

پیش بینی و آنالیز حساسیت تبخیر ماهانه از مخزن سد سیاه بیشه با استفاده

از شبکه های عصبی مصنوعی در ترکیب با الگوریتم ژنتیک

آزاده محمدیان شوئیلی^۱، حسین فتحیان^{۲*} و مهدی اسدی لور^۲

(۱) کارشناس ارشد آبیاری زهکشی، دانشگاه آزاد اسلامی واحد شوشتر، ایران.

(۲) اعضای هیات علمی گروه مهندسی آب، دانشکده کشاورزی، دانشگاه آزاد اسلامی واحد اهواز، ایران.

*نویسنده مسئول مکاتبات : Fathian.h58@gmail.com

تاریخ پذیرش: ۹۰/۰۵/۱۸

تاریخ دریافت: ۹۰/۰۳/۱۶

چکیده

فرآیند تبخیر، یکی از مؤلفه های اصلی چرخه آب در طبیعت است که نقش اساسی در مطالعات کشاورزی، هیدرولوژی و هواشناسی، بهره برداری از مخازن، طراحی سیستم های آبیاری و زهکشی، زمان بندی آبیاری و مدیریت منابع آب ایفا می کند. روش های زیادی از جمله روش های بیلان آب، تبخیر از تشت و روش های تجربی برای تخمین تبخیر از سطح آزاد، ارائه شده است که هر کدام از این روش ها، با محدودیت و خطای اندازه گیری توأم می باشد. امروزه تکنیک جدید استفاده از شبکه های عصبی مصنوعی که مبتنی بر هوش مصنوعی می باشد کاربرد گسترده ای در زمینه های مختلف علمی به ویژه مهندسی آب پیدا کرده است. در این تحقیق با استفاده از مدل شبکه عصبی مصنوعی پرسپترون چند لایه (MLP)، شبکه تابع پایه شعاعی (RBF) و شبکه پیش رو نده (FF)، میزان تبخیر ماهانه از مخزن سد سیاه بیشه تا ۳ ماه آینده پیش بینی شد. برای تعیین متغیرهای ورودی مؤثر در مدل های شبکه عصبی مصنوعی و تعداد نرون ها در لایه میانی هر یک از مدل ها، از قابلیت بهینه سازی الگوریتم ژنتیک استفاده شد. نتایج نشان می دهد که ضریب همبستگی بین مقادیر اندازه گیری شده و محاسبه شده با مدل های RBF، MLP و FF در برآورد و پیش بینی تبخیر ماهانه از مخزن سد سیاه بیشه به ترتیب برابر با ۰/۹۲ و ۰/۸۸ و ۰/۹۰ می باشد. بنابراین مدل RBF از دقت بیشتری نسبت به دو مدل MLP و FF در برآورد و پیش بینی میزان تبخیر ماهانه از مخزن سد، برخوردار می باشد. نتایج حاصل از آنالیز حساسیت نشان می دهد که تبخیر ماهانه از مخزن سد تا ۳ ماه آینده به ترتیب نسبت به زمان وقوع تبخیر بر حسب ماه، فشار هوا در سطح زمین در ۱، ۳ و ۲ ماه قبل، سرعت باد در سطح ۱۰۰۰ میلی بار در ۳ و ۲ ماه قبل و دمای هوا در سطح ۳۰۰ میلی بار در زمان حال بیشترین حساسیت را دارد.

واژه های کلیدی: پیش بینی، آنالیز حساسیت، تبخیر، شبکه عصبی مصنوعی، الگوریتم ژنتیک، سد سیاه بیشه.

مقدمه

فرآیند تبخیر، یکی از مؤلفه‌های اصلی چرخه آب در طبیعت است که نقش اساسی در مطالعات کشاورزی، هیدرولوژی و هواشناسی، بهره برداری از مخازن، طراحی سیستم‌های آبیاری و زهکشی، زمان بندی آبیاری و مدیریت منابع آب ایفا می‌کند. روش‌های مستقیم و غیر مستقیم زیادی جهت برآورد شدت تبخیر، وجود دارند. روش تشت تبخیر، جزء روش‌های مستقیم است که به طور معمول جهت برآورد تبخیر دریاچه‌ها و مخازن استفاده می‌شود. در روش‌های غیر مستقیم، شدت تبخیر با استفاده از روش‌های تجربی و استفاده از داده‌های هواشناسی و فرمول‌های مبتنی بر موازنۀ جرم و بقای انرژی برآورد می‌شود. یکی از روش‌های استاندارد اندازه گیری تبخیر، تشت تبخیر کلاس A مرکز هواشناسی آمریکاست، که در ایستگاه‌های هواشناسی ایران نیز از این نوع تشت تبخیر، استفاده می‌شود. نصب تشت تبخیر، دارای محدودیت‌های ابزاری و مشکلات عملی شامل خطای ناظر، کدورت آب و مشکلات نگهداری است و به همین دلیل از میزان دقت این ابزار می‌کاهد. بنابراین با توجه به مشکلات و محدودیت‌های تشت تبخیر، ارائه روش‌هایی برای برآورد میزان تبخیر با استفاده از دیگر متغیرهای هواشناسی ضروری است. از آنجایی که تبخیر، اساساً در طبیعت یک فرایند غیر خطی است، استفاده از روابط خطی، همراه با خطأ خواهد بود. بنابراین برای ایجاد رابطه غیر خطی بین تبخیر و متغیرهای هواشناسی می‌باید از روش‌های غیر خطی استفاده کرد (Kisi, 2006). طی دهه اخیر استفاده از روش‌های شبکه عصبی در مدل سازی تبخیر- تعرق و تبخیر از تشت، توسط محققین زیادی مورد تأیید قرار گرفته است. Bruton و همکاران در سال 2000 تبخیر روزانه از تشت، را با استفاده از شبکه عصبی مصنوعی تخمین زدند. آنها داده‌های بارندگی، دما، رطوبت نسبی، تابش خورشیدی و سرعت باد را به عنوان ورودی استفاده کردند. نتایج آنها بیانگر آن بود که میزان تبخیر برآورد شده با روش شبکه عصبی مصنوعی، کمترین خطأ (1/11 میلیمتر در روز) را نسبت به روش‌های رگرسیون خطی و پریستلی تیلور دارد. Terz و Erol Keskn در سال 2005 با به کارگیری داده‌های ایستگاه هواشناسی نزدیک دریاچه‌ای در غرب ترکیه، میزان تبخیر روزانه از تشت را با استفاده از مدل شبکه عصبی برآورد کردند. نتایج تحقیق آنها نشان داد که بهترین ترکیب مدل، با داده‌های ورودی دمای هوا، دمای سطح آب، تابش خورشیدی و فشار هوا به دست می‌آید (Kisi, 2006). در تحقیقی که مربوط به غرب ترکیه است، تبخیر روزانه از تشت را با استفاده از شبکه عصبی مصنوعی و روش عصبی- فازی، روش تجربی استیفینز- استوارت برآورد کرد. در این تحقیق داده‌های دمای هوا، استفاده از مدل شبکه عصبی برآورد کردند. نتایج مربوطه بیانگر آن است که روش عصبی- فازی، بهترین روش برای برآورد تبخیر از تشت است. رحیمی خوب در سال 2008 با ارائه مدل ANN، برتری شبکه‌های عصبی هوشمند را نسبت به معادله‌هارگریوز نشان داد. Chang و Chen در سال 2009 در مطالعه‌ای نشان دادند که استفاده از الگوریتم ژنتیک برای بهینه سازی داده‌های ورودی شبکه‌های عصبی مصنوعی می‌تواند نتایج دقیق تری را نسبت به حالتی که از این الگوریتم استفاده نمی‌شود به ما بددهد. در این تحقیق به برآورد و پیش‌بینی میزان تبخیر تا 3 ماه آینده در مخزن سد سیاه بیشه و با استفاده از شبکه‌های عصبی مصنوعی پرداخته می‌شود. همچنین به منظور تعیین متغیرهای ورودی مؤثر بر متغیرهای خروجی و تعیین ساختار بهینه مدل‌ها، از قابلیت بهینه سازی الگوریتم ژنتیک استفاده شده است.

مواد و روش‌ها


مدل شبکه عصبی مصنوعی

شبکه عصبی مصنوعی، روشی محاسباتی و الهام گرفته از سیستم‌های عصبی بیولوژیک است. شبکه عصبی مصنوعی از تعدادی عناصر پردازش تشکیل شده است که معمولاً به صورت موازی عمل می‌کنند و در معماری‌های منظمی، شکل می‌یابند. یک شبکه عصبی مصنوعی، شبیه مغز انسان، قابلیت یادگیری، فراخوانی و تعمیم یافتن از الگوهای یادگیری داده‌ها را دارد. این شبکه‌ها می‌توانند برای اجرای یک عمل خاص با تعديل کردن وزن‌های بین عناصر، آموزش ببینند. معمولاً شبکه‌های عصبی مصنوعی جهت تبدیل یک ورودی به یک خروجی، آموزش می‌بینند. مزیت شبکه‌های عصبی مصنوعی نسبت به روش‌های تجربی این است که قادر به مدل سازی سیستم‌های خطی و غیر خطی هستند (Riad, 2004). این روش در قیاس با دیگر روش‌ها، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی دارد. گزارش کمیته تحقیق جامعه مهندسین عمران آمریکا بر استفاده از شبکه‌های عصبی مصنوعی به عنوان گزینه‌های مفید و ارزشمند در مدل سازی‌های مختلف هیدرولوژیکی تأکید دارد. آنها با بررسی نقش شبکه‌های عصبی مصنوعی در شاخه‌های مختلف هیدرولوژی، نتیجه‌گیری کرده‌اند که شبکه‌های عصبی مصنوعی، قابلیت شبیه‌سازی بسیاری از نگاشت‌های پیچیده غیرخطی را در این زمینه دارا می‌باشند (ASCE, 2000a,b). یادگیری شبکه‌های عصبی، در واقع تنظیم پارامترهای شبکه چون مقادیر وزن‌های w و b است. شبکه ای دارای یک قابلیت یادگیری مناسب است که اگر برای یک وضعیت خاص آموزش داده شود و تغییر کوچکی در شرایط محیطی شبکه رخ دهد، شبکه بتواند با آموزشی مختصر، برای شرایط جدید نیز کارآمد باشد. نمای شماتیک شبکه عصبی در شکل ۱ نشان داده شده است. در این شبکه، نرون‌های هر لایه تماماً به نرون‌های لایه قبل متصل شده است. خروجی هر لایه پس از تأثیر گذاشتنتابع محرك، ورودی لایه بعدی می‌گردد و این روند تا بدست آمدن خروجی شبکه ادامه می‌یابد. روند یادگیری در شبکه‌های انتشار برگشتی، طی سه مرحله رفت، مرحله برگشت و مرحله تکرار محاسبات، انجام می‌ذیرد. رابطه بین خروجی هر نرون (قبل از ورود به تابع محرك) و مقادیر ورودی در رابطه فوق R ، تعداد کل ورودی‌ها، p ورودی‌های مدل، W شدت اتصال(وزن) بین نرونها و b بایاس مربوط به هر نرون می‌باشد. شبکه‌های عصبی مصنوعی با وجود اینکه با سیستم عصبی طبیعی قابل مقایسه نیستند، ویژگی‌هایی دارند که آنها را در بعضی از کاربردها مانند تفکیک الگو و یا هرجا که نیاز به یادگیری با یک نگاشت خطی و یا غیرخطی باشد، ممتاز می‌نمایند. از ویژگی‌ها و قابلیت‌های شبکه‌های عصبی مصنوعی به مواردی همچون قابلیت یادگیری و تطبیق پذیری با اطلاعات موجود، قابلیت تعمیم دهنده، پردازش موازی ورودی‌های شبکه و در نتیجه افزایش سرعت پردازش، تحمل پذیری بالای خطاها و غیره می‌توان اشاره کرد (منهاج, 1381). در این تحقیق از روش شبکه عصبی پرسپترون چند لایه (MLP)، شبکه تابع پایه شعاعی (RBF) و شبکه پیش رونده (FF) برای پیش بینی و برآورد ماهانه تبخیر از سد سیاه بیشه استفاده شده است.

به صورت زیر است:

$$n_i = \sum_{j=1}^R (p_j w_{i,j} + b_j) \quad (1)$$

در رابطه فوق R ، تعداد کل ورودی‌ها، p ورودی‌های مدل، W شدت اتصال(وزن) بین نرونها و b بایاس مربوط به هر نرون می‌باشد. شبکه‌های عصبی مصنوعی با وجود اینکه با سیستم عصبی طبیعی قابل مقایسه نیستند، ویژگی‌هایی دارند که آنها را در بعضی از کاربردها مانند تفکیک الگو و یا هرجا که نیاز به یادگیری با یک نگاشت خطی و یا غیرخطی باشد، ممتاز می‌نمایند. از ویژگی‌ها و قابلیت‌های شبکه‌های عصبی مصنوعی به مواردی همچون قابلیت یادگیری و تطبیق پذیری با اطلاعات موجود، قابلیت تعمیم دهنده، پردازش موازی ورودی‌های شبکه و در نتیجه افزایش سرعت پردازش، تحمل پذیری بالای خطاها و غیره می‌توان اشاره کرد (منهاج, 1381). در این تحقیق از روش شبکه عصبی پرسپترون چند لایه (MLP)، شبکه تابع پایه شعاعی (RBF) و شبکه پیش رونده (FF) برای پیش بینی و برآورد ماهانه تبخیر از سد سیاه بیشه استفاده شده است.



شکل ۱: یک شبکه عصبی مصنوعی تک لایه با s نرون

ارزیابی شبکه‌های عصبی مصنوعی

به منظور ارزیابی و بررسی مدل‌های مورد استفاده در برآورد تبخیر، از معیارهای متداول ضریب تعیین، جذر میانگین مربع خطأ و میانگین خطای مطلق استفاده می‌شود. معیار آماری ضریب تعیین، برای تعیین همبستگی بین مقادیر و برآورده شده و همچنین جذر میانگین مربع خطأ و میانگین خطای مطلق، برای تعیین مقادیر خطای برآورده شده، به کار برده شدند. روابط مربوطه به صورت زیر هستند:

$$R^2 = \frac{\left(\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right)^2}{\left(\sum_{i=1}^n (X_i - \bar{X})^2 (Y_i - \bar{Y})^2 \right)} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |X_i - \bar{Y}|}{n} \quad (4)$$

در این روابط: X_i و Y_i امين داده واقعی و برآورده شده، \bar{X} میانگین داده‌های واقعی، \bar{Y} میانگین داده‌های برآورده شده و n تعداد نمونه‌های ارزیابی هستند.


معرفی منطقه مورد مطالعه

حوزه مورد مطالعه، سد سیاه بیشه است که در منطقه کوهستانی البرز شمالی و در فاصله 125 کیلومتری شمال تهران واقع شده است. داده‌های این تحقیق از اداره کل هواشناسی استان مازندران اخذ گردیده شده. نزدیک ترین ایستگاه سینوپتیک به سد سیاه بیشه، ایستگاه سینوپتیک سیاه بیشه با مختصات جغرافیایی $25^{\circ} 36'$ عرض شمالی، $30^{\circ} 51'$ طول شرقی می‌باشد که 1855/4 متر از سطح دریا ارتفاع دارد. شکل 2 نمایی از منطقه مورد مطالعه را نشان می‌دهد. با توجه به روش طبقه‌بندی دومارتن، منطقه مورد مطالعه در اقلیم نیمه مرطوب قرار دارد که مشخصات اقلیمی آن در جدول ۱ ارائه شده است. اطلاعات هواشناسی مورد استفاده شامل: پارامترهای ماهانه حداکثر

و حداقل دمای هوا (T)، حداکثر و حداقل رطوبت نسبی (RH₁₀)، ساعت آفتابی و میزان بارندگی (R) بوده و همچنین اطلاعات هواشناسی ایستگاه جو بالا شامل: پارامترهای ماهانه دمای هوا در سطح 300 میلی بار و 1000 میلی بار، رطوبت نسبی در سطح 300 میلی بار و 1000 میلی بار، سرعت باد منطقه‌ای در سطح 300 میلی بار و 1000 میلی بار و فشار در سطح زمین می‌باشد. بازده زمانی مورد مطالعه از فروردین ماه سال 1365 الی اسفند سال 1388 می‌باشد.

جدول 1: شاخص‌های آماری پارامترها در ایستگاه سینوپتیک سیاه بیشه و ایستگاه جو بالا

حداقل	حداکثر	میانگین	شاخص آماری	دامنه	انحراف	ضریب	پارامتر
-10/1	16/1	5/8	دمای حداقل ماهانه (سانتیگراد)	26/2	6/6	1/12	
-1/5	26/13	14/60	دمای حداکثر ماهانه (سانتیگراد)	27/63	7/02	0/48	
54/51	311/1	155/53	ساعت آفتابی	256/6	50/38	0/32	
19	74	43/04	رطوبت نسبی حداقل (درصد)	55	9/33	0/21	
59/39	98	81/30	رطوبت نسبی حداکثر (درصد)	38/61	7	0/08	
0	224	79/64	تبخیر ماهانه (میلی متر)	224	65/75	0/82	
-49/26	-25/51	-39/44	دمای هوا در سطح 300 میلی بار (سانتیگراد)	23/75	7/26	-0/18	
4/5	37/65	22/94	دمای هوا در سطح 1000 میلی بار (سانتیگراد)	33/15	9/7	0/42	
1/118	46/52	17/94	رطوبت نسبی در سطح 300 میلی بار (درصد)	45/34	11/35	0/63	
21/66	88/48	49/44	رطوبت نسبی در سطح 1000 میلی بار (درصد)	66/82	15/95	0/32	
793/34	803/92	798/28	فشار در سطح زمین	10/58	2/1	0/002	
7/01	42/53	23/68	سرعت باد منطقه‌ای در سطح 300 میلی بار	35/52	7/4	0/31	
-4/2	3/59	-0/40	سرعت باد منطقه‌ای در سطح 1000 میلی بار	7/8	1/46	-3/7	



شکل 2: موقعیت ایستگاه سد سیاه بیشه در شمال ایران

تعیین متغیرهای ورودی مؤثر در مدل شبکه عصبی مصنوعی با بکارگیری الگوریتم ژنتیک

به منظور ایجاد و ساخت الگوهای آموزشی، داده‌های مرتب شده در مرحله پیش پردازش، در کنار یکدیگر قرار داده شدند. علاوه بر این به منظور در نظر گرفتن اثر پارامترهای ماههای قبل، تأخیر زمانی ۳ ماه قبل، برای متغیرهای ورودی در نظر گرفته شد تا مجموعه پتانسیل متغیرهای ورودی به دست آید. تعداد الگوهای به دست آمده بعد از تأخیر زمانی متغیرها، برابر با ۲۷۳ می‌باشد. جدول ۲ مجموعه پتانسیل متغیرهای ورودی حاصل از ساخت الگوهای آموزشی را نشان می‌دهد که برابر با ۵۳ متغیر ورودی می‌باشد. جدول ۳ متغیرهای خروجی موردنظر را نشان می‌دهد. به منظور تعیین متغیرهای ورودی مؤثر، از امکانات الگوریتم ژنتیک نرم افزار NeuroSolutions استفاده گردید. برای این منظور از مدل MLP که یک مدل پرکاربرد در مدل سازی فرایندهای هیدرولوژیکی و هیدرولوژیکی می‌باشد، در ترکیب با الگوریتم ژنتیک به ازای تعداد نسل‌های برابر با ۱۰۰ و تعداد افراد (جمعیت) تولید شده در هر نسل برابر با ۵۰ در نظر گرفته شد. جدول ۴ نتایج حاصل از تعیین متغیرهای ورودی مؤثر با به کارگیری قابلیت الگوریتم ژنتیک را نشان می‌دهد. در این جدول، متغیرهایی که در سیستم کدگذاری دودویی الگوریتم ژنتیک شامل عدد یک می‌باشند متغیرهای مؤثر و متغیرهایی که شامل عدد صفر هستند، جزء متغیرهای غیر مؤثر در نظر گرفته شده‌اند. با توجه به جدول ۴ تعداد متغیرهای ورودی مؤثر برابر با ۵۰ عدد حاصل گردید.

جدول ۲: مجموعه پتانسیل متغیرهای ورودی حاصل از ساخت الگوهای آموزشی

متغیرهای ورودی	معرفی متغیرهای ورودی	متغیرهای ورودی	معرفی متغیرهای ورودی
Month	سرعت باد منطقه‌ای در سطح 1000 میلی بار در ۱ ماه قبل	ZW 1000mb(t-1)	زمان برحسب ماه
Air temp 300mb(t-3)	سرعت باد منطقه‌ای در سطح 1000 میلی بار در زمان حال	ZW 1000mb(t)	دمای هوا در سطح 300 میلی بار در ۳ ماه قبل
Air temp 300mb(t-2)	دمای حداقل هوا در ۳ ماه قبل	T min (t-3)	دمای هوا در سطح 300 میلی بار در ۲ ماه قبل
Air temp 300mb(t-1)	دمای حداقل هوا در ۲ ماه قبل	T min (t-2)	دمای هوا در سطح 300 میلی بار در ۱ماه قبل
Air temp 300mb(t)	دمای حداقل هوا در ۱ ماه قبل	T min (t-1)	دمای هوا در سطح 300 میلی بار در زمان حال
Air temp 1000mb(t-3)	دمای حداقل هوا در زمان حال	T min (t)	دمای هوا در سطح 1000 میلی بار در ۳ ماه قبل
Air temp 1000mb(t-2)	دمای حداقل هوا در ۳ ماه قبل	T max (t-3)	دمای هوا در سطح 1000 میلی بار در ۲ ماه قبل
Air temp 1000mb(t-1)	دمای حداقل هوا در ۲ ماه قبل	T max (t-2)	دمای هوا در سطح 1000 میلی بار در ۱ماه قبل
Air temp 1000mb(t)	دمای حداقل هوا در ۱ ماه قبل	T max (t-1)	دمای هوا در سطح 1000 میلی بار در زمان حال
RH 300mb (t-3)	دمای حداقل هوا در زمان حال	T max (t)	رطوبت نسبی در سطح 300 میلی بار در ۳ ماه قبل
RH 300mb (t-2)	رطوبت نسبی حداقل در ۳ ماه قبل	RH min (t-3)	رطوبت نسبی در سطح 300 میلی بار در ۲ ماه قبل

متغیرهای ورودی	معرفی متغیرهای ورودی	متغیرهای ورودی	معرفی متغیرهای ورودی
RH min (t-2)	رطوبت نسبی در سطح 300 میلی بار در 1 ماه قبل	RH min (t-1)	رطوبت نسبی حداقل در 2 ماه قبل
RH min (t-1)	رطوبت نسبی در سطح 300 میلی بار در زمان حال	RH min (t)	رطوبت نسبی حداقل در 1 ماه قبل
RH min (t)	رطوبت نسبی در سطح 1000 میلی بار در 3 ماه قبل	RH min (t)	رطوبت نسبی حداقل در زمان حال
RH max (t-3)	رطوبت نسبی در سطح 1000 میلی بار در 2 ماه قبل	RH max (t-3)	رطوبت نسبی حداکثر در 3 ماه قبل
RH max (t-2)	رطوبت نسبی در سطح 1000 میلی بار در 1 ماه قبل	RH max (t-2)	رطوبت نسبی حداکثر در 2 ماه قبل
RH max (t-1)	رطوبت نسبی در سطح 1000 میلی بار در زمان حال	RH max (t-1)	رطوبت نسبی حداکثر در 1 ماه قبل
RH max (t)	فشار در سطح زمین در 3 ماه قبل	RH max (t)	رطوبت نسبی حداکثر در زمان حال
sun shine (t-3)	فشار در سطح زمین در 2 ماه قبل	sun shine (t-3)	ساعت آفتابی در 3 ماه قبل
sun shine (t-2)	فشار در سطح زمین در 1 ماه قبل	sun shine (t-2)	ساعت آفتابی در 2 ماه قبل
sun shine (t-1)	فشار در سطح زمین در زمان حال	sun shine (t-1)	ساعت آفتابی در 1 ماه قبل
sun shine (t)	سرعت باد منطقه‌ای در سطح 300 میلی بار در 3 ماه قبل	sun shine (t)	ساعت آفتابی در زمان حال
R (t-3)	سرعت باد منطقه‌ای در سطح 300 میلی بار در 2 ماه قبل	R (t-3)	بارندگی در 3 ماه قبل
R (t-2)	سرعت باد منطقه‌ای در سطح 300 میلی بار در 1 ماه قبل	R (t-2)	بارندگی در 2 ماه قبل
R (t-1)	سرعت باد منطقه‌ای در سطح 300 میلی بار در زمان حال	R (t-1)	بارندگی در 1 ماه قبل
R(t)	سرعت باد منطقه‌ای در سطح 1000 میلی بار در 3 ماه قبل	R(t)	بارندگی در زمان حال
	سرعت باد منطقه‌ای در سطح 1000 میلی بار در 2 ماه قبل		ZW 1000 mb(t-3)
			ZW 1000 mb(t-2)

جدول 3: متغیرهای خروجی مدل‌های شبکه عصبی مصنوعی

متغیرهای خروجی	معرفی خروجی‌ها
E(t)	تبخیر از تشت در زمان حال
E(t+1)	تبخیر از تشت در 1 ماه آینده
E(t+2)	تبخیر از تشت در 2 ماه آینده
E(t+3)	تبخیر از تشت در 3 ماه آینده

99	99	99	99	99	99	99	نسل
23	38	47	48	49	Best	Best	کروموزوم
1	1	1	1	1	1	1	T min (t-1)
1	1	1	1	1	1	1	T min (t)
1	0	1	1	1	1	1	T max (t-3)
1	1	0	1	1	1	1	T max (t-2)
0	0	0	0	0	0	0	T max (t-1)
1	1	1	1	1	1	1	T max (t)
1	1	0	00	1	1	1	RH min (t-3)
1	1	1	1	1	1	1	RH min (t-2)
1	1	1	1	1	1	1	RH min (t-1)
1	1	1	1	1	1	1	RH min (t)
1	1	1	1	1	1	1	RH max (t-3)
1	1	1	1	0	1	1	RH max (t-2)
1	1	1	1	1	1	1	RH max (t-1)
1	1	1	1	1	1	1	RH max (t)
1	1	1	1	1	1	1	sun shine (t-3)
1	1	1	1	1	1	1	sun shine (t-2)
1	1	1	1	1	1	1	sun shine (t-1)
1	1	1	1	1	1	1	sun shine (t)
1	1	1	1	1	1	1	R (t-3)
1	1	1	1	1	1	1	R (t-2)
1	1	1	1	1	1	1	R (t-1)
1	1	1	1	1	1	1	R (t)

کالیبراسیون مدل‌های شبکه عصبی مصنوعی

کالیبراسیون هر یک از مدل‌های شبکه عصبی مصنوعی، شامل تعیین تعداد تکرارهای مناسب جهت آموزش، تعیین مناسب ترین الگوریتم آموزش و نیز تابع تحریک در هر یک از لایه‌های پنهان، و خروجی شبکه، و تعیین تعداد بهینه نرون‌ها در لایه پنهان می‌باشد. با توجه به تعداد الگوهای (273)، از 70٪ الگوها جهت کالیبراسیون (آموزش) مدل‌های شبکه عصبی مصنوعی استفاده گردید. همچنانی از 15٪ الگوهای ارزیابی همزمان با آموزش شبکه و از 15٪ باقیمانده برای تست (آزمون) عملکرد شبکه‌های کالیبره شده استفاده گردید. جدول 5 نتایج حاصل از کالیبراسیون هر یک از مدل‌های FF MLP و RBF را نشان می‌دهد. در ادامه به علت حجم زیاد محاسبات و نمودارها و

جدول، برای هر یک از مدل‌ها فقط نتیجه حاصل از تعیین تعداد بهینه نرون‌ها در لایه میانی شبکه MLP با استفاده از الگوریتم ژنتیک بیان می‌شود.

جدول ۵: نتایج حاصل از کالیبراسیون هر یک از مدل‌های RBF و FF و MLP

تعداد لایه پنهان	تعداد مناسب	تکرار آموزش	تابع انتقال		نوع مدل	تعداد بهینه نرون‌ها در لایه میانی
			الگوریتم آموزش	لایه میانی		
1	2000	DeltaBarDelta	LinearSigmoidAxon	SigmoidAxon	67	MLP
1	3866	Momentum	TanhAxon	SigmoidAxon	10	FF
1	3794	Momentum	LinearTanhAxon	TanhAxon	15	RBF

تعیین تعداد بهینه نرون‌ها در لایه میانی شبکه MLP

به منظور تعیین تعداد بهینه نرون‌ها در لایه میانی شبکه MLP، از قابلیت بهینه سازی الگوریتم ژنتیک نرم افزار NeuroSolutions5 استفاده می‌شود. برای این منظور، آموزش مدل MLP حاصل از کالیبراسیون که در جدول ۵ ذکر شده به ازای تعداد مختلف نرون‌های لایه میانی با استفاده از الگوریتم ژنتیک تکرار گردیده تا تعداد بهینه نرون‌ها در لایه میانی به دست آید. برای تعریف دامنه تغییرات تعداد نرون‌ها در لایه پنهان، از فرمول تجربی زیر استفاده می‌شود.

$$N_H \leq 2N_I + 1 \quad (5)$$


که در آن N_H تعداد گره‌های لایه‌های پنهان و N_I تعداد ورودی‌ها می‌باشد. با توجه به اینکه تعداد ورودی‌های مؤثر بدست آمده برابر با 50 است، حداقل تعداد گره‌های لایه پنهان با توجه به معادله (5) برابر با 101 می‌باشد. به عبارتی دامنه تغییرات تعداد نرون‌ها در لایه میانی، بین 1 تا 101 خواهد بود. نتایج حاصل از بکارگیری الگوریتم ژنتیک برای تعیین تعداد بهینه گره‌های لایه میانی مدل MLP در جدول 6 نشان داده شده است. همان طوری که در جدول 6 مشاهده می‌شود تعداد بهینه گره‌های لایه میانی در مدل MLP بعد از 100 نسل آموزش مدل که منجر به خطای کمتر می‌گردد، برابر با 67 گره می‌باشد. به همین ترتیب، تعداد بهینه نرون‌های لایه میانی در مدل‌های FF و RBF با استفاده از الگوریتم ژنتیک به دست آمده در جدول 5 آورده شده است.


جدول 6: نتایج حاصل از بکارگیری الگوریتم ژنتیک برای تعیین تعداد بهینه گره‌های لایه میانی شبکه MLP

نسل	کروموزوم	تعداد گره‌ها	میزان برآش
0	0	1	.016543
0	Best	67	0/00508
1	Best	67	0/00508
2	Best	67	0/00508
3	Best	67	0/00508
4	Best	67	0/00508
...
97	Best	67	0/00508
98	Best	67	0/00508
99	Best	67	0/00508


مقایسه مدل‌های MLP, RBF, FF و انتخاب بهترین مدل به ازای الگوهای آزمون

بعد از کالیبراسیون (آموزش) مدل‌ها، هر سه مدل به ازای داده‌های آزمون، مقایسه و ارزیابی می‌شوند. شکل‌های 3 تا 6 مقایسه تغییرات مقادیر متغیرهای خروجی شبیه سازی شده با شبکه‌های عصبی مصنوعی، نسبت به مقادیر متناظر مشاهداتی را نشان می‌دهد. علاوه بر این، معادله خط برآش بر نقاط برای هر شبکه در شکل‌های 3 تا 6 نشان داده شده است. جدول 7 مقادیر میانگین مربعات خطأ (MSE)، میانگین قدر مطلق خطأ (MAE) و ضریب تعیین² (R^2) بین مقادیر محاسبه شده توسط هریک از مدل‌ها و نیز مقادیر اندازه‌گیری شده به ازای داده‌های آزمون را نشان می‌دهد.


شکل 3: مقایسه تغییرات مقادیر $E(t)$ شبیه‌سازی شده با شبکه‌های عصبی مصنوعی نسبت به مقادیر متناظر مشاهداتی



شکل ۴ : مقایسه تغییرات مقادیر $E(T+1)$ شبیه سازی شده با شبکه‌های عصبی مصنوعی نسبت به مقادیر متناظر مشاهداتی



شکل ۵ : مقایسه تغییرات مقادیر $E(t+2)$ شبیه سازی شده با شبکه‌های عصبی مصنوعی نسبت به مقادیر متناظر مشاهداتی




شکل ۶: مقایسه تغییرات مقادیر $E(t+3)$ شبیه سازی شده با شبکه‌های عصبی مصنوعی نسبت به مقادیر متناظر مشاهداتی

با توجه به معادلات خطوط برازش و نیز ضریب تعیین در شکل‌های 3 تا 6 می‌توان دریافت که شبیب خط مربوط به مدل RBF به عدد یک، نزدیک تر و عرض از مبدأ آن کوچکتر می‌باشد.علاوه بر این، مقایسه شاخص‌های آماری متناظر در جدول 7 نشان می‌دهد کمترین مقدار میانگین مربعات خطأ و نیز میانگین قدرمطلق خطأ، بین مقادیر محاسبه شده و اندازه گیری شده مربوط به مدل RBF می‌باشد. همچنانی با توجه به مقادیر ضریب تعیین جدول 7، میانگین مقادیر ضریب تعیین هر یک از متغیرهای خروجی شبکه‌ها با مقادیر اندازه گیری شده برای مدل‌های RBF ، MLP و FF به ترتیب برابر با 0/92 و 0/88 و 0/90 می‌باشد که معرف ضریب تعیین بالا برای مدل RBF نسبت به دو مدل دیگر می‌باشد. بنابراین مدل RBF از دقت بیشتری نسبت به دو مدل MLP و FF در برآورد و پیش‌بینی میزان تبخیر ماهانه از مخزن سد سیاه بیشه برخوردار می‌باشد.

جدول 7: مقایسه RMSE و ضریب تعیین بین مقادیر محاسبه شده توسط مدل‌ها به ازای الگوهای آزمون و مقادیر اندازه‌گیری شده

آنالیز حساسیت متغیرهای خروجی مدل RBF نسبت به متغیرهای ورودی

یکی از روش‌های بررسی میزان تأثیر تغییرات یک متغیر بر متغیر دیگر، آنالیز حساسیت است. در آنالیز حساسیت، درصد تغییر در متغیر خروجی به ازای تغییر در متغیرهای ورودی، محاسبه می‌شود. با توجه به اینکه مدل RBF بهترین مدل در پیش‌بینی میزان تبخیر ماهانه از مخزن سد سیاه بیشه شناخته شده است، بنابراین آنالیز حساسیت متغیرهای خروجی نسبت به متغیرهای ورودی با استفاده از این مدل بیان می‌شود. شکل 7 میزان حساسیت متغیرهای خروجی نسبت به متغیرهای ورودی را نشان می‌دهد.



شکل 7: میزان حساسیت متغیرهای خروجی نسبت به متغیرهای ورودی در مدل RBF

با توجه به شکل ۷ می‌توان دریافت که زمان وقوع تبخیر بر حسب ماه و نیز بر حسب فشار هوا در سطح زمین، در ۱، ۲ و ۳ ماه قبل، و نیز سرعت باد در سطح ۱۰۰۰ میلی بار در ۳ و ۲ ماه قبل و دمای هوا در سطح ۳۰۰ میلی بار در زمان حال به ترتیب بیشترین تأثیر بر میزان تبخیر را دارند. همچنانی تعداد ساعت آفتابی در ۲ ماه قبل، و نیز عمق بارش در ماه قبل و تعداد ساعت آفتابی در ۳ ماه قبل، و نیز عمق بارش در ۲ ماه قبل و زمان حال و رطوبت نسبی حداقل در ماه قبل و تعداد ساعت آفتابی در ماه، قبل به ترتیب کمترین تأثیر بر تبخیر از سطح مخزن را دارند.

بحث و نتیجه گیری

مدل‌های شبکه عصبی مصنوعی برای شناخت رابطه پیچیده بین مجموعه داده‌های ورودی و خروجی سیستم مورد مطالعه توانایی بالایی دارند. تنها ضعف این مدل‌ها نیاز آنها به تعداد الگوی داده شده نسبتاً زیاد، برای آموزش است. هر چه تعداد داده‌ها بیشتر باشد، شبکه‌ای با ساختار دقیق‌تر بدست خواهد آمد. علاوه بر این با بکارگیری قابلیت بهینه سازی الگوریتم ژنتیک، می‌توان ساختار بهینه هر یک از مدل‌های شبکه عصبی مصنوعی را از نظر تعداد لایه‌های پنهان، و نیز تعداد گره‌ها در لایه پنهان، نوع تابع تحریک و الگوریتم یادگیری شبکه را مشخص نمود. به طوری که با این روش، زمان لازم برای تعیین ساختار بهینه هر یک از مدل‌ها به میزان قابل ملاحظه ای کاهش می‌یابد. مقایسه نتایج حاصل از مدل‌ها نشان می‌دهد که مدل RBF دارای کمترین مقدار در پارامترهای آماری ریشه میانگین مربعات خطای میانگین خطای مطلق است و دارای بیشترین ضریب تعیین نسبت به دو مدل دیگر می‌باشد. بنابراین مدل RBF از توانایی بالاتری در برآورده و پیش‌بینی تبخیر ماهانه از مخزن سد سیاه بیشتر برخوردار می‌باشد. آنالیز حساسیت متغیرهای خروجی مدل‌ها نسبت به متغیرهای ورودی نشان می‌دهد که زمان وقوع تبخیر بر حسب ماه، و فشار هوا در سطح زمین در ۱، ۲ و ۳ ماه قبل، سرعت باد در سطح ۱۰۰۰ میلی بار در ۳ و ۲ ماه قبل و دمای هوا در سطح ۳۰۰ میلی بار در زمان حال، به ترتیب بیشترین تأثیر بر میزان تبخیر را دارند. علاوه بر این، تعداد ساعت آفتابی در ۲ ماه قبل، و نیز عمق بارش در ماه قبل، و تعداد ساعت آفتابی در ۳ ماه قبل، و نیز عمق بارش در ۲ ماه قبل و زمان حال، و رطوبت نسبی حداقل در ماه قبل و تعداد ساعت آفتابی در ماه قبل، به ترتیب کمترین تأثیر بر تبخیر از سطح مخزن را دارند.

مقایسه نتایج این تحقیق با تحقیقات دیگر، نظری طبری و همکاران (2010)، مقدم نیا و همکاران (2009)، شادمانی و همکاران (1390) و بیزدانی و همکاران (1389) در زمینه برآورد میزان تبخیر از سطح آب‌های آزاد با استفاده از مدل‌های شبکه عصبی مصنوعی، مؤید این مطلب است که شبکه‌های عصبی مصنوعی، دقت و توانایی بالایی جهت برآورد و پیش‌بینی میزان تبخیر از سطح آب‌های آزاد دارند. با محاسبه نسبتاً دقیق تبخیر از سطح آزاد، توسط شبکه عصبی می‌توان راهکارهای اساسی و مدیریتی مؤثری در جهت کاهش اثرات بحران ناشی از خشک سالی و نیز حفاظت از منابع آب اعمال نمود (بیزدانی و همکاران، ۱۳۸۹). مهمترین زمینه‌های تحقیقاتی پیشنهادی در ادامه تحقیق حاضر عبارتند از: استفاده از مدل‌های مختلف شبکه عصبی مصنوعی GRNN، PNN و RNN و غیره در برآورد و پیش‌بینی تبخیر از مخازن سدها و نیز مقایسه دقت آنها با یکدیگر و به کارگیری شبکه عصبی مصنوعی موجک (Neuro_Wavelate) در پیش‌بینی تبخیر از مخزن سد و مقایسه دقت آن با مدل‌های دیگر، همچنانی استفاده از روش‌های

الگوریتم SOM-GAGRNN وتابع گاما در تعیین بهترین و مؤثرترین ترکیب متغیرهای ورودی مدل‌های شبکه عصبی مصنوعی از نظر نوع، تعداد و تأخیر زمانی همچنین مقایسه مدل‌های مفهومی و فازی در برآورد تبخیر از مخزن سد و پیش‌بینی تبخیر روزانه از مخزن سد و غیره.

منابع

- شادمانی، م. و معروفی، ص. (1390). مقایسه چند روش برآورد تبخیر روزانه از تشت- مطالعه موردی منطقه کرمان. مجله علوم آب و خاک- علوم و فنون کشاورزی و منابع طبیعی، سال پانزدهم، شماره 55.
- طبری، ح.، معروفی، ص.، زارع ابیانه، ح.، امیری چایجان، ر.، شریفی، م. و آخوندعلی، م. (1388). مقایسه روش رگرسیون غیرخطی با روش‌های هوش محاسباتی در برآورد توزیع مکانی آب معادل برف در سراب کارون. مجله علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، سال سیزدهم، شماره 50.
- منهاج، م.ب. (1377). هوش محاسباتی، مبانی شبکه عصبی. جلد اول، انتشارات علانه طباطبایی، تهران.
- یزدانی، و.، قهرمان، ب. و داوری، ک. (1389). تعیین بهترین روش تجربی برآورد تبخیر از سطح آزاد در اراضی شالیزاری آمل بر پایه آنالیز حساسیت و مقایسه آن با نتایج شبکه عصبی مصنوعی. مجله پژوهش آب ایران، سال چهارم، شماره 7.

- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, (2000). Artificial Neural Networks in Hydrology: Preliminary Concepts. Part I, J. Hydrologic Engineering., ASCE, 5(2), pp. 115-123.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, (2000). Artificial Neural Networks in Hydrology: Hydrologic Applications. Part II, J. Hydrologic Engineering., ASCE, 5(2), pp. 123-137.
- Bruton, J.M., McClendonand, R.W and Hoogenboom, G. (2000). Estimating daily pan evaporation with artificial neural network .Trans.ASAE43(2), pp. 492-496.
- Chen, Y.h. and Chang, F.J. (2009). Evolutionary Artificial Neural Networks for Hydrological Systems Forecasting, Journal of Hydrology doi: 10.1016/j.jhydrol.2009.01.009
- Kisi, O. (2006). Daily pan evaporation modeling using a neuro-fuzzy computing technique. J. Hydrol, 329(3-4), pp. 636-646.
- Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S. and Han, D. (2009). Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. Advances in Water Resources, 32, pp. 88–97.
- Rahimi Koob, A. (2008). Comparative study of Hargreaves's and artificial neural. Irrigation Scientific. 26, PP. 253-259.

- **Riad, S., Mania, J and Najjar, L. (2004).** Rainfall-runoff model using an artificial neural network approach. *Math. Comput. Model.* 40, pp. 839-846.
- **Terz, O and Keskn, M.E (2005).** Modeling of daily pan evaporation. *J. Appl. Sci.* 5, PP.368-372.