

SID



سرویس های ویژه



سرویس ترجمه تخصصی



کارگاه های آموزشی



بلاگ مرکز اطلاعات علمی



عضویت در خبرنامه



فیلم های آموزشی

کارگاه های آموزشی مرکز اطلاعات علمی جهاد دانشگاهی



کارگاه آنلاین آشنایی با پایگاه های اطلاعات علمی بین المللی و ترند های جستجو



مباحث پیشرفته یادگیری عمیق؛ شبکه های توجه گرافی (Graph Attention Networks)



کارگاه آنلاین مقاله نویسی IEEE و ISI ویژه فنی و مهندسی



پیش‌بینی دبی در حوزه رودخانه با استفاده از مدل فازی عصبی "منطقه مورد مطالعه: رودخانه کرخه"

زهرا برزویی^۱، زینت کومه*^۲، کاظم رنگزن^۳

۱- کارشناسی ارشد سنجش از دور و GIS، دانشکده علوم زمین، دانشگاه شهید چمران اهواز

۲- کارشناسی ارشد سنجش از دور و GIS، دانشکده علوم زمین، دانشگاه شهید چمران اهواز

۳- دانشیار گروه سنجش از دور و GIS، دانشکده علوم زمین، دانشگاه شهید چمران اهواز

*z.komeh@gmail.com

چکیده

از نظر سنتی، تکنیک رگرسیون خطی چندگانه، یکی از مهم‌ترین مدل‌هایی است که بطور گسترده در شبیه‌سازی هیدرولوژیکی سری‌های زمانی مفید است. با این وجود، زمانی که پدیده غیرخطی مدنظر است، تکنیک رگرسیون خطی چندگانه جهت توسعه یک مدل پیش‌بینی مناسب با شکست مواجه می‌شود. اخیراً، سیستم‌های فازی عصبی جهت کالیبره کردن روابط غیرخطی شهرت زیادی به دست آورده‌اند. این مطالعه به ارزیابی پتانسیل سیستم‌های فازی عصبی پرداخته، تا اینکه در نهایت به پیش‌بینی دبی در یک حوزه رودخانه بپردازیم. اثر این مدل در حوزه رودخانه کرخه در استان خوزستان بررسی می‌شود. برای رسیدن به این هدف ابتدا تعداد ورودی‌های مدل با استفاده از پلات‌های همبستگی و همبستگی نسبی مشخص شده و بعد از انجام طبقه‌بندی داده‌ها به روش طبقه‌بندی تفاضلی، مدل فازی عصبی پیاده‌سازی گردید. بعنوان مقایسه، یک آنالیز رگرسیون خطی چندگانه نیز برای رودخانه مربوطه، با استفاده از شاخص‌های آماری مختلف آزمون شد. نتایج نهایی فازی عصبی در مقایسه با داده‌های مشاهده شده نشان می‌دهد که مدل فازی عصبی دبی‌های بزرگ را کمتر تخمین زده درحالی‌که دبی‌های متوسط و کوچک را نزدیک به داده‌ی مشاهده شده برآورد کرده است و مقایسه دقت پیش‌بینی فازی عصبی و رگرسیون خطی چندگانه با استفاده از شاخص‌های آماری نشان می‌دهد که روش فازی عصبی در پیش‌بینی دینامیک دبی رودخانه بسیار دقیق عمل کرده است، لذا با در نظر گرفتن سادگی و قابلیت این مدل، فازی عصبی را می‌توان بعنوان ابزاری برای مدل‌سازی دینامیک دبی در منطقه مطالعاتی پیشنهاد کرد.

واژه‌های کلیدی: پیش‌بینی دبی، رگرسیون خطی چندگانه، فازی عصبی، مدل‌سازی

الف- مقدمه

تهیه آب کافی یک نگرانی مهم برای برنامه‌ریزان و مدیران سیستم‌های منابع آب است. مانند شرایطی که اخیراً در بسیاری از کشورهای دیگر تجربه شده است، شرایط منابع آب در ایران به مرحله‌ای رسیده است که نیاز است در مصرف آب صرفه‌جویی شود تا بتوان با پدیده خشکسالی منطقی‌تر مواجه شد. بعلاوه تقاضا برای منابع آب به سرعت در حال افزایش است لذا برنامه‌های توسعه‌ای برای آبیاری، آب آشامیدنی سالم و آب صنعتی بایستی انجام شود. بمنظور پاسخ‌گو بودن به



همه نیازهای آبی، بایستی یک برنامه آبی در کشور توسعه یابد تا بتوان برای تخصیص آب قابل تجدید، تصمیم‌گیری مناسب انجام داد. در ارتباط با برنامه استفاده منطقی از آب در ایران، یکی از مهم‌ترین نیازها، پیش‌بینی دقیق ذخیره آب و میزان تقاضا برای آن است. این موضوع جهت برنامه‌ریزی موفق برای تهیه آب ضروری است و نهایتاً برای بهینه کردن تخصیص آب، در سطح حوزه رودخانه، هم این موضوع می‌تواند مفید باشد.

در دهه‌های اخیر، تکنیک‌های پیش‌بینی زیادی جهت شبیه‌سازی سری‌های زمانی هیدرولوژیکی توسعه یافته است. بیشتر تکنیک‌های پیش‌بینی منتشر شده با روش‌های رگرسیون غیرخطی و خطی توسعه یافته است، که این روش‌ها در ابتدا نیاز دارند تا کاربر یک مدل‌سازی ریاضی از همبستگی تجربی را مشخص بکند. تکنیک‌های خطی چندگانه بیشتر برای مدل‌سازی رابطه خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل استفاده می‌شود. با این وجود، زمانی که در سری‌های زمانی داده، هدف تحقیق در پدیده‌های غیرخطی است، روش‌های خطی جهت توسعه یک مدل پیش‌بینی مناسب با شکست مواجه می‌شود. بنابراین تکنیک‌های مدل‌سازی غیرخطی مانند سیستم‌های فازی عصبی برای ساختن یک مدل پیش‌بینی قابل اعتماد و دقیق ضروری هستند. سیستم‌های فازی عصبی که توسط جینگ^۱ (۱۹۹۳) با ترکیب مفاهیم منطق فازی در شبکه‌های عصبی ایجاد شد هدفش این است که فرایند یادگیری و انطباق در سیستم را آسان سازد. مدل‌های فازی عصبی اخیراً برای کالیبره کردن روابط غیرخطی بسیار دارای شهرت هستند، به این علت که این مدل‌ها نسبت به مدل‌های متعارف دیگر، مزایای زیادتری دارند که این مزایا عبارتند از قابلیت کنترل مقادیر زیادی داده نویزی نسبت به سیستم‌های غیرخطی و پویای دیگر، بخصوص در شرایطی که روابط فیزیکی بطور کامل درک نمی‌شود. دیگر مزایای مربوط به این روش، شامل بهبود یافتن انجام مدل، توسعه سریع‌تر مدل با زمان محاسبه کمتر است. بنابراین می‌توان گفت که مدل‌های فازی عصبی، ابزارهای مدل‌سازی مناسبی جهت شبیه‌سازی هیدرولوژیکی سری‌های زمانی هستند.

کاربردهای موفقیت‌آمیز مدل‌سازی بر اساس فازی عصبی در پیش‌بینی منابع آب بطور گسترده گزارش شده است. بازارتسرن^۲ و همکاران (۲۰۰۳) از مدل‌های فازی عصبی و شبکه عصبی برای پیش‌بینی سطح آب در دوره‌های کوتاه مدت استفاده کرد. ولنکا و لادرمیر^۳ (۲۰۰۰) یک مدل شبکه عصبی فازی برای پیش‌بینی جریان ورودی برای یک سیستم انرژی را توسعه دادند. نایاک^۴ و همکاران (۲۰۰۴) پیشنهاد داد که اگر داده ورودی قبل از ایجاد مدل بصورت دامنه‌ای نرمال تبدیل

1: Jang

2: Bazartseren

3: Valenca & Ludermir

4: Nayak



شود می‌توان گفت که سیستم استنتاج فازی عصبی بصورت قابل توجهی بهبود می‌یابد. ورنیو^۱ و همکاران (۲۰۰۵) استفاده از مدل‌های تکاگو و سوگونو را برای پیش‌بینی بارندگی پیشنهاد داد، وی این کار را با محاسبه و مقایسه روش‌های طبقه‌بندی مختلف انجام داد. دیکسن^۲ (۲۰۰۴) حساسیت مدل‌های فازی عصبی را برای پیش‌بینی آسیب‌پذیری آب زیرزمینی با ترکیب سیستم اطلاعات جغرافیایی و فازی عصبی بررسی کرد. پانمبالا^۳ و همکاران (۲۰۰۳) نیز از ترکیب سیستم‌های استنتاج فازی، شبکه عصبی و الگوریتم ژنتیک برای کم کردن واریانس، که مهم‌ترین مزیت آن در عملیات ذخیره آب است استفاده کرد. در تحقیق حاضر، مزیت تکنیک محاسباتی فازی عصبی در مدل‌سازی پیش‌بینی دبی در یک حوزه رودخانه بررسی می‌گردد. پیش‌بینی با ایجاد قواعد فازی انجام می‌شود که رابطه بین داده ورودی و خروجی و طبقه‌بندی این داده‌ها با استفاده از خوشه‌بندی تفاضلی^۴ انجام می‌شود. سپس بهینه‌یابی مجموعه قواعد فازی با یک سیستم استنتاج فازی عصبی^۵ انجام می‌گردد. در نهایت نیز با استفاده از روش‌های آماری به ارزیابی توانایی مدل پرداخته می‌شود.

ب- مواد و روش‌ها

۱- مدل فازی عصبی

مدل‌سازی فازی عصبی ترکیبی از شبکه‌های عصبی و منطق فازی در یافتن وزن‌ها می‌باشد. این دو تکنیک مکمل یکدیگر بوده‌اند. روش‌های فازی عصبی از استراتژی یادگیری محاسباتی تئوری شبکه‌های عصبی بهره برده تا اینکه موجب تکاملی در سیستم استنتاج فازی شود (براون و هاریس^۶، ۱۹۹۴). ترکیب شبکه‌های عصبی و منطق فازی، طبق یافته‌های ناچ و کراس^۷ (۱۹۹۹) قادر به غلبه بر معایب هر دو تکنیک بوده است. مزیت مهم روش فازی عصبی کاهش مدت زمان آموزش است و این مسئله نه فقط به دلیل کوچک‌تر شدن ابعاد مشکل، بلکه به این علت است که شبکه می‌تواند با پارامترهای مربوط به دامنه مشکل فعالیت خود را آغاز کند (مگوار^۸ و همکاران، ۱۹۹۸). یک روش مشخص در توسعه فازی عصبی،

¹ : Verniuwe

² : Dixon

³ : Ponnambalam

⁴ : Subtractive Clustering

⁵ : ANFIS

⁶ : Brown & Harris

⁷ : Nauck & Kruse

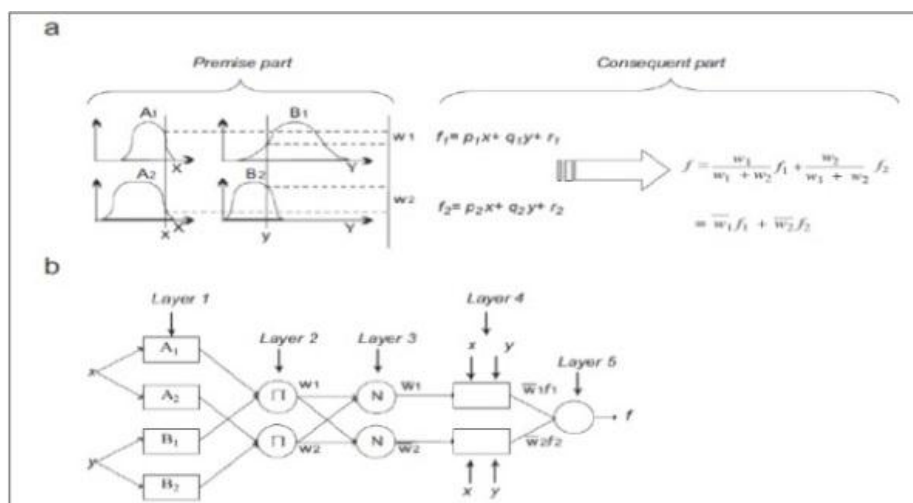
⁸ : Maguire



ANFIS است که در مدل‌سازی توابع غیرخطی نتایج مهمی را نشان می‌دهد (جانگ^۱ و همکاران، ۱۹۹۷؛ جانگ و گالی^۲، ۱۹۹۵).

۲- ساختار ANFIS (Adaptive-Network-Based Fuzzy Inference System)

ANFIS از یک شبکه رو به جلو^۳ جهت جستجوی قواعد تصمیم‌گیری فازی استفاده می‌کند تا این‌که وظیفه محوله را بخوبی انجام دهد. با استفاده از یک سری داده ورودی و خروجی مشخص، ANFIS یک سیستم استنتاج فازی^۴ برای پارامترهایی که توابع عضویشان با هم منطبق است، ایجاد می‌کند. در این شرایط ANFIS یا فقط از یک الگوریتم پس‌انتشار^۵ استفاده می‌کند و یا ترکیبی از الگوریتم پس‌انتشار و یک متد کمترین مربعات^۶ را بکار می‌گیرد. این مسئله به سیستم‌های فازی اجازه می‌دهد که فرایند یادگیری را روی داده‌های مدل‌سازی شده انجام دهد. یک مدل فازی تکاگو سوگنو درجه یک، با دو ورودی و یک خروجی، که برای هر ورودی دارای دو تابع عضویت می‌باشد در شکل ۱(a) نمایش داده شده است. ساختار ANFIS معادل سیستم استنتاج تکاگو سوگنو^۷ درجه یک نیز در شکل ۱(b) نشان داده شده است. جهت ساده‌سازی، فرض ما بر این است که سیستم استنتاج فازی دارای دو ورودی X و Y و یک خروجی Z است، علاوه بر آن دو قاعده if-then فازی از نوع تکاگو و سوگنو (۱۹۸۳) نیز داریم.



شکل ۱- (a) قاعده if-then فازی سوگنو و مکانیزم فازی و (b) ساختار ANFIS معادل سیستم.

¹: Jang

²: Jang & Gulley

³: feed forward

⁴: FIS

⁵: back propagation

⁶: Least Square Estimation

⁷: Takagi & Sugeno



Rule1: If x is A_1 , y is B_1 , (1)

$$\text{Then } f_1 = p_1x + q_1y + r_1$$

Rule2: If x is A_2 , y is B_2 , (2)

$$\text{Then } f_2 = p_2x + q_2y + r_2$$

کل سیستم شامل پنج لایه است و روابط بین ورودی و خروجی هر لایه بصورت زیر خلاصه می گردد:

لایه ۱: هر نقطه i در این لایه یک نقطه مربعی (دارای پارامتر) با یک تابع نقطه‌ای است، که در این لایه توابع عضویت محاسبه می شود.


$$O_i^1 = \mu_{A_i}(X) \quad (3)$$

X = ورودی نقطه i , A_i = متغیر زبانی (بزرگ و کوچک و) مربوط به این تابع نقطه‌ای، O_i^1 = تابع عضویت A_i که بیانگر درجه تعلق آن در لایه ۱ است.

معمولاً ما $\mu_{A_i}(X)$ را به شکل زنگی انتخاب می کنیم که در رابطه ۴ آمده است. (با ماکزیمم معادل ۱ و مینیمم معادل صفر)

$$\mu_{A_i}(X) = \exp\left\{-\left(\frac{x - c_i}{a_i}\right)^2\right\} \quad (4)$$

در این رابطه $\{c_i, b_i, a_i\}$ مجموعه پارامترها هستند، همانطور که ارزش این پارامترها تغییر می کند، شکل توابع زنگی هم تغییر می کند. معنای فیزیکی پارامترها در تابع زنگی شکل را می توان در شکل ۲ مشاهده کرد. پارامترها را در این لایه پارامترهای مقدمه یا فرض می گویند.



شکل ۲- معنای فیزیکی پارامترها در تابع زنگی شکل.

لایه ۲: هر نقطه در این لایه یک نقطه دایره‌ای (نقطه ثابت و بدون پارامتر) شکل بوده که دارای لیبیل II بوده و سیگنال‌های ورودی را در هم ضرب می کند.

$$W_i = \mu_{A_i}(X) \times \mu_{B_i}(y), \quad i=1, 2 \quad (5)$$



در این لایه عملگر T-norm انجام شده و هر خروجی نقطه نمایش دهنده وزن یک قاعده است.

لایه ۳: هر نقطه در این لایه یک نقطه دایره‌ای است که با لیبل N مشخص می‌شود. در این لایه، وزن‌های نرمالیزه محاسبه می‌گردد.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i=1, 2 \quad (6)$$

لایه ۴: هر نقطه i در این لایه یک نقطه مربع شکل با یک تابع نقطه‌ای است.

$$y = b_0 + \sum b_i x_i \quad (7)$$

$$o_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$$

در رابطه ۷، p_i و q_i و r_i پارامترهای نتیجه هستند که این ضرایب (پارامترها) در این لایه با قاعده کمترین مربعات تخمین زده می‌شود.

لایه ۵: نقطه دایره‌ای در این لایه دارای لیبل \sum است که کل خروجی را بعنوان مجموع همه سیگنال‌های ورودی مطابق رابطه ۸ محاسبه می‌کند.

$$o_i^5 = \sum \bar{w}_i f_i \quad (8)$$

۳- الگوریتم یادگیری هیبرید

الگوریتم یادگیری برای ANFIS، الگوریتم هیبرید است که ترکیبی از کاهش گرادیان و متد کمترین مربعات است (جانگ، ۱۹۹۳؛ جانگ و همکاران، ۱۹۹۷) جهت سادگی کار، شبکه انطباقی فقط دارای یک خروجی است که بصورت رابطه ۹ فرض می‌شود.

$$Output = F(\vec{I}, S) \quad (9)$$

در رابطه ۹، \vec{I} عبارتست از متغیرهای ورودی و S بیانگر پارامترها می‌باشد.

اگر در اینجا یک تابع H وجود داشته باشد، لذا تابع ترکیبی H و F در تعدادی از عناصر S خطی است، لذا این عناصر با متد کمترین مربعات معرفی می‌شوند. می‌توان گفت که اگر مجموعه پارامتر S مطابق رابطه ۱۰ بتواند به ۲ سری تجزیه شود:

$$S = S_1 + S_2 \quad (10)$$

H و F در عنصر S_2 خطی خواهد بود، پس با بکارگیری H در رابطه ۹ می‌توان رابطه ۱۱ را نوشت:



$$H(\text{Output}) = H, F(\vec{I}, S) \quad (11)$$

حال عناصر S_1 و داده آموزشی p می‌تواند در رابطه ۱۱ قرار گرفته و یک معادله ماتریسی مانند رابطه ۱۲ بدست دهد.

$$AX = B \quad (12)$$

وقتی که $|S_2| = m$ شود، پس ابعاد A ، X و B به ترتیب $p \times m$ و $m \times 1$ و $p \times 1$ خواهد بود. بهمین دلیل تعداد جفت داده آموزشی (p) معمولاً بزرگ‌تر از تعداد پارامترهای خطی یعنی m است. این مشکلی است که معمولاً باعث می‌شود که راه حل دقیقی برای معادله ۱۲ وجود نداشته باشد. به جای این روش می‌توان با تخمین کمترین مربعات از X مطابق رابطه ۱۳ خطای مربع را کاهش داد.

$$\|AX - B\|^2 \quad (13)$$

براساس ANFIS نشان داده شده در شکل ۱ می‌بینیم که ارزش‌های پارامترهای مقدمه ثابت هستند و خروجی کل می‌تواند بعنوان یک ترکیب خطی از پارامترهای نتیجه بیان شود. بصورت سمبلی می‌توان خروجی f را در شکل ۱ این‌گونه بازنویسی کرد:

$$\begin{aligned} F &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= \overline{w_1} f_1 + \overline{w_2} f_2 = (\overline{w_1^x}) p_1 + \\ &(\overline{w_1^y}) q_1 + (\overline{w_1^r}) r_1 + (\overline{w_2^x}) p_2 \\ &+ (\overline{w_2^y}) q_2 + (\overline{w_2^r}) r_2 \end{aligned} \quad (14)$$

که پارامترهای $p_1, q_1, r_1, p_2, q_2, r_2$ مربوط به نتیجه استنتاج هستند که بصورت خطی بیان می‌گردند. بعنوان نتیجه، مجموع پارامترهای کلی (S) می‌تواند در ۲ سری پارامترهای مقدمه (S_1) و پارامترهای نتیجه (S_2) جداسازی شوند. در نتیجه الگوریتم یادگیری هیبرید می‌تواند برای یک جستجوی مؤثر از پارامترهای بهینه ANFIS بکار رود. بصورت مشخص می‌توان گفت که در عبور رو به جلوی الگوریتم یادگیری هیبرید، خروجی‌ها به طرف جلو حرکت کرده، تا اینکه در لایه ۴ پارامترهای نتیجه با متد تخمین کمترین مربعات تعریف می‌شوند، ولی در عبور رو به عقب، پس‌انتشار خطای سیگنال‌ها و پارامترهای مقدمه با روش کاهش گرادیان تعیین می‌شود. ویژگی تعیین پارامترها در این دو نوع عبور، در یادگیری هیبرید در جدول ۱ نشان داده شده است.



جدول ۱- دو عبور در روش یادگیری هیبرید برای ANFIS

| عبور رو به جلو | عبور رو به عقب | |
|------------------|------------------------|----------------|
| پارامترهای مقدمه | ثابت | کاهش گرادیان |
| پارامترهای نتیجه | تخمین با کمترین مربعات | ثابت |
| سیگنالها | خروجی‌های نقطه‌ای | سیگنال‌های خطا |

ج- بحث و نتایج


۱- منطقه مطالعاتی و مجموعه داده

برای توصیف کاربرد عملی مدل فازی عصبی، رودخانه‌های کوچک که در حوزه آبریز رودخانه کرخه در خوزستان، واقع شده‌اند، بعنوان یک منطقه مطالعاتی مورد استفاده قرار گرفتند. رودخانه کرخه از مناطق میانی و جنوب غربی رشته کوه‌های زاگرس در نواحی غرب و شمال غرب کشور سرچشمه گرفته و پس از طی مسافتی در حدود ۹۰۰ کیلومتر در امتداد شمال به جنوب، سرانجام در مرز مشترک ایران و عراق به مرداب هورالعظیم می‌رسد. رودخانه کرخه پس از رودخانه‌های کارون و دز سومین رودخانه بزرگ ایران از نقطه نظر آب‌دهی محسوب می‌شود. حوزه آبریز رودخانه کرخه به وسعت حدود ۴۳ هزار کیلومتر مربع، بین ۴۶ درجه و ۵۷ دقیقه تا ۴۹ درجه و ۱۰ دقیقه طول شرقی و ۳۱ درجه و ۴۸ دقیقه تا ۳۴ درجه و ۵۸ دقیقه عرض شمالی واقع شده است و شامل استان‌های همدان، کرمانشاه، کردستان، ایلام، لرستان و خوزستان می‌باشد. سرشاخه‌های اصلی تشکیل‌دهنده رودخانه کرخه، رودخانه‌های سیمره، کشکان، قره‌سو، گاماسیاب و چرداول هستند. بارندگی در این منطقه حدود ۵۳۹ میلی‌متر بوده و از ۳۹۲ تا ۶۸۸ میلی‌متر در تغییر می‌باشد. این در حالی است که نوسان میانگین دمای سالانه در منطقه بین ۱۰ تا ۲۲ درجه سانتی‌گراد با میانگین ۱۴ درجه سانتی‌گراد است. علاوه بر آن می‌توان گفت که بیش از ۶۴٪ از کل رواناب سالیانه در ۴ ماه بهمن تا اردیبهشت ماه رخ می‌دهد و حداکثر رواناب ماهیانه مربوط به فروردین ماه است. در این مطالعه از داده‌های دبی ماهانه استفاده شد. داده‌ها شامل اطلاعات دبی ماهانه برای یک دوره ۱۵ ساله (۱۳۷۵-۱۳۸۹) بوده است. مدل با استفاده از داده‌های ۱۱ سال اول (۱۳۷۵-۱۳۸۵) آموزش داده شده و اعتبارسنجی مدل نیز با استفاده از داده‌های ۴ سال بعدی (۱۳۸۶-۱۳۸۹) انجام گردید.



۲- انتخاب ورودی‌ها

انتخاب متغیرهای ورودی مناسب در فرایند مدل‌سازی بسیار مهم است. پارامترهای مورد نیاز بعنوان متغیرهای ورودی، ارزش دبی‌ها در فواصل زمانی مختلف است که روی دبی پیش‌بینی شده اثر قابل توجهی دارد. در این مطالعه، تعداد پارامترهای فرض‌های مختلف بوسیله دو متد آماری تعیین شد: تابع ACF^1 و تابع $PACF^2$ بین متغیرها. همکاران، $PACF$ و ACF در تشخیص درجه رگرسیون و همچنین در مدل‌سازی فازی عصبی می‌تواند مفید باشد (سودهر^۳ و همکاران، همکاران، ۲۰۰۲). تعداد متغیرهای ورودی، با قرار دادن یک فاصله اطمینان^۴ ۹۵٪ روی پلات ACF و $PACF$ تعیین شد. ACF و درجه اطمینان ۹۵٪ مطابق آن از سری‌های دبی رودخانه برای lag صفر تا ۲۰ ماه در شکل ۳ نمایش داده شده است.




شکل ۳- پلات ACF از سری دبی رودخانه.

به همین ترتیب، $PACF$ و درجه اطمینان ۹۵٪ مطابق آن از سری دبی رودخانه برای lag صفر تا ۲۰ ماه در شکل ۴

نمایش داده شده است.

¹: AutoCorrelation Function
²: Partial AutoCorrelation Function
³: Sudheer
⁴: Confidence Interval



شکل ۴- پلات PACF از سری دبی رودخانه.

هر دو ACF و PACF یک همبستگی مهمی در فاصله اطمینان ۹۵٪ تا ۲ ماه را نمایش می‌دهند. بنابراین با توجه به آنچه که گفته شد برای پیش‌بینی دبی رودخانه از ۲ ورودی استفاده می‌شود، که ورودی اول دبی ماهانه رودخانه در زمان t و دیگری دبی ماهانه در زمان $t-1$ است.

۳- طبقه‌بندی داده‌های ورودی

در سیستم ANFIS، پارامتر ورودی ممکن است در چندین کلاس در لایه ۱ دسته‌بندی شود تا قواعد فازی مربوط به آن ساخته شود و هر قاعده فازی با دو تابع عضویت در لایه ۲ ساخته می‌شود. همانطور که تعداد قواعد فازی زیاد می‌شود، تعداد پارامترهایی هم که بایستی تعیین شود زیاد می‌گردد. در این تحقیق، از یک روش طبقه‌بندی تفاضلی جهت حل این مشکل استفاده شد، تا اینکه قاعده فازی بین داده‌های ورودی و خروجی ایجاد شود. روش طبقه‌بندی تفاضلی بر اساس اندازه‌گیری تراکم نقاط داده در فضای عارضه می‌باشد (چایو^۱، ۱۹۹۴). ابتدا بایستی همه سری داده‌ها نرمالایز شده و در فاصله صفر تا یک قرار بگیرد، یعنی رینج مختصاتی آن‌ها در هر بعد مشابه هم شود. بر خلاف روش طبقه‌بندی mountain که نقاط گرید بعنوان مراکز طبقه انتخاب می‌شوند، در روش طبقه‌بندی تفاضلی، به هر نقطه داده بعنوان یک مرکز طبقه توجه می‌شود و یک اندازه‌گیری از قابلیت هر نقطه x_i برای مرکز طبقه بودن مانند رابطه ۱۵ محاسبه می‌گردد.

$$D_i = \sum_{j=1}^n \exp\left(\frac{-\|x_i - x_j\|^2}{(ra/2)^2}\right) \quad (15)$$

بنابراین اندازه‌گیری D_i برای هر نقطه داده تابعی از فاصله‌اش تا همه نقاط دیگر است. یک نقطه داده که دارای نقاط داده همسایه بیشتری باشد دارای پتانسیل بالاتر برای مرکز طبقه شدن است. ra ثابت به تعریف شعاع همسایگی می‌پردازد،


^۱: Chiu



اینگونه که نقاط داده بیرون از این شعاع اثر کمی روی D_i خواهند داشت. البته بایستی در انتخاب مناسب ra دقت کافی داشت زیرا ra خیلی کوچک و یا خیلی بزرگ موجب کاهش دقت می‌شود. لذا مطابق یافته‌های پیریرو و همکاران [16]، ارزش بین $0.4-0.7$ برای انتخاب ra مناسب است. بعد از اینکه D_i هر نقطه محاسبه شد، نقطه با بالاترین D_i را بعنوان مرکز طبقه اول انتخاب می‌کنیم. اگر x_{c1} ، مرکز طبقه اول و D_{c1} میزان تراکم یا پتانسیل این نقطه باشد، لذا اندازه‌گیری تراکم برای هر نقطه داده دیگری بر اساس فاصله آن نقطه تا مرکز طبقه اول مطابق رابطه ۱۶ محاسبه می‌شود.

$$D_i^{New} = D_i - D_{c1} \times \exp\left(\frac{-\|x_i - x_{c1}\|^2}{(rb/2)^2}\right) \quad (16)$$

برای دوری از اینکه مراکز طبقه خیلی نزدیک به هم قرار نگیرند rb را اندکی بزرگ‌تر از ra انتخاب کرده و البته یک انتخاب مناسب برای rb این است که آنرا $1/5$ برابر ra در نظر بگیریم [15]. وقتی که D_i^{New} همه نقاط دوباره تجدید نظر شد نقطه داده با بالاترین پتانسیل یا تراکم بعنوان مرکز طبقه دوم انتخاب می‌شود. فرایند تعیین یک مرکز طبقه و تراکم مطابق آن ادامه یافته تا اینکه به تعداد مناسب مرکز طبقه انتخاب شود. ارزش بهینه ra با آزمون و خطا نهایتاً 0.5 در نظر گرفته شد که منجر به ایجاد سه طبقه داده گردید که در فرایند مدل‌سازی فازی عصبی این موضوع بهتر نمایش داده می‌شود. نمایشی از اینکه طبقات و مراکز آنها در ورودی اول (دبی در زمان t) و ورودی دوم (دبی در زمان t-1) چگونه تعیین می‌شوند در شکل ۵ نمایش داده شده است.



شکل ۵- مراکز طبقات در ورودی اول (دبی در زمان t) و ورودی دوم (دبی در زمان t-1).

همانطور که قبلاً هم گفته شد، داده‌ها با دو متغیر ورودی و یک متغیر خروجی می‌تواند در سه طبقه دسته‌بندی شوند. بنابراین هر ورودی و خروجی با دو تابع عضویت از نوع توابع زنگی، شکل گرفته و سه قاعده فازی نیز ایجاد می‌شود. هر سه قاعده بصورت جامع و کامل در جدول ۲ به صراحت آمده است. قسمت if یا مقدمه یک قاعده، مرکز و شعاع خوشه ورودی



و قسمت Then یا نتیجه آن، یک مدل خطی برای طبقه را نمایش می‌دهد. بعنوان مثال، قاعده ۱ در جدول ۲، نشان می‌دهد که در نزدیکی نقطه مرکزی طبقه ۱ $(mf_t, mf_{t-1}) = (0.088, 0.0477)$ خروجی دبی ماهانه (mf_{t+1}) می‌تواند با چند جمله‌ای رابطه ۱۷ مشخص گردد.

جدول ۲- مدل قواعد فازی برای تخمین دبی

| Rule | if part(cluster) | | | | Then-part |
|-------|------------------|--------|------------|--------|---|
| | mf_t | | mf_{t-1} | | |
| | Center | Radius | Center | Radius | |
| Rule1 | 0.088 | 0.5 | 0.0477 | 0.5 | $y = 0.0991 mf_t + 0.921 mf_{t-1} + 0.0179$ |
| Rule2 | 0.3695 | 0.5 | 0.4656 | 0.5 | $y = 2589 mf_t + 0.8164 mf_{t-1} - 0.006$ |
| Rule3 | 0.7281 | 0.5 | 0.8675 | 0.5 | $y = -0.0375 mf_t + 0.6977 mf_{t-1} + 0.1517$ |

$$y = 0.0991mf_t + 0.921mf_{t-1} + 0.0179 \quad (17)$$

این نکته لازم به ذکر است که همه ضرایب توابع عضویت خطی با متد کمترین مربعات تخمین زده می‌شود. بعد از انجام فرایند طبقه‌بندی داده‌ها، در این مرحله نیز با استفاده از نرم‌افزار متلب نسخه R2010b، مدل پیش‌بینی ANFIS انجام شد. ابتدا داده‌ها به دو دسته داده‌های آموزشی و داده‌های چک تقسیم‌بندی شده و توابع عضویت زنگی شکل مربوط به سه طبقه و سه قاعده تعریف شد، در مرحله بعد میزان مینیمم دو تابع عضویت هر قاعده مشخص شده و وزن هر کدام از قواعد تعیین می‌شود، سپس وزن‌ها نرمالایز شده و پارامترهای نتیجه تعریف می‌شوند، در پایان با آموزش شبکه نتایج پیش‌بینی ANFIS حاصل می‌گردد که قابل مقایسه با داده‌های مشاهده شده است.

۴- مدل رگرسیون خطی چندگانه

آنالیزهای رگرسیون خطی چندگانه متدی است که برای مدل‌سازی رابطه خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل استفاده می‌شود. هدف از آنالیزهای رگرسیون خطی چندگانه، این است که ارزش پارامترهای معادله رگرسیون را تعیین کرده و سپس فیت‌شدگی مناسب متغیرهای مستقل با توجه به متغیر وابسته را بصورت کمی نشان می‌دهد. جزئیات آنالیزهای رگرسیون خطی را می‌توان در کار کاجران و سدسر^۱ (۱۹۸۱) جستجو کرد. شکل کلی رگرسیون خطی چندگانه بصورت رابطه ۱۸ می‌باشد.

$$y = b_0 + \sum b_i x_i \quad (18)$$

¹ : Cochran & Snedecor



بعد از انجام آنالیزهای رگرسیون خطی چندگانه روی مجموعه داده‌ها، سپس توانایی پیش‌بینی این مدل با داده‌های فازی عصبی ارزیابی گردید و در نهایت به مقایسه نتایج حاصل از مدل فازی عصبی و رگرسیون خطی چندگانه بوسیله شاخص‌های آماری در این تحقیق پرداخته شد.

۵- ارزیابی مدل

ارزیابی مدل فازی عصبی و رگرسیون خطی چندگانه در این مطالعه، با استفاده از شاخص‌های آماری استاندارد انجام شد. اندازه‌گیری‌های آماری عبارتند از ضریب همبستگی پیرسون (R^1)، کفایت نشساتکلیف (E^2)، جذر میانگین خطای مربع ($RMSE^3$) و خطای میانگین مطلق بصورت درصد ($MAPE^4$) که در جدول ۳ و نتایج مقایسه دو مدل در جدول ۴ آمده است. R همبستگی خطی بین دبی مشاهده شده و محاسبه شده را ارزیابی می‌کند، درحالی‌که E قابلیت مدل را در پیش‌بینی دبی، جدا از میانگین بررسی می‌کند. در این تحقیق، $RMSE$ نیز به ارزیابی باقیمانده بین دبی مشاهده شده و پیش‌بینی شده پرداخته و $MAPE$ نیز خطای مطلق را بصورت درصدی از پیش‌بینی اندازه‌گیری می‌کند.

جدول ۳- اندازه‌گیری‌های انجام شده برای ارزیابی توانایی مدل

| Statistical parameter | Expression |
|-----------------------|---|
| R | $R = \frac{\sum_{i=1}^n (q_i^o - \bar{q}^o)(q_i^p - \bar{q}^p)}{\sqrt{\sum_{i=1}^n (q_i^o - \bar{q}^o)^2} \sqrt{\sum_{i=1}^n (q_i^p - \bar{q}^p)^2}}$ |
| E | $E = 1 - \sum_{i=1}^n (q_i^o - q_i^p) / \sum_{i=1}^n (q_i^o - \bar{q}^o)$ |
| RMSE | $RMSE = \sqrt{\frac{\sum_{i=1}^n (q_i^o - q_i^p)^2}{n}}$ |
| MAPE | $MAPE = \frac{1}{n} \sum_{i=1}^n \left \frac{q_i^p - q_i^o}{q_i^o} \right * 100$ |

تذکر: q_i^o و q_i^p به ترتیب عبارتند از دبی مشاهده شده و دبی پیش‌بینی شده در زمان t ، \bar{q}^o و \bar{q}^p نیز به ترتیب عبارتند از میانگین دبی مشاهده شده و میانگین دبی پیش‌بینی شده

¹: Pearson's correlation coefficient

²: Nash-Sutcliffe efficiency

³: Root mean Square Error

⁴: Mean Absolute Percentage Error



جدول ۴- ارزیابی دقت مدل فازی عصبی و رگرسیون خطی چندگانه طی مراحل آموزش و اعتبارسنجی

| شاخص | مدل فازی-عصبی | | رگرسیون خطی چندگانه | |
|-----------|---------------|--------|---------------------|--------|
| | اعتبارسنجی | آموزش | اعتبارسنجی | آموزش |
| R شاخص | ۰/۷۲۳ | ۰/۸۰۹ | ۰/۶۶۵ | ۰/۶۵ |
| E شاخص | ۰/۶۰۰ | ۰/۶۸۰ | ۰/۴۱۰ | ۰/۴۴۰ |
| شاخص RMSE | ۱۱/۷۰۶ | ۱۲/۳۹۰ | ۱۹/۱۵۷ | ۱۵/۶۶۸ |
| شاخص MAPE | ۱۸/۰۶۷ | ۱۶/۵۳۴ | ۲۴/۴۱۸ | ۲۵/۰۵۶ |

د- نتیجه گیری

تلاش این مطالعه در زمینه استفاده از مدل فازی عصبی جهت پیش بینی دبی در حوزه رودخانه کرخه بوده است. برای این مطالعه داده‌های دبی ماهانه به مدت ۱۵ سال بکار گرفته شد. ابتدا داده‌ها به دو سری داده‌های تست و داده‌های اعتبارسنجی تقسیم شدند، سپس تعداد ورودی‌ها برای این مدل با پلات‌های ACF و PACF با فاصله اطمینان ۰/۹۵ تعیین شد، سپس طبقه‌بندی داده‌ها به روش تفاضلی جهت تعیین تعداد قواعد فازی بکار گرفته شد و در نهایت بعد از انجام مدل فازی عصبی، برای ارزیابی مدل ANFIS با استفاده از شاخص‌های آماری مختلف از آنالیزهای رگرسیون خطی چندگانه استفاده شد که در پایان، نتایج دو مدل با استفاده از این شاخص‌های آماری با هم مقایسه گردید. نتایج نهایی ANFIS نشان داد که مدل فازی عصبی دبی‌های بزرگ را تا حدی کمتر تخمین زده، درحالی‌که دبی‌های متوسط و کوچک را نزدیک به داده مشاهده شده برآورد کرده است. دلیل اینکه مدل فازی عصبی در این زمینه دقت بالایی نشان نداده است این بوده که تعدادی از داده‌های سری زمانی از دست رفته است و این موضوع مخصوصاً در آموزش شبکه، مدل را بسیار تحت تأثیر قرار می‌دهد و تا حدی دقت کار را پایین می‌آورد. دیگر دلیل برای این مشکل فازی عصبی را می‌توان به سیستم استنتاج فازی نسبت داد که قادر به ایجاد قواعد فازی مناسب برای دبی‌های بزرگ نیست. جهت بهبود بیشتر قواعد فازی بهتر است از متغیرهای ورودی دیگر مانند بارندگی نیز، علاوه بر دبی استفاده کرد. همچنین توصیه می‌شود که ارزش‌های از دست‌رفته داده‌ها در تحقیق آتی جایگزین شود. در نهایت البته با مقایسه دقت‌های دو مدل که در جدول ۴ آمده است می‌توان مدل فازی عصبی را نسبت به رگرسیون خطی چندگانه برای مدل‌سازی دینامیک دبی قابل قبول‌تر دانست.

ه- فهرست منابع

- Jang, J.S.R.,(1993), "ANFIS: adaptive network based fuzzy inference system". IEEE Transactions on Systems Manual Cybernetion., 23(3): P 665-683.
- Bazartseren, B. Hildebrandt, G. and Holz, K.P., (2003), "Short-term water level prediction using neural networks and neuro-fuzzy approach". Neuro-computing., 55:P 439-450.
- Valenca, M. and Ludermir, T., (2000), "Monthly streamflow forecasting using an neural fuzzy network model". Proceeding of the Sixth Brazilian Symposium on Neural Networks., 6:P 117-119.



- Nayak, P.C., Sudheer, K.P., Rangan, D.M. and Ramasastri, K.S., (2004), "A neuro-fuzzy computing technique for modeling hydrological time series". *Journal of Hydrology*,. 291:P 52-66.
- Verniuwe, H., Georgieva, O., Baets, B.D., Pauwels V.R.N., Verhoest N.E.C. and Troch P.D., (2005), "Comparison of data-driven Takagi-Sugeno models of rainfall-discharge dynamics". *Journal of Hydrology*,. 302(1-4): P 173-186.
- Dixon, B., (2004), "Applicability of neuro-fuzzy techniques in predicting ground-water vulnerability: a GIS-based sensitivity analysis". *Journal of Hydrology*,. 309: P 17-38.
- Ponnambalam, K., Karray, F. and Mousavi S.J., (2003), "Minimizing variance of reservoir systems operations benefits using soft computing tools". *Fuzzy Sets and Systems*,. 139:P 451-461.
- Brown, M. and Harris, C., (1994), "Neuro-Fuzzy Adaptive Modeling and Control". Prentice-Hall, Upper Saddle River, New Jersey.
- Nauck, U. and Kruse, R., (1999), "Design and Implementation of a neuro-fuzzy data analysis tool in JAVA. Manual". Technical University of Braunschweig, Braunschweig, Germany.
- Maguire, L.P., Roche, B., McGinnity, T.T. and McDaid, L.J., (1998), "Predicting a chaotic time series using a fuzzy neural network". *Information Science*,. 112:P 125-136.
- Jang, J.S.R., Sun, C.T. and Mizutani, E., (1997), "Neuro-Fuzzy and Soft Computing: a Computational Approach to Learning and Machine Intelligence. Prentice-Hall", Eaglewood cliffs, NJ., P 503-534.
- Jang, J.S.R. and Gulley, N., (1995), "The Fuzzy Logic Toolbox for use with MATLAB". The Mathworks, Inc., Natick, Massachusetts.
- Takagi, T. and Sugeno, M., (1983), "Derivation of fuzzy control rules from human operators control actions, in proc". IFAC Symp. Fuzzy Inform, Knowledge Representation and Decision Analysis., P 55-60.
- Sudheer, K.P., Gosain A.K. and Ramasastri K.S., (2002). "A data-driven algorithm for constructing artificial neural network rainfall-runoff models". *Hydrological Processes* 16: P 1325-1330.
- Chiu, S.L., (1994), "Fuzzy model identification based on cluster estimation". *Journal of Intelligent & Fuzzy Systems*,. 2: P 267-278.
- Priyono, A., Ridwan, M., Alias, A. and Atiq, R., (2005), "Generation Of Fuzzy Rules With Subtractive Clustering". *Journal Taknologi*,43(D) Dis. 2005: P 143-153.
- Cochran, W.G. and Snedecor, G.W., (1981), "Statistical Methods", seventh ed. Jowa State University Press, Jowa.

SID



سرویس های ویژه



سرویس ترجمه تخصصی



کارگاه های آموزشی



بلاگ مرکز اطلاعات علمی



عضویت در خبرنامه




فیلم های آموزشی

کارگاه های آموزشی مرکز اطلاعات علمی جهاد دانشگاهی



کارگاه آنلاین آشنایی با پایگاه های اطلاعات علمی بین المللی و ترند های جستجو



مباحث پیشرفته یادگیری عمیق؛ شبکه های توجه گرافی (Graph Attention Networks)



کارگاه آنلاین مقاله نویسی IEEE و ISI ویژه فنی و مهندسی