

کاربرد سامانه های هوشمند و روش های آماری در تخمین توزیع غلظت رسوبات معلق

صالح ریاحی^{*}، محسن نصرآبادی^۲ و سید محمد موسوی^۳

تاریخ دریافت: ۹۲/۰۶/۲۴ تاریخ پذیرش: ۹۲/۰۹/۱۶

^۱- دانشجوی دکتری سازه های آبی، دانشگاه تربیت مدرس

^۲- دانشجوی دکتری سازه های آبی، دانشگاه تهران

^۳- دانش آموز خانه کارشناسی ارشد سازه های آبی، دانشگاه تهران

* مسئول مکاتبات، پست الکترونیکی: Saleh.riahi@ut.ac.ir

چکیده

آگاهی از توزیع عمقی رسوبات معلق در کانال ها و آبراهه های طبیعی در تخمین بار رسوبی جریان اهمیت بسیار زیادی دارد. هزینه های زیاد و زمان بر بودن عملیات نمونه برداری از رو دخانه ها و همچنین خطای قابل توجه روش ها و تجهیزات مختلف نمونه برداری، مهندسان و محققان را به سوی مدل های شبیه سازی و استفاده از روش های نوین آماری سوق داده است. در این مطالعه، برای تخمین توزیع غلظت رسوبات معلق از سه روش شبکه های عصبی مصنوعی (ANN)، سیستم استنتاج فازی - عصبی (ANFIS) و رگرسیون خطی چند متغیره استفاده شد. برای بررسی دقت و صحت هر روش، معتبرترین داده های آزمایشگاهی موجود مورد استفاده قرار گرفت. پس از ارزیابی عملکرد سه روش یاد شده، مشخص شد که روش شبکه عصبی مصنوعی با ضریب همبستگی ۰/۹۹ و RMSE برابر با ۰/۰۴۲ نسبت به روش های دیگر برتری نسبی داشته و به خوبی قادر به برآوردن توزیع غلظت رسوبات است. پس از این روش، دقت سیستم استنتاج فازی - عصبی با ضریب همبستگی ۰/۹۴ و RMSE برابر با ۰/۰۴۲ در مرتبه دوم قرار گرفت. با استفاده از رهیافت رگرسیون چند متغیره کارایی کمتری نسبت به دو مدل دیگر دارد. با مقایسه این مدل ها با روابط تجربی ارائه شده، مانند معادله راووس و معادله اینشتین و شن، مشخص شد که روش های آماری توزیع غلظت رسوبات معلق را با دقت بیشتری نسبت به معادلات تجربی برآورد می کنند.

واژه های کلیدی: توزیع غلظت رسوبات معلق، سیستم استنتاج فازی - عصبی، شبکه های عصبی مصنوعی، معادله راووس ، مدل رگرسیون خطی چند متغیره

Application of the Intelligent Systems and Statistical Models in Estimation of Suspended Sediment Distribution

S Riahi^{1*}, M Nasrabadi² and SM Mosavi³

Received: 15 September 2013 Accepted: 7 December 2013

¹Ph.D. Student of Water Structures, Tarbiat Modares Univ., Tehran, Iran

²Ph.D. Student of Water Structures, Dept. of Irrigation and Reclamation Engin., Univ. of Tehran, Karaj, Iran

³Former M.Sc. Student of Water Structures, Dept. of Irrigation and Reclamation Engin., Univ. of Tehran, Karaj, Iran

* Corresponding Author Email: Saleh.riahi@yahoo.com

Abstract

Understanding the vertical distribution of suspended sediment in channels and natural waterways is very important in estimation of the suspended load. High costs, time-consuming of the sampling operations from rivers, and remarkable error associated with equipment and sampling methods, have led engineers and researchers to perform the simulation models and the new statistical methods. In this study, three methods namely artificial neural networks (ANN), adaptive neuro-fuzzy inference system (ANFIS), and multivariate linear regression were used to estimate the distribution of suspended sediment concentration. The accuracy of each method was assessed using the most reliable experimental data. After evaluating the performance of the three aforesaid methods, it was found that the ANN method with the values of 0.999 and 0.042 for r and RMSE, respectively, had a relative advantage as compared with the other methods. This method precisely estimated the distribution of sediment concentration. Also the adaptive neuro-fuzzy inference system accuracy, with the values of 0.994 and 0.042 for r and RMSE, respectively, ranked in the second position. Two equations were proposed for the currents on the smooth and rough beds, using the multivariate regression approach. The results showed that the multivariate regression model had less efficiency than the two aforementioned models. By comparing these models with existing empirical equations such as Rouse's equation and the equation of Einstein and Chien, it was revealed that statistical methods had estimated the distribution of sediment concentration more accurately than empirical equations.

Keywords: ANFIS, Artificial Neural Network (ANN), Multivariate regression model, Rouse's equation, Suspended sediment distribution

ثابت‌های عددی هستند و از داده‌های آزمایشگاهی بدست می‌آیند). محققین بسیاری از جمله تاناکا و سوگیموتو (۱۹۵۸)، چانگ و همکاران (۱۹۶۵)، ویلیس (۱۹۷۹)، ایتاکورا و کیشی (۱۹۸۰)، مک‌تیگو (۱۹۸۱) و گری (۲۰۰۸) به بررسی توزیع غلظت رسوبات معلق در کanalها پرداختند و معادلاتی را برای این توزیع ارائه نمودند. نصرآبادی و همکاران (۱۳۹۲) با بررسی و ارزیابی کلیه روابط تجربی موجود برای برآورد توزیع غلظت رسوبات معلق، به این نتیجه رسیدند که معادله اینشتین و شن (۱۹۵۵) بهترین تطابق را با داده‌های آزمایشگاهی داشته است.

در کتاب روش‌های نیمه تجربی انتقال رسوب، استفاده از سامانه‌های هوشمند نیز کاربرد زیادی در برآورد بار رسوبی دارد. از جمله تحقیقات انجام شده می‌توان به موارد زیر اشاره نمود (بازیزدی و همکاران ۱۳۸۴، فیض‌نیا و همکاران ۱۳۸۸، رجایی و همکاران ۱۳۸۸، داننده‌مهر و همکاران ۱۳۸۹، طلوی و همکاران ۱۳۹۰ و فلامکی و همکاران ۱۳۹۲).

آوریده و همکاران (۱۳۸۰) بار رسوبی رودخانه را با استفاده از شبکه عصبی برآورد کردند و بیان کردند که این روش می‌تواند جایگزین مناسبی برای مدل‌های متدالو رگرسیونی باشد. طباطبائی و همکاران (۱۳۹۲) در تحقیقی به مطالعه عملکرد مدل شبکه عصبی مصنوعی در برآورد غلظت رسوب معلق رودخانه ای در رودخانه کارون پرداختند. سقیزاوقلو و کیشی (۲۰۰۶) در تحقیق خود از روش شبکه عصبی مصنوعی برای پیش‌بینی بار رسوب استفاده کردند و دقت برخی پارامترها را در بهینه کار شبکه عصبی بررسی نمودند. آلب و سقیزاوقلو (۲۰۰۷) با بیان این نکته که طبیعت غیر خطی بار معلق نیازمند استفاده از روش‌های غیرخطی برای تخمین بار معلق است، برای نیل به هدف خود از دو نوع شبکه عصبی استفاده کرد و با یک رگرسیون خطی چندگانه بررسی کردند و به این نتیجه رسیدند که شبکه عصبی شبیه‌سازی بسیار واقعی‌تری نسبت به رگرسیون چند متغیره انجام می‌دهد.

به دلیل پیچیدگی و مشکلات ناشی از جمع‌آوری داده‌ها برای استفاده از روابط موجود، به ابزاری که

مقدمه

در برآورد بار رسوبی جریان، آگاهی از توزیع عمیق رسوبات معلق در کanalها و آبراهه‌های طبیعی از اهمیت بسیار زیادی برخوردار است. از طرفی به دلیل اینکه تقریباً ۸۰ درصد از کل بار رسوبی آبراهه را رسوبات معلق تشکیل می‌دهد، پس می‌توان با محاسبه دبی بار معلق به میزان دبی کل رسوبات دست پیدا نمود. برای محاسبه میزان نرخ انتقال رسوبات معلق در کanalها به نحوه توزیع غلظت رسوبات معلق است. اولین رابطه تئوری توزیع غلظت رسوبات معلق توسط راووس (۱۹۳۷) ارائه شد. راووس (۱۹۳۷) با استفاده از معادله پخش ویلیام اشمیت برای جریان‌های دو بعدی یکنواخت و ماندگار رابطه زیر را ارائه کرد:

$$\frac{C}{C_a} = \left(\frac{D-y}{y} \frac{a}{D-a} \right)^z \quad [1]$$

که در آن، D عمق جریان، C_a غلظت رسوبات معلق در ارتفاع مرجع $y=a$ و z عدد تعیق یا عدد راووس نام دارد و به صورت زیر تعیین می‌شود:

$$z = \frac{W_s}{\beta \kappa U_*} \quad [2]$$

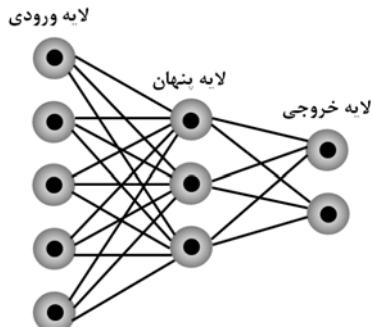
در این رابطه U_* سرعت برشی جریان، κ سرعت سقوط ذرات رسوب، β ضریب ون کارمن است و مساوی با $0.4/4$ در نظر گرفته می‌شود و β ضریبی است که برابر ۱ در نظر گرفته می‌شود.

اینشتین و شن (۱۹۵۵) با انجام اصلاحاتی از لحاظ تئوری، شامل تغییراتی در مفاهیم و جزئیات فرآیند تبادل تلاطم جریان برای معادله راووس، رابطه خود را به صورت زیر پیشنهاد کردند:

$$\frac{C}{C_a} = \left(\frac{1 - \sqrt{\frac{D-a}{D}}}{1 - \sqrt{\frac{D-y}{D}}} \right)^{\frac{z_1}{1+Nkz_1}} \left(\frac{1 + \sqrt{\frac{D-a}{D}}}{1 + \sqrt{\frac{D-y}{D}}} \right)^{\frac{z_1}{1-Nkz_1}} \times \left(\frac{\sqrt{\frac{D-a}{D}} + Nkz_1}{\sqrt{\frac{D-y}{D}} + Nkz_1} \right)^{\frac{2z_1}{N^2 k^2 z_1^2 - 1}} \quad [3]$$

در این رابطه، $(z_1 = \omega_s/(kU_*)$ عدد راووس (عدد تعیق) با فرض $\beta = 1$ و $N = B_1(0.5 - A_1)$ است (A_1 و B_1

می‌کند) و لایه خروجی (نتایج را به ازای ورودی‌های مشخص استخراج می‌کند). شبکه‌های عصبی می‌توانند از یک یا چند لایه پنهان تشکیل شوند. طراحی معماری شبکه به طور معمول بر اساس سعی و خطا است. در لایه ورودی باید به تعداد ابعاد هر الگوی ورودی، نرون قرار داده شود. بنابراین اندازه لایه ورودی را بعد از این داده‌های ورودی تعیین می‌کند. در مورد تعداد نرون‌های لایه میانی، مبنای خاصی وجود ندارد و معمولاً با سعی و خطا به نحوی انتخاب می‌شود که شبکه جواب معقولی ارائه دهد.



شکل ۱- ساختار شبکه عصبی پرسپترون چندلایه.

سیستم استنتاج عصبی-فازی

این مدل از ترکیب دو ساختار شبکه‌های عصبی و سیستم‌های فازی تشکیل شده است که در این ساختار، هم از مزایای شبکه‌های عصبی و هم سیستم‌های فازی بهره‌گیری شده است. به این معنی که از خصوصیت آموزش‌پذیری شبکه‌های عصبی و همچنین از ویژگی توانایی مدل‌سازی استنتاج سیستم‌های فازی که باعث افزایش قدرت تصمیم‌گیری در شرایط عدم قطعیت و افزایش دقت می‌شود، در ساختار شبکه عصبی فازی استفاده شده است. در منطق فازی روند سینماتیک برای طراحی یک کنترل‌کننده فازی وجود ندارد. به عبارت دیگر، یک شبکه عصبی این توانایی را دارد که از محیط آموزش ببیند (جفت‌های ورودی-خروجی)، ساختارش را خود مرتب کند و با شیوه‌ای، تعامل خود را تطبیق دهد. به این منظور جنگ (1993) مدل ANFIS را ارائه کرد، که قابلیت ترکیب توانایی دو روش یاد شده را داشت. ساختار ANFIS شامل ۵ لایه با تعدادی متغیر ورودی است که هر ورودی دو یا چند تابع عضویت دارد. در لایه

قابلیت یادگیری و درک تابع حاکم را داشته و در عین حال قابلیت انعطاف‌پذیری خطاهای را نیز داشته باشد، احتیاج است. روش‌های شبکه عصبی مصنوعی و مجموعه‌های فازی-عصبی از جمله روش‌های نوین هستند و مزیت این تکنیک‌ها نسبت به روش‌های رایج این است که در مدت زمان کوتاهی و بدون نیاز به یافتن رابطه پیچیده ریاضی، قادر به بررسی انواع پارامترهای در دسترس بر فرآیند مورد بررسی هستند. با توجه به توانایی مدل‌های هوش مصنوعی در شناسایی ارتباط بین متغیرهای ورودی و خروجی یک مسئله بدون در نظر گرفتن فیزیک مسئله، از این شبکه‌ها برای مدل‌سازی توزیع غلظت بار معلق استفاده شده است. از آنجاکه بخش عمده تحقیقات انجام شده در خصوص توزیع غلظت رسوبات معلق بصورت تحلیلی-تجربی بوده است، در تحقیق حاضر با هدف استفاده از شبکه عصبی مصنوعی، منطق فازی و روابط رگرسیونی به برآورد توزیع غلظت بار معلق پرداخته شده است.

مواد و روش‌ها

شبکه عصبی مصنوعی

شبکه عصبی در واقع یک مدل ریاضی است که توانایی نشان دادن فرایندها و ترکیبات دلخواه غیرخطی جهت ارتباط بین ورودی‌ها و خروجی‌های هر سیستم را دارد. این شبکه با داده‌های موجود طی فرآیند یادگیری، آموزش دیده و جهت پیش‌بینی در آینده استفاده می‌شود. در این تحقیق برای مدل‌سازی شبکه عصبی مصنوعی، از کدنویسی در نرم‌افزار متلب استفاده شده است. متداوول‌ترین روش شبکه عصبی مصنوعی در پیش‌بینی و حل مسائل غیرخطی به خصوص در علوم آب، شبکه‌های موسوم به پرسپترون چند لایه (MLP) است (دهقانی و همکاران ۱۳۸۹). آموزش در این شبکه‌ها با استفاده از الگوریتم پس انتشار خطا صورت می‌گیرد. شکل ۱ ساختار شبکه عصبی را نشان می‌دهد. معماری معمول شبکه عصبی متشکل از سه لایه است، لایه ورودی (داده‌ها را در شبکه توزیع می‌کند)، لایه پنهان (داده‌ها را پردازش

پارامترهایی مانند قطر، غلظت و جرم مخصوص را پوشش می‌دهند، همچنین محققین در اکثر مطالعات برای صحت‌سنجی روابط خود از این داده‌های آزمایشگاهی استفاده نموده‌اند. در جدول ۱ خلاصه داده‌ها و شرایط آزمایش‌های هر یک از محققان نشان داده شده است. آزمایش‌های ونونی (۱۹۴۶) در یک فلوم مستطیلی با عرض ۸۴/۵ سانتی‌متر، بسترهای زیر و شبیث ثابت ۰۰۰۲۵ میلی‌متر انجام شده با سه قطر ذره ۰/۱۳، ۰/۱۶ و ۰/۱۷ میلی‌متر انجام شده است. آزمایش‌های اینشتین و شن (۱۹۵۵) در یک فلوم مستطیلی با عرض ۳۰/۷ سانتی‌متر، بسترهای صاف و شبیث ۰۰۰۱۸۵ تا ۰۰۰۲۵ میلی‌متر انجام شده است. در واقع دلیل استفاده از داده‌های آزمایشگاهی مختلف، واسنجی معادلات با تغییر شرایط آزمایشگاهی مختلف از قبیل تغییر در قطر متواسط و وزن مخصوص رسوبات، شرایط بسترهای کanal، عرض و عمق جریان و همچنین محدوده غلظت رسوبات است. در مجموع تعداد ۲۰۴ مجموعه آزمایش مورد بررسی و مدل‌سازی قرار گرفت.

روش ارزیابی مدل‌ها

برای ارزیابی مدل‌های ارائه شده در این تحقیق از مهم‌ترین شاخص‌های آماری مانند ضریب همبستگی، ریشه میانگین مربعات خطأ^۳ و میانگین مطلق خطأ^۴ به شرح زیر استفاده شده است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad [4]$$

$$MAE = \frac{\sum |P_i - O_i|}{n} \quad [5]$$

در این روابط، P_i مقادیر برآورده شده، O_i مقادیر مشاهداتی و n تعداد نمونه‌های برداشت شده است. مقدار RMSE همواره مثبت بوده و بیشترین مقدار ضریب همبستگی و کمترین مقدار RMSE و MAE بهترین مدل را نشان می‌دهد.

اول (ورودی) میزان تعلق هر ورودی به بازه‌های مختلف فازی توسط کاربر مشخص می‌شود. با ضرب مقادیر ورودی به هر گره در یکدیگر، وزن قانون‌ها در لایه دوم به دست می‌آید. در لایه سوم عمل محاسبه وزن نسبی قوانین انجام می‌شود. لایه چهارم، لایه قوانین است که از انجام عملیات بر روی سیگنال‌های ورودی به این لایه حاصل می‌شود. لایه آخر، لایه خروجی شبکه است که هدف آن کمینه‌سازی اختلاف خروجی به دست آمده از شبکه و خروجی واقعی است.

در ANFIS قوانین ثابت هستند و آنچه بهینه‌سازی می‌شود پارامترهای توابع عضویت بوده که برای تعیین پارامترهای توابع عضویت (یا همان شکل توابع عضویت) از الگوریتم‌های آموزشی شبکه عصبی بهره‌گیری می‌شود. نوع توابع عضویت شامل توابع مختلفی از جمله مثلثی و گوسی بوده و شمار توابع عضویت برای ورودی‌ها و خروجی‌ها به روش سعی و خطای تابع می‌شود. در ANFIS لازم است که در لایه اول نوع تابع عضویت و شمار آن‌ها را مشخص شود. ساختار مناسب ANFIS متناسب با داده‌های ورودی، نوع تابع عضویت ورودی و خروجی، قوانین و تعداد تابع عضویت انتخاب می‌شود. برای افزایش قواعد فازی، دو روش زیرخوشه‌بندی^۱ و منقطع‌سازی شبکه‌ای^۲ وجود دارد (چانگ و چانگ ۲۰۰۵)، که در این مطالعه روش زیرخوشه‌بندی مورد استفاده قرار گرفت. برای انجام این قسمت از مطالعه از محیط ANFISEDIT در نرم‌افزار متلب استفاده شد و تحلیل حساسیت روی توابع عضویت ورودی و خروجی و تعداد توابع عضویت در نظر گرفته شده برای داده‌های ورودی انجام شد. روش انتخاب شده برای یادگیری، الگوریتم هیبرید بود.

داده‌های آزمایشگاهی مورد استفاده

در این مطالعه، به منظور ارزیابی کارایی مدل‌ها، از داده‌های آزمایشگاهی مربوط به مطالعات ونونی (۱۹۴۶) و اینشتین و شن (۱۹۵۵) استفاده شده است. این داده‌های آزمایشگاهی به عنوان معتبرترین داده‌های آزمایشگاهی شناخته شده و محدوده وسیعی از

³ RMSE

⁴ MAE

¹ Sub Clustering

² Grid Partitioning

گونه‌ای تعیین شوند که تعداد کمی از الگوهای ورودی بتواند ویژگی‌های منحصر به فرد موجود در داده‌ها را تعیین کنند. در این تحقیق، با توجه به پارامترهای بدست آمده از آزمایش‌های موجود، الگوهای مختلفی برای تعیین مؤثرترین ورودی‌های شبکه بررسی شد (جدول ۲). در این مدل‌ها، K_s , S , b و d_{50} به ترتیب نشان دهنده شبیب کanal، زبری رسوبات بستر، عرض کanal، قطر معادل ذرات رسوب می‌باشد.

نتایج و بحث برآورد توزیع بار معلق با استفاده از شبکه عصبی مصنوعی

گزینه‌های مختلفی برای بدست آوردن بهترین معماری شبکه عصبی ایجاد و تحت آموزش و آزمایش قرار گرفتند. در روش شبکه‌های عصبی مصنوعی باید ساختار بهینه شبکه تعیین شود. ساختار شبکه شامل نوع ورودی‌ها و خروجی‌ها، تعداد لایه‌های مخفی و شمار نرون‌ها در هر لایه مخفی، نوع تابع فعال‌سازی و نوع الگوریتم آموزشی است. پارامترهای ورودی باید به

جدول ۱- خلاصه داده‌ها و شرایط آزمایش‌ها.

نوع بستر	C_a (gr/lit)	d_{50} (mm)	U^* (cm/s)	D(cm)	شماره آزمایش	منبع
زبر	۴/۷۸	۰/۱	۴/۱۵	۱۴	Run-18	ونوئی (۱۹۴۶)
	۱/۲۹	۰/۱	۲/۹۷	۷/۲	Run-19	
	۴/۲۷	۰/۱	۵/۸۸	۲۰	Run-20	
	۳/۴۲	۰/۱	۴/۱۵	۷/۲	Run-21	
	۶/۷۵	۰/۱	۴/۶۹	۹	Run-22	
	۴۴/۴۴	۱/۳	۱۱/۴۸	۱۳/۷۸	S-1	
	۱۶۴/۷۴	۱/۳	۱۲/۸۵	۱۱/۹۵	S-2	
	۲۱۸/۵۲	۱/۳	۱۳/۲۷	۱۱/۶۴	S-3	
	۳۷۳/۰۳	۱/۳	۱۴/۲۸	۱۱/۵۲	S-4	
	۵۸۵/۸۴	۱/۳	۱۴/۵	۱۰/۹۷	S-5	
	۲۱/۵۳	۰/۹۴	۱۱/۸۲	۱۴/۳	S-6	
	۴۸/۴۲	۰/۹۴	۱۱/۷۳	۱۴/۲۳	S-7	
	۵۶/۱۹	۰/۹۴	۱۱/۵۴	۱۳/۷۸	S-8	اینشتن و شن (۱۹۵۵)
	۱۰۹/۴۹	۰/۹۴	۱۱/۸۶	۱۳/۵۳	S-9	
	۱۸۳/۳۷	۰/۹۴	۱۲/۶	۱۳/۰۱	S-10	
صف	۲۱	۰/۲۷۴	۱۰/۵۸	۱۳/۲۶	S-11	
صف	۱۴۰	۰/۲۷۴	۱۰/۰۵	۱۳/۲	S-12	
صف	۲۲۵	۰/۲۷۴	۱۰/۴۳	۱۳/۴۱	S-13	
صف	۲۹۵	۰/۲۷۴	۱۲/۱۷	۱۲/۳۱	S-14	
صف	۵۱۰	۰/۲۷۴	۱۲	۱۲/۴۴	S-15	
صف	۵۲۰	۰/۲۷۴	۱۲/۴۵	۱۱/۸۹	S-16	

در مدل ANN_1 ، β ضریبی است که به گفته بیشتر محققان برابر ۱ در نظر گرفته می‌شود و κ ضریب ون کارمن که برابر 0.4 در نظر گرفته شده است. با بررسی معماری‌های مختلف، در نهایت مدل پرسپترون چند لایه یا به اختصار MLP با روش پس انتشار خطای (که قابلیت بالایی جهت تخمین هر تابع غیرخطی دارد)،

جدول ۲- مدل‌های شبکه عصبی با پارامترهای ورودی متفاوت.

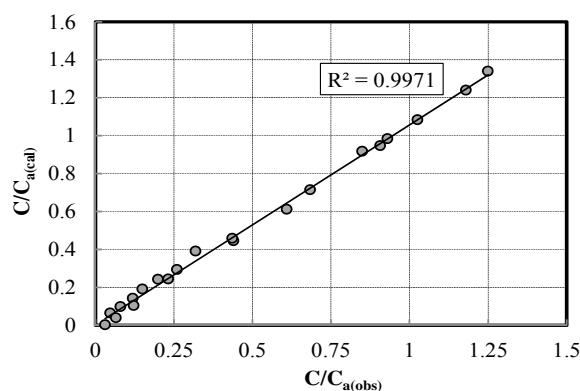
نام مدل	پارامترهای ورودی
ANN_1	$\kappa, \beta, k_s, b, S, d_{50}, y/D$
ANN_2	$k_s, b, S, d_{50}, y/D$
ANN_3	$S, d_{50}, y/D$

نیز ۶ نرون استفاده شد. جدول ۳ نتایج بررسی تعداد نرون‌ها و تعداد لایه‌های پنهان برای مجموعه داده آزمایشگاهی را نشان می‌دهد. در شکل ۲ مقادیر $C/C_{a(cal)}$ پیش‌بینی شده توسط شبکه عصبی مصنوعی (ANN₁) که برای در مقابل داده‌های مشاهده شده $C/C_{a(obs)}$ که برای آزمون مدل استفاده شده‌اند، ترسیم شده است. همچنین در شکل ۳ مقادیر اندازه‌گیری شده در مقابل مقادیر محاسبه شده توسط هر یک از مدل‌های شبکه عصبی ترسیم شده است.

تابع انتقال تانژانت زیگموئید (tansig) برای لایه مخفی و تابع انتقال خطی (pureline) برای لایه خروجی به عنوان بهترین معماری شبکه در این پیش‌بینی معرفی شد. همچنین از ۷۰ درصد داده‌ها برای آموزش مدل، از ۱۵ درصد داده‌ها برای صحبت‌سنگی و از ۱۵ درصد دیگر برای آزمون استفاده شد. تعداد لایه‌های مخفی و تعداد نرون‌های هر لایه به صورت سعی و خطأ برای سه مدل شبکه عصبی بدست آمد. برای هر سه مدل از ۱ لایه مخفی و برای ANN₁ ۶ نرون، ANN₂ ۷ نرون و ANN₃ ۱۱ نرون است.

جدول ۳- نتایج تعیین مقادیر بھینه برای تعداد لایه‌های پنهان و تعداد نرون‌ها در مدل ANN₁

ANN ₁						تعداد نرون	تعداد لایه پنهان
اینشتین (۱۹۵۵)			ونوی (۱۹۴۶)				
ضریب همبستگی	MAE	RMSE	ضریب همبستگی	MAE	RMSE		
-۰/۹۰۲	۰/۰۹۱	۰/۰۷۱	۰/۸۸	۰/۱۰۱	۰/۰۷۷	۲	
۰/۹۱۰	۰/۰۶۶	۰/۰۵۵	۰/۹۳	۰/۰۷۴	۰/۰۵۶	۳	
۰/۹۷۲	۰/۰۴۴	۰/۰۶	۰/۹۹	۰/۰۵۵	۰/۰۶۴	۵	۱
۰/۹۹۹	۰/۰۳۲	۰/۰۳۶	۰/۹۹۹	۰/۰۳۸	۰/۰۴۲	۶	
۰/۹۹۳	۰/۰۳۱	۰/۰۴۸	۰/۹۸	۰/۰۳۷	۰/۰۵۱	۷	
۰/۸۶۴	۰/۰۹	۰/۰۸	۰/۸۹	۰/۱۱۲	۰/۰۹۲	۲	
۰/۹۳۰	۰/۰۶۵	۰/۰۶۶	۰/۹۵	۰/۰۸۸	۰/۰۷۱	۳	
۰/۹۷۱	۰/۰۴	۰/۰۷۲	۰/۹۷	۰/۰۵	۰/۰۶۶	۵	۲
۰/۹۹۱	۰/۰۴۱	۰/۰۳۵	۰/۹۸	۰/۰۴۲	۰/۰۴۳	۶	
۰/۹۰۲	۰/۰۴۲	۰/۰۴	۰/۹۸	۰/۰۴۴	۰/۰۴۱	۷	
۰/۸۰۱	۰/۱۰۹	۰/۱۱	۰/۸۳	۰/۱۵۵	۰/۱۲۱	۲	
۰/۸۸۲	۰/۰۸۸	۰/۰۸۲	۰/۸۷	۰/۰۹	۰/۰۹۹	۳	
۰/۹۲۳	۰/۰۶	۰/۰۷۷	۰/۹۸۲	۰/۰۸۶	۰/۰۷	۵	۳
۰/۹۴	۰/۰۶۷	۰/۰۵۹	۰/۹۸۵	۰/۰۶۲	۰/۰۸۸	۶	
۰/۹۵	۰/۰۴۹	۰/۰۶	۰/۹۸	۰/۰۵۵	۰/۰۸	۷	

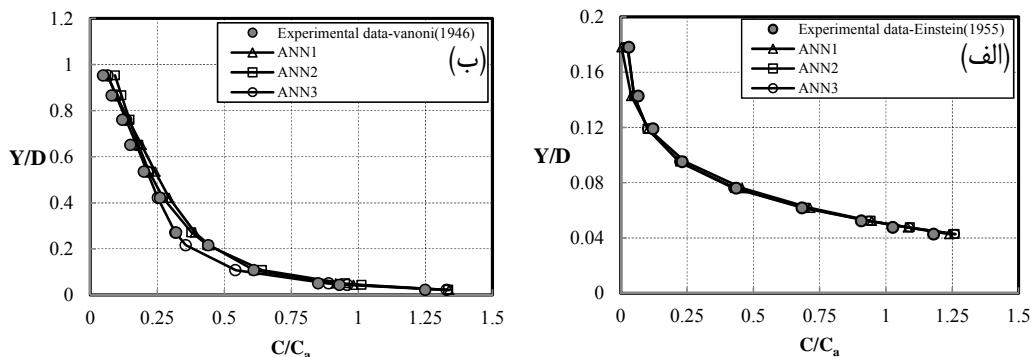


شکل ۲- ارتباط بین مقادیر مشاهده‌ای و پیش‌بینی شده غلظت رسوبات به وسیله شبکه عصبی مصنوعی.

نتایج نشان داد که با افزایش تعداد توابع عضویت، مدل دچار بیش برآژش شده و از کارایی آن کاسته می‌شود. نتایج مقایسه و تحلیل حساسیت بین توابع گوناگون مدل در جدول ۴ آمده است. در نهایت از بین توابع، تابع گوسی (gaussmf) به عنوان مناسب‌ترین تابع عضویت انتخاب شد. در شکل ۴ مقادیر محاسبه شده به وسیله روش منطق فازی- عصبی در مقابل داده‌های آزمایشگاهی رسم شده است.

تخمین توزیع بار معلق با استفاده از سیستم استنتاج فازی- عصبی

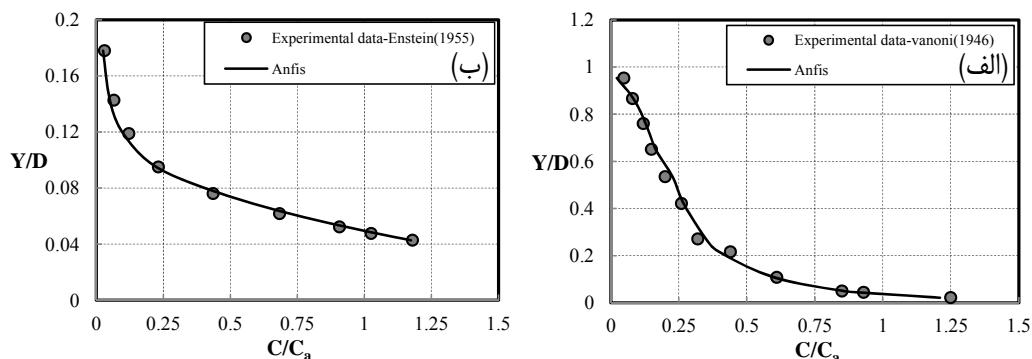
در این روش متغیرها به صورت فازی وارد شبکه می‌شوند. فازی کردن متغیرهای ورودی با تعریف توابع عضویت مختلف مانند تابع عضویت گوسی، زنگوله‌ای، ذوزنقه‌ای، مثلثی و ... انجام می‌شود. در این پژوهش نوع و تعداد توابع عضویت مختلف ارزیابی شد و با تحلیل حساسیت، از بین آن‌ها بهترین تابع عضویت که با مساله تطابق مناسبی داشته باشد، انتخاب شد.



شکل ۳- توزیع غلظت اندازه‌گیری شده و محاسبه شده به روش مدل‌های شبکه عصبی در مقابل داده‌های آزمایشگاهی:
الف) اینشتین و شن (۱۹۵۵) و (ب) ونونی (۱۹۴۶).

جدول ۴- نتایج سیستم استنتاجی فازی- عصبی با به کارگیری توابع عضویت مختلف.

داده‌های آزمون	داده‌های آموزش	ضریب همیستگی	RMSE		نوع تابع عضویت
			داده‌های آزمون	داده‌های آموزش	
۰/۸۸۶	۰/۹۳۰		۰/۱۷۷	۰/۱۰۱	مثلثی (trimf)
۰/۹۱۱	۰/۸۴۹		۰/۱۶۸	۰/۱۴۷	ذوزنقه‌ای (trapmf)
۰/۹۱۱	۰/۹۷۳		۰/۱۴۳	۰/۰۶۱	گوسی (gaussmf)
۰/۹۱۸	۰/۹۶۸		۰/۱۵۲	۰/۰۶۷	گوسی (gauss2mf)
۰/۸۹۳	۰/۹۶۰		۰/۱۶۰	۰/۰۷۴	زنگوله‌ای (gbellmf)
۰/۸۹۹	۰/۸۴۱		۰/۱۷۳	۰/۱۵۱	تابع Π (pimf)
۰/۱۷۷	۰/۱۰۲		۰/۸۸۱	۰/۹۳۱	تابع سیگموئید (psigmf)



شکل ۴- توزیع غلظت اندازه‌گیری شده و محاسبه شده به روش منطق فازی- عصبی در مقابل داده‌های آزمایشگاهی: (الف) ونونی (۱۹۴۶) و (ب) اینشتین و شن (۱۹۵۵).

جدول ۵- مدل‌های رگرسیونی توسعه داده شده.

مدل	ضریب همبستگی	رابطه
بستر صاف	.۹۹۲	$\frac{C}{C_a} = \left(\frac{U^*}{W_s}\right)^{1.504} \left(\frac{y}{D}\right)^{-1.18} \left(\frac{y}{a}\right)^{-0.804} \left(\frac{d_{50}}{D}\right)^{0.82}$
بستر زبر	.۹۶۹	$\frac{C}{C_a} = \left(\frac{U^*}{W_s}\right)^{1.82} \left(\frac{y}{D}\right)^{-0.826} \left(\frac{y}{a}\right)^{0.033} \left(\frac{d_{50}}{D}\right)^{0.433} \left(\frac{k_s}{d_{50}}\right)^{-1.039}$

عصبی و سیستم استنتاج فازی، با توجه به سرعت بالا در محاسبات برای تخمین توزیع غلظت رسوبات معلق در کانال‌های باز توصیه می‌شود.

در شکل ۶ نتایج برآورده توزیع غلظت با استفاده از مدل‌های آماری و تجربی بررسی شده در این تحقیق، به همراه داده‌های آزمایشگاهی ونونی و اینشتین آورده شده است. همان طور که در شکل ۶ و همچنین در جداول ۶ و ۷ مشاهده می‌شود، مدل شبکه عصبی ANN_3 بهترین برآورد از توزیع غلظت رسوبات معلق را در بین ۷ مدل کандیدا ارائه می‌دهد. نتایج این تحقیق با نتایج تحقیقات فیض‌نیا و همکاران (۱۳۸۸) و فلامکی و همکاران (۱۳۹۲) که در آن‌ها مدل شبکه عصبی نسبت به سایر مدل‌های رگرسیونی، به خوبی قادر به تخمین توزیع غلظت رسوبات معلق بوده است، مشابه می‌باشد.

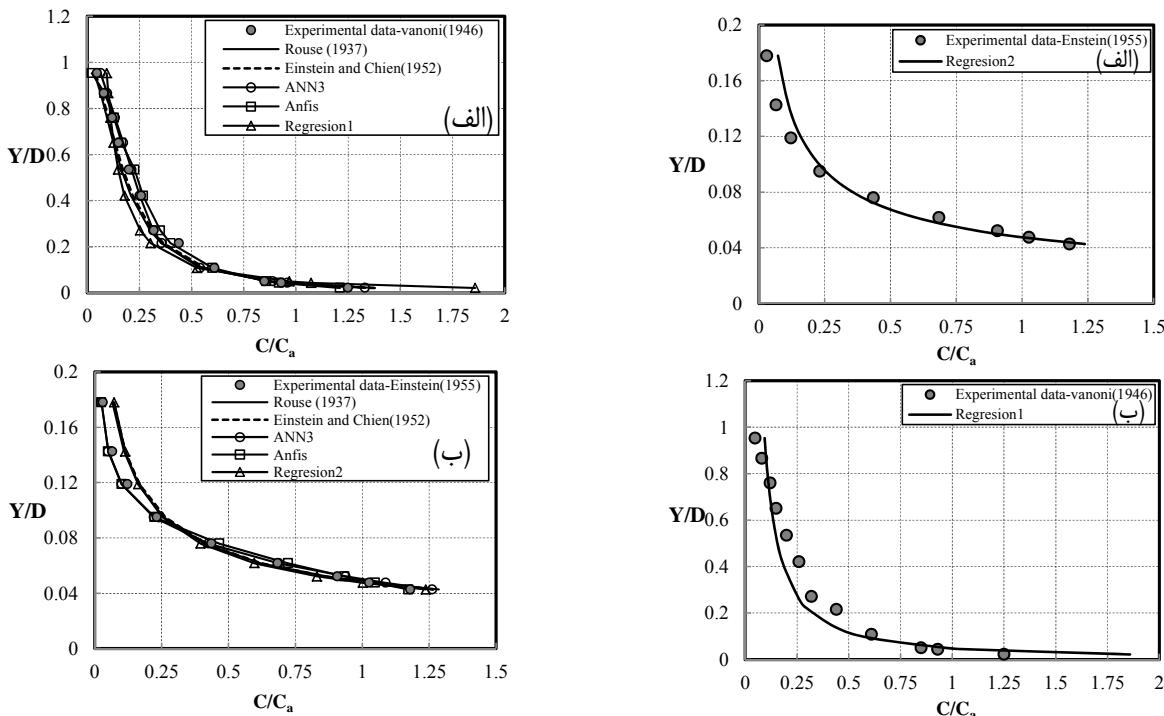
برآورد توزیع بار معلق با استفاده از رگرسیون چندمتغیره

به منظور برآورد توزیع بار معلق با استفاده از یک رابطه رگرسیونی که ارتباط بین داده‌های ورودی و خروجی را ایجاد کند، مدل‌های مختلفی توسعه داده شد و در نهایت عملکرد ۲ مدل برای بستر صاف و بستر زبر، گزارش شد (جدول ۵). توزیع غلظت اندازه‌گیری شده و محاسبه شده توسط هر یک از معادلات و مدل‌ها برای دو مجموعه داده ونونی (۱۹۴۶) و اینشتین و شن (۱۹۵۵)، در شکل ۵ رسم شده است.

همان طور که ملاحظه می‌شود هر سه مدل شبکه عصبی مصنوعی به خوبی قادر به پیش‌بینی توزیع غلظت رسوبات معلق هستند و مدل ANN_3 با وجود اینکه از پارامترهای ورودی کمی استفاده می‌کند، نتایج بسیار مناسبی را بدست می‌دهد، بررسی‌های آماری انجام شده در جداول ۶ و ۷ این نتیجه را تایید می‌کند. در مقایسه با معادلات تجربی روش شبکه

جدول ۶- نتایج حاصل از عملکرد روابط و مدل‌ها، مقایسه با داده‌های ونونی (۱۹۴۶).

روابط و مدل‌ها	RMSE	MAE	ضریب همبستگی
راوس	۰/۰۵۳	۰/۰۳۹	۰/۹۹۱
ونونی	۰/۰۴۷	۰/۰۳۴	۰/۹۹۳
ANN ₁	۰/۰۴۲	۰/۰۳۸	۰/۹۹۹
ANN ₂	۰/۰۵۳	۰/۰۴۴	۰/۹۹۸
ANN ₃	۰/۰۴۶	۰/۰۲۶	۰/۹۹۹
ANFIS	۰/۰۵۸	۰/۰۴۲	۰/۹۹۷
Regresion2	۰/۱۹۲	۰/۱۱۵	۰/۹۶۹



شکل ۶- توزیع غلظت محاسبه شده به وسیله هر یک از مدل‌های تجربی و آماری به همراه داده‌های آزمایشگاهی.

شکل ۵- توزیع غلظت اندازه‌گیری شده و محاسبه شده برای هر یک از معادلات و مدل‌های رگرسیون در مقابل داده‌های آزمایشگاهی (الف) اینشتین و شن (۱۹۵۵) و (ب) ونونی (۱۹۴۶).

تعداد لایه‌های پنهان شبکه پرسپترون چندلایه، یک لایه در نظر گرفته شد. در مدل سیستم استنتاج فازی-عصبی نیز با تحلیل حساسیت انجام شده روی توابع عضویت، تابع عضویت گوسی به عنوان بهترین تابع عضویت انتخاب شد. در این مدل نیز با افزایش تعداد توابع عضویت از کارایی مدل کاسته گردید. دقت مدل‌ها در برآورد توزیع غلظت با استفاده از آماره‌های ضربه همبستگی، MSE و RMSE مورد مقایسه قرار گرفت. با توجه به شکل ۶ و مقایسه نتایج بدست آمده با استفاده از سه روش نشان داد که مدل‌های هوش مصنوعی قابلیت بالایی در برآورد توزیع غلظت رسوبات داشته و مدل شبکه عصبی به خوبی قادر به برآورد توزیع غلظت رسوبات بوده و نسبت به بقیه مدل‌های ارائه شده برتری نسبی دارد. مدل استنتاج فازی-عصبی نیز قادر به مدل‌سازی توزیع غلظت بوده، اما نسبت به روش شبکه عصبی کارایی کمتری نشان داد. ارزیابی روابط رگرسیونی نشان می‌دهد که روابط ارائه شده برای بستر صاف و بستر زیر نسبت به سایر مدل‌ها از دقت پایین‌تری برخوردار بوده و استفاده از آن توصیه نمی‌گردد.

جدول ۷- نتایج حاصل از عملکرد روابط و مدل‌ها، مقایسه با داده‌های اینشتین وشن (۱۹۵۵).

روابط و مدل‌ها	ضریب همبستگی	MAE	RMSE
راوس	۰/۹۸۷	۰/۰۴۴	۰/۰۵۱
اینشتین وشن	۰/۹۸۸	۰/۰۴۳	۰/۰۴۸
ANN ₁	۰/۹۹۹	۰/۰۳۲	۰/۰۳۶
ANN ₂	۰/۹۹۹	۰/۰۲۶۸	۰/۰۳۷۴
ANN ₃	۰/۹۹۹	۰/۰۲۶۹	۰/۰۳۷۲
ANFIS	۰/۹۹۶	۰/۰۲۹	۰/۰۴۲
Regression1	۰/۹۹۲	۰/۰۴۸	۰/۰۵۲

نتیجه‌گیری کلی

در این مقاله سه روش شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی و رگرسیون چند متغیره به منظور برآورد توزیع غلظت رسوبات معلق در کانال‌های باز، مورد ارزیابی قرار گرفته شد. در روش شبکه عصبی از شبکه پرسپترون چند لایه (MLP) و در روش سیستم استنتاج فازی-عصبی (ANFIS) برای افزایش قواعد فازی از روش زیر خوشه‌بندی استفاده شد. نتایج نشان داد که در مدل شبکه عصبی با افزایش تعداد لایه‌های پنهان دقت شبکه بهبود نمی‌یابد و با افزایش آن به سه لایه حتی دقت شبکه کاهش می‌یابد و به همین علت

منابع مورد استفاده

- آوریده‌ف، بنی‌حیب‌م و شمسی‌ط، ۱۳۸۰. کاربرد شبکه‌های عصبی مصنوعی جهت تخمین دبی رسوب رودخانه‌ها. ۳۶۶ تا ۳۶۷.
- سومین کنفرانس هیدرولیک، ۵ تا ۷ آبان، تهران.
- امید‌مح و نصرآبادی، ۱۳۹۱. مهندسی رسوب، انتشارات دانشگاه تهران. چاپ اول. ۷۹۸ صفحه.
- بايزيدى ش، ياسى م، فتاحى ر و كارگر، ۱۳۸۴. پيش بيني و برآورد رسوب معلق روزانه با استفاده از شبکه‌های عصبی مصنوعی - مدل پرسپترون چند لایه، صفحه‌های ۵۶۱ تا ۵۵۵، پنجمین کنفرانس هیدرولیک ایران، ۲۱ آبان، کرمان.
- دانندۀ‌مهرع، علی‌ایی ا و قربانی، ۱۳۸۹. پيش بيني باز معلق رودخانه‌ها بر مبنای دبی جريان با استفاده از برنامه‌ريزي ژنتيك. پژوهش‌های آبخیزداری، شماره ۸۸ صفحه‌های ۴۵ تا ۵۴.
- دهقاني، عسگري، م و مساعدی، ۱۳۸۹. مقایسه سه روش شبکه عصبی مصنوعی، سیستم استنتاجي فازی-عصبي تطبیقی و زمین آمار در میان یابی سطح آب زیرزمینی (مطالعه موردی دشت قزوین). مجله علوم کشاورزی و منابع طبیعی جلد شانزدهم، ویژه نامه ۱ ب، صفحه‌های ۱ تا ۱۴.
- رجایي ط، ميرباقري سا و مرغوب ب، ۱۳۸۸. شبیه سازی سری زمانی باز معلق رودخانه توسط مدل شبکه عصبی مصنوعی. دومین سمینار بين المللی مهندسی محیط زیست. دانشگاه خواجه نصیرالدین طوسی، ۲۹ دی تا ۱ بهمن، تهران.
- طباطبائی م، شاهدی ک و سلیمانی ک، ۱۳۹۲. مدل شبکه عصبی مصنوعی برآورد غلظت رسوب معلق رودخانه‌ای به کمک تصاویر سنجنده مودیس (مطالعه موردی ایستگاه هیدرومتری ملاشانی - رودخانه کارون). نشریه آب و خاک (علوم و صنایع کشاورزی)، جلد ۲۷. شماره ۱، صفحه‌های ۱۹۳ تا ۲۰۴.

طلوعی س، دلیر ع، قربانی مع، فاخری فرد ا و سلامی ف، ۱۳۹۰. تخمین زمانی و مکانی بار معلق رودخانه آجی چای با استفاده از زمین آمار و شبکه عصبی مصنوعی. نشریه دانش آب و خاک. جلد ۲۱. شماره ۴، صفحه های ۹۳ تا ۱۰۴.

فلامکی ا، اسکندری م، بغلانی ع و احمدی س، ۱۳۹۲. مدل سازی بار رسوب کل رودخانه ها با استفاده از شبکه های عصبی مصنوعی. نشریه حفاظت منابع آب و خاک. سال دوم، شماره ۳. صفحه های ۱۲ تا ۲۲.

فیض نیا س، محمد عسگری ح و معلمی م، ۱۳۸۸. بررسی کارایی روش شبکه عصبی مصنوعی در تخمین رسوب معلق روزانه. مجله منابع طبیعی ایران. دوره ۶۰، شماره ۴. صفحه های ۱۱۹۹ تا ۱۲۱۰.

نصرآبادی م، ریاحی ص و صمدی بروجنی ح، ۱۳۹۲. ارزیابی معادلات توزیع غلظت رسوبات معلق در کانال های باز. مجله پژوهش آب ایران. سال ششم. شماره یازدهم، صفحه های ۱۱۲۲ تا ۱۲۱.

- Alp M and Cigizoglu HK, 2007. Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. *Environmental Modeling and Software* 22(1):2-13.
- Chang FJ, and Chang YT, 2005. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. *Advances in Water Resources* 29(1):1-10.
- Chang FM, Simons DB, and Richardson EV, 1967. Total bed-material discharge in alluvial channels. US Geological Survey Water-Supply paper 1498-I.
- Cigizoglu HK, and Kisi O, 2006. Methods to improve the neural network performance in suspended sediment estimation. *Journal of Hydrology* 317(3):221-238.
- Enistein HA, and Chien N, 1955. Effects of heavy sediment concentration near the bed on velocity and sediment distribution, Report No. 8. U. S. Army Corps of Engineers. Missouri River Division. University of California.
- Gary LB, 2008. Approximate profile for non-equilibrium suspended sediment. *Journal of Hydraulic Engineering* 134(7): 1010-1014.
- Itakura T, and Kishi T, 1980. Open channel flow with suspended sediments. *Journal of Hydraulic Division ASCE* 106(8): 1325-1343.
- Mtigue DF, 1981. Mixture theory for suspended sediment transport. *Journal of Hydraulic Division ASCE* 107(6): 659-673.
- Jang JS, 1993. ANFIS: Adaptive Network-based Fuzzy Inference System. *IEEE Transactions on Systems Man and Cybernetics* 23(3): 665-685.
- Rouse H, 1937. Modern conceptions of the mechanics of fluid turbulence. *Transactions of the American Society of Civil Engineers* 102(1): 463-505.
- Tanaka S, and Sugimoto S, 1958. On the distribution of suspended sediment in experimental flume flow. Memoirs of the faculty of engineering. No. 5. Kobe University, Japan.
- Vanoni VA, 1946. Transportation of suspended sediment by water. *Transactions of the American Society of Civil Engineers* 111(1): 67-102.
- Willis JC, 1979. Suspended load from error-function models. *Journal of Hydraulics Division ASCE* 105(7): 801-816