

پیش بینی تغییرات عمق آبستگي در اطراف گوشواره‌ی پلها (Abutment) با استفاده از سامانه‌ی منطق فازی - عصبی (ANFIS) و شبکه‌های عصبی (ANNs)

رضا محمدپور^{۱*}، فرهنگ محمدپور^۲

دریافت دریافت: ۹۲/۶/۲۸ تاریخ پذیرش: ۱۳۹۳/۱/۱۴

چکیده

به دلیل پیچیده بودن الگوی سه بعدی جریان در اطراف گوشواره‌ی پل ها، برآورد دقیق تغییرات عمق آبستگي نسبت به زمان دشوار، و در برخی موارد غیر ممکن می‌باشد. در این تحقیق، ابتدا تغییرات عمق آبستگي در اطراف گوشواره‌ها به صورت آزمایشگاهی تحت شرایط آب زلال مورد بررسی قرار گرفته است و سپس با استفاده از نتایج حاصل از سه روش، وایازی غیر خطی (NLR)، شبکه‌های عصبی (ANN) و سامانه‌ی منطق فازی-عصبی (ANFIS)، تغییرات آبستگي در اطراف این سازه‌ها پیش بینی شده است. هر چند رابطه‌ی وایازی بدست آمده، نتایج بهتری را نسبت به روابط پیشین ارائه می‌کند ($R^2=0.957$ ، $RMSE=0.049$ and $MAE=0.035$)، اما سامانه‌ی منطق فازی-عصبی دارای دقت بالاتری نسبت به رابطه‌ی وایازی ارائه شده و هم‌چنین روابط پیشین می‌باشد ($R^2=0.961$ ، $RMSE=0.041$ and $MAE=0.025$). نتایج حاصله از فراسنج‌های آماری نشان می‌دهد که، هر دو روش ANN و ANFIS می‌توانند به عنوان روش‌های قدرتمندی در پیش بینی عمق آبستگي مورد استفاده قرار گیرند.

واژه‌های کلیدی: آبستگي گوشواره‌ها، سامانه‌ی منطق فازی-عصبی، شبکه‌های عصبی، گوشواره کوتاه و متوسط، زمان آبستگي

^۱ - عضو هیأت علمی دانشگاه آزاد اسلامی واحد استهبان

^۲ - فارغ التحصیل مهندسی عمران دانشگاه یاسوج

* - نویسنده مسئول مقاله: reza564@gmail.com

مقدمه

به پایین و همچنین گردابه‌های نعل اسبی تشکیل شده که عامل اصلی آبشستگی در اطراف گوشواره‌ها می‌باشند. گردابه‌های برخاستگی که در اثر جدایی در پشت گوشواره تشکیل می‌شوند، باعث انتقال رسوبات این ناحیه به پایین دست شده، و ابعاد حفره‌ی آبشستگی گسترش می‌یابد. همچنین در مجاورت گوشواره، گردابه‌های دیگری به نام گردابه‌های ثانویه ایجاد می‌گردد که جهت چرخش آنها خلاف گردابه‌های نعل اسبی می‌باشد. این گردابه باعث گسترش حفره آبشستگی در مجاورت گوشواره می‌شود.

به‌طور کلی، گوشواره پلها را می‌توان بر حسب طول آنها (L) و همچنین عمق جریان (y) به سه دسته‌ی، گوشواره با طول بلند ($L/y > 25$)، متوسط ($1 < L/y \leq 25$) و کوتاه ($L/y \leq 1$) تقسیم بندی کرد (ملویل ۱۹۹۲). با توجه به نسبت L/y ، روابط قید شده در جدول ۱ قابل استفاده برای هر سه نوع گوشواره با طول کوتاه، متوسط و بلند می‌باشند.

آبشستگی در اطراف گوشواره و پایه‌ی پلها، یکی از عوامل اصلی در تخریب آنها محسوب می‌شود. از آنجاییکه آبشستگی در اطراف گوشواره‌ها تابعی از زمان بوده و هم-چنین الگوی سه بعدی جریان در اطراف این نوع سازه‌ها پیچیده می‌باشد، لذا بررسی تغییرات عمق آبشستگی بر حسب زمان، یکی از مسائل مهم در سازه‌های آبی بوده، که همواره مورد توجه محققین قرار گرفته است (یانماز و کوس، ۲۰۰۷، الیوتو و هاگر، ۲۰۰۲، کولمن و همکاران، ۲۰۰۳، بالیو و اورسی، ۲۰۰۱، کاردوسو و بیتس، ۱۹۹۹). در جدول ۱، برخی روابط پیشنهادی به‌وسیله‌ی محققین پیشین، جهت پیش بینی تغییرات آبشستگی بر حسب زمان ارائه شده است.

آبشستگی پدیده‌ای می‌باشد که در اثر برخورد گردابه‌ها به رسوبات بستر شکل می‌گیرد. در جلو گوشواره، در اثر برخورد جریان با گوشواره، جریان‌های رو

جدول ۱- روابط تجربی جهت پیش بینی تغییرات عمق آبشستگی در اطراف گوشواره‌ها

Reference	Equation	U/U_c	L/y	Standard deviation (σ_g)
Yanmaz and Kose (2007)	$\frac{d_s}{L} = 0.25 F_d^{0.85} \left(\frac{L}{y}\right)^{0.15} \left(\log\left(\frac{t d_{50} \sqrt{g \Delta d_{50}}}{L^2}\right)\right)^{0.6}$		0.68~0.99 1.12~2.4 ~1.4	
Oliveto and Hager (2002)	$\frac{d_s}{y^{1/3} L^{2/3}} = 0.068 N \sigma_g^{-0.5} F_d^{1.5} \log\left(\frac{t \sqrt{g \Delta d_{50}}}{y^{1/3} L^{2/3}}\right)$		--- 1.25~6.0 1.0 to 2.15	
Coleman et al. (2003)	$\frac{d_s}{d_{se}} = \exp\left[-0.07\left(\frac{U}{U_c}\right)^{-1} \left \ln\left(\frac{t}{t_e}\right)\right ^{1.5}\right]$		0.46~0.99 0.25~151 ---	
Ballio and Orsi (2001)	$\frac{d_s}{d_{se}} = 1 - \exp\left[-0.028\left(\frac{tU}{(Ly)^{0.5}}\right)^{0.28}\right]$		~1 0.27~1.09 1.3	
Cardoso and Bettess (1999)	$\frac{d_s}{d_{se}} = 1 - \exp\left[-1.025\left(\frac{t}{T^*}\right)^{0.35}\right]$	0.91~1.08	2~23.5	1.26

where T^* =time when $d_s=0.632d_{se}$, $\Delta=S-I$ and S =relative density of sediment particles, N =shape number equal to 1.25 for vertical-wall abutment.

(۲۰۱۳a,b). عظمت الله و همکاران (۲۰۰۵)، با استفاده از شبکه‌های عصبی، عمق آبشستگی در پایین دست سرریزها را مورد بررسی قرار دادند. نتایج حاصل از این تحقیق نشان داد که، استفاده از فراسنجهای بی بعد در ورودی شبکه عصبی، نتایج بهتری را جهت پیش بینی

در چند دهه‌ی اخیر، روشهای نوینی از جمله شبکه‌های عصبی (ANN)، سامانه‌ی منطق فازی-عصبی (ANFIS) و الگوریتم وراثتی به عنوان ابزارهای قدرتمند در حل مسائل آبی مورد توجه محققین قرار گرفته است (عظمت الله و همکاران، ۲۰۰۲، نجف زاده و همکاران،

دهه‌ی اخیر، جهت پیش بینی بیشتر مسائل مهندسی از جمله آبشستگی، مورد استفاده قرار گرفته است (عظمت الله و همکاران، ۲۰۰۸، عظمت الله و غنی، ۲۰۱۱، زنگنه و همکاران، ۲۰۱۱، فرات ۲۰۰۹). باطنی و همکاران (۲۰۰۷b)، برای محاسبه‌ی بیشینه‌ی عمق آبشستگی، و همچنین تغییرات عمق آبشستگی بر حسب زمان در اطراف پایه پلها، از سامانه‌ی فازی-عصبی بهره جستند. در مطالعات انجام شده توسط زونعت کرمانی (۲۰۰۷)، از دو روش شبکه‌ی عصبی و همچنین سامانه‌ی فازی-عصبی، برای محاسبه‌ی عمق آبشستگی در اطراف گروه پایه‌ها استفاده شده است. در این تحقیق، از دو روش مختلف در شبکه‌ی عصبی به نامهای روش پیشخور (FFBP) و شعاع مداری (RBF) استفاده شده است. تحقیق آماری انجام شده نشان داد که شبکه‌ی عصبی به روش پیشخور، قادر به پیش بینی آبشستگی با دقت بالایی نسبت به دو روش RBF و ANFIS می‌باشد. مزمیل (۲۰۱۱)، و مزمیل و همکاران (۲۰۱۱)، با مقایسه‌ی سامانه‌ی فازی-عصبی و روابط ارائه شده جهت محاسبه‌ی بیشینه‌ی عمق آبشستگی در اطراف گوشواره پلها، نشان دادند که سامانه‌ی فازی-عصبی، قادر به پیش بینی عمق آبشستگی با دقت بالایی می‌باشد.

موضوع اصلی این تحقیق، بررسی آزمایشگاهی تغییرات عمق آبشستگی در اطراف گوشواره‌های کوتاه ($L/y \leq 1$) و متوسط ($1 < L/y < 25$) تحت شرایط آب زلال می‌باشد. در این راستا، از دو نوع شبکه‌ی عصبی پیشخور (FFBP) و شعاع مداری (RBF)، و همچنین سامانه‌ی فازی-عصبی (ANFIS) استفاده شده، و در انتها، نتایج به دست آمده از این روشها، با داده‌های آزمایشگاهی مورد مقایسه قرار گرفته شده است.

تحقیق ابعادی:

عمق آبشستگی در اطراف گوشواره‌ی پلها به عوامل مختلفی از جمله زمان، شرایط جریان، ویژگیهای سیال، جنس رسوبات و همچنین شکل و ابعاد گوشواره بستگی دارد. در رابطه‌ی زیر مجموعه‌ی ای از این فراسنجه‌ها قید شده است (ملویل ۱۹۹۲):

عمق آبشستگی ارائه خواهد داد. مطالعات انجام شده توسط چیو و چونگ (۲۰۰۶)، نشان می‌دهد که شبکه‌های عصبی قادر به پیش بینی عمق آبشستگی در اطراف پایه‌ها با دقت بالایی هستند. آنها ترکیبی از داده‌های میدانی و آزمایشگاهی را در مطالعات خود مورد استفاده قرار داده‌اند. باطنی و همکاران (۲۰۰۷ a)، جهت پیش بینی عمق آبشستگی در اطراف پایه‌ها با استفاده از شبکه‌های عصبی، فراسنجه‌های بی بعد و بعد دار را مورد بررسی قرار داده و نتایج حاصله نشان دادند که فراسنجه‌های دارای بعد، قادر به تولید نتایج بهتری نسبت به فراسنجه‌های بی بعد هستند. در شرایط آب زلال و بستر زنده، توت و برندیمارت (۲۰۱۱)، با استفاده از شبکه‌های عصبی، عمق آبشستگی در اطراف پلها را به دست آوردند. سازلاک و تیگرک (۲۰۱۱)، مطالعاتی را با استفاده از شبکه‌های عصبی برای پیش بینی عمق آبشستگی در اطراف گوشواره‌ی پلها انجام دادند. این مطالعات نشان می‌دهد که سرعت جریان، یکی از مهمترین فراسنجه‌های موثر در عمق آبشستگی می‌باشد، در حالیکه عرض گوشواره دارای کمترین اهمیت است. بگیم و همکاران (۲۰۱۱)، با استفاده از شبکه‌های عصبی (Radial Basis Function) RBF، عمق آبشستگی در اطراف گوشواره‌ها را بررسی کرده و نشان دادند که طول گوشواره، یکی از مهمترین فراسنجه‌ها، در تعیین عمق آبشستگی می‌باشد. محمدپور و همکاران (۲۰۱۲)، عمق نهایی آبشستگی در اطراف گوشواره‌های بلند را با استفاده از الگوریتم وراثتی و شبکه‌های عصبی مورد بررسی قرار دادند. نتایج حاصله نشان دادند که، شبکه‌ی عصبی دارای جوابهای دقیقتری نسبت به الگوریتم وراثتی می‌باشد، اما روشهای وایازی و وراثتی، عملاً کاربردی تر می‌باشند. محمدپور و همکاران (۲۰۱۳)، ابعاد آبشستگی، و همچنین تغییرات آن را در اطراف گوشواره‌های کوتاه مورد بررسی قرار دادند. نتایج حاصله نشان دادند، عصبی پیشخور دارای جوابهای دقیقتری نسبت به روش وایازی می‌باشد و تغییرات آبشستگی نسبت به زمان، حساس تر از دیگر فراسنجه‌ها از جمله سرعت جریان و ابعاد گوشواره می‌باشد.


سامانه‌ی فازی-عصبی (ANFIS)، ترکیبی از روش شبکه‌های عصبی و سامانه‌ی فازی می‌باشد، که در چند

و $1.5-1.8 < \sigma_g$ باشد، رسوبات بستر یکنواخت بوده و می‌توان از تاثیر انحراف معیار استاندارد نیز چشم پوشی کرد (کاردوسو و فییل، ۲۰۱۰). در این تحقیق، شرایط بستر صاف در آزمایشگاه فراهم شده و محل انجام آزمایش نقطه ای از نهر در نظر گرفته شده است که جریان کاملا توسعه یافته (fully developed flow) برقرار گردد، لذا رابطه‌ی (۳) را می‌توان برای پیش بینی آبشستگی تحت شرایط گفته شده در بالا، بصورت زیر در نظر گرفت:

$$\frac{d_s}{d_{se}} = f\left(\frac{t}{t_e}, \frac{L}{y}, \frac{U}{U_c}\right) \quad (۴)$$

شبکه های عصبی (Artificial Neural Networks):

شبکه های عصبی مصنوعی، به عنوان یکی از شاخه های هوش مصنوعی، بدلیل دارا بودن ساختار پردازش موازی، دارای سرعت پردازش بسیار بالایی هستند. شبکه‌ی عصبی مصنوعی، نوعی سامانه‌ی پردازش داده هاست، که از تعداد زیادی پردازشگر ساده و مرتبط با هم به نام نرون، تشکیل شده و در ساختار آن، از ساختمان مغز، الهام گرفته شده است. ساختار شبکه‌های عصبی مصنوعی که معماری به آن اطلاق می‌گردد، به شکلی است که نرونها (واحدهای محاسباتی) در دسته‌هایی که لایه نام دارند، مرتب می‌شوند. معماری این نوع شبکه های عصبی در شکل ۱ نشان داده شده است.



شکل ۱- معماری شبکه‌ی عصبی پیشرو

معماری معمول شبکه‌ی عصبی، شامل سه لایه می‌باشند که عبارتند از، لایه‌ی ورودی (لایه‌ی توزیع

$$d_s = f\left(\frac{t}{t_e}, \frac{L}{y}, \frac{U}{U_c}, \sigma_g, \rho_s, K_\theta, K_s, K_G\right) \quad (۱)$$

در این رابطه، t زمان آبشستگی؛ L طول گوشواره؛ y عمق جریان؛ U سرعت جریان؛ g شتاب ثقل زمین؛ ρ و ρ_s به ترتیب چگالی و لزجت پویایی سیال؛ d_{50} قطر متوسط رسوبات؛ σ_g انحراف معیار استاندارد رسوبات؛ K_θ ضریب زاویه‌ی قرارگیری گوشواره و K_G ضریب شکل؛ K_s ضریب زاویه‌ی استفاده از رابطه‌ی فوق می‌توان رابطه‌ی بی بعد زیر را بر اساس تئوری باکینگهام، و بر حسب زمان آبشستگی نهایی (t_e) و بیشینه‌ی عمق آبشستگی به دست آورد (d_{se}):

$$\frac{d_s}{d_{se}} = f\left(\frac{t}{t_e}, \frac{L}{y}, \frac{d_{50}}{L}, F_d, R_e, \sigma_g, K_\theta, K_s, K_G\right) \quad (۲)$$

که در این رابطه، $F_d = U/\sqrt{\Delta g d_{50}}$ برابر با عدد فرود رسوبات بوده و $R_e = UL/\nu$ عدد رینولدز برای گوشواره و $\Delta = (\rho_s - \rho)/\rho$ برابر با چگالی نسبی می‌باشد. با توجه به اینکه در این تحقیق، از گوشواره‌های مستطیل شکل و بدون زاویه (عمود بر کناره‌ی نهر) استفاده شده است، بنابراین $K_\theta = 1$ و $K_s = 1$ می‌باشد. در نهرهای عریض با سطح مقطع مستطیل شکل و در شرایط جریان یکنواخت، K_G تاثیری بر آبشستگی نخواهد داشت، در نتیجه، معادله‌ی (۲) را می‌توان به صورت زیر بازنویسی کرد:

$$\frac{d_s}{d_{se}} = f\left(\frac{t}{t_e}, \frac{L}{y}, \frac{d_{50}}{L}, F_d, R_e, \sigma_g\right) \quad (۳)$$

در صورتیکه $L/d_{50} > 50$ می‌توان از تاثیر رسوبات بستر چشم پوشی کرد (ملویل و کولمن، ۲۰۰۰). بر اساس نظریه‌ی سیمارو و همکاران (۲۰۰۷)، مقدار $I = U/U_c$ که بیانگر نسبت سرعت متوسط جریان به سرعت بحرانی رسوبات می‌باشد را می‌توان معادل با عدد فرود رسوبات (F_d) در نظر گرفت. در شرایطی که $d_{50} > \approx 0.6$

در این رابطه، X_{min} و X_{max} به ترتیب مقادیر کمینه و بیشینه‌ی داده‌ها می‌باشند.

سامانه‌ی فازی - عصبی (Adaptive Neuro-fuzzy inference system):

سامانه‌ی فازی، سامانه‌ای منطبق بر قوانین اگر-آنگاه فازی است که با نظریه‌های احتمال قدیمی تحلیل پذیر نیست. هدف از منطق فازی، استخراج نتایج دقیق، با استفاده از مجموعه‌ای از قوانین است که به‌وسیله‌ی افراد خبیره و متخصص تعریف شده است. از طرفی، شبکه‌های عصبی، قابلیت آموزش و یادگیری دارند و می‌توانند با استفاده از داده‌های مشاهده شده، فراسنجهای شبکه را به گونه‌ای معین کنند که به ازای ورودی دلخواه، خروجی مطلوب حاصل شود. در عین حال، شبکه‌های عصبی، قابلیت استفاده از دانش بشری را ندارند و نمی‌توانند مانند سامانه‌های فازی با استفاده از عبارات زبانی استنتاج کنند. بنابراین، برای دستیابی به قابلیت یادگیری بهتر، دقت تقریب بیشتر و ساختار ساده تر، با الهام از قابلیت یادگیری شبکه‌های عصبی و خواص استنباط سامانه‌های فازی، سامانه‌ی فازی-عصبی ارائه شده است. این شبکه‌ها ضمن داشتن قابلیت یادگیری شبکه‌های عصبی و قدرت استنتاج سامانه‌های فازی، قابلیت یافتن هر نوع شبیه یا نگاشت غیرخطی را دارند و می‌توانند به طور دقیق، ورودیها (مقادیر اولیه) را با خروجی (مقادیر پیش بینی شده) مرتبط سازند (گالو و همکاران ۱۹۹۹). ساختار این سامانه در شکل ۲ نشان داده شده است.

در این ساختار، گره‌های ورودی و خروجی به ترتیب مقادیر ورودی و مقادیر پیش بینی شده را نشان می‌دهند. برای ساده سازی در این شکل، یک شبکه با دو ورودی و یک خروجی در نظر گرفته شده است. بدین ترتیب، می‌توان شبیه فازی مرتبه‌ی اول را بر اساس مجموعه‌ای از قوانین اگر-آنگاه فازی به شکل زیر نشان داد، برای نمونه، دو قانون در زیر آورده شده است:

(۷)

Rule 1: If x is A1 and y is B1, then $f1 = p_1x + q_1y + r1$

(۸)

Rule 2: If x is A2 and y is B2, then $f2 = p_2x + q_2y + r2$

کننده‌ی داده‌ها)، لایه‌ی پنهان (لایه‌ی پردازش داده‌ها) و لایه‌ی خروج (تولید کننده‌ی خروجی به ازای ورودیهای مشخص). یک شبکه می‌تواند از یک یا چند لایه‌ی پنهان تشکیل شود. در غالب مطالعات انجام شده، انتخاب معماری در طراحی شبکه‌های عصبی مصنوعی، با روش سعی و خطا می‌باشد که در آن با استفاده از ارقام مختلف، لایه‌های پنهان و نرونهای مربوط، می‌توان شبکه‌ی بهینه را تعیین نمود. هرچه تعداد لایه‌ها و نرونها افزایش یابد، باعث عملکرد بهتر شبکه، برای دوره‌ی آموزش می‌شود، اما عملکرد برای دوره‌ی آزمون شبکه معمولاً کاهش می‌یابد. این مسأله را برازش بیش از حد می‌نامند (over-fitting). بطوریکه شبکه، با داشتن تعداد زیاد لایه‌ی پنهان و نرونهای مربوط، بیش از اندازه براساس داده‌های دوره‌ی آموزش واسنجی می‌گردد، و قدرت انعطاف برای الگوهای دیگر را از دست می‌دهد.

نحوه‌ی محاسبات در شبکه‌های عصبی بدین شکل است که، ورودیهای به نرون (x_1 تا x_n) در وزنها (w_1 تا w_n) ضرب شده، و مجموع نتایج حاصل از هر ورودی پس از اعمال در یک تابع، خروجی نرون را تشکیل می‌دهد که شبیه ریاضی آن بصورت رابطه‌ی زیر است:

$$n = \sum w_{ij}x_i + b_i \quad (5)$$

b_i برابر با ضریب اربب (Bias) می‌باشد. شبکه‌های عصبی مصنوعی دارای شبیه‌های مختلفی هستند که مبتنی بر جهت ورود اطلاعات و پردازش آنها، به انواع مختلفی تقسیم بندی می‌شوند. در این تحقیق، دو نوع شبکه‌ی عصبی پیشرو (Feed-forward back propagation neural networks) و شعاع مداری (Radial basis function networks)، جهت پیش بینی زمان آبشستگی در اطراف گوشواره‌ها مورد استفاده قرار گرفته است.

در این تحقیق، داده‌های ورودی پس از بهنجار شدن در محدوده‌ی بین ۰.۱ تا ۰.۹ به‌وسیله‌ی رابطه‌ی زیر، به شبکه‌ی عصبی معرفی می‌شود:

(۶)

$$X_n = \frac{(X - X_{min})(0.9 - 0.1)}{(X_{max} - X_{min})} + 0.1$$

(۱۲)

$$\text{for } i=1,2 \quad (O_{2,k} = w_i = \mu_{Ai}(x)\mu_{Bi}(y))$$

• **لایه‌ی سوم:** شامل گره‌های بهنجار شده است که نسبت درجه‌ی مشارکت هر قانون به مجموع درجه‌ی مشارکت همه قوانین را محاسبه می‌کنند، در نتیجه، این لایه به شکل معادله‌ی زیر تعریف می‌شود:

$$\text{for } i=1,2 \quad O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (۱۳)$$

• **لایه‌ی چهارم:** مشتمل بر گره‌های تطبیقی است که با استفاده از فراسنجهای نتیجه، خروجی هر گره را با استفاده از معادله‌ی زیر محاسبه می‌کنند:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (۱۴)$$

که w_i خروجی i امین گره از لایه‌ی قبلی است و i ، p_i و q_i فراسنجهای تطبیقی خطی هستند.

• **لایه‌ی پنجم:** مشتمل بر گره‌های خروجی است که مقدار نهایی خروجی را به شکل مجموع خروجی گره‌های لایه‌ی پیشین، بیان می‌کنند:

$$O_{5,i} = f_{out} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (۱۵)$$

الگوریتم یادگیری سامانه‌ی فازی - عصبی، یک الگوریتم یادگیری هیبریدی، مشتمل بر الگوریتم گرادیان نزولی، و روش کمینه‌ی مربع بازگشتی است. از الگوریتم گرادیان نزولی برای به روزرسانی فراسنجهای غیرخطی شبکه و از تخمین زن کمینه‌ی مربع بازگشتی برای تنظیم وزنهای شبکه استفاده می‌شود. خطای آموزش شبکه به شکل معادله‌ی زیر تعریف شده است:

$$E = \sum_{i=1}^N (f_i - \bar{f}_i)^2 \quad (۱۶)$$

که در آن، f_i و \bar{f}_i به ترتیب خروجی مطلوب و تخمین زده شده‌ی شبکه به ازای i امین ورودی هستند و همچنین N تعداد کل زوج داده‌های ورودی خروجی (داده‌های آموزشی) شبکه است.

در معادله‌های بالا، x و y ورودیهای غیرفازی گره i ام و A_i و B_i توابع عضویت فازی هستند. بطور کلی، سامانه‌ی فازی-عصبی، شبکه‌ای دارای پنج لایه است که هر لایه دارای گره‌های مختلف بوده و هر گره در یک لایه‌ی ثابت یا تطبیقی است. لایه‌های مختلف با گره‌های متناظر آنها به طور خلاصه در زیر توصیف شده‌اند:

• **لایه‌ی اول:** هر گره از این لایه، مقادیر عضویتی است که به هریک از متغیرهای ورودی شبیه (y و x) نسبت داده می‌شود. مقادیر عضویت، بر اساس تعلق ورودیها به مجموعه‌های فازی A_i و B_i معین می‌شود. به عبارت دیگر، خروجی هر گره در این لایه، درجه‌ی عضویت تخصیص داده شده به متغیرهای ورودی در مجموعه‌های فازی است که به شکل زیر بیان می‌شود:

$$\text{for } i=1,2 \quad \text{or} \quad O_{1,i} = \mu_{Ai}(x) \quad (۹)$$

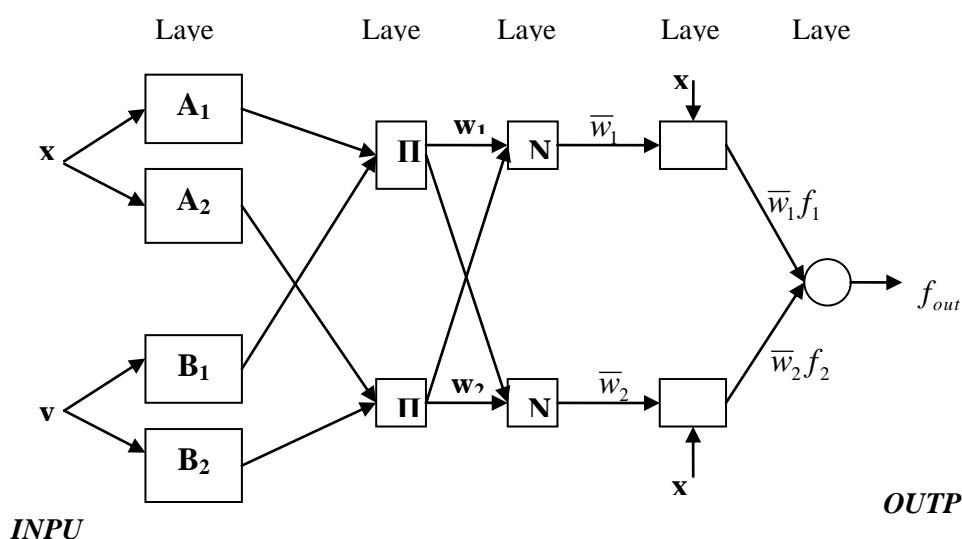
$$\text{for } i=3,4 \quad O_{1,i} = \mu_{Bi-2}(y) \quad (۱۰)$$

مقدار عضویت هر ورودی، به عنوان خروجی لایه‌ی اول با $\mu_{Ai}(x)$ و $\mu_{Bi}(y)$ مشخص می‌شود. بنابراین، باید فراسنجهای توابع عضویت که به عنوان فراسنجهای بخش مقدم قوانین فازی شناخته می‌شوند و از دسته‌ی فراسنجهای غیرخطی هستند، مشخص شوند. در ساختار فازی-عصبی، از فازی (سازهای گوس Gaussian fuzifier) استفاده می‌شود که تابع عضویت همان تابع زنگوله‌ای به صورت زیر می‌باشد:

$$O_{1,i} = \mu_{Ai}(x) = \frac{1}{1 + (x - \frac{c_i}{a_i})^{2b_i}} \quad (۱۱)$$

در این رابطه، فراسنجهای a ، b و c فراسنجهای بنیادی می‌باشند که باعث تغییر شکل تابع عضویت می‌شوند (بوراگوین و ماهانتا ۲۰۰۸).

• **لایه‌ی دوم:** شامل گره‌های قوانین است. هر گره در این لایه، درجه‌ی فعالیت یک قانون را محاسبه می‌کند. در این لایه از عملگر "و" برای محاسبه‌ی درجه‌ی مشارکت هر قانون استفاده می‌شود. $O_{2,k}$ نمایانگر خروجی گره k ام در لایه‌ی دوم و برابر حاصل ضرب درجه‌ی عضویت هر ورودی است.



شکل ۲- ساختار سامانه‌ی فازی-عصبی


آستانه‌ی حرکت رسوبات در نظر گرفته شده بطوری که U/U_c مابین ۰.۹۵ تا ۰.۹۸ قرار گرفت. سرعت بحرانی (U_c) جریان با استفاده از نمودار شیلدز و رابطه‌ی پیشنهادی ملویل (۱۹۹۲) محاسبه شده و در آزمایشگاه قبل از شروع آزمایشهای اصلی، این سرعت مهار گردید. جهت جلوگیری از ایجاد پشته‌ها در سطح اولیه رسوبات، در ابتدای هر آزمایش، نهر به وسیله‌ی شلنگ آب تا ارتفاع مورد نظر پر، و سپس با روشن کردن پمپها آزمایش آغاز می‌شد. در غیر اینصورت، پشته‌های ایجاد شده در سطح رسوبات، باعث ایجاد تغییرات در روند آبشستگی می‌شود. گوشواره‌ها از جنس پلاکسی گلاس شفاف ساخته شده و تغییرات آبشستگی با استفاده از یک دوربین که درون گوشواره نصب شده بود، اندازه‌گیری می‌شد (شکل ۴). در انتهای هر آزمایش، پستی و بلندی حفره‌ی آبشستگی با استفاده از یک لیمینومتر با دقت ± 1 mm برداشت شده است.

نهر آزمایشگاهی:


در این تحقیق، سه نوع گوشواره با طولهایی برابر با ۴، ۵.۵ و ۷ سانتیمتر، جهت بررسی تغییرات آبشستگی انتخاب گردید (جدول ۲). تمامی آزمایشهای انجام شده در این تحقیق، در نهری به طول ۶ متر، عرض ۰.۶ متر و عمق ۰.۶ متر انجام شده است. مکانی جهت رسوبها (sediment reces)، در ۳.۵ متری از ابتدای نهر در نظر گرفته شد (شکل ۳) و جهت کاهش انرژی جریان و فراهم آوردن یک جریان کاملا توسعه یافته و یکنواخت در این نقطه، از یکسری صفحات مشبک در ورودی نهر استفاده شده است. رسوبات انتخاب شده برای تمامی آزمایشها دارای انحراف معیار $\sigma_D = 1.2$ و قطر متوسط $d_{50} = 0.60$ mm می‌باشد. هم‌چنین عمق جریان به گونه‌ای انتخاب شده است که تاثیری بر روی آبشستگی نداشته باشد و بیشینه‌ی عمق آبشستگی، سرعت جریان نزدیک به $(L/y < I)$ برای فراهم نمودن شرایط آبشستگی آب زلال و

جدول ۲- خلاصه‌ای از نتایج و شرایط آزمایشگاهی

TEST	Q (lit/sec)	U/Uc	time (min)	L (cm)	B (cm)	y (cm)	L/y	ds (cm)
AB-1	۱۸/۰۰	۰/۹۶	۳۰/۵۲	۴/۰۰	۸/۰۰	۱۱/۱۰	۰/۳۶	۶/۷۰
AB-2	۱۸/۶۰	۰/۹۸	۴۰/۰۴	۵/۵۰	۱۱/۰۰	۱۱/۰۰	۰/۵۰	۹/۵۰
AB-3	۱۶/۰۰	۰/۹۵	۵۰/۸۰	۷/۰۰	۱۴/۰۰	۹/۷۰	۰/۷۲	۱۱/۸۰



شکل ۳- نهر آزمایشگاهی



شکل ۴- نمایی از دوربین طراحی شده در گوشواره

از شروع آزمایش‌ها، دارای نرخ تغییرات کمتر از ۱ میلی‌متر در یک بازه‌ی ۷ ساعته می‌باشد، که مقدار بسیار زیادی از آبشستگی (بیش از ۹۵٪) در این مدت بازه‌ی زمانی رخ داده است. بنابراین، این معیار به عنوان زمان آبشستگی در همه‌ی آزمایش‌ها انتخاب شد.

همانگونه که در جدول ۳ و شکل ۵ نشان داده شده است، تغییرات آبشستگی در زمانهای ابتدایی بسیار سریع بوده، بطوریکه تقریباً ۵۰٪ آبشستگی در ۲ ساعت ابتدایی رخ داده، و نرخ این تغییرات با گذشت زمان بتدیح کاهش می‌یابد. جهت صحت سنجی نتایج و همچنین پیش بینی آبشستگی در اطراف گوشواره‌ها، مقادیر حاصل، از آزمایشگاه انجام شده در این تحقیق با نتایج ارائه شده به‌وسیله‌ی دیگر محققین، از جمله پانماز و کوس، (۲۰۰۷)، دی و باربویا، (۲۰۰۵)، بالیو و اورسی، (۲۰۰۱)، کاردوسو و بیتس، (۱۹۹۹)، مقایسه شده است (شکل ۶). در این شکل، محور افقی و قائم به ترتیب با استفاده از

نتایج آزمایشگاهی:

بطور کلی، روند آبشستگی در اطراف گوشواره‌ها، وابسته به زمان بوده و لگاریتمی می‌باشد. روند تغییرات عمق آبشستگی بر حسب زمان برای هر سه گوشواره AB-1، AB-2 و AB-3 (جدول ۳) در شکل ۵ نشان داده شده است.

زمان آبشستگی نهایی با توجه به معیار گفته شده به‌وسیله‌ی کولمن و همکاران (۲۰۰۳)، انتخاب گردیده است. در این معیار، زمان آبشستگی نهایی، زمانی می‌باشد که در یک بازه‌ی زمانی ۲۴ ساعته، تغییرات عمق آبشستگی بیش از ۵٪ بعد گوشواره یا پایه نباشد. سه آزمایش با مدت زمانهای $t=3052 \text{ min}$ ، $t=4004 \text{ min}$ و $t=5080 \text{ min}$ به ترتیب برای گوشواره‌های AB-1، AB-2 و AB-3 انجام شد که نتایج آن در جدول ۳ آورده شده است. نتایج حاصله نشان می‌دهد که تغییرات آبشستگی پس از گذشت حدود ۴۲ ساعت (۲۵۰۰ دقیقه)

می‌باشد. نتایج نشان می‌دهند که، تقریباً ۸۰٪ الی ۹۰٪ بیشینه‌ی عمق آبخستگی در ۱۰ الی ۲۰٪ زمان آبخستگی نهایی رخ می‌دهد.

زمان آبخستگی نهایی (t_e) و بیشینه‌ی عمق آبخستگی (d_{se}) بی‌بعد شده‌اند. نتایج آزمایشگاهی بدست آمده با نتایج دیگر محققین کاملاً مطابقت دارد، که این مسأله، نشان دهنده‌ی صحت آزمایشهای انجام شده

جدول ۳- تغییرات عمق آبخستگی برای گوشواره‌های AB-1 و AB-2, AB-3

Time (min)	AB-III ds (cm)	AB-III ds (%)	AB-II ds (cm)	AB-II ds (%)	AB-I ds (cm)	AB-I ds (%)
۵	۵/۱۰	۴۳/۲۲	۲/۴	۲۵/۲۶	۱/۸۰	۲۶/۸۷
۱۰	۵/۹۰	۵۰	۲/۶۰	۲۷/۳۷	۲/۳۰	۳۴/۳۳
۱۵	۶/۳۰	۵۲/۳۹	۲/۹۰	۳۰/۵۳	۲/۵۰	۳۷/۳۱
۲۰	۶/۶۰	۵۵/۹۳	۳/۱۰	۳۲/۶۳	۲/۷۰	۴۰/۳
۳۰	۷/۱۰	۶۰/۱۷	۳/۵۰	۳۶/۸۴	۲/۸۰	۴۱/۷۹
۶۰	۸/۰۰	۶۷/۱۸	۳/۹۰	۴۱/۰۵	۳/۲۰	۴۷/۷۶
۹۰	۸/۲۰	۶۹/۴۹	۴/۳۰	۴۵/۲۶	۳/۴۰	۵۰/۷۵
۱۲۰	۸/۴۵	۷۱/۶۱	۴/۸۰	۵۰/۵۳	۳/۴۰	۵۰/۷۵
۱۵۰	۸/۵۵	۷۲/۴۶	۴/۹۰	۵۱/۵۸	۳/۶۰	۵۳/۷۳
۱۸۰	۸/۶۰	۷۲/۸۸	۵/۳۰	۵۵/۷۹	۳/۸۰	۵۶/۷۲
۲۴۰	۸/۷۵	۷۴/۱۵	۵/۷۰	۶۰	۳/۹۰	۵۸/۲۱
۳۰۰	۸/۹۰	۷۵/۴۲	۶/۱۰	۶۴/۲۱	۴/۱۰	۶۱/۱۹
۳۶۰	۹/۱۰	۷۷/۱۲	۶/۴۰	۶۷/۳۷	۴/۳۰	۶۴/۱۸
۴۲۰	۹/۲۰	۷۷/۹۷	۶/۵۰	۶۸/۴۲	۴/۴۰	۶۵/۶۷
۴۸۰	۹/۲۰	۷۷/۹۷	۶/۷۰	۷۰/۵۳	۴/۶۰	۶۸/۶۶
۵۴۰	۹/۵۰	۸۰/۵۱	۷/۰۰	۷۳/۶۸	۴/۹۰	۷۳/۱۳
۶۰۰	۹/۶۰	۸۱/۳۵	۷/۵۰	۷۸/۹۵	۵/۱۰	۷۶/۱۲
۶۶۰	۹/۶۰	۸۱/۳۵	۷/۶۰	۸۰	۵/۳۰	۷۹/۱
۱۰۰۰	۱۰/۰۰	۸۴/۷۵	۸/۰۰	۸۴/۲۱	۵/۷۰	۸۵/۰۷
۱۵۰۰	۱۰/۴۵	۸۸/۵۶	۸/۳۰	۸۷/۳۷	۶/۲۰	۹۲/۵۴
۲۰۰۰	۱۱/۱۰	۹۴/۰۷	۸/۹۰	۹۳/۶۸	۶/۳۰	۹۴/۰۳
۲۵۰۰	۱۱/۴۰	۹۶/۶	۹/۲۰	۹۶/۸۴	۶/۶۰	۹۸/۵۱
۳۰۵۲	۱۱/۴۵	۹۷/۰۳	۹/۳۰	۹۶/۸۴	۶/۷۰	۱۰۰
۳۵۰۰	۱۱/۵۰	۹۷/۴۵	۹/۴۰	۹۸/۹۵	----	----
۴۰۰۰	۱۱/۶۰	۹۸/۳	۹/۵۰	۱۰۰	----	----
۴۵۰۰	۱۱/۷۵	۹۹/۵۸	----	----	----	----
۵۰۸۰	۱۱/۸۰	۱۰۰	----	----	----	----

قرار گرفته است. جدول ۴، خلاصه‌ای از داده‌های مورد استفاده در این تحقیق را ارائه می‌دهد. فراسنجهای موجود در این جدول عبارتند از زمان نسبی (t/t_e)، طول نسبی (L/y)، سرعت نسبی (U/U_c)، عمق جریان (y)، طول گوشواره (L)، سرعت متوسط جریان (U)، سرعت بحرانی (U_c)، قطر متوسط رسوبات (d_{50}) و انحراف معیار استاندارد (σ_g). با توجه به نسبت L/y ، گوشواره‌های انتخابی عبارتند از گوشواره‌ها با طول کوتاه ($L/y \leq 1$) و طول متوسط ($1 < L/y \leq 25$).

پیش بینی آبخستگی به وسیله روش وایازی (Nonlinear Regression):

در این تحقیق، از سه روش وایازی، ANNs و ANFIS جهت پیش بینی عمق آبخستگی استفاده شده است. مجموعه‌ی همه‌ی داده‌های جمع‌آوری شده در آزمایشگاه و مطالعات پیشین، برابر با ۱۳۶۸ داده می‌باشد که در حدود ۸۰٪ این داده‌ها (۱۰۹۵ داده) برای آموزش، و مابقی ۲۰٪ (۲۷۳ داده) جهت آزمایش مورد استفاده

تغییرات عمق آبستنگی در اطراف گوشواره‌ها پیشنهاد می‌گردد:

$$\frac{d_s}{d_{se}} = \exp \left[-0.12 \left(\frac{U}{U_c} \right)^{-0.44} \left(\frac{y}{L} \right)^{0.12} \left| \ln \left(\frac{t}{t_e} \right) \right|^{1.12} \right] \quad (20)$$

در شکل ۷، مقایسه‌ی ای بین مقدار مشاهده شده در آزمایشگاه و مقدار پیش بینی شده به وسیله‌ی رابطه‌ی بالا ارائه شده است. این رابطه، قادر به تخمین عمق آبستنگی با دقت مناسب می‌باشد ($R^2=0.957$, $RMSE=0.049$ و $MAE=0.03$). مقایسه‌ی نتایج حاصله از این رابطه با نتایج محققان دیگر در جدول ۶ ارائه شده است.

جهت بررسی دقت روشهای ذکر شده، سه نوع فراسنج آماری انتخاب شده که عبارتند از ضریب تشخیص (R^2)، ریشه‌ی مربع خطا (RMSE) و متوسط خطا (MAE)؛ معادلات مربوط به این فراسنجهای عبارتند از:

$$R^2 = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \quad (17)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (18)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (19)$$

در روابط فوق O_i و P_i به ترتیب داده‌های مشاهده شده و پیش بینی شده بوده و n تعداد داده‌ها می‌باشد.

بر اساس سه فراسنج بی بعد ارائه شده در رابطه (۴)،

رابطه‌ی زیر به روش وایازی غیرخطی برای پیش بینی

جدول ۴- محدوده‌ی داده‌های مورد استفاده در روشهای ارائه شده

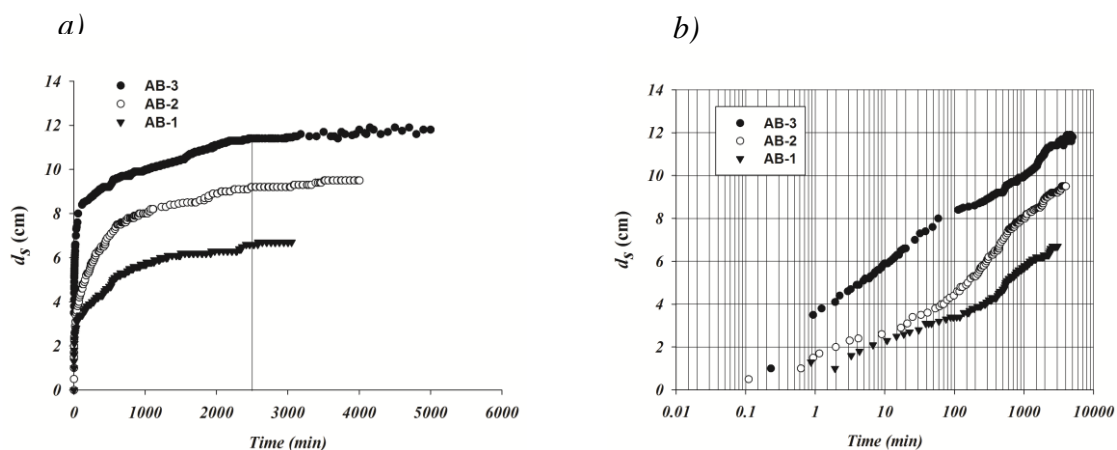
Parameter	Training		Testing	
	Maximum	Minimum	Maximum	Minimum
t/t_e	۰	۱	۰	۱
L/y	۰/۲۷	۱۴/۵۴	۰/۲۷	۱۴/۵۴
U/U_c	۰/۶۳	۱	۰/۶۳	۱
$y(cm)$	۳/۲	۲۰	۳/۲	۲۰
$L(cm)$	۴	۸۰	۴	۸۰
$U(m/s)$	۰/۲۶	۰/۸۹	۰/۲۶	۰/۸۹
$U_c(m/s)$	۰/۲۸	۱/۰۶	۰/۲۸	۱/۰۶
$d_{50}(mm)$	۰/۲۶	۵	۰/۲۶	۵
σ_g	۱/۱۴	۱/۳۸	۱/۱۴	۱/۳۸
No. of data	۱۰۹۵		۲۷۳	

جدول ۵- نتایج شبکه‌های عصبی با تعداد نرونهای مختلف در لایه‌ی پنهان

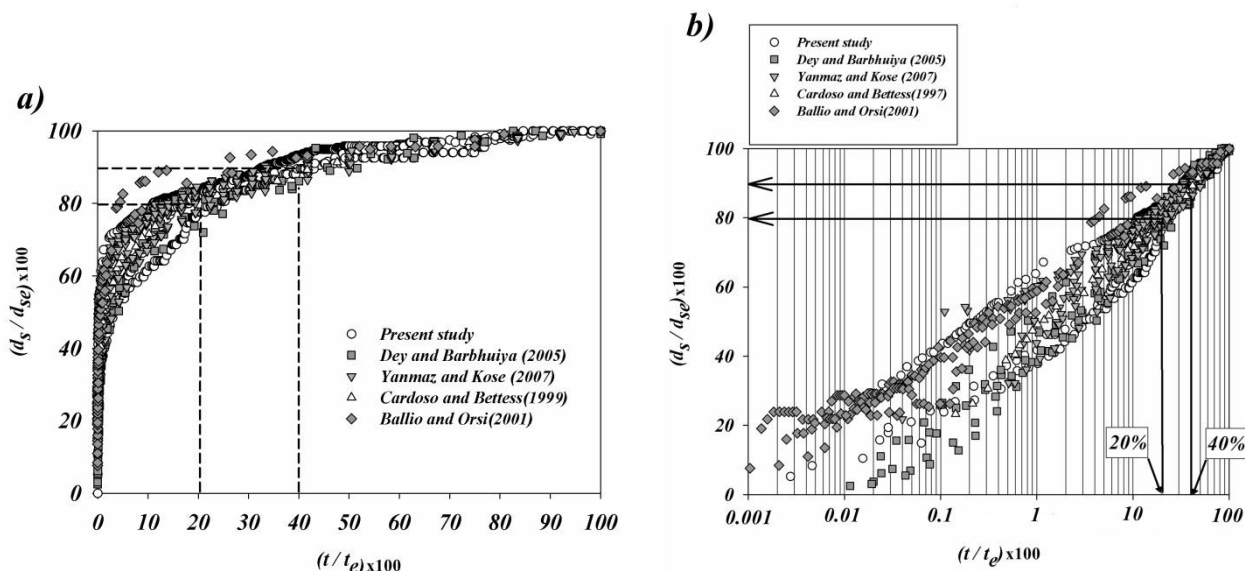
Network	No. of Neurons		آموزش (Training)			تست (Testing)		
	First layer	Second layer	R ²	RMSE	MAE	R ²	RMSE	MAE
شبکه‌ی پیشرو (FFBP) با یک لایه‌ی پنهان	۱۱	-	۰/۹۹۳۴	۰/۰۱۷۶	۰/۰۱۱۳	۰/۹۹۰۹	۰/۰۲۰۱	۰/۰۱۲۵
	۱۲	-	۰/۹۹۲۱	۰/۰۱۹۲	۰/۰۱۲۷	۰/۹۸۳۹	۰/۰۲۶۸	۰/۰۱۴۹
	۱۳	-	۰/۹۹۳۱	۰/۰۱۷۹	۰/۰۱۱۵	۰/۹۹۴۶	۰/۰۱۵۴	۰/۰۱۰۶
	۱۴	-	۰/۹۹۲۲	۰/۰۱۹۲	۰/۰۱۱۸	۰/۹۸۲۷	۰/۰۲۷۷	۰/۰۱۴۴
	۱۵	-	۰/۹۹۵۰	۰/۰۱۵۳	۰/۰۱۰۰	۰/۹۹۱۰	۰/۰۱۹۲	۰/۰۱۱۹
شبکه‌ی پیشرو (FFBP) با دو لایه‌ی پنهان	۷	۷	۰/۹۹۶۶	۰/۰۱۲۶	۰/۰۰۸۷	۰/۹۹۳۶	۰/۰۱۶۸	۰/۰۱۰۷
	۸	۸	۰/۹۹۵۵	۰/۰۱۴۶	۰/۰۰۹۷	۰/۹۹۰۶	۰/۰۲۰۴	۰/۰۱۲۰
	۹	۹	۰/۹۹۸۱	۰/۰۰۹۴	۰/۰۰۶۳	۰/۹۹۵۰	۰/۰۱۴۹	۰/۰۰۸۸
	۱۰	۱۰	۰/۹۹۸۶	۰/۰۰۸۱	۰/۰۰۵۳	۰/۹۹۷۱	۰/۰۱۱۴	۰/۰۰۶۷
	۱۱	۱۱	۰/۹۹۸۸	۰/۰۰۷۴	۰/۰۰۴۸	۰/۹۹۷۴	۰/۰۱۰۶	۰/۰۰۶۳
	۱۲	۱۲	۰/۹۹۷۶	۰/۰۱۰۶	۰/۰۰۶۵	۰/۹۸۷۶	۰/۰۲۳۵	۰/۰۱۱۸
شبکه‌ی شعاع مداری (RBF) (Spread Constant=0.8)	-	-	۰/۸۷۲۶	۰/۰۷۷۳	۰/۰۵۱۸	۰/۸۶۶۹	۰/۰۷۶۸	۰/۰۵۱۷
	13	-	۰/۸۷۲۵	۰/۰۷۷۴	۰/۰۵۱۸	۰/۸۶۶۸	۰/۰۷۶۹	۰/۰۵۱۷
	14	-	۰/۸۸۰۷	۰/۰۷۴۸	۰/۰۴۹۷	۰/۸۷۱۱	۰/۰۷۵۶	۰/۰۵۰۲
	15	-	۰/۸۸۰۸	۰/۰۷۴۸	۰/۰۴۹۷	۰/۸۷۱۱	۰/۰۷۵۶	۰/۰۵۰۲
	20	-	۰/۸۹۵۸	۰/۰۶۹۹	۰/۰۴۵۸	۰/۸۹۵۸	۰/۰۶۸۰	۰/۰۴۵۱
	30	-	۰/۹۱۹۲	۰/۰۶۱۶	۰/۰۴۲۱	۰/۹۱۰۵	۰/۰۶۳۰	۰/۰۴۳۵
	58	-	۰/۹۳۴۷	۰/۰۵۵۴	۰/۰۳۶۹	۰/۹۳۲۴	۰/۰۵۴۷	۰/۰۳۸۲
	60	-	۰/۹۳۶۷	۰/۰۵۴۵	۰/۰۳۶۲	۰/۹۱۱۱	۰/۰۶۲۸	۰/۰۳۹۳

جدول ۶- مقایسه‌ی نتایج حاصل از روشهای مختلف جهت پیش بینی تغییرات آبشستگی در اطراف گوشواره‌ها

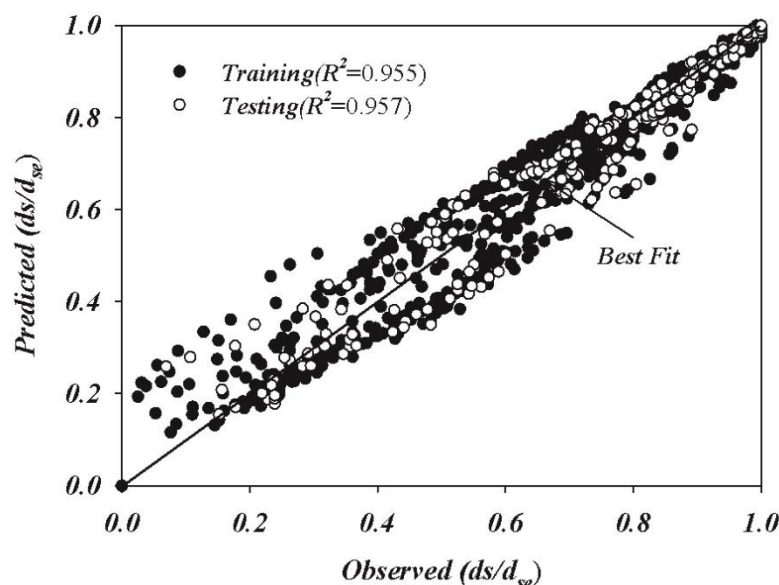
Method	Training			Testing		
	R ²	RMSE	MAE	R ²	RMSE	MAE
FFBP-two hidden layer	۰/۹۹۸	۰/۰۰۷۴	۰/۰۰۴۸	۰/۹۹۷	۰/۰۱۰۶	۰/۰۰۶۳
ANFIS-grid partition	۰/۹۶۰	۰/۰۴۳	۰/۰۲۴	۰/۹۶۱	۰/۰۴۱	۰/۰۲۵
Presented MLR (Eq.20)	۰/۹۵۵	۰/۰۵۲	۰/۰۳۶	۰/۹۵۷	۰/۰۴۹	۰/۰۳۵
ANFIS-subtractive clustering	۰/۹۴۶	۰/۰۵۰	۰/۰۲۸	۰/۹۴۴	۰/۰۵۰	۰/۰۲۹
Coleman et al.(2003)	۰/۹۴۰	۰/۰۷۲	۰/۰۵۴	۰/۹۴۵	۰/۰۶۸	۰/۰۵۰
Cardoso and Bettess(1999)	۰/۹۴۲	۰/۰۹۹	۰/۰۸۳	۰/۹۴۲	۰/۰۹۹	۰/۰۸۳
RBF-ANN	۰/۹۳۵	۰/۰۵۵	۰/۰۳۷	۰/۹۳۲	۰/۰۵۵	۰/۰۳۸
Ballio and Orsi (2001)	۰/۷۰۴	۰/۳۱۰	۰/۲۷۹	۰/۷۰۶	۰/۳۰۱	۰/۲۷۲
Oliveto and Hager (2002)	۰/۵۴۸	۰/۷۶۴	۰/۶۰۵	۰/۵۱۱	۰/۸۱۵	۰/۶۵۳
Yanmaz and Kose (2007)	۰/۴۶۳	۰/۴۱۹	۰/۳۱۲	۰/۴۳۲	۰/۴۳۵	۰/۳۳۴



شکل ۵- تغییرات عمق آبستگي بر حسب زمان (a) مقیاس بهنجار (b) مقیاس لگاریتمی



شکل ۶- مقایسه‌ی بین نتایج بدست آمده از این تحقیق و تحقیقات پیشین (a) مقیاس بهنجار (b) مقیاس لگاریتمی



شکل ۷- مقایسه‌ی بین داده‌های مشاهده شده و پیش‌بینی شده توسط رابطه‌ی وابازی

شبکه‌ی شعاع مداری و پیش‌خور کاهش می‌یابد. در شبکه‌ی پیش‌خور با دو لایه‌ی پنهان، با بیش از ۱۱ عدد نرون در لایه‌ی پنهان، پدیده‌ی *over-fitting* رخ می‌دهد (جدول ۵) که جهت خوانا بودن شکل، تغییرات با بیش از ۱۱ نرون در این شکل منعکس نشده است. نتایج حاصل از انواع شبکه‌های عصبی با تعداد نرونهای مختلف در لایه‌ی پنهان، در جدول ۵ قید شده است. در ارزیابی داده‌های انتخاب شده برای آزمایش شبکه‌ی عصبی (*testing data*)، نتایج حاصل از مقادیر آماری R^2 و RMSE نشان می‌دهد که بهینه‌ترین تعداد نرونها در لایه‌ی پنهان، برای شبکه‌ی عصبی پیش‌خور با یک لایه و دو لایه‌ی پنهان، به ترتیب عبارتند از ۱۳ و ۱۱ نرون در هر لایه، در حالیکه این مقدار برای شبکه‌ی عصبی شعاع مداری برابر با ۵۸ نرون در لایه‌ی پنهان می‌باشد. مقادیر فراسنجهای آماری نشان می‌دهند که، شبکه‌ی عصبی پیش‌خور با دو لایه‌ی پنهان و ۱۱ نرون در هر لایه ($R^2=0.997$ ، $RMSE=0.0106$ و $MAE=0.0063$) قادر به تخمین تغییرات عمق آبستگي با دقت بالاتری نسبت به شبکه‌ی عصبی با یک لایه‌ی پنهان و ۱۳ نرون ($R^2=0.995$ ، $RMSE=0.0154$ و $MAE=0.0106$) می‌باشد. همچنین، در مقایسه با شبکه‌های عصبی شعاع مداری با ۵۸ نرون در لایه‌ی پنهان ($MAE=0.0382$) و

پیش‌بینی تغییرات آبستگي توسط شبکه‌ی عصبی:

جهت پیش‌بینی تغییرات عمق آبستگي بوسیله‌ی شبکه‌های عصبی، از شبکه‌ی عصبی شعاع مداری (RBF) و دو نوع شبکه‌ی عصبی پیش‌خور (FFBP)، یک لایه و دو لایه پنهان، استفاده شده است. در ساختار شبکه‌ی عصبی از تابع سیگموئید (*log-sigmoid transfer function*) در لایه‌ی پنهان، و از تابع پرلین (*purelin*) در لایه‌ی خروجی استفاده شده است. سه فراسنج بی بعد t/t_e ، L/y و U/U_c به عنوان ورودی شبکه، و فراسنج نسبت عمق آبستگي (d_s/d_{se}) به عنوان خروجی معرفی شده است. بر اساس روش سعی و خطا، بهترین جوابهای بدست آمده برای شبکه‌ی عصبی شعاع مداری (RBF) با *spread* constant برابر با ۰.۸ و *epochs* برابر با ۲۰۰۰ است.

با افزایش تعداد نرونها در لایه‌ی پنهان، شبکه‌ی عصبی دارای عملکرد بهتری برای دوره‌ی آموزش می‌شود، اما عملکرد آن برای دوره‌ی آزمون شبکه معمولاً کاهش می‌یابد (شین و پارک، ۲۰۱۰) که اصطلاحاً به آن *over-fitting* گفته می‌شود. جهت جلوگیری از این مسأله، شبکه‌ی عصبی با تعداد نرونهای مختلف مورد بررسی قرار گرفت، و نتایج بدست آمده، با استفاده از فراسنج متوسط خطا (MAE) مورد ارزیابی قرار گرفت (شکل ۸).

با توجه به این شکل، با افزایش تعداد نرونها در لایه‌ی پنهان، مقدار متوسط خطا (MAE) در هر دو نوع

جوابهای بهتری ($R^2=0.961$, $RMSE=0.043$, $MAE=0.0424$) نسبت به روابط تجربی پیشین و همچنین روش وایزی ارائه شده (رابطه‌ی ۲۰) می‌باشد. این مطلب در مورد روش شعاع مداری شبکه‌های عصبی (RBF) نیز صدق می‌کند ($R^2=0.932$, $RMSE=0.0547$, $MAE=0.0382$). هر چند که رابطه‌ی وایزی ارائه شده، یک رابطه‌ی با کاربرد بالا و دقت خوب بوده، ولی در مواردی که رایانه به سادگی در دسترس نیست، این رابطه جنبه‌ی عملی بیشتری خواهد داشت.

شکل ۱۱، مقادیر باقیمانده برای روشهای ذکر شده در این تحقیق را نشان می‌دهد. پراکندگی مقادیر باقیمانده برای هر دو روش شبکه‌ی عصبی (FFBP) و سامانه‌ی فازی-عصبی (ANFIS) کمتر از دو روش وایزی و RBF می‌باشد. این مطلب بیانگر این واقعیت است که ANFIS یک روش بسیار مناسب و قدرتمند جهت پیش بینی تغییرات آبشستگی در اطراف گوشواره‌ها می‌باشد و می‌تواند به عنوان یک روش مناسب در کنار شبکه‌های عصبی FFBP مورد استفاده قرار بگیرد.

نتیجه گیری:

تغییرات آبشستگی در اطراف گوشواره‌ها وابسته به زمان می‌باشد، لذا، تحقیق پیرامون این پدیده امری ضروری جهت پیش‌گیری از تخریب پلها می‌باشد. در این تحقیق، تغییرات عمق آبشستگی در اطراف گوشواره‌ها در شرایط آب زلال به صورت آزمایشگاهی مورد بررسی قرار گرفته و اطلاعات برای دو نوع گوشواره با طول کوتاه ($L/y \leq 1$) و همچنین طول متوسط ($1 < L/y \leq 25$) جمع آوری شده است. جهت پیش‌بینی تغییرات عمق آبشستگی در اطراف گوشواره‌ها از سه روش وایزی، شبکه‌های عصبی و سامانه‌ی فازی-عصبی (ANFIS) استفاده شده است. در شبکه‌های عصبی از دو نوع شبکه به نامهای شبکه پیشخور (FFBP) و شعاع مداری (RBF) و همچنین در سامانه‌ی فازی-عصبی نیز از دو نوع سامانه‌ی subtractive clustering و گرید پارتیشن استفاده شده است. نتایج حاصله نشان داد، هر چند رابطه‌ی وایزی ارائه شده (رابطه‌ی ۲۰) دارای جوابهای بهتری نسبت به روابط پیشین می‌باشد ($R^2=0.957$, $RMSE=0.049$ and $MAE=0.035$)، اما روش grid partition در سامانه‌ی

شبکه‌ی عصبی پیشرو با ($R^2=0.932$, $RMSE=0.0547$)، دارای دقت بالاتری خواهد بود.

بررسی تغییرات آبشستگی به وسیله‌ی سامانه‌ی فازی-عصبی:

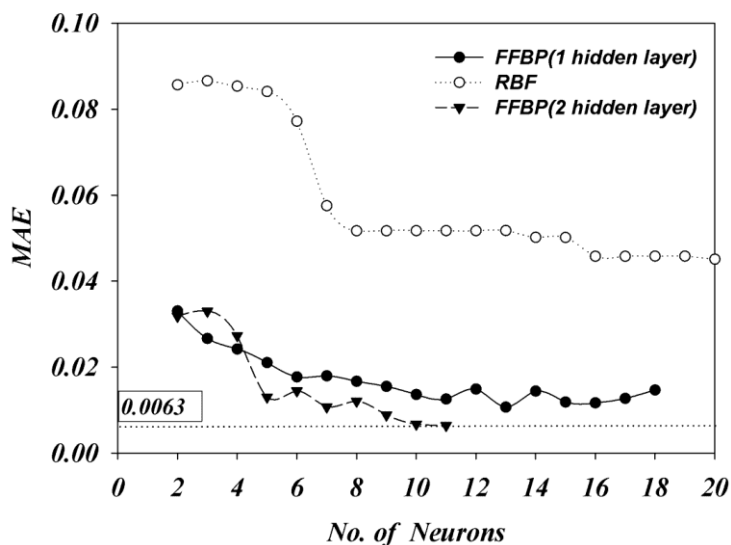
در این تحقیق، سامانه‌ی فازی-عصبی (ANFIS) نیز بر اساس داده‌های مورد استفاده در شبکه‌های عصبی مورد آموزش قرار گرفت. در تمام شبیه‌سازهای سامانه‌ی فازی-عصبی برای یافتن ارتباط بین فراسنجه‌ها، از محیط نرم افزار MATLAB استفاده شده است. بدین منظور، دو شبیه‌متفاوت گرید پارتیشن (grid partition) و subtractive clustering برای پیش‌بینی خروجیها (تغییرات عمق آبشستگی) توسعه داده شده است. با استفاده از روش سعی و خطا در شبیه subtractive clustering، مقدار بهینه‌ی cluster radius برابر با ۰.۱۳ و تعداد قوانین (rules) برابر با ۱۹ بدست آمده است. در حالیکه مقدار بهینه‌ی قوانین در شبیه grid partition برابر با ۲۷ قانون می‌باشد. در این شبیه، از تابع زنگوله‌ای (generalized bell-shape) به عنوان تابع عضویت (membership function) استفاده شده است. سامانه‌ی فازی-عصبی گرید پارتیشن در شکل ۹ نشان داده شده است که شامل سه متغیر ورودی، زمان نسبی (t/t_e)، طول نسبی (L/y) و سرعت نسبی (U/U_c) بوده و خروجی آن نسبت عمق آبشستگی در زمانهای مختلف (d_s/d_{se}) می‌باشد.

خلاصه نتایج حاصل از سامانه‌ی فازی-عصبی در جدول ۶ ارائه شده است. نتایج نشان می‌دهند که روش grid partition در سامانه‌ی فازی-عصبی قادر به پیش‌بینی تغییرات آبشستگی با دقت بالاتری ($R^2=0.961$, $RMSE=0.041$ and $MAE=0.025$) نسبت به روش subtractive clustering می‌باشد ($R^2=0.944$, $RMSE=0.050$ and $MAE=0.029$).


نتایج حاصله از جدول ۶ نشان می‌دهند که، معادله‌ی پیشنهاد شده در این تحقیق (رابطه‌ی ۲۰)، دارای دقت بالاتری ($R^2=0.957$ and $MAE=0.035$) نسبت به روابط تجربی پیشین از جمله (Coleman et al 2003) می‌باشد (شکل ۱۰). نتایج حاصل نشان می‌دهند که، روش گرید پارتیشن سامانه‌ی فازی-عصبی دارای

فازی-عصبی ($R^2=0.961$, $RMSE=0.041$ and $MAE=0.025$)
 دقت بالاتری هستند. $RMSE=0.0106$ and $MAE=0.0063$ دارای نتایج با

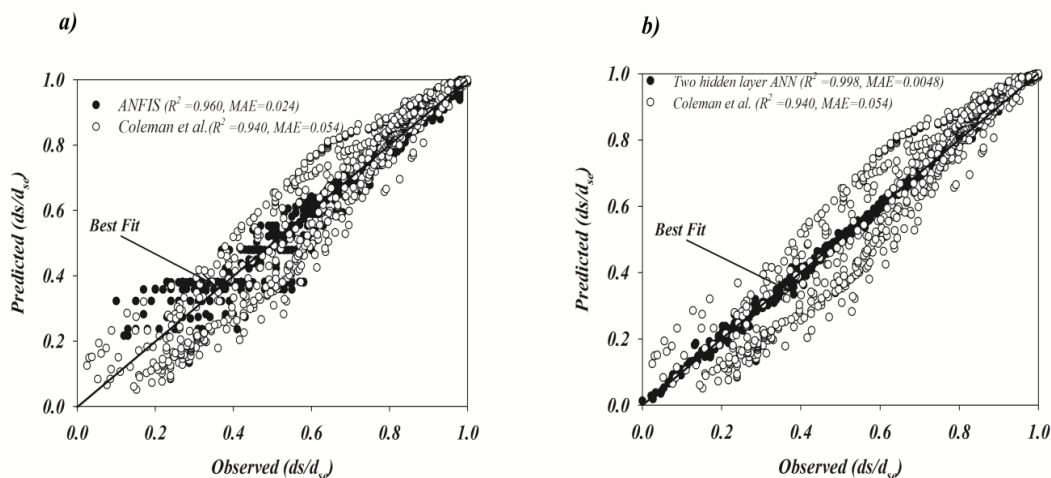
پنهان و ۱۱ نرون در هر لایه‌ی پنهان ($R^2=0.997$, $RMSE=0.0106$ and $MAE=0.0063$)



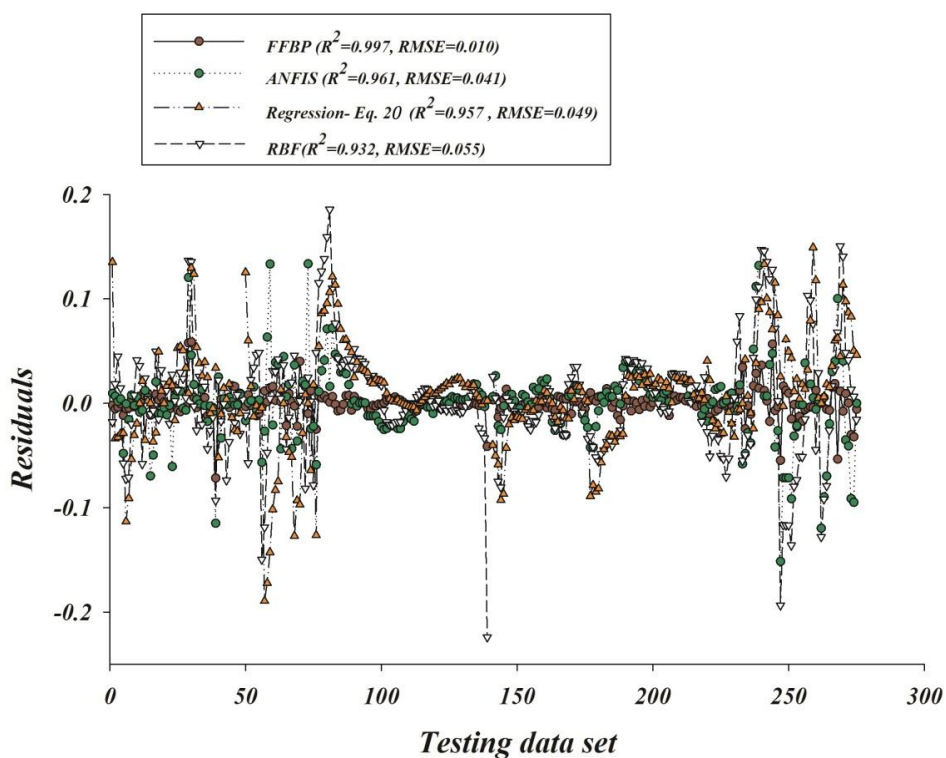
شکل ۸- تغییرات متوسط خطا در شبکه‌ی عصبی بر حسب تعداد نرونها در لایه‌ی پنهان



شکل ۹- سناریو مورد استفاده در سامانه‌ی فازی-عصبی **grid partition** با ۲۷ قانون



شکل ۱۰- مقایسه‌ی نتایج بین معادله‌ی ارائه شده توسط Coleman et al. (2003) و (a) سامانه‌ی فازی-عصبی؛ (b) سامانه‌ی فازی-عصبی با دو لایه‌ی پنهان



شکل ۱۱- مقادیر باقیمانده برای روشهای وایزنی، ANFIS و ANN

- منابع**
12. Cardoso, A.H., and C.M.S Fael. 2010. Time to equilibrium scour at vertical-wall bridge abutments. Proceedings of the Institution of Civil Engineers-Water Management. 163: 509-513.
 13. Choi, S.U., and S. Cheong. 2006. Prediction of local scour around bridge piers using artificial neural networks. J. Am. Water Resour. Assoc. 42:487-494.
 14. Coleman, S.E., C.S. Lauchlan, and B.W. Melville. 2003. Clear-water scour development at bridge abutments. J. Hydraul. Res. 41: 521-531.
 15. Dey, S., and A.K. Barbhuiya. 2005. Time variation of scour at abutments. J. Hydraul. Eng-ASCE. 131: 11-23.
 16. Firat, M. 2009. Scour depth prediction at bridge piers by Anfis approach. Proceedings of the Institution of Civil Engineers: Water Management, 162: 279-288.
 17. Gallo, G., I. Perfilieva, M. Spagnuolo, and S. Spinello. 1999. Geographical data analysis via mountain function. Int. J. Intell. Syst. 14: 359-373.
 18. Melville, B.W. 1992. Local scour at bridge abutments. J. Hydraul. Eng. 118:615-631.
 19. Melville, B.W., and S.E. Coleman. 2000. Bridge scour. Highlands Ranch, Colorado:Water Resources Publications.
 20. Mohammadpour, R., A. Ab Ghani, and H.M. Azamathulla. 2012. Prediction of equilibrium scour time around long abutments. Proceedings of the ICE - Water Management. 7: 394-401.
 21. Mohammadpour, R., A. Ab Ghani, and H.M. Azamathulla. 2013. Estimation of dimension and time variation of local scour at short abutment. International Journal of River Basin Management. 11: 121-135.
 22. Muzzammil, M. 2010. ANFIS approach to the scour depth prediction at a bridge abutment. J. Hydroinf. 12:474-485.
 23. Muzzammil, M. 2011. ANFIS-base approach to scour depth prediction at abutment in armored bed. J. Hydroinf. 13:669-713.
 24. Najafzadeh, M., G.A. Barani, and M.R.H. Kermani. 2013a. Abutment scour in clear-water and live-bed conditions by GMD
 1. Azamathulla, H.M. 2012. Gene-expression programming to predict scour at a bridge abutment. J. Hydroinf. 14: 324-331
 2. Azmathullah, H.M., M.C. Deo, and P.B. Deolalikar. 2005. Neural Networks for Estimation of Scour Downstream of a Ski-Jump Bucket. J. Hydraul. Eng. 131: 898-908.
 3. Azamathulla, H.M., M.C. Deo, and P.B. Deolalikar. 2008. Alternative neural networks to estimate the scour below spillways. Adv. Eng. Softw. 39:689-698.
 4. Azamathulla, H.M., and A.A. Ghani. 2011. ANFIS-Based approach for predicting the scour depth at culvert outlets. J. Pipeline Syst. Eng. Pract. 2: 35-40.
 5. Azamathulla, H.M., A.A. Ghani, and S.Y. Fei. 2012. ANFIS-based approach for predicting sediment transport in clean sewer. Appl. Soft Comput. 12:1227-1230.
 6. Begum, S.A., A.K.M. Fujail, and A.K. Barbhuiya. 2011. Radial basis function to predict scour depth around bridge Abutment. 2nd National Conference on Emerging Trends and Applications in Computer Science, Shillong, Meghalaya, India. 76-82.
 7. Ballio, F., and E. Orsi. 2001. Time evolution of scour around bridge abutments. Water Eng. Res, 2:243-259.
 8. Bateni, S.M., D.S. Jeng, and B.W. Melville. 2007a. Bayesian neural networks for prediction of equilibrium and time-dependent scour depth around bridge piers. Adv. Eng. Softw. 38:102-111.
 9. Bateni, S.M., S.M. Borghei, and D.S. Jeng. 2007b. Neural network and neuro-fuzzy assessments for scour depth around bridge piers. Eng. Appl. Artif. Intell. 20: 401-414.
 10. Buragohain, M., and C. Mahanta. 2008. A novel approach for ANFIS modelling based on full factorial design. Appl. Soft Comput. 8:609-625.
 11. Cardoso, A.H., and R. Bettess. 1999. Effects of time and channel geometry on scour at bridge abutments. J. Hydraul. Eng-ASCE. 125: 388-399.

30. Toth, E., and L. Brandimarte. 2011. Prediction of local scour depth at bridge piers under clear-water and live-bed conditions: Comparison of literature formulae and Artificial Neural networks. *J. Hydroinf.* 13:812-824.
31. Yanmaz, A.M., and O. Kose. 2007. Time-wise variation of scouring at bridge abutments. *Sadhana-Academy Proceedings. Eng. Sci.* 32: 199-213.
32. Zanganeh, M., A. Yeganeh-Bakhtiary, and R. Bakhtyar. 2011. Combined particle swarm optimization and fuzzy inference system model for estimation of current-induced scour beneath marine pipelines. *J. Hydroinf.* 13:558-573.
33. Zounemat-Kermani, M., A.A. Beheshti, B. Ataie-Ashtiani, and S.R. Sabbagh-Yazdi. 2009. Estimation of current-induced scour depth around pile groups using neural network and adaptive neuro-fuzzy inference system. *Appl. Soft. Comput.* 2: 746-755.
- Hnetwork. *Water Sci. Technol.* 67: 1121-1128.
25. Najafzadeh, M., G.A. Barani, and M.R.H. Kermani. 2013b. GMDH based back propagation algorithm to predict abutment scour in cohesive soils. *Ocean Eng.* 59: 100-106
26. Oliveto, G., and W.H. Hager. 2002. Temporal evolution of clear-water pier and abutment scour. *J. Hydraul. Eng-ASCE.* 128: 811-820.
27. Sarlak, N., and T. Sahnaz. 2011. Analysis of experimental data sets for local scour depth around bridge abutments using artificial neural networks. *Water Sa.* 37:595-602.
28. Shin, J.H., and H.I. Park. 2010. Neural network formula for local scour at piers using field data. *Mar. Georesour. Geotec.* 28: 37-48.
29. Simarro, G., L. Teixeira, and A.H. Cardoso. 2007. Flow intensity parameter in pier scour experiments. *J. Hydraul. Eng.* 133: 1261-1264.