

تخمین عمق چاله آبستگي پایه پل در سازه‌های آبی با روش رگرسیون فرایند گاوسی

علی رضازاده جودی* و محمدتقی ستاری**

* نگارنده مسئول: باشگاه پژوهشگران جوان و نخبگان، دانشگاه آزاد اسلامی، مراغه. ایران. تلفن: ۰۶۱۰۳۳۳۶۰۶۱۰، پیام‌نگار: alijoudi66@gmail.com
** به ترتیب: کارشناسی ارشد عمران-آب، باشگاه پژوهشگران جوان و نخبگان، واحد مراغه؛ و عضو هیات علمی گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز
تاریخ دریافت: ۹۴/۶/۲؛ تاریخ پذیرش: ۹۴/۱۰/۱۹

چکیده

پایداری پایه‌های پل احداث شده روی رودخانه‌ها یا کانال‌های عریض و عمیق آبیاری یکی از دغدغه‌های مهم مهندسان سازه‌های آبی است. در آزمایشگاه‌های هیدرولیک برای محاسبه عمق چاله آبستگي پایه پل روابط متعددی ارائه شده است، برای داده‌های میدانی متاثر از شرایط محیطی غیرقابل کنترل، رابطه جامع و مانعی گزارش نشده است. فرایند گاوسی شامل مجموعه‌ای از متغیرهای تصادفی به عنوان یکی از روش‌های نوین داده‌کاوی، با داشتن خصوصیات نرمال و با بهره‌گیری از توابع کرنل توانایی بالایی در حل مسائل غیرخطی دارد. در این تحقیق، کارایی روش رگرسیون فرایند گاوسی در تخمین عمق آبستگي پایه پل برای داده‌های میدانی بررسی و نتایج به دست آمده با نتایج هشت رابطه تجربی مقایسه شد. از میان روابط تجربی مورد ارزیابی، رابطه فرولیک نسبت به سایر روابط دارای عملکرد بهتر و دقت بیشتری است. در تخمین عمق آبستگي با پارامترهای با بعد و با استفاده از روش رگرسیون فرایند گاوسی با تابع کرنل پیرسون، ترکیب پارامترهای ورودی شامل ضریب شکل پایه پل، عرض پایه پل، متوسط اندازه ذرات رسوبی بستر و عمق جریان بهترین ترکیب پارامتر ورودی شناخته شد. نتایج نشان می‌دهد که در تخمین عمق آبستگي با داده‌های میدانی روش رگرسیون فرایند گاوسی، در مقایسه با روابط تجربی کارایی نسبتاً بالاتری دارد.

واژه‌های کلیدی

آبستگي موضعی، تابع کرنل، داده‌کاوی، رگرسیون فرایند گاوسی، روابط تجربی

مقدمه

گذشته حضور مهندسی هیدرولیک و رودخانه را طلب می‌کنند تا با دانش عمیق تری به مسائل آبراهه‌ها بپردازند (Arvanaghi et al., 2008). همچنین پایداری پایه‌های ناوسمان‌ها و فلوم‌های هوایی که بر حسب ضرورت یا در داخل رودخانه، کانال‌های بزرگ شبکه‌های آبیاری و زهکشی و یا در دره‌های عمیق احداث می‌شوند، اهمیت چشم‌گیری در مطالعات هیدرولیکی دارند. از دلایل مختلف تخریب سازه‌های هیدرولیکی، عوامل هیدرولیکی سهم عمده‌ای دارند و از عوامل هیدرولیکی، آبستگي

پل مهم‌ترین و حیاتی‌ترین سازه ارتباطی است که از دیرباز ساخته و از آن بهره‌برداری شده است. پایداری پایه پل‌هایی که روی رودخانه‌ها و یا کانال‌های عریض آبیاری، با هدف تسهیل تردد، ساخته می‌شوند مورد توجه جدی کارشناسان طراحی و اجرای سازه‌های آبی است. با گسترش شهرسازی و افزایش روز افزون نیاز انسان به جابه‌جایی، پل‌های بزرگ و جدید روی رودخانه‌ها در سراسر جهان با رشد فزاینده‌ای ساخته می‌شوند و برخلاف

شکل پایه و غیره و پارامترهای رسوبی مانند اندازه مواد رسوبی و توزیع دانه‌بندی و غیره (Shafaie-Bejestan, 2011). برآورد میزان پایین رفتن بستر و نشست پایه در اثر آبشستگی که در اطراف سازه‌هایی چون پل‌ها، کناره‌ها، پایه‌های شبکه‌های آبیاری و زهکشی اتفاق می‌افتد، مستلزم شناخت دقیق و جامع الگوی جریان اطراف پایه پل و مکانیزم هیدرولیکی و فیزیکی حاکم بر این پدیده است. بی‌توجهی به این مقوله علاوه بر تحمیل هزینه‌های به بازسازی و اصلاح سازه‌ها، خسارات مدیریتی دیگری از جمله تنش‌های اجتماعی در اثر شکست در تخصیص به‌هنگام آب مورد نیاز بخش‌های کشاورزی، صنعتی و شرب را نیز به دنبال دارد. روابط تجربی ارائه شده برای محاسبه عمق آبشستگی تابع شرایط آزمایشگاهی خاصی است و متغیرهای محدودی را بررسی می‌کنند و یا بازه محدودی از آن متغیر را در نظر می‌گیرند، به همین جهت، این روابط قابل تعمیم و استفاده در شرایط میدانی مختلف نخواهند بود (Pal *et al.*, 2012). از طرف دیگر این معادلات برای تخمین عمق حفره آبشستگی موضعی در یک موقعیت خاص، غالباً نتایج کاملاً متفاوتی داده‌اند، بنابراین، انتخاب معادله‌ای که بیشترین تطابق را با واقعیت داشته باشد اساساً اگر امکان‌پذیر باشد، کار ساده‌ای نیست (Kuchekzadeh *et al.*, 2002).

یکی از متداول‌ترین روش‌های جایگزین برای روابط سنتی و تجربی موجود برای مدلسازی پدیده‌های فیزیکی پیچیده، روش‌های موسوم به داده‌کاوی است (Ghazanfari-Hashemi & Shahidi, 2012). ایوبلو و همکاران (Ayubloo *et al.*, 2011) عمق آبشستگی در پایین‌دست دریچه‌های جت اسکی را با استفاده از مدل درختی M5، مدل طبقه‌بندی و رگرسیون درختی و ماشین‌بردار پشتیبان پیش‌بینی و کارایی قابل توجه این روش‌ها را اعلام کردند. هوشمند و همکاران (Houshmand *et al.*, 2011) عملکرد روش‌های شبکه عصبی مصنوعی و

بیشترین نقش را دارد. چپو (Chiew, 1995) گزارش داده است که در ایالات متحده آمریکا طی سی سال گذشته، از مجموع پانصد هزار پل ساخته شده روی رودخانه‌ها هزار پل تخریب شده که شصت درصد آنها در اثر آبشستگی بوده است، در حالی که سهم زلزله در این تخریب‌ها تنها دو درصد است. آبشستگی به معنای فرسایش بستر در پایین‌دست سازه‌های هیدرولیکی به علت شدت جریان زیاد و یا به معنای فرسایش بستر در اثر به وجود آمدن جریان‌های متلاطم موضعی، است. عمق ناشی از فرسایش بستر نسبت به بستر اولیه را عمق آبشستگی می‌نامند (Shafaie-Bejestan, 2011). آبشستگی به سه دسته کلی آبشستگی عمومی، آبشستگی تنگ‌شدگی و آبشستگی موضعی تقسیم می‌شود. آبشستگی عمومی پدیده‌ای طبیعی بوده و وقوع آن صرف‌نظر از حضور سازه‌های مصنوعی امکان‌پذیر است. آبشستگی تنگ‌شدگی در مناطقی رخ می‌دهد که عرض رودخانه به واسطه احداث سازه‌ای مانند پل کاهش پیدا کند. آبشستگی موضعی یعنی کاهش ناگهانی در رقوم بستر مجرا در اطراف تاسیسات آبی به واسطه تغییرات شدید در الگوی جریان در اطراف این سازه‌ها (Simons & Senturk, 1992). از طرف دیگر، با توجه به حرکت رسوبات در جریان رودخانه‌ای، آبشستگی به دو دسته آبشستگی آب زلال^۱ و آبشستگی بستر زنده^۲ تقسیم‌بندی می‌شود. در آبشستگی آب زلال حداکثر میزان عمق آبشستگی پایه‌های پل ایجاد می‌شود (Arvanaghi *et al.*, 2008). عامل اولیه آبشستگی موضعی جریان رو به پایینی است که نظیر یک جت عمودی عمل کرده و مواد کناره پایه پل را بلند می‌کند و جریان معمولی آب آن را می‌شوید. پارامترهای موثر شناخته شده بر آبشستگی پایه پل عبارت‌اند از پارامترهای هیدرولیکی مانند عمق جریان، سرعت متوسط جریان و غیره، پارامترهای مربوط به سیال مانند شتاب ثقل، جرم واحد حجم و غیره، پارامترهای هندسی مانند قطر پایه،

تفاوت اساسی با تحقیق حاضر دارد یکی اینکه آنها توسعه زمانی و تکامل عمق آبشستگی را بررسی کردند در صورتی که هدف از تحقیق حاضر تخمین و پیش‌بینی بیشینه عمق چاله آبشستگی پایه‌های پل و سایر سازه‌های رودخانه‌ای است و دیگری اینکه آنها نیز همانند اکثر تحقیقات مشابه برای پژوهش خود از داده‌های آزمایشگاهی استفاده کرده‌اند در صورتی که استفاده از داده‌های میدانی در این تحقیق و مقایسه کارایی و دقت روش رگرسیون فرایند گاوسی در مقایسه با روابط تجربی مرسوم در زمینه تخمین بیشینه عمق آبشستگی از بارزترین برتری‌های این پژوهش است. صمدی و همکاران (Samadi *et al.*, 2014) نتایج مدل M5 و درختان طبقه‌بندی و رگرسیون در پیش‌بینی عمق آبشستگی در زیر سرریز اوجی آزاد را با نتایج شبکه‌های عصبی مصنوعی مقایسه کردند و به این نتیجه رسیدند که مدل درختی M5 نتایج کاربردی‌تری ارائه می‌دهد. آکیب و همکاران (Akib *et al.*, 2014) با استفاده از روش‌های رگرسیون خطی و سیستم استنتاج عصبی-فازی به پیش‌بینی عمق آبشستگی در پایه‌های پل پرداختند و برتری روش سیستم استنتاج عصبی-فازی را نسبت به روش رگرسیون خطی ساده نشان دادند. حسینی و امینی (Hosseini & Amini, 2015) عمق آبشستگی در اطراف گروه پایه‌های پل را با استفاده از روابط تجربی و شبکه عصبی مصنوعی تخمین زدند. نتایج بررسی‌ها نشان‌دهنده کارایی و دقت عمل بیشتر شبکه عصبی مصنوعی در این زمینه بود. نجف‌زاده و همکاران (Najafzadeh *et al.*, 2015) با استفاده از روش شبکه‌های GMDH^۱ عمق آبشستگی موضعی پایه پل با رسوبات درشت‌دانه در بستر را پیش‌بینی کردند و به این نتیجه رسیدند که کارایی و دقت عمل شبکه‌های GMDH نسبت به روابط تجربی بالاست. نجف‌زاده و همکاران (Najafzadeh *et al.*, 2016) با استفاده از مدل‌های ماشین‌بردار پشتیبان و سیستم استنتاج عصبی-فازی

سیستم استنتاج تطبیقی فازی-عصبی را در تخمین حداکثر عمق آبشستگی پایه پل مقایسه کرده و نتیجه گرفتند که بهترین نتیجه مربوط به مدل‌های شبکه عصبی مصنوعی است. پال و همکاران (Pal *et al.*, 2011) با استفاده از رگرسیون بردار پشتیبان به مدلسازی آبشستگی پایه پل پرداختند و نتایج حاصل را با نتایج شبکه عصبی مصنوعی و روابط تجربی مقایسه و مشاهده کردند که هر دو روش رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی نسبت به روابط تجربی دقت بالاتری دارند. غضنفری هاشمی و همکاران (Ghazanfari-Hashemi & Shahidi, 2012) عمق آبشستگی اطراف پایه پل را با استفاده از ماشین‌های بردار پشتیبان و شبکه‌های عصبی مصنوعی پیش‌بینی کرده و دریافتند که ماشین‌های بردار پشتیبان نسبت به شبکه‌های عصبی مصنوعی دقیق‌ترند و هر دو روش یاد شده به مراتب بهتر از روابط تجربی هستند. پال و همکاران (Pal *et al.*, 2012) کارایی مدل درختی M5 را برای پیش‌بینی آبشستگی پایه پل‌ها با استفاده از داده‌های میدانی بررسی کرده و به این نتیجه رسیدند که عرض پل، عمق و سرعت جریان از عوامل مهم در پیش‌بینی عمق آبشستگی هستند و مدل M5 به خوبی شبکه‌های عصبی مصنوعی می‌تواند در این مسئله به کار رود. موزمیل و الم (Mozzamil & Alam, 2013) با استفاده از روش سیستم استنتاج عصبی-فازی^۱ عمق آبشستگی در اطراف سازه‌های کنترلی را پیش‌بینی و برتری این روش را در مقایسه با روش‌های رگرسیون خطی ساده و شبکه عصبی مصنوعی اعلام کردند. نیروکاتی و همکاران (Neerukatti *et al.*, 2013) تکامل آبشستگی پایه پل را با استفاده از فرایند گاوسی پیش‌بینی کردند و دریافتند که این الگوریتم در بیشتر اوقات می‌تواند تکامل آبشستگی را با خطای کمتر از ۲۰ درصد پیش‌بینی کند و زمانی که داده‌های آموزشی به اندازه کافی موجود باشند، این خطا به ۵ درصد یا کمتر کاهش پیدا می‌کند. پژوهش آنان دو

وقوع آبشستگی در مواد بستر چسبنده، پایه پل از نوع گروه، مواد بستر نامشخص، مقادیر متغیر ورودی از دست رفته، داشتن آبشستگی برابر مقدار صفر و داده‌های مربوط به آبشستگی در پایین دست پایه‌های پل حذف شدند. تعداد ۲۳۲ مجموعه داده مربوط به آبشستگی بالادست پایه‌های پل برای بررسی در این مطالعه انتخاب شدند، که ۶۶ درصد از آنها یعنی ۱۵۴ مجموعه داده به صورت تصادفی برای قسمت آموزش مدل رگرسیون فرایند گاوسی و ۳۴ درصد از آنها یعنی ۷۸ مجموعه داده برای قسمت آزمون مدل مذکور انتخاب شدند. داده‌های استفاده شده شامل پارامترهای عمق آبشستگی موضعی پایه پل (D_s)، ضریب شکل پایه پل (P_s)، عرض پایه پل (P_w)، زاویه پایه پل با مسیر جریان، سرعت جریان (V)، عمق جریان (D)، متوسط اندازه دانه‌بندی مواد رسوبی (d_{50}) و توزیع دانه‌بندی مصالح بستر (σ) هستند. همچنین برای بررسی پارامترهای بی‌بعد، پارامترهای ذکر شده به صورت ضریب شکل پایه پل (P_s) (برای پایه‌های دایره‌ای شکل برابر ۱، برای پایه‌های نوک‌تیز برابر ۰/۷ و برای پایه‌های مربعی شکل برابر ۱/۳)، نسبت عمق آبشستگی پایه پل به عرض پایه پل (D_s/P_w)، زاویه پایه پل با مسیر جریان ($skew$)، نسبت سرعت جریان به سرعت بحرانی جریان (V/V_c)، نسبت عمق جریان به عرض پایه پل (D/P_w)، عدد فرود (v/\sqrt{gh})، نسبت متوسط اندازه دانه‌بندی مواد رسوبی به عرض پایه پل (d_{50}/P_w) و توزیع دانه‌بندی مصالح بستر (σ) نیز بررسی شده است. مشخصات آماری از جمله حداقل، میانگین، حداکثر و انحراف استاندارد پارامترهای ذکر شده در جدول ۱ ارائه شده است.

آبشستگی در آبراهه‌های دارای انقباض طولانی را پیش‌بینی و اعلام کردند که روش سیستم استنتاج عصبی- فازی، نسبت به روش ماشین‌بردار پشتیبان و روابط تجربی برتری دارد. با توجه به بررسی منابع مشاهده می‌گردد که، اکثر تحقیقات در زمینه تخمین عمق آبشستگی پایه پل، مربوط به استفاده از داده‌های آزمایشگاهی بوده و همچنین توسط روش‌های شبکه عصبی مصنوعی، مدل درختی M5 و ماشین‌بردار پشتیبان است و تحقیق چندانی در زمینه امکان‌سنجی کاربرد روش رگرسیون فرایند گاوسی به عنوان یک روش نوین داده‌کاوی برای تخمین عمق آبشستگی با استفاده از داده‌های میدانی صورت نپذیرفته است. لذا هدف از مطالعه حاضر ارزیابی عملکرد روش رگرسیون فرایند گاوسی در تخمین عمق آبشستگی با استفاده از داده‌های میدانی و مقایسه نتایج آن با نتایج به‌دست آمده از هشت رابطه تجربی است. همچنین در این مطالعه سعی شده است با تحلیل حساسیت مدل به پارامترهای ورودی، پارامترهایی شناسایی و معرفی گردند که بیشترین تاثیر را بر میزان بیشینه عمق آبشستگی موضعی پایه پل دارند.

مواد و روش

داده‌های استفاده شده

داده‌های به کار رفته در این مطالعه از تحقیق مولر و واگنر (Muller & Wagner, 2005)، شامل ۴۹۳ مجموعه داده میدانی مربوط به پارامترهای اندازه‌گیری شده آبشستگی تعدادی از پل‌های ایالات متحده آمریکا است. تعداد زیادی از این مجموعه داده‌ها به دلایلی همچون

تخمین عمق چاله آبشستگی پایه پل در سازه‌های...

جدول ۱- مشخصات آماری و محدوده پارامترهای استفاده شده

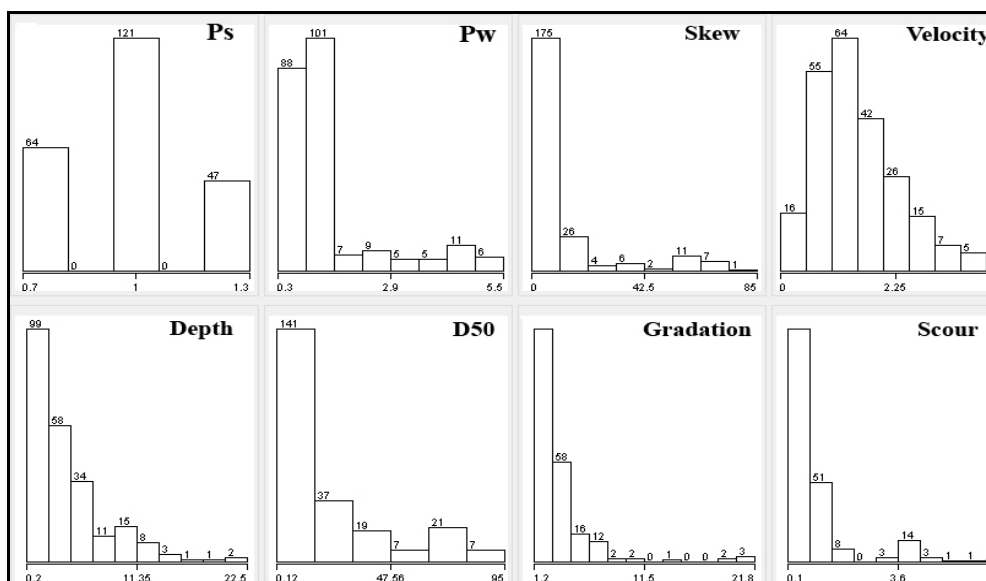
داده‌های آموزش				داده‌های آزمون				پارامترهای ورودی
حداقل	حداکثر	میانگین	انحراف استاندارد	حداقل	حداکثر	میانگین	انحراف استاندارد	
داده‌های با بعد								
۰/۷	۱/۳	۰/۹۷	۰/۲۱	۰/۷	۱/۳	۰/۹۹	۰/۲۰	P_s
۰/۳	۵/۵	۱/۵۶	۱/۱۶	۰/۳	۵/۵	۱/۴	۱/۱۵	P_w (متر)
۰	۸۵	۹/۲۶	۱۸/۶۳	۰	۸۵	۹/۹	۱۸/۳۷	$Skew(\theta)$
۰/۴۳	۴/۰۵	۱/۵۸	۱/۰۶۶	۰/۳۸	۴/۰۵	۱/۵۷	۱/۰۵	$Velocity$ (متر بر ثانیه)
۰/۳	۲۲/۵	۴/۵۵	۴/۰۱۹	۰	۲۲/۵	۳/۷۹	۳/۵۸	D (متر)
۰/۱۲	۹۵	۱۸/۹۸	۲۶/۷۶	۰/۱۵	۹۵	۱۹/۴۷	۲۵/۱	D_{50} (میلی‌متر)
۱/۲	۲۰/۳	۳/۶۵	۳/۲۹	۱/۲	۲۰/۳	۳/۶۱	۲/۹۰	σ
۰/۱	۷/۱	۱/۱۲	۱/۲۷	۰/۱	۷/۱	۰/۹۴	۱/۰۶	D_s (متر)
داده‌های بی‌بعد								
۰/۱۴	۰/۸۳۸	۱/۴۲	۰/۹۴	۰	۰/۸۳۸	۱/۱۶	۰/۷۶	v/v_c
۰/۰۴۶	۰/۷۸۴	۰/۲۸۸	۰/۱۴۴	۰	۰/۷۸۴	۰/۲۶	۰/۱۳	V/\sqrt{gh}
۰/۳۳	۱/۴۴	۳	۱/۸۲۶	۰/۴	۱/۴۴	۲/۹۴	۱/۸	D/p_w
۰	۰/۱۲	۰/۰۲	۰/۰۳	۰	۰/۱۲	۰/۰۲	۰/۰۳	D_{50}/p_w
۰/۰۹	۲	۰/۷۴	۰/۴۵	۰/۱۱	۲	۰/۷۴	۰/۴۹	D_s/p_w

برای بررسی میزان همبستگی بین پارامترهای مستقل و پارامتر وابسته (ویژگی هدف) به منظور تعریف سناریوها (ترکیب پارامترهای ورودی به مدل) همبستگی بین پارامترهای مختلف بی‌بعد در جدول ۲ ارائه شده است.

جدول ۲- همبستگی میزان عمق چاله آبشستگی با پارامترهای بی‌بعد موثر

D_s/p_w	σ	D_{50}/p_w	D/p_w	v/gh	v/v_c	$Skew(\theta)$	P_s
							۱
							P_s
						۱	$Skew(\theta)$
					۱	-۰/۳۱	v/v_c
				۱	-۰/۰۲	-۰/۲۹	v/gh
			۱	-۰/۲۳	۰/۲۵	-۰/۰۳	D/p_w
		۱	-۰/۱۵	۰/۴۹	-۰/۵۱	-۰/۰۳	D_{50}/p_w
	۱	-۰/۲۱	-۰/۰۸	-۰/۲۷	-۰/۱۶	۰/۳۵	σ
۱	-۰/۱۱	-۰/۰۸	۰/۴	۰/۰۴	۰/۲۷	۰/۱۸	D_s/p_w

همچنان که از بررسی جدول ۲ مشاهده می‌شود، از بیشترین همبستگی را با نسبت عمق چاله آبشستگی به عرض پایه پل (D_s/P_w) دارند. شکل ۱ نشان‌دهنده میزان فراوانی هر یک از پارامترهای موثر بر میزان عمق حفره بحرانی جریان (V/V_c) و نیز ضریب شکل پایه پل (P_s)



شکل ۱- فراوانی پارامترهای مختلف تاثیرگذار بر عمق حفره آبشستگی

رگرسیون فرایند گاوسی

فرایند گاوسی مجموعه‌ای از متغیرهای تصادفی است که تعداد دلخواه محدودی از آنها با توزیع‌های گاوسی ادغام (سازگار) شده‌اند. فرایند گاوسی به طور کامل توسط تابع میانگین $m(x)$ و تابع کوواریانس $k(x, x')$ آن معین می‌شود. این فرایند، تعمیمی طبیعی از توزیع گاوسی است که میانگین و کوواریانس آن به ترتیب یک بردار و یک ماتریس است (رابطه ۱).

$$f \sim GP(m, k) \quad (1)$$

مدل‌های رگرسیون فرایند گاوسی بر مبنای این فرض هستند که مشاهدات تنظیم باید حامل اطلاعاتی درباره همدیگر باشد. فرایندهای گاوسی راهی برای مشخص کردن اولویتی به صورت مستقیم روی فضای تابع هستند. این کار تعمیم طبیعی توزیع گاوسی است که میانگین و کوواریانس آن به ترتیب بردار و ماتریس هستند. توزیع گاوسی روی بردارهاست در حالی که فرایند گاوسی روی توابع است. در نتیجه، مدل‌های فرایند گاوسی به دلیل دانش قبلی درباره وابستگی‌های تابعی و داده‌ها، برای تعمیم به هیچ فرایند اعتبارسنجی نیاز ندارند و مدل‌های

رگرسیون فرایند گاوسی قادر به درک توزیع پیش‌بینی متناظر با ورودی آزمون هستند (Pal & Deswal, 2010). فرایندهای گاوسی به صورت مجموعه‌ای از متغیرهای تصادفی تعریف می‌شود، هر تعداد محدودی از آنها دارای توزیع گاوسی چند متغیره توامی است. $X * Y$ به ترتیب نشان‌دهنده دامنه‌های ورودی‌ها و خروجی‌ها است، از آن زوج (x_i, y_i) به صورت مستقل استخراج و به صورت یکسان توزیع شده‌اند. در رگرسیون، فرض می‌شود که $y \in R_e$ ؛ در آن صورت فرایند گاوسی روی X با تابع میانگین $\mu: Y \rightarrow R_e$ و تابع کوواریانس $k: X * X \rightarrow R_e$ تعریف می‌شود. فرض اصلی رگرسیون فرایند گاوسی این است که y با $\xi + f(x)$ داده می‌شود که در آن، $\xi \sim N(0, \sigma^2)$ است. در رگرسیون فرایند گاوسی، برای هر ورودی x متغیر تصادفی مرتبط $f(x)$ وجود دارد که مقدار تابع تصادفی f در آن مکان است. در این کار، فرض می‌شود که خطای مشاهده ξ مستقل نرمال و دارای توزیع یکسان با مقدار میانگین صفر ($\mu(x) = 0$) و واریانس (σ^2) است و $f(x)$ از فرایند گاوسی روی X که با k مشخص شده کشیده شده است. یعنی (رابطه ۲):

اعمال نویز بی‌زی^۱ یعنی بیشینه کردن درست‌نمایی حاشیه‌ای آموزش داد.

$$P(\sigma^2, K) = \frac{1}{2} Y^T (K + \sigma^2 I)^{-1} Y + \frac{1}{2} \log |K + \sigma^2 I| - \log p(\sigma^2) - \log(K) \quad (5)$$

برای یافتن هایپر پارامترها، می‌توان مشتق جزئی رابطه ۵ نسبت به σ^2 و k را یافت و با کاهش گرادینت به کمینه‌سازی دست یافت (Pal & Deswal, 2010). در این مطالعه برای مدلسازی تخمین عمق چاله آبخستگی موضعی پایه پل با روش رگرسیون فرآیند گاوسی از نرم‌افزار WEKA استفاده شد که در دانشگاه ویکاتو نیوزلند توسعه یافته است.

توابع کرنل

یکی از روش‌های متداول برای حل مسائل غیر خطی، استفاده از توابع کرنل است که بر اساس ضرب داخلی داده‌های مفروض تعریف می‌شود. طراحی روش‌های رگرسیون مبتنی بر فرآیند گاوسی نیز شامل استفاده از مفهوم تابع کرنل است. در واقع، با یک تبدیل غیر خطی از فضای ورودی به فضای خصیصه با ابعاد بیشتر (حتی نامتناهی) می‌توان مسائل را به صورت خطی تفکیک‌پذیر ساخت. از مهم‌ترین توابع کرنل می‌توان به کرنل خطی، کرنل چند جمله‌ای، کرنل چند جمله‌ای نرمال شده، کرنل تابع شعاع محور و کرنل مبتنی بر تابع پیرسون اشاره کرد که در این مطالعه از این توابع کرنل استفاده شده است. این توابع در روابط ۶ تا ۹ قابل مشاهده‌اند:

$$(6) \quad \text{تابع کرنل چند جمله‌ای ساده:}$$

$$k(x_i, x_j) = (x_i^T x_j + I)^p$$

$$Y = (Y_1, \dots, Y_n) \sim N(0, K + \sigma^2 I) \quad (2)$$

که در آن،

I ماتریس همبستگی است. چون $K_{ij} = k(x_i, x_j)$ و $Y/X \sim N(0, K + \sigma^2 I)$ نرمال است، در نتیجه توزیع شرطی برچسب‌های آزمون به شرط داده‌های آزمون و آموزشی $(Y^*/Y, X, X^*)$ p است. در آن صورت $Y^*/Y, X, X^* \sim N(\mu, \sigma)$ که در آن،

$$\mu = K(X_*, X)(K(X, X) + \sigma^2 I)^{-1} Y \quad (3)$$

$$\sigma = K(X_*, X_*) - \sigma^2 I - K(X_*, X)(K(X, X) + \sigma^2 I)^{-1} K(X, X_*) \quad (4)$$

اگر n داده آموزشی و n^* داده آزمون وجود داشته باشد، در آن صورت $K(x, x')$ ماتریس $n \times n^*$ کواریانس‌های ارزیابی شده در همه زوج‌های مجموعه‌های داده آزمون و آموزشی را نشان می‌دهند که به صورت مشابه برای مقادیر دیگر $K(X, X)$ ، $K(X, X^*)$ و $K(X^*, X^*)$ هم صحیح است؛ در اینجا X و Y بردار داده‌های آموزشی و برچسب‌های داده‌های آموزشی y_i است، در حالی که X^* بردار داده‌های آزمون است. تابع کواریانس مشخص شده برای ایجاد ماتریس کواریانس نیمه محدود مثبت k لازم است که در آن $K_{ij} = k(x_i, x_j)$ است. با دانستن مقادیر کرنل k و درجه نویز σ^2 ، روابط ۳ و ۴ برای استنتاج کافی هستند. در طول فرآیند آموزش مدل‌های رگرسیون فرآیند گاوسی، لازم است تابع کواریانس مناسب و همچنین پارامترهای آن انتخاب شود، زیرا نقش مرکزی در مدل رگرسیون فرآیند گاوسی متعلق به تابع کواریانس $K(x, x')$ است. این تابع ساختار هندسی نمونه‌های آموزشی را تعبیه می‌نماید. از طریق این تابع، تعریف دانش پیشین درباره تابع خروجی مذکور $F(0)$ امکان‌پذیر می‌گردد (Pasolli et al, 2010). در حالت رگرسیون فرآیند گاوسی با مقدار ثابت نویز گاوسی، مدل فرآیند گاوسی را می‌توان با

دارد. علاوه بر انتخاب پارامترهای خاص کرنل، در رگرسیون فرایند گاوسی به مشخص کردن مقادیر بهینه سطح نويز گاوسی نیاز است. برای انتخاب پارامترهای انتخاب شده توسط کاربر (یعنی $C, \gamma, \sigma, \omega, \varepsilon$ و نويز گاوسی) روش‌های متعددی مثل روش دستی (سعی و خطا)، روش جستجوی شبکه، الگوریتم ژنتیک، بهینه‌سازی اجتماع ذره و... ارائه شده است (Pal & Deswal, 2010). در مطالعه حاضر، برای انتخاب این پارامترها از روش سعی و خطا استفاده شده است. مقادیر بهینه پارامترهای مختلف تعریف شده توسط کاربر طوری انتخاب شده‌اند که ریشه میانگین مربع خطا را کمینه و ضریب همبستگی را بیشینه کند.

روابط تجربی

در این تحقیق هشت رابطه تجربی مختلف روی داده‌های میدانی جمع‌آوری شده، بررسی و آزمایش شد؛ که این روابط در جدول ۳ ارائه شده‌اند.

(۷) تابع کرنل چند جمله‌ای نرمال شده:

$$k(x_i, x_j) = \frac{(x_i^T x_j + 1)^p}{\sqrt{(x_i^T x_i)(x_j^T x_j)}}$$

(۸) تابع پایه شعاعی

$$k(x_i, x_j) = \exp(-Y|x_i - x_j|^2)$$

(۹) تابع کرنل پیرسون:

$$k(x_i, x_j) = \frac{1}{\left[1 + \left(2\sqrt{\|x_i, x_j\|^2} \sqrt{2^{1/w} - 1/\sigma}\right)\right]^w}$$

هر یک از این توابع پارامترهای خاص کرنل خود را دارد که به آنها هایپرپارامتر گفته می‌شود. استفاده از روش‌های مدلسازی مبتنی بر کرنل به ایجاد پارامترهای مناسب تعریف شده توسط کاربر نیاز دارد، زیرا دقت این روش رگرسیونی وابستگی زیادی به انتخاب این پارامترها

جدول ۳- روابط تجربی استفاده شده در این تحقیق

رابطه	رابطه تجربی
$D_s = 3.4b(F_r)^{2/3}(Y/b)^{1/3}$	Shen <i>et al</i> (1969)
$D_s = 2.2Y(b/Y)^{0.65}(F_r)^{0.43}$	CSU ¹ (Anon, 1975)
$D_s/b = 1.85(F_r - F_{rc})^{0.25}(d_0)^{0.5}$ یا $D_s/b = 2(F_r - F_{rc})^{0.25}(d_0/b)^{0.5}$	Jain & Fischer (1980)
$D_s = 0.32\Phi g^{-0.1}V_0^{0.2}y_0^{0.36}b^{0.62}D_{50}^{-0.08}$	Froehlich (1988)
$D_s = 0.32\Phi g^{-0.1}V_0^{0.2}y_0^{0.36}b^{0.62}D_{50}^{-0.08} + b$	Froehlich Design (1988)
$D_s = 1.141K_s b^{0.6}y_0^{-0.15}D_m^{-0.07}\left(\frac{v_a - v_{ic}}{v_c - v_{ic}}\right)$	Simplified Chinese (Gao, 1992)
$D_s = K_i K_d K_{yb}$	Melville (1997)
$\frac{D_s}{D^*} = f_1\left(\frac{y_0}{D^*}\right)\left[2.2\left(\frac{v_c - 1}{v_c}\right) + 2.5f_2\left(\frac{D^*}{D_{50}}\right)\left(\frac{v_{sp} - v_c}{v_c}\right)\right]$	Sheppard and Miller (2006)
$f_1\left(\frac{y_0}{D^*}\right) = \tanh\left[\left(\frac{y_0}{D^*}\right)^{0.4}\right]$	-
$f_2\left(\frac{D^*}{D_{50}}\right) = \frac{D^*/D_{50}}{0.4\left(\frac{D^*}{D_{50}}\right)^{1.2} + 10.6\left(\frac{D^*}{D_{50}}\right)^{-0.13}}$	-

تخمین عمق چاله آبشستگی پایه پل در سازه‌های...

روابط ۹ تا ۱۲ ارائه گردیده است. در این روابط X شامل مقادیر مشاهداتی و Y شامل مقادیر محاسباتی هستند.

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=0}^n |X_i - Y_i| \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (y_i - x_i)^2}{N}} \quad (11)$$

$$EP = \frac{\sum_{i=1}^n |Y_i - X_i|}{\sum_{i=1}^n X_i} \times 100 \quad (12)$$

در این روابط d_s و D_s = عمق چاله آبشستگی (متر)؛ b و D^* = عرض یا قطر پایه پل (متر)؛ F_r = عدد فرود؛ F_{rc} = عدد فرود متناظر با سرعت بحرانی؛ Y_0 و d_0 = عمق جریان (متر)؛ θ = ضریب شکل دماغه پایه پل؛ g = با شتاب ثقل زمین؛ V = سرعت جریان (متر بر ثانیه)؛ $d_{50} = d_m$ = متوسط اندازه رسوبات بستر (میلی‌متر)؛ k_s = ضریب شکل پایه پل؛ V_{ic} = سرعت متناظر با سرعت بحرانی جریان (متر بر ثانیه)؛ V_{ip} = سرعت حداکثر در آبشستگی بستر زنده؛ K_i = ضریب شدت جریان؛ K_{yb} = ضریب عمق جریان و عرض پایه پل؛ K_d = ضریب اندازه رسوبات بستر؛ و V_c = سرعت بحرانی جریان (متر بر ثانیه) است (برای بررسی بیشتر روابط و پارامترها به منابع مربوطه مراجعه شود).

نتایج و بحث

بررسی نتایج روابط تجربی

نتایج مربوط به هشت رابطه تجربی بررسی شده در این تحقیق بر اساس آماره‌های آماری مطرح شده در جدول ۴ ارائه شده است.

معیارهای ارزیابی

در این تحقیق عملکرد روش رگرسیون فرایند گاوسی و روابط تجربی بر پایه محاسبه ضریب همبستگی^۱، جذر میانگین مربعات خطا^۲، میانگین خطای مطلق^۳ و درصد خطا^۴ ارزیابی شده است. نحوه محاسبه آماره‌های فوق در

جدول ۴- شاخص‌های آماری مربوط به نتایج روابط تجربی

R	RMSE (متر)	MAE (متر)	درصد خطا	رابطه تجربی
۰/۴۹۶	۱/۸۲۱	۱/۲۴۸	۱۵۸/۳۵	Shen et al (1969)
۰/۵۵	۱/۶۴۰	۱/۰۹۱	۱۳۹/۹۵	Anon (1975)
۰/۸۷۵	۱/۷۲۸	۱/۴۰۲	۱۵۲/۱۳	Jain & Fischer (1980)
۰/۷۵۳	۰/۹۵۷	۰/۲۳۸	۴۹/۶۹	Froehlich (1988)
۰/۶۶۵	۱/۹۸۹	۱/۲۷۰	۱۴۱/۳۴	Froehlich Design (1988)
۰/۷۴۸	۵/۵۶۱	۲/۳۳۳	۳۰۹/۹	Simplified Chinese (Gao, 1992)
۰/۴۹۶	۳/۰۴۵	۱/۷۰۲	۲۰۷/۸۵	Melville (1997)
۰/۸۲۳	۱/۶۶۹	۱/۳۸۲	۱۴۴/۲۶	Sheppard & Miller (2006)

این پدیده را مد نظر قرار داده است. به همین دلیل با اینکه تمامی این روابط در محدوده داده‌های آزمایشگاهی خود به خوبی پاسخگو هستند اما، همچنان که مشاهده

همچنان که در قسمت مقدمه بیان گردید، هر یک از روابط تجربی در شرایط خاص آزمایشگاهی توسعه داده شده است و هر یک تأثیر برخی از پارامترهای دخیل بر

1- Correlation Coefficient
3- Mean Absolute Error

2- Root Mean Square Error
4- Error Percent

می‌گردد، در محدوده داده‌های میدانی عملکرد مناسبی ندارند و مقادیر بالای درصد خطا بیانگر این موضوع است. دقت پایین روابط تجربی به هنگام کاربرد آنها در داده‌های میدانی در تحقیق پال و همکاران (Pal et al, 2012) نیز مورد توجه و تاکید قرار گرفته است. نتایج جدول ۴ نشان می‌دهد که رابطه جین و فیشر (Jain & Fischer, 1980) دارای بیشترین مقدار ضریب همبستگی است اما از لحاظ مقادیر آماره‌های مربوط به خطا نیز دارای خطای بیشتری است، اما رابطه فرولیک (Froehlich, 1988) با توجه به مقدار ضریب همبستگی نسبتاً مناسب و مقادیر کمتر خطا در هر سه آماره مربوط به خطا، دارای عملکرد بهتری نسبت به سایر روابط تجربی است و بعد از آن به ترتیب روابط فرولیک دیزاین (Froehlich Design, 1988) و شپارد و میلر (Sheppard & Miller, 2006) در جایگاه بعدی قرار دارند. همچنین روابط شن و همکاران (Shen et al., 1969) Simplified Chinese (Gao, 1992) دارای نتایج ضعیف‌تری می‌باشند.

نتایج رگرسیون فرایند گاوسی

توابع کرنل با توجه به ساختار ریاضی‌شان نیازمند تعریف و انتخاب پارامترهایی هستند تحت عنوان هایپرپارامتر که برای انتخاب این هایپر پارامترها از روش سعی و خطا استفاده شده است. هنگام استفاده از تابع مختلف کرنل مقدار پارامتر نوین فرایند گاوسی با استفاده از آزمون و خطا بین ۰/۱ تا ۱ در نظر گرفته شد و ملاحظه گردید که با افزایش مقدار نوین نتایج تغییر نمی‌کنند یا ضعیف‌تر می‌شوند و بهترین جواب در این محدوده حاصل

می‌شود. همچنین در استفاده از تابع کرنل چند جمله‌ای ساده و تابع کرنل چند جمله‌ای نرمال شده مقدار توان و درجه تابع بین ۱ تا ۱۲ بررسی و مشاهده شد که با افزایش مقدار نوین نتایج تغییر نمی‌کنند یا ضعیف‌تر می‌شوند و بهترین نتیجه در این محدوده حاصل می‌شود. همچنین در استفاده از تابع کرنل پایه شعاعی مقدار هایپرپارامتر γ بین ۰/۱ و ۳ بررسی و مشاهده گردید که بهترین نتایج بین مقادیر ۰/۱ و ۲ به دست می‌آیند. هنگام استفاده از تابع کرنل پیرسون مشاهده شد که وقتی مقدار هایپرپارامترهای ω و σ با هم برابر در نظر گرفته می‌شود، نتایج بهتری حاصل خواهد شد. مقدار هایپرپارامتر ω و σ بین ۰/۱ و ۳ بررسی و مشاهده گردید که بهترین نتایج در محدوده ۰/۱ و ۲/۵ به دست می‌آید. در این تحقیق برای بررسی تاثیر پارامترهای با بعد بر میزان عمق چاله آبشستگی، چهار سناریوی مختلف شامل ترکیب پارامترهای با بعد متفاوت تعریف شد. برای بررسی تأثیر پارامترهای بی‌بعد بر میزان عمق چاله آبشستگی نیز پنج سناریوی مختلف شامل ترکیب پارامترهای بی‌بعد متفاوت تعریف گردید. این سناریوها بر اساس جدول و ماتریس همبستگی بین پارامترهای مختلف با بعد و بی‌بعد انتخاب شدند. در جدول ۵ سناریوهای مربوط به پارامترهای با بعد و بی‌بعد ارائه شده‌اند.

این ترکیب پارامترها به ازای توابع کرنل مختلف بررسی و مدلسازی شدند که بهترین و دقیق‌ترین نتیجه مربوط است به پارامترهای با بعد و سناریوی ۳ که در جدول ۶ ارائه شده است.

جدول ۵- سناریوهای مختلف ترکیب پارامترهای ورودی برای تخمین میزان عمق چاله آبشستگی

سناریو	پارامترهای ورودی با بعد
(۱)	$P_s, P_w, D_{50}, Depth, Skew, V, \sigma$
(۲)	$P_s, P_w, D_{50}, Depth, V$
(۳)	$P_s, P_w, D_{50}, Depth$
(۴)	$P_w, Depth$
پارامترهای ورودی بی‌بعد	
(۵)	$P_s, Skew, V/V_c, V/gh, Depth/P_w, D_{50}/P_w, \sigma$
(۶)	$P_s, Skew, V/V_c, Depth/P_w, D_{50}/P_w, \sigma$
(۷)	$P_s, Skew, V/V_c, Depth/P_w, \sigma$
(۸)	$P_s, Skew, V/V_c, Depth/P_w$
(۹)	$P_s, V/V_c, Depth/P_w$

جدول ۶- شاخص‌های آماری با استفاده از توابع کرنل مختلف برای سناریوی ۳ پارامترهای با بعد

خطا (درصد)	میانگین خطای مطلق (متر)	ریشه میانگین مربعات خطا (متر)	ضریب همبستگی	هایپر پارامتر	نویز	تابع کرنل	پارامترهای ورودی
۴۰/۷۳	۰/۳۸	۰/۴۸	۰/۹۳	۴	۰/۱	چند جمله‌ای ساده	
۳۷/۶۰	۰/۳۵	۰/۵۵	۰/۸۵	۸	۰/۴	چند جمله‌ای نرمال شده	$P_s, P_w, D_{50}, Depth$
۲۵/۰۰	۰/۲۳	۰/۳۳	۰/۹۵	۲	۰/۱	تابع پایه شعاعی	
۲۴/۰۲	۰/۲۲	۰/۳۱	۰/۹۶	۱	۰/۳	تابع کرنل پیرسون	

است برابر خواهد بود، با ۰/۰۹ در ضریب همبستگی، ۰/۱۸ در ریشه میانگین مربعات خطا و ۰/۱۶ در میانگین خطای مطلق. با توجه به اهمیت تعیین میزان پارامتر نویز در روش رگرسیون فرایند گاوسی طبق نتایج به دست آمده، بهترین محدوده برای پارامتر نویز هنگام تخمین عمق حفره آبشستگی با استفاده از داده‌های با بعد در محدوده ۰/۱ تا ۰/۳ است. در جدول ۷ نتایج ترکیب پارامترهای ورودی بی‌بعد برای بهترین سناریو، یعنی سناریوی ۲، با استفاده از روش رگرسیون فرایند گاوسی ارائه شده است.

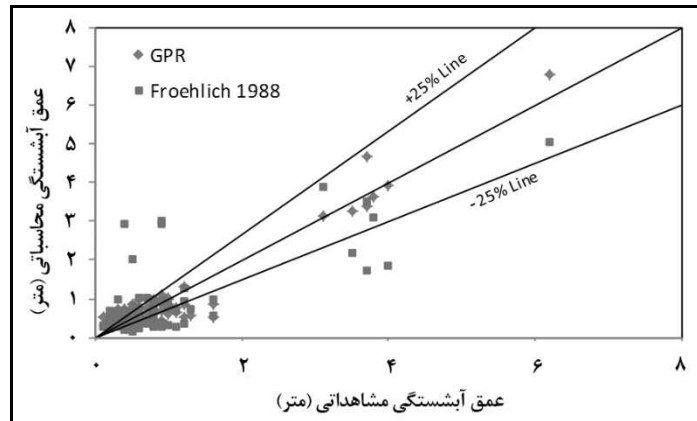
در جدول ۶ مشاهده می‌شود که تابع کرنل پیرسون بهترین نتیجه را با استفاده از مقدار نویز ۰/۳ و مقدار هایپر پارامترهای σ و ω برابر با ۱، ارائه کرده است و پس از آن با فاصله‌ای اندک تابع پایه شعاعی عملکرد خوبی داشته است. همچنین، تابع چند جمله‌ای نرمال شده دارای کمترین دقت است. همان‌طور که قبلاً اشاره گردید، نتایج ارائه شده در جدول ۶ مربوط به بهترین مقدار به دست آمده برای مقادیر نویز و هایپر پارامترهای مربوط به هر یک از توابع کرنل است. بنابراین، بیشینه تفاوتی که در این حالت با استفاده از توابع کرنل مختلف ایجاد شده

جدول ۷- شاخص‌های آماری با استفاده از توابع کرنل مختلف برای سناریوی ۲ پارامترهای بی بعد


خطا (درصد)	میانگین خطای مطلق (متر)	ریشه میانگین مربعات خطا (متر)	ضریب همبستگی	هایپر پارامتر	نویز	تابع کرنل	پارامترهای ورودی
۴۱/۲۲	۰/۳۰	۰/۳۷	۰/۶۹	۴	۱	چند جمله‌ای ساده	$P_{ss}, Skew,$
۳۹/۶۷	۰/۲۹	۰/۳۸	۰/۶۳	۱۲	۰/۵	چند جمله‌ای نرمال شده	V/V_{σ}
۳۰/۵۴	۰/۲۲	۰/۲۸	۰/۸۱	۲	۰/۲	تابع پایه شعاعی	$Depth/P_{Wp}$
۲۹/۵۲	۰/۲۲	۰/۲۷	۰/۸۲	۲	۰/۱	تابع کرنل پیرسون	$D_{50}/P_{Wp}, \sigma$

با ۰/۱۹، برای ریشه میانگین مربعات خطا برابر با ۰/۱۱ متر و برای میانگین خطای مطلق برابر با ۰/۰۸ متر است. برای درک بهتر نتایج در شکل ۲ نمودار پراکنش نتایج به دست آمده از روش رگرسیون فرایند گاوسی با استفاده از سناریوی ۳ با بعد تابع کرنل پیرسون نسبت به رابطه تجربی فرولیک (Froehlich, 1988)، و در شکل ۳ نمودار پراکنش نتایج رگرسیون فرایند گاوسی به دست آمده از سناریوی ۲ بی بعد با تابع کرنل پیرسون نسبت به داده‌های مشاهداتی عمق آبشستگی ارائه شده است.

در جدول ۷ مشاهده می‌شود که بهترین نتیجه مربوط به تابع کرنل پیرسون با مقدار نویز ۰/۱ و مقدار هایپر پارامترهای ω و σ برابر با ۲ به دست آمده است. پس از آن با فاصله‌ای اندک تابع پایه شعاعی عملکرد خوبی داشته است همچنین، تابع چند جمله‌ای نرمال شده کمترین دقت را دارد. یادآوری می‌شود که نتایج ارائه شده در جدول ۷ مربوط به بهترین مقدار نویز و هایپر پارامترهای مربوط به هر کدام از توابع کرنل است. از این جهت بیشینه تفاوت نتایج برای ضریب همبستگی برابر



شکل ۲- نمودار پراکنش داده‌های محاسباتی نسبت به داده‌های مشاهداتی (روش رگرسیون فرایند گاوسی با استفاده از سناریوی ۳ با بعد تابع کرنل پیرسون)



شکل ۳- نمودار پراکنش داده‌های محاسباتی نسبت به داده‌های مشاهداتی (روش رگرسیون فرایند گاوسی با استفاده از سناریوی ۲ بی بعد با تابع کرنل پیرسون)

آبشستگی به دست آمده از روش رگرسیون فرایند گاوسی با استفاده از پارامترهای بی بعد، نسبت به داده‌های مشاهداتی عمق آبشستگی، پراکنش و همخوانی مناسب تری دارد و حدوداً ۶۵ درصد از داده‌ها بین خطوط +۲۵ و -۲۵ درصد خطا قرار دارد که این امر نشان‌دهنده دقت و کارایی مناسب این مدل است.

تحلیل حساسیت مدل‌ها به پارامترهای ورودی

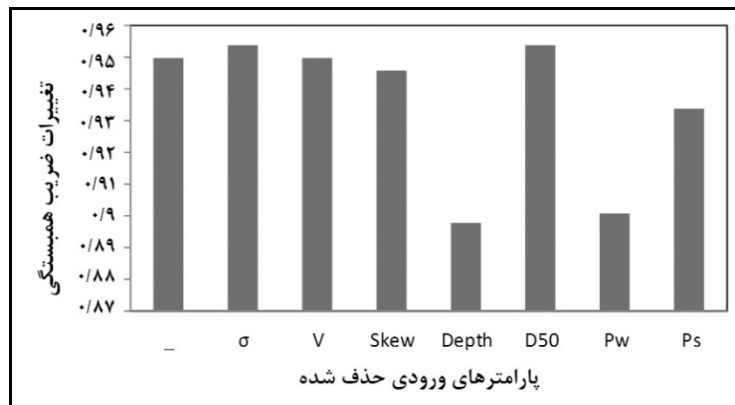
در این مرحله با حذف تعدادی از پارامترها، تاثیر پارامترهای حذف شده در مدل‌ها بررسی شد. بر این اساس، با استفاده از شاخص‌های ارزیابی آماری اشاره شده در بخش‌های قبل، نتایج تحلیل حساسیت روش رگرسیون فرایند گاوسی با استفاده از تابع کرنل پیرسون، که نتیجه دقیق تری ارائه کرده بود، در جدول ۸ و شکل ۴ ارائه شده است.

در شکل ۲ مشاهده می‌شود که داده‌های عمق آبشستگی به دست آمده از روش رگرسیون فرایند گاوسی نسبت به داده‌های عمق آبشستگی به دست آمده از رابطه فرولیک (Froehlich, 1988) همخوانی بیشتری با داده‌های مشاهداتی عمق آبشستگی دارد و تعداد داده بیشتری بین خطوط +۲۵ و -۲۵ درصد خطا، حول نیمساز ناحیه اول قرار دارد (حدوداً ۷۴ درصد از داده‌ها)، که این امر نشان‌دهنده دقت و کارایی بیشتر این روش است. همچنین، پراکنش نامناسب و تعداد کم داده‌های محاسباتی به دست آمده از رابطه فرولیک (Froehlich, 1988)، که بین خطوط +۲۵ و -۲۵ درصد خطا (حدوداً ۴۵ درصد از داده‌ها) واقع شده‌اند، نشان‌دهنده دقت کم این رابطه نسبت به روش رگرسیون فرایند گاوسی است.

در شکل ۳ نیز مشاهده می‌شود که داده‌های عمق

جدول ۸- تحلیل حساسیت مدل نسبت به حذف داده‌های ورودی با تابع کرنل پیرسون

شماره سناریو	(۱)	(۲)	(۳)	(۴)	(۵)	(۶)	(۷)	(۸)
پارامتر ورودی حذف شده	-	σ	V	Skew	D	D_{50}	P_w	P_s
ضریب همبستگی	۰/۹۵۵	۰/۹۵۷	۰/۹۵۸	۰/۹۵۲	۰/۸۹۸	۰/۹۵۷	۰/۹۰۰	۰/۹۳۰
ریشه میانگین مربعات خطا (متر)	۰/۳۱۴	۰/۳۰۶	۰/۳۰۶	۰/۳۲۶	۰/۴۸۳	۰/۳۰۷	۰/۴۶۱	۰/۳۸۵
میانگین خطای مطلق (متر)	۰/۲۲۴	۰/۲۲۳	۰/۲۱۷	۰/۲۳۱	۰/۲۷۷	۰/۲۱۸	۰/۲۰۵	۰/۲۶۳
درصد خطا	۲۳/۸۴	۲۳/۶۸	۲۳/۰۸	۲۴/۵۶	۲۹/۴۴	۲۳/۱۶	۳۲/۴۲	۲۸/۰۰




شکل ۴- تغییرات میزان ضریب همبستگی به ازای حذف داده‌های ورودی با بعد با تابع کرنل پیرسون

مدل به ازای حذف پارامترهای ورودی بی‌بعد با استفاده از تابع کرنل پیرسون ارائه شده است. در جدول ۹ و شکل ۵ می‌توان مشاهده کرد که از میان پارامترهای بی‌بعد، پارامتر نسبت عمق جریان به عرض پایه پل بیشترین تاثیر را بر تخمین عمق چاله آبشستگی دارد. زیرا نتایج مدل با حذف این پارامتر ورودی بیشترین کاهش را نشان می‌دهد. بعد از این پارامتر، ضریب شکل پایه پل و سپس زاویه جریان با پایه پل بیشترین تاثیر را بر روی تخمین این پدیده توسط پارامترهای بی‌بعد دارند. با حذف سایر پارامترها، نتایج تغییر چندانی نمی‌کنند.

در جدول ۸ و شکل ۴ می‌توان مشاهده کرد که از میان پارامترهای با بعد، پارامتر عمق جریان بیشترین تاثیر را بر تخمین عمق چاله آبشستگی دارد زیرا نتایج مدل با حذف این پارامتر ورودی بیشترین کاهش را نشان می‌دهد. همچنین، بعد از پارامتر عمق جریان، عرض پایه پل و سپس ضریب شکل پایه پل بیشترین تاثیر را روی تخمین این پدیده دارند. با حذف سایر پارامترها نتایج تغییر چندانی نمی‌کنند و حتی با حذف پارامترهای ورودی سرعت و توزیع دانه‌بندی مصالح بستر نتایج نسبتاً بهبود می‌یابند. در جدول ۹ و شکل ۵ نتایج تحلیل حساسیت

جدول ۹- تحلیل حساسیت مدل نسبت به حذف داده‌های ورودی بی‌بعد با تابع کرنل پیرسون

شماره سناریو	(۱)	(۲)	(۳)	(۴)	(۵)	(۶)	(۷)	(۸)
پارامتر ورودی حذف شده	-	σ	V/V _c	Skew	D/P _w	D ₅₀ /P _w	P _s	F _r
ضریب همبستگی	0.805	0.795	0.804	0.761	0.578	0.795	0.685	0.758
ریشه میانگین مربعات خطا (متر)	0.288	0.294	0.288	0.319	0.397	0.301	0.357	0.321
میانگین خطای مطلق (متر)	0.214	0.224	0.211	0.241	0.299	0.234	0.266	0.254
درصد خطا	28/92	30/25	28/59	32/65	38/88	28/91	36/29	29/52



شکل ۵- تغییرات میزان ضریب همبستگی به ازای حذف داده‌های ورودی بی‌بعد با تابع کرنل پیرسون

در حل مسائل غیر خطی دارد و می‌تواند با دقت نسبتاً خوبی این پدیده را تخمین زند. با توجه به کلیه آماره‌های ارزیابی، مقایسه نتایج به دست آمده از روابط تجربی و سناریوی برتر مربوط به روش رگرسیون فرایند گاوسی نشان می‌دهد که، رابطه تجربی فرولیک (Froehlich, 1988)، در مقایسه با روش رگرسیون فرایند گاوسی با استفاده از تابع کرنل پیرسون، در حالت استفاده از پارامترهای هم‌باعد و هم بی‌بعد عملکرد ضعیف‌تری دارد. همچنین داده‌های عمق آبشستگی به دست آمده از روش رگرسیون فرایند گاوسی نیز پراکنش بهتری نسبت به رابطه تجربی فرولیک (Froehlich, 1988) دارند و داده‌های به دست آمده با داده‌های مشاهداتی موجود همخوانی بیشتری نشان می‌دهند. در تحقیق مشابهی، پال و همکاران (Pal et al., 2012) عمق چاله آبشستگی را با مدل درختی M5 و شبکه‌های عصبی مصنوعی پیش‌بینی کردند و ضریب همبستگی برابر با ۰/۹۳ و ریشه میانگین مربعات خطا برابر با ۰/۳۹۵ متر را برای داده‌های با بعد و ضریب همبستگی برابر با ۰/۷۳۵ و ریشه میانگین مربعات خطا برابر با ۰/۷۴۸ متر را برای داده‌های بی‌بعد با استفاده از مدل درختی M5 و ضریب همبستگی برابر با ۰/۹۳۷ و ریشه میانگین مربعات خطا برابر با ۰/۳۹۰ متر را برای داده‌های با بعد با استفاده از روش شبکه عصبی مصنوعی به

نتیجه‌گیری

پدیده آبشستگی موضعی پایه پل همواره خسارات زیادی به پل‌ها در سراسر جهان وارد می‌کند. از این‌رو، این مسئله همواره مورد توجه محققان بوده، تحقیقات بسیاری در این زمینه شده، و روابط تجربی زیادی برای تخمین بیشینه عمق آبشستگی در راستای طراحی بهینه پل‌ها ارائه گردیده است. هر یک از روابط تجربی برای مجموعه داده آزمایشگاهی خود دارای کارایی بالایی است، اما بررسی کلی نتایج تحقیق حاضر نشان می‌دهد که روش رگرسیون فرایند گاوسی که برای اولین بار در ایران در این زمینه به کار گرفته شده است، در تخمین و مدلسازی بیشینه عمق آبشستگی موضعی پایه پل با استفاده از داده‌های میدانی نسبت به روابط تجربی بررسی شد، کارایی و دقت عمل بالاتری دارد. این موضوع می‌تواند برگرفته از این مسئله باشد که هر یک از روابط آزمایشگاهی تحت شرایط آزمایشگاهی خاصی به دست آمده و تعداد محدودی از متغیرها در آنها لحاظ گردیده است. در صورتی که در طبیعت شرایط محیطی بسیار متفاوت است و بسیاری از عوامل که در پدیده آبشستگی تأثیرگذار هستند در روابط آزمایشگاهی به کار نرفته‌اند. در صورتی که روش رگرسیون فرایند گاوسی با ماهیت تصادفی خویش و با بهره‌گیری از توابع کرنل توانایی بالایی

دست آوردند و نتایج را با روابط تجربی مقایسه کردند. مقایسه نتایج تحقیقات پال و همکاران (Pal et al., 2012) با نتایج تحقیق حاضر برتری اندک روش رگرسیون فرایند گاوسی را نسبت به مدل درختی M5 و شبکه عصبی مصنوعی نشان می‌دهد. نیروکاتی و همکاران (Neerukatti et al., 2013) با استفاده از روش رگرسیون فرایند گاوسی تکامل عمق آبشستگی در اطراف پایه پل را با داده‌های با بعد آزمایشگاهی پیش‌بینی کردند و با استفاده از تابع کرنل با پایه شعاعی گاوسی مقدار ضریب همبستگی عمل بالای روش رگرسیون فرایند گاوسی است. تحلیل حساسیت مدل نسبت به پارامترهای ورودی نشان‌دهنده تاثیرگذاری بیشتر پارامترهای عمق جریان، عرض پایه پل و شکل پایه پل در تخمین دقیق میزان بیشینه عمق آبشستگی موضعی پایه پل می‌باشد که این موضوع نتایج

تحقیق پال و همکاران (Pal et al., 2012) را تایید می‌کند. در تحقیق حاضر از میان توابع کرنل چند جمله‌ای ساده، چند جمله‌ای خطی، تابع پایه شعاعی و تابع پیرسون بهترین نتایج مربوط به توابع پایه شعاعی و تابع پیرسون به دست آورده شد و این توابع برای مسائل مشابه پیشنهاد می‌شود. هنگام تخمین عمق چاله آبشستگی با پارامترهای با بعد بهترین ترکیب پارامتر ورودی شامل پارامترهای ضریب شکل پایه پل، عرض پایه پل، متوسط اندازه ذرات رسوبی بستر و عمق جریان به دست آمد. هنگام تخمین عمق چاله آبشستگی با پارامترهای بی‌بعد، بهترین ترکیب پارامتر ورودی شامل پارامترهای نسبت عمق جریان به عرض پایه پل، نسبت متوسط اندازه ذرات رسوبی به عرض پایه پل، ضریب شکل پایه پل، زاویه جریان با پایه پل، نسبت سرعت جریان به سرعت بحرانی جریان و توزیع دانه‌بندی ذرات بستر شناخته شد.

مراجع

- Akib, S., Mohammadhassani, M. and Jahangirzadeh, A. 2014. Application of ANFIS and LR in prediction of scour depth in bridges. *J. Comput. Fluids*. 91, 77-86.
- Anon. 1975. Highways in the river environment: hydraulic and environmental design considerations. User Manual. Federal Highway Administration. U. S. Department of Transportation. Colorado State University.
- Arvanaghi, H., Hoseinzadeh, D., Farsadizadeh, A. and Fakheri, A. 2008. Time variation of scour around bridge piers and empirical relationship. *J. Agric. Knowl*. 18(2): 1-10. (in Persian)
- Ayubloo, M. K., Azamathulla, H. M., Ahmad, Z., Ghani, A. A., Mahjoobi, J. and Rasekh, A. 2011. Prediction of scour depth in downstream of ski-Jump spillways using soft computing techniques. *Int. J. Comput. Appl*. 33(1): 92-97.
- Chiew, Y, M. 1995. Mechanism of riprap failure at bridge piers. *J. Hydraul. Eng-ASCE*. 121(9): 635-643.
- Froehlich, D. C. 1988. Analysis of on-site measurements of scour at piers. *Proceedings of the ASCE Hydraulic Engineering Conference*. Aug. 8-12. New York.
- Gao, D. G., Posada, L. G. and Nordin, C. F. 1992. Pier scour equations used in the People's Republic of China-review and summary: Fort Collins CO. Colorado State University, Department of Civil Engineering. Draft Report.
- Ghazanfari-Hashemi, S. and Shahidi, A. A. 2012. Predicting of the local scour depth around bridge piers using support vector machine. *J. Modarres Civil Eng*. 12(2): 23-36. (in Persian)
- Hosseini, R. and Amini, A. 2015. Scour depth estimation methods around pile groups. *KSCE J. Civil Eng*. 19(7): 2144-2156.

- Houshmand, M., Givechi, M., Dehgani, A. A. and Azizian, Gh. 2011. Comparison of the performance of artificial neural network and adaptive fuzzy inference neural system in estimating of the maximum scour depth at bridge piers. Proceedings of the 6th National Congress of Civil Engineering. Apr. 26-27. University of Semnan. Semnan, Iran. (in Persian)
- Jain, S. C. and Fischer, E. E. 1980. Scour around bridge piers at high Froude numbers. Report No. FHWA-RD-79-104. Federal Highway Administration. Washington D. C. USA.
- Kuchekzadeh, S., Liaghat, A. and Sheikh-Shamayel, H. 2002. Estimation local scour depth around piers located in a river main channel using artificial neural networks. J. Iranian Agr. Sci. 33(4): 617-626.
- Melville, B.W. 1997. Pier and abutment scour: integrated approach. J. Hydraul. Eng. ASCE. 132(2): 125-136.
- Mozzammil, M. and Alam, J. 2013. ANFIS-Based approach to scour prediction at the grade control structures. European Int. J. Sci. Technol. 2(6): 123-136.
- Muller, D. S. and Wagner, C. R. 2005. Field observations and evaluations of streambed scour at bridges. Federal Highway Administration. U. S. Department of Transportation. Washington D. C. USA.
- Najafzadeh, M., Shahidi, A. A. and Yong Lim, S. 2016. Scour prediction in long contractions using ANFIS and SVM. J. Ocean Eng. 111(1): 128-135.
- Najafzadeh, M., Barani, G. A. and Hessami-Kermani, M. R. 2015. Evaluation of GMDH networks for prediction of local scour depth at bridge abutments in coarse sediments with thinly armored beds. J. Ocean Eng. 104, 387-396.
- Neerukatti, R. K., Kim, I., Yekani-Fard, M. and Chattopadhyay, A. 2013. Prediction of scour depth around bridge piers using Gaussian Process. Proceedings of the Smart Structures and Materials/NDE Conference. SPIE. 8692. March 10-14. San Diego. California. USA.
- Pal, M. and Deswal, S. 2010. Modelling pile capacity using Gaussian process regression. Comput. Geotech. 37, 942-947.
- Pal, M., Singh, N. K. and Tiwari, N. K. 2011. Support vector regression based modeling of pier scour using field data. Eng. Appl. Artif. Intel. 24, 911-916.
- Pal, M., Singh, N. K. and Tiwari, N. k. 2012. M5 model tree for pier scour prediction using field dataset. KSCE J. Civil Eng. 16(6): 1079-1084.
- Pasolli, L., Melgani, F., Member, S. and Blanzieri, E. 2010. Gaussian process regression for estimating chlorophyll concentration in subsurface waters from remote sensing data. Geosci. Remote Sensing Letters. IEEE. 7(3): 464-468.
- Samadi, M., Jabbari, E. and Azamathulla, H. M. 2014. Assesment of M5 model tree and classification and regression trees for prediction of scour depth below free overfall spillways. Neural Comput. Appl. 24(2): 357-366.
- Shafaie-Bejestan, M. 2011. Sediment Hydraulic. Shahid Chamran University Press. (in Persian)
- Shen, H. W., Schneider, V. R. and Karaki, S. 1969. Local scour around bridge piers. J. Hydr. Eng. Div. ASCE. 95(5): 1919-1940.
- Sheppard, D. M. and Miller, W. 2006. Live-Bed local pier scour experiments. J. Hydraul. Eng. ASCE. 132(7): 635-642.
- Simons, B. D. and Senturk, F. 1992. Sediment Transport Technology: Water and Sediment Dynamics. Water Resources Publications. littleton, CO.

Estimation of Scour Depth of Piers in Hydraulic Structures using Gaussian Process Regression

A. Rezazadeh-Joudi* and M. T. Sattari

* Corresponding Author: M. Sc. Water Civil Engineering, Young Researchers and Elite Club, Islamic Azad University, Maragheh Branch, Maragheh, Iran. Email: alijoudi66@gmail.com

Received: 24 August 2015, Accepted: 9 January 2016

The stability of bridge piers on rivers or in wide and deep irrigation channels is a major concern for hydraulic structural engineers. Despite development of several empirical equations for determining local scour depth at bridge abutments in hydraulic laboratories, for field data, which is affected by uncontrollable environmental circumstances, no comprehensive relationship has been reported. Gaussian process regression (GPR) is a data mining method consisting of a set of random variables that, according to normal characteristics using kernel functions, have a high ability to solve nonlinear problems. This study evaluated the efficiency of GPR for estimating pier scour depth using field scour data and compared the results with those from eight empirical equations. Of the empirical equations studied, the Froehlich empirical equation showed the best performance and was more accurate than the other experimental equations. When estimating the scour hole depth using dimensional parameters and GPR with a Pearson kernel function, the combination of input parameters of pier form factor, pier width, average particle size of bed sediment, and depth of stream provided the best-case scenario. The results represent the greatest efficiency and highest accuracy of GPR in comparison with empirical equations to estimate scour depth using sets of field data.

Keywords: Data Mining, Empirical Equations, Gaussian Process Regression, Kernel Function, Local Pier Scour