

## ارزیابی دقّت شبکه عصبی مصنوعی بازگشتی نارکس در پیش بینی بارش روزانه در استان کرمان

### کمال امیدوار

استاد گروه اقلیم شناسی، دانشگاه یزد، ایران

### مصطفویه فبوی زاده\*

کارشناس ارشد اقلیم شناسی، دانشگاه یزد، ایران

### میثم ذمه‌قاسم

کارشناس ارشد هوش مصنوعی، دانشگاه باهنر، ایران

تاریخ پذیرش: ۱۳۹۴/۴/۱

تاریخ دریافت: ۱۳۹۳/۱۲/۱۷

### چکیده

بارش یکی از پارامترهای مهم اقلیم‌شناسی و سایر علوم جوی که از اهمیت والای در حیات بشر برخوردار است. در سال‌های اخیر، سیل و خشک‌سالی خسارات‌های فراوانی را در بسیاری از مناطق جهان در پی داشته است. پیش‌بینی بارش در مدیریت و هشدار این معضلات نقش مهمی بر عهده دارد. امروزه شبکه‌های عصبی مصنوعی از جمله روش‌های نوین می‌باشد که برای تخمین و پیش‌بینی پارامترها با استفاده از ارتباط ذاتی بین داده‌ها توسعه یافته است. هدف این پژوهش، ارزیابی دقّت شبکه عصبی بازگشتی نارکس در پیش‌بینی بارش روزانه می‌باشد که با استفاده از آمار روزانه هواشناسی ایستگاه‌های کرمان، بافت و میانده جیرفت، طی دوره مشترک آماری ۲۳ ساله (۱۹۸۹-۲۰۱۲)، می‌باشد به منظور مقایسه به آموزش شبکه‌های عصبی مصنوعی با ساختار پرسپترون چند لایه و شبکه عصبی بازگشتی نارکس پرداخته شد. عوامل اقلیمی مؤثر در بارش به عنوان ورودی‌های شبکه‌های عصبی مصنوعی و بارش روزانه به عنوان خروجی شبکه در نظر گرفته شد. آمارهای میانگین مربع‌ها خطأ (MSE) و ضریب همبستگی (R)، به منظور ارزیابی روش‌های بکار برده شده، استفاده گردید. نتایج نشان داد که مدل ترکیبی، بر پایه قانون آموزش لونبرگ مارکوات وتابع محرک سیگمونید با همه پارامترهای هواشناسی در هر سه ایستگاه از دقّت قابل قبولی برخوردار است. همچنین مشخص شد که مدل‌های مطلوب شبکه عصبی مصنوعی در حالت تغییرات افزایشی نسبت به رطوبت نسبی، دارای بیشترین حساسیت هستند.

**واژگان کلیدی:** پیش‌بینی بارش، شبکه عصبی پرسپترون، شبکه عصبی نارکس، کرمان، بافت، میانده جیرفت.

## مقدمه

بارش یک عنصر مهم از منابع آبی در تمام نقاط جهان از جمله مناطق خشک و نیمه خشک می‌باشد. بارندگی یکی از پیچیده‌ترین و اتفاقی‌ترین پدیده‌های طبیعی می‌باشد. در واقع تأثیر عوامل محسوس و یا غیر محسوس آن چنان در ایجاد حادثه دخیل است که این روند را از یک نظام قانونمند به سوی یک ساختار پیچیده و آشوبناک سوق داده است (خلیلی، ۱۳۸۹: ۸).

از جمله روش‌های کارآمد که امروزه برای پیش بینی بارش به عنوان یک فرایند نامنظم، اهمیت دارد، شبکه‌های عصبی مصنوعی ANN است که به عقیده متخصصان، علت اصلی مقبولیت و استفاده روزافزون آن، قدرت و سرعت بالا در شبیه‌سازی فرایندهایی است که درک و شناخت درستی از آن وجود نداشته و یا بررسی آن‌ها با دیگر روش‌های موجود، بسیار دشوار و وقت گیر می‌باشد (فی زاده، ۱۳۸۸: ۵۳).

در این بررسی سعی شده است به ارزیابی دقّت خروجی شبکه‌های عصبی بازگشتی نارکس<sup>۱</sup> در تخمین بارش روزانه درایستگاه کرمان، بافت، میانده جیرفت، پرداخته شود. به این منظور مقایسه‌ای هم بین خروجی این شبکه و شبکه‌های عصبی پرسپترون انجام پذیرفت. شبکه عصبی نارکس، در مقایسه با شبکه عصبی پرسپترون، حساسیت کمتری به وابستگی‌های دراز مدت دارند و می‌توان میرا شدن گرادیان خطرا را به تأخیر انداخت. در این مقاله، توانایی یادگیری و فرآگیر شدن بهتر نارکس نسبت به شبکه عصبی پرسپترون تأیید شد.

بارش به عنوان مهمترین عنصر اقلیمی همواره در سرزمین ایران از پیچیدگی‌های خاصی برخوردار بوده است. به طوری که محققان بسیاری کوشیده‌اند تا در پژوهش‌های خود به تبیین دقیق این تغییر پذیری‌ها در حوضه‌های مختلف پردازنند و پژوهش‌های بسیاری در این زمینه انجام داده‌اند که در ادامه برخی از آنها بیان می‌شود: هال و همکاران<sup>۲</sup> (۱۹۹۸: ۳۳۸)، با بکارگیری گره‌های متصل شبکه به پیش بینی بارندگی، نشان دادند که میزان همبستگی بین بارش واقعی و بارش پیش بینی شده توسط شبکه عصبی ۹۵ درصد می‌باشد. شمس الدین و همکاران (۲۰۰۱: ۵۷۷)، به پیش بینی و برتری شبکه عصبی نارکس تأکید داشته است. ترافالیس<sup>۳</sup> (۲۰۰۲: ۷۷۵)، استفاده از شبکه‌های عصبی مصنوعی به پیش بینی بارش پرداختند. ایشان از داده‌های بارش را دارای به عنوان داده‌های ورودی شبکه استفاده کردند و به این نتیجه رسیدند که شبکه‌های عصبی دقّت بیشتری نسبت به سایر روش‌ها دارند. سیگلومون<sup>۴</sup> (۱۹۹۷: ۲۰۸)، محاسبه‌ای برای توانایی شبکه عصبی نارکس انجام داده است و به این نتیجه رسیده است که نارکس، نسبت به شبکه‌های عصبی دیگر

<sup>1</sup> - Nonlinear Autoregressive External

<sup>2</sup> - Hall et. al

<sup>3</sup> - Trafalidis

<sup>4</sup> - Siegelmann

به علت پویا بودن می‌تواند سری‌های زمانی را با وابستگی‌های دراز مدت پیش بینی کند. ماریا و همکاران<sup>۱</sup> (۲۰۰۸: ۳۳۳۶)، در یک ارزیابی تجربی به مقایسه بین چندین شبکه عصبی پرداخته است. نتایج وی نشان داده است که شبکه عصبی دینامیکی نارکس با دقت بیشتری می‌تواند به پیش بینی سری‌های زمانی بپردازد همچنین در پژوهش دیگری (۲۰۰۸: ۴۵۵)، به پیش بینی بارش ماهانه در سواحل شمال شرقی بزرگی با شبکه عصبی نارکس، پرداخته است. وی به این نتیجه رسیده است که نارکس خیلی موفق‌تر از سایر شبکه‌ها می‌تواند به پیش بینی با درجه خطای خیلی کمتری برسد.

دیاکونزو<sup>۲</sup> (۲۰۰۸)، نیز توانایی شبکه عصبی دینامیکی نارکس نسبت به روش‌های کلاسیک آماری را بیان کرده است و این که نارکس در پیش بینی دقیق سری زمانی که آشوبی و نامنظم هستند، موفق بوده است. زموری و همکاران<sup>۳</sup> (۲۰۱۰: ۲۵۰۶)، به برتری شبکه عصبی نارکس نسبت به سایر شبکه‌های عصبی بازگشتی اذعان دارد.

قلی زاده (۱۳۸۸: ۵۲)، به پیش بینی بارش ماهانه تهران پرداخته است. وی با آموزش مجدد شبکه و ترکیب آن با الگوریتم بهینه سازی ژنتیک باعث کاهش خطا در پیش بینی و افزایش دقت و سرعت محاسبه‌ها شده است. بهارلو (۱۳۸۸: ۲۴)، نیز به پیش بینی سری زمانی با وابستگی‌های دراز مدت با استفاده از شبکه عصبی بازگشتی پرداخته است و به این نیجه رسیده است مدل‌های خود برگشتی غیر خطی با ورودی‌های برونزاد (narکس) حساسیت کمتری به وابستگی‌های دراز مدت دارند و می‌توان میرا شدن گرادیان خطرا را در آنها به تأخیر انداخت و نارکس توانایی یادگیری و فرآگیر شدن بهتر را دارد.

پژوهش‌های مشابه دیگری از جمله (اژدرپور، ۱۳۸۷: ۴۵)، (حلييان، ۱۳۸۸: ۱۲)، (اردلاني و ذوالفاری ۱۰: ۲۵۴۰)، (سيتي و وييوو<sup>۴</sup>، ۲۰۱۲: ۱۵۰۶)، (سان تانم<sup>۵</sup> و همکاران، ۱۱: ۹۶۲)، در این خصوص انجام شده است.

## روش پژوهش

به منظور ارزیابی دقت شبکه عصبی نارکس در پیش بینی بارش روزانه، مقایسه‌ای بین خروجی این شبکه و شبکه عصبی پرسپترون انجام گرفت. به این منظور، از داده‌های بارش روزانه ایستگاه‌های کرمان، یافت و میانده جیرفت در یک دوره آماری مشترک ۲۳ ساله از ۱۹۸۹ تا ۲۰۱۲ استفاده شد که شامل پارامترهای: (کمینه و بیشینه و میانگین دما، رطوبت نسبی، جهت و سرعت باد، میانگین فشار به ترتیب با علامت‌های اختصاری: DD FF RH  $T_{mean}$ ,  $T_{max}$ ,  $T_{min}$ )

<sup>1</sup> - Maria et.al

<sup>2</sup>- Diaconescu et.al

<sup>3</sup> - Zemouri et.al

<sup>4</sup> Siti Hajar & Antoni

<sup>5</sup> -Santhanam et.al

$Per_{mean}$  به عنوان سیگنال‌های ورودی) و بارش روزانه با علامت‌های اختصاری: (P) به عنوان خروجی شبکه تعیین شد. از ۸۵۸۵ داده روزانه، ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد بقیه برای تست به کار گرفته شده است. شایان ذکر است در ایستگاه‌های نامبرده همه ترکیب‌های ممکن، (۴۲ مدل) از سیگنال‌های ورودی تهیّه و به شبکه‌ها معرفی گردید (جدول ۱). در نهایت دقّت مدلی که کمترین خطا و بیشترین همبستگی را داشت؛ به عنوان مدل برتر و عوامل اقلیمی موجود در ترکیب ورودی به عنوان مهمترین عوامل مؤثر در پیش بینی بارش معرفی شدند.

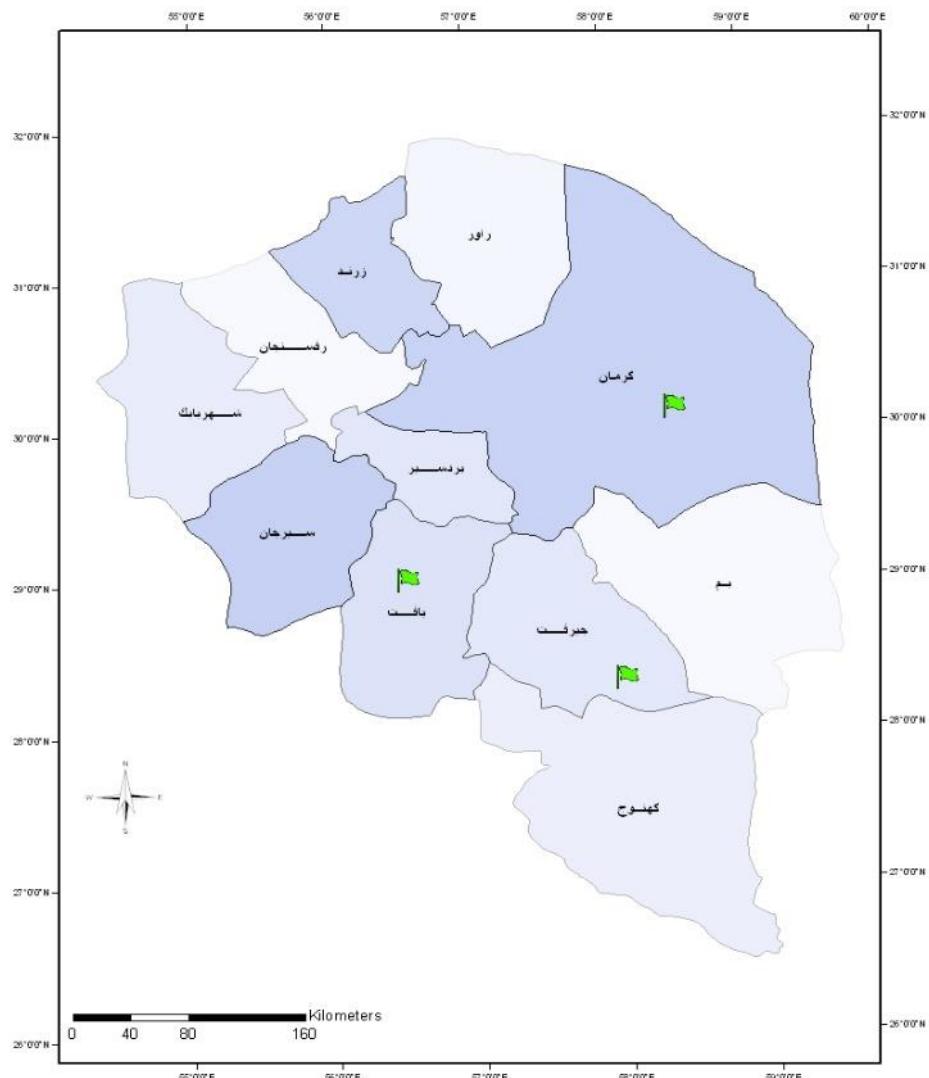
### منطقهٔ مورد مطالعه

ایستگاه‌های مورد مطالعه در این پژوهش شهر کرمان، بافت و میانده جیرفت می‌باشد (شکل ۱).

- **کرمان:** ۱۷۵۳/۸ متر از سطح دریا و متوسط بارندگی در طی سال‌های مورد مطالعه (۲۰۱۲-۱۹۸۹)، ۱۳۱/۲۶ میلی‌متر برآورده است. در این دوره، انحراف معیار بارندگی سالانه ۴۷/۴ و ضریب تغییرات برابر با ۳۶/۱۱ درصد بوده است. که طی سال‌های مورد مطالعه کاهش داشته است و جزو مناطق خشک می‌باشد؛

- **بافت:** ۲۲۸۰ متر از سطح دریا ارتفاع دارد و جزو مناطق کوهستانی و مرتفع‌ترین شهر استان می‌باشد؛ متوسط بارندگی در طی سال‌های مورد مطالعه (۱۹۸۹-۲۰۱۲)، ۲۴۴/۳ میلی‌متر برآورده است. در این دوره، انحراف معیار بارندگی سالانه ۹۰/۸۷ و ضریب تغییرات برابر با ۱۹/۳ درصد بوده است؛

- **جیرفت:** دارای ارتفاع ۶۰۱ متر، جزو مناطق گرم‌سیری در استان محسوب می‌شود. متوسط بارندگی در طی سال‌های مورد مطالعه (۱۹۸۹-۲۰۱۲)، ۱۷۴/۲۶ میلی‌متر برآورده است. در این دوره، انحراف معیار بارندگی سالانه ۹۱/۷۶ و با بیشترین ضریب تغییرات برابر با ۵۲/۶۵ درصد بوده است. علت انتخاب این سه ایستگاه، به علت آب و هوای متفاوتی که دارند می‌باشد تا تأثیر این تفاوت در خروجی شبکه‌های عصبی مورد نظر مشاهده شود.



مأخذ: نگارندگان ۹۲

شکل ۱: موقعیت ایستگاه‌های مورد مطالعه

جدول ۱: مدل‌های ورودی ساخته شده بر اساس سیگنال‌های ورودی (ماخذ: نگارنگان ۱۳۹۲)

شماره شبکه	پارامترهای بردار ورودی
۱	$P = f(T_{\min})$
۲	$P = f(T_{\max})$
۳	$P = f(T_{\text{mean}})$
۴	$P = f(RH)$
۵	$P = f(FF)$
۶	$f(DD)P$
۷	$P = f(\text{Pre}_{\text{mean}})$
۸	$P = f(T_{\min} + T_{\max})$
۹	$P = f(T_{\min} + T_{\text{mean}})$
۱۰	$P = f(T_{\min} + RH)$
۱۱	$P = f(T_{\min} + FF)$
۱۲	$P = f(T_{\min} + DD)$
۱۳	$P = f(T_{\min} + \text{Pre}_{\text{mean}})$
۱۴	$P = f(T_{\max} + T_{\text{mean}})$
۱۵	$P = f(T_{\max} + RH)$
۱۶	$P = f(T_{\max} + FF)$
۱۷	$P = f(T_{\max} + DD)$
۱۸	$P = f(T_{\max} + \text{Pre}_{\text{mean}})$
۱۹	$P = f(T_{\text{mean}} + RH)$
۲۰	$P = f(T_{\text{mean}} + FF)$
۲۱	$P = f(T_{\text{mean}} + DD)$
۲۲	$P = f(T_{\text{mean}} + \text{Pre}_{\text{mean}})$
۲۳	$P = f(RH + FF)$
۲۴	$P = f(RH + DD)$
۲۵	$P = f(RH + \text{Pre}_{\text{mean}})$
۲۶	$P = f(FF + DD)$
۲۷	$P = f(FF + \text{Pre}_{\text{mean}})$
۲۸	$P = f(T_{\min} + T_{\max} + T_{\text{mean}})$
۲۹	$P = f(T_{\min} + T_{\max} + RH)$
۳۰	$P = f(T_{\min} + T_{\max} + FF)$
۳۱	$P = f(T_{\min} + T_{\max} + DD)$
۳۲	$P = f(T_{\min} + T_{\max} + \text{Pre}_{\text{mean}})$
۳۳	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + RH)$
۳۴	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + FF)$
۳۵	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + DD)$
۳۶	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + \text{Pre}_{\text{mean}}))$
۳۷	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + RH + FF)$
۳۸	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + RH + DD)$
۳۹	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + RH + \text{Pre}_{\text{mean}})$
۴۰	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + RH + FF + DD)$
۴۱	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + RH + FF + \text{Pre}_{\text{mean}})$
۴۲	$P = f(T_{\min} + T_{\max} + T_{\text{mean}} + RH + FF + DD + \text{Pre}_{\text{mean}})$

## داده‌های پژوهش

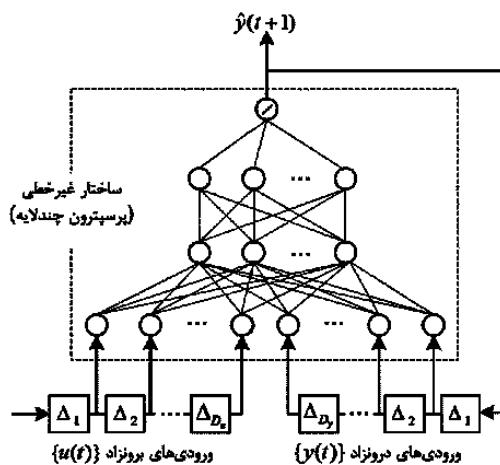
اساس شبکه‌های عصبی مصنوعی در واقع شبیه سازی و مدل‌سازی تفکر مغز انسان از طریق سلول‌های عصبی می‌باشد. هر سلول عصبی به عنوان یک واحد پردازشگر عددی عمل می‌کند. نرون‌های شبکه با هم در ارتباط بوده و به صورات موازی کار می‌کنند (حلیان، ۱۳۸۸: ۱۰).

### - شبکه عصبی بازگشتی نارکس

بر خلاف شبکه‌های انتشار مستقیم مانند پرسپترون چند لایه، در شبکه‌های بازگشتی از نuron‌های لایه‌های میانی یا لایه خروجی به لایه‌های قبل، یا همان لایه، پس‌خورد وجود دارد. این پسخورد معمولاً شامل یک واحد تأخیر زمانی است. همین ارتباطات تأخیردار به امکان به وجود آوردن حافظه در ساختار شبکه کمک می‌کند و شبکه‌های بازگشتی را به ابزاری پویا تبدیل می‌نماید. مدل نارکس دسته‌های از سامانه‌های خود برگشتی غیرخطی گسسته در زمان است که علاوه بر ورودی‌های درون‌زاد، دارای ورودی‌های بروزنزد است و با رابطه ذیل توصیف می‌شود.

$$\hat{y}(t+1) = f(y(t), \dots, y(t-D_y), u(t), \dots, u(t-D_u)) + \varepsilon_t$$

در اینجا  $\{y(t)\}$ ، سری زمانی مورد علاقه است که باید پیش‌بینی شود و  $\{u(t)\}$ ، سری زمانی دیگری است که جملات آن به طور متناظر با جملات  $\{y(t)\}$ ، مرتبط هستند. جملات  $u(t), \dots, u(t-D_u)$  ورودی‌های بروزنزد هستند که توسط یک خط تأخیر با مرتبه  $D_u$  تولید می‌شوند. به طور مشابه  $y(t), \dots, y(t-D_y)$  ورودی‌های درون‌زاد را تشکیل می‌دهند و با خط تأخیری با مرتبه  $D_y$  خروجی شبکه نارکس را تولید می‌کند.  $f$  یک تابع غیر خطی است که مقدار بعدی سری  $\{y(t)\}$  را تخمین می‌زند.  $\varepsilon_t$  نویز جمع شونده تخمین است (شکل ۲). در شبکه نارکس، می‌توان با افزایش تعداد تأخیرها در خط تأخیر خروجی شبکه، میرا شدن گرادیان را به تأخیر انداخت. مزیت شبکه نارکس بر دیگر شبکه‌های بازگشتی آن است که پس‌خوردها به طور مستقیم، خروجی را به ورودی ارتباط می‌دهند (بهارلو، ۱۳۸۸: ۳).



شکل ۲: یک مدل خود برگشتی غیر خطی با ورودی بروزنزد (نارکس)

### - توابع انتقال مورد استفاده

توابع مورد استفاده در شبکه عصبی MLP و NARX، تابع سیگموئید. در لایه خروجی هر دو شبکه از تابع همانی(خطی) استفاده شد.

### یافته‌های پژوهش

در این پژوهش، در شبکه‌های عصبی: MLP و NARX، فرایند آموزش به منظور شبیه سازی بارش با تعداد چرخش<sup>۱</sup> ۱۰۰۰ بار انجام گرفت. میزان نرون‌های لایه مخفی متناسب با  $n^2$  طراحی شد که  $n$  متناسب با تعداد عوامل ورودی به مدل می‌باشد. برای ۴۲ مدل ترکیبی، میانگین مربع‌ها خطأ و ضریب همبستگی به منظور ارزیابی تأثیر آنها محاسبه شد.

### - تعیین میزان همبستگی بین عوامل اقلیمی

در بررسی‌های اقلیمی، هر چه دوره آماری طولانی‌تر باشد، پژوهش از ارزش بالاتری بهره مند خواهد بود. بنابراین در این پژوهش از دوره مشترک آماری، پارامترهای روزانه مؤثر در بارندگی از قبیل بارش، حداقل و حداکثر مطلق دما، میانگین دمای روزانه، رطوبت نسبی، سرعت و جهت باد، که برای هر کدام، شامل ۸۵۸۵ داده روزانه می‌باشد در سه ایستگاه کرمان و جیرفت و بافت مورد استفاده قرار گرفت. در جداول زیر، میزان همبستگی بین عوامل اقلیمی مشخص می‌باشد. میانگین فشار در ایستگاه کرمان و سرعت باد در ایستگاه بافت و جیرفت همبستگی مشاهده نشد(جدول ۲، ۳، ۴).

**جدول ۲: میزان همبستگی بین پارامترهای اقلیمی با متغیر واپسیه بارش در ایستگاه کرمان**

	حداقل دما	حداکثر دما	میانگین دما	میانگین دمای رطوبت نسبی	سرعت باد	جهت باد	میانگین فشار
ضریب پرسیون	-۰/۰۵**	-۰/۲۶**	-۰/۱۴۹ **	.۰/۴۳۲ **	.۰/۰۵۱ **	.۰/۰۵۲ **	-۰/۰۱۶
سطح معناداری	.	.	.	.	.	.	.۰/۱۲۷
تعداد	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵

**جدول ۳: میزان همبستگی بین پارامترهای اقلیمی با متغیر واپسیه بارش در ایستگاه بافت**

	حداقل دما	حداکثر دما	میانگین دما	میانگین دمای رطوبت نسبی	سرعت باد	جهت باد	میانگین فشار
ضریب پیرسون	**-۰/۲۴۷	**.۰/۱۲۳	**-۰/۱۹۰	**.۰/۳۸۹	.۰/۰۰۴	**-۰/۰۳۰	**-۰/۰۸۵
سطح معناداری	.	.	.	.	.۰/۶۸۹	.۰/۰۰۵	.
تعداد	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵

<sup>۱</sup> -Epoch

**جدول ۴ : میزان همیستگی بین عوامل اقلیمی با متغیر وایسنه بارش در ایستگاه جیرفت**

	میانگین فشار	جهت باد	سرعت باد	روطوبت نسبی	حداکثر دما	حداقل دما	ضریب پرسون
ضریب پرسون	**-۰/۰۴۸	**-۰/۰۴۱	۰/۰۷۹	**-۰/۰۳۱۵	**-۰/۰۳۲	**-۰/۰۲۰	**-۰/۰۸۲
سطح معنا داری	.	.	.	.	۰/۰۰۳	.	.
تعداد	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵

**- تعیین متغیرهای ورودی**

یکی از مهم‌ترین گام‌ها در پیشبرد رضایت بخش مدل پیش‌بینی شبکه‌های عصبی مصنوعی، انتخاب متغیرهای ورودی مناسب می‌باشد. به این منظور نیاز به ارزیابی عملکرد شبکه‌های عصبی با ورودی‌های مختلف می‌باشد. سعی بر این است که شبکه‌ای با کمترین خطأ و بالاترین همبستگی معرفی شود.

به منظور طراحی ساختار بهینه، شبکه‌های عصبی مذکور برای الگوهای متعددی اجرا شد. سپس از بین حالت‌های مختلف، ساختاری که در آن بیشترین ضریب همبستگی و کمترین خطأ وجود داشت، انتخاب شد. همچنین به منظور بررسی اثر پارامترهای مختلف ورودی در این پژوهش از ۴۲ ساختار مختلف برای ورودی شبکه‌های عصبی استفاده شده است و برای هر دو شبکه عصبی به صورت جداگانه مورد بررسی قرار گرفت (جدول ۱).

**- شبکه عصبی بازگشتی NARX**

از مزیت این نوع شبکه، میزان خطای کم (MSE) و ضریب همبستگی نسبتاً زیاد می‌باشد. در این ایستگاه‌ها، مدل‌هایی که توانسته‌اند ضریب همبستگی  $0/7$  و بالاتر را به دست آورند به عنوان ورودی‌های مؤثر معرفی می‌کنیم. شبکه‌های بازگشتی نیز در این پژوهش، از توانمندی بالایی برخوردار می‌باشد. نتایج به دست آمده از آموزش و آزمون شبکه بازگشتی برای ۴۲ نوع ساختار مختلف ورودی، برای هر سه ایستگاه به صورت جداگانه ارایه شده است (جدول ۵). در شبکه‌های عصبی، بیشترین ضریب همبستگی و کمترین میزان خطأ، مدل بهینه را مشخص می‌کند.

**الف) نتایج شبکه عصبی NARX در ایستگاه کرمان**

مدل‌های شماره ۳۷، ۳۸، ۴۰، ۴۲، ۳۹، ۳۸، ترکیب‌هایی بودند که نسبت به بقیه، همبستگی بالای  $0/7$  و دقیق بالایی داشته‌اند، کمینه و بیشینه و میانگین دما، رطوبت نسبی در این شبکه نیز از عوامل مهم و مؤثر بوده‌اند. نتایج، بیانگر این واقعیت بود که NARX42، با سه لایه، شامل یک لایه ورودی با ۷ نرون و یک لایه خروجی با یک نرون و یک لایه مخفی با ۱۴ نرون و تابع محرک سیگموئید، ساختار برگزیده است. نتایج نشان می‌دهد که ساختار

۴۲ از دقّت بالاتری نسبت به سایر ساختارها برخوردار است. این ترکیب شامل: کمینه دما، پیشینه دما، میانگین دما، رطوبت نسبی و جهت باد و میانگین فشار بهترین کارایی را داشته است (جدول ۵).

### ب) نتایج شبکه عصبی NARX در ایستگاه بافت

مدل‌های شماره ۳۹، ۴۰، ۴۱، ۴۲، ترکیب‌هایی بودند که نسبت به بقیه، همبستگی بالای ۰/۷ و دقّت بالایی داشته‌اند، رطوبت نسبی در تخمین بارش از مهمترین عوامل تأثیرگذار بوده است و کمترین تأثیرگذار عامل جهت باد است. در جدول ۵، مشاهده می‌شود که با ورود این دو عامل رطوبت نسبی و پارامترهای مربوط به دما، کارایی شبکه و ضریب همبستگی بهتر می‌شود. شاهد این نکته، بالا رفتن کارایی و همبستگی در مدل‌های ۱۹، ۲۳، ۲۴، ۲۵، ۲۷، ۳۴، ۳۵، ۳۶، ۳۷، نسبت به ترکیب‌های قبل و بعد این مدل‌ها است.

نتایج، بیانگر این واقعیّت بود که NARX42، با ضریب همبستگی ۰/۷۶۹ با سه لایه، شامل یک لایه ورودی با ۷ نرون و یک لایه خروجی با یک نرون و یک لایه مخفی با ۱۴ نرون و تابع محرک سیگموئید، در میان سایر ساختارها برگزیده است. نتایج نشان می‌دهد که ساختار ۴۲ از دقّت بالاتری نسبت به سایر ساختارها برخوردار است (جدول ۵).

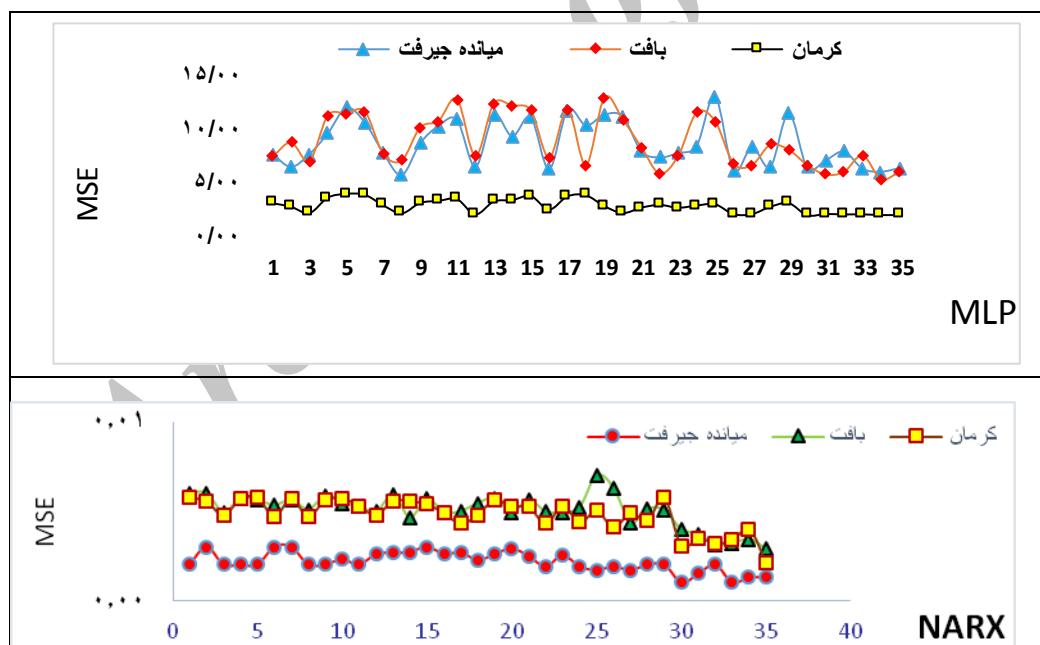
### ج) نتایج شبکه عصبی NARX در ایستگاه جیرفت

مدل‌های شماره ۳۲، ۳۴، ۴۰، ۴۱، ۴۲، ۴۳، ۴۷، ترکیب‌هایی بودند که نسبت به بقیه، همبستگی بالای ۰/۷ و دقّت بالایی داشته‌اند، کمینه و بیشینه و میانگین دما، رطوبت نسبی در این شبکه نیز از عوامل مهم و مؤثر بوده‌اند. نتایج، بیانگر این واقعیّت بود که NARX42، با سه لایه، شامل یک لایه ورودی با ۷ نرون و یک لایه خروجی با یک نرون و یک لایه مخفی با ۱۴ نرون و تابع محرک سیگموئید، ساختار برگزیده است. نتایج نشان می‌دهد که ساختار ۴۲ از دقّت بالاتری نسبت به سایر ساختارها برخوردار است (جدول ۵).

- بهترین آزمون NARX در ایستگاه جیرفت می‌باشد. کارایی بالا و میزان MSE بسیار کمتر نسبت به دو ایستگاه دیگر، نشان می‌دهد که تخمین NARX در آب و هوایی که بارش‌ها از شدت زیاد و رگباری و دارای خاصیّت دینامیکی و تغییر ذیری بالامی باشند، از توانمندی بالایی برخوردار است. در اینجا استناد به پژوهشی که ماربیا و همکاران(۲۰۰۸): ۶۲۴ در سواحل جنوب شرقی برزیل انجام داده است، به این نتیجه رسیده است، چون آب و هوای این سواحل از خاصیّت دینامیکی و تغییرپذیری بالایی برخوردار است، مدل دینامیکی NARX بهتر از سایر شبکه‌های عصبی قادر به پیش بینی بارش می‌باشد. در این پژوهش هم با مقایسه ضریب تغییرات ایستگاه‌های مورد نظر، مشاهده می‌شود که تغییر پذیری در جیرفت (۵۲/۶۵ درصد)، بیشتر می‌باشد ضریب همبستگی بالا و خطای بسیار کم کسب شده NARX در ایستگاه میانده جیرفت نشانه این امر است (شکل‌های ۳، ۴) و (جدول ۵).

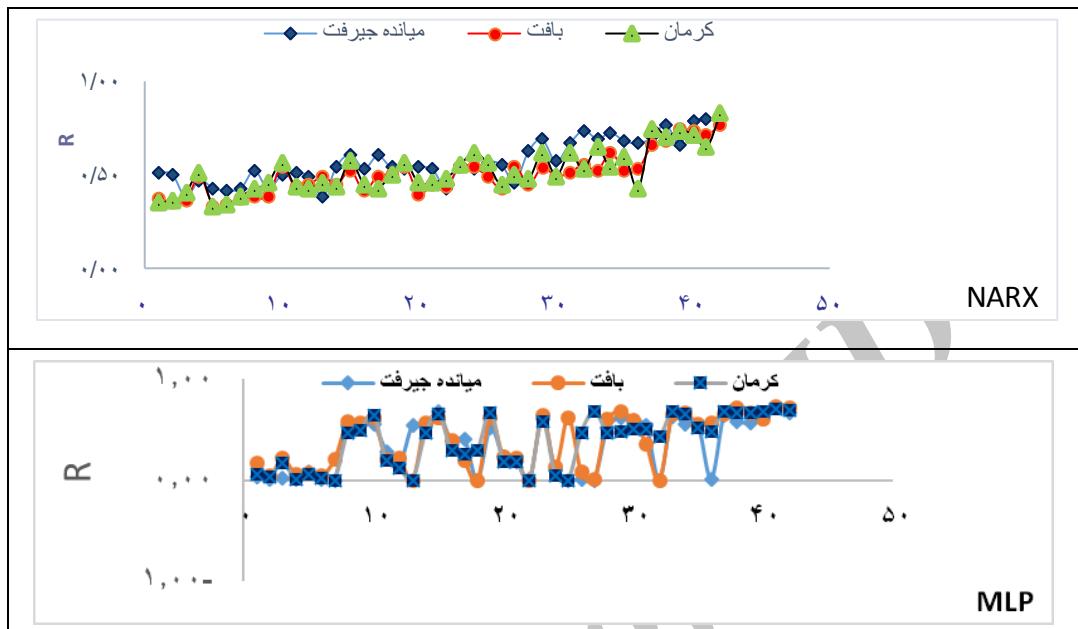
### شبکه عصبی پرسپترون در ایستگاه‌های مورد مطالعه

برای درک بهتر از دقّت شبکه نارکس، مقایسه‌ای بین خروجی NARX و MLP انجام گرفت که خطای زیاد MLP نشان از دقّت پایین خروجی این نوع شبکه عصبی مصنوعی در پیش‌بینی فرایند اتفاقی بارش می‌باشد. بهترین مدل، MLP41، با ترکیب کمینه دما، میانگین دما، رطوبت نسبی و جهت باد و میانگین فشار ضریب همبستگی ۰/۷ را کسب کرده است. بیشترین ضریب کسب شده در دو ایستگاه دیگر مدل MLP40، با ترکیب کمینه دما، پیشینه دما، میانگین دما، رطوبت نسبی و جهت و سرعت باد می‌باشد. با افزایش میزان ورودی‌های تأثیرگذار دقّت شبکه افزایش یافته است (جدول ۵). این نوع شبکه در ایستگاه کرمان خطای کمتری را نسبت به دو ایستگاه دیگر کسب کرده است، این بدان علت است که افت و اخیر بارش در این ایستگاه کمتر از دو ایستگاه دیگر است و این شبکه در فرایندهای نامنظم خروجی دقیقی ندارد. میزان خطای زیاد این نوع شبکه در (جدول ۵) و (شکل‌های ۳، ۴) کاملاً مشخص شده است.



شکل ۳: مقایسه نتایج ضریب نکویی کسب شده توسط شبکه عصبی MLP و NARX

مأخذ: نگارنده‌گان، ۱۳۹۲



شکل ۴: مقایسه خطای بین دو شبکه مورد آزمون: NARX و MLP

ماخذ: نگارندهان، ۱۳۹۲

جدول ۵ : مقایسه نتایج شبکه عصبی NARX و MLP در ایستگاه‌های مورد مطالعه

نمره مدل	کرمان				بافت				میانده جیرفت			
	NARX		MLP		NARX		MLP		NARX		MLP	
	R	MSE	R	MSE	R	MSE	R	MSE	R	MSE	R	MSE
۱	.۰/۳۶	.۰/۰۰۶۱	.۰/۰۶	.۳/۵	.۰/۳۸	.۰/۰۰۶	.۰/۱۷	.۱۰/۴	.۰/۵۱	.۰/۰۰۲	.۰/۰۳	.۱۰/۸
۲	.۰/۳۶	.۰/۰۰۶۱	.۰/۰۴	.۳/۵	.۰/۳۵	.۰/۰۰۶۲	.۰/۰۴	.۱۱/۵	.۰/۵۱	.۰/۰۰۲	.۰/۰۰۲	.۱۲/۲
۳	.۰/۴	.۰/۰۰۶	.۰/۱۷	.۳/۵	.۰/۳۶	.۰/۰۰۶۱	.۰/۲۲	.۱۰/۳	.۰/۳۸	.۰/۰۰۳	.۰/۰۲	.۱۰/۳
۴	.۰/۵۱	.۰/۰۰۵۲	.۰/۰۰۲	.۳/۹	.۰/۴۹	.۰/۰۰۵۳	.۰/۰۶	.۱۱/۵	.۰/۵۱	.۰/۰۰۲	.۰/۰۰۱	.۱۱/۹
۵	.۰/۳۳	.۰/۰۰۶۲	.۰/۰۵	.۳/۶	.۰/۳۳	.۰/۰۰۶۳	.۰/۰۸	.۱۲/۹	.۰/۴۳	.۰/۰۰۳	.۰/۰۸	.۱۱/۷
۶	.۰/۳۴	.۰/۰۰۶۶	.۰/۰۲	.۳/۵	.۰/۳۴	.۰/۰۰۶۲	.۰/۰۵	.۱۱/۹	.۰/۴۲	.۰/۰۰۳	.۰/۰۰۳	.۱۱/۲
۷	.۰/۳۸	.۰/۰۰۵۹	*	.۳/۳	.۰/۳۷	.۰/۰۰۶۱	.۲/۰۴	.۱۰/۹	.۰/۴۳	.۰/۰۰۳	*	.۸/۶
۸	.۰/۳۳	.۰/۰۰۶	.۰/۴۶	.۳/۱	.۰/۳۸	.۰/۰۰۶	.۰/۰۷	.۷/۵	.۰/۵۲	.۰/۰۰۲	.۰/۵۴	.۷/۷
۹	.۰/۴۶	.۰/۰۰۵۶	.۰/۴۹	.۲/۷۱	.۰/۳۸	.۰/۰۰۶	.۰/۰۷	.۸/۸	.۰/۴۳	.۰/۰۰۳	.۰/۵۴	.۶/۷
۱۰	.۰/۵۷	.۰/۰۰۳	.۰/۶۵	.۲/۱۲	.۰/۵۵	.۰/۰۰۴۹	.۰/۶۲	.۷/۰۵	.۰/۵	.۰/۰۰۲	.۰/۵۵	.۷/۷
۱۱	.۰/۴۴	.۰/۰۰۵۶	.۰/۱۹	.۳/۶	.۰/۴۳	.۰/۰۰۵۷	.۰/۲۱	.۱۱/۳	.۰/۵۱۱	.۰/۰۰۲	.۰/۲۸	.۹/۷
۱۲	.۰/۴۷	.۰/۰۰۶	.۰/۱۲	.۳/۹	.۰/۴۵	.۰/۰۰۵۶	.۰/۲۲	.۱۱/۵	.۰/۴۹	.۰/۰۰۲	.۰/۱۵	.۱۲/۰
۱۳	.۰/۴۶	.۰/۰۰۶	*	.۳/۸	.۰/۴۹	.۰/۰۰۵۳	*	.۱۱/۷	.۰/۳۸	.۰/۰۰۳	*	.۱۰/۶
۱۴	.۰/۴۳	.۰/۰۰۶	.۰/۴۶	.۲/۸	.۰/۴۵	.۰/۰۰۵۶	.۰/۵۶	.۷/۷۱	.۰/۵۵	.۰/۰۰۳	.۰/۵۴	.۷/۸
۱۵	.۰/۵۸	.۰/۰۰۴۶	.۰/۶۶	.۲/۰۹	.۰/۵۳	.۰/۰۰۵۱	.۰/۶۲	.۷/۱	.۰/۶۱	.۰/۰۰۲	.۰/۶۸	.۵/۷

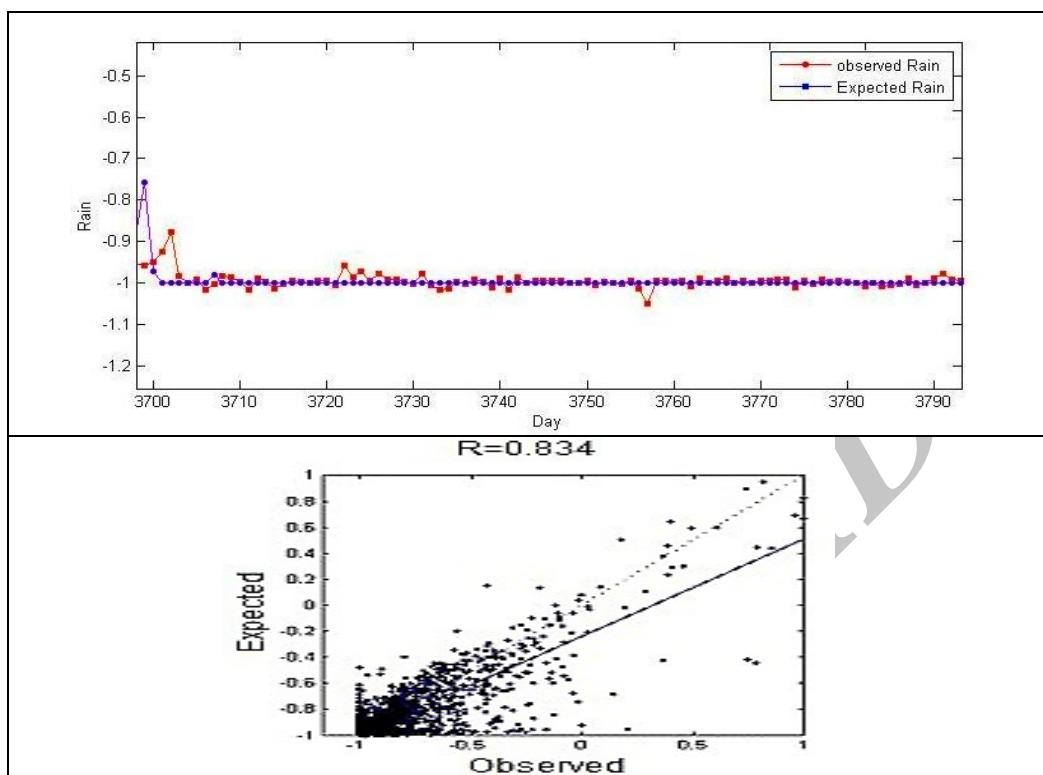
ادامه جدول													
۱۶	.۰/۴۵	.۰/۰۰۵۶	.۰/۲۹	۳/۱	.۰/۴۱	.۰/۰۰۵۸	.۰/۳۹	۱۰/۲	.۰/۵۳	.۰/۰۰۲	.۰/۳۸	۸/۷	
۱۷	.۰/۴۳	.۰/۰۰۶	.۰/۲۵	۳/۲	.۰/۵	.۰/۰۰۵۴	.۰/۱۹	۱۰/۸	.۰/۶	.۰/۰۰۲	.۰/۴۱	۱۰/۳	
۱۸	.۰/۵	.۰/۰۰۵۲	.۰/۲۹	۳/۴	.۰/۵	.۰/۰۰۵۳	*	۱۲/۹	.۰/۵۴	.۰/۰۰۲	*	۱۰/۹	
۱۹	.۰/۵۶	.۰/۰۰۴۷	.۰/۶۷	۱/۹۹	.۰/۵۴	.۰/۰۰۴۹	.۰/۶۱	۷/۵	.۰/۵۳	.۰/۰۰۳	.۰/۵۲	۶/۵	
۲۰	.۰/۴۵	.۰/۰۰۵۵	.۰/۱۹	۳/۲۱	.۰/۴	.۰/۰۰۶	.۰/۲۳	۱۲/۴	.۰/۵۴	.۰/۰۰۳	.۰/۲۳	۱۱/۳	
۲۱	.۰/۴۶	.۰/۰۰۵۵	.۰/۱۹	۳/۳	.۰/۴۴	.۰/۰۰۵	.۰/۲۲	۱۲/۲	.۰/۵۲	.۰/۰۰۳	.۰/۱۹	۹/۴	
۲۲	.۰/۴۸	.۰/۰۰۵۴	*	۳/۷	.۰/۴۳	.۰/۰۰۵۶	*	۱۱/۸	.۰/۴۲	.۰/۰۰۳	.۰/۰۰۳	۱۱/۷	
۲۳	.۰/۵۵	.۰/۰۰۴۸	.۰/۵۹	۲/۵	.۰/۶	.۰/۰۰۵	.۰/۶۴	۷/۴	.۰/۵۵	.۰/۰۰۳	.۰/۶۱	۶/۲	
۲۴	.۰/۶۲	.۰/۰۰۴۳	.۰/۰۴	۳/۷	.۰/۵۴	.۰/۰۰۵	.۰/۱۴	۱۱/۹	.۰/۵۳	.۰/۰۰۳	.۰/۱	۱۱/۸	
۲۵	.۰/۵۶	.۰/۰۰۴۸	*	۳/۸	.۰/۵	.۰/۰۰۵۴	.۰/۶۲	۶/۶	.۰/۵۶	.۰/۰۰۲	*	۱۰/۴	
۲۶	.۰/۴	.۰/۰۰۵۶	.۰/۴۶	۲/۸	.۰/۴۳	.۰/۰۰۵۷	.۰/۰۹	۱۳	.۰/۵۵	.۰/۰۰۳	.۰/۰۰۳	۱۱/۴	
۲۷	.۰/۵	.۰/۰۰۵۲	.۰/۷	۲/۱۲	.۰/۵۵	.۰/۰۰۴۹		۱۰/۹	.۰/۵	.۰/۰۰۳	*	۱۱/۲	
۲۸	.۰/۴۸	.۰/۰۰۵۲	.۰/۵	۲/۶	.۰/۴۵	.۰/۰۰۵۶	.۰/۶	۸/۳	.۰/۶۳	.۰/۰۰۳	.۰/۵۱	۷/۹	
۲۹	.۰/۶۲	.۰/۰۰۴۳	.۰/۵	۲/۹	.۰/۵۴	.۰/۴۹۶	.۰/۶۷	۵/۹	.۰/۶۹	.۰/۰۰۲	.۰/۶۲	۷/۴	
۳۰	.۰/۵	.۰/۰۰۵	.۰/۵	۲/۶	.۰/۵	.۰/۰۰۵	.۰/۵۹	۷/۵	.۰/۵۷	.۰/۰۰۳	.۰/۵۹	۷/۸	
۳۱	.۰/۶۲	.۰/۰۰۴	.۰/۵۱	۲/۸	.۰/۵۲	.۰/۰۰۵	.۰/۴	۱۱/۶	.۰/۶۶	.۰/۰۰۲	.۰/۵۳	۸/۴	
۳۲	.۰/۵۳	.۰/۰۰۵	.۰/۴	۲/۹	.۰/۶	.۰/۰۰۷	*	۱۰/۸	.۰/۷۳	.۰/۰۰۲	*	۱۳/۱	
۳۳	.۰/۶۵	.۰/۰۰۴۱	.۰/۶۹	۲/۰۲	.۰/۵۲	.۰/۰۰۶۲	.۰/۶۵	۶/۸	.۰/۷	.۰/۰۰۲	.۰/۶۳	۶/۱۴	
۳۴	.۰/۵۳	.۰/۰۰۴۹	.۰/۶۵	۲/۰۲	.۰/۶۲	.۰/۰۰۴	.۰/۶۶	۶/۶	.۰/۷۲	.۰/۰۰۲	.۰/۵۵	۸/۳	
۳۵	.۰/۶	.۰/۰۰۵	.۰/۵۲	۲/۷۱	.۰/۵	.۰/۰۰۵۲	.۰/۵۶	۸/۶	.۰/۶۸	.۰/۰۰۲	.۰/۵۴	۶/۵	
۳۶	.۰/۴۲	.۰/۰۰۶	.۰/۸	۳/۰۵	.۰/۵	.۰/۰۰۵	.۰/۶	۸/۱	.۰/۶۷	.۰/۰۰۲	.۰/۰۰۷	۱۱/۵	
۳۷	.۰/۷۵	.۰/۰۰۳۱	.۰/۷	۱/۹۱	.۰/۶۶	.۰/۰۰۴	.۰/۶۶	۶/۷	.۰/۷	.۰/۰۰۱	.۰/۶۵	۶/۴۱	
۳۸	.۰/۷۱	.۰/۰۰۴	.۰/۷	۲/۰۳	.۰/۶۸	.۰/۰۰۴	.۰/۷	۵/۸	.۰/۸	.۰/۰۰۲	.۰/۵۸	۷/۰۹	
۳۹	.۰/۷	.۰/۳۲۱	.۰/۶۶	۱/۹۹	.۰/۷۴	.۰/۳۱۳	.۰/۷	۶/۰۱	.۰/۶۷	.۰/۰۰۲	.۰/۵۷	۷/۹	
۴۰	.۰/۷۲	.۰/۰۰۳	.۰/۷	۲	.۰/۷۴	.۰/۳۱۹	.۰/۷	۵/۳	.۰/۸	.۰/۰۰۱	.۰/۷۲	۶/۰۲	
۴۱	.۰/۶۵	.۰/۰۰۴	.۰/۷	۱/۹۳	.۰/۷۲	.۰/۰۰۳	.۰/۷	۶/۴	.۰/۸	.۰/۰۰۱	.۰/۶۳	۶/۸	
۴۲	.۰/۸	.۰/۰۰۲	.۰/۶۹	۱/۹۴	.۰/۷۷	.۰/۰۰۳	.۰/۷	۶/۰۱	.۰/۸۱	.۰/۰۰۱	.۰/۶۷	۶/۶	

### شبیه سازی فرایند بارش توسط بهترین شبکه مورد آزمون: NARX

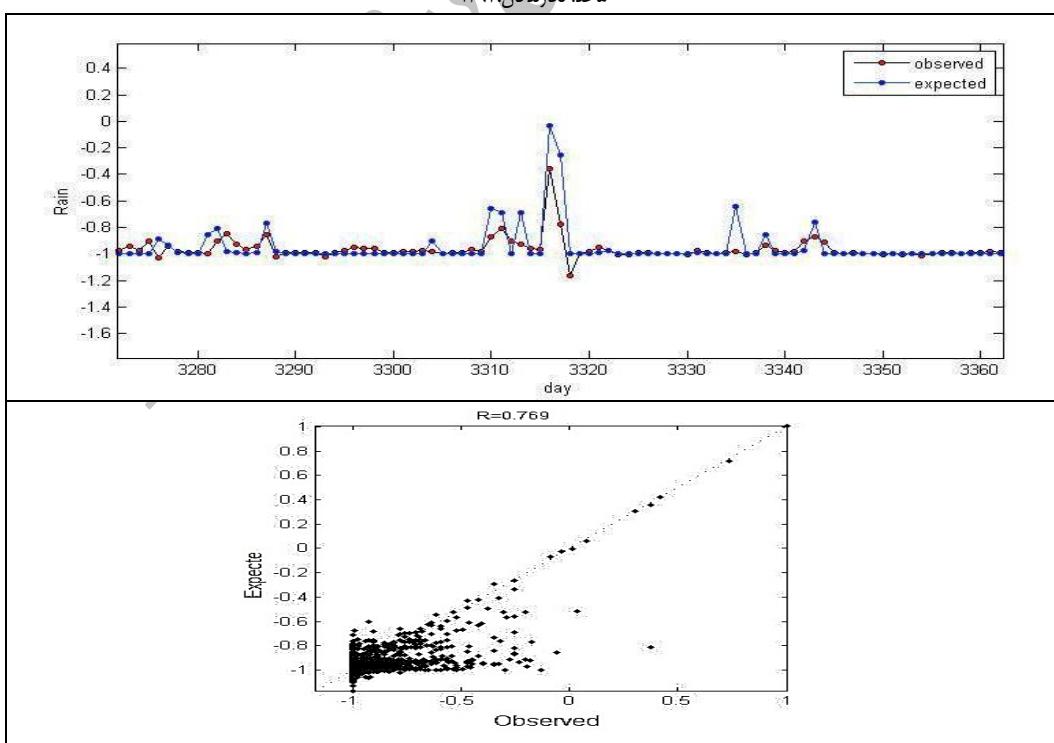
همپوشانی بین خروجی شبکه همان داده های پیش بینی شده<sup>۱</sup> و داده های واقعی<sup>۲</sup>، NARX، در سه ایستگاه نامبرده شبیه سازی شده اند (بازه زمانی روزهای ۵، ۶، ۷)، وجود دارد به علت کثرت داده ها گزینشی می باشد). همپوشانی بین داده های پیش بینی شده و داده های واقعی، شبکه عصبی NARX از دقّت نسبتا بالایی برخوردار است(شکل های ۵، ۶، ۷).

<sup>1</sup> - Expected

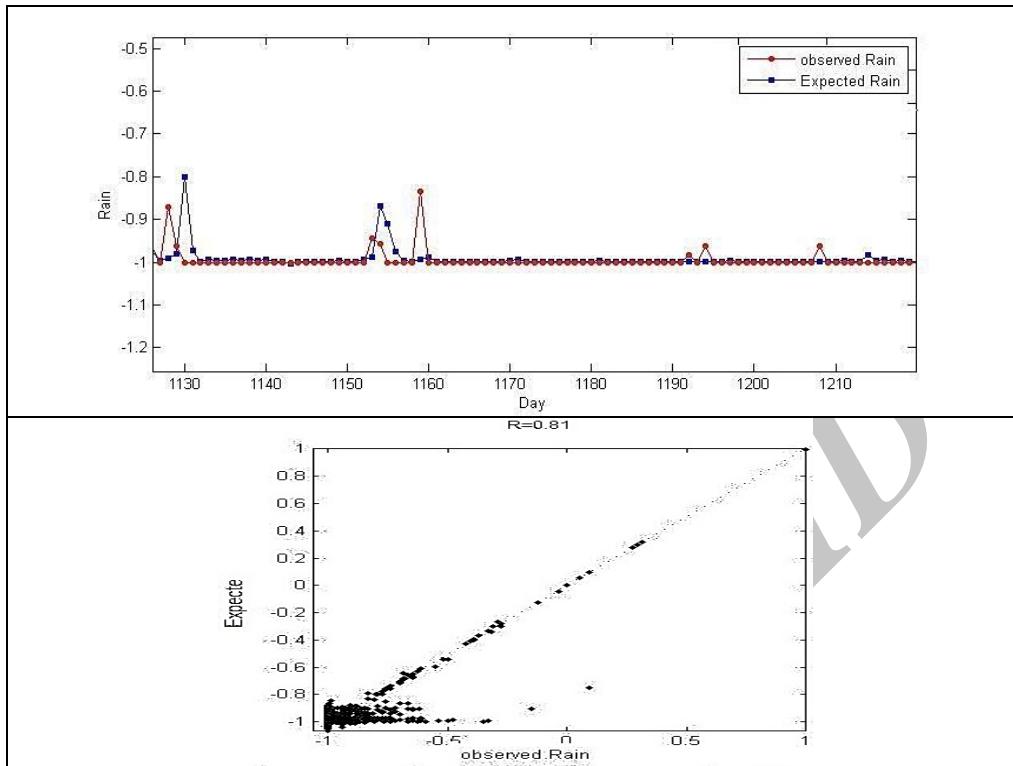
<sup>2</sup> - Observed



شکل ۵: مقایسه نتایج شبکه عصبی (Expected)، و داده‌های واقعی (Observed)، در مدل NARX42 کرمان و ضریب همبستگی بین آنها  
مأخذ: نگارندگان، ۱۳۹۲



شکل ۶: مقایسه نتایج شبکه عصبی (Expected)، و داده‌های واقعی (Observed)، در مدل NARX42 بافت و ضریب همبستگی بین آنها  
مأخذ: نگارندگان، ۱۳۹۲



شکل ۷: مقایسه نتایج شبکه عصبی (Expected)، و داده‌های واقعی (Observed)، در مدل NARX42 میانده جیرفت و ضریب همبستگی بین آنها، مأخذ: تکارندگان، ۱۳۹۲؛

### نتیجه‌گیری

- شبکه عصبی NARX حتی با داشتن متغیرهای کم، از خروجی با درجه خطای بسیار کم و دقّت بالا برخوردار است. بنابراین در بعضی از ایستگاه‌های ایران که تمام متغیرهای هوا را ندارند، این شبکه به خوبی می‌تواند به پیش‌بینی بارش بپردازد؛
- کمترین خطای NARX در ایستگاه جیرفت می‌باشد. کارایی بالا نسبت به دو ایستگاه دیگر، نشان می‌دهد که تخمین مدل دینامیکی NARX در آب و هوایی که بارش‌ها از شدت زیاد و رگباری و دارای خاصیت دینامیکی می‌باشند، از توانمندی بالایی برخوردار است؛
- شبکه‌های NARX، جزء شبکه‌های عصبی دینامیکی که دارای یک لینک پویا هستند، می‌باشند. این شبکه، دارای عملکرد مناسبی در تخمین فرایندهایی که نامنظم و آشوبی هستند، می‌باشند و قادرند که با دقّت کافی به تخمین بارش بپردازنند؛
- شبکه‌های MLP، جزء شبکه‌های عصبی هستند که کاربرد زیادی دارند، این شبکه‌ها در مدل‌سازی فرآیندها به کار برده می‌شوند. در این پژوهش در ایستگاه کرمان از خطای کمتری برخوردار بوده است. دینامیکی بودن و افت و خیز زیاد، دقّت این شبکه را پایین می‌آورد؛

- مرحله بهینه یابی و تنظیم پارامترهای مربوط به معماری ساختار مناسب شبکه‌های مورد استفاده به زمان زیادی نیاز دارد که با روش سعی و خطا به دست می‌آید؛
- در هر سه ایستگاه، رطوبت نسبی و پارامترهای مربوط به دما، در بهبود کارایی شبکه‌ها نقش بسزایی دارد. به طوری که ترکیب عامل رطوبت نسبی با بقیه پارامترها، میزان خطا را کاهش می‌دهد. به طور کلی، می‌توان بیان داشت که با افزایش میزان ورودی‌های مؤثر، کارایی شبکه‌های عصبی بهبود پیدا می‌کند؛
- توصیه می‌گردد سازمان‌های مربوط به منابع آب، از نتایج پیش‌بینی و مدل‌سازی فرایند بارش توسط شبکه بهینه این پژوهش، برای برنامه‌ریزی جهت جلوگیری از خسارات احتمالی سیل یا خشک‌سالی استفاده نمایند.

## منابع

- ۱- افخمی، ح.، دستورانی، م.ت.، ملکی نژاد، م.ج.، مبین، م.ج.، (۱۳۸۹): بررسی تأثیر عناصر اقلیمی بر افزایش دقّت روش شبکه عصبی مصنوعی در پیش‌بینی خشک‌سالی منطقه یزد، علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، شماره ۵۱، ۱۶۹. .۱۵۸
- ۲- ازدرپور، م. (۱۳۸۷): پیش‌بینی رابطه بارش رواناب به روش شبکه عصبی مصنوعی در حوضه آبریز رودخانه اعظم هرات، پایان نامه کارشناسی ارشد دانشگاه یزد، دانشکده علوم انسانی، ۱۰۰-۱.
- ۳- بهارلو، ر.، (۱۳۸۸): پیش‌بینی سری زمانی با وابستگی‌های دراز مدت با استفاده از شبکه عصبی بازگشتی NARX، دوازدهمین کنفرانس دانشجویی مهندسی برق، ص ۱۶.
- ۴- حلیان، ا.م.، (۱۳۸۸): پیش‌آگاهی و برآورد بارش بزد با استفاده از شبکه عصبی مصنوعی، نشریه تحقیقات کاربردی علوم جغرافیا، جلد ۱۱، شماره ۱۴، ص ۲۸-۸.
- ۵- خلیلی، ن؛ خداشناس، س، ر.، داوری، ک، موسوی بایگی، م.، (۱۳۸۹): پیش‌بینی بارش روزانه با شبکه‌های عصبی مصنوعی، مطالعه موردی: ایستگاه سینوپتیک مشهد، پژوهش‌های آبخیزداری، شماره ۸۹، ۱۵:۸.
- ۶- خسروی، م.، شکیبا، ه.، (۱۳۸۹): پیش‌بینی بارش با استفاده از شبکه‌های عصبی مصنوعی به منظور مدیریت سیل ایرانشهر، مجموعه مقالات چهارمین کنگره بین المللی جغرافی دانان جهان اسلام، ۲۱-۲.
- ۷- قلی‌زاده، م.ج. و دارند، م. (۱۳۸۸): پیش‌بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مورد تهران)، مجله پژوهش‌های جغرافیای طبیعی، ۷۱، ص ۶۳-۵۱.

- 8- Ardalani, A., Zolfaghari, S., (2010): "Chaotic Time Series Prediction With Residual Analysis Method Using Hybrid Elman–NARX Neural Networks" Neurocomputing 73, 2540–2553.
- 9- Diaconescu, E., (2008): "The Use of NARX Neural Networks to Predict Chaotic Time Series", Wseas Transactions on Computer Research, pp, 182-191.
- 10- Hall, T., Brooks, H.E., Doswell, C. A. (1999): "Precipitation Forecasting Using a Neural Network", Weather and Forecasting, No. 144, 338-345.

- 11- Hung, N. Q. Babel, Weesakul, M. S. S. and Tripathi N. K., (2008): "An Artificial Neural Network Model For Rainfall Forecasting in Bangkok, Thailand, Hydrol", Earth Syst. Sci. Discuss., 5. 183–218.
- 12- Imran, Maqsood, M .Riaz Khan, Ajith. A.(2004): "An Ensemble of Neural Networks for Weather Forecasting", Neural Computing & Applications, Vol 13, (2),
- 13- Maria. J., P., Guilherme A. B, (2008): "Long-Term Time Series Prediction with The NARX Network: An Empirical Evaluation", Department of Teleinformatics Engineering, Federal University of Ceara, Av. Mister Hull, S/N,CP 6005, CEP 60, Fortaleza-CE, Brazil,pp.455-760
- 14- Maria. J., P. and Guilherme A. B, (2008): "Multistep-Ahead Prediction of Rainfall Precipitation Using the NARX Network", Federal University of Ceara, Department of Teleinformatics Engineering, Av. Mister Hull, S/N, CP 6005, CEP 60, Fortaleza, Ceara, Brazil. Pp 624-633.
- 15- Shamseldin, A. Y., Connor, K. M., (2001): "A Non-Linear Neural Network Technique for Updating of River flow Forecasts", Hydrology and Earth System Sciences, 5(4), 577–597.
- 16- Santhanam, T., and Subhajini, A.C., (2011): "An Efficient Weather Forecasting System using Radial Basis Function Neural Network", Journal of Computer Science 7 (7): 962-966.
- 17- Siegelmann, H. T., Horne, B. G., and Lee Giles, C., Member, S. (1997): "Computational Capabilities of Recurrent NARX Neural Networks", IEEE Transactions on Systems, Man, and Cybernetics—Part B: Vol. 27, No. 2, pp. 209-215.
- 18- Siti, H. A., and Wibowo, A., (2011): "Neural Networks Based Nonlinear Time Series Regression for Water Level Forecasting of Dungun River", Department of Modeling and Industrial Computing Faculty Computer Science and Information Systems, University Teknologi Malaysia (UTM), Johor Bahru, Johor, 81310, Malaysia, pp.1506-1513.
- 19- Trafalis, TB .White, A., Santosa, B., Richmar MB. (2005): Dataming Techniques For Improved WSR-80. Rainfall Estimation.Computers in Industrail Engineering, No. 45. pp.775: 786
- 20- Zemouri.R, Gouriveau. R, Zerhouni. N., (2010): "Defining and Applying Prediction Performance Metrics on Arecurrent NARX Time Series Model", Neurocomputing 73, 2506–2521.