



پیش پردازش موجکی (Wavelet) و فراکتالی سریهای زمانی جریان رودخانه برای مدل

پیش بینی شبکه عصبی مصنوعی

محمد هادی فتاحی^۱، ناصر طالب بیدختی^۲، غلامرضا رخشنده رو^۳، ابوالفضل شمسایی^۴

چکیده

در تحقیق حاضر از تکنیک آنالیز موجکی برای پیش پردازش سریهای زمانی جریان رودخانه استفاده شده است. با استفاده از تبدیلات پیوسته و گسسته موجکی سیگنال مورد مطالعه که همان سری زمانی جریان رودخانه قره آغاچ در چند ایستگاه مورد مطالعه می باشد به سیگنالهای تقریب و جزئیات تجزیه می گردد. سیگنال تقریب همان سیگنال اصلی است که اختلالات در آن از موج پایه جدا شده اند و سیگنال جزئیات در حقیقت سیگنال اختلالات می باشد. در گام بعد با کاربرد آنالیز فراکتال ضریب H هر یک از سیگنالهای نامبرده در ایستگاه های مختلف بدست آمده و از آن طریق ضریب همبستگی در آنها محاسبه شده است. انرژی متوسط سیگنال نیز در هر حالت محاسبه گردیده است. با بررسی ضرایب همبستگی و انرژی متوسط سیگنال مشخص است که سریهای زمانی پس از حذف اختلالات دارای همبستگی بالاتری می باشند که از افزایش حافظه سری حکایت می کنند. در مرحله پیش بینی سریهای زمانی جریان که توسط آنالیز موجکی پیش پردازش شده اند توسط مدل شبکه عصبی مصنوعی از نوع پرسپترون چند لایه پیش خوران با الگوریتم حاکم Levenberg-Marquardt پیش بینی شده اند. نتایج حاصل از افزایش قابل توجه در دقت پیش بینی جوابهای مدل شبکه عصبی در صورت استفاده از سریهای پیش پردازش شده بوسیله آنالیز موجکی و خصوصاً از نوع تبدیلات گسسته دلالت می کند.

^۱ - عضو هیئت علمی دانشگاه آزاد اسلامی واحد مرودشت
^۲ - استاد دانشکده مهندسی دانشگاه شیراز
^۳ - دانشیار دانشکده مهندسی دانشگاه شیراز
^۴ - استاد دانشکده مهندسی دانشگاه صنعتی شریف



همایش ملی مدیریت بحران آب
The National Conference on Water Crisis Management
دانشگاه آزاد اسلامی واحد مرودشت، اسفندماه ۱۳۸۸



مقدمه

بسیاری از پدیده های طبیعی مانند نوسانات زمین لرزه ای، خصوصیات ژئوفیزیکی و فرآیندهای هیدرولوژیکی را می توان در قالب سریهای زمانی بررسی نمود. قابل ارائه بودن پدیده های طبیعی در قالب سریهای زمانی به معنای قابلیت بررسی ویژگیهای هندسی و دینامیکی آنها در بستر زمان و بررسی تغییرات خصوصیات رفتاری آنها در قالب تغییر مقیاسهای زمانی است. با در نظر گرفتن خصوصیات رفتاری همچون ضریب خود همبستگی (Autocorrelations Coefficient)، خاصیت خودشبهاتی (Self similarity)، خاصیت خود نسبتی (Self-affinity)، روند (trend) و تغییر دینامیک رفتاری در بازه تغییرات مقیاسی می توان ضمن اشراف بر تاریخچه فرآیند مذکور، مقدمات پیش بینی رفتار آن در آینده را نیز با تعریف دقیق فراهم ساخت.

از جمله ابزارهای منحصربفردی که باتواناییهای ویژه آن می توان به درک واقع بینانه تری از طبیعت سیگنالهای هیدرولوژیکی رسید تبدیل wavelet (موجکی) می باشد. آنالیز دینامیکی سریهای زمانی در گذشته توسط دو تبدیل فوریه (FT) و تبدیل سریع فوریه (FFT) صورت می گرفت. تبدیل موجک (wavelet Transform) این کار را بصورت سریعتری انجام می دهد و محتوای فرکانسی (نرخ تغییرات با زمان) را دقیقتر حاصل می کند. به کمک دو تبدیل (FT) و (FFT) می توان فرکانس های یک موج را بدست آورد. در واقع این دو تبدیل به کمک دو تبدیل هارمونیک سینوسی و کسینوسی از $-\infty$ تا $+\infty$ که بصورت یکنواخت تکرار می شوند به این هدف دست می یابند. اشکال تبدیل فوریه آن است که نمی تواند در کنار تعیین مقدار فرکانس، زمان وقوع آن را نیز مشخص کند که البته این اشکال را روش تبدیل قطعه ای فوریه (STFT) تا حدی برطرف ساخته است اما ایراد همچنان در اموج غیرپایا (non stationary) پابرجاست. سریهای زمانی بطور عمده از لحاظ کلاس سیگنال به دو صورت fGn ^۱ و fBm ^۲ تقسیم می شوند. سیگنالهای fGn از نوع پایا (ایستا) با یک مقدار متوسط مورد انتظار و یک واریانس ثابت در طول زمان و سیگنالهای fBm غیرپایا (ناایستا) با یک واریانس متبنی بر زمان می باشند.

۱) fractional Gaussian noise

۲) fractional Brownian motion



همایش ملی مدیریت بحران آب
The National Conference on Water Crisis Management
دانشگاه آزاد اسلامی واحد مرودشت، اسفندماه ۱۳۸۸



بطور عمومی بسیاری از سریهای زمانی طبیعی اعم از سریهای زمانی هیدرولوژیکی، از نوع غیرپایا (fBm) می باشند که همانطور که عنوان گردید تبدیل فوریه گزینه چندان مناسبی در تحلیل محتوای فرکانسی آنها نمی باشد. تبدیل موجکی یا (Wavelet) این مشکل را کاملاً مرتفع ساخته است. در تبدیل WT ضمن آنالیز فرکانس سیگنال با امکان تغییر مقیاس، می توان زمان و حجم محاسبات را کاهش داد. از برجسته ترین قابلیت های آنالیز Wavelet امکان تجزیه و ترکیب سیگنالها به امواج پایه و اختلالات در مراتب مختلف می باشد. ایده اصلی تحقیق حاضر، جدا نمودن اختلالات (noise) از سیگنال پایه بوسیله تبدیل موجکی (WT) (به منظور دست یافتن به هندسه و روند سری و در نتیجه امکان پیش بینی بهتر آن می باشد. بدین منظور ضمن آنالیز تجزیه (De noising) سیگنال در چند مرحله، به بررسی خصوصیات دینامیکی و هندسی سری در قالب رفتار فراکتالی (Fractal) آن و همچنین نحوه تغییرات همبستگی سری از آنالیز فراکتال می پردازیم. سپس با تجزیه و ترکیب موجکی سیگنال امکان پیش پردازش داده های سری زمانی جریان رودخانه قبل از آموزش داده ها توسط مدل پیش بینی شبکه عصبی مصنوعی را فراهم می گردد.

۲ تئوری

۱-۲ آنالیز موجکی (Wavelet Analysis):


از نقطه نظر تعریف ریاضی، عملکرد آنالیز فوریه را می توان با تبدیل فوریه نشان داد:

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

که حاصلجمع سیگنال $f(t)$ در طول بازه زمانی و ضرب در ضریب توانی است که البته این ضرایب را می توان به دو دسته ضرایب واقعی و مجازی سینوسی تبدیل کرد. نتایج این تبدیل ضرایب فوریه $F(w)$ را حاصل



می کنند که بعد از ضرب شدن در فرکانس سینوسی w ، اجزاء متشکله سینوسی سیگنال اصلی را بدست می دهند.




شکل ۱. نحوه عملکرد آنالیز فوریه در تبدیل سیگنالها

بطور مشابه تبدیل پیوسته موجکی^۱ (CWT) از ضرب حاصلجمع سیگنال در طول بازه زمانی در مقیاس بدست می آید که حالت تناوبی موجکی $1/w$ می باشد.

$$C(\text{scale}, \text{position}) = \int_{-\infty}^{+\infty} f(t)(\text{scale}, \text{position}, t) dt \quad (2)$$

نتایج (CWT) ضرایب موجکی C می باشند که تابع مقیاس و موقعیت هستند. از حاصلضرب هر یک از

ضرایب در موجک مناسب، موجکهای متشکله سیگنال اصلی بدست می آید.



۱) Continues Wavelet Coefficient



شکل ۲. نحوه عملکرد آنالیز موجکی در تبدیل سیگنالها

با مقایسه موجک ها (wavelets) با موجهای سینوسی (که نوسانات آنالیز فوریه به حساب می آیند) واضح است که موجهای سینوسی استمرار مشخصی ندارند و اصولاً از منهای بینهایت تا مثبت بینهایت کشیده می شوند و باوجود نوسانات سینوسی و آرام، صد در صد قابل پیش بینی اند در حالیکه موجکها به عدم تقارن و بی قاعدگی متمایل اند. تبدیل فوریه در واقع شکستن یک سیگنال به امواج سینوسی با فرکانس های متعدد است در حالیکه تبدیل موجکی شکستن یک سیگنال (سیگنال مادر) به امواج دیگری با مقیاس ها و تناوب های دیگر می باشد. با مقایسه موجک ها و امواج سینوسی، بطور حسی قابل درک است که سیگنالهای با تغییرات تند و نوسانات زیاد را با استفاده از موجکهای بی قاعده آنالیز موجکی بهتر می توان آنالیز کرد تا امواج منظم و آرام سینوسی تبدیل فوریه.

با استفاده از تبدیل Wavelet یک سیگنال می توان بطور همزمان اطلاعات زمان و فرکانس یک سری زمانی را استخراج کرد. بنابراین می توان تبدیل موجکی را به عنوان نمایش زمان/ فرکانس یک سیگنال معرفی کرد. برای این منظور سریهای زمانی توسط تبدیلهایی به موجک هایی (wavelets) که در واقع نمونه های تغییر مقیاس داده شده از موج اصلی (wavelet) می باشند شکسته می شوند (نیسون و همکاران، ۱۹۹۹). تبدیل پیوسته موجکی (CWT) از یک سیگنال $x(t)$ بصورت زیر تعریف می گردد:

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



که در آن s پارامتر مقیاس و τ پارامتر تبدیل می باشد. در اینجا مفهوم فرکانس با مفهوم مقیاس که با s نشان داده می شود تعویض می گردد. $\psi(t)$ در حقیقت تابع تبدیل می باشد که به موجک مادر (mother wavelet) مشهور می باشد. عبارت wavelet به معنای موج کوچک یا موجک می باشد و دلیل تأکید بر کوچک بودن در این عبارت، در حقیقت ثابت بودن تابع تبدیل در طول معین است. عبارت موج به حالتی اطلاق می گردد که نوسانی باشد و تأکید بر مادر بودن wavelet دلالت بر مشتق شدن توابع تبدیل از یک تابع اصلی (موج مادر) می باشد.

ضریب موجک CWT_x^ψ وقتی که سیگنال $x(t)$ و موجک $\psi * \left(\frac{t-\tau}{s} \right)$ مشابه می باشند، بزرگ است. بنابراین سریهای زمانی بعد از تجزیه این اجازه را می دهند تا فرکانس سیگنال را در مقیاسهای متفاوت بررسی کرد. محاسبه CWT مستلزم وقت و حساسیت ویژه می باشد. تبدیل گسسته موجکی (DWT) ^۱ برعکس CWT زمان محاسبات کمتری را شامل می شوند و لاجرم کاربرد ساده تری نیز دارند. در DWT مقیاس و موقعیت، معمولاً توانی از ۲ می باشد که در اصطلاح به آن مقیاس دیادی (dyadic scales) می گویند. در این تبدیل نمایش wavelet بصورت زیر است:

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



بستگی به این زمان τ_0 یک زمان تأخیر ثابت می باشد. فاکتور تبدیل $S_0 > 1$ جزء صحیح و k و z که در آن آنست که مقیاس زمان/ مکان را می توان به بازه های مجزا تبدیل کرد. wavelet تأخیر دارد. اثر تجزیه کردن فیلترهای گذربالا (High pass) و گذر پایش (Low pass) متعددی با فرکانس های مختلف برای تجزیه سیگنال در مقیاسهای مختلف وجود دارد. بدینوسیله سیگنال را می توان به دو بخش موج تقریب، شامل روند موج پایه و موج جزئیات، شامل فرکانس های بالا و اختلالات تقسیم بندی کرد. با کوچک یا بزرگ کردن نمونه ها (در بازه) می توان مقیاس را تغییر داد. عملیات فیلترینگ را در طول قسمتی از سیگنال تا حذف فرکانس مشخصی تکرار می کنیم. بدینوسیله موج تقریب و همچنین موج جزئیات بسته به سطح تجزیه (در یک یا چند مرتبه) بدست می آید. به عبارت دیگر در تبدیل DWT بر اساس اینکه S کوچک یا بزرگ باشد، موج به دو دسته تقسیم می شود:


۱- برای فرکانس های بالا (مقیاس کوچک) موج تقریب a_i حاصل می شود.

۲- برای فرکانس های پایین (مقیاس بالا) موج جزئیات d_j بدست می آید.


سپس بین هر دو نقطه، یک نقطه به عنوان داده مؤثر انتخاب می گردد که به این فرآیند (Down Sampling) می گویند. سپس در مرحله اول داده ها نصف شده و به دو بخش a_1 و d_1 تقسیم می شود. در گام بعد می توان از a_1 به a_2 و d_2 رسید و این پروسه به همین ترتیب ادامه می یابد. فرآیند ذکر شده به یک صورت دیگر نیز انجام می پذیرد بگونه ای که جزئیات d_1 خود مجدداً به سیگنال تقریب و جزئیات در مرتبه بالاتر تبدیل می شود. شکل (۳) و شکل (۴) فرآیند مذکور را تفسیر می کنند.




یکی از عوامل مؤثر بر نتایج DWT، تابع wavelet انتخاب شده می باشد. از معروفترین توابع موجک مورد استفاده در محاسبات مهندسی، می توان به موجک هار، موجک دابینچز، موجک سیملت و موجک کونچلت اشاره کرد. موجک مورد استفاده در تبدیل wavelet تحقیق حاضر، از نوع دابینچز از مرتبه ۴ می باشد (db4). در شکل (۵) سری زمانی جریان رودخانه قره آغاچ در ایستگاه بند بهمن که توسط بسته آنالیز موجکی (Wavelet Packet Analysis) به فرم سری زمانی تقریب و جزئیات در آمده است در کنار سیگنال اصلی نشان داده شده است.



شکل ۳. روش تجزیه سیگنال در بسته آنالیز موجکی (Wavelet Packet Analysis)



شکل ۴. سیگنال جزئیات نیز مانند سیگنال تقریب قابل تجزیه می باشد



شکل ۵. سری زمانی جریان رودخانه قره آغاج در ایستگاه بند بهمن بصورت اصلی، سری با حذف اختلالات و سری اختلالات

۲-۲ آنالیز فراکتال:

فراکتال ها اشیاء و یا فرآیندهایی هستند که در مقیاسهای مکانی و یا زمانی متعددی، شکل ظاهری و یا رفتار یکسانی از خود بروز می دهند. این چنین اشیاء و یا فرآیندهایی دارای چنان پیچیدگیهایی در مقیاسهای بسیار کوچک می باشند که هنسه اقلیدسی قادر به تفسیر آن نمی باشد. مندلبرات مفهوم فراکتال را در قالب خاصیت خود متشابه آماری بیان کرد. بعد فراکتال، پارامتری است که میزان پیچیدگی یک شکل خود شبیه را نشان می دهد. مندلبرات و همکاران در ۱۹۶۸ مفهوم فراکتال را با ارائه خاصیت خود تناسب (self-affine) به حیطه تحلیل سریهای زمانی وارد کردند. در نظر گرفتن یک سری زمانی به عنوان یک سری فراکتال به معنی رصد کردن اطلاعات آن سری زمانی در مقیاسهای زمانی مختلف است.



فرآیندهای هیدرولوژیکی اغلب بصورت الگوهای پیچیده ای از همبستگی ها که مقیاسهای زمانی تو در تو و متعددی را شامل می شوند، بیان می گردند. بنابراین یک مقدار در یک سری زمانی در یک زمان خاص تنها به مقادیری که بلافاصله بعد از آن حاضر می شوند، بستگی ندارد؛ بلکه به تغییرات مقادیر سری در گذشته و آینده دور نیز بستگی دارد. افزایش خواص فراکتالی یک سری زمانی در حقیقت به معنای افزایش همبستگی ها در سری می باشد و این به معنای افزایش قدرت تحلیل در پیش بینی سری است.

آنالیز فراکتال برای درک بهتر از طبیعت این تغییرات و کشف وابستگیهای ذاتی موجود مابین مقادیر سریهای زمانی بکار گرفته می شود. برای این منظور باید ابتدا بعد فراکتال سری زمانی و به تبع آن ضریب H^1 سری را بدست آورد. برای این منظور روشهای مختلفی وجود دارد که هر یک بسته به کلاس سیگنال (fBm/ fGn) قابل استفاده می باشند. در تحقیق حاضر از دو روش، یکی مبتنی بر آنالیز wavelet برای حصول به ضریب H به نام روش AWC^2 یا روش متوسط ضرایب موجکی و برای تعیین ضریب H سریهای زمانی غیرپایا (fBm) و دیگری آنالیز طیفی توان به روش موجکی $Wavelet PSD^3$ برای تحلیل سریهای زمانی پایا (fGn) استفاده شده است.

۱-۲-۲ روش متوسط ضرایب موجکی (Average Wavelet Coefficients)

^۱) Hurst

^۱) Average Wavelet Coefficients

^۲) Wavelet Power Spectral Density



با استفاده از آنالیز موجکی فراکتال (Fractal wavelet analysis) می توان به برآورد دقیقی از تغییرات دینامیکی مشخصات یک سیگنال دست یافت. تبدیل موجکی (WT)^۱ به سه روش می تواند ضریب H را محاسبه کند که عبارتند از: (۱) روش تبدیلات مدول ماکسیما (WTMM) (۲) آنالیز بسته موجکی (Wavelet packet) و (۳) روش میانگین ضرایب موجکی (AWC). در دامنه wavelet یک سیگنال، به موجک هایی با تناوب محدود که از موج مادر استخراج شده اند تبدیل می شود. موج مادر را می

$$\psi_{a;b}(x) = \psi\left(\frac{x-b}{a}\right) \quad \text{توان بصورت زیر نمایش داد:}$$

(۵)

که در آن $a > 0$ پارامترهای مقیاسی و $-\infty < b < \infty$ پارامتر تبدیل تابع $h(x)$ می باشد. بدین صورت CWT بصورت زیر نمایش داده می شود:

$$W[h](a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi_{a;b}^*(x) h(x) dx \quad (۶)$$

و تابع wavelet فراکتال های خود متناسب بصورت زیر است:

$$W[h](\lambda_a, \lambda_b) \approx \lambda^{(1/2)+H} W[h](a, b) \quad (۷)$$

با توجه به تغییرات b ضرایب بصورت میانگین بیان می گردند و داریم:

$$W[h](a) = \langle |W[h](a, b)| \rangle_b \quad (۸)$$



که در آن $\langle \cdot \rangle_b$ نمایانگر مقدار متوسط ریاضی استاندارد مربوط به متغیر b می باشد و در نتیجه معادله بصورت زیر در می آید:

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

مقدار H را می توان از شیب خطی که به نمودار $\log(W[h](a))$ در مقابل $\log(a)$ برازش داده می شود بصورت زیر بدست آورد:

$$H = (1/2) - \text{شیب}$$

۲-۲-۲ آنالیز طیفی توان به کمک تبدیل موجکی : Wavelet Power Spectral Density

بر اساس رابطه ای که مندلبرات و ون سن ارائه کردند می توان گفت:

$$S(f) \propto 1/f^\beta \quad (10)$$

که در این رابطه f تناوب و $S(f)$ مقدار مجذور وابسته به آن می باشد. β با محاسبه شیب منحنی نمودار دو

لگاریتمی $S(f)$ در برابر f بدست می آید. آندراس اکه و همکاران نشان دادند که این روش می تواند برای

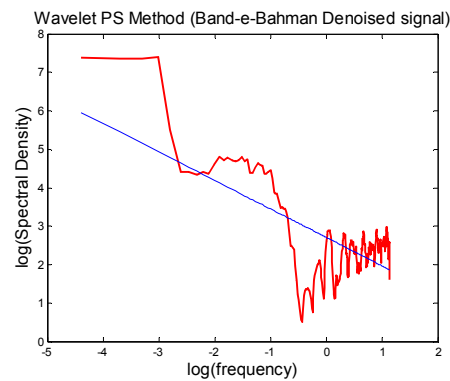
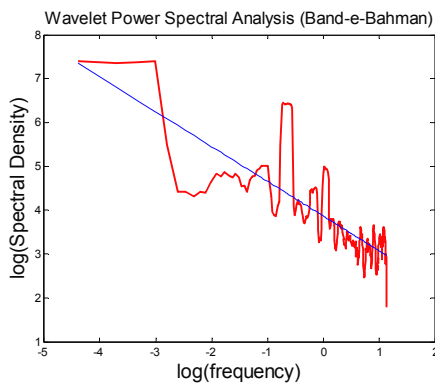
هر دو نوع سری fBm و fGn استفاده شود به گونه ای که در fGn ، β در دامنه -1 تا $+1$ و در fBm در دامنه 1

تا 3 تغییر می کند. این روش استاندارد PSD می باشد که بر اساس تبدیل فوریه عمل می کند حال اگر بجای

تبدیل فوریه از تبدیل موجکی (WT) استفاده کنیم در حقیقت آنالیز طیفی توان موجکی را بکار برده ایم که در



مورد سریهای زمانی با توجه به دینامیک غیر خطی و هندسه نامنظم گزینه مناسب تری می باشد. در شکل (۶) تحلیل طیفی سری زمانی جریان رودخانه قره آجاج در ایستگاه بند بهمن به دو صورت اصلی (Original Signal) و با حذف اختلالات (De noised Signal) نشان داده شده است.



شکل ۶. نمایش تحلیل طیفی سری زمانی جریان در دو حالت اصلی و حذف اختلالات برای سری زمانی جریان در ایستگاه بند بهمن

۳-۲ 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.

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

با یک متوسط صفر:



$$\langle [B_H(t) - B_H(t_0)] \rangle = \int_{-\infty}^{+\infty} [B_H(t) - B_H(t_0)] P\{[B_H(t) - B_H(t_0)]\} d\{[B_H(t) - B_H(t_0)]\} = 0$$

و واریانسی آن

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

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 $0 < H < 1$ را ارضا کند. رابطه همبستگی بین افزایش های متوالی این سری از $[B_H(0) - B_H(-t)]$ در گذشته و $[B_H(t) - B_H(0)]$ در آینده بصورت زیر

بیان می شود:

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

با در نظر گرفتن اینکه

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

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

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

با استفاده از این رابطه و با داشتن ضریب H سریهای زمانی، می توان میزان همبستگی اطلاعات یک سری

زمانی و یا به عبارتی حافظه بلند مدت آن را بررسی کرد. نتایج حاصل از بررسی اثر حذف اختلالات بر روی



افزایش میزان ضریب Hurst به تبع آن افزایش ضریب همبستگی سری زمانی جریان رودخانه قره آغاج در ایستگاه های بند بهمن، علی آباد و تنگ کارزین در جدول ۲ آمده است.

۲-۴ اندازه گیری توان سیگنال:

برای محاسبه توان متوسط یک سیگنال می توان مساحت زیر منحنی PSD را در طول دامنه زمانی موردنظر جمع کرد. برای این منظور ابتدا با استفاده از روش PSD یک منحنی طیفی از سیگنال موردنظر ترسیم گردیده و سپس با انتگرال گیری از ابتدا تا انتهای بازه زمانی، میانگین توان سیگنال بدست می آید. باید دقت داشت که مساحت زیر منحنی PSD میانگین توان سیگنال می باشد و نه پیک توان.

هدف از انجام این آنالیز بررسی نقش حذف اختلالات از سیگنال اصلی است. با توجه به شکل (۷) مشخص می گردد که پس از حذف اختلالات از سیگنال، توان آن تقریباً به نصف کاهش یافته است. کاهش انرژی سیگنال بواسطه حذف اختلالات نشان دهنده کاهش حضور پرشها و بی قاعدگی های غیر قابل پیش بینی در سیگنال ضرایب (De noised Signal) می باشد. بدین ترتیب امکان شناسایی دینامیک و هندسه سری زمانی اصلی بیشتر فراهم خواهد بود. نتایج حاصل از حذف اختلالات از سری های زمانی جریان رودخانه قره آغاج در ایستگاه های بند بهمن، علی آباد و تنگ کارزین در جدول ۲ آمده است.


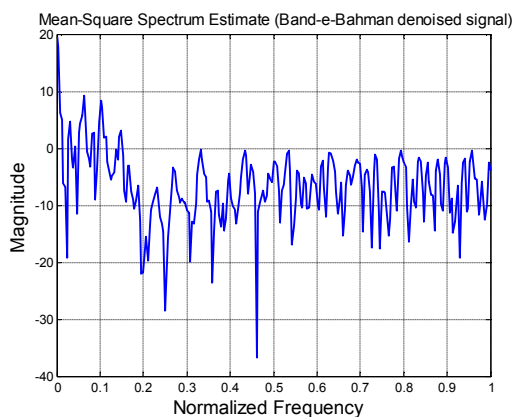
۲-۵ شبکه عصبی مصنوعی (ANN):



همایش ملی مدیریت بحران آب
The National Conference on Water Crisis Management
دانشگاه آزاد اسلامی واحد مرودشت، اسفندماه ۱۳۸۸



شبکه های عصبی مصنوعی به عنوان ابزاری قدرتمند در مدلسازی فرآیندهای هیدرولوژیکی بشمار می روند. فرآیندهایی نظیر بارش- رواناب، کیفیت آب، رسوب گذاری، پیش بینی بارندگی و سایر پارامترهای هیدرولوژیکی توسط محققین مختلف با این ابزار مورد بررسی و پیش بینی قرار گرفته اند. نتایج مدل شبکه عصبی مصنوعی به عنوان پیش بینی از تغییرات سری هیدرولوژیکی در آینده، به شدت به نحوه ارائه و آموزش ورودیها به مدل دارد. این موضوع خصوصاً در مورد سریهای زمانی غیرپایا (non-stationary) تا به آنجاست که در صورت عدم انجام پیش پردازش مناسب بر روی ورودیها و (یا) پس پردازش خروجیها، مدل از داشتن عملکرد درست، ناتوان خواهد بود (کاناس، ۲۰۰۶). کلید تحلیل



شکل ۷. میانگین توان سری زمانی در دو حالت سیگنال اصلی و پس از حذف اختلالات از آن برای سری زمانی جریان رودخانه قره آغاج در ایستگاه بند

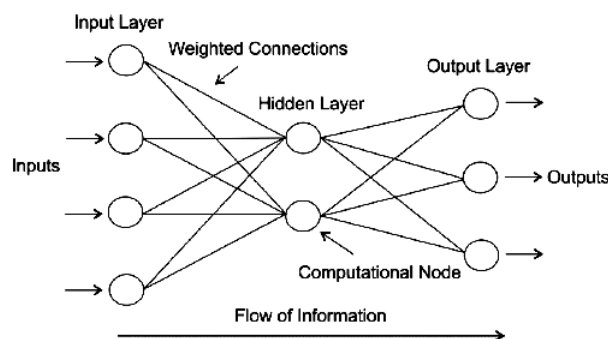
بهمن.



همایش ملی مدیریت بحران آب
The National Conference on Water Crisis Management
دانشگاه آزاد اسلامی واحد مرودشت، اسفندماه ۱۳۸۸



سریهای زمانی در وقع لحاظ کردن تغییرات زمانی خود سیگنالها نمی باشد، بلکه منظور کردن اثر فرآیندی است که سیگنال را بوجود می آورد. در تحقیق حاضر برای شبیه سازی و پیش بینی دبی ماهیانه رودخانه قره آغاج از اطلاعات ایستگاههای دبی سنجی بند بهمن، علی آباد و تنگ کارزین واقع در حوضه آبریز رودخانه استفاده شده است. تکنیک مورد استفاده جهت پیش پردازش داده های ورودی (سری زمانی رودخانه) به مدل شبکه عصبی، روش حذف اختلالات با استفاده از تئوری موجک (wavelet De noising) می باشد. در این روش تنها با بکارگرفتن ضرایب موجکی می توان با حذف اختلالات از موج پایه در مقیاسهای مختلف، تفسیری از ساختار سری زمانی و اطلاعات مهم و اساسی را از حافظه سری زمانی استخراج کرد. این روش بصورت گسترده بر روی سریهای زمانی و خصوصاً کلاس fBm (غیرپایا) بکار گرفته می شود (نیسون و ون شاس، ۱۹۹۹).



شکل ۸. شبکه عصبی چندلایه پرسپترون (MLP)

۲-۵-۱ شبکه عصبی پرسپترون چندلایه:



شبکه های عصبی مصنوعی ابزاری قدرتمند در حل مسائل گوناگون از قبیل تشخیص و بازیابی الگوها، پردازش اطلاعات، کنترل غیرخطی و پیش بینی سریهای زمانی ارائه می دهند. این روش خصوصاً در حل مسائل شامل حجم عظیم داده های غیرخطی، پویا و همراه اختلال و در حالتی که روابط در پوسته زیرین فرآیندهای فیزیکی پدید آورنده سریهای زمانی کاملاً شناخته شده نیست، بسیار مؤثرند (سی و اپنشاو، ۱۹۹۹).

شبکه های عصبی مصنوعی ساختارهایی توزیعی، استنتاجی، عموماً غیر خطی و شامل المانهای پردازشی به نام نرون (neuron) می باشند. هر نرون به نرونهای دیگر متصل است. اتصال مجموعه نرونها به یکدیگر ساختار شبکه عصبی مصنوعی ANN را بوجود می آورد. اتصالات بین نرونها توسط پارامترهای قابل تنظیمی به نام وزن، مقیاس دهی می شوند. هر نرون با دریافت ورودی از نرونهای دیگر یک تابع استاتیک غیرخطی وزن دار از آنها تولید کرده و به عنوان خروجی معرفی می کند. متداول ترین شبکه عصبی، شبکه عصبی چندلایه پرسپترون (MLP) نامیده می شود (شکل ۸). اختلاف بین خروجی حاصل شده با مقدار مورد انتظار، بصورت انتشار بازگشتی به شبکه برگردانده می شود و وزنهای اتصالات در مرحله آموزش و از طریق یک الگوریتم آموزشی به روز می گردند و این عمل مجدداً تا جایی تکرار می گردد که خطای حاصله، از حداقل مقدار مورد نظر شبکه کمتر شود. در تحقیق حاضر از یک شبکه عصبی MLP مبتنی بر الگوریتم Levenberg-Marquardt استفاده شده است. تعداد لایه های میانی با انجام عمل سعی و خطا ۳۷ تعیین گردید و در نهایت ساختاری که در مرحله صحت سنجی، کمترین میزان خطا را در قالب خطاهای RMS و MAP ارایه کرد به عنوان ساختار اصلی مدل پیش بینی انتخاب گردید.



۳ منطقه مورد مطالعه:

داده های استفاده شده مربوط به حوضه آبریز رودخانه قره آغاچ واقع در استان فارس می باشد. داده ها بصورت ماهیانه بوده و آمار ۳۶ ساله برداشت شده از سه ایستگاه بند بهمن، علی آباد و تنگ کارزین را شامل می شود. حوضه آبریز رودخانه قره آغاچ دارای طبیعتی نیمه کوهستانی و نیمه مسطح می باشد. منطقه مورد مطالعه در تحقیق حاضر بیش از ۸۰۰۰ هکتار وسعت دارد. مدل شبیه سازی توسعه داده شده بر روی ۱۰۰ ماه آخر بازه آماری موجود اجرا شده است.

۴ نتایج:

برای جدا کردن اختلالات از موج پایه از دو روش CWT و DWT استفاده شده است. در هر دو روش از موجک دابینچز از مرتبه ۴ (db ϵ) که توسط دابینچز در ۱۹۹۲ ارائه شده است، استفاده گردید. برای بررسی اثر حذف اختلال از سیگنال بر روی جوابهای پیش بینی، سه سناریو در نظر گرفته شده است.

(۱) سناریو اول عبارت از آموزش شبکه عصبی توسط ضرایب CWT به عنوان ورودی و همان ضرایب یک ماه بعد به عنوان خروجی می بود. ضرایب پیش بینی توسط مدل شبکه عصبی نشان دهنده داده های پیش بینی جریان رودخانه در ماه بعد است (شکل ۹).



همایش ملی مدیریت بحران آب
The National Conference on Water Crisis Management
دانشگاه آزاد اسلامی واحد مرودشت، اسفندماه ۱۳۸۸




۲) سناریو دوم عبارت از آموزش شبکه عصبی توسط ضرایب DWT به عنوان ورودی و همان ضرایب یک ماه بعد به عنوان خروجی می بود که در این حالت نیز ضرایب پیش بینی شده توسط MLP نشان دهنده دبی رودخانه در ماه بعد است (شکل ۱۰).

۳) سناریو سوم عبارت از آموزش شبکه عصبی با داده های اصلی (بدون حذف اختلالات) به عنوان ورودی و همان داده ها یک ماه بعد به عنوان خروجی می بود. در این حالت نیز مقادیر پیش بینی شده توسط MLP نشان دهنده دبی رودخانه در ماه بعد است. در کلیه حالات، ورودیها قبل از وارد شدن به شبکه عصبی نرمال شده اند (شکل ۱۱).

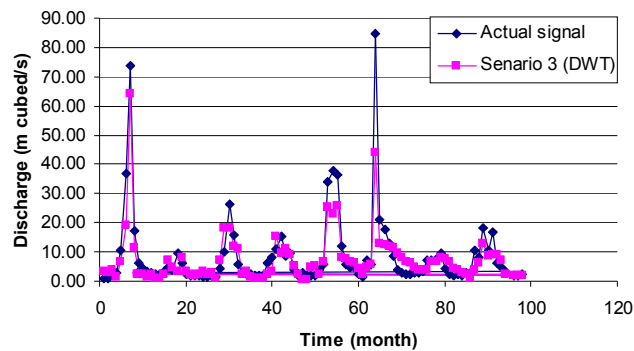
نتایج حاکی از آنست که عملکرد مدل در دو سناریو ۱ و ۲ بهتر از حالتی است که داده ها بدون پیش پردازش به مدل شبکه عصبی داده شوند. معیار سنجش عملکرد مدل در هر سناریو میزان خطای حاصل در مقایسه با داده های معتبر موجود می باشد که بصورت RMSE و MAE نشان داده شده است. در شکل (۵) سری زمانی مربوط به سیگنال اصلی دبی در ایستگاه بند بهمن، سیگنال اصلی منهای اختلالات و سیگنال اختلالات نمایش داده شده است.




همایش ملی مدیریت بحران آب
The National Conference on Water Crisis Management
دانشگاه آزاد اسلامی واحد مرودشت، اسفندماه ۱۳۸۸



شکل ۹. مقایسه نتایج حاصل از مدل پیش بینی شبکه عصبی مصنوعی با داده های واقعی در حالتی که ورودی مدل ضرایب CWT تبدیل موجکی باشد.



شکل ۱۰. مقایسه نتایج حاصل از مدل پیش بینی شبکه عصبی مصنوعی با داده های واقعی در حالتی که ورودی مدل ضرایب DWT تبدیل موجکی باشد.



شکل ۱۱. مقایسه نتایج حاصل از مدل پیش بینی شبکه عصبی مصنوعی با داده های واقعی در حالتی که ورودی مدل داده های نرمال شده واقعی باشد.



شاخص های زیر مبنای مقایسه عملکرد مدل پیش بینی در مورد هر سناریو را بیان می کنند. در روابط زیر N

تعداد مشاهدات، O_i مقادیر مشاهدات واقعی و P_i مقادیر پیش بینی شده است.

○ خطای RMS (Root Mean Squared error)

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

○ خطای MA (Mean Absolute error)

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

بر این اساس جدول ۱ نتایج حاصل از این بررسی را برای هر سه سناریو انجام شده نمایش می دهد. آنچه

مسلّم است وجود خطای کمتر در نتایج مدل پیش بینی در دو حالت انجام پیش پردازش بر روی سریهای زمانی

جریان رودخانه قبل از آموزش داده ها توسط شبکه عصبی می باشد.

جدول ۱. شاخص بررسی نتایج حاصل از پیش بینی مدل شبکه عصبی مصنوعی با توجه به هر یک از سناریوها

	RMSE	MAE
(ضرایب CWT): سناریو ۱	۱۲/۹۴	۹/۸
(ضرایب DWT): سناریو ۲	۱۱/۰۷	۷/۴۴
(داده های اصلی): سناریو ۳	۱۷/۱۱	۱۲/۲۳



همایش ملی مدیریت بحران آب
The National Conference on Water Crisis Management
دانشگاه آزاد اسلامی واحد مرودشت، اسفندماه ۱۳۸۸



نتایج مربوط به تحلیل همبستگی و رابطه آن با میزان انرژی سری زمانی پس از انجام فرآیند پیش پردازش موجکی شامل تجزیه سیگنال به موج تقریب و موج جزئیات نشان می دهد که سری زمانی پس از حذف اختلالات همزمان که ضریب همبستگی بیشتری پیدا می کند از متوسط انرژی اش بطور معناداری کاسته می گردد بگونه ای که می توان اذعان کرد که انرژی ناشی از اختلالات در سری زمانی تقریباً نیمی از انرژی کل سیگنال است که بصورت بی نظمی (Irregularity) و یا پرش و نوسانات تند غیر قابل پیش بینی (Jumps & Spikes) در سیگنال حضور دارند. حذف فرآیندهای ذکر شده از سیگنال اصلی مقدمات داشتن تخمین های دقیقتر توسط مدل های پیش بینی را فراهم می سازد.

جدول ۲: مقایسه ضرایب H و ضرایب همبستگی (C) و همچنین متوسط انرژی سیگنال در سریهای زمانی جریان رودخانه قره آغاج در ایستگاههای مورد

مطالعه

نام ایستگاه	ضریب H در سیگنال اصلی	ضریب H پس از حذف اختلالات	ضریب همبستگی C در سیگنال اصلی	ضریب همبستگی C پس از حذف اختلالات	توان سیگنال اصلی	توان سیگنال پس از حذف اختلالات
بند بهمن	۰/۴۴۱۷۳	۰/۸۱۲۸۷	-۰/۰۷۷۶	۰/۵۴۳	۲۹۹/۹۵۲۹	۱۵۴/۸۷۶۵
علی آباد	۰/۴۳۴۱۹	۰/۷۸۶۹۶	-۰/۰۸۷۱	۰/۴۸۸	۴۲۴/۵۵۸۰	۲۰۵/۸۵۳۶
تنگ کارزین	۰/۴۸۷۵۴	۰/۸۸۹۷۹	-۰/۰۱۷۱	۰/۷۱۶۶	۱۲۱۳/۸	۶۴۷/۸۹۶۴



۵ نتیجه گیری:

شبکه عصبی پرسپترون پیش خوران با الگوریتم LM^۱ برای پیش بینی دبی ماهیانه رودخانه قره آغاچ واقع در استان فارس بکار گرفته شده است. نتایج نشان می دهد که پیش پردازش موجکی سریهای زمانی بوسیله تبدیلیهای CWT و DWT می تواند به میزان قابل توجهی دقت پیش بینی های مدل MLP شبکه عصبی را افزایش دهد. در این بین روش DWT نتایج بهتری را ارائه می دهد در حالیکه اختلاف چندانی از نظر دقت در عملکرد با نتایج حاصل از CWT ندارد. نتایج حاصله در هر صورت، بر انجام پیش پردازش ورودیهای شبکه عصبی به صورت موجکی تأکید کرده و از افزایش کارکرد مدل پیش بینی و دقت در نتایج نهایی خبر می دهد. نتایج حاصله همچنین بر افزایش ضریب همبستگی سری زمانی پس از انجام پیش پردازش موجکی دلالت دارند.

۶ منابع:

Abrahart, R.J., See, L., Comparing neural network (NN) and Autoregressive Moving Average (ARMA) techniques for the provision of continuous river flow forecasts in two contrasting catchments, *Hydrological Processes* (۲۰۰۰) ۱۴, ۲۱۵۷-۲۱۷۲.

۱) Levenberg- Marquardt



همایش ملی مدیریت بحران آب
The National Conference on Water Crisis Management
دانشگاه آزاد اسلامی واحد مرودشت، اسفندماه ۱۳۸۸



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* ۳۱ (۲۰۰۶) ۱۱۶۴-۱۱۷۱

Cannas, B., Montisci, A., Fanni, A., See, L., Sechi, G.M., Comparing artificial neural networks and support vector machines for modeling rainfall-runoff, *Proceedings of the ۶th International Conference on Hydro informatics*, World Scientific Publishing Company (۲۰۰۴).

Daubechies, I., *Ten Lectures on Wavelets CSBM – NSF Series, Application Mathematics*, vol. ۶۱ SIAM publication, Philadelphia, A (۱۹۹۲).

Nason, G.P., Von Sachs, R., *Wavelets in time series analysis. Philosophical Transactions of the Royal Society of London Series A* (۱۹۹۹) ۳۵۷, ۲۵۱۱-۲۵۲۶.

Principe, J.C., Euliano, N.R., Curt Lefebvre, W., *Neural and Adaptive Systems*. Wiley & Sons (۲۰۰۰).

See, L., Openshaw, S., *Applying soft computing approaches to river level forecasting. Hydrological Sciences Journal* (۱۹۹۹) ۴۴, ۷۶۳-۷۷۸.