Streamflow Volume forecasting. water resources planning and management, 118(6):654-670.
7. Grygier, J., Stedinger, J.R., H. Yin and G. Freeman. 1993. Disaggregating Models of Seasonal Streamflow Forecast. 50th Eastern Snow Conference, Quebec City.
8. Karunanithi, N., W.J. Greeny., D. Whiteley and Bovee, 1994. Neural Network for River Flow Prediction. computing in civil engineering, 8(2):201-219.
9. McCuen, R., W. Rawls, and B. Whaley. 1979. Comparative evaluation of statistical methods for water supply forecasting. Water Resources Bulletin, AWRA, 15(4):935-946.
10. Moradkhani, H., K. Hsu, and S. Sorooshian. 2004. Improved streamflow forecasting using self organizing radial basis function artificial neural network. Hydrology, 295:246-262.
11. Romanov, p., G. Utman and I. Csiszer. 2002. Satellite-derived snow cover for North America: accuracy assessment Advances in Space Research, 30(11):2455-2460.
12. Stedinger, J.R., J. Grygier and H. Yin. 1988. Seasonal stream flow forecasting based on regression. Proc. 3rd Water Resources Operations Management Workshop: Computerized Decision Support Systems for Water Managers, CSU, Fort Collins, CO, J. W. Labadie, L.E. Brazil, I. Cuba, and L.E. Johnson, (eds.), ASCE, New York, pp:266-279.
13. Tappiner, U., G. Tappiner, J. Aschenwald, E. Tasser and B. Ostendorf. 2001. GIS based modeling of spatial pattern of snow cover duration in an alpine area. Ecological modeling, 138:265-275.
14. USACE, 2007. Water Balance and Regulation Alternative Analysis for Kajakai Reservoir Using HEC-ResSim- Phase 1 and 2. final report, PR-63, pp. 57.
15. Zuzle, J. and L. Cox. 1978. Review of operational water supply forecasting techniques in areas with seasonal snow cover. Western Snow Conference, 69-77.

Evaluation of Riverflow Forecasting Models

M. Bagheri, A. Borhani

ABSTRACT

Snowfall has an important role in the amount and distribution of river flows in mountainous basins. Therefore, it is crucial to assess the application of river flow forecasting models that employ an index of snow in their structure. In this paper, a range of forecasting models that have been in use since decades ago are presented and compared with the more recently developed ones. These include some conventional models based on simple statistical methods and models that use more sophisticated methods such as Artificial Neural Networks (ANN) and Geographic Information Systems (GIS) with remotely sensed snow covered area (SCA) data obtained through NOAA satellites. Moreover, it is shown that the use of test periods is important in reaching realistic conclusions about the models. In addition, a testing method is presented that through an iterative process, evaluates the whole period of available data. Data from the Dez Basin in Iran is used to carry out the calculations. Furthermore, the role of spring rainfalls and their simultaneous implication in the forecasting models is investigated.

KEYWORDS: FLOW FORECASTING, SNOW COVERED AREA, REMOTELY SENSED DATA, ARTIFICIAL NEURAL NETWORKS, DEZ BASIN

Archive of SID