

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

کمال امیدوار

استاد گروه اقلیم شناسی، دانشگاه یزد، ایران

معصومه نبوی زاده*

کارشناس ارشد اقلیم شناسی، دانشگاه یزد، ایران

میثم ثمره قاسم

کارشناس ارشد هوش مصنوعی، دانشگاه باهنر، ایران

تاریخ پذیرش: ۱۳۹۴/۴/۱

تاریخ دریافت: ۱۳۹۳/۱۲/۱۷

چکیده

بارش یکی از پارامترهای مهم اقلیم شناسی و سایر علوم جوی که از اهمیت والایی در حیات بشر برخوردار است. در سال های اخیر، سیل و خشک سالی خسارت های فراوانی را در بسیاری از مناطق جهان در پی داشته است. پیش بینی بارش در مدیریت و هشدار این معضلات نقش مهمی بر عهده دارد. امروزه شبکه های عصبی مصنوعی از جمله روش های نوین می باشد که برای تخمین و پیش بینی پارامترها با استفاده از ارتباط ذاتی بین داده ها توسعه یافته است. هدف این پژوهش، ارزیابی دقت شبکه عصبی بازگشتی نارکس در پیش بینی بارش روزانه می باشد که با استفاده از آمار روزانه هواشناسی ایستگاه های کرمان، بافت و میانده جیرفت، طی دوره مشترک آماری ۲۳ ساله (۲۰۱۲-۱۹۸۹)، می باشد به منظور مقایسه به آموزش شبکه های عصبی مصنوعی با ساختار پرسپترون چند لایه و شبکه عصبی بازگشتی نارکس پرداخته شد. عوامل اقلیمی مؤثر در بارش به عنوان ورودی های شبکه های عصبی مصنوعی و بارش روزانه به عنوان خروجی شبکه در نظر گرفته شد. آمارهای میانگین مربع ها خطا (MSE) و ضریب همبستگی (R)، به منظور ارزیابی روش های بکار برده شده، استفاده گردید. نتایج نشان داد که مدل ترکیبی ۴۲، بر پایه قانون آموزش لونیبرگ مارکوات و تابع محرک سیگموئید با همه پارامترهای هواشناسی در هر سه ایستگاه از دقت قابل قبولی برخوردار است. همچنین مشخص شد که مدل های مطلوب شبکه عصبی مصنوعی در حالت تغییرات افزایشی نسبت به رطوبت نسبی، دارای بیشترین حساسیت هستند.

واژگان کلیدی: پیش بینی 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 اتفافی‌ترین پدیده‌های طبیعی می‌باشد. در واقع تأثیر عوامل محسوس و یا غیر محسوس آن‌چنان 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 (قلی زاده، ۱۳۸۸: ۵۳).

در این بررسی سعی شده است به ارزیابی دقت خروجی شبکه‌های عصبی بازگشتی نارکس^۱ در تخمین بارش روزانه در ایستگاه 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 خطا را به تأخیر انداخت. در این مقاله، توانایی یادگیری و فراگیر 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 بپردازند و پژوهش‌های بسیاری در این زمینه انجام داده‌اند که در ادامه برخی از آنها بیان می‌شود: هال و همکاران^۲ (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^۳ (۲۰۰۲: ۷۷۵)، استفاده از شبکه‌های عصبی مصنوعی به پیش بینی بارش پرداختند. ایشان از داده‌های بارش رادار به عنوان داده‌های ورودی شبکه استفاده کردند و به این نتیجه رسیدند که شبکه‌های عصبی دقت بیشتری نسبت به سایر روش‌ها دارند. سیگلومن^۴ (۱۹۹۷: ۲۰۸)، محاسبه‌ای برای توانایی شبکه عصبی نارکس انجام داده است و به این نتیجه رسیده است که نارکس، نسبت به شبکه‌های عصبی دیگر

¹ - Nonlinear Autoregressive External

² - Hall et. al

³ -Trafalis

⁴ - Siegelmann

به علت پویا بودن می‌تواند سری‌های زمانی را با وابستگی‌های دراز مدت پیش بینی کند. ماریا و همکاران^۱ (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 برزیل 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^۲ (۲۰۰۸: ۱۸۲)، 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^۳ (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 نتیجه رسیده است مدل‌های خود برگشتی غیر خطی با ورودی‌های برونزاد (نارکس) حساسیت کمتری به وابستگی‌های دراز مدت دارند و می‌توان میرا شدن گرادیان خطا را در آنها به تأخیر انداخت و نارکس توانایی یادگیری و فراگیر شدن بهتر را دارد.

پژوهش‌های مشابه دیگری از جمله (اژدرپور، ۱۳۸۷: ۴۵)، (حلییان، ۱۳۸۸: ۱۲)، (اردلانی و ذوالفقاری ۲۰۱۰: ۲۵۴۰)، (سیتی و ویوو^۴، ۲۰۱۲: ۱۵۰۶)، (سان تانم^۵ و همکاران، ۲۰۱۱: 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، بافت و میانه 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: $(T_{mean}, T_{max}, T_{min}, DD, FF, RH)$

¹ - Maria et.al

² - Diaconescu et.al

³ - Zemouri et.al

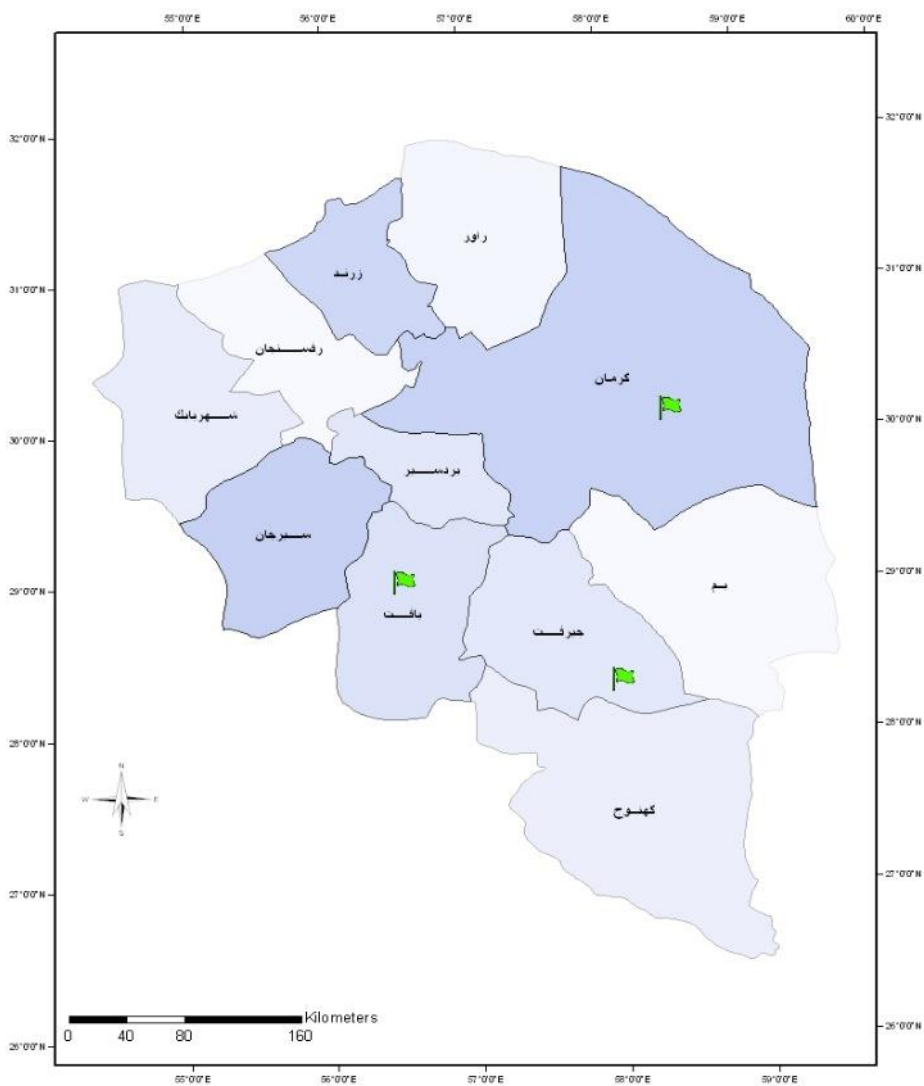
⁴ - Siti Hajar & Antoni

⁵ -Santhanam et.al

P_{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 تهیه و به شبکه‌ها معرفی گردید (جدول ۱). در نهایت دقت 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.

منطقه مورد مطالعه

- ایستگاه‌های مورد مطالعه در این پژوهش شهر کرمان، بافت و میانه جیرفت می‌باشد (شکل ۱).
- **کرمان:** ۱۷۵۳/۸ متر از سطح دریا و متوسط بارندگی در طی سال‌های مورد مطالعه (۲۰۱۲-۱۹۸۹)، ۱۳۱/۲۶ میلی‌متر برآورد شده 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 (۲۰۱۲-۱۹۸۹)، ۲۴۴/۳ میلی‌متر برآورد شده است. در این دوره، انحراف معیار بارندگی سالانه ۹۰/۸۷ و ضریب تغییرات برابر با ۳۷/۱۹ درصد بوده است؛
 - **جیرفت:** دارای ارتفاع ۶۰۱ متر، جزو مناطق گرمسیری در استان محسوب می‌شود. متوسط بارندگی در طی سال‌های مورد مطالعه (۲۰۱۲-۱۹۸۹)، ۱۷۴/۲۶ میلی‌متر برآورد شده 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 (مأخذ: نگارندگان ۱۳۹۲)

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

داده‌های پژوهش

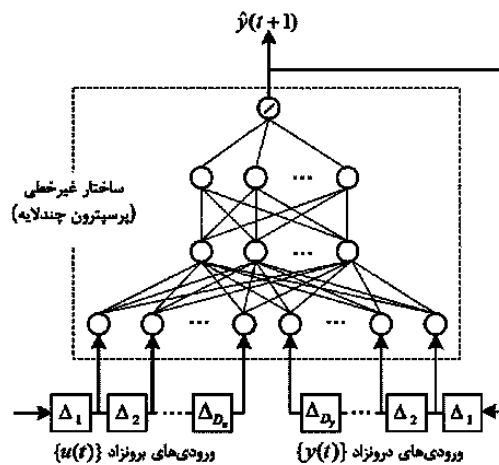
اساس شبکه‌های عصبی مصنوعی در واقع شبیه سازی و مدل سازی تفکر مغز انسان از طریق سلول‌های عصبی می‌باشد. هر سلول عصبی به عنوان یک واحد پردازشگر عددی عمل می‌کند. نرون‌های شبکه با هم در ارتباط بوده و به صورت موازی کار می‌کنند (حلیبان، ۱۳۸۸: ۱۰).

– شبکه عصبی بازگشتی نارکس

بر خلاف شبکه‌های انتشار مستقیم مانند پرسپترون چند لایه، در شبکه‌های بازگشتی از نرون‌های لایه‌های میانی یا لایه خروجی به لایه‌های قبل، یا همان لایه، پس-خورد 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 دست‌های از سامانه‌های خود برگشتی غیرخطی گسسته در زمان است که علاوه بر ورودی‌های درون‌زاد، دارای ورودی‌های برون‌زاد 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 این جا $\{y(t)\}$ ، سری زمانی مورد علاقه است که باید پیش بینی 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 برون‌زاد هستند که توسط یک خط تأخیر با مرتبه D_u تولید می‌شوند. به طور مشابه $y(t), \dots, y(t-D_y)$ ورودی‌های درون‌زا 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. ε_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 برون‌زاد (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^۱ ۱۰۰۰ بار انجام گرفت. میزان نرون‌های لایه مخفی متناسب با n2 طراحی شد که n متناسب با تعداد عوامل ورودی به مدل می‌باشد. برای ۴۲ مدل ترکیبی، میانگین مربع‌ها خطا 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 می‌باشند. 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 وابسته بارش در ایستگاه کرمان

	حد‌اقل دما	حداکثر دما	میانگین دما	رطوبت نسبی	سرعت باد	جهت باد	میانگین فشار
ضریب پیرسون	-.۰۵**	-.۰۲۲۶**	-.۰۱۴۹**	.۰۴۳۲**	.۰۰۵۱**	.۰۰۵۲**	-.۰۰۱۶
سطح معناداری۰/۱۲۷
تعداد	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵

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

	حد‌اقل دما	حداکثر دما	میانگین دما	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 معناداری۰/۶۸۹	.۰/۰۰۵	.
تعداد	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵

¹ -Epoch

جدول ۴: میزان همبستگی بین عوامل اقلیمی با متغیر وابسته بارش در ایستگاه جیرفت

	حد اقل دما	حداکثر دما	میانگین دما	رطوبت نسبی	سرعت باد	جهت باد	میانگین فشار
ضریب پیرسون	**-/۰.۸۲	**./۲۰۰	**-/۰.۳۲	**./۳۱۵	۰./۰.۷۹	**-/۰.۴۱	**-/۰.۴۸
سطح معناداری	۰	۰	۰./۰.۰۳	۰	۰	۰	۰
تعداد	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵	۸۵۸۵

- تعیین متغیرهای ورودی

یکی از مهم‌ترین گام‌ها در پیشبرد رضایت بخش مدل پیش بینی 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 خطا 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 خطا 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 ۰/۷ 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 خطا، مدل بهینه را مشخص می‌کند.

الف) نتایج شبکه عصبی NARX در ایستگاه کرمان

مدل‌های شماره ۳۷، ۳۸، ۳۹، ۴۰، ۴۲، ترکیب‌هایی بودند که نسبت به بقیه، همبستگی بالای ۰/۷ و دقت 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 دقت بالاتری نسبت به سایر ساختارها برخوردار است. این ترکیب شامل: کمیته 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 دقت بالایی داشته‌اند، رطوبت نسبی در تخمین بارش از مهمترین عوامل تأثیرگذار بوده است و کمترین تأثیر گذار 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، ۲۷، ۲۵، ۳۴، ۳۷، نسبت به ترکیب‌های قبل و بعد این مدل‌ها است.

نتایج، بیانگر این واقعیت 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 دقت بالاتری نسبت به سایر ساختارها برخوردار است (جدول ۵).

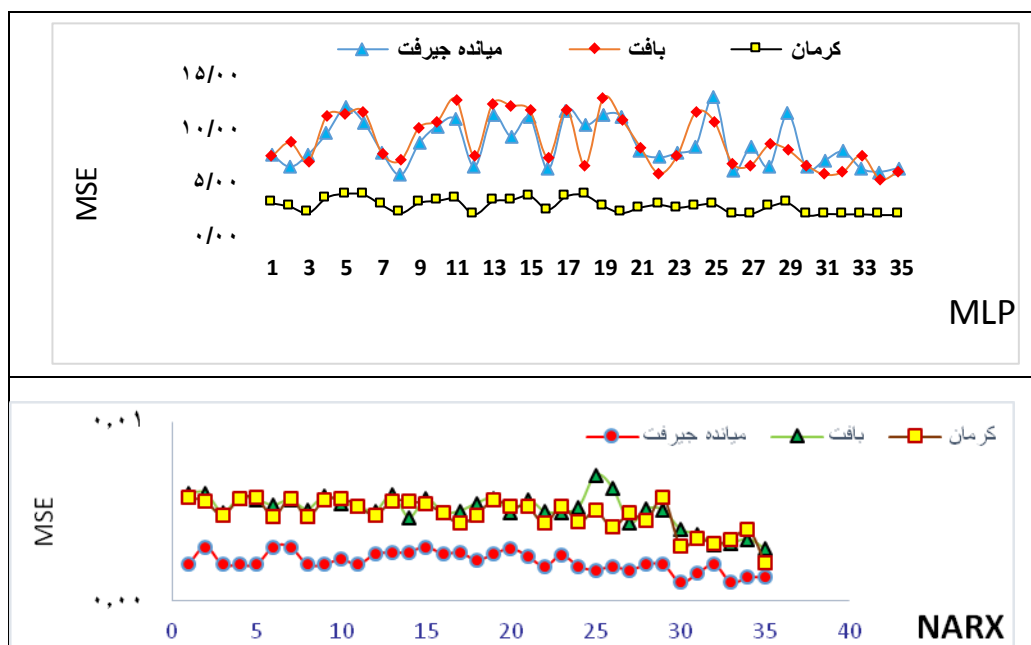
ج) نتایج شبکه عصبی NARX در ایستگاه جیرفت

مدل‌های شماره ۳۲، ۳۴، ۳۷، ۳۸، ۴۰، ۴۱، ۴۲، ترکیب‌هایی بودند که نسبت به بقیه، همبستگی بالای ۰/۷ و دقت بالایی داشته‌اند، کمیته و پیشینه 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 دقت 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 خاصیت دینامیکی و تغییر پذیری بالایی باشند، از توانمندی بالایی برخوردار است. در این‌جا استناد به پژوهشی که ماریا و همکاران (۲۰۰۸: ۶۲۴) در سواحل جنوب شرقی برزیل انجام داده است، به این نتیجه رسیده است، چون آب و هوای این سواحل از خاصیت دینامیکی و تغییر پذیری 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 میانه جیرفت نشانه این امر است (شکل‌های ۳، ۴) و (جدول ۵).

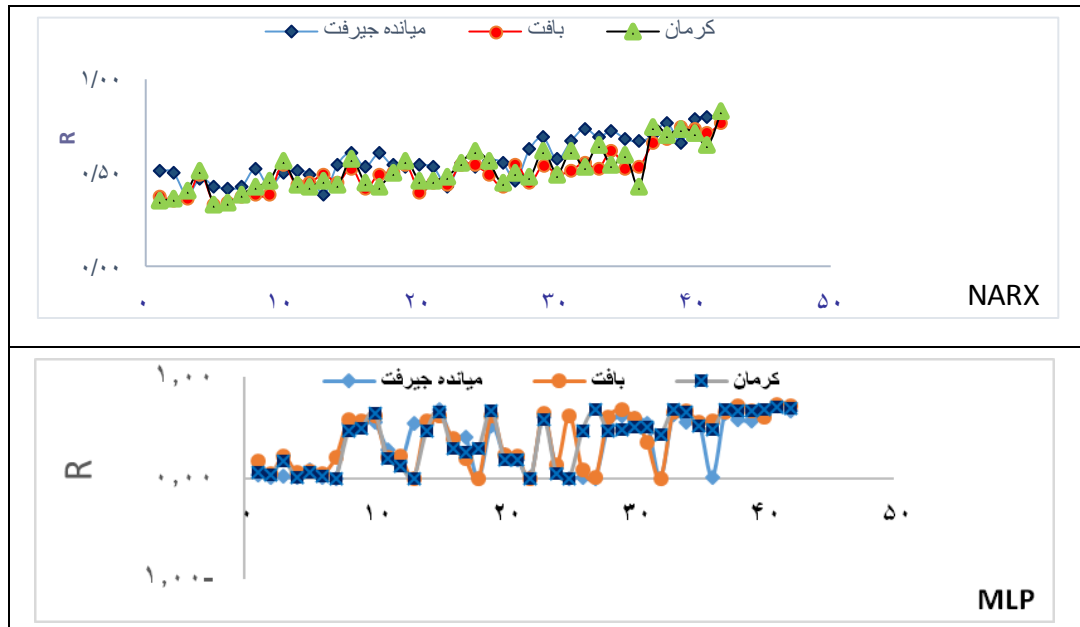
شبکه عصبی پرسپترون در ایستگاه‌های مورد مطالعه

برای درک بهتر از دقت شبکه نارکس، مقایسه‌ای بین خروجی NARX و MLP انجام گرفت که خطای زیاد MLP نشان از دقت پایین خروجی این نوع شبکه عصبی مصنوعی در پیش بینی فرایند اتفّاقی بارش می‌باشد. بهترین مدل، MLP41، با ترکیب کمینه دما، پیشینه 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 دقت 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 اخیز 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 برازش یا همبستگی کسب شده توسط شبکه عصبی: MLP و NARX

مأخذ: نگارندگان، ۱۳۹۲



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

مأخذ: نگارندگان، ۱۳۹۲

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

شماره 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	۰/۰۲	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	۰/۰۰۲	۱۱/۲
۷	۰/۳۸	۰/۰۰۵۹	*	۳/۳	۰/۳۷	۰/۰۰۶۱	۲/۰۴	۱۰/۹	۰/۴۳	۰/۰۰۳	*	۸/۶
۸	۰/۴۳	۰/۰۰۶	۰/۴۶	۳/۱	۰/۳۸	۰/۰۰۶	۰/۵۷	۷/۵	۰/۵۲	۰/۰۰۲	۰/۵۴	۷/۷
۹	۰/۴۶	۰/۰۰۵۶	۰/۴۹	۲/۷۱	۰/۳۸	۰/۰۰۶	۰/۵۷	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

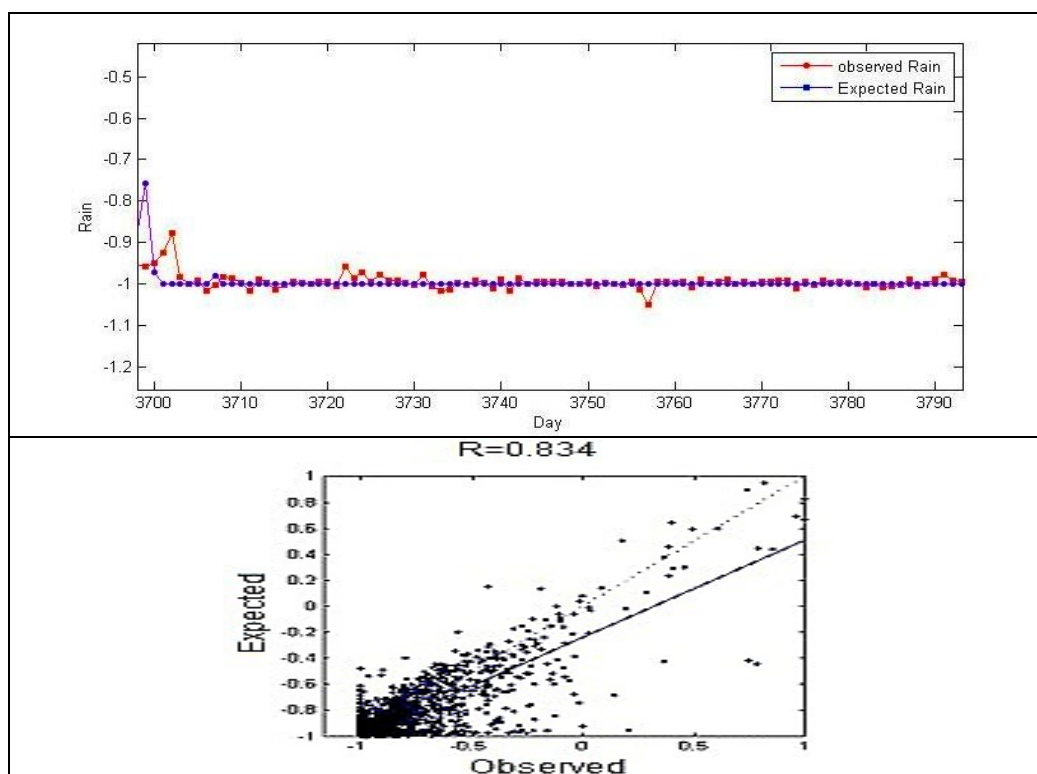
ادامه جدول												
۱۶	۰/۴۵	۰/۰۰۵۶	۰/۲۹	۳/۱	۰/۴۱	۰/۰۰۵۸	۰/۳۹	۱۰/۲	۰/۵۳	۰/۰۰۲	۰/۳۸	۸/۷
۱۷	۰/۴۳	۰/۰۰۶	۰/۲۵	۳/۲	۰/۵	۰/۰۰۵۴	۰/۱۹	۱۰/۸	۰/۶	۰/۰۰۲	۰/۴۱	۱۰/۳
۱۸	۰/۵	۰/۰۰۵۲	۰/۲۹	۳/۴	۰/۵	۰/۰۰۵۳	*	۱۲/۹	۰/۵۴	۰/۰۰۲	*	۱۰/۹
۱۹	۰/۵۶	۰/۰۰۴۷	۰/۶۷	۱/۹۹	۰/۵۴	۰/۰۰۴۹	۰/۶۱	۷/۵	۰/۵۳	۰/۰۰۳	۰/۵۲	۶/۵
۲۰	۰/۴۵	۰/۰۰۵۵	۰/۱۹	۳/۲۱	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	۰/۰۰۳	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	۰/۵۲	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

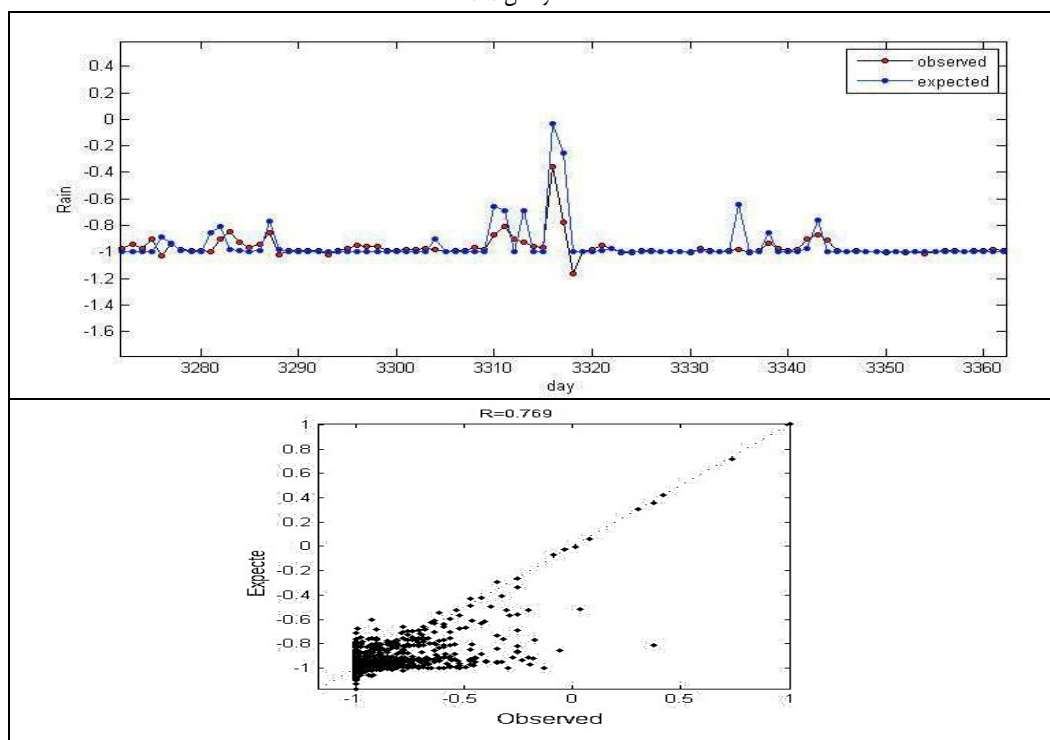
همپوشانی بین خروجی شبکه همان داده‌های پیش بینی شده^۱ و داده‌های واقعی^۲، NARX، در سه ایستگاه نامبرده شبیه سازی شده‌اند (بازه زمانی روزهای که در (شکل‌های ۵، ۶، ۷)، وجود دارد به علت کثرت داده‌ها گزینشی می‌باشد). همپوشانی بین داده‌های پیش بینی شده و داده‌های واقعی، شبکه عصبی NARX، از دقت نسبتاً بالایی برخوردار است (شکل‌های ۵، ۶، ۷).

¹ - Expected

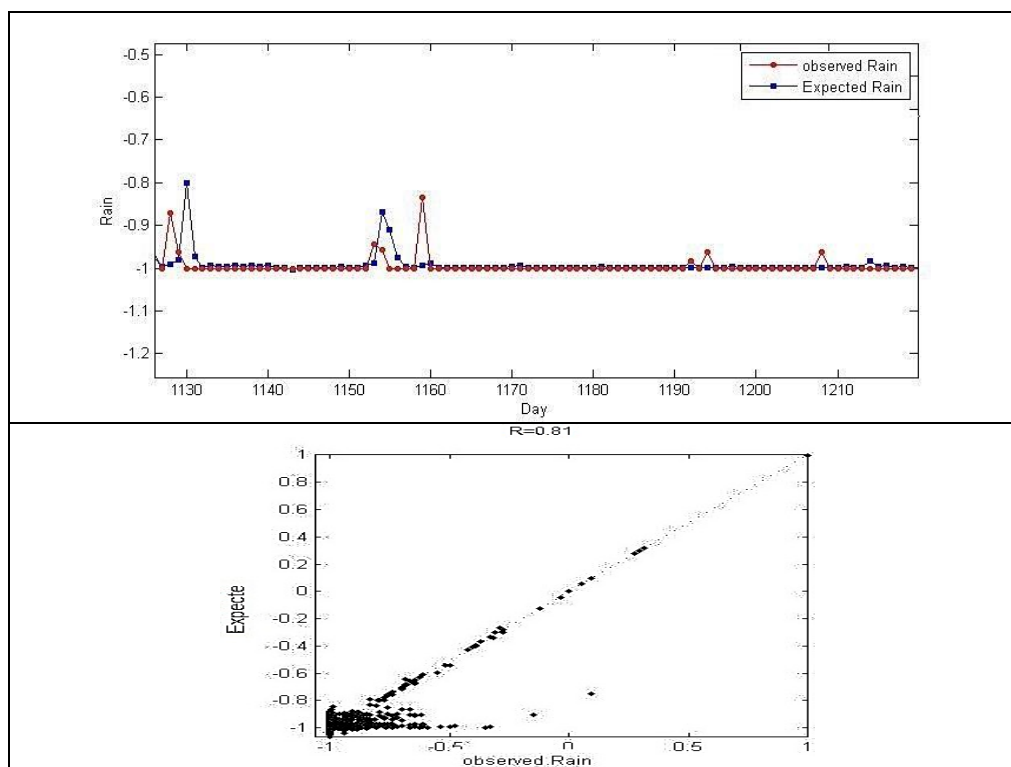
² - Observed



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 جبرفت و ضرب همبستگی بین آنها، مأخذ: نگارندگان، ۱۳۹۲

نتیجه گیری

- شبکه عصبی NARX حتی با داشتن متغیرهای کم، از خروجی با درجه خطای بسیار کم و دقت بالا برخوردار است. بنابراین در بعضی از ایستگاه‌های ایران که تمام متغیرهای هوا را ندارند، این شبکه به خوبی می‌تواند به پیش بینی بارش بپردازد؛
- کمترین خطای NARX در ایستگاه جبرفت 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 دقت کافی به تخمین بارش بپردازند؛
- شبکه‌های MLP، جزء شبکه‌های عصبی هستند که کاربرد زیادی دارند، این شبکه‌ها در مدل‌سازی فرایندها به کار برده می‌شوند. در این پژوهش در ایستگاه کرمان از خطای کمتری برخوردار بوده است. دینامیکی بودن و افت و خیز زیاد، دقت 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، ح.، مبین، م.ح.، (۱۳۸۹): بررسی تأثیر عناصر اقلیمی بر افزایش دقت روش شبکه عصبی مصنوعی در پیش بینی خشک سالی منطقه یزد، علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک، شماره ۱۶۹، ۵۱-۱۵۸.
- ۲- اژدرپور، م. (۱۳۸۷): پیش بینی رابطه بارش رواناب به روش شبکه عصبی مصنوعی در حوضه آبریز رودخانه اعظم هرات، پایان نامه کارشناسی ارشد دانشگاه یزد، دانشکده علوم انسانی، ۱-۱۰۰.
- ۳- بهارلو، ر.، (۱۳۸۸): پیش بینی سری زمانی با وابستگی‌های دراز مدّت با استفاده از شبکه عصبی بازگشتی NARX، دوازدهمین کنفرانس دانشجویی مهندسی برق، ص ۱:۶.
- ۴- حلبیان، ا.م.، (۱۳۸۸): پیش آگاهی و برآورد بارش یزد 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): پیش بینی بارش روزانه با شبکه‌های عصبی مصنوعی، مطالعه موردی: ایستگاه سینوپتیک مشهد، پژوهش‌های آبخیزداری، شماره ۸۹، ص ۱۵:۸.
- ۶- خسروی م.، شکیبیا، ه.، (۱۳۸۹): پیش بینی 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- قلی زاده م.ح. و دارنده، م. (۱۳۸۸): پیش بینی بارش ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مورد تهران)، مجله پژوهش‌های جغرافیای طبیعی، ۷۱، صص 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 Cear'a, Department of Teleinformatics Engineering, Av. Mister Hull, S/N, CP 6005, CEP 60, Fortaleza, Cear'a, 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.

