

توسعه مدل‌های هیبریدی شبکه عصبی مصنوعی-الگوریتم تکاملی جهت پیش‌بینی عدد فرود جریان در کanal‌های باز در مدل‌سازی انتقال رسوب

ناصر آریا آذر، سامی قوردویی میلان و نازیلا کارдан

دوره ۷، شماره ۱، بهار ۱۴۰۰، صفحات ۷۳-۸۷

Vol. 7(1), Spring 2021, 73-87

DOI: 10.22034/jewe.2020.248209.1421

Development of a Hybrid ANN-Evolutionary Algorithms Models to Predict the Froude Number in Open Channel Flows in Modeling of Sediment Transport

Arya Azar, N., Ghordoyee Milan, S. and Kardan, N.



[www.jewe.ir](http://www.jewe.ir)

OPEN  ACCESS

ارجاع به این مقاله:

آریا آذر ن، قوردویی میلان س. و کاردان ن. (۱۴۰۰). توسعه مدل‌های هیبریدی شبکه عصبی مصنوعی-الگوریتم تکاملی جهت پیش‌بینی عدد فرود جریان در کanal‌های باز در مدل‌سازی انتقال رسوب. محیط‌زیست و مهندسی آب، دوره ۷، شماره ۱، صفحات ۷۳-۸۷.

**Citing this paper:** Arya Azar, N., Ghordoyee Milan, S. and Kardan, N. (2021). Development of a hybrid ANN-evolutionary algorithms models to predict the Froude number in open channel flows in modeling of sediment transport. Environ. Water Eng., 7(1), 73-87. DOI: 10.22034/jewe.2020.248209.1421

## مقاله پژوهشی

## توسعه مدل‌های هیبریدی شبکه عصبی مصنوعی - الگوریتم تکاملی جهت پیش‌بینی عدد فرود جریان در کanal‌های باز در مدل‌سازی انتقال رسوب

ناصر آریا آذر<sup>۱</sup>, سامی قوردویی میلان<sup>۲</sup> و نازیلا کارдан<sup>۳\*</sup>

<sup>۱</sup>کارشناس ارشد، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

<sup>۲</sup>کارشناس ارشد، گروه مهندسی آب، پردیس ابوریحان، دانشگاه تهران، تهران، ایران

<sup>۳</sup>استادیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه شهید مدنی آذربایجان، تبریز، ایران

\*نویسنده مسئول: [n.kardan@azaruniv.ac.ir](mailto:n.kardan@azaruniv.ac.ir)

تاریخ دریافت: [۱۳۹۹/۰۶/۲۴] تاریخ بازنگری: [۱۳۹۹/۰۸/۲۰] تاریخ پذیرش: [۱۳۹۹/۰۸/۲۶]

### چکیده

تخمین مقدار عدد فرود در مهندسی آب بسیار مهم است. از طرفی استفاده از مدل‌های یادگیری ماشین به دلیل اینکه نیاز به اطلاعات ساختمانی سامانه‌ها ندارند، مورد توجه قرار گرفته‌اند. در پژوهش حاضر از مدل شبکه عصبی مصنوعی (ANN) استفاده شده و از الگوریتم‌های تکاملی ازدحام ذرات (PSO)، الگوریتم کرم شبتاب (FA) و الگوریتم تفاضلی (DE) جهت بهبود نتایج ANN در پیش‌بینی مقدار عدد فرود بهره گرفته شد. پارامترهای مؤثر بر پیش‌بینی عدد فرود پارامترهای رسوب حجمی، اندازه دانه‌ها، عامل اصطکاک و نسبت اندازه دانه‌ها به شعاع هیدرولیکی بودند که باهم ترکیب شدند و الگوهای رسودی مختلفی به عنوان ورودی به مدل‌ها تدوین شد. نتایج نشان داد الگویی که با مشارکت همه پارامترهای ورودی باشد بیشترین دقت را در پیش‌بینی عدد فرود دارد. استفاده از الگوریتم‌های تکاملی پیشنهادی توانست دقت مدل ANN را به صورت قابل توجهی بهبود بخشد. در بین الگوریتم‌های مورد بررسی، الگوریتم‌های FA و PSO در بیشتر معیارهای ارزیابی دقت مناسبی داشتند. در حالت کلی استفاده از الگوریتم‌های تکاملی، دقت مدل ANN را به میزان  $0.07 \text{ m}$  در  $0.089 \text{ m}$  و  $0.07 \text{ m}$  در  $0.089 \text{ m}$  به ترتیب برای معیار ارزیابی RMSE و  $R^2$  بهبود بخشید. نتایج مدل‌های یادگیری ماشین در مقایسه با معادلات تجربی نیز اختلاف چشم‌گیری داشتند و حاکی از دقت بسیار مناسب مدل‌های یادگیری ماشین بودند. به همین سبب استفاده از مدل‌های یادگیری ماشین به جای استفاده از معادلات تجربی در برآورد مقدار عدد فرود پیشنهاد می‌گردد.

**واژه‌های کلیدی:** انتقال رسوب؛ عدد فرود؛ مدل هیبریدی؛ ANN.

## ۱- مقدمه

شبکه‌های عصبی یکی از پرکاربردترین مدل‌های یادگیری است که کارایی مناسب آن در شبیه‌سازی‌های مختلف اثبات شده است. این مدل می‌تواند با داشتن حداقل اطلاعات ممکن از هر سامانه با دقت مناسبی عملکرد آن را شبیه‌سازی و با توجه به تغییرات عوامل مؤثر بر آن به پیش‌بینی تغییرات عملکرد آن بپردازد. مدل شبکه عصبی مصنوعی از الگوریتم‌های آموزشی پس انتشار خطا برای همگرایی خطا استفاده می‌کند اما به دلیل سرعت همگرایی پایین و همچنین گیر افتادن در بهینه‌های محلی قادر به تخمین بهینه سرتاسری نیست (Zhang 2006)؛ بنابراین برای رفع مشکلات به وجود آمده جهت آموزش شبکه عصبی مصنوعی از دیگر الگوریتم‌های بهینه‌سازی نظری از دحام ذرات استفاده می‌شود، در این زمینه به عنوان نمونه می‌توان به پژوهش‌های شینگون در هنگ‌کنگ اشاره پیش‌بینی سطح آب رودخانه شینگون در هنگ‌کنگ اشاره کرد (Chau 2006). در پژوهش دیگری جهت پیش‌بینی رواناب در حوضه رودخانه آنапولیس کانادا از روش‌های مختلف برای آموزش شبکه عصبی پرسپترون چندلایه استفاده شده است (Piotrowski 2011).

نتایج حاکی از کارایی مناسب شبکه عصبی در جهت پیش‌بینی رواناب بود. یکی از الگوریتم‌های تکاملی، الگوریتم کرم شبتاب است که در سال ۲۰۱۰ معرفی گردید (Yang 2010). برای اولین بار این الگوریتم جهت بهره‌برداری بهینه از مخزن سد آغدوش مورد استفاده قرار گرفت، نتایج این الگوریتم رضایت‌بخش ارزیابی شد (Garoosi Nejhad and Bozorg Hadad 2011). همچنین عملکرد الگوریتم کرم شبتاب برای مقایسه بهره‌برداری بهینه از مخزن سد بازفت برای تأمین نیاز کشاورزی بررسی شد. نتایج الگوریتم مذکور با نتایج الگوریتم‌های ژنتیک و از دحام ذرات مقایسه گردیده و نشان داده شد الگوریتم کرم شبتاب نسبت به دو الگوریتم دیگر دارای دقت بالاتری است (Hosseini- Moghri and Banihabib 2014).

با این وجود انتظار می‌رود با استفاده از الگوریتم‌های بهینه‌سازی در جهت به دست آوردن مقدار بهینه وزن‌ها و بایاس‌ها به جای الگوریتم‌های موجود در شبکه عصبی، نتایج قابل قبول تری ارائه گردد.

با توجه به پژوهش‌های صورت گرفته در خصوص انتقال رسوب در کanal‌های باز و پیش‌بینی عدد فروود، نتیجه کلی بررسی

یکی از مشکلات عمده کanal‌های باز، تهنشینی رسوب در بستر کanal‌ها است. اگر سرعت ذرات در یک کanal باز با شبیث ثابت پایین بیاید، رسوب‌گذاری در عمق کanal رخ می‌دهد. وجود مواد جامد در بستر کanal نیز موجب می‌گردد سطح مقطع جریان کاهش و زبری بستر افزایش یابد، بر این اساس سرعت و توزیع تنش برشی نیز تغییر می‌کنند (Safari et al. 2018; Butler et al. 2003; Delleur 2001) به لحاظ تئوری، هنگامی که سرعت جریان به طور قابل توجهی پایین‌تر از سرعت بحرانی باشد، رسوبات تمایل به تهنشینی دارند و با گذشت زمان تا عمق خاصی انباسته می‌شوند (Montes et al. 2020). با این حال ذرات می‌توانند کندرت از سرعت جریان حتی در شرایط جریانی که در آن رسوب اتفاق نمی‌افتد، حرکت کنند (Ota and Perrusquia 2013). طراحی بهینه و عملکرد مناسب سازه‌های منابع آب، نظری مخزن، سد کanal، نیازمند تخمین دقیق از بار رسوبی رودخانه است (Kisi and Shiri 2012). بار رسوب معلق رودخانه‌ای که حدود ۷۵ تا ۹۵٪ کل رسوب رودخانه را شامل می‌گردد، از جنبه‌های مختلف نظری مهندسی منابع آب، مسائل محیط‌زیستی و کیفیت آب حائز اهمیت بوده و می‌تواند به عنوان شاخصی از وضعیت فرسایش خاک و شرایط بوم‌شناسختی حوزه در نظر گرفته شود (Zhu et al. 2007).

در چند دهه اخیر جهت برآورد مقدار عدد فرود از روابط تجربی بهره می‌برند. رابطه Novak and Nalluri (1975) به طور تجربی حرکت رسوب اولیه بسترهای سخت را از نظر سرعت بحرانی (Vc) شرح می‌دهد. روابط ایشان توسط El-Zaemey (1991)، (2013) و Salem (1991) با توجه به اندازه رسوبات مختلف و ضخامت بستر رسوب گسترش یافته است. بر اساس این معادله‌ها سرعت بحرانی برای تعیین تأثیر جریان روی رسوب بسیار مهم بوده و تابعی از ضخامت رسوب، اندازه رسوب متوسط و عمق آب طبیعی است (Bong et al. 2016). اخیراً به دلیل ماهیت پیچیده فرآیند انتقال رسوب در جریان کanal باز و تأثیر عدد فرود بر این فرآیند، فن‌های یادگیری ماشین برای تخمین عدد فرود و میزان انتقال رسوب مورد توجه بسیاری از پژوهش‌گران قرار گرفته است (Olyaei et al. 2015; Chen 2015).

مورد مقایسه قرار گرفت. از بین مدل‌های مذکور مناسب‌ترین مدل جهت پیش‌بینی عدد فرود انتخاب شد.

## ۲- موارد و روش

### ۲-۱- داده‌های مورد استفاده

روابط تجربی زیادی برای برآورد این پارامتر ارائه شده‌است که مطابق جدول (۱) مشخص است که بیشتر روابط مذکور در سال‌های بین ۱۹۹۰-۲۰۱۰ بوده است. این روابط با وجود آنکه توسط پژوهش‌گران مختلفی توسعه یافته‌اند اما همواره از دقت ضعیفی در تخمین مقدار عدد فرود برخوردار هستند. در جدول (۱)،  $C_v$  رسوب حجمی،  $D_{gr}$  اندازه دانه‌ها،  $d$  اندازه متوسط دانه‌ها (mm)،  $R$  شعاع هیدرولیکی (mm)،  $\lambda$  عامل اصطکاک،  $g$  شتاب گرانش ( $m/s^2$ ),  $V$  سرعت متوسط جريان ( $m/s$ ) و  $F_{rp}$  عدد فرود جريان است.

پژوهشات گذشته بيان می‌کند معادلات تجربی مختلفی جهت برآورد مقدار عدد فرود ارائه شده است. در سال‌های اخیر نیز برخی مدل‌های یادگیری ماشین جهت برآورد مقدار عدد فرود موردن استفاده قرار گرفته‌اند. کارایی این مدل‌ها نسبت به معادلات تجربی کمتر موردن توجه قرار گرفته و بررسی و مقایسه کافی انجام نشده است. در سال‌های اخیر، استفاده از الگوریتم‌های تکاملی توانسته‌اند دقت شبکه‌های عصبی مصنوعی را تا حدود زیادی بهبود بخشدند و این نکته مورد توجه محققان مختلفی قرار گرفته است. لذا استفاده از الگوریتم‌های جدید و ارزیابی کارایی آن‌ها در بهبود دقت شبکه عصبی ضروری به نظر می‌رسد. به همین منظور در پژوهش حاضر به ارزیابی الگوریتم کرم شبکه در آموزش شبکه عصبی مصنوعی برای برآورد مقادیر عدد فرود پرداخته شد. نتایج مدل هیبریدی مذکور همچنین با نتایج شبکه عصبی و شبکه عصبی-الگوریتم از دحام ذرات الگوریتم تکامل تفاضلی

جدول ۱- برخی معادلات تجربی پیشنهادشده در خصوص برآورد مقدار عدد فرود (Bong et al. 2016)

Table 1 Some of proposed experimental equations for estimating the Froude number (Bong et al. 2016)

No	Author (year)	Equation
1	Salem (2013)	$\frac{V_c}{\sqrt{gd(s-1)}} = 1.07 \left( \frac{d}{R} \right)^{-0.23}$
2	Mayerle et al. (1991)	$\frac{V}{\sqrt{gd(s-1)}} = 14.43 C_v^{0.18} D_{gr}^{-0.14} (d/R)^{-0.43} \lambda^{0.18}$
3	Vongvisessomjai et al. (2010)	$\frac{V}{\sqrt{gd(s-1)}} = 4.31 C_v^{0.226} (d/R)^{-0.616}$
4	Mayerle (1998)	$\frac{V_t}{\sqrt{gd(SG-1)}} = 4.32 C_v^{0.23} \left( \frac{d}{R} \right)^{-0.68}$
5	Ab Ghani (1993)	$\frac{V_t}{\sqrt{gd(SG-1)}} = 3.08 C_v^{0.21} D_{gr}^{-0.09} \left( \frac{d}{R} \right)^{-0.53} \lambda_s^{-0.21}$
6	Montes (2020)	$\frac{V_t}{\sqrt{gd(SG-1)}} = C_v^{0.209} \left( \frac{d}{R} \right)^{-0.593} 4.79 \lambda^{0.058}$

به منظور پیش‌بینی عدد فرود و مدل‌سازی انتقال رسوب در کانال‌های مرزی صلب، از چهار مجموعه داده Mayerle (1988), May (1993), Ab Ghani (1993) and

Vongvisessomjai et al. (2010) در این مطالعه استفاده شده است. خلاصه پارامترهای آماری داده‌های مورد استفاده در جدول (۲) ارائه شده است.

جدول ۲- خلاصه پارامترهای آماری برای داده‌های مورداستفاده

Table 2 Summary of statistical parameters for the used data

Statistical parameter	$F_{rp}$	$\lambda$	$d/R$	$D_{gr}$ (mm)	$C_v$ (ppm)
Maximum	13.52	0.050	0.4162	215.5	0.0001568
Average	4.400	0.020	0.0671	65.10	0.0002830
Minimum	1.290	0.011	0.0052	5.00	0.0000002
Standard deviation	4.900	0.023	0.1006	88.26	0.0004320

### ۳-۲- مدل هیبریدی شبکه عصبی مصنوعی - الگوریتم تکاملی

شکل (۱) فلوچارت پژوهش حاضر و نحوه ترکیب مدل شبکه عصبی مصنوعی و الگوریتم‌های تکاملی را نشان می‌دهد. در بهینه‌سازی با استفاده از الگوریتم‌های تکاملی متغیرهای بهینه‌سازی در آموزش یک شبکه عصبی شامل وزن‌ها و بایاس‌های مربوط به شبکه می‌شوند (Mehra and Wah 1990). مراحل مدل‌سازی بدین صورت است که ابتدا  $N$  بردار موقعیت  $X_i$  که  $N$  برابر با تعداد اعضای دسته است، به صورت تصادفی تولید می‌گردد. شبکه عصبی به ازای پارامترهایی این بردارها اجرا شده و خطای بدست‌آمده از هر اجرا به عنوان میزان برازنده‌گی بردار متغیر آن شبکه در نظر گرفته می‌شود. این روند آن قدر تکرار می‌شود تا هم‌گرایی نهایی حاصل گردد. در واقع در نقطه هم‌گرایی نهایی مقادیر وزن‌ها و بایاس‌ها به حالت بهینه رسیده به‌نحوی که خطای آموزش به ازای آن کمینه گردد. با این وجود تابع هدف مسئله، کمینه کردن میزان خطا است.

### ۴- الگوریتم ازدحام ذرات

الگوریتم ازدحام ذرات (PSO)<sup>۱</sup> یکی از روش‌های بهینه‌سازی الهام گرفته از طبیعت است که اولین بار در Eberhart and Kennedy سال ۱۹۹۵ مطرح شد (1995). الگوریتم PSO با ایجاد یک جمعیت تصادفی شروع می‌شود. هر جزوی در طبیعت مجموعه مختلف متغیرهای تصمیم است که مقادیر بهینه آن‌ها باید تأمین گردد و در واقع هر ذره یک بردار را در فضای حل مسئله

در جدول (۲)،  $C_v$  رسواب حجمی،  $D_{gr}$  اندازه دانه-های که مقادیر آن در بازه (mm) ۲۱۵/۵ - ۶۵/۱ در نوسان بوده و متوسط مقدار آن (mm) ۶۵/۱ است،  $d_{50}$  اندازه متوسط داده‌ها،  $R$  شاعع هیدرولیکی (mm)،  $\lambda$  عامل اصطکاک،  $g$  شتاب گرانش ( $m/s^2$ )،  $V$  سرعت متوسط جریان ( $m/s$ ) و  $F_{rp}$  عدد فرود جریان است که برای رودخانه‌های موردمطالعه در چهار پژوهش فوق، مقدار آن در محدوده ۱/۲۹ و ۱۳/۵۲ قرار دارد. مقدار عدد فرود از رابطه (۱) محاسبه می‌شود.

$$Fr_p = \frac{V}{\sqrt{gd(s-1)}} \quad (1)$$

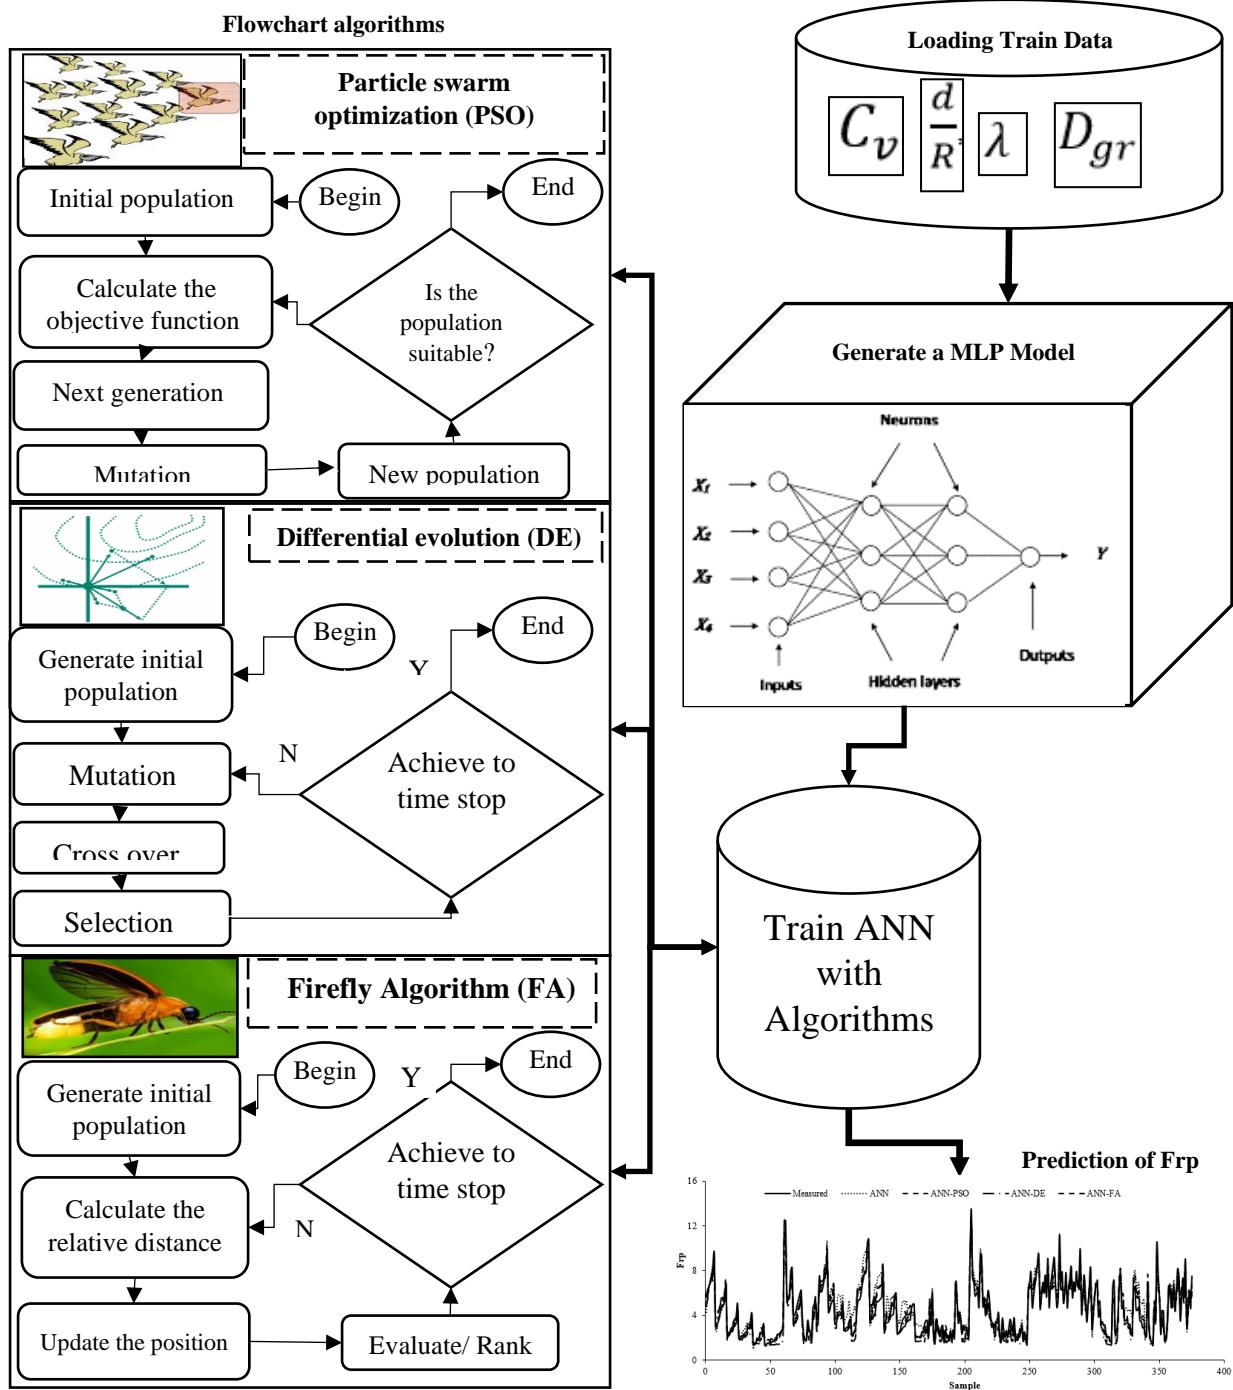
### ۳- شبکه عصبی مصنوعی

مدل‌های شبکه عصبی مصنوعی (ANN)، سال‌های زیادی به امید رسیدن به عملکردی مشابه کارایی انسان در زمینه سرعت و شناخت موردمطالعه قرار گرفته‌اند (Lippman 1987). در شبکه عصبی مصنوعی، بعد از انتخاب ورودی‌های مختلف، ابتدا باید تعداد لایه‌های میانی و خروجی تعیین گردد و برای هر لایه میانی مقدار نرون اولیه داده شود. در ادامه معیار ارزیابی شبکه انتخاب می‌گردد تا مقدار خطای مشاهداتی و تخمینی شبکه را محاسبه کند (Haykin 1999). در بخش نتایج، معماری منتخب و تعداد نرون مناسب برای لایه‌های میانی، توابع انتقال و الگوریتم منتخب جهت آموزش شبکه آورده شده است. برای انجام مدل‌سازی، داده‌ها پس از نرمال‌سازی به دو زیرمجموعه شامل مرحله آموزش (۷۵٪ از کل داده‌ها)، مرحله آزمایش (۲۵٪ از کل داده‌ها) تقسیم شده‌اند.

<sup>1</sup>Artificial Neural Network (ANN)

<sup>2</sup>Particle Swarm Optimization

(Arumugam et al. 2008) نشان می‌دهد



شکل ۱- فلوچارت مدل در پژوهش حاضر در خصوص شبکه عصبی مصنوعی با الگوریتم‌های تکاملی پیشنهادی

Fig. 1 Model flowchart in the present study on the combination of artificial neural networks with proposed evolutionary algorithms

می‌دهند. در جستجوی یک فضای D بعدی، مکان I امین ذره بهوسیله یک بردار D بعدی به نام  $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$  و سرعت هر ذره بهوسیله یک بردار D بعدی سرعت به نام  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  نشان داده می‌شود. سرانجام جمعیت، با استفاده از روابط (۲) و (۳) بهصورت هدفمند به سمت نقطه بهینه حرکت می‌کند.

$$V_{id}^{n+1} = X \left( \omega_1 V_{id}^n + c_1 r_1^n (p_{id}^n - x_{id}^n) + c_2 r_{id}^n (p_{pg}^n - x_{id}^n) \right) \quad (2)$$

پارامترهای موردادستفاده در این الگوریتم که به حالت مطلوب رسیده است آورده شده است.

### ۲-۶- الگوریتم کرم شبتاب

الگوریتم کرم شبتاب (FA) برای اولین بار توسط یانگ در سال ۲۰۱۰ پیشنهادشده است (Yang 2010). ایده اصلی این الگوریتم از ارتباط نوری بین کرم شبتاب الهام گرفته شده است. کرم‌های شبتاب نورهای موزون و کوتاه تولید می‌کنند. الگوی نوری هرکدام از کرم‌های شبتاب با یکدیگر متفاوت است. فرض می‌شود n تعداد کرم‌های تابشی است و  $x_i$  امین موقعیت ذره است بنابراین میزان روشنایی هر کرم شبتاب برابر با مقدار تابع هزینه است (رابطه ۴):

$$I_i = f(x_i) \quad 1 \leq i \leq n \quad (4)$$

کرم شبتاب دارای یک ویژگی تابشی است که نشان‌دهنده قدرت آن است. این ویژگی یک مقدار نسبی است که با تغییر فاصله بین کرم شبتاب ۱ و کرم شبتاب j تغییر می‌کند. تابع جاذبه به شرح رابطه (۵) است.

$$\beta(r) = \beta e^{-\gamma r^2} \quad (5)$$

که در آن  $\beta$  بیانگر بیشینه جاذبیت با دامنه تغییرات [0, 1]،  $\gamma$  بیانگر ضریب جذب با دامنه تغییرات [0,  $\infty$ ] است. r فاصله حشره ۱ از حشره j است که رابطه آن بهصورت رابطه (۶) می‌باشد.

$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i + y_j)^2} \quad (6)$$

حرکت حشره ۱ ام به سمت حشره j ام با رابطه (7) بهدست

این الگوریتم علاوه بر داشتن بردار حرکت دارای یک بردار سرعت نیز است که اعضای مجموعه را به تغییر موقعیت در فضای جستجو ودار می‌کند. این بردار سرعت خود برآیند دو بردار به نام‌های P و  $P_g$  است. P بهترین موقعیتی است که یک ذره تاکنون به آن رسیده است و  $P_g$  بهترین موقعیتی است که بهترین ذره در همسایگی آن ذره تاکنون به آن رسیده است. در این الگوریتم هرکدام از اعضای مجموعه در هر تکرار یکراحت حل را ارائه

$$x_{id}^{n+1} = x_{id}^n + V_{id}^{n+1} \quad (3)$$

که در آن X فاکتور انقباض است و از آن برای نرخ کارایی و سرعت همگرایی شدن استفاده می‌شود.  $r_1$  و  $r_2$  عدد تصادفی در بازه صفر و یک با توزیع یکنواخت است. N شماره تکرارها،  $c_1$  مؤلفه شناختی و بهترین راه حلی که یک ذره به دست می‌آورد.  $c_2$  مؤلفه اجتماعی و بهترین راه حلی توسط کل گروه تشخیص داده می‌شود. انتخاب مقادیر مناسب برای مؤلفه شناختی و اجتماعی منجر به تسريع الگوریتم و جلوگیری از همگرایی زودرس در نقاط بهینه محلی می‌شود.

### ۲-۵- الگوریتم تکاملی تفاضلی

در سال ۱۹۹۵ این الگوریتم برای حل مسائل بهینه‌سازی ارائه شد (Storn and Price 1997). این الگوریتم از یک اپراتور تفاضلی جهت تولید جواب‌های جدید بهره می‌گیرد که این اپراتور باعث مبادله اطلاعات بین اعضای جمعیت می‌شود. در این الگوریتم همه اعضای یک جمعیت شناسی مساوی برای انتخاب شدن بهعنوان یکی از والدین را دارند. به این صورت که نسل نوزاد با نسل والد از نظر میزان شایستگی که توسط تابع هدف سنجیده می‌شود، مقایسه می‌گردد. سپس بهترین اعضا بهعنوان نسل بعدی وارد مرحله بعد می‌گردند. این روش تنها با تنظیم سه پارامتر جهش، متقطع و انتخاب شروع به کار می‌کند و به نقطه بهینه می‌رسد. از مهم‌ترین ویژگی این الگوریتم سادگی، سرعت بالا و قدرتمند بودن آن است. مشابه سایر الگوریتم‌های موردادستفاده در این پژوهش، هدف این الگوریتم در ترکیب مدل شبکه عصبی مصنوعی بهینه کردن حداقل خطای بین مقادیر مشاهداتی و شبیه‌سازی شده است. در قسمت نتایج مقادیر

<sup>۱</sup>Firefly Algorithm (FA)



جدول ۳- تدوین الگوهای ورودی مختلف جهت برآورد عدد فرود  
Table 3 Developing different input patterns to estimate the Froude number

Pattern	Input Parameters				Output
	$\lambda$	$d/R$	$D_{gr}$	$c_p$	
P1	✓	✓	✗	✓	
P2	✓	✓	✓	✗	
P3	✗	✓	✓	✓	$F_r p$
P4	✓	✓	✓	✓	

جدول (۴) مشخصات نهایی مدل‌های ANN-PSO، ANN و ANN-DE و ANN-FA را نشان می‌دهد. برای هر مدل، تعداد جمعیت، مشخصات کد الگوریتمها و تکرارهای مختلفی ارزیابی شده است و مقادیر پارامترهای نهایی در جدول آمده است. تعداد تکرار در هر الگوریتم متفاوت بوده و به کارگیری تعداد بیشتر، از مقداری که در جداول آورده شده است تأثیری در بهبود نتایج نداشته است. قبل از ارائه نتایج مربوط به هر یک از الگوها، ضروری است که معماری شبکه عصبی بکار رفته در پژوهش مشخص گردد، برخی از مشخصات این معماری در جدول (۴) ارائه شده است. برای همه الگوهای موردنظر معماری‌های مختلفی در نظر گرفته شده و در نهایت معماری مناسب برای همه ورودی‌ها مطابق جدول مذکور به دست آمد.

نتایج معیارهای ارزیابی خطا برای الگوهای مختلف در جدول (۵) داشته‌اند. مقادیر معیارهای ارزیابی RMSE و  $R^2$  برای ANN-DE و ANN-FA بیشترین دقت در خروجی نتایج را آزمون به دست آمد. مدل ANN-FA نیز نتایج مشابه و بسیار نزدیکی نسبت به ANN-DE ارائه کرد که معیارهای ارزیابی به ترتیب  $0.91$  و  $0.92$  برای داده‌های آزمون به دست آمد.

همان‌طور که ملاحظه می‌شود نتایج هر دو مدل بسیار نزدیک به هم بوده و از دقت یکسانی در پیش‌بینی مقدار عدد فرود برای داده‌های آزمون برخوردار هستند. در صورتی که دقت داده‌های

می‌آید.

$$x_i(t+1) = x_i(t) + \beta_r(x_j - x_i) \quad (7)$$

#### ۷-۲- معیارهای ارزیابی برای مقایسه الگوهای و مدل‌ها

برای ارزیابی الگوهای و مدل‌ها، معیارهای ارزیابی میانگین قدر مطلق درصد خطای  $MAPE$  (رابطه ۸)، خطای جذر میانگین مربعات ( $RMSE$ ) (رابطه ۹) و ضریب تبیین  $R^2$  (رابطه ۱۰) استفاده شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_o - x_p)^2}{n}} \quad (8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_o - x_p}{x_o} \right| \quad (9)$$

$$R^2 = \frac{\left[ \sum_{i=1}^n (x_o - \bar{x})(x_p - \bar{x}) \right]^2}{\sum_{i=1}^n (x_o - \bar{x})^2 \sum_{i=1}^n (x_p - \bar{x})^2} \quad (10)$$

که در آن  $x_o$  داده‌های مشاهداتی (اندازه‌گیری شده) و  $x_p$  داده‌های شبیه‌سازی شده توسط روابط تجربی و مدل‌های به کار رفته می‌باشد. هرچقدر  $MAPE$  و  $RMSE$  به صفر نزدیک‌تر و مقدار  $R^2$  به یک نزدیک باشد نشان از دقت مناسب مدل استفاده شده دارد.

### ۳- نتایج و بحث

۱-۳- ارزیابی نتایج مدل‌های هیبریدی-الگوریتم تکاملی  
ابتدا نتایج مدل‌های یادگیری ماشین در قالب الگوهای مختلف ورودی تشریح شده و سپس نتایج برخی معادلات تجربی ارائه شده است. در نهایت نتایج مدل یادگیری ماشین و مدل‌های تجربی، مقایسه گردیده است. از آنجایی که عدد فرود از ورودی‌های مختلف تأثیر می‌پذیرد، از چهار ترکیب ورودی مطابق جدول (۳) برای شبیه‌سازی عدد فرود استفاده شده است. ترکیب این ورودی‌ها برای هر مدل یادگیری ماشین باید مورد ارزیابی قرار گیرد تا بهترین ترکیب از بین آن‌ها انتخاب گردد

<sup>2</sup>Root Mean Square Error

<sup>1</sup>Mean Absolute Percent Error

دانه‌ها بود. این نکته نشان می‌دهد مقادیر اندازه دانه‌ها تأثیر بیشتری در تخمین درست مقدار عدد فرود نسبت به سایر پارامترهای ورودی دیگر دارد. از این‌رو مؤثرترین پارامتر در بین پارامترهای مورد استفاده است.

آموزش نتایج متفاوتی را نشان می‌دهد؛ اما از آنجایی که معمولاً نتایج بخش آزمون مورد توجه است از این جهت مدل‌های مذکور دارای بیشترین دقت هستند. از بین الگوهای الگوی P1 در تمام مدل‌ها دارای کمترین دقت در پیش‌بینی  $F_{rb}$  بود. پارامترهای ورودی در این الگو شامل همه پارامترهای ورودی به جز اندازه

جدول ۴- خصوصیات معماری در نظر گرفته شده برای مدل ANN

Table 4 Architecture parameters of the ANN Model

Model	Parameter	Value
ANN	Number of network layers	2
	Number of neurons in hidden layer	12
	Transform function of hidden layer	logsig
	Transform function of output layer	Purlin
	Learning algorithm	Levenberg-Marquardt
	Iteration	2000
ANN-PSO	Population size	30
	Maximum particles number	2000
	Initial inertia weight (Wmin)	1
	Inertia weight damping ratio (Wdamp)	0.99
	Cognitive acceleration (C1)	1
ANN-FA	Social acceleration (C2)	2
	Population size	25
	Maximum number of generation in DE	2000
	Lower Bound of scaling factor (beta_min)	0.2
	Upper Bound of scaling factor (beta_max)	0.8
ANN-DE	Crossover Probability (pCR)	0.1
	Population size	30
	Maximum number of generation in FA	2000
	Light Absorption Coefficient ( $\gamma$ )	1
	Attraction Coefficient Base Value ( $\beta_0$ )	2
	Mutation Coefficient ( $\alpha$ )	0.2

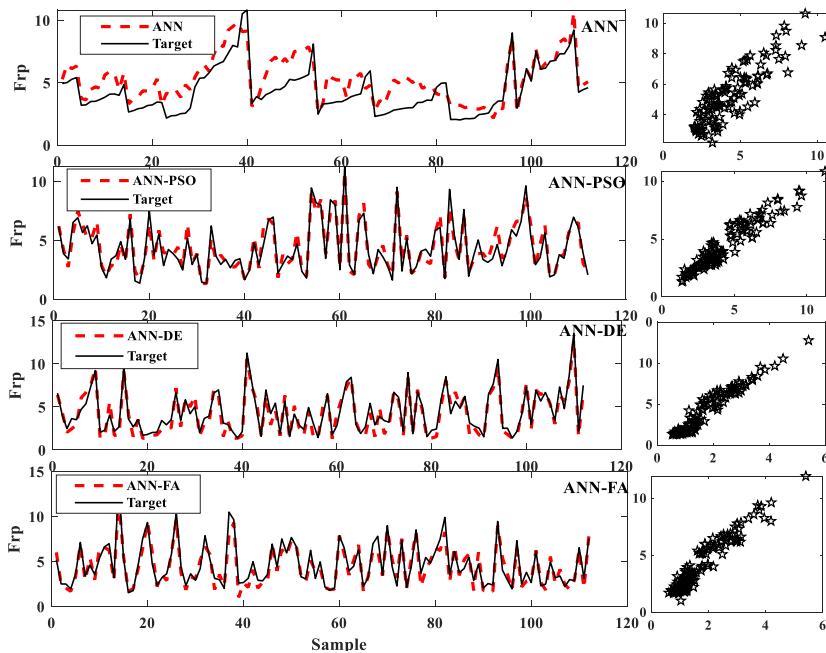
جدول ۵- نتایج معیارهای ارزیابی خطای الگوهای مختلف به کارفته در پژوهش حاضر.

Table 5 Evaluation criteria of studied scenarios using different models

Model	Pattern	MAPE (m)		RMSE (m)		$R^2$	
		train	Test	train	test	Train	test
ANN	P1	0.23	0.27	1.30	1.42	0.74	0.72
	P2	0.18	0.22	0.96	1.00	0.80	0.79
	P3	0.17	0.22	0.98	1.10	0.79	0.77
	P4	0.15	0.16	0.93	0.97	0.84	0.82
PSO-ANN	P1	0.19	0.20	1.10	1.00	0.77	0.79
	P2	0.18	0.21	1.10	1.14	0.75	0.76
	P3	0.14	0.14	0.90	0.96	0.83	0.80
	P4	0.11	0.13	0.80	0.85	0.87	0.85
ANN-FA	P1	0.19	0.18	1.08	1.13	0.76	0.76
	P2	0.18	0.19	0.89	0.92	0.84	0.81
	P3	0.15	0.16	0.85	0.88	0.86	0.84
	P4	0.10	0.12	0.70	0.76	0.90	0.91
ANN-DE	P1	0.20	0.21	1.12	1.15	0.78	0.75
	P2	0.16	0.14	0.83	0.81	0.84	0.85
	P3	0.13	0.15	0.81	0.88	0.86	0.82
	P4	0.13	0.11	0.77	0.75	0.89	0.92

مطابق نتایج حاصله از جدول (۵) از معیارهای ارزیابی، می‌توان همچنین بیان می‌کند هرچقدر تعداد پارامترهای ورودی به مدل‌های یادگیری ماشین بیشتر باشد دقت شبیه‌سازی مدل نیز بهتر می‌شود. به عبارتی با افزایش ورودی‌ها، سامانه پیچیده‌تر شده و روابط غیرخطی پیچیده‌تری ایجاد می‌گردد اما از آنجایی که این مدل‌ها عموماً برای حالت‌هایی که روابط غیرخطی پیچیده‌تر می‌گردد نتایج قابل قبول‌تری ارائه می‌دهند و توانایی بالایی در تشخیص این روابط غیرخطی و پیچیده دارند؛ به همین سبب الگوهایی که بیشترین ورودی را شامل می‌شوند از دقت مناسب‌تری برخوردار هستند. شکل (۲) تغییرات مقادیر اندازه‌گیری شده و مقادیر پیش‌بینی شده عدد فرود را برای الگوی منتخب در مدل‌های مختلف نشان می‌دهد.

مطابق نتایج حاصله از جدول (۵) از معیارهای ارزیابی، می‌توان بیان کرد الگوریتم‌های DE و FA و PSO توانایی بالایی در به کارگیری آموزش شبکه عصبی برخوردار هستند و بهتر از الگوریتم PSO شبکه عصبی را آموزش داده‌اند. هرچند که مدل هیبریدی ANN-PSO نتایج قابل قبولی در شبیه‌سازی مقدار خروجی داشته است اما نسبت به دو الگوریتم دیگر از دقت کمتری برخوردار بود. نتایج ارزیابی معیارهای ارزیابی خطا همچنین نشان می‌دهد مدل‌های هیبریدی و استفاده از الگوریتم‌های تکاملی نتایج بهتر و قابل قبول‌تری از مدل انفرادی شبکه عصبی ارائه می‌دهند؛ بنابراین با توجه به نتایج معیارهای ارزیابی خطا اگر رتبه‌بندی مدل‌ها مدنظر باشد از نظر دقت در تخمین مقدار  $F_{rb}$  می‌توان مدل‌ها را به ترتیب ANN-DE، ANN-FA، ANN-PSO و در ادامه ANN-DE، ANN-FA و در ادامه



شکل ۲- مقادیر داده‌های اندازه‌گیری شده و شبیه‌سازی شده مدل‌های مختلف برای داده‌های آزمون الگوی منتخب.

Fig. 2 Values of measured and simulated data of different models for selected pattern test data

پیش‌بینی شده و اندازه‌گیری شده خیلی به هم‌دیگر نزدیک هستند و در اطراف خط رگرسیونی به صورت متراکم پخش شده‌اند. شکل مذکور همچنین بیان می‌کند مدل‌های هیبریدی به درستی تغییرات رفتار پارامتر خروجی را تشخیص داده‌اند و در نتیجه سری زمانی شبیه‌سازی شده مقادیر توسط مدل هیبریدی بسیار

بررسی روند تغییرات این پارامتر نشان می‌دهد مدل شبکه عصبی مصنوعی با دقت کمتری قادر به تخمین این پارامتر است و پراکندگی داده‌ها در اطراف خط رگرسیون نیز صحبت این مسئله را تائید می‌کند؛ اما استفاده از الگوریتم‌های تکاملی این مشکلات را برطرف نموده تا جایی که به عنوان نمونه در ANN-FA مقادیر

نسبت به همدیگر و خط رگرسیون ترسیم و در شکل (۳) آورده شده است. هرچقدر تراکم نقاط بیشتر و نزدیک به خط رگرسیون باشد بیان‌گر مناسب بودن دقت پیش‌بینی است. پراکندگی و تراکم نقاط نسبت به خط مذکور برای معادلات تجربی و مدل‌های یادگیری ماشین مشهود است. در بین مدل‌های هیبریدی تراکم داده‌های اندازه‌گیری شده و پیش‌بینی شده نسبت به خط رگرسیون نزدیک به هم و تشابه زیادی دارند اما این تراکم تفاوت نسبتاً محضوسی با مدل شبکه عصبی دارد و بهنوعی تراکم داده‌ها در گراف مربوط به شبکه عصبی تا حدودی کاسته شده است.

بهمنظور ارزیابی بهتر نتایج حاصل از مدل‌های تجربی و الگوریتم هیبریدی-تکاملی از گراف تیلور نیز استفاده شد. در این گراف، محور افقی و عمودی بیان‌گر ضریب تغییرات و مکان ربع دایره ضریب همبستگی را نشان می‌دهد. برای نشان دادن RMSD از کمان‌های داخل ربع دایره استفاده می‌شود. در این گراف، هرچقدر نتایج حاصل از مدل‌ها به مقادیر اندازه‌گیری شده نزدیک باشد، ضریب همبستگی برای آن بیشتر خواهد بود. گراف تیلور برای مدل‌های تجربی و الگوریتم هیبریدی-الگوریتم تکاملی در شکل (۴) نشان داده شده است. در گراف مربوط به معادلات تجربی مشاهده می‌شود مقادیر ضریب همبستگی در دامنه ۰/۸ تا ۰/۹ قرار دارد. بیشترین ضریب همبستگی در مدل‌های تجربی مربوط به معادله (1993) Ab Ghani است که مقداری نزدیک به ۰/۹ دارد و مقدار RMSD آن روی کمان ۱ m قرار دارد. بیشترین مقدار RMSD برای (1991) Mayrel et al. است که بیشتر از ۲ m می‌باشد. این ارقام نشان می‌دهد هیچ‌یک از معادلات تجربی قادر به پیش‌بینی مقدار عدد فروند با دقت مناسب نبودند.

نزدیک به داده‌های اندازه‌گیری شده مشاهده شده است.

### ۲-۳- مقایسه نتایج مدل‌های هیبریدی-الگوریتم تکاملی با روابط تجربی

در سال‌های اخیر معادلات تجربی توسط محققین مختلفی در خصوص تعیین مقدار عدد فروند پیشنهادشده است. در ادامه نتایج روابط تجربی پیشنهادشده برخی پژوهش‌گران با نتایج مدل‌های یادگیری ماشین مورد ارزیابی قرار گرفته است. عملکرد مدل‌ها از نظر سه شاخص آماری  $R^2$ , MAPE و RMSE در جدول (۶) بررسی شده است. مقادیر ارزیابی خطای برای مدل‌های تجربی و مدل‌های یادگیری ماشین نشان می‌دهد این مدل‌ها دارای عملکرد بهتری نسبت به مدل‌های تجربی هستند. مقادیر تغییرات درصد خطای در بین مدل‌های یادگیری ماشین بسیار کمتر از معادلات تجربی بود. به عنوان نمونه نتایج بهترین معادله تجربی MAPE, RMSE Montes است که پیش‌بینی با دقت ۰/۷۹ و ضریب تبیین نزدیک به ۱/۳۶ m داشته است. در حالی که بدترین دقت مدل‌های یادگیری ماشین به کاررفته برای معیارهای ارزیابی خطای ترتیب برابر ۰/۹۶ m و ۰/۱۶ m بود که مختص مدل ANN است. این نکته بیان‌گر آن است که استفاده از مدل‌های یادگیری ماشین تا حد زیادی نتایج قابل قبول‌تری در این خصوص ارائه می‌دهند.

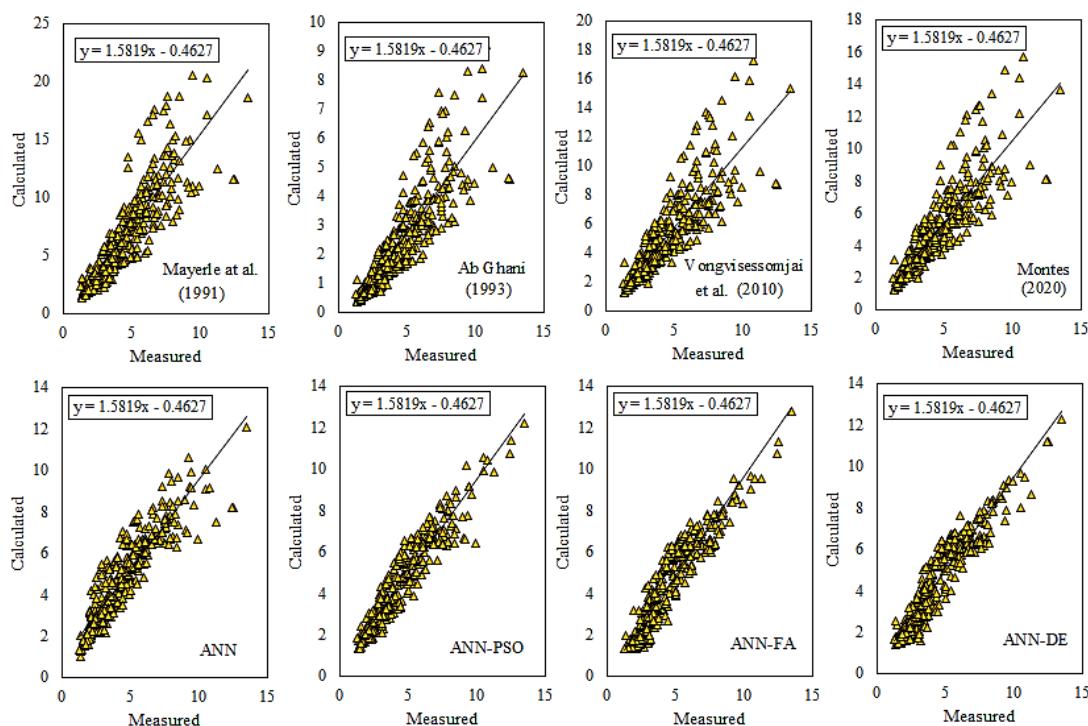
در بین الگوریتم‌های مختلف نیز الگوریتم کرم شبتاب قادر به آموزش بهتر ساختار شبکه عصبی مصنوعی بوده است به طوری که معیارهای ارزیابی نشان می‌دهد در حدود ۰/۰۷ m و ۰/۸۹ m به ترتیب مقادیر MAPE, RMSE و ضریب تبیین نسبت به مدل شبکه عصبی بهبود داده شده‌اند. مقادیر اندازه‌گیری شده و پیش‌بینی شده معادلات تجربی و مدل‌های یادگیری ماشین

جدول ۶- نتایج معیارهای ارزیابی خطای برای نتایج معادلات تجربی و الگوی منتخب مدل‌های یادگیری ماشین

Table 6 Value of error criteria for the results achieved by experimental equations and the selected model of machine learning models

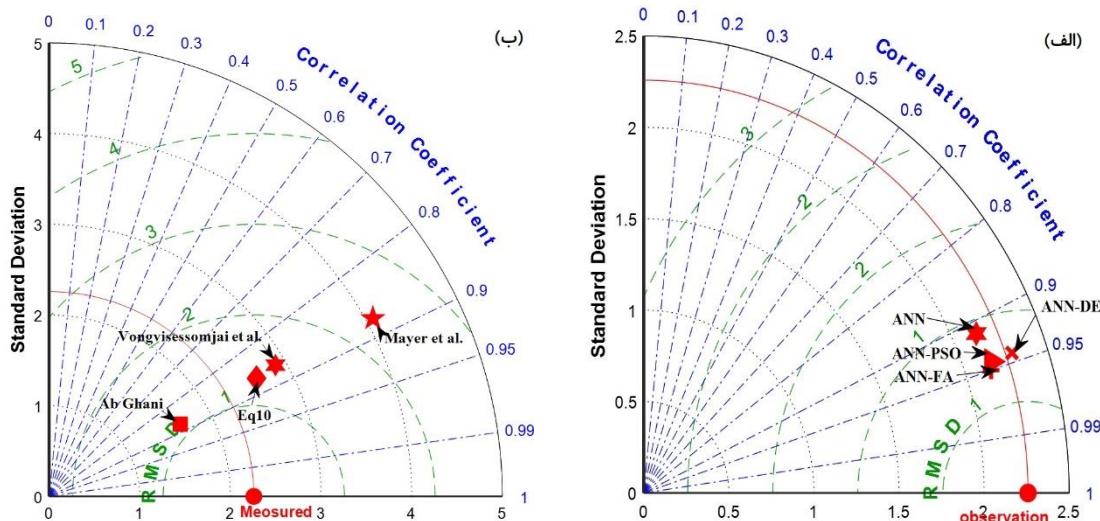
Parameter	ANN-FA	ANN-DE	ANN-PSO	ANN	Montes (2020)	Vongvisessomjai et al. (2010)	Ab Ghani (1993)	Mayerle et al. (1991)
$R^2$	0.89	0.89	0.90	0.83	0.79	0.75	0.78	0.77
RMSE	0.70	0.74	0.73	0.93	1.36	1.61	2.36	3.16
MAPE	0.10	0.14	0.12	0.16	0.20	0.22	0.50	0.44





شکل ۳ - مقایسه مدل‌ها برای مقادیر اندازه‌گیری شده و شبیه‌سازی شده نسبت به خط رگرسیون

Fig. 3. Comparison of models for measured and simulated values regarding to regression line



شکل ۴ - نمودار تیلور ترسیم شده، (الف) مدل‌های یادگیری ماشین، (ب) معادلات تجربی

Fig. 4. Plotted Taylor diagrams, by (a) machine learning models, (f) experimental equations

۰/۹۱ است؛ اما سه مدل دیگر که از الگوریتم‌های تکاملی جهت بهبود آموزش مدل شبکه عصبی استفاده شده بود ضریب همبستگی نزدیک به هم و در حدود ۰/۹۵ داشتند. به جز مدل

اما در مدل‌های یادگیری ماشین و تکاملی ضریب همبستگی بیشتر از ۰/۹ است، کمترین ضریب همبستگی مربوط به داده‌های شبکه عصبی مصنوعی است که مقدار آن در حدود

$R^2$  و نمودار تیلور استفاده گردید. نتایج کلی نشان از عملکرد مناسب الگوریتم‌های مورداستفاده در آموزش شبکه عصبی مصنوعی و درنتیجه دقت پیش‌بینی عدد فرود گردید. درنهایت نیز نتایج پژوهش حاضر را می‌توان به موارد ذیل اشاره کرد:

- ۱- الگوریتم‌های تکاملی PSO، DE و FA در این پژوهش به خوبی توانستند دقت مدل ANN را تا حدود زیادی بهبود بخشند. این الگوریتم‌ها نتایج قابل قبول و نزدیکی نسبت به همیگر داشتند و درنتیجه پیش‌بینی با دقت مناسبی انجام گردید.
- ۲- بر اساس معیارهای ارزیابی خطا و نمودار تیلور ANN-FA مناسب‌ترین مدل از بین مدل‌های مختلف برای پیش‌بینی عدد فرود انتخاب شد.
- ۳- استفاده از مدل‌های هیبریدی دقت پیش‌بینی را به صورت چشم‌گیری نسبت به معادلات تجربی افزایش می‌دهد.
- ۴- ترکیب تمام پارامترهای ورودی به عنوان بهترین الگو انتخاب گردید که می‌تواند مقدار عدد فرود را با بیش‌ترین دقت ممکن پیش‌بینی نماید.

### دسترسی به دادها

داده‌ها حسب درخواست، از طرف نویسنده مسئول از طریق ایمیل قابل ارسال است.

ANN-DE که انحراف معیار بیشتر از مقدار ۲/۵ دارد، سایر مدل‌های یادگیری انحراف معیار نزدیک به هم و در حدود  $m = 2/25$  را دارا هستند. از این تحلیل‌های صورت گرفته و نمودار تیلور می‌توان نتیجه گرفت مدل هیبریدی ANN-FA و ANN-PSO نزدیک‌ترین معیارها به مقادیر اندازه‌گیری شده هستند و از نظر این معیار ANN-FA و ANN-PSO مناسب‌ترین مدل جهت پیش‌بینی عدد فرود می‌باشند.

مطابق نتایج دیاگرام تیلور و اختلاف زیاد دقت پیش‌بینی مقدار عدد فرود با معادلات تجربی و مدل‌های یادگیری ماشین، امروزه دیگر استفاده از معادلات تجربی پیشنهاد نمی‌گردد و با استفاده از مدل‌های یادگیری مانند شبکه عصبی مصنوعی و مدل‌های هیبریدی آن می‌توان مقادیر را با دقت بالاتری پیش‌بینی نمود. به علاوه نتایج این دیاگرام کمی متفاوت از نتایج معیارهای ارزیابی موجود در جدول (۵) می‌باشد چرا که در تحلیل نتایج جدول مذکور مناسب‌ترین مدل‌ها ANN-DE و ANN-FA پیشنهاد شدند. با این وجود اختلاف دقت نتایج مدل‌های هیبریدی نسبت به یکدیگر ناچیز است و نشان می‌دهد هر سه الگوریتم از دقت بالایی در پیش‌بینی مقدار عدد فرود برخوردار هستند.

### ۴- نتیجه‌گیری

در پژوهش حاضر به منظور پیش‌بینی مقدار عدد فرود در فرآیند انتقال رسوب از مدل‌های شبکه عصبی مصنوعی و در ادامه از سه الگوریتم تکاملی PSO، DE و FA جهت آموزش بهتر ANN و بهبود نتایج آن استفاده شد. هم‌چنین پارامترهای مؤثر بر پیش- $B$ ینی عدد فرود پارامترهای  $\lambda$ ،  $D_{gr}$ ،  $d/R$ ،  $C_v$  بوده که باهم ترکیب و الگوهای مختلفی به عنوان ورودی به مدل‌ها تدوین شده است. برای تحلیل و ارزیابی الگوها و مدل‌ها از معیارهای ارزیابی

### References

- Ab Ghani, A. (1993). Sediment Transport in Sewers. PhD Thesis, University of Newcastle upon Tyne, UK.
- Arumugam, M. S., Rao, M. V. C. and Chandramohan, A. (2008). A new and improved version of particle swarm optimization algorithm with global-local best parameters. Knowl. Inf. Syst., 16(3), 331-357.
- Bong, C. H. J. (2013). Self-cleansing Urban Drain Using Sediment Flushing Gate Based on Incipient Motion. Ph.D. Thesis. Universiti Sains Malaysia.
- Bong, C. H. J., Lau, T. L., Ab Ghani, A. and Chan, N. W. (2016). Sediment deposit thickness and its effect on critical velocity for incipient motion. Water Sci. Technol. 74(8), 1876-1884.
- Butler, D., May, R. and Ackers, J. (2003). Self-cleansing sewer design based on sediment

- transport principles. *J. Hydraul. Eng.*, ASCE, 129(4), 276–282.
- Chen, X. Y. and Chau, K. W. (2016). A hybrid double feedforward neural network for suspended sediment load estimation. *Water Resour Manag.*, 30(7), 2179–2194.
- Chau, K. W. (2006). Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River. *J. Hydrol.*, 329(3-4), 363–367.
- Delleur, J. W. (2001). New results and research needs on sediment movement in urban drainage. *J. Water Resour. Plan. Manag.*, 127(3), 186–193.
- Eberhart, R. and Kennedy, J. (1995). Particle swarm optimization. In Proceedings of the IEEE international conference on neural networks (Vol. 4, pp. 1942–1948). Citeseer.
- El-Zaemey, A. K. S. (1991). Sediment Transport Over Deposited Beds in Sewers. PhD Thesis, University of Newcastle upon Tyne, UK.
- Garoosi Nejhad, A. and Bozorg Hadad, O. (2011). Optimal operation of the tank using algorithm implementation Optimization of firefly. Fifth Iranian Water Resources Management Conference, Shahid Beheshti University, Iran [In Persian].
- Haykin, S. (1999). Neural network a comprehensive foundation. Prentice-Hall, New Jersey.
- Hosseini-Moghari, S. and Banihabib, M. (2014). Optimizing operation of reservoir for agricultural water supply using firefly algorithm. *J. Soil Water Conserv.*, 3(4), 17–31 [In Persian].
- Kennedy, J. and Eberhart, R. (1995). Particle Swarm Optimization. Proceedings of IEEE International Conference on Neural Networks. IV. pp. 1942–1948.
- Kisi, O. and Shiri, J. (2012). River suspended sediment estimation by climatic variables implication: Comparative study among soft computing techniques. *Comput. Geosci.*, 43, 73–82.
- Lippman, R. (1987). An introduction to computing with neural nets. *IEEE ASSP Mag.*, 4(2), 4–22.
- May, R. (1993). Sediment Transport in Pipes and Sewers with Deposited Beds. Report SR 320, HR Wallingford, Oxfordshire, UK.
- Mayerle, R., Nalluri, C. and Novak, P. (1991). Sediment transport in rigid bed conveyances. *J. Hydraul. Res.*, 29(4), 475–495.
- Mayerle, R. (1988). Sediment Transport in Rigid Boundary Channels. PhD thesis, University of Newcastle upon Tyne, Newcastle upon Tyne, UK.
- Mehra, P. and Wah, B. W. (1990). Artificial neural networks: concepts and theory. IEEE Computer Society Press.
- Montes, C., Vanegas, S., Kapelan Z., Berardi, L. and Saldarriaga, J. (2020). Non-deposition self-cleansing models for large sewer pipes. *Water Sci. Technol.*, 81(3), 606–621.
- Novak, P. and Nalluri, C. (1975). Sediment transport in smooth fixed bed channels. *J. Hydraul. Div.*, 101(9), 1139–1154.
- Olyaie, E., Banejad, H., Chau, K. W. and Melesse, A. M. (2015). A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems: a case study in United States. *Environ. Monit. Assess.*, 87(4), 189.
- Ota, J. J. and Perrusquia, G. S. (2013). Particle velocity and sediment transport at the limit of deposition in sewers. *Water Sci. Technol.*, 67(5), 959–967.
- Piotrowski, A. P. and Napiorkowski, J. J. (2011). Optimizing neural networks for river flow forecasting—Evolutionary Computation methods versus the Levenberg–Marquardt approach. *J. Hydrol.*, 407(1–4), 12–27.
- Safari, M. J. S., Ebtehaj, I., Bonkdari, H. and Es-haghi, M. S. (2019). Sediment transport modeling in rigid boundary open channels

- using generalize structure of group method of data handling. *J. Hydrol.*, 577, 125-142.
- Safari, M. J. S. and Danandeh Mehr, A. (2018). Multigene genetic programming for sediment transport modeling in sewers at non-deposition with deposited bed condition. *Int. J. Sediment Res.*, 33(3), 262–270.
- Salem, A. M. (2013). The effects of the sediment bed thickness on the incipient motion of particles in a rigid rectangular channel. Seventeenth International Water Technology Conference (IWTC17), Istanbul, Turkey.
- Storn, R. and Price, K. (1997). Differential Evolution – A Simple and Efficient Heuristic for global Optimization over Continuous Spaces. *J. Global Optim.*, 11, 341–359.
- Vongvisessomjai, N., Tingsanchali, T. and Babel, M. S. (2010). Non-deposition design criteria for sewers with part-full flow. *Urban Water J.*, 7(1), 61–77.
- Yang, X-S. (2010). Firefly algorithm, stochastic test functions and design optimization. *Int. J. Bio-Inspired Comput.*, 2(2), 78–84.
- Zhang, Y. (2006). Towards piecewise-linear primal neural networks for optimization and redundant robotics. In: Proceedings of IEEE International Conference on Networking, Sensing and Control, pp. 374–379. IEEE Computer Society Press, Los Alamitos.
- Zhu Y. M., Lu X. X. and Zhou Y. (2007). Suspended sediment flux modeling with artificial neural network: An example of the Long Chuanjiang River in the Upper Yangtze Catchment, China. *Geomorph.*, 84(1), 111-125.

## Research Paper

# Development of a Hybrid ANN-evolutionary Algorithms Models to Predict the Froude Number in Open Channel Flows in Modeling of Sediment Transport

**Naser Arya Azar<sup>1</sup>, Sami Ghordoyee Milan<sup>2</sup> and Nazila Kardan<sup>3\*</sup>**

<sup>1</sup>M. Sc., Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

<sup>2</sup>M. Sc., Department of Irrigation and Drainage Engineering, Aburaihan Campus, University of Tehran, Tehran, Iran

<sup>3</sup>Assist. Professor, Department of Civil Engineering, Azarabaijan Shahid Madani University, Tabriz, Iran

**\*Corresponding author:** n.kardan@azaruniv.ac.ir

**Received:** September 14, 2020

**Revised:** November 10, 2020

**Accepted:** November 16, 2020

### **Abstract**

In water engineering, estimating Froude number's value is very important. The applying of machine learning models has received much attention because it does not require system building information. For this purpose, in the present study, the artificial neural network (ANN) model was used. To improve the ANN results, evolutionary algorithms including Particle Swarm Algorithm (PSO), Firefly Algorithm (FA) and Differential Evolution Algorithm (DE) have been used to predict the amount of Froude number. The parameters affecting the prediction of Froude number were  $\lambda$ ,  $d / R$ ,  $D_{gr}$ ,  $C_v$  that combined, and different input patterns have been developed as input to the models. The results showed that the model involving all the affecting input parameters has the highest accuracy in predicting the Froude number. The proposed evolutionary algorithms significantly improved the accuracy of the ANN model. Among the algorithms, FA and PSO algorithms had good accuracy in most evaluation criteria. In general, the applying of evolutionary algorithms improved the accuracy of the ANN model by 0.89 m, 0.07 m and 0.1. The results of machine learning models were also significantly different from the experimental equations and indicated the high accuracy of machine learning models. Therefore, it is recommended to use them instead of using experimental equations in estimating the value of the Froude number.

**Key words:** ANN Hybrid Model; ANN; Froude Number; Sediment Transport.