

ارزیابی فراکتالی از روش پیش پردازش موجکی گروه‌های زمانی جریان رود مطالعه‌ی موردی رود قره‌آقاج در استان فارس

محمدهادی فتاحی^{۱*}، ناصر طالب بیدختی^۲، غلامرضا رخشنده‌رو^۳، ابوالفضل شمسایی^۴

تاریخ دریافت: ۱۳۸۹/۰۳/۲۵ تاریخ پذیرش: ۱۳۸۹/۰۹/۱۶

چکیده

در تحقیق حاضر، از روش تحلیل موجکی برای پیش پردازش سری‌های زمانی جریان رود استفاده شده است. با استفاده از تبدیلات پیوسته و گسسته موجکی نشانه‌ی مورد مطالعه که همان گروه زمانی جریان رود قره‌آقاج در چند ایستگاه مورد مطالعه می‌باشد، به نشانه‌های تقریب و جزییات تجزیه می‌گردند. نشانه‌ی تقریب نشان‌دهنده‌ی روند پایه جریان و نشانه‌ی اختلال در واقع نماینده بی‌نظمی‌ها، تغییرات و جهش‌های سریع در گروه زمانی می‌باشند. با کاربرد تحلیل فراکتال ضریب H هر یک از نشانه‌های نامبرده در ایستگاه‌های مختلف به دست آمده و از آن طریق ضریب همبستگی و درجه پایایی گروه‌های زمانی جریان رود قبل و بعد از پیش پردازش موجکی، برآورد گردیده است. کارمایه متوسط نشانه نیز از روش تحلیل طیفی در هر حالت محاسبه گردیده است. با بررسی ضرایب همبستگی و کارمایه‌ی متوسط نشانه، مشخص است که گروه‌های زمانی پس از حذف اختلالات دارای همبستگی بالاتری می‌باشند که از افزایش حافظه گروه حکایت می‌کنند، در عین حال، کارمایه متوسط نشانه نیز پس از حذف اختلالات بطور معنی‌داری کاهش می‌یابد، به گونه‌ای که می‌توان عنوان کرد که بیش از نیمی از کارمایه نشانه مربوط به اختلالات و بی‌نظمی‌های موجود در گروه زمانی می‌باشد. در مرحله‌ی پیش‌بینی، گروه‌های زمانی جریان که به‌وسیله‌ی تحلیل موجکی پیش پردازش شده‌اند و همچنین گروه‌های غیر پردازش شده به‌وسیله‌ی شبیه شبکه عصبی مصنوعی از نوع پرسپترون چند لایه پیش‌خوران با الگوریتم آموزش $Levenberg-Marquardt$ پیش‌بینی شده‌اند. نتایج حاصل از افزایش قابل توجه در دقت پیش‌بینی جواب‌های شبیه شبکه‌ی عصبی در صورت استفاده از روش‌های تحلیلی موجکی درمورد گروه‌های زمانی جریان رود دلالت می‌کنند. نتایج همچنین حاکی از آنند که روش تبدیلات گسسته موجکی در مقایسه با روش تبدیلات پیوسته از کارایی بالاتری برخوردار است.

واژه‌های کلیدی: تحلیل موجکی، ارزیابی فراکتالی، قابلیت پیش‌بینی شدن، شبیه شبکه‌ی عصبی مصنوعی.

۱- استادیار گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد مرودشت.

۲- استاد دانشکده‌ی مهندسی دانشگاه شیراز.

۳- دانشیار دانشکده‌ی مهندسی دانشگاه شیراز.

۴- استاد دانشکده‌ی مهندسی دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران.

* نویسنده‌ی مسوول: fattahi_mh@yahoo.com

مقدمه

بسیاری از پدیده‌های طبیعی مانند نوسان‌های زمین لرزه‌ای، خصوصیات زمین فیزیکی و فرایندهای آب‌شناسی را می‌توان در قالب گروه‌های زمانی بررسی نمود. قابل ارائه بودن پدیده‌های طبیعی در قالب گروه‌های زمانی به معنای قابلیت بررسی ویژگی‌های هندسی و پویایی آنها در بستر زمان و بررسی تغییرات خصوصیات رفتاری آنها در قالب تغییر مقیاس‌های زمانی است. با در نظر گرفتن ویژگی‌های رفتاری، همچون ضریب خود همبستگی^۱، خاصیت خودشبه‌اشی^۲، خاصیت خود نسبتی^۳، روند^۴ و تغییر پویایی رفتاری در بازه‌ی تغییرات مقیاسی می‌توان ضمن اشراف بر تاریخچه‌ی فرایند مذکور، مقدمات پیش‌بینی رفتار آن را در آینده نیز با تعریف دقیق فراهم ساخت.

از جمله ابزارهای منحصر به فردی که با توانایی‌های ویژه آن می‌توان به درک واقع بینانه‌تری از طبیعت نشانه‌های آب‌شناسی رسید، تبدیل موجکی^۵ می‌باشد. تحلیل پویایی گروه‌های زمانی در گذشته به‌وسیله‌ی دو تبدیل فوریه و تبدیل سریع فوریه صورت می‌گرفت. تبدیل موجکی این کار را به‌صورت سریع‌تری انجام می‌دهد و محتوای بسامد (نرخ تغییرات با زمان) را دقیق‌تر حاصل می‌کند. به کمک دو تبدیل فوریه و تبدیل سریع فوریه می‌توان بسامدهای یک موج را به دست آورد. در واقع، این دو تبدیل به کمک دو تبدیل همساز سینوسی و کسینوسی از $-\infty$ تا $+\infty$ ، که به صورت یکنواخت تکرار می‌شوند، به این هدف دست می‌یابند. اشکال تبدیل فوریه آن است که نمی‌تواند در کنار تعیین مقدار بسامد، زمان وقوع آن را نیز مشخص کند، خصوصاً در اموج غیرپایا^۶. گروه‌های زمانی به‌طور عمده از لحاظ طبقه نشانه به دو صورت FGN^۷ و FBM^۸ تقسیم می‌شوند. نشانه‌های FGN از نوع پایا^۹ (ایستا) با یک مقدار متوسط مورد انتظار و یک واریانس

ثابت در طول زمان و نشانه‌های FBM غیرپایا (ناایستا) با یک واریانس مبتنی بر زمان می‌باشند.

به‌طور عمومی، بسیاری از گروه‌های زمانی طبیعی اعم از گروه‌های زمانی آب‌شناسی، از نوع غیرپایا (FBM) می‌باشند و همان‌گونه که عنوان گردید، تبدیل فوریه گزینه‌ی چندانی مناسبی در تحلیل محتوای بسامدی آنها نمی‌باشد. تبدیل موجکی این مشکل را کاملاً مرتفع ساخته است. در تبدیل موجکی، ضمن تحلیل بسامد نشانه با امکان تغییر مقیاس، می‌توان زمان و حجم محاسبات را کاهش داد. از برجسته‌ترین قابلیت‌های تجزیه و تحلیل موجکی، امکان تجزیه و ترکیب نشانه‌ها به امواج پایه و اختلالات در مراتب مختلف می‌باشد. انگاره‌ی اصلی تحقیق حاضر، جدا نمودن اختلالات^{۱۰} از نشانه پایه به‌وسیله‌ی تبدیل موجکی به منظور دست یافتن به هندسه و روند گروه و در نتیجه امکان پیش‌بینی بهتر آن می‌باشد. بدین منظور، ضمن تحلیل و تجزیه نشانه در چند مرحله، به بررسی خصوصیات پویایی و هندسی گروه در قالب رفتار فراکتالی آن و همچنین نحوه‌ی تغییرات همبستگی گروه از تحلیل فراکتال می‌پردازیم. سپس با تجزیه و ترکیب موجکی نشانه امکان، پیش پردازش داده‌های گروه زمانی جریان رود قبل از آموزش داده‌ها به‌وسیله‌ی شبیه پیش‌بینی شبکه‌ی عصبی مصنوعی فراهم می‌گردد.

مواد و روشها

آنالیز موجکی

از نقطه نظر تعریف ریاضی، عملکرد تحلیل فوریه را می‌توان با تبدیل فوریه نشان داد:

$$F(w) = \int_{-\infty}^{+\infty} f(t) e^{-j\omega t} dt \quad (1)$$

که حاصل جمع نشانه‌ی $f(t)$ در طول بازه‌ی زمانی و ضرب در ضریب توانی است که البته این ضرایب را می‌توان به دو دسته‌ی ضرایب واقعی و مجازی سینوسی تبدیل کرد. نتایج این تبدیل ضرایب فوریه $F(w)$ را حاصل می‌کنند که بعد از ضرب شدن در بسامد سینوسی w ، اجزای متشکله‌ی سینوسی نشانه‌ی اصلی را به‌دست

- 1) Auto-Correlation Coefficient
- 2) Self-Similarity
- 3) Self-Affinity
- 4) Trend
- 5) Wavelet Transform
- 6) Non-Stationary
- 7) Fractional Gaussian Noise
- 8) Fractional Brownian Motion
- 9) Stationary

که در آن s فراسنج مقیاس و τ فراسنج تبدیل می‌باشد. در این جا مفهوم بسامد با مفهوم مقیاس که با s نشان داده می‌شود، تعویض می‌گردد. $\psi(t)$ در حقیقت تابع تبدیل می‌باشد که به موجک مادر مشهور است. عبارت موج به حالتی اطلاق می‌گردد که بسامدی باشد و تأکید بر مادر بودن دلالت بر مشتق شدن توابع تبدیل از یک تابع اصلی (موج مادر) می‌باشد.

ضریب موجک CWT_x^ψ وقتی که نشانه‌ی $x(t)$ و موجک $\psi * \left(\frac{t-\tau}{s} \right)$ مشابه می‌باشند، بزرگ است. بنابراین

گروه‌های زمانی بعد از تجزیه این اجازه را می‌دهند تا بسامد نشانه را در مقیاس‌های متفاوت بررسی کرد.

محاسبه‌ی CWT مستلزم وقت و حساسیت ویژه می‌باشد. تبدیل گسسته‌ی موجکی^۲ برعکس CWT زمان محاسبات کمتری را شامل می‌شود و لاجرم کاربرد ساده‌تری نیز دارد. در DWT مقیاس و موقعیت، معمولاً توانی از ۲ می‌باشد که در اصطلاح به آن مقیاس دیاپیک^۳ می‌گویند. در این تبدیل نمایش موجک به صورت زیر است:

$$\psi_{j,k}(t) = \frac{1}{\sqrt{|S_0^j|}} \psi \left(\frac{t - k\tau_0 S_0^j}{S_0^j} \right) \quad (4)$$

که در آن j و k اجزاء صحیح و $S_0 > 1$ یک زمان تأخیر ثابت می‌باشد. عامل تبدیل τ_0 بستگی به این زمان تأخیر دارد. اثر تجزیه کردن موجک آن است که مقیاس زمان/ مکان را می‌توان به بازه‌های مجزا تبدیل کرد.

صافی‌های گذربالا و گذر پایین متعددی با بسامدهای مختلف برای تجزیه‌ی نشانه در مقیاس‌های مختلف وجود دارند. بدین وسیله نشانه را می‌توان به دو بخش موج تقریب، شامل روند موج پایه و موج جزئیات، شامل بسامدهای بالا و اختلالات تقسیم‌بندی کرد. با کوچک یا بزرگ کردن نمونه‌ها (در بازه) می‌توان مقیاس را تغییر داد. عملیات صافی کردن را در طول قسمتی از نشانه تا حذف بسامد مشخصی تکرار می‌کنیم. بدین وسیله، موج تقریب، و همچنین موج جزئیات، بسته به سطح تجزیه (در یک یا چند مرتبه) به دست می‌آیند. به عبارت دیگر، در تبدیل

می‌دهند. به‌طور مشابه، تبدیل پیوسته‌ی موجکی^۱ از ضرب ضرب حاصل جمع نشانه در طول بازه‌ی زمانی در مقیاس به دست می‌آید که حالت تناوبی موجکی ψ می‌باشد.

$C(scale, position) = \int_{-\infty}^{+\infty} f(t)(scale, position, t) dt \quad (2)$
نتایج (CWT) ضرایب موجکی C می‌باشند که تابع مقیاس و موقعیت‌اند. از حاصل ضرب هر یک از ضرایب در موجک مناسب، موجک‌های متشکله نشانه‌ی اصلی به دست می‌آید.

با مقایسه‌ی موجک‌ها با موج‌های سینوسی (که نوسان‌های تحلیل فوریه به حساب می‌آیند) واضح است که موج‌های سینوسی استمرار مشخصی نداشته و اصولاً از منهای بی‌نهایت تا مثبت بی‌نهایت کشیده شده و با وجود نوسانات سینوسی و آرام، صددرصد قابل پیش‌بینی‌اند، درحالی‌که موجک‌ها به عدم تقارن و بی‌قاعدگی متمایل‌اند. تبدیل فوریه در واقع شکستن یک نشانه به امواج سینوسی با بسامدهای متعدد است، در حالی که تبدیل موجکی شکستن یک نشانه (نشانه‌ی مادر) به امواج دیگری با مقیاس‌ها و تناوب‌های دیگر می‌باشد. با مقایسه‌ی موجک‌ها و امواج سینوسی، به‌طور حسی قابل درک است که نشانه‌های با تغییرات تند و نوسان‌های زیاد را با استفاده از موجک‌های بی‌قاعده‌ی تحلیل موجکی بهتر می‌توان تجزیه و تحلیل کرد تا امواج منظم و آرام سینوسی تبدیل فوریه.


با استفاده از تبدیل موجکی یک نشانه می‌توان به‌طور همزمان اطلاعات زمان و بسامد یک گروه زمانی را استخراج کرد، بنابراین می‌توان تبدیل موجکی را به‌عنوان نمایش زمان/ بسامد یک نشانه معرفی نمود. برای این منظور، گروه‌های زمانی به‌وسیله‌ی تبدیل‌هایی به موجک‌هایی که در واقع نمونه‌های تغییر مقیاس داده شده از موج اصلی می‌باشند، شکسته می‌شوند (نیسون و همکاران، ۱۹۹۹). تبدیل پیوسته‌ی موجکی (CWT) از یک نشانه $x(t)$ به صورت زیر تعریف می‌گردد:

$$CWT_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \psi * \left(\frac{t-\tau}{s} \right) dt \quad (3)$$

2) Discrete Wavelet Transform (DWT)

3) Dyadic Scale

1) Continuous Wavelet Transform (CWT)



شکل ۱- تجزیه نشانه به نشانه‌ی اختلالات و موج پایه. (الف) نشانه‌ی تقریبات ایستگاه بند بهمن (ب) نشانه‌ی اختلالات ایستگاه بند بهمن.

تحلیل فراکتال

فراکتال‌ها اشیاء و یا فرایندهایی هستند که در مقیاس‌های مکانی و یا زمانی متعددی، شکل ظاهری و یا رفتار یکسانی را از خود بروز می‌دهند. این چنین اشیاء و یا فرایندها دارای چنان پیچیدگی‌هایی در مقیاس‌های بسیار کوچک می‌باشند که هندسه‌ی اقلیدسی قادر به تفسیر آن نمی‌باشد. مندلیبرات و وان نس (۱۹۶۸) مفهوم فراکتال را در قالب خاصیت خود متشابه آماری بیان کرد. بعد فراکتال، فراسنجی است که میزان پیچیدگی یک شکل خود شبیه را نشان می‌دهد. مندلیبرات و ون نس در ۱۹۶۸ مفهوم فراکتال را با ارائه‌ی خاصیت خود تناسب به حیطه‌ی تحلیل گروه‌های زمانی وارد کردند. در نظر گرفتن یک گروه زمانی به‌عنوان یک گروه فراکتال به معنی رصد کردن اطلاعات آن گروه زمانی در مقیاس‌های زمانی مختلف است.

فرایندهای آب‌شناسی اغلب به صورت الگوهای پیچیده‌ای از همبستگی‌ها که مقیاس‌های زمانی تو در تو و متعددی را شامل می‌شوند، بیان می‌گردند. بنابراین یک مقدار در یک گروه زمانی در یک زمان خاص تنها به مقادیری که بلافاصله بعد از آن حاضر می‌شوند، بستگی ندارد؛ بلکه به تغییرات مقادیر گروه‌های در گذشته و آینده‌ی دور نیز بستگی دارد. افزایش خواص فراکتالی یک گروه زمانی در

DWT بر اساس این که S کوچک یا بزرگ باشد، موج به دو دسته تقسیم می‌شود:

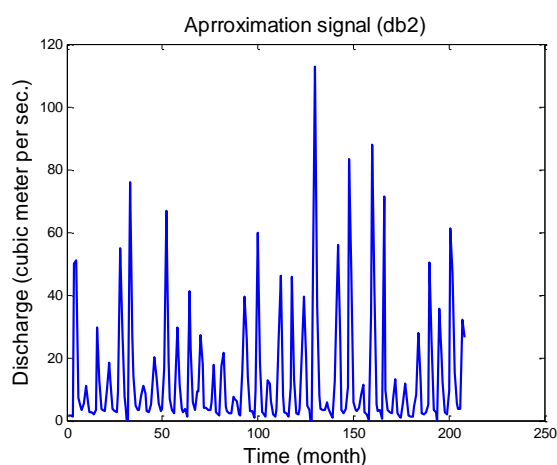
۱- برای بسامدهای بالا (مقیاس کوچک)، موج تقریب a_i حاصل می‌شود.

۲- برای نوسان‌های پایین (مقیاس بالا) موج جزئیات d_j به دست می‌آید.

سپس بین هر دو نقطه، یک نقطه به‌عنوان داده مؤثر انتخاب می‌گردد^۱. سپس در مرحله‌ی اول داده‌ها نصف شده و به دو بخش a_1 و d_1 تقسیم می‌شود. در گام بعد، می‌توان از a_1 به a_2 و d_2 رسید و این فرایند به همین ترتیب ادامه می‌یابد.

یکی از عوامل مؤثر بر نتایج DWT، تابع موجک انتخاب شده می‌باشد. موجک مورد استفاده در تبدیل موجکی تحقیق حاضر، از نوع دابیچز^۲ از مرتبه‌ی ۲ می‌باشد (db2). در شکل ۱ گروه زمانی جریان رود قره‌آغاج در ایستگاه بند بهمن که به‌وسیله‌ی بسته‌ی تحلیل موجکی^۳ به شکل گروه زمانی تقریب و جزئیات در آمده است در کنار نشانه‌ی اصلی نشان داده شده است.

(الف)



- 1) Down Sampling
- 2) Daubechies
- 3) Wavelet Packet Analysis

و تابع موجک فراکتال‌های خود متناسب به‌صورت زیر است:

$$W[h](\lambda_a, \lambda_b) \approx \lambda^{1/2+H} W[h](a, b) \quad (7)$$

با توجه به تغییرات b ضرایب به‌صورت میانگین بیان می‌گردند و داریم:

$$W[h](a) = \langle |W[h](a, b)| \rangle_b \quad (8)$$

که در آن $\langle \cdot \rangle_b$ نمایانگر مقدار متوسط ریاضی معیار مربوط به متغیر b می‌باشد و در نتیجه معادله به‌صورت زیر در می‌آید:

$$W[h](\lambda_a) \approx \lambda^{(1/2)+H} W[h](a) \quad (9)$$

مقدار H را می‌توان از شیب خطی که به نمودار $\log(W[h](a))$ در مقابل $\log(a)$ برازش داده می‌شود به‌صورت زیر به‌دست آورد:

$$H = (1/2) - \text{شیب}$$

آنالیز طیفی توان نشانه

بر اساس رابطه‌ای که مندلبرات و ون نس (۱۹۶۸) ارائه کردند، می‌توان گفت:

$$S(f) \propto \frac{1}{f^\beta} \quad (10)$$

که در این رابطه f تناوب و $S(f)$ مقدار مجذور وابسته به آن می‌باشد. β با محاسبه‌ی شیب منحنی نمودار دو لگاریتمی $S(f)$ در برابر f به‌دست می‌آید. آندراس اکه و همکاران نشان دادند که این روش می‌تواند برای هر دو نوع گروه fBm و fGn استفاده شود، به‌گونه‌ای که در fGn، β در دامنه‌ی ۱- تا ۱+ و در fBm در دامنه ۱ تا ۳ تغییر می‌کند. این روش معیار PSD می‌باشد که بر اساس تبدیل فوریه عمل می‌کند. حال اگر به جای تبدیل فوریه از تبدیل موجکی استفاده کنیم، در حقیقت تحلیل طیفی توان موجکی را به کار برده‌ایم که در مورد گروه‌های زمانی با توجه به پویایی غیرخطی و هندسه‌ی نامنظم گزینه مناسب‌تری می‌باشد. در شکل ۲، تحلیل طیفی گروه زمانی جریان رود قره‌آغاج در ایستگاه بند بهمن نشان داده شده است.

حقیقت به معنای افزایش همبستگی‌ها در سری می‌باشد و این به معنای افزایش قدرت تحلیل در پیش‌بینی گروه است.

تحلیل فراکتال برای درک بهتر از طبیعت این تغییرات و کشف وابستگی‌های ذاتی موجود مابین مقادیر گروه‌های زمانی به کار گرفته می‌شود. برای این منظور باید ابتدا بعد فراکتال گروه زمانی و به تبع آن ضریب هورست^۱ (H) گروه را به‌دست آورد. برای این منظور روش‌های مختلفی وجود دارند که هر یک بسته به طبقه نشانه (fBm/ fGn) قابل استفاده می‌باشند. در تحقیق حاضر از دو روش، یکی مبتنی بر تحلیل موجکی برای حصول به ضریب H بنام روش متوسط ضرایب موجکی^۲ و برای تعیین ضریب H گروه‌های زمانی غیرپایا (fBm) و دیگری تحلیل طیفی توان^۳ برای تحلیل گروه‌های زمانی پایا (fGn) استفاده شده است.

روش متوسط ضرایب موجکی

با استفاده از تحلیل موجکی فراکتال می‌توان به برآورد دقیقی از تغییرات پویایی مشخصات یک نشانه دست یافت. تبدیل موجکی به سه روش می‌تواند ضریب H را محاسبه کند که عبارتند از: (۱) روش تبدیلات مدول ماکسیما. (۲) تحلیل بسته‌ی موجکی. (۳) روش میانگین ضرایب موجکی (AWC). در دامنه‌ی موجک یک نشانه، به موجک‌هایی با تناوب محدود که از موج مادر استخراج شده‌اند تبدیل می‌شود. موج مادر را می‌توان به‌صورت زیر نمایش داد:

$$\psi_{a,b}(x) = \psi\left(\frac{x-b}{a}\right) \quad (5)$$

که در آن $a > 0$ فراسنج‌های مقیاسی و $-\infty < b < \infty$ فراسنج تبدیل تابع $h(x)$ می‌باشد. بدین صورت CWT به‌گونه‌ی زیر نمایش داده می‌شود:

$$W[h](a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi_{a,b}^*(x) h(x) dx \quad (6)$$

1) Hurst Number

2) Averaged Wavelet Coefficient (AWC)

3) Power Spectral Density (PSD)

$$P[B_H(t) - B_H(t_0)] = \frac{1}{\sqrt{2\pi}\sigma_0 |t - t_0|^H} \times \exp\left\{-\frac{[B_H(t) - B_H(t_0)]^2}{2\sigma_0^2 |t - t_0|^{2H}}\right\} \quad (11)$$

با یک متوسط صفر

$$\langle [B_H(t) - B_H(t_0)] \rangle = \int_{-\infty}^{+\infty} [B_H(t) - B_H(t_0)] \quad (12)$$

$$P\{[B_H(t) - B_H(t_0)]\} d\{[B_H(t) - B_H(t_0)]\} = 0$$

و واریانسی که از رابطه ی زیر برآورد می گردد.

$$\langle [B_H(t) - B_H(t_0)]^2 \rangle = \int_{-\infty}^{\infty} [B_H(t) - B_H(t_0)]^2 \quad (13)$$

$$P\{[B_H(t) - B_H(t_0)]\} d\{[B_H(t) - B_H(t_0)]\} = |t - t_0|^{2H} \sigma_0^2$$

که در آن σ_0^2 واریانس افزایش های fBm در توالی های متوالی همسایه است که طول هر گام آن $|t - t_0|$ ، معادل با یک واحد زمان گردد. در این حالت ضریب H باید رابطه ی $0 < H < 1$ را ارضا کند. رابطه ی همبستگی بین افزایش های متوالی این گروه از $[B_H(0) - B_H(-t)]$ در گذشته و $[B_H(t) - B_H(0)]$ در آینده به صورت زیر بیان می شود:

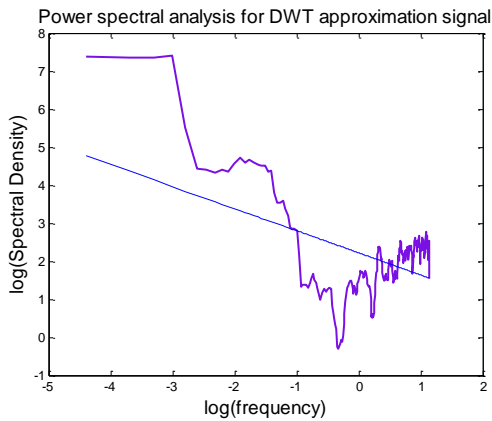

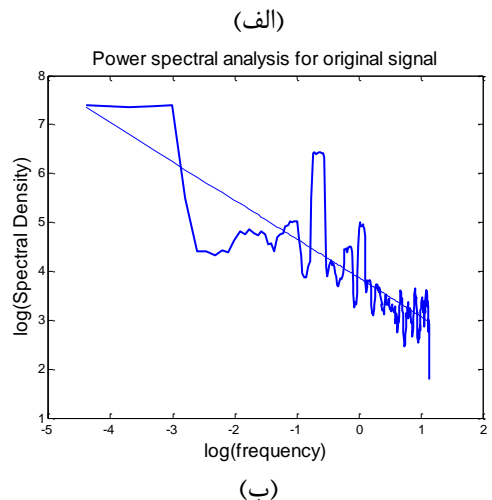
$$C(t) = \frac{\langle [B_H(0) - B_H(-t)][B_H(t) - B_H(0)] \rangle}{\langle [B_H(t)]^2 \rangle} = \frac{\langle -B_H(-t)B_H(t) \rangle}{\langle [B_H(t)]^2 \rangle} \quad (14)$$

با در نظر گرفتن این که

$$\langle [B_H(t) - B_H(-t)]^2 \rangle \equiv 2\langle [B_H(t)]^2 \rangle - 2\langle B_H(-t)B_H(t) \rangle \quad (15)$$

برای $t_0 \equiv -t$ می توان به رابطه ی زیر رسید:

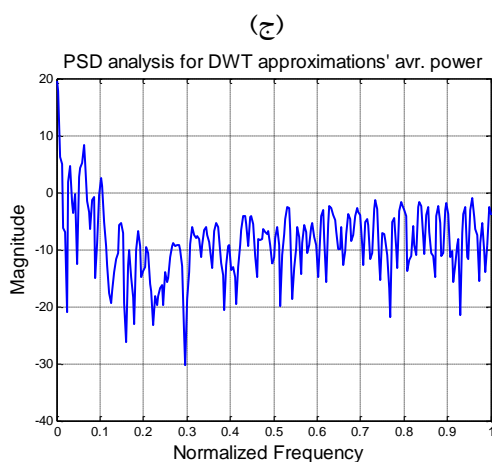

$$C(t) = \frac{|2t|^{2H}}{2|t|^{2H}} - 1 = 2^{2H-1} - 1 \quad (16)$$



شکل ۲ - تحلیل طیفی برای محاسبه ی ضریب H در ایستگاه بند بهمن (الف) گروه زمانی اصلی (ب) گروه تقریبات CWT (ج) گروه تقریبات DWT.

تحلیل فراکتالی همبستگی

فرآیند تصادفی یک بعدی $B_H(t)$ را FBM می نامیم، اگر که افزایش $B_H(t) - B_H(t_0)$ توزیع گوسی (Gaussian) داشته باشد.



شکل ۳- تحلیل طیفی توان نشانه در ایستگاه بند بهمن
(الف) گروه زمانی اصلی (ب) گروه تقریبات CWT (ج)
گروه تقریبات DWT.

شبکه‌ی عصبی مصنوعی^۱

شبکه‌های عصبی مصنوعی به‌عنوان ابزاری قدرتمند در شبیه‌سازی فرایندهای آب‌شناسی به‌شمار می‌روند. فرایندهایی نظیر بارش- رواناب، کیفیت آب، رسوب‌گذاری، پیش‌بینی بارندگی و سایر فراسنج‌های آب‌شناسی به‌وسیله محققین مختلف با این ابزار مورد بررسی و پیش‌بینی قرار گرفته‌اند. نتایج شبیه‌شبکه‌ی عصبی مصنوعی به‌عنوان پیش‌بینی تغییرات فرایندهای آب‌شناسی در آینده، به شدت به نحوه‌ی ارائه و آموزش ورودی‌ها به شبیه‌بستگی دارد. این موضوع خصوصاً در مورد گروه‌های زمانی غیرپایا تا به آن جاست که در صورت عدم انجام پیش‌پردازش مناسب در مورد ورودی‌ها و (یا) پس‌پردازش خروجی‌ها،


با استفاده از این رابطه و با داشتن ضریب H گروه‌های زمانی، می‌توان میزان همبستگی اطلاعات یک گروه زمانی، و یا به عبارتی حافظه‌ی بلند مدت آن را، بررسی کرد.

اندازه‌گیری توان نشانه

برای محاسبه‌ی توان متوسط یک نشانه می‌توان مساحت زیرمنحنی PSD را در طول دامنه‌ی زمانی موردنظر جمع کرد. برای این منظور، ابتدا با استفاده از روش PSD، یک منحنی طیفی از نشانه‌ی مورد نظر ترسیم گردیده، سپس با انتگرال‌گیری از ابتدا تا انتهای بازه‌ی زمانی، میانگین توان نشانه به‌دست می‌آید. باید دقت داشت که مساحت زیرمنحنی PSD میانگین توان نشانه می‌باشد و نه اوج توان.

هدف از انجام این تحلیل بررسی نقش حذف اختلالات از نشانه‌ی اصلی است. با توجه به شکل ۳، مشخص می‌گردد که پس از حذف اختلالات از نشانه، توان آن تقریباً به نصف کاهش یافته است. کاهش کارمایه نشانه به واسطه‌ی حذف اختلالات نشان دهنده‌ی کاهش حضور پرش‌ها و بی‌قاعدگی‌های غیرقابل پیش‌بینی در نشانه‌ی ضرایب می‌باشد. بدین ترتیب امکان شناسایی هندسه سری زمانی اصلی بیشتر فراهم خواهد بود.

(الف)



1) Artificial Neural Networks

شبکه‌ی عصبی، شبکه عصبی چندلایه‌ی پرسپترون^۳ نامیده می‌شود. اختلاف بین خروجی حاصل شده با مقدار مورد انتظار، به‌صورت انتشار بازگشتی به شبکه برگردانده شده و وزن‌های اتصالات در مرحله‌ی آموزش و از طریق یک الگوریتم آموزشی بروز می‌گردند و این عمل مجدداً تا جایی تکرار می‌گردد که خطای حاصله از حداقل مقدار موردنظر شبکه کمتر شود. در تحقیق حاضر از یک شبکه‌ی عصبی MLP مبتنی بر الگوریتم Levenberg-Marquardt استفاده شده است. معماری شبیه شبکه عصبی در تحقیق حاضر شامل سه لایه است: یک لایه ورودی، یک لایه میانی و یک لایه خروجی با یک نرون که نشان دهنده‌ی جریان در زمان $t+1$ می‌باشد. کلیه پیش‌بینی‌ها برای جریان رود در یک ماه بعد انجام پذیرفته است.

منطقه‌ی مورد مطالعه

داده‌های استفاده شده مربوط به حوضه‌ی آبخیز رود قره‌آغاج واقع در استان فارس می‌باشد. داده‌ها به‌صورت ماهانه بوده و آمار ۳۸ ساله برداشت شده از سه ایستگاه بند بهمن، علی آباد و تنگ کارزین را شامل می‌شود. حوضه‌ی آبخیز رود قره‌آغاج دارای طبیعتی نیمه کوهستانی و نیمه مسطح می‌باشد. منطقه‌ی مورد مطالعه در تحقیق حاضر بیش از ۸۰۰۰ هکتار وسعت دارد. مساحت آبخیز قره‌آغاج تا بند بهمن ۱۶۰۱ کیلومتر مربع، تا علی آباد ۲۶۳۱ کیلومتر مربع و تا تنگ کارزین ۱۳۰۷۵ کیلومتر مربع می‌باشد.

نتایج و بحث

برای جدا کردن اختلالات از موج پایه از دو روش CWT و DWT استفاده شده است. در هر دو روش از موجک دابیز از مرتبه‌ی ۲ (db2) که به وسیله دابیز در ۱۹۹۲ ارائه شده است، استفاده گردید. برای بررسی اثر حذف اختلال از نشانه بر جواب‌های پیش‌بینی، سه نمایشنامه در نظر گرفته شده است.

۱) نمایشنامه‌ی اول عبارت از آموزش شبکه‌ی عصبی به‌وسیله‌ی ضرایب CWT به‌عنوان ورودی و همان ضرایب یک ماه بعد به‌عنوان خروجی بود. ضرایب CWT

شبیه از عملکرد درست ناتوان خواهد بود (کاناس و همکاران، ۲۰۰۶). کلید تحلیل گروه‌های زمانی در واقع لحاظ کردن تغییرات زمانی خود نشانه‌ها نمی‌باشد، بلکه منظور کردن اثر فرایندی است که نشانه را به‌وجود می‌آورد. در تحقیق حاضر برای شبیه‌سازی و پیش‌بینی بدهی ماهانه‌ی رود قره‌آغاج از اطلاعات ایستگاه‌های بده‌سنجی بند بهمن، علی آباد و تنگ کارزین واقع در حوضه‌ی آبخیز رود مزبور استفاده شده است. روش مورد استفاده جهت پیش پردازش داده‌های ورودی (گروه زمانی رود) به شبیه شبکه عصبی، روش حذف اختلالات با استفاده از انگاره موجک^۱ می‌باشد. در این روش می‌توان با به‌کارگرفتن ضرایب موجکی با حذف اختلالات از موج پایه در مقیاس‌های مختلف، تفسیری را از ساختار گروه زمانی و اطلاعات مهم و اساسی از حافظه‌ی گروه زمانی استخراج کرد. این روش به صورت گسترده در مورد گروه‌های زمانی، خصوصاً طبقه FBM (غیرپایا) به‌کار گرفته می‌شود (نیسون و ون شاس، ۱۹۹۹).

شبکه‌ی عصبی پرسپترون چندلایه

شبکه‌های عصبی مصنوعی ابزاری قدرتمند را در حل مسائل گوناگون، از قبیل تشخیص و بازیابی الگوها، پردازش اطلاعات، مهار کردن غیرخطی و پیش‌بینی گروه‌های زمانی ارائه می‌دهند. این روش خصوصاً در حل مسائل شامل حجم عظیم داده‌های غیرخطی، پویا و همراه با اختلال و در حالتی که روابط در پوسته‌ی زیرین فرایندهای فیزیکی پدیدآورنده گروه‌های زمانی کاملاً شناخته شده نیست، بسیار مؤثرند (سی و اپنشاو، ۱۹۹۹).

شبکه‌های عصبی مصنوعی ساختارهایی توزیعی، استنتاجی، عموماً غیرخطی و شامل اجزای پردازشی بنام نرون^۲ می‌باشند. هر نرون به نرون‌های دیگر متصل است. اتصال مجموعه نرون‌ها به یکدیگر ساختار شبکه‌ی عصبی مصنوعی ANN را به‌وجود می‌آورد. اتصالات بین نرون‌ها به‌وسیله‌ی فراسنج‌های قابل تنظیمی بنام وزن، مقیاس‌دهی می‌شوند. هر نرون با دریافت ورودی از نرون‌های دیگر یک تابع پایای غیرخطی وزن‌دار از آنها تولید کرده و به‌عنوان خروجی معرفی می‌کند. متداول‌ترین

1) Wavelet De-Noising

2) Neurone

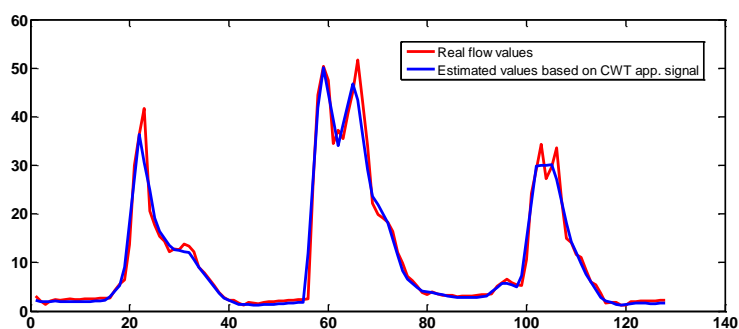
3) Multi-Layer Perceptron (MLP)

همان داده‌ها یک ماه بعد به‌عنوان خروجی بود. در این حالت نیز مقادیر پیش‌بینی‌شده نشان دهنده‌ی بدهی رود در ماه بعد است. در کلیه حالات، ورودی‌ها قبل از وارد شدن به شبکه‌ی عصبی به‌نچار شده‌اند (شکل ۶). نتایج حاکی از آن شد که عملکرد شبیه در دو نمایشنامه‌ی ۱ و ۲ بهتر از حالتی است که داده‌ها بدون پیش پردازش به شبیه شبکه عصبی داده شوند. معیار سنجش عملکرد شبیه در هر نمایشنامه اندازه خطای حاصل در مقایسه با داده‌های معتبر موجود می‌باشد که به‌صورت RMSE و MAE نشان داده شده‌اند.


پیش‌بینی شده به‌وسیله‌ی شبیه شبکه‌ی عصبی نشان دهنده‌ی داده پیش‌بینی جریان رود در ماه بعد است (شکل ۴).

نمایشنامه‌ی دوم عبارت از آموزش شبکه‌ی عصبی به وسیله‌ی ضرایب DWT به‌عنوان ورودی و همان ضرایب یک ماه بعد به‌عنوان خروجی بود که در این حالت نیز ضرایب DWT پیش‌بینی شده نشان دهنده‌ی بدهی رود در ماه بعد است (شکل ۵).


نمایشنامه‌ی سوم عبارت از آموزش شبکه‌ی عصبی با داده‌های اصلی (بدون حذف اختلالات) به‌عنوان ورودی و



شکل ۴ - داده‌های واقعی و نتایج شبیه پیش‌بینی برای ورودی‌های ضرایب CWT.



شکل ۵ - داده‌های واقعی و نتایج شبیه پیش‌بینی برای ورودی‌های ضرایب DWT.



شکل ۶ - داده‌های واقعی و نتایج شبیه پیش‌بینی برای ورودی‌های داده‌های اصلی

جدول ۱ نتایج شاخص عملکرد شبیه پیش بینی در هر نمایشنامه

ایستگاه	نمایشنامه	RMSE	MAE	R
بند بهمن	DWT نشانۀ تقریبات	۶.۴۷	۳.۵۹	۰.۷۵
	CWT نشانۀ تقریبات	۸.۹۴	۴.۹۳	۰.۶۸
	نشانۀ اصلی جریان	۱۲.۰۱۸۹	۷.۰۰۳۵	۰.۳۸
علی آباد	DWT نشانۀ تقریبات	۷.۵۷۶۵	۴.۱۸۷۶	۰.۷۱
	CWT نشانۀ تقریبات	۹.۳۲۱۱	۵.۲۴	۰.۶۴
	نشانۀ اصلی جریان	۱۵.۲۶۲۳	۸.۵۴۶	۰.۳۴
تنگ کارزین	DWT نشانۀ تقریبات	۱۱.۸۶۳	۶.۷۴۱۳	۰.۴۲
	CWT نشانۀ تقریبات	۱۴.۵۱۲	۸.۳۳۲	۰.۳۴
	نشانۀ اصلی جریان	۲۴.۶۹۸۱	۱۴.۱۷۳۶	۰.۲۸

جدول ۲ نتایج تحلیل توان متوسط نشانۀ در هر نمایشنامه

ایستگاه	توان متوسط نشانۀ اصلی جریان	توان متوسط نشانۀ تقریبات DWT	توان متوسط نشانۀ تقریبات CWT
بند بهمن	۲۹۹.۹۵۲۹	۱۵۴.۸۵۶۷	۱۸۶.۴۱۱۳
علی آباد	۴۲۴.۵۵۸	۲۰۵.۸۵۳۶	۲۳۲.۰۱۵۱
تنگ کارزین	۱۲۱۳.۸	۶۴۵.۸۹۶۵	۷۹۱.۴۱۲

جدول ۳ نتایج تحلیل همبستگی گروه زمانی جریان در هر سه ایستگاه و در هر نمایشنامه

ایستگاه	H			C(t)		
	نشانۀ اصلی جریان	نشانۀ تقریبات	نشانۀ تقریبات	نشانۀ اصلی جریان	نشانۀ تقریبات	نشانۀ تقریبات
		DWT	CWT		DWT	CWT
بند بهمن	۰.۴۴۱۷۳	۰.۸۱۲۸۷	۰.۷۸۴۱۲	-۰.۰۷۷۶	۰.۵۴۳	۰.۴۸۲۷
علی آباد	۰.۴۳۴۱۹	۰.۷۸۶۹۶	۰.۷۵۲۱۹	-۰.۰۸۷۱	۰.۴۸۸	۰.۴۱۸۴۹
تنگ کارزین	۰.۴۸۷۵۴	۰.۸۸۹۷۹	۰.۸۳۴	-۰.۰۱۷۱	۰.۷۱۶۶	۰.۵۸۸۸

شاخص عملکرد

شاخص‌های زیر مبنای مقایسه عملکرد شبیه پیش‌بینی در مورد هر نمایشنامه را بیان می‌کنند. در روابط زیر N تعداد مشاهدات، O_i مقادیر مشاهدات واقعی و P_i مقادیر پیش‌بینی شده است.

خطای MA

$$MAE = N^{-1} \sum_{i=1}^N |O_i - P_i|$$

معیار ضریب همبستگی^۱

خطای RMS

$$EMSE = N^{-1} \sqrt{\sum_{i=1}^N (O_i - P_i)^2}$$

1) Correlation Coefficient

رود قره‌آغاج واقع در استان فارس به کار گرفته شده است. نتایج نشان می‌دهد که پیش‌پردازش موجکی گروه‌های زمانی به‌وسیله‌ی تبدیل‌های CWT و DWT می‌تواند به میزان قابل توجهی دقت پیش‌بینی‌های شبیه MLP شبکه‌ی عصبی را افزایش دهد. در این بین، روش DWT نتایج بهتری را ارائه می‌دهد. نتایج حاصله در هر صورت، بر انجام پیش‌پردازش ورودی‌های شبکه‌ی عصبی به‌صورت موجکی تأکید کرده و از افزایش کارکرد شبیه پیش‌بینی و دقت در نتایج نهایی خبر می‌دهد. نتایج حاصله، همچنین بر افزایش ضریب همبستگی گروه زمانی پس از انجام پیش‌پردازش موجکی دلالت دارند.

منابع

- 1- Cannas B., Fanni A., See L., Sias G., Data preprocessing for river flow forecasting using neural networks: Wavelet transforms and data partitioning, *Physics and Chemistry of the Earth* 31 (2006) 1164–1171
- 2- Daubechies, I., Ten Lectures on Wavelets CSBM – NSF Series, Application Mathematics, vol. 61 SIAM publication, Philadelphia, A (1992).
- 3- Mandelbrot B.B., Van Ness J.W. Fractional Brownian motions, fractional noises and applications. 1968; *S IAM Rev.* 10 422-437.
- 4- Nason, G.P., Von Sachs, R., Wavelets in time series analysis. *Philosophical Transactions of the Royal Society of London Series A* (1999) 357, 2511–2526.
- 5- See, L., Openshaw, S., Applying soft computing approaches to river level forecasting. *Hydrological Sciences Journal* (1999) 44, 763–778.

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2 (P_i - \bar{P})^2}}$$

جدول ۱ نتایج حاصل از این بررسی را برای هر سه نمایشنامه‌ی انجام شده نمایش می‌دهد. آنچه مسلم است وجود خطای کمتر در نتایج شبیه پیش‌بینی در دو حالت انجام پیش‌پردازش درمورد گروه‌های زمانی جریان رود و افزایش ضریب همبستگی در گروه‌های پیش‌پردازش شده است.

نتایج

نتایج مربوط به تحلیل میزان کارمایه گروه زمانی پس از انجام فرایند پیش‌پردازش موجکی شامل تجزیه نشانه به موج تقریب و موج جزئیات نشان می‌دهند که گروه زمانی پس از حذف اختلالات از متوسط کارمایه‌اش به‌طور معنی‌داری کاسته می‌گردد، به گونه‌ای که می‌توان ادعان کرد که کارمایه‌ی ناشی از اختلالات در گروه زمانی تقریباً نیمی از کارمایه‌ی کل نشانه است که به‌صورت بی‌نظمی و یا پرش و نوسان‌های تند غیرقابل پیش‌بینی در نشانه حضور دارند. حذف فرایندهای ذکر شده از نشانه اصلی مقدمات داشتن تخمین‌های دقیق‌تر به‌وسیله‌ی شبیه‌های پیش‌بینی را فراهم می‌سازد. نتایج مربوط به تأثیر پیش‌پردازش موجکی بر میزان تغییرات کارمایه متوسط نشانه در جدول ۲ آمده‌اند.

نتایج مربوط به تحلیل فراکتال همبستگی در گروه‌های زمانی نیز بیانگر آنند که میزان همبستگی و پایایی گروه‌های زمانی جریان رود به‌طور معنی‌داری با انجام پیش‌پردازش موجکی آنها افزایش می‌یابد که این موضوع را می‌توان با افزایش قابلیت پیش‌بینی شدن^۱ گروه‌های زمانی پس از پیش‌پردازش موجکی مرتبط دانست. نتایج مربوط به تحلیل فراکتالی همبستگی در جدول ۳ آمده‌اند.

نتیجه‌گیری

شبکه عصبی پرسپترون پیش‌خوران با الگوریتم آموزش Levenberg-Marquardt برای پیش‌بینی بده ماهانه

