



## مدیریت آب و آبیاری (نشریه علمی)

دوره ۱۱ ■ شماره ۲ ■ تابستان ۱۴۰۰

صفحه‌های ۱۴۳-۱۳۱

DOI: 10.22059/jwim.2021.312641.838

مقاله پژوهشی:

### مدل سازی درصد کاهش هد جریان غلیظ نمکی با استفاده از هوش مصنوعی

مهدی درخشان‌نیا<sup>۱</sup>، مهدی قمشی<sup>۲</sup>، سید سعید اسلامیان<sup>۳\*</sup>، سید محمود کاشفی‌پور<sup>۲</sup>

۱. دانشجوی دکتری، گروه مهندسی عمران، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران.

۲. استاد، گروه مهندسی سازه‌های آبی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.

۳. استاد، گروه مهندسی عمران، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران و گروه مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، اصفهان، ایران.

تاریخ پذیرش مقاله: ۱۴۰۰/۰۳/۱۵

تاریخ دریافت مقاله: ۱۳۹۹/۰۸/۲۰

#### چکیده

جریان غلیظ یکی از مهم‌ترین عوامل در فرایند رسوب‌گذاری سدها می‌باشد. چون این جریان از عوامل مؤثر بر کاهش کارایی عمر سدهای بزرگ بوده، بنابراین درک الگوهای رسوب‌گذاری جهت مدیریت مخزن سدها بسیار کارآمد می‌باشد. بر این اساس در این پژوهش درصد کاهش هد جریان غلیظ نمکی تحت تأثیر موانع نفوذپذیر دوزنقه‌ای شکل (پرسیده با دانه‌های شن با قطر ۰/۵ سانتی‌متر)، با در نظر گرفتن متغیرهایی هم‌چون دبی، غلظت و ارتفاع موانع به صورت آزمایشگاهی مورد بررسی قرار گرفته است و براساس نتایج حاصله اقدام به مدل‌سازی هد جریان غلیظ نمکی با روش شبکه عصبی مصنوعی پیش‌خور و روش کلاسیک رگرسیون چندمتغیره شده و کارکرد این دو روش مورد مقایسه قرار گرفته است. نتایج نشان داد که روش هوشمند شبکه عصبی مصنوعی پیش‌خور در مدل‌سازی درصد کاهش هد جریان غلیظ نمکی نسبت به روش رگرسیون چند متغیره برتری قابل توجهی دارد.

**کلیدواژه‌ها:** جریان غلیظ، درصد کاهش هد، رگرسیون چندمتغیره شبکه عصبی پیش‌خور.

### Modeling the reduction percentage of the density current head flux using artificial intelligence

Mehdi Derakhshannia<sup>1</sup>, Mehdi Ghomeshi<sup>2</sup>, Seyed Saeid Eslamian<sup>3\*</sup>, Seyed Mahmood Kashefipour<sup>2</sup>

1. Ph.D. Candidate, Department of Civil Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran.

2. Professor, Department of Water Structures, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

3. Professor, Department of Civil Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran and Department of Water Engineering, College of Agriculture, Isfahan University of Technology, Isfahan, Iran.

Received: November, 10, 2020

Accepted: June, 05, 2021

#### Abstract

Density current is one of the most important factors in the sedimentation process of dams. Because this current is one of the important factors affecting the reduction of life efficiency of large dams, so understanding sedimentation patterns to manage the reservoir of dams is very effective. Accordingly, in this study, the reduction percentage of the density current head flux under the influence of trapezoidal permeable barriers (filled with sand grains with a diameter of 0.5 cm) is investigated also variable parameters effect such as discharge, slope, concentration and height of obstacles on density current control is examined experimentally, based on the results, the reduction percentage of the density current head flux was modeled using the artificial neural network feed-forward method and the classical multivariable regression method, and the performance of these two methods was compared. The results showed that the intelligent method of feed-forward artificial neural network has a significant advantage over the multivariable regression method in modeling the reduction percentage of the density current head flux.

**Keywords:** Density current, Feed-forward artificial neural network, Head reduction percentage, Multivariable regression.

## مقدمه

سالیانه عمر مفید تعداد زیادی از سدهای مخزنی در سراسر جهان به دلیل ته‌نشینی رسوبات در نزدیکی دیواره آن‌ها کاهش پیدا می‌کند. با پژوهش‌های انجام‌شده مشخص شد که عامل اصلی انتقال این رسوبات، جریان‌های کدر می‌باشند. از آنجایی که نیروی گرانش بر این جریان‌ها (که غلظت بیش‌تری از آب شفاف دارند) تأثیر می‌گذارد، جریان‌های کدر به‌عنوان جریان‌های زیرین به حرکت خود در مخازن ادامه می‌دهند. چون عامل ایجاد این جریان‌ها نیروی جاذبه واردشده بر اختلاف چگالی دو سیال می‌باشد. بر این اساس جریان‌های کدر زیرمجموعه جریان‌های چگال یا غلیظ قرار گرفته می‌شوند (Rzadkiewicz *et al.*, 1997). وقوع جریان کدر در مخازن سد سبب نزدیکی رسوبات به بدنه سدها شده که تهدیدهای قابل‌توجهی برای تأسیسات آزادسازی آب مانند دریچه‌های ورودی و خروجی بخش پایینی سد ایجاد می‌کند، کنترل و حذف چنین جریان‌هایی سبب بهبود و افزایش طول عمر مفید سدها می‌شود (Asghari Pari *et al.*, 2017). مهندسین تکنیک‌های مختلفی برای مدیریت رسوب-گذاری در مخازن ارائه داده‌اند که ساخت موانع در مخازن یکی از مؤثرترین روش‌ها جهت کنترل یا انحراف جریان‌ها غلیظ می‌باشد، همین امر سبب کاهش غلظت و چگالی جریان عبوری از روی موانع شده و در نتیجه بسیاری از رسوبات در پشت مانع رسوب می‌کنند. با این حال جریان غلیظ اندکی که از روی مانع عبور کرده، به دلیل کاهش چگالی نسبی جریان از بین می‌رود. وقتی جریان غلیظ با مانعی روبه‌رو می‌شود، بسته به ارتفاع مانع و شرایط ورودی روند متفاوتی رخ می‌دهد، که می‌توان آن را به چهار حالت طبقه‌بندی نمود. این نظریه توسط (Asghari Pari *et al.*, 2010)

به‌طور گسترده موردبحث قرار گرفته است و به‌طور خلاصه در شکل (۱) ارائه شده است. در شکل (۱) رژیم جریان عبوری از مانع را در یک جریان دو لایه، با لایه فوقانی شفاف برای عدد فرود متفاوت ارائه داده شده است. حالت اول زمانی اتفاق می‌افتد که ارتفاع مانع کم باشد، در این حالت جریان کاملاً از روی مانع عبور می‌کند، این حالت مربوط به مناطق A، B و C می‌باشد. حالت دوم زمانی اتفاق می‌افتد که ارتفاع مانع به گونه‌ای باشد که جریان با عمق بحرانی به‌طور کامل از روی مانع عبور می‌کند. حالت سوم زمانی اتفاق می‌افتد که ارتفاع مانع به گونه‌ای باشد که جریان حتی با عمق بحرانی نیز نتواند از روی مانع عبور کند، در این حالت بخشی از جریان از روی مانع عبور می‌کند و باقی آن به‌صورت پرش هیدرولیکی به سمت بالادست حرکت می‌کند. چنین پرشی منجر به اتلاف انرژی شده و شرایط جریان را در بالادست و پایین دست تنظیم می‌کند. این حالت مربوط به منطقه D می‌باشد. حالت چهارم زمانی اتفاق می‌افتد که ارتفاع مانع به اندازه کافی زیاد انتخاب شود تا جریان کاملاً مسدود شود (منطقه E). از آنجاکه در دو مورد اول، جریان در حالت ثابت باقی‌مانده و انسداد نسبی جریان اتفاق نمی‌افتد، این دو حالت بر الگوی رسوب تأثیر نمی‌گذارند. بنابراین چنین مواردی در محدوده این پژوهش نمی‌گنجد، در این پژوهش همه آزمایش‌ها در شرایطی انجام شده که انسداد نسبی یا کامل جریان رخ دهد (یعنی مناطق D و E که عدد فرود کم‌تر از یک می‌باشد).

Wilson *et al.* (2018) در پژوهشی آزمایشگاهی به بررسی اثر مانع مستطیلی شکل پرداختند و متوجه شدند که میزان اغتشاش در نزدیک مانع به شدت افزایش یافته که به کاهش سرعت می‌انجامد.

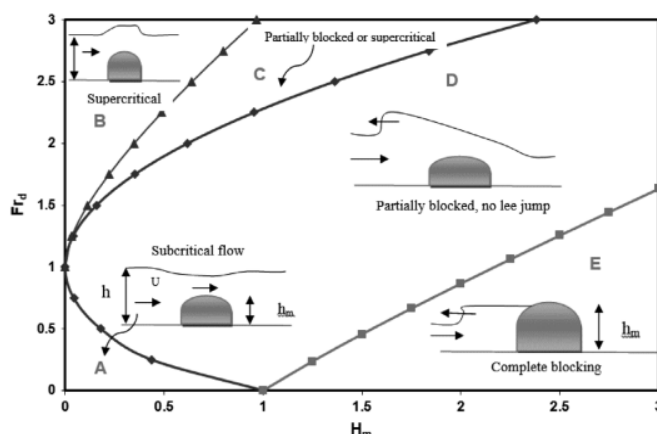


Figure 1. The process of crossing the density current over obstacles (Asghari pari *et al.*, 2010)

پژوهشی آزمایشگاهی به بررسی دبی، غلظت، شیب و ارتفاع موانع پرداختند، که نتایج نشان از افزایش کارایی موانع با افزایش ارتفاع آن‌ها داشت. Baghalian & Ghodsian (2020) در پژوهشی آزمایشگاهی به بررسی اثر زبری بستر مصنوعی بر جریان کدر با تغییر ناگهانی در شیب بستر پرداختند. نتایج نشان داد که تأثیر زبری بستر بر سرعت هد جریان کدر چشم‌گیر است.

Kooti *et al.* (2018) از نظر آزمایشگاهی به بررسی میزان تأثیر زبری بر ایجاد اختلاط بین سیال شفاف و غلیظ در مرز دو سیال پرداختند که متوجه شدند افزایش زبری کف تأثیر چندانی در ایجاد اختلاط در مرز دو سیال ندارد. Jahangir *et al.* (2020) در مطالعه آزمایشگاهی به بررسی اثر تخلخل و زاویه نصب و ضخامت (بعد) موانع نفوذپذیر بر کنترل جریان غلیظ پرداختند. آن‌ها متوجه شدند که افزایش زاویه نصب سبب کاهش کارایی موانع می‌شود.

ساخت یک مانع در مخزن سد یک روش جدید و کارآمد در کاهش اثرات جریان غلیظ می‌باشد بر این اساس در پژوهش حاضر از یک مدل فیزیکی برای بررسی تأثیر اثر موانع دوزنقه‌ای نفوذپذیر (پرشده با شن ۰/۵ سانتی‌متر) بر هد جریان غلیظ تحت متغیرهایی هم‌چون دبی و غلظت ورودی، شیب و ارتفاع مانع استفاده شده و براساس نتایج

Xu *et al.* (2020) در پژوهشی عددی به مطالعه جریان غلیظ پرداختند و برای این منظور متغیرهایی هم‌چون غلظت و سرعت جریان غلیظ را در پایین‌دست فلوم بررسی کردند و متوجه شدند که عمق بدنه جریان غلیظ ۰/۳ تا ۰/۶ کل ارتفاع سیال موجود در فلوم می‌باشد. Ebrahimzadeh *et al.* (2019) با توسعه مدل پویایی سیستم‌ها به شبیه‌سازی سد حاجیلرچای پرداختند. He *et al.* (2018) با استفاده از شبیه‌سازی عددی متوجه شدند که افزایش شیب سبب تشکیل سریع‌تر هد جریان غلیظ می‌شود که همین امر سبب کاهش کارایی موانع می‌شود. Davoodi & Shafaei (2011) Bajestani به بررسی عملکرد صفحات مستغرق در کنترل رسوب آبگیرهای منشعب از کانال‌های آبیاری پرداختند. Pirnia *et al.* (2012) به مدل‌سازی نفوذ نمک به رودخانه‌ها و ایجاد جریان‌های غلیظ پرداختند. Nasrollahpour & Qomshi (2012) تأثیر هندسه زبری را بر غلظت هد جریان غلیظ مورد بررسی قرار دادند. Oshaghi *et al.* (2013) یک سری آزمایش‌های آزمایشگاهی را با ارتفاع‌های مانع و عدد فرود متفاوت ورودی انجام دادند. نتایج نشان داد که جریان غلیظ با عدد فرود ورودی کم‌تر، سریع‌تر نسبت به جریان با عدد فرود بیشتر نسبت به حضور مانع واکنش نشان می‌دهد. Abhari *et al.* (2018) در

فلوم قابلیت افزایش شیب به صورت دستی به میزان ۴ درصد را داشت (شکل ۲). سرریزی در انتها کانال تعبیه شده بود که بتوان ارتفاع آب را در حین آزمایش کنترل نمود و دریچه‌ای در ابتدای کانال نصب شده بود و با شروع هر آزمایش به میزان ۱۰ سانتی‌متر به‌طور ناگهانی باز می‌شد. این دریچه امکان جداسازی سیال غلیظ در بالادست و آب شفاف را در پایین دست کانال را بدون اختلاط میسر می‌کرد. یک مانع نفوذپذیر دوزنقه‌ای با طول ۲۵ سانتی‌متر، ارتفاع متغیر و شیب جداره ۱:۱ که با شن با قطر ۰/۵ سانتی‌متر کاملاً پر شده، به‌گونه‌ای که عرض کانال را کاملاً اشغال کرده، در فاصله ۲ متری دریچه ورودی قرار داده شده بود. سیال غلیظ در مخزن استوانه‌ای شکل با حجم ۳۰۰۰ لیتر با اضافه کردن نمک و پرمنگنات (جهت ردیابی جریان) تهیه می‌شد و برای این‌که بتوان جریان یک‌نواخت را در آزمایش‌ها ایجاد کرد با پمپ تعبیه‌شده در کنار مخزن این سیال را به هد تانک که در ارتفاع ۳ متری سطح زمین قرار داده شده بود، منتقل می‌شد. از دی‌سنج الکترومغناطیس با دقت ۰/۰۰۱ لیتر در ثانیه برای تعیین سیال غلیظ عبوری استفاده می‌شد و هنگامی که سطح سیال غلیظ در پشت دریچه و سیال شفاف در کانال پایین دست به ارتفاع ۵۰ سانتی‌متر می‌رسید، دریچه کاملاً باز شده و جریان غلیظ تشکیل می‌شد. در تمامی آزمایش‌ها حالت جریان زیربحرانی بود.

در مجموع ۷۲ آزمایش جریان غلیظ نمکی انجام شد و متغیرهای مورد بررسی شامل شیب (۰/۵، ۱ و ۱/۵ درصد)، غلظت ورودی (۱۰ و ۱۵ گرم در لیتر) و دبی (۱ و ۱/۵ و ۲ لیتر در ثانیه) بود. هجده آزمایش بدون مانع (برای تعیین بدنه جریان غلیظ) و ۵۴ آزمایش با مانع (با ارتفاع ۱، ۱/۵ و ۲ برابر ارتفاع بدنه جریان غلیظ) انجام شد. در فواصل ۰/۵ متر قبل و بعد از مانع سیفون نصب شده بود تا بتوان میزان هد جریان غلیظ را ثبت کرد و با فیلم‌برداری کلیه آزمایش‌ها، مقادیر ارتفاع و سرعت هد جریان غلیظ تعیین می‌شد.

حاصله میزان درصد کاهش شار هد جریان مشخص می‌شود. در بخش بعد با توجه به نتایج آزمایشگاهی به مدل‌سازی این جریان با هوش مصنوعی (شبکه عصبی مصنوعی پیش‌خور و روش رگسیون چند متغیره) پرداخته شده است. در واقع انجام آزمایش‌های آزمایشگاهی بسیار محدود می‌باشد و دستیابی به نتایج آزمایشگاهی براساس تمامی شرایط مؤثر بر طرح تعریف‌شده تقریباً غیرممکن می‌باشد، که محدودیت‌های مختلفی از جمله هزینه بالا و مدت زمان طولانی برای انجام تست‌های آزمایشگاهی نیز در این زمینه وجود دارد. علاوه بر این بسیاری اوقات طرح‌های آزمایشگاهی به صورت خاص برای شرایط یک مشکل طرح‌ریزی شده و هنگامی که طراحان نتایج آزمایشگاهی را دریافت می‌کنند، متوجه می‌شوند که در برخی شرایط نیاز به معرفی متغیرهای اضافی بوده که دستیابی به آزمایشگاه و ابزارآلات مربوطه و ایجاد تغییرات در محیط آزمایشگاهی براساس طرح پژوهشی جدید، گاهی اوقات امکان‌پذیر نمی‌باشد. بنابراین ارائه یک ابزار هوشمند برای مجهز کردن طراح جهت پیش‌بینی دقیق شرایط و امکان ایجاد تغییرات متنوع در روند آزمایش‌ها لازم می‌باشد، هم‌چنین راه‌کاری باید تعریف شود که بتواند مقادیر پارامترهای طراحی مستقل و خروجی‌های موردنظر را ارائه دهد و با این کار سبب ساده‌شدن بسیاری از طرح‌ها شود. مشکلات بیان شده با استفاده از رویکرد ارائه‌شده از این مطالعه براساس هوش مصنوعی قابل حل است و امکان تعیین دقت پیش‌بینی برای این آزمایش‌ها در مراحل مختلف و با داده‌های مختلف قابل اندازه‌گیری است.

## آزمایش‌ها

آزمایش‌های این پژوهش در آزمایشگاه هیدرولیک دانشگاه شهید چمران اهواز در فلومی مستطیلی شکل به طول ۷/۸ متر، عرض ۴۰ سانتی‌متر و ارتفاع ۷۰ سانتی‌متر انجام شد. این

مدل‌سازی درصد کاهش هد جریان غلیظ نمکی با استفاده از هوش مصنوعی




Figure 2. Laboratory flume view (Asghari Pari et al., 2010)

تعداد لایه‌ها و نورون‌های پنهان، ج) آموزش و تست شبکه تعیین می‌شود که براساس رابطه (۱) ارائه می‌شود:

$$Y_i = f_2 \left[ \sum_{j=1}^j W_{ij} f_1 \left( \sum_{i=1}^i W_{ji} X_i \right) \right] \quad (1)$$

که در آن،  $Y_i$  خروجی شبکه،  $X_i$  ورودی شبکه و  $w_i$  و  $w_j$  به ترتیب وزن‌دهی بین نورون‌های ورودی و لایه پنهان و هم‌چنین لایه پنهان و خروجی می‌باشد. طبق نظرات Maier and Dandy (2000) عملکرد انتقال نوع سیگموئیدی و توابع انتقال خطی به ترتیب برای لایه پنهان و خروجی توصیه می‌شود. در این مطالعه  $f_1$  تابعی از تانسینگموئید در نظر گرفته شده است که یک تابع غیرخطی است و  $f_2$  تابعی خطی بوده که به شرح زیر تعریف شده است (رابطه‌های ۲ و ۳):

$$f_1 = \frac{2}{1 + \exp(-2x)} - 1 \quad (2)$$

$$f_2(x) = x \quad (3)$$

مدل‌های ANN براساس الگوریتم لونیبرگ-مارکارد آموزش داده شده‌اند و تعداد سلول‌های عصبی پنهان بر الگوریتم سازنده انتخاب شدند. در مدل‌سازی ANN همیشه شانس فرابرازش وجود دارد و برای جلوگیری از بروز این مشکل، در این مطالعه از روش توقف اولیه هنگام آموزش استفاده شده است. در این روش شبکه از فرابرازش بیش‌تر جلوگیری می‌کند (Rojas, 2013).

### شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی (ANN) یک مدل ریاضی است که توانایی پیدا کردن رابطه غیرخطی بین پارامترهای ورودی و خروجی بدون نیاز به حل معادلات پیچیده جزئی دیفرانسیل را دارد. ANN در بسیاری از طرح‌های مهندسی از جمله جریان‌های غلیظ کاربرد دارد. ANN از شبکه‌های عصبی بیولوژیکی الهام گرفته که شامل نورون‌ها و اتصالات ساده‌ای است که اطلاعات را پردازش کرده تا رابطه‌ای بین ورودی و خروجی پیدا کنند. معمول‌ترین معماری ANN که توسط مهندسين استفاده شده، گیرنده‌های چند لایه است که یک شبکه تغذیه‌کننده پیش‌خور می‌باشد که از سه لایه نورون که شامل لایه ورودی، لایه‌های پنهان و لایه خروجی تشکیل شده است. تعداد نورون‌های ورودی و خروجی براساس تعداد داده‌های ورودی و خروجی می‌باشد، لایه ورودی فقط به‌عنوان دریافت داده‌های ورودی برای پردازش بیش‌تر در شبکه عصبی عمل می‌کند و لایه‌های پنهان بخش بسیار مهمی در MLP ایفا می‌کند زیرا قادر به ایجاد روابط غیرخطی بین مجموعه‌های ورودی و خروجی می‌باشد. با افزایش نورون‌های پنهان در لایه‌های پنهان یا تعداد لایه‌های پنهان می‌توان مشکلات پیچیده‌تری را حل کرد. نورون خروجی در واقع خروجی مطلوب مدل است. فرایند ارتقا ANN براساس الف) ورودی مناسب مجموعه داده‌ها، ب)

### مدل‌سازی با استفاده از رگرسیون چندجمله‌ای

رگرسیون چندجمله‌ای در واقع تابعی چندجمله‌ای است که قادر به ایجاد رابطه بین هر مجموعه ورودی و خروجی مربوطه می‌باشد. مدل رگرسیون چندجمله‌ای که شامل بیش از دو متغیر پیش‌بینی‌کننده باشد، MPR نامیده می‌شود. اگر رگرسیون چندجمله‌ای درجه بالایی داشته باشد و یا دامنه عملکرد آن صفر نباشد می‌تواند از نظر عددی ناپایدار شود، از طرفی اگر درجه چندجمله‌ای خیلی کم باشد، نمی‌تواند پیچیدگی تابعی را که فراگرفته به‌خوبی نمایش دهد. اما با تمام ضعف‌های بیان‌شده، این روش هنوز از بهترین روش‌های مدل‌سازی می‌باشد. در اینجا رابطه آماری بین درصد کاهش هد جریان غلیظ براساس سایر پارامترها (ارتفاع موانع، شیب، دبی و غلظت) را با استفاده از معادله MPR مرتبه‌های مختلف بیان شده است و مرتبه مناسب برای مدل‌سازی این داده‌ها استفاده شده است. معادله چندجمله‌ای موردنظر در این تحقیق در حالت کلی به شکل زیر است (رابطه ۴):

$$y = P(m, n, k) = \beta_0 + \beta_1 x_1 + \beta_{12} x_1^2 \dots + \beta_{1m} x_1^m + \beta_{21} x_2 + \beta_{22} x_2^2 + \dots + \beta_{2n} x_2^n + \beta_{31} x_3 + \beta_{32} x_3^2 \dots + \beta_{3k} x_3^k + \beta_{41} x_4 + \beta_{42} x_4^2 + \dots + \beta_{4p} x_4^p \quad (4)$$

که در آن،  $y$  نشان‌دهنده پیش‌بینی درصد کاهش هد جریان غلیظ و  $x_1, \dots, x_n$  پارامترهای ورودی هستند. برای به‌دست‌آوردن پارامترهای  $\beta$  معمولاً از روش تحلیلی حداقل میانگین مربعات خطا با استفاده از مفاهیم جبر خطی براساس رابطه (۵) استفاده می‌شود.

$$A = \begin{bmatrix} 1 & x_{11} & \dots & x_{11}^m & x_{21} & \dots & x_{21}^n & x_{31} & \dots & x_{31}^k & x_{41} & \dots & x_{41}^p \\ 1 & x_{12} & \dots & x_{12}^m & x_{22} & \dots & x_{22}^n & x_{32} & \dots & x_{32}^k & x_{42} & \dots & x_{42}^p \\ \vdots & \vdots & \dots & \vdots & \vdots & \dots & \vdots & \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{1t} & \dots & x_{1t}^m & x_{2t} & \dots & x_{2t}^n & x_{3t} & \dots & x_{3t}^k & x_{4t} & \dots & x_{4t}^p \end{bmatrix} \quad (5)$$

که رابطه (۵) شامل داده‌های پارامترهای ورودی می‌باشد ( $t$  تعداد داده‌ها می‌باشد).

$$y = [y_1, y_2, \dots, y_t]^T \quad (6)$$

که در آن،  $y$  برداری شامل داده‌های خروجی می‌باشد و پارامترهای چند جمله‌ای به‌صورت زیر به‌دست می‌آیند (رابطه ۷).

$$\beta = (A^T A)^{-1} A^T y \quad (7)$$

این روش بسیار دقیق بوده و قابلیت ایجاد پارامترهای مدل چندجمله‌ای را به‌صورت تحلیلی را دارد. استفاده از این روش مشکلاتی نیز دارد و از جمله این که ابعاد ماتریس  $A^T A$  می‌تواند بسیار زیاد باشد و این باعث می‌شود که گرفتن معکوس این ماتریس بسیار مشکل و زمان‌بر باشد. مورد دیگر این که ماتریس فوق از مرتبه کامل نباشد و در نتیجه باعث می‌شود که درمیان آن صفر شود و در نتیجه ماتریس فوق معکوس‌پذیر نبوده و دیگر این روش پاسخ‌گو نمی‌باشد. به‌دلیل مشکلات ذکرشده، لازم است برای تعیین این پارامترها از روش‌های بهینه‌سازی استفاده شود که در این مقاله از الگوریتم بهینه‌سازی ژنتیک استفاده شده است (Bishop, 2006).

### الگوریتم بهینه‌سازی ژنتیک

یکی از مؤثرترین و کاراترین روش‌های بهینه‌سازی ابتکاری استفاده از الگوریتم ژنتیک می‌باشد. در الگوریتم ژنتیک معمولاً یک جمعیت تصادفی تعیین شده سپس برای دستیابی به راه‌حل‌های بهتر مجموعه اولیه تکامل می‌یابد. این فرایند تکامل ادامه پیدا کرده تا شرایط توقف تکامل ایجاد و مهیا شود. در ابتدا جواب‌های اولیه به‌عنوان کروموزوم‌های اولیه انتخاب شده و براساس تابع هزینه، هزینه اولیه محاسبه می‌شود و سپس با انتخاب کروموزوم‌های بهتر، این کروموزوم‌ها با هم ترکیب شده و نسل بعدی کروموزوم‌ها ایجاد می‌شوند. پس از اجرای این فرایند مشاهده می‌شود که در هر نسل، کروموزوم‌های (جواب‌های) بهتری حاصل می‌شوند. پس از انجام فرایند تکامل، مناسب‌ترین کروموزوم به‌عنوان یک پاسخ بهینه برای

ماکزیمم آن پارامتر تقسیم شده تا داده‌های مربوطه بین صفر و یک قرار گیرند.

۲- در آموزش شبکه عصبی ۸۵ درصد داده‌ها به صورت تصادفی (داده‌ها با استفاده از نرم‌افزار MATLAB و به‌کارگیری تابع شبه‌تصادفی، سبب قرارگیری داده‌ها به صورت تصادفی در ماتریس جدیدی می‌شوند) انتخاب شده و برای آموزش شبکه استفاده می‌شوند و ۱۵ درصد باقیمانده داده‌ها برای تست استفاده می‌شوند. واضح است، شبکه‌ای عملکرد مناسب‌تری دارد که خطای تخمین خروجی آن برای هر دو داده‌های آموزشی و تست کمینه باشد.

۳- در این بخش به شبیه‌سازی برای نوروهای لایه‌های مختلف پرداخته می‌شود.

۴- حالت بهینه طوری انتخاب می‌شود که معیار RMSE برای داده‌های آموزشی بسیار کم بوده و R آن بسیار زیاد و نزدیک به یک باشد، که پس از این که نتایج مناسب برای داده‌های آموزش ارائه شد این دو شرط برای داده‌های تست نیز مورد بررسی قرار می‌گیرد سپس ساختاری انتخاب می‌شود که حالت بهینه برای داده‌های آموزشی و تست ایجاد کند.

با توجه به جدول (۲) واضح است که شبکه با ساختار (۱-۱۳-۴) مناسب‌ترین شبکه برای مدل‌سازی داده‌های مربوطه بوده و مقدار  $0/0001$  خطای پیش‌بینی را برای داده‌های آموزشی نشان داده است، که مقدار خطای کم و بسیار مناسبی را نشان می‌دهد. خطای بسیار کم شبکه عصبی در تخمین درصد کاهش شار هد جریان غلیظ می‌تواند به دلیل فرابرازش در یادگیری شبکه عصبی اتفاق افتاده باشد. به این صورت شبکه عصبی عملاً داده‌های آموزشی را حفظ کرده و فقط می‌تواند برای این داده‌ها به پیش‌بینی درست پردازد که این مورد یکی از بزرگ‌ترین مسایل الگوریتم‌های یادگیری هوشمند می‌باشد، یکی از کاربردی‌ترین روش‌ها برای بررسی فرابرازش در شبکه عصبی استفاده از داده‌های تست می‌باشد که لازم است مورد بررسی قرار گیرد.

مسئله داده‌شده انتخاب می‌شود. در جدول (۱) طبقه‌بندی الگوریتم ژنتیک به صورت گام‌به‌گام نشان داده شده است (Kochenderfer and Wheeler, 2019).

**Table 1. Genetic algorithm framework (Kochenderfer and Wheeler, 2019)**

Genetic algorithm
1. Create an initial population set
2. If the stop criteria are not met, the algorithm continues
3. Do for each chromosome in the population
4. Calculate the cost function for chromosomes
5. Combine chromosomes
6. The new generation will replace the old generation
7. Return to 2

## نتایج و بحث

در این بخش با ذکر جزئیات به ارائه نتایج حاصل از مدل‌سازی داده‌های درصد کاهش هد جریان براساس پارامترهای ورودی (ارتفاع مانع، شیب کف، غلظت و دبی ورودی) پرداخته شده است. ساختار بهینه‌ای از دو روش مدل‌سازی انتخاب شده و به مقایسه کارایی دو روش پرداخته شده است.

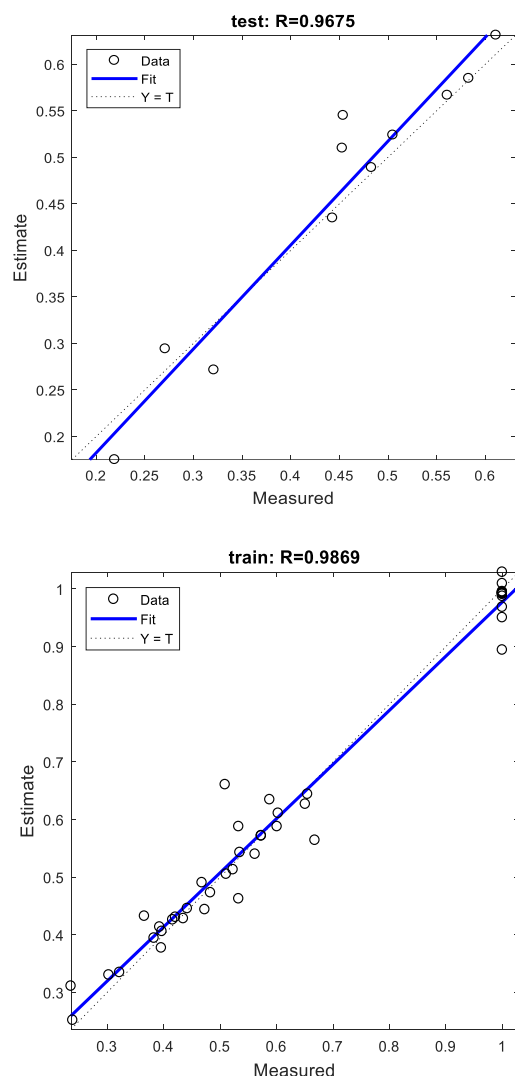
## نتایج مدل‌سازی با شبکه عصبی پیش‌خور

در این بخش به مدل‌سازی داده‌ها با استفاده از شبکه عصبی پیش‌خور پرداخته شده است. ورودی‌های این شبکه شامل ارتفاع مانع، شیب کف، غلظت و دبی ورودی بوده و خروجی شبکه درصد کاهش شار جریان می‌باشد. ساختار شبکه عصبی استفاده‌شده در این بخش  $(1-n-4)$  می‌باشد که اولین عدد از سمت چپ، نشان‌گر تعداد ورودی‌های شبکه، دومین عدد نشان‌گر تعداد نوروها در لایه پنهان و سومین عدد نشان‌گر تعداد خروجی می‌باشد. در این بخش توجه به دو نکته ضروری است:

۱- به منظور آموزش صحیح شبکه عصبی و تأثیر مناسب هر یک از ورودی‌ها بر خروجی موردنظر، داده‌ها ابتدا نرمالیزه شده سپس به شبکه اعمال می‌شوند، به این صورت که داده‌های مربوط به هر پارامتر ورودی بر مقدار

**Table 2. Performance of feed artificial neural network for different network structures**

Row	Structure	Train		Test	
		R	RMSE	R	RMSE
3	4-3-1	0.8779	0.04	0.01	0.01
4	4-4-1	0.8738	0.09	0.9053	0.03
5	4-5-1	0.87	0.007	0.97	0.008
6	4-6-1	0.9757	0.003	0.7203	0.01
7	4-7-1	0.9311	0.015	0.597	0.03
8	4-8-1	0.9987	0.009	0.9235	0.009
9	4-9-1	0.9709	0.0002	0.7212	0.004
10	4-10-1	0.9839	0.0009	0.8247	0.02
11	4-11-1	0.9881	0.003	0.4568	0.05
12	4-12-1	0.8474	0.03	0.9501	0.05
13	4-13-1	0.9869	0.0001	0.9675	0.001
14	4-14-1	0.9634	0.009	0.6021	0.05
15	4-15-1	0.988	0.001	0.854	0.01



**Figure 3. Neural chart of testing and training**

به این ترتیب مشخص شود که آیا شبکه عصبی می‌تواند به تخمین مناسب هد جریان پردازد، اما همان‌گونه که نشان داده شده است خطای پیش‌بینی برای داده‌های تست برای ساختار (4-13-1) مقدار 0.001 بوده که به نحوه مناسبی بسیار کم می‌باشد و این نشان از عملکرد مناسب شبکه عصبی و قدرت پیش‌بینی برای داده‌های جدید را دارد. البته با بررسی نتایج این شبکه با ساختارهای دیگر مشاهده می‌شود که خطای آموزش کم‌تر نیز حاصل شده، اما ساختار (4-13-1) مقدار خطای تست کم‌تری نیز داشته و در پیش‌بینی داده‌های جدید بسیار کارآمد می‌باشد. در بعضی از ساختارهای شبکه عصبی مشخص می‌شود که خطای پیش‌بینی برای داده‌های تست کم‌تر از خطای پیش‌بینی برای داده‌های آموزش می‌باشد که این پدیده در بعضی از الگوریتم‌های پیش‌بینی مشاهده می‌شود که یکی از دلایل اصلی این رخداد این پدیده کم‌بودن نمونه‌های آزمایشگاهی می‌باشد که با افزایش داده‌های موردبررسی تا حد مطلوبی این پدیده برطرف می‌شود. رخداد این پدیده نشان از ضعف الگوریتم یادگیری نمی‌باشد، چرا که در پژوهش‌های مهمی هم‌چون *El-Kenaw et al.* (2020) نیز این پدیده مشاهده می‌شود. در ادامه و در شکل (3) به بررسی دقیق‌تر نمودارهای رگسیون این شبکه برای داده‌های آموزشی و تست پرداخته شده است.



مدل‌سازی داده‌ها توسط رگرسیون چندجمله‌ای با استفاده از الگوریتم ژنتیک ارائه شده است. برای به دست آوردن ضرایب رگرسیون چندجمله‌ای با استفاده از الگوریتم ژنتیک به این صورت عمل می‌شود که تابع هزینه‌ای شامل اختلاف داده‌های واقعی و تخمین زده شده توسط روش رگرسیون به این الگوریتم داده شده و این الگوریتم با کمینه کردن این تابع، ضرایب بهینه را مشخص می‌کند و این ضرایب قادرند بهترین تخمین را ارائه دهند. تابع هزینه استفاده شده در این پژوهش به صورت رابطه (۸) می‌باشد.

$$\cos t = \text{RMSE} (P(x_1, x_2, x_3, x_4) - y) \quad (8)$$

$$= \text{RMSE} (A\beta - y)$$

با بهینه‌سازی این تابع هزینه به وسیله الگوریتم ژنتیک ضرایب بهینه رگرسیون چندمتغیره به دست می‌آیند. در جدول (۳) نتایج مدل‌سازی برای ساختار مختلف ارائه شده است و برای مشخص کردن ساختار بهینه لازم است که معیار RMSE برای داده‌های آموزشی بسیار کم بوده و R آن بسیار زیاد و نزدیک به یک باشد سپس نیاز است که به ارزیابی این دو شرط برای حالت تست نیز پرداخته شود و ساختاری که معیارهای آموزش و تست آن شروط بالا را تأمین کنند به عنوان حالت بهینه معرفی شود.

شکل (۳) نمودار رگرسیون را برای داده‌های آموزش و تست شبکه عصبی پیش‌خور با ساختار (۱-۱۳-۴) را نشان می‌دهد، همان‌طور که مشخص است هر چه مقدار رگرسیون به ۱ نزدیک‌تر باشد، شبکه عملکرد بهتری در پیش‌بینی داده‌های جدید دارد. مقدار رگرسیون داده‌های آموزشی و تست ۰/۹۶۷۵ و ۰/۹۸۶۹ بوده که به صورت مطلوبی نزدیک به یک است و نشان از قدرت پیش‌بینی بالای شبکه دارد. در ادامه به مدل‌سازی داده‌ها با رگرسیون چندمتغیره پرداخته شده است.

### نتایج مدل‌سازی با روش رگرسیون چندمتغیره

در این بخش به ارائه نتایج مدل‌سازی داده‌های درصد کاهش هد جریان براساس پارامترهای ورودی پرداخته شده و برای به دست آوردن ضرایب رگرسیون چندجمله‌ای از الگوریتم ژنتیک استفاده شده است. به این صورت که ابتدا به مدل‌سازی داده‌ها برای چندجمله‌ای‌های مختلف پرداخته و سپس توان پارامترها را تا حدی که فرابرازش اتفاق بیافتد ادامه داده، و براساس معیار RMSE و R بهترین مدل انتخاب شده است. در جدول (۳) نتایج

Table 3. Results of data modeling by polynomial regression and genetic algorithm

Row	Structure	Train		Test	
		R	RMSE	R	RMSE
1	P (1,1,1,1)	0.8725	0.1255	0.86	0.5228
2	P (1,1,1,2)	0.882	0.1181	0.883	0.1229
3	P (1,1,2,1)	0.9131	0.1048	0.9092	0.222
4	P (1,2,1,1)	0.8477	0.1983	0.8243	0.1353
5	P (2,1,1,1)	0.8729	0.1254	0.8204	0.2369
6	P (1,1,2,2)	0.9215	0.0884	0.913	0.1761
7	P (1,2,1,2)	0.8316	0.3511	0.7967	0.4247
8	P (2,1,1,2)	0.8883	0.118	0.8809	0.1426
9	P (1,2,2,1)	0.8836	0.5027	0.8736	0.1364
10	P (2,1,2,1)	0.9137	0.1049	0.9117	0.1251
11	P (2,2,1,1)	0.8535	0.2347	0.827	0.1236
12	P (1,2,2,2)	0.9338	0.1176	0.9167	0.1889
13	P (2,1,2,2)	0.8573	0.225	0.8841	0.1615
14	P (2,2,1,2)	0.8858	0.1559	0.883	0.1035
15	P (2,2,2,1)	0.8816	0.3839	0.981	0.3491
16	P (2,2,2,2)	0.9263	0.1306	0.9051	0.1259

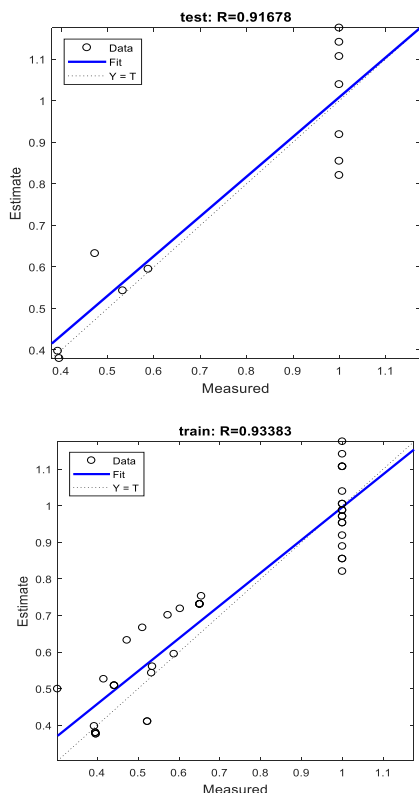


Figure 4. Regression diagram of testing and training

**مقایسه شبکه عصبی مصنوعی پیش‌خور و رگسیون چندجمله‌ای در مدل‌سازی درصد کاهش شار هد جریان**

در این بخش عملکرد روش هوشمند شبکه عصبی مصنوعی پیش‌خور با روش رگسیون چندجمله‌ای (بهینه‌شده با الگوریتم هوشمند ژنتیک) بر مقادیر درصد کاهش هد جریان مورد مقایسه قرار گرفته است تا بتوان تعیین نمود کدام روش مدل‌سازی کارایی بهتر، خطای پیش‌بینی کم‌تر و قدرت پیش‌بینی بیش‌تری دارد. به دست آوردن روش بهینه مدل‌سازی در این پژوهش از اهمیت ویژه‌ای برخوردار است، چون انجام آزمایش و محاسبه درصد کاهش هد به صورت آزمایشگاهی به‌ازای طیف وسیعی از متغیرها بسیار پرهزینه و زمان‌بر می‌باشد. بر این اساس شبکه عصبی با نورون مخفی بهینه و رگسیون چندجمله‌ای با مناسب‌ترین درجه با هم مقایسه شده‌اند. نتایج مقایسه در شکل (۵) ارائه شده است.

در جدول (۳) نتایج مدل‌سازی داده‌ها به‌وسیله رگسیون چندجمله‌ای با درجه‌های مختلف ارائه شده است. توجه شود که امکان مدل‌سازی داده‌ها با چند جمله‌ای‌های مرتبه بالاتر میسر نمی‌باشد. در مدل‌سازی این داده‌ها فرابرازش اتفاق می‌افتاد به این صورت که عملاً چندجمله‌ای داده‌های آموزشی را حفظ کرده و در نتیجه خطای داده‌های تست به صورت زیادی افزایش یافته و پاسخ‌های حاصل قابل استناد و مناسب نمی‌باشند.

با توجه به جدول (۳) مشخص است که رگسیون چندجمله‌ای به صورت نسبتاً مناسبی قادر بوده داده‌ها را مدل کند و رفتار آن‌ها را پیش‌بینی نماید. در این بین با مقایسه توابع چندجمله‌ای با درجه‌های مختلف مشخص شد که چندجمله‌ای (۱،۲،۲،۲)  $p$  به بهترین حالت توانسته رفتار داده‌ها را مدل کند. به صورتی که خطای پیش‌بینی برای داده‌های آموزشی و تست به ترتیب ۰/۱۱۷۶ و ۰/۱۸۸۹ بوده است که مقادیر بسیار کمی می‌باشند در ادامه به بررسی نمودارهای رگسیون در شکل (۴) پرداخته شده است.

با توجه به شکل (۴) که نمودار رگسیون چندجمله‌ای با درجه (۱،۲،۲،۲)  $p$  را نشان می‌دهد و مشخص است که خطاهای برازش‌شده روی داده‌ها به خط مرجع با شیب یک بسیار نزدیک می‌باشد. هم‌چنین ضریب رگسیون برای داده‌های آموزشی و تست به ترتیب ۰/۹۱۶۷ و ۰/۹۳۳۸ می‌باشد، که نشان از قدرت پیش‌بینی این روش مدل‌سازی دارد.

معادله حاصل که از روش رگسیون به دست آمد در رابطه (۹) ارائه شده است.

$$P(x_1, x_2, x_3, x_4) = \quad (9)$$

$$\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \beta_5 x_1^2 + \beta_6 x_2^2 + \beta_7 x_3^2 + \beta_8 x_4^2$$

که بردار ضرایب معادله به صورت رابطه (۱۰) می‌باشد:

$$\beta = [-1.98 \quad 1.42 \quad -1.21 \quad 1.46 \quad -0.56 \quad 2.027 \quad -0.281 \quad 0.3] \quad (10)$$

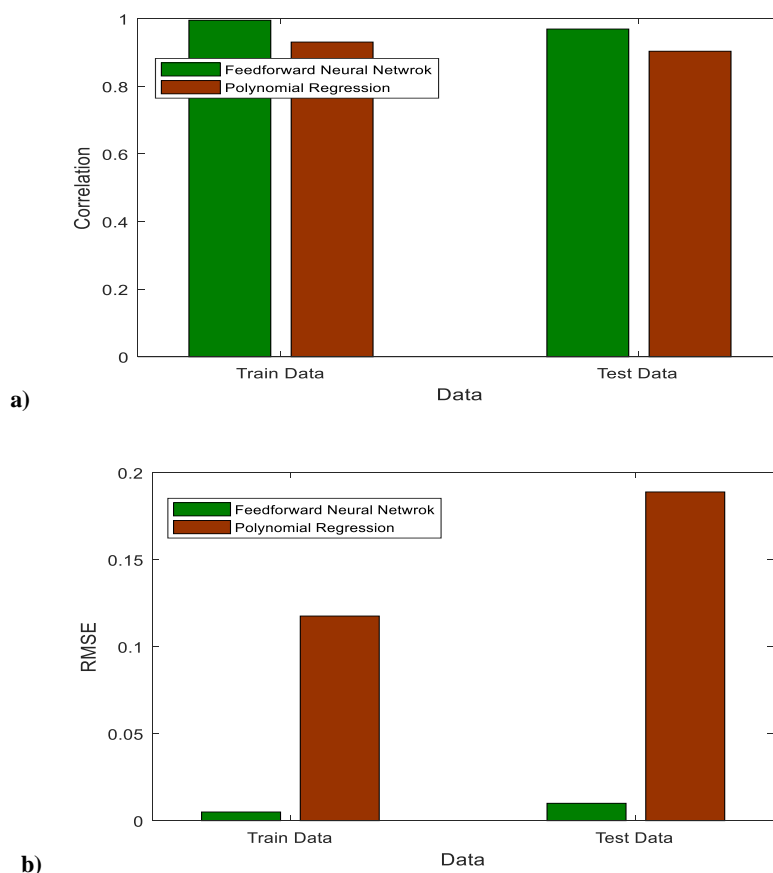


Figure 5. Comparison of artificial feed neural network and multivariable regression (a) RMSE comparison (b) regression comparison

داده‌های آموزشی دارند)، مشخص شد که عملکرد شبکه عصبی پیش‌خور بسیار بهتر بوده و کاملاً مشخص است که معیار RMSE برای این شبکه کم‌تر از نصف این مقدار برای روش رگسیون چندمتغیره بوده است.

در شکل (b-5) به مقایسه مقدار رگسیون دو روش مدل‌سازی برای داده‌های آموزشی و تست پرداخته شده است. در هر دو روش مقدار رگسیون نزدیک به یک به دست آمده، با این حال تفاوت‌هایی در مقدار رگسیون آن‌ها مشاهده می‌شود و در داده‌های آموزشی مقدار رگسیون شبکه عصبی پیش‌خور تقریباً برابر یک بوده که بسیار مطلوب است. با این حال همین مقدار برای مدل‌سازی با رگسیون چندمتغیره مقدار کم‌تری بوده است،

همان‌طور که از شکل (a-5) مشخص است عملکرد شبکه عصبی مصنوعی پیش‌خور با تعداد ۱۳ نورون مخفی عملکرد بسیار بهتری نسبت به روش کلاسیک رگسیون چندمتغیره بهینه‌شده با الگوریتم ژنتیک داشته است. به‌صورتی که دیده شد شاخص RMSE برای شبکه عصبی مصنوعی پیش‌خور در پیش‌بینی داده‌های آموزشی مقدار کمی بوده که نزدیک به صفر است. در حالی که همین معیار در رگسیون چندمتغیره برای داده‌های آموزشی به مراتب بیشتر بوده است. با بررسی عملکرد این دو روش برای داده‌های تست (داده‌هایی که روش یادگیری در طول آموزش با آن‌ها مواجه نبوده است این داده‌ها در بررسی عملکرد روش یادگیری اهمیت بسیار بیشتری نسبت به

### منابع

1. Abhari, M.N., Iranshahi, M., Ghodsian, M., & Firoozabadi, B. (2018). Experimental study of obstacle effect on sediment transport of turbidity currents. *Journal of Hydraulic Research*, 56(5), 618-629.
2. Asghari Pari, S. A., Kashefipour, S. M., & Ghomeshi, M. (2017). An experimental study to determine the obstacle height required for the control of subcritical and supercritical gravity currents. *European Journal of Environmental and Civil Engineering*, 21(9), 1080-1092.
3. Asghari Pari, S. A., Kashefipour, S., Ghomeshi, M., & Bajestan, M. S. (2010). Effects of obstacle heights on controlling turbidity currents with different concentrations and discharges. *Journal of Food, Agriculture & Environment*, 8(2), 930-935.
4. Baghalian, S., & Ghodsian, M. (2020). Experimental study on the effects of artificial bed roughness on turbidity currents over abrupt bed slope change. *International Journal of Sediment Research*, 35(3), 256-268.
5. Bishop, C. M. (2006). *Pattern recognition and machine learning*. Cambridge: Springer.
6. Davoodi, L., & Shafaei Bajestan, M. (2011). Application of submerged plates in bed sediment load control of branched catchments from trapezoidal irrigation canals. *Water and Irrigation Management*, 1(2), 59-71. (In Persian).
7. Ebrahimzadeh, A., Zarghami, M., & Nooranif, V. (2019). Hajilarchai dam overpass risk management with monte carlo simulation and system dynamics. *Water and Irrigation Management*, 5(1), 96-81. (In Persian).
8. El-Kenawy, E.S.M., Ibrahim, A., Mirjalili, S., Eid, M.M. & Hussein, S.E. (2020). Novel feature selection and voting classifier algorithms for COVID-19 classification in CT images. *IEEE Access*, 8, 179317-179335.
9. He, Z., Zhao, L., Hu, P., Yu, C., & Lin, Y.T. (2018). Investigations of dynamic behaviors of lock-exchange turbidity currents down a slope based on direct numerical simulation. *Advances in Water Resources*, 119, 164-177.
10. Jahangir, A., Esmaili, K., & Maghrebi, M.F. (2020). Experimental investigation of porosity, installation angle, thickness and second layer of permeable obstacles on density current. *International Journal of Engineering*, 33(9), 1710-1720.
11. Kochenderfer, M. J., & Wheeler, T. A. (2019). *Algorithms for optimization*. Stanford: Mit Press.

که حکایت از عملکرد بهتر شبکه عصبی مصنوعی پیش‌خور دارد. مقایسه این مقادیر در داده‌های تست نیز از عملکرد بهتر شبکه عصبی مصنوعی پیش‌خور حکایت دارد. همان‌طور که مشخص است مقدار رگسیون شبکه عصبی به صورت مطلوبی بیش‌تر از این مقدار برای رگسیون چندمتغیره است که از عملکرد بهتر این شبکه و قدرت پیش‌بینی بالاتر آن برای داده‌های جدید حکایت دارد.

### نتیجه‌گیری

این پژوهش از معدود مطالعاتی می‌باشد که به مدل‌سازی مقادیر درصد کاهش شار هد داده‌های آزمایشگاهی پرداخته است. بر این اساس، اثر متغیرهایی هم‌چون دبی، غلظت جریان ورودی، شیب و ارتفاع موانع نفوذپذیر (شن با قطر ۰/۵ سانتی‌متر) بر هد جریان غلیظ به‌طور آزمایشگاهی مورد مطالعه قرار گرفته و شار هد جریان غلیظ محاسبه شده و براساس نتایج حاصله درصد کاهش هد جریان محاسبه شده است. سپس با استفاده از داده‌های آزمایشگاهی به مدل‌سازی جریان غلیظ با استفاده از شبکه عصبی مصنوعی پیش‌خور و روش کلاسیک رگسیون چندمتغیره پرداخته شده است. برای تعیین پارامترهای مورد نظر در روش رگسیون چندمتغیره، از روش الگوریتم هوشمند ژنتیک استفاده شده است. با مقایسه انجام‌شده، مشخص شد که روش مدل‌سازی با شبکه عصبی مصنوعی پیش‌خور برای داده‌های آموزشی و تست عملکرد بسیار بهتری نسبت به روش رگسیون چندمتغیره دارد. به‌طوری‌که معیار RMSE مربوط به شبکه عصبی بسیار کم‌تر از مقدار این معیار برای روش رگسیون چندمتغیره بوده و مقدار رگسیون آن به یک نزدیک می‌باشد.

### تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

12. Kooti, F., & Kashefipour, S. M. (2018). Sensitivity of the head velocity in density currents to the various initial conditions. *ISH Journal of Hydraulic Engineering*, 24(1), 74-80.
13. Maier, H. R., & Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling and software* 15(1), 101-24.
14. Nasrollahpour, R., & Ghomeshi, M. (2012). Effect of roughness geometry on characteristics of density currents head. *Indian Journal of Science and Technology*, 5(12), 3783-3787.
15. Oshaghi, M. R., Afshin, H., & Firoozabadi, B. (2013). Experimental investigation of the effect of obstacles on the behavior of turbidity currents. *Canadian Journal of Civil Engineering*, 40(4), 343-352.
16. Pirnia, S. P., Wali Samani, J., & monaem, M. J. (2012). Spatial and temporal study of salinity infiltration in tidal river using COHERENS model: a case study of Bahmanshir river. *Journal of Water and Irrigation Management*, 3(1), 13-27. (In Persian).
17. Rojas, R (2013). *Neural networks: a systematic introduction*. Berlin: Springer Science & Business Media.
18. Rzadkiewicz, S. A., Mariotti, C., & Heinrich, P. (1997). Numerical simulation of submarine landslides and their hydraulic effects. *Journal of Waterway, Port, Coastal, Ocean Eng*, 123(4), 149-157.
19. Wilson, R.I., Friedrich, H., & Stevens, C. (2018). Flow structure of unconfined turbidity currents interacting with an obstacle. *Environmental Fluid Mechanics*, 18(6), 1571-1594.
20. Xu, J., Li, Y., Xuan, G., Melville, B.W., & Macky, G.H. (2020). Numerical simulation of turbidity current in approach channels with a closed end. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 146(5), p.04020036.