

Technical Note

Prediction of Froude Number of Three Phases Flow in Sewer Systems Using Extreme Learning Machines

F. Yosefvand ¹, S. Shabanlou ², M. A. IzadBakhsh ³

1. Assist. Prof., Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran
(Corresponding Author) fariborzosefvand@gmail.com
2. Assoc. Prof., Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran
3. Assist. Prof., Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

(Received Nov. 18, 2017 Accepted Feb. 8, 2018)

To cite this article :

Yosefvand, F., Shabanlou, S., IzadBakhsh, M. A., 2018, "Prediction of froude number of three phases flow in sewer systems using extreme learning machines." Journal of Water and Wastewater, (In press).
Doi: 10.22093/wwj.2018.106161.2543. (In Persian)

Abstract

Generally, circular channels are used in urban sewage systems where the flow is a three phase flow including water, air, and sediments. Accordingly, there are many studies carried out by different researchers related to flow within sewage channels. In current study, the Froude number of three phase flow within sewer channels is predicted using Extreme Learning Machine (ELM). Using parameters affecting the Froude number, 127 various ELM models were defined. The superior model was then introduced. For instance, for the superior model as a function of volumetric sediment concentration, the ratio of the particle size to overall hydraulic radius and overall friction factor for sediment load of 60% and 40% in train and test, respectively, the R², MAPE and RMSE in testing mode were calculated as 0.856, 0.117, and 0.738, respectively. In addition, the results of superior model were compared with Artificial Neural Network (ANN) and support Vector Machine (SVM) models. Analyses of modeling results showed that extreme learning machine simulated the aim function with more accuracy.

Keywords: Sewer Channel, Froud Number, Extreme Learning Machine, Artificial Neural Network, Support Vector Machine.



یادداشت فنی

پیش‌بینی عدد فرود جریان سه فازی در سیستم‌های فاضلاب‌رو
با استفاده از ماشین آموزش نیرومندفریبرز یوسفوند^۱، سعید شعبانلو^۲، محمد علی ایزدبخش^۳۱- استادیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران
(نویسنده مسئول) fariborzosefvand@gmail.com۲- دانشیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران
۳- استادیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

(دریافت ۹۶/۸/۲۷ پذیرش ۹۶/۱۱/۱۹)

برای ارجاع به این مقاله به صورت زیر اقدام فرمایید:

یوسفوند، ف.، شعبانلو، س.، ایزدبخش، م.ع.، ۱۳۹۷، "پیش‌بینی عدد فرود جریان سه فازی در سیستم‌های فاضلاب‌رو با استفاده از ماشین آموزش نیرومند" مجله آب و فاضلاب، (در انتظار چاپ). Doi: 10.22093/wwj.2018.106161.2543

چکیده

به‌طور کلی کانال‌های دایروی در سیستم‌های جمع‌آوری فاضلاب‌های شهری مورد استفاده قرار می‌گیرند. در مقابل جریان درون این مجاری یک جریان سه فازی شامل آب، هوا و رسوبات است. مطالعات فراوانی در ارتباط با جریان درون کانال‌های فاضلاب توسط پژوهشگران مختلف انجام شده است. در پژوهش حاضر با استفاده از مدل ماشین آموزش نیرومند، عدد فرود جریان سه فازی درون کانال‌های دایروی فاضلاب‌رو تخمین زده شد. سپس با استفاده از پارامترهای مؤثر بر روی عدد فرود، ۱۲۷ مدل ماشین آموزش نیرومند مختلف تولید و مدل برتر معرفی شد. برای مدل برتر که تابعی است از غلظت حجمی رسوبات، نسبت قطر متوسط ذرات رسوب به شعاع هیدرولیکی و ضریب مقاومت کلی بار رسوب، در شرایط ۶۰ درصد آموزش و ۴۰ درصد آزمون، مقادیر ضریب تبیین، درصد میانگین مطلق خطا و خطای جذر میانگین مربعات در حالت آزمون به ترتیب ۰/۸۵۶، ۰/۱۱۷ و ۰/۷۳۸ محاسبه شد. علاوه بر این، نتایج مدل برتر با مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقایسه شد. تجزیه و تحلیل نتایج مدل‌سازی نشان داد که ماشین آموزش نیرومند، مقادیر تابع هدف را با دقت بیشتری شبیه‌سازی می‌کند.

واژه‌های کلیدی: کانال فاضلاب‌رو، عدد فرود، ماشین آموزش نیرومند، شبکه عصبی مصنوعی، ماشین بردار پشتیبان

۱- مقدمه

خطی، رگرسیون غیرخطی و مدل آریمای مقایسه کردند (Melessea et al., 2011).
ابتهاج و بنکداری در سال ۲۰۱۳ توسط شبکه عصبی مصنوعی، الگوی انتقال بار رسوبات درون مجاری فاضلاب‌رو را شبیه‌سازی نمودند. آنها نتایج مدل خود را با شبکه ANFIS نیز مقایسه کردند و نشان دادند که شبکه عصبی مصنوعی مقادیر آزمایشگاهی را با دقت بیشتری پیش‌بینی می‌کند (Ebtahaj & Bonakdari, 2013).
همچنین ابتهاج و همکاران در سال ۲۰۱۶ با استفاده از یک مدل غیر خطی، نحوه جابجایی رسوبات غیر چسبنده داخل کانال‌های دایروی شکل را پیش‌بینی نمودند (Ebtahaj et al., 2016).

با توجه به پژوهش‌های میدانی، حدود ۱۰ درصد همه فاضلاب‌ها دارای رسوبات ته‌نشینی دائمی هستند و تا ۲۰ درصد مواد معلق در دوره زمانی هوای خشک به‌علت دبی کم ته‌نشین می‌شوند (Ackers et al., 1996).
در سال‌های اخیر استفاده از الگوریتم‌های مختلف شبکه عصبی مصنوعی و روش‌های گوناگون محاسبات به‌منظور مدل‌سازی پدیده‌های پیچیده و نامنظم علوم مختلف استفاده شده است. به‌عنوان مثال ملسا و همکاران در سال ۲۰۱۱ بار رسوبات معلق درون سیستم رودخانه‌های ایالت متحده را با استفاده از شبکه عصبی مصنوعی تخمین زدند. آنها نتایج مدل مذکور را با نتایج رگرسیون



دارد به طوری که شرط $\sum_{i=1}^M \|o_j - t_i\|$ برقرار باشد. در واقع یک β_i ، w_i و b_i به شکل زیر وجود خواهد داشت

$$\sum_{i=1}^M \beta_i g(w_i \cdot x_i + b_i) = y_j \quad j=1,2,\dots,N \quad (2)$$

معادله فوق را می‌توان به فرم ماتریسی زیر بیان کرد

$$H\beta = Y \quad (3)$$

به طوری که

$$H(\tilde{a}, \tilde{b}, \tilde{x}) = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_1) \\ \vdots & & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix}_{N \times L} \quad \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}$$

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_L^T \end{bmatrix}_{N \times m}$$

ماتریس H ، خروجی لایه مخفی مربوط به یک شبکه عصبی پیشخور تک لایه است به طوری که i آمین ستون H ، خروجی i -آمین نود مخفی برای ورودی‌های $x_1, x_2, x_3, \dots, x_N$ است. پس از تعیین تصادفی وزن‌های ورودی و نرون‌های لایه مخفی، آموزش شبکه آغاز می‌شود. به این منظور، معادله ۳ به صورت یک مسئله حداقل مربعات به شکل زیر، حل می‌شود

$$\min_{\beta} \|H\beta - Y\| \quad (4)$$

همچنین، کمترین معیار^۳ حداقل مربعات، به صورت زیر محاسبه می‌شود

$$\hat{\beta} = H^+ Y \quad (5)$$

که در آن ماتریس H^+ ، معکوس اصلاح شده مور-پنروسه^۴ ماتریس H است. بنابراین روش ماشین آموزش نیرومند را می‌توان در سه مرحله شامل: (۱) تولید تصادفی بردار وزن (w) که لایه ورودی و

در مطالعه کاربردی حاضر برای اولین بار از ماشین آموزش نیرومند برای تخمین حداقل سرعت مورد نیاز به منظور جلوگیری از ته‌نشینی رسوبات استفاده شد که این موضوع به عنوان نوآوری پژوهش حاضر در نظر گرفته می‌شود. در ابتدا عوامل مؤثر بر روی عدد فرود شناسایی و سپس به منظور آنالیز حساسیت، ۱۲۷ مدل متفاوت تعریف شدند و در نهایت مدل برتر و مؤثرترین پارامترها معرفی شدند.

۲- مواد و روش‌ها

۲-۱- ماشین آموزش نیرومند

ماشین آموزش نیرومند یک الگوریتم آموزش ماشین برای شبکه عصبی پیش‌خور تک لایه است که برای اولین بار توسط هوآنگ و همکاران در سال ۲۰۰۶ ارائه شده است (Huang et al. 2006). اگر m تعداد گره‌ها در لایه ورودی، M تعداد گره‌ها در لایه مخفی، n تعداد گره‌ها در لایه خروجی، b_i بایاس و $g(x)$ تابع فعال‌سازی نرون‌های لایه مخفی باشند، شکل استاندارد یک شبکه عصبی تک لایه با تعداد M نرون در لایه مخفی و تابع فعال‌سازی $g(x)$ به صورت زیر مدل‌سازی می‌شود (Liang et al., 2006).

$$\sum_{i=1}^M \beta_{ij} g(w_i \cdot x_i + b_i) = t_j \quad j=1,2,\dots,N \quad (1)$$

که در آن

$t_i = [t_{j1}, t_{j2}, \dots, t_{jn}]^T$ بردار خروجی مربوط به شبکه عصبی پیش‌خور تک لایه است^۱، $w_i \cdot x_i$ ضرب داخلی^۲ مربوط به X_i و W_i است، b_i بایاس مربوط به i آمین نرون لایه مخفی است، $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$ بردار وزنی است که با i آمین نرون لایه مخفی و گره‌های خروجی در ارتباط است و $W_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ بردار وزنی است که با i آمین نرون مخفی و گره‌های ورودی در ارتباط است. تابع فعالیت غیر خطی ماشین آموزش نیرومند در این پژوهش از نوع سیگموئید بود. فرم استاندارد یک شبکه عصبی پیش‌خور تک لایه با تابع فعال‌سازی $g(x)$ و تعداد M نرون مخفی، توانایی تخمین تمامی N نمونه در نظر گرفته شده با خطای صفر را

³ Norm

⁴ Moore-Penrose generalized inverse

¹ Single Layer Feed-forward Neural Network (SLFNN)

² Inner product



۳- نتایج و بحث

در این پژوهش به منظور ارزیابی دقت مدل‌های شبیه‌سازی از شاخص‌های آماری ضریب تبیین^۱ (R^2)، درصد میانگین مطلق خطا^۲، خطای جذر میانگین مربعات^۳، شاخص^۴ BIAS و شاخص پراکندگی^۵ که در قالب معادلات زیر معرفی شده‌اند، استفاده می‌شوند

$$R^2 = \frac{\left(\sum_{i=1}^n R_{(Predicted)_i} R_{(Observed)_i} - \sum_{i=1}^n R_{(Predicted)_i} \sum_{i=1}^n R_{(Observed)_i} \right)^2}{\left(\sum_{i=1}^n (R_{(Predicted)_i})^2 - \sum_{i=1}^n (R_{(Predicted)_i}) \right) \left(\sum_{i=1}^n (R_{(Observed)_i})^2 - \sum_{i=1}^n (R_{(Observed)_i}) \right)} \quad (8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{|R_{(Predicted)_i} - R_{(Observed)_i}|}{R_{(Observed)_i}} \right) \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{(Predicted)_i} - R_{(Observed)_i})^2} \quad (10)$$

$$SI = \frac{RMSE}{(\bar{R})_{(Observed)}} \quad (11)$$

که در این معادلات

$R_{(Observed)_i}$ مقدار آزمایشگاهی، $R_{(Predicted)_i}$ نتایج پیش‌بینی شده، $(\bar{R})_{(Observed)_i}$ میانگین مقادیر آزمایشگاهی و n تعداد اندازه‌گیری‌های آزمایشگاهی است.

۳-۱- نحوه ترکیب مدل‌های ماشین آموزش نیرومند

برای حساسیت‌سنجی پارامترهای ورودی که شامل d/R ، d/D ، D_{gr} ، R/D ، D^2/A و λ_s است، ۱۲۷ مدل ELM مختلف معرفی شد. کلیه حالت‌های موجود در شکل ۱ نشان داده شده است.

۳-۲- نتایج مدل‌های ELM

در ابتدا مدل‌های با یک پارامتر ورودی بررسی شدند. در بین مدل‌های شماره یک تا هفت، مدل شماره پنج مقادیر عدد فرود را

مخفی را به هم متصل می‌کند و تولید بایاس لایه مخفی (۲) محاسبه ماتریس خروجی لایه مخفی (H) (۳) و محاسبه وزن خروجی خلاصه کرد.

۲-۲- مدل فیزیکی

حداقل سرعت مورد نیاز برای انتقال رسوبات بدون ته‌نشینی (V) تابعی از غلظت حجمی رسوبات (Cv)، عمق جریان (y)، شعاع هیدرولیکی (R)، قطر لوله (D)، نسبت قطر متوسط ذرات (d_{50})، نسبت چگالی رسوبات به چگالی آب (s)، شتاب گرانش (g) و ضریب مقاومت کلی بار رسوب (λ_s) است (Ebtehaj and Bonakdari, 2019, Vongrissomjai et al., 2010)

$$V = f(Cv, y, R, D, d_{50}, s, g, \lambda_s) \quad (6)$$

همچنین ابتهاج و بنکداری در سال ۲۰۱۴ با معرفی پنج گروه بدون بعد شامل عدد فرود (Fr)، غلظت حجمی رسوبات (Cv)، رسوبات شامل (d/R ، D^2/A ، انتقال، $(D_{gr}=d_{50}(g(s-1)/v^2)^{1/3}$ ، d/D) و R/D و ضریب مقاومت کلی بار رسوب (λ_s) بیان نمودند که عدد فرود تابعی از چهار گروه بدون بعد d/R ، d/D ، Cv و λ_s است. بنابراین معادله ۶ به صورت زیر بازنویسی می‌شود

$$Fr = f(Cv, d/D, d/R, \lambda_s) \quad (7)$$

که در آن

Fr عدد فرود، Cv غلظت حجمی رسوبات، d/D نسبت قطر متوسط ذرات به قطر لوله، d/R نسبت قطر متوسط ذرات رسوب و شعاع هیدرولیکی و λ/s ضریب مقاومت کلی با رسوب یا ضریب مقاومت جریان رسوبی است.

برای اعتبارسنجی مدل‌های ELM از مقادیر آزمایشگاهی اندازه‌گیری استفاده شد (Abghani, 1993, Ota and Nalluri, 1991)

آنها مقادیر $(D_{gr}=d_{50}(g(s-D_{gr}, R/D, D^2/A, d/R, Cv, Fr, \lambda_s, d_{50}/D, 1/v^2)^{1/3})$ را اندازه‌گیری نمودند. به بیان دیگر آنها تأثیر پارامترهای مذکور را روی تغییرات عدد فرود (Fr) مورد بررسی قرار دادند.

¹ Coefficient of determination

² Mean Absolute Percentage Error (MAPE)

³ Root Mean Square Error (RMSE)

⁴ BIAS Index

⁵ Scatter Index (SI)



مدل‌های شماره ۶۴ تا ۹۸ بر حسب چهار پارامتر ورودی بود مدل شماره ۶۹ در بین این مدل‌ها بیشترین دقت را داشت. همچنین مدل شماره ۱۰۷ در میان مدل‌های ELM با پنج پارامتر ورودی دارای بیشترین دقت و کمترین خطا بود. در بین مدل‌های با ۶ پارامتر ورودی (مدل‌های شماره ۱۲۰ تا ۱۲۶) مدل شماره ۱۲۴ به‌عنوان مدل برتر شناسایی شد. برای مدل شماره ۱۲۷ مقادیر RMSE، BIAS و SI در وضعیت آزمون به‌ترتیب برابر ۱/۱۲۸، ۰/۲۳۸ و ۰/۲۷۳ بود. مدل شماره ۳۳ به‌عنوان مدل برتر معرفی شد. این مدل مقادیر تابع هدف را بر حسب غلظت حجمی رسوبات، نسبت قطر متوسط ذرات رسوب به شعاع هیدرولیکی و ضریب مقاومت کلی بار رسوب شبیه‌سازی کرد. در حالت آموزش این مدل در مقایسه با مدل برتری که مقادیر تابع هدف را با یک پارامتر ورودی پیش‌بینی می‌کند، مقدار ضریب تبیین را ۱۹ درصد بهبود بخشید. همچنین درصد بهبود RMSE مدل برتر برای شرایط آموزش در مقایسه با مدل‌های با دو و چهار پارامتر ورودی به‌ترتیب برابر ۵ و ۱۵ بود. علاوه بر این، شاخص آماری MAPE برای مدل برتر برای شرایط آزمون در مقایسه با مدل‌های با ۵، ۶ و ۷ پارامتر ورودی تقریباً ۳۵، ۳۴ و ۳۷ درصد بهبود یافت. نتایج مدل‌سازی این مدل در هر دو وضعیت آموزش و آزمون در شکل ۲ نشان داده شده است. همچنین در میان تمامی مدل‌های با شش ورودی (مدل‌های

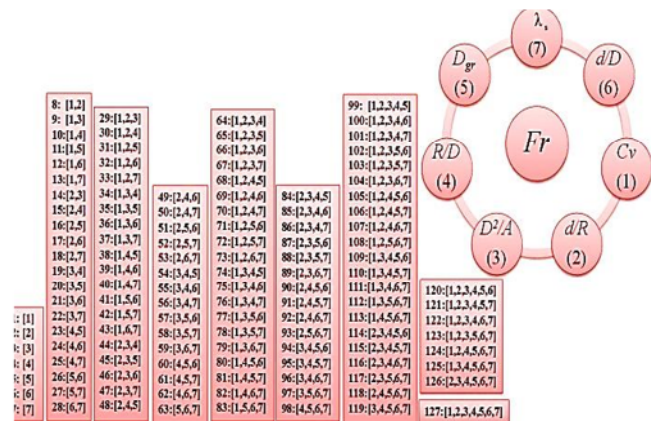


Fig. 1. Combination of input parameters for different models

شکل ۱- ترکیب پارامترهای ورودی برای مدل‌های مختلف

با دقت بیشتری تخمین می‌زند. برای این مدل مقدار RMSE در حالت آموزش برابر ۰/۹۴۶ به‌دست آمد. در بین مدل‌های ماشین آموزش نیرومند با ترکیبی از دو پارامتر ورودی، مدل شماره هشت از دقت بیشتری برخوردار است. مقدار MAPE برای شرایط آموزش و آزمون مدل شماره ۸ به‌ترتیب مساوی ۰/۰۹۳۸ و ۰/۱۱۰ تخمین زده شد. در بین مدل‌های با سه ورودی، مدل شماره ۳۳ خطای کمتر و ضریب تبیین بیشتری داشت. به‌عنوان مثال مقدار R^2 ، MAPE و RMSE در حالت آزمون به‌ترتیب مساوی ۰/۸۵۶، ۰/۱۱۷ و ۰/۷۳۸ به‌دست آمد. شبیه‌سازی مقدار عدد فرود در




Fig. 2. Scatter plot (a) train (b) test for model number 33

شکل ۲- نمودار پراکنندگی وضعیت الف- آموزش ب- آزمون برای مدل شماره ۳۳

۴- نتیجه‌گیری

در این پژوهش با استفاده از مدل جدید ماشین آموزش نیرومند، عدد فرود جریان سه فاز آبی، هوا و رسوبات تخمین زده شد. در بین کلیه مدل‌های ELM مدلی که با سه پارامتر ورودی مقادیر عدد فرود را تخمین زد مدل برتر شناسایی شد. برای این مدل، مقادیر R^2 ، MAPE و RMSE در حالت آزمون به ترتیب مساوی $0/856$ ، $0/117$ و $0/738$ به دست آمد. همچنین با مقایسه نتایج مدل برتر ELM با دو مدل ANN و SVM نشان داده شد که مدل ELM مقادیر آزمایشگاهی را با دقت بیشتری در مقایسه با دو مدل دیگر پیش‌بینی می‌کند. همچنین بر اساس نتایج آنالیز حساسیت، پارامترهای λ_s و d/R به ترتیب مؤثرترین پارامترها برای پیش‌بینی عدد فرود جریان سه فاز توسط مدل ماشین آموزش نیرومند شناسایی شدند.

۵- قدردانی

نویسندگان این مقاله مراتب قدردانی خود را از معاونت پژوهش و فناوری دانشگاه آزاد اسلامی واحد کرمانشاه که امکانات علمی لازم در راستای اجرای این پژوهش را فراهم نمودند، اعلام می‌نمایند.

۱۲۰ تا ۱۲۶) در کلیه وضعیت‌های آزمون و آموزش، مدل‌های شماره ۱۲۰ و ۱۲۴ دارای بیشترین مقدار خطا و کمترین مقدار ضریب تبیین بودند. برای این مدل‌ها به ترتیب تأثیر پارامترهای λ_s و d/R حذف شدند. بنابراین این دو پارامتر به عنوان مؤثرترین پارامترها معرفی شدند.

۳-۳- مقایسه نتایج مدل‌های ANN، ELM و SVM

در ادامه نتایج مدل برتر ELM (مدل ۳۳) با نتایج مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقایسه شد. لازم به ذکر است که سه مدل ELM، SVM و ANN دارای تعداد پارامتر ورودی یکسان و شرایط آزمون و آموزش برابر می‌باشند. بر اساس نتایج شبکه عصبی مصنوعی مقدار ضریب تبیین و MAPE برای وضعیت آموزش به ترتیب برابر $0/657$ و $0/271$ تخمین زده شد. این در حالی است که برای مدل SVM در وضعیت آموزش مقدار MAPE، RMSE و SI به ترتیب برابر $0/171$ ، $0/001$ و $0/660$ به دست آمد. همان‌گونه که مشاهده می‌شود، مدل ماشین بردار پشتیبان مقادیر عدد فرود را با دقت بیشتری در مقایسه با مدل شبکه عصبی مصنوعی پیش‌بینی نمود.

References

- Ab Ghani, A. 1993. Sediment transport in sewers. Ph.D. Thesis, University of Newcastle Upon Tyne, UK.
- Ackers, J.C., Butler, D. & May, R.W.P. 1996. *Design of sewers to control sediment problems*. Construction Industry Research and Information Association, London.
- Ebtehaj, I. & Bonakdari, H. 2013. Evaluation of sediment transport in sewer using artificial neural network. *Engineering Applications of Computational Fluid Mechanics*, 7(3), 382-392.
- Ebtehaj, I., Bonakdari, H. & Zaji, A.H. 2016. A nonlinear simulation method based on a combination of multilayer perceptron and decision trees for predicting non-deposition sediment transport. *Water Science and Technology: Water Supply*, 16(5), 1198-1206.
- Ebtehaj, I. & Bonakdari, H. 2014. Comparison of genetic algorithm and imperialist competitive algorithms in predicting bed load transport in clean pipe. *Water Science and Technology*, 70 (10), 1695-1701.
- Huang, G-B., Zhu, Q-Y. & Siew, C-K. 2006. Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1), 489-501.
- Liang, N.Y., Huang, G.B., Rong, H.J., Saratchandran, P. & Sundararajan, N. 2006. A fast and accurate on-line sequential learning algorithm for feedforward networks. *IEEE Trans Neural Netw*, 17, 1411-1423.
- Melessea, A.M., Ahmadb, S., McClaina, M.E., Wangc, X. & Limd, Y.H. 2011. Suspended sediment load prediction of river systems: An artificial neural network approach. *Agricultural Water Management*, 98, 855-866.
- Ota, J.J. & Nalluri, C. 1999. Graded sediment transport at limit deposition in clean pipe channel. In *28th Congress of International Association Hydro-Environmental Engineering Research*, Graz, Austria.
- Vongvisessomjai, N., Tingsanchali, T. & Babel, M.S. 2010. Non-deposition design criteria for sewers with part-full flow. *Journal of Urban Water*, 7(1), 61-77.

