مجله دانش كشاورزی/جلد 18 شماره 1/ سال 1387/ صفحه‌های 1-15

مدل سازي بارش دشت تبريز با استفاده از شبكه‌هاي عصبي مصنوعي

اصغر اصغري مقدم[1*]، وحيد نوراني[2] و عطاا... نديري[3]

تاريخ پذيرش: 86/7/14

1- دانشياردانشكده علوم طبيعي، دانشگاه تبريز
2- استاديار دانشكده مهندسي عمران، دانشگاه تبريز
3- دانشجوي كارشناسي ارشد هيدروژئولوژي، دانشگاه تبريز
*مسئول مكاتبه E-mail:Moghaddam@Tabrizu.ac.ir

چكيده

گسترش سريع استفاده از شبكه‌هاي عصبي مصنوعي [Artificial Neural Networks (ANNs)] به عنوان مدل تجربي و كارآمد در علوم مختلف از جمله هيدرولوژي نشان دهنده ضرورت و ارزش بالاي مطالعه اين مدل هاست. مهمترين كاربردهاي اين مدل ها در هيدرولوژي شامل پيش‌بيني، بهينه‌سازي، دسته‌بندي داده‌ها، محاسبه پارامترهاي هيدرولوژي، ارائه مدل هاي كيفي و غيره مي‌باشد. در اين مقاله از شبكه‌هاي عصبي مصنوعي و فرمول تجربي ارائه شده براي تعيين تعداد گره‌هاي مياني جهت تهية مدل پيش‌بيني بارش دشت تبريز استفاده گرديده است. در اين مدل‌سازي از 6 ساختار مختلف شبكه‌هاي عصبي مصنوعي استفاده شده است. بر اساس نتايج به دست آمده در مراحل مختلف آن بهترين مدل از یک شبكه پيشرو با شش گره ورودي، یک گره خروجي، يك لايه مياني و الگوريتم Levenberg-Marquard (LM) تشكيل شده است كه براي نشان دادن تاثير تعداد گره‌هاي مياني، تنوع نمونه‌هاي آموزشي و چگونگي بدست آوردن كمترين خطاي مدل مورد استفاده قرار گرفته است.

واژه‌هاي كليدي: شبكه پيشرو، شبكه‌هاي عصبي مصنوعي، مدل تجربي، مدل‌سازي بارش

Modeling of Tabriz Plain Rainfall Using Artificial Neural Networks

A Asghari Moghaddam[1*], V Nourani[2] and A Nadiri[3]

[1]Department of Geology, Faculty of Natural Sciences, University of Tabriz, Tabriz, Iran
[2]Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran
[3]MSc Student, Department of Geology, Faculty of Natural Sciences, University of Tabriz, Tabriz, Iran
*Corresponding author: E-mail:Moghaddam@Tabrizu.ac.ir

Abstract

Fast spreading of using artificial neural networks (ANNs), black box and qualified models, in different sciences such as hydrology shows its studying necessity and values. The most important applications of the model in hydrology are water quality modeling and prediction, optimization, classification, estimation of hydrological phenomena and parameters. The aim of this paper was to provide application of artificial neural networks, empirical equation of ascertaining hidden nodes and discussing their strengths and limitations for presenting rainfall artificial neural network forecasting model of Tabriz plain area. In this modeling six different structures of ANNs were used in which the feed forward network with six input nodes and a hidden layer composed the best model. This model was used for showing the effects of learning sample and hidden nodes numbers on minimizing of the model error.

Key Words: ANNs, Black box model, Feed forward network, Rainfall modeling

مقدمه

با توجه به ضرورت شناخت سيستم‌هاي مورد مطالعه در علوم مختلف، مدل‌سازي به طور روزافزوني توسعه پيدا كرده است. مدل ها بسته به اين كه پارامترها و ساختار آنها تا چه حد قابل شناسايي باشند، تقسيم بندي مي‌شوند. مدل هايي كه پارامترها و ساختار (فعل و انفعالات داخل سيستم) آنها به طور كامل قابل شناسايي باشد، مدل هاي رياضي ناميده مي‌شوند. اگر پارامترها و ساختار مدل نامعلوم و فقط وروديها و خروجي‌هاي مدل قابل شناسايي باشند، اين مدل ها را مدل هاي تجربي گويند و مدل هاي بينابيني نيز بين اين دو مدل وجود دارد. مدل هاي فيزيكي با ساختار معين و پارامترهاي نامعين حدواسط اين دو مدل را تشكيل مي‌دهند(اندرسون و مك نيل 1992) (شكل1).

شبكه عصبي مصنوعي به عنوان يک مدل تجربي براي اولين بار از فرموله كردن توانائي‌هاي مغز انسان توسط مک کالچ و پيتس (1943) ارائه گرديد. در دهه اخير با توجه به ضرورت وجود ابزارهاي محاسباتي در مطالعات، تحقيقات گسترده‌اي براي بررسي توانايي شبكه‌هاي عصبي مصنوعي در بدست آوردن، معرفي و محاسبه داده‌ها از تبديل فضاي چند متغيره به فضاي ديگر صورت گرفته است. شبكه‌هاي عصبي مصنوعي گسترش خود را مديون تلاشهاي هاپفيلد در دو دهه اخير مي‌باشند (هايكين 1994). با ارائه يك چهارچوب تئوريك رياضي توسط رامل هارت و مک کللند (1986) براي شبكه‌هاي عصبي، رشد شگرفي در مكانيزم محاسبات پديد آمد. سرانجام كاربردهاي شبكه عصبي مصنوعي در زمينه‌هاي مختلفي مثل فيزيك، مهندسي پزشكي، زيست‌شناسي، مهندسي برق، علوم كامپيوتر، روبات‌ها، پردازش تصوير، مسائل مالي و غيره پديدار شد. در هيدرولوژي، اين مدل هاي غيرخطي به علت عدم استفاده از فرمول‌هاي پيچيده ديفرانسيلي و براي ايجاد رابطه بين داده‌هاي ورودي و خروجي و حساسيت كمتر آنها به خطاي داده‌هاي ورودي و قابليت پردازش موازي داده‌ها مورد استفاده قرار مي‌گيرند (كامديل 1987).

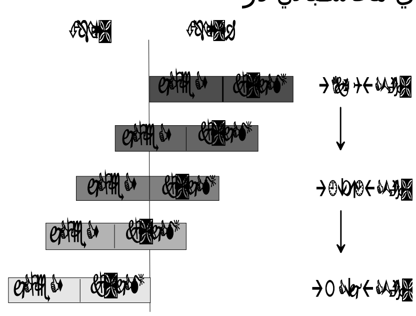

شكل1- تقسيم بندي مدل ها بر اساس اطلاعات اوليه موجود

توضيح جامعي از شبكه‌هاي عصبي در يك سري از مقاله‌ها توسط كامديل (1987، 1988 و1989) ارائه شده است. مهمترين كاربردهاي شبكه عصبي مصنوعي در علوم مهندسي را مي‌توان به صورت زير بيان نمود:

1- دسته‌بندي[1] الگوها (داده‌ها، اشكال وغيره)، 2- خوشه‌بندي[2] الگوها (داده‌ها، اشكال وغيره)، 3- پيش‌بيني در زمينه‌هاي مختلف، 4- بهينه‌سازي، 5- حافظه در دسترس براي ذخيره‌سازي و 6- كنترل سيستم‌هاي مختلف (آنيل و همكاران 1996).

از اواخر دهه 90، شبكه‌هاي عصبي مصنوعي در مسائل هيدرولوژي و هيدروژئولوژي مثل مدل‌سازي بارش و رواناب، پيش‌بيني جريان رودخانه‌ها، مدل‌سازي آبهاي‌زيرزميني، كيفيت آب، مديريت آب، پيش‌بيني بارش و سري‌هاي زماني و غيره استفاده مي‌شوند. از ميان كاربردهاي فوق كه براي شبكه‌هاي عصبي مصنوعي ذكر شد، مدل‌سازي بارش-رواناب و پيش‌بيني بارش در مطالعات آبهاي سطحي از اهميت بالايي برخوردار است و اخيراً مطالعات فراواني بر روي بارش-رواناب و پيش‌بيني بارش در حوضه‌هاي مختلف با اين مدل انجام گرفته است (تيروماليا و دو 1998، مير و دندي 2000 ، توس و همكاران 2000 و ساهو و ري 2006). هدف اين مقاله مقايسة نتايج ساختارهاي مختلف شبكه‌هاي عصبي مصنوعي و تعيين بهترين ساختار براي پيش‌بيني بارش دشت تبريز مي‌باشد.

مواد و روش‌ها

شبكه‌هاي عصبي مصنوعي يك سيستم پردازشگر اطلاعات توده‌اي هستند كه به صورت موازي قرار گرفته‌اند و عملكردي شبيه شبكه عصبي مغز انسان دارند (هاپفيلد 1982). اصول زير نشانگر اساس شبكه‌هاي عصبي مصنوعي مي‌باشند:

1- پردازش داده‌ها در واحدهاي منفردي به نام گره صورت مي‌گيرد. 2- سيگنال‌هاي بين گره‌ها از طريق خطوط ارتباطي انتقال مي‌يابند. 3- وزن نسبت داده شده به هر خط ارتباطي نشانگر قدرت ارتباطي آن خط است. 4- هر گره به طور معمول داراي توابع فعال سازي[3] و تبديل‌گر براي تعيين سيگنال‌هاي خروجي از داده‌هاي ورودي شبكه مي‌باشد.

ساختار شبكه‌هاي عصبي مصنوعي بوسيله الگوي ارتباط بين گره‌ها، متد تعيين وزنهاي ارتباطي و تابع فعاليت، معرفي مي شود (فلچر و ريوز 1964). ساختار عادي يك شبكة عصبي مصنوعي، معمولاً از لايه ورودي، لايه‌هاي مياني (مخفي) و لايه خروجي تشكيل شده است (شكل2). لايه ورودي يك لايه انتقال دهنده و وسيله‌اي براي تهيه كردن داده‌هاست. آخرين لايه يا لايه خروجي شامل مقادير پيش‌بيني شده بوسيلة شبكه مي‌باشد و بنابراين خروجي مدل را معرفي مي‌كند. لايه‌هاي مياني يا مخفي كه از گره‌هاي پردازشگر تشكيل شده‌اند، محل پردازش داده‌هاست. شمار لايه‌هاي مخفي و شمار گره‌ها در هر لايه مخفي به طور معمول بوسيلة روش آزمون و خطا مشخص مي‌شود. گره‌هاي لايه‌هاي مجاور در شبكه به طور كامل با هم در ارتباط هستند.

ورودي‌هاي هر گره ممكن است از متغيرهاي ورودي يا از خروجي گره‌هاي ديگر حاصل شود. هر گره داراي یک تابع تبديل‌گر[4] است (شكل 3 و رابطه 2). ورودي‌ها به شكل یک بردار $X(x_1,x_2,\dots,x_n)$ هستند و هر ورودي توسط یک وزن به گره پردازشگر مربوط مي شود و در نهايت تسلسلي از وزنها به شكل بردار وزن $W(w_1,w_2,\dots,w_n)$ به گره مورد نظر مرتبط مي‌گردد، w_1 وزن ارتباطي از گره لايه پيشين به لايه مزبور را نشان مي‌دهد. خروجي گره كه y ناميده مي‌شود، طبق رابطه (1) محاسبه مي شود:

$$y = f(x.w - b) \qquad [1]$$

كه در اين رابطه x داده‌هاي ورودي، w بردار وزن، b مقدارآستانه يا باياس[5] مي‌باشند. درون هر گره

[1]Classification
[2]Clustering
[3]Activation Function
[4]Transfer Function
[5]Bias

پردازش‌گر تابع تبدیل‌گر، تولیدکننده خروجي‌هاي آن گره به شمار مـي‌رود و يكـي از انـواع مهـم ايـن توابـع، تـابع سيگموئيد مي‌باشد:

$$f(t)=\frac{1}{1+\exp(-tn)} \quad [2]$$

كه در آن f(t) تابع تبديل‌گر، n ورودي خالص نـرون و t تقريبي است كه بيانگر طول قسمت خطي نمودار تـابع تبديل‌گر مي‌باشد، بطوري كه اگـر t بـزرگ باشـد قـسمت خطي تابع بصورت عمودي درآمـده و در واقـع تـابع بـه شکل يک تابع حدي دو مقداره درمي‌آيـد و اگـر t کوچـک باشد، تابع به شکل يک s کشيده در امتداد محور افقـي در خواهد آمد. شكل تابع f(t) تعيين‌كننده جواب يك گـره بـه سيگنال ورودي كلي است، كه آن را دريافت مي‌كنـد. ايـن تابع يك تابع كران‌دار، يكنواخت و غير كاهنده است و بـه علـت سـادگي و كـارايي بـالاي آن، در فرآينـد آمـوزش[1] مورد استفاده قرار مي‌گيرد.

ساختار شبكه‌هاي عصبي مصنوعي

يكي از معيـارهـاي تقـسيم‌بنـدي شـبكه‌هـاي عـصبي مـصنوعي نـوع شـبكه يـا آرايـش گـره‌هـاي ورودي و خروجي و جهت پردازش داده‌هاست كه به صـورت زيـر ارائه مي‌گردد:

1- شبكه‌هـاي پيـشرو[2] **(FFN)** : در يـك شـبكة پيـشرو گره‌هاي پردازش‌گر در لايه‌هاي مخفي قـرار گرفتـه‌انـد و هر شبكه مي‌تواند چندين لايه مخفي و هر لايه مخفي هـم مي‌تواند چندين گره داشته باشد. در اين شبكه‌ها اطلاعات از ورودي به طرف خروجي حركـت مـي‌كننـد. گـره‌هـاي موجود در يك لايه بهم مرتبط نمي‌شوند بلكه گـره‌هـا در يك لايه به لايه بعدي ارتباط مي‌يابنـد. بنـابراين خروجـي يك گره در يك لايه به سيگنالي كه از لايـه قبلـي دريافـت مي‌كند، وزن تعيين شده براي آن و نـوع تـابع تبـديل گـر بستگي دارد (كوليبالي و همكاران 2000).

2- شبكه‌هاي برگشتي[3] **(RNN)** : در ايـن نـوع شـبكه‌هـا داده‌ها بين گره‌ها در دو جهت جريان مي‌يابنـد از ورودي به خروجي و كاملاً برعكس. اين شبكه از خروجي‌هـا بـه عنوان ورودي‌هاي جديد صحيح استفاده مي‌كند، بنابراين به داده‌ها اجازه برگـشت بـه ورودي را مـي‌دهنـد. گـاهي اوقـات بـراي اهـداف خـاص از ارتبـاطـهـاي جـانبي بـين گره‌هاي يك لايـه نيـز اسـتفاده مـي‌شـود. شـكل4 نـشان دهنده زير مجموعه‌هاي اين دو شبكه است كـه هـر كـدام براي اهداف متفاوتي به كار مي‌روند.

الگوريتم‌هاي آموزش

مراحل انجام شده در يک شبكه توسط الگـوريتم‌هـاي رياضـي متفـاوت صـورت مـي‌گيـرد كـه مهمتـرين آنهـا عبارتند از:

1- الگوريتم انتشار خطا به عقب[4] **(BP):** ايـن الگـوريتم مشهورترين الگوريتم براي آمـوزش شـبكه‌هـاي عـصبي مصنوعي بوده و در واقع يک روش كاهش گراديان براي كمينـه كـردن تـابع خطـا مـي باشـد (وازرمـن 1989). داده‌هاي ورودي در جهت خروجـي جريـان مـي‌يابنـد و براي بدست آوردن خطاي شبكه با خروجي مورد انتظار مقايسه مي‌شوند. اين خطا در طي شبكه به طرف ورودي جريان مي‌يابـد و بـر روي وزن‌هـاي ارتبـاطي سرشـكن مي‌شود و به همان نسبت وزنها تعديل مي‌شوند تا شبكه، خروجي مورد نظر را توليد نمايد (فلچر و ريوز 1964). ايـن الگـوريتم مهمتـرين و كـاربردي‌تـرين الگـوريتم در كـارهـاي مهندسـي بـه شـمار مـي‌آيـد و از نظـر فراينـد آموزشـي قابليـت بـالايي دارد (فـالمن و لبيـر 1990). چگونگي كاهش خطاي شبكه از فرمول زير تبعيت مي‌كند:

$$S=\sum_{o}\left|\sum_{p}(V_p-\overline{V})(E_{p,o}-\overline{E}_o)\right| \quad [3]$$

در رابطـه فـوق V_p خروجـي گـره مخفـي جديـد بـراي ورودي‌هاي p ، $\overline{V}$ متوسط خروجي كل داده‌ها، $E_{p,o}$ خطاي شبكه براي خروجـي گـره o از داده‌هـاي p ، $\overline{E}_o$ متوسـط

[1]Training Process
[2]Feedforward Network

[3]Recurrent / Feedback Neural Network
[4]Back Propagation Algorithm

خطاي كلي شبكه و S همبستگي بين خروجي و خطاي شبكه مي‌باشند.

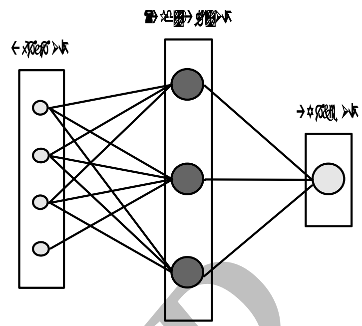

شكل 2- یک شبکه سه لایه معمول

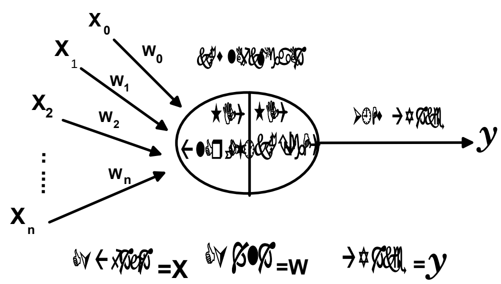

شكل 3- یک گره پردازشگر معمول

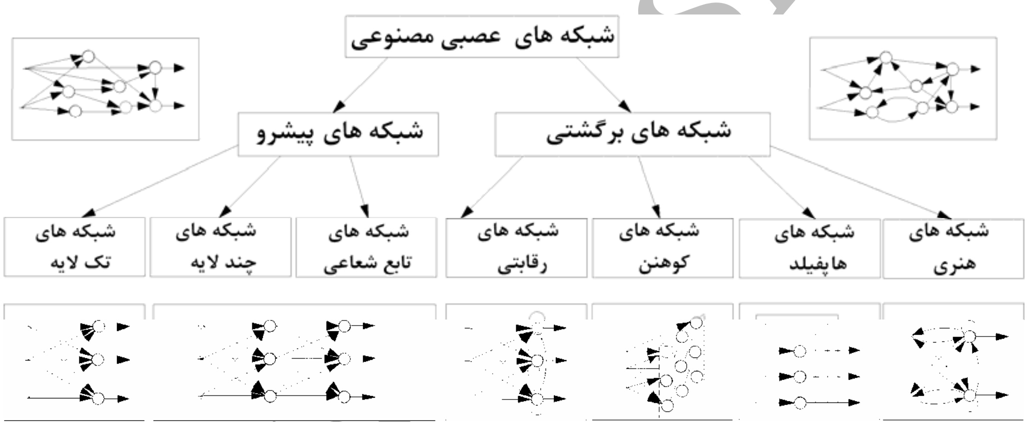

شكل 4- انواع شبكه‌هاي عصبي مصنوعي

2- الگوريتم گراديان مزدوج[1] **(CG)**: اين الگوريتم بر خلاف الگوريتم انتشار خطا به عقب در جهت گراديان خطا عمل نمي‌كند، بلكه در خلاف جهت مرحله قبل عمل مي‌كند (هايكين 1994). با اين عمل اثر تعديل وزن هر مرحله براي مرحله بعدي حذف مي شود. فالمن و ليبري چنين بيان كردند كه اين الگوريتم از توان دوم همگرايي برخوردار است و اين روش مي تواند سرعت فرايند آموزش را در بسياري از موارد افزايش دهد (فاست 1994). در اين الگوريتم از نظر رياضي، تعيين وزنهاي شبكه براي مراحل بعدي از فرمول زير تبعيت مي‌كند:

$$W(n+1)=W(n)+\varepsilon P(n) \qquad [4]$$

[1]Conjugate Gradient Algorithm

كه W(n)،W(n+1) به ترتيب بردارهاي وزن در تكرارهاي n وn+1، ε سرعت آموزش[2] و P(n) نشانگر جهت بردار در سرشكن كردن خطا مي‌باشد.

3- الگوريتم لونبرگ-ماركوارت[3] **(LM)**: اين روش تغيير يافته الگوريتم كلاسيک نيوتن است كه براي پيدا كردن راه حلي مناسب براي مسائلي كه نياز به كمينه‌سازي دارند به كار مي‌رود. اين روش يک تقريب براي ماتريس هيزن[4] در تغيير وزنها مثل روش نيوتن در نظر مي‌گيرد:

$$X_{k+1} = X_k - \left[J^T J + \mu\ I\right]^{-1} J^T + e \qquad [5]$$

[2]Training Rate
[3]Levenberg-Marquardt
[4]Hessian Matrix

در رابطه فوق، X وزنهاي شبكه عـصبي، J ژاكـوبين ماتريس معيـار اجـراي شـبكه كـه بايـد كمينـه شـود، μ عدديست كه فرايند آموزش را كنترل مـيكنـد و e بـردار خطاي باقيمانده است. وقتي μ صفر باشد، معادلـه فـوق همـان روش نيـوتن اسـت كـه از روش هيـزن اسـتفاده ميكند ولي وقتي μ مقداري بزرگ باشد معادله تبديل به يک رابطه كاهش گراديان با فاصله زماني كـم مـيشـود. روش نيوتن از سرعت بالايي برخوردار است و نتايج آن بسيار نزديک به مينيمم خطا خواهد بود. اين الگـوريتم بـا توجه به خـصوصيات فـوق در بـسياري از مطالعـات بـا موفقيت مـورد اسـتفاده قـرار گرفتـه اسـت (مينيـسكي و پـــاپرت 1969، كوليبـــالي و همكـــاران a,b,c 2001 و دياكوپولوس و همكاران 2005). همچنـين ايـن الگـوريتم داراي بــازدهي بــالا و بــسيار پايــدار اســت (تــوس و همكاران، 2000).

تقسيم بندي شبكهها از نظر نوع توابع گرهها

پس از ارائة گرههـاي شـبكههـاي عـصبي مـصنوعي توسط مككالوچ و پيتس، توابع تبـديلگـر ايـن گـرههـاي پـردازشگـر نيـز توسـط خـود آنهـا ارائـه شـد(انجمـن مهندسين آمريكا 2000). توابع موجود در هر گره بـه دو قسمت توابع فعالسـازي و تبـديلگـر تقـسيم مـيشـوند. توابع فعالسازي هر گره، توابعي هستند كه وروديهـاي هر گره و وزنهـاي اضـافه شـده بـه آنهـا را جمـع بنـدي ميكنند. اين توابـع عـلاوه بـر ايـن مـيتواننـد بـر حـسب الگوريتم جاري بر شبكه و نوع شبكه، دادهها را آنـاليز و نرماليزه كرده و ماكزيمم و مينـيمم آنهـا را تعيـين كننـد. اين توابـع بـستگي بـه الگـوريتم انتخـابي دارنـد و تـاثير محـسوسي بـر روي خروجـي شـبكه ندارنـد (آنكتايـل و همكاران 2004).

خروجــيهــاي توابــع فعــالســازي بــراي ايجــاد خروجـيهـاي گـره توسـط توابـع تبـديلگـر پـردازش ميشوند. خروجي اين توابع بسته به نوع تـابع مـيتوانـد در بازه (1,1-) قرار بگيرند. يكي از اين توابع، تابع خطـي است. اين تابع بسيار ساده عمل ميكند و مشكل اساسـي شبكههاي اوليه به حساب ميآمـد (ريـاد و مانيـا 2003). نوع ديگري از اين توابع، توابع آستانه[1] هستند. اين توابـع وروديها را با در نظـر گـرفتن مـاكزيمم و مينـيمم آنهـا، غير خطي ميكنند. مهمترين و كاراترين توابـع تبـديلگـر، توابع سيگمويید يا S شكل است. اين توابـع در بـازههـاي (0,1) و (1,1-) بـه ترتيـب توابـع سـيگموييد و تانژانـت هيپربوليک ناميده ميشود. اشكال متفاوتي از ايـن توابـع وجـود دارنـد و در حـال توسـعه هـستند. ايـن توابـع در كارهاي مهندسي و از جمله هيـدرولوژي كـاربرد بـسيار بالا دارند (شكل5).

تقسيم بندي شبكهها از نظر نوع آموزش

1- نظارت شده[2]: در اين نوع آموزش شبكه به يك معلم يـا تعلـيمدهنـده خـارجي (دادههـاي مـشاهدهاي) بـراي راهنمائي فرآيند آموزش نياز دارد. در ايـن روش شـمار زيادي از دادههاي ورودي و خروجي براي آمـوزش بـه كار ميروند و آمـوزش شـبكه بوسـيله بهينـه سـازي و تعديل وزنهاي ارتباطي و مقادير بحراني به روش تكـرار صورت ميگيرد.

2- غيرنظارت شده: در طي اين آمـوزش تنهـا دسـتهاي از دادههاي ورودي بـراي شـبكه تهيـه شـده و وزنهـاي ارتباطي به طور اتوماتيك و بدون وجـود خروجـيهـاي تعليمدهنده تعديل ميشوند. اين روش در علوم مهندسي كاربرد زيادي ندارد و براي اولين بار توسـط كوهـونن (1984) ابداع گرديده است.

ارزيابي دقـت مـدل: معمـولاً دو معيـار مختلـف زيـر بـه منظـور ارزيـابي كـارايي هـر شـبكه و توانـائي آن بـراي پيشگوئي دقيق استفاده مـيشـود. ريـشه مربـع متوسـط خطا (MSE) به صورت زير محاسبه ميشود :

$$MSE = \Sigma_{i=1}^{n} \frac{(y_i - \hat{y})^2}{N} \qquad [6]$$

[1]Threshold Function
[2]Supervised

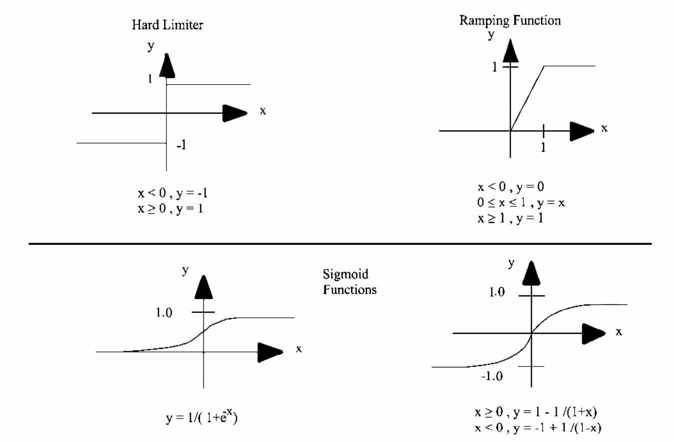

شكل 5- مهمترين توابع تبديل گر شبكه‌هاي عصبي مصنوعي

در رابطـه فـوق، y_i نتـايج مـشاهداتي و $\hat{y}_i$ نتـايج محاسباتي و N تعداد كل مـشاهدات اسـت MSE اخـتلاف مابين مقـدار مـشاهده شـده و مقـادير محاسـبه شـده را نـشان مـي‌دهـد. كمتـرين مقـدار MSE بـالاترين صـحت پيشگوئي را نشان مي‌دهد. همچنـين R^2 (ضـريب تبيـين[1]) نشانگر ميزان بازده شبكه مي‌باشد كـه بـه صـورت زيـر ارائه مي‌گردد:

$$R^2=1-\frac{\sum (y_i-\hat{y}_i)^2}{\sum y_i^2-\frac{\sum \hat{y}_i^2}{n}} \qquad [7]$$

بهترين جواب براي مدل هنگامي ايجاد خواهـد شـد R^2 و MSE كه به ترتيب به يك و صفر ميل كنند.

منطقه مطالعاتي

در اين تحقيق دشـت تبريـز بـه عنـوان منطقـه مـورد مطالعـه بـراي مـدل‌سـازي بـارش و كـاربرد مـدل هـاي شبكه‌هاي عصبي مصنوعي انتخاب گرديد. اين دشت يكي از دشتهاي شمال‌غرب كشور و جزء منـاطق نيمـه‌خـشك محسوب مي‌شود (شكل6). دشت تبريز قسمتي از حوضه درياچه اروميه مي‌باشد و بزرگترين رودخانه موجود در اين دشـت آجـي‌چـاي (تلخـه رود) نـام دارد كـه بـه ايـن درياچه منتهي مي‌شود. در طي فـصول پـربـارش بيـشتر بارشـهاي ايـن دشـت تحـت تـاثير جريانهـاي جـوي بارش‌زايي كه از طرف درياي مديترانه صورت مي‌گيـرد، حاصل مي‌شـود. در ايـن منطقـه بيـشينة بـارش بـاران و بـرف بـه ترتيـب در فـصول بهـار و زمـستان صـورت مي‌گيرد. بر اساس داده‌هاي ايستگاه هواشناسي فرودگاه تبريز، متوسط دماي ماهانة هوا در اين منطقـه از 0/3 °C در اسفند تا 26 °C متغير است و متوسـط دمـاي سـالانة آن 11/5 °C و متوسط بارش سالانة آن در بـازة زمـاني 15 سـاله (1384-1369)، 257 ميلـي‌متـر مـي‌باشـد. بـر اساس همين داده‌ها، بيشينه رطوبت نسبي 75 تا 80% در ماه‌هاي آبان و بهمن و كمينه آن 35 تا 45% در مـاه‌هـاي تير و مرداد مي‌باشد. براي مطالعه تاثير تعداد نمونه‌هـاي آموزشـي و گـره‌هـا در نتـايج بدسـت آمـده در مرحلـه آموزش و صـحت‌سـنجي در ايـن مـدل هـا، از يـک مـدل شبكه‌هـاي عـصبي مـصنوعي كـه بـه ايـن منظـور بـراي پيش‌بيني بارش ماهانه در محدودة دشت تبريز مدل شـد، اسـتفاده گرديـد. در ايـن مـدل سـازي از شـش سـاختار مختلف-RNN ,RNN-CC ,FNN-LM ,FNN-GC ,FNN-CC) (GC ,RNN-LM اسـتفاده شـده اسـت. بـراي هـر يـك از ساختارهاي فوق سه مرحلة كلي آموزش، صحت‌سـنجي، آزمايش صورت گرفته است. بر اسـاس نتـايج بـه دسـت آمده بهترين مدل از يک شبكه پيشرو سـه لايـه بـا شـش گره ورودي، يک گره خروجي (متوسـط بـارش) و شـش گره مياني و الگوريتم LM تشكيل شـده اسـت. نتـايج بـه

[1] Determination Coefficient

دست آمده از ساختارهاي مختلف در بخش بحث و نتايج ارائه شده است.

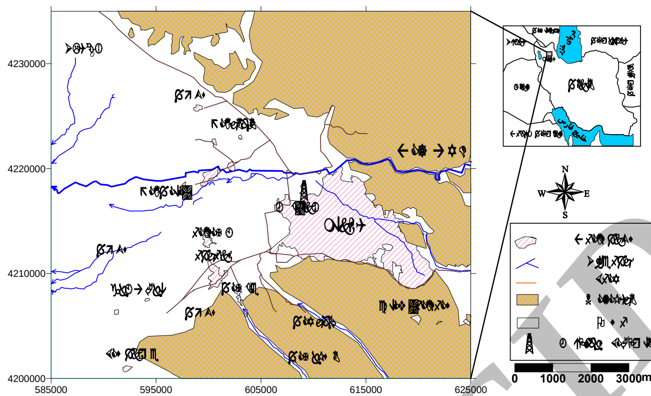

شکل **6**- موقعيت منطقه مطالعاتي و ايستگاه سنوپتيك

آموزش شبكه‌هاي عصبي مصنوعي

براي اينكه شبكه عصبي مصنوعي بتواند خروجي را تا حد امكان نزديك به بردار هدف كند به فرايند آموزش نياز دارد. آموزش عبارت است از پيدا كردن مناسب‌ترين بردار وزني w و بردار bias وكمينه‌سازي كردن تابع خطاي از پيش تعيين شده كه معمولاً به صورت رابطه 8 تعريف مي‌شود:

$$E = \sum_{P} \sum_{b} (y - t)^2 \qquad [8]$$

كه در تابع فوق t نتايج مشاهداتي، y نتايج محاسباتي، b تعداد گره‌هاي خروجي، P تعداد داده‌هاي آموزشي مي‌باشند.

اين مرحله از مدل شبيه كاليبراسيون است كه در بيشتر مدل هاي هيدرولوژي استفاده مي‌شود. هدف اوليه آموزش كمينه كردن تابع خطا بوسيله جستجوي قدرت ارتباطي و مقادير بحراني است كه باعث مي‌شود شبكه خروجي‌هائي برابر يا نزديك به مقادير هدف (داده‌هاي مشاهداتي) توليد كند. بعد از اينكه آموزش پايان يافت، شبكه براي دادن جوابهاي منطقي به داده‌هاي جديد توانا مي‌شود. در صورت تعيين توابع تبديل‌گر مناسب، تهيه داده‌هايي با دقت بالا و شبكه‌اي كارآمد، معمولاً آموزش اين مدل ها به مناسب‌ترين نحو صورت مي‌گيرد.

جمع‌آوري، آناليز و بررسي آماري و نرمال كردن داده‌هاي مورد نياز

در اين مرحله ابتدا داده‌هاي بارش و دماي ماهانة 15 ساله (1384-1369) در محدودة مطالعاتي از ايستگاه سينوپتيك فرودگاه تبريز تهيه گرديد. داده‌هاي جمع آوري شده پس از آناليز آماري (رسم Spline براي داده‌هاي هر پارامتر) در دسته‌هاي كلي(متوسط بارش ماهانه در زمان t و t-1، دماي متوسط، دماي بيشينه و كمينه در زمانt+1 از ايستگاه فوق) تقسيم بندي شدند. منظور از متوسط بارش ماهانه در بازه زماني (t-1,t) عبارت از دسته‌بندي داده‌هاي متوسط بارش ماهانه براي زمان حال (t) و با يک زمان تأخير (t-1) است. بارش و دماي ماهانه از ايستگاه سنوپتيك فرودگاه تبريز به عنوان بخشي از داده‌هاي خام اين مطالعه، در شكل 7 ارائه شده است. در بيشتر موارد داده‌هاي ورودي شبكه بايد نرمال شوند(انجمن مهندسين آمريكا 2000). چندين روش براي نرمال كردن داده‌هاي مورد استفاده، وجود دارد. از جمله مي‌توان به تقسيم داده‌ها به ماكزيمم آنها و نرمال كردن داده‌ها بوسيله تعيين متوسط و انحراف استاندارد آنها اشاره نمود، كه در اين روش ابتدا مقدار متوسط را برابر صفر گرفته و مقادير انحراف استاندارد به صورت منفي يا مثبت به مقدار صفر اضافه مي‌شود.

در اين مطالعه براي نرمال كردن داده‌ها از روش زير استفاده شده است(انحراف معيار داده‌ها= δ): [9]

$$X_{normalise} = \frac{X_{input} - \overline{X}}{\delta}$$: داده‌ها ی ورودی

$$Y_{normalise} = \frac{Y_{input} - \overline{Y}}{\delta}$$: داده‌های خروجی

در روابط فوق X,Y به ترتيب خروجي‌ها و ورودي‌هاي مدل و $\overline{X},\overline{Y}$ به ترتيب متوسط خروجي‌ها و ورودي‌هاي مدل مي‌باشد.

نتايج و بحث

1- آناليز حساسيت بر روي داده‌هاي ورودي: با تغيير پارامترهاي ورودي (حذف و اضافه كردن آنها با تأخيرهاي مختلف، t,t-1,t-2) و بررسي نتايج به دست آمده از مدل، پارامترهاي موثر (متوسط بارش در زمان t وt-1، دماي متوسط در زمانt+1 از ايستگاه فوق) در مدل مورد نظر شناسايي شد و در مراحل بعد پارامترهايي كه اثر نامحسوس بر نتايج مدل داشتند حذف شدند. داده‌هاي نرماليزه شده به سه دسته آموزشي، صحت سنجي و آزمايش تقسيم شدند اين دسته‌بندي در اين مرحله و بصورت آزمون و خطا صورت مي‌گيرد. معمولاً 40 تا 60 درصد داده‌ها براي آموزش و بقيه به طور مساوي براي استفاده در دو مرحله باقي مانده تقسيم مي‌شوند كه در اين تحقيق 60 درصد داده‌ها براي مرحلة آموزش و بقيه به دو قسمت تقسيم شده و براي مراحل صحت سنجي و آزمايش در نظر گرفته شد. خروجي مدل در تمام مراحل شامل متوسط بارش(در بازه زماني t+1) در محدودة مطالعاتي است.

2- آموزش شبكه عصبي مصنوعي با الگوريتم **LM**: در اين مرحله با استفاده از پارامترهاي نرمال موثر در مدل شبكه پيشرو بوسيلة الگوريتم LM آموزش داده شد. مهمترين و اصلي‌ترين مراحل آموزش اين مدل شبكة عصبي مصنوعي تعيين گره‌هاي مياني و تعداد داده‌هاي آموزشي مي‌باشد كه در زير در بخش 3-1 و3-2 بطور كامل توضيح داده شده است.

2-1- بررسي تاثير تعداد داده‌هاي آموزشي بر نتايج شبكه: داده‌هاي آموزشي و نتايج به دست آمده از آن (شكل 8 الف و ب) ، بهترين نتيجه آموزش ممكن براي شبكة سه لايه مورد نظر را در حالت ايده آل با شش گره مياني نشان مي‌دهد. شكل 8 الف و ب به ترتيب نتايج آموزش اين شبكه را با 33 درصد داده‌هاي آموزشي و كل آنها را نشان مي‌دهد، كه با داده‌هاي كم خطاي مرحله آموزش كم (نتايج كاملاً به مقادير هدف نزديک مي شود) و خطاي مرحله صحت سنجي بسيار بالا خواهد بود(شكل 8 الف). با افزايش تعداد داده‌ها به اندازه كافي (شكل8 ب)، خطاي مرحله آموزش بيشتر از شكل شكل 8 الف است اما خطاي مرحله صحت سنجي آن كمتر است. در شكل 8 ج به طور شماتيک چگونگي نزديک نرخ متوسط خطاي مرحله آموزش و آزمايش، با افزايش گره‌ها (در10مرحله) نشان داده شده است. اين آزمايش در يک شبكة يكسان از نظر فاكتورهاي موثر بر خطا (تابع فعال سازي، نوع شبكه و ورودي‌ها و خروجي‌ها و...) صورت گرفته است.

2-2- بررسي تاثير تعداد گره‌هاي پردازشگر بر نتايج شبكه: با همان شبكه فوق آزمايش ديگري براي تعيين تاثير تعداد گره‌هاي پردازشگر در نتايج اين مدل انجام شد. شكل9(الف و ب) داده‌هاي آموزشي، نتايج به دست آمده از آموزش و بهترين نتيجه آموزش ممكن را نشان مي‌دهد. اين نتايج از يک شبكة سه لايه با داده‌هاي آموزشي يكسان و به ترتيب با 8 گره و 20 گره مياني حاصل شده است. شكل 9 ب نشانگر حالتي در نتايج است كه به آموزش زياد[1] معروف مي باشد. اين حالت در مواقعي ايجاد مي‌شود كه تعداد گره‌ها بيش از ميزان بهينه براي مدل مورد نظر باشد و يا داده‌هاي آموزشي

[1] Over training

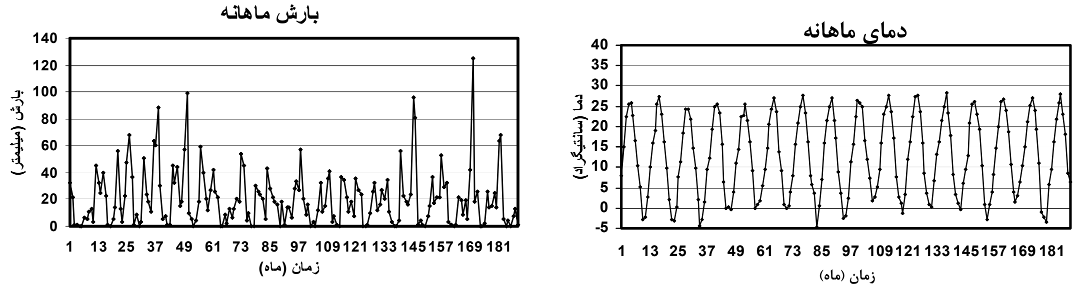

الف ب

شکل 7- داده‌هاي ایستگاه سینوپتیک فرودگاه تبریز الف) دماي ماهانه در بازه زماني (**1384-1369**) ب) بارش ماهانه در بازه زماني (**1384-1369**)

داراي خطاي بالايي باشند که مي توان با دسته بندي داده‌ها و حذف خطاهاي موجود و بهینه کردن گره‌ها بر این مشکل فائق آمد. این مثال نشان مي‌دهد که افزایش گره‌هاي پردازشگر باعث کاهش خطا در مرحله آموزش مي‌شود، اما لزوماً خطاي مرحله صحت‌سنجي را کاهش نمي‌دهد. معمولاً تا رسیدن گره‌ها به میزان بهینه آن براي مدل هر دو خطا روند نزولي داشته و عبور از تعداد بهینه گره‌هاي میاني، باعث افزایش میزان خطا در شبکه مي‌شود که به این حالت اثر به اوج رسیدن[1] تعداد گره‌ها مي‌گویند. شکل9 ج به طور شماتیك میزان متوسط خطاي آموزش و صحت سنجي در شبکه فوق را در مقابل تعداد گره‌هاي مخفي نشان مي‌دهد.

یکي از عوامل موثر در مرحله آموزش سرعت یادگیري مي‌باشد که زمان لازم براي یادگیري شبکه را تعیین مي کند . این زمان معمولاً به فاکتورهاي متنوعي (مثل نوع شبکه، اندازه آن، نوع الگوریتم، تابع تبدیل‌گر و غیره) بستگي دارد و داراي بازه عددي بین (0،1) است. این فاکتور اگر بالاتر از یک در نظر گرفته شود، الگوریتم زمان زیادي براي تعیین وزنها در نظر مي‌گیرد و شاید هیچگاه شبکه تثبیت نشود و اگر کم در نظر گرفته شود مدل داراي خطاي بسیار بالايي خواهد بود. معمولاً بهترین مقدار سرعت یادگیري براي کارهاي هیدرولوژیکي بسته به حجم داده‌ها در بازه(0/3تا 0/7) مي باشد. در این تحقیق نیز سرعت یادگیري 0/6داراي نتایج قابل قبولي بود. تعداد گره‌هاي لایه میاني به طوري که شبکه به شکل بیضوي یا تخم مرغي در آید از بهترین روشهاي تجربي معمول براي تعیین تعداد گره‌هاي لایه میاني است (انجمن مهندسین آمریکا 2000).

در این تحقیق فرمول تجربي زیر براي تعداد گره‌هاي لایه میاني استفاده گردید:

$$(A+1)B+(B+1)C \le \frac{1}{10}\times D \qquad [11]$$

در رابطه فوق A تعداد گره‌ها در لایه ورودي، B تعداد گره‌ها در لایه میاني، C تعداد گره‌ها در لایه خروجي، D تعداد دوره‌هاي آموزشي مي‌باشد.

فرمول تجربي فوق حاصل مطالعات قبلي انجام گرفته توسط مولفین و مطالعات صورت گرفته در این تحقیق مي‌باشد. با بررسي‌هاي انجام یافته مي‌توان گفت که این فرمول در بیشتر مطالعات اخیر از دقت خوبي برخوردار است. پس از انجام مراحل فوق نتایج مرحله آموزش مدل مذکور به صورت شکل 10 بدست آمده است و نتایج به دست آمده از ساختارهاي مختلف براي مرحلة آموزش در جدول 1 ارائه شده است. ممکن است تا سه بار مراحل آموزش و صحت‌سنجي تکرار شود تا مدل به نتیجه مطلوب برسد. بهترین شکل مدل، حالتي است که سیستم در مقابل داده‌هاي این مرحله

[1] Peaking effect

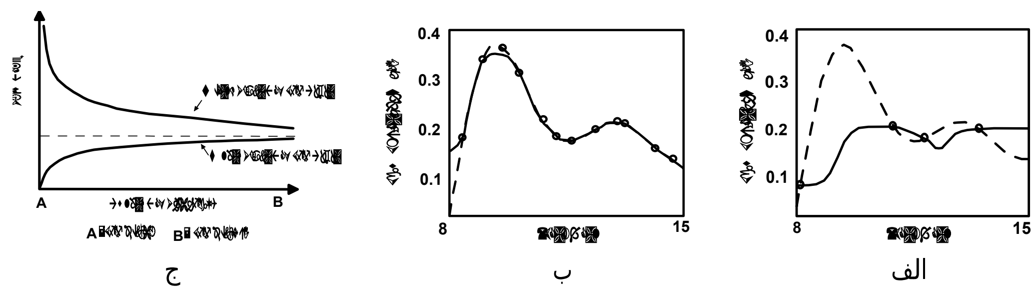

شكل **8**- شكل شماتيكي از تاثير تعداد داده‌هاي آموزشي بر خطاي شبكه(دايره: داده‌ها، خط پيوسته : نتيجه به دست آمده، خط نا پيوسته: بهترين نتيجه مدل). الف) بخشي از نمودار نتايج شبكه با **33** درصد داده‌هاي آموزشي ب) بخشي از نمودار نتايج شبكه با كل داده‌هاي آموزشي ج) نمودار همگرايي مدل با افزايش نمونه‌هاي آموزشي

رفتاري شبيه مرحله آموزش داشته باشد كه اين مرحلـه را تعميم[1] مي‌گويند. اگر با انجام مراحل فوق دقت مطلوب حاصل نشود، در هر مرحله به تعداد گره‌ها و يا لايه‌هـاي مياني برحسب هدف مـورد نظـر افـزوده مـي‌گـردد. ايـن افزايش گره‌ها تا زماني كه تعداد آنها به ميزان بهينه براي مدل برسد، ادامـه مـي‌يابـد و باعـث كـاهش خطـاي مـدل مي‌شود. اگر حجم يا ابعاد مدل از مقدار بهينه (كه در هـر مدل بسته به داده‌هاي ورودي و خروجي، ساختار مـدل، تابع فعاليت و نوع شبكه متفاوت است) بالاتر رود، ميزان خطا افزايش مي‌يابد. شكل11 الف بـه صـورت شـماتيک رابطه بين ابعاد سيستم با مقدار بحراني (bias)، واريـانس و MSE شكل 11ب رابطه بين ابعاد و اندازه شـبكه را بـا خطا در مرحله آموزش و صحت‌سنجي را نـشان مـي‌دهـد. نتيجة بدست آمده براي مرحلة صحت‌سنجي مدل پيش‌بيني بارش، در محدودة مطالعاتي در شكل 12 الـف ارائـه شـده است و نتايج به دست آمـده از سـاختارهاي مختلـف بـراي مرحلة صحتسنجي در جدول 2، ارائه شده است.

آزمايش مدل شبكه عصبي

اين مرحله از مـدل‌سـازي در حقيقـت همـان مرحلـة بررسي نتايج نهـايي مـدل اسـت. در صـورتي كـه نتـايج مرحله صحت‌سنجي پس از انجام مراحل فوق قابل قبـول باشد با سومين قـسمت از داده‌هـا، مـدل مـورد آزمـايش قرار مي‌گيرد. در غير اينصورت مراحل فوق بـا تغييراتـي كه مي‌تواند بر بهبود نتايج تاثير گذارد تكرار مي‌شود. در اين تحقيق با توجه به تكرار چندين باره مراحـل آمـوزش و صحت‌سنجي جهت تعيين ساختار مـدل و دسـته‌بنـدي داده‌ها براي مراحل مختلف مدل، نتـايج حاصـل شـده در مرحله آزمـايش در مـدل‌سـازي بـارش دشـت تبريـز در شكل 12ب نشان داده شده است و نتايج به دسـت آمـده از ساختارهاي مختلف براي مرحلة آزمـايش در جـدول 3، ارائه شده است.

نتيجه گيري

شبكة عصبي مصنوعي به عنوان يک مدل تجربي، به علت عدم استفاده از فرمول هاي پيچيده ديفرانسيلي و ايجـاد رابطـة دقيـق بـين داده‌هـاي ورودي و خروجـي، حـساسيت كمتـر بـه خطـاي داده‌هـاي ورودي و قابليـت پردازش موازي داده‌ها مورد استفاده قرار مي‌گيـرد. ايـن مدل ها به علت توانايي بالا در مـدل‌سـازي و اسـتفاده از شبكه‌ها، الگوريتم‌ها و توابع متنوع قادر به حـل بـسياري از مـسائل پيچيـده و پـيش‌بينـي پديـده‌هـاي هيـدرولوژي مي‌باشند. با وجود نتايج نـسبتاً قابـل قبـول سـاختارهاي مختلـف مـورد بحـث در ايـن تحقيق،كـاراترين شـبكه، الگوريتم و توابع در پيش‌بيني بـارش محـدودة مطالعـاتي

[1]Generalization

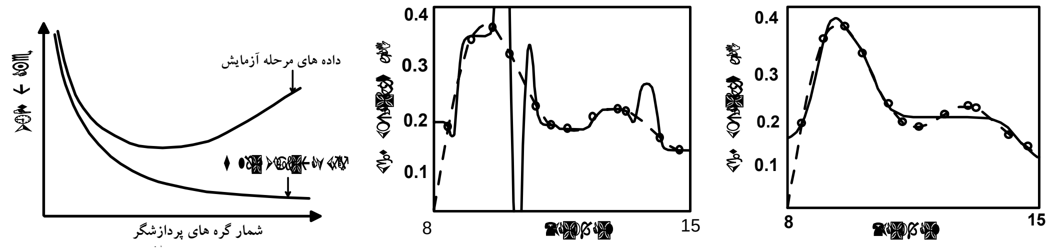

الف ب ج

شكل **9**- تاثير تعداد گره‌هاي پردازشگر بر خطاي شبكه(دايره: داده‌ها، خط پيوسته : نتيجه به دست آمده، خط نا پيوسته: بهترين نتيجه مدل). الف) بخشي از نمودار نتايج شبكه با **6** گره پردازشگر در لايه مياني ب)بخشي از نمودار نتايج شبكه با**20** گره پردازشگر در لايه مياني ج) شكل شماتيک تاثير افزايش گره‌هاي پردازشگر بر خطاي شبكه

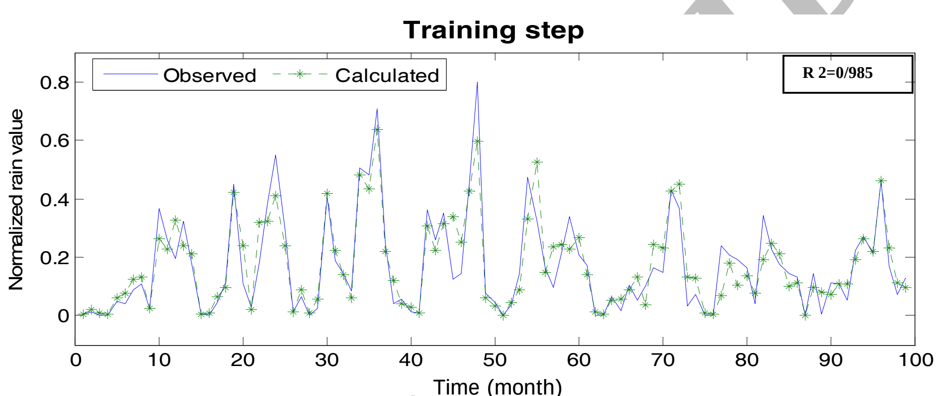

شكل **10**- نتايج مدل پيش‌بيني بارش براي دشت تبريز

جدول **1**- ضرايب تبيين به دست آمده براي ساختار هاي مختلف در مرحله آموزش

[illegible]	FNN-BP	FNN-GC	FNN-LM	RNN-LM	RNN-BP	RNN-GC
[illegible] R^2	[illegible]	[illegible]	[illegible]	[illegible]	[illegible]	[illegible]

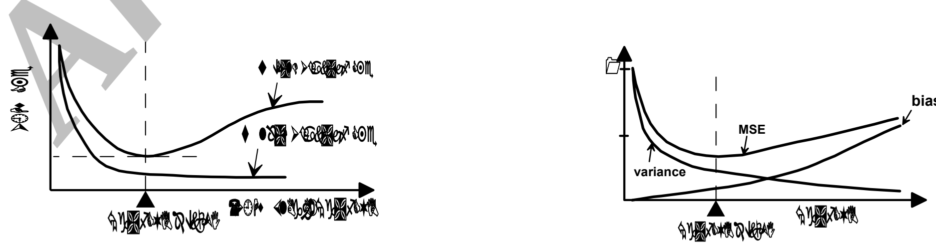

ب الف

شكل **11**- ابعاد شماتيك مدل نسبت به خطاي شبكه، واريانس خطا، باياس الف)رابطه بين **Variance, MSE, bias** ب)رابطه بين ابعاد و خطاي شبكه

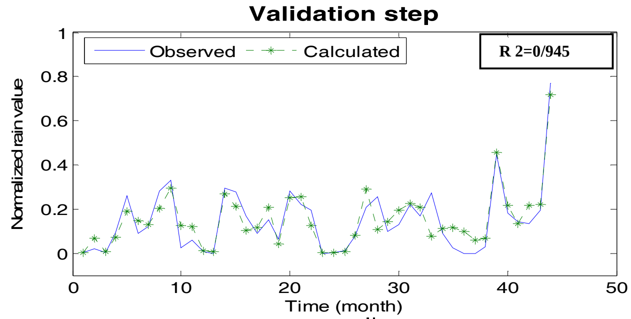

الف

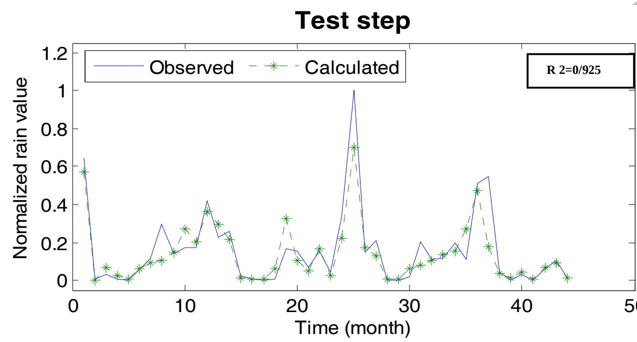

ب

شكل 12- نتايج مدل در مرحله(الف) صحت سنجي و (ب)آزمايش

جدول 2- ضرايب تبيين به دست آمده براي ساختار هاي مختلف در مرحله صحت سنجي

[illegible]	FNN-BP	FNN-GC	FNN-LM	RNN-LM	RNN-BP	RNN-GC
[illegible] R^2	[illegible]	[illegible]	[illegible]	[illegible]	[illegible]	[illegible]

جدول3- ضرايب تبيين به دست آمده براي ساختار هاي مختلف در مرحله آزمايش

[illegible]	FNN-BP	FNN-GC	FNN-LM	RNN-LM	RNN-BP	RNN-GC
[illegible] R^2	[illegible]	[illegible]	[illegible]	[illegible]	[illegible]	[illegible]

بـه ترتيـب شـبكه پيـشرو، الگـوريتم LM و توابـع سيگموئيدي مي‌باشد. نتـايج حاصـل از ايـن مـدل‌سـازي نشان داد با افزايش گره‌هاي مياني تا حد بهينه آن و نيـز افـزايش تعـداد داده‌هـاي ورودي مـدل كـارايي بـالاتري خواهد داشت. براي بدست آوردن مدلي بهينه مي‌تـوان از رابطه نموداري ارائه شده بين باياس، ابعاد مدل، متوسط خطا و واريانس كمك گرفت. شـبكه‌هـاي برگـشتي نتـايج ضعيف‌تري نسبت به شبكه‌هاي پيشرو نـشان دادنـد كـه دليل آن را مي‌توان به پيچيده بودن شبكه‌هاي برگشتي و كارايي پايين الگوريتم‌هـا در بـه كـارگيري ايـن شـبكه‌هـا دانست. نتايج قابل قبول بـه دسـت آمـده از مـدل بـارش دشت تبريز كارايي و چگونگي استفاده از اين مـدل هـا را نشان مي‌دهد. اين مدل سازي و ارائه چهارچوب اين نـوع مدل ها و فرمول تجربي، براي فـائق آمـدن بـه مـشكلاتي

همچون تعيين تعداد گره‌هاي مياني، چگونگي تقسيم‌بنـدي داده‌ها براي مراحل آمـوزش، صـحت‌سـنجي و آزمـايش مي‌تواند راهگشاي بسياري از مطالعات هيدرولوژيكي بـا اسـتفاده از ايـن مـدل هـا باشـد. اسـتفاده از شـبكه‌هـاي عصبي مصنوعي براي بررسي و پيش‌بيني سـطح آبهـاي زيرزميني در محدودة مطالعاتي با ايجاد رابطة بين آبهاي سطحي و زيرزميني مي‌توانـد بـه عنـوان پيـشنهاد بـراي ادامه اين تحقيق ارائه گردد.

منابع مورد استفاده

Anderson D and McNeill1 G, 1992. Artificial neural networks technology. Kaman Sciences Corp, New York, 83p.

Anctial F, Perrin C and Andreassian V, 2004. Impact of the length of observed records on the performance of ANN and conceptual parsimonious rainfall-runoff forecasting models. Environ Modeling Software 19: 357-368.

Anil KJ, Mao J and Mohiuddin KM, 1996. Artificial neural network: a tutorial. IEEE.

ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000. Artificial neural network in hydrology, part I and II. J Hydrol Eng 5: 115-137.

Camdill M, 1987. Neural network primer I. AI Expert.

Camdill M, 1988. Neural network primer II, III, IV and V AI Expert.

Camdill M, 1989. Neural network primer VI, VII and VIII. AI Expert.

Coulibaly P, Anctil F and Bobée B, 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. J Hydrol 230: 244-257.

Coulibaly P, Anctil F, Aravena R and Bobée, B, 2001a. Artificial neural network modeling of water table depth fluctuation. Water Resour Res 37: 885-896.

Coulibaly P, Anctil F and Bobée B, 2001b. Multivariate reservoir inflow forecasting using temporal neural networks. J Hydrol Eng 9-10: 367-376

Coulibaly P, Bobee B and Anctil F, 2001c. Improving extreme hydrologic events forecasting using a new criterion for artificial neural network selection. Hydrol Process 15: 1533–1536.

Daliakopoulos NI, Coulibaly P and Tsanis IK, 2005. Ground water level forecasting using artificial neural networks. J Hydrol 309: 229-240.

Fahlman SE and Lebiere C, 1990. The cascade-correlation learning architecture. Advances in neural information processing systems 2, D. S. Morgan Kaufman, San Mateo, Calif, 524-532.

Fausett L, 1994. Fundamentals of neural network. Prentice Hall, Englewood Cliffs.

Fletcher R and Reeves CM, 1964. Function minimization by conjugate gradient. Comp J 7: 149-154.

Haykin S, 1994. Neural network: A comprehensive foundation. MacMillan College Publishing Co, New York.

Hopfield JJ, 1982. Neural network and physical systems with emergent collective computational abilities. Proc Nat Academy of Scientists 79: 2554-2558.

Kohonen T, 1988. An introduction to neural computing. Neural Networks 1: 3–16.

Maier HR and Dandy GC, 2000. Neural network for the prediction and forecasting water resources variables: a review of modeling issues and applications. Environ Modeling Software 15: 101–124

McCulloch WS and Pitts W, 1943. A logic calculus of the ideas immanent in nervous activity. Bull of Math Biophys 5: 115-133.

Minisky ML and Papert S, 1969. Perceptrons: An introduction to computational geometry, MIT Press, Cambridge.

Riad S and Mania J, 2003. Rainfall-runoff Model using an artificial neural network approach. Mathematical and Computer Modeling 40: 839-846.

Rumelhart DE and McClelland JL, 1986. Parallel distributed processing: Exploration in the microstructure of cognition. Foundations, 1, MIT Press.

Sahoo GB and Ray C, 2006. Flow forecasting for a Hawaii stream using rating curves and neural networks. J Hydrol 317: 63-80.

Thirumaliah K and Deo MC, 1998. River stage forecasting using neural networks. J Hydrol Eng 3: 26-32.

Toth E, Brath A and Montanari A, 2000. Comparison of short-term rainfall prediction model for real-time flood forecasting. J Hydrol 239: 132-147.

Wasserman PD, 1989. Neural computing: theory and practice. Van Nostrand Reinhold, New York.