

مدل سازی کاهش کشش به وسیله نانوسیال سیلیکا در خطوط لوله افقی جریان تک فازی آب با روش وایزش بردار پشتیبان بهینه شده با الگوریتم ژنتیک و مقایسه نتایج مدل با داده های تجربی

عبدالمحمد قایدی^{۱*}، عبدالرسول پورانفرد^{۲*}، نبی اله رضانی^۳ و اعظم وفائی^۴

۱- دانشیار شیمی کاربردی، گروه شیمی، واحد گچساران، دانشگاه آزاد اسلامی، گچساران، ایران

۲- استادیار مهندسی شیمی، گروه مهندسی شیمی، دانشگاه یاسوج، یاسوج، ایران

۳- دانشجوی کارشناسی ارشد شیمی کاربردی، گروه شیمی، واحد گچساران، دانشگاه آزاد اسلامی، گچساران، ایران

۴- استادیار شیمی تجزیه، گروه شیمی، واحد گچساران، دانشگاه آزاد اسلامی، گچساران، ایران

دریافت: شهریور ۱۳۹۵، بازنگری: مرداد ۱۳۹۶، پذیرش: آبان ۱۳۹۷

چکیده: در این پژوهش، برای پیش بینی کاهش کشش با نانوسیال در جریان تک فاز آب در لوله های افقی، یک مدل پیش بینی براساس وایزش بردار پشتیبان به کار گرفته شد. برای ساخت یک مدل مؤثر وایزش بردار پشتیبان، عامل های وایزش بردار پشتیبان باید به دقت تنظیم می شد. از این رو، یک روش ترکیبی، شناخته شده با عنوان وایزش بردار پشتیبان- الگوریتم ژنتیک پیشنهاد شد که در آن جستجو برای عامل های بهینه وایزش بردار پشتیبان با الگوریتم ژنتیک انجام می گیرد و پس از آن عامل های بهینه را برای ایجاد مدل وایزش بردار پشتیبان می پذیرد. مقادیر کاهش کشش به دست آمده با مدل پیشنهادی در توافق خوبی با داده های تجربی بود. عملکرد مدل وایزش بردار پشتیبان- الگوریتم ژنتیک با مدل وایزش خطی چندگانه مقایسه شد. مقادیر ضریب تعیین ۰/۹۴۸۵ و ۰/۸۷۴۰ و مقادیر میانگین مربع خطا ۰/۰۱۱۷۷ و ۰/۰۱۷۷۲ به ترتیب بین داده های تجربی و پیش بینی شده با مدل های وایزش بردار پشتیبان- الگوریتم ژنتیک و وایزش خطی چندگانه به دست آمدند. نتایج نشان داد که مدل وایزش بردار پشتیبان- الگوریتم ژنتیک می تواند به عنوان یک روش مؤثر برای پیش بینی کاهش کشش به کار برده شود.

واژه های کلیدی: کاهش، وایزش بردار پشتیبان، الگوریتم ژنتیک، نانو سیال، لوله افقی، آب

مقدمه

برگشتی قابل توجهی بر چاه تحمیل می کند، که این پدیده باعث کاهش مقدار تولید می شود [۱]. پدیده کاهش کشش^۱ در جریان خطوط لوله برای نخستین بار توسط یک شیمیدان انگلیسی در سال ۱۹۴۸ توسط تومس^۲ گزارش شد [۲]. عامل های کاهش کشش، مواد افزودنی از قبیل بسپارها، ماده سطح فعال، حباب ریز و

در صنایع نفت و گاز که به صورت سامانه های تولید چند فازی هستند، فاصله واحدهای جداکننده مایع و گاز از چاه تولیدی به طور معمول زیاد و می تواند به اندازه چندین کیلومتر باشد. افت فشار بالا با توجه به اثرات چند فازی در خطوط لوله بیشتر یک فشار

1. Drag 2. Toms

کاهش کشش با افزایش وزن مولکولی و عدد رینولدز تمایل به افزایش دارد [۸]. در سال ۲۰۱۰، لی^۶ و همکارانش کاهش قابل توجه کشش در جریان آشفته نفت سفید حاصل از دیسک گردان در محفظه بسته، با افزودن مقداری کمی از پلی‌ایزوبوتیلن حل شده در نفت را مشاهده کردند و به تاثیر عامل‌های تجربی مانند عدد رینولدز و دما بر وابستگی زمانی کاهش کشش پرداختند که کاهش بهره‌وری پلی‌ایزوبوتیلن حل شده در نفت سفید به واسطه تخریب مکانیکی زنجیر بسپاری ناشی از جریان متلاطم بود [۹]. در سال ۲۰۱۲، کرمی و مولا، تاثیر عامل‌های متفاوت بر کاهش افت فشار ناشی از افزودن بسپارهای کاهنده کشش در خطوط انتقال نفت خام را بررسی کردند. نتیجه‌های به‌دست آمده نشان‌دهنده رابطه مستقیم کاهش کشش با دما، دبی جریان نفت، زبری لوله و غلظت مواد کاهنده کشش بود. همچنین، دریافتند که کاهش کشش با کاهش قطر لوله افزایش می‌یابد [۱۰]. در سال ۲۰۱۳، درازازگا^۷ و همکارانش در مورد تأثیر ماده فعال در سطح غیریونی بر اثر کاهش کشش در آب و نانوسیال اکسید فلزی مطالعه انجام دادند. آن‌ها دو ماده فعال در سطح غیریونی و نانوسیال پایه آبی مس اکسید (II) را مورد آزمایش قرار دادند. ضریب اصطکاک برای یک لوله به قطر ۴ میلی‌متر و عدد رینولدز بین ۸۰۰۰ و ۵۰۰۰۰ تعیین شد. نتیجه‌ها نشان داد که افزودن ماده فعال در سطح غیریونی سبب کاهش ضریب اصطکاک در آب و نانو سیال می‌شود. اثر کاهش کشش در هردو مورد مشابه بود. حضور نانوذرات در سامانه تاثیر قابل توجهی بر اثر کاهش کشش نداشت [۱۱]. در سال ۲۰۱۵، پوران‌فرد و همکارانش به بررسی تاثیر تزریق نانوسیالات، به‌ویژه نانوسیالیکیا به‌عنوان ماده کاهنده کشش در غلظت‌های متفاوت بر افت فشار جریان آب و هوا در لوله افقی پرداختند. آن‌ها از ۵ لوله با طول‌های مشابه ۹ متری با قطر داخلی ۱٫۲۵-۰٫۸ اینچ و سیال آب و هوا در گستره جریان حجمی آرام با نانوسیالیکیا در گستره غلظت ۱-۰٫۱ تا ۱ درصد وزنی استفاده کردند. نتیجه‌های کاهش کشش نشان داد که کاهش کشش بر قطرهای کوچک

نانوسیال هستند. افزودن این مواد به خطوط لوله (به‌طور معمول خطوط لوله نفت) با کاهش تلاطم باعث افزایش ظرفیت خط لوله می‌شوند [۳].

در سال ۱۹۹۶ گوین^۱ نشان داد که کسر حجمی هوای تزریق شده در نزدیک دیوار نسبت به نقاط دورتر در داخل لایه مرزی تاثیر بیشتری در کاهش اصطکاک دارد [۴]. در سال ۱۹۹۷ تاکاهاشی^۲ [۵] و در سال ۲۰۰۰ کوداما^۳ [۶]، پدیده کاهش کشش با ریزحباب‌ها را به‌طور کامل توسعه یافته در جریان کانال مشاهده کردند. برپایه گزارش‌های این افراد، بازده ریزحباب‌ها در کاهش کشش با مقدار کسر حجمی حباب‌ها رابطه مستقیم دارد و در این آزمایش‌ها، تا حدود ۸۰٪ کاهش، در ضریب اصطکاک گزارش شده است. در سال ۲۰۰۶، مولا و نادری به مطالعه تاثیر حضور پلی‌ایزوبوتیلن به‌عنوان کاهنده کشش بر تفاوت فشار خطوط افقی حاوی جریان آرام دو فازی نفت خام و هوا پرداختند. آن‌ها از سه لوله، یکی از جنس پلی‌کربنات با طول ۱۰٫۳ متر و قطر داخلی ۲٫۵۴ سانتی‌متر و دو لوله روی‌اندود^۴ آهنی با طول مشابه ۸٫۸ متر و قطرهای داخلی ۲٫۵۴ سانتی‌متر و ۱٫۲۷ سانتی‌متر استفاده کردند. درصد کاهش کشش به‌دست آمده از نتیجه‌های به‌دست آمده نشان داد که کاهش کشش تا بعضی از مقادیر مواد کاهنده کشش می‌تواند مؤثر باشد و پس از آن افت فشار ثابت خواهد ماند. آن‌ها تا ۴۰ درصد کاهش کشش برای بعضی از شرایط اعمال شده را به‌دست آوردند [۷].

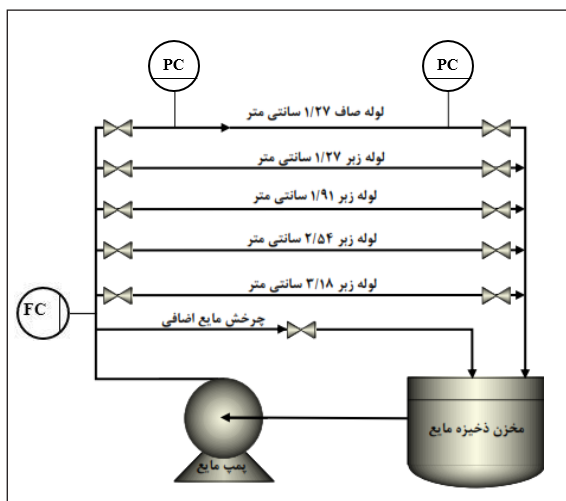
در سال ۲۰۰۹، کیم^۵ و همکارانش از اکسیدهای پلی‌اتیلن به منظور کاهش کشش استفاده کردند. تاثیر غلظت و وزن مولکولی بسپار بر سطح کاهش کشش اندازه‌گیری شد. شرایط هیدرولیکی متفاوت با اعداد رینولدز ۳۰۰۰ تا ۶۰۰۰۰ متغیر بود. نتایج نشان داد که کاهش کشش برای همه وزن‌های مولکولی استفاده شده در این پژوهش بیش از ۲۰ درصد بود. همچنین، کاهش کشش بیش از ۵۰ درصد برای وزن مولکولی 4×10^6 و غلظت ۲۰ میلی‌گرم در لیتر به‌دست آمد. در نهایت نتیجه‌ها نشان داد که

1. Guin 2. Takahashi 3. Kodama 4. Galvanized 5. Kim 6. Lee 7. Drzazga

بخش تجربی

انتخاب داده‌ها

از داده‌های نتیجه‌های آزمایش پوران فرد و همکاران در بررسی و اندازه‌گیری تأثیر تزریق نانوسیالات بر کاهش کشش در خطوط لوله افقی جریان تک فاز آب استفاده شد [۲۷]. این آزمایش‌ها همانند شکل ۱ بر یک خط لوله به‌طور کامل صاف و چهار خط لوله روی‌اندود آهنی با طول یکسان و با قطر داخلی ۱٫۲۷، ۱٫۹۱، ۲٫۵۴ و ۳٫۱۸ سانتی‌متر انجام شد و تفاوت فشار آب یک بار بدون حضور نانوسیال (ΔP) و در حضور نانوسیال سیلیکا (ΔP_{DRA}) در گستره غلظت ۰٫۲۵، ۰٫۵، ۰٫۷۵ و ۱ درصد وزنی اندازه‌گیری و درصد کاهش کشش در رینولدزهای متفاوت محاسبه شد. تغییرات تفاوت فشار آب در حضور نانوسیال و بدون حضور نانوسیال در ۸۰ تکرار انجام گرفت که بالاترین درصد کاهش کشش اندازه‌گیری شده، حدود ۲۴ درصد و مربوط به حضور نانوسیال با غلظت ۱ درصد وزنی با عدد رینولدز ۲۷۸۶۲ در خط لوله زبر با قطر داخلی ۱٫۲۷ سانتی‌متر بود. جدول ۱ داده‌های تجربی استفاده شده را نشان می‌دهد که این داده‌ها به‌صورت تصادفی به دو گروه آموزش و اعتبارسنجی با نسبت ۷۰ به ۳۰ تقسیم شدند.



شکل ۱ طرح‌واره‌ای از دستگاه تجربی

عملکرد بهتری نسبت به قطرهای بزرگ‌تر دارد. بیش‌ترین مقدار کاهش کشش حدود ۶۶٫۸ درصد برای ۰٫۷۵ درصد وزنی از غلظت نانوسیال بود [۱۲].

مدل‌سازی یک روش مفید و اثبات شده برای حل مشکلات در رشته‌های متفاوت مهندسی با ساده‌کردن سامانه‌های پیچیده است. وایزش بردار پشتیبان یک ماشین یادگیری جدید براساس نظریه یادگیری آماری و اصل حداقل‌سازی ریسک ساختاری است، که با موفقیت برای مدل‌سازی سامانه غیرخطی استفاده شده است [۱۳]. در مقایسه با شبکه‌های عصبی مصنوعی، یک وایزش بردار پشتیبان عملکرد قابل اعتمادتر و بهتری در شرایط آموزشی یکسان فراهم می‌کند [۱۴ و ۱۵]، ولی در پژوهش‌های علمی و کاربردهای صنعتی به‌طور محدود استفاده می‌شود، زیرا کاربر باید عامل‌های متفاوت مناسب را برای این مدل تعریف کند. عامل‌های وایزش بردار پشتیبان^۱ باید به دقت به منظور ساخت مدل مؤثر تنظیم شوند [۱۶ تا ۱۸]. انتخاب نامناسب عامل‌های وایزش بردار پشتیبان منجر به وراموزی^۲ یا کم‌آموزی و تفاوت قابل توجهی در عملکرد مدل خواهد شد [۱۹]. بنابراین، انتخاب عامل‌های بهینه یک گام مهم در طراحی وایزش بردار پشتیبان است. با این حال، هیچ دستورالعمل عمومی برای کمک به انتخاب این عامل‌ها قابل دسترس نیست [۲۰ تا ۲۲]. پای^۳ و هونگ^۴ [۲۳] با الگوریتم ژنتیک^۵ و الگوریتم تبرید تدریجی^۶ [۲۴] و هونگ و همکاران برپایه الگوریتم بهینه‌سازی کلونی مورچگان پیوسته^۷ [۲۵] و الگوریتم ژنتیک [۲۶] متغیرهای ماشین بردار پشتیبان را به‌دست آوردند.

در این پژوهش، یک رویکرد ترکیبی از وایزش بردار پشتیبان با الگوریتم ژنتیک پیشنهاد شده است، درنهایت از الگوریتم ژنتیک برای تعیین عامل‌های وایزش بردار پشتیبان در پیش‌بینی کاهش کشش با نانوسیال سیلیکا در خطوط لوله افقی جریان تک فازی آب استفاده شد.

1. Support vector regression 2. Overlearning 3. Pai 4. Hong 5. Genetic algorithm 6. Simulated annealing
7. Continuous ant colony optimization algorithms

جدول ۱ داده‌های تجربی کاهش کشش

ردیف	غلظت نانو سیال (درصد وزنی)	درصد کاهش کشش*				
		لوله صاف با قطر داخلی (برحسب سانتی‌متر)	لوله زبر با قطر داخلی (برحسب سانتی‌متر)			
		۱,۲۷	۱,۲۷	۱,۹۱	۲,۵۴	۳,۱۸
۱	۰,۲۵	۰,۹	۲,۵	۳,۵	۳,۲	۳,۸
۲	۰,۵۰	۲,۶	۸,۱	۸,۹	۷,۹	۷,۱
۳	۰,۷۵	۳,۸	۱۰,۸	۱۰,۹	۹,۵	۸,۸
۴	۱,۰۰	۵,۱	۱۲,۵	۱۲,۴	۱۱,۱	۱۰,۱
۵	۰,۲۵	۳,۴	۴,۶	۵,۷	۳,۹	۲,۵
۶	۰,۵۰	۸,۹	۱۱,۲	۱۱,۴	۹,۱	۷,۱
۷	۰,۷۵	۱۱,۳	۱۲,۹	۱۳,۳	۱۰,۸	۸,۲
۸	۱,۰۰	۱۳,۲	۱۴,۶	۱۴,۲	۱۲,۷	۹,۸
۹	۰,۲۵	۵,۴	۶,۲	۷,۶	۴,۸	۳,۸
۱۰	۰,۵۰	۱۱,۹	۱۲,۹	۱۳,۷	۱۰,۷	۹,۶
۱۱	۰,۷۵	۱۳,۸	۱۴,۶	۱۵,۶	۱۲,۴	۱۱,۱
۱۲	۱,۰۰	۱۵,۲	۱۶,۱	۱۷,۲	۱۳,۵	۱۱,۹
۱۳	۰,۲۵	۹,۳	۱۱,۳	۱۰,۲	۷,۸	۵,۱
۱۴	۰,۵۰	۱۵,۷	۱۹,۲	۱۵,۴	۱۳,۱	۱۰,۴
۱۵	۰,۷۵	۱۸,۲	۲۱,۸	۱۷,۰	۱۴,۵	۱۲,۲
۱۶	۱,۰۰	۱۹,۸	۲۳,۶	۱۸,۶	۱۵,۲	۱۳,۲

$$* ((\Delta P - \Delta P_{DRA}) / \Delta P) \times 100$$

ماشین بردار پشتیبان برای پیش‌بینی متغیرهای هدف پیوسته به کار گرفته شده است [۲۹]. اگر داده‌ها به حالت غیر خطی با پیچیدگی و ابعاد زیاد باشد، ابتدا داده‌ها به فضای ویژگی انتقال داده می‌شود، و سپس، در این فضا با تابع جداسازی خطی f ، رابطه غیر خطی بین متغیر ورودی و خروجی فرمول‌بندی می‌شود. این تابع که تابع وایزش بردار پشتیبان نامیده می‌شود، برای پیش‌بینی متغیر خروجی استفاده می‌شود.

$$f(x) = w^T \phi(x) + b \quad (1)$$

وایزش بردار پشتیبان

وایزش بردار پشتیبان برای نخستین بار توسط وپنیک برای حل مسأله‌های پیش‌بینی بر اساس بردارهای پشتیبان ارائه شد [۲۸]. ماشین‌های بردار پشتیبان به‌طور عموم برای مسأله‌های کلاس‌بندی به کار گرفته می‌شوند. در حالی که در مسأله‌ها با متغیر هدف پیوسته (برای مسأله‌های پیش‌بینی)، از توسعه یافته بردار پشتیبان یعنی وایزش بردار پشتیبان استفاده می‌شود. وایزش بردار پشتیبان بر پایه نظریه حاشیه نرم به‌عنوان روشی برای حل مسأله‌ها و مشکلات وایزش غیرخطی و توسعه مدل دو کلاسه

تفاوت بین مقدار واقعی خروجی (v_i) و مقدار پیش‌بینی در گستره وایازش، صفر در نظر گرفته می‌شود. این مدل از یک سوی خطا بر داده‌های آموزشی (ریسک عملی) و از سوی دیگر، ریسک ساختاری را کم می‌کند تا مدل دچار بیش‌برازش نشود.

ماشین بردار پشتیبان مبتنی بر کاهش ساختاری ریسک است که از نظریه آموزش آماری گرفته شده است [۲۸]. وپنیک برای کاربرد ماشین‌های بردار پشتیبان در مسأله‌های وایازش از تابع خطایی استفاده کرد که خطاهایی که در یک ϵ -Insensitive نام فاصله معین از مقادیر واقعی هستند، را نادیده می‌گیرد [۳۰]. این تابع به صورت معادله ۴ تعریف می‌شود:

$$L = (y, f(x, a)) = |y - f(x, a)| \epsilon = \begin{cases} 0 & \text{for } \dots |y - f(x, a)| \geq \epsilon \\ |y - f(x, a)| - \epsilon & \text{if } \dots |y - f(x, a)| > \epsilon \end{cases} \quad (4)$$

این تابع خطا مقادیر خطای کمتر از ϵ را در نظر نمی‌گیرد. مسأله تقریب یک مجموعه از داده‌های زیر را در نظر می‌گیریم:

$$D = \{(x^1, y^1), \dots, (x^i, y^i)\}, (x \in R^n, y \in R) \quad (5)$$

تابع وایازش با تابع زیر تخمین زده می‌شود:

$$f(x) = \langle w, x \rangle + b \quad (6)$$

که در آن، $\langle \cdot \rangle$ ضرب داخلی است. تابع بهینه وایازش به وسیله کمترین تابع زیر بیان می‌شود:

$$\varphi = (\omega, \xi) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N (\xi_i^- + \xi_i^+) \quad (7)$$

به شرط:


$$\begin{cases} y_i - (\langle \omega, x_i \rangle + b) \leq \epsilon + \xi_i \\ (\langle \omega, x_i \rangle + b) - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

که در آن w وزن بردارها و b عرض از مبدأ است. هدف در وایازش کمتر کردن مقدار خطا بین مقدار متغیر خروجی واقعی (v_i) و مقدار پیش‌بینی ($f(x) = w^T \phi(x_i) + b$) است. بنابراین، با توجه به شکل ۲، مسأله تبدیل به مدل کمینه‌سازی برنامه‌ریزی غیرخطی به صورت زیر در می‌آید:

$$\text{Min } \frac{1}{2} \|w\|^2 \quad (2)$$

به شرط:

$$\begin{cases} y_i - w \phi(x) - b \leq \epsilon \\ w \phi(x) + b - y_i \leq \epsilon \end{cases}$$



شکل ۲ نگاهت داده‌ها در فضای ویژگی برای اعمال بردار پشتیبان وایازش

با در نظر گرفتن حاشیه نرم C و قبول کردن مقداری خطا، دو متغیر کمکی ξ_i^* و ξ_i^- (فاصله بین مقدار واقعی داده با گستره وایازش) به مدل افزوده می‌شوند و مسأله وایازش به صورت زیر تبدیل می‌شود:

$$\text{Min } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (3)$$

به شرط:

$$\begin{cases} y_i - w \phi(x) - b \leq \epsilon + \xi_i & \xi_i \geq 0 \\ w \phi(x) + b - y_i \leq \epsilon + \xi_i^* & \xi_i^* \geq 0 \end{cases}$$

باید با یک روش بهینه‌سازی به‌طور دقیق محاسبه شوند. این عامل‌ها عبارت‌اند از:

- عامل تابع کرنل σ

- عامل تنظیم‌کننده C

- عامل دقت ϵ مربوط به حداکثر خطا

انتخاب صحیح عامل‌های کرنل (C, σ, ϵ) ، تأثیر بسزایی در دقت بردار پشتیبان دارد [۳۱]. روش‌های ابتکاری موفقی برای تعیین مقدار این عامل‌ها استفاده نشده است. در این پژوهش، از الگوریتم ژنتیک برای بهینه‌سازی عامل‌های وایزش بردار پشتیبان استفاده شده است.

الگوریتم ژنتیک

الگوریتم‌های ژنتیک توسط گولبرگ^۱ در سال ۱۹۸۹ پیشنهاد شد [۳۲]. الگوریتم‌های ژنتیک به صورت کلی زیر مجموعه الگوریتم‌های تکاملی به حساب می‌آیند. الگوریتم ژنتیک از اصول تکامل طبیعی داروین گرفته شده و یکی از شیوه‌های جستجو و بهینه‌سازی تصادفی است که بر مبنای اصول تکامل طبیعی پایه‌ریزی شده است [۳۳]. نخستین و مهم‌ترین نقطه قوت این الگوریتم‌ها این است که به‌طور ذاتی موازی‌اند. بیشتر الگوریتم‌های دیگر موازی نیستند و فقط می‌توانند فضای مسئله مورد نظر را در یک جهت در یک لحظه جستجو کنند. اگر راه حل پیدا شده یک جواب بهینه محلی و یا زیر مجموعه‌ای از جواب اصلی باشد باید تمام کارهایی که تا به حال انجام شده را کنار گذاشت و دوباره از اول شروع کرد. از آنجایی که الگوریتم ژنتیک چندین نقطه شروع دارد، در یک لحظه می‌تواند فضای مسأله را از چند جهت متفاوت جستجو کند. اگر یکی به نتیجه نرسید، سایر راه‌ها ادامه می‌یابند و منابع بیشتری در اختیارشان قرار می‌گیرد. از محدودیت‌های این الگوریتم می‌توان به مشکل چگونگی نوشتن عملگر ارزیاب اشاره کرد که منجر به بهترین راه حل برای مسأله می‌شود. اگر این کارکرد برآزش به خوبی و قوی انتخاب نشود، ممکن است باعث شود که راه حلی برای مسئله پیدا نکنیم یا مسأله‌ای دیگر به اشتباه

که در آن C ، یک مقدار از پیش تعیین شده و ξ_i^* ، ξ_i متغیرهای پوسته هستند که قیدهای بالا و پایین خروجی سامانه را تعیین می‌کنند. اگر داده‌ها به صورت خطی مجزا از هم باشند، یک سطح بهینه که داده‌ها را بدون خطا و با حداکثر فاصله میان صفحه و نزدیک‌ترین نقاط آموزشی (بردارهای پشتیبان) تفکیک می‌کند، آموزش می‌دهد. اگر نقاط آموزش را به صورت $[x_i; y_i]$ و بردار ورودی $x_i \in R^n$ تعریف کنیم، در حالتی که داده‌های به صورت خطی قابل تفکیک باشند، معادله به صورت زیر است:

$$y = f(x) = \text{sign} \left[\sum_{i=1}^N y_i a_i \langle x_{i,x} \rangle + b \right] \quad (8)$$

که در آن، y خروجی معادله و y_i ارزش طبقه نمونه آزمایشی x_i است. بردار $x = (x_1, x_2, \dots, x_n)$ نشان‌دهنده یک داده ورودی و بردارهای $x_i, i=1, 2, \dots, N$ بردارهای پشتیبان هستند. اگر داده‌ها به صورت خطی قابل تفکیک نباشند، می‌توان با اعمال پیش پردازش، نمونه‌ها را به فضایی بالاتر برد. در این حالت معادله ۸ به صورت معادله ۹ تغییر می‌یابد:

$$y = f(x) = \text{sign} \left[\sum_{i=1}^N y_i a_i K \langle x_{i,x} \rangle + b \right] \quad (9)$$

تابع $K(x, x_i)$ تابع کرنلی است که برای ایجاد ماشین‌هایی با انواع متفاوتی از سطوح غیرخطی در فضای داده‌ها، ضرب‌های داخلی تولید می‌کند. برای مدل وایزش بردار پشتیبان، تابع‌های کرنلی متفاوتی شامل خطی، درجه دوم، گوسی و چند جمله‌ای به‌کارگرفته می‌شوند. به‌طور معمول تابع کرنل گوسی شعاعی برای پیش‌بینی عملکرد بهتری دارد [۳۱]. معادله این تابع کرنل به صورت زیر است:

$$K(x, y) = \exp \left(-\frac{\|x_i - y_j\|^2}{2\sigma^2} \right) \quad (10)$$

در ساخت یک مدل کارآمد ماشین بردار پشتیبان، عامل‌هایی

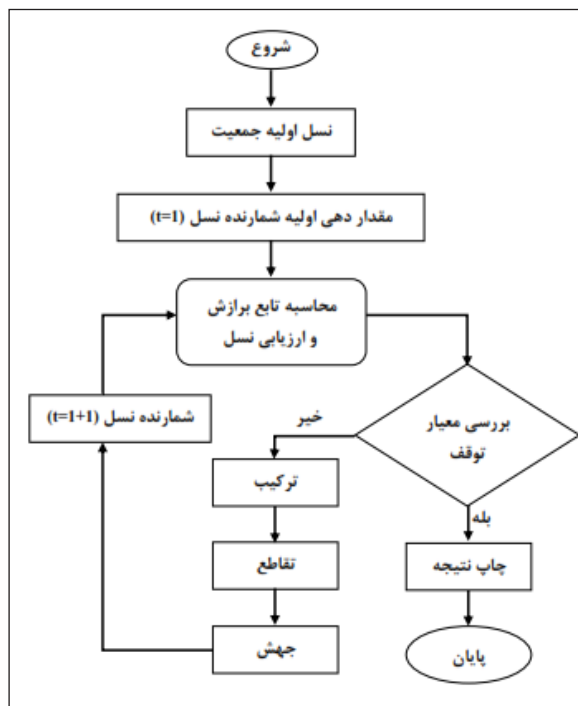
1. Golberg

۱. مقداردهی اولیه عامل‌های الگوریتم ژنتیک.
۲. تولید تصادفی جمعیت اولیه و آماده‌سازی رشته کد شده.
۳. محاسبه شایستگی هر فرد در جمعیت قدیمی.
۴. ایجاد یک استخر تولید مثل از جمعیت قدیمی.
۵. انتخاب تصادفی دو والد از استخر تولید مثل.
۶. انجام ادغام تقاطعی والدین برای تولید دو فرزند.
۷. جهش در صورت لزوم.
۸. قراردادن رشته‌های فرزند به‌عنوان جمعیت جدید.
۹. محاسبه شایستگی هر فرد در جمعیت جدید.
۱۰. ایجاد بهترین و مناسب‌ترین جمعیت از جمعیت قبلی و جدید.
۱۱. تکرار مراحل ۴ تا ۱۰ تا اینکه بهترین افراد در جمعیت‌های جدید مقدار بهینه تابع عملکرد را نشان دهند.

وایازش بردار پشتیبان-الگوریتم ژنتیک

شکل ۴ ساختار مدل وایازش بردار پشتیبان-الگوریتم ژنتیک را نشان می‌دهد. در این مدل، از الگوریتم ژنتیک برای انتخاب بهینه‌ترین عامل‌های وایازش بردار پشتیبان استفاده شده است. متغیرهای مربوط به وایازش بردار پشتیبان عامل‌های تابع کرنل را نیز در بر می‌گیرند. برای این کار از تابع پایه شعاعی کرنل استفاده شد، چرا که تابع پایه شعاعی کرنل داده‌های با ابعاد بالاتری را می‌تواند تحلیل کند. مدل ارائه شده با وایازش بردار پشتیبان-الگوریتم ژنتیک، شامل چهار گام اصلی است که در ادامه به تفصیل شرح داده می‌شوند. بررسی مدل پیشنهادی با دو گروه انجام شد. گروه اول شامل ۷۰ درصد داده‌ها به عنوان گروه آموزش در نظر گرفته شد و گروه دیگر شامل ۳۰ درصد داده‌ها به عنوان گروه اعتبارسنجی در نظر گرفته شد. در این مدل پس از بارگذاری داده‌ها و تنظیم دیگر عامل‌های مدل مثل جمعیت اولیه و شرط توقف (تعداد نسل‌ها) الگوریتم ژنتیک شروع به عمل می‌کند، الگوریتم ژنتیک برای بررسی کروموزوم‌ها از احتمال پیش‌بینی خطا با وایازش بردار پشتیبان به‌عنوان تابع جریمه استفاده می‌کند.

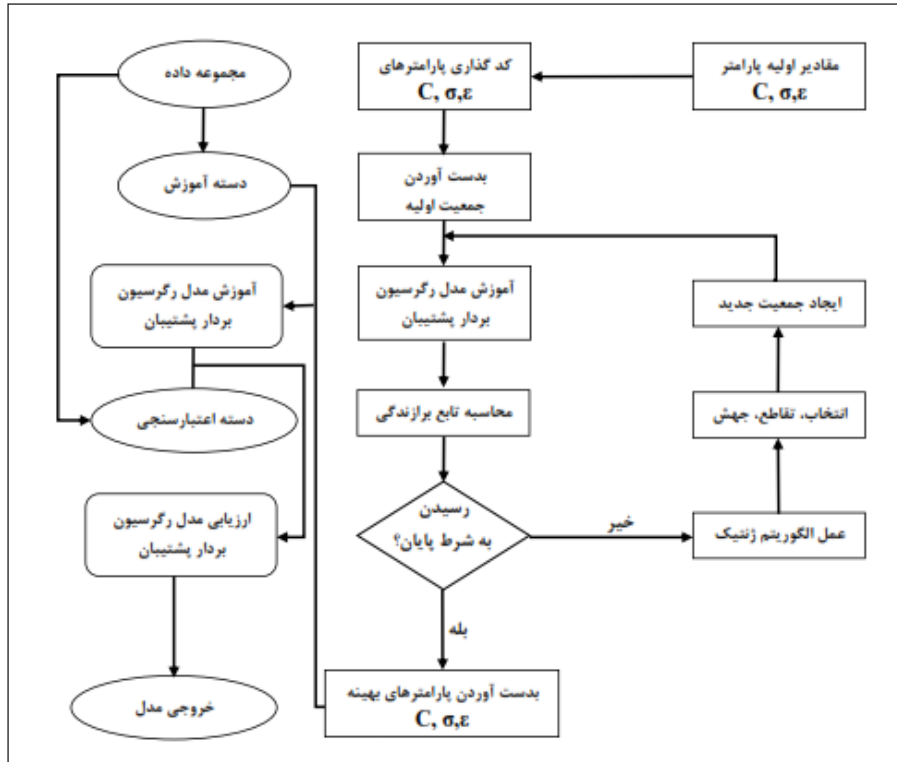
حل شود. مشکل دیگر، که آن را «نارس» می‌نامند، این است که اگر یک ژنوم که فاصله‌اش با اندازه ژنوم‌های نسل‌اش زیاد باشد (خیلی بهتر از بقیه باشد) خیلی زود دیده می‌شود و ممکن است محدودیت ایجاد کند و راه حل را به سوی جواب بهینه محلی سوق دهد. این اتفاق به‌طور معمول در جمعیت‌های کم اتفاق می‌افتد [۳۴]. در دهه ۷۰ میلادی دانشمندی از دانشگاه میشیگان به نام هلند^۱ ایده استفاده از الگوریتم ژنتیک را در بهینه‌سازی‌های مهندسی مطرح کرد [۳۵]. از آنجایی که الگوریتم ژنتیک نیازی به مشتق‌گیری و حدس اولیه ویژه‌ای ندارد و نیز یک فرایند اتفاقی است، قادر است تمامی فضای حل را با احتمال بیشتری، نسبت به دیگر شیوه‌های معمول، برای یافتن جواب کلی جستجو کند. قدرتمندی، بازده و انعطاف‌پذیری از ویژگی این الگوریتم است. با توجه به این موارد، استفاده از این الگوریتم در مهندسی به سرعت رو به ازدیاد است. عمل الگوریتم ژنتیک برای بهینه‌سازی عامل‌ها را می‌توان به شرح زیر بیان کرد (شکل ۳) [۳۶].



شکل ۳ نمودار جریان الگوریتم ژنتیک

1. Holland

پس از اجرای الگوریتم و رسیدن به شرط توقف، کروموزوم نهایی که عملکرد بهتری داشت به‌عنوان بهترین جواب انتخاب شد. در این پژوهش، از نرم‌افزار متلب^۱ برای برنامه‌نویسی و اجرای مدل استفاده شد.



شکل ۴ ساختار مدل و ابازش بردار پشتیبان- الگوریتم ژنتیک

که در آن‌ها، N تعداد داده‌ها، y_m میانگین مقادیر تجربی، y_i مقدار پیش‌بینی شده و y_{id} مقدار واقعی است.

نتیجه‌ها

نتیجه‌های بهینه‌سازی با روش و ابازش بردار پشتیبان- الگوریتم ژنتیک

برای به‌دست آوردن بهترین پاسخ عامل‌های اندازه جمعیت، نسل، تقاطع و جهش به ترتیب در گستره ۲۰-۱ و ۳۰۰-۵۰ و ۱-۰٫۱ و ۱-۰٫۱ تغییر داده شد که بهترین نتیجه‌ها برای این متغیرها در جدول ۲ نشان داده شده است. با تغییر عامل‌های

بررسی عملکرد مدل

معیار عملکرد، شاخصی است که درصد صحت پیش‌بینی مدل را می‌سنجد. در این پژوهش، از دو معیار میانگین مربعات خطا^۲ (MSE) و ضریب تعیین^۳ (R^2) به منظور بررسی عملکرد مدل‌های پیشنهادی استفاده شد.

$$MSE = \frac{1}{N} \sum_{i=1}^N (|y_i - y_{id}|)^2 \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - y_{id})^2}{\sum_{i=1}^N (y_i - y_m)^2} \quad (12)$$

1. Golberg 2. Mean square error 3. Coefficient of determination

الگوریتم ژنتیک عامل‌های بهینه خروجی الگوریتم، که منجر به بهترین نتیجه‌ها برای وایزش بردار پشتیبان شد، در جدول ۳ گزارش شده است.

جدول ۲ عامل‌های بهینه الگوریتم ژنتیک

عامل	گستره تغییر عامل	بهترین حالت
اندازه جمعیت	۱۰-۲۰۰	۱۰۰
نسل	۵۰۰-۳۰۰۰	۱۰۰۰
تقاطع	۰.۱-۱.۰	۰.۸
جهش	۰.۱-۱.۰	۰.۵

جدول ۴ عامل‌های آماری به‌دست آمده برای گروه‌های اعتبارسنجی و آموزش


روش	گروه	MSE	R ²
GA-SVR*	آموزش	۰.۰۱۹۵۶	۰.۹۳۶۵
	اعتبارسنجی	۰.۰۱۱۷۷	۰.۹۴۸۵

* Genetic Algorithm-Support Vector Regression

شکل ۵ همبستگی بین داده‌های تجربی و مقادیر پیش‌بینی شده با مدل را برای گروه‌های آموزش و اعتبارسنجی نشان می‌دهد. همان‌طور که این شکل‌ها نشان می‌دهند، توافق خوبی بین نتیجه‌های تجربی و پیش‌بینی شده وجود دارد.

جدول ۳ عامل‌های بهینه شده مدل وایزش بردار پشتیبان

شماره	ε	σ	C
۱	۰.۰۱۳۵	۰.۱۱۲۷	۰.۵۵۶۰
۲	۰.۰۲۶۱	۰.۲۰۰۵	۰.۶۱۷۵
۳	۰.۰۲۴۴	۰.۰۵۲۴	۱/۰.۰۲۱
۴	۰.۰۱۸۲	۰.۰۸۲۴	۱.۰۲۲۷
۵	۰.۰۲۴۴	۰.۱۳۱۸	۰.۷۴۸۴
۶	۰.۰۳۳۵	۰.۰۳۴۱	۱.۴۷۱۵
۷	۰.۰۲۱۹	۰.۱۲۹۴	۰.۵۷۴۷
۸	۰.۰۲۲۹	۰.۰۸۴۲	۰.۸۷۰۸
۹	۰.۰۱۲۱	۰.۱۲۰۵	۰.۴۳۴۴
۱۰	۰.۰۲۴۸	۰.۰۴۸۴	۱.۷۶۱۵
۱۱	۰.۰۱۴۹	۰.۱۴۱۶	۰.۵۳۹۷
۱۲	۰.۰۱۶۹	۰.۱۵۶۴	۰.۳۸۷۳
۱۳	۰.۰۲۳۰	۰.۱۲۲۵	۰.۶۶۱۴
۱۴	۰.۰۲۱۲	۰.۱۱۱۹	۰.۸۳۷۳
۱۵	۰.۰۲۵۹	۰.۰۶۹۱	۱.۱۸۴۴
۱۶	۰.۰۲۴۰	۰.۱۶۸۴	۰.۴۴۸۲
۱۷	۰.۰۱۳۸	۰.۱۸۰۳	۰.۴۳۶۴
۱۸	۰.۰۱۴۵	۰.۲۱۷۴	۰.۴۶۹۴
۱۹	۰.۰۲۵۶	۰.۱۵۰۱	۰.۶۷۷۶
۲۰	۰.۰۲۲۹	۰.۰۶۹۹	۰.۹۳۱۲



شکل ۵ همبستگی بین داده‌های تجربی و مقادیر پیش‌بینی شده با مدل پیشنهادی برای گروه‌های آموزش و اعتبارسنجی

پیش‌بینی و بررسی اعتبار مدل

جدول ۴ مقدار R² و MSE را برای گروه آموزش به ترتیب

نتیجه‌گیری

مدل پیشنهادی با هشتاد داده تجربی مورد بررسی قرار گرفت و نتایج‌های آن با وایازش خطی چندگانه مقایسه شد. عامل‌های آماری محاسبه شده از قبیل ضریب تعیین و میانگین مربع خطا به ترتیب با مقادیر ۰٫۹۴۸۵ و ۰٫۱۱۷۷ برتری مدل پیشنهادی را نسبت به وایازش خطی چندگانه نشان داد. توافق خوبی که بین نتیجه‌های تجربی و مقادیر پیش‌بینی شده وجود داشت، اعتبار مدل پیشنهادی را تأیید کرد. برای کارهای آینده می‌توان از الگوریتم‌های ازدحام ذرات و رقابت استعماری برای بهینه‌سازی عامل‌ها از مدل وایازش بردار پشتیبان استفاده کرد.

سپاسگزاری

این پژوهش با حمایت دانشگاه آزاد اسلامی واحد گچساران انجام شده است که به این وسیله تشکر و قدردانی نویسندگان از این واحد آموزشی به‌عمل می‌آید.

بیشتر صنایع تولیدکننده نفت و گاز برای کمک به کاهش افت فشار در انتقال مایعات تک فاز در مسافت‌های طولانی از مواد کاهش کشش استفاده می‌کنند که یکی از این مواد افزودنی نانوسیال است. نتیجه‌های پژوهش‌های پیشین نشان می‌دهد که با افزایش غلظت نانوسیال مقدار کاهش کشش افزایش می‌یابد، اما یک غلظت بحرانی وجود دارد که بالاتر از آن هیچ کاهش قابل توجهی از کاهش کشش در لوله‌ها دیده نمی‌شود. همچنین، به علت جریان متلاطم بیشتر در لوله‌های زیر، نسبت کاهش کشش در این لوله به لوله صاف بیشتر است. هدف این پژوهش، پیش‌بینی کاهش کشش با نانوسیال سیلیکا در جریان تک فاز آب در لوله‌های افقی با استفاده از مدل ترکیبی وایازش بردار پشتیبان و الگوریتم ژنتیک بود که الگوریتم ژنتیک برای به‌دست آوردن عامل‌های بهینه مدل وایازش بردار پشتیبان به‌کاربرده شد.

مراجع

- [1] Fernandes, R.; Jutte, B.; Rodriguez, M.; Int. J. Multiph. Flow 30, 1051-1069, 2004.
- [2] Toms, B.A.; "Proc. 1st Int. Cong. Rheol." 135-141, Amsterdam, North-Holland, 1948.
- [3] Abdulbari, H.; Ming, F.; J. Eng. Res. 12, 60-67, 2015.
- [4] Guin, M.M.; Kato, H.; Yamaguchi, H.; Maeda, M.; Miyanaga, M.; J. Mar. Sci. Tech. 1, 241-254, 1996.
- [5] Takahashi, T.; Kakugawa, A.; Kodama, Y.; J. Soc. Nav. Archit. Jpn. 182, 1-8, 1997.
- [6] Kodama, Y.; Kakugawa, A.; Takahashi, T.; Kawashima, H.; Int. Heat Fluid Fl. 21, 582-588, 2000.
- [7] Mowla, D.; Naderi, A.; Chem. Eng. Sci. 61, 1549-1554, 2006.
- [8] Kim, N.-J.; Kim, S.; Lim, S.H.; Chen, K.; Chun, W.; Int. J. Heat Mass Transf. 36, 1014-1019, 2009.
- [9] Lee, K.-H.; Zhang, K.; Choi, H.J.; J. Ind. Eng. Chem. 16, 499-502, 2010.
- [10] Karami, H.; Mowla, D.; J. Nonnewton. Fluid Mech. 177, 37-45, 2012.
- [11] Drzazga, M.; Gierczycki, A.; Dzido, G.; Le-manowicz, M.; Chin. J. Chem. Eng. 21, 104-108, 2013.
- [12] Pouranfard, A.; Mowla, D.; Esmailzadeh, F.; Chin. J. Chem. Eng. 23, 471-475, 2015.
- [13] Vapnik, V.; Golowich, S.E.; Smola, A.; Adv. Neural Inf. Process Syst. 9, 281-287, 1997.
- [14] King, S.L.; Bennett, K.P.; List, S.; Comput. Electron. Agric. 27, 401-406, 2000.
- [15] Yuan, Y.; Zhang, R.; Hu, R.; Ruan, X.; Eur. J. Med. Chem. 44, 25-34, 2009.
- [16] Duan, K.; Keerthi, S.S.; Poo, A.N.; Neuro-computing 51, 41-59, 2003.

- [17] Keerthi, S.S.; IEEE Trans. Neural Netw. 13, 1225-1229, 2002.
- [18] Lin, P.; "Support vector regression: systematic design and performance analysis", Doctoral Dissertation, Department of Electronic Engineering, National Taiwan University, 2001.
- [19] Niani, C.; Wencong, L.; Jie, Y.; Gozheng, L.; "Support Vector Machine in Chemistry", World Scientific Publishing Co. Pet. Ltd., Shanghai, 2004.
- [20] Cristianini, N.; Shawe-Taylor, J., "An introduction to support vector machines and other kernel-based learning methods". Cambridge university press, Cambridge, 2000.
- [21] Schölkopf, B.; Smola, A.J., "Learning with kernels: support vector machines, regularization, optimization, and beyond", MIT press, Cambridge, 2002.
- [22] Vapnik, V.N.; Vapnik, V., "Statistical learning theory", Wiley, New York, 1998.
- [23] Pai, P.F.; Hong, W.-C.; Ann. Tourism Res. 32, 1138-1141, 2005.
- [24] Pai, P.F.; Hong, W.-C.; J. Syst. Software 79, 747-755, 2006.
- [25] Hong, W.C.; Dong, Y.; Zheng, F.; Lai, C.Y.; Appl. Math. Model. 35, 1282-1291, 2011.
- [26] Hong, W.C.; Dong, Y.; Chen, L.-Y.; Wei, S.-Y.; Appl. Soft Comput. 11, 1881-1890, 2011.
- [27] Pournafard, A.; Mowla, D.; Esmailzadeh, F.; J. Ind. Eng. Chem. 20, 633-637, 2014.
- [28] Vapnik, V., "The nature of statistical learning theory", Springer Science & Business Media, Berlin, Heidelberg, 2013.
- [29] Smola, A.J.; Schölkopf, B.; Stat. Comput. 14, 199-222, 2004.
- [30] Basak, D.; Pal, S.; Patranabis, D.C.; Neural Inf. Process. Lett. Review. 11, 203-224, 2007.
- [31] Cherkassky, V.; Ma, Y.; Neural Netw. 17, 113-126, 2004.
- [32] Golberg, D.E.; "Genetic algorithms in search, Optimization and Machine Learning", Addison-Wesley, New York, 1989.
- [33] *
* به اوی، امید؛ صالحی، منوچهر؛ "الگوریتم‌های ژنتیک و بهینه سازی های مرکب"، انتشارات دانشگاه صنعتی امیر کبیر، ۱۳۸۷، ۲۴.
- [34]*
* رضائی، علیرضا؛ رنجبران، سجاد؛ "آموزش کاربردی الگوریتم ژنتیک در نرم‌افزار متلب"، انتشارات آذر، تهران، ۱۳۸۶.
- [35] Holland, J.; "Adaption in Natural and artificial systems", Ann Arbor, MI: University of Michigan Press, MI, USA, 1975.

Modelling of drag reduction of silica nanofluid in single-phase flow of water through horizontal pipelines using support vector regression optimized by genetic algorithm and comparison between the model results and experimental data

A.M. Ghaedi^{1*}, A.R. Pouranfard^{2*}, A. Vafaei³ and N. Ramezani⁴

1. Associate Prof. of Applied Chemistry, Department of Chemistry, Gachsaran Branch, Islamic Azad University, Gachsaran, Iran
2. Assistant Prof. of Chemical Engineering, Department of Chemical Engineering, Yasouj University, Yasouj, Iran
3. Assistant Prof. of Analytical Chemistry, Department of Chemistry, Gachsaran Branch, Islamic Azad University, Gachsaran, Iran
4. M.Sc. student in Applied Chemistry, Department of Chemistry, Gachsaran Branch, Islamic Azad University, Gachsaran, Iran

Received: August 2016, Revised: August 2017, Accepted: November 2018

Abstract: Drag reduction prediction plays an important role in oil and gas industries. Due to the nonlinearity and instability of drag reduction, the precision of the commonly used conventional methods, including regression analyses, has been limited. A prediction model based on support vector regression (SVR) is presented in this paper to predict drag reduction by nanofluids in single-phase flow of water through horizontal pipes. To construct an effective SVR model, the SVR parameters must be set carefully. This study proposes a hybrid approach, known as support vector regression- genetic algorithm (SVR-GA), which searches for the optimal SVR parameters using GA, and accepts the optimal parameters to create the SVR models. The results indicated that the obtained drag reduction values by the proposed model are in good agreement with the experimental data. The performance of the SVR-GA model was compared with multiple linear regression (MLR). The coefficient of determination (R^2) of 0.9485 and 0.8740; mean square error (MSE) of 0.01177 and 0.01772, for experimental and predicted data by SVR-GA and MLR models were obtained, respectively. This result shows that SVR-GA can be applied as an effective approach to predict drag reduction.

Keywords: Drag, Support vector regression, Genetic algorithm, Nanofluid, Horizontal pipelines, Water