



ارزیابی توانایی مدل‌های هوشمند در پیش‌بینی بارندگی ماهانه به کمک الگوهای پیوند از دور (مطالعه موردی استان خراسان رضوی)

فرزانه نظریه^{۱*} - حسین انصاری^۲

تاریخ دریافت: ۱۳۹۲/۰۶/۱۱

تاریخ پذیرش: ۱۳۹۳/۱۲/۲۰

چکیده

الگوهای پیوند دور از جمله عوامل موثر بر میزان بارش می‌باشند، در این تحقیق توانایی مدل‌های هوشمند در پیش‌بینی بارندگی ماهانه به کمک داده‌های پیوند از دور در هشت ایستگاه سینوپتیک استان خراسان رضوی برای سال‌های ۱۹۹۱ تا ۲۰۱۰ مورد بررسی قرار گرفت. مدل‌های هوشمند مورد بررسی عبارتند از مدل شبکه عصبی مصنوعی، مدل استنتاج فازی و مدل نروفازی. معیارهای آماری برای مقایسه نتایج مدل‌ها شامل ضریب همبستگی، میانگین خطای اریبی، میانگین مربعات خطا و معیارهای ترکیبی جاکووی دز و صباغ می‌باشد. پس از یافتن بهترین ساختار برای مدل‌های هوشمند و مقایسه آن‌ها، مشخص گردید مدل نروفازی بهترین نتایج را دارا می‌باشد. معیارهای آماری برای پیش‌بینی بارش به روش نروفازی به ترتیب در یک ماهه آینده برابر ۰/۸، ۰/۵۵، ۰/۴۳، ۰/۷، ۰/۹۱، برای دو ماهه آینده برابر ۰/۷۹، ۰/۳۲، ۰/۴۸، ۰/۵۶، ۰/۴ و برای سه ماهه آینده برابر ۰/۷۳، ۰/۳۷، ۰/۵۴، ۰/۴۷، ۰/۳۶ به دست آمد. نتایج مدل‌های هوشمند برای ایستگاهی که داده‌های آن در بخش آموزش بکار برده نشده بود حاکی از این است که مدل‌ها برای منطقه جغرافیایی آموزش دیده توانایی پیش‌بینی بارش را دارند. بررسی دقت مدل نروفازی در هر یک از کلاس‌های شاخص بارندگی استاندارد نشان داد که این مدل در برآورد مقادیر بارش در کلاس‌های تر سالی بسیار شدید و تر سالی شدید کم برآورد داشته است. در نهایت نتایج این تحقیق نشان داد که مدل‌های هوشمند مخصوصاً مدل نروفازی ابزار مناسبی برای پیش‌بینی بارندگی می‌باشند، اما از این مدل‌ها در کلاس‌های تر سالی بسیار شدید و تر سالی شدید با تامل بیشتری باید استفاده نمود.

واژه‌های کلیدی: پیش‌بینی بارندگی، الگوهای پیوند از دور، سیستم استنتاج فازی، شبکه عصبی مصنوعی، شبکه نروفازی

مقدمه

مدل‌های پیش‌بینی بارندگی استفاده شده است، از جمله این تحقیقات می‌توان به مواردی زیر اشاره نمود. دروسدوسکی و چامبر (۳) از الگوی دمای سطح اقیانوس آرام و اقیانوس هند برای پیش‌بینی بارندگی فصلی در استرالیا استفاده کردند. آلمیرا و ساین (۲) از دمای نقاط مختلف اقیانوس آرام و اقیانوس اتلانتیک به روش رگرسیون گام‌به‌گام برای پیش‌بینی بارش در شمال شرق آراژانتین استفاده کردند. کیم و همکاران (۹) در تحقیقی بارش‌های فصلی در حوضه رودخانه کلورادو را متاثر از تغییرات دما و فشار اقیانوس آرام دانسته‌اند. اسمیت و همکاران (۱۸) با استفاده از روش همبستگی استاندارد CCA^0 و به کمک دما و فشار سطح دریاها به بازسازی بارش سالانه در مقیاس جهانی پرداختند. شوکلا و همکاران (۱۷) به کمک دمای سطح دریا در مناطق مختلف نینو^۱ واقع در اقیانوس آرام بارش‌های موسمی برای کشور هند را پیش‌بینی نمودند. مکانیک و ایمیتز (۱۰) با

اطلاع از میزان بارندگی در برنامه‌ریزی و مدیریت منابع آب، خصوصاً در زمینه مدیریت خشکسالی از اهمیت بالایی برخوردار است. پیش‌بینی بارندگی برای ماه‌های آبی در مناطقی با اقلیم خشک و نیمه خشک، ابزار مناسبی برای کاهش خسارات ناشی از خشکسالی می‌باشد. بارندگی در سطح جهان را می‌توان تحت تأثیر تغییرات در سطح دریاها، خصوصاً تغییرات دمای سطح دریا SST^3 و فشار سطح دریا SLP^4 دانست. ارتباط بین نوسانات عناصر اقلیمی (مانند بارندگی) در یک مکان با تغییرات الگوهای SST و SLP در نقاط جغرافیایی دیگر را پیوند از دور می‌نامند.

در تحقیقات متعددی از الگوهای پیوند از دور به عنوان ورودی

۱ و ۲- دانشجوی دکتری آبیاری و زهکشی و دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه فردوسی مشهد

(*-نویسنده مسئول: (Email: ff.nazarieh@gmail.com)

3-Sea Surface Temperature

4- Sea Level Pressure

5- canonical correlation analysis

6- NINO

عوامل موثر بر این پدیده مانند SST و SLP به‌طور دقیق مشخص نمی‌باشد. بنابراین استفاده از مدل‌های هوشمند مانند سیستم‌های استنتاج فازی، مدل نروفازی و مدل شبکه عصبی می‌تواند راه حل مناسبی برای پیش‌بینی بارندگی باشند.

با توجه به تحقیقات انجام گرفته تأثیرپذیری بارندگی در منطقه مورد مطالعه از الگوهای پیوند از دور مورد تأیید قرار گرفته است. اما در این تحقیقات اغلب تأثیر پذیری بارندگی از الگوهای پیوند از دور در یک ماه مورد بررسی قرار گرفته است و یا تنها از یک مدل برای پیش‌بینی بارندگی استفاده شده است. بنابراین در این تحقیق در ابتدا با توجه به نتایج تحقیقات گذشته، شاخص‌های پیوند از دور موثر بر بارندگی در منطقه شناسایی و رابطه بین این شاخص‌ها با بارندگی‌های یک، دو و سه ماهه آینده تعیین گردید. سپس مدل‌های هوشمند (مدل‌های استنتاج فازی، نروفازی و شبکه عصبی) برای پیش‌بینی بارندگی تهیه گردید. در ساخت مدل‌های هوشمند علاوه بر بارندگی و شاخص‌های اقلیمی در ماه‌های قبل از اطلاعات جغرافیایی ایستگاه‌ها شامل عرض جغرافیایی و ارتفاع نیز برای تهیه مدل‌ها استفاده شده است تا بتوان از مدل‌ها برای نقاطی در محدوده مطالعاتی که ایستگاه هواشناسی در آن موجود نیست استفاده نمود. در نهایت با مقایسه توانایی مدل‌های هوشمند تواناترین مدل در پیش‌بینی بارندگی ارائه گردید.

ناحیه مورد مطالعه

ناحیه مورد مطالعه در این تحقیق منطقه خراسان رضوی در شمال شرق کشور می‌باشد. به منظور ارائه مدل پیش‌بینی بارندگی در این منطقه از اطلاعات بارش ماهانه هفت ایستگاه سینوتیک مشهد، گل‌مکان، نیشابور، کاشمر سبزوار، تربت‌حیدریه و سرخس در سال‌های ۱۹۹۱ تا ۲۰۱۰ (۲۰ سال داده) استفاده گردید. این ایستگاه‌ها در محدوده عرض جغرافیایی ۱۲° ۳۵' تا ۴° ۳۷' درجه شمالی و طول جغرافیایی ۴۲° ۵۷' تا ۱۰° ۶۱' درجه غربی واقع شده‌اند، در جدول ۱ موقعیت مکانی هر یک از ایستگاه‌ها آورده شده است.

مواد و روش‌ها

در این تحقیق از سه تکنیک شبکه عصبی مصنوعی، سیستم استنتاج فازی و شبکه‌های نروفازی به منظور مدل‌های پیش‌بینی کننده بارندگی استفاده شده است. ورودی مدل‌ها شامل داده‌های پیوند از دور، عرض جغرافیایی و ارتفاع هر ایستگاه، و خروجی آن‌ها پیش‌بینی بارندگی برای یک، دو و سه ماهه آینده می‌باشد (ورودی و خروجی کلیه مدل‌ها یکسان می‌باشد).

استفاده دما و فشار سطح اقیانوس‌های آرام و هند، و به کمک تکنیک شبکه عصبی بارش‌های ویکتورین در کشور استرالیا را پیش‌بینی نمودند.

در کشور ایران نیز تحقیقات متعددی تأثیر الگوهای پیوند از دور بر بارندگی را مورد بررسی قرار داده‌اند. صداقت کردار و فتاحی موثرترین سیگنال‌ها بر میزان بارندگی در نه ناحیه کشور را مورد بررسی قرار دادند. نتایج این تحقیق نشان داد، در مناطق شمال شرقی ایران (مشهد و سبزوار)، NINO₁₂ و NINO₃ موثرترین سیگنال‌های اقلیمی می‌باشند (۱۶). در تحقیق انجام گرفته توسط ناظم السادات و همکاران (۱۱) از مدل خودرگرسیون با ورودی برونزا ARX به عنوان یک مدل خطی و از مدل شبکه عصبی بر مبنای توسعه مدل خودرگرسیون با ورودی برونزا NNARX به عنوان یک مدل غیرخطی برای پیش‌بینی بارندگی در ایستگاه شیراز و بهشهر در جنوب غرب ایران استفاده شده است. در ورودی این مدل‌ها علاوه بر بارش در گام‌های زمانی گذشته از داده‌های پیوند از دور دمای سطح دریای خلیج فارس PGSST، نوسانات اتلانتیک شمال NAO و شاخص نوسانات جنوبی SOI نیز بهره گرفته شده است. نتایج این تحقیق نشان داد که مدل ARX به‌طور عمومی و مدل NNARX به‌صورت خاص توانایی پیش‌بینی بارش فصلی در منطقه مورد مطالعه را دارند. رضایی و همکاران (۱۳) در پژوهشی میزان تأثیرپذیری بارش‌های فصلی نیمه غربی کشور را از دمای سطح دریای مدیترانه مورد بررسی قرار دادند. قاهری و همکاران (۴) تأثیر دما و فشار نقاط شاخصی از سطح دریا بر دما و بارش منطقه خراسان مورد بررسی قرار دادند، و از داده‌های مناطق تأثیرگذار به عنوان ورودی مدل پیش‌بینی کننده بارندگی استفاده نمودند. علیزاده و همکاران (۱) با استفاده از روش رگرسیون گام‌به‌گام به بررسی جامع سیگنال‌های ارتباط از دور موثر بر دما و بارش ایستگاه سینوتیک مشهد پرداختند. ورودی‌های مدل رگرسیون گام به گام شامل ۳۰ شاخص پیوند از دور مختلف با تاخیر زمانی ۲ تا ۱۲ ماهه بوده است. مدل‌های برتر ارائه شده در این تحقیق نشان دادند، که شاخص‌های NINO_{1,2} (با تاخیر زمانی ۲ و ۵ ماهه)، NINO₄ (با تاخیر زمانی ۲ و ۶ ماهه)، MEI (با تاخیر زمانی ۴ ماهه)، TNI (با تاخیر زمانی ۵ ماهه) و MANSOON (با تاخیر زمانی ۱۱ ماهه) از موثرترین سیگنال‌های اقلیمی بر میزان بارش ایستگاه سینوتیک مشهد می‌باشند. رضائیان و طبری (۱۴) با استفاده از شبکه عصبی MLP به پیش‌بینی مقادیر کمی شاخص خشکسالی SPI برای ماه آینده در پنج ایستگاه آبادان، انزلی، ایران-شهر، کرمانشاه و مشهد پرداختند. نتایج این تحقیق حاکی از آن بود که اضافه نمودن دو شاخص NAO و SOI به ورودی‌های شبکه عصبی باعث بهبود نتایج پیش‌بینی شاخص SPI می‌شود.

پیش‌بینی بارندگی به دلیل پیچیدگی‌ها و عدم قطعیتی که در این پدیده وجود دارد مشکل می‌باشد. و اغلب رابطه فیزیکی بین بارش و

جدول ۱- موقعیت مکانی ایستگاه‌های مورد استفاده

Table 1- The location of stations used

نام ایستگاه	عرض جغرافیایی (دقیقه درجه)	طول جغرافیایی (دقیقه درجه)	ارتفاع (متر)	
Station Name	Latitude	Longitude	Altitude	
مشهد	Mshhad	32' 36"	27' 59"	999.2
گلمکان	Golmakan	32' 36"	17' 59"	1176
نیشابور	Nyshaboor	32' 36"	48' 58"	1213
قوچان	Ghochan	32' 36"	30' 58"	1287
سبزوار	Sebzevar	32' 36"	42' 57"	977.6
ترت حیدریه	Torbat Heidarieh	32' 36"	13' 59"	1450.5
کاشمر	Kashmar	32' 36"	28' 58"	1109.7
سرخس	Saraks	32' 36"	10' 61"	235

سیستم استنتاج فازی

از زمانی که تئوری مجموعه‌های فازی، اولین بار در سال ۱۹۶۵ توسط پروفیسور لطفی عسگرزاده پایه گذاری شد، کارهای نسبتاً خوبی در مورد کاربرد سیستم‌های فازی در زمینه پیش‌بینی متغیرهای هواشناسی مانند بارندگی (۱۲)، تبخیر (۸) تابش (۵)، انجام گرفته است.

منطق فازی یک سیستم بر مبنای قوانین اگر آنگاه می‌باشد، در این سیستم بجای مقادیر قطعی مقادیر تقریبی در نظر گرفته می‌شوند. منطق فازی امکان استفاده از دانش زبانی در سیستم را ممکن می‌سازد. کلیه پارامترها در سیستم فازی دارای معنای فیزیکی می‌باشند، به‌طوری‌که ورودی‌های x_i مرکز ثقل بخش اگر، قوانین و جواب خروجی y مرکز ثقل بخش آنگاه، قوانین می‌باشند. اما در شبکه عصبی مصنوعی که بر پایه ساختار مغز انسان ساخته شده است چنین تعریفی برای متغیرهای ورودی و خروجی وجود ندارد. با توجه به تعرف کلاسیک سیستم، مدل منطق فازی را می‌توان یک مدل جعبه خاکستری و مدل شبکه عصبی را یک مدل جعبه سیاه دانست، یعنی در مدل فازی دانش نسبی قبلی در مورد ساختار مدل وجود دارد اما در مدل شبکه عصبی مصنوعی هیچگونه دانش قبلی در مورد ساختار مدل در دست نمی‌باشد. در برخی موارد که حداقل دانش برای ساخت مدل فازی موجود نیست می‌توان مانند شبکه عصبی از الگوریتم‌های تطبیقی برای ساخت مدل استفاده نمود.

سیستم استنتاج فازی را می‌توان به کمک دانش متخصصان و یا به کمک داده‌های موجود طراحی نمود. یکی از روش‌های طراحی سیستم‌های فازی به کمک داده‌های موجود، استفاده از رویکرد خوشه‌بندی^۲ می‌باشد. در این تحقیق از رویکرد خوشه‌بندی کاهشی به منظور تعیین تعداد قوانین و توابع عضویت استفاده گردید، سپس به

برای واسنجی مدل‌ها از ۸۰ درصد داده‌های مربوط به شش ایستگاه مشهد، گلمکان، قوچان، سبزوار، ترت حیدریه، کاشمر و سرخس به‌طور تصادفی استفاده شده است. صحت‌سنجی مدل‌ها در دو قسمت انجام گرفته است. قسمت اول صحت‌سنجی مربوط به ۲۰ درصد داده‌های باقی مانده از شش ایستگاه مذکور و قسمت دوم مربوط به داده‌های ایستگاه نیشابور می‌باشد ایستگاه نیشابور از نظر طول جغرافیایی و ارتفاع بین شش ایستگاه دیگر واقع شده است. این بخش از صحت‌سنجی به منظور بررسی توانایی مدل در پیش‌بینی بارش در نقاطی غیر از ایستگاه‌های بخش واسنجی انجام گرفته است. برای مشخص نمودن الگوهای پیوند از دور که بر بارش منطقه تأثیر گذار هستند، مروری در تحقیقات گذشته انجام گرفت و نتایج دو تحقیق فلاح (۴) و علیزاده (۱) مبنای مطالعه حاضر قرار گرفت. با محاسبه ضریب همبستگی پیرسون بین بارش منطقه مورد مطالعه و داده‌هایی که از تحقیقات ذکر شده در دسترس بود، نهایتاً اطلاعات ۱۴ شاخص پیوند از دور (جدول ۲) به عنوان ورودی مدل‌های پیش‌بینی کننده بارش انتخاب گردید.

شبکه‌های عصبی

شبکه عصبی مصنوعی یک سامانه پردازشی داده‌ها است که از مغز انسان ایده گرفته است، یک شبکه عصبی شامل اجزای سازنده لایه‌ها و وزن‌ها می‌باشد. رفتار شبکه نیز وابسته به ارتباط بین اعضا است. نوع شبکه مورد استفاده در این تحقیق شبکه پرسپترون چندلایه (MLP) می‌باشد، که برای بهینه نمودن پارامترهای آن از الگوریتم لونیگ-مرکوریتم^۱ استفاده گردیده. تابع انتقال مورد استفاده برای نرون‌های لایه میانی شبکه، تابع تانژانت سیگموئید و برای نرون‌های لایه خروجی تابع خطی می‌باشد.

کمک روش کمترین مربعات خطا معادله مربوط به نتیجه هر قانون استخراج شده است.

جدول ۲- داده‌های پیوند از دور مورد استفاده در این تحقیق

Table 2-Teleconnection data used in this study

توضیحات Description	علامت اختصاری	شاخص مورد استفاده Used Index
فشار سطح دریا در ۴۳ درجه شمالی و ۱۵ درجه غربی	ΔP Ad	فشار دریای آدریاتیک ^۱
فشار سطح دریا در ۲۵ درجه شمالی و ۳۵ درجه غربی	ΔP So	فشار سطح شمال دریای سرخ ^۲
فشار سطح دریا در ۴۱ درجه شمالی و ۵ درجه غربی	ΔP Me	فشار سطح دریای مدیترانه ^۳
فشار سطح دریا در ۴۵ درجه شمالی و ۶۰ درجه غربی	ΔP Ar	فشار سطح دریاچه آرال ^۴
دما سطح دریا در ۶۰ درجه شمالی و ۵۶ درجه غربی	ΔT la	دمای سطح دریای لابرادور ^۵
دما سطح دریا در ۲۴ درجه شمالی و ۶۵ درجه غربی	ΔT Om	دمای سطح دریای عمان ^۶
دما سطح دریا در ۴۵ درجه شمالی و ۵۰ درجه غربی	ΔT Kh	دمای سطح دریای خزر ^۷
دما سطح دریا در ۲۷ درجه شمالی و ۵۰ درجه غربی	$T\Delta$ Fa	دمای سطح دریای خلیج فارس ^۸
فشار سطح دریا در منطقه ۳۰-۶۵ درجه شمالی و ۱۶۰ درجه شرقی تا ۱۴۰ درجه غربی	NP	الگوی آرام شمالی ^۹
درجه حرارت سطح دریا (حد فاصل صفر تا ۱۰ درجه جنوبی و ۱۶۰ درجه شرقی تا ۱۵۰ درجه غربی -	NINO _{1,2}	دمای سطح آب در ناحیه نینو ۱-۲ (تاخیر ۴ ماهه) ^{۱۰}
اختلاف درجه حرارت سطح دریا در ۵ درجه شمالی و ۵ درجه جنوبی تا حوالی ۱۵۰ و ۹۰ درجه غربی	NINO ₃	دمای سطح آب در ناحیه نینو ۳ (تاخیر ۴ ماهه) ^{۱۱}
آنومالی اصلی این الگو در عرض‌های میانی غرب و مرکز اقیانوس آرام شمالی و منطقه آنومالی ضعیف‌تر آن در منطقه شرقی سیبری، آلاسکا و منطقه بین کوه در آمریکای شمال است.	NP	شاخص نوسانات آرام شمالی ^{۱۲} (تاخیر ۶ ماهه)
تفاضل بین متوسط دمای سطح دریا در مناطق NINO ₄ و NINO ₁₂	TNI	شاخص انتقالی نینو ^{۱۳} (تاخیر ۷ ماهه)
شاخصی محاسبه شده از شش متغیر اصلی فشار سطح دریا، مؤلفه مداری، بادهای سطحی، مؤلفه نصف النهاری بادهای سطحی، دمای سطح دریا، دمای هوای سطحی و مجموع کسر ابرناکی آسمان در اقیانوس آرام	MEI	شاخص چندمعیاره انسو ^{۱۴} (تاخیر ۴ ماهه)

- 1- Adriatic South - Surface pressure
- 2- Northern Red Sea Level Pressure
- 3- Mediterranean Sea level pressure
- 4- Aral sea level pressure
- 5- Labrador Sea surface temperature
- 6- Amman Sea surface temperatures
- 7- Caspian Sea temperatures
- 8- Persian Gulf sea surface temperature
- 9- North Pacific pattern
- 10- Sea surface temperature in Nino1,2 the region
- 11- Sea surface temperature in Nino3 the region
- 12- North Pacific Oscillation Index
- 13- Trans-Nino Index
- 14- Multivariate ENSO Index

میانگین خطای اریبی^{۱۰} (MBE) و معیارهای ترکیبی، جاکوویدز^{۱۱} (t) و معیار بکار رفته توسط صباغ و همکاران (Rt) استفاده گردید. معیار جاکوویدز (۶) از ترکیب معیارهای میانگین خطای اریبی MBE و مجذور میانگین مربعات خطا RMSE ساخته شده است. و معیار ارائه شده توسط صباغ و همکاران (۱۵) ترکیبی از دو معیار ضریب همبستگی R و جاکوویدز t می باشد. فرمول کلی این معیارها به ترتیب در روابط ۱ تا ۵ نمایش داده شده است.

$$R = \frac{\sum_{i=1}^n (P_{sim} - \bar{P}_{sim})(P_{obs} - \bar{P}_{obs})}{\sqrt{\sum_{i=1}^n (P_{sim} - \bar{P}_{sim})^2 \sum_{i=1}^n (P_{obs} - \bar{P}_{obs})^2}} \quad (1)$$

$$NRMSE = \sqrt{\frac{\sum (P_{obs} - P_{sim})^2}{\sum P_{obs}^2}} \quad (2)$$

$$MBE = \frac{\sum (P_{obs} - P_{sim})}{n} \quad (3)$$

$$t = \sqrt{\frac{(n-1)MBE^2}{(RMSE^2 - MBE^2)}} \quad (4)$$

$$Rt = \frac{R^2}{t} \quad (5)$$

در معادلات فوق P_{sim} و P_{obs} میزان بارش واقعی و پیش‌بینی شده و n تعداد داده‌ها می‌باشند. هر چه معیارهای R و Rt بزرگتر و معیارهای MBE، t و NRMSE کوچک‌تر باشند نشان‌دهنده دقت بهتر مدل می‌باشد.

برای بررسی دقت مدل‌های پیش‌بینی بارش در عمق‌های مختلف، بارندگی با توجه شاخص بارش استاندارد به شش کلاس تر سالی بسیار شدید ($SPI > 2$)، تر سالی شدید ($1/99 < SPI < 1/5$)، ترسالی ($1 < SPI < 1/5$)، نرمال ($-0/99 < SPI < 0/99$)، خشکسالی ($-1/49 < SPI < -1$)، خشکسالی شدید ($SPI < -1/5$)، و ($-1/99 < SPI < -2$)، خشکسالی بسیار شدید ($SPI < -2$)، تقسیم‌بندی شده، و معیارهای ارزیابی کارایی مدل مجدداً برای هر کلاس شاخص بارش استاندارد محاسبه گردید.

تابع عضویت گوسی^۱ و تابع عضویت زنگوله‌ای^۲ به علت همواری همواری و پیچیدگی کم از پرکاربردترین توابع عضویت در منطق فازی می‌باشند، بنابراین برای تمامی ورودی‌ها و خروجی مدل از تابع گوسی استفاده شده است. در این تحقیق برای استنتاج فازی از روش سوگینو، برای استلزام^۳ از روش ضرب، برای تجمیع^۴ قوانین فازی روش مجموع و برای غیرفازی نمودن از روش متوسط وزن‌دار^۵ استفاده شده شده است.

شبکه‌های نرو فازی

شبکه‌های نرو فازی (ANFIS) ترکیبی از شبکه‌های عصبی مصنوعی و سیستم‌های فازی می‌باشد. شبکه‌های نرو فازی در واقع توسعه یافته مدل‌های فازی بر مبنای به کارگیری تکنیک‌های آموزش مختلف در شبکه عصبی است. این مدل از یک شبکه پیش‌خور برای بهینه کردن پارامترهای سیستم استنتاج فازی استفاده می‌کند، الگوریتم آموزش برای مدل نروفازی شامل روش انتشار برگشتی^۶ به تنهایی و یا همراه روش حداقل مربعات^۷ است. آموزش مدل به این صورت است که سیستم استنتاج فازی داده‌هایی که برای آموزش آماده شده است را تقلید می‌کند، بدین معنی که سیستم یاد می‌گیرد با ورودی داده شده خروجی‌هایی را که ما آموزش داده‌ایم، تولید کند. این کار با تصحیح پارامترهای تابع عضویت بر اساس معیار خطای انتخاب شده انجام می‌گیرد (۷).

اولین گام در شبیه‌سازی با مدل نروفازی مشخص نمودن سیستم استنتاج فازی می‌باشد، که در بخش قبل توضیحات کاملی در مورد خصوصیات سیستم استنتاج فازی مورد استفاده ارائه گردید. دومین گام آموزش بهینه نمودن ساختار فازی تولید شده می‌باشد در این تحقیق برای آموزش و بهینه سازی مدل از روش شبکه انتشار برگشتی به همراه روش حداقل مربعات استفاده شده است.

معیارهای ارزیابی کارایی مدل

در این تحقیق، برای ارزیابی دقت مدل‌ها و مقایسه مقادیر بارندگی پیش‌بینی شده با مقادیر واقعی از معیارهای ضریب همبستگی^۸ (R)، میانگین مربعات خطا^۹ (NRMSE)، معیارهای

- 1- Gauss Membership function
- 2- Bell Membership function
- 3- Implication
- 4- Aggregation
- 5- Wtaver
- 6- Back Propagation
- 7- Least Square
- 8- Correlation coefficient

- 9- Root Mean Square Error
- 10- Mean Bias Error
- 11- Jacovides

جدول ۳- همبستگی پیرسون بین بارندگی ایستگاه مشهد و شاخص‌های پیوند از دور

Tale 3-Correlation between rainfall of Mashhad stations and teleconnection indexes

شاخص Index	ΔP Ad	ΔP So	ΔP Me	ΔP Ar	ΔT La	ΔT Om	ΔT Kh	ΔT Fa	NP (6)*	NINO 1,2(4)	NINO 3(4)	TIN (7)	MEI (4)
۱ ماه 1 Month	0.57	0.41	-0.53	0.49	-0.64	-0.64	-0.65	-0.66	0.43	-0.45	-0.28	0.28	0.26
۲ ماه 2 Month	0.62	0.47	-0.35	0.53	-0.65	-0.61	-0.65	-0.65	0.44	-0.47	-0.2	0.25	0.21
۳ ماه 3 Month	0.54	0.44	-0.12	0.47	-0.46	-0.41	-0.47	-0.46	0.36	-0.34	-0.07	0.21	0.15

* - اعداد درون پرانتز نشان دهنده تعداد گام زمانی قبل می‌باشد

نتایج و بحث

کننده همین نکته می‌باشد. افزایش شاخص نوسانات آرام شمالی NP

نیز باعث افزایش بارش‌ها در منطقه خراسان رضوی می‌شود.

پس از تعیین نمودن شاخص‌های موثر بر بارندگی در منطقه مورد مطالعه، مدل‌های سیستم استنتاج فازی، نرو فازی و شبکه عصبی مصنوعی با ساختارهای مختلف تست شدند، تا ساختار بهینه برای هر مدل حاصل شود. مدل استنتاج فازی برای پیش‌بینی بارش در یک ماه، دو ماه و سه ماه آینده به ترتیب دارای ۱۵، ۱۳ و ۱۸ قانون می‌باشد. مدل نرو فازی از سیستم‌های استنتاج فازی ارائه شده در بخش فازی استفاده کرده و آن‌ها را به روش هیبرید (روش پس انتشار همراه با تخمین حداقل مربعات) بهینه‌سازی می‌کند. شبکه عصبی مورد استفاده پرسپترون چند لایه با یک لایه پنهان می‌باشد. مدل شبکه عصبی بهینه برای پیش‌بینی بارش در یک ماه، دو ماه و سه ماه آینده به ترتیب دارای ۱۸، ۱۶ و ۱۱ نرون در لایه پنهان می‌باشد. جدول‌های ۴، ۵ و ۶ به ترتیب آماره‌های مربوط به مدل‌های استنتاج فازی، نروفازی و شبکه عصبی مصنوعی را برای مراحل واسنجی و صحت‌سنجی نشان می‌دهند.

در این تحقیق ابتدا تأثیر پذیری بارش در استان خراسان رضوی از تغییرات سطح دریاها مورد بررسی قرار گرفت. جدول ۳ همبستگی پیرسون بین الگوهای پیوند از دور منتخب و بارندگی رخ داده در یک، دو و سه ماه آینده برای ایستگاه مشهد را نشان می‌دهد در سایر ایستگاه‌ها نیز همبستگی‌ها تقریباً به همین اندازه بوده است.

همان‌گونه که در جدول ۳ مشاهده می‌شود، بارش در منطقه مورد مطالعه با فشار در دریای آدریاتیک، شمال دریای سرخ و دریاچه آرال همبستگی مثبت و با فشار در دریای مدیترانه همبستگی منفی داشته است. یعنی با افزایش فشار در دریاهای آدریاتیک، شمال دریای سرخ، دریاچه آرال بارش در خراسان رضوی افزایش و با افزایش فشار در دریای مدیترانه، بارش‌ها کاهش می‌یابند. افزایش دما در دریاهای لابرادور، خزر، عمان و خلیج فارس باعث کاهش بارش‌ها می‌شود. در مورد پدیده انسو نیز که شاخص‌های $NINO_{1,2}$ و $NINO_3$ و TNI و MEI معرف آن می‌باشند، در فاز سرد بارش‌ها کاهش یافته و در فاز گرم افزایش می‌یابند، همبستگی مثبت بین MEI و بارش نیز تایید

جدول ۴- آماره‌های مربوط به مدل استنتاج فازی

Table 4- Statistics related to Fuzzy Inference Systems

مدل Model	بارش ماه آینده Precipitation of next month		R	MBE	NRMSE	t	RT
	ماه	month					
آموزش Trainig	۱ ماه	month 1	0.85	-0.3	0.41	0.84	0.87
	۲ ماه	month 2	0.82	-0.35	0.46	0.88	0.75
	۳ ماه	month 3	0.81	-0.48	0.46	1.17	0.56
صحت‌سنجی (۱) Verification (1)	۱ ماه	month 1	0.79	-0.65	0.48	0.81	0.76
	۲ ماه	month 2	0.79	-1.4	0.48	1.66	0.38
	۳ ماه	month 3	0.69	-1.5	0.57	1.53	0.31
صحت‌سنجی (۲) Verification(2)	۱ ماه	month 1	0.82	-0.71	0.45	0.83	0.81
	۲ ماه	month 2	0.81	-0.86	0.47	0.89	0.74
	۳ ماه	month 3	0.79	-1.3	0.55	1.33	0.47

جدول ۵- آماره‌های مربوط به مدل شبکه نروفازی

Table 5-Statistics related to Neuro-fuzzy

Model مدل	بارش ماه آینده		R	MBE	NRMSE	t	RT
	Precipitation of next month						
آموزش Trainig	۱ ماه	month 1	0.88	-0.25	0.37	0.79	0.99
	۲ ماه	month 2	0.84	-0.31	0.43	0.83	0.85
	۳ ماه	month 3	0.84	-0.52	0.43	1.19	0.59
صحت سنجی (۱) Verification (1)	۱ ماه	month 1	0.8	-0.55	0.43	0.7	0.91
	۲ ماه	month 2	0.79	-1.32	0.48	1.56	0.4
	۳ ماه	month 3	0.73	-1.37	0.54	1.47	0.36
صحت سنجی (۲) Verification(2)	۱ ماه	month 1	0.82	-0.66	0.44	0.83	0.81
	۲ ماه	month 2	0.82	-0.82	0.47	0.86	0.78
	۳ ماه	month 3	0.81	-1.25	0.46	1.37	0.48

جدول ۶- آماره‌های مربوط به مدل شبکه عصبی مصنوعی

Table 6-Statistics related to Artificial Neural Network


Model مدل	بارش ماه آینده		R	MBE	NRMSE	t	RT
	Precipitation of next month						
آموزش Trainig	۱ ماه	month 1	0.89	-0.37	0.39	1.18	0.67
	۲ ماه	month 2	0.86	-0.61	0.44	1.78	0.42
	۳ ماه	month 3	0.85	-0.94	0.46	2.46	0.29
صحت سنجی (۱) Verification (1)	۱ ماه	month 1	0.79	-1.14	0.51	1.44	0.43
	۲ ماه	month 2	0.79	-2	0.49	2.36	0.27
	۳ ماه	month 3	0.77	-2.5	0.56	2.89	0.2
صحت سنجی (۲) Verification(2)	۱ ماه	month 1	0.84	-1.03	0.45	1.25	0.56
	۲ ماه	month 2	0.83	-1.5	0.47	1.79	0.38
	۳ ماه	month 3	0.81	-2.2	0.51	2.47	0.27

خوبی برآورد ننموده است. دلیل این اختلاف در برآورد میزان بارش را می‌توان کم بودن داده‌ها در مقادیر حدی و خوب آموزش ندیدن شبکه برای مقادیر حدی، و همچنین تأثیر پذیری بارش‌های منطقه مورد مطالعه از الگوهای دیگر که در این تحقیق در نظر گرفته نشده‌اند، دانست. پس با توجه به معیارهای R، NRMSE و MBE نمی‌توان مدل برتر را تعیین نمود. بنابراین استفاده از معیارهای ترکیبی می‌تواند به تصمیم‌گیری در مورد بهترین مدل کمک نماید. با توجه به معیار t بهترین نتیجه مربوط به مدل نروفازی می‌باشد، معیار Rt که در برگزیده همبستگی و میزان خطا می‌باشد نیز این مطلب را تصدیق می‌کند. بنابراین می‌توان برای پیش‌بینی بارش در منطقه مورد نظر مدل نروفازی را مناسب‌تر از دو مدل دیگر معرفی نمود.

با توجه به مطلوب بودن نتایج صحت‌سنجی قسمت دوم (صحت‌سنجی در ایستگاه نیشابور) در مدل نروفازی (جدول ۵) می‌توان نتیجه‌گیری نمود که مدل ارائه شده توانایی پیش‌بینی بارش در نقاطی غیر از ایستگاه‌هایی که برای آن آموزش دیده را دارد. البته باید این نکته در مورد مناطقی که از لحاظ مختصات جغرافیایی و ارتفاعی بین ایستگاه‌های مورد بررسی در این تحقیق قرار گرفته‌اند صدق می‌کند.

همان‌گونه که در جداول ۴ تا ۶ مشاهده می‌شود، در کلیه مدل‌ها با افزایش فاصله زمانی بین ماهی که داده‌های ورودی مربوط به آن هستند و ماهی که در آن بارش پیش‌بینی می‌شود از دقت مدل‌ها کاسته می‌شود. دلیل این اتفاق به دقت ورودی مدل‌ها برمی‌گردد، چرا که در جدول ۳ همبستگی بین ورودی‌ها و بارش با افزایش گام زمانی کاهش پیدا می‌کند. بنابراین با استفاده از ورودی‌ها و مدل‌های ارائه شده در این تحقیق پیش‌بینی بارش برای بیش از سه ماهه آینده توصیه نمی‌شود. با توجه به کاهش معیارهای NRMSE، MBE و t و افزایش معیارهای R و t در مدل نروفازی نسبت به مدل استنتاج فازی (جدول ۴ و ۵) می‌توان نتیجه گرفت که استفاده از روش هیبرید (بهینه‌سازی در نروفازی) باعث بهبود نتایج سیستم استنتاج فازی شده است.

اگر در جداول مربوط به نتایج مدل‌ها (جدول ۴ تا ۶) تنها معیار ضریب همبستگی R را در نظر بگیریم شبکه عصبی مصنوعی نتایج بهتری نسبت به دو مدل دیگر داشته است. اما اگر معیار NRMSE، MBE را در نظر بگیریم شبکه عصبی نتیجه ضعیف‌تری، نسبت به مدل‌های دیگر داشته است. یعنی مدل شبکه عصبی علی‌رغم این‌که روند تغییرات بارش را به خوبی پیش‌بینی نموده، اما اندازه بارش را به



شکل ۱- بارش پیش‌بینی شده و واقعی در یک ماه آینده در ایستگاه مشهد
Figure 1- Predicted and actual rainfall in the coming months in Mashhad station

کمتر از حد نرمال، بیش‌برآورد داشته است. مقدار بیش‌برآوردها نسبت به کم‌برآوردها قابل توجه‌تر می‌باشند. البته با توجه به اینکه درصد داده‌هایی که به کلاس خیلی زیاد مرطوب و خیلی مرطوب تعلق دارند تنها ۱/۵ و ۴/۲۱ درصد از کل داده‌ها می‌باشد، مدل برای این دسته از داده‌ها خوب آموزش ندیده بنابراین در برآورد مقادیر ماکسیمم کم برآورد داشته است. جدول مربوط به MBE بارش پیش‌بینی شده برای دو و سه ماه آینده نیز به همین صورت بوده که برای اختصار از آورده آن‌ها خودداری شده است.

نتیجه‌گیری کلی

در این تحقیق با مقایسه توانایی مدل‌های هوشمند در پیش‌بینی بارندگی با استفاده از داده‌های پیوند از دور مشخص گردید رتبه بندی این مدل‌ها با توجه به معیار ارائه شده توسط صباغ و همکاران (Rt) به ترتیب مربوط به مدل شبکه نروفازی، مدل سیستم استنتاج فازی و مدل شبکه عصبی مصنوعی می‌باشد.

شکل ۱ سری زمانی بارش پیش‌بینی شده یک ماهه آینده توسط مدل نروفازی برای ایستگاه مشهد را نشان می‌دهد. همان‌گونه که مشاهده می‌شود مقادیر بارش پیش‌بینی شده در ماکسیمم‌ها کمتر از مقادیر واقعی می‌باشد، یعنی در ماکسیمم‌ها مدل کم برآورد دارد. کم برآورد مدل نروفازی در ماکسیمم‌ها در مورد سایر ایستگاه‌ها و ماه‌های دیگر پیش‌بینی بارش نیز صادق می‌باشد. اما از طرف دیگر اگر به معیار MBE در جدول ۵ توجه شود مثبت بودن این مقادیر نشان می‌دهد مدل بطور کلی بیش برآورد دارد. بنابراین برای بررسی دقت مدل نروفازی در پیش‌بینی بارش با عمق‌های مختلف، داده‌های بارندگی در کلیه ایستگاه‌ها با توجه به شاخص استاندارد شده بارش به شش کلاس تقسیم‌بندی شده، و آماره MBE مجدداً برای هر کلاس خشکسالی محاسبه گردید. جدول ۷ آماره MBE برای بارش پیش‌بینی شده یک ماه آینده در کلاس‌های مختلف SPI را نشان می‌دهد. در این جدول درصد داده‌هایی که به هر کلاس SPI تعلق دارد نیز نمایش داده شده است. همان‌گونه که در جدول ۷ مشاهده می‌شود، مدل در برآورد بارش‌های بیشتر از حد نرمال، کم‌برآورد و برای بارش‌های نرمال و

جدول ۷- آماره MBE مربوط به کلاس‌های مختلف شاخص SPI در ایستگاه مشهد
Table 7-Statistical criteria MBE Related to various SPI classes Mashhad station

خشکسالی بسیار شدید	خشکسالی شدید	خشکسالی	نرمال	ترسالی	ترسالی شدید	ترسالی بسیار شدید	
Extremely dry	Severely dry	Moderately dry	Near normal	Moderately Wet	Severely Wet	Extremely Wet	
0	1/52	3/42	78/22	11/11	4/21	1/52	درصد داده‌های متعلق به این کلاس
0	-3/65	-2/39	-2/96	6/66	16/74	32/02	Percent data belonging to this class
							MBE

می‌باشند کم برآورد دارد.

در کل می‌توان مدل‌های هوشمند مخصوصا مدل نروفازی را ابزار مناسبی برای پیش‌بینی بارندگی ارزیابی نمود. در نهایت پیشنهاد می‌شود با افزایش گستره مکانی ایستگاه‌های مورد بررسی و استفاده از شاخص‌های بیشتر هواشناسی در سطوح مختلف فشاری مدلی جامع‌تر برای منطقه وسیع‌تری از کشور ارائه گردد.

آماره (Rt) برای بارش‌های پیش‌بینی شده در یک ماهه، دوماهه و سه ماهه آینده در مدل نروفازی برابر ۰/۴۹۱، ۰/۰، ۰/۳۶ برای مدل استنتاج فازی برابر ۰/۷۶، ۰/۳۱/۳۸، ۰/۰ و برای مدل شبکه عصبی برابر ۰/۴۳، ۰/۲۷، ۰/۲ می‌باشند. مدل نروفازی به عنوان برترین مدل پیشنهادی، در برآورد مقادیر بارش بسیار زیاد که متعلق به کلاس ترسالی شدید، و ترسالی بسیار شدید، در شاخص بارندگی استاندارد

منابع

- 1- Alizadeh A., Erfanian M., Ansari H. 2011. Assessment of Teleconnection Patterns Affecting Rainfall and Temperature (Case Study: Mashhad Synoptic Station), Iranian Journal of Irrigation and drainage, 2(5): 176-185. (In Persian with English abstract).
- 2- Almeida G.J., Scian B. 2006. Some atmospheric and oceanic indices as predictors of seasonal rainfall in the Del Plata Basin of Argentina. Journal of Hydrology, 329: 350-359.
- 3- Drosowsky W., Chambers L.E. 2001. Near global scale sea surface temperature anomalies as predictors of Australian seasonal rainfall, Journal of climate, 14:1677-1687.
- 4- Fallah-Ghalhari G.A. 2014. Rainfall Prediction Using Teleconnection Patterns Through the Application of Artificial Neural Networks, Modern Climatology. Book 1. Dr Shih-Yu Wang (Ed.), 361-386.
- 5- Gomez V., Casanovas A. 2002. Fuzzy logic and meteorological variables: a case study of solar irradiance, Fuzzy Sets and Systems, 126:121-128.
- 6- Jacovides C.P. 1998. Reply to comment on 'Statistical procedures for the evaluation of evapotranspiration computing models'. Agricultural Water Management, 37: 95-97.
- 7- Jang J.S.R. 1993. ANFIS: Adaptive-network-based fuzzy inference system, IEEE Trans. Syst., Man and Cybernetics, 23(3): 665-684.
- 8- Keskin M.E., Terzi O., Tayalan D. 2004. Fuzzy logic model approaches to daily pan evaporation estimation in western Turkey. Hydrological Sciences-Journal-des Sciences Hydrologiques, 49(6):1001-1010.
- 9- Kim T.W., Valde's J.B., Nijssen B., Roncayolo D. 2006. Quantification of linkages between large-scale climatic patterns and precipitation in the Colorado River Basin. Journal of Hydrology, 321:173-186.
- 10- Mekanik F., and Imteaz M.A. 2012. A Multivariate Artificial Neural Network Approach for Rainfall Forecasting: Case Study of Victoria, Australia. p. 1-5. Proceedings of the World Congress on Engineering and Computer Science, Vol I, 24-26 October 2012. WCECS, San Francisco, USA
- 11- Nazemosadat M.J., Setoodeh P., Safavi A. 2008. Improving Neural Network Models for forecasting Seasonal Precipitation in Southwestern Iran: The Evaluation of Oceanic- Atmospheric indices. Asia Oceania Geosciences Society 5th Annual General Meeting, at Busan Exhibition & Convention Center, Busan, South Korea.
- 12- Pongracz R., Bartholy J., and Bogardi I. 2001. Fuzzy rule-based prediction of monthly precipitation, Journal of Physical Chemistry B, 26(9):663-667.
- 13- Rezaee-Banafshe M., Jahan-Bakhsh S., Bayati-Khatibi M., Zeynali B. 2011. Forecast of Autumn and Winter Precipitation of West Iran by Use from Summer and Autumn Mediterranean Sea Surface Temperature, Physical Geography Research Quarterly 74, 47-62. (in Persian with English abstract).
- 14- Rezaeian-Zadeh M., Tabari H. 2012. MLP-based drought forecasting in different climatic regions. Theoretical and Applied Climatology, 109(3-4): 407-414.
- 15- Sabbagh J., Sayigh A.A.M., Al-Salam E.M.A. 1977. Estimation of the total solar radiation from meteorological data. Solar Energy, 19(3): 307-311.
- 16- Sedaghat Kerdar A., Fatahi E. 2008. Drought Early Warning Methods over Iran, Geography and Development Iranian Journal, 11: 76-89. (in Persian with English abstract).
- 17- Shukla R.P., Tripathi K.C., Pandey A.C., Das I.M.L. 2011. Prediction of Indian summer monsoon rainfall using Niño indices: A neural network approach, Atmospheric Research, 102 (1-2): 99-109.
- 18- Smith, T.M., Arkin P.A., Sapiano M.R.P., CHang C.Y. 2010. Merged Statistical Analyses of Historical Monthly Precipitation Anomalies Beginning 1900, Journal of Climate, 23: 5755-5770.



Assessing Intelligent Models in Forecasting Monthly Rainfall by Means of Teleconnection Patterns (Case Study: Khorasan Razavi Province)

F. Nazarieh^{1*} - H. Ansari²

Received:02-09-2013

Accepted:11-03-2015

Introduction: Rainfall is affected by changes in the global sea level change, especially changes in sea surface temperature SST (Sea Surface Temperature) and sea level pressure SLP (Sea level Pressure). Climate anomalies being related to each other at large distance is called teleconnection. As physical relationships between rainfall and teleconnection patterns are not defined clearly, we used intelligent models for forecasting rainfall. The intelligent models used in this study included Fuzzy Inference Systems, neural network and Neuro-fuzzy. In this study, first the teleconnection indices that could affect rainfall in the study area were identified. Then intelligent models were trained for rainfall forecasting. Finally, the most capable model for forecasting rainfall was presented. The study area for this research is the Khorasan Razavi Province. In order to present a model for rainfall forecasting, rainfall data of seven synoptic stations including Mashhad, Golmakan, Nishapur, Sabzevar, Kashmar, Torbate and Sharks since 1991 to 2010 were used.

Materials and Methods: Based on previous studies about Teleconnection Patterns in the study area, effective Teleconnection indexes were identified. After calculating the correlation between the identified teleconnection indices and rainfall in one, two and three months ahead for all stations, fourteen teleconnection indices were chosen as inputs for intelligent models. These indices include, SLP Adriatic, SLP northern Red Sea, SLP Mediterranean Sea, SLP Aral sea, SST (Sea surface temperature) Labrador sea, SST Oman Sea, SST Caspian Sea, SST Persian Gulf, North Pacific pattern, SST Tropical Pacific in NINO₁₂ and NINO₃ regions, North Pacific Oscillation, Trans-Nino Index, Multivariable Enso Index. Inputs of the intelligent models include fourteen teleconnection indices, latitude and altitude of each station and their outputs are the prediction of rainfall for one, two and three months ahead. For calibration of the models, eighty percent of the data belonged to six stations. Mashhad, Golmakan, Sabzevar, Kashmar, Torbate and Sarakhs were used. Verification of the model was carried out in two parts. The first part of verification was done with twenty percent of the remaining data which belonged to the mentioned six stations. The second part of verification was done with data from the Nishapur station. Nishapur geographically is located between other stations and did not participate in the calibration. So, it provides a condition for assessing models in location except for the calibration stations. To assess and compare the accuracy of the models, the following statistical criteria have been used: correlation coefficient (R), normal root mean square error (NRMSE), mean bias error (MBE), Jacovides criteria (t), and ratio (R2/t). To evaluate models in different rainfall depths, rainfall data based on standard precipitation index (SPI) was divided into seven classes, and the accuracy of each class was calculated separately.

Results and Discussion: By comparing the models' ability to predict rainfall according to the R² /t criteria it can be concluded that the ranking of the models is Neuro-fuzzy model, Fuzzy Inference Systems, and Neural network, respectively. R² /to criteria for prediction of rainfall one, two, and three month earlier in the Neuro-fuzzy model are 0.91, 0.4, 0.36, in Fuzzy Inference Systems are 0.76, 0.38, 0.31 and in the neural network model are 0.43, 0.27, 0.2. The statistical criteria of Neuro-fuzzy model (R, MBE, NRMSE, t, R2/ t) for rainfall forecasting one month earlier are 0.8, -0.55, 0.43, 0.7, 0.91; two months earlier are 0.79, -1.32, 0.48, 1.56, 0.4; and three months earlier are 0.73, -1.37, 0.54, 1.47, 0.36. Calculation of MBE criteria for Neuro-fuzzy models in all classes of SPI indicated that this model has a lower estimate in extremely wet and very wet classes. This is because of lack of data belonging to these classes for model training.

Conclusion: The results of this research showed that teleconnection indices are suitable inputs for intelligent models for rainfall prediction. Computing the best structure of fuzzy, neural network and Neuro-fuzzy models showed that Neuro-fuzzy can predict rainfall the most accurately. But, the results of these models in very wet and extremely wet condition are not reliable. So, these models should be used with more caution in these conditions.

Keywords: Fuzzy Inference Systems, Neural network, Neuro-fuzzy, Rainfall forecasting, Teleconnection patterns

1, 2 - PhD Student of Irrigation and Drainage and Associate Professor, Department of Water Engineering, College of Agriculture, Ferdowsi University of Mashhad

(*-Corresponding Author Email: ff.nazarieh@gmail.com)