

بر آورد مشخصات پرش هیدرولیکی واگرا با استفاده از شبکه عصبی مصنوعی

مهدی اسمعیلی ورکی^۱، محمود امید^۲ و محمدحسین امید^۳

دانشجوی دکتری تأسیسات آبیاری گروه مهندسی آبیاری و آبادانی، استادیار گروه مهندسی مکانیک ماشین‌های کشاورزی دانشگاه تهران، استادیار

گروه مهندسی آبیاری و آبادانی دانشگاه تهران

تاریخ دریافت: ۸۲/۳/۱۳؛ تاریخ پذیرش: ۸۳/۱۲/۲۲

چکیده

در این تحقیق یک رهیافت شبکه عصبی مصنوعی (ANN) با ساختار پرسپترون چند لایه برای مدل کردن عمق ثانویه و طول پرش هیدرولیکی واگرا در مقاطع دوزنقه‌ای و مستطیلی که از حالت‌های خاص و پیچیده پرش هیدرولیکی می‌باشند، بکار گرفته شده است. تعداد ۳۰۰۰ داده تئوری و آزمایشگاهی عمق ثانویه و طول پرش مستقیم و واگرا مربوط به مقاطع مستطیلی و دوزنقه‌ای، برای گستره وسیعی از شیب‌های جانبی و زوایای واگرایی مورد استفاده قرار گرفت. در توسعه مدل ANN، هفده ساختار پرسپترون چند لایه، با تعداد لایه‌های پنهان و نرون‌های مختلف، مورد ارزیابی قرار گرفتند. در هر مورد، ساختاری که بالاترین مقدار R^2 را تولید می‌کرد به عنوان مدل بهینه‌گزینه‌ش گردید. برای مقاطع مستطیلی مستقیم و واگرا، مناسبترین مدل ANN برای عمق ثانویه به ترتیب ساختارهای ۲-۲-۱ و ۴-۱-۱ با ۱ و ۹ نرون در هر لایه پنهان و R^2 به ترتیب برابر با ۰/۹۷ و ۰/۹۱ به دست آمد. مناسبترین مدل ANN برای طول پرش نیز به ترتیب ساختارهای ۳-۲-۱ و ۴-۱-۱ با ۱ و ۳ نرون در هر لایه پنهان و R^2 به ترتیب برابر با ۰/۹۸ و ۰/۸۹ بود. برای مقاطع دوزنقه‌ای مستقیم و واگرا، مناسبترین مدل ANN برای عمق ثانویه به ترتیب ساختارهای ۳-۲-۱ و ۵-۲-۱ با ۹ و ۵ نرون در هر لایه پنهان و R^2 به ترتیب برابر با ۰/۹۹ و ۰/۹۴ و برای طول پرش، ساختارهای ۴-۲-۱ و ۵-۲-۱ با ۹ و ۶ نرون در هر لایه پنهان و R^2 به ترتیب برابر با ۰/۹۰ و ۰/۸۵ بود. مقادیر بالای به دست آمده برای R^2 در هر ۸ مورد، بیانگر همبستگی نزدیک بین مقادیر خروجی مدل ANN و داده‌های تئوری و آزمایشگاهی می‌باشد.

واژه‌های کلیدی: پرش هیدرولیکی، پرش هیدرولیکی واگرا، حوضچه آرامش، شبکه عصبی مصنوعی

مقدمه

یکی از متداول‌ترین سازه‌های مستهلک‌کننده انرژی در انتهای سازه‌هایی نظیر سرریزها، تندآبها و دریچه‌ها، حوضچه‌های آرامش با پرش هیدرولیکی می‌باشند. در این حوضچه‌ها، با تشکیل پرش هیدرولیکی و عبور جریان از

فوق‌بحرانی به زیربحرانی، انرژی جریان مستهلک می‌شود. 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 معمولی در مقاطع



شرایط، می‌تواند کمک مؤثری برای طراحی اینگونه حوضچه‌های آرامش باشد.

شبکه‌های عصبی مصنوعی^۱ (ANNs) که برگرفته از شبکه‌های عصبی بیولوژیکی می‌باشند، می‌توانند در حل مسائلی نظیر مسئله فوق کمک نمایند. این شبکه‌ها که از سیستم‌های هوشمند به حساب می‌آیند، اکنون با ساختارهای متنوع و وسیع، در بسیاری از علوم از جمله هیدرولیک گسترش یافته‌اند که به‌عنوان نمونه می‌توان به موارد زیر اشاره کرد.

شایا و سبلانی (۱۹۹۸)، با بکارگیری یک مدل ANN با ساختار پرسپترون چند لایه، عملکرد آن را در پیشگویی ضریب زبری لوله برای آرایش‌های مختلف در لایه میانی بررسی کردند. جین (۲۰۰۱)، با بکارگیری یک مدل ANN با ساختار پرسپترون چند لایه، عملکرد مدل را در پیشگویی دبی رسوب رودخانه می‌سی‌سی‌پی بررسی کرد. بارانی و همکاران (۱۳۸۱)، با بکارگیری مدل ANN با ساختار پرسپترون چند لایه، توانایی مدل را در پیشگویی دبی اوج هلیل رود بررسی نمودند.

در تحقیق حاضر، امکان استفاده از سیستم هوشمند شبکه عصبی (ANNs) در برآورد مشخصات پرش هیدرولیکی واگرا مورد بررسی قرار گرفته است.

شبکه عصبی مصنوعی با ساختار پرسپترون چند لایه: شبکه عصبی مصنوعی (ANN) را می‌توان به‌عنوان یک مدل ریاضی که توانایی مدل‌سازی و ایجاد روابط ریاضی غیرخطی را برای درونیابی دارد، معرفی کرد. از زمانی که اولین مدل شبکه عصبی مصنوعی توسط کولاج و پیترس (۱۹۴۳) ارائه شد (البرزی، ۱۳۸۰)، تاکنون مدل‌های زیادی با ساختارهای مختلف پیشنهاد گردیده که بطور وسیعی در حوزه‌های مختلف علوم مورد استفاده قرار می‌گیرند. در این تحقیق از یک مدل شبکه عصبی مصنوعی با ساختار پرسپترون^۲ چند لایه استفاده گردیده است. این مدل بطور کلی از سه لایه و هر لایه از تعدادی واحد پردازشگر

مستطیلی، مقدار عمق ثانویه با روابط تئوری حاصل از قوانین پیوستگی و مومتوم قابل محاسبه بوده و طول پرش نیز با معادلات حاصل از نتایج تجربی برآورد می‌گردد. لیکن پیش‌بینی مشخصات پرش هیدرولیکی در مقاطع غیرمستطیلی و بخصوص در حوضچه‌های واگرا، بدلیل پیچیدگی تنها با فرضیات ساده‌کننده امکان‌پذیر می‌باشد. از سال ۱۸۲۰ که پرش هیدرولیکی توسط بیدون مورد بررسی قرار گرفت (ابریشمی، ۱۳۷۷)، تاکنون تحقیقات زیادی در خصوص پرش در وضعیت‌های مختلف صورت گرفته است. در اینجا تنها به تعدادی از آنها که در مورد پرش‌های هیدرولیکی واگرا می‌باشد، اشاره می‌گردد.

کلوسیوس و احمد (۱۹۶۱)، با فرض تغییرات خطی بین عمق اولیه و ثانویه پرش و بکارگیری اصول پیوستگی، انرژی و مومتوم، روابطی برای نسبت عمق ثانویه و افت نسبی انرژی ارائه کردند. اربهابیراما و ابلا (۱۹۷۱)، خصوصیات پرش هیدرولیکی در کانال مستطیلی واگرا را بررسی و با فرض شکل ربع بیضی برای نیمرخ پرش روابطی برای نسبت عمق ثانویه و افت نسبی انرژی ارائه کردند. خلیفه و مک کروکودال (۱۹۷۹)، خصوصیات پرش هیدرولیکی شعاعی را بررسی کردند. این محققین با شعاعی در نظر گرفتن خطوط جریان و نسبت دادن یک معادله درجه دوم برای نیمرخ سطح آب، روابطی برای نسبت عمق ثانویه و افت نسبی انرژی در کانال مستطیلی واگرا ارائه کردند.

صرف‌نظر از فرضیات صورت گرفته در هر یک از تحقیقات فوق، نتایج همه آنها منجر به ارائه روابط پیچیده‌ای برای محاسبه نسبت عمق ثانویه گردیده که بدلیل وجود طول پرش در معادلات، هیچیک از حل دقیق برخوردار نمی‌باشند. برآورد خصوصیات پرش هیدرولیکی واگرا در مقاطع دوزنقه‌ای حتی از پیچیدگی بیشتری برخوردار بوده و تاکنون نیز مطالعات کافی در مورد آنها صورت نگرفته است. لذا توسعه مدل‌های ساده و در عین حال دقیق برای حل مسائل پرش هیدرولیکی در این گونه



1- Artificial Neural Network


2-Precptron

بطور معمول نرون‌های هر لایه به کلیه نرون‌های لایه مجاور از طریق یک رابطه جهت‌دار مرتبط می‌باشند. اطلاعات بین نرون‌ها از طریق این اتصالات منتقل می‌شوند. هر یک از این اتصالات دارای مشخصه‌ای (وزن) مختص به خود هستند که در اطلاعات انتقال یافته از یک نرون به نرون دیگر ضرب می‌گردد. هر نرون، خروجی‌های وزن شده ($W_{ij} X_i$) را از نرون‌های لایه قبلی دریافت و مجموع آنها، ورودی نرون (Net_j) را تولید می‌کند (شکل ۲):


$$Net_j = \sum w_{ij}x_i + b_i \quad [1]$$

در رابطه فوق W_{ij} بیانگر وزن اتصال بین گره‌های i و j ، X_i خروجی از گره i و ضریب b_i بایاس گره i نامیده می‌شود.

بنام نرون^۳ (سلول، واحد و یا گره) تشکیل شده است. اولین لایه هر شبکه را لایه ورودی می‌گویند که در این لایه بردارهای داده‌های ورودی نگاشت مورد نظر قرار می‌گیرد. در این لایه هیچگونه پردازشی انجام نخواهد شد. لایه آخر هر شبکه به لایه خروجی معروف بوده و در آن بردارهای خروجی نگاشت استقرار می‌یابد. همچنین هر پرسپترون از تعدادی لایه میانی که لایه‌های پنهان نامیده می‌شوند، تشکیل شده است. تعداد این لایه‌ها و همچنین تعداد نرون‌ها در هر لایه توسط طراح و طی فرآیند آزمون و خطا پیدا می‌شود. در شکل ۱ نمای کلی یک شبکه عصبی با ساختار پرسپترون چند لایه نشان داده شده است. در این شکل y_1 و y_2 عمق‌های مزدوج پرش، Fr_1 عدد فرود جریان قبل از پرش و θ زاویه واگرایی می‌باشد که به‌عنوان لایه ورودی به شبکه منتقل شده و طول پرش (L_j) پارامتر خروجی می‌باشد.



شکل ۱ - نمای کلی از یک شبکه عصبی با ساختار پرسپترون چند لایه برای پیش‌بینی طول پرش هیدرولیکی.



شکل ۲ - جزئیات یک نرون با بردارهای ورودی و خروجی مربوطه.



سرعت یادگیری و دقت در شبکه عصبی مؤثر می‌باشد. در آموزش شبکه‌های عصبی دو روند آموزش الگو به الگو^۸ و آموزش گروهی^۹ پیشنهاد گردیده است. در روش الگو به الگو، به ازای هر بار اعمال الگوی ورودی به شبکه، پارامترهای شبکه در مسیر رفت محاسبه و با محاسبه میزان خطا، مقدار تغییرات پارامترهای شبکه تعیین و در مسیر برگشت پارامترها تصحیح می‌گردند. در آموزش گروهی، به ازای تمام تکرارهای الگوهای ورودی، میزان تغییر پارامترها محاسبه و در پایان مرحله آموزش، پارامترها اصلاح می‌شوند.

مواد و روش‌ها

در این تحقیق از جعبه ابزار ۴. Neural Network موجود در نرم‌افزار Matlab نسخه ۶.۵ برای پیاده‌سازی شبکه عصبی با ساختار پرسپترون چند لایه استفاده شد.

آماده‌سازی داده‌ها: برای جلوگیری از کوچک شدن بیش از حد وزن‌ها، لازم است داده‌های مورد استفاده برای شبکه‌های عصبی نرمال یا استاندارد شوند. برای این منظور، روش‌های متعددی ارائه گردیده که در این تحقیق از رابطه ۴ برای نرمال‌سازی داده‌ها استفاده شد. با استاندارد (نرمال) کردن داده‌ها با استفاده از رابطه ۴، کلیه داده‌ها در دامنه ۰ تا ۱ قرار می‌گیرند. در این رابطه \bar{X}_i داده نرمال شده، X_i داده مورد استفاده و X_{min} و X_{max} حداقل و حداکثر داده‌ها در سری مورد نظر می‌باشد.

$$\bar{X}_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad [4]$$

بعد از نرمال‌سازی داده‌ها، مجموعه داده‌ها به سه بخش آموزشی، امتحانی و صحت‌یابی تقسیم گردید. در این تحقیق برای نرمال‌سازی داده‌ها از ۳۰۰۰ داده تصوری حاصل از رابطه ۵ و داده‌های مربوط به آزمایش‌های صورت گرفته بر روی یک مدل آزمایشگاهی برای عمق ثانویه و طول پرش مستقیم و واگرا در مقاطع مستطیلی و دوزنقه‌ای استفاده گردید.

نرون‌ها برای محاسبه خروجی خود (Y_i) ، ورودی دریافتی را از یک تابع فعال‌سازی (آستانه) عبور می‌دهد. توابع فعال‌سازی دارای انواع مختلفی نظیر توابع باینری، سیگموئیدی، تانژانت هیپربولیک، خطی و گوسی می‌باشند. متداول‌ترین تابع برای تعریف خروجی (Y_i) در این زمینه، تابع سیگموئیدی است که بصورت زیر ارائه می‌گردد.

$$y_j = f(\text{Net}_j) = \frac{1}{1 + e^{-(\text{Net}_j)}} \quad [2]$$

آموزش شبکه براساس ساختار پرسپترون چند لایه: اساس آموزش شبکه‌های عصبی، تغییر وزن اتصالات شبکه جهت تولید خروجی مطلوب می‌باشد. آموزش این شبکه‌ها را می‌توان به آموزش "با سرپرستی"، که در آن خروجی معینی به هر ورودی نسبت داده می‌شود و آموزش "بدون سرپرستی" که دارای خروجی از قبل نامشخص است، تقسیم نمود. نحوه عمل پرسپترون چند لایه بدین صورت است که ابتدا الگویی به شبکه عرضه شده و سپس خروجی آن محاسبه می‌گردد. با مقایسه خروجی شبکه با خروجی مطلوب، میزان خطا برای اصلاح وزن‌های شبکه (W_{ij}) از طریق رابطه زیر محاسبه و از یک لایه به لایه قبل منتشر می‌گردد.

$$E_p = \frac{1}{2} \sum_j (o_{pj} - y_{pj})^2 \quad [3]$$

در این رابطه، E_p مقدار خطای الگوی p ، o_{pj} خروجی مطلوب و y_{pj} خروجی واقعی در گره j ام است. انتخاب روش آموزش بر سرعت یادگیری و دقت شبکه مؤثر می‌باشد.

تاکنون روش‌های مختلفی برای آموزش شبکه‌های عصبی پیشنهاد گردیده است که از مهمترین آنها می‌توان به الگوریتم پس انتشار خطای بیشترین شیب^{۱۰} (SD)، الگوریتم پس انتشار گرادیان‌های مزدوج^{۱۱} (GDM) و الگوریتم پس انتشار مارکوآرت - لورنبرگ^{۱۲} (LM) اشاره کرد (۵). علاوه بر روش آموزش، روند آموزش نیز بر

8- Epochs

9- Batch

1-Steepest Descent
2-Conjugated Gradient
3-Marquardt Lovenberg



پیوستگی و مونتسوم و نیز اعمال فرضیاتی، رابطه را استخراج گردید:

[5]


$$\frac{y_2}{y_1} = \left[\frac{Fr_1^2 \frac{D_1}{y_1} \left(1 - \frac{A_1}{A_2}\right) + K_1}{A_2 K_2} - \frac{2L_j \left(\frac{y_2^2}{3} + \frac{5y_1^2}{6} - \frac{2y_1 y_2}{3}\right) \sin \theta}{\sin(\cot g^{-1} z) A_2 K_2 y_1} \right]^{0.5}$$

در رابطه فوق، A_1 و A_2 به ترتیب عمق‌های اولیه و ثانویه پرش، Fr_1 عدد فرود اولیه جریان قبل از پرش، A_1 و A_2 سطح مقاطع جریان قبل و بعد از پرش، L_j طول پرش، θ زاویه واگرایی، Z نماینده شیب جانبی، $K = \frac{1}{3} + \frac{b}{6b'}$ ، $b' = b + yz$ عرض کف حوضچه، $D = \frac{by + y^2 z}{b + 2yz}$ و نمایه‌های ۱ و ۲ به ترتیب مربوط به شرایط جریان قبل و بعد از پرش می‌باشد.


انتخاب نوع تابع فعال‌سازی: با توجه به دامنه داده‌های نرمال شبکه که بین ۰ تا ۱ بود، تابع فعال‌سازی لوگ سیگموئید برای تمام نرون‌های لایه‌های پنهان و خروجی انتخاب گردید (شکل ۳).

طرح مدل آزمایشگاهی که برای این تحقیق طراحی و ساخته شد، در شکل ۳ نشان داده شده است. مدل شامل یک مخزن آرام‌کننده با سرریز مستطیلی لبه تیز و مخزن ایجاد ارتفاع در بالادست، دریچه کشویی لبه تیز، یک کانال مستطیلی به عرض ۰/۵ متر، دیواره‌های شیشه‌ای به ارتفاع ۰/۶ متر و طول ۹ متر و یک مخزن اندازه‌گیری حجمی در پایین دست می‌باشد. بخشی از کانال به طول ۳ متر که بلافاصله بعد از دریچه مخزن قرار دارد، بگونه‌ای ساخته شد که به‌عنوان حوضچه آرامش، امکان ایجاد همزمان شیب‌های جانبی مختلف و واگرایی با زوایای متفاوت فراهم بود. با استفاده از مخزن بالادست و دریچه کشویی، ایجاد جریان‌های ورودی به حوضچه آرامش با عمق و سرعت‌های مختلف (اعداد فرود اولیه تا ۹) امکان‌پذیر بود.

آزمایش‌های انجام شده مربوط مقاطع مستطیلی و دوزنقه‌ای با شیب‌های جانبی (عمودی: افقی) ۰/۵:۱، ۱:۱ و ۱/۵:۱ و زوایای واگرایی ۲، ۵، ۷ و ۹ درجه می‌باشد. برای محاسبه مقدار تئوری عمق ثانویه در پرش هیدرولیکی واگرا در مقطع دوزنقه‌ای، با بکارگیری اصول



شکل ۳- طرح کلی مدل آزمایشگاهی.



شکل ۴- تابع فعال‌سازی لوگ سیگموئید.

گانه آموزش، امتحان و صحت‌یابی به‌منظور پیش‌بینی عمق ثانویه و طول پرش در مقاطع مستطیلی و دوزنقه‌ای مستقیم و واگرا، پارامترهای بردارهای ورودی در جدول ۱ آورده شد. در مورد تعداد لایه‌های پنهان و همچنین تعداد نرون‌ها در هر لایه با انتخاب حالت‌های مختلف و بررسی عملکرد شبکه بهترین ساختار انتخاب گردید.

انتخاب الگوی آموزش و روند آموزشی: در این تحقیق الگوریتم LM به‌منظور آموزش و الگوریتم GDM به‌منظور امتحان شبکه انتخاب گردید. همچنین روند آموزش از نوع الگو به الگو بود. تعیین تعداد نرون‌های لایه‌های شبکه: تعداد نرون‌های لایه‌های ورودی و خروجی برابر با تعداد متغیرهای بردارهای ورودی و خروجی می‌باشند. برای مراحل سه

جدول ۱ - مشخصات پارامترهای ورودی و خروجی مربوط به پیشگویی عمق ثانویه و طول پرش.

شکل مقطع	پارامتر خروجی		پارامترهای ورودی	
مستطیلی مستقیم	y_2	y_1	Fr_1	y_1
	L_j	y_1	Fr_1	y_2
دوزنقه‌ای مستقیم	y_2	Z	Fr_1	y_1
	L_j	Z	Fr_1	y_2
مستطیلی واگرا	y_2	\oplus	Fr_1	L_j
	L_j	\oplus	Fr_1	y_2
دوزنقه‌ای واگرا	y_2	Z	Fr_1	L_j
	L_j	Z	Fr_1	y_2

حالت‌های فوق، مربوط به آرایش‌های شماره‌های ۹ و ۵ می‌باشد. همچنین براساس R^2 های مربوط به طول پرش در این مقاطع، بهترین عملکرد شبکه مربوط به آرایش‌های شماره‌های ۹ و ۲ است. با انتخاب بهترین آرایش از میان آرایش‌های اعمال شده به شبکه در هر وضعیت، به‌منظور ارزیابی شبکه و صحت‌یابی پیشگویی داده‌هایی که مدل با آن مواجه نگردیده است، عملکرد شبکه با اعمال مجموعه سوم از داده‌های نرمال شده (داده‌های صحت‌یابی)، بررسی گردید. برای درک بهتر از وضعیت عملکرد شبکه، نمودارهای خروجی شبکه برای مجموعه الگوهای امتحانی و صحت‌یابی در مقابل داده‌های تئوری و آزمایشگاهی مربوطه و نیز نمودارهای تغییرات نسبت عمق ثانویه و طول نسبی پرش برای یکی از زاویای واگرایی در شکل‌های ۵ تا ۷ نشان داده شده است.

نتایج و بحث

به‌منظور بررسی عملکرد شبکه با آرایش‌های مختلف در لایه‌های پنهان، از فاکتور R^2 (ضریب تبیین) استفاده گردید. نظر به اینکه برای آموزش شبکه، روند الگو به الگو انتخاب شد، در هر آرایش لایه میانی، با اعمال تعداد الگوهای مختلف (تکرارهای مختلف)، بهترین مقدار R^2 انتخاب و برای آن آرایش در نظر گرفته شد. نتایج عملکرد شبکه برای پیشگویی عمق ثانویه و طول پرش برای مقاطع مستطیلی و دوزنقه‌ای مستقیم و واگرا در جدول‌های ۲ و ۳ آورده شده است.


الف) عملکرد شبکه برای پیشگویی عمق ثانویه و طول پرش مستقیم و واگرا در مقطع مستطیلی: همانگونه که از R^2 های مربوط به عمق‌های ثانویه پرش هیدرولیکی در جدول ۲ مشاهده می‌گردد، بهترین عملکرد شبکه برای



جدول ۲- عملکرد شبکه در پیشگویی عمق ثانویه و طول پرش در مقاطع مستطیلی مستقیم و واگرا.



مقطع مستطیلی واگرا		مقطع مستطیلی مستقیم		مقطع مستطیلی مستقیم		مقطع مستطیلی مستقیم		آرایش لایه پنهان شبکه	
طول جهش		عمق ثانویه		طول جهش		عمق ثانویه		تعداد لایه	تعداد نرون
R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE		
۰/۷۹	۰/۰۸	۰/۸۸	۰/۰۶۳	۰/۹۷	۰/۰۶۳	۰/۹۳	۰/۱۸۳	۱	۱
۰/۸۹	۰/۰۵۳	۰/۹	۰/۰۵۶	۰/۹۴	۰/۱۸۵	۰/۹۵	۰/۰۶۷	۳	۱
۰/۸۹	۰/۰۷۴	۰/۶۴	۰/۰۹۶	۰/۹۶	۰/۰۸۶	۰/۹۵	۰/۰۶۳	۵	۱
۰/۸۲	۰/۰۷۱	۰/۸۶	۰/۰۶۹	۰/۹۵	۰/۱۴۶	۰/۹۵	۰/۰۹۶	۷	۱
۰/۸۷	۰/۰۶۹	۰/۹۱	۰/۰۵۹	۰/۹۵	۰/۱۵۲	۰/۹۴	۰/۰۸۷	۹	۱
۰/۸۳	۰/۱۹۲	۰/۸۷	۰/۰۹۶	۰/۹۶	۰/۰۹۵	۰/۹۵	۰/۰۷۸	۱۱	۱
۰/۸۳	۰/۰۶۳	۰/۶۶	۰/۰۹۱	۰/۹۵	۰/۱۰۶	۰/۹۷	۰/۰۶۳	۱۳	۱
۰/۸۶	۰/۰۸۳	۰/۷۴	۰/۱۰۸	۰/۹۷	۰/۱۱۵	۰/۹۷	۰/۰۶۱	۱۵	۱
۰/۸۴	۰/۰۷۸	۰/۸۵	۰/۰۸۱	۰/۹۸	۰/۰۲۷	۰/۹۷	۰/۰۴۳	۱	۲
۰/۸۲	۰/۰۷۸	۰/۷۲	۰/۱	۰/۹۷	۰/۰۳۷	۰/۹۵	۰/۰۴۹	۲	۲
۰/۸۷	۰/۰۵۶	۰/۷۱	۰/۰۹	۰/۹۵	۰/۰۷۲	۰/۹۴	۰/۰۸۴	۳	۲
۰/۸۲	۰/۰۸۳	۰/۵۵	۰/۱۴۵	۰/۹۵	۰/۱۰۳	۰/۹۵	۰/۰۷۳	۴	۲
۰/۸۵	۰/۰۶۶	۰/۸۱	۰/۰۶۲	۰/۹۷	۰/۰۳۱	۰/۹۴	۰/۰۶۶	۵	۲
۰/۸۶	۰/۰۹۷	۰/۸۱	۰/۰۶۳	۰/۹۸	۰/۰۴۴	۰/۹۶	۰/۰۸۲	۶	۲
۰/۸۴	۰/۰۸	۰/۸۳	۰/۰۹۵	۰/۹۶	۰/۰۷۶	۰/۹۷	۰/۰۵۳	۷	۲
۰/۷۵	۰/۱۰۹	۰/۷۸	۰/۰۷	۰/۹۴	۰/۰۵۲	۰/۹۴	۰/۰۶۴	۸	۲
۰/۸۹	۰/۰۷۲	۰/۸۱	۰/۰۷	۰/۹۶	۰/۰۹۴	۰/۹۶	۰/۰۷۲	۹	۲

بر اساس R²ها و نیز مقادیر RMSE مربوط در این جداول، عملکرد شبکه در پیش بینی پارامترهای مورد نظر ارزیابی می گردد.





شکل ۵- ارزیابی عملکرد شبکه برای پیش گویی عمق ثانویه در مقطع مستطیلی واگرا (نمایه ANN مربوط به خروجی شبکه و نمایه های Th و Exp به ترتیب مربوط به داده های تنوری و آزمایشگاهی می باشد).





شکل ۶- ارزیابی عملکرد شبکه برای پیش گویی طول پرش در مقطع مستطیلی واگرا.



شکل ۷- عملکرد شبکه برای پیش‌بینی نسبت عمق ثانویه و طول پرش واگرا در مقطع مستطیلی با واگرایی ۷ درجه.

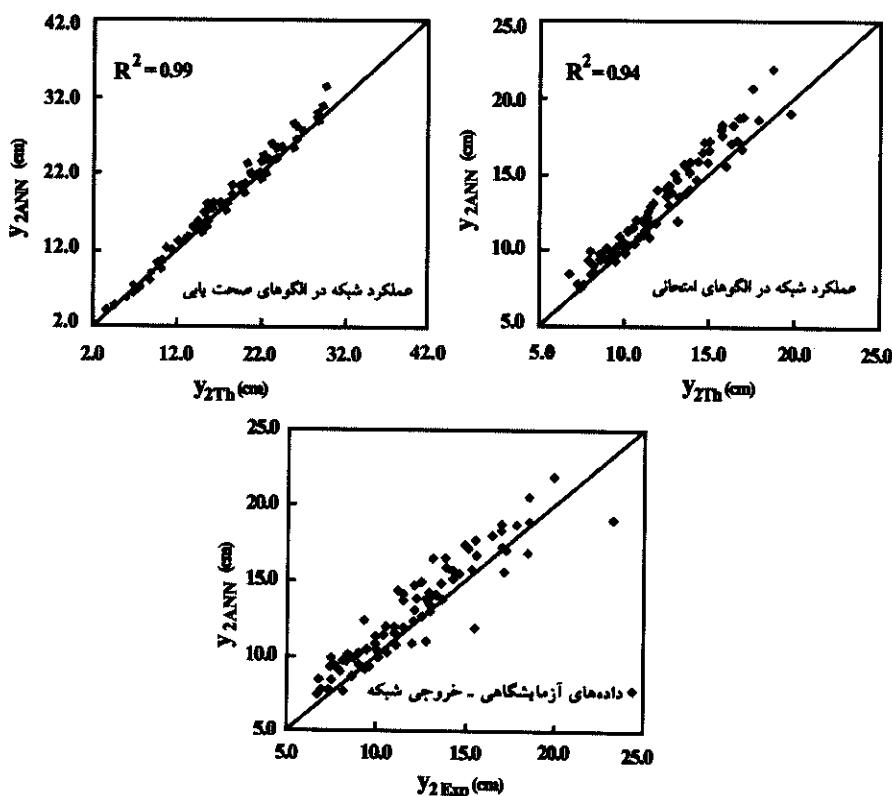
وضعیت، به منظور ارزیابی شبکه و صحت‌یابی داده‌های پیشگویی شده که مدل قبلاً با آن مواجه نگردیده است، با استفاده از مجموعه سوم از داده‌های نرمال شده (داده‌های صحت‌یابی)، عملکرد شبکه بررسی گردید. برای مشاهده عملکرد شبکه در این حالت، نمودارهای خروجی شبکه برای مجموعه الگوهای امتحانی و صحت‌یابی در مقابل داده‌های تئوری و آزمایشگاهی مربوطه و نیز نمودارهای تغییرات نسبت عمق ثانویه و طول نسبی پرش برای مقطع واگرا با زاویه واگرایی ۷ درجه، در شکل‌های ۸ تا ۱۰ نشان داده شده است.

ب) عملکرد شبکه برای عمق ثانویه و طول پرش در مقطع دوزنقه‌ای مستقیم و واگرا: همانگونه که از R^2 های مربوط به عملکرد شبکه در پیش‌گویی عمق‌های ثانویه پرش هیدرولیکی برای مقطع دوزنقه‌ای مستقیم و واگرا در جدول ۳ مشاهده می‌گردد، بهترین عملکرد شبکه برای حالت‌های فوق، مربوط به آرایش‌های شماره‌های ۱۷ و ۱۳ می‌باشد. همچنین براساس R^2 های مربوط به طول پرش در این مقاطع، بهترین عملکرد شبکه مربوط به آرایش‌های شماره‌های ۱۷ و ۱۴ است. با انتخاب بهترین آرایش از میان آرایش‌های اعمال شده به شبکه در هر



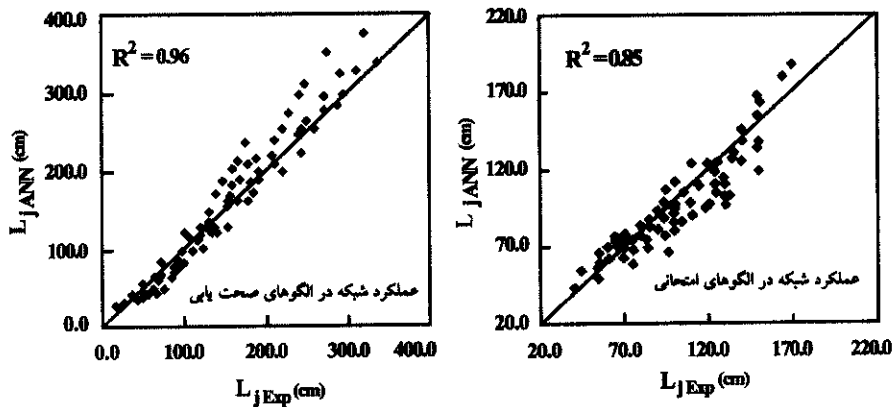
جدول ۳- عملکرد شبکه در پیشگویی عمق ثانویه و طول پرش در مقاطع دوزنقه‌ای مستقیم و واگرا.

مقطع دوزنقه‌ای مستقیم		مقطع دوزنقه‌ای واگرا		مقطع دوزنقه‌ای مستقیم		مقطع دوزنقه‌ای واگرا		آرایش لایه پنهان شبکه		
عمق ثانویه	طول جهش	عمق ثانویه	طول جهش	عمق ثانویه	طول جهش	عمق ثانویه	طول جهش	شماره	تعداد لایه	تعداد نرون
R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE			
۰/۷۰	۰/۰۳	۰/۶۰	۰/۰۵۳	۰/۶۵	۰/۰۳۹	۰/۷۶	۰/۱۰۴	۱	۱	۱
۰/۷۶	۰/۰۸۶	۰/۷۴	۰/۰۴۱	۰/۶۰	۰/۱۴۱	۰/۸۳	۰/۱۲۴	۳	۱	۲
۰/۷۶	۰/۰۶۳	۰/۸۲	۰/۰۳۵	۰/۷۱	۰/۰۴۱	۰/۸۵	۰/۱۲۳	۵	۱	۳
۰/۷۱	۰/۱۲۲	۰/۷۸	۰/۰۴۶	۰/۷۰	۰/۰۷۶	۰/۹۴	۰/۱۸۳	۷	۱	۴
۰/۸۲	۰/۰۵۷	۰/۷۷	۰/۰۵۳	۰/۷۷	۰/۰۳۹	۰/۷۲	۰/۱۳۷	۹	۱	۵
۰/۷۱	۰/۰۷۸	۰/۶۹	۰/۰۵۳	۰/۷۵	۰/۰۶۳	۰/۸۵	۰/۱۰۴	۱۱	۱	۶
۰/۷۹	۰/۰۲۷	۰/۵۰	۰/۰۸۷	۰/۷۱	۰/۰۴۲	۰/۸۷	۰/۱۰۶	۱۳	۱	۷
۰/۶۴	۰/۰۷۲	۰/۶۳	۰/۰۷۳	۰/۸۱	۰/۰۳۲	۰/۹۱	۰/۱۵۵	۱۵	۱	۸
۰/۷۲	۰/۰۲۷	۰/۶۱	۰/۰۳۷	۰/۷۶	۰/۰۵۷	۰/۸۴	۰/۱۲۴	۱	۲	۹
۰/۷۲	۰/۰۵۳	۰/۷۱	۰/۰۷۹	۰/۶۲	۰/۱۲۸	۰/۷۳	۰/۱۱۳	۲	۲	۱۰
۰/۷۱	۰/۱۴۸	۰/۸۰	۰/۰۴۸	۰/۷۸	۰/۰۴۳	۰/۸۳	۰/۱۲۷	۳	۲	۱۱
۰/۶۸	۰/۰۹	۰/۹۲	۰/۰۲۹	۰/۷۹	۰/۰۳۴	۰/۸۵	۰/۰۹۴	۴	۲	۱۲
۰/۷۷	۰/۱۰۱	۰/۹۴	۰/۰۲۵	۰/۸۶	۰/۰۶۷	۰/۹۳	۰/۱۰۸	۵	۲	۱۳
۰/۸۵	۰/۰۲	۰/۷۲	۰/۰۳۹	۰/۸۳	۰/۰۲۴	۰/۸۳	۰/۲۱۱	۶	۲	۱۴
۰/۷۶	۰/۰۹۳	۰/۷۷	۰/۰۵	۰/۷۳	۰/۰۳۷	۰/۹۶	۰/۱۷۵	۷	۲	۱۵
۰/۷۸	۰/۰۵۲	۰/۹۱	۰/۰۲۶	۰/۸۱	۰/۰۳	۰/۹۳	۰/۲۵۸	۸	۲	۱۶
۰/۷۲	۰/۱۴۹	۰/۷۸	۰/۰۴۳	۰/۹۰	۰/۰۱۷	۰/۹۹	۰/۰۸۷	۹	۲	۱۷




شکل ۸- ارزیابی عملکرد شبکه برای پیش‌گویی عمق ثانویه در مقطع دوزنقه‌ای واگرا.





شکل ۹- ارزیابی عملکرد شبکه برای پیش‌گویی طول پرش واگرا در مقطع دوزنقه‌ای.



شکل ۱۰- عملکرد شبکه برای برآورد نسبت عمق ثانویه و طول پرش واگرا در مقطع دوزنقه‌ای با شیب جانبی ۱:۱.

پنهان می‌باشد که مقادیر نسبت عمق ثانویه را با 0.97 و $R^2 = 0.43$ و $RMSE = 0.027$ و $R^2 = 0.98$ پیش‌گویی می‌کند.

❖ برای مقاطع مستطیلی واگرا، مناسب‌ترین مدل ANN برای برآورد نسبت عمق ثانویه و طول پرش، ساختاری با ۱ لایه پنهان (۱-۱-۴) و به ترتیب ۹ و ۳ نرون در هر لایه پنهان می‌باشد که مقادیر نسبت عمق ثانویه را با $R^2 = 0.91$ و $RMSE = 0.059$ و طول نسبی پرش را با $R^2 = 0.89$ و $RMSE = 0.053$ پیش‌گویی می‌کند.

❖ برای مقاطع دوزنقه‌ای مستقیم، مناسب‌ترین مدل ANN برای برآورد نسبت عمق ثانویه و طول پرش، ساختاری با ۲ لایه پنهان (۱-۲-۳) و (۱-۲-۴) و ۹ نرون در هر لایه پنهان می‌باشد که مقادیر نسبت عمق ثانویه را با $R^2 = 0.99$ و $RMSE = 0.087$ و طول نسبی پرش را با $R^2 = 0.9$ و $RMSE = 0.017$ پیش‌گویی می‌کند.

نتیجه‌گیری

در این تحقیق، امکان استفاده از شبکه عصبی مصنوعی (ANN) برای برآورد نسبت عمق ثانویه و طول پرش هیدرولیکی مستقیم و واگرا در مقاطع دوزنقه‌ای و مستطیلی که از حالت‌های خاص و پیچیده پرش هیدرولیکی می‌باشند، مورد بررسی قرار گرفت. رهیافت مورد بررسی در این تحقیق، شبکه عصبی مصنوعی با ساختار پرسپترون چند لایه بود. نتایج حاصل نشان‌دهنده توانایی بالای این سیستم در برآورد مشخصات پرش هیدرولیکی در این مقاطع می‌باشد. با توجه به نتایج حاصل از شبکه برای آرایش‌های مختلف و مقایسه آنها با نتایج تئوری و داده‌های آزمایشگاهی، می‌توان گفت:

برای مقاطع مستطیلی مستقیم، مناسب‌ترین مدل ANN برای برآورد نسبت عمق ثانویه و طول پرش، ساختاری با ۲ لایه پنهان (۱-۲-۳) و (۱-۲-۴) ۱ نرون در هر لایه



پنهان می‌باشد که مقادیر نسبت عمق ثانویه را با $R^2 = 0/94$ و $RMSE = 0/025$ و طول نسبی پرش را با $R^2 = 0/85$ و $RMSE = 0/02$ پیشگویی می‌کند.

برای مقاطع دوزنقه‌ای واگرا، مناسب‌ترین مدل ANN برای برآورد نسبت عمق ثانویه و طول پرش، ساختاری با ۲ لایه پنهان (۱-۲-۵) و به ترتیب ۵ و ۶ نرون در هر لایه

منابع

۱. ابریشمی، ج و م. حسینی. ۱۳۷۷. هیدرولیک کانال‌های باز. انتشارات آستان قدس رضوی. چاپ ششم. ۵۰۱ صفحه.
۲. اسمعیلی ورکی، م. ۱۳۸۲. بررسی خصوصیات جهش هیدرولیکی واگرا در حوضچه آرامش دوزنقه‌ای. پایان‌نامه کارشناسی ارشد در رشته تاسیسات آبیاری. گروه مهندسی آبیاری و آبادانی، دانشگاه تهران. ۱۲۰ صفحه.
۳. اسمعیلی ورکی، م. امید و م. ح. امید. ۱۳۸۲. برآورد مشخصات پرش هیدرولیکی واگرا در مقاطع مستطیلی و دوزنقه‌ای با استفاده از شبکه عصبی مصنوعی. مجموعه مقالات چهارمین کنفرانس هیدرولیک ایران، دانشکده مهندسی دانشگاه شیراز، صفحه ۹۸۹-۹۸۱.
۴. اسمعیلی ورکی، م. ح. امید و ص. کوچک‌زاده. ۱۳۸۲. مطالعه آزمایشگاهی خصوصیات پرش هیدرولیکی واگرا در مقاطع دوزنقه‌ای. مجموعه مقالات چهارمین کنفرانس هیدرولیک ایران، دانشکده مهندسی دانشگاه شیراز، صفحه ۱۳۰-۱۲۳.
۵. البرزی، م. ۱۳۸۰. آشنایی با شبکه‌های عصبی، انتشارات دانشگاه صنعتی شریف. ۱۳۷ صفحه.
۶. بارانی، غ. ع. م. ب. رهنما و ش. شباک. ۱۳۸۱. پیش بینی دبی اوج با استفاده از شبکه عصبی مصنوعی (مطالعه موردی رودخانه هلیل). مجموعه مقالات ششمین سمینار مهندسی رودخانه ایران، دانشگاه شهید چمران اهواز. صفحه ۴۸۶-۴۷۹.
۷. منهای، م. ب. ۱۳۷۷. کاربرد هوش محاسباتی در کنترل. انتشارات دانشگاه صنعتی امیرکبیر، جلد دوم. ۴۶۷ صفحه.
8. Arbhahirama, A., and Abella, A. 1971. Hydraulic jump within gradually expanding channel, Journal of Hydraulic Division. ASCE, VOL 97, NO. HY1, pp. 31-42.
9. Jain, S.K. 2001. Development of integrated sediment rating curves using Ann's. Journal of Hydraulic Engineering. Vol. 127. No. 1. pp30-36.
10. Khlifa, A.M., and Corquodale, Mc A.M. 1979. Radial hydraulic jump. Journal of Hydraulic Division, ASCE, Vol. 105. NO. HY9, pp. 1065-1078.
11. Kouluseus, H. j., and Ahmad, D. 1961. Circular hydraulic jump. Journal of Hydraulic Division. ASCE. Vol. 95. NO. HY1, pp. 409-422.
12. Howard, D., and Mark, B. 2001. User's guide for neural network toolbox with matlab. Version 6.1.0. pp. 750.
13. Shaya, H., and Sabalani, S. 1998. Artificial neural network for non-iterative calculation of the friction factor in pipe flow. Comp. and Electronics Journal in Agricultural. 219 – 228.



A neural network model to predict characteristics of gradually expanding hydraulic jumps

¹M. Esmaeeli varaki, ²M. Omid and ³M.H. Omid

¹ Ph.D student, Dept. of Irrigation and Reclamation Eng., University of Tehran, ²Assistant Professor, Dept. of Mechanic and Machinery Eng., University of Tehran, ³Assistant Professor, Dept. of Irrigation and Reclamation Eng., University of Tehran.

Abstract

In this research an Artificial Neural Network (ANN), with multilayer perception structure, was adapted to model conjugate depth and gradually expanding jump length, which are especial but complex cases of hydraulic jumps. More than 3000 interpolated and experimental data on conjugate depths and jump lengths for both normal and gradually expanding jumps were used. The data was due to rectangular and trapezoidal sections, for a wide range of divergent angles and side wall slope. In developing the ANN models, seventeen configurations, each having a different number of hidden layers and/or neurons, were investigated. The optimal models were capable of predicting conjugate depth and jump length for a wide range of conditions. In each case, the configuration attained highest R^2 value was selected as the optimal model. For rectangular sections, the simplest ANN model had a 2-2-1 configuration, with one neuron in each of the two hidden layers, and $R^2=0.97$ (for normal x-section), and had a 4-1-1 configuration, with nine neurons in the hidden layer and $R^2=0.91$ (for gradually expanding x-section), respectively. The best ANN model for predicting respective jump lengths had 3-2-1 and 4-1-1 configurations with one and three neuron(s) in hidden layer(s), and $R^2=0.99$ and 0.94 , respectively. For trapezoidal sections, the simplest ANN model had a 4-2-1 configuration, with nine neurons in each of the hidden layers and $R^2=0.99$ (for normal x-section), and had a 5-2-1 configuration, with six neurons in each of the two hidden layers and $R^2=0.94$ (for gradually expanding x-section), respectively. The best ANN model for respective jump lengths had 4-2-1 and 5-2-1 configurations, with nine and six neurons in each of the two hidden layers, and $R^2=0.90$ and 0.85 , respectively. The high values obtained for R^2 in all of the eight cases, suggest a close agreement between the ANN's output variable and the experimental data. The developed ANN models in this paper are, therefore, suitable for predicting gradually expanding hydraulic jump characteristics, which require a large amount of repetitive computations, for both rectangular and trapezoidal sections often encountered in the design of stilling basins.

Keywords: Hydraulic jump; stilling basin; Artificial neural network; Multilayer Perception

