

## استفاده از شبکه عصبی مصنوعی در پیش‌بینی خصوصیات پرش هیدرولیکی در مقاطع مستطیلی واگرا با شیب معکوس

زهرا شجاعیان<sup>1</sup>، علی حسین زاده دلیر<sup>2</sup>، مهدی دریائی<sup>3</sup>، سید محمود کاشفی پور<sup>4</sup> و داود فرسادی زاده<sup>5</sup>

تاریخ دریافت: 89/06/16 تاریخ پذیرش: 90/01/22

<sup>1</sup> دانش‌آموخته کارشناسی ارشد سازه‌های آبی دانشکده کشاورزی، دانشگاه تبریز

<sup>2</sup> استاد گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

<sup>3</sup> دانشجوی دکتری گروه سازه‌های آبی، دانشکده علوم آب، دانشگاه شهیدچمران اهواز

<sup>4</sup> استاد گروه سازه‌های آبی، دانشکده علوم آب، دانشگاه شهیدچمران اهواز

<sup>5</sup> دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

\*مسئول مکاتبه E-mail: [z.shojaeian64@gmail.com](mailto:z.shojaeian64@gmail.com)

### چکیده

حوضچه آرامش از مهمترین سازه‌های مستهلک کننده انرژی جریان در پایین دست سازه‌های آبی که جریان در آن‌ها حالت فوق بحرانی دارد، می‌باشد. نظر به اهمیت این سازه و همچنین پرهزینه بودن احداث آن، ضرورت مدل کردن قبل از ساخت کاملاً محسوس می‌باشد. همچنین مدل کردن این سازه در شرایط آزمایشگاهی برای حالات مختلف پرهزینه بوده و نیاز به زمان زیادی دارد. لذا از گذشته سعی بر این بوده که خصوصیات پرش هیدرولیکی از قبیل طول پرش، افت انرژی پرش، نسبت اعماق مزدوج و غیره را به پارامترهای هیدرولیکی و مشخصات سطح مقطع جریان مانند عدد فرود، زاویه واگرایی، شیب کف، شیب دیواره‌های جانبی و غیره ارتباط دهند. به همین جهت مطالعات زیادی در این خصوص صورت پذیرفته است. در این تحقیق خصوصیات پرش هیدرولیکی شامل نسبت اعماق مزدوج، طول پرش و افت انرژی پرش در مقاطع مستطیلی واگرا با شیب معکوس به صورت توابعی از پارامترهای عدد فرود اولیه، شیب کف و زاویه واگرایی با استفاده از شبکه عصبی مصنوعی مدل گردیدند و میزان دقت مدل در برآورد هر یک از این مشخصات هیدرولیکی مورد بررسی قرار گرفت. نتایج حاصل نشان داد که مدل قادر به پیش‌بینی این خصوصیات با دقت بسیار بالا می‌باشد. همچنین میزان اهمیت هر یک از پارامترهای مورد استفاده در پیش‌بینی خصوصیات مورد مطالعه پرش هیدرولیکی در این تحقیق توسط مدل تعیین، که با استفاده از نتایج حاصل و نرم‌افزار Data Fit برای هر یک از این خصوصیات یک رابطه بر حسب پارامترهای موجود استخراج گردید که این روابط نیز از دقت بالایی در پیش‌بینی خصوصیات مورد نظر بهره‌مند می‌باشند.

واژه‌های کلیدی: پرش هیدرولیکی، شبکه عصبی مصنوعی، شیب معکوس، مقاطع واگرا.

## Application of Artificial Neural Network to Estimate Hydraulic Jump Characteristics in Divergent Rectangular Sections on Inverse Slope

Z Shojaeian<sup>1</sup>, A Hosseinzadeh dalir<sup>2</sup>, M Daryae<sup>3</sup>,  
SM Kashefipour<sup>4</sup>, D Farsadizadeh<sup>5</sup>

Received: 7 September 2010, Accepted : 11 April 2011

<sup>1</sup>- Former MSc Student, Dept. of Hydraulic Structures, Univ. of Tabriz, Iran.

<sup>2</sup>- Prof, Dept. of Water Engin, University of Tabriz, Tabriz, Iran

<sup>3</sup>- PhD Student, Dept. of Hydraulic Structures, Univ. of Shahid Chamran, Ahvaz, Iran.

<sup>4</sup>- Prof, Dept. of Hydraulic Structures, Univ. of Shahid Chamran, Ahvaz, Iran.

<sup>5</sup>- Assoc. Prof, Dept. of Water Engin, University of Tabriz, Tabriz, Iran

\*Corresponding author: E-mail: [z.shojaeian64@gmail.com](mailto:z.shojaeian64@gmail.com)

### Abstract

Stilling basins are the most important energy dissipating structures placed at the end of spillways and any source of supercritical flow to control the hydraulic jump. Due to its importance and high construction costs, modeling of stilling basins are necessary prior to construction. Physical modeling of stilling basins are time consuming and costly, therefore attempts have been made so far to relate the hydraulic jump characteristics such as the jump length, energy loss, etc., to some hydraulic parameters like Froude number, divergence and the bed slope. In this study hydraulic jump characteristics such as the jump length and energy loss in divergent rectangular sections on inverse slopes were modeled as functions of Froude number, angle of divergence and inverse bed slope, using Artificial Neural Network. The accuracy of the model for estimating different hydraulic parameters was also verified. The results indicated that the model was capable of predicting hydraulic parameters with high accuracy. Furthermore, the weight of each parameter for estimating hydraulic characteristics was determined. Data Fit software was used to produce relationships between the parameters. The relationships found to be accurate enough to predict the hydraulic jump characteristics.

**Key words:** Artificial Neural Networks, Divergent channel sections, Hydraulic jump, Inverse slope.

دست سازه‌هایی نظیر سرریزها، تندآب‌ها و دریچه‌ها،  
پیش‌بینی خصوصیات این پدیده با توجه به ابعاد طراحی  
شده سازه ضرورت می‌یابد. یکی از روش‌های تعیین  
خصوصیات پرش هیدرولیکی با توجه به مشخصات

مقدمه

نظر به اهمیت طراحی و تعیین دقیق ابعاد حوضچه  
آرامش در کنترل جریان فوق بحرانی و استهلاك انرژی  
ناشی از آن با ایجاد پدیده پرش هیدرولیکی در پایین

ابعاد و طراحی حوضچه آرامش، مدل کردن طرح موردنظر در آزمایشگاه می‌باشد. با توجه به این موضوع که استفاده از مدل آزمایشگاهی مستلزم صرف وقت و هزینه بالا می‌باشد و از طرف دیگر در بعضی موارد به علت شرایط محدود در آزمایشگاه نمی‌توان برخی از مدل‌ها را اجرا کرد، در بسیاری از موارد در مطالعات اولیه طرح از روابط تجربی موجود استفاده می‌شود. صرف‌نظر از پیچیدگی این روابط مسئله‌ای که باید در استفاده از آنها مدنظر قرار گیرد، این است که هر کدام از روابط تجربی ممکن است با در نظر گرفتن یک سری فرضیات در آزمایشگاه بدست آمده باشد و در صورتی که این فرضیات ضمن استفاده از روابط موجود در نظر گرفته نشود، ممکن است صحت تخمین‌هایی که زده می‌شود در حاله‌ای از ابهام قرار گیرد. در طراحی حوضچه‌های آرامش، عمق ثانویه و طول پرش هیدرولیکی پارامترهای مهمی می‌باشند که با استفاده از آنها می‌توان رقوم کف، عمق و طول حوضچه را طراحی کرد. در مورد پرش هیدرولیکی در مقاطع مستطیلی مقدار عمق ثانویه با استفاده از روابط تئوری حاصل از قوانین پیوستگی و مومنتم قابل محاسبه می‌باشد. همچنین طول پرش و میزان استهلاک انرژی ناشی از آن را نیز می‌توان با استفاده از معادلات بدست آمده از نتایج تجربی تعیین کرد. ولی در مورد مقاطع غیر مستطیلی به خصوص مقاطع واگرا پیش‌بینی خصوصیات پرش هیدرولیکی تنها با در نظر گرفتن فرضیات ساده‌کننده امکان‌پذیر خواهد بود (امید و اسمعیلی ورکی ۱۳۸۴). از سال 1820 که پرش هیدرولیکی توسط بیدون مورد بررسی قرار گرفت، مطالعات زیادی تا کنون درباره این پدیده در حالات مختلف صورت پذیرفته است. کلوسیوس و احمد (1961) با فرض تغییرات خطی بین عمق اولیه و ثانویه پرش در مقاطع مستطیلی واگرا و با استفاده از قوانین پیوستگی، انرژی و مومنتم، روابطی برای نسبت عمق ثانویه به عمق اولیه و همچنین افت نسبی انرژی ارائه کردند. اربهابیراما و ابلا (1971) خصوصیات

پرش هیدرولیکی با فرض شکل ربع بیضی برای نیمرخ پرش را مورد بررسی قرار داده و روابطی برای نسبت عمق ثانویه به عمق اولیه و افت نسبی انرژی ارائه کردند. خلیفه و مک کروکودال (1979) با شعاعی در نظر گرفتن خطوط جریان روابطی برای نسبت عمق ثانویه به عمق اولیه و افت نسبی انرژی در کانال‌های مستطیلی واگرا ارائه کردند. بختیاری (1387) پارامترهای پرش هیدرولیکی در مقاطع واگرا را مورد بررسی قرار داد و تاثیر افزایش زاویه واگرایی را بر روی پارامترهای پرش هیدرولیکی مورد بررسی قرار داد. در مورد پرش بر روی حوضچه‌های با شیب معکوس در ابتدا توسط رز، واستیونس (1944) مورد مطالعه قرار گرفت و سپس توسط خدر و راجاگوپال (1972)، ابریشمی و صانعی (1994) ادامه یافت که به ارائه روابط تجربی منتهی شد. پوزی و هسینگ<sup>1</sup> (1938) تاثیر شیب جانبی را بر طول پرش در حوضچه دوزنقه‌ای بررسی کردند.

ردی (2003) از ابزارهای GIS و شبکه عصبی مصنوعی برای پیش‌بینی رواناب در هندوستان استفاده کرد. کاشفی‌پور و همکاران (2005) غلظت کالیفرم را در آبهای ساحلی دریایی واقع در غرب اسکاتلند به کمک شبکه عصبی مصنوعی مدل نمودند. سارانگی و بیهاتا چاریا<sup>2</sup> (2005) در حوزه (Banha) هندوستان با استفاده از مدل‌های شبکه عصبی مصنوعی و مدل‌های رگرسیون دبی رسوب را برای هر دو مدل برآورد کرده و نتیجه گرفتند مدل شبکه عصبی مصنوعی از دقت بسیار بالایی برخوردار است. طارقیان و کاشفی‌پور (2007) دبی ورودی به سد دز را با استفاده از سیستم فازی و عصبی مورد بررسی قرار دادند. حسین زاده دلیر و همکاران (1388) تاثیر نوسانات سطح آب و دبی جریان بر میزان بار معلق را با استفاده از شبکه عصبی مصنوعی مطالعه کرده و اعلام داشتند که با افزایش دبی جریان نتایج شبکه عصبی از کیفیت بهتری در پیش‌بینی

<sup>1</sup> Posey and Hsing

<sup>2</sup> Sarangiand Bhattacharya

میزان بار معلق بر خوردار می‌باشد در حالی که نوسانات سطح آب چنین روندی را نشان نمی‌دهد. امید و اسمعیلی ورکی (1384) با استفاده از شبکه عصبی مصنوعی اقدام به مدل نمودن پرش هیدرولیکی در مقاطع نوزنقه‌ای واگرا نمودند که نتایج حاصل بیانگر دقت بسیار بالای مدل در این مورد می‌باشد.

با توجه به مطالب فوق‌الذکر کاربرد مدل‌های ریاضی ساده که قادر به حل دقیق مسائل مربوط به پرش هیدرولیکی در شرایط مختلف باشند، کمک موثری به طراحی هرچه دقیق‌تر حوضچه‌های آرامش در حالات مختلف خواهد کرد. در مقاله حاضر سعی بر آن است که با استفاده از مدل شبکه عصبی مصنوعی که در حال حاضر کاربرد وسیعی در علوم مختلف از جمله مهندسی هیدرولیک دارد، مدلی ارائه گردد که با استفاده از آن خصوصیات پرش هیدرولیکی در مقاطع مستطیلی واگرا با شیب معکوس با دقت بسیار بالایی پیش‌بینی شود.

## مواد و روش‌ها

### شبکه عصبی مصنوعی

شبکه عصبی مصنوعی<sup>1</sup> یک مدل محاسباتی الهام گرفته از ساختمان و فعالیت سلول‌های مغز انسان می‌باشد که قادر است با پردازش روی داده‌های تجربی، قانون یا دانش نهفته در ورای داده‌ها را به ساختار شبکه منتقل کند. مغز انسان به عنوان یک سیستم پردازش اطلاعات با ساختار موازی از تعداد بسیار زیادی نرون تشکیل شده که این نرون‌ها ساده‌ترین واحد ساختاری سیستم‌های عصبی هستند. اجتماعی از این نرون‌ها هستند که اطلاعات و پیام‌ها را از یک قسمت بدن به قسمت دیگر منتقل می‌کنند (منهاج 1379). ایده استفاده از روش شبکه‌های عصبی مصنوعی خیلی تازه نیست. ولی استفاده کاربردی از آن تقریباً از سال 1946 شروع شد

و فردی بنام هو<sup>2</sup> در تز خود برای پیش‌بینی وضع هوا از آن استفاده نمود. ولی به دلیل محاسبات و عدم استفاده از کامپیوتر موفقیت چندانی نداشت. شبکه عصبی مصنوعی متشکل از مجموعه‌ای از نرون‌ها با ارتباطات داخلی بین یکدیگر می‌باشد که قادر است بر اساس اطلاعات و داده‌های ورودی، جواب‌های خروجی را تهیه نماید. شبکه‌های عصبی معمولاً به صورت لایه لایه و منظم ایجاد می‌گردند. اولین لایه که اطلاعات و داده‌های ورودی به آن وارد می‌گردند لایه ورودی است. لایه‌های میانی لایه‌های مخفی و آخرین لایه که جواب‌های خروجی از مدل را فراهم می‌نماید لایه خروجی می‌باشند (منهاج 1379). ساده‌ترین و معمول‌ترین نوع شبکه عصبی که در بسیاری از علوم مختلف از جمله تحقیق حاضر استفاده می‌گردد، شبکه‌های عصبی چندلایه پیشخور<sup>3</sup> همراه با ناظر که از روش پس‌انتشار خطا برای آموزش کمک می‌گیرد، می‌باشد. در این شبکه تعداد نرون‌های لایه ورودی برابر با تعداد عناصر بردار ورودی و تعداد نرون‌های لایه خروجی برابر با تعداد عناصر بردار خروجی می‌باشد. آنالیز دقیق و واقعی برای پیدا کردن تعداد نرون‌های لایه میانی در کل بسیار پیچیده است. اما می‌توان گفت که تعداد نرون‌های لایه میانی تابعی از تعداد عناصر برداری ورودی و همچنین حداکثر تعداد نواحی از فضای ورودی که به طور خطی از هم قابل تفکیک می‌باشد. از این رو تعداد نرون‌های لایه مخفی عموماً بطور تجربی بدست می‌آید. هر نرون توسط خروجی‌اش به نرون‌های لایه بعد متصل است، ولی با نرون‌های لایه خودش ارتباط ندارد. خروجی هر نرون توسط رابطه 1 تعریف می‌شود: (منهاج 1379).

$$a = f\left(\sum_{i=1}^n p_i w_{ji} + b_j\right) \quad [1]$$

که در این رابطه:

<sup>2</sup> Hu

<sup>3</sup> multi-layer perceptron

<sup>1</sup> Artificial neural network

## روش تحقیق

جهت آموزش شبکه نیاز به تعدادی الگوی آموزش دهنده مناسب می‌باشد. بدین منظور از نتایج آزمایشات انجام شده بر روی پدیده پرش هیدرولیکی که در مقاطع مستطیلی و اگر با شیب معکوس در آزمایشگاه‌های هیدرولیک دانشگاه تبریز و دانشگاه شهیدچمران اهواز انجام شده بود استفاده شد و در کل تعداد 160 سری اطلاعات جهت مدل‌سازی تهیه گردید (شجاعیان 1389). این اطلاعات شامل عمق اولیه، عمق ثانویه، افت انرژی و طول پرش برای زوایای و اگرایی 0 تا 25 درجه، شیب معکوس 0 تا 6/7 درصد و عدد فرود 2/6 تا 6 می‌باشد.

همانگونه که قبلاً اشاره شد، هدف از این تحقیق مدل کردن خصوصیات پرش هیدرولیکی شامل نسبت اعماق مزدوج، نسبت طول پرش به عمق اولیه، نسبت افت انرژی پرش به انرژی اولیه و نسبت طول پرش به عمق ثانویه در مقاطع مستطیلی و اگر با شیب معکوس به صورت تابعی از پارامترهای عدد فرود اولیه، شیب کف و زاویه و اگرایی با استفاده از شبکه عصبی مصنوعی می‌باشد. بنابراین می‌توان توابعی به صورت زیر در نظر گرفت:

$$\frac{y_2}{y_1} = f_1(Fr_1, a, q) \quad [3]$$

$$\frac{L_j}{y_1} = f_2(Fr_1, a, q) \quad [4]$$

$$\frac{L_j}{y_2} = f_3(Fr_1, a, q) \quad [5]$$

$$\frac{E_j}{E_1} = f_4(Fr_1, a, q) \quad [6]$$

که در این معادلات  $y_1$  عمق اولیه پرش،  $y_2$  عمق ثانویه پرش،  $L_j$  طول پرش،  $Fr_1$  عدد فرود اولیه،  $E_1$  افت انرژی قبل از پرش،  $E_j$  افت انرژی پرش،  $a$  زاویه و اگرایی و  $q$  شیب معکوس کف می‌باشد. باید توجه داشت که به منظور استفاده از مدل تهیه شده برای تمامی سیستم‌های اندازه‌گیری، مشخصات هیدرولیکی مورد مطالعه به صورت بدون بعد در نظر گرفته شده است. با توجه به

$w_{j,i}$  = مقدار وزن اتصال بین نرون  $j$  ام لایه مذکور با نرون  $i$  ام لایه قبل است که بیانگر اهمیت ارتباط بین دو نرون در دو لایه متوالی می‌باشد،  $b_j$  = وزن مربوط به بایاس<sup>1</sup> برای نرون  $j$  ام،  $p_i$  = مقدار خروجی از نرون  $i$  ام لایه قبل،  $a$  = مقدار خروجی از نرون  $j$  ام و  $f$  = تابع آستانه نرون  $j$  ام.

توابع زیادی هستند که در انتقال اعداد از لایه قبل به لایه بعد ممکن است مورد استفاده قرار گیرند. از جمله می‌توان توابع زیگموید، گوس، تانژانت هیپربولیک و سکانت هیپربولیک را نام برد. ولی تابع زیگموید بیشترین استفاده را در مسائل مهندسی دارد. این تابع به صورت زیر می‌باشد: (منهاج 1379).

$$f(z) = \frac{1}{1 + \exp(-z)} \quad [2]$$

در روش شبکه‌های عصبی مصنوعی غالباً مدل در دو مرحله تهیه می‌گردد. مرحله اول آموزش شبکه است که بر اساس تعدادی از داده‌های اندازه‌گیری شده (حدود 70 درصد کل داده‌ها) انجام می‌پذیرد. در مرحله دوم مدل با حدود 20 تا 30 درصد مقادیر اندازه‌گیری شده صحت‌سنجی می‌گردد. در مدل‌سازی به کمک شبکه‌های عصبی مصنوعی بسته به متغیرهای ورودی و ارتباط آنها با پارامتر موردنظر که مدل می‌گردد، حدود 10 درصد اطلاعات را برای تست و ارزیابی مدل و برآورد نقاط بحرانی مانند نقطه عطف و یا نقاط حداکثر و حداقل یک منحنی استفاده می‌گردند. البته این داده‌ها نپایستی در مراحل آموزش و صحت‌سنجی استفاده شده باشند. امروزه این روش کاربرد وسیعی در علوم مختلف دارد. در مهندسی آب و هیدرولیک نیز از این روش در سال‌های اخیر بسیار زیاد استفاده شده است که از آن جمله می‌توان به موارد زیر اشاره کرد.

<sup>1</sup> Bias

### نتایج و بحث

در این تحقیق به منظور تعیین میزان دقت و تجزیه و تحلیل مشخصات مورد نظر پرش هیدرولیکی در آزمایشگاه و برآورد شده توسط مدل از روش‌های آماری که در زیر ارائه شده‌اند استفاده گردید:

1-  $R^2$  و  $a$  که به ترتیب عبارتند از مجذور ضریب

همبستگی و شیب خط رگرسیون ( $a = \frac{C_m}{C_p}$ ). دقت پیش-

بینی هر رابطه به پارامترهای فوق بستگی دارد. بدین صورت که هرچه  $R^2$  و  $a$  به یک نزدیکتر باشند آن رابطه بهتر می‌تواند مقادیر اندیس فشردگی را تخمین بزند.

2- درصد خطای نسبی ( $E\%$ ) که بصورت زیر تعریف می‌شود:

$$\% E = \frac{\sum_{i=1}^N |C_{mi} - C_{pi}|}{\sum_{i=1}^N C_{mi}} \times 100 \quad [7]$$


3- جذر میانگین مربعات خطا (RMSE) که به صورت زیر تعریف شده است:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (C_{mi} - C_{pi})^2}{N}} \quad [8]$$

که در این روابط،  $N$  = تعداد داده‌ها،  $C_m$  = مقادیر مشخصه هیدرولیکی اندازه‌گیری شده در آزمایشگاه و  $C_p$  = مقادیر مشخصه هیدرولیکی برآورد شده توسط مدل شبکه عصبی مصنوعی می‌باشد.

نتایج آماری حاصل از مراحل آموزش، صحت‌سنجی و تست برای اطلاعات اندازه‌گیری شده در آزمایشگاه و محاسبه شده توسط مدل شبکه عصبی مصنوعی برای مشخصات هیدرولیکی مورد نظر بررسی و میانگین نتایج حاصل از این 3 مرحله برای هر یک از آنها در جدول 1 آمده است.

متغیرهای مستقل و وابسته در معادلات فوق، شبکه عصبی مصنوعی مورد استفاده برای هر یک از این معادلات باید دارای سه نرون در لایه ورودی و یک نرون در لایه خروجی باشد. در شکل 1 نمای کلی شبکه عصبی مورد استفاده نشان داده شده است.



شکل 1- ساختار کلی شبکه عصبی مورد استفاده.

از 160 سری اطلاعات اندازه‌گیری شده تعداد 110 سری برای آموزش، 30 سری برای صحت‌سنجی و 20 سری اطلاعات برای تست نهایی مدل برای هر مشخصه استفاده گردید. برای رسیدن به کمترین میزان خطا، پس از تغییر در تعداد گره‌های لایه پنهان و تکرار حین آموزش شبکه، این نتیجه حاصل شد که شبکه مورد استفاده با تعداد 3 گره در لایه پنهان و تعداد تکرار تا 65000 کمترین خطا را در برآورد هر یک از مشخصات هیدرولیکی مورد نظر دارد. تابع انتقال برای اجرای مدل، تابع زیگموید انتخاب گردید. همچنین با استفاده از سری اطلاعات موجود و نتایج حاصل از مدل در تعیین میزان اهمیت هر پارامتر در برآورد مشخصه هیدرولیکی مورد نظر اقدام به استخراج روابطی برای مشخصات هیدرولیکی مورد نظر پرش هیدرولیکی در این تحقیق به صورت تابعی از پارامترهای موجود با استفاده از نرم-افزار دیتا فیت<sup>1</sup> گردید.

<sup>1</sup> Data Fit

جدول 1- مقایسه آماری مدل شبکه عصبی مصنوعی برای مشخصات پرش هیدرولیکی

RMSE	%E	a	R <sup>2</sup>	مشخصه هیدرولیکی
0/02	4/29	1/01	0/97	$\frac{y_2}{y_1}$
0/06	8/58	1/01	0/90	$\frac{L_j}{y_1}$
0/04	4/94	1/03	0/96	$\frac{E_j}{E_1}$
0/07	10/78	0/97	0/89	$\frac{L_j}{y_2}$


این جدول بر حسب درصد هستند. با توجه به جدول 2 نیز مشاهده می‌شود که مدل در پیش‌بینی مشخصه هیدرولیکی  $\frac{y_2}{y_1}$  در حد 98 درصد مقادیر پیش‌بینی شده در بازه موردنظر بالاترین دقت را در برآورد مشخصات هیدرولیکی مورد مطالعه در این تحقیق دارا می‌باشد. هم چنین مدل در پیش‌بینی مشخصه هیدرولیکی  $\frac{L_j}{y_2}$  در حد 78 درصد مقادیر پیش‌بینی شده در بازه مورد نظر کمترین دقت را در این بین دارا می‌باشد. در مجموع می‌توان این‌گونه بیان کرد که مدل شبکه عصبی مصنوعی، قادر به پیش‌بینی مشخصات هیدرولیکی موردنظر با دقت بسیار بالا می‌باشد

در شکل‌های 2 تا 5 مقادیر مشخصات هیدرولیکی مورد نظر اندازه‌گیری شده در آزمایشگاه و برآورد شده توسط مدل در مرحله تست مدل نشان داده شده است. با توجه به این شکل‌ها نیز همانطوریکه ملاحظه می‌گردد همبستگی بسیار خوبی بین مقادیر اندازه‌گیری شده در آزمایشگاه و محاسبه شده توسط مدل وجود دارد.

با توجه به جدول مشاهده می‌گردد که مدل در برآورد مشخصه هیدرولیکی  $\frac{y_2}{y_1}$  دارای دقت بالاتر و خطای کمتری نسبت به سایر مشخصات هیدرولیکی می‌باشد. البته دقت مدل در برآورد مشخصه هیدرولیکی  $\frac{E_j}{E_1}$  نیز نسبتاً خوب می‌باشد. از طرف دیگر مشاهده می‌شود که مدل مشخصات هیدرولیکی  $\frac{L_j}{y_1}$  و  $\frac{L_j}{y_2}$  را با دقتی کمتر و مقدار خطای بالاتر نسبت به دو مشخصه دیگر برآورد می‌کند. دلیل این امر را می‌توان خطای قرائت مربوط به طول پرش ضمن انجام آزمایشات به دلیل آشفتگی موجود در جریان دانست. در جدول 2 از روش دیگری برای تعیین میزان دقت مدل در پیش‌بینی مشخصات هیدرولیکی مورد نظر و همچنین مقایسه دقت مدل در برآورد هر یک از این مشخصات استفاده گردیده است. که در آن  $C_p$  مشخصات هیدرولیکی محاسبه شده و  $C_m$  مشخصات هیدرولیکی اندازه‌گیری شده می‌باشد. در این جدول مشخصات هیدرولیکی موردنظر در محدوده تغییرات  $C = \pm 20\%$  ذکر گردیده تا بتوان در مورد نحوه پیش‌بینی مدل بهتر قضاوت نمود. اعداد داخل


جدول 2- درصد پیش‌بینی مشخصات هیدرولیکی مورد نظر توسط مدل شبکه عصبی مصنوعی در محدوده خطای  $\pm 20\%$

مشخصه هیدرولیکی			مشخصه
$C_p/C_m > 1.2$	$0.8 \leq C_p/C_m \leq 1.2$	$C_p/C_m < 0.8$	
6	89	5	$\frac{E_j}{E_1}$
13	84	3	$\frac{L_j}{y_1}$
12	78	10	$\frac{L_j}{y_2}$
2	98	0	$\frac{y_2}{y_1}$



شکل 3- مقایسه مشخصه هیدرولیکی  $\frac{L_j}{y_2}$  اندازه‌گیری و

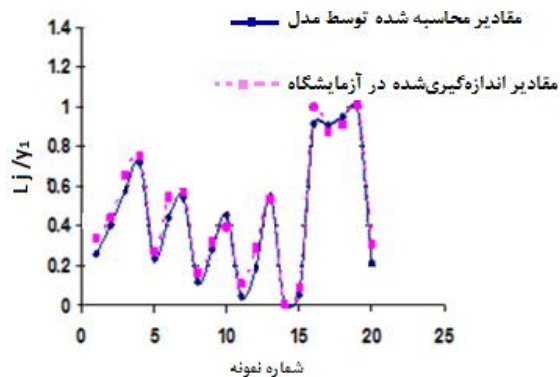
پیش‌بینی شده در روال تست شبکه




شکل 2- مقایسه مشخصه هیدرولیکی  $\frac{y_2}{y_1}$  اندازه‌گیری و

پیش‌بینی شده در مرحله تست شبکه





شکل 5- مقایسه مشخصه هیدرولیکی  $\frac{L_j}{y_1}$  اندازه‌گیری و پیش‌بینی شده در مرحله تست شبکه



شکل 4- مقایسه مشخصه هیدرولیکی  $\frac{E_j}{E_1}$  اندازه‌گیری و پیش‌بینی شده در مرحله تست شبکه

کف) با مقادیر درصد اهمیت حدود 10 و 12 درصد می‌باشد.

پس از تعیین میزان اهمیت پارمترهای مورد نظر توسط مدل شبکه عصبی مصنوعی در برآورد مشخصات هیدرولیکی مورد مطالعه و همچنین با استفاده از سری اطلاعات جمع‌آوری شده، اقدام به استخراج روابطی جهت تعیین مشخصات هیدرولیکی مورد مطالعه توسط نرم‌افزار دیتا فیت گردید. بدین صورت که ابتدا نرم‌افزار برای هر یک از مشخصات هیدرولیکی تابعی را که قادر به پیش‌بینی این مشخصات با بالاترین دقت می‌باشد را تعیین نمود. این توابع برای مشخصات هیدرولیکی  $\frac{y_2}{y_1}$  و  $\frac{L_j}{y_1}$ ، تابع نمایی و برای مشخصات هیدرولیکی  $\frac{E_j}{E_1}$  و  $\frac{L_j}{y_2}$ ، تابع خطی به صورت زیر می‌باشند

$$\left(\frac{y_2}{y_1}, \frac{L_j}{y_1}\right) = e^{((a \times x) + (b \times q) + (c \times Fr_1) + d)} \quad [9]$$

$$\left(\frac{E_j}{E_1}, \frac{L_j}{y_2}\right) = (a \times x) + (b \times q) + (c \times Fr_1) + d \quad [10]$$

پس از اجرای مدل شبکه عصبی، میزان اهمیت پارمترهای دخیل در برآورد هر یک از مشخصات هیدرولیکی مورد مطالعه، بررسی گردید. نتایج اهمیت هر پارامتر بر حسب درصد مشارکت در ایجاد مدل شبکه عصبی مصنوعی در جدول 3 آمده است. همانطوری‌که در این جدول مشاهده می‌شود در برآورد مشخصات هیدرولیکی  $\frac{y_2}{y_1}$ ،  $\frac{E_j}{E_1}$  و  $\frac{L_j}{y_1}$  بیشترین مشارکت و اهمیت را پارامتر  $Fr_1$  (عدد فرود اولیه) با مقادیری حدود 80 درصد، 50 درصد و 45 درصد و برای مشخصه هیدرولیکی  $\frac{L_j}{y_2}$ ، پارامتر  $a$  (زاویه واگرایی) با میزان مشارکت حدود 57 درصد دارا می‌باشد. همچنین کمترین درصد اهمیت را پارامتر  $q$  با مقادیری حدود 6 درصد، 21 درصد، 10 درصد و 12 درصد برای مشخصات هیدرولیکی  $\frac{L_j}{y_2}$ ،  $\frac{E_j}{E_1}$ ،  $\frac{y_2}{y_1}$  و  $\frac{L_j}{y_1}$  را دارا می‌باشد. باید توجه داشت که در پیش‌بینی مشخصات هیدرولیکی  $\frac{L_j}{y_1}$  و  $\frac{L_j}{y_2}$  توسط مدل، میزان اهمیت پارامتر  $a$  (زاویه واگرایی) با دارا بودن مقادیری حدود 43 و 57 درصد برای این مشخصات به مراتب بیشتر از پارامتر  $q$  (شیب معکوس

جدول 3- درصد میزان اهمیت پارامترهای موثر مورد بررسی در برآورد مشخصات هیدرولیکی

$Fr_1$	$q$	$a$	مشخصه هیدرولیکی
79/17	6/21	14/62	$\frac{y_2}{y_1}$
49/05	21/12	29/83	$\frac{E_j}{E_1}$
45/45	10/78	43/77	$\frac{L_j}{y_1}$
29/58	12/88	57/54	$\frac{L_j}{y_2}$

:

با توجه به ضرایب ثابت موجود در روابط فوق مشاهده می‌شود که نرم‌افزار دیتا فیت بر اساس درصد اهمیت پارامترهای موثر در پیش‌بینی مشخصات هیدرولیکی مورد نظر که توسط شبکه عصبی مصنوعی تعیین گردیده بود، به پارامترهای موثرتر ضریب بالاتر و به پارامترهایی که تاثیر کمتری را در پیش‌بینی مشخصات هیدرولیکی مورد نظر دارا بودند، ضریب پایین‌تری را اختصاص داده است. جهت تعیین دقت این روابط در برآورد مشخصات هیدرولیکی مورد مطالعه، نتایج حاصل از تحلیل آماری این روابط در جدول 4 ارائه شده است. با توجه به جدول 4 مشاهده می‌شود که روابط استخراج شده قادر به برآورد مشخصات هیدرولیکی مورد نظر با دقت قابل قبولی می‌باشند.

a و b و c و d ضرایب ثابتی هستند که با انجام آزمون و خطا توسط نرم‌افزار برای هر یک از مشخصات هیدرولیکی تعیین می‌شوند. پس از تعیین این ضرایب روابط نهایی برای هر یک از این مشخصات به صورت زیر ارائه گردید.

$$\frac{y_2}{y_1} = e^{((-0.02 \times a) + (-0.03 \times q) + (0.45 \times Fr_1) + 0.25)} \quad [11]$$

$$\frac{L_j}{y_1} = e^{((-0.06 \times a) + (-0.02 \times q) + (0.354 \times Fr_1) + 1.9)} \quad [12]$$

$$\frac{E_j}{E_1} = (0.02 \times a) + (0.009 \times q) + (0.06 \times Fr_1) + 0.15 \quad [13]$$

$$\frac{L_j}{y_2} = (-0.05 \times a) + (-0.16 \times q) + (0.5 \times Fr_1) + 3.17 \quad [14]$$

جدول 4- نتایج حاصل از تحلیل آماری روابط استخراج شده برای مشخصات هیدرولیکی با نرم‌افزار دیتا فیت

مشخصه هیدرولیکی	$R^2$	$a$	%E	RMSE
$\frac{y_2}{y_1}$	0/96	1/05	5/27	0/06
$\frac{L_j}{y_1}$	0/80	1/14	12/58	0/09
$\frac{E_j}{E_1}$	0/83	0/74	6/94	0/10
$\frac{L_j}{y_2}$	0/95	0/98	5/78	0/07

## نتیجه‌گیری

از میان مشخصات هیدرولیکی مورد مطالعه در این تحقیق، مدل مشخصه هیدرولیکی  $\frac{y_2}{y_1}$  را با بیشترین دقت و مشخصه هیدرولیکی  $\frac{L_j}{y_2}$  را با کمترین دقت نسبت به سایر مشخصات برآورد می‌کند. موثرترین پارامتر در پیش‌بینی مشخصات هیدرولیکی  $\frac{E_j}{E_1}$ ،  $\frac{L_j}{y_1}$  و  $\frac{y_2}{y_1}$  پارامتر  $Fr_1$ ، و در پیش‌بینی مشخصه هیدرولیکی  $\frac{L_j}{y_2}$  بیشترین تاثیر را پارامتر  $a$  دارا می‌باشد. تاثیر پارامتر  $a$  در پیش‌بینی مشخصات هیدرولیکی  $\frac{L_j}{y_1}$  و  $\frac{L_j}{y_2}$  به مراتب بیشتر از تاثیر پارامتر  $q$  می‌باشد.

در این تحقیق برخی از مهمترین خصوصیات پرش هیدرولیکی به صورت نسبت‌های بدون بعد شامل  $\frac{y_2}{y_1}$ ،  $\frac{L_j}{y_2}$ ،  $\frac{E_j}{E_1}$  و  $\frac{L_j}{y_1}$  توسط شبکه عصبی مصنوعی بر حسب پارامترهای  $a$ ،  $q$  و  $Fr_1$  مدل گردید و دقت مدل در برآورد هر یک از این خصوصیات بر حسب پارامترهای مورد نظر، مورد بررسی قرار گرفت. از جمله مهمترین نتایج حاصل از این تحقیق می‌توان به موارد زیر اشاره کرد: مدل شبکه عصبی مصنوعی قادر به پیش‌بینی خصوصیات هیدرولیکی مورد مطالعه در این تحقیق با دقت بسیار بالا می‌باشد.

## منابع مورد استفاده

- ابریشمی ج و حسینی س. م، 1384. هیدرولیک کانالهای باز. انتشارات آستان قدس رضوی، دانشگاه امام رضا (ع)، چاپ دوازدهم.
- امید م ح و اسمعیلی ورکی م، 1384. برآورد مشخصات هیدرولیکی با استفاده از شبکه عصبی مصنوعی. مجله علوم و فنون کشاورزی و منابع طبیعی، جلد 12، شماره 2. صفحه های 17-29.
- امید م ح و اسمعیلی ورکی م، 1384. مطالعه تئوری و آزمایشگاهی پرش هیدرولیکی و اگر در مقاطع نوزنقه‌ای شکل. مجله علوم و فنون کشاورزی و منابع طبیعی، جلد 9، شماره 2، صفحه‌های 17-29.
- بختیاری م، 1387. بررسی هیدرولیکی پارامترهای جهش هیدرولیکی در مقاطع واگرا (تبدیل‌های خروجی). پایان‌نامه کارشناسی ارشد دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز.

- حسین زاده دلیر ع، فرسادی زاده د و قربانی م ع، 1388 تاثیر نوسانات سطح آب و دبی جریان بر میزان بار معلق با استفاده از شبکه‌های عصبی مصنوعی، مجله دانش آب و خاک شماره 2. صفحه‌های 23-24.
- شجاعیان ز، 1389. بررسی خصوصیات پرش هیدرولیکی در مقاطع واگرا با شیب معکوس. پایان‌نامه کارشناسی ارشد دانشکده کشاورزی، دانشگاه تبریز.
- منهاج م، 1379. مبانی شبکه‌های عصبی. انتشارات دانشگاه صنعتی امیرکبیر.
- Abrishami J and Saneie M, 1994. Hydraulic jump in adverse basin slopes. *Iranian J of Water Research Engin* 2: 51-63.
- Arabhabhira A and Abela A, 1971. Hydraulic jump within gradually expanding channel. *J of Hydraulic Div ASCE* 97:31-42.
- Beirami KM and Chamani MR, 2006. Hydraulic jumps in sloping channels: Sequent depth ratio. *J of Hydraulic Engineering ASCE* 132:1061-1068.
- Kashefipour SM, Lin B and Falconer FA, 2005. Neural networks for predicting seawater bacterial levels. *J Water Manage* 158: 111-118.
- Khadar MH A and Rajagopal S, 1972. Hydraulic jump in adverse channel slopes. *Irrig Pwt*, 29: 77-82.
- Khalifa AM and Corquodale Mc AM, 1979. Radial hydraulic jump. *J of Hydraulic Div, ASCE* 105(9):1065-1078.
- Kouluseus HJ and Ahmad D, 1961. Circular hydraulic jump. *J of Hydraulic Division ASCE* 95(1): 409-422.
- Posey CJ and Hsing PS, 1938. Hydraulic jump in trapezoidal channel. *Engineering News-Record* 121: 797-798.
- Reddy SB, 2003. Estimation of watershed runoff using Artificial Neural Networks. PhD Thesis in Agric Engg (unpubl), Post Graduate School, IARI, New Delhi.
- Sarangi A, Bhattacharya AK., 2005. Comparison of Artificial Neural Network and Regression Models for Sediment loss Prediction from Banha watershed in India. Water Technology Center, IARI.Pusa Campus, New Delhi, India.
- Stevens J C, 1944. Discussion of the paper by Kindsvater, hydraulic jump in sloping channel. *Trans ASCE* 109: 1125-1135.
- Tareghian R and Kashefipour SM, 2007. Application of fuzzy systems and artificial neural networks for flood forecasting. *J Applied Sciences* 7(22): 3451-3459.