



پیش‌بینی بار معلق رودخانه با استفاده از مدل‌های سری زمانی و شبکه عصبی مصنوعی (مطالعه موردی: ایستگاه قزاقلی رودخانه گرگانرود)

فاطمه برزگری^۱ و محمدتقی دستورانی^۲

۱- عضو هیات علمی گروه کشاورزی دانشگاه پیام نور (نویسنده مسؤل: fa_barzegar@yahoo.com)

۲- دانشیار، دانشگاه فردوسی مشهد

تاریخ دریافت: ۹۲/۲/۸ تاریخ پذیرش: ۹۲/۹/۱۲

چکیده

بر آورد میزان دقیق رسوبات معلق در رودخانه‌ها از ابعاد مختلف کشاورزی، حفاظت خاک، کشتیرانی، سدسازی، حیات آبریان و ابعاد تحقیقاتی، دارای اهمیت فراوانی است. روش‌های مختلفی برای بررسی و بر آورد رسوبات معلق رودخانه، موجود می‌باشد که البته توانایی این روش‌ها متفاوت است. در تحقیق حاضر به منظور مقایسه و بررسی توانایی مدل‌های سری زمانی شامل مارکف، ARIMA و شبکه‌های عصبی در پیش‌بینی رسوب معلق، از داده‌های روزانه ایستگاه قزاقلی واقع روی رودخانه گرگانرود استفاده شده است. داده‌های موجود به صورت متوسط رسوب معلق ماهانه در محیط نرم‌افزار Minitab 16 و Neurosolutions 5 به کار گرفته شد و در نهایت پیش‌بینی رسوب برای ۱۱۱ ماه انجام گرفت. در مرحله بعد، مقادیر پیش‌بینی شده توسط مدل‌های مختلف، با شاخص‌های اندازه‌گیری خطا شامل RMSE و NMSE نشان داد که شبکه‌های عصبی در مقایسه با مدل‌های سری زمانی توانایی بهتری در پیش‌بینی و مدل‌سازی رسوب ماهانه دارد و نیز در بین مدل‌های سری زمانی، مدل مارکف در مقایسه با مدل ARIMA دارای توانایی بهتری در بر آورد رسوب معلق می‌باشد.

واژه‌های کلیدی: آریما، رسوب معلق، قزاقلی، مارکف، مدل‌سازی

مقدمه

فرسایش خاک علاوه بر این‌که به‌عنوان یک تهدید جدی برای محیط زیست به‌شمار می‌آید، خسارت‌های محسوس و نامحسوس زیادی را نیز به دنبال دارد. به‌عنوان نمونه، نتیجه بررسی‌های اقتصادی، خسارت سالانه فرسایش خاک در ایالات متحده را بالغ بر ۱۰ میلیارد دلار گزارش می‌دهد (۱۸). بیش از ۵۰٪ آلودگی آب‌ها به خاطر فرسایش اراضی کشاورزی و جنگلی مناطق بالادست آنها می‌باشد (۱۱).

با وجود پیشرفت‌های موجود در زمینه کنترل منابع آلاینده، مساله کیفیت آب و مدل‌سازی رسوب هنوز به‌عنوان یک معضل در هیدرولوژی باقی مانده است (۱۹). ارتباط بین رسوب رودخانه و دبی جریان سال‌هاست که به صورت مدل‌های مختلف با ضرایب اصلاحی متعدد در مطالعات مربوط به این زمینه (۳، ۴، ۵، ۶، ۱۲، ۱۳، ۱۴، ۲۱، ۳۱، ۳۵) به چشم می‌خورد.

مدل‌های سری زمانی نیز از جمله مباحث نوظهوری است که در دهه‌های اخیر در مدل‌سازی رسوب به‌کار گرفته شده است، از جمله مطالعات انجام شده با این روش می‌توان به موارد زیر اشاره نمود:

چن و دایک (۷)، در تحقیقی، مدل سری زمانی آریما و مدل خودهمبسته مرتبه ۵ را برای بررسی رسوب معلق در مقیاس زمانی ساعتی، به‌کار گرفتند. در

این بررسی هر مقدار رسوب معلق بر اساس ارتباط با مقادیر قبلی آن شبیه‌سازی شد و نتایج این مطالعه نشان داد که مدل سری زمانی آریما در مقایسه با مدل خودهمبسته مرتبه ۵، توانایی بهتری در پیش‌بینی رسوب معلق دارد. چن و همکاران (۸) نیز از سری زمانی برای بیان ارتباط رسوب معلق و سرعت آب در دلتای Rifuji در تانزانیا استفاده نمودند. سینگر و دان (۳۲)، از طریق بررسی سری زمانی دبی رودخانه و رسوب معلق، ارتباط بین این دو پارامتر را به صورت معادله‌ای نشان دادند، آنها در مطالعه خود از داده‌های فشرده جمع‌آوری شده در یک دوره ۲ ساله برای تخمین رسوب متوسط در یک دوره ۳۲ ساله استفاده نمودند. ملس و همکاران (۱۹)، مدل آریما را برای پیش‌بینی داده‌های رسوب روزانه سه رودخانه به‌کار گرفتند و نتایج مدل آریما را در دو رودخانه می‌سی‌سی‌پی و می‌سوری مناسب گزارش دادند. نورانی و رومیانفر (۲۵)، از مدل آریما برای مدل‌سازی بارش-رواناب و از شبکه عصبی برای پیش‌بینی رسوب در حوضه آبخیز اهر چای استفاده نمودند.

با ظهور روش‌های مبتنی بر هوش مصنوعی کامپیوتر از جمله شبکه‌های عصبی مصنوعی در مطالعات هیدرولوژی، مطالعات رسوب نیز تحت تأثیر قرار گرفته است که از جمله آنها می‌توان به تحقیقات

در دهه‌های گذشته به دلیل وجود چنین مشکلاتی هیدرولوژیست‌ها و محققین سعی کرده‌اند مدل‌های ساده شده و تجربی را برای پیش‌بینی و محاسبه خصوصیات مختلف و مهم حوزه‌های آبخیز مانند رسوب، رواناب و غیره به کار گیرند. استفاده از این روش‌ها علی‌رغم سادگی، دارای خطای زیادی در برآورد است و در بسیاری از مناطق نمی‌توان بر نتایج حاصل از آنها تکیه و استناد کرد. به همین علت، در دهه‌های اخیر سعی شده روش‌هایی مورد استفاده قرار گیرند که بتوانند شرایط طبیعی را تا حدودی درک کنند و نتایج حاصل از آنها از دقت و صحت مناسبی برخوردار باشند. یکی از روش‌هایی که در بسیاری از علوم از جمله هیدرولوژی توسعه یافته است، استفاده از روش‌های محاسبات نرم نظیر شبکه‌های عصبی مصنوعی است. شبکه‌های عصبی توانایی خوبی را در شبیه‌سازی پدیده‌های پیچیده و غیرخطی در زمینه‌های مختلف از خود نشان داده‌اند. در رابطه با مدل‌سازی رسوب معلق نیز همان‌گونه که ذکر شد پیچیدگی‌های خاصی وجود دارد و روش‌های تجربی ساده اغلب قادر به شبیه‌سازی مناسب آن نیستند لذا ارزیابی روش‌هایی چون شبکه عصبی در رابطه با این پدیده و مقایسه آن با روش‌های ساده موجود می‌تواند کمکی به حل این مشکل باشد. در این راستا در تحقیق حاضر نسبت به استفاده از این روش و ارزیابی کارایی آن اقدام گردیده است.

به‌منظور انجام این تحقیق از داده‌های رسوب معلق روزانه مربوط به ایستگاه قزاقلی استفاده شد. ایستگاه مورد مطالعه در حوزه آبخیز گرگانرود واقع شده است. حوضه آبخیز مورد نظر با مساحت ۱۰۲۰۰ کیلومتر مربع یکی از حوزه‌های دریای خزر است که در محدوده ۱۰' ۵۴ تا ۲۶' ۵۶ طول شرقی و ۳۵' ۳۶ تا ۱۵' ۳۸ عرض شمالی قرار گرفته است. طول رودخانه اصلی این حوضه بالغ بر ۲۵۰ کیلومتر می‌باشد که در امتداد عمومی شرقی- غربی گسترش یافته و از جنوب شرقی دریای خزر به این دریا می‌پیوندد. رودخانه گرگانرود به دلیل موقعیت جغرافیایی، اقلیمی و زمین‌شناسی از جایگاه ویژه‌ای در مطالعات رسوب معلق برخوردار است. هم‌چنین به دلیل قرار گرفتن در بالادست سد وشمگیر دارای آمار فشرده‌ای از رسوب معلق بوده که از نظر مطالعاتی ارزشمند می‌باشد. طول دوره آماری مذکور از سال ۱۳۴۹ تا ۱۳۸۸ بوده و شامل ۶۷۷۷ داده می‌باشد که به‌صورت روزانه جمع‌آوری شده است. با وجود این داده‌های کافی و اهمیت سد وشمگیر، هنوز رقم دقیق و قابل اعتمادی از میزان رسوب ورودی به سد در دست نمی‌باشد. البته مطالعاتی در زمینه برآورد رسوب انجام شده است (۴)، ولی با توجه به ارزش این ایستگاه هیدرومتری از نظر تعداد داده‌های رسوب و اهمیت سد

ابتخارت و وایت (۱)، نگی و همکاران (۲۳)، بیتیان و گو (۳۴)، جین (۱۶)، کیسی (۱۷)، آلپ و سی گی زوگلو (۲)، سی گی زوگلو و کیسی (۹)، کوبارنر و همکاران (۱۰)، نورانی و همکاران (۲۶)، رجائی و همکاران (۲۸)، رضابور و همکاران (۳۰) و جعفری میانایی و کشاورز (۱۵) اشاره نمود. تحقیقات ذکر شده همگی بر توانایی شبکه عصبی مصنوعی در پیش‌بینی رسوب معلق تأکید دارند. راگوشی و همکاران (۲۷)، به‌منظور پیش‌بینی رواناب و رسوب معلق متناظر با آن، از شبکه عصبی مصنوعی استفاده نمودند، نتایج بررسی ایشان بیان‌گر دقت مناسب شبکه عصبی در مقایسه با روش‌های رگرسیون خطی می‌باشد. مصطفی و همکاران (۲۲)، نیز با هدف برآورد رسوب معلق، شبکه عصبی مصنوعی را در دو ساختار MLFF و RBF به کار گرفتند. نتایج بررسی تحقیق مذکور، قابلیت هر دو مدل را در بررسی رسوب معلق، تأیید می‌کند. البته بر اساس نتایج این تحقیق، مدل RBF شبیه‌سازی را با دقت بالاتری انجام داده است. رضوی‌زاده و همکاران (۲۹)، نیز از مدل شبکه عصبی مصنوعی برای شبیه‌سازی بار معلق روزانه در رودخانه طالقان استفاده و نتایج این شبیه‌سازی را قابل قبول و مناسب گزارش نمودند.

تاکنون کاربرد شبکه‌های عصبی در پیش‌بینی رسوب معلق یا بر اساس مدل‌سازی با استفاده از پارامترهای فیزیکی و اقلیمی تأثیرگذار در میزان بار رسوبی بوده (۲۵، ۳۳) و یا بر اساس داده‌های ساعتی و گاه لحظه‌ای حاصل از اندازه‌گیری مستقیم رسوب معلق استوار می‌باشد، که در مورد اخیر اطلاعات مربوطه در شرایط فعلی ایستگاه‌های هیدرومتری کشور ما موجود نمی‌باشد. بنابراین یا باید از داده‌های فشرده لحظه‌ای استفاده نمود یا داده‌های رسوبی را در مقاطعی غیر از روزانه بررسی کرد. لذا در مطالعه حاضر برای اولین بار از شبکه‌های عصبی در پیش‌بینی داده‌های رسوب ماهانه استفاده شد که با شرایط موجود در ایران نیز، سازگاری بیشتری دارد. از طرفی، به علت سادگی و کاربرد راحت مدل‌های آماری سری زمانی و اعتبار بیشتر آنها در مقایسه با منحنی‌های سنجه، در تحقیق حاضر، این روش نیز در کنار شبکه عصبی، در پیش‌بینی رسوب ماهانه به کار گرفته شد و نتایج روش‌ها مورد مقایسه و تحلیل قرار گرفت.

مواد و روش‌ها

پارامترهای متعدد دخیل در تولید و انتقال رسوبات معلق رودخانه‌ای، به همراه وجود پیچیدگی‌های زیاد و روابط غیرخطی بین این پارامترها با یکدیگر و هم‌چنین با ورودی‌ها و خروجی‌های سیستم آبخیز، باعث شده پیش‌بینی دقیق مقدار رسوب معلق بسیار مشکل باشد.

$${}_n(B) = 1 - {}_{n_1}B - {}_{n_2}B^2 - \dots - {}_{n_q}Bq \quad (3)$$

در روابط ارائه شده، Z_t سری اصلی، V_t سری تصادفی با میانگین صفر و واریانس σ_v^2 ، W پارامترهای مدل خود همبسته (AR)، θ پارامترهای میانگین متحرک (MA)، P مرتبه مربوط به مدل خود همبسته، q مرتبه مربوط به مدل میانگین متحرک، d مرتبه مربوط به تفاضل و B عملگر پسرو می‌باشد (۲۴).

به منظور کاربرد روش‌های سری زمانی از داده‌های ماهانه مذکور در محیط نرم‌افزار آماری Minitab 16 استفاده شد. با توجه به این که شرط استفاده از مدل‌های سری زمانی، نرمال بودن داده‌هاست، ابتدا با استفاده از آزمون نرمال بودن، وضعیت داده‌ها بررسی و سپس با به کارگیری تبدیل لگاریتمی، داده‌ها نرمال شد و در نهایت، مدل‌های مارکف و ARIMA روی داده‌های تبدیل شده به کار گرفته شد.

نتایج حاصل از به کارگیری این سه روش با استفاده از مجموع مربع انحرافات (SSR) (رابطه ۴) و معیار اکائیک (رابطه ۵) مورد مقایسه قرار گرفت.

$$SSR = \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (4)$$

$$AIC = n \ln(SSR) + 2(p+q) \quad (5)$$

در این معادلات، x_i مقدار رسوب برآورد شده با مدل، \hat{x}_i مقدار رسوب اندازه‌گیری شده، p مرتبه اول مدل سری زمانی ARIMA(p,d,q) و q مرتبه سوم مدل سری زمانی ARIMA(p,d,q) می‌باشد. لازم به ذکر است که مدل دارای مجموع مربع انحرافات و یا معیار اکائیک کمتر، مدل مناسب‌تری می‌باشد.

نتایج و بحث

نتایج حاصل از تبدیل Box-Cox بیانگر نرمال بودن داده‌های حاصل از تبدیل است (شکل ۱). داده‌ها هم در میانگین و هم در واریانس ایستا هستند.

و شمگیر در پایداری و ثبات اکوسیستم منطقه، می‌توان گفت که هنوز مطالعات زیادی را در این زمینه می‌طلبید.

از آنجایی که داده‌های دبی رسوب و دبی جریان، به صورت منظم جمع‌آوری نشده بود، با استفاده از برنامه Excel داده‌ها به صورت متوسط ماهانه تنظیم گردید تا تناسب بهتری با مدل‌های مورد استفاده داشته باشد.

جهت مدل‌سازی با شبکه عصبی از داده‌های دبی ماهانه و رسوب متناظر آن در محیط نرم‌افزار Neurosolutions 5 استفاده گردید. لازم به ذکر است که در مطالعات مربوط به منابع طبیعی، اغلب از مدل شبکه عصبی پرسپترون چند لایه استفاده می‌شود که همیشه تناسب لازم را با داده‌های موجود ندارد، به عنوان مثال، معماریان و بالاسوندرام در سال ۲۰۱۲ به بررسی رفتار رسوب روزانه با شبکه پرسپترون چند لایه و شبکه پایه شعاعی در مناطق نیمه خشک پرداختند و هر دو مدل را برای ارزیابی مقادیر زیاد رسوب روزانه، نامناسب دانستند (۲۰)، لذا در تحقیق حاضر ۴۴ ساختار مختلف از مدل‌های مورد نظر شامل مدل‌های Multilayer Perceptron, Generalized Feed Forward Modular Neural Network, Jordan/Elman Network, PCA, Recurrent Network مورد بررسی و استفاده قرار گرفتند و در نهایت، مناسب‌ترین آنها برای پیش‌بینی رسوب انتخاب گردید که در قسمت نتایج ارائه شده است.

در مرحله بعد، از مدل‌های آماری سری زمانی استفاده شد. تجزیه و تحلیل سری زمانی در ابتدا توسط Box and Jen Kins ارائه شده است. تابع خطی این مدل بر اساس سه مولفه خطی پارامتریک زیر می‌باشد:

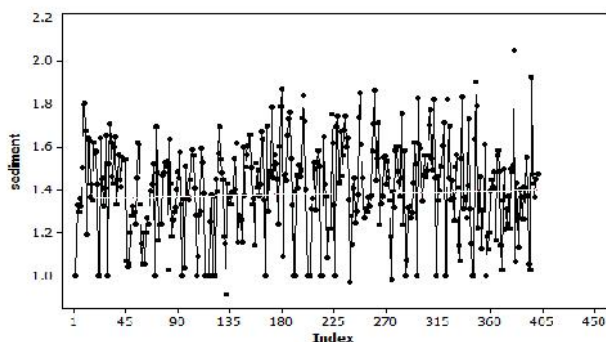
Moving Average (MA), Integration (I), Auto regression (AR)

در نهایت سری زمانی ARIMA را می‌توان به شکل رابطه (۱) بازنویسی نمود.

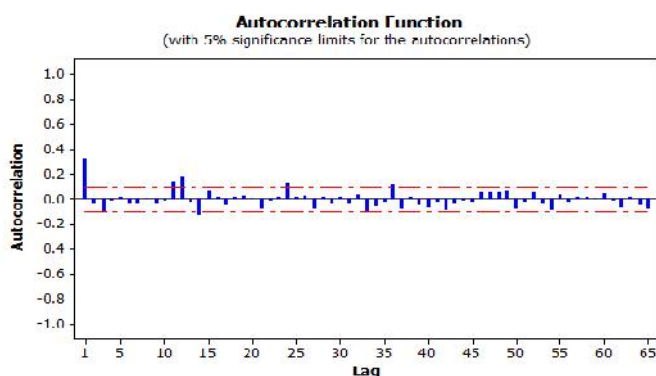
$$w(B)(1-B)^d Z_t = {}_n(B) V_t \quad (1)$$

که در آن $\theta(B), \phi(B)$ به صورت روابط ۲ و ۳ تعریف می‌شوند:

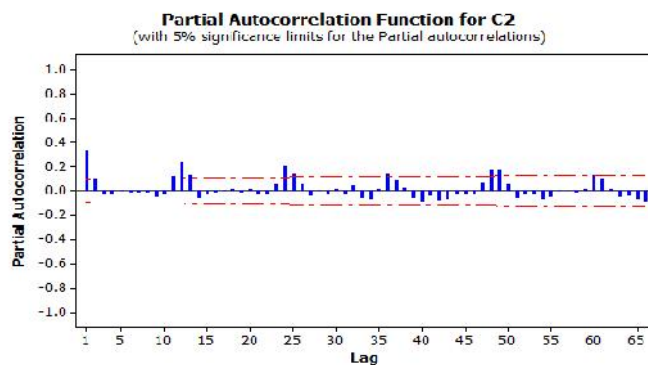
$$w(B) = 1 - w_1 B - w_2 B^2 - \dots - w_p B^p \quad (2)$$



شکل ۱- نمودار داده‌های رسوب تبدیل شده



شکل ۲- نمودار مربوط به خودهمبستگی داده‌های رسوب تبدیل شده



شکل ۳- نمودار مربوط به خودهمبستگی جزئی داده‌های رسوب تبدیل شده

جهت مقایسه استفاده گردید. نتایج مربوط به مقایسه مدل‌ها با مجموع مربع انحرافات و یا معیار اکائیک در جدول ۱ آمده است. با توجه به این که مدل دارای مجموع مربع انحرافات و یا معیار اکائیک کمتر، مدل مناسب‌تری می‌باشد، بنابراین می‌توان ادعا نمود که مدل مارکف و $ARIMA(1,1,2)$ در مقایسه با مدل $ARIMA(2,1,3)$ دارای اطمینان بیشتری هستند.

شکل ۲ و ۳ به ترتیب نمودار مربوط به خود همبستگی^۱ و خود همبستگی جزئی^۲ داده‌های تبدیل شده را نشان می‌دهند. همان‌طور که ملاحظه می‌شود، برای حذف روند داده‌ها، ایجاد دو تأخیر در سری داده‌ها مناسب به نظر می‌رسد. بنابراین از مدل آریما با مرتبه (۱ و ۲) روی داده‌های تبدیل شده می‌توان استفاده نمود. البته به منظور نتیجه‌گیری بهتر، از مدل مارکف یا اتورگرسیو درجه یک و مدل $ARIMA(2,1,3)$ نیز

1- Autocorrelation factor

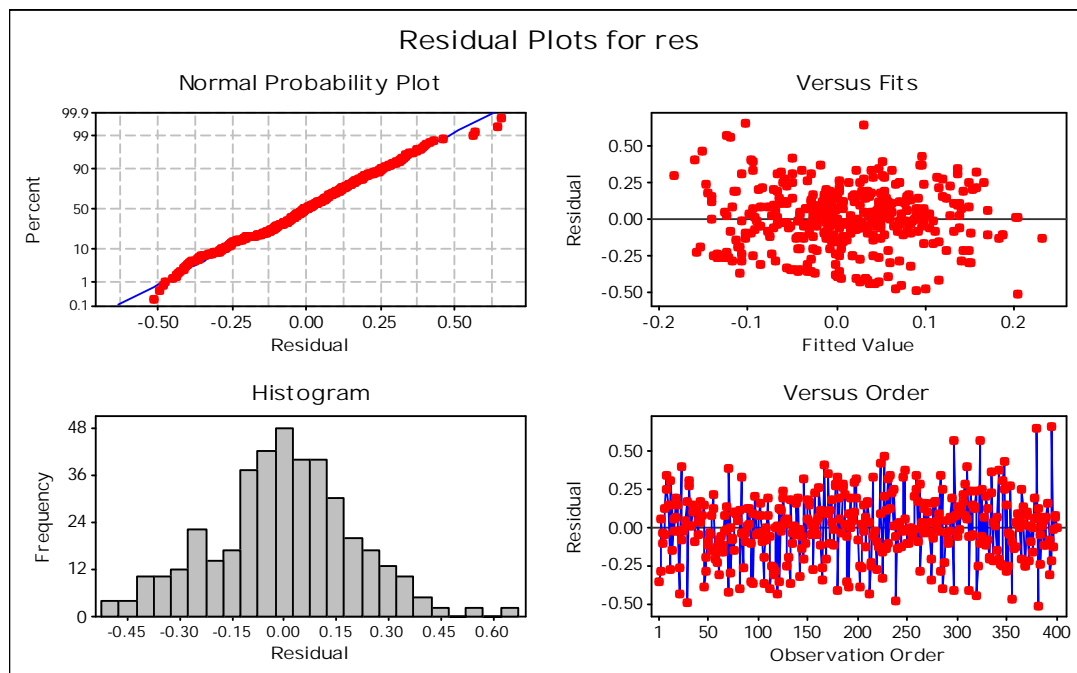
2- Partial autocorrelation factor

جدول ۱- مقایسه مدل‌های مختلف با معیار اکائیک

مدل	SSR	AIC
ARIMA(1,1,2)	۳۰۰۳/۹۹	۳۰۰۹/۸۹۸
ARIMA(2,1,3)	۳۰۰۳/۸۹	۳۰۱۳/۸۹۸۷
مارکف	۳۰۰۳/۱۰۴	۳۰۱۳/۱۰۴۸

مارکف، باقیمانده‌های مدل نهایی مورد بررسی قرار گرفت (شکل ۴).

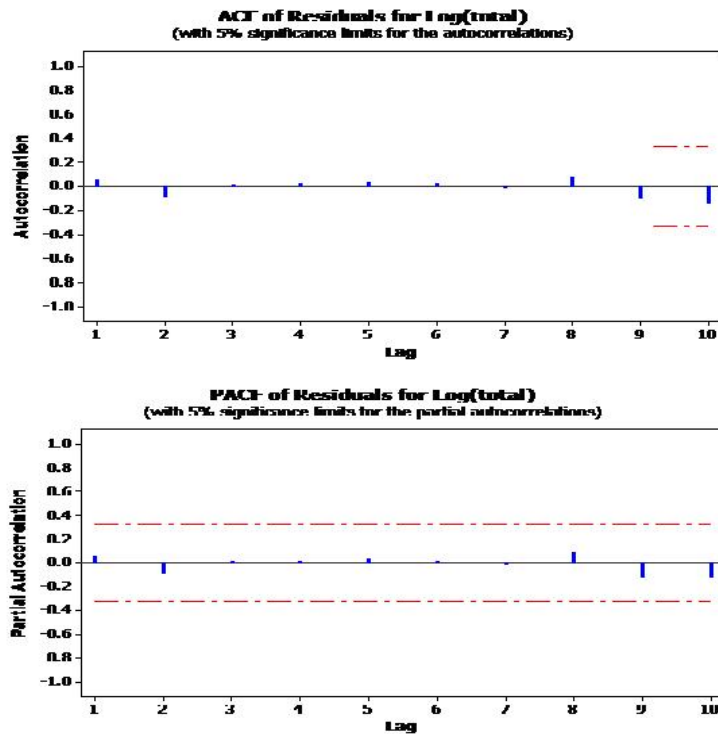
بررسی مناسبیت مدل انتخابی سری زمانی به منظور بررسی مناسب بودن مدل انتخابی سری زمانی



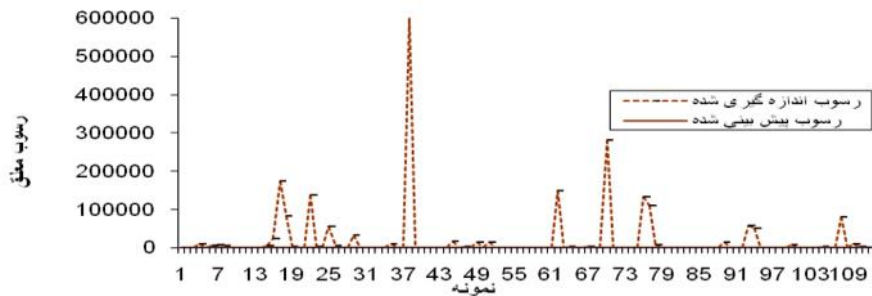
شکل ۴- نمودار مربوط به توزیع باقیمانده‌های حاصل از برازش مدل مارکف

می‌توان گفت، هیچ یک از خود همبستگی‌ها معنی‌دار نیستند زیرا از حدود استانداردشان تجاوز نکرده‌اند. این به معنی ناهمبسته بودن باقیمانده‌ها و تصادفی بودن آنهاست که تناسب مدل انتخابی را با داده‌ها نشان می‌دهد. نتایج حاصل از پیش‌بینی رسوب ماهانه برای ۱۱۱ ماه (۲۵ درصد داده‌ها)، با استفاده از مدل مارکف، ARIMA(1,1,2) و مدل‌های برگزیده شبکه عصبی مصنوعی در شکل‌های ۶ تا ۹ آمده است.

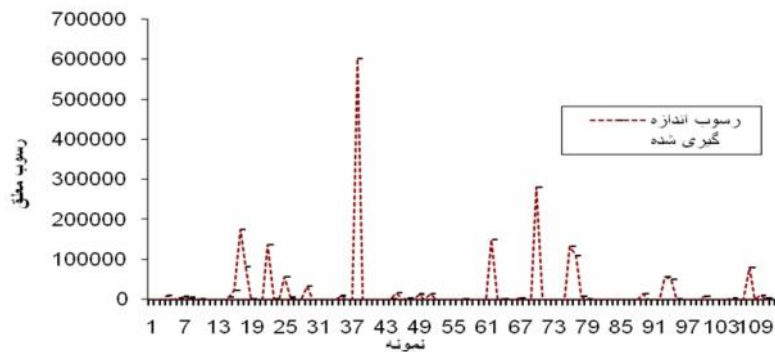
در نمودار احتمال نرمال، نقاط تقریباً در امتداد یک خط راست قرار گرفته‌اند و این نشان می‌دهد که باقیمانده‌های حاصل از برازش مدل مارکف (اتورگرسیو درجه ۱) به صورت نرمال توزیع شده‌اند. نمودار باقیمانده‌ها در برابر مقادیر برازش داده شده نیز ساختار خاصی را نشان نمی‌دهد، برای بررسی فرض استقلال باقیمانده‌ها، خودهمبستگی و خودهمبستگی جزئی آنها رسم می‌گردد شکل (۵). بنابراین می‌توان فرض ثابت بودن واریانس باقیمانده‌ها را پذیرفت. با توجه به شکل ۵



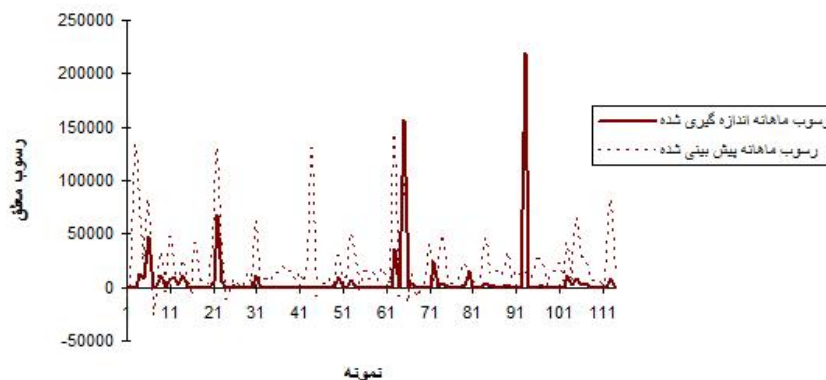
شکل ۵- خودهمبستگی و خودهمبستگی جزئی باقیمانده‌های سری تفاضلی شده لگاریتم داده‌های رسوب



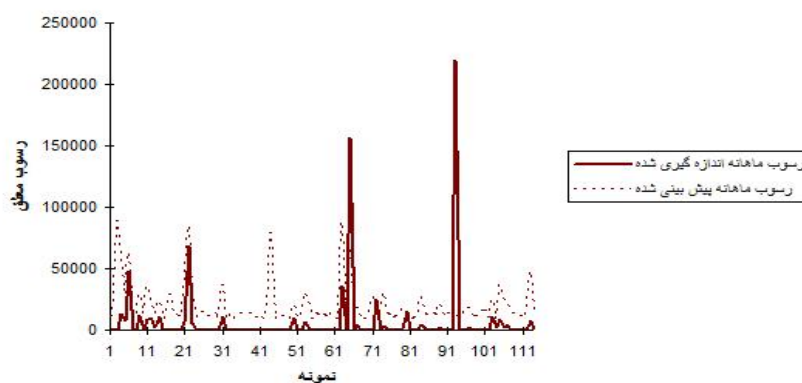
شکل ۶- مقایسه نتایج مدل ARIMA(1,1,2) با داده‌های واقعی



شکل ۷- مقایسه نتایج مدل مارکف با داده‌های واقعی



شکل ۸- مقایسه نتایج مدل تابع تانژانت خطی Jordan/Elman Network با داده‌های واقعی



شکل ۹- مقایسه نتایج مدل تابع تانژانت Modular Neural Network با داده‌های واقعی

آماري میانگین انحرافات^۱ و میانگین انحرافات نرمال شده^۲ استفاده شد. نتایج مقایسه با شاخص‌های مذکور در جدول ۲ آمده است.

همان‌طور که از شکل‌های ۶ تا ۹ پیداست، شبکه‌های عصبی توانایی بهتری در شبیه‌سازی رسوب معلق ماهانه دارند. به‌منظور مقایسه آماری مدل‌های برگزیده شبکه عصبی و مدل آریمای و مارکف، از شاخص

جدول ۲- نتایج مقایسه مدل‌ها با شاخص RMSE و NMSE

نام مدل	Modular Neural Network	Jordan/Elman Network	ARMA(1,1,2)	مارکف
RMSE	۲۸/۹۹**	۳۴/۶۷*	۷۱/۳۴	۷۸/۵۶
NMSE	۱/۱۸**	۱/۷۸*	۲/۴۸	۳/۲

پیش‌بینی رسوب برای ۱۱۱ ماه انجام گرفت. همان‌گونه که از نتایج استنباط می‌شود، مدل‌های آماری سری زمانی در مقایسه با شبکه عصبی توانایی کمتری در برآورد رسوب معلق به‌ویژه در ماه‌های سیلابی دارند و در واقع متوسطی از وضعیت رسوبی ایستگاه مورد نظر ارائه می‌دهند. مرور منابع بیان‌گر این است که محققین قبلی از جمله چن و دایک (۷)، سینگر و دان (۳۲) و ملس و همکاران (۱۹)، در مطالعات خود، از داده‌های رسوب روزانه جهت بررسی سری زمانی استفاده کردند و دلیل

نتایج بیانگر اولویت شبکه‌های عصبی در مدل‌سازی رسوب معلق ماهانه می‌باشد.

در تحقیق حاضر به‌منظور مقایسه و بررسی توانایی مدل‌های سری زمانی شامل مارکف و ARIMA و شبکه‌های عصبی در پیش‌بینی رسوب معلق، از داده‌های روزانه ایستگاه قزاقلی واقع روی رودخانه گرگانرود استفاده شده است. داده‌های موجود به‌صورت متوسط رسوب معلق ماهانه در محیط نرم‌افزار Minitab 16 و Neurosolutions 5 به‌کار گرفته شد و در نهایت

1- RMSE

2- NMSE

ملس و همکاران (۱۹) نیز قبلاً برتری شبکه عصبی به مدل آریمای را در پیش‌بینی رسوب روزانه نشان دادند. افرادی نظیر ابتخارت و وایت (۱)، نگی و همکاران (۲۳)، بیتیان و گو (۳۴)، جین (۱۶)، کیسی (۱۷)، آلپ و سی هی زوگلو (۲)، کوبارنر و همکاران (۱۰)، نورانی و رومیانفر (۲۵)، ساین و پاندا (۳۳) و جعفری میانایی و کشاورز (۱۵) از شبکه عصبی در پیش‌بینی رسوب روزانه استفاده نموده و قابلیت آن را تأیید نموده‌اند. البته این افراد به دو صورت از شبکه عصبی بهره گرفته‌اند، یا با استفاده از پارامترهای فیزیکی و اقلیمی به مدل‌سازی رسوب پرداخته‌اند و یا از داده‌های رسوب روزانه و ساعتی جهت پیش‌بینی سری زمانی رسوب بهره گرفته‌اند. در مطالعات مربوط به رسوب معلق، تاکنون از داده‌های رسوب معلق ماهانه استفاده نشده بود که در این تحقیق از این شکل داده‌ها استفاده گردید. شایان ذکر است که معمولاً در اغلب مطالعات مربوط به جریان و رسوب از مدل شبکه عصبی پرسپترون چند لایه استفاده شده است ولی مطالعه حاضر نشان داد برای رسوب معلق ماهانه، مدل‌های دیگری به غیر از مدل متداول ذکر شده، جوابگو هستند، البته قبلاً معماریان و بالاسوندرام (۲۰) نیز به عدم کارایی شبکه پرسپترون چندلایه در برآورد رسوب در غلظت‌های بالا اشاره نموده‌اند.

دلیل جوابگو بودن مدل‌های سری زمانی در مطالعات آنها کیفیت داده‌های موجود می‌باشد که به صورت فشرده و لحظه‌ای جمع‌آوری گردیده است. با توجه به کمبود امکانات اندازه‌گیری رسوب معلق در ایران و پراکنده بودن داده‌های روزانه جمع‌آوری شده، مناسب‌ترین بازه زمانی مناسب برای کاربرد سری زمانی در رسوب معلق، داده‌های ماهانه می‌باشد. نتایج تحقیق حاضر نشان داد سری زمانی برای پیش‌بینی رسوب در دبی‌های متوسط مناسب است ولی توانایی کافی جهت پیش‌بینی مقادیر رسوب جریان‌های سیلابی را ندارد. شاید دلیل این امر، سیستم نامناسب نمونه‌برداری رسوب معلق در ایران است که بیشتر از دبی‌های متوسط و پایه نمونه‌برداری نموده و نمونه‌های رسوبی کمتری از دبی‌های سیلابی در دسترس می‌باشد. بنابراین می‌توان گفت در شرایط فعلی نمونه‌برداری از رسوب معلق، استفاده از این مدل‌ها قابل توصیه نمی‌باشد. البته در صورتی که به دلیل مزایایی از جمله سادگی و سرعت عملکرد، مدل‌های سری زمانی در اولویت قرار گیرند، بهتر است از مدل مارکف و $ARIMA(1,1,2)$ استفاده شود.

همان‌گونه که از جدول ۲ و نمودارهای ۶ تا ۹، برمی‌آید شبکه عصبی دارای خطای کمتری به ویژه در برآورد رسوب مربوط به دبی ماه‌های سیلابی می‌باشد.

منابع

1. Abrahart, R.J. and S.M. White. 2001. Modeling sediment transfer in Malawi: comparing backpropagation neural network solutions against a multiple linear regression benchmark using small data sets. *Physics and Chemistry of the Earth B*, 26: 19-24.
2. Alp, M. and H.K. Cigizoglu. 2007. Suspended sediment estimation by feed forward back propagation method using hydro meteorological data. *Environmental Modelling and Software*, 22: 2-13.
3. Arabkhedri, M., Sh. Hakimkhani and J. Varvani. 2004. The Validity of extrapolation methods in estimation of annual mean suspended sediment yield (17 Hydrometric Stations), *Journal of Agricultural Science and Natural Resources*, 11:123-131. (In Persian)
4. ArabKhedry, M. and H.R. Abdollahi. 2002. Application of flood hydrograph on estimation of suspended load, *Proceedings of the National Conference of land management, soil erosion and sustainable development*. Arak. pp: 218-205.
5. Asselman, NEM. 2002. Fitting and interpretation of sediment rating curves, *Journal of Hydrology*, 234: 228-248.
6. Barzegari, F. 2004. A Comparison of common methods of estimating Suspended Load (Case study: Ghezeloan Watershed), M.Sc. thesis, Natural Resources Faculty of Tehran University, 120 pp. (In Persian)
7. Chen, H. and P.P.G. Dyke. 1998. Multivariate time series models for concentration of suspended sediment concentration, *Continental Shelf Research*, 18: 123-150.
8. Chen, H., A. Zinober and R. Ruan. 1996. Strong consistency and convergence rate of parameter identification for bilinear systems. *International Journal of Control*, 63: 907-919.
9. Cigizoglu, H.K. and O. Kisi. 2006. Methods to improve the neural network performance in suspended sediment estimation. *Journal of Hydrology*, 317: 221-238.
10. Cobaner, M., B. Unal and O. Kisi. 2009. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydro-meteorological data, *Journal of Hydrology*, 367: 52-61.
11. EPA. 1990. National Water Quality Inventory: 1988 Report to Congress. EPA 40- 4-90-003, Office of Water, U.S. Environmental Protection Agency, Washington, D.C. 248 pp.
12. Ferguson RI. 1986. River load underestimated by rating curves, *Water Resources Research*, 22: 74-76.
13. Hakimkhani, Sh. 1998. Investigation and determination of effective factors on sediment production and yield of drainage basins (Case Study: Oroumia Basin), M.Sc. thesis, Natural Resources Faculty of Tehran University, 212 pp. (In Persian)
14. Horowitz, A.J. 2002. The use of rating curves to predict suspended sediment concentration: A matter of temporal resolution. *Turbidity and other surrogate Workshop*. April 30-May 2, Reno NV. 7 pp.

15. Jafari Myanayy, S. and A.R. Keshavarz. 2008. Comparison of fuzzy and statistical regression methods to estimate sediment load in rivers, Forth National Congress of Civil Engineering, Tehran University, 8 pp.
16. Jain, S.K. 2001. Development of integrated sediment rating curves using ANNs. *Journal of Hydraulic Engineering* 127: 30-37.
17. Kisi, O. 2008. Constructing neural network sediment estimation models using a data-driven algorithm, *Mathematics and Computers in Simulation* 79: 94-103.
18. Lovejoy, S.B., J.G. Lee, T.O. Randhir and B.A. Engel. 1997. Research needs for water quality management in the 21st century: a spatial decision support system. *Journal of Soil and Water Conservation* 52: 18-22.
19. Meless, A.M., S. Ahmad, M.E. McClain, X. Wang and Y.H. Lim. 2011. Suspended sediment load prediction of river systems: an artificial neural network approach. *Agricultural Water Management*, 98: 855-866.
20. Memarian, H. and S.K. Balasundram. 2012. Comparison between Multi-Layer Perceptron and Radial Basis Function Networks for Sediment Load Estimation in a Tropical Watershed, *Earth and Environmental Science*, 4: 870-876.
21. Mosaedi, A., A. Mohammadi Ostadkelayeh, A. Najafi nejad and F. Yaghmaiee. 2006. Optimization of the Relations between Flow Discharge and Suspended Sediment Discharge in Selected Hydrometric Stations of Gorganroud River Iranian *Journal of Natural Resources*, 59: 332-341. (In Persian)
22. Mustafa, M.R., M.H. Isa and R.B. Rezaur. 2011. A Comparison of Artificial Neural Networks for Prediction of Suspended Sediment Discharge in River, A Case Study in Malaysia. *World Academy of Sci., Eng. and Technol. (WASET)*. 81: 372-376
23. Nagy, H.M., K. Watanabe and M. Hirano. 2002. Prediction of sediment load concentration in rivers using artificial neural network model. *Journal of Hydraulic Engineering* 128: 588-595.
24. Niroumand, H.A. and A.Gh. Bozorgnia. 2010. *Introduction to Time Series Analysis*, Publications of Ferdousi University, 290 pp. (In Persian)
25. Nourani, V. and S. Romyanfar. 2010. Using Hybrid ARIMA-ANN models on the modeling of the rainfall-runoff-precipitation in Aharchay catchment, 5th National Congress of Civil Engineering, Ferdowsi University, pp: 1-8.
26. Nourani, V., O. Kalantari and A. Baghanam. 2012. Two Semi distributed ANN-Based Models for Estimation of Suspended Sediment Load, *Journal of Hydrologic Engineering*, 17: 1368-1380.
27. Raghuwanshi, N.S., R. Singh and L.S. Reddy. 2006. Runoff and sediment yield modeling using artificial neural networks: Upper Siwane River, India. *J. Hydraul. Eng. ASCE*. 11: 71-79.
28. Rajaei, T., V. Nourani, M. Zounemat-Kermani and O. Kisi. 2011. River Suspended Sediment Load Prediction: Application of ANN and Wavelet Conjunction Model. *Journal of Hydrologic Engineering*, 16: 613-627.
29. Razavizadeh, S., A. Kavian and M. Vafakhah. 2014. Estimation of Suspended Sediment Discharge by Optimal Structure of Artificial Neural Network in Taleghan Watershed *Journal of Science and Technology of Agriculture and Natural Resources, Water and Soil Science*. 18: 79-88.
30. Rezapour, O.M., T.L. Shui and D.B. Ahmad. 2010. Review of Artificial Neural Network Model for Suspended Sediment Estimation, *Australian Journal of Basic and Applied Sciences*, 4: 3347-3353.
31. Robert, B.T. 1985. Estimating total suspended sediment yield with probability sampling, *Water Resources Research*, 21: 1381-1388.
32. Singer, M.B. and T. Dunne. 2001. Identifying eroding and depositional reaches of valley by analysis of suspended sediment transport in the Sacramento River, California. *Water Resources Research*, 37: 3371-3382.
33. Singh, G. and R.K. Panda. 2011. Daily Sediment Yield Modeling with Artificial Neural Network Using 10-Fold cross Validation Method: A Small Agricultural Watershed, Kapgari, India, *International Journal of Earth Sciences and Engineering*, 4: 443-450.
34. Yitian, L. and R.R. Gu. 2003. Modeling flow and sediment transport in a river system using an artificial neural network. *Environmental Management*, 31: 122-134.
35. Zoratipoor, A. 2006. A Comparison of Hydrological (Statistical) methods for estimating Suspended Load (Case Study: Taleghan Watershed), M.Sc. thesis, Natural Resources Faculty of Tehran University, 150 pp. (In Persian)

Suspended Sediment Prediction using Time Series and Artificial Neural Networks Models (Case Study: Ghazaghly Station in Gorganroud River)

Fariba Barzegari¹ and Mohammad Taghi Dastorani²

1- Academic member, Agricultural Department, Payam Noor University
(Corresponding author: fa_barzegar@yahoo.com)

2- Associate Professor, Ferdowsi University of Mashhad

Received: April 28, 2013

Accepted: December 3, 2013

Abstract

Accurate estimation of suspended sediment in rivers is very important from different aspects including agriculture, soil conservation, shipping, dam construction and aquatic research. There are different methods for suspended sediment estimation. In the present study to evaluate the ability of time-series models including Markov and ARIMA in predicting suspended sediment and to compare their results to Artificial Neural Networks it was tried to use daily suspended data from Ghazaghly station of Gorganroud River, as average monthly values in Minitab 16 software and Neurosolutions 5, and finally suspended sediment was predicted for 111 months. Calculation of the error measurement indices including RMSE and NMSE based on the results of this study showed a good ability of Artificial Neural Network models in estimating average monthly suspended sediment. On the other hand between time series models, Markov model has better ability in estimating monthly suspended sediment in comparison to the ARIMA model.

Keywords: ARIMA, Suspended sediment, Ghazaghly, Markov, Modeling