

"مقاله کوتاه پژوهشی"**بررسی عملکرد شبکه عصبی مصنوعی و سری‌های زمانی در مدل‌سازی شاخص خشکسالی بارش استاندارد (مطالعه موردی: ایستگاه‌های منتخب استان خوزستان)**

محمد رضا گلابی، دانشجوی کارشناسی ارشد گروه مهندسی منابع آب، دانشگاه شهید چمران اهواز
hamid_golabi65@yahoo.com

فریدون رادمنش، استاد یار دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز

علی محمد آخوند علی، استاد دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز

دریافت: ۱۳۹۱/۰۳/۱۱

پذیرش: ۱۳۹۲/۰۳/۲۰

چکیده

خشکسالی پدیده‌ای طبیعی است که می‌تواند در هر جایی رخ دهد و خسارات قابل توجهی به بشر و سازه‌های طبیعی وارد آورد. در این تحقیق به منظور پیش‌بینی شاخص خشکسالی بارش استاندارد، از دو نوع شبکه‌های عصبی مصنوعی، پرسپترون چند لایه و تابع پایه‌ی شعاعی و مدل‌های سری‌زمانی استفاده شد. به این منظور، در ابتدا مقادیر شاخص بارش استاندارد در دوره‌های سه، شش، نه و دوازده ماهه‌ی ایستگاه‌های منتخب استان خوزستان محاسبه گردید. سپس با استفاده از مدل‌های شبکه عصبی مصنوعی و سری‌های زمانی اقدام به پیش‌بینی مقادیر شاخص بارش استاندارد گردید. نتایج این تحقیق نشان داد که مدل‌های سری‌زمانی در تمام دوره‌های زمانی مورد مطالعه عملکرد بهتری در پیش‌بینی مقادیر شاخص بارش استاندارد نسبت به شبکه‌های عصبی مصنوعی دارند و شبکه عصبی مصنوعی پرسپترون چندلایه نیز نسبت به شبکه عصبی مصنوعی تابع پایه‌ی شعاعی در تمام دوره‌ها مقادیر شاخص بارش استاندارد را بهتر پیش‌بینی می‌کند.

واژه‌های کلیدی: خشکسالی، پیش‌بینی، شبکه‌های عصبی مصنوعی، سری‌های زمانی، شاخص بارش استاندارد، خوزستان.

مقدمه

های بلندمدت برای اهداف هیدرولوژی مورد استفاده قرار گیرد. پیش‌بینی خشکسالی در برنامه‌ریزی‌های کشاورزی و منابع آب با اهمیت بوده و در یک نظام هدفمند و جامع مدیریتی منجر به برنامه‌ریزی در ذخیره آبی سدها، پیش-بینی میزان واردات مواد غذایی، تغییر الگوی کشت، اطلاع رسانی برای پیش‌آگاهی مبارزه با خشکسالی و غیره خواهد شد. از شبکه عصبی و سری‌های زمانی در پیش‌بینی خشکسالی استان خراسان رضوی استفاده نمود و مدل سری‌های زمانی را جهت پیش‌بینی خشکسالی پیشنهاد کردند [۳]. با استفاده از شبکه عصبی مصنوعی، به پیش-بینی خشکسالی‌های شهر خاش در سه بازه زمانی ماهانه، سه ماهه و دوازده‌ماهه پرداختند [۷]. مقایسه نتایج با مدل رگرسیونی نشان دهنده برتری شبکه عصبی در مقایسه با مدل رگرسیونی بود.

خشکی و خشکسالی یکی از ویژگی‌های اجتناب‌ناپذیر و زیان‌بار اقلیمی کشور ایران به شمار می‌رود، بنابراین، پژوهش و مطالعه در این زمینه بسیار ضروری است. خشکسالی غالباً یک پدیده خزننده توصیف می‌شود و توصیف زمانی و مکانی آن بسیار مشکل است. یکی از قدم‌های مهم و اساسی در مطالعات خشکسالی و ترسالی برای بیان کمی خشکسالی و همچنین ارزیابی آن در مقیاس‌های مختلف زمانی و مکانی در هر منطقه، تعیین شاخص‌هایی است که می‌توان براساس آن‌ها میزان شدت و تداوم خشکسالی و ترسالی را ارزیابی کرد. شاخص مورد استفاده در این تحقیق شاخص بارش استاندارد (SPI) است که یکی از جامع‌ترین شاخص مطالعه خشکسالی و ترسالی به شمار می‌آید. تغییرپذیری SPI باعث می‌شود که در مقیاس‌های کوتاه‌مدت برای اهداف کشاورزی و در مقیاس

(۱)

$$u_t = \sum_{i=1}^p \phi_i u_{t-i} + \varepsilon_t - \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

در این رابطه: u سری حاصل از تفاضل‌گیری ld ام سری اصلی و پارامترهای مدل p و q مرتبه‌های هر یک از جزءهای میانگین متحرک و اتورگرسیو است. فرض می‌شود که متغیر تصادفی در زمان t دارای توزیع نرمال، میانگین صفر و واریانس یک است. اگر $q=0$ سپس رابطه (۱) یک مدل AR از مرتبه p می‌شود و وقتی $p=0$ است، رابطه (۱) یک مدل MA با مرتبه q می‌شود [۳].

شبکه عصبی مصنوعی

شبکه‌های چند لایه پیشخور یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی هستند که سیگنال ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شود. این نوع شبکه معمولاً پرسپترون چند لایه (MLP) نامیده می‌شود. شبکه‌های RBF نیازمند نرون‌های بیشتری نسبت به شبکه‌های استاندارد پیشخور می‌باشد ولی اغلب این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های پیشخور، آموزش داد [۶].

پس از بازسازی و تعیین درستی آمار هر یک از ایستگاه‌ها، اقدام به محاسبه مقادیر SPI در مقیاس‌های زمانی سه، شش، نه و دوازده ماهه گردید. سپس به پیش‌بینی مقادیر آن‌ها با استفاده از مدل‌های سری‌های زمانی پرداخته شد. برای توسعه مدل‌های سری‌های زمانی بر اساس الگوریتم پیشنهادی [۱] سه مرحله تشخیص، برآورد و تعیین صحت مدل وجود دارد.

برای استفاده از شبکه عصبی ابتدا داده‌ها بطور تصادفی به سه دسته تقسیم شدند: مجموعه آموزش^۱ با ۷۵٪ کل داده‌ها، مجموعه اعتبارسنجی^۲ با ۱۰٪ کل داده‌ها و مجموعه آزمون^۳ با ۱۵٪ باقیمانده داده‌ها. بعد از پردازش، بهترین ساختار شبکه عصبی با سعی و خطا و با توجه به مقایسه معیارهای عددی عملکرد، انتخاب شد. بردار ورودی ترکیب متفاوتی از مقادیر SPI پیشین بود که

[۴] به مدل‌سازی بارش فصلی با استفاده از شبکه عصبی مصنوعی و مدل ARIMA^۱ در استان خوزستان پرداخت. مشخص گردید که شبکه عصبی مصنوعی در مقایسه با مدل ARIMA نتایج بهتری می‌دهد. در تحقیقی به پیش‌بینی خشکسالی هواشناسی بر اساس شاخص SPI توسط مدل‌های SARIMA و ARIMA در حوزه‌ای در کشور ترکیه پرداخت [۲].

هدف از انجام این تحقیق، مدل‌سازی و پیش‌بینی شاخص خشکسالی SPI با استفاده از شبکه عصبی-مصنوعی پرسپترون چندلایه (MLP) و شبکه عصبی مصنوعی با تابع پایه شعاعی (RBF) و مدل سری‌های زمانی (ARIMA) و مقایسه نتایج این مدل‌ها با یکدیگر است.

مواد و روش‌ها

در این مطالعه از داده‌های بارش ماهانه سه ایستگاه هواشناسی استان خوزستان شامل اهواز، آبادان و دزفول که دارای آمار بلندمدت بارندگی هستند، استفاده شد. دوره زمانی مورد مطالعه در این تحقیق یک دوره ۴۸ ساله است از ۱۳۴۰ تا ۱۳۸۷ قرار دارد.

شاخص SPI

شاخص بارش استاندارد (SPI) توسط [۵] جهت تعیین دوره‌های خشکسالی و ارزیابی شدت آن تدوین شد. برای تعیین شاخص SPI ابتدا یک توزیع گاما با داده‌های بارش هر ایستگاه برازش داده. سپس تبدیل احتمال تجمعی از توزیع گامای به‌دست آمده، به توزیع نرمال استاندارد تجمعی با میانگین صفر و واریانس یک صورت می‌گیرد.

مدل سری‌های زمانی

مدل سری‌های زمانی در مورد داده‌هایی که همبستگی سریالی دارند مورد استفاده قرار می‌گیرد. مدل‌های-ARIMA نوع ویژه‌ای از مدل‌های ARMA هستند که در سری‌هایی که نایستا هستند و با تفاضل‌گیری ایستا می‌گردند مورد استفاده قرار می‌گیرند. یک مدل ARIMA را می‌توان به صورت رابطه (۱) نشان داد.

1-Train
2- Cross Validation
3-Test

1-Auto Regressive Integrated Moving Average

عبارت دیگر، هر تغییر غیرقابل انتظاری در مقدار بارش یک ماه تاثیر معنی داری روی مقادیر SPI می گذارد. سپس اقدام به توسعه‌ی مدل‌های گوناگون سری‌های زمانی برای هر یک از ایستگاه‌ها گردید. پس از انتخاب مدل مناسب با استفاده از آن، اقدام به پیش‌بینی مقادیر SPI در هر یک از ایستگاه‌ها گردید (جدول ۲).

جدول ۲- عملکرد مدل‌های سری‌های زمانی در ایستگاه‌های مورد

مطالعه					
ایستگاه	مدل	مقیاس زمانی	R	RMSE	MAE
اهواز	$(0,1,1)(0,0,1)_3$	۳	۰/۹۰۲۲	۳۱/۳۱	۰/۵۴۲۳
	$(1,0,1)(0,0,1)_6$	۹	۰/۹۶۱۲	۴۶/۱۳	۰/۵۱۴۱
	$(0,1,1)(0,0,1)_{12}$	۱۲	۰/۹۱۱۴	۱۸/۱۶	۰/۲۸۲۶
دزفول	$(1,1,0)(1,0,1)_6$	۶	۰/۸۳۴۲	۳۹/۳۱	۰/۵۲۱۷
	$(1,1,0)(1,1,1)_{12}$	۱۲	۰/۹۳۱۸	۲۷/۱۹	۰/۳۵۱۳
	$(0,0,0)(0,0,0)_3$	۳	۰/۸۶۳۱	۶۱/۱۵	۰/۸۳۲۷
آبادان	$(1,0,0)(0,0,1)_6$	۶	۰/۸۵۱۹	۵۲/۳۱	۰/۶۹۱۸
	$(1,1,0)(0,0,1)_9$	۹	۰/۹۳۱۴	۳۳/۱۷	۰/۴۹۷۳
	$(1,1,1)(0,0,1)_{12}$	۱۲	۰/۹۲۱۶	۱۷/۱۶	۰/۲۳۱۲

در گام بعدی، مدل‌های گوناگون شبکه عصبی پرسپترون چندلایه (MLP) و شبکه عصبی با تابع پایه‌ی شعاعی (RBF) برای هر یک از ایستگاه‌های مورد مطالعه ساخته شد. برای شبکه عصبی مصنوعی، یک شبکه با یک لایه مخفی که تعداد نرون‌های لایه مخفی از ۱۶-۱ امتحان شد، مورد استفاده قرار گرفت. تعداد بهینه نرون‌های لایه مخفی با سعی و خطا مشخص گردید. نتایج مربوط به تمام مدل‌های شبکه عصبی مصنوعی در جدول ۳ و ۴ ارائه شده است.

جدول ۳- عملکرد مدل‌های گوناگون شبکه عصبی MLP در ایستگاه-

های مورد مطالعه					
ایستگاه	مقیاس زمانی	شماره بردار ورودی	RMSE	MAE	R
اهواز	۳	۲	۵۵/۱۷	۰/۳۸۴۰	۰/۸۷۵۱
	۹	۲	۵۴/۷۵	۰/۴۷۱۲	۰/۹۳۱۱
	۱۲	۲	۳۳/۱۹	۰/۲۰۱۷	۰/۸۸۶۳
دزفول	۶	۱	۵۲/۱۸	۰/۴۱۱۳	۰/۷۱۲۵
	۱۲	۲	۳۷/۱۳	۰/۲۸۱۲	۰/۸۹۱۱
	۳	۲	۸۵/۱۰	۰/۶۳۱۹	۰/۸۲۵۳
آبادان	۶	۱	۷۲/۱۳	۰/۵۵۱۸	۰/۸۳۱۰
	۹	۳	۵۲/۹۲	۰/۳۴۱۲	۰/۹۱۱۷
	۱۲	۲	۲۹/۶۵	۰/۱۸۶۳	۰/۸۷۱۶

بهترین بردار ورودی با سعی و خطا مشخص گردید. مجموعه‌ی بردارهای ورودی در جدول (۱) نشان داده شده است.

جدول ۱- بردارهای ورودی مورد استفاده در شبکه‌های عصبی مصنوعی

نام مدل	ورودی
۱	S_{t-1}
۲	S_{t-1}, S_{t-2}
۳	$S_{t-1}, S_{t-2}, S_{t-3}$
۴	$S_{t-1}, S_{t-2}, S_{t-3}, S_{t-4}$
۵	$S_{t-1}, S_{t-2}, S_{t-3}, S_{t-4}, S_{t-5}$

بر اساس بررسی‌ها و دامنه‌ی داده‌های ورودی و خروجی در این تحقیق از تابع تانژانت هیپربولیک به عنوان تابع تحریک نرون‌های لایه مخفی و از تابع خطی، به عنوان تابع تحریک نرون‌های لایه خروجی استفاده شد. از میان الگوریتم‌های مختلف آموزش، به دلیل همگرایی سریع‌تر در آموزش، از الگوریتم لونیگ-مارکواریت^۱ استفاده گردید. تعداد تکرارهای شبکه برابر تعداد داده‌های یادگیری بوده و در این بررسی برای هر شبکه ۱۰۰ دور در نظر گرفته شد. معیارهای عددی که در تعیین کارایی مدل‌ها و در نتیجه انتخاب بهترین مدل به کار می‌رود شامل ریشه میانگین مربعات خطا^۲ (RMSE) و میانگین مطلق خطا (MAE)^۳ و ضریب همبستگی خطی (R)^۴ هستند.

بحث و نتایج

در ابتدا اقدام به محاسبه شاخص SPI در مقیاس‌های زمانی ۳، ۶، ۹ و ۱۲ ماهه برای هر یک از ایستگاه‌های مورد مطالعه شد. در تمام ایستگاه‌های مورد مطالعه با افزایش مقیاس زمانی از شدت دوره خشک و تر کاسته شده است. اما دوام دوره‌های خشک و تر افزایش یافته است. علت آن این است که در محاسبه شاخص SPI از مقدار بارش تجمعی ماه‌های قبل استفاده می‌شود و به همین خاطر است که در مقیاس‌های زمانی کوتاه‌مدت مقدار بارش کل کمتر از مقیاس زمانی بلندمدت است. به

4- Levenberg - Marquardt
5- Root Mean Squared Error
6-Mean Absolute Error
7-Correlation Coefficient

بینی شده با استفاده از مدل ARIMA و شبکه عصبی MLP در مقیاس زمانی ۹ ماهه برای ایستگاه آبادان را نشان می‌دهد.


نتیجه‌گیری

بر اساس نتایج، SPI نه ماهه نسبت به دوره‌های زمانی دیگر این شاخص حداکثر ضریب همبستگی را در هر سه روش دارا است. در روش سری‌های زمانی عدم قطعیت موجود در پیش‌بینی مقادیر SPI ناشی از احتمال در نظر گرفته می‌شود، در صورتی که در روش‌های هوش مصنوعی این عدم قطعیت ناشی از عدم قطعیت در عامل‌ها و امکان و غیرخطی بودن فرآیند مورد بررسی در نظر گرفته می‌شود. در خشکسالی هواشناسی مقادیر SPI به گونه‌ای مستقیم در ارتباط با مقادیر بارش بوده و مقادیر بارش نیز یک فرآیند احتمالی می‌باشد تا یک فرآیند غیرخطی. همچنین نتایج بیان‌گر این امر است که در هر سه مدل مقادیر SPI برای مقیاس‌های زمانی ۹ و ۱۲ ماهه بهتر از مقادیر SPI برای دوره‌های ۳ و ۶ ماهه پیش‌بینی گردید. مشابه این نتایج را [۳] به‌دست آوردند. آن‌ها از شبکه عصبی و سری‌های زمانی برای پیش‌بینی مقادیر SPI در استان خراسان رضوی استفاده کرده و مدل سری‌های زمانی را جهت پیش‌بینی خشکسالی پیشنهاد نمودند. در نهایت با توجه به نتایج به‌دست آمده از این پژوهش، استفاده از مدل‌های سری‌های زمانی، جهت پیش‌بینی خشکسالی‌های آتی در این استان پیشنهاد می‌گردد.


جدول ۴- عملکرد مدل‌های گوناگون شبکه عصبی RBF در ایستگاه های مورد مطالعه

ایستگاه	مقیاس زمانی	شماره بردار ورودی	RMSE	MAE	R
اهواز	۳	۲	۵۸/۱۶	۰/۴۳۱۹	۰/۸۵۱۲
	۹	۱	۵۶/۱۲	۰/۴۸۱۶	۰/۸۶۱۰
	۱۲	۲	۳۴/۱۷	۰/۲۱۱۳	۰/۸۳۱۲
دزفول	۶	۱	۵۳/۱۵	۰/۴۲۱۰	۰/۷۴۲۱
	۱۲	۲	۴۱/۱۳	۰/۳۱۱۲	۰/۸۱۲۴
	۳	۱	۸۶/۱۶	۰/۶۴۱۵	۰/۷۹۱۵
آبادان	۶	۲	۷۳/۲۱	۰/۵۶۱۷	۰/۸۱۲۵
	۹	۲	۵۴/۱۲	۰/۳۵۱۲	۰/۸۶۳۴
	۱۲	۲	۳۲/۱۸	۰/۱۹۱۵	۰/۸۱۱۲

با توجه به جداول ۳ و ۴، مشاهده شد که در شبکه‌ی عصبی MLP، به عنوان مثال برای ایستگاه اهواز بهترین مدل برازش‌یافته در مقیاس ۳، ۹ و ۱۲ ماهه، مدلی است که بردار ورودی مورد استفاده در آن (جدول ۳)، بردار شماره ۲ است. با توجه به جداول ۲ و ۳ و ۴ و مقایسه معیارهای عددی عملکرد مدل‌های برازش‌یافته ملاحظه می‌شود که عملکرد مدل‌های سری‌زمانی در مقطع‌های زمانی مورد مطالعه بهتر از مدل‌های شبکه عصبی است. عملکرد مدل شبکه‌ی عصبی MLP نیز در برازش به داده‌های مورد مطالعه بهتر از شبکه‌ی عصبی RBF است. همچنین عملکرد مدل‌های شبکه عصبی و سری‌های زمانی در پیش‌بینی مقادیر SPI، ۹ و ۱۲ ماهه بهتر از ۳ و ۶ ماهه است. در بین سه ایستگاه مورد مطالعه مقادیر SPI در ایستگاه اهواز بهتر از ایستگاه‌های دیگر پیش‌بینی شده است. در شکل‌های ۱ و ۲ مقادیر SPI مشاهداتی و پیش-



شکل ۱- مقادیر پیش‌بینی شده و مشاهداتی SPI دوره زمانی ۹ ماهه با استفاده از مدل ARIMA برای ایستگاه آبادان.



شکل ۲- مقادیر پیش‌بینی شده و مشاهداتی SPI دوره ۹ ماهه با استفاده از مدل شبکه عصبی MLP برای ایستگاه آبادان.

References

- [1].Box, G. E. P., & Jenkins, G. M. (1976). Time series analysis forecasting and control, Holden-Day, San Francisco, 575p.
- [2].Durdu, F. (2010). Application of linear stochastic models for drought forecasting in the Buyuk Menderes river basin, western Turkey. *Stoch Environ Res Risk Assess*, 24, 366-383.
- [3].Fathabadi, A., Gholami, H., Salajeghe, A., Azanivand, H., & Khosravi, H. (2009). Drought forecasting using neural network and stochastic models. *Advances in Natural and Applied Sciences*, 3(2), 137-146.
- [4].Golabi, M. R., Radmanesh, F., Akhondali, A. M., & Kashefipoor, M. (2013). Simulation of Seasonal precipitation using ANN and ARIMA Models: A case study of (Iran) Khozestan. *Elixir Computer Science and Engineering*, 55, 13039-13046.
- [5].McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales, In: 8th Conference on Applied Climatology. *American Meteorological Society, Boston, MA*, 179-184.
- [6].Menhaj, M. B. (2005). Foundations of Neural Networks, Amir Kabir University of Technology, Tehran.
- [7].Negareh, H., Armesh, M. (2011). Drought Forecasting in Khash City by Using Neural Network. *Arid Regions Geographic Studies*, 2(6), 33-50.

"Short Research Paper"

An Investigation of Artificial Neural Network and Time Series Performance in the Index Standard Precipitation Drought Modeling (Case Study: Selected Stations of Khuzestan Province)

- 1- M. R. Golabi, MSc Student of Water Resource Engineerring, Faculty of Water Engineering.
hamid_golabi65@yahoo.com
- 2- F. Radmanesh, Assistant Professor, Faculty of Water Engineering, Shahid Chamran University, Ahvaz, Iran.
- 3- A. M. Akhondali, Professor Faculty of Water Engineering, Shahid Chamran University, Ahvaz, Iran.

Accepted: 31 May 2012

Received: 10 Jun 2013

Abstract

Drought is a natural phenomenon which may happen everywhere and cause remarkable damages to human and natural structures. In this study, two types of artificial Neural networks; multilayer perceptron, radial basis function, as well as time series models have been used to predict the standardized pereipitation drought index. To this end, the amount of standard precipitation index was calculated firstly in the selected stations of Khuzestan province in three, six, nine, and twelve months periods. Finally, the amount of standard precipitation index was predicted using the artificial Neural network and time series models. The results showed that the time series models have better performance in predicting the amount of standard precipitation index in all of the mentioned time periods in comparison to the artificial Neural network. In addition, the results indicated that the multilayer perceptron could better predict the amount of standard precipitation index in all periods comparing to the radial basis function.

Keywords: Drought; Prediction; Artificial Neural Network; Time series; Standard precipitation index; Khuzestan