

## پیش‌بینی فاصله بین کومه‌های هلالی چندترازه با استفاده از شبکه‌های عصبی مصنوعی

آزاده ولی‌پور<sup>۱\*</sup> و حسین شیرگاهی<sup>۲</sup>

<sup>۱</sup> استادیار، گروه علوم و فنون دریایی، دانشگاه آزاد اسلامی، واحد جویبار، ایران

<sup>۲</sup> استادیار، گروه کامپیوتر، دانشگاه آزاد اسلامی، واحد جویبار، ایران

(دریافت: ۱۴۰۱/۱۲/۰۴، پذیرش: ۱۴۰۲/۰۴/۱۸)

### چکیده

کومه‌های هلالی، عوارض موجی شکل منظمی هستند که معمولاً در وجه ساحل، قابل رویتند. در این مطالعه به پیش‌بینی فواصل بین کومه‌های هلالی چند سطحی با استفاده از شبکه عصبی مصنوعی پرداخته شد. نتایج اصلی این تحقیق حاکی از مطابقت عالی بین نتایج پیش‌بینی فواصل بین کومه‌ها توسط مدل بهینه شبکه عصبی با مشاهدات میدانی است. به طوریکه نتایج حاکی از آن است که این مدل ابزار مؤثری را برای پیش‌بینی سریع و دقیق فواصل کومه‌ها در ترازهای مختلف منطقه شستشو به خصوص در تراز بالایی وجه ساحل فراهم می‌کند. نتایج همچنین نشان داد که دقت بدست آمده از نتایج شبکه عصبی با اختلاف جزئی به ترتیب در مدل‌های پس‌انتشار المان، پس‌انتشار پیشرو و پس‌انتشار آبشاری پیشرو، بیشترین به کمترین مقدار است. نتایج دیگر این تحقیق حاکی از آن است توابع، بسته به نوع مدل انتخاب شده دقت متفاوتی در نتایج پیش‌بینی شده، در مراحل مختلف آزمون، ارزیابی و آموزش نشان می‌دهند.

**کلمه‌های کلیدی:** وجه ساحل، منطقه شستشو، پس‌انتشار المان، پس‌انتشار پیشرو، پس‌انتشار آبشاری پیشرو

## ۱ مقدمه

محیط‌های ساحلی و به‌ویژه سواحل ماسه‌ای، سیستم‌هایی هستند که بواسطه تعامل مداوم توپوگرافی بستر با فرآیندهای انتقالی ناشی از باد، موج و نیروهای جزر و مدی به سرعت در حال تکامل و تغییر هستند. به منظور درک کامل و کمی‌سازی اطلاعات مورفودینامیکی ساحل، به دست آوردن داده‌هایی با دقت بالا در مورد تغییرات توپوگرافی ساحل ضروری است (کسلا و همکاران، ۲۰۲۰). در میان مناطق مختلف ساحلی منطقه شستشو (swash zone) در اثر حملات موج و جزر و مد به شدت از لحاظ مکانی و زمانی دچار تغییر می‌شود (پولنو و همکاران، ۲۰۰۰). منطقه شستشو مابین تراز میانگین سطح دریا (Mean Sea Level) و بالاترین حد عملکرد بالاروی موج (uprush) قرار دارد (برنابشو و همکاران، ۲۰۰۲). در واقع منطقه شستشو منطقه‌ای از کرانه است که تحت تأثیر بالاروی و پایین‌روی (backwash) موج قرار می‌گیرد و ابعاد این محل با سطح کشند تغییر می‌کند، به عبارت دیگر می‌توان گفت که این ناحیه همان منطقه کنش موج است (شرت، ۱۹۹۹). اثرات ناشی از بالاروی و پایین‌روی موج موجب شکل‌گیری عوارض مورفودینامیکی به نام کومه‌های هلالی در صورت ساحل می‌شوند که به صورت مجموعه‌ای از عوارض منظم از شاخ‌ها (horn) و فرورفتگی‌هایی (embayment) در طول ساحل است، که در مجموع یک خط ساحلی موجدار (shoreline undulating) را شکل می‌دهند (گارنیر و همکاران، ۲۰۱۰).

تاکنون چندین نظریه در مورد تشکیل این عوارض موجی شکل توسط محققان مختلف ارائه شده است. یکی از اولین نظریه‌ها، مربوط به تغییرات انتقال رسوب بر اثر شکست امواج ایستاده است که در یک بستر شیب‌دار در نزدیکی ساحل بدام می‌افتادند و موجب شکل‌گیری این عوارض می‌شوند (گازا و اینمن، ۱۹۷۵ و اینمن و گازا،

۱۹۸۲). بعدها سایر محققین نیز در این مورد به توافق رسیدند (مانند کانکو، ۱۹۸۵؛ سیمور و اویری، ۱۹۸۵؛ شرمین و همکاران، ۱۹۹۳؛ سیریانو و همکاران، ۲۰۰۵). مطابق این نظریه فاصله بین کومه‌ها برای امواج لبه‌ای از رابطه زیر بدست می‌آید:

$$\lambda_c = \frac{g}{\pi} T^2 (2n + 1) \tan \beta \quad (1)$$

همچنین فاصله بین کومه‌ها در هجوم امواج همزمان (synchronous) از رابطه زیر بدست می‌آید:

$$\lambda_c = \frac{g}{2\pi} T^2 (2n + 1) \tan \beta \quad (2)$$

که در این رابطه  $m$  به ترتیب ۱ و ۰/۵ برای امواج لبه‌ای زیرهارمونیک (sub-harmonic) و برای امواج همزمان است. در این رابطه  $\beta$  شیب ساحل،  $g$  شتاب گرانشی و  $T$  دوره تناوب امواج محسوب می‌شود.

نظریه بعدی در مورد شکل‌گیری کومه‌های هلالی توسط ورنر و فینک (۱۹۹۳) ارائه شد که شکل‌گیری این عوارض را به پویایی درونی سیستم کومه‌ها که ناشی از بازخورد مثبت و منفی بین مورفولوژی ساحل و هیدرودینامیک منطقه شستشو است، نسبت دادند و به همین دلیل اصطلاح خودسازماندهی (self-organization) را در مورد نحوه پیدایش کومه‌های هلالی مطرح کردند. این محققین فاصله بین کومه‌های هلالی را به عنوان تابعی از طول مسیر افقی حرکت جریان شستشو، بیان کردند:

$$\lambda_c = f S_c \quad (3)$$

که در این رابطه ضریب بدون بعد  $f$  بین ۱ و ۳ معمولاً معادل ۱/۶ است (ورنر و فینک، ۱۹۹۳).

مسلینک و همکاران (۱۹۹۷) برای تعیین آستانه شکل‌گیری و تخریب کومه‌های هلالی، پارامتر شباهت خیزاب ساحلی (surf similarity parameter) را به صورت زیر مطرح کردند:

$$\zeta = \frac{\tan \beta}{\sqrt{\frac{H_B}{L_0}}} \quad (4)$$

که در این رابطه  $L_0$  طول موج آب عمیق،  $H_B$  ارتفاع شکست موج و  $\tan \beta$  شیب صورت ساحل است. طبق

دلیل نتایج این تحقیق گامی مؤثر در پیش‌بینی رفتار مورفولوژیکی صورت ساحل بدون صرف هزینه‌های چشمگیر پایش اقلیمی و مورفولوژیکی در شرایط هیدرودینامیکی مختلف ساحل محسوب می‌شود.

## ۲ مواد و روش کار

در این پژوهش به منظور پیش‌بینی فواصل بین کومه‌های هلالی چند ترازه از نتایج مشاهدات میدانی به عمل آمده از یک سیستم کومه‌های هلالی چند سطحی، به عنوان ورودی‌های مدل شبکه عصبی مصنوعی استفاده شده است. در این راستا نخست نتایج مشاهدات میدانی به عمل آمده توسط ناتز و همکاران (۲۰۲۰) در ماههای مختلف به صورت ویژگی‌های این سیستم کومه‌های هلالی در ۲۳ گروه و ۶۱ داده مورفودینامیکی در وجه ساحل استخراج شد (ناتز و همکاران ۲۰۲۰). ویژگی‌های این سیستم کومه‌ها شامل دامنه، ارتفاع و عمق کومه‌های هلالی در سه سطح پایینی، میانی و بالایی وجه ساحل به عنوان ورودی و فاصله کومه‌های هلالی به عنوان خروجی مدل شبکه عصبی ثبت شد. مدل‌های شبکه عصبی مورد استفاده در این تحقیق شامل الگوریتم پس‌انتشار پیشرو (Feed-Forward Back Propagation-FFBP)، پس‌انتشار آبشاری پیشرو (Cascade-Forward Back Propagation-CFBP) و الگوریتم پس‌انتشار المان (Elman Back Propagation-EBP) می‌باشد.

در این سه مدل تعداد نورون‌های لایه میانی از ۱ تا ۲۰ انتخاب شده است. در حالی که توابع مورد استفاده در الگوریتم‌های FFBP و CFBP براساس هفت تابع مختلف (لوین برگ مارکوآت (Levenberg marquardt-lm)، بیسین رگولیشن (Bayesian regularization-br)، کانجوکیت گرادینت ویت بیل پاول ری‌استارتز (Conjugate gradient with beale restarts-gb)، پاول ری‌استارتز (powell restarts-gb)، گرادینت ویت ممتنم بگ

نتایج استخراج شده، اگر شرایط هیدرودینامیکی و مورفولوژیکی در ساحل موجب شود که  $\lambda_c < 1/2$  باشد آنگاه کومه‌ها شروع به تخریب شدن می‌کنند و اگر شرایط در ساحل موجب شود که  $\lambda_c > 1/2$  باشد کومه‌ها شروع به شکل‌گیری می‌کنند (مسلینک و پتی آرچی، ۱۹۹۷).

بعدها محققان از طریق ارزیابی تصاویر کومه‌ها در یک بازه زمانی چندین ساله دریافتند که این عوارض از طریق بازخوردهای خودسازماندهی بین جریان منطقه شستشو، انتقال رسوب ناشی از شرایط هیدرودینامیکی و مورفولوژی صورت ساحل پدیدار می‌شوند و به این ترتیب این نظریه توسط سایر محققین نیز مورد تایید قرار گرفته است (کوکو و همکاران، ۱۹۹۹ و ۲۰۰۳).

سونامورا (۲۰۰۴) گزارش داد که فاصله کومه‌های هلالی (cusp spacing) تحت تاثیر اندازه دانه‌های رسوبی است، چراکه فاصله کومه‌ها با مسیر جریان صعودی موج که در شاخ کومه هلالی واگرا می‌شود، ارتباط نزدیکی دارد. از طرفی مسیر این جریان صعودی تحت تاثیر اندازه دانه‌های رسوبی است. این محقق معادله زیر را برای پیش‌بینی فاصله کومه‌ها ( $\lambda_c$ ) ارائه داده است:

$$\lambda_c = A\phi T\sqrt{gh} \quad (5)$$

که  $h$  ارتفاع موج نزدیک به ساحل (nearshore zone) و  $T$  دوره تناوب موج است.  $\phi$  یک کمیت بدون بعد است که نشان دهنده اندازه دانه رسوبی است و  $A$  ثابتی است که برابر با  $1/35$  تخمین زده شده است.

با توجه به سابقه تحقیق آشکار است فرآیندهای فیزیکی که فاصله کومه‌های هلالی ساحل را تعیین می‌کنند هنوز کاملاً مشخص نیستند (سونامورا، ۲۰۰۴) و از طرفی روش‌هایی که برای بررسی و اخذ اطلاعات مورفودینامیکی از ساحل مورد استفاده قرار می‌گیرند در حالت ایده‌آل، باید دقیق، سریع و کم‌هزینه باشند (شرت، ۲۰۱۹). لذا در این پژوهش از قابلیت بالای شبکه عصبی برای پیش‌بینی فواصل بین کومه‌های هلالی ساحل استفاده شده است و به همین

عددی به دست آمده توسط ناتز و همکاران (۲۰۲۱) مورد مقایسه قرار گرفت. به این ترتیب صحت توانایی شبکه عصبی مصنوعی به منظور پیش‌بینی دینامیک یک سیستم کومه‌های هلالی چند سطحی ارزیابی و بررسی شد.

## ۱-۲ توصیف منطقه مورد مطالعه

محل ساحل مورد مطالعه در لانگ استرند (Long Strand) ایرلند می‌باشد. این ساحل در جنوب غربی ایرلند در خلیج راسکربی (Rosscarbery) واقع شده است و تقریباً ۱/۸ کیلومتر طول دارد. این ساحل، ساحلی شنی با رسوباتی متشکل از کوارتز است. بخشی از ساحل شیبی نسبتاً یکنواخت و منظم دارد ( $\tan\beta=0.03$ ) و بخشی دیگر ساحل دارای شیبی تند ( $\tan\beta=0.11$ ) است. یک سیستم تپه‌ای گسترده در پشت ساحل وجود دارد که از عرض ۱۵۰ متر در غرب تا ۲۵۰ متر در شرق متغیر است. لانگ استرند ایرلند یک ساحل بازتابان (reflective) با انرژی موج متوسط (میانگین ارتفاع موج قابل توجه  $H_s=1.3$  متر، متوسط پریود موج  $T_p=10$  ثانیه) و عمدتاً ساحلی مزوتایدال (meso-tidal beach) است. مشاهدات میدانی از یک سیستم کومه‌های هلالی چند ترازه در این ساحل انجام شده است (شکل ۱).

## ۲-۲ مجموعه داده‌ها

در این مطالعه، از چهار مجموعه داده شامل فاصله بین کومه‌های هلالی، ارتفاع کومه‌ها (elevation cusp)، عمق کومه‌ها (cusp depth) و دامنه کومه‌ها (amplitude) استفاده شده است (شکل ۲). فاصله کومه‌ها ( $C_s$ ) به عنوان فاصله افقی در امتداد ساحل بین بالاترین نقطه برجستگی دو شاخ کومه‌های هلالی کنار هم تعریف می‌شود.

ارتفاع کومه ( $C_e$ ) فاصله بالاترین نقطه روی شاخ کومه هلالی از تراز میانگین آب دریا (MSL) است. عمق کومه


پروپجیشن (Gradient descent with momentum backpropagation-gdm)، کواسی نیوتن- (Quasi-newton-bfg)، گرادینت دیسنت بگ پروپجیشن (Gradient descent backpropagation-gd)، گرادینت دیسنت ویت آدپتو لرنینگ ریت (Gradient descent with adaptive learning rate-gda) در لایه پنهان انتخاب شدند و در الگوریتم EBP پنج تابع مختلف (گرادینت دیسنت ویت ممنت اند ادپتو لرنینگ ریت) (Gradient descent with momentum and adaptive learning rate backpropagation-gdx) گرادینت دیسنت بگ پروپجیشن، گرادینت ویت ممنت بگ پروپجیشن، بیسین رگیولیشن و گرادینت دیسنت ویت آدپتو لرنینگ ریت) مورد ارزیابی قرار گرفتند. سپس در هر مرحله (epoch number) معیارهای آماری مرتبط محاسبه و مورد مقایسه واقع شد.

سپس در مرحله بعدی هر کدام از معیارها به تفکیک برای نوروها و توابع مختلف در سه مرحله آموزش، آزمون و ارزیابی مورد ارزیابی قرار گرفتند. به این ترتیب مدل بهینه به همراه تعداد نوروهای مطلوب و توابع مناسب برای پیش‌بینی فواصل بین کومه‌های هلالی انتخاب شد. هم‌زمان برای هر تابع خاص، روند تغییرات هر معیار و زمان تحلیل شبکه نیز در مراحل مختلف مورد بررسی قرار گرفت. در گام بعدی میزان دقت مدل بهینه شبکه عصبی در هر کدام از ترازهای سیستم کومه‌های هلالی مورد مقایسه قرار گرفت و بخش‌هایی از ساحل که مطلوب‌ترین نتایج را در خروجی شبکه عصبی ارائه داده بودند معرفی شد.


به منظور مدل‌سازی شبکه عصبی مصنوعی در این پژوهش از نرم‌افزار متلب نسخه ۲۰۱۹ استفاده شده است. این نرم‌افزار که در برگیرنده شبکه‌های متفاوت با قوانین یادگیری مختلف است، امکان طراحی و ارزیابی شبکه‌های عصبی مصنوعی را فراهم می‌کند. در مرحله نهایی نتایج به دست آمده با استفاده از شبکه عصبی مصنوعی با نتایج

هوایی بدون سرنشین (Unmanned Aerial Vehicle) هوایی بدون سرنشین بین ماه مارس و سپتامبر ۲۰۱۹ در سواحل جنوب غربی ایرلند انجام گرفت. در این مطالعه ۸۰ درصد از داده‌های موجود برای آموزش و ۲۰ درصد داده‌های باقی مانده برای مقایسه با داده‌های پیش‌بینی شده شبکه عصبی استفاده می‌شود (ماندال و پرابهاران، ۲۰۰۶).

هلالی ( $C_d$ ) فاصله بالاترین نقطه در شاخ کومه تا محدوده سیر شستشوی موج در فرورفتگی (bay) کومه هلالی است و دامنه کومه ( $C_a$ ) به عنوان حداکثر اختلاف ارتفاع شاخ کومه و فرورفتگی کومه هلالی تعریف می‌شود (نولان و همکاران، ۱۹۹۹). بررسی‌ها از یک سیستم کومه‌های هلالی چند ترازه در یک عملیات میدانی با یک سیستم وسیله نقلیه



شکل ۱. (الف) تصویر ماهواره‌ای از منطقه مورد مطالعه (برگرفته از گوگل ارث) (ب) نتایج یک مدل دیجیتالی سطحی در نرم‌افزار ArcMap 10.6. خط‌چین‌های (۱)، (۲) و (۳) به ترتیب نشان‌دهنده برش‌های طولی تراز بالایی، میانی و پایینی کومه‌های ساحلی هستند (ناتز و همکاران ۲۰۲۱).



شکل ۲. طرح کلی از پارامترهای کومه‌های هلالی ساحلی.

جدول ۱. بخشی از پارامترهای ثبت شده از کومه‌های هلالی در مشاهدات میدانی (ناتز و همکاران، ۲۰۲۱).

عمق کومه (متر)	ارتفاع کومه (متر)	دامنه کومه (متر)	فاصله بین کومه‌ها (متر)	ترازها	تاریخ
۱۶/۹۱	۵/۴۱	۰/۸۶	۳۹/۵	تراز بالایی	۲۶ مارس
۱۶/۵۷	۳/۱۴	۰/۵۸	۳۸/۵	تراز میانی	
-	-	-	-	تراز پایینی	
۱۵/۰۱	۵/۴۶	۰/۸۳	۴۰/۳	تراز بالایی	۱۰ آوریل
۱۲/۳۱	۲/۸۱	۰/۳۴	۲۴/۶	تراز میانی	
۹/۸۷	۱/۹۱	۰/۲۵	۱۱/۵	تراز پایینی	
۱۴/۹۸	۵/۶۲	۰/۸۷	۳۹/۲	تراز بالایی	۱۱ آوریل
۱۲/۶۹	۲/۷۶	۰/۴۳	۲۵/۰	تراز میانی	
-	-	-	-	تراز پایینی	
۱۵/۶۷	۴/۸۷	۱/۰۵	۳۸/۹	تراز بالایی	۰۱ مه
۹/۰۶	۲/۳۳	۰/۲۱	۱۴/۹	تراز میانی	
۶/۰۱	۲/۰۸	۰/۳۲	۱۱/۶	تراز پایینی	
۱۳/۲۴	۵/۶۹	۰/۸۱	۳۷/۷	تراز بالایی	۰۲ مه
۸/۸۱	۲/۴۲	۰/۲۳	۱۲/۸	تراز میانی	
۲/۷۳	۱/۰۳	۰/۰۴	۱۲/۳	تراز پایینی	
۱۲/۳۲	۵/۶۸	۰/۷۹	۳۷/۹	تراز بالایی	۱۰ مه
۸/۵۵	۲/۹۶	۰/۲۹	۱۹/۹	تراز میانی	
۸/۹۷	۱/۸۲	۰/۱۸	۱۶/۵	تراز پایینی	

جدول ۲. پارامترهای آماری برای ترازهای مختلف سامانه کومه‌های هلالی (ناتز و همکاران، ۲۰۲۱).

خواص آماری	تراز بالایی	تراز میانی	تراز پایینی
بیشینه (متر)	۴۹/۹	۳۸/۵	۱۶/۷
کمینه (متر)	۳۷/۷	۱۱/۱	۶/۵
میانگین (متر)	۴۰/۲۶	۱۸/۱۷	۱۱/۰۹
انحراف معیار (متر)	۰/۹۵	۵/۴۸	۲/۹۱
ضریب تغییر	۰/۰۲	۰/۳۰	۰/۲۶


## ۲-۳ مدل شبکه عصبی

شده‌اند و از طریق وزن‌ها (weights) به هم متصل می‌شوند. وزن‌ها از نظر مفهومی رابط بین نورون‌هایی هستند که در طول تمرین و پیش‌بینی فعال می‌شوند. شبکه عصبی از سه لایه به عنوان لایه‌های ورودی (input layer)، پنهان (hidden layer) و خروجی (output layer) تشکیل شده است. داده‌های ورودی از طریق شبکه عصبی تا زمانی که یک خروجی در لایه انتهایی به دست آید، منتقل می‌شوند و عمل می‌کنند. هر نورون ورودی‌های زیادی را از نورون‌های دیگر از طریق اتصالات وزنی دریافت

شبکه عصبی یک روش محاسباتی نرم در حل مسائل مختلف و در قالب سیستمی هوشمند است که ظرفیت یادگیری، بخاطر سپاری و ایجاد روابط بین داده‌های مختلف را دارد. در واقع شبکه عصبی بر اساس شبیه‌سازی مغز انسان، برای مدل‌سازی سیستم‌های مختلف از جمله سیستم‌های غیرخطی، پویا، نویزدار و پیچیده، به طور ایده‌آل عمل می‌کند. ساختمان شبکه عصبی از نورون‌هایی تشکیل شده است که در گروه‌هایی به نام لایه‌ها مرتب

پس انتشار خطا به گونه‌ای استفاده می‌شود که نورون‌ها وزن خود را برای به دست آوردن اطلاعات جدید انطباق می‌دهند (باده و همکاران، ۲۰۰۹ و اشמידهوبر، ۲۰۱۵).

یادگیری در این نوع از شبکه عصبی در طول مرحله آموزش اتفاق می‌افتد و در این یادگیری هر الگوی ورودی از مجموعه آموزش به لایه ورودی اعمال می‌شود و به جلو پیش می‌رود؛ سپس الگوی فعال‌سازی رسیده به لایه خروجی با الگوی صحیح خروجی مورد مقایسه قرار می‌گیرد تا سرانجام سیگنال خطا محاسبه گردد. این سیگنال خطا برای هر کدام از الگوهای خروجی هدف از لایه خروجی به نورون‌های ورودی برای تنظیم وزن لایه‌ها در شبکه به عقب انتشار پیدا می‌کند. پس از مرحله آموزش، شبکه عصبی نحوه طبقه‌بندی درست را برای مجموعه‌ای از ورودی‌ها می‌آموزد که از آن در مجموعه ثانویه از نمونه‌ها که همان مجموعه آزمون است برای بررسی میزان دقت طبقه‌بندی الگوهای جدید مورد استفاده قرار گیرد؛ بنابراین در استفاده از یادگیری پس‌انتشار خطا، میزان دقت تعمیم شبکه اهمیت دارد (شکل ۳).



شکل ۳. معماری شبکه عصبی در مدل FFBP.

می‌کند. این نوع ورودی‌ها با وزن بیشتر اضافه می‌شوند تا تابع انتقال خطی و لجستیکی و در نهایت، خروجی نهایی نورون را تولید کنند (هیکنین، ۲۰۰۸؛ ونکاترامانان و همکاران، ۲۰۱۷ و ساهین و وردار، ۲۰۲۰).

تابع درون نورون با معادله زیر داده می‌شود:

$$y_j = \sum_{i=1}^n w_{ij}x_i + b_j \quad (6)$$

که  $x_i$  پارامترهای ورودی،  $w_{ij}$  وزن‌های مرتبط با هر اتصال ورودی هستند، و  $b_j$  بایاس (bias)، شرکت یافته مرتبط با نورون  $j$  است. همچنین مجموع  $y$ ها از تابع سیگموئید غیرخطی می‌گذرد. در نهایت مقادیر خروجی لایه پنهان، مقادیر ورودی لایه سوم شبکه (به نام لایه خروجی) را شکل می‌دهند (بیل و جکسون، ۱۹۹۰؛ کینر و یان، ۱۹۹۸ و وانگ و همکاران، ۲۰۰۹).

### ۲-۳-۱ شبکه عصبی پس انتشار (BP)

پس انتشار یا عملیات انتشار رو به عقب یک روش یادگیری شبکه‌های عصبی است. یادگیری پس انتشار یک فرآیند جستجوی تکراری است که وزن‌ها را از لایه خروجی به لایه ورودی در هر اجرا تنظیم می‌کند تا زمانی که بهبود بیشتری در مقدار خطا پیدا نشود.

در واقع الگوریتم BP میزان خطا را محاسبه می‌کند، سپس برای تنظیم وزن‌ها ابتدا در لایه خروجی و سپس توزیع آن به عقب از خروجی به عنوان گره‌های پنهان و ورودی استفاده می‌شود.

### ۲-۳-۱-۱ شبکه عصبی پس انتشار پیشرو (FFBP)

شبکه عصبی پس انتشار پیشرو، پایه‌ای‌ترین و ساده‌ترین نوع شبکه عصبی مصنوعی است. در این شبکه کلیه نورون‌ها در لایه ورودی به نورون‌های لایه پنهان و کلیه نورون‌های در لایه پنهان به نورون‌های لایه خروجی متصل است. در شبکه عصبی پس انتشار پیشرو برای یادگیری از الگوریتم

نورون‌ها در لایه‌های مجاور از طریق وزن‌دهی به بقیه متصل می‌شوند. گره‌های منفرد ورودی را از گره‌های متصل دریافت می‌کنند و از وزن‌ها همراه با یک تابع ساده برای محاسبه مقادیر خروجی استفاده می‌کنند. باید توجه داشت که گره‌های درون یک لایه معماری شبکه به یکدیگر متصل هستند.

در روابط زیر  $x_i$  ( $i=1, \dots, m$ ) نشانگر بردار ورودی،  $y_k$  نمایانگر خروجی شبکه عصبی المان (ENN) و مقادیر  $z_j$  ( $j=1, \dots, n$ ) خروجی لایه پنهان است.  $b_k$  و  $b_j$  به ترتیب بایاس‌ها در لایه پنهان و لایه خروجی هستند.  $u_j$  نورون‌های لایه زمینه را نشان می‌دهد،  $w_{ij}$  وزنی است که بین گره‌های ورودی ( $i$ ) و گره‌های پنهان ( $j$ ) اتصال برقرار می‌کند.  $c_j$  نشان دهنده وزنی است که بین گره‌های پنهان و گره‌های زمینه اتصال برقرار می‌کند.  $v_{jk}$  وزنی است که گره  $j$  در لایه پنهان را به گره‌های خروجی متصل می‌کند.

(۷)

$$net_j(t) = \sum_{i=1}^m w_{ij} x_i(t-1) + \sum_{j=1}^n c_j u_j(t) + b_j$$

$z_j$  مقدار گره لایه زمینه است که توسط رابطه زیر محاسبه می‌شود.

$$u_j(t) = z_j(t-1) \quad (۸)$$

تابع فعال سازی انتخاب شده در لایه پنهان تابع سیگموئید است که به صورت زیر ارائه می‌شود:

$$z_j(t) = f(net_j(t)) \quad (۹)$$

$$f(x) = \frac{1}{(1 + e^{-x})}$$

خروجی ENN به شرح زیر است:


$$net_k(t) = \sum_{j=1}^n v_{jk} z_j(t) + b_k \quad (۱۰)$$

$$y_k(t) = f(net_k(t))$$

معماری ENN در شکل ۵ ارائه شده است.

### ۲-۳-۱-۲ شبکه عصبی پس‌انتشار آبخاری پیشرو (CFBP)

مدل انتشار پس‌انتشار آبخاری پیشرو شبیه شبکه‌های پیشرو است، اما شامل یک اتصال وزنی از ورودی به هر لایه و از هر لایه به لایه‌های متوالی بعدی است (شکل ۴). در حالی که شبکه‌های پیشرو دو لایه، به طرز بالقوه‌ای می‌توانند تقریباً هر رابطه ورودی و خروجی را یاد بگیرند، شبکه‌های پیشرو با لایه‌های بیشتر ممکن است روابط پیچیده را سریعتر یاد بگیرند. مدل آبخاری پیشرو با پس‌انتشار خطا شبیه به شبکه عصبی انتشار به عقب در استفاده از الگوریتم انتشار برگشتی برای به‌روزرسانی وزن‌ها است، اما نشانه اصلی این شبکه این است که هر لایه از نورون‌ها به تمام لایه‌های قبلی نورون‌ها مربوط می‌شود (هووارد و مارک، ۲۰۰۴ و باده و همکاران، ۲۰۰۹).



شکل ۴. معماری شبکه عصبی در مدل CFBP

### ۲-۳-۱-۳ شبکه عصبی پس‌انتشار المان (ElmanBP)

شبکه عصبی پس‌انتشار المان نوعی شبکه عصبی چند سطحی با بازخورد رو به جلو است که ساختار توپولوژی آن در شکل ۵ نشان داده شده است. در این شکل آشکار است که چهار نوع لایه عصبی وجود دارد (یعنی یک لایه ورودی، چندین لایه پنهان، چندین لایه بازخورد یا زمینه (context layer) و یک لایه خروجی) و در هر سطح،



میدانی و  $\bar{P}_m$  میانگین مقادیر خروجی محاسبه شده از نتایج شبکه عصبی است.

یکی از معیارهای ارزیابی، دامنه ضریب کارایی (CE) است که هرچه مقدار آن به یک نزدیک باشد نمایانگر ایده‌آل بودن مدل است. مقدار ضریب همبستگی (R) همواره بین ۱- تا ۱ است و مقدار ۱ نمایانگر پیش‌بینی بدون خطا می‌باشد.


مقادیر مجذور میانگین مربعات خطا (RMSE) همواره به صورت نرمال می‌باشد و نزدیک شدن به صفر نمایانگر دقت زیاد در پیش‌بینی مدل است. همچنین شاخص پراکندگی (SI) نشان‌دهنده درصد پراکندگی داده‌های پیش‌بینی شده نسبت به داده‌های واقعی است و مقدار صفر بیانگر عدم پراکندگی در نتایج حاصل از پیش‌بینی مدل‌های شبکه عصبی است.

### ۳ نتایج و بحث

#### ۳-۱ مشاهدات شبکه عصبی

در مدل‌های مختلف به منظور بررسی دقت نتایج پیش‌بینی شده مقادیر مربوط به معیارهای آماری از یک تا بیست نورون براساس روابط حاکم بر توابع مختلف با استفاده از نرم‌افزار متلب استخراج شده است. شکل ۶ در مدل CFBP و شکل ۷ در مدل FFBP روند تغییرات پارامتر R را به طور نمونه تحت تابع gdm با ۱۹ نورون در سه مرحله آزمون، آموزش و ارزیابی نشان می‌دهد.

شکل ۸ به طور نمونه نتایج مدل FFBP را به صورت روند تغییرات پارامتر CE در نورون‌های مختلف تابع gda نشان می‌دهد. لازم به ذکر است در هر سه مدل شبکه عصبی هم‌زمان با انتخاب بهترین نتیجه در هر تابع خاص، روند تغییرات هر معیار خاص و زمان تحلیل شبکه عصبی در مراحل متفاوت مورد ارزیابی قرار گرفت (شکل‌های ۹ و ۱۰).



شکل ۵. معماری شبکه عصبی در مدل ENN.

#### ۲-۳-۲ ارزیابی مدل

به منظور بررسی و مقایسه نتایج پیش‌بینی مدل با مشاهدات میدانی، از پنج شاخص، ضریب کارایی (CE)، ضریب همبستگی (R)، مجذور میانگین مربعات خطا (RMSE)، شاخص پراکندگی (SI) و میانگین مربعات خطا (MSE)، که به ترتیب در روابط ۱۱ تا ۱۵ آورده شده، استفاده شده است:

$$CE = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O}_m)^2} \quad (11)$$

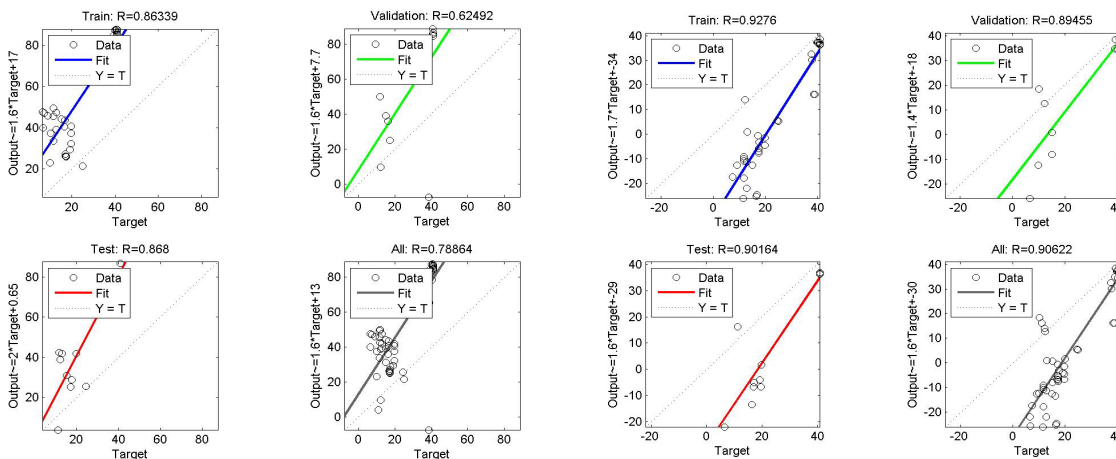
$$R = \frac{\sum_{i=1}^N (O_i - \bar{O}_m) \sum_{i=1}^N (P_i - \bar{P}_m)}{\sqrt{\sum_{i=1}^N (O_i - \bar{O}_m)^2} \sqrt{\sum_{i=1}^N (P_i - \bar{P}_m)^2}} \quad (12)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (13)$$

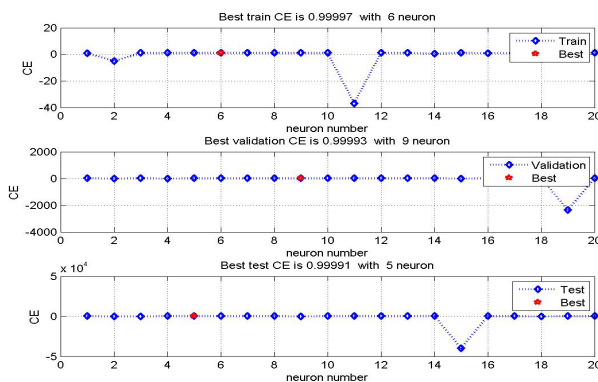
$$SI = \frac{RMSE}{\text{avrage observed value}} \quad (14)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \quad (15)$$

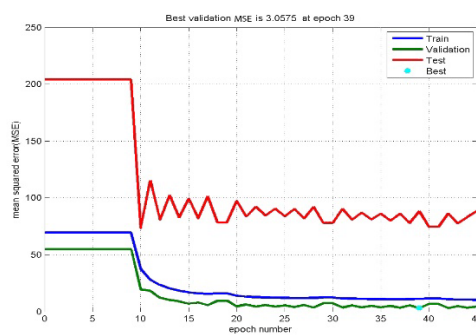
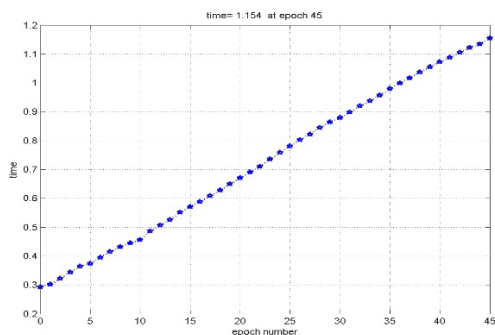
در روابط بالا N معرف تعداد کل داده‌ها،  $O_i$  مقدار مشاهده شده از مطالعات میدانی،  $P_i$  مقدار پیش‌بینی حاصل از نتایج شبکه عصبی،  $\bar{O}_m$  میانگین مقادیر مشاهده شده از مطالعات



شکل ۶. تغییرات پارامتر R در مدل CFBP با ۱۹ نورون و اجرای تابع gdm. شکل ۷. تغییرات پارامتر R در مدل FFBP با ۱۹ نورون و اجرای تابع gdm.



شکل ۸. تغییرات پارامتر CE در نورون‌های مختلف و اجرای تابع gda در سه مرحله آموزش، ارزیابی و آزمون مدل FFBP.



شکل ۹. تغییرات پارامتر MSE با تعداد مراحل، مدل FFBP-تابع gda (۱۲ نورون).

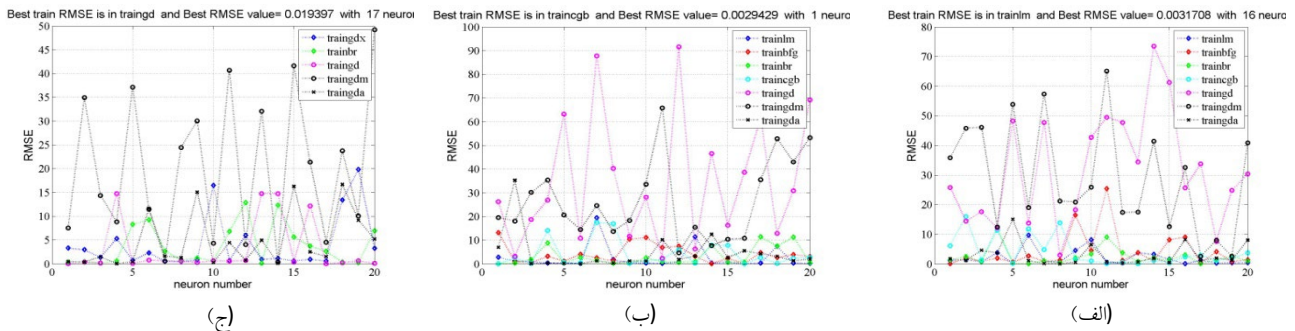
شکل ۱۰. تغییرات زمان با تعداد مراحل، مدل FFBP-تابع gda (۱۲ نورون).

مجدور خطا (MSE) در سه مدل مختلف CFBP, FFBP و ElmanBP در مراحل مختلف آموزش، آزمون و ارزیابی استخراج شد. شکل ۱۱ و ۱۲ به طور نمونه روند تغییرات معیار سنجش RMSE و R را با افزایش تعداد

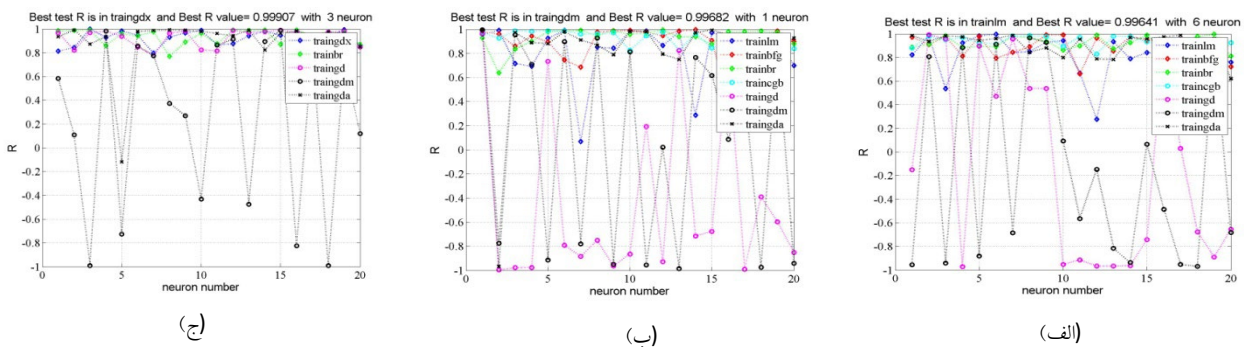
سرانجام نتایج بهینه مشاهدات شبکه عصبی با ارزیابی هر یک از معیارهای آماری ضریب کارایی (CE)، ضریب همبستگی (R)، مجدور میانگین مربعات خطا (RMSE)، شاخص پراکندگی (SI) و میانگین

انتخاب شده برای مقایسه در شکل ۱۳ نشان دهنده بیشترین دقت در مدل ElmanBP با تابع  $gd$  و  $MSE=0.1769$  نسبت به دو مدل دیگر است. جدول ۳ نتایج مقادیر بهینه معیارهای آماری در مدل‌های مختلف را نشان می‌دهد.

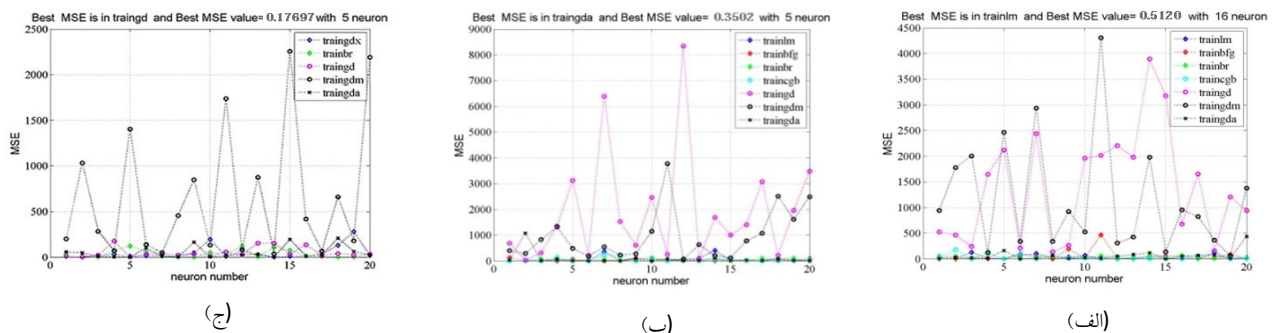
نورون‌ها در مرحله آموزش و آزمون برای توابع مختلف مدل‌های مورد بررسی نشان می‌دهد. در نهایت روند تغییرات کلی معیارهای آماری در توابع و نورون‌های مختلف مربوط به کل شبیه سازی استخراج شد. مقایسه روند تغییرات معیار  $MSE$  به عنوان معیار اصلی



شکل ۱۱. روند تغییرات پارامتر RMSE در توابع و نورون‌های مختلف مربوط به نتایج آموزش (الف) مدل CFBP (ب) مدل FFBP (ج) مدل ElmanBP



شکل ۱۲. روند تغییرات پارامتر R در توابع و نورون‌های مختلف مربوط به آزمون (الف) مدل CFBP (ب) مدل FFBP (ج) مدل ElmanBP



شکل ۱۳. روند تغییرات پارامتر MSE در توابع و نورون‌های مختلف مربوط به کل شبیه سازی (الف) مدل CFBP (ب) مدل FFBP (ج) مدل ElmanBP

۶ و ۸ رسم شده است، حاکی از آن است که در مراحل مختلف ارزیابی، آزمون و آموزش در مدل ElmanBP به


مطالعه شکل‌های ۱۴ و ۱۵ از طریق بررسی نمودارهای راداری مربوط به معیار R که به طور تصادفی در نورون‌های

دیگر، بررسی شکل های ۱۶ و ۱۷ که نشانگر نمودار راداری مربوط به معیار MSE است که به طور تصادفی در نوروں های ۸ و ۱۶ انتخاب شده حاکی از آن است که در مدل ElmanBP تابع gdm دارای کمترین دقت و توابع gd و br دارای بیشترین دقت می باشد در حالیکه در مدل های


جز تابع gdm، مقادیر R در تقریباً تمام توابع نزدیک به یک و دارای دقت قابل ملاحظه ای هستند. در حالیکه در مدل های CFBP و FFBP مقادیر R برای تابع gd دارای مقادیر حول صفر و حتی منفی است و در سایر توابع مقادیر R به طور تقریبی در محدوده یک هستند. از طرف

جدول ۳. نتایج مقادیر بهینه معیارهای آماری در مدل های مختلف.


معیار آماری	تابع			مقدار معیار آماری			نورون			نتایج
	CFBP	FFBP	ELMANBP	CFBP	FFBP	ELMANBP	CFBP	FFBP	ELMANBP	
RMSE	br	br	gd	۰/۰۶۶۸۴	۰/۰۴۵۰۶۵	۰/۰۴۱۲۱	۷	۵	۸	آزمون
MSE	br	br	gd	۰/۰۰۴۴۶۷۵	۰/۰۰۲۰۳۰۹	۰/۰۰۱۶۹۸	۷	۵	۸	
SI	br	br	gd	۰/۰۰۲۷۴۰۳	۰/۰۰۲۱۷۰۹	۰/۰۰۱۶۹۲	۷	۵	۸	
CE	gd	gd	gdm	۰/۵۳۱۲۶	۰/۵۹۵۵۴	۰/۹۸۳۲۴	۹	۱۳	۷	
R	lm	gdm	gdx	۰/۹۹۶۴۱	۰/۹۹۶۸۲	۰/۹۹۹۰۷	۶	۱	۳	
RMSE	lm	cgb	gd	۰/۰۰۳۱۷۰۸	۰/۰۰۲۹۴۲۹	۰/۰۱۹۳۹	۱۶	۱	۱۷	آموزش
MSE	lm	cgb	gd	۰/۰۰۰۰۱	۰/۰۰۰۰۰۸	۰/۰۰۰۳۷	۱۶	۱	۱۷	
SI	lm	cgb	gd	۰/۰۰۰۱۲۲۷۷	۰/۰۰۰۱۲۴۶۹	۰/۰۰۰۷۶۴	۱۶	۱	۱۷	
CE	gd	gdm	gdx	۰/۹۵۳۴۶	۰/۹۱۰۶۸	۰/۹۹۹۲۳	۸	۱۲	۸	
R	lm	lm	br	۰/۹۹۹۴۶	۰/۹۹۷۷	۰/۹۹۱۹۶	۱۶	۱۰	۸	
RMSE	br	lm	br	۰/۰۳۵۹۲۱	۰/۱۰۴۰۵	۰/۰۸۱۳۹	۷	۱	۹	ارزیابی
MSE	br	lm	br	۰/۰۰۱۲۹۰	۰/۰۱۰۸۲۵	۰/۰۰۶۶۲۵	۷	۱	۹	
SI	gda	br	br	۰/۰۰۱۳۴۲	۰/۰۰۳۹۸۶۹	۰/۰۰۳۳۵۸	۷	۹	۱۲	
CE	gdm	gdm	gdm	۰/۸۳۶۲۵	۰/۵۰۵۹۲	۰/۹۹۸۳	۱۹	۹	۱۳	
R	lm	lm	br	۰/۹۹۸۷۶	۰/۹۹۷۵۳	۰/۹۹۷۴۶	۱۷	۶	۶	
MSE	lm	gda	gda	۰/۵۱۲۰۴	۰/۳۵۰۲۰	۰/۱۷۶۹۷	۱۶	۵	۵	کل




شکل ۱۴. نمودار راداری مربوط به معیار R در توابع مختلف (نورون ۸) مدل های شبکه عصبی الف) CFBP ب) FFBP و ج) ElmanBP.



شکل ۱۵: نمودار راداری مربوط به معیار R در توابع مختلف (نورون ۶) مدل‌های شبکه عصبی الف) CFBP ب) FFBP و ج) ElmanBP




شکل ۱۶: نمودار راداری مربوط به معیار MSE در توابع مختلف (نورون ۸) مدل‌های شبکه عصبی الف) CFBP ب) FFBP و ج) ElmanBP



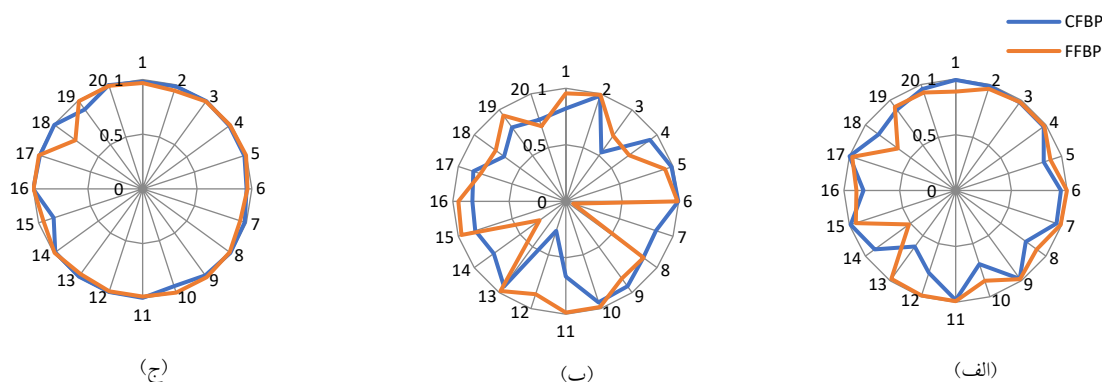
شکل ۱۷: نمودار راداری مربوط به معیار MSE در توابع مختلف (نورون ۱۶) مدل‌های شبکه عصبی الف) CFBP ب) FFBP و ج) ElmanBP

شکل‌های ۱۸ و ۱۹ مورد مقایسه قرار گرفتند. نتایج حاصل مقایسه این شکل‌ها حاکی از آن است که در مدل‌های CFBP و FFBP تابع gd دارای کمترین دقت است. این در حالی است که همین تابع در مدل ElmanBP دارای دقت بالایی در کلیه نورون‌هاست. بنابراین مجدداً این امر تأیید می‌شود که توابع، بسته به نوع مدل انتخاب شده دقت متفاوتی در نتایج پیش‌بینی شده، ارائه می‌دهند. مقایسه نمودار راداری

CFBP و FFBP توابع gdm و gd دارای کمترین دقت و تابع lm دارای بیشترین دقت در روش‌های CFBP و FFBP است. بنابراین ممکن است توابع مختلف در مدل‌های متفاوت، عملکرد مشابهی از لحاظ میزان دقت نتایج ارائه ندهند. نمودار راداری مربوط به معیار R در نورون‌های مختلف تابع gd و تابع lm در مدل‌های مختلف شبکه عصبی در



شکل ۱۸: نمودار راداری مربوط به معیار R در نورون‌های مختلف (تابع gd) مدل‌های شبکه عصبی (الف) ارزیابی (ب) آزمون (ج) آموزش.



شکل ۱۹: نمودار راداری مربوط به معیار R در نورون‌های مختلف (تابع lm) مدل‌های شبکه عصبی (الف) ارزیابی (ب) آزمون (ج) آموزش.

شکل ۲۰ نشان می‌دهد، به طور نمونه، در تراز میانی سیستم کومه‌های هلالی ساحل، فاصله پیش‌بینی شده کومه‌ها طبق نتایج شبکه عصبی ( $R^2=0.79$ ) دقت بالاتری نسبت به نتایج بدست آمده از شبیه‌سازی عددی ناتز و همکاران (۲۰۲۱) با  $R^2=0.72$  ارائه می‌دهد. این مطلب نشانگر برتری مطالعات شبکه عصبی در مقایسه با نتایج بدست آمده با استفاده از مدل‌سازی عددی است.

نمودارهای پراکندگی بر اساس فاصله پیش‌بینی شده کومه‌های هلالی بر اساس مدل CFBP (تابع بهینه lm) و سایر پارامترهای مورفولوژیکی سیستم کومه‌های هلالی بیانگر همبستگی قوی بین فواصل بین کومه‌های هلالی با کلیه پارامترهای مورفولوژیکی سیستم کومه‌های هلالی خصوصاً ارتفاع کومه‌های هلالی است (شکل ۲۱).

شکل ۲۲ مقادیر فواصل پیش‌بینی شده بین کومه‌های هلالی در مقابل مقادیر فواصل مشاهده شده در مطالعه میدانی در بخش‌های مختلف منطقه شستشو را در وجه ساحل نشان می‌دهد. مقایسه مقادیر معیارهای آماری حاکی از آن است

مربوط به معیار R در نورون‌های مختلف تابع lm در دو مدل CFBP و FFBP در مراحل ارزیابی، آزمون و آموزش نشانگر دقت بیشتر مدل FFBP نسبت به CFBP است.

### ۲-۳ مقایسه با داده‌های میدانی

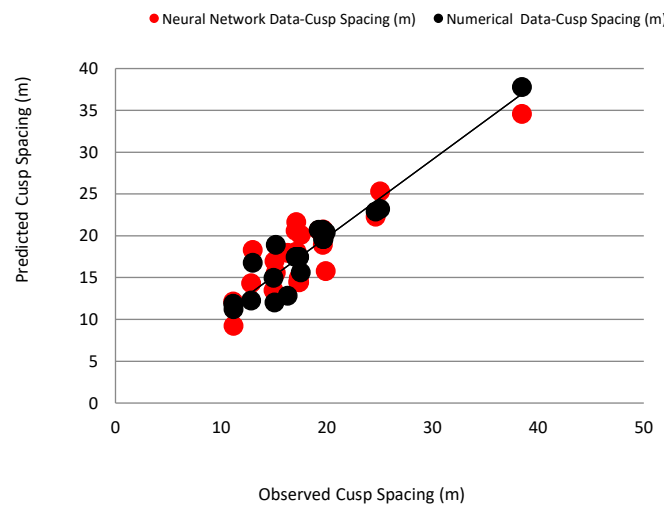
نتایج این پژوهش همچنین با مطالعات عددی انجام شده توسط ناتز و همکاران (۲۰۲۱) که به طور تصادفی برای مقایسه با تعدادی از داده‌های میدانی انتخاب شد، مورد مقایسه قرار گرفت.

از آنجاییکه در این پژوهش بالاترین دقت محاسبه شده در شاخص SI (نشانگر درصد پراکندگی داده‌های پیش‌بینی شده نسبت به داده‌های واقعی)، مربوط به مدل CFBP است و از طرفی در شاخص R تفاوت دو مدل CFBP و FFBP بسیار اندک است، پس علی‌رغم برتری اندک مدل FFBP نسبت به CFBP، از نتایج مدل CFBP برای مقایسه با نتایج مدل عددی ناتز و همکاران (۲۰۲۱) استفاده می‌کنیم. همانطور که نمودار پراکندگی


تعیین دقت بیشتر مد نظر قرار می‌دهیم. از آنجایی که کمترین مقدار MSE بیانگر کمترین اختلاف مقادیر پیش‌بینی شده و مشاهده شده است. مشاهده می‌شود مقادیر MSE در بخش بالایی ساحل کمترین مقدار را نشان می‌دهد که نشان دهنده کمترین تفاوت بین مقادیر پیش‌بینی شده از شبکه عصبی و مقادیر مشاهده شده از مطالعات میدانی در این بخش از منطقه شستشو است.

در کل بخش‌های منطقه شستشو دقت نتایج شبکه عصبی به ترتیب در مدل‌های ElmanBP، FFBP و CFBP بیشترین به کمترین مقدار را دارد.

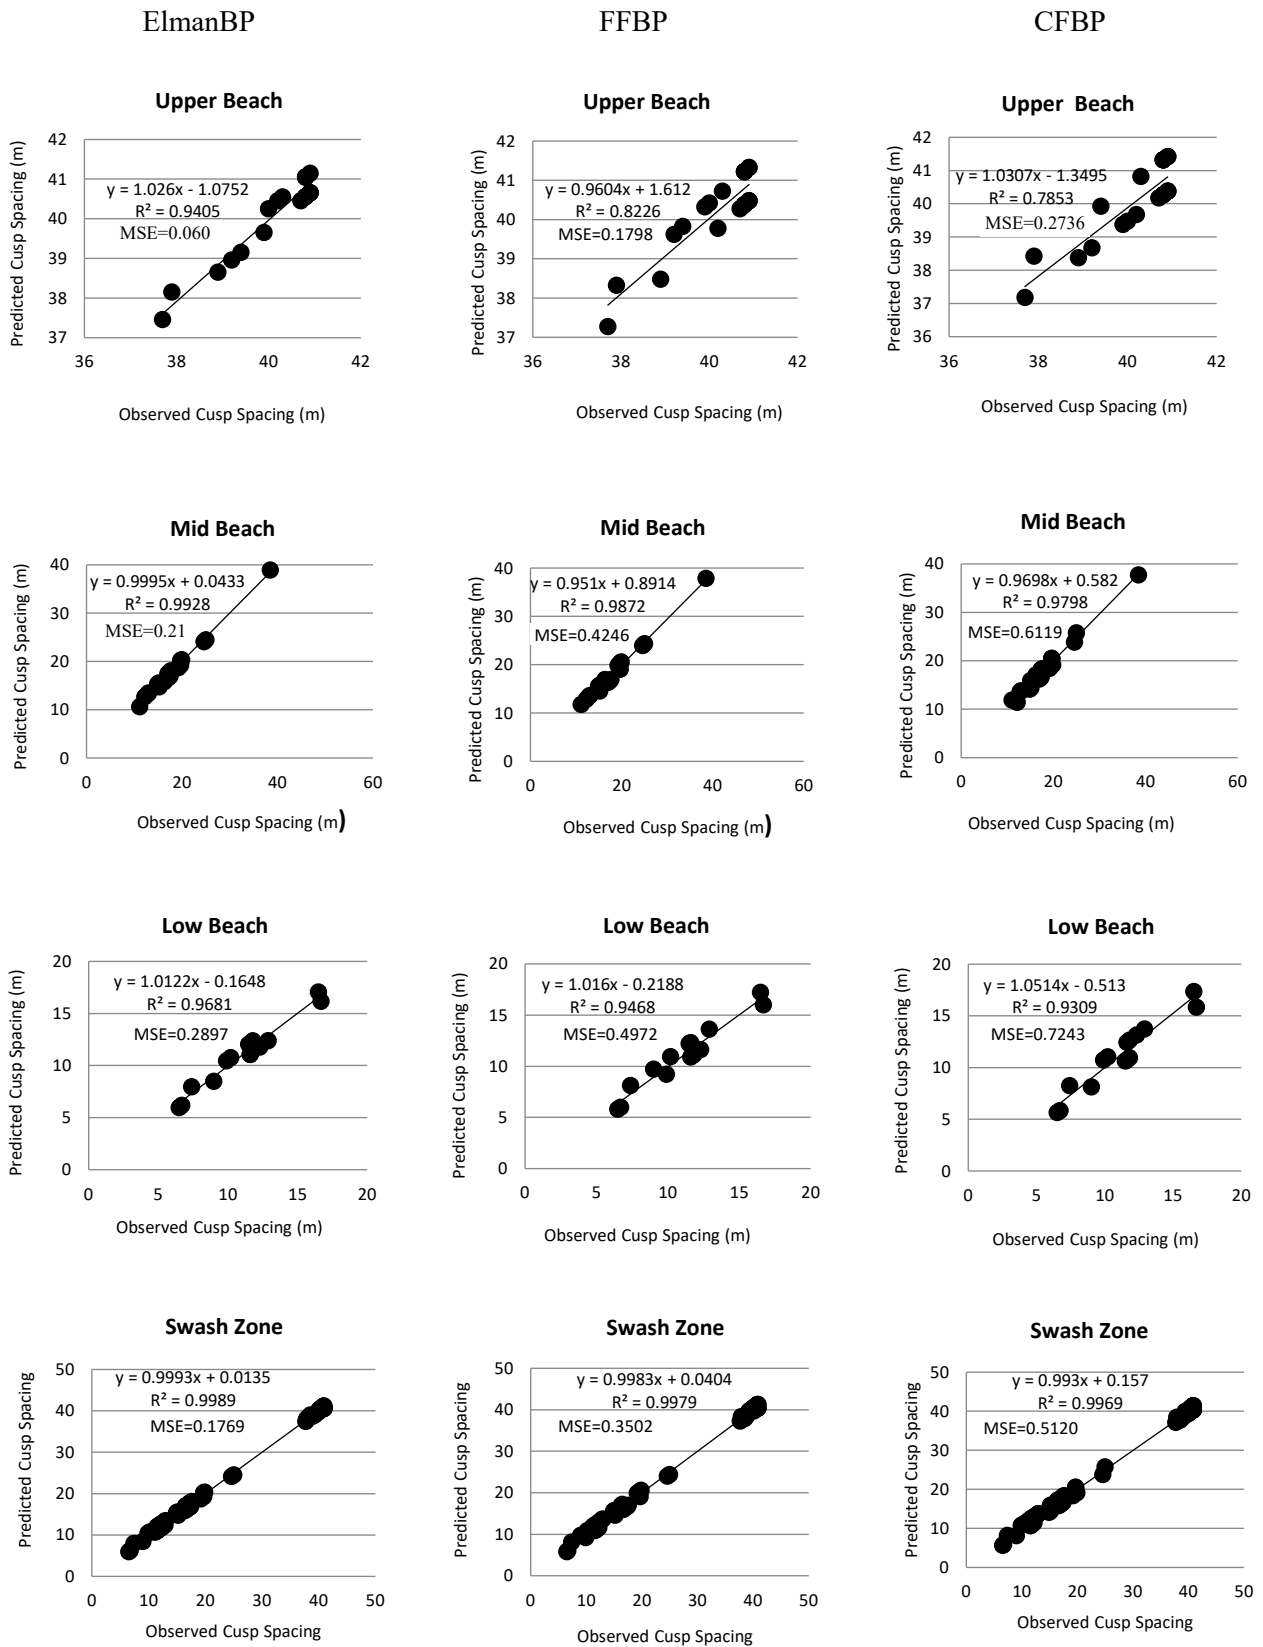
علی‌رغم مقایسه مقادیر ضریب تعیین  $R^2$  در بخش‌های مختلف منطقه شستشو و از آنجایی که هر چقدر مقادیر  $R^2$  به یک نزدیکتر باشد نشان دهنده تناسب بهتر بین پیش‌بینی‌های مدل و مشاهدات واقعی است. بنابراین معیار MSE را برای



شکل ۲۰. نمودار پراکندگی فاصله مشاهده شده در مقابل فاصله پیش‌بینی شده میان کومه‌ها، نقاط قرمز مقادیر داده‌های شبکه عصبی ( $R^2=0.79$ ) نقاط مشکی داده‌های مدل عددی ناتز و همکاران (۲۰۲۱) با دقت ( $R^2=0.72$ ) در تراز میانی سیستم کومه‌های هلالی.



شکل ۲۱. نمودارهای پراکندگی فاصله کومه‌های هلالی پیش‌بینی شده در محور X بر اساس روش CFBP (تابع بهینه  $lm$ ) و سایر پارامترهای کومه هلالی در محور Y، با (الف) عمق کومه هلالی، (ب) ارتفاع کومه هلالی و (ج) دامنه کومه هلالی.



شکل ۲۲. مقادیر فواصل پیش‌بینی شده بین کومه‌ها در مقابل مقادیر فواصل مشاهده شده در مطالعه میدانی در بخش‌های مختلف صورت ساحل و منطقه شستشو.



## ۴ نتیجه‌گیری

این مطالعه عملکرد سه مدل شبکه عصبی پس انتشار (BP) شامل مدل‌های شبکه عصبی پس انتشار پیشرو (FFBP)، شبکه عصبی پس انتشار آبخاری پیشرو (CFBP) و شبکه عصبی پس انتشار المان (EBP) را جهت پیش‌بینی فواصل بین کومه‌های هلالی در یک منطقه ساحلی در جنوب غربی ایرلند مورد مقایسه قرار می‌دهد. سه پارامتر از مجموعه پارامترهای مربوط به ویژگی‌های مورفودینامیکی صورت ساحل شامل ارتفاع کومه‌های هلالی ( $C_e$ )، عمق کومه‌ها ( $C_d$ ) و دامنه کومه‌ها ( $C_a$ ) به عنوان پارامترهای ورودی استفاده شده است. نتایج کلی این پژوهش گویای آن است که با استفاده از عوارض مورفودینامیکی مرتبط در یک منطقه‌ی در دسترس در وجه ساحل با کمک مدل‌های شبکه عصبی مصنوعی امکان پیش‌بینی سریع و دقیق رفتار سیستم کومه‌های هلالی چند ترازه در هر کدام از ترازهای منطقه شستشو فراهم می‌آید. از طرفی با توجه به روابط مستخرج از تئوری‌های حاکم بر پیش‌بینی فواصل بین کومه‌ها می‌توان تا حد زیادی به شرایط هیدرودینامیکی حاکم بر ساحل و در نتیجه حالت ساحل دسترسی پیدا کرد. همچنین این تحقیق آشکار می‌کند که نتایج مدل شبکه عصبی در کدام بخش از بخش‌های مختلف صورت ساحل با نتایج میدانی همخوانی بیشتری دارد. به طوری که یافته‌های زیر به طور خلاصه از این بررسی‌ها استخراج شده است:

۱- ارزیابی نمودارهای مربوط به روند تغییرات معیارهای آماری در مدل‌های مختلف شبکه عصبی در توابع و نورون‌های مختلف مربوط به کل شبیه سازی حاکی از آن است که دقت نتایج شبکه عصبی در مدل‌های ElmanBP، FFBP و CFBP به ترتیب بیشترین به کمترین مقدار است. مقایسه روند تغییرات معیار MSE به عنوان معیار اصلی انتخاب

شده برای مقایسه حاکی از آن است که بیشترین دقت در مدل ElmanBP با تابع gd و  $MSE=0.1769$  نسبت به دو مدل دیگر حاصل می‌شود.

۲- بررسی نمودارهای راداری مربوط به معیارهای مختلف آماری در مراحل مختلف نشان می‌دهد توابع، بسته به نوع مدل انتخاب شده دقت متفاوتی در نتایج پیش‌بینی شده، ارائه می‌دهند.

۳- نمودارهای پراکندگی مربوط به فاصله پیش‌بینی شده کومه‌ها توسط مدل CFBP تحت (تابع بهینه  $lm$ ) در مقابل سایر پارامترهای کومه‌های هلالی نمایانگر همبستگی قوی بین فواصل کومه‌ها با کلیه پارامترهای مورفولوژیکی سیستم کومه‌های هلالی خصوصا ارتفاع کومه‌ها در صورت ساحل است.

۴- مقایسه نمودارهای پراکندگی مربوط به مقادیر فواصل پیش‌بینی شده بین کومه‌های هلالی در مقابل مقادیر فواصل مشاهده شده در مطالعه میدانی در بخش‌های مختلف منطقه شستشو در وجه ساحل حاکی از آن است که میزان دقت حاصل از نتایج شبکه عصبی در ناحیه بالایی وجه ساحل دارای بیشترین مقدار است. این نتایج با نتایج بدست آمده توسط ناتز و همکاران (۲۰۲۱) که سطح پایینی را متأثر از جزرو مد معرفی کردند کاملا همخوانی دارد. زیرا در طول هر جزر و مد سطح پایینی سیستم کومه‌های هلالی کاملا در آب غوطه‌ور می‌شود و در معرض فرآیندهای انتقال رسوب در منطقه شستشو قرار می‌گیرد، بنابراین در طول اکثر چرخه‌های جزر و مدی الگوهای منظم جدیدی ظاهر می‌شوند.

۵- مقایسه نتایج این پژوهش با مطالعات عددی انجام شده توسط ناتز و همکاران (۲۰۲۱) نشان می‌دهد، به طور نمونه، در تراز میانی سیستم کومه‌های هلالی ساحل، فاصله پیش‌بینی

- Development of cusp-related, gravel size and shape facies at Malin Head, Ireland. *Sedimentology*, 40(6):1139–52.
- Kaneko, A., 1985, Formation of beach cusps in a wave tank. *Coast Eng*, 9(1):81–98.
- Seymour, R.J., Aubrey, D.G., 1985, Rhythmic beach cusp formation: A conceptual synthesis. *Mar Geol*, 65(3–4):289–304.
- Werner, B.T., Fink, T.M., 1993, Beach cusps as self-organized patterns. *Science*, 260(5110):968–71.
- Masselink, G., Pattiaratchi, C., 1997, Morphodynamic impact of sea breeze on a beach with beach cusp morphology. *J Coast Res*, 22:1139–1156.
- Coco, G., O'Hare, T.J., Huntley, D.A., 1999, Beach cusps: A comparison of data and theories for their formation. *J Coast Res*, 15(3):741–9.
- Coco, G., Burnet, T.K., Werner, B.T., Elgar, S., 2003, Test of self-organization in beach cusp formation. *J Geophys Res Ocean*, 108(3).
- Sunamura, T., 2004, A predictive relationship for the spacing of beach cusps in nature. *Coast Eng*, 51(8–9):697–711.
- Short, A.D., 2019, *Sandy Beach Morphodynamics* Edited [Internet], Available from: <https://www.barbadospocketguide.com/barbados-attractions/beaches-and-bays/south-coast-beaches/sandy-beach.html>
- Nuyts, S., Murphy, J., Li, Z., Hickey, K., 2020, A Methodology to Assess the Morphological Change of a Multilevel Beach Cusp System and their Hydrodynamics: Case Study of Long Strand, Ireland. *J Coast Res*, 95(sp1):593–8.
- Nuyts, S., Li, Z., Hickey, K., Murphy, J., 2021, Field observations of a multilevel beach cusp system and their swash zone dynamics. *Geosci*, 11(4):1–24.
- Nolan, T.J., Kirk, R.M., Shulmeister, J., 1999, Beach cusp morphology on sand and mixed sand and gravel beaches, South Island, New Zealand. *Mar Geol*, 157(3–4):185–98.
- Mandal, S., Prabaharan, N., 2006, Ocean wave forecasting using recurrent neural networks. *Ocean Eng*, 33(10):1401–10.
- Şahin, V., Vardar, N., 2020, Determination of wastewater behavior of large passenger ships based on their main parameters in the pre-design stage. *J Mar Sci Eng*, 8(8):1–18.
- Venkatramanan, S., Chung, S.Y., Selvam, S., Son, J.H., Kim, Y.J., 2017, Interrelationship between geochemical elements of sediment and شده کومه‌ها طبق نتایج شبکه عصبی ( $R^2=0.79$ ) دقت بالاتری نسبت به نتایج بدست آمده از شبیه سازی عددی ناتز و همکاران (۲۰۲۱) با ( $R^2=0.72$ ) ارائه می‌دهد. این مطلب نمایانگر برتری نتایج شبکه عصبی نسبت به نتایج به دست آمده از مدل سازی عددی است. این میزان اندک خطا حاکی از آن است که شبکه عصبی قادر است، پیش‌بینی‌هایی به مراتب دقیق‌تر در مقایسه با مدل‌های عددی و ضمناً مقرون به صرفه‌تر در مقایسه با مشاهدات میدانی ارائه دهد. به طوریکه که قابلیت بالای شبکه عصبی موجب می‌شود که به عنوان ابزاری کارآمد در تخمین تغییرات دینامیکی منطقه شستشو در وجه ساحل محسوب شود.

## منابع

- Casella, E., Drechsel, J., Winter, C., Benninghoff, M., Rovere, A., 2020, Accuracy of sand beach topography surveying by drones and photogrammetry. *Geo-Marine Lett*, 40(2):255–68.
- Puleo, J.A., Beach, R.A., Holman, R.A., Allen, J.S., 2000, Swash zone sediment suspension and transport and the importance of bore-generated turbulence. *J Geophys Res Ocean*, 105(C7):17021–44.
- Bernabeu Tello, A.M., Santamaría, R.M., Pascual, C.V., 2002, An equilibrium profile model for tidal environments. *Sci Mar*, 66(4):325–35.
- Short, A., 1999, *Hand book of beach and shore face morphodynamics*. university of Sydney.
- Garnier, R., Ortega-Sánchez, M., Losada, M.A., Falqués, A., Dodd, N., 2010 Beach cusps and inner surf zone processes: Growth or destruction? A case study of Trafalgar Beach (Cádiz, Spain). *Sci Mar*, 74(3):539–53.
- Guza, R.T and Inman, D., 1975, Edge Waves and Beach Cusps. *J Geophys Res*, 80(21):2997–3012.
- Inman, D.L., Guza, R.T., 1982, The origin of swash cusps on beaches. *Mar Geol*, 49(1–2):133–48.
- Ciriano, Y., Coco, G., Bryan, K.R., Elgar, S., 2005, Field observations of swash zone infragravity motions and beach cusp evolution. *J Geophys Res Ocean*, 110(2):1–10.
- Sherman, D.J., Orford, J.D., Carter, R., 1993,

- m imagery for estimating suspended sediments concentration in Hangzhou Bay, China. *Environ Geol*, 56(6):1093–101.
- Schmidhuber, J., 2015, Deep Learning in neural networks: An overview. *Neural Networks*, 61:85–117.
- Badde, D.S., Gupta, A., Patki, V.K., 2009, Cascade and Feed Forward Back propagation Artificial Neural Network Models for Prediction of Compressive Strength of Ready Mix Concrete. *IOSR J Mech Civ Eng*, (2278–1684):1–6.
- Howard, D., 2004, Mark B. Neural Network Toolbox Documentation. *Neural Netw Tool*, 846.
- groundwater at Samrak Park Delta of Nakdong River Basin in Korea: multivariate statistical analyses and artificial neural network approaches. *Environ Earth Sci*, 76(13).
- Haykin, S., 2008, *Neural Networks and Learning Machines*. Vol. 3, Pearson Prentice Hall New Jersey USA 936 pLinks.. 906 p.
- Keiner, L.E., Yan, X.H., 1998, A neural network model for estimating sea surface chlorophyll and sediments from thematic mapper imagery. *Remote Sens Environ*, 66(2):153–65.
- Beale, R., Jackson, T., 1990, *Neural Computing: An Introduction*. Neural Computing: CRC, Boca Raton, <https://doi.org/10.1887/0852742622>.
- Wang, F., Zhou, B., Xu, J., Song, L., Wang, X., 2009, Application of neural network and MODIS 250

## Prediction of the multi-level beach cusp spacing using artificial neural networks

Azadeh Valipour <sup>1\*</sup> and Hossein Shirgahi <sup>2</sup>

<sup>1</sup> Assistant Professor, Department of Marine Science and Technology, Jouybar Branch, Islamic Azad University, Jouybar, Iran

<sup>2</sup> Assistant Professor, Department of Computer Engineering, Jouybar Branch, Islamic Azad University, Jouybar, Iran

(Received: 23 February 2023, Accepted: 09 July 2023)

### Summary

Beach cusps are rhythmic wave-shaped features usually observable on the beach face. These features in the swash zone are so variable in terms of space and time due to wave attacks and tides. In this study, an artificial neural network was used to fully understand the behavior of multi-level beach cusps on the beach face. A neural network is a soft computing method for solving problems as an intelligent system that can learn, remember, and create relationships between different data. In this research, the parameters related to the beach cusps were recorded as the input of the neural network model, including the cusp amplitude, cusp elevation, and cusp depth in the lower, middle, and upper levels of the beach, as well as the cusps spacing as the output of the model. To achieve the goal of this research to predict the cusps spacing, the performance of three back-propagation neural network models was investigated in different functions and neurons. Then, relevant statistical criteria were calculated and compared at each stage. Back-propagation learning is an iterative search process that adjusts the weights from the output layer to the input layer in each run until no further improvement in the error value is found. The main results of this research indicate an excellent agreement between the results of the neural network model and the recorded values of the cusps spacing in the field observations. The comparison of the scatter plots related to the values of the predicted spacings of beach cusps against the values of the observed spacings in different parts of the swash zone on the beach face indicates that the accuracy of the results of the neural network in the upper part of the beach face is the highest. These results are perfectly consistent with other researchers' results who introduced the lower part affected by tides. The evaluation of the graphs related to the trend of statistical criteria changes in different neural network models in the whole simulation indicates that the accuracy of neural network results is the highest to the lowest in Elman back propagation (Elman BP), Feed-forward back propagation, and CFBP, respectively. Scatter plots related to the predicted spacings of cusps by the Cascade-forward back propagation (CFBP) model (lm optimum function) against other parameters of beach cusps show that there is a strong correlation between the cusps spacing with all the morphological parameters of the beach cusps system, especially the cusp elevation on the beach face. Another result of this research using a comparison of the radar charts related to different statistical criteria in the different stages indicates that the functions provide various accuracy in the predicted results depending on the type of selected models in the different stages of the testing, evaluation, and training.

**Keywords:** Beach face, swash zone, Elman back propagation, Feed-forward back propagation, Cascade-forward back propagation