

یادداشت فنی

ارزیابی کارایی مدل‌های شبکه عصبی در پیش‌بینی وقایع خشکسالی در ایستگاه یزد

حمیده افخمی^{۱*} و محمدتقی دستورانی^۲

چکیده

امروزه مدل‌های مختلف هوش محاسباتی توانایی بالایی را در پیش‌بینی سری‌های زمانی از خود نشان داده‌اند. هدف اصلی این مقاله ارزیابی کارایی شش مدل شبکه عصبی مصنوعی در شبیه‌سازی بارش و به دنبال آن خشکسالی در ایستگاه یزد است تا مدل با بالاترین کارایی شناسایی شود. برای ارزیابی کارایی مدل نیز از دو پارامتر ریشه مربعات خطا و ضریب اطمینان استفاده شد. نتایج نشان دادند ساختارهای دینامیک شبکه عصبی شامل دو شبکه برگشتی و برگشتی با تأخیر زمانی به ترتیب با ضریب کارایی ۰/۷۷ و ۰/۷۸ در پیش‌بینی‌ها، کارایی بهتری را از خود نشان داده‌اند و در نهایت مدل برگشتی با تأخیر زمانی به عنوان مدل برتر شناسایی شد.

واژه‌های کلیدی: ایستگاه هواشناسی یزد، پیش‌بینی خشکسالی، شبکه عصبی مصنوعی، شبیه‌سازی.

ارجاع: افخمی ح. و دستورانی م. ت. ۱۳۹۳. ارزیابی کارایی مدل‌های شبکه عصبی در پیش‌بینی وقایع خشکسالی در ایستگاه یزد. مجله پژوهش آب ایران. ۲۰۹-۲۰۵: (۱۴) ۸.

۱- دانش‌آموخته کارشناسی ارشد آبخیزداری، دانشکده منابع طبیعی، دانشگاه یزد.

۲- دانشیار دانشکده منابع طبیعی و محیط زیست، دانشگاه فردوسی مشهد.

* نویسنده مسئول: hamide.afkhami@gmail.com

تاریخ پذیرش: ۱۳۹۱/۰۶/۰۸

تاریخ دریافت: ۱۳۸۹/۱۰/۰۸

مقدمه

امروزه تکنیک شبکه عصبی مصنوعی^۱ توانایی زیادی را در شبیه‌سازی و پیش‌بینی بارش و خشکسالی از میان انواع مدل‌های تجربی و غیرخطی از خود نشان داده است. (میشرا و همکاران، ۲۰۰۷) در زمینه کاربردهای شبکه عصبی مصنوعی می‌توان به نتایج پژوهش‌های (مینس و همکاران، ۱۹۹۶) و (هسو و همکاران، ۱۹۹۵) در ارتباط با مدل‌سازی بارش- رواناب اشاره کرد. همچنین در زمینه پیش‌بینی جریان رودخانه با مدل‌های شبکه عصبی می‌توان به نتایج موفقیت‌آمیز پژوهش‌های (کارونایتی و همکاران، ۱۹۹۴)، (کومار و همکاران، ۲۰۰۴) و (دستورانی و رایت، ۱۳۸۲) اشاره کرد. کاربرد این روش در پیش‌بینی سیل در حوزه‌های فاقد آمار نیز موفق بوده است (دستورانی، ۲۰۰۳). همچنین پژوهش‌هایی در زمینه کاربرد هوش محاسباتی در شبیه‌سازی جریان‌های سیلابی انجام گرفت، مدل شبکه عصبی برگشتی^۲ نتایج درخشانی از خود نشان داد (دستورانی، ۱۳۸۶). در رابطه با خشکسالی نیز می‌توان به پژوهش‌های میشرا و دیسای (۲۰۰۵) در زمینه پیش‌بینی خشکسالی در حوضه کانسباتی هند با استفاده از مدل‌های آماری اشاره کرد. میشرا و دیسای (۲۰۰۶) برتری شبکه‌های عصبی مصنوعی در پیش‌بینی خشکسالی را نسبت به روش‌های آماری در همان حوزه نشان دادند. در پژوهش دیگری که توسط نامبردگان انجام شد نتایج پیش‌بینی خشکسالی با مدل‌های ترکیبی نتایج برتری را نسبت به دو روش آماری و شبکه عصبی مصنوعی دیگر داشت. (مرید و همکاران، ۲۰۰۷) نیز پیش‌بینی خشکسالی در استان تهران را با استفاده از شاخص خشکسالی مؤثر^۳ و به کارگیری شبکه‌های عصبی مصنوعی انجام دادند و به نتایج درخشانی دست یافتند.

در این پژوهش نیز کارایی مدل‌های شبکه عصبی مصنوعی در پیش‌بینی بارش و خشکسالی در ۱۲ ماه آینده بر این اساس شش نوع متفاوت از شبکه‌های عصبی مصنوعی ارزیابی و تجزیه و تحلیل شد.

مواد و روش‌ها

منطقه مورد مطالعه در این پژوهش ایستگاه سینوپتیک یزد با مختصات طول جغرافیایی ۱۷° ۵۴' و عرض جغرافیایی ۳۱° ۵۳' است. برای انجام این پژوهش ۶ مدل شبکه‌های عصبی استفاده شد که عبارتند از: پرسپترون چندلایه (MLP)^۴، شبکه‌های روبه‌جلو پیمانه‌ای (MNN)^۵، آنالیز مؤلفه اصلی (PCA)^۶، شبکه‌های المان (JN)^۷، شبکه‌های برگشتی (RN)^۸، شبکه‌های برگشتی با تأخیر زمانی (TLRN)^۹ است. داده‌های اقلیمی لازم در این پژوهش که استفاده شده است شامل آمار ماهانه بارش از سال ۱۳۸۴ است. در مرحله اول تنها ورودی به مدل بارش است که در شش مدل به‌عنوان ورودی معرفی شد و بارش یک سال بعد به‌عنوان خروجی پیش‌بینی شد. بعد از انتخاب دو مدل برتر ورودی دو مدل شامل ترکیبات مختلف از پارامترهای اقلیمی و خروجی نیز همان بارش یک سال بعد است. ترکیبات در این مرحله به‌صورت‌های مختلف شامل داده‌های خام بارش (P)، بارش نرمال (P_n)، شاخص بارش استاندارد (P_{spi})، بارش فصلی (P_{seasonal})، میانگین متحرک ۳ ساله بارش (P_{3y.ave}) همچنین پارامترهای اقلیمی شامل رطوبت نسبی (RH)، تبخیر (ER)، دمای حداکثر (T_{max}) و دمای حداقل (T_{min}) است. لازم به ذکر است نرم‌افزار مورد استفاده در این مقاله Neural Solution است.

در این مطالعه ۷۰ درصد داده‌ها، به‌عنوان داده‌های آموزشی، ۲۰ درصد داده‌ها برای آزمون و ۱۰ درصد برای اعتبارسنجی مدل استفاده شد. در تمام مدل‌ها، برای آموزش، بارش نرمال ماهانه به‌عنوان ورودی و همان داده‌ها با یک سال تأخیر به‌عنوان خروجی به شبکه معرفی شد. در کلیه مدل‌ها، در لایه مخفی و لایه خروجی سه تابع خطی^۹، تانژانت هیپربولیک^{۱۰} و سیگموئیدی^{۱۱} بررسی شد. داده‌های بارش که به‌صورت نرمال استفاده شد، مطابق معادله ۱ برآورد شد.

4- Multi Layer Perceptron (MLP)
5- Modular Neural Network (MNN)
6 -Principal Component Analysis (PCA)
7- Jordan/Elman Network (EN)
8- Time Lag Recurrent Network (TLRN)
9- Linear
10 -Tan hyperbolic
11 -Sigmoid

1- Artificial neural network
2 -Recurrent network
3 -Effective drought index

در این جدول‌ها نتایج بهترین شبیه‌سازی‌ها ارائه شده است. به عنوان مثال ترکیب‌های (P-Wd-ER-RH) و (P-Tmax) حالت‌هایی هستند که از بارش و سایر پارامترها استفاده شده است. در این حالت بهترین ضریب کارایی در مدل RN با ترکیب (P-Wd-ER-RH) معادل ۰/۶۳ حاصل شده است و بهترین ترکیب در مدل TLRN، (P-Tmax) با ضریب کارایی ۰/۶۷ است. همچنین ترکیب‌های ۳ و ۴ بهترین ترکیب‌ها با استفاده از شاخص بارش استاندارد در دو مدل است. ترکیب‌های شماره ۵ و ۶ بهترین ترکیب‌ها با استفاده از بارش نرمال، ترکیب‌های ۷ و ۸ بهترین ترکیب‌ها با استفاده از بارش فصلی و ترکیب‌های ۹ و ۱۰ بهترین ترکیب‌ها با استفاده از میانگین متحرک ۳ ساله و نرمال شده بارش در دو مدل RN و TLRN تشخیص داده شد. شکل‌های ۱ و ۲ مقایسه مقادیر پیش‌بینی شده و اندازه‌گیری شده را که دارای بالاترین ضریب کارایی هستند، در دو مدل RN و TLRN نمایش می‌دهد. همان‌گونه که از نمودارهای فوق نیز برمی‌آید مدل TLRN نسبت به مدل RN برتری دارد. استفاده از میانگین متحرک سه ساله بارش به همراه ترکیب‌های مختلف نتایج را تا حد زیادی بهبود بخشید. این نتایج نیز به‌خصوص در شبکه‌های TLRN کارایی مناسبی را از خود نشان داد، به طوری که در شبکه‌های TLRN ترکیب بارش-دمای ماکزیمم از بین ترکیبات مختلف با $R=0/95$ و $RMSE=0/06$ به‌عنوان بهترین ترکیب و شبکه TLRN به‌عنوان مطلوب‌ترین شبکه شناخته شد (شکل ۲). مناسب‌ترین ساختار ANN نیز ساختاری است که تعداد نرون‌های لایه مخفی معادل با دو برابر تعداد نرون‌های ورودی است.

$$X_n = \frac{X_O - X_{Min}}{X_{Max} - X_{Min}} \quad (1)$$

که در آن X_n و X_{On} داده‌های نرمال و داده‌های اولیه و X_{Max} و X_{Min} مقادیر حداقل و حداکثر داده‌ها است (افخمی، ۱۳۸۷).

معیارهای ارزیابی کارایی مدل‌ها

برای مقایسه مقادیر شبیه‌سازی شده با مقادیر واقعی از معیارهای آماری مانند ضریب کارایی^۱ و ریشه میانگین مربعات خطا^۲ استفاده شد (جدول ۱) و نحوه محاسبه این دو پارامتر در معادلات ۲ و ۳ نشان داده شده است. بدیهی است ترکیبی که بالاترین ضریب کارایی را داشته و میانگین مربعات خطای آن حداقل است به‌عنوان شبکه مطلوب طراحی شده انتخاب می‌شود.

$$RMSE = \sqrt{\left(\frac{1}{n} \sum_{i=1}^n [(O_i) - (P_i)]^2 \right)} \quad (2)$$

که O_i و P_i مقادیر مربوط به داده‌های مشاهداتی و شبیه‌سازی شده و n تعداد کل وقایع را نشان می‌دهد.

$$R = 1 - \left[\frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum (O_i - \bar{O})^2} \right] \quad (3)$$

که O_i و P_i مقادیر مربوط به داده‌های مشاهداتی و پیش‌بینی شده و $\bar{O}$ میانگین داده‌های مشاهداتی است.

نتایج و بحث

نتایج این مطالعه بر این اساس خروجی حاصل از شش نوع شبکه‌های عصبی مصنوعی است که در جدول ۱ ارائه شده است. شبیه‌سازی‌هایی که در این مرحله انجام گرفت بیشتر برای انتخاب چند مدل برتر انجام شد دو مدل RN و TLRN در شبیه‌سازی بارش و خشکسالی نسبت به سایر مدل‌ها برتری داشته و توابع تانژانت هایپربولیک و سیگموئید در لایه مخفی و تابع تانژانت هایپربولیک در لایه خروجی به عنوان بهترین توابع شناخته شد (جدول ۱). نتایج مرحله دوم نیز برای تعیین مهم‌ترین پارامترهای اقلیمی مؤثر و در نهایت مدلی است که کارایی بالاتری را در شبیه‌سازی نشان می‌دهد (جدول ۲).

1- Efficiency Coefficient

2- Root Mean Squared Error (RMSE)

جدول ۱- مقایسه مدل‌های مورد بررسی در شبیه‌سازی

نوع مدل	r	RMSE	Hidden function	Output function
پرسپترون چندلایه	۰/۴۰	۰/۱۱	Tan hyperbolic	Tan hyperbolic
شبکه‌های المان	۰/۴۰	۰/۱۳	sigmoid	Tan hyperbolic
شبکه‌های پیمانه‌ای	۰/۴۰	۰/۱	Tan hyperbolic	Tan hyperbolic
آنالیز مؤلفه اصلی	۰/۴۱	۰/۱	Tan hyperbolic	Tan hyperbolic
شبکه‌های برگشتی	۰/۶۲	۰/۰۹	sigmoid	Tan hyperbolic
شبکه‌های برگشتی تأخیری	۰/۶۵	۰/۰۹	Tan hyperbolic	Tan hyperbolic


جدول ۲- نتایج حاصل برای ترکیبات مختلف ورودی در دو مدل RN و TLRN

ترکیب	مدل	r	RMSE
P-Wd-ER-RH	RN	۰/۶۳	۸/۷۷
P-Tmax	TLRN	۰/۶۷	۵/۴
P _{SPI}	RN	۰/۵۵	۰/۶۷
P _{SPI}	TLRN	۰/۶۰	۰/۶۰
P _{SPI}	TLRN	۰/۶۰	۰/۶۰
Pn-RH	RN	۰/۶۷	۰/۰۷
Pn-Tmax-RH	TLRN	۰/۶۷	۰/۰۸
Psesonal-Tmax-Ws-Wd-RH	TLRN	۰/۶۷	۰/۰۸
Psesonal-Tmax-Ws-Wd-RH	TLRN	۰/۷۸	۰/۰۸
P3y.ave	RN	۰/۷۷	۰/۰۸


نتیجه‌گیری

نتایج حاصل از این مطالعه، کارایی مناسب دو ساختار دینامیک (شبکه برگشتی و شبکه‌های برگشتی با تأخیر زمانی) را در پیش‌بینی بارش و به دنبال آن خشکسالی در ایستگاه سینوپتیک یزد را نشان می‌دهد. سایر شبکه‌های به کار گرفته شده توانایی پیش‌بینی سری داده‌هایی که با زمان تغییر می‌کنند را با دقت کافی ندارند. با توجه به مقادیر ضریب کارایی در ترکیب‌های مختلف، شبکه‌های برگشتی با تأخیر زمانی در اکثر موارد نسبت به شبکه‌های برگشتی دارای برتری بوده‌اند.

نتایج این پژوهش با نتایج پژوهش دستورانی که در رابطه با پیش‌بینی و شبیه‌سازی به هنگام جریان‌های سیلابی انجام گرفته، مقایسه شد. در پژوهش نامبرده شبکه برگشتی بهترین شبیه‌سازی با بالاترین ضریب کارایی را نشان داد (دستورانی، ۱۳۸۶). در این پژوهش با وجود برتری دو شبکه برگشتی و برگشتی با تأخیر زمانی در نهایت برترین کارایی مربوط به شبکه‌های برگشتی با تأخیر زمانی بودند.



شکل ۱- مقایسه مقادیر پیش‌بینی شده و اندازه‌گیری شده در ترکیب شماره ۹ در شبکه‌های RN



شکل ۲- مقایسه مقادیر پیش‌بینی شده و اندازه‌گیری شده در ترکیب شماره ۱۰ در شبکه‌های TLRN

منابع

۱. افخمی ح. ۱۳۸۷. بررسی و پیش‌بینی وضعیت خشکسالی در منطقه یزد با استفاده از تکنیک شبکه‌های عصبی مصنوعی. پایان‌نامه کارشناسی ارشد، دانشگاه یزد. ۲۳۶ ص.
۲. دستورانی م. ت. و رایت ن. ج. ۱۳۸۲. بهینه‌سازی نتایج حاصل از یک مدل هیدرودینامیکی در پیش‌بینی جریان رودخانه توسط سیستم عصبی مصنوعی. مجموعه مقالات چهارمین کنفرانس هیدرولیک ایران، شیراز.
۳. دستورانی م. ت. ۱۳۸۶. بررسی کاربرد مدل‌های هوش محاسباتی در شبیه‌سازی و پیش‌بینی به‌هنگام جریان‌های سیلابی. مجله علوم و فنون کشاورزی و منابع طبیعی (علوم آب و خاک). ۱۱(۴۰):۲۹-۴۰.
4. Dastorani M. T. and Wright N. G. 2003. Application of Artificial neural network for ungauged catchment flood prediction. flood plain managment Association. March 12-16.
5. Hsu K. L. Gubta H. V. and Sorooshian S. 1995. Artificial Neural Network modeling of the rainfall-runoff processes. Water Resources Research. 31(10):2517-2530.
6. Karunanithi N. Grenney W. J. Whitley D. and Bovee K. 1994. Neural networks for flow prediction. Civil Engineering. 8(2):201-220.
7. Minns A. W. and Hall M. J. 1996. Artificial Neural Network as rainfall-runoff models. Journal of Hydrological Science. 41(3):399-417.
8. Mishra A. K. and Desai V. R. 2005. Drought forecasting using stochastic models. stochastic environmental research and risk assessment. Springer Verlag. 19(5):326-339.
9. Mishra A. K. and Desai V. R. 2006. Drought forecasting using feed-forward recursive neural network. Ecological Modelling. 127-138.
10. Mishra A. K. Desai V. R. and Singh V. P. 2007. Drought forecasting using a hybrid stochastic and neural network model. Hydrologic Engineering. ASCE. 12(6):626-638.
11. Morid S. Smakhtin V. and Bagherzadeh K. 2007. Drought forecasting using artificial neural networks and time series of drought indices. Climatology. 27(15):2103-2111.
12. Nagesh Kumar D. Raju K. S. and Satish T. 2004. River Flow forecasting using recurrent neural network. Water Resources Management. 18(2):141-163.

