



Research paper

(Received Jun. 16, 2024

Accepted Jun. 17, 2024)

Simulation of Groundwater Level Aquifer of Baft Plain Using the Radial Basis Function Neural Network Model

Saeid Akbarifard^{*1}, Hoshang Ansari²

¹ *Department of Water Engineering, Faculty of Civil and Surveying Engineering, Graduate University of Advanced Technology, P.O. Box 76315116, Kerman, Iran.*

² *Master of Water Resources Management and Director of Technical and Soil Mechanics Laboratory of Khersan Dam and Power Plant, Ministry of Roads and Urban Development.*

Abstract

Groundwater has always been considered as one of the important and basic resources of drinking, agricultural and environmental water supply, especially in dry areas. Simulating the groundwater level of a region plays an important role in water resources management. For this reason, today the simulation of the groundwater level using mathematical and computer models with relatively low time and cost is of interest in groundwater studies. In the present study, the groundwater level of Baft area located in Kerman province was simulated using the radial basis function neural network (RBFNN) model. The parameters of precipitation, evaporation, river flow, water demand of the region, amount of abstraction from the aquifer and the level of groundwater with a time delay period as input and the level of the water table in the desired period as the output of the model in a monthly time scale during the statistical period (2002-2016) was selected. Also, in order to evaluate the performance of the model, the statistical indices of regression coefficient (R^2), root mean squared error (RMSE), mean absolute error (MAE), mean square error (MSE), normalized mean square error (NMSE) and Willmott's index of agreement (d) were used. The results of the statistical indicators showed that the radial basis function neural network with R^2 , RMSE, MAE, MSE, NMSE and d, 0.9989, 0.1256, 0.064, 0.0158, 0.0011, and 0.9997 have a high ability to simulate the groundwater level and provide reliable results.

Keywords: Simulation of Groundwater Level Aquifer, Radial Basis Function Neural Network, Groundwater, Hydrogeological model.

* Corresponding Author: Saeid Akbarifard
Email: s.akbarifard@kgut.ac.ir
Phone: 03431623357



مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۳/۲۷ تاریخ پذیرش: ۱۴۰۳/۳/۲۸ تاریخ انتشار: ۱۴۰۳/۴/۳۰

شبیه‌سازی تراز سطح آب زیرزمینی آبخوان دشت بافت با استفاده از مدل شبکه عصبی تابع شعاع مدار

سعید اکبری فرد^{۱*}، هوشنگ انصاری^۲

۱- استادیار گروه مهندسی آب، دانشکده مهندسی عمران و نقشه برداری، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران.
۲- کارشناس ارشد مهندسی و مدیریت منابع آب و مدیر آزمایشگاه فنی و مکانیک خاک سد و نیروگاه خرسان، وزارت راه و شهرسازی.

چکیده

آبهای زیرزمینی همواره به عنوان یکی از منابع مهم و اساسی تأمین آب شرب، کشاورزی و زیست محیطی به ویژه در مناطق خشک مطرح بوده اند. شبیه سازی سطح آب زیرزمینی یک منطقه نقش مهمی را در مدیریت منابع آبی ایفا می کند. به همین دلیل، امروزه شبیه سازی تراز آب زیرزمینی با استفاده از مدل های ریاضی و کامپیوتری با صرف زمان و هزینه نسبتاً پایین در مطالعات آب های زیرزمینی مورد توجه می باشد. در مطالعه حاضر، با استفاده از مدل شبکه عصبی تابع شعاع مدار (RBFNN) تراز آب زیرزمینی منطقه بافت واقع در استان کرمان مورد شبیه سازی قرار گرفت. پارامترهای بارش، تبخیر، آورد رودخانه، نیاز آبی منطقه، میزان برداشت از آبخوان و تراز آب زیرزمینی با یک دوره تاخیر زمانی به عنوان ورودی و تراز سطح ایستابی در دوره موردنظر به عنوان خروجی مدل در مقیاس زمانی ماهانه در طی دوره آماری (۱۳۹۵-۱۳۸۱) انتخاب گردید. همچنین به منظور ارزیابی عملکرد مدل از شاخص های ضریب تبیین، جذر میانگین مربعات خطا، میانگین قدر مطلق خطا، مربع میانگین خطای استاندارد، مربع میانگین خطای استاندارد نرمال شده و شاخص توافق ویلموت استفاده شد. نتایج حاصل از شاخص های آماری نشان داد که مدل شبکه عصبی تابع شعاع مدار به ترتیب با ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، مربع میانگین خطای استاندارد (MSE)، مربع میانگین خطای استاندارد نرمال شده (NMSE) و شاخص توافق ویلموت (d)، ۰/۹۹۸۹، ۰/۱۲۵۶، ۰/۰۶۴، ۰/۰۱۵۸، ۰/۰۰۱۱ و ۰/۹۹۹۷ توانایی بالایی در شبیه سازی تراز آب زیرزمینی دارد و نتایج قابل اطمینانی را ارائه می دهد.

کلمات کلیدی: شبیه سازی تراز آبخوان، شبکه عصبی تابع شعاع مدار، آب های زیرزمینی، مدل هیدروژئولوژیکی.

۱- مقدمه

به دلیل اهمیت بالای تخمین و شبیه سازی تراز آب های زیرزمینی مطالعات فراوانی در ارتباط با مدل های مختلف اندازه گیری و شبیه سازی کمی و کیفی منابع آب زیرزمینی انجام گرفته است. در دهه های اخیر، شبکه های عصبی مصنوعی به عنوان شاخه ای از روش های هوش مصنوعی توانایی خود را در ارائه نتایج دقیق و قابل اعتماد مدل سازی فرآیندهای هیدرولوژیکی نشان داده است. ANN یک روش موثر برای مدلسازی مقادیر زیادی از داده های پویا، غیرخطی و پر از خطا، به ویژه هنگامی که روابط اساسی فیزیکی آنها به طور کامل شناخته نشده است می باشد. علاوه بر این، در سال های اخیر استفاده از الگوریتم های مختلف شبکه عصبی مصنوعی به شکل قابل ملاحظه ای برای شبیه سازی و تخمین پدیده های مختلف هیدرولوژیکی و هیدروژئولوژیکی مورد استفاده قرار گرفته اند. ملک زاده و همکاران [۱] تراز آب زیرزمینی در منطقه کبودر آهنگ استان همدان را با استفاده از مدل ترکیبی موجک-ماشین آموزش نیرومند خودتطبیقی (WA-SAELM) شبیه سازی نمودند. تجزیه و تحلیل نتایج شبیه سازی نشان دهنده دقت بالای مدل WA-SAELM در تخمین تراز آب زیرزمینی بود. کریمیان و اگدرنژاد [۲] به منظور شبیه سازی پارامترهای شوری و تراز آب زیرزمینی دشت رامهرمز از مدل های شبکه عصبی مصنوعی و شبکه عصبی مصنوعی بهینه شده استفاده نمودند. نتایج نشان داد که بالاترین دقت پیش بینی پارامترهای شوری و تراز سطح آب زیرزمینی مربوط به مدل ANN+PSO با تابع محرک تانژانت سیگموئیدی می باشد. ترابی پوده و همکاران [۳] به جهت پیش بینی سطح آب های زیرزمینی محدوده های مطالعاتی از نا-الیگودرز، دورود-بروجرد، سلسله و دلفان واقع در استان لرستان از شبکه عصبی موجک استفاده و نتایج آن را با روش شبکه عصبی مصنوعی مقایسه نمودند. نتایج حاصل از معیارهای ارزیابی نشان داد مدل شبکه عصبی موجک کارایی بهتر و خطای کمتری نسبت به شبکه عصبی مصنوعی دارد. کماسی و همکاران [۴] با استفاده از مدل ترکیبی پویایی سیستم و شبکه عصبی فازی موجکی (SD-WANFIS) به پیش بینی نوسانات سطح آب در حوضه آبریز دریاچه ارومیه پرداختند. نتایج مدل سازی نشان داد که مدل SD-WANFIS دارای عملکرد مناسبی می باشد. عسکری و اگدرنژاد [۵] به منظور شبیه سازی پارامترهای سطح و شوری آب زیرزمینی دشت دزفول-اندیمشک از مدل های ANN و ANN+GA استفاده نمودند. نتایج نشان داد که مدل بهینه برای شبیه سازی سطح آب زیرزمینی ANN+GA با تابع محرک تانژانت سیگموئید و مدل بهینه برای شبیه سازی شوری آب زیرزمینی ANN+GA با تابع محرک لگاریتم سیگموئید می باشد.

دالیاکوپولوس و همکاران [۶] عملکرد شبکه عصبی مصنوعی (ANN) را در شبیه سازی تراز آب زیرزمینی مورد استفاده قرار دادند. آنها به منظور بهینه سازی مدل عددی خود، هفت مدل عصبی با پیکربندی مختلف را مورد ارزیابی قرار داده و بیان داشتند که مدل های مذکور از توانایی مناسبی در تخمین تراز آب زیرزمینی برخوردار هستند. نورانی و همکاران [۷] با استفاده از شبکه عصبی مصنوعی تغییرات تراز آب زیرزمینی درون یک آبخوان واقع در استان آذربایجان شرقی واقع در بخش شمال غربی کشور ایران را شبیه سازی کردند. آنها شش ساختار مختلف شبکه عصبی مصنوعی را برای پیش بینی این پدیده هیدروژئولوژیکی استفاده نمودند و با تجزیه و تحلیل نتایج کلیه مدل ها، بهینه ترین معماری را انتخاب نمودند. چیت سازان و همکاران [۸] با استفاده از شبکه عصبی مصنوعی تراز آب زیرزمینی درون آبخوان ها را شبیه سازی نمودند. آنها شبکه عصبی خود را با دو لایه پنهان اجرا نمودند و نشان دادند که در این حالت مقادیر مشاهداتی و شبیه سازی شده به هم نزدیکتر است. خاکی و همکاران [۹] تغییرات تراز آب زیرزمینی در طی یک دوره ۷ ساله را به وسیله مدل عصبی و ANFIS شبیه سازی نمودند. آنها با استفاده از سری زمانی و پارامترهای موثر مدل های مختلفی را توسعه دادند و بهترین ترکیب را معرفی نمودند. آنها بیان نمودند که مدل ANFIS دارای دقت بیشتری است. ملک زاده و همکاران [۱۰] با استفاده از یک مدل هوش مصنوعی و مدل عددی مادفلو تراز آب زیرزمینی درون یک سفره آب زیرزمینی واقع در استان همدان را شبیه سازی نمودند. نتایج نشان داد که مدل هوش مصنوعی عملکرد بهتری در مقایسه با مدل مادفلو دارد.

کشور ایران در یک منطقه خشک واقع گردیده و دارای میانگین بارندگی پایینی است. بارندگی استان کرمان نیز از بارندگی کشور بسیار کمتر می باشد. لذا استفاده از منابع آب زیرزمینی به عنوان یک ضرورت اجتناب ناپذیر همواره مد نظر بوده و در طول تاریخ همواره از دشت های استان جهت تهیه آب شرب و کشاورزی استفاده شده است. محدوده مورد مطالعه بافت یکی از حوضه های آبریز واقع در محدوده استان کرمان بوده که با توجه به بهره برداری غیراصولی از منابع آب و خاک و همچنین توسعه روزافزون برداشت از منابع آبی (سطحی و خصوصاً زیرزمینی) توانایی تامین تقاضاهای روزافزون را ندارد. در سال های اخیر با حفر چاه های غیرمجاز، بهره برداری از دشت ها به شدت افزایش یافته که نتیجه بدهی این امر افت سطح آب های زیرزمینی می باشد لذا جهت حفاظت بهتر از

آبخوان و مدیریت مناسب منابع آب زیرزمینی، در مطالعه حاضر برای نخستین بار از مدل شبکه عصبی تابع شعاع مدار (RBFNN) به منظور شبیه سازی بلند مدت تراز آب زیرزمینی منطقه بافت واقع در استان کرمان استفاده شد.

۲- مواد و روش ها

۲-۱- منطقه مورد مطالعه

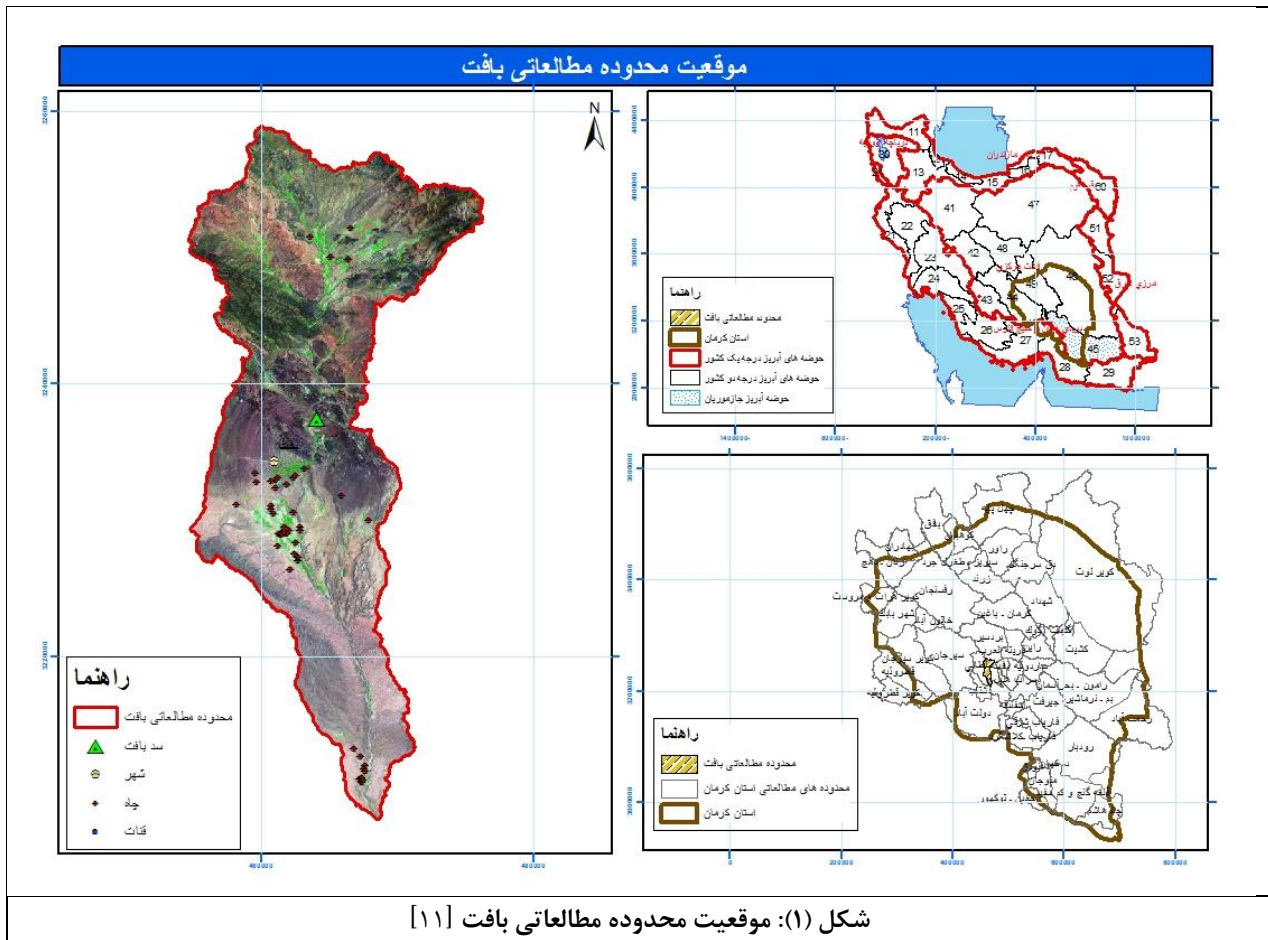
محدوده مطالعاتی بافت در فاصله ۱۶۰ کیلومتری جنوب شرقی کرمان قرار گرفته و مساحتی معادل ۵۱۹/۱ کیلومتر مربع دارد که ۵۲/۳ کیلومتر آن را دشت و بقیه ارتفاعات است. مهمترین شهر این محدوده مطالعاتی، شهر بافت است که این شهر در قسمت مرکز محدوده مطالعاتی و در کنار رودخانه بافت قرار گرفته است. این محدوده مطالعاتی در حوزه آبریز درجه دو هامون جازموریان قرار دارد. محدوده مطالعاتی بافت بین طول شرقی ۳۱-۵۶ و ۴۵-۵۶ و عرض شمالی ۲۸ - ۵۹ و ۲۷-۲۹ قرار دارد، حد غربی این محدوده مطالعاتی ۴۵۴۰۰۰، حد شرقی آن ۴۷۶۰۰۰، حد شمالی و حد جنوبی آن نیز به ترتیب ۳۲۰۸۰۰۰ و ۳۲۵۹۰۰۰ در سیستم UTM و زون ۴۰ شمالی است و در محدوده عملکرد استان کرمان قرار دارد. این محدوده از شمال با محدوده مطالعاتی بردسیر، از شرق با محدوده مطالعاتی بزجان، از جنوب با محدوده های مطالعاتی دشتاب و پایاب دهوج و از غرب با محدوده مطالعاتی سلطانی مجاور می باشد [۱۱].

محدوده مطالعاتی بافت به شکل نامنظم با کشیدگی شمالی- جنوبی گسترده شده است. بیشترین طول محدوده مورد مطالعه حدود ۵۲ کیلومتر و متوسط عرض آن نیز بالغ بر ۱۷ کیلومتر می باشد. منابع آب سطحی منطقه شامل رودخانه بافت می باشد، این رودخانه از ارتفاعات شمالی سرچشمه گرفته و پس از طی مسیر و عبور از نواحی سنگی وارد دشت می گردد. در محدوده مطالعاتی بافت سد مخزنی بافت بر روی رودخانه بافت وجود دارد سد یاد شده در ارتفاع ۲۳۰۰ متری از سطح دریای آزاد و شرق بافت واقع شده است. عوامل هیدرولوژیکی به طور مستقیم یا غیر مستقیم در میزان و نوع جریان آب های زیرزمینی و سطحی دخالت دارد. همچنین نتایج مطالعات هیدرولوژیکی در مطالعات مدیریت منابع آب، احداث و طراحی سدها و سرریز اضطراری سدها و برآورد عمر مفید سدها و طراحی هیدرولیکی سازه های انتقال آب و... مورد استفاده قرار می گیرد.

تجزیه و تحلیل آمار و اطلاعات آب های سطحی و کاربرد نتایج بدست آمده از آن در سایر موارد تلفیق مطالعات خصوصاً مطالعات بیلان آب دارای اهمیت زیادی می باشد. به مجموع دبی پایه ناشی از ذوب برف و چشمه ها و رواناب ناشی از بارش آبدی گفته می شود. هرگاه شدت بارندگی از ظرفیت نفوذ خاک بیشتر باشد، بخشی از آب حاصله از بارندگی در سطح حوضه باقی می ماند. این آب پس از پر کردن گودی های سطح زمین در امتداد شیب به راه می افتد و از طریق آبراهه اصلی از حوضه خارج می شود. به این بخش از بارندگی که می توان مقدار آن را در رودخانه اندازه گیری کرده روان آب سطحی می گویند. با توجه به اینکه خصوصیات فیزیکی حوضه نسبتاً ثابت است بین بارندگی و روان آب رابطه مستقیمی وجود دارد. مهمترین رودخانه ای که در این محدوده مطالعاتی جریان دارند رودخانه بافت بوده که یکی از سرشاخه های رودخانه هلیل می باشد. در این محدوده مطالعاتی مسیلهای فصلی زیادی وجود داشته که در مجموع وارد رودخانه بافت می گردند و نهایتاً رودخانه بافت پس از طی مسیری در جهت جنوب پس از ایستگاه بافت وارد رودخانه هلیل می گردد.

محدوده مطالعاتی بافت دارای وسعتی معادل با ۵۱۹ کیلومتر مربع بوده که ۴۶۶/۸ کیلومتر مربع بخش کوه (حدود ۹۰٪ سطح حوضه) و ۵۲/۳ کیلومتر مربع را بخش دشت تشکیل می دهد. پهنه های کم وسعت و محدود بصورت جداگانه در بین ارتفاعات تشکیل شده که به عنوان دشت های میان کوهی بوده و دارای وسعت محدود و پراکنده می باشند و نمی توانند آبخوان های پر اهمیتی را تشکیل دهند. براساس آخرین گزارشات آماربرداری از منابع آب زیرزمینی در محدوده طرح، منابع آبی محدوده مطالعاتی شامل ۵۰ حلقه چاه و ۲۷ رشته قنات گزارش شده است. مجموع آب استحصال شده از منابع فوق بالغ بر ۳/۲۸۲ میلیون مترمکعب است.

از تعداد ۵۰ حلقه چاه نیمه عمیق، تعداد ۲۲ حلقه چاه در دشت بافت می باشد که تعداد ۱۷ حلقه چاه دارای آبدی و ۵ حلقه چاه فاقد آبدی می باشد که تخلیه سالانه ۰/۳۵۵ میلیون متر مکعب می باشد. از تعداد ۲۸ حلقه چاه که در ارتفاعات حفاری شده تعداد ۲۲ حلقه چاه دارای آبدی و ۶ حلقه چاه فاقد آبدی می باشد و تخلیه سالانه ۰/۵۹۵ میلیون متر مکعب را دارا می باشند [۱۱].



۳- شبکه‌های عصبی مصنوعی

بعضی از پیش‌زمینه‌های شبکه‌های عصبی را می‌توان به اوایل قرن بیستم و اواخر قرن نوزدهم برگرداند. دیدگاه جدید شبکه عصبی در دهه ۴۰ قرن بیستم شروع شد، نخستین کاربرد عملی شبکه‌های عصبی در اواخر دهه ۵۰ قرن بیستم مطرح شد، زمانی که فرانک روزنبلات در سال ۱۹۵۸ شبکه پرسپترون را معرفی نمود. این شبکه قادر بود الگوها را از هم شناسایی کند. در همین زمان بود که برنارد ویدرو در سال ۱۹۶۰ شبکه خطی آدالین را با قانون یادگیری جدید مطرح نمود که از لحاظ ساختار شبیه شبکه پرسپترون بود. اولین ایده استفاده از مکانیسم تصادفی جهت توضیح عملکرد یک طبقه وسیع از شبکه‌های برگشتی که می‌توان آن‌ها را جهت ذخیره‌سازی اطلاعات استفاده نمود. دومین ایده مهم که کلید توسعه شبکه‌های عصبی در دهه ۸۰ شد، الگوریتم پس از انتشار خطا می‌باشد که در سال ۱۹۸۶ توسط راملهارت مطرح شد. با بروز این دو ایده شبکه‌های عصبی متحول شدند. اکنون شبکه‌های عصبی در هر دو جهت توسعه تئوریک و عملی در حال رشد می‌باشند.

شبکه‌های عصبی از عناصر عملیاتی ساده‌ای به صورت موازی ساخته می‌شوند. ساختار شبکه‌های عصبی مصنوعی از شبکه‌های عصبی زیستی تبعیت می‌کند که در آن با تنظیم مقادیر هر اتصال تحت عنوان وزن اتصال نحوه ارتباط بین اجزای آن تعیین می‌گردد. پس از آموزش شبکه (تنظیم وزن‌ها) اعمال یک ورودی خاص منجر به دریافت پاسخ خاص می‌شود. شبکه بر مبنای تطابق و همسنجی بین ورودی و هدف سازگار می‌شود تا اینکه خروجی شبکه و هدف بر هم منطبق گردند [۱۲].

۴- ویژگی‌های شبکه‌های عصبی

شبکه‌های عصبی مصنوعی با وجود اینکه با سیستم عصبی طبیعی قابل مقایسه نیستند، ویژگی‌هایی دارند که آن‌ها را در بعضی از کاربردها مانند تفکیک الگو و یا هر جا که نیاز به یادگیری با یک نگاشت خطی و غیرخطی باشد، ممتاز می‌نمایند. این ویژگی‌ها عبارتند از:

• قابلیت یادگیری

استخراج نتایج تحلیلی از یک نگاشت غیر خطی که با چند مثال مشخص شده، کار ساده‌ای نیست چون می‌دانیم که یک نرون یک دستگاه غیرخطی است، در نتیجه یک شبکه عصبی که از اجتماع این نرون‌ها تشکیل می‌شود هم یک سیستم کاملاً پیچیده و غیرخطی خواهد بود. به علاوه خاصیت غیرخطی عناصر پردازش، در کل شبکه توزیع می‌گردد. پیاده‌سازی این مسائل با یک الگوریتم با قابلیت یادگیری، به مراتب آسان‌تر از انجام آن در یک سیستم بدون هیچ قابلیت است چرا که در سیستم اخیر افزودن یک مثال جدید به منزله تعویض کلیه کارهای انجام شده قبلی می‌باشد. قابلیت یادگیری، یعنی توانایی تنظیم پارامترهای شبکه در زمانی که محیط شبکه تغییر می‌کند و شبکه شرایط جدید را تجربه می‌کند، با این هدف که اگر شبکه برای یک وضعیت خاص، آموزش دید و تغییر کوچکی در شرایط محیطی شبکه رخ داد، شبکه بتواند با آموزش مختصر برای هر نرون در شبکه، به صورت بالقوه از کل فعالیت‌های سایر نرون‌ها متأثر می‌شود. در نتیجه اطلاعات از نوع مجزا از هم نبوده، بلکه متأثر از کل شبکه می‌باشد [۱۲].

• پراکندگی اطلاعات

آنچه که شبکه فرا می‌گیرد، در وزن‌های آن استتار شده است. رابطه یک به یکی بین ورودی‌ها و وزن‌ها وجود ندارد. می‌توان گفت که هر نرون، مربوط به همه ورودی‌هاست ولی به هیچ یک از آن‌ها به طور منفرد و مجزا مربوط نیست. به عبارت دیگر هر نرون در شبکه از کل فعالیت‌های سایر نرون‌ها متأثر می‌شود. در نتیجه اطلاعات به صورت متن توسط شبکه‌های عصبی پردازش می‌شود. بر این اساس چنانچه بخشی از سلول‌های شبکه حذف شوند و یا عملکرد غلط داشته باشند باز هم احتمال رسیدن به پاسخ تقریباً صحیح وجود دارد. اگر چه این احتمال برای تمام این ورودی‌ها کاهش یافته ولی برای هیچ یک از بین نرفته است [۱۲].

• قابلیت تعمیم

پس از آنکه مثال‌های اولیه به شبکه آموزش داده شد، شبکه می‌تواند در مقابل یک ورودی آموزش داده نشده قرار گیرد و یک خروجی مناسب ارائه نماید. این خروجی براساس مکانیسم تعمیم، که همانا چیزی جز یک پروسه درون‌یابی نیست به دست می‌آید. به عبارت روشن‌تر، شبکه تابع را یاد می‌گیرد، الگوریتم را می‌آموزد و یا رابطه تحلیلی مناسبی را برای تعداد نقاط در فضا به دست می‌آورد [۱۲].

• پردازش موازی

هنگامی که شبکه عصبی در قالب سخت افزار پیاده می‌شود، سلول‌هایی که در یک تراز قرار می‌گیرند می‌توانند به طور همزمان به ورودی‌های آن تراز پاسخ دهند. این ویژگی باعث افزایش سرعت پردازش می‌شود. در واقع در چنین سیستمی، وظیفه کلی پردازش، بین پردازنده‌های کوچک‌تر مستقل از یکدیگر توزیع می‌گردد [۱۲].

• مقاوم بودن


در یک شبکه عصبی، هر سلول به طور مستقل عمل می‌کند و رفتار کلی شبکه، برآیند رفتارهای محلی سلول‌های متعددی است. این ویژگی باعث می‌شود تا خطاهای محلی از چشم خروجی نهایی دور بمانند. به عبارت دیگر، سلول‌ها در یک روند همکاری، خطاهای محلی یکدیگر را تصحیح می‌کنند. این خصوصیت باعث افزایش مقاومت (تحمل‌پذیری خطاها) در سیستم می‌گردد [۱۲].

۵- ساختار نرون

شبکه‌های عصبی از عناصر کوچک پردازش کننده اطلاعات به نام نرون تشکیل شده اند، p و a به ترتیب ورودی و خروجی می‌باشند. خروجی نرون با رابطه (۱) تعریف می‌شود:

$$a = f(wp + b) \quad (1)$$

در رابطه (۱)، a خروجی نرون، f تابع محرک، w بردار وزن‌ها، p ورودی نرون و b مقدار بایاس می‌باشد. میزان تأثیر p روی a به وسیله مؤلفه w تعیین می‌شود که در شکل (۲) نشان داده شده است [۱۳].



شکل (۲): مدل نرون تک ورودی [۱۳]

اگر نرون مصنوعی تک ورودی با نرون بیولوژیکی مقایسه شود وزن (w) معادل شدت سیناپس، مجموعه جمع کننده و تابع محرک، معادل هسته سلول و a معادل سیگنال گذرنده از اکسون خواهد بود. وزن و بایاس قابل تنظیم می‌باشند و بایاس قابل تنظیم می‌باشند و تابع محرک نیز توسط طراح شبکه انتخاب می‌شود. طی فرآیند یادگیری پارامترهای وزن و بایاس باید طوری تنظیم شوند که رابطه ورودی و خروجی نرون با هدف خاصی مطابق کند [۱۳]. باید توجه داشت که بایاس ورودی نرون نیست بلکه از پارامترهای قابل تنظیم نرون می‌باشد.

۶- تعمیم پذیری^۱

مسئله اصلی در یادگیری، توانایی و قابلیت الگوریتم در تعمیم دادن صحیح تعداد محدودی از نمونه‌های مورد آزمایش است، یعنی الگوریتم به طور نسبتاً دقیقی درون بایی و به طور محلی برون بایی نماید. به محض آنکه شبکه عصبی طراحی شد، واکنش آن را می‌توان به طور معین بسط داد. پس باید شبکه به تغییرات جزئی مجموعه داده‌های ورودی حساس نباشد. همچنین وجود این قابلیت در حضور خطا با نویز از اهمیت بالایی برخوردار است. نکته مهم آن است که شبکه عصبی مصنوعی باید بدون استفاده از هوش انسان و به واسطه ساختار خود تعمیم پذیری را ایجاد کند. قابلیت مدل سازی شبکه عصبی برای دستیابی صحیح به اهداف باید به مقدار کافی انعطاف داشته باشد ولی اگر بیش از حد انعطاف پذیر باشد، می‌تواند از حدود داده‌ها تجاوز کند (بیش برآزی) و بنابراین خاصیت تعمیم پذیری شبکه تضعیف خواهد شد. سازگاری شبکه عصبی باید به خوبی شکل داده شود زیرا تعمیم پذیری علاوه بر نیاز به ساختار مدل خوب، نیاز به همگرایی خوب پارامترها نیز دارد. اگر یک شبکه به طور ضعیفی شکل داده شود، طراح ممکن است این گونه فکر کند که شبکه به طور صحیحی کار می‌کند زیرا خطاهای پیش بینی کوچک هستند. با این وجود همگرایی پارامترها در شبکه که به خوبی شکل گرفته نشده است به کندی صورت می‌گیرد و خاتمه فرایند یادگیری زودتر اتفاق می‌افتد. این به این معنی است که شبکه قادر نیست تکرارها در مرحله آموزش است در واقع به دنبال یک آموزش مناسب هستیم تا شبکه قادر به تعمیم مطلوب مدل در مرحله آزمون باشد.

بنابراین برای مدل سازی بهینه یک فرایند با شبکه عصبی مصنوعی باید مراحل زیر طی شود:

انتخاب نوع شبکه عصبی

۱. تعیین تعداد نرون‌های لایه ورودی با توجه به پدیده مورد نظر (سعی و خطا)

۲. تعیین تعداد نرون‌های لایه مخفی (معلوم)

۳. تعیین تعداد لایه نرون خروجی (معلوم)

۴. تعیین تعداد تکرارها در مرحله آموزش (سعی و خطا)

۵. منظم نمودن آمار موجود و تعیین مجموعه آموزشی و مجموعه آزمون

۶. آموزش شبکه عصبی با استفاده از مجموعه آموزشی و الگوریتم آموزش انتخاب شده

۷. آزمایش شبکه عصبی با استفاده از مجموعه آزمون [۱۴]

۷- پایداری و قابلیت اطمینان شبکه

قبل از به کارگیری شبکه‌های عصبی مصنوعی در موقعیت‌های مختلف باید قابلیت آن‌ها مورد بحث قرار گیرد. شبکه‌های عصبی مصنوعی مانند مغز انسان درجه معینی از عدم قابلیت پیش‌بینی را حفظ می‌کنند. علیرغم این مسئله باید تمام مقادیر ورودی ممکن را آزمایش کرد که البته این راه مطمئنی برای پیش‌بینی دقیق مقادیر خروجی نیست. در یک شبکه بزرگ آزمایش تمام موارد ممکن غیرعملی است و باید با ارزیابی آماری از عملکرد آن اطمینان حاصل کرد. اگر داده‌های مجموعه آموزش، متعلق به مناطق خاصی از فضای ورودی باشند آنگاه باید تنها داده‌های مناسب جمع‌آوری شوند. زمانی که وزن‌های یاد گرفته شده نزدیک به وزن‌های بهینه نیستند، آموزش باید تکرار شود. زمانی که مجموع داده‌های آموزش به مقدار کافی زیاد باشند می‌توان با اطمینان ادعا کرد که شبکه آموزش دیده، راه حل‌های مفیدی را تولید خواهد کرد و نیاز به تکرار کمی از فرآیند آموزش است. در ارزیابی شبکه آموزش دیده، فهم تأثیر وزن هر شاخه بر نتایج شبکه مطلوب است. از آنجا که مقادیر این پارامترها به طور مستقیم بر نتایج خروجی شبکه تأثیرگذار هستند، تعیین جداگانه این تأثیرات، اجازه جستجوی منطقه‌ای را که شبکه در آن به خوبی آموزش ندیده، فراهم آورده و در ارزیابی شبکه نیز کمک خواهد کرد [۱۳].

۸- صحت‌سنجی شبکه‌های عصبی^۱

مهم‌ترین قسمت هر روش طراحی مدل، ارزیابی اعتبار آن مدل است. لذا برای تخمین محدودیت شبکه که داده‌های آموزش را یاد گرفته و قابلیت آن در تعمیم‌پذیری (درون‌یابی و برون‌یابی) برای موارد پیش‌بینی نشده، آزمون‌هایی انجام می‌گیرد. بیشتر الگوریتم‌های آموزش قادر به یادگیری موفقیت‌آمیز مجموعه داده‌های آموزش هستند با این وجود هنوز قابلیت آن‌ها در داشتن ویژگی تعمیم‌پذیری صحیح و دقیق مورد تردید است. باید با دلایل قانع‌کننده عملکرد شبکه آموزش دیده را سنجید زیرا به سادگی نمی‌توان به شبکه اعتماد کرد همان‌طور که نمی‌توان در مورد یک جعبه سیاه چیزی را ثابت کرد. با روش‌های مختلفی می‌توان عملکرد شبکه آموزش دیده را ارزیابی کرد. ساده‌ترین روش، ارزیابی عملکرد شبکه آموزش دیده با داده‌های آموزش باز تولید شده است. بهترین روش تقسیم داده‌های موجود به دو دسته مجموعه آموزش^۲ و مجموعه آزمایش^۳ استفاده از مجموعه داده‌های آزمایش برای ارزیابی مدل نهایی می‌باشد. به عبارت دیگر، مجموعه داده‌های آموزش در الگوریتم یادگیری برای آموزش شبکه به کار می‌رود و از مجموعه داده‌های آزمایش برای تخمین عملکرد شبکه، از طریق آزمایش، قابلیت آن برای داشتن ویژگی تعمیم‌پذیری صحیح به کار می‌رود. با این وجود اگر داده‌های موجود کم باشند تقسیم داده‌ها به دو مجموعه آزمایش و آموزش مشکل است. ابتکاری که در عمل از آن بیشتر استفاده می‌شود آن است که از $\frac{2}{3}$ داده‌ها برای آموزش و از $\frac{1}{3}$ بقیه برای آزمایش شبکه استفاده شود. این روش معقولی است زیرا اگر داده‌های آموزش کافی نباشند الگوریتم یادگیری نمی‌تواند به خوبی عمل کند. البته اگر مجموعه آزمایش نیز خیلی کوچک باشد نمی‌توان با دقت نتایج خروجی را ارزیابی کرد [۱۳].

۹- شبکه عصبی چند لایه پیش‌خور (MLP)

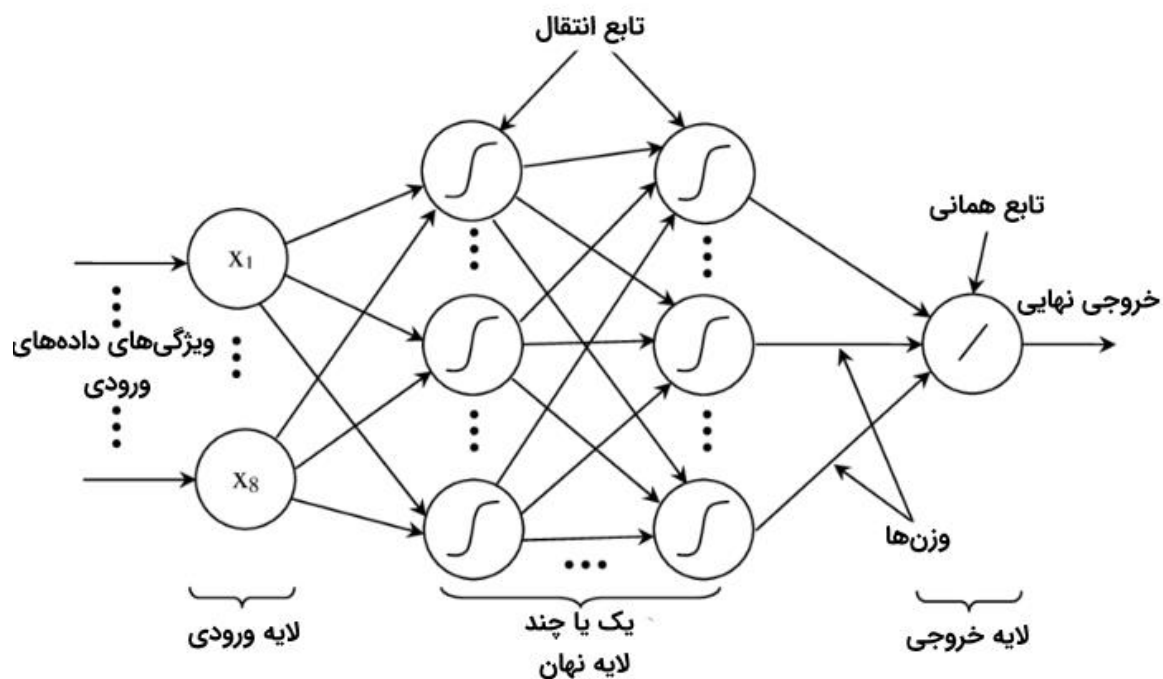
تحقیقات روی شبکه‌های عصبی چند لایه پیش‌خور بر می‌گردد به کارهای اولیه فرانک روزنبلات روی شبکه عصبی پرسپترون تک لایه و کارهای اولیه برنارد ویدرو و ماریان هوف. هر چند استفاده از عبارت پس انتشار عملاً از سال ۱۹۸۵ متداول گشت، لیکن نخستین توصیف الگوریتم پس انتشار (BP) توسط پاول وربز در سال ۱۹۷۴ در رساله دکترایش مطرح شده بود. توسعه الگوریتم BP با فراهم آوردن روشی از نظر محاسباتی کارا، رنسانسی در شبکه‌های عصبی ایجاد نمود، چون که شبکه‌های MLP با قاعده آموزش BP همچنان بیشترین کاربرد را در مسائل فنی- مهندسی دارند. به طور کلی شبکه‌های پیش‌خور دارای مشخصات زیر هستند:

Validation of a Neural Network

Training set

Test set

این شبکه‌ها دارای سه لایه به نام‌های لایه ورودی، لایه‌های میانی (پنهان) و لایه خروجی می‌باشند. تعداد لایه پنهان محدودیتی ندارد. در این شبکه‌ها نرون‌های هر لایه به نرون‌های لایه بعد از خود سیگنال می‌فرستند. گره‌ها توسط اتصالاتی به یکدیگر متصل بوده و هر اتصال دارای وزن قابل تغییر مخصوص به خود می‌باشد. گره‌ها در لایه‌های موازی چیده می‌شوند و گره‌های هر لایه فقط به گره‌های دو طرف خود وصل می‌شوند. نخستین لایه را، لایه ورودی و آخرین لایه را، لایه خروجی می‌نامند. به لایه میانی نیز لایه پنهان گفته می‌شود. هر نرون یا گره مانند پردازشگر کار می‌کند یعنی از راه اتصالات خروجی به لایه بعد از خود می‌فرستد، اما از آنجایی که این گره‌ها می‌توانند نرمال عمل کنند، پس یک سیستم پردازش موازی تشکیل می‌دهد. زمانی که بردار ورودی عرضه می‌شود گره‌های لایه ورودی آن را دریافت کرده و آن را بدون هیچ پردازشی به گره‌های اولین لایه پنهان می‌فرستند. این گره‌ها بر روی اطلاعات رسیده، پردازش انجام داده، نتیجه را به گره‌های لایه بعدی می‌فرستند تا اینکه سرانجام نتیجه از گره‌های خروجی به عنوان یک بردار خروجی منظم به خارج فرستاده می‌شود. به همین دلیل این نوع شبکه را شبکه پیش‌خور می‌نامند. پردازشی که در کل گره‌ها صورت می‌گیرد، ممکن است بسیار پیچیده باشد عموماً یک نرون بیش از یک ورودی دارد در شکل (۳) مدلی از شبکه چندلایه‌ای پیش‌خور نمایش داده شده است [۱۵].



شکل (۳): مدلی از شبکه چندلایه‌ای پیش‌خور

هر نرون بردار ورودی را در وزن‌های خود ضرب کرده و با بایاس جمع می‌کند. حاصل این عبارت ورودی خالص به تابع محرکه خواهد شد، که به صورت رابطه (۲) بیان می‌شود:

$$net_j = \sum_{j=1}^l w_{ij} x_j + w_0 \quad (2)$$

که در آن net_j ورودی خالص به تابع محرکه، w_{ij} ماتریس وزن‌های شبکه، x_j بردار ورودی به شبکه و w_0 بردار بایاس شبکه می‌باشند. درون گره j یک تابع F به نام تابع محرکه (فعالیت) وجود دارد که بر روی net_j عمل کرده و نتیجه به صورت Y_j از گره j به عنوان ورودی به گره‌های لایه بعدی فرستاده می‌شود، اما پیش از ورود به گره‌های لایه بعد در وزن‌های اتصال مربوط ضرب می‌شود و این گسترش اطلاعات تا رسیدن به لایه خروجی ادامه می‌یابد. خروجی لایه خروجی، نتیجه نهایی عکس‌العمل‌های شبکه عصبی در برابر ورودی به شبکه می‌باشد. مسلماً خروجی تولیدشده توسط شبکه با خروجی واقعی یکسان نخواهد بود. هدف ما انتخاب مناسب تابع محرکه F و وزن‌های شبکه w_{ij} و تعداد نرون‌های لایه پنهان می‌باشد. به طوری که اختلاف بین خروجی‌های شبکه و مقادیر در حد

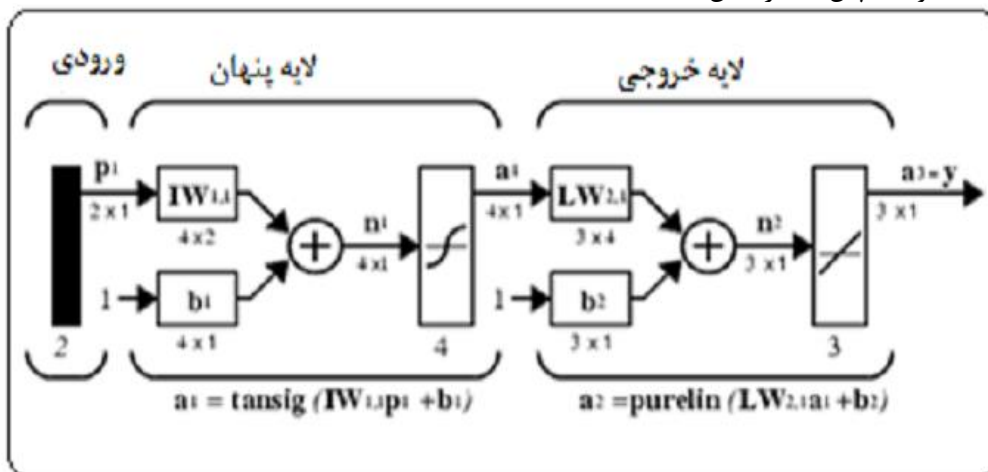
مجاز کوچک می‌باشد. شبکه‌های عصبی چند لایه پیش‌خور تابع سه جز عمده تعداد لایه‌ها و تعداد نرون‌ها در هر لایه، تابع انتقال یا تابع محرکه مورد استفاده و وزن‌های شبکه عصبی مصنوعی می‌باشند. برای رسیدن به یک مدل مناسب برای حل یک مساله خاص باید سه جز مذکور به طرز مناسبی تعیین گردند (با فرض یک الگوی ورودی خاص).

۱۰- تعداد لایه‌ها و نرون‌های شبکه عصبی پیش‌خور

حداقل لایه‌ها در شبکه عصبی چند لایه سه عدد می‌باشد و به طور معمول وجود یک لایه پنهان به منظور پردازش مناسب اطلاعات کافی است. با این حال در صورت نیاز می‌توان لایه‌های پنهان بیشتری را مورد آزمایش قرار داد. تعداد نرون‌ها در لایه ورودی وابسته به تعداد پارامترهای ورودی بوده و تعداد نرون‌ها در لایه خروجی بستگی به تعداد پارامترهای خروجی مورد نیاز مساله دارد. تعداد نرون‌ها در لایه پنهان و تعداد لایه‌های پنهان تابعی از نوع اطلاعات و نوع ارتباط آن‌ها با یکدیگر می‌باشند، لیکن در مسائل مهندسی آب نتایج تجربی نشان داده است که بهتر است تعداد نرون‌ها در لایه پنهان با تعداد نرون‌ها در لایه ورودی برابر و یا یکی بیشتر باشد. اگر تعداد نرون‌ها کم باشد، مدل درست آموزش نخواهد دید و برعکس اگر زیاد باشد آموزش مدل به نحوی خواهد شد که برای اطلاعات و داده‌های جدید جواب‌ها صحیح نخواهد شد. به عبارت ساده‌تر وزن‌ها برای شرایط محلی و موضعی به دست می‌آیند و کلی نخواهند بود. به طور کلی تعداد نرون‌ها در لایه پنهان تابع ضابطه خاصی نبوده و تعیین تعداد مناسب آن‌ها فقط از طریق سعی و خطا امکان‌پذیر است. به این معنی که تعداد بهینه نرون‌های مخفی زمانی حاصل می‌شود که شبکه عصبی بهترین پردازش را با کمترین خطا در هر دو مرحله آموزش مدل و صحت‌یابی آن را انجام دهد [۱۵].

۱۱- شبکه‌های پس انتشار^۱

شبکه‌های پس انتشار یک شبکه چندلایه با تابع محرک غیر خطی و قاعده یادگیری Widrow-Hoff می‌باشد و برای تقریب توابع، یافتن ارتباط بین ورودی و خروجی و دسته‌بندی ورودی‌ها براساس روش‌های تعیین شده توسط طراح استفاده می‌شوند. یک شبکه BP دارای بایاس، یک لایه سیگموئید و یک لایه خروجی خطی توانایی تخمین زدن هر تابعی با نقاط ناپیوستگی محدود را داراست. BP استاندارد یک الگوریتم با شیب نزولی می‌باشد که در آن وزن‌های شبکه در جهت خلاف تابع کارایی حرکت می‌کند، برای آموزش این شبکه‌ها از دو روش گام به گام^۲ و روش دسته‌ای^۳ استفاده می‌شود. در روش گام به گام، وزن‌ها و بایاس‌ها بعد از اعمال هر ورودی به روز می‌شوند در صورتی که در روش دسته‌ای پس از اعمال تمام ورودی‌ها عملیات به روزرسانی انجام می‌شود [۱۶]. در شکل (۴) ساختار یک شبکه دو لایه پس انتشار نشان داده شده است.



شکل (۴): شبکه پس انتشار دو لایه با توابع tansig و purelin

^۱Back Propagation

^۲Incremental

^۳Batch

۱۲- شبکه عصبی تابع شعاع مدار^۱

شبکه عصبی تابع شعاع مدار به خاطر کاربردهای متنوعش به یکی از مهمترین شبکه‌های عصبی تبدیل شده است. این شبکه عصبی مهم‌ترین رقیب پرسپترون چندلایه به حساب می‌آید. شبکه عصبی تابع شعاع مدار بیش‌ترین الهام را از تکنیک‌های آماری طبقه‌بندی الگوها گرفته است. این شبکه نسبت به شبکه‌ی پس انتشار نیاز به نرون‌های بیش‌تری دارند ولی نیاز به زمان کم‌تری برای طراحی دارد. این شبکه وقتی که ورودی‌های زیادی داشته باشد بهترین کارایی را خواهد داشت. شبکه‌های رگرسیون^۲ و شبکه‌های احتمالی^۳ دو نمونه از مهم‌ترین شبکه‌های تابع شعاع مدار می‌باشند.

شبکه‌های رگرسیون: از این شبکه‌ها اغلب در تخمین توابع استفاده می‌شود و دارای یک لایه Radial Basis و یک لایه خطی خاص می‌باشند.

شبکه‌های عصبی احتمالی: از این شبکه برای مسائل طبقه‌بندی استفاده می‌شود. وقتی که یک بردار ورودی به شبکه اعمال می‌شود، لایه‌ی اول فاصله بردار ورودی را از ورودی‌های آموزشی محاسبه می‌کند و به این ترتیب برداری را فراهم می‌آورد که عناصر آن تعیین‌کننده میزان فاصله بین ورودی و ورودی آموزشی است. لایه‌ی دوم با استفاده از خروجی لایه‌ی اول، برداری از احتمال‌ها را به عنوان خروجی شبکه تولید می‌کند. در نهایت تابع محرک موجود در لایه دوم حداکثر مقدار احتمال‌ها را از بردار احتمال‌ها انتخاب کرده و به ازای آن خروجی یک و به ازای بقیه احتمال‌ها خروجی صفر تولید می‌نماید.

شبکه‌های عصبی RBF معمولاً به وسیله‌ی یک الگوریتم دو مرحله‌ای آموزش داده می‌شود که این مراحل عبارتند از:

۱. روش بدون نظارت: بردارهای مرکز C_i برای توابع RBF در لایه مخفی انتخاب می‌شوند. این مرحله با روش‌هایی مانند نمونه برداری تصادفی و یا خوشه بندی K-means clustering اجرا می‌شود.

۲. روش نظارت شده: مرحله‌ی دوم به سادگی و با یک مدل خطی با ضرایب W_i برای خروجی‌های لایه مخفی با توجه به تابع هدف، متناسب می‌شود. وزن‌های شبکه در این مرحله می‌تواند از طریق الگوریتم BP به دست آید.

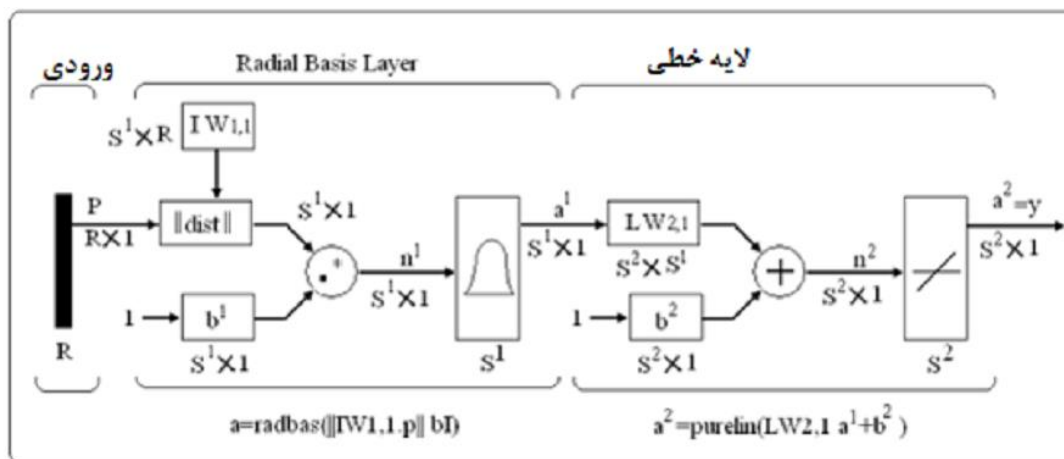
در نهایت خروجی‌ها در RBF با استفاده از رابطه زیر محاسبه می‌گردد.

$$y = w_1\varphi_1(\|x - c_1\|) + \dots + w_{m1}\varphi_{m1}(\|x - c_{m1}\|) + w_0, \quad x = (x_1, \dots, x_m) \quad (3)$$

که در آن، x ورودی‌های مدل و w ، c و φ ضرایبی هستند که توسط مدل شبکه عصبی RBF بدست می‌آیند.

شکل (۵) شبکه تابع شعاع مدار را نشان می‌دهد که در آن R تعداد عناصر ورودی و S^1 و S^2 تعداد نرون‌های لایه اول و لایه دوم

می‌باشند [۱۶].



شکل (۵): شبکه Radial Basis [۱۶]

^۱Radial Basis Function

^۲GRNN

^۳PNN

^۴Unsupervised method

^۵Supervised method

۱۳- الگوریتم‌های آموزش

۱۳-۱- الگوریتم لونیبرگ-مارکوارت (LM)

از میان روش‌های مختلف آموزش به روش پس انتشار خطا، الگوریتم لونیبرگ-مارکوارت^۱ به دلیل همگرایی سریع‌تر در آموزش شبکه‌های با اندازه‌ی متوسط، برای استفاده در تحقیق حاضر انتخاب شده است. الگوریتم پس انتشار خطا، وزن‌های شبکه و مقادیر بایاس آنرا در جهتی تغییر می‌دهد که تابع عملکرد با سرعت بیشتری کاهش یابد. الگوریتم پس انتشار خطا را می‌توان به شکل معادله (۴) نشان داد:

$$x_{k+1} = x_k - a_k g_k \quad (4)$$

که در آن x_k بردار وزن‌ها و بایاس در تکرار K ام و a_k نرخ آموزش در تکرار K ام و g_k گرادیان در تکرار k ام می‌باشد. الگوریتم لونیبرگ-مارکوارت برای دستیابی به آموزش سریع‌تر شبکه بسط داده شده است و از رابطه‌ی (۵) استفاده می‌کند:

$$x_{k+1} = x_k - [j^t j + \mu I]^{-1} J^T e \quad (5)$$

که در آن X_k بردار وزن‌ها و بایاس در تکرار K ام، J ماتریس ژاکوبین شامل اولین مشتقات خطای شبکه با توجه به وزن‌ها و بایاس e ، بردار خطاهای شبکه، I ماتریس واحد و μ یک کمیت اسکالر است. μ پس از هر گام موفق کاهش می‌یابد و در صورتی که یک گام منفرد تابع عملکرد را افزایش می‌دهد μ نیز افزایش می‌یابد به این ترتیب تابع عملکرد در هر تکرار الگوریتم کاهش خواهد یافت.

۱۴- یادگیری

در دهه چهل و به خصوص دهه پنجاه از قرن بیستم محققان تلاش می‌کردند که ساختار شبکه‌های عصبی را با قانون یادگیری کامل کنند. قانون یادگیری، یعنی اینکه پارامترهای شبکه براساس ارائه الگوها تنظیم شود. روزنبلات و آرونسون^۳ [۱۷] نشان داد که نوعی از شبکه‌های عصبی موسوم به پرسپترون^۴ را می‌توان جهت حل مسئله دسته‌بندی الگوها آموزش داد. کار مهم او معرفی این شبکه نبود، بلکه ابداع قانون یادگیری برای شبکه پرسپترون بود. او قانون ساده و اتوماتیکی را مطرح نمود که قادر بود از هر شرط اولیه که شبکه انتخاب می‌کرد به جواب مسئله همگرا شود. متأسفانه شبکه پرسپترون روزنبلات از حل بسیاری از مسائل و طبقه‌بندی الگوهایی که در فضای ورودی به طوری خطی از هم جداناپذیرند ناتوان بود. در دهه ۸۰ قرن بیستم این محدودیت‌ها توسط الگوریتم جدیدی موسوم به پس انتشار خطا، برای شبکه‌های عصبی پرسپترون چند لایه مرتفع شد. رفتار این سیستم‌های یادگیری توسط الگوریتم‌های بازگشتی بیان می‌شود به همین خاطر به این الگوریتم‌ها، قوانین یادگیری می‌گویند و به طور عموم توسط معادلات تفاضلی (دیفرانسیلی) بیان می‌شوند. این الگوریتم‌ها روی اطلاعات موجود آنگونه پردازش می‌کنند که شاخص اجرایی مشخص شده‌ای که عموماً تقریبی است از هدف خاص که مقصود فرایند یادگیری می‌باشد، بهینه گردد و این کار تنها راه جبران نمودن نقایص اطلاعات اولیه می‌باشد و به این دلیل به فرایند یادگیری نیاز است: زیرا اطلاعات (ارتباط ورودی و خروجی) کاملاً مشخص نیستند. به این ترتیب یادگیری را می‌توان فرایند تعدیل اوزان ارتباطی در یک شبکه عصبی دانست به گونه‌ای که در هنگام دریافت بردار محرک از لایه ورودی، بردار خروجی مناسب را به عنوان پاسخ تولید کند [۱۴].

^۱Levenberg - Marquardt

^۲Bias

^۳Rosenblatt and Aronson

^۴Perceptron

۱۵- تدوین مدل شبیه سازی RBFNN

در اکثر مطالعات انجام شده پیرامون کاربرد شبکه عصبی مصنوعی در علوم مختلف و به ویژه هیدرولوژی و پیش بینی سطح آب زیرزمینی، شبکه های عصبی عملکرد قابل قبولی از خود نشان داده است. به همین ترتیب نیز در این پژوهش برای بررسی و پیش بینی وضعیت آبخوان منطقه بافت از مدل شبکه عصبی RBFNN استفاده شد.

هدف نهایی از مدل شبیه ساز در مطالعه حاضر، بدست آوردن تراز آب زیرزمینی در هر منطقه می باشد. از آنجایی که معادلات آب زیرزمینی بر مبنای قانون بقای جرم هستند، پس هر تغییری در تراز آب در آبخوان در اثر ورودی ها و خروجی های مختلف خواهد بود. از این رو تعیین عواملی که تاثیرات قابل توجهی بر این تغییرات دارند، امری ضروری است.

ورودی های موثر در مدل شبیه ساز RBFNN و خروجی مورد نظر به صورت زیر در نظر گرفته می شود:

- میزان برداشت از آب زیرزمینی در گام زمانی جاری
 - میزان تخصیص به نیازهای هر منطقه در گام زمانی جاری
 - میزان بارندگی در گام زمانی جاری
 - میانگین تبخیر ماهانه در گام زمانی جاری
 - آورد متوسط رودخانه (داده ایستگاه هیدرومتری) در گام زمانی جاری
 - به منظور وارد کردن شرایط اولیه، میانگین تراز آب پیژومترهای هر منطقه در گام زمانی قبل نیز به عنوان ورودی مدل شبیه ساز RBFNN در نظر گرفته خواهد شد.
 - به منظور وارد کردن شرایط مرزی آبخوان، میانگین تراز آب پیژومترهای مناطق مجاور در گام زمانی قبل نیز به عنوان ورودی مدل شبیه ساز RBFNN در نظر گرفته خواهد شد. بدین ترتیب تاثیر تغییرات سطح آب زیرزمینی در هر منطقه بر شرایط مناطق مجاور نیز در نظر گرفته خواهد شد.
 - در نهایت خروجی مدل شبیه ساز RBFNN میانگین تراز آب زیرزمینی منطقه در گام زمانی جاری می باشد.
- در نهایت به منظور ارزیابی عملکرد مدل RBFNN، به مقایسه معیارهای سنجش و توانایی مدل در برآورد تراز آب زیرزمینی منطقه مورد مطالعه پرداخته شد.

۱۶- معیارهای سنجش خطا

برای ارزیابی عملکرد مدل شبیه ساز توسعه یافته در این پژوهش از شاخص های ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، مربع میانگین خطای استاندارد (MSE)، مربع میانگین خطای استاندارد نرمال شده (NMSE) و شاخص توافق ویلموت (d) بهره برده شده است که در روابط (۶) تا (۱۱) آورده شده اند.

$$R^2 = \left(\frac{\sum (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum (O_i - \bar{O})^2 \times \sum (S_i - \bar{S})^2}} \right)^2 \quad (6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_i - O_i)^2} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |S_i - O_i| \quad (8)$$

۱- Root Mean Squared Error

۲- Mean Absolute Error

۳- Mean Square Error

۴- Normalized Mean Square Error

۵- Willmott's index of agreement

$$d = 1 - \frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n (|S_i - \bar{S}| + |O_i - \bar{O}|)^2} \quad (9)$$

$$MSE = \frac{\sum_{i=1}^n (O_i - S_i)^2}{n} \quad (10)$$

$$NMSE = \frac{\sum_{i=1}^n (O_i - S_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (11)$$

در روابط فوق S_i داده‌های محاسباتی حاصل از سیستم استنتاج عصبی-فازی، \bar{S} میانگین داده‌های محاسباتی، O_i داده‌های مشاهداتی، \bar{O} میانگین داده‌های مشاهداتی و n تعداد مشاهدات می‌باشد. دامنه تغییرات شاخص توافق ویلموت از $-\infty$ تا ۱ است که مقدار ۱، توافق کامل بین داده‌های مشاهداتی و محاسباتی را نشان می‌دهد. کم بودن مقدار RMSE و بالا بودن ضریب R^2 بیانگر دقت قابل قبول مدل و برتری آن نسبت به مدل دیگر است.

MAE، MSE و NMSE هر کدام به شیوه‌ای اختلاف بین داده‌های مشاهداتی و محاسباتی را نشان می‌دهند، که هر چه این مقادیر کمتر باشند یعنی کار نتیجه بخش‌تر بوده است.

۱۷- نتایج و بحث

۱۷-۱- اجرای مدل شبیه ساز RBFNN در برآورد تراز آب زیرزمینی

در پژوهش حاضر، به منظور تخمین تراز ایستابی آبخوان در محدوده مورد مطالعه بافت از مدل شبکه عصبی تابع شعاع مدار (RBFNN) استفاده شد. کدهای مربوط به این روش‌ها در محیط برنامه‌نویسی نرم‌افزار MATLAB (R2018b) نوشته شد و نتایج حاصل از آن با مقادیر مشاهداتی موجود مورد مقایسه و بررسی قرار گرفت.

در این مقاله به منظور شبیه‌سازی سطح ایستابی آبخوان محدوده بافت در حوضه آبریز هلیل رود از داده‌های اندازه‌گیری شده بارش، تبخیر، آورد رودخانه (آمار هیدرومتری رودخانه)، نیاز آبی مناطق، میزان برداشت از آبخوان و تراز آب زیرزمینی به صورت ماهانه و با طول آماری ۱۴ سال، بین سال‌های آبی ۸۲-۱۳۸۱ تا ۹۵-۱۳۹۴ استفاده شده است. در همین راستا، مدل‌های شبیه‌سازی متفاوت با ساختارهای مختلف توسعه داده شد و در نهایت به منظور شبیه‌سازی تراز آب زیرزمینی در منطقه مورد مطالعه مدل برتر انتخاب شد.

داده‌های ورودی به مدل‌های شبیه ساز شامل، داده‌های بارش ماهانه (Pr)، تبخیر ماهانه (Ev)، آورد ماهانه رودخانه (Hy)، نیاز آبی ماهانه هر منطقه (De)، میزان برداشت از آبخوان در هر ماه (G) و تراز ماهانه آب زیرزمینی (Lev_G) با یک دوره تاخیر زمانی می‌باشد. همچنین در نهایت خروجی مدل شبیه ساز تراز آب زیرزمینی در ماه جاری می‌باشد.

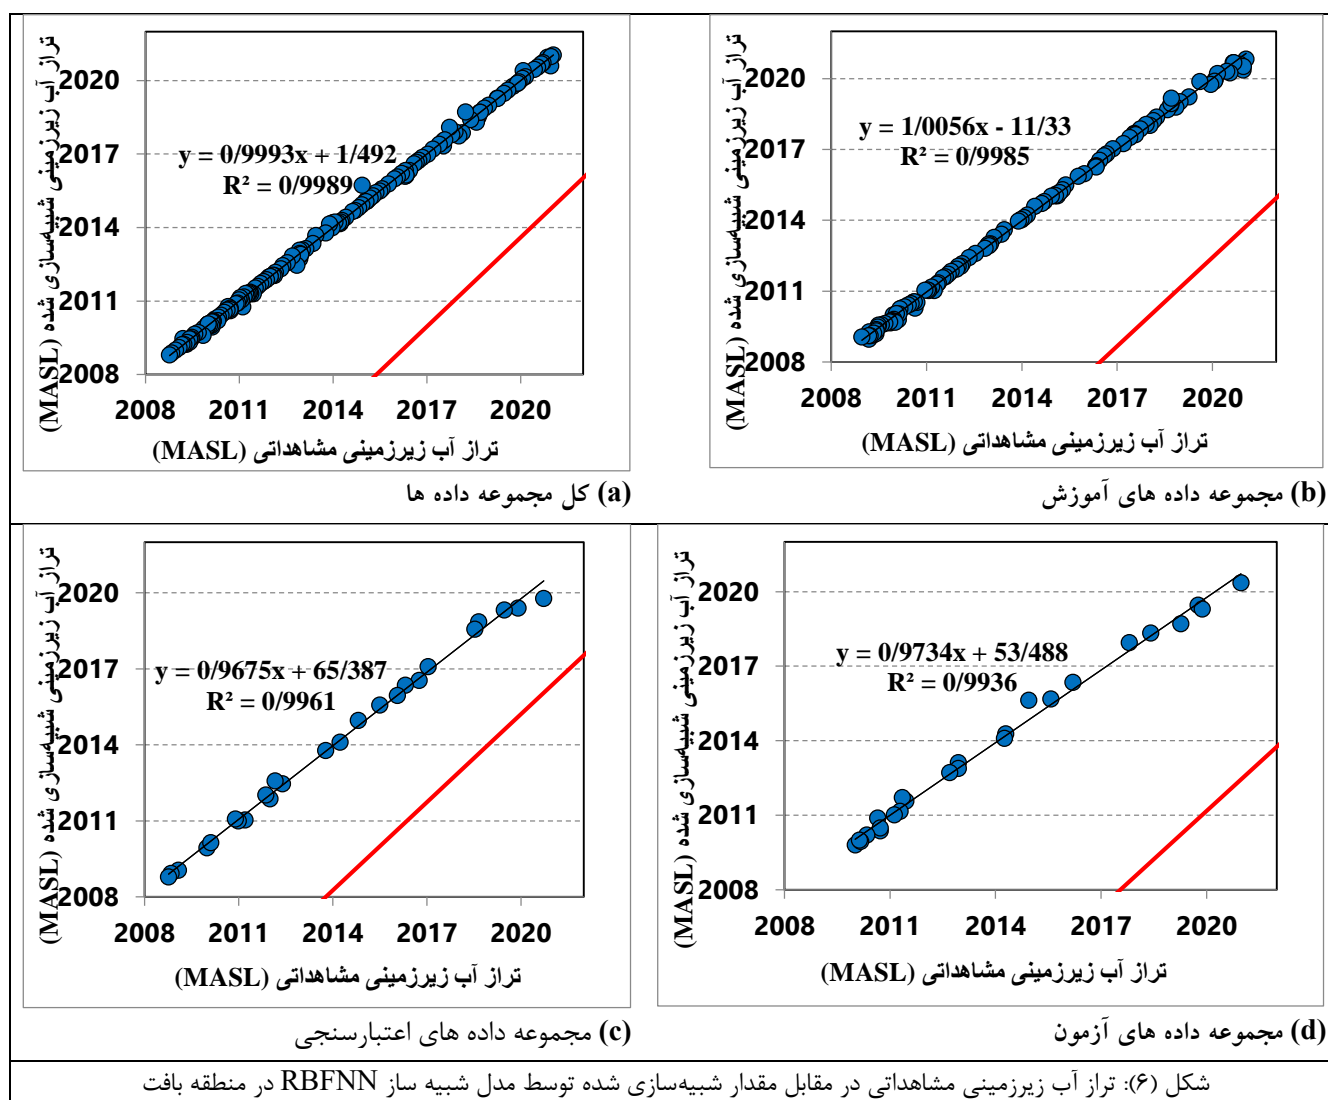
جهت رسیدن به ساختار مناسب در مدل شبیه ساز RBFNN، مدل‌های مختلف با ورودی‌های ذکر شده و ساختارهای مختلف طراحی و آزمون شده و در نهایت بهترین ساختار به منظور تخمین تراز ماهانه آب زیرزمینی انتخاب شد. جدول (۱) نتایج مدل برتر شبیه ساز RBFNN در محدوده بافت برای مجموعه داده های کل، آموزش، اعتبارسنجی و آزمون را نشان می‌دهد.

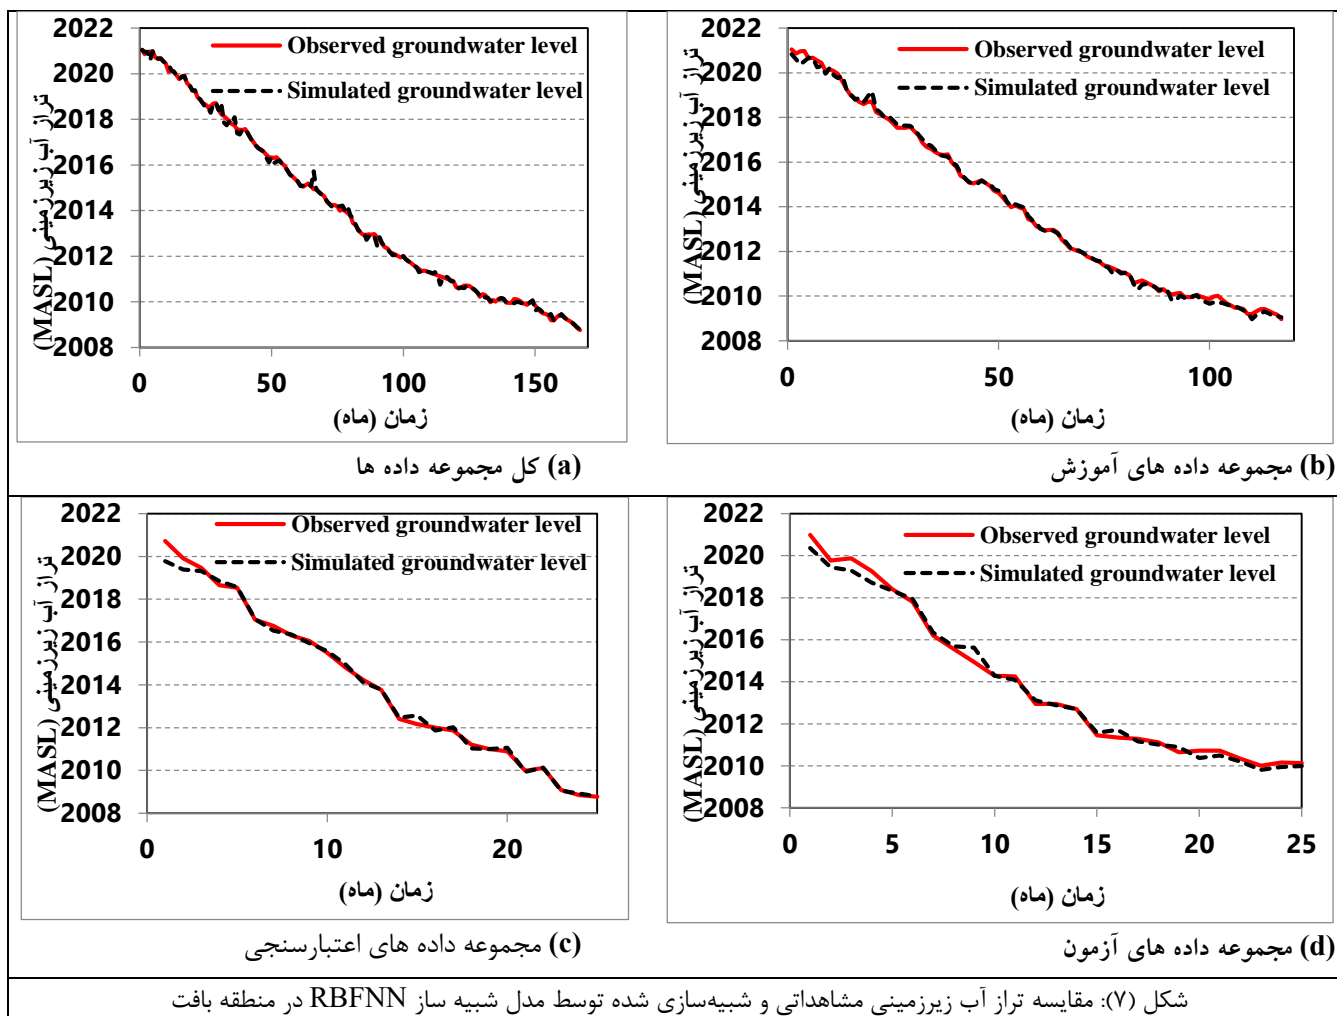
جدول (۱): نتایج پارامترهای آماری مدل شبیه ساز RBFNN در تخمین تراز ماهانه آبخوان منطقه بافت

ورودی ها	مجموعه داده ها	R^2	RMSE	MAE	MSE	NMSE	d
$Ev_{(t)}, Pr_{(t)}, Hy_{(t)}, De_{(t)}, G_{(t)}, Lev_G_{(t-1)}$	کل مجموعه داده ها	۰/۹۹۸۹	۰/۱۲۵۶	۰/۰۶۴	۰/۰۱۵۸	۰/۰۰۱۱	۰/۹۹۹۷
	مجموعه داده آموزش	۰/۹۹۸۵	۰/۱۴۸۸	۰/۱۰۶۵	۰/۰۲۲۱	۰/۰۰۱۶	۰/۹۹۹۶
	مجموعه داده اعتبارسنجی	۰/۹۹۶۱	۰/۲۵۳۶	۰/۱۵۶۲	۰/۰۶۴۳	۰/۰۰۴۸	۰/۹۹۸۷
	مجموعه داده آزمون	۰/۹۹۳۶	۰/۳۰۱۵	۰/۲۳۶۲	۰/۰۹۰۹	۰/۰۰۷۳	۰/۹۹۸۱

همانطور که در جدول (۱) مشاهده می‌شود در محدوده مورد مطالعه مدل شبیه ساز با ساختار ورودی های پیشنهادی عملکرد مناسبی در تخمین تراز آب زیرزمینی داشته است. نتایج نشان داد که شبیه سازی تراز آب زیرزمینی توسط مدل شبکه عصبی تابع شعاع مدار در کل مجموعه داده ها با شاخص های آماری R^2 , RMSE, MAE, MSE, NMSE و d ، $0/064$ ، $0/1256$ ، $0/9989$ و $0/158$ ، $0/011$ و $0/9997$ عملکرد قابل قبولی دارد. همچنین مقادیر شاخص های آماری R^2 , RMSE, MAE, MSE, NMSE و d ، در مجموعه داده های آموزش به ترتیب $0/9985$ ، $0/1488$ ، $0/1065$ ، $0/0221$ ، $0/0016$ و $0/9996$ و در مجموعه داده های آزمون به ترتیب $0/9936$ ، $0/3015$ ، $0/2362$ ، $0/0909$ ، $0/0073$ و $0/9981$ بدست آمد.

نمودارهای پراکنش داده‌های مشاهداتی و شبیه سازی شده توسط مدل RBFNN در تخمین تراز آب زیرزمینی منطقه بافت از حوضه آبریز هلیل رود مربوط به ۴ مجموعه کل داده ها، داده های آموزش، اعتبارسنجی و آزمون در شکل (۶) نشان داده شده است. همچنین تراز آب زیرزمینی مشاهداتی در مقایسه با تراز آب زیرزمینی شبیه‌سازی شده توسط مدل شبیه ساز RBFNN در ماه های مختلف مورد بررسی برای ۴ مجموعه داده در شکل (۷) ارائه شده است.





با توجه به شکل های (۶) و (۷) مشاهده می‌شود که مدل شبیه ساز RBFNN توانایی بالایی در برآورد تراز آب زیرزمینی در منطقه بافت از حوضه آبریز هلیل رود را داشته است. با توجه به عملکرد مناسب مدل شبیه ساز RBFNN که در جدول (۱) و شکل های (۶) و (۷) به اثبات رسید، از این مدل می‌توان به عنوان مدل شبیه ساز در تخمین تراز آب زیرزمینی منطقه بافت استفاده نمود.

۱۸- نتیجه گیری

در این پژوهش با استفاده از مدل شبکه عصبی تابع شعاع مدار (RBFNN) تراز آب زیرزمینی منطقه بافت واقع در استان کرمان در یک بازه زمانی ۱۴ ساله از ۱۳۸۱ تا ۱۳۹۵ به صورت ماهانه شبیه سازی شد. در نهایت به منظور ارزیابی عملکرد مدل از شاخص های آماری استفاده شد. نتایج حاصل از شاخص های آماری نشان داد که مدل شبکه عصبی تابع شعاع مدار به ترتیب با ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، مربع میانگین خطای استاندارد (MSE)، مربع میانگین خطای استاندارد نرمال شده (NMSE) و شاخص توافق ویلموت (d)، ۰/۹۹۸۹، ۰/۱۲۵۶، ۰/۰۶۴، ۰/۰۱۵۸، ۰/۰۰۱۱ و ۰/۹۹۹۷ توانایی بالایی در شبیه سازی تراز آب زیرزمینی دارد و نتایج قابل اطمینانی را ارائه می‌دهد. نتایج این مطالعه نشان داد که مدل های هوش مصنوعی و به طور خاص مدل شبکه عصبی تابع شعاع مدار (RBFNN) ابزاری قدرتمند، دقیق، کارآمد و ارزان هستند که توانایی شبیه سازی تغییرات تراز آب زیرزمینی در بازه های درازمدت را دارند که مسئولین و تصمیم گیران می‌توانند از این ابزارهای مفید برای برنامه ریزی و مدیریت در حوزه آب و منابع آب های زیرزمینی استفاده نمایند.

۱۹- منابع و مراجع

- ۱- ملک زاده، م؛ کاردار، س؛ شعبانلو، س. شبیه سازی تراز آب زیرزمینی با استفاده از مدل ترکیبی موجک-ماشین آموزش نیرومند خودتطبیقی. تحقیقات آب و خاک ایران (علوم کشاورزی ایران)، ۱۳۹۹، ۵۱(۴)، ۹۷۵-۹۸۶. SID. <https://sid.ir/paper/365923/fa>
- ۲- کریمیان، ع؛ اگدرنژاد، ا. شبیه سازی پارامترهای شوری و سطح آب زیرزمینی دشت رامهرمز با استفاده از مدل شبکه عصبی مصنوعی و مدل شبکه عصبی مصنوعی بهینه شده. پژوهش در بهداشت محیط، ۱۴۰۰، ۷(۱)، ۱۷-۲۶. SID. <https://sid.ir/paper/1081510/fa>
- ۳- ترابی پوده، ح؛ نصرالهی، ع. ح؛ دهقانی، ر. ارزیابی مدل شبکه عصبی موجک در پیش بینی منابع آب زیرزمینی (مطالعه موردی: استان لرستان، ایران). هیدروژئولوژی، ۱۴۰۰، ۶(۱)، ۱-۱۲. SID. <https://sid.ir/paper/1036278/fa>
- ۴- کماسی، م؛ قشلاقی، ن؛ شرقی، س. پیش بینی تراز سطح آب با استفاده از مدل ترکیبی پویایی سیستم و شبکه عصبی فازی موجکی. مهندسی عمران و محیط زیست (دانشکده فنی)، ۱۴۰۱، ۵۲(۳) (پیاپی ۱۰۸)، ۱۰۵-۱۱۵. SID. <https://sid.ir/paper/1051218/fa>
- ۵- عسکری، ج؛ اگدرنژاد، ا. مدل سازی آب زیرزمینی با استفاده از روش های هوش مصنوعی (مطالعه موردی: دشت دزفول-اندیمشک). پژوهش در بهداشت محیط، ۱۴۰۱، ۸(۲)، ۱۶۰-۱۷۱. SID. <https://sid.ir/paper/1081450/fa>
- 6-Daliakopoulos, I. N., Coulibaly, P., and Tsanis, I. K. Groundwater level forecasting using artificial neural networks. *Journal of hydrology*, 2005. 309(1-4), 229-240. <https://doi.org/10.1016/j.jhydrol.2004.12.001>
- 7-Nourani, V., Mogaddam, A. A., and Nadiri, A. O. An ANN-based model for spatiotemporal groundwater level forecasting. *Hydrological Processes: An International Journal*, 2008. 22(26), 5054-5066. <https://doi.org/10.1002/hyp.7129>
- 8-Chitsazan, M., Rahmani, G., and Neyamadpour, A. Groundwater level simulation using artificial neural network: a case study from Aghili plain, urban area of Gotvand, south-west Iran. *Geopersia*, 2013. 3(1), 35-46. DOI: 10.22059/jgeope.2013.31930
- 9-Khaki, M., Yusoff, I., and Islami, N. Simulation of groundwater level through artificial intelligence system. *Environmental Earth Sciences*, 2015. 73, 8357-8367. <https://doi.org/10.1007/s12665-014-3997-8>
- 10-Malekzadeh, M., Kardar, S., and Shabanlou, S. Simulation of groundwater level using MODFLOW, extreme learning machine and Wavelet-Extreme Learning Machine models. *Groundwater for Sustainable Development*, 2019. 9, 100279. <https://doi.org/10.1016/j.gsd.2019.100279>
- ۱۱- شرکت سهامی آب منطقه ای کرمان، طرح مطالعات زیست محیطی، منابع و مصارف حوضه غرب جازموریان با رویکردی سیستمی و جامع نگر، گزارش شرکت مهندسی مشاور یکم، وزارت نیرو، ۱۳۸۸.
- ۱۲- یقینی، م؛ اخوان کاظم زاده، م. ر. الگوریتم های بهینه سازی فراابتکاری، تالیف. چاپ اول، انتشارات جهاد دانشگاهی واحد صنعتی امیرکبیر، ۱۳۹۰، ۴۴۸ ص.
- ۱۳- منهای، م. مبانی شبکه های عصبی (هوش محاسباتی). نشر دکتر حسابی، تهران، ۱۳۷۷، ۷۱۵ صفحه.
- ۱۴- محمدی زاده، ر. مدل سازی سطح آب زیرزمینی با استفاده از شبکه عصبی مصنوعی و سری های زمانی چندمتغیره. پایان نامه کارشناسی ارشد، دانشگاه باهنر کرمان، ۱۳۹۱.
- ۱۵- شهریار شاه حسینی، ه؛ موسوی میر کلائی، س. م؛ ملاجعفری، م. الگوریتم های تکاملی مبانی، کاربردها، پیاده سازی، تالیف، چاپ اول، انتشارات دانشگاه علم و صنعت ایران، ۱۳۹۱، ۵۹۰ ص.

- 16-Kia, E., Emadi, A. R., and Fazlola, R. Investigation and evaluation of artificial neural networks in Babolroud River suspended load estimation. *Journal of Civil Engineering and Urbanism*, 2013. 3(4), 183-190. <http://www.ojceu.ir/main/>
- 17-Rosenblatt, J. S., and Aronson, L. R. The decline of sexual behavior in male cats after castration with special reference to the role of prior sexual experience. *Behaviour*, 1958. 12(4), 285-338.